

Identification of dental conditions in panoramic radiographs using a deep learning algorithm

Mohaddeseh Mesvari¹, Mehdi Akhoondzadeh Hanzaie^{2*}

1- PhD Student, Department of Photogrammetry and Remote Sensing, Faculty of Mapping and Geospatial Information Engineering, Technical College, University of Tehran, Tehran, Iran

2- Associate Professor, Department of Photogrammetry and Remote Sensing, Faculty of Mapping and Geospatial Information Engineering, Technical College, University of Tehran, Tehran, Iran

Article Info

Article type:
Research Article

Article History:
Received: 18 Apr 2026
Accepted: 1 Aug 2026
Published: 11 Aug 2026

Corresponding Author:
Mehdi Akhoondzadeh Hanzaie

Department of Photogrammetry and
Remote Sensing, Faculty of Mapping
and Geospatial Information
Engineering, Technical College,
University of Tehran, Tehran, Iran

(Email: makhonz@ut.ac.ir)

Abstract

Background and Aims: Panoramic radiographs are routinely used for the assessment of dental conditions; however, their manual interpretation is time-consuming and highly dependent on the clinician's expertise. This study aimed to develop a deep learning-based U-Net framework for the automatic segmentation of four common dental conditions: dental caries, dental fillings, root canal-treated teeth, and impacted third molars.

Materials and Methods: This study was designed as the development of an applied model and was conducted in 2021 at the University of Tehran. Panoramic dental images were collected from publicly available sources. Two dentists collaboratively annotated the images and assigned labels corresponding to four dental conditions: dental caries, dental fillings, root canal treatment, and impacted wisdom teeth. To prevent data leakage, 10% of the entire dataset were initially reserved as an independent test set. Data augmentation were then applied exclusively to the training and validation data. Following augmentation, the remaining dataset were split into training and validation sets using an 80:20 ratio, respectively. A modified U-Net model was trained using preprocessed images resized to 512×512 pixels. Model performance was evaluated using Recall, precision, F1-score, and accuracy.

Results: The proposed model demonstrated promising performance in detecting the four target conditions. F1-scores, which were considered the primary performance metric because of potential class imbalance, were 73.56% for caries, 92.2% for fillings, 87.1% for impacted wisdom teeth, and 76.0% for root canal treatment. Precision values were 79.74%, 97.5%, 77.0%, and 61.2%, respectively, while accuracy values ranged from 98.4% to 99.5%.

Conclusion: The proposed U-Net-based framework demonstrated promising performance for the automated identification of dental conditions in panoramic radiographs and might facilitate computer-aided dental screening and treatment planning. Further validation using larger and more heterogeneous datasets are required to enhance the model's generalizability.

Keywords: Dental caries, Dental fillings, Root canal treatment, Impacted third molar, Panoramic radiography, Deep learning

Cite this article as: Mesvari M, Akhoondzadeh Hanzaie M. Identification of dental conditions in panoramic radiographs using a deep learning algorithm. J Dent Med-TUMS. 2026;39:30. [Persian]



شناسایی وضعیت‌های دندانی در تصاویر رادیوگرافی پانورامیک با استفاده از الگوریتم یادگیری عمیق

محدثه مسواری^۱، مهدی آخوندزاده هنزائی^{۲*}

۱- دانشجوی دکتری، گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران، تهران، ایران
۲- دانشیار، گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران، تهران، ایران

چکیده	اطلاعات مقاله
زمینه و هدف: تصاویر رادیوگرافی پانورامیک به طور گسترده برای ارزیابی وضعیت‌های دندانی استفاده می‌شوند، اما تفسیر دستی آن‌ها زمان‌بر و وابسته به تجربه بالینی است. این پژوهش با هدف توسعه یک چارچوب یادگیری عمیق مبتنی بر U-Net برای قطعه بندی خودکار چهار وضعیت دندانی شامل پوسیدگی دندان، ترمیم‌های دندانی، دندان‌های تحت درمان ریشه و دندان‌های مولر سوم نهفته انجام شد. روش بررسی: این پژوهش از نوع توسعه یک مدل کاربردی بود که در سال ۱۴۰۰ توسط پژوهشگران دانشگاه تهران انجام شد. تصاویر پانورامیک از منابع عمومی در دسترس گردآوری شدند. دو دندانه‌شک به طور مشارکتی فرایند برچسب گذاری و تعیین کلاس هدف شامل چهار وضعیت دندانی شامل پوسیدگی، پرکردگی، درمان ریشه و دندان عقل نهفته را انجام دادند. برای جلوگیری از data leakage، ابتدا ۱۰ درصد از مجموعه داده به عنوان مجموعه آزمایشی از کل داده‌ها جدا شد و سپس فرایند افزایش داده صرفاً بر روی مجموعه آموزش و اعتبارسنجی انجام گرفت. پس از افزایش داده، مجموعه داده با نسبت ۸۰ به ۲۰ درصد به ترتیب به داده‌های آموزشی و اعتبارسنجی افزاز گردید. مدل U-Net اصلاح شده بر روی تصاویر پیش پردازش شده ۵۱۲×۵۱۲ آموزش داده شد و عملکرد آن با معیارهای با استفاده از معیارهای حساسیت (Recall)، دقت مثبت (Precision)، امتیاز F1 و صحت (Accuracy) ارزیابی شد. یافته‌ها: مدل پیشنهادی در هر چهار وضعیت دندانی عملکرد امیدوار کننده‌ای نشان داد. با توجه به نامتوازن بودن نسبی داده‌ها، معیار اصلی تفسیر عملکرد مدل F1-score در نظر گرفته شد، به طوری که مقادیر آن برای پوسیدگی، پرکردگی، دندان عقل نهفته و درمان ریشه به ترتیب ۰.۷۳/۵۶، ۰.۹۲/۲، ۰.۸۷/۱ و ۰.۷۶/۰ درصد بود. مقادیر Precision نیز به ترتیب ۰.۷۹/۷۴، ۰.۹۷/۵، ۰.۹۷/۰ و ۰.۶۱/۲ درصد و Accuracy بین ۰.۹۸/۴ تا ۰.۹۹/۵ درصد گزارش شد. نتیجه گیری: چارچوب پیشنهادی مبتنی بر U-Net توانست عملکرد مناسبی در شناسایی خودکار وضعیت‌های دندانی در تصاویر پانورامیک نشان دهد و می‌تواند در غربالگری دندانی به کمک رایانه و برنامه‌ریزی درمان مورد استفاده قرار گیرد. با این حال، ارزیابی مدل بر روی مجموعه داده‌های بزرگ‌تر و ناهمگن‌تر برای بهبود تعمیم‌پذیری ضروری است. کلید واژه‌ها: پوسیدگی دندان، پرکردگی دندان، درمان ریشه، دندان عقل نهفته، رادیوگرافی پانورامیک، یادگیری عمیق	نوع مقاله: مقاله پژوهشی دریافت: ۱۴۰۵/۰۱/۲۹ پذیرش: ۱۴۰۵/۰۵/۱۰ انتشار: ۱۴۰۵/۰۵/۲۰ نویسنده مسؤول: مهدی آخوندزاده هنزائی گروه فتوگرامتری و سنجش از دور، دانشکده مهندسی نقشه برداری و اطلاعات مکانی، دانشکده فنی، دانشگاه تهران، تهران، ایران (Email: makhonz@ut.ac.ir)

مقدمه

امروزه یکی از مسائل مهم در علوم پزشکی و دندانپزشکی، تشخیص به موقع بیماری‌ها جهت پیشگیری و کمک به فرایند درمان است. سلامت دهان و دندان یکی از مؤلفه‌های مهم سلامت عمومی است و آمار مربوط به بیماری‌های دهان و دندان در سطح جهانی همچنان بالا گزارش می‌شود. بر اساس گزارش سازمان جهانی بهداشت، بیماری‌های دهان و دندان نزدیک به $\frac{3}{7}$ میلیارد نفر را در جهان تحت تأثیر قرار داده‌اند و پوسیدگی درمان نشده دندان‌های دائمی همچنان یکی از شایع‌ترین مشکلات سلامت در سرتاسر جهان محسوب می‌گردد (۱،۲). بنابراین، بر اساس مطالعات و بررسی‌های صورت گرفته، همواره درصد بالایی از افراد یک جامعه به بیماری‌های دهان و دندان دچار می‌گردند (۳). تحقیقات صورت گرفته به رابطه احتمالی سلامت دهان و بروز مسائلی همچون بیماری‌های قلبی، به دنیا آمدن نوزادان نارس و نوزادان دچار کمبود وزن اشاره دارد. با وجود مطالعات صورت گرفته در مورد ارتباط بین سلامت دهان و دندان و سلامت عمومی فرد، این بیماری‌ها به خودی خود نیز می‌تواند باعث ایجاد مشکلات تغذیه، درد دهان و صورت، عفونت و زخم گلو، سرطان دهان، بیماری لثه و همچنین نقص زیبایی و به تبع آن ایجاد مشکل در روابط اجتماعی گردد (۴-۶). از این رو، استفاده از ابزارهای کمکی برای شناسایی سریع‌تر و دقیق‌تر وضعیت‌های دندانی در تصویربرداری رادیولوژیک اهمیت زیادی دارد.

پوسیدگی دندان یک بیماری تخریبی است که غالباً توسط باکتری‌های *Lactobacillus acidophilus* در اثر مصرف مواد قندی و عدم رعایت بهداشت دهان و دندان ایجاد می‌گردد. چندین عامل درونی و بیرونی در توسعه و پیشرفت پوسیدگی دندان نقش دارند. این ضایعه به شدت به سبک زندگی و رژیم غذایی افراد وابسته است. پوسیدگی دندان فرایند پیچیده‌ای است که در این فرایند در نتیجه تخمیر کربوهیدرات‌ها به وسیله متابولیسم باکتریایی، اسید تولید می‌شود. دیمینرالیزاسیون بافت‌های سخت در نتیجه این حمله اسیدی رخ می‌دهد (۷). همچنین دندان‌هایی که به علت تجويز دارو، شکستگی، خوردگی و یا فشار زیاد به مرور زمان دچار حفره و یا ترک می‌شوند و یا به مرور زمان دچار پوسیدگی می‌گردند، با استفاده از موادی مانند کامپوزیت و یا آمالگام پر می‌شوند. در صورتی که عصب‌های دندان به دلیل عفونت باکتریایی، شکستگی و یا ترمیم‌های قدیمی تحت فشار قرار گرفته باشد،

فرایند عصب کشی با حذف و پاکسازی و سپس استفاده از کامپوزیت و یا فلز جهت استحکام و کارایی بهتر دندان انجام می‌شود (۸). در صورت وجود مشکلاتی مانند کمبود فضا در دهان، انحراف در رشد دندان‌ها و یا آسیب دیدن دندان‌های مجاور، ممکن است دندان عقل درون لثه قرار گرفته و به صورت کامل در سطح دهان ظاهر نشود. این دندان ممکن است باعث بروز درد، عفونت و یا فشار بر دندان‌های مجاور گردد و در برخی از موارد امر تشخیص را دشوار سازد. به عبارت دیگر، دندان نهفته دندانی است که به واسطه یک مانع یا سد فیزیکی در مسیر رویش از رشد بازمانده است. شایع‌ترین دندان‌های نهفته، مولرهای سوم فک بالا و پایین و سپس کانین‌های فک بالا و پر مولرهای فک پایین هستند. عوامل مختلفی مانند تجمع دندانی، موقعیت نامناسب جوانه دندانی، دندان‌های اضافه، فقدان فضا در قوس دندانی کیست‌ها، ریشه‌های دندان تحلیل نرفته و عادت‌های دهانی مثل مکیدن انگشت عامل ایجاد نهفتگی دندان دانسته شده است (۹-۱۳).

در تصاویر پانورامیک، برخی یافته‌ها ماهیت بیماری‌زا دارند، مانند پوسیدگی و دندان عقل نهفته، در مقابل، برخی موارد از جنس وضعیت‌ها یا یافته‌های درمانی‌اند، مانند پرکردگی و درمان ریشه. در مطالعه حاضر، برای پرهیز از ابهام، از اصطلاح وضعیت‌های دندانی برای اشاره به مجموعه این یافته‌ها استفاده شده است. تشخیص صحیح این وضعیت‌ها می‌تواند در غربالگری، برنامه‌ریزی درمان و کاهش خطای انسانی مؤثر باشد. تفسیر دستی تصاویر پانورامیک، به ویژه در حضور هم پوشانی ساختارهای آناتومیک، تغییرات کنتراست، نویز و تفاوت کیفیت بین دستگاه‌های تصویربرداری، فرایندی زمان بر و وابسته به تجربه بالینی است. در سال‌های اخیر، روش‌های یادگیری عمیق و به ویژه شبکه‌های پیچشی (Convolutional) توانسته‌اند به عنوان ابزار کمکی در تحلیل خودکار تصاویر دندانی مورد توجه قرار گیرند (۱۴-۱۸).

در جهت بهبود سرعت و دقت در تشخیص بیماری‌ها و ارزیابی وضعیت دهان و دندان، استفاده از شبکه‌های یادگیری عمیق و پردازش‌های هوشمند به طور قابل توجهی توسعه یافته است. این فناوری‌ها با خودکارسازی تحلیل تصاویر رادیوگرافیک، موجب افزایش کارایی و یکنواختی تشخیص شده و در بسیاری موارد به‌عنوان جایگزین یا مکمل روش‌های سنتی مانند تفسیر تصاویر پانورامیک توسط متخصصان یا تحلیل‌های آماری مورد استفاده قرار می‌گیرند (۱۸-۲۳).

ادغام الگوریتم‌های کامپیوتری و هوش مصنوعی در تشخیص بیماری‌های دندان به طور چشمگیری دندانپزشکی مدرن را پیش برده و دقت، کارایی و مراقبت‌های شخصی سازی شده از بیماران را بهبود بخشیده است. سیستم‌های مبتنی بر هوش مصنوعی می‌توانند تصاویر دندان، از جمله تصاویر اشعه ایکس و اسکن‌های سه بعدی را با دقت بسیار بالایی تجزیه و تحلیل کنند و امکان تشخیص زود هنگام مواردی مانند پوسیدگی‌ها، بیماری‌های پریودنتال و سرطان‌های دهان را فراهم آورند. این الگوریتم‌ها با شناسایی الگوهای ظریفی که ممکن است توسط متخصصان انسانی نادیده گرفته شوند، خطر تشخیص نادرست را کاهش می‌دهند. علاوه بر این، ابزارهای هوش مصنوعی در برنامه‌ریزی درمان نیز کمک می‌کنند و با پیش‌بینی پیشرفت بیماری و توصیه رویکردهای مداخله‌ای بهینه، نقش مهمی ایفا می‌کنند. این پیشرفت تکنولوژیکی نه تنها نتایج بیماران را بهبود می‌بخشد، بلکه فرآیندهای کاری متخصصان دندانپزشکی را نیز بهینه کرده و دسترسی به مراقبت‌های دندان با کیفیت بالا را آسان‌تر و مؤثرتر می‌سازد (۱۴). امروزه شبکه‌های عصبی پیچشی (Convolutional Neural Networks (CNN)) کاربردهای گسترده‌ای در تشخیص هرچه سریع‌تر و دقیق‌تر بیماری‌ها یافته‌اند (۲۴-۲۶). در این مقاله جهت تشخیص بیماری‌های دهان و دندان از پتانسیل‌های موجود در شبکه عصبی عمیق استفاده شده است، تا از یک سو مدت زمان فرایند درمان کوتاه‌تر و از سوی دیگر با افزایش دقت در روند تشخیص بیماری، طرح درمانی با اطمینان بالاتر و مطلوب‌تر انجام گیرد.

در سال ۲۰۰۸ Devito و همکاران (۲۷) به بررسی کاربرد شبکه عصبی پرسپترون چند لایه (Multilayer perceptron neural network) جهت تشخیص دندان‌های پوسیده با استفاده از تصاویر رادیوگرافی پرداختند. در این تحقیق از میکروسکوپ‌های نوری جهت تشخیص پوسیدگی‌ها و انجام فرایند برچسب گذاری استفاده شده است. در نهایت، مقایسه‌ای میان نتایج حاصل از شبکه عصبی و نظر ۲۵ کارشناس صورت گرفته که در نتیجه این امر دقت تشخیص بیماری توسط شبکه عصبی نسبت به کارشناسان بالاتر بوده است. Ali و همکاران (۲۸) در سال ۲۰۱۶ برای نخستین بار به کمک تصاویر رادیوگرافی پانورامیک و شبکه عصبی عمیق به تشخیص و طبقه بندی پوسیدگی‌های دندان اقدام کردند. نتایج حاصل از این روش در دو کلاس دندان‌های پوسیده

(پوسیدگی کامل) و غیر پوسیده ارائه شده‌اند (۲۹). در سال ۲۰۱۹ Bouchahma و همکاران (۳۰) با استفاده از ۲۰۰ تصویر اشعه ایکس (X-ray) به بررسی کاربرد یک مدل یادگیری عمیق در پیش بینی پوسیدگی دندان‌ها پرداخت و حالات مختلف آن را مورد بررسی قرار داد. نهایتاً وی برای هریک از این نتایج به دست آمده طرح درمانی متناسب با میزان پوسیدگی ارائه داد که دقت کلی این روش‌ها ۸۷ درصد بوده و در این میان طرح درمان با فلوراید با دقت ۹۸ درصد بالاترین میزان دقت و طرح پرکردن دندان کم‌ترین میزان دقت (۷۷ درصد) را داشته است. Ghaznavi Bidgoli و همکاران (۳۱) در سال ۲۰۲۰ با اعمال دو شبکه VGGNet16 و AlexNet و با ایجاد یک مجموعه داده آموزشی مناسب، اقدام به طبقه بندی دندان‌ها در ۴ کلاس دندان‌های سالم، پوسیده، عصب کشی شده و شکسته نمودند. این روش عملکرد مناسبی در روند شناسایی کلاس‌های مختلف از خود نشان داده است (دقت ۹۲ درصد). در سال ۲۰۲۳ طی تحقیقی که توسط Zhu و همکاران (۱۶) انجام شده است، یک چهارچوب هوش مصنوعی بر اساس دو شبکه عصبی عمیق پیچشی BDU-Net و annU-Net جهت تشخیص بیماری‌های دهان و دندان توسعه داده شده است. این روش در تشخیص دندان‌های تحت فشار، تاج‌های کامل، دندان‌های نهفته و ریشه‌های باقی مانده با دقت بالا عمل نموده و کارایی آن با نظرات دندانپزشکان با ۳ تا ۱۰ سال سابقه کار مقایسه شده است. عملکرد این روش به کمک معیارهای Recall و دقت برای هر بیماری بررسی شده است. Meem و همکاران (۳۲) نیز در این سال به کمک روش‌های یادگیری انتقالی به تشخیص بیماری‌های دهان و دندان با استفاده از تصاویر رادیوگرافی پرداختند. شش مدل یادگیری انتقالی شامل Resnet50، VGG16، Densenet201 و EfficientnetB7، Xception، InceptionV3 به منظور شناسایی نواقص موجود استفاده شدند. در این میان، مدل Densenet201 دقت بالاتری (برابر با ۹۸ درصد) حاصل نموده و عملکرد آن نیز زمان‌برتر بوده است؛ این در حالی است که مدل InceptionV3 بهترین تعادل بین زمان و دقت را فراهم نموده است. این امر در مطالعه مذکور بیان‌گر این مطلب است که یادگیری انتقالی، همراه با مدل‌های یادگیری عمیق، پتانسیل بالایی در تشخیص مؤثر بیماری‌های دندان را داراست.

تشخیص بیماری‌های دهان و دندان همچنان یکی از چالش‌های

مهم در دندانپزشکی مدرن به شمار می‌رود، به ویژه به دلیل پیچیدگی تصاویر رادیوگرافیک، همپوشانی ساختارها و وابستگی نتایج به تجربه تشخیص دهنده. از این رو، در سال‌های اخیر مطالعات متعددی با هدف بهبود دقت، سرعت و یکنواختی تشخیص در این حوزه انجام شده است (۳۶-۳۳). در گذشته، روش‌های کلاسیک پردازش تصویر به صورت عمده با هدف بهبود کیفیت تصاویر و استخراج ویژگی‌های دستی به منظور کمک به فرآیند تشخیص مورد استفاده قرار می‌گرفتند. در مقابل، در سال‌های اخیر با پیشرفت هوش مصنوعی و به ویژه یادگیری عمیق، فرآیند تحلیل تصاویر دندانی به صورت خودکار و مبتنی بر یادگیری ویژگی‌ها توسط مدل انجام می‌شود که منجر به بهبود دقت و کارایی تشخیص شده است (۴۰-۳۷). اغلب این روش‌های مبتنی بر هوش مصنوعی در راستای طبقه‌بندی بیماری‌های دهان و دندان عمل نموده و کلاس‌های محدودی از بیماری‌ها را مورد مطالعه قرار داده‌اند. بنابراین محل دقیق این بیماری‌ها در اغلب این روش‌ها مورد بررسی قرار نگرفته است. این امر موجب می‌شود که شدت و ضعف بیماری شناسایی شده به خوبی تشخیص داده نشود و به تبع منجر به ارائه راهکارهای درمانی نامناسب گردد.

با وجود این پیشرفت‌ها، بسیاری از مطالعات موجود یا بر تعداد محدودی از کلاس‌ها تمرکز کرده‌اند، یا خروجی آن‌ها در سطح طبقه‌بندی کلی بوده و محل دقیق ناحیه هدف را در تصویر مشخص نکرده‌اند. علاوه بر این، استفاده از مجموعه داده‌های عمومی و ناهمگن در پژوهش‌های جدید نشان داده است که تعمیم‌پذیری مدل‌ها همچنان به کیفیت داده و روش برچسب‌گذاری وابسته است (۴۳-۴۱). از میان معماری‌های رایج، U-Net به دلیل ساختار رمزگذار-رمزگشا و اتصالات پرشی برای مسائل قطعه‌بندی پزشکی انتخاب مناسبی است و در مطالعات اخیر مرتبط با تصاویر پانورامیک نیز عملکرد امیدوارکننده‌ای نشان داده است (۴۴). در عین حال، ناهمگنی کیفیت تصاویر، تفاوت در پروتکل‌های برچسب‌گذاری و کمبود داده‌های برچسب‌خورده با کیفیت بالا، هنوز از چالش‌های مهم این حوزه محسوب می‌شوند (۴۲، ۴۱).

با توجه به محدودیت برخی مطالعات پیشین در شناسایی هم‌زمان چند وضعیت دندانی و نیز نبود تعیین دقیق محل ضایعه در سطح تصویر، هدف این پژوهش توسعه و ارزیابی یک چارچوب مبتنی بر U-Net برای شناسایی و قطعه‌بندی پیکسلی چهار وضعیت دندانی در تصاویر

رادیوگرافی پانورامیک بود. این مطالعه با تمرکز بر پوسیدگی، پرکردگی، درمان ریشه و دندان عقل نهفته انجام شد و می‌تواند زمینه‌ساز توسعه ابزارهای مختلف برای غربالگری و برنامه‌ریزی درمان در دندانپزشکی باشد.

روش بررسی

طراحی مطالعه، داده‌ها و پیش‌پردازش

این پژوهش از نوع توسعه یک مدل کاربردی یادگیری عمیق بود که در سال ۱۴۰۰ توسط پژوهشگران دانشگاه تهران انجام شد. تصاویر پانورامیک مورد استفاده از منابع عمومی در دسترس گردآوری شدند (۴۸-۴۵). در کل حدود ۶۰۰ تصویر پانورامیک جمع‌آوری شد. پس از بررسی اولیه کیفیت، حدود ۱۰۰ تصویر به دلیل نویز زیاد، کیفیت پایین یا نامناسب بودن برای برچسب‌گذاری حذف شدند و ۵۰۰ تصویر وارد فرایند نهایی شدند. در این پژوهش، مجموعه داده مورد استفاده صرفاً از منابع عمومی در دسترس تهیه شد و هیچ تصویر اختصاصی دریافت شده از مراکز درمانی یا دانشگاهی وارد تحلیل نهایی نشد. در فرایند بازبینی داده‌ها، حدود ۱۵۰ تصویر از مجموعه اولیه به دلیل کیفیت نامناسب، نویز، یا عدم انطباق با معیارهای ورود به مطالعه حذف گردید و ۳۵۰ تصویر باقی‌مانده برای استخراج نواحی هدف مورد استفاده قرار گرفت. این تصاویر پیچ‌بندی شدند و پیچ‌های متناظر با وضعیت‌های مختلف دندانی استخراج گردیدند. بر این اساس، از مجموعه تصاویر باقی‌مانده، ۲۷۵ پیچ مربوط به پرکردگی، ۲۹۸ پیچ مربوط به دندان عقل نهفته، ۳۱۰ پیچ مربوط به درمان ریشه و ۴۲۰ پیچ مربوط به پوسیدگی استخراج شد. از آنجا که تصاویر مورد استفاده به صورت عمومی در اختیار پژوهش قرار گرفتند، اطلاعات جمعیت شناختی بیماران از جمله سن، جنس و سایر ویژگی‌های فردی در دسترس نبود، بنابراین، ارزیابی تنوع جمعیتی مجموعه داده در این پژوهش امکان‌پذیر نبود.

برای بهبود کیفیت داده‌های آموزشی کلاس پوسیدگی، فرایند آموزش مدل برای وضعیت پوسیدگی با استفاده از دیتاست عمومی که در مطالعه Wang و همکاران (۴۹) به کار گرفته شده است، تکرار شد. این دیتاست شامل ۲۳۸۹ پیچ تصویر مربوط به پوسیدگی دندان به همراه لیبل‌های متناظر است و برای مسئله قطعه‌بندی پوسیدگی که از جمله وضعیت‌های دندانی حساس در حوزه دندانپزشکی است، ارائه شده است.

بنابراین، آموزش و ارزیابی مدل بر پایه داده‌های عمومی، ناشناس و فاقد اطلاعات هویتی بیماران انجام شد.

برای جلوگیری از data leakage، ابتدا ۱۰ درصد از مجموعه داده به عنوان مجموعه آزمایشی از کل داده‌ها جدا شد و سپس عملیات افزایش داده صرفاً بر روی مجموعه آموزش و اعتبارسنجی انجام گرفت. این عملیات یکی از گام‌های اساسی پیش از آموزش مدل است و می‌تواند به ایجاد یک مدل جامع در راستای هدف مدنظر کمک نماید.

با توجه به ماهیت آناتومیک تصاویر رادیوگرافی پانورامیک، در این مطالعه از یک پروتکل افزایش داده یکسان برای تمام وضعیت‌های دندان‌های استفاده نشد، بلکه نوع و شدت تبدیل‌ها متناسب با ویژگی‌های تصویری و بالینی هر کلاس تعیین گردید. اصل اساسی در انتخاب تکنیک‌های افزایش داده، حفظ اعتبار آناتومیک تصویر و جلوگیری از ایجاد نمونه‌های غیر واقعی بود، به گونه‌ای که پس از اعمال هر تبدیل، انطباق میان تصویر و ماسک برچسب حفظ شود و برچسب تولید شده همچنان از نظر تشخیصی معتبر باقی بماند.

برای وضعیت پوسیدگی، به دلیل کوچک بودن ضایعات، کنتراست نسبتاً پایین، مرزهای نامشخص و شباهت احتمالی آن با برخی تغییرات ساختاری دندان، از تبدیل‌های هندسی شدید استفاده نشد. افزایش داده در این کلاس عمدتاً به تغییرات محافظه کارانه شدت تصویر، شامل تغییر محدود روشنایی و کنتراست، افزودن نویز گاوسی خفیف و تغییر مقیاس یا برش محدود در سطح پیچ‌ها محدود شد. برای کلاس پرکردگی، با توجه به اینکه پرکردگی‌ها معمولاً به صورت نواحی با کنتراست نسبتاً بالا در تصاویر پانورامیک مشاهده می‌شوند، علاوه بر تغییرات محدود روشنایی، کنتراست و نویز خفیف، از تغییر مقیاس محدود و چرخش بسیار کوچک نیز استفاده شد. در مواردی که داده‌ها به صورت پیچ‌های موضعی و مستقل از سمت آناتومیک پردازش شدند، وارونگی افقی به صورت محدود قابل استفاده بود. با این حال، وارونگی قائم و تغییرات هندسی شدید به دلیل ایجاد ساختارهای غیرواقعی در فرایند افزایش داده حذف مد نظر قرار نگرفتند.


بنابراین، آموزش و ارزیابی مدل بر پایه داده‌های عمومی، ناشناس و فاقد اطلاعات هویتی بیماران انجام شد.

برای جلوگیری از data leakage، ابتدا ۱۰ درصد از مجموعه داده به عنوان مجموعه آزمایشی از کل داده‌ها جدا شد و سپس عملیات افزایش داده صرفاً بر روی مجموعه آموزش و اعتبارسنجی انجام گرفت. این عملیات یکی از گام‌های اساسی پیش از آموزش مدل است و می‌تواند به ایجاد یک مدل جامع در راستای هدف مدنظر کمک نماید.

با توجه به ماهیت آناتومیک تصاویر رادیوگرافی پانورامیک، در این مطالعه از یک پروتکل افزایش داده یکسان برای تمام وضعیت‌های دندان‌های استفاده نشد، بلکه نوع و شدت تبدیل‌ها متناسب با ویژگی‌های تصویری و بالینی هر کلاس تعیین گردید. اصل اساسی در انتخاب تکنیک‌های افزایش داده، حفظ اعتبار آناتومیک تصویر و جلوگیری از ایجاد نمونه‌های غیر واقعی بود، به گونه‌ای که پس از اعمال هر تبدیل، انطباق میان تصویر و ماسک برچسب حفظ شود و برچسب تولید شده همچنان از نظر تشخیصی معتبر باقی بماند.

برای وضعیت پوسیدگی، به دلیل کوچک بودن ضایعات، کنتراست نسبتاً پایین، مرزهای نامشخص و شباهت احتمالی آن با برخی تغییرات ساختاری دندان، از تبدیل‌های هندسی شدید استفاده نشد. افزایش داده در این کلاس عمدتاً به تغییرات محافظه کارانه شدت تصویر، شامل تغییر محدود روشنایی و کنتراست، افزودن نویز گاوسی خفیف و تغییر مقیاس یا برش محدود در سطح پیچ‌ها محدود شد. برای کلاس پرکردگی، با توجه به اینکه پرکردگی‌ها معمولاً به صورت نواحی با کنتراست نسبتاً بالا در تصاویر پانورامیک مشاهده می‌شوند، علاوه بر تغییرات محدود روشنایی، کنتراست و نویز خفیف، از تغییر مقیاس محدود و چرخش بسیار کوچک نیز استفاده شد. در مواردی که داده‌ها به صورت پیچ‌های موضعی و مستقل از سمت آناتومیک پردازش شدند، وارونگی افقی به صورت محدود قابل استفاده بود. با این حال، وارونگی قائم و تغییرات هندسی شدید به دلیل ایجاد ساختارهای غیرواقعی در فرایند افزایش داده حذف مد نظر قرار نگرفتند.

برای کلاس درمان ریشه، به دلیل اهمیت امتداد ریشه‌ها، موقعیت کانال‌های درمان شده و الگوی خطی مواد پرکننده داخل کانال، از تبدیل‌هایی که جهت‌گیری طبیعی ریشه را به طور قابل توجه تغییر دهند استفاده نشد. بنابراین، افزایش داده در این کلاس شامل تغییرات




شکل ۱- نمونه ای از تصویر پانورامیک (۱) قبل و (۲) بعد از بهبود کنتراست

فرایند برچسب گذاری تصاویر با مشارکت دو دندانپزشک متخصص دارای تحصیلات دکتری تخصصی دندانپزشکی و بیش از ۳۰ سال سابقه کاری انجام شد. یکی از دندانپزشکان دارای تخصص جراحی و دیگری

به زیرگروه‌هایی مانند آمالگام و کامپوزیت انجام نشد، زیرا برچسب‌های موجود برای آموزش مدل در سطح وجود ناحیه پرکردگی تعریف شده بودند و اطلاعات اختصاصی درباره جنس ماده ترمیمی برای همه نمونه‌ها در دسترس نبود. بنابراین، مدل پیشنهادی برای تشخیص و قطعه بندی کلی نواحی پرکردگی توسعه داده شد و نباید به عنوان ابزاری برای تعیین نوع ماده ترمیمی تفسیر شود. با توجه به اینکه مواد ترمیمی مختلف، از جمله آمالگام و کامپوزیت، می‌توانند در تصاویر رادیوگرافی درجات متفاوتی از رادیوپسسته و ظاهر تصویری داشته باشند، تفکیک این مواد می‌تواند در مطالعات آینده به عنوان یک هدف مستقل مورد بررسی قرار گیرد. در پژوهش‌های آتی، در صورت دسترسی به داده‌های برچسب خورده کافی و تأیید بالینی نوع ماده ترمیمی، می‌توان کلاس پرکردگی را به زیرکلاس‌هایی مانند پرکردگی آمالگام و پرکردگی کامپوزیت تقسیم کرد و عملکرد مدل را برای هر یک به صورت جداگانه ارزیابی نمود. برای هر تصویر، ماسک‌های متناظر با نواحی هدف تولید شد و پس از بازبینی و نهایی سازی برچسب‌ها، این ماسک‌ها برای آماده سازی داده‌ها و آموزش مدل U-Net مورد استفاده قرار گرفتند.

مطالعه حاضر با بهره‌گیری از تصاویر پانورامیک و یک معماری U-Net اصلاح شده، بر شناسایی چهار وضعیت دندانی در سطح پیکسل تمرکز دارد. تفاوت اصلی این پژوهش با بسیاری از مطالعات موجود در آن است که خروجی مدل صرفاً یک برچسب کلاسی نیست، بلکه محل دقیق ناحیه هدف نیز در تصویر مشخص می‌شود، موضوعی که می‌تواند برای تفسیر بالینی و تصمیم‌گیری درمانی مفید باشد. این مطالعه به کمک تصاویر پانورامیک و شبکه عصبی عمیق که پتانسیل بالایی در فرایند تشخیص و قطعه بندی داراست، به شناسایی ۴ کلاس مختلف از وضعیت دندانی شامل پوسیدگی، عصب کشی، عقل نهفته و پرکردگی و مشخص کردن محل دقیق آن‌ها در این تصاویر می‌پردازد. در واقع مطالعه حاضر، یک کاربرد نوآورانه از معماری یادگیری عمیق U-Net را معرفی شده که به‌طور خاص برای قطعه بندی تصاویر پانورامیک به منظور تشخیص دقیق بیماری‌های دندانی طراحی شده است. برخلاف روش‌های سنتی که به بازرسی دستی و روش‌های تصویربرداری استاندارد متکی هستند، رویکرد کلی این مطالعه از قدرت یادگیری عمیق برای خودکارسازی فرایند تشخیص بهره می‌برد و به طور قابل توجهی سرعت و دقت تشخیص‌های دندانی را بهبود می‌بخشد. نوآوری این

دارای تجربه تخصصی در حوزه دندانپزشکی زیبایی بود. این دو متخصص عضو تیم اصلی توسعه مدل نبودند و در تعیین نواحی هدف شامل پوسیدگی، پرکردگی، درمان ریشه و دندان عقل نهفته مشارکت داشتند. در این مطالعه، برچسب گذاری به معنای مشخص کردن پیکسل‌های متعلق به هر وضعیت دندانی بر روی تصاویر پانورامیک بود. با توجه به ماهیت تخصصی و پیکسلی فرایند برچسب گذاری، فرایند برچسب گذاری به صورت مشورتی و مبتنی بر توافق نهایی انجام شد. در مواردی که درباره مرز، وسعت یا ماهیت ناحیه هدف ابهام وجود داشت، تصاویر به صورت مشترک توسط دو دندانپزشک بازبینی شدند و ماسک نهایی پس از بحث تخصصی و رسیدن به اجماع تولید گردید. استفاده از فرایند اجماعی میان دو دندانپزشک باتجربه با هدف کاهش خطای برچسب گذاری و تولید ماسک مرجع نهایی برای آموزش مدل انجام شد. پس از تکمیل برچسب گذاری، ماسک‌های نهایی برای آموزش مدل تولید شد و تصاویر و برچسب‌ها وارد مرحله نرمال سازی و آماده سازی نهایی شدند. شکل ۲ نمونه‌ای از تصویر اصلی و خروجی برچسب گذاری را نشان می‌دهد.



شکل ۲- نمونه‌ای از تصویر پانورامیک و خروجی برچسب گذاری شده

برچسب گذاری تصاویر با استفاده از نرم افزار CVAT (Computer Vision Annotation Tool) انجام شد. تصاویر پانورامیک با فرمت png وارد نرم افزار شدند و نواحی مربوط به هر یک از چهار وضعیت دندانی شامل پوسیدگی، پرکردگی، درمان ریشه و دندان عقل نهفته به صورت پیکسلی مشخص گردیدند. در این مطالعه، پرکردگی به عنوان یک کلاس کلی برای نواحی دندانی ترمیم شده تعریف شد و هدف مدل، قطعه بندی نواحی قابل مشاهده پرکردگی در تصاویر پانورامیک بود. در طراحی این پژوهش، تفکیک نوع ماده ترمیمی

تصادفی نورون‌ها استفاده شده است. در این شبکه اطلاعات موجود در تصاویر در مسیر کدگذار استخراج شده و در مسیر کدگشا این ویژگی‌های به دست آمده بازیابی می‌گردند و در نهایت به کمک تابع اتلاف خروجی نهایی شامل کلاس‌های هدف و غیر هدف ایجاد می‌گردد (۵۶). در این مدل در مقایسه با ساختار کلی مدل U-NET، در بخش کدگذار تعداد فیلترها به صورت تصاعدی افزایش یافته تا ویژگی‌های پیچیده‌تر از تصاویر پانورامیک استخراج گردند. این امر سبب می‌گردد که جزئیات بیشتری از تصاویر همچون مرز دندان‌ها و پوسیدگی‌ها شناسایی شوند. همچنین با افزایش تعداد لایه‌های پیش‌بینی توانایی مدل در استخراج ویژگی‌های با وضوح بالاتر از داده‌های پیچیده افزایش یافته است و بعد از هر لایه پیش‌بینی از Batch Normalization جهت کاهش نوسانات در یادگیری و بهبود پایداری مدل استفاده شده است که از بیش‌برازش جلوگیری نموده و افزایش سرعت همگرایی می‌گردد. به علاوه، به جای اتصالات پرشی معمولی، از اتصالات پرشی با مکانیزم توجه (Attention Skip Connections) استفاده شده است که سبب تمرکز بیشتر مدل بر نواحی مهم‌تر (کلاس‌های بیماری) شده است. در بخش کدگشا نیز از فیلترهای بزرگتر (۵×۵ و ۷×۷) در برخی از لایه‌ها استفاده شده است تا مدل توانایی بیشتری در بازسازی نواحی با وضوح بالا داشته باشد. تابع اتلاف مورد استفاده در این شبکه نیز ترکیبی از توابع اتلاف Binary Cross Entropy و Dice Loss است. این تابع اتلاف ترکیبی سبب افزایش توانایی مدل در شناسایی نواحی کوچک و غیر متعادل می‌گردد. این تابع اتلاف تحت عنوان Unified Focal loss است که در قطعه بندی تصاویر پزشکی مورد استفاده قرار می‌گیرد (۵۷). در مسیر کدگشا نیز نهایتاً خروجی‌های شبکه از تابع Sigmoid در لایه آخر عبور داده شده و ویژگی‌های استخراج شده در دو کلاس کلی قرار می‌گیرند. معادله ۱ رابطه مربوط به این تابع را نشان می‌دهد. در این معادله x مقدار ورودی تابع است.


$$\text{Sigmoid } S(x) = \frac{1}{1+e^{-x}} \quad (\text{معادله ۱})$$

همچنین در این شبکه از بهینه‌ساز Adam در فرایند آموزش مدل استفاده شده است. شکل ۳ معماری مربوط به ساختار کلی این شبکه را نشان می‌دهد. در این تحقیق به جای استفاده از یک مدل عمومی،

پژوهش در تطبیق مدل U-Net، که در اصل برای قطعه بندی تصاویر زیست پزشکی طراحی شده بود، با چالش‌های منحصر به فرد تصاویر پانورامیک نهفته است. این تصاویر اغلب شامل ساختارهای پیچیده، کنتراست‌های متغیر و ویژگی‌های آناتومیک هم‌پوشانی هستند که وظیفه قطعه بندی را به‌طور ویژه‌ای چالش برانگیز می‌سازد. ما با بهینه سازی معماری U-Net برای تصاویر پانورامیک و با استفاده از تکنیک‌های پیش پردازش و افزایش داده‌ها، توانایی مدل در تفکیک بین نواحی سالم و بیمار در ساختار دندانی را افزایش دادیم. این امر به کمک افزایش تعداد لایه‌های پیش‌بینی، استفاده از مکانیزم توجه (Attention Mechanisms) و لایه‌های Residual صورت پذیرفته است. همچنین به منظور بهبود مدل در شناسایی نواحی کوچک، از ترکیب توابع اتلاف Binary Cross Entropy و Dice Loss استفاده شده است که تحت عنوان Unified Focal loss در حوزه پردازش تصاویر پزشکی می‌تواند مورد استفاده قرار گیرد.

معماری شبکه و فرایند آموزش

در این پژوهش شبکه U-Net به عنوان یک شبکه پیش‌بینی چند لایه مورد استفاده قرار گرفته است. این مدل شامل پنج لایه پیش‌بینی دو بعدی در بخش کدگذار و چهار لایه پیش‌بینی در بخش کدگشا است. در معماری این شبکه، هر بلوک پیش‌بینی دو بعدی متشکل از دو لایه پیش‌بینی بوده و در هر یک از این بلوک‌های پیش‌بینی اندازه فیلتر به صورت ۳×۳ در نظر گرفته شده است (۵۲). همچنین ابعاد تصاویر ورودی و خروجی مشابه یکدیگر است. هر بلوک شامل یک تابع فعال سازی برای هر نورون پیش‌بینی است. از جمله نکات مهم در طراحی هر مدل یادگیری عمیق استفاده از تابع فعال سازی مناسب است که وظیفه فعال و غیر فعال کردن نورون را بر عهده دارد و به تبع در فرایند به روزرسانی وزن‌ها اثرگذار است. همچنین انتخاب یک تابع فعال سازی مناسب می‌تواند از بیش‌برازش شدن شبکه جلوگیری نموده و در حل مسائل غیرخطی به خوبی عمل نماید. با توجه به کاربرد گسترده تابع فعال سازی Relu در مطالعات متعدد، در این مدل نیز از این تابع فعال سازی استفاده شده است (۴۴،۵۳،۵۴)، چرا که مشتق این تابع فعال سازی برای مقادیر مثبت برابر ۱ بوده و این امر سبب می‌گردد که مقادیر خروجی خارج از محدوده مدنظر قرار نگیرند و موجب ایجاد خطا در شبکه پیش‌بینی نگردند (۵۵). به منظور جلوگیری از بیش‌برازش شدن شبکه از روش حذف



شکل ۳- ساختار معماری شبکه U-Net مورد استفاده در پژوهش

مشخص می‌گردد. پس از آماده سازی و نرمالیزاسیون مجموعه داده، فرایند آموزش به کمک شبکه عصبی عمیق مذکور صورت می‌گیرد. سپس هاپیرپارامترهای موجود در این شبکه به تدریج بهینه سازی شده و در نهایت این شبکه به کمک مقادیر برآورده شده آموزش دیده و مدل نهایی استخراج می‌گردد. با اعمال این مدل بر مجموعه داده آزمایشی، عملکرد این مدل به کمک معیارهای ارزیابی مورد تحلیل و بررسی قرار گرفته است.

معیارهای ارزیابی


پس از پایان یافتن فرایند آموزش عملکرد مدل به کمک معیارهای ارزیابی شامل صحت، دقت، F1-Score و حساسیت مورد بررسی قرار می‌گیرد. حال هر یک از این معیارها به تفصیل شرح داده خواهد شد. در این بخش هریک از معیارهای ارزیابی کمی مورد بحث قرار گرفته است.

دقت مثبت (Precision) و Recall (Sensitivity)

صحت نسبت پیکسل‌های متعلق به یک کلاس که توسط مدل به درستی شناسایی شده‌اند به کل تعداد پیکسل‌هایی است که مدل به صورت کلی شناسایی نموده است. معیار یادآوری نیز نسبت پیکسل‌هایی است که به درستی تشخیص داده شده‌اند به کل پیکسل‌هایی که توسط مدل شناسایی شده‌اند. حداقل مقدار این معیار برابر صفر و حداکثر مقدار آن برابر یک است. معادلات ۲ و ۳ نحوه

از یک معماری با کلاس‌های مستقل استفاده شده‌است. در واقع یک مدل اختصاصی برای هر کلاس بیماری آموزش داده شده و این امر سبب کاهش اثر عدم توازن کلاس‌ها و بهبود دقت مدل‌ها گردد. همچنین در این مدل، با اضافه نمودن لایه‌های Residual از احتمال از بین رفتن گرادینان جلوگیری شده‌است.

در شکل ۴ روند کلی انجام این تحقیق نشان داده شده است.



شکل ۴- روند کلی انجام پژوهش از گردآوری داده تا ارزیابی مدل

همانطور که در این شکل مشاهده می‌گردد، ابتدا تصاویر پانورامیک جمع آوری شده و سپس از میان این تصاویر، تصاویری که کیفیت بالایی ندارند، از مجموعه داده حذف می‌گردند. سپس روند برچسب گذاری برای این مجموعه داده صورت پذیرفته و در هر تصویر پیکسل‌های متعلق به کلاس‌های پرکردگی، پوسیدگی، عصب‌کشی و دندان عقل نهفته

محاسبه این معیارها را نشان می‌دهد.

$$Precision = \frac{TP}{TP+} \quad (\text{معادله ۲})$$

$$Sensitivity = \frac{TP}{TP+} \quad (\text{معادله ۳})$$

یافته‌ها

در مرحله گردآوری داده‌ها، حدود ۶۰۰ تصویر پانورامیک جمع‌آوری شد که پس از حذف حدود ۱۰۰ تصویر نویزی یا کم‌کیفیت، ۵۰۰ تصویر وارد فرایند نهایی شدند. این مجموعه پس از افزایش داده و آماده‌سازی برای آموزش، به سه بخش آموزش، اعتبارسنجی و آزمون تقسیم شد. جدول ۱ عملکرد مدل را برای چهار وضعیت دندانی نشان می‌دهد. با وجود بالا بودن Accuracy در تمامی کلاس‌ها، با توجه به نامتوازن بودن نسبی داده‌ها، F1-score شاخص مناسب‌تری برای تفسیر عملکرد مدل بود. بر این اساس، بهترین عملکرد مدل در شناسایی پرکردگی و دندان عقل نهفته مشاهده شد، در حالی که کلاس پوسیدگی همچنان چالش برانگیزترین کلاس باقی ماند. به طور کلی، بهترین عملکرد مدل در شناسایی پرکردگی و دندان عقل نهفته مشاهده شد. در مقابل، کلاس پوسیدگی نسبت به سایر کلاس‌ها چالش بیشتری داشت.

در جدول ۲، که یک مقایسه مفهومی مبتنی بر مطالعات موجود است، عملکرد روش پیشنهادی به صورت توصیفی با چند روش کلاسیک رایج در پردازش تصاویر شامل حد آستانه گذاری کلی، Fuzzy C-means، Watershed و Canny edge detection مقایسه شده است (۴۴۶۰، ۶۱). حد آستانه گذاری کلی مبتنی بر جدا سازی نواحی هدف بر اساس شدت روشنایی است، اما در تصاویر پانورامیک به دلیل تغییرات کنتراست و هم پوشانی ساختارها معمولاً عملکرد محدودی دارد. روش Fuzzy C-means با خوشه بندی فازی پیکسل‌ها تلاش می‌کند مرز نواحی را بهتر مدل کند، اما به نویز و ناهمگنی شدت حساس است. روش Watershed برای جدا سازی نواحی بر پایه گرادیان تصویر به کار می‌رود، ولی در تصاویر پیچیده مستعد بیش قطعه بندی است. روش Canny edge detection نیز بر استخراج مرزها تمرکز دارد، اما در نواحی با کنتراست پایین یا مرزهای نامشخص، به تنهایی کفایت ندارد. این روش‌ها به عنوان روش‌های مبنای (Benchmark) کلاسیک در مطالعات پیشین بر روی تصاویر پانورامیک یا داده‌های مشابه گزارش شده‌اند.

در این روابط، TP (True Positive) و TN (True Negative) پیکسل‌هایی هستند که به درستی توسط مدل شناسایی و رد شده‌اند. همچنین FP (False Positive) و FN (False Negative) نیز به ترتیب تعداد پیکسل‌هایی است که مدل به اشتباه شناسایی و رد نموده است.

F1-Score

این معیار به صورت میانگین هارمونیک دو معیار صحت و یادآوری تعریف می‌شود. معادله ۴ نحوه محاسبه این معیار را نشان می‌دهد (۵۸).

$$F1\ score = \frac{2 \times (Precision \times Recall)}{(Precision + Recall)} \quad (\text{معادله ۴})$$

صحت

صحت (Accuracy) یک مدل را می‌توان به عنوان معیاری در نظر گرفت که نحوه عملکرد آن را برای همه کلاس‌ها توصیف می‌کند. این معیار به صورت درصد پیش‌بینی‌های صحیح مدل به کل پیش‌بینی‌ها تعریف می‌گردد و به صورت معادله ۵ محاسبه می‌شود (۵۹).

$$Accuracy = \frac{\sum_{i=0}^k pii}{\sum_{i=0}^k \sum_{j=0}^k pij} \quad (\text{معادله ۵})$$


بنابراین به صورت کلی در این مطالعه، معیارهای Recall، دقت، F1-Score و صحت برای ارزیابی عملکرد مدل استفاده شدند. Recall جهت شناسایی کامل نواحی هدف و کاهش از دست دادن پیکسل‌های متعلق به بیماری ضروری است، در حالی که دقت بر کاهش پیش‌بینی‌های اشتباه تمرکز دارد. با توجه به ماهیت نامتوازن داده‌ها و اینکه Accuracy ممکن است در چنین شرایطی تصویری بیش از حد خوش بینانه از عملکرد مدل ارائه دهد، بنابراین، در این پژوهش

جدول ۱- مقادیر معیارهای ارزیابی کمی مدل در هریک از وضعیت‌های دندانی


وضعیت دندانی	Sensitivity	F1-score	Precision	Accuracy
پوسیدگی	۹۹/۸	۷۳/۶	۷۹/۷	۹۹/۵
پرکردگی	۹۹/۹	۹۲/۲	۹۷/۵	۹۹/۴
دندان عقل نهفته	۹۸/۰	۸۷/۱	۷۷/۰	۹۹/۴
درمان ریشه	۹۹/۴	۷۶/۰	۶۱/۲	۹۸/۴

جدول ۲- مقایسه توصیفی روش پیشنهادی با روش‌های گزارش شده در مطالعات مشابه مبتنی بر تصاویر پانورامیک


روش مورد مطالعه	Sensitivity	F1-score	Precision	Accuracy
Thresholding	۸۱	۵۶	۵۲	۷۹
Fuzzy C-means	۹۱	۴۹	۶۱	۸۲
Watershed	۷۵	۵۸	۴۸	۷۷
Canny edge detection	۶۴	۱۷	۴۵	۷۹
مطالعه حاضر	۹۹/۲	۸۲/۲	۷۸/۹	۹۹/۲




شکل ۵- نمونه‌ای از خروجی مدل در کلاس پرکردگی (۱) تصویر اصلی، (۲) برجسب مرجع و (۳) پیش‌بینی مدل



شکل ۶- نمونه‌ای از خروجی مدل در کلاس دندان عقل نهفته (۱) تصویر اصلی، (۲) برجسب مرجع و (۳) پیش‌بینی مدل



شکل ۷- نمونه‌ای از خروجی مدل در کلاس درمان ریشه (۱) تصویر اصلی، (۲) برچسب مرجع و (۳) پیش‌بینی مدل



شکل ۸- نمونه‌ای از خروجی مدل در کلاس پوسیدگی (۱) تصویر اصلی، (۲) برچسب مرجع و (۳) پیش‌بینی مدل

بالاترین Accuracy کلی (۹۸/۹ درصد) را نشان داد. شکل‌های ۵ تا ۸ نمونه‌هایی از تصویر اصلی، برچسب مرجع و خروجی پیش‌بینی مدل را در هر یک از کلاس‌های مورد بررسی نشان می‌دهند.

بحث و نتیجه‌گیری

در این پژوهش، با بهره‌گیری از تصاویر پانورامیک دندان و تکیه بر قابلیت‌های روش‌های یادگیری عمیق، مدلی مبتنی بر معماری اصلاح شده U-Net برای شناسایی چهار وضعیت دندان شامل پوسیدگی، درمان ریشه، پرکردگی و دندان نهفته توسعه داده شد. پیش از گسترش روش‌های یادگیری عمیق، تمرکز بسیاری از مطالعات در حوزه پردازش تصاویر پزشکی به صورت کلی بر بهبود کیفیت تصاویر به منظور افزایش دقت تشخیص توسط پزشک معالج قرار داشت. با این حال، پیشرفت شبکه‌های عمیق امکان خودکارسازی این فرایند را

نتایج موجود در مطالعه مشابه نیز نشان می‌دهد (۶۲) که معماری U-Net برای تشخیص بیماری‌های دندان در قطعه بندی تصاویر پانورامیک عملکرد مناسبتری را نسبت به معماری VGGNet، با دقت حداکثر ۸۹ درصد، از خود نشان داده است. این امر را می‌توان این گونه تفسیر نمود که اولاً، U-Net به طور خاص برای وظایف تقسیم بندی تصویر مهندسی شده است که دارای معماری رمزگذار-رمزگشای متقارن است که امکان مکان یابی دقیق و تقسیم بندی دقیق ساختارهای پیچیده را در یک تصویر فراهم می‌کند. اتصالات پرشی در U-Net به طور مؤثری لایه‌های رمزگذار و رمزگشا را به یکدیگر مرتبط کرده و ویژگی‌های سطح بالا را در طول فرایند نمونه برداری حفظ می‌کنند. این قابلیت به ویژه هنگام برخورد با ویژگی‌های پیچیده و وجود همپوشانی موجود در تصاویر پانورامیک، که نیاز به ترسیم مرز دقیق دارند، سودمند است. روش پیشنهادی این مطالعه در این مقایسه توصیفی

فراهم کرده و مدل‌ها قادر شده‌اند با دقت بالا نواحی بیماری را شناسایی کنند. در میان روش‌های کلاسیک، روش‌های مبتنی بر منطق فازی از عملکرد بهتری برخوردار بوده‌اند، اما حتی این روش‌ها نیز در مقایسه با رویکردهای مبتنی بر یادگیری عمیق، از جمله روش به‌کاررفته در این پژوهش، دقت پایین‌تری نشان می‌دهند.

در این مطالعه، فرایند شناسایی بیماری‌ها به صورت قطعه بندی پیکسل مبنا انجام شد که در مقایسه با بسیاری از پژوهش‌های موجود در این حوزه که رویکرد شی مبنا دارند، رویکردی دقیق‌تر و سخت‌گیرانه‌تر محسوب می‌شود. نتایج حاصل نشان داد که معماری U-Net در شرایطی که حجم داده‌های آموزشی محدود است، نسبت به برخی مدل‌های یادگیری عمیق دیگر مانند ResNet و Mask R-CNN عملکرد مناسب‌تری داشته و توانسته است نواحی هدف را با کارایی مطلوب‌تری شناسایی کند. برتری نسبی معماری U-Net نسبت به روش‌های کلاسیک را می‌توان در توانایی آن برای یادگیری ویژگی‌های چند مقیاسی و مدل سازی مستقیم نواحی هدف توضیح داد. در حالی که روش‌های کلاسیک عمدتاً بر شدت روشنایی، خوشه بندی یا لبه‌ها متکی‌اند و نسبت به نویز، تغییرات کنتراست و هم پوشانی ساختارهای آناتومیک حساس‌تر هستند، U-Net می‌تواند بازنمایی عمیق‌تری از الگوهای تصویری مربوط به وضعیت‌های دندانی ایجاد کند. با این وجود، افزایش حجم داده‌های آموزشی می‌تواند به شکل قابل توجهی موجب بهبود عملکرد مدل شود، موضوعی که دسترسی محدود به داده‌های پزشکی، آن را به یکی از چالش‌های مهم این حوزه تبدیل کرده است (۵۳،۶۳).

بر اساس نتایج ارزیابی و با در نظر گرفتن نامتوازن بودن نسبی داده‌ها، F1-score نشان داد که مدل در شناسایی کلاس‌های پرکردگی و دندان عقل نهفته عملکرد بهتری نسبت به سایر کلاس‌ها دارد، در حالی که کلاس پوسیدگی همچنان دشوارترین وضعیت برای قطعه بندی دقیق باقی مانده است. پایین‌تر بودن عملکرد مدل در شناسایی پوسیدگی می‌تواند ناشی از ماهیت این ضایعه باشد، زیرا پوسیدگی در مراحل اولیه ممکن است بسیار کوچک و ظریف بوده و مرزهای مشخصی نداشته باشد. علاوه بر این، پوسیدگی ممکن است از نظر ظاهری با پدیده‌هایی مانند ترک‌ها یا ساییدگی‌ها شباهت داشته باشد و همین امر تشخیص آن را دشوارتر کند. از سوی دیگر، کیفیت تصاویر

پانورامیک نیز همواره یکنواخت نیست و عواملی مانند کنتراست متغیر، شرایط نوری نامناسب یا سطح نویز متفاوت و گاه غیرگوسی می‌تواند بر دقت تشخیص تأثیر بگذارد. تفاوت‌های آناتومیکی میان بیماران، از جمله تغییر در شکل، اندازه و موقعیت دندان‌ها نیز ممکن است باعث شود پوسیدگی در افراد مختلف با الگوهای ظاهری متفاوتی مشاهده شود. یافته‌های این پژوهش با روند کلی مطالعات اخیر در حوزه هوش مصنوعی در دندانپزشکی همسو است و نشان می‌دهد شبکه‌های یادگیری عمیق می‌توانند به‌عنوان ابزار کمکی در تحلیل تصاویر پانورامیک مورد استفاده قرار گیرند. با این حال، تفاوت در نوع داده‌ها، سطح برچسب گذاری و معیارهای ارزیابی گزارش شده در مطالعات مختلف، مقایسه مستقیم نتایج را تا حدی محدود می‌کند. از نظر کاربرد بالینی نیز باید توجه داشت که تصاویر پانورامیک در شرایط واقعی همواره از نظر کیفیت، وضوح و کنتراست یکسان نیستند. در این پژوهش، بخشی از این ناهمگنی از طریق مراحل پیش‌پردازش، به ویژه بهبود کنتراست و نرمال سازی تصاویر، کاهش داده شد. با وجود این، ارزیابی عملکرد مدل بر روی داده‌های خارجی و ناهمگن‌تر همچنان ضروری است. بنابراین می‌توان پیش‌پردازش را بخشی از رویکرد عملی سامانه در نظر گرفت، در حالی که بررسی میزان تعمیم پذیری مدل به مجموعه داده‌های متنوع‌تر یکی از مسیرهای مهم پژوهش‌های آینده خواهد بود.

از نقاط قوت این مطالعه می‌توان به برچسب گذاری داده‌ها با مشارکت دو دندانپزشک، تمرکز بر قطعه بندی پیکسل مبنا و گزارش هم زمان چند معیار ارزیابی اشاره کرد. در مقابل، این پژوهش دارای چند محدودیت نیز بود. نخست، حجم مجموعه داده نسبتاً محدود بود که می‌تواند بر پایداری عملکرد مدل در داده‌های متنوع‌تر اثر بگذارد. دوم، تصاویر از منابع مختلف و با کیفیت‌های ناهمگن گردآوری شدند. بنابراین، احتمال بروز سوگیری داده‌ای ناشی از تفاوت در شرایط تصویربرداری، کیفیت تصویر و پروتکل‌های تهیه داده وجود دارد. سوم، با وجود استفاده از روش‌هایی مانند dropout و batch normalization برای کاهش بیش برازش، به دلیل محدود بودن حجم داده‌ها، احتمال بیش برازش به طور کامل قابل رد نیست. چهارم، در این پژوهش از مجموعه داده خارجی مستقل برای اعتبارسنجی استفاده نشد. بنابراین، تعمیم پذیری مدل به محیط‌های بالینی و مراکز دیگر نیازمند ارزیابی بیشتر است. همچنین، اطلاعات جمعیت شناختی بیماران از جمله سن و جنس در

می‌سازد. موضوعی که از نظر تفسیر بالینی اهمیت زیادی دارد. از سوی دیگر، استفاده از پیش پردازش و تکنیک‌های افزایش داده، به استحکام نسبی نتایج کمک کرده است.

با وجود این، نتایج مطالعه باید با در نظر گرفتن محدودیت‌های آن تفسیر شوند. حجم نسبتاً محدود مجموعه داده، ناهمگنی منابع تصویری، نبود داده خارجی مستقل برای اعتبارسنجی و فقدان اطلاعات جمعیت شناختی بیماران از جمله عواملی هستند که می‌توانند بر تعمیم پذیری مدل اثر بگذارند. همچنین، هرچند در این پژوهش از راهکارهایی برای کاهش بیش برآزش و مدیریت تفاوت کیفیت تصاویر استفاده شد، برای کاربرد گسترده‌تر در محیط‌های واقعی بالینی هنوز نیاز به ارزیابی مدل بر روی مجموعه داده‌های بزرگ‌تر، چند مرکزی و ناهمگن‌تر وجود دارد. بر این اساس، پیشنهاد می‌شود در مطالعات آینده، افزون بر توسعه حجم و تنوع داده‌ها، اعتبارسنجی خارجی و طراحی مدل‌های مقاوم‌تر در برابر تغییرات کیفیت تصویر، پروتکل‌های تصویربرداری و تفاوت‌های آناتومیک بیماران نیز مورد توجه قرار گیرد.

تشکر و قدردانی

نویسندگان مراتب سپاس و قدردانی خود را از تمامی افراد که با مشارکت ارزشمند و همکاری صمیمانه خود در انجام این پژوهش نقش داشتند، ابراز می‌دارند. همچنین از دندانپزشکان محترم و تمامی افرادی که در فرایند اجرا و جمع آوری داده‌های پژوهش همکاری لازم را فراهم کردند، صمیمانه تشکر می‌شود.

References:

- 1- Organization WH. Oral health. Geneva: WHO. 2025. 2025.
- 2- Organization WH. Global oral health status report: towards universal health coverage for oral health by 2030: World Health Organization; 2022.
- 3- Petersen PE. The burden of oral disease: challenges to improving oral health in the 21st century. Bull World Health Organ. 2005;83(1):3.
- 4- Pretty IA. Caries detection and diagnosis: novel technologies. J Dent. 2006;34(10):727-39.
- 5- Page RC, Eke PI. Case definitions for use in population-based surveillance of periodontitis. J Periodontol. 2007;78:1387-99.
- 6- Eckhard T, Valero EM, Nieves JL, editors. Labial teeth and gingiva color image segmentation for gingival health-state assessment. Conference on Colour in Graphics, Imaging, and Vision. 2012;(6).
- 7- Khan A, Qureshi B, Qureshi A, Imtiaz Y, Qadeer S. Correlation of salivary characteristics with high risk of dental

دسترس نبود و این موضوع ارزیابی تنوع جمعیتی مجموعه داده را محدود کرد. افزون بر این، استقرار مدل در محیط واقعی بالینی با چالش‌هایی مانند تفاوت کیفیت و کنتراست تصاویر، تنوع دستگاه‌های تصویربرداری و تفاوت در ویژگی‌های آناتومیک بیماران همراه است. از این رو، انجام مطالعات چند مرکزی و ارزیابی مدل بر روی داده‌های خارجی و ناهمگن‌تر برای کاربرد گسترده‌تر بالینی ضروری است.

در مجموع، مطالعه حاضر نشان داد که استفاده از یک معماری اصلاح شده U-Net می‌تواند چارچوبی موثر برای شناسایی و قطعه بندی خودکار وضعیت‌های دندان در تصاویر رادیوگرافی پانورامیک فراهم کند. این مدل توانست چهار وضعیت مهم شامل پوسیدگی، پرکردگی، درمان ریشه و دندان عقل نهفته را در سطح پیکسل شناسایی کند و در ارزیابی کمی، به ویژه از نظر F1-score، عملکرد امیدوار کننده‌ای از خود نشان دهد. نتایج به دست آمده بیانگر آن بود که مدل در شناسایی پرکردگی و دندان عقل نهفته موفق‌تر عمل کرده، در حالی که تشخیص پوسیدگی به دلیل اندازه کوچک‌تر ضایعه، مرزهای نامشخص‌تر و شباهت ظاهری با برخی تغییرات ساختاری، همچنان چالش برانگیز باقی مانده است. یافته‌های این پژوهش حاکی از آن است که چنین رویکردی می‌تواند به عنوان یک ابزار کمکی در غربالگری، کاهش وابستگی به تفسیر دستی و پشتیبانی از برنامه ریزی درمان در دندانپزشکی مورد استفاده قرار گیرد. مزیت اصلی این چارچوب در آن است که برخلاف بسیاری از روش‌های طبقه بندی محور، تنها به اعلام وجود یک وضعیت دندان بسنده نمی‌کند، بلکه محل تقریبی ناحیه هدف را نیز در تصویر مشخص

- caries; A clinical investigation. Future Dent J. 2018;4(1):72-5.
- 8- Vertucci FJ. Root canal anatomy of the human permanent teeth. Oral Surg Oral Med Oral Pathol. 1984;58(5):589-99.
- 9- Al-Ramil AM, Al-Wosaibi AM, Bukhary MT, Al-wusaybie MM. Prevalence of impacted teeth and associated pathologies—A radiographic study, Al Ahsa, Saudi Arabia Population. Egypt J Hospital Med. 2018;70(12):2130-6.
- 10- Laganà G, Venza N, Borzabadi-Farahani A, Fabi F, Danesi C, Cozza P. Dental anomalies: prevalence and associations between them in a large sample of non-orthodontic subjects, a cross-sectional study. BMC Oral Health. 2017;17(1):62.
- 11- Hupp JR, Ellis E, Tucker MR. Contemporary oral and maxillofacial surgery. 2009.
- 12- Pinto AC, Francisco H, Marques D, Martins JN, Carames J. Worldwide prevalence and demographic predictors of impacted third molars—Systematic review with meta-analysis. J Clin Med. 2024;13(24):7533.

- 13- Oliva-Ferrusola E, Baus-Domínguez M, Torres-Lagares D, Serrera-Figallo M-A. Genetic Aspects of Dental Impaction: A Scoping Review. *Genes*. 2026;17(3):265.
- 14- Schwendicke F, Singh T, Lee J-H, Gaudin R, Chaurasia A, Wiegand T, et al. Artificial intelligence in dental research: checklist for authors, reviewers, readers. *J Dent*. 2021;107:103610.
- 15- Schwendicke F, Golla T, Dreher M, Krois J. Convolutional neural networks for dental image diagnostics: A scoping review. *J Dent*. 2019;91:103226.
- 16- Zhu J, Chen Z, Zhao J, Yu Y, Li X, Shi K, et al. Artificial intelligence in the diagnosis of dental diseases on panoramic radiographs: a preliminary study. *BMC Oral Health*. 2023;23(1):358.
- 17- Bonfanti-Gris M, Herrera A, Salido Rodríguez-Manzanique MP, Martínez-Rus F, Pradies G. Deep learning for tooth detection and segmentation in panoramic radiographs: a systematic review and meta-analysis. *BMC Oral Health*. 2025;25(1):1280.
- 18- 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(22):6859.
- 19- Wang Y-CC, Chen T-L, Vinayahalingam S, Wu T-H, Chang CW, Chang HH, et al. Artificial Intelligence to Assess Dental Findings from Panoramic Radiographs--A Multinational Study. *arXiv:2502.10277*. 2025.
- 20- Hejazi K. Deep learning-based system for automated classification and detection of lesions in dental panoramic radiography: master's thesis]. Damascus, Syria: Syrian Virtual University; 2024.
- 21- Ameli N, Moghaddam MM, Lai H, Pacheco-Pereira C. Automated quality evaluation of dental panoramic radiographs using deep learning. *Imaging Sci Dent*. 2025;55(2):175-880.
- 22- Kazimierzczak N, Sultani N, Chwarscianek N, Krzykowski S, Janiszewska-Olszowska J, Serafin Z, et al. Detection accuracy of an AI platform for dental treatment features on panoramic radiographs--tooth-and patient-level analyses. *Sci Rep*. 2025;16(1):2436.
- 23- 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(7):20230284.
- 24- Albawi S, Mohammed TA, Al-Zawi S. Understanding of a convolutional neural network. 2017 International Conference on Engineering and Technology (ICET); 2017: Ieee.
- 25- Krizhevsky A, Sutskever I, Hinton GE. Imagenet classification with deep convolutional neural networks. *Communications of the ACM*. 2017;60(6):84-90.
- 26- Szegedy C, Vanhoucke V, Ioffe S, Shlens J, Wojna Z. Rethinking the inception architecture for computer vision. *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016.
- 27- Devito KL, de Souza Barbosa F, Felipe Filho WN. An artificial multilayer perceptron neural network for diagnosis of proximal dental caries. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod*. 2008;106(6):879-84.
- 28- Ali RB, Ejbali R, Zaied M, editors. Detection and classification of dental caries in x-ray images using deep neural networks. *International conference on software engineering advances (ICSEA)*; 2016.
- 29- Selwitz RH, Ismail AI, Pitts NB. Dental caries. *Lancet*. 2007;369(9555):51-9.
- 30- Bouchahma M, Hammouda SB, Kouki S, Alshemali M, Samara K. An automatic dental decay treatment prediction using a deep convolutional neural network on X-ray images. 2019 IEEE/ACS 16th International Conference on Computer Systems and Applications (AICCSA); 2019: IEEE.
- 31- Ghaznavi Bidgoli SA, Sharifi A, Manthouri M. Automatic diagnosis of dental diseases using convolutional neural network and panoramic radiographic images. *Computer Methods in Biomechanics and Biomedical Engineering: Imaging & Visualization*. 2021;9(5):447-55.
- 32- Meem FA, Ferdus J, Sarkar WA, Ahmed MI, Islam MS, editors. Detection of Dental Issues Using the Transfer Learning Methods. *Proceedings of the Fourth International Conference on Trends in Computational and Cognitive Engineering: TCCE 2022*; Springer Nature Lik. 2023:367-79.
- 33- Farman AG, Farman TT. A comparison of 18 different x-ray detectors currently used in dentistry. *Oral Surg Oral Med Oral Pathol Oral Radiol Endod*. 2005;99(4):485-9.
- 34- Bhat S, Birajdar G, Patil M. Enhanced diagnostic accuracy for dental caries and anomalies in panoramic radiographs using a custom deep learning model. *Cureus*. 2024;16(8):e67315.
- 35- Tarek R, Elshenawy A, Assadwy MI, Madkour MA. Automated diagnosis of dental diseases using deep learning on radiographic images. *SN Computer Sci*. 2025;6(6):751.
- 36- Zhicheng H, Yipeng W, Xiao L. Deep learning-based detection of impacted teeth on panoramic radiographs. *Biomed Eng Comput Biol*. 2024;15:11795972241288319.
- 37- Jain AK, Chen H. Matching of dental X-ray images for human identification. *Pattern Recognition*. 2004;37(7):1519-32.
- 38- Putra RH, Doi C, Yoda N, Astuti ER, Sasaki K. Current applications and development of artificial intelligence for digital dental radiography. *Dentomaxillofac Radiol*. 2022;51(1):20210197.
- 39- Panahi O. Deep Learning in Dental Image Analysis: A Comprehensive Review of Current Applications and Future Directions. *J Case Rep Clin Images*. 2025;8(1):1172.
- 40- Zhou Z, Zhu J, Zhang Y, Guan X, Wang P, Li T. Deep Learning in Dental Image Analysis: A Systematic Review of Datasets, Methodologies, and Emerging Challenges. *arXiv preprint arXiv:251.2025.020634*.
- 41- Uribe SE, Issa J, Sohrabniya F, Denny A, Kim N, Dayo A, et al. Publicly available dental image datasets for artificial intelligence. *J Dent Res*. 2024;103(13):1365-74.
- 42- van Nistelrooij N, Ghoul KE, Xi T, Saha A, Kempers S, Cenci M, et al. Combining public datasets for automated tooth assessment in panoramic radiographs. *BMC Oral Health*.

2024;24(1):387.

43- Silva B, Pinheiro L, Sobrinho B, Lima F, Sobrinho B, Abdalla K, et al. OdontoAI: A human-in-the-loop labeled data set and an online platform to boost research on dental panoramic radiographs. arXiv preprint arXiv:220315856. 2022.

44- Sivagami S, Chitra P, Kailash GSR, Muralidharan S. Unet architecture based dental panoramic image segmentation. 2020 International Conference on Wireless Communications Signal Processing and Networking (WiSPNET); 2020: IEEE.

45- Goldberger AL, Amaral LA, Glass L, Hausdorff JM, Ivanov PC, Mark RG, et al. PhysioBank, PhysioToolkit, and PhysioNet: components of a new research resource for complex physiologic signals. *Circulation*. 2000;101(23):E215-20.

46- Zhang Y, Ye F, Chen L, Xu F, Chen X, Wu H, et al. Children's dental panoramic radiographs dataset for caries segmentation and dental disease detection. *Sci Data*. 2023;10:380.

47- Brahmi W, Jdey I, Drira F. Exploring the role of Convolutional Neural Networks (CNN) in dental radiography segmentation: A comprehensive Systematic Literature Review. *Engineering Applications Artificial Intelligence*. 2024;133:108510.

48- Brahmi W, Jdey I. Automatic tooth instance segmentation and identification from panoramic X-Ray images using deep CNN. *Multimedia Tools Applications*. 2024;83(18):55565-85.

49- Wang X, Gao S, Jiang K, Zhang H, Wang L, Chen F, et al. Multi-level uncertainty aware learning for semi-supervised dental panoramic caries segmentation. *Neurocomputing*. 2023;540:126208.

50- Yang S, Xiao W, Zhang M, Guo S, Zhao J, Shen F. Image data augmentation for deep learning: A survey. arXiv preprint arXiv:220408610. 2022.

51- Shorten C, Khoshgoftaar TMJ. A survey on image data augmentation for deep learning. *J Big Data*. 2019;6(6):1-48.

52- Gonzalez R, Woods R. *Digital Image Processing*. Prentice Hall, Upper Saddle River. NJ, USA. 2002.

53- Lee J-H, Kim D-H, Jeong S-N, Choi S-H. Detection and

diagnosis of dental caries using a deep learning-based convolutional neural network algorithm. *J Dent*. 2018;77:106-11.

54- Agarap AF. Deep learning using rectified linear units (relu). arXiv preprint arXiv:180308375. 2018.

55- Zhang H, Weng T-W, Chen P-Y, Hsieh C-J, Daniel L. Efficient neural network robustness certification with general activation functions. *Adv Neural Information Processing Systems*. 2018;31.

56- LeCun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436-44.

57- Yeung M, Sala E, Schönlieb C-B, Rundo LJCM. Unified focal loss: Generalising dice and cross entropy-based losses to handle class imbalanced medical image segmentation. *Computerized Medical Imaging and Graphics*. 2022;95:102026.

58- Chicco D, Jurman G. The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation. *BMC Genomics*. 2020;21:6.

59- Maxwell AE, Warner TA, Guillén LA. Accuracy assessment in convolutional neural network-based deep learning remote sensing studies—part 1: Literature review. *Remote Sens*. 2021;13(13):2450.

60- Haniah M, Aditya CSK, Harto A, Arifin AZ. Cortical bone segmentation using watershed and region merging based on statistical features. *J Ilmu Komputer dan Informasi*. 2015;8(2):76-82.

61- Silva G, Oliveira L, Pithon M. Automatic segmenting teeth in X-ray images: Trends, a novel data set, benchmarking and future perspectives. *Expert Systems with Applications*. 2018;107:15-31.

62- Majanga V, Viriri S. A Deep Learning Approach for Automatic Segmentation of Dental Images. *Mining Intelligence and Knowledge Exploration*. 2020;143-52.

63- Muramatsu C, Morishita T, Takahashi R, Hayashi T, Nishiyama W, Aiji Y, et al. Tooth detection and classification on panoramic radiographs for automatic dental chart filing: improved classification by multi-sized input data. *Oral Radiol*. 2021;37(1):13-9.