مقاله مروری

مجله ماشین‌بینایی و پردازش‌تصویر
سال یازدهم، شماره چهارم، بهار ۱۴۰۴

مروری بر روش‌های نوین پردازش تصاویر دندان با رویکرد تشخیص، شماره‌گذاری، بخش‌بندی دندان و دسته‌بندی بیماری

مهدیه دهقانی[۱]، رضا آقائی زاده ظروفی[۲]

چکیده

هوش مصنوعی در زمینه تفسیر تصاویر استخراج شده از سیستم‌های تصویربرداری اشعه ایکس پیشرفت چشم‌گیری داشته است. در زمینه تصاویر دندان‌پزشکی نیز تکنیک‌های مختلف بینایی ماشین و یادگیری عمیق به عنوان جایگزین فرآیند دستی تفسیر تصویر که در عین وقت‌گیربودن مستعد خطا است، معرفی شده‌اند. تشخیص، شماره‌گذاری و بخش‌بندی دندان و حتی دسته‌بندی بیماری‌های دندان با استفاده از رویکردهای یادگیری عمیق پیشرفت چشم‌گیری داشته‌اند. هدف این پژوهش تحلیل و مقایسه تکنیک‌های سنتی و مبتنی بر یادگیری عمیق تفسیر یا بهبود تصاویر دندان پزشکی به تفکیک عملکرد است. روش‌شناسی این مطالعه شامل مروری جامع بر پژوهش‌های انجام شده از سه دیدگاه اصلی بهبود کیفیت تصویر، شناسایی دندان و شناسایی بیماری است. در بخش بهبود کیفیت تصویر، تکنیک‌های پیش‌پردازش و در بخش شناسایی دندان، فرآیندهای تشخیص، دسته‌بندی و بخش‌بندی دندان‌ها با تأکید بر اهمیت تعیین نام و نوع دندان در گزارشات پزشکی تحلیل شده است. همچنین، در بخش شناسایی بیماری، چالش‌های مربوط به گستردگی طیف بیماری‌های دندان و ضریب خطای مدل‌ها بررسی شده است. نتایج این بررسی نشان می‌دهد که چالش‌هایی نظیر دسترسی محدود به داده‌ها، عدم تعادل در دسته‌ها و تفسیرهای متفاوت متخصصین، تأثیر قابل توجهی بر عملکرد مدل‌ها دارند. در نهایت، این پژوهش به روشن‌تر شدن وضعیت فعلی و آینده تحقیقات در این حوزه کمک می‌کند و تکنیک‌هایی برای مقابله با چالش‌ها و راه‌های تحقیقاتی آتی شناسایی شده‌اند. به طور خاص، این پژوهش به بررسی امکان استفاده از سیستم‌های هوشمند در تسریع فرآیند گزارش‌نویسی و بهبود دقت تشخیص بیماری‌های دندان به عنوان ابزاری مکمل برای پزشکان می‌پردازد.

کلید واژه ها

پردازش تصاویر دندان، شماره‌گذاری دندان، دسته‌بندی بیماری دندان، بخش‌بندی دندان، یادگیری عمیق، تفسیر هوشمند تصاویر دندان

۱- مقدمه

دندان یکی از عناصر حیاتی بدن انسان است، امروزه حفظ سلامت دندان و پیشگیری از بیماری به دلیل خسارات جبران ناپذیر وارده از اهمیت بالایی برخوردار است. تصویربرداری پزشکی اهمیت زیادی در تشخیص و درمان بسیاری از بیماری‌ها دارد. با پیشرفت روز افزون در این زمینه دستگاه‌های متفاوتی برای انواع تصویربرداری به بازار عرضه شده‌اند. تصاویر دندان پزشکی گستره بالایی داشته و اطلاعات بسیار زیادی را می‌توان از این تصاویر استخراج نمود [۱].

تفسیر تصاویر دندان‌پزشکی به سطح تخصص مفسر وابسته است. شیوع بالای پوسیدگی‌های دندان و افزایش مراجعه بیماران منجر به ایجاد ساعت‌های کاری طولانی و طاقت‌فرسا برای متخصصین شده است. از طرفی در بسیاری از مناطق و ساعات متخصصی برای تفسیر تصاویر دندان پزشکی وجود ندارد. این چالش‌ها

این مقاله در بهمن‌ماه ۱۴۰۳ دریافت شد؛ در فروردین‌ماه بازنگری و در اردیبهشت‌ماه پذیرفته شد.

[۱] دانشجو دکتری مهندسی نرم‌افزار، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران
رایانامه: dehghani.mahdieh@ut.ac.ir

[۲] استاد، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران
رایانامه: zoroofi@ut.ac.ir

نویسنده مسئول: رضا آقائی زاده ظروفی

اهمیت استفاده از تکنیک‌های هوش‌مصنوعی برای تفسیر تصاویر را افزایش می‌دهد[۲]. جمع‌آوری تصاعدی داده‌ها منجر به توسعه روزافزون الگوریتم‌های یادگیری نظارت شده در این حیطه است. این پیشرفت‌ها با ورود سیستم‌های منطق فازی که شرایط عدم قطعیت برچسب‌گذاری را مدیریت می‌کنند، ملموس‌تر شد. شبکه‌های عصبی مصنوعی الگوریتم‌های یادگیری مبتنی بر عملکرد شبکه‌های عصبی بیولوژیکی هستند. ساختار اصلی یک شبکه عصبی مصنوعی مجموعه‌ای از لایه های به هم پیوسته نورون های عامل است و اصطلاح عمیق به شبکه عصبی مصنوعی با تعداد زیادی لایه‌ها و نورون‌ها در هر لایه اشاره دارد [۳].

چندین سیستم هوشمند تشخیص بیماری و دندان تا کنون ارائه شده‌اند. کاربرد یادگیری عمیق در تصاویر دندان پزشکی نتایج امیدوار کننده‌ای را فراهم نموده است. این نوع تکنیک‌ها می‌توانند به طراحی سیستم‌های پشتیبانی تصمیم‌گیری با کارایی بالا کمک کنند. با این حال، مسائل خاصی از جمله مجموعه داده‌های محدود، عدم توازن دسته‌ها و تفسیرپذیری متفاوت تصاویر چالش‌های این حوزه محسوب می‌گردند [۲] تا [۴].

آسیب به دندان‌ها و اسکلت صورت در اثر بیماری‌های دهان و دندان یا تصادفات بسیار رایج است. با توجه به شرح حال بیمار، نوع و شدت جراحات ممکن است از هر یک از روش‌های تصویربرداری دهان و دندان استفاده شود. شکستگی دندان‌ها شامل شکستگی‌های کرونر و شکستگی ریشه است. در انواع شکستگی دندان ممکن است مینا، عاج، سمان و غیره آسیب دیده باشد. هر یک از دندان‌های پیشین، نیش، آسیاب ساختار متفاوتی داشته و در تفسیر تصاویر از این ساختارها استفاده می‌شود [۵]. با توجه به طیف گسترده بیماری‌های دهان و دندان تفسیر تصاویر دندانپزشکی نیازمند تجربه بوده و استفاده از برخی روش‌های پردازش تصاویر پزشکی برای دندان دقت مناسبی را فراهم نمی‌کند.

در بخش ۱ روش انجام تحقیق بیان شده و دیدگاه کلی بررسی منابع و روش بررسی منابع بیان شده است. بخش ۲ روش انجام فرآیند تحقیق، چارچوب‌ها و نحوه تفسیر و نتیجه‌گیری را بیان می‌کند. بخش ۳ حاوی توضیحاتی مختصر از انواع تصاویر دندانپزشکی و برخی اطلاعات ضروری تفسیر تصاویر است. در بخش‌های ۴، ۵ و ۶ به ترتیب پژوهش‌ها از دید بهبود کیفیت تصویر، تشخیص، شماره‌گذاری و بخش‌بندی دندان و دسته‌بندی بخش‌بندی بیماری مورد بررسی قرار گرفته و به تفکیک در انتهای هر بخش جدولی مبنی بر مقایسه روش‌ها از دید پایگاه داده، مدل ، ویژگی‌های انحصاری و پارامترهای ارزیابی قرار گرفته است. در بخش ۵ جمع‌بندی پژوهش براساس اطلاعات بخش‌های گذشته، مقایسه مدل‌ها با حفظ بی‌طرفی کامل صورت پذیرفته است.

۲- روش تحقیق

ارزیابی منابع با استفاده از رویکرد مرور سیستماتیک با هدف ارائه نتیجه‌گیری مستند براساس پژوهش‌های موجود و شفاف‌سازی نقاط قوت و ضعف مطالعات مختلف صورت پذیرفته است. مقالات بررسی شده از منابع Google Scholar، ScienceDirect، Scopus و IEEE Xplore استخراج شده و مقالات از دید، ارائه متن کامل، ارائه معیار ارزیابی، ارائه دقیق نوع پایگاه داده، استفاده از پایگاه داده مرتبط، تناسب با هدف پژوهشی مقاله و غیره مورد بررسی قرار گرفته و انتخاب شده‌اند. مقالات از دید نوع و اندازه داده، ویژگی‌های منحصر به فرد و معیارهای ارزیابی متناسب با موضوع مورد بررسی قرار گرفته‌اند. در مقالات حیطه هوش مصنوعی با استفاده از معیارهای دقت[۱]، پوشش[۲] و صحت[۳] گزارش شده مقایسه صورت پذیرفته و با توجه به ماهیت پژوهش در کلیه موارد از ارائه تحلیل کاربردهای بالینی خودداری شده است.

بررسی‌ها شامل پژوهش‌های پردازش تصاویر دندانپزشکی داخل حفره دهان بوده و تصویربرداری عادی و اشعه ایکس را در برمی‌گیرد. تحلیل پژوهش‌های ارائه شده در راستای پاسخ‌گویی به نیاز تعیین سیر تکاملی رویکردهای پردازش تصاویر دندانپزشکی بوده و شامل بررسی بهبود کیفیت تصویر، تشخیص وبخش‌بندی دندان، تومور یا نشانک در حفره دهان و تعیین نوع بیماری است. به طور کلی پژوهش‌های حیطه تصاویر دندان را می‌توان به سه بخش، بهبود تصویر، تشخیص یا بخش‌بندی عنصر خاصی در تصویر و تعیین نوع بیماری عناصر تصویر تقسیم نمود. عنصر می‌تواند دندان، تومور، ضایعه یا غیره باشد، که در این پژوهش به طور خاص فقط دندان در نظر گرفته شده است.

امروزه بهبود چشم‌گیری در دستگاه‌ها و فرآیندهای تصویربرداری حوزه دندانپزشکی رخ داده است، از این رو تعداد کمی از پژوهش‌ها به بهبود تصویر پرداخته و اکثر پژوهش‌های این زمینه از روش‌های سنتی پردازش تصویر استفاده نموده‌اند. با این حال تصویربرداری دندانپزشکی به شرایط بیمار وابسته بوده و در صورت تکان خوردن سر تصویر کیفیت لازم را نخواهد داشت. از طرفی برخی اوقات نمی‌توان شرایط را برای تصویربرداری با کیفیت فراهم نمود، از این رو تکنیک‌های بهبود کیفیت تصویر همچنان اهمیت دارند.

منظور از تشخیص دندان تعیین محل دندان‌ها بدون توجه به نوع، نام یا شماره دندان بوده و صرفا تعیین کادر در برگیرنده دندان کافی است. زمانی که از شماره‌گذاری دندان صحبت می‌شود منظور تعیین نام، نوع یا شماره دندان تشخیص داده شده است، که در واقع در سطح بالاتر تشخیص باید دسته‌بندی دندان‌ها نیز صورت پذیرد. بخش‌بندی دندان شامل تعیین دندان به تفکیک لبه‌ها و

---

[۱] Accuracy

[۲] Recall

[۳] Precision

تعیین کامل آناتومی دندان است، در این حالت ممکن است هر یک از دندان‌ها مجزا یافت شوند و در برخی موارد به شکل به هم پیوسته از دیگر اجزای تصویر تفکیک شوند.

دسته‌بندی بیماری دندان دو قسم متفاوت دارد، در برخی موارد دسته‌بندی به منظور تفکیک دندان سالم و خراب است، که به این امر غربالگری گفته می‌شود، در قسم دوم دسته‌بندی نام بیماری است، که در آن بیماری دندان‌ها به تفکیک بیان می‌شود. توجه کنید برخی از بیماری‌های لثه، تومورها، استخوان فک و غیره بسیار به سلامت دندان مرتبط هستند، از این رو برخی پژوهش‌ها این بیماری‌ها را نوعی بیماری دندان تلقی می‌کنند. منظور از بخش‌بندی بیماری تعیین محل خرابی دندان (در تاج، ریشه و غیره) با استفاده از کادر یا لبه‌های پوسیدگی موجود در تصویر است، که شامل زیر مجموعه‌ای از کادر کل دندان است.

۳- انواع تصاویر دندان‌پزشکی

امروزه از روش‌های مختلف تصویربرداری پزشکی در تشخیص بیماری‌های دهان و دندان استفاده می‌شود. به طور کلی می‌توان این تصاویر را به چهار دسته تصاویر فلورانس فراطیفی[۱]، دامنه فرکانسی خاص[۲]، اشعه ایکس داخل و خارج دهان تقسیم نمود.

رادیوگرافی داخل دهانی یکی از پرکاربردترین روش‌های تصویربرداری دندانپزشکی است، که تصاویری با وضوح بالا جهت شناسایی بیماری‌های دندان و استخوان فک فراهم می‌کند. این تصاویر اطلاعات مفیدی در مورد ساختار و تراکم استخوان ارائه می دهند. دو روش برای تهیه این نوع تصاویر وجود دارد: روش زوایای موازی و نیم‌ساز. در روش اول سنسور به شکل موازی روی دندان‌ها قرار گرفته و کاملا دندان را در معرض اشعه ایکس قرار می دهد. در روش دوم گیرنده تا حد امکان نزدیک به دندان قرار گرفته و پرتو به صورت عمود بر خط فرضی هدایت می‌شود. این خط اجازه می دهد تا زاویه را به دو نیم تقسیم کند که یک محور طولانی را روی سطح دندان و گیرنده تشکیل می‌دهد [۶]. شکل (۱) نشان دهنده انواع روش‌های رادیوگرافی داخل دهان است. دندان پزشکان معمولا از سه روش رادیوگرافی داخل دهانی استفاده می کنند.

- اشعه ایکس بایت وینگ[۳]: تصویر واضحی از قوس های دندانی فک بالا و پایین در ناحیه خاصی از استخوان نگهدارنده ارائه می دهد. این تصاویر به تشخیص تغییرات پوسیدگی ، یافتن پوسیدگی خصوصا پوسیدگی‌های بین دو دندان و شناسایی ترمیم‌های گذشته کمک می‌کنند.
- اشعه ایکس پری آپیکال[۴]: دندان‌ها را در نمای تمام بعدی یکی از قوس‌های دندانی نشان می‌دهد و امکان تشخیص مشکلات در مجموعه خاصی از دندان‌ها را فراهم می‌نماید. شناسایی ناهنجاری‌های ساختار ریشه و تشخیص ساختار استخوان اطراف قوس با استفاده از این تصاویر صورت می پذیرد.
- اشعه ایکس اکزوال[۵]: این تصویر سطح داخلی دندان‌های قوس‌های فک بالا و پایین را نمایش داده و موقعیت دندان و رشد بعدی آن را می‌توان با استفاده از این تصاویر بررسی نمود.

کاربرد تصویربرداری خارج دهانی تشخیص مشکلات دندانی در فک و جمجمه است. این تصاویر بیماری‌های فک، جمجمه، ریشه دندان و غیره را نمایش می‌دهند. شکل (۱) نشان دهنده انواع روش‌های رادیوگرافی خارج دهان است. سه روش تصویربرداری متفاوت خارج دهانی وجود دارد [۲].

- پانورامیک اشعه ایکس[۶]: این روش درواقع نمایی دو بعدی از حفره دهان شامل فک بالا و پایین را با استفاده از اشعه ایکس نمایان می‌کند. این تصاویر جهت تشخیص دندان های نهفته و تومورهای دندانی استفاده می‌شوند [۷].
- سفالوگرام جانبی[۷]: تصویری شامل کل نمای سر از یک جانب جانب را نمایش داده و به پزشکان در تشخیص مشکلات استخوان فک کمک می‌کند [۸].
- توموگرافی محاسبه پرتو مخروطی[۸]: این نوع تصویربرداری ساختارهای داخلی بدن را به صورت تصاویر سه بعدی نشان می دهد و امکان شناسایی شکستگی‌ها و تومورها در استخوان های صورت را فراهم می‌کند. این روش در واقع با استفاده از اشعه ایکس یک راه حل اساسی برای محدودیت‌های رادیوگرافی معمولی ارائه می‌دهد [۹].

امروزه برخی از پژوهش‌ها به بررسی تصاویر غیرپزشکی برای تشخیص بیماری دندان پرداخته‌اند، این تصاویر با استفاده از دوربین‌های عادی و در قالب RGB اخذ می‌گردند و با عنوان تصاویر عادی از آن‌ها یاد می‌شود [۱۰] و [۱۱]. در این مقاله تمرکز اصلی بررسی پژوهش‌های انجام شده روی تصاویر رادیوگرافی داخل و خارج دهان و مواردی محدود از تصاویر عادی می‌باشد.

---

۱ Fluorescence Hyperspectral Imaging
۲ Spatial Frequency Domain Imaging (SFDI)
۳ Bitewing x-ray
۴ Periapical x-ray
۵ Occlusal x-ray
۶ Panoramic x-ray
۷ Lateral Cephalogram
۸ CBCT x-ray

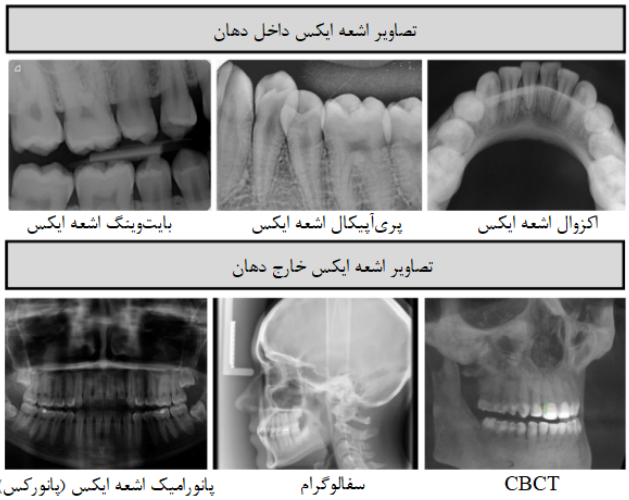

شکل (۱) : انواع تصاویر رادیوگرافی داخلی و خارجی دهان[۲]

۳-۱- پردازش تصاویر دندان‌پزشکی

تصویربرداری پزشکی نقش به سزایی درتشخیص، پیشگیری و درمان بیماری‌ها دارد. تصویربرداری دندان از هر نوع و به هر دلیلی که صورت پذیرد نیازمند تفسیر پزشک متخصص بوده و تشخیص برخی از مشکلات آنقدر دشوار است، که تجربه پزشکان در این تفاسیر از اهمیت بالایی برخوردار است. از این رو با توجه به، عدم دسترسی کلیه بیماران به پزشک با تجربه و از طرفی زمان‌بر بودن تفسیر تصاویر که می‌تواند منجر به خستگی پزشک و کاهش دقت او شود، بسیاری به فکر استفاده از روش‌های مختلف پردازش تصور جهت تفسیر خودکار تصاویر دندان افتاده‌اند.

تفسیر تصاویر پزشکی با توجه به تاثیر ویژه در تصمیم پزشک با حساسیت بالا صورت می‌پذیرد. تفسیر تصاویر دندان نیز از این دست بوده و با توجه به تعداد زیاد بیماری‌های دهان و دندان امکان تشخیص همه این بیماری‌ها و ارائه روش‌های درمانی به شکل خودکار تا کنون در هیچ پژوهشی فراهم نشده است. بهبود کیفیت تصویر، تشخیص، بخش‌بندی و شماره‌گذاری دندان، دسته‌بندی، تشخیص و بخش‌بندی برخی از بیماری‌های دندان در پژوهش‌های مختلف مورد بررسی قرار گرفته‌اند. اخیرا با توجه به عملکرد قابل قبول روش‌های یادگیری ماشین و به خصوص یادگیری عمیق در پردازش تصاویر، پژوهش‌های مربوط به تفسیر تصاویردندان‌پزشکی نیز براساس این روش‌ها ارائه می‌شوند.

۴- بهبود تصویر

بهبود کیفیت تصاویر پزشکی حساسیت بالایی داشته و با هدف افزایش دقت تشخیص دندان‌پزشک صورت می‌پذیرد. در بسیاری از موارد به دلیل تاثیر منفی که ممکن است، روش برجزئیات موجود در تصویر بگذارد، از روش‌های بهبود کیفیت تصاویرعادی در تصاویر پزشکی استفاده نمی‌شود. بهبود کیفیت تصویر در حیطه پزشکی بر اساس نیاز و جهت افزایش قدرت تفسیرپذیری تصویر صورت می‌پذیرد. بسیاری از روش‌های تفسیر تصاویر پزشکی پیش از انجام فرآیند تشخیصی به سراغ بهبود کیفیت تصویر می‌روند، که امروزه این امر در قالب لایه‌های ابتدایی شبکه‌های عمیق انجام می‌شود. با افزایش قدرت تجهیزات پزشکی نیاز به بهبود کیفیت تصویر کمتر شده، اما با توجه به شرایط تصویر برداری و اهمیت کاهش تابش اشعه به بیمار در تصویربرداری دندان‌پزشکی برخی اوقات به دلیل شکستگی‌های موجود در جمجمه، خردسال بودن بیمار و غیره بهبود کیفیت تصویر همچنان مورد نیاز است.

بهبود کیفیت تصویر با استفاده از روش سنتی به منظور تفکیک اجزا صورت می‌پذیرد. لین و همکاران [۱۲] یک سیستم دسته‌بندی و شماره‌گذاری دندان با استفاده از تصاویر بایت وینگ ارائه داده‌اند، که در این روش ابتدا به شکل هم زمان از تلفیق سه روش فیلتر هوموروفیک[۱]، بسط تباین[۲] همگن و تبدیل ریخت شناسی تطبیقی جهت بهبود کیفیت تصویر استفاده شده است. به این ترتیب با استفاده از آستانه‌های تکراری تفکیک دندان‌ها به شکل قابل قبولی صورت می‌پذیرد. بهبود تصویر، با استفاده از تکنیک‌های یکسان‌سازی هیستوگرام، در تصاویر دندان‌پزشکی نیز کاربرد دارد. احمد و همکاران [۱۴] با مقایسه کمی وکیفی چهار تکنیک یکسان سازی هیستوگرام تطبیقی[۳] (AHE)، یکسان‌سازی هیستوگرام تطبیقی تباین[۴] (CLAHE)، یکسان‌سازی هیستوگرام تطبیقی میانه[۵] (MAHE) و یکسان‌سازی هیستوگرام تطبیقی تباین تقویت شده[۶] (SCLAHE) نشان داده‌اند که تکنیک‌های بهبود کیفیت تصویر قابلیت تشخیص ناهنجاری‌ها را بالاتر می‌برند. تصاویر اشعه ایکس دندان معمولا با تشعشع پایین اشعه ایکس تهیه شده و از این رو اغلب به صورت تیره، حاوی نویز و تباین پایین هستند، استفاده از تکنیک مناسب جهت بهبود کیفیت تصویر می‌تواند تا حد زیادی تشخیص بیماری‌های ضایعه پری‌آپیکال را بهبود دهد. در این تحقیق بهبود کیفیت تصویر از طریق معیار های کمی شاخص بهبود تباین، نسبت سیگنال به نویز و خطای جذر میانگین مربعات انجام پذیرفته و شاخص کیفی با استفاده از ارزیابی پرسشنامه تهیه شده از دندانپزشکان گزارش شده است.

در پژوهشی مشابه، حنیفا و همکاران [۱۵] به منظور بهینه‌سازی تباین، افزایش روشنایی تصویر و کاهش نویز از چهار روش تبدیل مرزی (CT)، تبدیل موجک، کشش تباین (CS) و CLAHE استفاده کرده‌اند. نتیجه این مطالعه با توجه به معیارهای نسبت سیگنال به نویز قله[۷](PSNR) و میانگین مربعات خطا گزارش شده است، از بین چهار روش ارائه شده CT بالاترین میانگین امتیاز MSE و PSNR را بدست آورده است. با استفاده از روش موجک ورودی به تصاویر بسیار روشنی تبدیل می‌شود، که

---

۱ Homomorphic
۲ Contrast
۳ Adaptive Histogram Equalization
۴ Contrast Adaptive Histogram Equalization
۵ Median Adaptive Histogram Equalization
۶ Sharp Contrast Adaptive Histogram Equalization
۷ Peak Signal to Noise Ratio (PSNR)

قابلیت تشخیص را بسیار دشوار کرده است، از این رو این روش کمترین امتیاز را بدست آورده است. افزایش تباین تصاویر اشعه ایکس منجر به بهبود عملکرد متخصصین در تشخیص می‌شود. از این رو رومن و همکاران [۱۳] با بهره از روش‌های ریخت‌شناسی ریاضی، روش تبدیل مقیاس بالا با بازسازی ژئودزیک (MSTHGR) را ارائه نموده‌اند. این الگوریتم با افزایش تباین، جزئیات و لبه تصاویر پانورامیک اشعه ایکس را افزایش داده و ویژگی‌های متعدد تاریک و روشن را نمایان می‌کند. این روش با استفاده از ۵۹۸ تصویر پانورامیک اشعه ایکس با ۸ روش مشابه از دید بهبود تباین، میزان انرژی[۱] و فرکانس فضایی[۲] مقایسه شده و بهبود موضعی بهتری نسبت به سایر موارد داشته است.

هریس و همکاران [۱۴] از متغیرهای تطبیق تباین برای بهبود کیفیت تصویر رادیولوژی دندان استفاده کردند. نتایج حاصل از این تحقیق نشان داد این روش ساده نتایج امیدوار کننده ای از بهبود کیفیت تصویر فراهم کرده است. استفاده از فیلترهای مختلف نیز در بهبود تصاویر دندانپزشکی رایج است. رادهیا و همکاران [۱۶] پیش‌پردازش فیلتر گوسی و یکسان‌سازی هیستوگرام را جهت بهبود کیفیت تصویر پیش از بخش‌بندی دندان‌ها در تصویر رادیوگرافی معرفی کرده‌اند. در این تحقیق دو معیار نسبت سیگنال به نویزو برچسب‌گذاری اعتبارسنجی به ترتیب برای فیلتر گوسی ۳۲,۲۱، ۸۰,۵۸ درصد و برای یکسان‌سازی هیستوگرام ۲۲,۵۲، ۸۱,۸۸ درصد گزارش شده است. در تحلیل نتایج حاصل فیلتر گوسی به وضوح توانسته است کیفیت تصویر را بهبود بخشد، در مقایسه یکسان‌سازی هیستوگرام نسبت سیگنال به نویز پایین‌تری را نشان می‌دهد. این ممکن است به این معنا باشد که این روش به اندازه فیلتر گوسی در کاهش نویز و بهبود کیفیت تصویر مؤثر نبوده است. با این حال، درصد بالای برچسب‌گذاری اعتبارسنجی نشان می‌دهد که این روش در شناسایی و تفکیک دندان‌ها نیز عملکرد خوبی داشته است و می‌تواند به عنوان یک گزینه معتبر در فرآیند پیش‌پردازش در نظر گرفته شود.

بافت دندان، لثه، تومور، استخوان فک و غیره مشخص شده در تصاویر دندان قابل تفکیک است، از این رو برخی از پژوهش‌ها به بررسی ویژگی‌های بافت دندان پوسیده پرداخته‌اند. به عنوان مثال، گیتا و همکاران [۱۷] یک ویژگی بافتی مناسب برای تشخیص پوسیدگی دندان پیشنهاد نموده‌اند، که از فیلتر لاپلاس به منظور افزایش وضوح تصویر قبل از پردازش اصلی استفاده شده است. نتایج تجربی نشان دهنده عملکرد بهتر روش تفاوت سطح خاکستری[۳] (GLDM) و ماترس هم‌روی سطح خاکستری[۴] (GLCM) نسبت به دیگر ویژگی‌های بافتی است، که دقت ۹۶,۸۸ درصد را فراهم می‌نماید. از آنجا که فیلتر لاپلاس نمی‌تواند لبه‌های دندان و پس‌زمینه را با سطوح روشنایی یکسانی نمایش دهد، این مشکل با تقسیم‌بندی حل شده و با توجه به اینکه مناطق کوچک‌تر در یک تصویر تقریبا روشنایی یکنواختی دارند، از آستانه انطباقی استفاده شده است.

وینا و همکاران [۱۸] با استفاده از تکنیک‌های بهبود کیفیت تصاویر پانورامیک اشعه ایکس قابلیت تشخیص جرم دندان را فراهم نموده‌اند. همچنین جهت تشخیص کیست‌ها از روش GLCM استفاده شده، که این روش بافت تصاویر پانورامیک اشعه ایکس را با تعیین مقدار انرژی، همگنی، بی‌نظمی و تباین تعیین می‌کند. نتایج حاصل از این روش توسط رادیولوژیست فک و صورت مورد تایید قرار گرفته است. تفکیک بخش‌های مختلف عناصر دهان، جهت تعیین آستانه‌های بهبود تباین خاص برای هر بخش راه حلی برای غلبه بر ناکارآمدی تطبیق تباین تک آستانه‌ای است. ایندراسوار و همکاران [۱۹] روش قطعه‌بندی را برای افزایش تباین تصاویر دندان پیشنهاد نموده‌اند. در این روش از آستانه‌سازی بانکی فیلتر جهت‌دار بدون حذف[۵] و آستانه تطبیقی چند مرحله‌ای[۶] استفاده شده است. فرآیند بهبود تباین و تشخیص شکل دندان در سه مرحله اصلی تشکیل تصاویر، تقویت لبه و قطعه‌بندی انجام شده است. نتایج این روش روی ۴۰ تصویر اعمال شده و عملکرد آن با میانگین خطای ۱۷ درصد بهتر از روش‌های آستانه گذاری گزارش شده است. شکل ۲ نشان‌دهنده خروجی هر یک از مراحل فرآیند بهبود تباین روش نامبرده است.

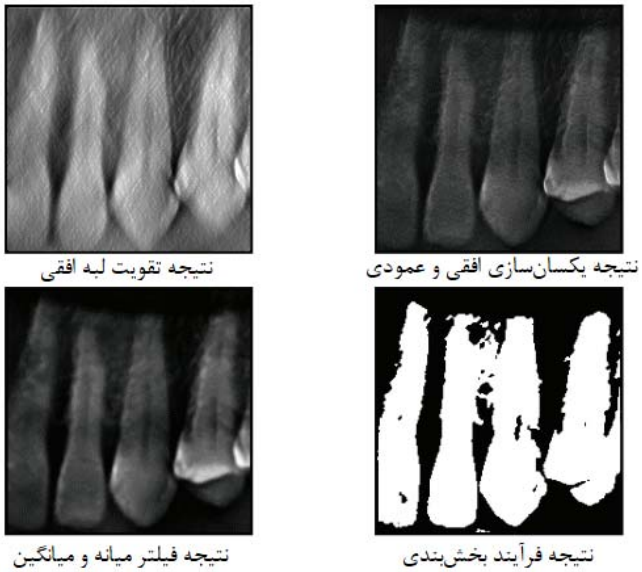

شکل (۲): فرآیند بهبود تباین تصویر[۱۹]

یوسفی و همکاران [۲۰] از فیلتر لاپلاس و سپس عملیات ریخت‌شناسی استفاده کرده‌اند. خروجی حاصل از این فرایند تحت تبدیل موجک ترکیب و به عنوان ورودی دسته‌بند بیز مورد استفاده قرار می‌گیرد. در نهایت مجددا از ترکیب تبدیل موجک استفاده

[۱] Entropy
[۲] Spatial Frequency
[۳] Gray Level Difference Method
[۴] Gray Level Co-occurrence Matrix
[۵] Decimation-Free Directional Filter Bank Thresholding
[۶] Multistage Adaptive Thresholding

شده و تصاویر اشعه ایکس دندان بهبود یافته‌اند. مطالعات اندکی در حیطه بهبود کیفیت تصویر دندانپزشکی از یادگیری ماشین استفاده نموده‌اند. دسته‌بند بیز قسمت‌ها و کانال‌های دندان را به شکل مستقل دسته‌بندی نموده از این رو بهبود کیفیت تصویر مستقل از بخش‌های دیگر انجام می‌شود. برخی از روش‌های بهبود تصویر برای بخش‌بندی و تشخیص دندان پیش از تکنیک‌های سنتی پردازش تصویر استفاده می‌شوند. ستیانیگروم و همکاران [۲۱] با استفاده از روش آستانه Otsu تصاویر اشعه ایکس را بهبود داده و از این بهبود برای تفکیک دندان‌های سالم و پوسیده استفاده کرده است. مقدار آستانه برای تصاویر دندان‌های سالم کمتر از دندان‌های پوسیده است. این فرآیند روی ۴۰ تصویر از ۱۰ بیمار متفاوت اعمال شده و نتایج حاصل تفکیک دندان‌ها و بخش‌بندی را بهبود داده است. زینل و دوستان [۲۲] به منظور بهبود تفاوت تباین و روشنایی تصاویر حاصل از روش‌ها و کانال‌های تصویر برداری مختلف با استفاده از روش CYcleGAN[1] تصاویر را با بهره‌گیری از مدل داده دیگر بهبود داده‌اند. CYcleGAN نوعی شبکه متخاصم با ورودی و خروجی تصویر است. ثبات چرخه در این شبکه تضمین کننده قابلیت برگشت تصویر بعد از تبدیل بوده و برای انجام این فرآیند نیاز به دو مولد و جداکننده می‌باشد. این روش نیازمند وجود مجموعه داده جفتی نیست، از این رو می‌توان از آن در فرایند بهبود کیفیت تصویر استفاده نمود.

بهبود تصاویر دندان از دید روشنایی اجزای تصویر نیز کاربرد دارد. لتک و همکاران [۲۳] با استفاده از الگوریتم Retinex تصاویر رادیوگرافی دندان را از نظر روشنایی و تباین بهبود داده و با استفاده از یک شبکه سبک وزن ویژگی‌های تصویر را استخراج می‌نمایند. نتایج تجربی نشان می‌دهد که استفاده از روش‌های مبتنی به Retinex در بهبود نمایش ضایعات پری‌آپیکال موثر بوده است. Retinex یک الگوریتم ثبات رنگ است، که با نرمال‌سازی تغییرات انعکاس و روشنایی، کیفیت تصویر را بهبود می‌دهد. ایده اصلی الگوریتم منعطف کردن تصویر در برابر شرایط روشنایی از طریق تقسیم اجزای روشنایی و انعکاس آن است. در پژوهشی دیگر نیز با استفاده از تکنیک‌های یادگیری عمیق، خان و همکاران [۲۴] به منظورحفظ سازگاری نور تطبیقی شبکه Dentical-Edification (Ded-Net) را معرفی نمودند. این شبکه از دو شاخه تشکیل شده و تصاویر ورودی را با چند لایه از دید بازتاب و روشنایی تقسیم می‌کند. سپس فرایندی تقویتی به منظور جلوگیری از تخریب پنهان بازتاب و روشنایی انجام شده و سازگاری نور تطبیقی با استفاده از شاخه دوم صورت می‌پذیرد. این شبکه با استفاده از تعداد محدودی تصاویر طیفی دهان و دندان (ODSI-DB) آموزش داده شده و نتایج حاصل از دید تجربی تباین و لبه‌های تصویر را بهبود داده است.

تفسیر تصاویر دندانپزشکی به دلیل ظرافت و حساسیت بالای دندان از اهمیت بالایی برخوردار است، بهبود کیفیت این تصاویر می‌تواند منجر به تشخیص بهتر بیماری و شرایط دهان شود. با این حال در گذشته پژوهش‌های بیشتری در این حیطه صورت گرفته و اکثر این پژوهش‌ها از روش‌های سنتی پردازش تصویر بهره گرفته‌اند، اما به مرور زمان نیاز به این امر کاهش یافته است. امروزه پژوهش‌های حیطه بهبود کیفیت تصویر از شبکه های عمیق جهت افزایش کیفیت استفاده می‌کنند، برخی از این روش‌ها پیش از تشخیص، شماره‌گذاری، بخش‌بندی و غیره دندان به شکل خودکار به منظور افزایش دقت روی تصاویر اعمال می‌گردد. جدول (۱) مزایا و معایب رویکردهای مختلف پژوهش‌های بررسی شده در این بخش را نمایش می‌دهد. بررسی پژوهش‌ها نشان می‌دهد که بهبود کیفیت تصاویر رادیوگرافی دندان‌ها نیازمند ترکیب چندین تکنیک و استفاده از معیارهای معتبر برای ارزیابی است. هر یک از روش‌ها نقاط قوت و ضعف خاص خود را دارند و انتخاب مناسب‌ترین روش بستگی به نوع تصویر و نیازهای تشخیصی دارد.

جدول (۱) : پژوهش‌های حیطه بهبود تصویر

رویکرد	ایده اصلی	مزایا/ معایب
روش‌های پردازش تصویر سنتی	تطبیق تباین [۱۲] و [۱۴] یکسان‌سازی هیستوگرام [۱۰] و[۱۵]و[۱۶] ریخت‌شناسی [۱۳] و[۱۷] و[۱۸] آستانه‌گذاری [۱۹] و [۲۱]	سادگی پیاده‌سازی/ از دست رفتن جزئیات، کاهش دقت
یادگیری ماشین	تبدیل موجک و دسته‌بندی [۲۰]	بهبود دقت/ کاربرد پایین
یادگیری عمیق	شبکه متخاصم[۲۲]، الگوریتم ثبات رنگ[۲۳]، De-Net [۲۴]	بهبود چشمگیر/ پیچیدگی پیاده‌سازی، کاربرد خاص

۵- تشخیص، شماره‌گذاری و بخش‌بندی

در تفسیر تصاویر دندانپزشکی ابتدا باید دندان و موقعیت آن تعیین شود. منظور از تشخیص، یافتن موقعیت دندان در حفره دهان است، در برخی از پژوهش‌ها صرفا تعیین وجود دندان [۳۰] در تصویر و موقعیت آن در دهان با رسم کادر هدف است. در بخش شماره‌گذاری دندان [۳۸] و [۴۰] و [۳۹] پس از تشخیص موقعیت هر دندان باید تعیین شود که هر دندان به خصوص از چه نوعی بوده و در یک سیستم شماره‌گذاری (۱۶ یا ۳۲) شماره دندان تعیین شود. بخش‌بندی دندان [۵۳] تا [۵۵] تنها به منظور تشخیص موقعیت دندان و تعیین دقیق مرز دندان انجام می‌شود. در این دست پژوهش‌ها تاج و ریشه دندان از بافت لثه تفکیک می‌شوند. ضرورت تفکیک مفاهیم تشخیص، شماره‌گذاری و بخش‌بندی در نوع برچسب‌گذاری داده و الگوریتم روش تشخیص نمایان می‌شود.

[1] Cycle-Consistent Generative Adversarial Network

۵-۱- تشخیص، شماره‌گذاری و تعیین نوع دندان

پردازش تصاویر دندان‌پزشکی با استفاده از روش‌های استخراج ویژگی صورت می‌پذیرد. روش‌های سنتی استخراج ویژگی با تکیه بر ریخت‌شناسی آناتومی دندان از گذشته برای تعیین محل دندان کاربرد داشته است، در این روش‌ها پس از تعیین ویژگی‌ها از الگوریتم‌های دسته‌بندی یادگری ماشین و یا منطق فازی برای تعیین نوع یا شماره دندان استفاده می‌شود. تشخیص نوع دندان با استفاده از ویژگی‌های آناتومیک از طریق استخراج ویژگی نیز امکان پذیر است.

لین و همکاران [۲۵] یک سیستم طبقه‌بندی و شماره‌گذاری دندان را در تصاویر رادیوگرافی بایت‌وینگ ارائه می‌دهند. بهبود تصویر شامل فیلتر کردن هوموورفیک، کشش کنتراست مبتنی بر همگنی و تبدیل مورفولوژیکی تطبیقی، که به طور همزمان کنتراست و یکنواختی روشنایی تصاویر رادیوگرافی را بهبود می‌بخشد، به منظور افزایش دقت صورت پذیرفته است. پس از جداسازی دندان‌ها به نواحی مورد نظر، استخراج کانتور دندان و پالپ (در صورت وجود) انجام می‌شود. برای دسته‌بندی دندان‌ها به آسیاب یا آسیای کوچک، از ماشین بردار پشتیبانی خطی استفاده می‌شود که نسبت‌های طول به عرض دندان‌ها و پالپ‌ها و اندازه تاج را به عنوان ویژگی‌ها در نظر می‌گیرد. در نهایت، یک الگوریتم تشخیص دندان‌های غایب و یک نسخه ساده از هم‌راستایی توالی که معمولاً در بیوانفورماتیک استفاده می‌شود، برای اختصاص شماره مناسب به هر دندان ارائه می‌شود. نتایج تجربی نشان می‌دهند که این سیستم به ترتیب دارای دقت ۹۵,۱ و ۹۸ درصد در دسته‌بندی و شماره‌گذاری است.

ماهور و همکاران [۲۶] از طبقه‌بندی بیزی برای تفکیک دندان‌ها به مولر و پرمولر استفاده کرده و سپس شماره‌گذاری دندان صورت می‌پذیرد. ویژگی‌های مورد استفاده در این دسته‌بندی شامل توصیف‌گرهای فوریه از کانتورهای دندان‌ها هستند. پس از دسته‌بندی، روابط فضایی بین دو نوع دندان برای تصحیح اشتباهات دسته‌بندی و تخصیص شماره به هر دندان بررسی می‌شود. آزمایش‌ها با ۵۰ تصویر بایت‌وینگ شامل بیش از ۴۰۰ دندان نشان می‌دهند که این روش قادر به دسته‌بندی و اختصاص شماره به دندان‌ها با دقت بالا است. نتایج نشان می‌دهند که الگوریتم ارائه شده می‌تواند مشکلات ناشی از دندان‌های ناقص در حاشیه تصاویر و همچنین دندان‌های نیش را به خوبی مدیریت کند.

آینی و همکاران [۲۷] روشی شامل سه مرحله اصلی تعیین موقعیت و اندازه دقیق گردن دندانی برای هر نوع دندان، دسته‌بندی دندان‌ها با استفاده از یک مدل خطی و شناسایی نوع و تعداد دندان‌های غایب و یا شکسته پیشنهاد کرده‌اند. این روش امکان می‌دهد اختصاص شماره‌هایی را به دندان‌های باقی‌مانده با استفاده از سیستم شماره‌گذاری جهانی می‌دهد. نتایج تجربی حاصل از بررسی بر روی پایگاه داده‌ای شامل ۴۷۶ دندان نشان می‌دهد که این روش در شناسایی گردن دندان و شماره‌گذاری دندان‌ها، و همچنین شناسایی دندان‌های شکسته و غایب نسبت به کارهای قبلی پیشرفته‌تر است. علاوه بر این، مقاله به بررسی تأثیر چرخش و تمایل دندان‌ها به سمت یکدیگر پس از کشیده‌شدن دندان‌ها می‌پردازد و بر اهمیت اندازه‌گیری عرض خط لثه و گردن دندانی به عنوان ویژگی‌های مرجع تأکید می‌کند.

در مقایسه سه پژوهش در زمینه شناسایی و دسته‌بندی دندان‌ها با استفاده از فرایند استخراج ویژگی دستی، هر یک از مقالات نقاط قوت و ضعف خاص خود را دارند. براساس نتایج حاصل [۲۵] با استفاده از تکنیک‌های پیشرفته بهبود تصویر، کارایی بالایی را ارائه می‌دهد، اما پیچیدگی روش و محدودیت داده‌ها ممکن است چالش‌ساز باشد. از طرفی [۲۶] با بهره‌گیری از طبقه‌بندی بیزی و مدیریت دندان‌های ناقص، دقت خوبی را در شناسایی کانتور دندان‌ها به نمایش می‌گذارد، اما محدودیت در تعداد تصاویر آزمایشی و عدم بررسی کامل روابط فضایی بین دندان‌ها از نقاط ضعف آن است. در نهایت [۲۷] با رویکرد جامع و تمرکز بر شناسایی دندان‌های غایب و شکسته، بر روی ۴۷۶ دندان آزمایش شده و سیستم شماره‌گذاری جهانی را معرفی می‌کند، اما پیچیدگی روش و نیاز به داده‌های بیشتر همچنان چالش‌هایی برای کارایی آن به شمار می‌آید.

روش‌های یادگیری ماشین، دسته‌بندی ویژگی‌های استخراج شده را براساس آستانه و پارامترهای متفاوت تفکیک می‌کنند. استفاده از استنتاج‌های منطق فازی قابلیت‌های متفاوتی را فراهم می‌کند. مارتین و همکاران [۲۸] روشی بر اساس خصوصیات فازی چندگانه جهت دسته‌بندی دندان‌ها در تصاویر رادیوگرافی پری‌آپیکال ارائه نموده‌اند. این روش با استخراج ویژگی‌های مساحت، محیط، طول، عرض و نسبت مساحت به محیط و نسبت طول به عرض برای تک تک دندان‌ها محاسبه شده و قانون فازی تشکیل می‌شود. نسبت‌های تعیین شده در ویژگی‌ها امکان غلبه بر مشکل تغییر نسبت به مقیاس را فراهم می‌کند. سیستم استنتاجی براساس ۳۱ دندان تعیین شده و در این پژوهش گزارش شده که با توجه به الگوی نسبی می‌توان دندان‌های آسیاب و آسیای کوچک را براساس نسبت اندازه تشخیص داد و دیگر دندان‌ها مانند ثنایا و نیش قابل تشخیص نیستند. در این پژوهش از ۷۸ تصویر پری‌آپیکال شامل ۲۲۳ دندان استفاده شده و دقت دسته‌بندی ۸۲/۵۱ درصد گزارش شده است.

این روش با استفاده از روش خصوصیات فازی چندگانه، رویکردی متفاوت را برای دسته‌بندی دندان‌ها در تصاویر رادیوگرافی پری‌آپیکال ارائه می‌دهد. با این حال، دقت نسبی ۵۱,۸۲ درصدی آن نسبت به [۲۵] که دقت بالاتری را ارائه می‌دهند، پایین‌تر است. همچنین، در مقایسه [۲۷] که به شناسایی دندان‌های غایب و شکسته توجه دارد، این پژوهش محدودیت‌هایی در شناسایی دندان‌های خاص مانند ثنایا و نیش دارد. در نتیجه، هرچند روش فازی مزیت‌هایی در مدیریت

تغییرات مقیاس دارد، اما دقت پایین‌تر و محدودیت در شناسایی برخی دندان‌ها از نقاط ضعف آن به شمار می‌آید.

با توجه به ضرورت افزایش دقت تفسیر تصاویر پژوهش‌های بسیاری با استفاده از روش‌های استخراج ویژگی خودکار و تکیه بر یادگری عمیق انجام شده است. میکی وهمکاران [۲۹] با استفاده از ۵۲ تصویر CBCT مدلی براساس شبکه پیچشی عمیق معرفی نموده‌اند. این مدل جهت ثبت پرونده بیماران در پزشکی قانونی ارائه شده است. پس از مرگ وضعیت دندان‌ها در نمودار دندانی ثبت شده و با وضعیت پیش از مرگ مقایسه می‌شود، این امر با توجه به متغیر بودن وضعیت جسد در حوادث متفاوت علاوه بر دشواری‌های روحی به دقت و تخصص نیز نیازمند است. مدل ارائه شده با معماری AlexNet، از ۵ لایه پیچشی، سه لایه ادغام و دولایه اتصال کامل تشکیل شده است. شبکه با استفاده از ۵۲ تصویر رادیوگرافی، ۴۲ مورد برای آموزش و ۱۰ مورد برای آزمایش با تفکیک تصویر، هر یک از دندان‌ها وزن‌دهی و ارزیابی شده است. جهت غلبه بر کمبود تعداد داده‌ها از دو تکنیک چرخش و تغییر شدت استفاده شده و برای جلوگیری از تاثیر نحوه نمونه‌گیری سه مرتبه این کار تکرار شده است. میانگین دقت ۸۸,۸ درصد برای این مدل گزارش شده و مدل توانایی دسته‌بندی ۷ نوع دندان را دارد.

پژوهش‌های حیطه دندان‌پزشکی طیف گسترده‌ای داشته و در برخی از پژوهش‌ها تعداد مختصری از داده‌ها نتایج قابل قبولی را فراهم آورده‌اند. تشخیص نوع دندان با استفاده از تصاویر بدون در نظر گرفتن موقعیت دندان‌ها تاکنون انجام نشده است. از این رو چن و همکاران [۳۰] مدلی مبتنی بر شبکه عصبی پیچشی بر اساس شرایط سه بعدی دندان ارائه کردند. این مدل دسته‌بندی ۸ دندان (آسیاب و آسیای کوچک یک و دو فک بالا و پایین) را با آنالیز ریخت‌شناسی سطح اکزوال معرفی نموده‌اند. سطح اکزوال سه بعدی به تصویر عمقی به منظور دسته‌بندی بر اساس CNN تبدیل می‌شود. با توجه به ترتیب دندان‌ها از دسته‌بندی سلسله مراتبی استفاده شده که هر زیر شبکه از دو مرحله دسته‌بندی آبشاری جهت تفکیک ۸ دندان استفاده کرده است. با استفاده از تبدیلات هندسی و شبکه‌های متخاصم مولد پیچیده[1] (DCGAN)، افزایش داده برای هر زیر شبکه آبشاری انجام شده است.

نتایج گزارش شده نشان دهنده بهبود دسته‌بندی، پس از ترکیب روش سنتی و خروجی شبکه DCGAN است. آموزش مدل با استفاده از تصاویر حاصل از یک اسکنر سه بعدی داخل دهان که برای بررسی محل قرارگیری ارتودنسی کاربرد دارد، صورت پذیرفته است. دقت گزارش شده در این پژوهش ۹۱,۳۵ درصد است، که تصاویر مصنوعی ایجاد شده جهت آموزش مناطق مهم کوچک‌تر عملکرد بهتری داشته‌اند، همچنین برای تشخیص حفره‌ها، شیارها و مناطق مهم در دسته‌بندی آبشاری کاربرد مناسبی داشته‌اند. ترکیب روش‌های سنتی و مدرن، بهبود قابل توجهی در دسته‌بندی دندان‌ها نمایش می‌دهد. این نوآوری می‌تواند به عنوان یک الگو برای تحقیقات آینده در این زمینه باشد. از نقاط قوت این پژوهش شامل دقت بالا، استفاده از تکنیک‌های نوین برای افزایش داده و توانایی در شناسایی جزئیات مهم دندانی است، اما وابستگی به تصاویر سه‌بعدی و پیچیدگی در پیاده‌سازی از نقاط ضعف آن به شمار می‌آید. در مقایسه با روش‌های استخراج ویژگی دستی [۲۸] و[۲۵] این پژوهش دقت بیشتری را فراهم نموده، که در این نتیجه‌گیری به متفاوت بودن تعداد و نوع داده‌ها نیز باید توجه کرد.

مدل‌های آشکارسازی دو مرحله‌ای کاربرد بالایی در شناسایی محل و شماره دندان‌ها در تصاویر مختلف دارند، این روش‌ها با وجد سرعت کمتر از روش‌های تک مرحله‌ای دقت بسیار خوبی را برای دسته‌بندی فراهم نموده و نیاز به استخراج ویژگی دستی و دسته‌بندی مجزا را از بین می‌برند. گروز و همکاران [۳۱] مدل تشخیص و شماره‌گذاری دندان را در سه بخش با بهره‌گیری از مدل R-CNN ارائه نموده که در بخش اول دسته‌بند فک، در بخش دوم دسته‌بند محلی و در نهایت یک دسته‌بند کامل برای تعیین شماره دندان استفاده شده است. با استفاده از ۱۶۸۶ تصور پری‌آپیکال مدل آموزش و آزمایش شده، که مقدار صحت ۷۸/۱۲ درصد و پوشش ۹۸/۶۷ درصد توسط مدل فراهم آورده شده است. روش‌های سریع‌تری نیز برای شماره‌گذاری با استفاده از مدل R-CNN پیشنهاد شده‌اند. بیلگیر و همکاران [۳۲] با استفاده از ۲۴۸۲ تصویر پانورامیک اشعه ایکس روشی جهت تشخیص و شماره‌گذاری دندان براساس R-CNN سریع‌تر ارائه نموده‌اند. در این پژوهش دندان‌ها براساس ربع‌های دهان، هر یک با اعداد بین یک تا هشت شماره‌گذاری شده‌اند و برای غلبه بر مشکل نبود یک دندان مدل تشخیص تک دندان استفاده شده است. صحت ۹۶/۵۲ درصد و پوشش ۹۵/۵۹ درصد برای این مدل گزارش شده است.

یاسا و همکاران [۳۳] نیز با استفاده از مدل R-CNN سریع‌تر روشی جهت تشخیص وشماره‌گذاری دندان‌ها در تصاویر بایت‌وینگ ارائه نموده‌اند. آن‌ها با استفاده از ۱۱۲۵ تصویر بایت‌وینگ، مدل را با ۲۴ کلاس جهت تشخیص دندان‌های نیش، آسیاب و آسیای کوچک آموزش داده‌اند. مقدار صحت ۹۲/۹۳ درصد و پوشش ۹۷/۴۸ درصد برای این مدل گزارش شده است. کلیک و همکاران [۵] با استفاده از R-CNN سریع‌تر آموزش داده شده با COCO مدلی جهت تشخیص و شماره‌گذاری دندان‌های شیری ارائه نموده‌اند. در این روش از۴۲۱ تصویر پانورامیک اشعه ایکس استفاده شده و دندان‌ها به ۲۰ دسته مجزا تقسیم‌بندی شده‌اند. پس از ارزیابی مدل صحت ۹۸/۰۴ درصد و پوشش ۹۵/۷۱ درصد فراهم شده است. اندازه و مشخصات دندان شیری چالش‌های این پژوهش را بالاتر می‌برد با این حال دقت بدست آمده در مقایسه با پژوهش‌های قبل قابل قبول است، با

[1] Deep Convolutional Generative Adversarial Networks

توجه به تعداد کم تصاویر استفاده شده در این پژوهش استفاده از COCO این کمبود را جبران کرده است. استفاده از داده‌های زیاد و متنوع در این پژوهش تعمیم‌پذیری مدل را بالابر ده و نسبته به [۳۱] تا [۳۳] دقت بالاتری فراهم شده است. با این وجود [۳۳] مدلی ارائه نموده است که توانایی تشخیص نوع دندان در تصاویر بایت‌وینگ، که ممکن است برخی از دندان‌ها در آن به شکل ناقص نمایان شود را فراهم نموده است، در نتیجه روش R-CNN سریع‌تر در تشخیص و شماره‌گذاری دندان عملکرد قابل قبولی برای انواع تصاویر فراهم آورده است. در حالی که این مدل‌ها به تعداد داده‌ها وابستگی بالایی دارند.

چن و همکاران [۳۴] با استفاده از فیلم‌های پری‌آپیکال و R-CNN سریع‌تر روشی جهت تشخیص دندان ارائه نموده‌اند. در این روش سه تکنیک پس‌پردازش، فیلتر کادرهای هم‌پوشان خروجی R-CNN سریع‌تر، مدل مجزا شبکه عصبی جهت تشخیص دندان‌های کشیده شده و مدل براساس شماره‌گذاری دندان جهت حذف برچسب‌های نقض کننده قوانین بصری پیشنهاد شده‌اند. مدل پیشنهادی از دید کمی و کیفی مورد بررسی قرار گرفته و دقت بالای ۹۰ درصد را فراهم نموده، علاوه براین در مقایسه با نظرات سه دندان پزشک خروجی مدل هم‌تراز با نظرات یک دندانپزشک جوان گزارش شده است. در این روش به منظور بهبود محل کادرهای استخراج شده برای دندان‌ها، نتایج خروجی شبکه عصبی با استفاده از دانش قبلی ماتریس محل دندان‌ها مورد پردازش قرار گرفته‌اند. این رویکرد در مقایسه با رویکردهای قبلی با تأکید بر استفاده از دانش قبلی و پس‌پردازش، می‌توانند به بهبود دقت و کیفیت نتایج کمک کند. با این حال تغییر معماری آشکارساز R-CNN نیز می‌تواند عملکرد مدل را تغییر دهد.

توزف و همکاران [۳۵] با استفاده از R-CNN سریع‌تر فرآیند شماره‌گذاری دندان براساس نماد FDI را با آموزش ۱۳۵۲ تصویر پانورامیک اشعه ایکس انجام داده‌اند. جهت بهبود روش‌پیشنهادی از شبکه عصبی پیچشی سنتی با معماری VGG-16 استفاده شده و ارزیابی عملکرد سیستم با ۲۲۲ تصویر، ۹۹,۴۱ درصد صحت شماره‌گذاری گزارش شده است. همچنین عملکرد تشخیص سیستم را مشابه متخصصان معرفی کرده و نتایج ارزیابی خطای سیستم را مشابه با متخصصان که صحت ۹۹/۹۹ و پوشش ۹۹/۸۰ داشته است، گزارش کرده‌اند. نتایج گزارش شده قدرت بالای معماری استفاده شده را تعیین می‌کند. VGG-16 از ۱۳ لایه پیچشی و سه لایه اتصال کامل تشکیل شده و در پردازش تصاویر پزشکی کاربرد زیادی دارد. با این حال استفاده از تصاویر بیشتر در آموزش مدل قدرت تعمیم‌پذیری را بالاتر می‌برد. شبکه‌های پیچشی در استخراج ویژگی‌های تصاویر کاربرد ویژه‌ای دارند، R-CNN ابتدا نواحی پیشنهادی را تعیین نموده و سپس با استفاده از شبکه‌های کانولوشن به استخراج اطلاعات می‌پردازد، این فرایند منجر به فراهم آوری دقت بالایی می‌شود. این مدل توانایی تشخیص همزمان چند دندان در تصویر را دارد. میما و همکاران [۳۶] یک شبکه عصبی پیچشی R-CNN[1] سریع‌تر جهت تشخیص محل دندان معرفی نموده‌اند. در این پژوهش از ۱۶۰ تصویر پانورامیک اشعه ایکس دندان استفاده شده و برای کاهش موارد مثبت کاذب[2] ابتدا شبکه ناحیه‌ای مستطیل شکل شامل کل دندان‌ها استخراج سپس ناحیه به شش قسمت تقسیم می‌شود. این مدل توانایی تشخیص و دسته‌بندی ۳۲ دندان با دقت ۹۱,۷ درصد را دارد، که در مقایسه با اعمال R-CNN سریع‌تر برای کل تصویر با دقت ۸۸,۸ درصد بهبود چشم‌گیری را فراهم نموده است.

استفاده از روش‌های یادگیری عمیق در دسته‌بندی نوع یا شماره دندان کاربرد بالایی دارد با این حال این مدل‌ها نقاط ضعفی دارند. تلفیق روش‌های یادگیری عمیق و اکتشافی عملکرد مناسبی را برای مجموعه داده کم فراهم می‌آورد. کیم و همکاران [۳۷] با استفاده از ترکیب شبکه R-CNN، تشخیص دهنده چند ناحیه‌ای تک نما[3] (SSD) و روش‌های اکتشافی مدلی جهت تشخیص و شماره‌گذاری دندان‌ها در تصاویر پانورامیک اشعه ایکس ارائه نموده‌اند. این روش به میانگین دقت ۹۶,۷ درصد برای تشخیص و ۸۴,۲ درصد جهت شماره‌گذاری صحیح دست یافته است. ۲۵۳ تصویر برای آموزش و ۵۰ تصویر جهت آزمایش استفاده شده‌اند که توانایی تشخیص تاج و ایمپلنت دندان را نیز به شکل مجزا فراهم می‌کنند. شبکه SSD در یک مرحله همزمان دسته و کادر دندان را بررسی می‌کند، عملکرد این شبکه در تصاویر با کیفیت پایین بسیار مناسب است و از نگاشت چند ویژگی در هر مرحله استفاده می‌کند. در نتیجه این شبکه توانایی پیش‌بینی احتمال دسته و موقعیت را دارد. بیلگر و همکاران [۳۸] با استفاده از شبکه عصبی R-CNN سریع‌تر مدلی جهت شماره‌گذاری دندان‌ها معرفی کردند. این مدل با استفاده از ۲۴۸۲ تصویر آموزش دیده و پوشش ۹۵,۵۹ و صحت ۹۶,۵۲ درصد برای این مدل گزارش شده است. در این پژوهش از تصاویر دندان‌های شیری، ناهنجاری‌های رشد دندان، جابجایی دندان‌های نیش و غیره استفاده نشده و مدل با استفاده از تصاویر دندان‌های دائمی که شامل ترمیم‌ها و مصنوعات بودند، آموزش داده شده است.

مقایسه مدل‌های مختلف R-CNN در شناسایی و شماره‌گذاری دندان‌ها نشان‌دهنده تنوع رویکردها و داده‌های مورد استفاده است که هر یک نقاط قوت و ضعف خاص خود را دارند. [۳۲] مدلی سریع و کارآمد ارائه داده، که به خوبی مشکلات ناشی از نبود دندان را مدیریت می‌کند، اما وابستگی به تعداد بالای تصاویر ممکن است محدودیت‌هایی را ایجاد کند. این درحالی است که استفاده از نوع دیگر تصاویر [۳۳] در مقایسه با دیگر پژوهش‌ها از تنوع کمتری برخوردار است. البته استفاده از تصاویر متفاوت و دسته‌بندی دندان‌های شیری [۵] دلیل چالش‌های خاص

---

[1] Region-based Convolutional Neural Network
[2] False Positive
[3] Single Shot Multibox Detector

این نوع دندان‌ها، حائز اهمیت است. استفاده از تکنیک‌های پس‌پردازش و دانش قبلی [۳۴]، دقت بالای ۹۰ درصد را فراهم می‌کند، که بهبود کیفیت نتایج را نشان می‌دهد، تغییر معماری [۳۵] در روش‌های R-CNN سریع‌تر دقت‌های متفاوتی فراهم می‌کند. بررسی قدرت معماری‌های مختلف می‌تواند یکی از موضوعات چالش برانگیز باشد. در حالی که استفاده از داده‌های زیاد و متنوع می‌تواند به بهبود دقت کمک کند، چالش‌های خاص هر نوع تصویر و نوع دندان نیز باید در نظر گرفته شوند. محدودیت تعداد داده [۳۷] و اعمال چارچوب‌های متفاوت [۳۸] برای داده‌های مدل منجر به کاهش تعمیم‌پذیری می‌شود.

اوزسیلیک و همکاران [۳۹] DentifyNet را به عنوان معماری جدید یادگیری عمیق برای تشخیص و شماره‌گذاری خودکار دندان‌ها معرفی کرده‌اند. این مدل با استفاده از چارچوب R-CNNسریع‌تر سفارشی، شبکه‌های هرم ویژگی (FPN)، ساختارهای لنگر انعطاف‌پذیر و RoI زاویه دار، به افزایش دقت تشخیص کمک می‌کند. DentifyNet بر روی ۴۶۸ تصویر پانورامیک که توسط کارشناسان دندان‌پزشکی با استفاده از سیستم شماره‌گذاری FDI نشانه‌گذاری شده بودند، آموزش و ارزیابی شد. نتایج تجربی نشان می‌دهد که این مدل با دستیابی به صحت ۹۷,۵۲ درصد، پوشش ۹۷,۴۹ درصد دقت کلی ۹۷,۵۰، عملکردی فراتر از معماری‌های استاندارد R-CNN سریع‌تر ارائه می‌دهد. این معماری به طور مؤثری به تشخیص موارد چالش‌برانگیز، مانند دندان‌های مشابه مجاور و دندان‌های غایب، پرداخته است. در بررسی مقالات مختلف، می‌توان به تفاوت‌های قابل توجهی در روش‌های داده، معیارهای ارزیابی و مزایا و معایب هر یک از مدل‌ها پی برد. در مجموع، در حالی که همه این مدل‌ها به بهبود دقت و کارایی در تشخیص دندان‌ها کمک کرده‌اند، DentifyNet به دلیل استفاده از تکنیک‌های نوین و داده‌های متنوع‌تر، بهترین عملکرد را در مقایسه با سایر مدل‌ها ارائه می‌دهد.

معماری‌های گوناگون یادگیری عمیق عملکرد مناسبی در تفسیر تصاویر پزشکی دارند. آشکارسازهای دو مرحله‌ای ابتدا نواحی از تصویر که ممکن است شی در آن باشد را بررسی کرده و در مرحله دوم ویژگی را با استفاده از CNN استخراج می‌کنند و در نهایت شی دسته‌بندی می‌شود. این در حالی است که آشکارسازهای تک مرحله‌ای همزمان با استخراج ویژگی دسته‌بندی را نیز انجام می‌دهند. این امر منجر به افزایش سرعت مدل می‌شود. موریشیتا و همکاران [۴۰] شبکه آشکارساز چند جعبه تک مرحله‌ای به همراه یک شاخه جانبی معرفی نمودند، که در دو مرحله تک کلاس تنها جهت تشخیص دندان و ۱۶ کلاس جهت تشخیص نوع دندان کاربرد دارد. نتایج حاصل ادغام شده و در نهایت ۳۲ دندان متفاوت دسته‌بندی می‌شوند. این پژوهش با استفاده از ۹۵۰ تصویر پانورامیک اشعه ایکس به نرخ دسته‌بندی ۹۶,۷۹ درصد برای ۳۲ دندان دست یافته است.

اورهان و همکاران [۴۱] یک سیستم مبتنی بر یادگیری عمیق جهت دسته‌بندی ریخت‌شناسی ریشه دندان‌های آسیاب اول فک پایین در تصاویر CBCT معرفی کردند. این پژوهش با استفاده از ۴۰۰ تصویر، دقت تشخیصی ۸۶,۹ درصد را برای تعیین ریشه‌های منفرد و اضافه گزارش کرده است. در این پژوهش با استفاده از ۱۶۳ تصویر تصادفی عملکرد سیستم یادگیری عمیق با دو رادیولوژیست مجرب با بیش از ۲۰ سال تجربه مقایسه شده و تصاویر دندان از دید وجود ریشه‌های دیستال منفرد و اضافه مورد بررسی قرار گرفته‌اند. برای هر دو مدل AlexNet و GoogleNet نسبت به رادیولوژیست‌ها از دید دقت، صحت و پوشش عملکرد بهتری گزارش شده است.

چنگ و همکارن [۴۲] روش محلی‌سازی نقطه‌ای و تنظیم فاصله را برای تشخیص دندان پیشنهاد داده‌اند. شبکه پیشنهادی ابتدا رگرسیون نقطه مرکزی را برای تمام دندان‌های آناتومیک بدست می‌آورد، که به طور خودکار هر دندان تشخیص داده شود، سپس شبکه عصبی چند وظیفه‌ای جهت بهبود دقت استفاده می‌شود. شبکه پیشنهادی به دلیل استفاده از رگرسیون قادر به تشخیص ۳۲ نقطه ثابت بدون تشخیص دندان است، در نتیجه قدرت تشخیص دندان‌هایی که در دهان نیستند، را دارد. میزان بهبود نسبت به روش‌های دیگر جهت تشخیص دندان ۱۵,۷۱ درصد اعلام شده است. شکل (۳) نحوه تعیین نقاط انحراف در نظر گرفته شده را نمایش می‌دهد. در مقایسه می‌توان دریافت [۴۱] روی تشخیص ریخت‌شناسی دندان‌ها تمرکز داشته، همچنین مدل‌های پیشنهادی توانایی تشخیص جزئیات بالا را دارند و با انسان رقابت می‌کنند، در حالی که [۴۲] بر روی محلی‌سازی و تشخیص دندان‌ها به‌طور کلی تأکید دارد، با این حال مشکل نبود دندان در تصاویر پانورکس تاثیر مخربی بر دقت مدل‌های یادگیری دارد، استفاده از تکنیک تشخیص محل دندان کشیده شده منجر به افزایش دقت مدل شده است. طبق جدول (۲) باتوجه به تفاوت نوع تصاویر استفاده شده در مقالات نمی‌توان روشی را بر دیگری برتری داد، اما کارکرد مناسب شبکه‌های یادگیری عمیق مشهود است.

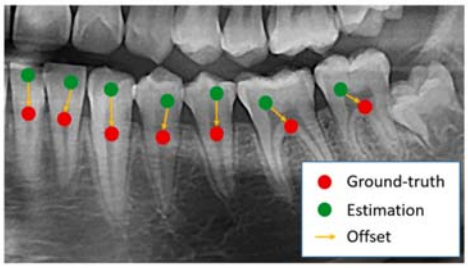

شکل (۳): بردار مرزی با توجه به نقطه مرکزی محل حقیقی [۴۲]

در برخی موارد دقت مدل‌های R-CNN از نوع آشکارساز دو مرحله‌ای کمتر از روش‌های YOLO از نوع آشکارساز تک مرحله‌ای است. رمضان و همکاران [۴۳] به بررسی عملکرد مدل یادگیری عمیق YOLOv10 در تشخیص و شماره‌گذاری دندان‌ها

در تصاویر پانورامیک کودکان پرداخته‌اند. با استفاده از ۲۰۰ تصویر پانورامیک و برچسب‌گذاری دستی ۸۱۵۳ دندان، داده‌ها به نسبت ۷۰درصد برای آموزش، ۱۵ درصد برای آزمون و ۱۵ درصد برای اعتبارسنجی تقسیم شدند. نتایج نشان می‌دهد که صحت ۹۰، پوشش ۹۴ و میانگین دقت (mAP50) ۹۶,۸ درصد به دست آمده است. این نتایج نشان‌دهنده توانایی بالای مدل در تشخیص دقیق دندان‌های شیری و دائمی است. همچنین، YOLOv10 با حذف نیاز به مراحل اضافی مانند NMS ، زمان پردازش را کاهش داده و کارایی را افزایش می‌دهد. در مقایسه با [۳۶] این رویکرد نه تنها دقت بالاتری دارد، بلکه به دلیل استفاده از تعداد بیشتری تصویر، می‌تواند به تعمیم‌پذیری بهتری در تشخیص دندان‌ها دست یابد. با این حال، معایب هر دو روش نیز قابل توجه است.

شبکه آشکارساز [۴۰] به دلیل استفاده از یک شبکه پیچیده‌تر و تعداد بیشتری از تصاویر، ممکن است زمان پردازش بیشتری را طلب کند. در حالی که دقت بالای ۹۶,۷۹ درصد نشان‌دهنده کارایی بالای این روش است. این در حالی است که، [۴۲] به دلیل توانایی تشخیص دندان‌های غایب، ممکن است در سناریوهایی که نیاز به شناسایی دندان‌ها در شرایط خاص وجود دارد، مفیدتر باشد. در تشخیص محل دندان شبکه‌های R-CNN سریع‌تر به دلیل سرعت بالا و از طرفی حساسیت به محل محبوبیت بالایی دارند. در تصاویر پری‌آپیکال غلبه بر سناریوهای دندان غایب اهمیت دارد، از این رو استفاده از شبکه‌های از پیش آموزش دیده نیز در تشخیص و شماره‌گذاری دندان کاربرد دارد و منجر به افزایش سرعت مدل می‌گردد.

رویکرد [۳۲] به وضوح بر روی تصاویر پانورامیک تمرکز دارد که می‌تواند اطلاعات بیشتری درباره ساختار دندان‌ها ارائه دهد. تغییر رویکرد تشخیص دسته‌ای دندان‌ها به مدل تک دندان با تشخیص ربع دهان دقت کمتری را نسبت به [۴۲] فراهم نموده با این حال این روش تعمیم‌پذیری بالاتری داشته و مجموعه داده زیادی را استفاده کرده است. همچنین مشابه با [۴۲] با تمرکز بر روی مدل تشخیص تک دندان، به یک چالش مهم در تشخیص دندان‌ها پاسخ داده‌اند، به ویژه در شرایطی که یک دندان وجود ندارد. تصاویر بایت‌وینگ اطلاعات دقیق‌تری را نسبت به بخشی از دندان‌ها فراهم می‌کنند از این رو تشخیص شماره دندان در این تصاویر دشوار است، [۳۳] نوع و نام هر دندان را تشخیص داده و با استفاده از ۲۴ کلاس برای تشخیص دندان‌ها، رویکردی متنوع‌تر را اتخاذ کرده که می‌تواند به شناسایی دقیق‌تر دندان‌ها کمک کند. [۳۱] با تقسیم مدل به سه بخش مختلف، رویکردی ساختاریافته و جامع‌تر را ارائه داده که می‌تواند به بهبود دقت کلی کمک کند و در نهایت دقت کمتر و تعمیم‌پذیری بالاتر نسبت به سایرین دارد.

در مقایسه [۲۸] با استفاده از ویژگی‌های آناتومیک و روش‌های فازی، رویکردی ساده‌تر و قابل فهم‌تر را ارائه داده، اما این روش ممکن است در برخی موارد به دقت کمتری منجر شود.

این مقایسه نشان می‌دهد که انتخاب روش و نوع داده‌ها می‌تواند تأثیر زیادی بر نتایج و دقت تشخیص دندان‌ها داشته باشد.

با توجه به جدول (۲) دقت‌های گزارش شده در این پژوهش‌ها نشان‌دهنده تنوع قابل توجهی در عملکرد مدل‌ها است. به عنوان مثال [۳۵] با صحت ۹۹,۴۵ درصد یکی از بالاترین صحت‌ها را با استفاده از R-CNN سریع‌تر فراهم نموده است. در حالی که [۲۸] با دقت ۵۱,۸۲ درصدی، نتایج کمتری را ارائه می‌دهد. نوع تصاویر استفاده‌شده در این پژوهش‌ها تأثیر زیادی بر دقت و قابلیت تعمیم مدل‌ها دارد. نوآوری‌های موجود در این پژوهش‌ها نشان‌دهنده پیشرفت‌های قابل توجهی در حوزه تشخیص دندان است. [۳۰] با ترکیب روش‌های سنتی و مدرن، به بهبود قابل توجهی در دسته‌بندی دندان‌ها دست یافته و [۳۷] قدرت ترکیب مدل‌ها را نمایش می‌دهد، که می‌تواند رویکردی مناسب برای تحقیقات آتی را نمایش دهد. استفاده از شبکه‌های یادگیری عمیق، به ویژه R-CNN و روش‌های ترکیبی، به بهبود دقت و کارایی در تشخیص دندان‌ها کمک کرده است. با این حال، انتخاب نوع داده‌ها و روش‌ها می‌تواند تأثیر زیادی بر نتایج داشته باشد. در نهایت، پژوهش‌ها باید به سمت بهبود تعمیم‌پذیری و کاهش زمان پردازش حرکت کنند تا در شرایط بالینی واقعی به کارایی بهتری دست یابند.

۵-۲- تشخیص مصنوعات دندان

مصنوعات دهان شامل ترمیم‌ها، ایمپلنت و غیره در تصاویر با فرکانس متفاوتی نمایش داده می‌شوند. تشخیص برخی از پوسیدگی‌ها پس از ترمیم دندان به علت دشواری تفکیک مرز دندان و مصنوعات دشوار است. از طرفی تشخیص نوع ایمپلنت دندان نیز با استفاده از تصاویر دندان پزشکی ممکن بئده و در روند درمانی نقش به سزایی دارد. تشخیص ایمپلنت‌های تصویر نیز به عنوان ساده‌ترین عملیات پردازش تصویر کاربرد دارد. جانگ و همکاران [۴۴] مدلی مبتنی بر R-CNN سریع‌تر را جهت تشخیص ایمپلنت و بافت اطراف آن با استفاده از۳۰۰ تصویر رادیوگرافی پری‌آپیکال پیشنهاد نموده‌اند. این مدل یادگیری عمیق توانایی تشخیص دندان ایمپلنت شده را با صحت ۹۷,۷ درصد فراهم نموده است. در مدل پیشنهادی از یک شبکه پیشنهاد محل[۱] (RPN) استفاده شده، که لایه دسته‌بندی و رگرسیون، به ترتیب تشخیص ایمپلنت و رسم کادر را برعهده دارند، پس از دو مرحله لایه ادغام و اتصال کامل پاسخ را تعیین می‌کنند.

تشخیص پل‌ها در تصاویر به دلیل به هم‌پیوستگی دندان دشوارتر از تشخیص پروتزهای دیگر است.علی و همکاران [۴۵] با استفاده از آشکارساز YOLOv7 و الگوریتم بهینه‌سازی برای اصلاح نتایج آشکارساز یک مدل جدید شماره‌گذاری دندان معرفی کردند. این مدل علاوه بر توانایی شماره‌گذاری دندان اطلاعات مصنوعات

[۱] Region Proposal Network

دندان را نیز تعیین می‌کند. در این پژوهش شبکه با استفاده از ۳۱۳۸ تصویر پانورامیک اشعه که ۲۵۵۳ تصویر حاوی پروتز می‌باشند، آموزش دیده و صحت ۹۸,۲ و ۹۸,۳ درصد را به ترتیب جهت شماره‌گذاری و تشخیص پروتز فراهم می‌آورد. پارامترهای ارزیابی شبکه به تفکیک جهت تشخیص مصنوعات دندان (آنلی[۱]، روکش، پل، ایمپلنت) صحت ۹۲ تا ۱۰۰ و پوشش ۹۶ تا ۱۰۰ درصد می‌باشند.

چوی و همکاران [۴۶] با استفاده از شبکه عصبی پیچشی اصلاح شده توسط EfficientDet-D3 که از قبل آموزش دیده است، مدلی جهت تشخیص دندان‌های طبیعی، ترمیم شده، ایمپلنت و کشیده شده ارائه داده‌اند. این روش با استفاده از ۱۶۳۸ تصویر پانورامیک اشعه ایکس افراد بزرگسال آموزش داده شده است. تصاویر شامل دندان‌های طبیعی، مصنوعات، ایمپلنت‌ها و ترمیم‌های ریشه ای بوده‌اند. در این پژوهش تاثیر نوع مواد به‌کار گرفته شده در ترمیم دندان نیز بررسی شده است، کانال‌های ریشه و ترمیم‌های تاج درصورتی که حاوی موادی با قدرت عبور تشعشع بالا باشند، قابلیت تشخیص آن برای مدل ارائه شده راحت‌تر از مواد با قدرت رد تشعشع پایین است. به عنوان مثال تاج طلا نسبت به رزین کامپوزیت بهتر تشخیص داده شده است. متوسط صحت مدل برای تشخیص دندان‌های طبیعی ۹۹,۱ درصد، دندان‌های ترمیم شده ۸۰,۶ درصد، ایمپلنت ۹۶,۸ و کانال‌های ریشه درمان شده ۸۱,۲ درصد گزارش شده است. بررسی تاثیر نوع مواد به‌کار گرفته شده در ترمیم دندان نمایانگر قدرت مدل پیشنهادی است.

مقایسه دو پژوهش [۴۵] و [۴۴]، از نظر روش، دقت و داده‌ها، نشان‌دهنده تفاوت‌های بارز در رویکردها و نتایج است. پژوهش [۴۴] با بهره‌گیری از شبکه پیشنهاد محل (RPN) کارایی خوبی در تشخیص ایمپلنت‌ها دارد. در مقابل، [۴۵] با استفاده از YOLOv7 و ۳۱۳۸ تصویر پانورامیک، دقت بالاتری را برای شماره‌گذاری دندان و تشخیص پروتز ارائه داده است. این مدل به‌خوبی توانسته است اطلاعات مربوط به انواع مصنوعات دندانی را تفکیک کند، که نشان‌دهنده قدرت آن در پردازش داده‌های متنوع است. در نهایت، [۴۶] با ۱۶۳۸ تصویر، مدل پیچیده‌تری را ارائه داده‌اند که توانایی شناسایی انواع مختلف دندان‌ها و تأثیر مواد ترمیمی را بررسی کرده و دقت‌های متفاوتی را برای هر نوع دندان گزارش کرده، این تنوع در داده‌ها و دقت‌ها نشان‌دهنده دقت قابل قبول مدل است، اما با توجه به استفاده از داده کمتر قدرت تعمیم‌پذیری مدل قابل بررسی است.

۵-۳- بخش‌بندی و تعیین نوع دندان

بخش‌بندی دندان به عنوان اولین مسائل مطرح شده در تصاویر دندان‌پزشکی است. از این رو تکنیک‌های ریاضی بسیاری برای استخراج ویژگی‌های آناتومیک و هندسی ارائه شده است. بررسی دندان متوفیان یکی از پژوهش‌های آغازین است که به دلیل کار طاقت‌فرسا و تاثیرات روحی تمایل به خودکارسازی این فرآیند بیش‌تر است. شا و همکاران [۴۷] به بررسی سیستم‌های شناسایی افراد متوفی بر اساس ویژگی‌های دندانی می‌پردازند. اولین مرحله در این سیستم، تخمین کانتور هر دندان است که برای استخراج ویژگی‌ها و مقایسه دندان‌ها در سوابق دیجیتال دندانی ضروری است. استخراج کانتور دندان‌ها به عنوان یک مرحله چالش‌برانگیز در بخش‌بندی و شناسایی دندان شناخته شده و در این مقاله، از الگوریتمی به نام کانتور فعال بدون لبه برای این منظور استفاده می‌شود. این تکنیک بر اساس شدت ناحیه کلی تصویر دندان عمل می‌کند و نیازی به وجود مرزهای مشخص ندارد. نتایج تجربی نشان‌دهنده کارایی این روش در استخراج کانتور دندان‌ها است.

ساید و همکاران [۴۸] یک رویکرد ریاضی ریخت‌شناسی را برای حل مسئله دسته‌بندی دندان‌ها ارائه می‌دهند و همچنین از یک تبدیل کشش تباین خاکستری برای بهبود عملکرد این فرآیند استفاده می‌کنند. نتایج نشان می‌دهد که روش پیشنهادی علاوه بر توانایی در پردازش تصاویر بایت‌وینگ و پری‌آپیکال، کمترین نرخ خطا را در میان سایر رویکردهای بررسی شده دارد. در ارزیابی عملکرد، آزمایش‌ها بر روی دو مجموعه شامل ۵۰۰ فیلم بایت‌وینگ و ۱۳۰ فیلم پریاپیکال انجام شده است. با به‌کارگیری تکنیک‌های بهبود تصویر، نرخ خطا کاهش یافته و دقت الگوریتم افزایش یافته است. همچنین، مقایسه زمان پیچیدگی الگوریتم پیشنهادی با دیگر الگوریتم‌ها نشان می‌دهد که این روش از نظر کارایی و سرعت نیز مزیت‌هایی دارد.

کندو و همکاران [۴۹] به بررسی یک روش خودکار برای بخش‌بندی دندان‌ها از تصاویر دیجیتالی سه‌بعدی مدل‌های دندانی می‌پردازند که با استفاده از اسکنر لیزری گرفته شده‌اند. نویسندگان با اجتناب از پیچیدگی پردازش مستقیم داده‌های مش سه‌بعدی، ایده نوآورانه‌ای را برای شناسایی ویژگی‌ها در دو تصویر دامنه ارائه می‌دهند. ابتدا قوس دندانی از تصویر دامنه به دست می‌آید و سپس با استفاده از این قوس، تصویر دامنه پانورامیک محاسبه می‌شود. با استفاده از این دو تصویر، فضاهای بین دندان‌ها شناسایی و نتایج ترکیب می‌شوند تا مکان‌ها و جهت‌های این فضاها تعیین شوند. الگوریتم پیشنهادی بر روی ۳۴ مدل دندانی آزمایش شده و نشان داده است که این روش دقت و قابلیت اطمینان بالایی دارد. با تبدیل داده‌های مش سه‌بعدی به ساختار داده‌های منظم، امکان استفاده از عملیات ریاضی و تکنیک‌های قوی برای استخراج ویژگی‌های تصویر فراهم می‌شود. در نهایت، نتایج نشان می‌دهد که این روش به‌طور مؤثری توانایی شناسایی فضاهای بین دندان‌ها را افزایش می‌دهد و به‌ویژه در مورد دندان‌های نامرتب کارایی بالایی دارد.

مقایسه مفهومی دو پژوهش [۴۸] و [۴۹] نشان‌دهنده رویکردهای متفاوتی در حل مسائل مربوط به دندان‌پزشکی است.

---

[۱] Inlay

[۴۸] با استفاده از یک رویکرد ریاضی ریخت‌شناسی و تبدیل کشش تباین خاکستری، به بهبود دقت در دسته‌بندی دندان‌ها پرداخته که نتایج آن‌ها نشان‌دهنده کمترین نرخ خطا و کارایی بالای الگوریتم است. در مقابل، [۴۹] با تمرکز بر بخش‌بندی دندان‌ها از تصاویر سه‌بعدی، روشی نوآورانه برای شناسایی ویژگی‌ها و تعیین فضاهای بین دندان‌ها ارائه داده است، که به قدرت بالایی در شخیص دندان‌ها با فواصل پایین دارد. این دو رویکرد، هر یک با تمرکز بر جنبه‌های خاصی از پردازش تصویر، به بهبود دقت و کارایی در تشخیص و تحلیل دندان‌ها کمک می‌کنند، اما از تکنیک‌ها و داده‌های متفاوتی بهره می‌برند.

لی و همکاران [۵۰] یک الگوریتم خوشه‌بندی فازی براساس ماتریس نوتروسفیک[۱] برای بخش‌بندی تصاویر پانورامیک اشعه ایکس دندان ارائه نموده‌اند. در این روش تصاویر به یک مجموعه نوتروسفیک تبدیل شده و اطلاعات داخل ماتریس برش ورودی را تعیین می‌نمایند. بخش‌بندی نهایی با استفاده از اصل تعامد پیکسل‌ها صورت می‌پذیرد. ماتریس نوتروسفیک، ماتریسی مربعی است، که سطرو ستون‌های آن بردارهای متعامد هستند. از این ماتریس‌ها در پردازش تصویر برای نمایش تصویر، استخراج ویژگی، تبدیل تصویر و بخش‌بندی می‌توان استفاده نمود. در مقایسه با [۴۸] هر دو از خصوصیات آناتومی دندان استفاده کرده‌اند، با این حال ماتریس نوتروسفیک استخراج ویژگی را در حالت عدم قطعیت ممکن می‌سازد. استفاده از ۶۶ تصویر پانوکس تعمیم‌پذیری مدل را کاهش می‌دهد. قابلیت تعمیم مدل [۴۸] برای دونوع تصویر نشان دهنده توانایی بالای مدل در تشخیص آناتومی دندان‌ها با استفاده از رویکرد ریاضی است، استفاده از داده‌های بیشتر این امر را در مواجه با رویکردهای خاص افزایش می‌دهد.

براهمی و همکاران [۵۱] با استفاده از ۱۰۷ تصویر پانورامیک اشعه ایکس مدلی بر اساس Mask-RCNN ارائه داده‌اند، که شناسایی و دسته‌بندی دندان‌ها را با میانگین دقت ۹۰ درصد فراهم می‌کند. در این روش با استفاده از شبکه عصبی پیچشی دندان‌ها بخش‌بندی شده و سپس از Mask-RCNN جهت تشخیص محل دندان استفاده شده است. قابلیت مدل‌سازی حالات پیچیده مانند همپوشانی دندان‌ها در پژوهش‌های [۴۸] تا [۵۰] نسبت به روش‌های یادگیری عمیق کمتر است. تلفیق روش‌های بخش‌بندی و دسته‌بندی قابلیت تعیین نوع یا شماره دندان را نیز فراهم می‌کند. بخش‌بندی دندان محدوده دقیق‌تری را نسبت به الگوریتم‌های تشخیص شی فراهم می‌کند.

چان و همکاران [۵۲] با استفاده از ۱۲۱ تصاویر CBCT مدلی بر اساس شبکه U-Net متراکم جهت بخش‌بندی و دسته‌بندی دندان آسیاب نهفته فک پایین ارائه نموده‌اند. در این پژوهش با در نظر گرفتن رابطه باکال-لینگال[۲] موقعیت سه‌بعدی دندان آسیاب سوم فک پایین و کانال آلوئولی تحتانی به شکل خودکار یافت شده است. بالاترین میانگین صحت ۸۷، ۹۶ و ۹۴ درصد به ترتیب برای بخش‌بندی دندان آسیاب سوم فک پایین، کانال آلوئولی تحتانی و هر دو باهم گزارش شده است. همچنین شبکه‌ای براساس فاصله مطلق با در نظر گرفتن مراحل دسته‌بندی و بخش‌بندی طراحی شده است، که در مرحله دسته‌بندی آموزش با استفاده از خصوصیات آناتومیک و هندسی انجام شود.

نیشیتانی و همکاران [۵۳] روشی برای بخش‌بندی دندان‌ها در تصاویر پانورامیک اشعه ایکس بر اساس شبکه U-Net ارائه نموده‌اند. در این روش به منظور تفکیک بهتر لبه دندان‌ها از تابع کاهش وزن روی لبه دندان استفاده شده است. مدل پیشنهادی مجموعا روی ۱۶۲ تصویر پانورامیک اشعه ایکس برای آموزش و ارزیابی اعمال شده و شاخص جاکارد و دایس برای این مدل به ترتیب ۰,۸۶۴ و ۰,۹۲۷ گزارش شده است. در مقایسه با پژوهش [۵۲] هر دو از U-Net برای بخش‌بندی استفاده کرده اند، اما جنس تصاویر و تمرکز تکنیک‌ها متفاوت است. با توجه به معیارهای ارزیابی متفاوت امکان مقایسه کمی وجود ندارد، اما دقت گزارش شده حاکی از قدرت مدل U-Net در بخش‌بندی دندان در تصاویر گوناگون است. ارائه مدل‌های تلفیقی بدون وابستگی به نوع داده با استفاده از U-Net می‌تواند موضوعی از تحقیقات آتی باشد.

مقایسه روش‌های بخش‌بندی در تصاویر دندان پزشکی با مجموعه داده بزرگ‌تر می‌تواند به عنوان پایه‌ای برای تحقیقات آینده در بهبود دقت و کارایی مدل‌های بخش‌بندی دندان‌ها مورد استفاده قرار گیرد. رکا و همکاران [۵۴] چهار مدل بخش‌بندی U-Net، DCU-Net، DoubleU-Net و Nano-Net را که بیشتر برای تصاویر پزشکی به کاربرده شده‌اند، به منظور بخش‌بندی دندان‌ها مقایسه نموده‌اند. آموزش و ارزیابی مدل‌ها با استفاده از ۱۵۰۰ تصویر پانورامیک اشعه ایکس صورت گرفته است. معیارهای ارزیابی دقت، صحت و پوشش به ترتیب برای مدل U-Net مقادیر ۹۵,۹۶، ۹۵,۳۴ و ۸۷,۱۲ درصد، برای مدل DCU-Net مقادیر ۹۶,۲، ۹۶,۱ و ۸۷,۵۴ درصد، برای مدل DoubleU-Net مقادیر ۹۶,۵۹، ۹۳,۰۹ و ۹۲,۷ درصد و برای مدل Nano-Net مقادیر ۹۵,۵۷، ۹۶,۳۲ و ۸۴,۲۲ درصد گزارش شده است. به این ترتیب مدل DoubleU-Net بهترین عملکرد را برای بخش‌بندی دندان در تصاویر پانورکس داشته است. با این حال از آنجا که مدل Nano-Net تعداد پارامتر کمتری داشته و سبک‌تر است، این مدل نیز عملکرد قابل قبولی داشته است. این پژوهش با بررسی چندین مدل مختلف و ارزیابی دقیق‌تر، به درک بهتری از کارایی تکنیک‌های مختلف در تصاویر پانورامیک دست یافته است. در مقایسه با [۵۳] با مجموعه داده یکسان معیارهای ارزیابی به دلیل تعمیم‌پذیری بیشتر قابلیت اطمینان بالاتری دارند. علاوه‌براین استفاده از مدل‌های گوناگون امکان بهینه‌سازی در کنار افزایش دقت را فراهم نموده است.

---

[۱] Neutrosophic

[۲] Buccal-lingual

ژنگ و همکاران [۵۵] یک مدل U-Net متراکم با محدودیت آناتومیک را برای بخش‌بندی ضایعه و دندان در تصاویر CBCT ارائه نموده‌اند. در این روش از بهینه‌سازی متناسب با تغییرات میدان میانگین و رمزگذاری برای تبدیل دانش توصیفی به کمی استفاده شده است. مدل براساس تصاویر ۲۰ بیمار تشکیل و ارزیابی شده و برای معیار زیان متقاطع[۱] به ترتیب صحت و پوشش ۹۰ و ۸۰ درصد گزارش شده است. در مقایسه [۵۲] بر روی دقت بالای بخش‌بندی تمرکز داشته و مجموعه داده بزرگ‌تری را برای دندان‌های خاص بررسی می‌کند در حالی که [۵۵] به بهینه‌سازی و کاربرد محدودیت‌های آناتومیک توجه بیشتری دارد. لین و همکاران [۵۶] شبکه عصبی سبک را به منظور بخش‌بندی دندان در تصاویر پانورامیک اشعه ایکس ارائه نموده‌اند. مدل ارائه شده شبکه عصبی مبتنی بر دانش KCNet نامیده شده و برای ارزیابی و آموزش آن از ۱۳۲۱ تصویر پانورامیک اشعه ایکس استفاده شده است. مدل پیشنهادی در مقایسه با روش‌های سبک دیگر بهبود چشم‌گیری حاصل نموده و ضریب دایس ۸۹ درصد را فراهم نموده است.

با توجه به جدول (۲) مقایسه بین سه مدل [۵۲] و [۵۵] و [۵۶] نشان می‌دهد که هر یک از این رویکردها نقاط قوت و ضعف خاص خود را دارند. مدل [۵۲] با دقت بالای خود در بخش‌بندی دندان‌ها، به ویژه در شناسایی دندان‌های نهفته، به نظر می‌رسد که در کاربردهای بالینی فوری بسیار موثر باشد. با این حال، تمرکز [۵۵] بر روی محدودیت‌های آناتومیک و بهینه‌سازی نشان‌دهنده پتانسیل بیشتری برای توسعه در زمینه‌های پیچیده‌تر بخش‌بندی است. از سوی دیگر، KCNet [۵۶] با بهبود قابل توجهی در تصاویر پانورامیک، نشان‌دهنده یک گام رو به جلو در استفاده از داده‌های بزرگ و تکنیک‌های یادگیری عمیق است. با این حال، در زمینه تحقیق و توسعه، مدل [۵۵] ممکن است جای بیشتری برای پیشرفت داشته باشد، زیرا با توجه به تمرکز بر محدودیت‌های آناتومیک، می‌توانند به بهبود دقت در شرایط پیچیده‌تر و متنوع‌تری کمک کند. همچنین، KCNet با توجه به داده‌های بیشتری که استفاده کرده است، می‌تواند به عنوان یک پایه برای تحقیقات آینده در زمینه‌های مختلف بخش‌بندی دندان‌ها به کار رود. بنابراین، اگرچه [۵۲] در دقت بخش‌بندی پیشرو هستند، اما جایگاه تحقیقاتی [۵۵] و KCNet [۵۶] به دلیل پتانسیل‌های توسعه بیشتر و کاربردهای وسیع‌تر، برجسته‌تر به نظر می‌رسد.

کادی و همکاران [۵۷] با استفاده از شبکه عصبی آشکارساز مبادله‌ای[۲] (DETR) روشی برای بخش‌بندی و شماره‌گذاری دندان‌ها معرفی کرده‌اند. معیار ارزیابی میانگین صحت گزارش شده نشان‌دهنده عملکرد خوب مدل در شناسایی دندان‌ها در ۵۲ کلاس مختلف می‌باشد. نتایج اولیه نشان داد که مدل DETR بدون استفاده از تکنیک‌های افزایش داده، mAP بالای ۰,۶۹ را به دست آورد. با اعمال تکنیک‌های افزایش داده، به ویژه تغییرات هندسی، این مقدار به ۰,۸۲ افزایش یافت، که نشان‌دهنده تأثیر مثبت این تکنیک‌ها بر دقت مدل در شرایطی با داده‌های محدود است. همچنین، دندان‌ها از تصاویر جداسازی شده و با ادغام تصاویر دندان تصاویر جدیدی ایجاد می‌شوند که امکان ایجاد طیف رنگی را فراهم می‌کند. استفاده این تکنیک‌ها عملکرد مدل را به mAP برابر با ۰,۷۶ رساند. این یافته‌ها نشان می‌دهد که ترکیب DETR با تکنیک‌های افزایش داده می‌تواند به عنوان یک رویکرد مؤثر برای غلبه بر چالش‌های کمبود داده‌ها در زمینه بیماری‌های نادر دهانی عمل کند.

مقایسه بین مقالات [۵۷] و [۵۴] و [۵۱] و [۵۶] نشان دهنده نقاط قوت خاص هر پژوهش است. [۵۷] با استفاده از مدل DETR و تکنیک‌های افزایش داده، به دقت قابل توجهی در شناسایی دندان‌ها دست یافته است. با این حال، این مدل به دلیل وابستگی به تکنیک‌های افزایش داده ممکن است در شرایط واقعی که داده‌های کمتری موجود است، عملکرد بهینه‌ای نداشته باشد. در مقابل، [۵۴] با بررسی چندین مدل مختلف، به وضوح نشان می‌دهد که مدل DoubleU-Net بهترین عملکرد را در بخش‌بندی دندان‌ها دارد و این می‌تواند به عنوان یک مرجع قوی برای کاربردهای بالینی در نظر گرفته شود. از سوی دیگر، مدل KCNet [۵۶] بهبود قابل توجهی در دقت بخش‌بندی ارائه داده و ضریب دایس ۸۹ درصد را به دست آورده است. این نشان‌دهنده پتانسیل بالای این مدل برای کاربردهای عملی است. همچنین، [۵۱] با تلفق بخش‌بندی و از Mask-RCNN دقت قابل قبولی را فراهم نموده است. در نهایت، به نظر می‌رسد که مدل KCNet و DoubleU-Net به دلیل دقت بالای خود و قابلیت‌های کاربردی بیشتر، جای تحقیق و توسعه بیشتری دارند و می‌توانند به عنوان پایه‌ای برای پیشرفت‌های آینده در زمینه بخش‌بندی دندان‌ها در تصاویر پانورامیک محسوب شوند.

دسته‌بندی و شماره‌گذاری تصاویر دندان با استفاده از شبکه‌هایی مناسب تشخیص شی توسعه یافته‌اند، درحالی که برای بخش‌بندی تصاویر دندان از شبکه‌هایی بر اساس بخش‌بندی نمونه[۳] استفاده می‌شود. نوع تصاویر به کار گرفته شده در شماره‌گذاری دندان‌ها متفاوت است، اما تصاویری مانند بایت‌وینگ برای این موضوع به دلیل عدم پوشش کلیه دندان‌ها کاربرد چندانی ندارند. برخی از مدل‌ها [۴۸] قابلیت پشتیبانی از تصاویر با انواع متفاوتی دارند. مدل‌های یادگیری عمیق بسیاری برای شماره‌گذاری دندان‌ها در تصاویر مختلف ارائه شده‌اند. در این بین مدل‌های تشخیص شی دو مرحله‌ای به دلیل فراهم آوری دقت مناسب‌تر بیشتر به چشم می‌خورند و تحقیقات زیادی روی معماری‌های مختلف R-CNN [۵] و [۳۱] تا [۳۸] و [۴۴] صورت گرفته است. از این

[۱] Cross entropy loss

[۲] Detection Transformer

[۳] Instance Segmentation

رو ارائـه پژوهش‌هـای مقایسـه معماری‌هـای مختلـف [۳۹] چالش‌های موجود و مسیر تحقیقات آتی را بهتر نمایان می‌کند. جدول (۲) خصوصیات انحصاری، پارامترهای ارزیابی و داده مورد استفاده در پژوهش‌های نامبرده را مقایسه می‌کند، با توجه به نتایج می‌توان مشاهده نمود هر مدل برای داده‌ای که در آن آموزش دیده است عملکرد قابل قبولی دارد، با این حال در علم پزشکی با توجه به اخلاق در پزشکی، خطای مدل قابل پذیرش نیست.

منظـور از خصوصـیات انحصـاری برخـی از نوآوری‌هـای پـژوهش است، کـه آن را از دیگـر مـوارد مجـزا می‌سـازد. یکـی از چالش‌های مطرح شـده در بسیاری از پژوهش‌هـا حجـم داده پـایین است، که در صورت بالا رفتن حجم داده ممکن است، دقت مـدل بهتـر شـود. حجـم داده تـاثیر مسـتقیمی بـر تعمیم‌پـذیری روش نیـز دارد، از این رو در بسیاری از پژوهش‌هـا از روش‌هـای افـزایش داده استفاده شده است، که منجر به بهبود عملکرد روش پیشنهادی بوده است. ارائه مجموعه داده‌های غنی‌تر و مقایس عملکرد تکنیک‌هـای افزایش داده روی مدل‌های مختلف می‌تواند موضوعات تحقیقـات آتی را فراهم آورد. برچسب‌گذاری داده‌های مورد استفاده نیـز یکی از مـوارد تاثیرگـذار بـر دقـت خروجـی مـدل اسـت، برچسـب‌گذاری توسط متخصصین صورت می‌پذیرد و اگر خطای انسانی رخ دهـد، مدل براساس این خطا آموزش داده می‌شـود. از طرفـی بـا توجـه بـه میزان تخصص و عملکرد افراد ممکن است، مدل سوگیری خاصـی داشته باشد. با این حال در بررسی تخصصی پژوهش‌هـای موجـود در برخی از موارد شرایط پایگاه داده به خوبی توصیف نشده است. با توجه به جدول (۲) استفاده از رویکردهای یادگیری عمیق نسبت بـه روش‌هـای سـنتی و آشکارسـاز مبادلـه‌ای بیشـتر اسـت کـه نشـان دهنده افزایش قدرت این روش‌ها در تفسیر تصاویر دنـدان پزشـکی می‌باشد. با ایـن حـال در ایـن روش‌هـا آشکارسـازهای دو مرحلـه‌ای بیش از دیگر موارد به چشم می‌خورنـد. مقایسـه عملکـرد مـدل‌های تـک و دو مرحلـه‌ای آشکارسـازها و بررسـی دلیـل دقـت بـالاتر مـدل‌های دو مرحلـه‌ای روی تصـاویر دندان‌پزشـکی می‌توانـد رویکردهای پژوهشی جدید را فراهم آورد.

جدول (۲) : مقایسه مدل، ویژگی، نوع تصویر و معیارهای ارزیابی پژوهش‌های حیطه تشخیص، شماره‌گذاری و بخش‌بندی دندان

پژوهش	مدل	ویژگی انحصاری	نوع تصویر	دقت (%)	صحت (%)	پوشش (%)
لین و همکاران [۲۵]	SVM	پیچیدگی پایین و سادگی پیاده‌سازی	۴۷ بایت‌وینگ	۹۸	–	–
ماهور و همکارن [۲۶]	دسته‌بند بیز	شبیه‌سازی با استفاده از تکنیک‌های هندسی	۵۰ بایت‌وینگ	–	–	–
آینی و همکاران [۲۷]	دسته‌بند خطی	استخراج ویژگی برپایه تکنیک‌های ریاضی	۴۷۶ دندان بایت‌وینگ	۱۰۰	–	–
مارتین و همکارن [۲۸]	منطق فازی	استفاده از ویژگی‌های ریخت‌شناسی و تصمیم‌گیری بر اساس اطلاعات مبهم	۷۸ رادیوگرافی پری‌آپیکال	۸۲/۵۱	–	–
میکی وهمکاران [۲۹]	CNN	استفاده از شبکه AlexNet وارائه روش کاربردی بررسی دندان اجساد	CBCT ۵۲	۸۸/۸	–	–
چن و همکاران [۳۰]	CNN	تحلیل سه بعدی دندان و تلفیق یادگیری عمیق با DCGAN	۱۷۵ تصاویر سه بعدی فک	۹۱/۳۵	۹۱/۴۹	–
گروز و همکاران [۳۱]	R-CNN	شماره‌گذاری دندان براساس روش سلسه مراتبی	۱۶۸۶ رادیوگرافی پری‌آپیکال	–	۸۷/۱۲	۹۸/۶۷
بیلگیر و همکارن [۳۲]	R-CNN سریع‌تر	تشخیص سلسله مراتبی با قابلیت تشخیص دندان غایب	۲۴۸۲ پانورکس	–	۹۶/۵۲	۹۵/۵۹
یاسا و همکاران [۳۳]	R-CNN سریع‌تر	تشخیص دندان‌های خاص نیش، آسیاب و آسیای کوچک	۱۱۲۵ بایت‌وینگ	–	۹۲/۹۳	۹۷/۴۸
کلیک و همکاران [۵]	R-CNN سریع‌تر	تشخیص و شماره‌گذاری دندان شیری و بهره‌گیری از COCO	۴۲۱ پانورکس	–	۹۸/۰۴	۹۵/۷۱
چن و همکاران [۳۴]	R-CNN سریع‌تر	فیلتر کادرهای همپوشان و تشخیص دندان غایب با آموزش مدل مجزا	۱۲۵۰ فیلم پری‌آپیکال	–	۹۱/۷	۹۱/۴
توزف و همکاران[۳۵]	R-CNN سریع‌تر	استفاده از معماری VGG-16 و دست‌یابی به دقت بالا در عین حفظ تعمیم‌پذیری	۱۳۵۲ پانورکس	–	۹۹/۴۵	۹۹/۴۱
میما و همکاران [۳۶]	R-CNN سریع‌تر	شماره‌گذاری دندان براساس تقسیمات ششگانه	۱۶۰ پانورکس	۹۱/۷	–	–
کیم و همکاران [۳۷]	R-SSMD+CNN	ارائه مدل پیش‌بینی همزمان دسته و کادردندان	۳۰۳ پانورکس	۸۴/۵	۸۴/۲	۷۵/۵
بیلگر و همکاران [۳۸]	R-CNN سریع‌تر	آموزش مدل پس از فیلتر داده‌های ناهنجار و استفاده از ۲۲ لایه و دسته‌بند کمکی	۲۴۸۲ پانورکس	–	۹۶/۵۲	۹۵/۵۹

موریشیتا و همکاران [۴۰]	شبکه آشکارساز	مدل سلسله مراتبی تشخیص کل، ۱۶ و ۳۲ دندان	۹۵۰ پانورکس	۹۶/۷۹	–	–
اورهان و همکاران [۴۱]	یادگیری عمیق	تشخیص ریشه دندان‌های آسیاب اول فک پایین برپایه ریخت شناسی	CBCT ۴۰۰	۸۷/۴	۷۷/۳	۹۷/۱
چنگ و همکارن [۴۲]	شبکه عصبی چند وظیفه‌ای	استفاده از رگرسیون و قابلیت تشخیص دندان‌های غایب	۸۱۸ پانورکس	–	۹۹/۷	۹۷/۲
رمضان و همکاران [۴۳]	YOLOv10	استفاده از آشکارساز تک مرحله‌ای	۳۰۰ پانورکس	–	۹۰	۹۴
اوزسیلیک و همکاران [۳۹]	DentifyNet	مقایسه معماری های مختلف R-CNN	۵۰۰ پانورکس	۹۷,۵۰	۹۷,۵۲	۹۷,۴۹
جانگ و همکاران [۴۴]	R-CNN سریع‌تر	قابلیت تشخیص همزمان ایمپلنت و بافت اطراف	۳۰۰ رادیوگرافی پری‌آپیکال	–	۹۷/۷	۹۹/۲
علی و همکاران [۴۵]	YOLOv7	قابلیت تشخیص مصنوعات دندان در حین شماره‌گذاری	۳۱۳۸ پانورکس	–	۹۲الی۱۰۰	۹۶الی۱۰۰
چوی و همکاران [۴۶]	EfficientDet-D3	بررسی تاثیر مواد به کاررفته در مصنوعات دندان	۱۶۳۸ پانورکس	–	۹۹/۱ (تشخیص دندان سالم)	۹۹/۶ (تشخیص دندان سالم)
شا و همکارن [۴۷]	کانتور فعال بدون لبه	استفاده از روش های سنتی استخراج ویژگی	۳۴۰ دندان بایت‌وینگ	–	–	–
ساید و همکاران [۴۸]	رویکرد ریاضی	استفاده از روش‌های ریخت‌شناسی و قدرت بررسی دو نوع تصویر	۵۰۰ بایت‌وینگ و ۱۳۰ پری‌آپیکال	–	–	–
کندو و همکاران [۴۹]	رویکرد ریاضی	توانایی بخش‌بندی دندان‌های همپوشان	تصاویر اسکن لیزر	–	–	–
علی و همکاران [۵۰]	ماتریس‌های متعامد نوتروسوفیک	استفاده از روش‌های منطقی براساس تعامد پیکسل‌ها	۶۶ پانورکس	–	–	–
براهمی و همکاران [۵۱]	Mask-RCNN	تلفیق مدل بخش‌بندی و دسته‌بندی	۱۰۷ پانورکس	–	۹۶	–
چان و همکارن [۵۲]	U-Net	تشخیص دندان نهفته و استفاده از رابطه باکال-لینگال در افزایش قدرت مدل	CBCT ۱۲۱	–	۹۴	–
نیشیتانی و همکاران [۵۳]	U-Net	بخش‌بندی دندان به تفکیک لبه با استفاده از تابع کاهش وزن	۱۶۲ پانورکس	–	–	–
رکا و همکاران [۵۴]	U-Net، DCU-Net، DoubleU-Net و Nano-Net	مقایسه قدرت چهار مدل خاص بخش‌بندی تصویر	۱۵۰۰ پانورکس	۹۶,۵۹ Double U-Net	۹۳,۰۹ DoubleU-Net	۹۲,۷ Double U-Net
ژنگ و همکاران [۵۵]	U-Net	استفاده از خصوصیات اناتومی در آموزش مدل	CBCT ۲۰	–	۹۰	۸۰
لین و همکاران [۵۶]	KCNet	استفاده از مدل سبک	۱۳۲۱ پانورکس	–	–	–
کادی و همکاران [۵۷]	DETR	استفاده از مدل‌های مبتنی بر مبدل	۱۵۶ رادیوگرافی پانورامیک	–	–	–

۶- دسته‌بندی و بخش‌بندی بیماری

در تفسیر تصاویر پزشکی تعیین نوع بیماری دندان پس از تشخیص محل دندان صورت می‌پذیرد، با این حال در برخی از پژوهش‌ها صرفا تعیین نوع بیماری و محل تخریب شده، مورد بررسی قرار گرفته است. تشخیص نوع بیماری دندان بسیار دشوارتر از تشخیص موقعیت دندان است، زیرا بیماری‌های دندان طیف گسترده‌ای داشته و تا کنون پژوهشی موفق به تشخیص کلیه بیماری‌های دندان نشده است. بخش‌بندی بیماری صرفا مرز و محدوده بیماری را تعیین نموده و محل‌های تخریب شده را مشخص می‌نماید. برخی از بیماری‌های ریشه دندان ناشی از عفونت و کیست‌های لثه بوده و شناسایی برخی از بیماری‌های دهان نیز می‌تواند جزئی از مراحل درمانی و تعیین بیماری دندان در نظر گرفته شود، از این رو در بخش ۲-۶ مدل‌های تشخیص برخی از بیماری‌های دهان نیز، مورد بررسی قرار گرفته‌اند. تشخیص برند و خرابی ایمپلنت در پژوهش‌های متفاوتی مورد بررسی قرار گرفته است. تشخیص برند ایمپلنت به عنوان یکی از مصنوعات دندان در روند درمان تاثیر بالایی دارد، این درحالی است، که تشخیص برند ایمپلنت با استفاده از تصویر توسط متخصصین نیز دشوار است. از این رو بررسی پژوهش‌های تشخیص برند و تخریب ایمپلنت به عنوان یک دندان مصنوعی نیز در حیطه غربالگری دندان قرار گرفته است.

۶-۱- غربالگری و تعیین نوع بیماری دندان

غربالگری دندان با استفاده از تصاویر دندانپزشکی دندان‌های سالم و بیمار را از یکدیگر تفکیک کرده و وارد تشخیص نوع و نام بیماری دندان نمی‌شود. از این رو غربالگری دندان با استفاده از دو دسته سالم و ناسالم قابل انجام است. سرنام و همکاران [۵۸] به منظور دسته‌بندی دندان‌های پوسیده و سالم پس از بخش‌بندی دندان‌ها با استفاده از GLCM فرآیند استخراج ویژگی را از ۱۲۰ تصویر پانورامیک اشعه ایکس تکمیل نموده‌اند. پس از انجام فرآیند استخراج ویژگی با استفاده از نرخ یادگیری مناسب با طراحی یک شبکه عصبی پیش‌خور دسته‌بندی دندان‌ها صورت پذیرفته است، مقدار بیش از ۹۹ درصد دقت برای این روش گزارش شده است. بخش‌بندی دندان در این روش به منظور تفکیک تک تک دندان‌ها و آماده‌سازی تصویر جهت استخراج GLCM است.

گراک و همکاران [۵۹] با استفاده از فیلترهای مربعی ۷ ویژگی متفاوت (گرادیان، میانگین شدت، چولگی هیستوگرام، میانگین تباین و غیره) را از ۶ تصویر که مجموعا ۴ هزار پیکسل داشته‌اند استخراج نموده است. پس از استخراج ویژگی از دسته‌بند C4.5 جهت تعیین پوسیدگی سطح دندان استفاده شده است. در این روش میزان دقت دسته‌بندی ۹۶/۸۶ درصد بدون استفاده از روش‌های کاهش ابعاد ویژگی گزارش شده است. دویتو و همکاران [۶۰] با استخراج ویژگی تصاویر توسط ۲۵ متخصص (از سطح ۱ تا ۵) و آموزش پرسپترون چند لایه روشی جهت بهبود تشخیص پوسیدگی سطح دندان ارائه نموده‌اند. در این پژوهش از ۱۶۰ تصویر رادیوگرافی استفاده شده، علاوه براین سطوح دندان کشیده شده با استفاده از میکروسکوپ بررسی شده است. برای هر تصویر ۲۵ تشخیص به عنوان ویژگی در نظر گرفته شده و سطح زیر نمودار ROC فراهم شده توسط شبکه عصبی ۸۸/۴ درصد بوده که در مقایسه با عملکرد انسانی ۳۹/۴ درصد بهبود داشته است.

در مقایسه بین سه پژوهش [۵۸] تا [۶۰] استخراج ویژگی به روش سنتی و استفاده از تکنیک‌های یادگیری ماشین جهت دسته‌بندی نتایج قابل قبولی را فراهم آورده است. [۵۸] با دقت بیش از ۹۹ درصد، به وضوح بهترین عملکرد را در دسته‌بندی دندان‌های پوسیده و سالم دارد. این دقت بالا به دلیل استفاده از GLCMو طراحی شبکه عصبی پیش‌خور است که می‌تواند به عنوان یک مرجع قوی برای بهبود عملکرد دیگر مدل‌ها مورد بررسی قرار گیرد. در مقابل، [۵۹] با دقت ۹۶,۸۶ درصد اگرچه به استخراج ویژگی‌های متنوعی پرداخته است، با این حال عملکرد ضعیف‌تری دارد. بهبود قابل توجه نسبت به عملکرد انسانی [۶۰] با دقت ۸۸,۴ درصد، قابلیت‌های کاربردی پژوهش را زیر سوال می‌برد. با این حال استفاده از روش‌های سنتی برای تشخیص ویژگی نقطه شروعی برای توسعه روش‌های دسته‌بندی بیماری دندان بوده است.

بیو و همکارن [۶۱] به منظور تشخیص پوسیدگی دندان تصاویر پانورامیک اشعه ایکس را بخش‌بندی نموده و از ۵۳۳ تصویر حاصل، که ۲۹۹ مورد شامل دندان‌های پوسیده و بقیه موارد سالم بودند، جهت استخراج ویژگی عمیق استفاده نموده‌اند. مدل پیشنهاد شده شامل دو مرحله استخراج ویژگی و دسته‌بندی است. استخراج ویژگی با استفاده از بهترین مدل‌های استخراج ویژگی تصاویر رادیوگرافی از پیش آموزش دیده مانند VGG-16، VGG-19، Resnet18، Resnet50، Resnet101، Alexnet،Googlenet و Xception صورت گرفته و پس از آن ویژگی های بافت، میانگین و غیره نیز به آن اضافه شده است. در مرحله دسته‌بندی از مدل‌های درخت تصمیم، K نزدیک‌ترین همسایه، بیز[۱]، جنگل تصادفی و SVM استفاده شده ، که به ترتیب میانگین دقت ۶۵/۲۸، ۷۸/۴۹، ۷۳/۹۱، ۸۵/۲۸ و ۹۱/۷۰ را فراهم نموده‌اند. در این پژوهش برای مدل SVM بهترین عملکرد با صحت ۹۰/۴۳ و دقت ۹۲/۶۷ گزارش شده است. این پژوهش به دلیل ترکیب روش‌های پیشرفته استخراج ویژگی و دسته‌بندی، مزایای قابل توجهی نسبت به مقالات قبل دارد. این رویکرد به بهبود دقت در تشخیص پوسیدگی دندان‌ها کمک کرده و نشان‌دهنده قابلیت‌های بالای یادگیری عمیق در این زمینه است. همچنین، با استفاده از چندین الگوریتم دسته‌بندی، این پژوهش توانسته است دقت‌های متفاوتی را ارائه دهد که نشان‌دهنده تنوع و انعطاف‌پذیری در انتخاب مدل‌های مناسب برای تشخیص پوسیدگی است. تلفیق این روش با یادگیری انتقالی می‌تواند یکی از مسیرهای تحقیقات آتی محسوب گردد.

یادگیری عمیق در حیطه تشخیص بیماری دندان نیز کاربرد بالایی داشته و بسیاری از پژوهش‌ها امروزه استخراج ویژگی تصاویر را با استفاده از مدل‌های یادگیر عمیق مانند CNN، R-CNN، YOLO و غیره انجام داده و از روش‌های سنتی استخراج ویژگی کمتر استفاده می‌شود. لی و همکاران [۶۲] با استفاده از ۳ هزار تصویر پری‌آپیکال و شبکه عصبی GoogLeNet از پیش آموزش دیده مدلی جهت تشخیص بیماری دندان‌های آسیاب و آسیای کوچک ارائه نموده‌اند. تصاویر پیش از آموزش برش داده شده و تصویر دندان‌ها به تفکیک در مدلی با ۲۲ لایه عمیق استفاده شده‌اند. نتایج گزارش شده به تفکیک برای دندان آسیاب دقت ۸۸ درصد و برای دندان آسیای کوچک دقت ۸۹ درصد را فراهم آورده که با در نظر گرفتن کلیه دندان‌های آسیاب و آسیای کوچک به ۸۲ درصد کاهش می‌یابد. تشخیص بیماری دندان به تصاویر پزشکی محدود نیست و از تصاویر عادی نیز برای تشخیص بیماری دندان‌ها استفاده شده است.

مائو و همکاران [۶۳] با مقایسه چهار شبکه عصبی VGG-19، GoogleNet، AlexNet و ResNet50 مدلی بر اساس شبکه عصبی AlexNet جهت تشخیص پوسیدگی و ترمیم دندان‌ها ارائه

---

[۱] Naïve Bayes

نموده‌اند. در این روش با استفاده از سه مرحله پیش‌پردازش دندان‌ها از تصاویر بایت‌وینگ تفکیک و برای آموزش مدل استفاده شده‌اند. به منظور بهبود کیفیت تصویر در مرحله اول از فیلتر گوسی بالاگذر و آستانه Otsu استفاده شده و در مرحله دوم برش تصاویر جهت تفکیک دندان انجام شده است. در مرحل سوم دندان‌هایی که به شکل کامل در تصویر بایت‌وینگ قرار ندارند، حذف شده‌اند. مجموعا از ۲۷۸ تصویر استفاده شده که پس از انجام مراحل پیش‌پردازش ۳۷۱۶ دندان به تفکیک یافت شده است. برچسب‌گذاری دندان‌ها توسط سه متخصص انجام شده که حداقل ۳ سال سابقه کار دارند. از مجموع دندان‌های تفکیک شده ۶۱۰دندان ترمیم و فقط ۸۸ مورد پوسیدگی داشته‌اند، از این رو به منظور متعادل کردن تعداد هر دسته از فرآیند افزایش داده استفاده شده است. در فرآیند دسته‌بندی پوسیدگی دقت ۹۰,۳ درصد و در فرآیند تشخیص ترمیم دقت ۹۵,۵۶ درصد توسط مدل تعیین شده است. این نتایج حاکی از این است که روش‌های پیش‌پردازش و انتخاب مدل تأثیر مثبتی بر دقت تشخیص داشته و به نظر می‌رسد که این مقاله توانسته است با استفاده از تکنیک‌های بهینه‌سازی بیشتری، دقت کلی را افزایش دهد. با این حال، [۶۲] با استفاده از مجموعه داده بزرگتر و تنوع بیشتر در تصاویر، پتانسیل خوبی برای تحقیقات آینده داشته واستفاده از داده‌های بیشتر و متنوع‌تر در این پژوهش از نقاط قوت آن است.

تشخیص پوسیدگی دندان در تصاویر مختلف اشعه ایکس صورت می‌پذیرد با این حال تصاویر بایت‌وینگ و پانورکس بیش از دیگر موارد در پژوهش‌های دسته‌بندی خودکار به کار برده شده‌اند. مران و همکاران [۶۴] با استفاده از ۱۱۲ تصویر رادیوگرافی بایت‌وینگ مدلی جهت دسته‌بندی پوسیدگی دندان با توجه به شدت ضایعه ارائه نموده‌اند. مدل پیشنهادی بر اساس ResNet با توجه به سه نرخ متفاوت یادگیری آموزش داده شده و دقت ۷۳,۳ درصد برای آن گزارش شده است. اسماعیلی فرد و همکاران [۶۵] در پژوهشی مشابه روشی جهت تشخیص پوسیدگی دندان‌های آسیاب ارائه نموده‌اند. تصاویر ۳۸۲ دندان با پوسیدگی و ۴۰۳ دندان فاقد پوسیدگی از دید سهمی[۱]، تاجی[۲] و عرضی-افقی[۳] برای آموزش و ارزیابی مدل استفاده شده‌اند. مدل ارائه شده بر پایه CNN پوسیدگی را براساس عمق و نوع آن‌ها دسته بندی نموده است. مدل ارائه شده به ترتیب دقت ۹۵,۳ و ۹۴,۸ درصد را برای دسته‌بندی دندان‌های پوسیده و فاقد پوسیدگی فراهم نموده است. در مقایسه با [۶۴] علاوه بر فراهم آوری دقت بالاتر به دلیل آموزش مدل با توجه به پوسیدگی دندان از دیدهای مختلف امکان ترکیب مدل برای تشخیص پوسیدگی کلیه دندان‌ها در تحقیقات آتی وجود دارد. تفاوت نوع و تعداد داده‌های مورد استفاده در پژوهش‌های مختلف با توجه به جدول (۳) امکان مقایسه عادلانه پژوهش‌ها از دید معیارهای ارزیابی را از بین برده است. با این حال، بررسی پژوهش‌های [۶۳] و [۶۴] با نوع داده مشابه نشان‌دهنده تاثیر تعداد مجموعه داده استفاده شده است.

چن و همکاران [۶۶] به منظور دسته‌بندی بیماری دندان از سه مدل با آموزش مجزا جهت تشخیص سه بیماری متفاوت در سه سطح خفیف، متوسط و شدید استفاده نموده‌اند. به منظور جلوگیری از کاهش دقت مدل یک شبکه جهت دسته‌بندی همه بیماری‌ها و دیگری جهت تشخیص سطح بیماری برای تک تک بیماری‌ها و شبکه دیگر جهت دسته‌بندی سطوح بیماری ارائه شده است. مدل‌ها توسط ۲۹۰۰ تصویر پری‌آپیکال آموزش داده شده و ارزیابی آن نیز انجام شده است. مدل‌های یادگیری عمیق براساس R-CNN سریع‌تر طراحی شده و به ترتیب برای بیماری‌های پوسیدگی[۴]، پریودنتیت[۵] و پریودنتیت پری‌آپیکال[۶] صحت ۶۱,۹۳، ۵۶,۴۴ و ۵۱,۶۱ درصد و پوشش ۵۴,۳۹، ۶۱,۵۲ و ۵۱,۸ درصد توسط مدل یادگیری کلیه بیماری‌ها فراهم شده است. این پژوهش به دلیل استفاده از چندین مدل برای تشخیص بیماری‌های مختلف و سطوح شدت، پتانسیل خوبی برای تحقیقات آینده دارد. اگرچه دقت‌های آن پایین‌تر است، اما این رویکرد می‌تواند به بهبود درک پژوهشگران از بیماری‌های مختلف دندانی و توسعه مدل‌های دقیق‌تر کمک کند. در حالی که [۶۵] عملکرد بهتری از دید دقت فراهم نموده، مجموعه داده کوچکتر استفاده شده در آن تعمیم‌پذیری مدل را کاهش می‌دهد.

لین و همکاران [۶۷] شبکه عصبی پیچشی برای تشخیص پوسیدگی پروگزیمال ارائه نموده‌اند. مدل پیشنهادی براساس Cifar-10Netاز پیش آموزش داده شده دسته‌بندی دندان‌های پوسیده و سالم را انجام می‌دهد. در این پژوهش مجموعا از ۸۰۰ تصویر برای آموزش و ارزیابی مدل استفاده شده است، استراتژی ارائه شده براساس تشخیص لبه و بخش‌بندی دندان عمل می‌کند. روش پیشنهادی برای تشخیص محل، تشخیص لبه و بخش‌بندی به ترتیب به دقت ۸۲,۱، ۸۵,۹ و ۶۰,۶ درصد دست یافته است. این پژوهش عملکرد دقیق‌تری را نسبت به [۶۶] فراهم می‌کند، با این حال، [۶۶] به دلیل استفاده از چندین مدل برای دسته‌بندی سطوح مختلف بیماری‌ها و تمرکز بر روی سه نوع بیماری، پتانسیل بیشتری برای تحقیقات آینده دارد. این روش به دلیل رویکرد جامع‌تری که در تشخیص سطوح مختلف بیماری‌ها دارد، می‌تواند به عنوان یک نقطه شروع برای تحقیقات آینده در این حوزه مورد توجه قرار گیرد.

زو و همکاران [۶۸] با توجه به کمبود مجموعه‌های داده عمومی برای دندان‌های کودکان، یک پایگاه داده عمومی شامل

---

[۱] Sagittal
[۲] Coronal
[۳] Axial
[۴] Decay
[۵] Periodontitis
[۶] Periapical periodontitis

۸۴۹ تصویر پانورامیک از دندان‌های کودکان ارائه داده و دو مدل مبتنی بر CNN و مکانیزم‌های توجه، یعنی DCD-Net و DPD-Net، معرفی کرده‌اند. مدل DCD-Net با استفاده از یک مدل تصحیح دسته، قادر به تقسیم‌بندی و شمارگذاری خودکار دندان‌های کودکان با میانگین دقت (mAP50) ۹۶,۴ درصد است و به طور قابل توجهی تعداد تصاویر آموزشی مورد نیاز را کاهش می‌دهد. همچنین، مدل DPD-Net به شناسایی بیماری‌های دندانی پرداخته و میانگین دقت (mAP50) ۸۰ درصد را به دست می‌آورد. نتایج نشان می‌دهد که DCD-Net در مقایسه با سایر مدل‌ها، از جمله YOLOv8n-OBB ، بهترین عملکرد را در شناسایی انواع دندان‌ها دارد.

لی و همکارن [۶۹] به بررسی یک روش یادگیری تدریجی برای تشخیص و تقسیم‌بندی پوسیدگی دندان در تصاویر رادیوگرافی پری‌آپیکال می‌پردازند. هدف این مطالعه ایجاد یک مجموعه داده بزرگ شامل ۵۵۶۹ تصویر رادیوگرافی پری‌آپیکال و تصاویر ماسک مربوطه است که بر اساس سوابق تشخیصی پزشکی برچسب‌گذاری شده‌اند. در ابتدا، مدل تشخیص شیء YOLOX برای شناسایی کادرهای پوسیدگی در تصاویر رادیوگرافی استفاده شده و کادرهای مربوط به پوسیدگی در تصاویر اصلی تولید می‌گردند. سپس، با استفاده از مدل تقسیم‌بندی معنایی FCN-8s ، مناطق پوسیدگی در تصاویر برش‌خورده شناسایی می‌شوند. نتایج نشان می‌دهد که مدل YOLOX در شناسایی محدوده پوسیدگی به میانگین صحت (mAP) ۶۸,۳۵دست یافته است. همچنین، مدل FCN-8s برای تقسیم‌بندی مناطق پوسیدگی دقت ۸۲,۰۵ درصد و ضریب شباهت دایس برابر ۰,۸۴۳ را کسب کرده است. این روش یادگیری تدریجی نشان‌دهنده پیشرفت‌های قابل توجهی در تشخیص و تقسیم‌بندی خودکار پوسیدگی دندان بر روی رادیوگرافی‌های پریاپیکال است. مدل DCD-Net [۶۸] عملکرد بسیار بالایی در تقسیم‌بندی و شمارگذاری دندان‌های کودکان دارد و به طور قابل توجهی نیاز به تصاویر آموزشی را کاهش می‌دهد. با این حال، [۶۹] به دلیل ایجاد یک مجموعه داده بزرگ شامل ۵۵۶۹ تصویر رادیوگرافی و برچسب‌گذاری دقیق بر اساس سوابق پزشکی، پتانسیل خوبی برای تحقیقات آینده دارد. این مجموعه داده می‌تواند به توسعه مدل‌های جدید و بهبود دقت تشخیص کمک کند.

تشخیص بیماری دندان در تصاویر CBCT با توجه به اهداف در مانی این نوع تصویر کمتر صورت می‌پذیرد. با این حال، زانینی و همکاران [۷۰] از روش یادگیری خود نظارتی جهت دسته‌بندی پوسیدگی دندان در تصاویر CBCT استفاده نموده‌اند. یکی از چالش‌های مهم تشخیص پوسیدگی دندان با استفاده از روش‌های یادگیری عمیق برچسب‌گذاری تصاویر است، که علاوه بر کم بودن تعداد داده‌ها، سوگیری برچسب‌گذاری نیز مطرح است. روش ارائه شده با توجه به استفاده از روش یادگیری خود نظارتی نیاز به داده‌های برچسب‌گذاری شده نداشته و از تکنیک‌های پردازش تصویر برای آموزش استفاده کرده است. در این پژوهش برای معماری ResNet-18 همراه با وظایف SimCLR[۱] بهترین عملکرد با صحت ۹۰,۴۴ درصد و ۸۶,۶۷ درصد پوشش گزارش شده است. SimCLR از چارچوب یادگیری متضاد استفاده می‌کند، هدف به حداقل رساندن شباهت در یک تصویر و همچنین به حداقل رساندن شباهت با دیگر تصاویر است. با استفاده از این روش ویژگی‌های تقویت شده نسخه‌های مختلف تصویر را می‌توان بدست آورد. استفاده از این بخش قابلیت تشخیصی مدل را افزایش می‌دهد. یادگیری خود نظارتی به عنوان یک تکنیک نوین در یادگیری ماشین، امکان استفاده از ویژگی‌های موجود در داده‌ها را فراهم می‌کند. این رویکرد با ایجاد وظایف یادگیری که به مدل‌ها اجازه می‌دهد تا شباهت‌ها و تفاوت‌ها را در تصاویر شناسایی کنند، دقت قابل قبولی را فراهم می‌کند. در مقایسه با [۶۸] دقت فراهم شده در مدل خود نظارتی عملکرد ضعیف‌تری را داشته اما به دلیل کاهش نیاز به برچسب‌گذاری پتانسیل بیشتری برای تحقیقات آتی دارد.

استفاده از تصاویر پزشکی امکان بررسی دقیق شرایط دندان، نوع و میزان پوسیدگی را برای متخصصین فراهم می‌کند. با این حال امروزه برخی از پژوهش‌ها به دنبال روش‌های کاربردی تشخیص بیماری با استفاده از تصاویر عادی می‌باشند. کانیش و همکاران [۱۰] با استفاده از ۲۴۱۷ تصویر معمولی که در قالب RGB گرفته شده‌اند و مدل CNN روشی جهت تشخیص بیماری دندان ارائه نموده‌اند. با توجه به سه دسته سالم، ضایعه پوسیدگی بدون حفره، پوسیدگی با حفره دندان‌ها دسته‌بندی شده و جهت تسریع فرآیند آموزش مدل از وزن‌های MobileNetV2 از پیش آموزش دیده شده استفاده شده است. دقت فراهم شده برای سه دسته نام برده به ترتیب برابربا ۹۰/۶، ۸۵/۲ و ۷۹/۵ درصد است. شکل (۴) نمونه‌ای از تصاویر و پاسخ شبکه عصبی را نمایش می‌دهد، نقاط آبی محل‌هایی است، که مدل پیشنهاد شده بیشترین تمرکز را جهت تصمیم‌گیری برآن داشته است.

در پژوهشی مشابه، زیانگ و همکاران [۱۱] نیز با استفاده از تصاویر عادی مدلی جهت تشخیص پوسیدگی دندان و فیشورسیلانت[۲] (جرم شکاف دندان آسیاب) ارائه نموده‌اند. در این روش با استفاده از ۱۰۲۰ تصویر مدل اصلاح شده YOLOX آموزش داده شده است. پوشش و صحت گزارش شده برای تشخیص پوسیدگی ۸۱,۷ و ۸۰,۷ درصد و برای تشخیص سیلانت ۷۱,۴ و ۷۵ درصد است. شکل (۵) نمونه‌ای از تشخیص پوسیدگی و سلانت را نمایش می‌دهد. نتایج حاصل از مدل با تشخیص دندان پزشک با یک سال سابقه مقایسه شده که به ترتیب برای تشخیص پوسیدگی صحت ۸۱,۴ و ۱۰۰ درصد وپوشش ۸۰,۷ و ۴۲,۸ درصد گزارش شده است. از نظر معیارهای

---

[۱] Simple Framework for Contrastive Learning of Visual Representations

[۲] Fissure sealant

ارزیابی، [۱۰] از دقت بالاتری برخوردار است و این امر می‌تواند به دلیل استفاده از وزن‌های MobileNetV2 از پیش آموزش دیده باشد که به تسریع فرآیند آموزش مدل کمک کرده است. در حالی که [۱۱] نیز از مدل YOLOX بهره برده، اما دقت‌های گزارش شده کمتر هستند. با توجه به این نتایج، [۱۰] می‌تواند به عنوان مبنای تحقیقاتی برای توسعه روش‌های جدید و بهبود دقت در آینده مورد استفاده قرار گیرد مجموع داده کوچک‌تر [۱۱] نیز می‌تواند منجر به کاهش دقت مدل شده باشد.

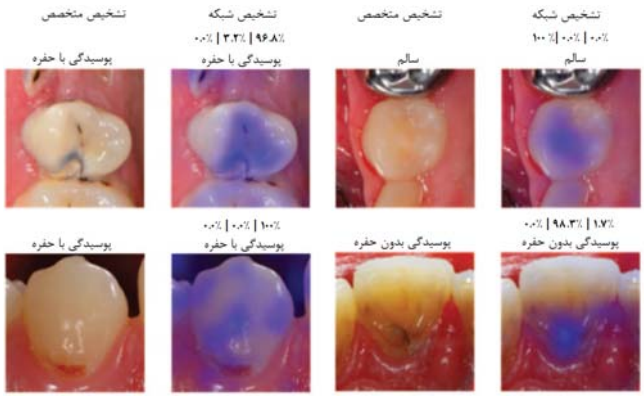

شکل (۴): نمونه‌ای از تصاویر بالینی و پاسخ شبکه عصبی [۱۰]

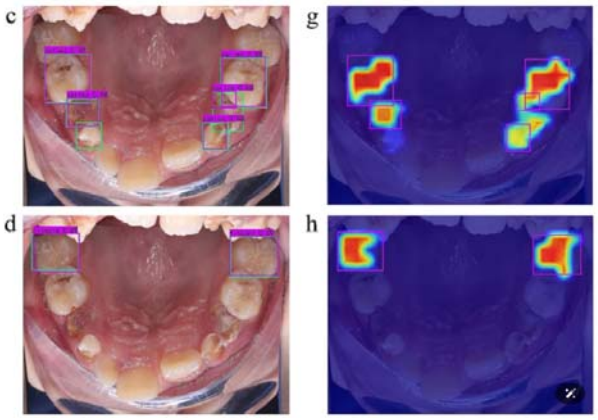

شکل (۵): تشخیص پوسیدگی و سیلانت [۱۱]

۶-۲- دسته‌بندی ضایعات و بیماری‌های دهان

بیماری‌های دهان و دندان طیف گسترده‌ای داشته و تشخیص بسیاری از بیماری‌ها با استفاده از تصویر برداری امکان پذیر است. رشید و همکاران [۷۱] با استفاده از روش InceptionResNetV2 مدلی جهت تشخیص هفت دسته بیماری دهان و دندان شامل برفک ، سرطان دهان، زخم سرد و غیره ارائه نموده‌اند. در این پژوهش از ۵۱۷ تصویر که با دوربین عادی گرفته شده‌اند، استفاده شده است. مدل ارائه شده به طور میانگین برای کلیه دسته‌ها دقت ۹۹,۵۱ درصد را فراهم آورده و پارامترهای صحت و پوشش به ترتیب بین ۹۸ تا ۱۰۰ درصد گزارش شده‌اند.

بررسی استخوان‌های فک در برخی از بیماری‌های ناشی از ناهنجاری‌های رشد دندان، کاربرد دارد. بو وهمکاران [۷۲] با استفاده از SVM دو مرحله‌ای روشی جهت بررسی پوکی استخوان ترابکولار[۱] در تصاویر پانورامیک اشعه ایکس ارائه نموده‌اند. در این روش با استفاده از مناطق مطلوب SVM آموزش دیده و پس از آن با ترکیب احتمالات خروجی SVM خطی جهت پیش‌بینی ایجاد می‌شود. روش پیشنهادی با استفاده از ۴۰ تصویر، که ۱۹ تصویر دچار مشکل وبقیه عادی بوده‌اند، بررسی شد و دقت ۷۲/۵ درصد برای آن گزارش شده است. در این پژوهش از هشت ROI استفاده شده، که به دو گروه متقارن تبدیل می‌شوند، شکل (۶) این مناطق را نمایش می‌دهد. ویژگی‌های هیستوگرام شدت[۲]، هیستوگرام الگوی باینری محلی[۳] و هیستوگرام توصیف‌گر گرادیان جهت‌دار[۴] جهت استخراج ویژگی استفاده شده‌اند، که هیستوگرام توصیف‌گر گرادیان جهت‌داربهترین نتیجه را فراهم نموده است. شکل (۶) هشت نقطه مورد نظر را در یک تصویر نمایش می‌دهد.

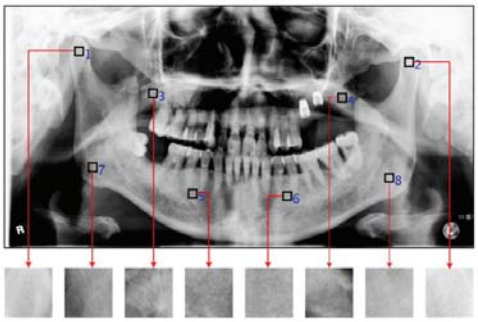

شکل (۶): نواحی ROI تصویر پانورکس [۷۲]

در پژوهشی مشابه، سندوال و همکاران [۷۳] در پژوهشی با استفاده از تصاویر سفالوگرام سعی بر تعیین موقعیت صحیح فک پایین داشتند. در این پژوهش با استفاده از ۲۲۹ تصویر متعلق به ۹۵ زن و ۱۳۴ مرد، که بازه سنی بین ۱۸ تا ۲۵ سال داشته‌اند، مختصات نشان‌های[۵] صورت به عنوان ویژگی در نظر گرفته شده‌اند. نشان‌ها با تحلیل ریخت‌شناسی هندسی و بهره‌گیری از تخصص دندان پزشک اخذ شده‌اند، که هر تصویر با استفاده از ۷ نشان فک پایین و ۱۲ متغیر کرانیومگزیلاری[۶] تفسیر می‌شود. با استفاده از SVM اسکلت صورت افراد به سه کلاس تقسیم شده که دقت بدست آماده برای کلیه کلاس‌ها ۶۵/۲۲ درصد گزارش شده است. این پژوهش به رغم تعداد بیشتر تصاویر دقت پایین‌تری را فراهم می‌کند، که نشان‌دهنده چالش‌های بیشتری در تحلیل و تفسیر داده‌های پیچیده‌تر است. مقایسه [۷۲] و [۷۳] به دلیل ماهیت متفاوت پژوهش ممکن نیست اما می‌توان به عنوان یکی از مسیرهای آتی پژوهش تغییر روش‌های استخراج ویژگی، افزایش حجم داده‌ها و استفاده از روش‌های جدید یادگیری را برای هر دو پژوهش مطرح نمود.

---

۱ Trabecular
۲ Intensity Histogram
۳ Local Binary Pattern Histogram
۴ Histogram of Oriented Gradient Descriptor
۵ Landmarks
۶ Craniomaxillary

کیست‌های دندان معمولا به دلیل عفونت ریشه دندان، دندان را مستعد پوسیدگی می‌سازند، تشخیص کیست‌های دندان و تعیین نوع آن کمک شایانی بر جلوگیری از تخریب بیشتر دندان می‌نماید. آمیلوبلاستوم، کراتوسیست و دنتیژروس[۱] از کیست‌های رایج دندان هستند، بانو وهمکاران [۷۴] با استفاده از روش ماتریس هم‌وقوع سطح خاکستری[۲] (GLCM) با استخراج ویژگی‌های تباین، همبستگی، انرژی، هم‌جنسی و غیره مدلی براساس روش k-میانگین جهت دسته‌بندی کیست‌های دندانی ارائه نموده‌اند. در این روش که براساس تحلیل بافت از طریق روش‌های سنتی پردازش تصویر ارائه شده، مجموعا از ۴۵ تصویر استفاده شده و به ترتیب دقت ۸۰، ۸۵/۷ و ۸۱/۸۱ درصد برای تومورهای آمیلوبلاستوم، کراتوسیست و دنتیژروس گزارش شده است. گیتا و همکاران [۷۵] در پژوهشی مشابه با استفاده از روش‌های استخراج ویژگی سنتی و فیلتر لاپلاس برای افزایش وضوح تصویر و آستانه تطبیقی و ریخت‌شناسی پوسیدگی دندان را دسته‌بندی نموده‌اند. در این پژوهش از GLCM و روش تفاوت سطوح خاکستری[۳] (GLDM) جهت استخراج ویژگی‌های بافت و سپس از ماشین بردار پشتیبان[۴] (SVM) برای دسته‌بندی استفاده شده است. ویژگی‌ها با استفاده از ۶۴ تصویر رادیوگرافی استخراج و ۹۶/۸۸ درصد دقت را فراهم نموده‌اند.

رویکرد [۷۴] بر پایه تحلیل بافت و ویژگی‌های سنتی است، در حالی که دقت قابل قبولی دارد، به دلیل محدودیت در تعداد تصاویر و استفاده از تکنیک‌های قدیمی‌تر در استخراج ویژگی، ممکن است نتایج نهایی با استفده از تکنیک‌های بروزتر بهبود یابند. در مقابل [۷۵] از ترکیبی از روش‌های پیشرفته‌تر مانند فیلتر لاپلاس و ماشین بردار پشتیبان(SVM) ، استفاده کرده است. با توجه به نتایج، این روش به دلیل دقت بالاتر و استفاده از تکنیک‌های مدرن در یادگیری ماشین و استخراج ویژگی، برتری بیشتری نسبت به [۷۵] دارد. کارهای آتی می‌توانند بر روی بهینه‌سازی این روش‌ها و افزایش حجم داده‌ها تمرکز کنند تا به نتایج بهتری دست یابند. یادگیری عمیق در تشخیص بیماری‌های لثه و دسته‌بندی ضایعات کاربرد زیادی دارد. لی و همکاران [۷۶] با استفاده از یادگیری عمیق روشی جهت تشخیص پوسیدگی دندان‌ها و به طور همزمان تشخیص آبسه پری‌آپیکال ارائه نموده‌اند. آموزش و ارزیابی مدل با استفاده از ۴۱۲۹ تصویر رادیوگرافی انجام شده و از شبکه ResNet-18 اصلاح شده، پس از جداسازی محل ریشه و تاج دندان در تصاویر برای آموزش مدل استفاده شده است. در این پژوهش برای تشخیص پوسیدگی صحت ۸۲,۲۷ و پوشش ۸۳,۵ درصد و برای تشخیص آبسه پری‌آپیکال صحت ۸۳,۶۷ و پوشش ۸۲ درصد گزارش شده است. این پژوهش در مقایسه با روش‌های استخراج ویژگی سنتی نیاز به داده بیشتری داشته است، اما تعمیم‌پذیری فراهم شده توسط مدل به شکل چشم‌گیری متفاوت است.

لی و همکاران [۷۷] با استفاده از CNN روشی جهت تشخیص ضایعات پری‌آپیکال دندان که اغلب منجر به عفونت‌های مزمن می‌شوند ارائه نموده‌اند. در این روش به منظور افزایش دقت مدل از فیلتر گوسی بالاگذر استفاده شده که تمایز بیشتر ریشه از سطوح خاکستری دیگر را فراهم می‌کند. پس از انجام فرآیند پیش‌پردازش هر یک از دندان‌ها با استفاده از برش عمودی به تفکیک از تصاویر جدا شده و برای آموزش CNN استفاده می‌شوند. داده مورد استفاده مجموعا شامل ۴۷۶ دندان است، که تنها ۶۵ دندان آسیب دیده‌اند، از آنجا که تعداد دسته‌ها متقارن نبوده و این تاثیر زیادی بر دقت مدل دارد، از چرخش تصاویر برای افزایش تعداد داده‌ها استفاده شده است، برچسب‌گذاری داده توسط سه پزشک با حداقل ۴ سال سابقه انجام شده و مدل دقت ۹۲,۵ درصد را فراهم نموده است. انگوک و همکاران [۷۸] با استفاده از ۱۰۰۰ تصویر پری‌آپیکال اشعه ایکس مدل R-CNN سریع‌تر را آموزش داده و برای بررسی عملکرد مدل از ۱۳۰ تصویر دیگر که مجموعا شامل ۱۴۳ دندان با ضایعه پری‌آپیکال بود، بهره برده است. این مدل توانایی فراهم آوری دقت ۹۵,۶ درصد و پوشش ۸۹,۵ درصد را داشته و عملکرد مدل برای دندان‌های خلفی فک بالا و قدامی فک پایین معیارهای ارزیابی ۱۰۰ درصد را فراهم آورده است.

اگرچه [۷۶] از حجم داده بالایی بهره‌مند است، اما دقت آن نسبت به [۷۷] و [۷۸] کمتر است و این می‌تواند به دلیل پیچیدگی‌های موجود در تشخیص همزمان دو نوع عارضه باشد. تلفیق دو مدل مجزا هر یک برای تشخیص عارضه‌ای متفاوت موضوعی برای پژوهش‌های اتی است. [۷۸] به دقت بیشتری دست یافته است، که نشان از قدرت بیشتر مدل R-CNN سریع‌تر نسبت به [۷۷] است. استفاده از تکنیک‌های افزایش داده برای هر دو پژوهش ضروری است، [۷۶] با وجود دقت پایین‌تر تعمیم‌پذیری بالاتری داشته و نتایج گزارش شده قابل استنادتر می‌باشند. عدم تقارن تعداد دسته‌ها در پژوهش‌ها منجر به سوگیری مدل خواهد شد که می‌تواند در پژوهش‌های آتی مورد بررسی قرار گیرد.

۶-۳- بخش‌بندی ناحیه بیماری دندان

تشخیص دقیق محل بیماری دندان با استفاده از مدل‌های آشکارساز و بخش‌بندی قابل انجام است. لی و همکاران [۷۹] روشی جهت تشخیص بیماری دندان با استفاده از شبکه عصبی U-Net آموزش داده شده توسط تصاویر بایت‌وینگ ارائه نموده‌اند. در مجموع ۳۵۴ تصویر استفاده شده که فقط ۵۰ مورد برای بررسی دقت مدل و بقیه برای آموزش به کار برده شده‌اند.

---

[۱] Dentigerous
[۲] Gray level co-occurrence matrix
[۳] Grey Level Difference Method
[۴] Support Vector Machine

برچسب‌گذاری داده توسط سه متخصص با حداقل ۵ سال تجربه بالینی انجام شده و تصاویر دندان با خطوطی تفکیک شده جهت تعیین پوسیدگی و ساختار دندان (مینا، عاج، پاپ، ترمیم‌های همرنگ دندان، ترمیم‌های فلزی و گوتاپرکا[۱]) بخش‌بندی شده‌اند، درصورت بروز اختلاف در وجود و یا عدم وجود پوسیدگی با توافق دو متخصص یا ورود متخصص سوم یک تصمیم واحد گزارش شده است. به ترتیب مقادیر صحت و پوشش ۶۳/۲۹ و ۶۵/۰۲ درصد برای این مدل گزارش شده است.

در پژوهشی مشابه، کانتو و همکاران [۸۰] به منظور تشخیص ناحیه پوسیدگی دندان از شبکه عصبی U-Net استفاده نموده و آموزش و ارزیابی شبکه را با استفاده ۳۲۹۳ تصویر بایت‌وینگ، انجام داده‌اند. در این پژوهش برچسب‌گذاری دندان‌ها توسط متخصصین که بین ۳ تا ۱۴ سال سابقه کار دارند، صورت پذیرفته است. خرابی دندان‌ها در سطوح یک تا سه (D1/3) و نوع خرابی داخلی و خارجی(E1/2) نیز در تصاویر موجود بوده است. دقت فراهم شده برای دید دیستال ۸۸ و مزیال ۸۹ درصد گزارش شده است، در مجموع مدل ارائه شده دقت ۸۰ و پوشش ۷۵ درصد را فراهم آورده است. ضریب همبستگی متیوز[۲]، که معیار مناسبی برای بررسی نامتعادل بودن دسته‌ها است، در این پژوهش ۵۷ درصد گزارش شده است. همچنین، بایراکدار و همکاران [۸۱] با استفاده از دو شبکه VGG-16 و U-Net روشی جهت دسته‌بندی و بخش‌بندی همزمان پوسیدگی دندان ارائه نموده‌اند. در این پژوهش از ۶۲۱ تصویر بایت‌وینگ استفاده شده که صحت و پوشش فراهم شده برای دسته‌بندی پوسیدگی به ترتیب ۸۱، ۸۴ درصد و برای بخش‌بندی پوسیدگی ۸۴ و ۸۶ درصد گزارش شد است.

پژوهش [۷۹] به دلیل استفاده از حجم داده محدود و برچسب‌گذاری توسط متخصصین با تجربه، نتایج نسبتا پایینی را ارائه می‌دهد. همچنین، فرآیند تصمیم‌گیری در مورد وجود یا عدم وجود پوسیدگی به دلیل نیاز به توافق بین متخصصین ممکن است زمان‌بر و پیچیده باشد. این درحالی است، که در نظر گرفتن تخصص افراد و حساسیت در تعیین برچسب داده‌ها از سوگیری مدل جلوگیری کرده و نتایج گزارش شده را قابل اطمینان‌تر می‌سازد. در مقایسه [۸۰] نه تنها از حجم داده بیشتری بهره‌مند است، بلکه برچسب‌گذاری توسط متخصصینی با سابقه کار بین ۳ تا ۱۴ سال انجام شده که می‌تواند به افزایش دقت و اعتبار نتایج کمک کند. همچنین، ضریب همبستگی متیوز ۵۷ درصد نشان‌دهنده توانایی این مدل در مدیریت عدم تعادل دسته‌ها است. [۸۱] با بهره‌گیری از دو مدل متفاوت نتایج بهتری را در مقایسه با مقالات مشابه فراهم نموده است، این در حالی است، که از مجموعه داده کوچکتری استفاده کرده و ممکن است شامل تنوع کافی در شرایط مختلف، که می‌تواند به قابلیت تعمیم نتایج آسیب برساند. بهبود در حجم داده‌ها و کیفیت برچسب‌گذاری می‌تواند در پژوهش‌های آتی به افزایش دقت و کارایی این روش کمک کند.

در پژوهشی دیگر با تقویت مدل و بهره‌گیری از داده‌های بیشتر، لیان و همکاران [۸۲] با ارائه روشی به نام nnU-Net پوسیدگی‌های موجود را با توجه به عمق آن به تفکیک یافته و با استفاده از شبکه DenseNet121 ضایعات را از دید نوع پوسیدگی دسته‌بندی نموده‌اند. در این روش نتایج حاصل با رویکرد شش دندان‌پزشک مجرب مقایسه و دقت ۹۸,۶ درصد و پوشش ۸۲,۱ درصد برای این مدل گزارش شده است. در این پژوهش از ۱۱۶۰ تصویر پانورکس استفاده شده، که ابتدا سطوح خرابی به سه دسته تقسیم شده و سپس فرآیند آموزش جهت بخش‌بندی پوسیدگی و پس از آن دسته‌بندی نوع پوسیدگی با توجه به عمق خرابی صورت پذیرفته است. در مجموع ۱۱۶۶ پوسیدگی نوع یک، ۱۰۳۹ پوسیدگی نوع دو و ۱۶۳۵ پوسیدگی نوع سه از مجموع کل تصاویر استخراج شده است. در پژوهشی دیگر، رهرر و همکاران [۸۳] مدلی براساس U-Net ارائه نموده‌اند، که توانایی بخش‌بندی دندان در تصاویر پانورامیک اشعه ایکس براساس تاج، ترمیم، کانال ریشه و ایمپلنت را دارد. در این مدل برای آموزش و ارزیابی از ۱۷۸۱ تصویر پانورامیک اشعه ایکس استفاده شده و توانایی بخش‌بندی ریشه‌های مخروطی شکل کوچک تا ۲۹۴ درصد افزایش یافته است.

تکنکیک [۸۲] با تاکید بر تفکیک عمیق‌تر، دقت بیشتری را فراهم نموده است. تحلیل عمق پوسیدگی تاثیر بسزایی در دقت مناسب مدل و فراهم آوری اطلاعات دقیق‌تر داشته است. مقایسه نتایج مدل با ارزیابی شش دندان‌پزشک مجرب، اعتبار و قابلیت اعتماد به نتایج را افزایش می‌دهد و نشان‌دهنده تاثیر مثبت روش پیشنهادی بر روی تصمیم‌گیری‌های بالینی است. در مقایسه [۸۳] با استفاده از مجموعه داده کمتر دقت قابل قبولی را فراهم نموده، استفاده از مجموعه داده کوچک‌تر تعمیم‌پذیری مدل را کاهش داده است. افزایش تنوع پوسیدگی‌های موجود در تصاویر و ارتقا ساختار [۸۲] nnU-Net از مسیرهای پژوهش‌های آتی می‌باشد.

٦-٤- دسته‌بندی برند و بیماری ایمپلنت

ایمپلنت‌های دندان در واقع ریشه‌های دندان مصنوعی هستند، که معمولا از جنس تیتانیوم ساخته می‌شوند. ایمپلنت‌های اندوستال[۳] مستقیما درون استخوان فک قرار گرفته و ایمپلنت ساپریوستال[۴] زیر لثه و بالای استخوان فک قرار می‌گیرند. ایمپلنت‌ها مانند دندان طبیعی دچار پوسیدگی نمی‌شوند، مگر اینکه در شرایط خاص باعث ایجاد عفونت و التهاب شوند. چالش مهم جراحی ایمپلنت تشخیص محل قرارگیری و بررسی‌های ثانویه برای

---

[۱] Gutta percha

[۲] Matthew’s correlation coefficient

[۳] Endosteal

[۴] Subperiosteal

اطمینان از قرارگیری درست این شی خارجی در دهان است. جایگیری مناسب ایمپلنت می‌تواند از بسیاری از التهاب و عفونت‌های ممکن جلوگیری نماید. با توجه به جنس ایمپلنت در تصاویر دندان‌پزشکی این بخش مقدارعددی نزدیک به ۲۵۵ در سطوح خاکستری دارد.

ویمولا و همکاران [۸۴] با استفاده از تکنیک‌های پردازش تصویر شبکه عصبی پیشنهاد نموده‌اند، که توانایی دسته‌بندی ایمپلنت‌های شکسته شده را دارد. در این پژوهش از شبکه از پیش آموزش دیده شده VGG-16 و VGG-19 استفاده شده و با توجه به طیف رنگی ایمپلنت در تصاویر پری‌آپیکال، داده‌های فرکانس بالا برای حفظ اطلاعات از طریق کسینوس گسسته دو بعدی تبدیل شده‌اند. مجموعا از ۲۵۱ تصویر که ۱۹۴ مورد ایمپلنت سالم و بقیه موارد تخریب شده‌اند، برای آموزش و ارزیابی مدل استفاده شده و دقت ۹۵,۷ درصد برای این شبکه گزارش شده است. در پژوهشی مشابه سوکیگاوا و همکاران [۸۵] با استفاده از معماری‌های VGG-16 و VGG-19 مدلی جهت دسته‌بندی انواع برندهای مختلف ایمپلنت‌ها طراحی نموده‌اند. شبکه با استفاده از ۸۸۵۹ تصویر پانورامیک اشعه ایکس آموزش داده شده و سپس ارزیابی می‌شود. در این پژوهش ۵ مدل یادگیری عمیق شبکه عصبی پیچشی، VGG-16 و VGG-19 انتقالی و از پیش آموزش دیده مقایسه شده‌اند، که VGG-16 از پیش آموزش دیده بهترین عملکرد را داشته و به ترتیب پارامترهای دقت، صحت و پوشش این مدل ۹۳,۵ ، ۹۲,۸ و ۹۰,۷ درصد گزارش شد است.

پژوهش [۸۴] به دلیل استفاده از تکنیک‌های پردازش تصویر و تبدیل داده‌های فرکانس بالا، اطلاعات مهمی را از تصاویر پری‌آپیکال حفظ می‌کند. با این حال، محدودیت اصلی این پژوهش به حجم کم داده‌ها (۲۵۱ تصویر) مربوط می‌شود که می‌تواند تأثیر زیادی بر قابلیت تعمیم‌پذیری مدل داشته باشد و نتایج را تحت تأثیر قرار دهد. در حالی که، [۸۵] با استفاده از ۸۸۵۹ تصویر پانورامیک، به بررسی انواع برندهای مختلف ایمپلنت‌ها پرداخته و مدل‌های مختلفی را مقایسه کرده است. اگرچه دقت VGG-16 از پیش آموزش دیده ۹۳,۵ درصد گزارش شده، اما این دقت نسبت به پژوهش [۸۴] پایین‌تر است. با این حال، تنوع بالای داده‌ها و مقایسه چندین مدل، اعتبار نتایج را افزایش می‌دهد. کارهای آتی برای هر دو پژوهش می‌تواند شامل افزایش حجم داده‌ها، بهبود فرآیند برچسب‌گذاری و استفاده از تکنیک‌های یادگیری انتقالی برای بهبود عملکرد مدل‌ها باشد.

تشخیص نوع برند ایمپلنت کمک شایانی در برنامه‌ریزی درمان می‌نماید. از این رو در پژوهشی دیگر کرتلوس و همکاران [۸۶] با مقایسه ۲۵ مدل شبکه عصبی از جمله معماری‌های VGG-16، EfficientNet،ConvNet و غیره دسته‌بندی شش سیستم مختلف ایمپلنت را با استفاده از تصاویر پانورامیک اشعه ایکس ارائه نموده‌اند. پس از آموزش و ارزیابی مدل‌ها با استفاده از ۱۲۵۸ تصویر نتایج حاصل نشان داد مدل ConvNeXt با فراهم آوری دقت ۹۵,۷۴ درصد عملکرد بهتری را داشته است. با توجه به تعداد زیاد دسته‌ها تصویر با تغییر مقیاس و چرخش در زوایای مختلف، برای آموزش بهتر مدل‌ها افزایش یافته‌اند. لی و همکاران [۸۷] با استفاده از معماری عمیق GoogLeNet Inception-v3 مدلی جهت دسته‌بندی سه برند متفاوت ایمپلنت ارائه نموده‌اند. در این پژوهش از ۵۳۹۰ تصویر پانورامیک اشعه ایکس و ۵۳۸۰ تصویر پری‌آپیکال استفاده شده و پوشش ۹۵,۳، ۹۳,۶ و ۹۷,۱ درصد را برای هر یک از دسته‌ها فراهم نموده است.

در مقایسه دو تکنیک اخیر، [۸۶] به دلیل تنوع بالا در مدل‌ها و استفاده از ۱۲۵۸ تصویر، اعتبار و قابلیت تعمیم‌پذیری خوبی دارد. همچنین، استفاده از تکنیک‌های تغییر مقیاس و چرخش تصاویر به بهبود عملکرد مدل کمک کرده است. در مقابل، پژوهش [۸۷] با استفاده از معماری GoogLeNet Inception-v3 و ۱۰۷۷۰ تصویر توانایی دسته‌بندی در دو نوع تصویر متفاوت را دارد. اگرچه دقت کلی این پژوهش کمتر از [۸۶] است، اما حجم بالای داده‌ها و تنوع نوع تصاویر می‌تواند به افزایش اعتبار نتایج کمک کند. بررسی مدل‌های مختلف به منظور ایجاد تکنیک‌های تلفیقی مستقل از نوع تصویر مسیری از تحقیقات آتی است.

آرجی و همکاران [۸۸] با طراحی دو مدل یادگیری عمیق روشی برای دسته‌بندی چهار برند ایمپلنت ارائه نموده‌اند. مدل اول با استفاده از معماری YOLOV7 تصاویر را با توجه به محل ایمپلنت برش داده و مدل دوم با استفاده از معماری EfficientNet نوع برند ایمپلنت را تشخیص می‌دهد. دو مدل با استفاده از ۱۵۷۴ تصویر پانورامیک اشعه ایکس که جمعا حاوی ۳۶۷۵ ایمپلنت از چهار برند متفاوت بوده‌اند آموزش و ارزیابی شده‌اند. مدل اول در برش دندان‌ها ایمپلنت به پوشش ۱۰۰ و صحت ۹۷,۹ درصد و مدل دوم در دسته‌بندی برندها غیر ازیک برند به معیار ارزیابی بالای ۹۲ درصد رسیده است. سوکیگاوا و همکاران [۸۹] پنج معماری ResNet-18، ۳۴، ۵۰، ۱۰۱ و ۱۵۲ را به منظور دسته‌بندی ۱۲ برند متفاوت ایمپلنت مقایسه نموده‌اند. در این پژوهش از ۷۰۷۹ تصویر پانورامیک اشعه ایکس استفاده شده، که به شکل دستی به ۹۷۶۷ تصویر ایمپلنت دندان برش داده شده‌اند. دقت فراهم شده توسط معماری‌های چندوظیفه‌ای ResNet-18، ۳۴، ۵۰، ۱۰۱ و ۱۵۲ به ترتیب ۹۸,۰۳، ۹۸,۵۱، ۹۸,۶۹، ۹۸,۹۹ و ۹۹,۰۸ درصد است.

لی و همکاران [۹۰] معماری ResNet-50 از پیش آموزش دیده را برای آموزش مدل با استفاده از ۱۵۶۹۶۵ تصویر پانورامیک اشعه ایکس و پری‌آپیکال استفاده نموده‌اند. این مدل قادر به تشخیص سیستم ایمپلنت تصاویر تخریب شده و با کیفیت پایین است. ۵۳۰ تصویر با کیفیت پایین و تخریب شده نیز برای ارزیابی مدل استفاده شده، این تصاویر با در نظر گرفتن تخریب‌های غیر عمود بر پایه ایمپلنت، قرار گرفتن در معرض تشعشع بالا، برش راس پایه ایمپلنت و حاوی اجسام خارجی تغییر یافته‌اند. مدل ارائه شده قادر به تشخیص پنج دسته متفاوت

بیماری لثه دندان بر اساس ایمپلنت است. این مدل به ترتیب به دقت، صحت و پوشش ۹۲,۴۹، ۹۵,۹۱، ۹۵,۰۵ درصد دست یافته است. با این حال پس از تخریب تصاویر برای دسته‌بندی پنج بیماری براساس ۹ نوع برند دقت ۲۹±۳۷,۲ درصد فراهم شده است. کیم و همکاران [۹۱] شبکه عصبی عمیق براساس معماری YOLOV3 ارائه نموده‌اند، که قادر به دسته‌بندی سه برند ایمپلنت سطح استخوان می‌باشد. در این پژوهش از معماری YOLOV3 از پیش آموزش دیده شده با پایگاه داده حجیم COCO استفاده شده است، سپس از ۲۶۳ تصویر پری آپیکال اشعه ایکس که جمعا حاوی ۳۵۵ ایمپلنت است، برای آموزش و ارزیابی مدل استفاده شده است. نتایج حاصل از ارزیابی دقت ۹۶,۷ و پوشش ۹۴,۴ درصد را فراهم نموده است.

استفاده از مدل‌ها تلفیقی در [۸۸] دقت قابل قبولی را فراهم کرده است. [۸۹] با حجم داده بالاتری با استفاده از پنج معماری مختلف ResNet ، به مقایسه ۱۲ برند ایمپلنت پرداخته‌اند و دقت‌های بالای ۹۸ درصد را برای هر یک از مدل‌ها گزارش کرده است. با این حال، تمرکز بر روی مدل‌های چندوظیفه‌ای ممکن است پیچیدگی بیشتری را در فرآیند آموزش و ارزیابی ایجاد کند. این در حالی است که مدل‌های آشکارساز تک مرحله‌ای سرعت بالاتری داشته و می‌توان به شکل برخط از آنها استفاده نمود. [۹۱] به دلیل استفاده از پایگاه داده COCO و دقت نسبتا بالا در شرایط محدود، مزیتی در سرعت و کارایی دارد. با این حال، محدودیت در تعداد برندهای مورد بررسی و حجم کم داده‌ها، مشابه مشکلاتی است که [۸۸] با آن مواجه است. [۹۰] دقت پایین‌تری نسبت به دیگر پژوهش‌ها داشته اما به دلیل استفاده از نوع تصویر متنوع عملکرد مدل قابل قبول است. بررسی حجم بالایی از داده‌ها و به چالش کشیدن مدل با استفاده از تصاویر تخریب شده، نتایجی قابل اطمینان را فراهم نموده و نویسنده با تخریب تصاویر سعی بر شبیه‌سازی محیط بالینی داشته است.

پژوهش‌های حیطه دسته‌بندی و بخش‌بندی بیماری دندان با توجه به تعداد زیاد بیماری‌های دندان هنوز قادر به تشخیص کلیه بیماری‌های دندان به تفکیک نوع نیستند، اما تلاش‌های بسیاری در این حیطه صورت پذیرفته است، در برخی مقالات [۶۲] و [۶۵] فقط برخی از دندان‌ها به عنوان هدف تعیین شده و پوسیدگی این دندان‌ها با توجه به شرایط خاص در تصاویر بررسی شده است. با توجه به جدول شماره (۳) در برخی از پژوهش‌ها با استفاده از خصوصیات آناتومیک از روش‌های سنتی استخراج ویژگی [۵۸] تا [۶۱] استفاده شده و فرآیند دسته بندی بیماری با استفاده از روش‌های یادگیری عمیق صورت پذیرفته است. روش‌های سنتی استخراج ویژگی در مقایسه با روش‌های استخراج ویژگی از طریق شبکه‌های عمیق [۷۹] تا [۸۱] عملکرد ضعیف‌تری داشته‌اند. امروزه آشکارسازهای تک مرحله‌ای [۸۸] و [۹۱] و شبکه‌های بخش‌بندی تصویر [۷۹] و [۸۲] نیز برای دسته‌بندی بیماری دندان در تصاویر متنوع به کار گرفته می‌شوند.

با توجه به ضریب خطای موجود در پاسخ‌های روش‌های ارائه شده همچنان پژوهش‌ها در این زمینه برای دستیابی به اطلاعات دقیق‌تر ادامه دارد. استفاده از انواع معماری Res-Net [۸۹] و [۹۰] جهت دسته‌بندی بیماری و U-Net [۸۲] و [۸۳] جهت بخش‌بندی محدوده پوسیدگی ، خرابی ریشه و غیره در بین پژوهش‌های انجام شده بیشتر دیده می‌شود. تعیین نوع بیماری دندان در تصاویر متفاوت قابل انجام بوده و برخی از پژوهش‌های این حیطه تومورهای عفونی [۷۴] را به عنوان علت پوسیدگی دندان شناسایی نموده‌اند. استفاده از تصاویر اخذ شده با دوربین عادی [۱۰] و [۱۱] نیز به تازگی در پژوهش‌های این حیطه مشاهده می‌شود، که در این پژوهش‌ها صرفا تشخیص پوسیدگی‌های سطحی مورد بررسی قرار گرفته و امکان تعیین شرایط ریشه دندان وجود ندارد.

۷- جمع‌بندی

تفسیر تصاویر دندانپزشکی شامل تعیین نوع بیماری یا پوسیدگی دندان است، که دندان مورد نظر با استفاده از سیستم‌های شماره‌گذاری تعیین می‌شود، در نهایت پزشک با توجه به بیماری، شرایط بیمار، تجربه و غیره برنامه درمان بیمار را تعیین نموده و گزارش تکمیل می‌شود. تشخیص بیماری‌های دندان گام بزرگی در راستا تفسیر تصاویر دندان است. یکی از اهداف مهم هوشمندسازی تفسیر تصاویر سرعت بخشیدن به فرآیند گزارش نویسی تصاویر است. استفاده از سیستم‌های هوشمند قابلیت بهره‌مندی از تجربیات پزشکان با تجربه را نیز افزایش می‌دهد، در نتیجه می‌توان از سیستم هوشمند آموزش دیده با تجربیات پزشکان خبره جهت خدمت‌رسانی در مناطق و ساعاتی که پزشک حضور ندارد، استفاده نمود. بدیهی است با توجه به اخلاق پزشکی همچنان تجربه و دانش ارزشمند پزشکان در کنار هوشمندسازی مورد نیاز بوده و سیستم‌های هوشمند به عنوان ابزار مکمل به فرآیند تشخیص بالینی کمک می‌کنند.

پژوهش حاضر تصاویر اشعه ایکس داخل دهان و اندکی از تصاویر دیگر را مورد بررسی قرار داده است. اکثر پژوهش‌های بررسی شده مربوط به سال‌های اخیر بوده و کمتر روش‌های استخراج ویژگی سنتی مورد بررسی قرار گرفته‌اند. از ین رو باید اذعان کرد این پژوهش شامل تمامی مطالعات انجام شده نبوده و تمرکز بالایی روی مقالات حیطه یادگیری عمیق داشته است. در این پژوهش نمایی کلی از پژوهش‌های انجام شده ارائه شده که با رویکرد علمی پژوهش‌ها به سه بخش متفاوت تقسیم شده‌اند. پژوهش‌ها از دید تخصصی پردازش تصویر بررسی شده و از دیدگاه کاربرد بالینی هیچ استنباطی صورت نگرفته است.

بهبود تصویر به عنوان پایه‌ترین فرآیند بیان شده که همچنان در بسیاری از پژوهش‌ها از تکنیک‌های این بخش برای پیش‌پردازش استفاده می‌شود. تشخیص، دسته‌بندی و بخش‌بندی دندان پیش از فرآیند بررسی بیماری اهمیت بالایی دارد زیرا تعیین نام و نوع

دندان در گزارشات پزشکی اهمیت بالایی دارد. دسته‌بندی و بخش‌بندی بیماری دندان نسبت به دیگر بخش‌ها به دلیل طیف گسترده بیماری، نامتوازن بودن تعداد دندان‌های پوسیده و سالم و غیره چالش بیشتری دارد. در هر بخش با توجه به معیارهای ارزیابی گزارش شده دقت، صحت و پوشش جداولی مقایسه‌ای تشکیل شده که امکان بررسی عملکرد پژوهش‌های مختلف را فراهم می‌آورد. باید پذیرفت که مقایسه انجام شده به داده هر پژوهش وابسته است و از آن جا که همه پژوهش‌ها از مجموعه داده معیار استفاده نکرده‌اند نمی‌توان مقایسه را به روش اصولی انجام داد. با این حال در هیچ بخشی از پژوهش حاضر مقایسه‌ای مغرضانه صورت نپذیرفته است.

۷-۱- چالش‌های پردازش تصاویر دندان پزشکی

هوش مصنوعی فرصت‌های چشمگیری را برای پژوهشگران و متخصصان بالینی دندان‌پزشکی در زمینه تشخیص بیماری‌های دهان و دندان فراهم آورده است. افزون بر این، این فناوری ظرفیت قابل‌توجهی برای ارتقای روش‌های تشخیص در دندان‌پزشکی ایجاد کرده است. با این حال، به‌دلیل کمبود پایگاه‌های داده عمومی و در دسترس، به‌کارگیری عملی این فناوری با چالش‌های جدی مواجه شده است. همچنین، بهره‌گیری از الگوریتم‌های یادگیری ماشین و یادگیری عمیق هنوز به‌طور کامل در فرآیندهای روتین و روزمره دندان‌پزشکی یکپارچه نشده است؛ چرا که مسائل مرتبط با اشتراک‌گذاری داده‌ها و حفظ محرمانگی اطلاعات بیماران، نیازمند تدوین دستورالعمل‌های سیاست‌های استاندارد برای مدیریت داده‌ها هستند.

با توجه به پژوهش‌های صورت پذیرفته در این زمینه چالش‌های متعددی جهت هوشمندسازی تفسیر تصایر دندان وجود دارد. یکی از مهم‌ترین چالش‌ها، تشخیص متفاوت پزشکان است، با توجه به اینکه اکثر پژوهش‌ها از روش‌های یادگیری نظارت شده استفاده می‌کنند، برچسب‌گذاری داده‌ها از اهمیت بالایی برخوردار است. پیش‌بینی‌های مبتنی بر هوش مصنوعی تا حد زیادی به صحت برچسب‌گذاری داده‌ها وابسته‌اند؛ داده‌هایی که به‌صورت ناقص یا نادرست برچسب‌گذاری شده‌اند، می‌توانند منجر به نتایج نادقیق شده و اثربخشی سامانه‌های هوشمند تشخیص بیماری‌های دندانی را به‌طور جدی تحت‌تاثیر قرار می‌دهند.آموزش شبکه‌ها با توجه به نظر متخصص صورت پذیرفته و در صورتی که خطای انسانی رخ داده شود، متخصصین در نوع یا وجود بیماری توافق نداشته باشند، شبکه سوگری خاصی داشته و قابلیت اطمینان شبکه پایین می‌آید. به منظور جلوگیری از این مشکل در بسیاری از پژوهش‌ها [۶۰] و [۷۹] و [۶۳] و [۸۰] نظر چند متخصص دخیل بوده و در صورت بروز اختلاف از متخصص دیگری استفاده می‌شود. علاوه بر این از متخصصینی که تجربه بالینی بالایی داشته باشند جهت انجام فرآیند برچسب‌گذاری استفاده می‌شود. در برخی از پژوهش‌ها [۷۰] از روش‌های یادگیری خود نظارتی استفاده شده که نیاز به برچسب‌گذاری داده در این روش‌ها کمتر است.

از دیگر چالش‌های موجود، نبود مجموعه داده‌های معیار است، که بتوان عملکرد مدل‌ها را روی این داده‌ها بررسی نمود و امکان مقایسه اصولی پژوهش‌های انجام شده فراهم شود. از طرفی حداقل معیارهای ارزیابی مورد نیاز تعیین شود. با توجه به اخلاق پزشکی افشای اطلاعات بیمار ممنوع است، از این رو تعداد پایگاه داده‌های محدودی از تصاویر دندان وجود دارد، که به شکل عمومی در اختیار پژوهشگران قرار گیرد. از آنجا که تعداد دندان‌های سالم نسبت به دندان‌های پوسیده بسیار بیشتر است، توازن بین دسته‌های داده حفظ نشده و این عدم تعادل منجر به سوگیری شبکه‌ها هنگام آموزش شده و توانایی تشخیص بیماری توسط شبکه‌ها پایین می‌آید. به منظور غلبه بر این چالش نیز در پژوهش‌های مختلف [۲۹] و [۶۵] و [۶۳] تا [۷۸] از روش‌های افزایش داده با استفاده از تکنیک‌های چرخش، تغییر مقیاس و غیره استفاده می‌شود. عدم انتشار مجموعه داده‌های مورد استفاده در پژوهش‌ها منجر به کاهش قابلیت اطمینان نتایج می‌شود. شفافیت، به‌ویژه از منظر دسترسی‌پذیری و قابل‌فهم بودن داده‌ها، از جمله مؤلفه‌های کلیدی در پیاده‌سازی مسئولانه هوش مصنوعی محسوب می‌شود.

۷-۲- پیشنهادات تحقیقات آتی

طیف گسترده تصاویردندان‌پزشکی زمینه پژوهش‌های بسیاری را فراهم آورده است. تایید قابلیت استفاده از مدل‌های هوشمند ارائه شده در محیط بالینی توسط متخصصین صورت می‌پذیرد، در بسیاری از پژوهش‌ها این امر نادیده گرفت شده و جامعه آماری مناسبی برای بررسی و تحلیل عملکرد مدل‌ها توسط متخصصین ارائه نشده است. استفاده از مدل‌های تلفیقی به منظور افزایش دقت و پوشش تنوع تصاویر به منظور استفاده از خصوصیات متفاوت تصاویر نیز می‌تواند در آینده مورد بررسی قرار گیرد. خلأ روش‌های تفسیر بالینی و ارائه برنامه تخصصی درمان با استفاده از تفاسیر متخصصین با تحلیل زبان‌های طبیعی در آینده بیشتر احساس شده و ایجاد مجموعه داده‌های مورد نیاز برای این مدل‌ها نیز از مسیرهای آتی پژوهش‌های تفسیر تصاویر دندان‌پزشکی است. ارائه مجموعه داده‌های معیار، روش‌های مستقل از برچسب‌گذاری داده و مجموعه داده‌های متنوع تشخیصی را نیز می‌توان به عنوان ایده‌های پژوهش‌های آتی بیان نمود. بهینه‌سازی مدل‌های یادگیری با داده‌های محدود، توسعه چارچوب‌های تبیین‌پذیر برای ارتقاء شفافیت مدل‌ها، و ارتقاء همگرایی میان تخصص بالینی و فناوری‌های یادگیری ماشین نیز اهمیت ویژه‌ای دارد. تمرکز بر این اولویت‌های پژوهشی می‌تواند موجب ارتقاء اثربخشی سامانه‌های هوشمند در کاربردهای بالینی دندان‌پزشکی گردد. طراحی سیستم‌های تشخیص زمان پیشگیری نیز یکی از خلأهای موجود در پژوهش‌های حاظر است.

جدول (۳) : مقایسه مدل، ویژگی، نوع تصویر و معیارهای ارزیابی پژوهش‌های حیطه دسته‌بندی و بخش‌بندی بیماری دندان

پژوهش	مدل	ویژگی انحصاری	نوع تصویر	دقت (%)	صحت (%)	پوشش (%)
سرنام و همکاران [۵۸]	شبکه عصبی پیشخور	استخراج ویژگی با GLCM	۱۲۰ پانورکس	۹۹/۱۶		
گراک و همکاران [۵۹]	C4.5	استخراج ویژگی به روش سنتی	۶ پانورکس	۹۶/۸۶	۹۷	۱۰۰
دویتو وهمکاران [۶۰]	پرسپترون	استخراج ویژگی به روش دستی	۱۶۰ رادیوگرافی	۸۸/۴		
بیو وهمکاران [۶۱]	Resnet18، Resnet50 Resnet101، Googlenet،Alexnet و Xception	استخراج ویژگی با استفاده از شبکه عصبی، مقایسه دسته‌بندهای متفاوت	۵۳۳ نمونه دندان پانورکس	۹۱/۷	۹۰/۴۳	۹۲/۶۷
لی و همکارن [۶۲]	CNN	بررسی بیماری دندان‌های خاص	۳۰۰۰ پری‌آپیکال	۸۲	۸۱	۸۳
مائو و همکاران [۶۳]	VGG-19، GoogleNet، AlexNet و ResNet50	مقایسه چهار رویکرد یادگیری عمیق در تشخیص بیماری	۲۷۸ بایت‌وینگ	۹۰,۳ تشخیص پوسیدگی		
مران و همکارن [۶۴]	ResNet	دسته‌بندی براساس شدت ضایعه	۱۱۲ بایت‌وینگ	۷۳,۳		
اسماعیلی فرد و همکاران [۶۵]	CNN	افزایش داده با برش‌های متفاوت	CBCT ۷۸۵	۹۵,۳ (تشخیص پوسیدگی)		۹۲,۱ (تشخیص پوسیدگی)
چن و همکاران [۶۶]	R-CNN سریع‌تر	تلفیق تکنیک‌های مختلف و تعیین سطح بیماری	۲۹۰۰ رادیوگرافی پری‌آپیکال		۶۱,۹۳ (تشخیص پوسیدگی)	۵۴,۳۹ (تشخیص پوسیدگی)
لین و همکاران [۶۷]	Cifar-10Net	بخش‌بندی و لبه‌یابی همزمان با تشخیص پوسیدگی	۸۰۰ پانورکس	۸۲,۱ (تشخیص محل)		
زو وهمکاران [۶۸]	DCD-Net و DPD-Net	تشخیص بیماری دندان کودکان	۸۴۹ پانورکس			
لی و همکاران [۶۹]	FCN-+YOLOX 8s	استفاده از مدل تقسیم‌بندی معنایی در کنار آشکارساز	۵۵۶۹ رادیوگرافی پری‌آپیکال	۸۲,۰۵ (تشخیص پوسیدگی)	۸۳,۵۴ (تشخیص پوسیدگی)	۸۵,۰۸ (تشخیص پوسیدگی)
زانینی و همکاران [۷۰]	ResNet-18 + SimCLR	استفاده از روش‌های یادگیری خود نظارتی	CBCT ۳۴۷		۹۰,۴۴	۸۶,۶۷
کانیش و همکاران [۱۰]	CNN و MobileNetV2	استفاده از تصاویر غیرپزشکی	۲۴۱۷ تصویر عادی	۷۹/۵ الی ۹۰/۶	-	-
زیانگ و همکاران [۱۱]	YOLOX	توانایی تشخیص سیلانت و دسته‌بندی آن در تصاویر عادی	۱۰۲۰ تصویر عادی		۸۱,۷ (تشخیص پوسیدگی)	۸۰,۷ (تشخیص پوسیدگی)
رشید و همکاران [۷۱]	InceptionResNetV2	دسته‌بندی همزمان بیماری دهان و دندان	۵۱۷ تصویر عادی	۹۹,۵۱	۱۰۰-۹۸	۱۰۰-۹۸
بو وهمکاران [۷۲]	SVM	استخراج ویژگی به روش سنتی	۴۰ پانورکس	۷۲/۵		
سندوال و همکاران [۷۳]	SVM	استخراج نشان‌های فک و صورت به عنوان ویژگی با تکیه بر آناتومی	۲۲۹ سفالوگرام	۶۵/۲۲	۶۲/۵ الی ۸۲/۳۵	۵۸/۸۲ الی ۸۷/۵
بانو وهمکاران [۷۴]	k-میانگین	استفاده از GLCM به عنوان روش سنتی پردازش تصویر در کنار دسته‌بند خطی	۴۵ رادیوگرافی پری‌آپیکال	۸۲/۵	-	-
گیتا و همکاران [۷۵]	SVM	استفاده از GLDM به عنوان روش سنتی پردازش تصویر	۶۴ رادیوگرافی پری‌آپیکال	۹۶/۸۸	۹۶/۰۸	۱۰۰
لی و همکاران [۷۶]	ResNet-18	توانایی تشخیص همزمان آبسه پری‌آپیکال و پوسیدگی دندان	۴۱۲۹ رادیوگرافی		۸۲,۹۶	۸۲,۷۵

انگوک و همکاران [۷۷]	R-CNN سریع‌تر	استفاده از تکنیک‌های افزایش داده	۱۱۳۰ رادیوگرافی پری‌آپیکال	۹۵,۶		۸۹,۵
لی و همکاران [۷۸]	CNN	برش عمودی دندان و افزایش داده برای آموزش بهتر مدل	۴۷۶ دندان رادیوگرافی پری‌آپیکال	۹۲,۵	-	-
لی و همکاران [۷۹]	U-Net	تشخیص اندازه پوسیدگی و ساختار دندان	۳۵۴ بایت‌وینگ	-	۶۳/۲۹	۶۵/۰۲
کانتو همکاران [۸۰]	U-Net	تفکیک پوسیدگی دیستال و مزیال	۳۲۹۳ بایت‌وینگ	۸۰		۷۵
بایراکدار و همکاران [۸۱]	U-Net و VGG-16	تشخیص همزمان پوسیدگی و محل آن	۶۲۱ پانورکس		۸۱ (دسته‌بندی)	۸۴ (دسته‌بندی)
لیان و همکاران [۸۲]	nnU-Net	تصمیم‌گیری براساس عمق پوسیدگی	۱۱۶۰ پانورکس	۹۸,۶		۸۲,۱
رهرر و همکاران [۸۳]	U-Net	بخش‌بندی ریشه	۱۷۸۱ پانورکس			
ویمولا و همکاران [۸۴]	VGG-16 و VGG-19	پیش‌پردازش تصاویر با توجه به طیف فرکانس	۲۵۱ رادیوگرافی پری‌آپیکال	۹۵,۷	۹۵,۲	۹۴,۳
سوکیگاوا و همکاران [۸۵]	VGG-16 و VGG-19	تشخیص برند ایمپلنت	۸۸۵۹ پانورکس	۹۳,۵	۹۲,۸	۹۰,۷
کرتلوس و همکاران [۸۶]	۲۵ مدل متفاوت	تشخیص برند ایمپلنت با استفاده از ۲۵ مدل متفاوت	۱۲۵۸ پانورکس	۹۵,۷۴ (ConvNeXt)	۹۶,۰۱ (ConvNeXt)	۹۴,۷۲ (ConvNeXt)
لی و همکاران [۸۷]	GoogLeNet Inception-v3	استفاده همزمان از دو نوع تصویر متفاوت	۵۳۹۰ پانورکس ۵۳۸۰ رادیوگرافی پری‌آپیکال			۹۳,۶ الی ۹۷,۱
آرجی و همکاران [۸۸]	YOLOV7 و EfficientNet	استفاده از دو مدل مجزا برای تشخیص و دسته‌بندی	۱۵۷۴ پانورکس		۹۷,۹ YOLOV7	۱۰۰ YOLOV7
سوکیگاوا و همکاران [۸۹]	۵ مدل ResNet	مقایسه معماری‌های متفاوت در حالت تک و چند وظیفه‌ای	۷۰۷۹ پانورکس	۹۹,۷۲ ResNet-152	۹۹,۷۲ ResNet-152	۹۹,۶۳ ResNet-152
لی و همکاران [۹۰]	ResNet-50	بررسی تاثیر تخریب تصویر در دقت پاسخ مدل	۱۵۶۹۶۵ پانورکس و پری‌آپیکال	۹۵,۰۵	۹۵,۹۱	۹۲,۴۹
کیم و همکاران [۹۱]	YOLOV3	استفاده از مدل از پیش آموزش دیده	۲۶۳ پانورکس	۹۶,۷		۹۴,۴

مراجع

[1] *Stookey, G.K.; Jackson, R.D.; Zandona, A.G.; Analoui, M. Dental Caries Diagnosis. Dent. Clin. N. Am. 43, 665–677, 1999.*

[2] *Shafi, Imran, et al. "A comprehensive review of recent advances in artificial intelligence for dentistry e-health." Diagnostics 13.13, p 2196, 2023.*

[3] *Carrillo-Perez, F., Pecho, O.E., Morales, J.C., Paravina, R.D., Della Bona, A., Ghinea, R., Pulgar, R., Pérez, M.D.M. and Herrera, L.J., "Applications of artificial intelligence in dentistry: A comprehensive review." Journal of Esthetic and Restorative Dentistry, 34(1), pp.259-280, 2022.*

[4] *Ossowska, A.; Kusiak, A.; Swietlik, D. "Artificial Intelligence in Dentistry—Narrative Review." Int. J. Environ. Res. Public Health, 19, 3449, 2022.*

[5] *Kılıc, Münevver Coruh, et al. "Artificial intelligence system for automatic deciduous tooth detection and numbering in panoramic radiographs." Dentomaxillofacial Radiology 50.6, p 20200172, 2021.*

[6] *Rahman, Md Mijanur, et al. "A comprehensive study of artificial intelligence and machine learning approaches in confronting the coronavirus (COVID-19) pandemic." International Journal of Health Services 51.4, pp 446-461, 2021.*

[7] *Bounds, A. D., and J. M. Girkin. "Early stage dental caries detection using near infrared spatial frequency domain imaging", Sci. Rep. 11 p 2433, 2021.*

[8] *Krois, Joachim, et al. "Deep learning for the radiographic detection of periodontal bone loss." Scientific reports 9.1, p 8495, 2019.*

[9] *Tangel, Martin L., et al. "Dental classification for periapical radiograph based on multiple fuzzy*

conference on informatics and computing (ICIC). IEEE, 2017.

[22] Fang, Xinle, et al. "Automatic detection of the third molar and mandibular canal on panoramic radiographs based on deep learning." Journal of Stomatology, Oral and Maxillofacial Surgery, p 101946, 2024.

[23] Latke, Vaishali, and Vaibhav Narawade. "Detection of dental periapical lesions using retinex based image enhancement and lightweight deep learning model." Image and Vision Computing 146, p 105016, 2024.

[24] Khan, Rizwan, et al. "Dental image enhancement network for early diagnosis of oral dental disease." Scientific Reports 13.1, p 5312, 2023.

[25] Lin, Phen-Lan, Yan-Hao Lai, and Po-Whei Huang. "An effective classification and numbering system for dental bitewing radiographs using teeth region and contour information." Pattern Recognition 43, no. 4, 2010.

[26] Mahoor, Mohammad H., and Mohamed Abdel-Mottaleb. "Classification and numbering of teeth in dental bitewing images." Pattern Recognition 38, no. 4, 2005.

[27] Aeini, Faraein, and Fariborz Mahmoudi. "Classification and numbering of posterior teeth in bitewing dental images." In 2010 3rd international conference on advanced computer theory and engineering (ICACTE), vol. 6, pp. V6-66. IEEE, 2010.

[28] Tangel, Martin L., et al. "Dental classification for periapical radiograph based on multiple fuzzy attribute." 2013 Joint IFSA World Congress and NAFIPS Annual Meeting (IFSA/NAFIPS). IEEE, 2013.

[29] Miki, Yuma, et al. "Classification of teeth in cone-beam CT using deep convolutional neural network." Computers in biology and medicine 80 , p 24-29, 2017.

[30] Chen, Qingguang, et al. "Hierarchical CNN-based occlusal surface morphology analysis for classifying posterior tooth type using augmented images from 3D dental surface models." Computer methods and programs in biomedicine 208, p 106295, 2021.

[31] Görürgöz, Cansu, et al. "Performance of a convolutional neural network algorithm for tooth detection and numbering on periapical radiographs." Dentomaxillofacial Radiology 51.3, p 20210246, 2022.

[32] Bilgir, Elif, et al. "An artificial ıntelligence approach to automatic tooth detection and numbering in panoramic radiographs." BMC medical imaging 21, p 1-9, 2021.

[33] Yasa, Yasin, et al. "An artificial intelligence proposal to automatic teeth detection and numbering in dental bite-wing radiographs." Acta Odontologica Scandinavica 79.4, p 275-281, 2021.

[34] Chen, Hu, et al. "A deep learning approach to automatic teeth detection and numbering based on object detection attribute." 2013 Joint IFSA World Congress and NAFIPS Annual Meeting (IFSA/NAFIPS). IEEE, 2013.

[10] Kühnisch J, Meyer O, Hesenius M, Hickel R, Gruhn V. Caries Detection on Intraoral Images Using Artificial Intelligence. Journal of Dental Research.101(2), pp 158-165, 2022.

[11] Chang, Hyuk-Joon, et al. "Deep learning hybrid method to automatically diagnose periodontal bone loss and stage periodontitis." Scientific reports 10.1, p 7531, 2020.

[12] Lin, Phen-Lan, Yan-Hao Lai, and Po-Whei Huang. "An effective classification and numbering system for dental bitewing radiographs using teeth region and contour information." Pattern recognition 43.4, p 1380-1392,2010.

[13] Román, Julio César Mello, et al. "Panoramic dental radiography image enhancement using multiscale mathematical morphology." Sensors 21.9, p 3110,2021.

[14] Widodo, Haris B., et al. "Calculating contrast stretching variables in order to improve dental radiology image quality." IOP Conference Series: Materials Science and Engineering. Vol. 105. No. 1. IOP Publishing, 2016.

[15] Rahmi-Fajrin H, Puspita S, Riyadi S, Sofiani E. Dental radiography image enhancement for treatment evaluation through digital image processing. J Clin Exp Dent,1, p 10(7),2018.

[16] Radhiyah, Aisyatur, Tri Harsono, and Riyanto Sigit. "Comparison study of Gaussian and histogram equalization filter on dental radiograph segmentation for labelling dental radiograph." 2016 International Conference on Knowledge Creation and Intelligent Computing (KCIC). IEEE, 2016.

[17] Geetha, V., and K. S. Aprameya. "Textural analysis based classification of digital X-ray images for dental caries diagnosis." Int J Eng Manuf (IJEM) 9.3, p 44-45,2019.

[18] Veena Divya K., A. Jatti, R. Joshi and Deepu Krishna S., "Characterization of dental pathologies using digital panoramic X-ray images based on texture analysis," 2017 39th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC), Jeju, Korea (South), pp. 592-595, 2017.

[19] R. Indraswari, A. Z. Arifin, D. A. Navastara and N. Jawas, "Teeth segmentation on dental panoramic radiographs using decimation-free directional filter bank thresholding and multistage adaptive thresholding," 2015 International Conference on Information & Communication Technology and Systems (ICTS), Surabaya, Indonesia, pp. 49-54,2015.

[20] Yousefi, Bardia, et al. "Visibility enhancement of digital dental X-ray for RCT application using Bayesian classifier and two times wavelet image fusion." Journal of American Science 8.1, p 7-13,2012.

[21] Setianingrum, Anif Hanifa, Amanda Satya Rini, and Nashrul Hakiem. "Image segmentation using the Otsu method in Dental X-rays." 2017 second international

[47] Shah, Samir, Ayman Abaza, Arun Ross, and Hany Ammar. "Automatic tooth segmentation using active contour without edges." In 2006 biometrics symposium: special session on research at the biometric consortium conference, pp. 1-6. IEEE, 2006.

[48] Said, Eyad Haj, Diaa Eldin M. Nassar, Gamal Fahmy, and Hany H. Ammar. "Teeth segmentation in digitized dental X-ray films using mathematical morphology." IEEE transactions on information forensics and security 1, no. 2, 2006.

[49] Kondo, Toshiaki, Sim Heng Ong, and Kelvin WC Foong. "Tooth segmentation of dental study models using range images." IEEE Transactions on medical imaging 23, no. 3, 2004.

[50] Ali, Mumtaz, Mohsin Khan, and Nguyen Thanh Tung. "Segmentation of dental X-ray images in medical imaging using neutrosophic orthogonal matrices." Expert Systems with Applications 91, p 434-441, 2018.

[51] Brahmi, Walid, and Imen Jdey. "Automatic tooth instance segmentation and identification from panoramic X-Ray images using deep CNN." Multimedia Tools and Applications 83.18, p 55565-55585,2024.

[52] Chun, So-Young, et al. "Automatic classification of 3D positional relationship between mandibular third molar and inferior alveolar canal using a distance-aware network." BMC Oral Health 23.1, p 794, 2023.

[53] Nishitani, Y., Nakayama, R., Hayashi, D. et al. Segmentation of teeth in panoramic dental X-ray images using U-Net with a loss function weighted on the tooth edge. Radiol Phys Technol 14, p 64–69, 2021.

[54] da Silva Rocha, É.; Endo, P.T. A Comparative Study of Deep Learning Models for Dental Segmentation in Panoramic Radiograph. Appl. Sci., p12, 3103, 2022.

[55] Z. Zheng, H. Yan, F. C. Setzer, K. J. Shi, M. Mupparapu and J. Li, "Anatomically Constrained Deep Learning for Automating Dental CBCT Segmentation and Lesion Detection," in IEEE Transactions on Automation Science and Engineering, vol. 18, no. 2, pp. 603-614, 2021.

[56] Bayrakdar, I.S., Orhan, K., Akarsu, S. et al. Deep-learning approach for caries detection and segmentation on dental bitewing radiographs. Oral Radiol 38, p 468–479, 2022.

[57] Kadi, Hocine, Théo Sourget, Marzena Kawczynski, Sara Bendjama, Bruno Grollemund, and Agnés Bloch-Zupan. "Segmentation, and Numbering in Oral Rare Diseases: Focus on Data Augmentation and Inpainting Techniques." In 2023 International Conference on Computational Science and Computational Intelligence (CSCI), pp. 1358-1363. IEEE, 2023.

[58] Sornam, M., and M. Prabhakaran. "A new linear adaptive swarm intelligence approach using back propagation neural network for dental caries classification." 2017 IEEE International Conference on Power, Control, in dental periapical films." Scientific reports 9.1 (2019): 3840.

[35] Tuzoff, Dmitry V., et al. "Tooth detection and numbering in panoramic radiographs using convolutional neural networks." Dentomaxillofacial Radiology 48.4, p 20180051, 2019.

[36] Mima, Yuichi, et al. "Tooth detection for each tooth type by application of faster R-CNNs to divided analysis areas of dental panoramic X-ray images." Radiological Physics and Technology 15.2, p 170-176,2023.

[37] Kim, Changgyun, et al. "Automatic tooth detection and numbering using a combination of a CNN and heuristic algorithm." Applied Sciences 10.16, p 5624, 2020.

[38] Bilgir, Elif, et al. "An artificial ıntelligence approach to automatic tooth detection and numbering in panoramic radiographs." BMC medical imaging 21, p 1-9, 2021.

[39] Özçelik, Salih Taha Alperen, Hüseyin Üzen, Abdulkadir Sengur, Muammer Türkoğlu, Adalet Çelebi, and Nebras M. Sobahi. "Optimized Multi-Scale Detection and Numbering of Teeth in Panoramic Radiographs Using DentifyNet." IEEE Access, 2025.

[40] Morishita, Takumi, et al. "Tooth recognition of 32 tooth types by branched single shot multibox detector and integration processing in panoramic radiographs." Journal of Medical Imaging 9.3, p 034503-034503, 2022.

[41] Hiraiwa, Teruhiko, et al. "A deep-learning artificial intelligence system for assessment of root morphology of the mandibular first molar on panoramic radiography." Dentomaxillofacial Radiology 48.3, p 20180218, 2019.

[42] Chung, Minyoung, et al. "Individual tooth detection and identification from dental panoramic x-ray images via point-wise localization and distance regularization." Artificial Intelligence in Medicine 111, p 101996, 2021.

[43] Peker, Ramazan Berkay, and Celal Oguz Kurtoglu. "Evaluation of the Performance of a YOLOv10-Based Deep Learning Model for Tooth Detection and Numbering on Panoramic Radiographs of Patients in the Mixed Dentition Period." Diagnostics 15, no. 4, 2025.

[44] Jang, Woo Sung, et al. "Accurate detection for dental implant and peri-implant tissue by transfer learning of faster R-CNN: a diagnostic accuracy study." BMC oral health 22.1, p 591, 2022.

[45] Ali, Md Anas, Daisuke Fujita, and Syoji Kobashi. "Teeth and prostheses detection in dental panoramic X-rays using CNN-based object detector and a priori knowledge-based algorithm." Scientific Reports 13.1, p 16542,2023.

[46] Choi, Hye-Ran, et al. "Automatic detection of teeth and dental treatment patterns on dental panoramic radiographs using deep neural networks." Forensic Sciences Research 7.3, p 456-466, 2022.

Nunes. "Enhancing dental caries classification in CBCT images by using image processing and self-supervised learning." Computers in Biology and Medicine 183, p 109221, 2024.

[71] Rashid, Javed, et al. "Mouth and oral disease classification using InceptionResNetV2 method." Multimedia Tools and Applications 83.11, p 33903-33921, 2024.

[72] Bo, Chunjuan, et al. "Osteoporosis prescreening using dental panoramic radiographs feature analysis." 2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017). IEEE, 2017.

[73] Niño-Sandoval, Tania Camila, et al. "An automatic method for skeletal patterns classification using craniomaxillary variables on a Colombian population." Forensic Science International 261, p 159-e1, 2016.

[74] Banu, A. Farzana Shahar, et al. "Texture based classification of dental cysts." 2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT). IEEE, 2014.

[75] Geetha, V., and K. S. Aprameya. "Textural analysis based classification of digital X-ray images for dental caries diagnosis." Int J Eng Manuf (IJEM) 9.3, p 44-45, 2019.

[76] Li, Shihao, et al. "Artificial intelligence for caries and periapical periodontitis detection." Journal of dentistry 122, p 104107, 2022.

[77] Li, Chun-Wei, et al. "Detection of dental apical lesions using CNNs on periapical radiograph." Sensors 21.21, p 7049, 2021.

[78] Ngoc, V., et al. "Periapical lesion diagnosis support system based on X-ray images using machine learning technique." World 12.3, p 190, 2021.

[79] Lee, Shinae, et al. "Deep learning for early dental caries detection in bitewing radiographs." Scientific reports 11.1, p 16807, 2021.

[80] Cantu, Anselmo Garcia, et al. "Detecting caries lesions of different radiographic extension on bitewings using deep learning." Journal of dentistry 100, 103425, 2020.

[81] Xiong, Y., Zhang, H., Zhou, S. et al. Simultaneous detection of dental caries and fissure sealant in intraoral photos by deep learning: a pilot study. BMC Oral Health 24, p 553, 2024.

[82] Lian, L.; Zhu, T.; Zhu, F.; Zhu, H. Deep Learning for Caries Detection and Classification. Diagnostics, 11, p 1672, 2021.

[83] Rohrer, C.; Krois, J.; Patel, J.; Meyer-Lueckel, H.; Rodrigues, J.A.; Schwendicke, F. Segmentation of Dental Restorations on Panoramic Radiographs Using Deep Learning. Diagnostics, 12, p 1316, 2022.

[84] Vemula, S. R., M. Vemula, and R. Vatambeti. "Advanced dental implant system classification with pre-trained CNN models and multi-branch spectral channel Signals and Instrumentation Engineering (ICPCSI). IEEE, 2017.

[59] Olsen, Grace F., et al. "An image-processing enabled dental caries detection system." 2009 ICME International Conference on Complex Medical Engineering. IEEE, 2009.

[60] Devito, Karina Lopes, Flávio de Souza Barbosa, and Waldir Neme Felippe Filho. "An artificial multilayer perceptron neural network for diagnosis of proximal dental caries." Oral Surgery, Oral Medicine, Oral Pathology, Oral Radiology, and Endodontology 106.6, p 879-884, 2008.

[61] Bui, T.H.; Hamamoto, K.; Paing, M.P. Deep Fusion Feature Extraction for Caries Detection on Dental Panoramic Radiographs. Appl. Sci., 11, p 2005, 2021.

[62] Lee, Jae-Hong, et al. "Detection and diagnosis of dental caries using a deep learning-based convolutional neural network algorithm." Journal of dentistry 77, p 106-111, 2018.

[63] Mao, Yi-Cheng, et al. "Caries and restoration detection using bitewing film based on transfer learning with CNNs." Sensors 21.13, p 4613, 2021.

[64] Moran, M.; Faria, M.; Giraldi, G.; Bastos, L.; Oliveira, L.; Conci, A. Classification of Approximal Caries in Bitewing Radiographs Using Convolutional Neural Networks. Sensors, 21, 5192, 2021.

[65] Esmaeilyfard, Rasool, Haniyeh Bonyadifard, and Maryam Paknahad. "Dental Caries Detection and Classification in CBCT Images Using Deep Learning." international dental journal 74.2, p 328-334, 2024.

[66] Chen, Hu, et al. "Dental disease detection on periapical radiographs based on deep convolutional neural networks." International Journal of Computer Assisted Radiology and Surgery 16, p 649-661, 2021.

[67] Kim, Hak-Sun, et al. "Transfer learning in a deep convolutional neural network for implant fixture classification: A pilot study." Imaging Science in Dentistry 52.2, p 219, 2022.

[68] Zhu, Hongzhou, Yuhao Qiu, Renjie Hu, Ang Li, Shengji Zhu, and Lei Wang. "Automatic Numbering and Pathological Recognition of Pediatric Teeth Using CNN and Attention Mechanisms." In ICASSP 2025-2025 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), pp. 1-5. IEEE, 2025.

[69] Liu, Jie, Hongxiao Zhang, Junyan Chen, Ruiqing Meng, Chang Gao, Lihong Han, Yuting Song, Yang Tian, and Yan Wang. "Automated detection and segmentation of dental caries using a novel cascaded learning approach." Biomedical Signal Processing and Control 102 ,2025.

[70] Zanini, Luiz Guilherme Kasputis, Izabel Regina Fischer Rubira-Bullen, and Fátima de Lourdes dos Santos

attention networks." Acadlore Trans. Mach. Learn 3.2, p 94-105, 2024.

[85] *Sukegawa, Shintaro, et al. "Deep neural networks for dental implant system classification." Biomolecules 10.7, p 984, 2020.*

[86] *Kurtulus, Ikbal Leblebicioglu, et al. "A robust deep learning model for the classification of dental implant brands." Journal of Stomatology, Oral and Maxillofacial Surgery, 101818, 2024.*

[87] *Lee, Jae-Hong, and Seong-Nyum Jeong. "Efficacy of deep convolutional neural network algorithm for the identification and classification of dental implant systems, using panoramic and periapical radiographs: A pilot study." Medicine 99.26, e20787, 2020.*

[88] *Ariji, Yoshiko, et al. "Two-step deep learning models for detection and identification of the manufacturers and types of dental implants on panoramic radiographs." Odontology, p 1-11, 2024.*

[89] *Sukegawa, Shintaro, et al. "Multi-task deep learning model for classification of dental implant brand and treatment stage using dental panoramic radiograph images." Biomolecules 11.6, p 815, 2021.*

[90] *Lee, Jae-Hong, Young-Taek Kim, and Jong-Bin Lee. "Identification of dental implant systems from low-quality and distorted dental radiographs using AI trained on a large multi-center dataset." Scientific Reports 14.1, 12606, 2024.*

[91] *Kim, Hak-Sun, et al. "Transfer learning in a deep convolutional neural network for implant fixture classification: A pilot study." Imaging Science in Dentistry 52.2, 219, 2022.*

مهدیه دهقانی مدرک کارشناسی و کارشناسی ارشد خود را در سال‌های ۱۳۹۶ و ۱۳۹۸ به عنوان شاگرد اول دوره به ترتیب از دانشگاه شهید باهنر کرمان و دانشگاه تهران اخذ نمود. وی در سال ۱۳۹۸ موفق به دریافت بورس تحصیلی بنیاد ملی نخبگان شد و هم اکنون نامزد دریافت درجه دکتری در رشته مهندسی کامپیوتر گرایش نرم‌افزار از دانشگاه تهران می‌باشد. زمینه پژوهشی مورد علاقه ایشان بینایی ماشین و یادگیری عمیق می‌باشد.

رضا آقائی زاده ظروفی مدرک دکتری خود را در زمینه آنالیز تصاویر پزشکی از دانشگاه ازاکای ژاپن در سال ۱۳۷۵ دریافت نمود. وی همچنین از سال ۱۳۷۵ لغایت ۱۳۷۸ بعنوان محقق دکتری و فوق دکتری در وزارت صنایع ژاپن، مرکز تحقیقات قلب و عروق ژاپن و دانشکده پزشکی از دانشگاه ازاکای ژاپن همکاری نمود. وی به عنوان استادیار در اسفند سال ۱۳۷۸ به دانشگاه تهران پیوست و در حال حاضر استاد دانشکده مهندسی برق وکامپیوتر این دانشگاه می‌باشد. او همچنین از سال ۱۳۷۸ تاکنون به عنوان محقق و استاد مدعو با دانشگاه های ژاپن همکاری علمی مستمر داشته است. زمینه کاری تخصصی ایشان پردازش، مهندسی و مدیریت جامع تصاویر پزشکی می‌باشد.