

## فهرست مطالب

پیشگفتار مترجمین.....	۷
پیشگفتار.....	۹
<b>بخش اول: ماشین لرنینگ در تصویربرداری دندانپزشکی.....</b>	<b>۱۳</b>
فصل اول: یادگیری ماشین برای CBCT تقسیم‌بندی ساختارهای استخوانی فک و صورت.....	۱۵
فصل دوم: یادگیری ماشینی برای دیجیتالی‌سازی لندمارک‌های فک و صورت در تصویربرداری سه‌بعدی.....	۲۷
فصل سوم: تقسیم‌بندی استخوان‌ها در MRI مغز با استفاده از یادگیری مولد رقابتی (GAL).....	۳۹
فصل چهارم: یادگیری فرهنگ لغت پراکنده (SDL) برای تخمین سه‌بعدی اسکلت صورت بر اساس تصاویر دوبعدی.....	۵۳
فصل پنجم: یادگیری ماشینی برای تشخیص چهره در ارتودنسی.....	۶۷
<b>بخش دوم: یادگیری ماشینی برای تشخیص و درمان ناهنجاری‌های دهان.....</b>	<b>۷۹</b>
فصل ششم: یادگیری ماشینی/عمیق برای تشخیص‌های ارتودنسی و برنامه‌ریزی درمان.....	۸۱
فصل هفتم: یادگیری ماشینی در ارتودنسی: رویکردی جدید برای تصمیم‌گیری جهت خارج‌سازی دندان.....	۹۱
فصل هشتم: یادگیری (عمیق) ماشینی برای شناسایی تغییرات حجمه و صورت.....	۱۰۳
فصل نهم: مدل مرجع ویژه بیمار برای برنامه‌ریزی جراحی ارتوگناتیک.....	۱۱۷
<b>بخش سوم: یادگیری ماشینی و طراحی‌های دندانپزشکی.....</b>	<b>۱۲۷</b>
فصل دهم: یادگیری (عمیق) ماشینی برای فناوری‌های CAD/CAM ارتودنسی.....	۱۲۹
فصل یازدهم: ارزیابی نتایج با استفاده از یادگیری ماشینی.....	۱۴۳
<b>بخش چهارم: یادگیری ماشینی در حمایت از تحقیقات دندانپزشکی.....</b>	<b>۱۵۷</b>
فصل دوازدهم: یادگیری ماشینی در تحقیقات سنتز شواهد.....	۱۵۹
فصل سیزدهم: یادگیری ماشینی و یادگیری عمیق در ژنتیک و ژنومیک.....	۱۷۵
فصل چهاردهم: یادگیری ماشینی (عمیق) و مدلسازی اجزاء محدود.....	۱۹۵
واژه‌نامه.....	۲۰۱
واژه‌یاب.....	۲۰۳

## پیشگفتار مترجمین

در دهه اخیر هوش مصنوعی حضور و اهمیت خود را در طیف گسترده‌ای از زمینه‌های پزشکی از جمله دندانپزشکی افزایش داده و روزبه‌روز بر نفوذ هوش مصنوعی در زندگی روزمره افزوده می‌شود، یادگیری ماشینی، زیرمجموعه از هوش مصنوعی است که به طور خودکار یک ماشین یا سیستم را قادر می‌سازد تا بر اثر تجربه، مهارتی را آموخته و عملکرد خود را بهبود بخشد، یادگیری ماشینی به جای برنامه‌نویسی به شیوه معمول، از الگوریتم‌ها برای تجزیه و تحلیل مقادیر زیادی از داده‌ها، خودآموزی و سپس تصمیم‌گیری آگاهانه استفاده می‌کند. کتابی که همینک پیش روی شماست به بررسی کاربرد تکنیک‌های یادگیری ماشینی در زمینه‌های مختلف دندانپزشکی می‌پردازد. این کتاب از مبانی یادگیری ماشینی تا مباحث پیشرفته‌تری مانند یادگیری عمیق و بینش ماشینی را پوشش می‌دهد؛ امیدوارم این اثر مورد توجه همکاران و دانشجویان گرامی قرار گرفته و مرجعی مناسب در آموزش هوش مصنوعی در دندانپزشکی باشد، به طور قطع این ترجمه با وجود ویراستاری تھی از اشکال نخواهد بود و تقاضا دارم انتقادهای، پیشنهادهای و راهنمایی‌های خود را در جهت ارتقای سطح کیفی اثر در چاپ‌هایی بعد از اینجانب دریغ نفرمایید.

دکتر علیرضا ابراهیم پور

تابستان ۱۴۰۲

### ماشین لرنینگ (یادگیری ماشین) در دندانپزشکی

یادگیری ماشین یک شاخه از شاخه‌های هوش مصنوعی است که همزمان به رشد خود در جامعه پژوهشی و همچنین در میان عموم مردم ادامه می‌دهد. در دندانپزشکی معاصر، فناوری‌های دیجیتال مانند مقطع‌نگاری رایانه‌ای با اشعه‌ی مخروطی (CBCT)، اسکن سه‌بعدی داخل دهانی، چاپ سه‌بعدی و برنامه‌ریزی طرح درمان اختصاصی نقش بزرگی در تحقیقات و اجرا ایفا کرده‌اند. این فناوری‌ها نویدبخش درمان قابل پیش‌بینی‌تر، عینی‌تر و مؤثرتر و در عین حال با عوارض کمتر می‌باشند. جهت پوشاندن جامه عمل به این تغییرات متخصصان داده و متخصصان دندانپزشکی از حوزه‌های مختلف مرتبط نیازمند همکاری با یکدیگر هستند تا تجزیه و تحلیل داده‌های بزرگ که ارزش تفسیری دارند توسعه یافته تا به کارگیری این موارد در مراقبت‌های بهداشت دهان و دندان و علوم زیستی امکانپذیر شود.

در گذشته، اطلاعات تشخیصی از طریق مصاحبه، مدل‌های پلاستر و مشاهدات بالینی جمع‌آوری می‌شد و سپس این اطلاعات توسط کارشناسان برای پیشنهاد یک طرح‌درمان مورد تفسیر قرار می‌گرفت. بسته به تجربه پزشک، گوناگونی و تفاوت‌ها در هر یک از مراحل تشخیص، برنامه‌ریزی و اجرای درمان دارای پیچیدگی، حجم زیاد و همچنین کاملاً به صورت تجربی بود. به این ترتیب، آموزش دندانپزشکی مرسوم تا حد زیادی به آموزش مکرر چشم‌ها، دست‌ها و قضاوت پزشک (تفکر انتقادی) برای به حداقل رساندن تنوع در مراقبت‌های استاندارد وابسته بود. مدت زمان صرف شده در دانشگاه و همچنین آموزش‌های مداوم در طول دوره کاری بسیار طولانی و بیش از اندازه بوده و هیچ تضمینی وجود نداشت که افراد به اعتبار استاندارد یکسانی برسند.

امروزه فناوری‌های جدید می‌توانند جایگزین چشم‌ها و دست‌های انسان شوند و هوش مصنوعی می‌تواند فرآیندهای یادگیری انسان را به ماشین آموزش دهد تا شکاف‌های آموزشی را از بین ببرد. بسیاری از ارائه‌دهندگان مراقبت‌های بهداشتی، فناوری‌های دیجیتال را در جریان‌های کاری‌شان ادغام کرده‌اند، که وابستگی به مهارت‌های دست و شناخت بصری را کاهش می‌دهد. نرم‌افزارهای رایانه‌ای که برای بهبود درک عینی، شناخت و عملکرد بر اساس ادغام این فناوری‌ها به کارگرفته می‌شوند هنوز در ابتدای راه خود قرار دارند. با این وجود، ماشین لرنینگ در دندانپزشکی به معنای توسعه یک درمان دقیق، شخصی‌سازی شده، همراه تشخیص بهبود یافته با برنامه‌ریزی از طریق داده‌های بزرگ، علم روز، تجربه و یادگیری مبتنی بر نتایج است. این موارد شامل کند و کاو در مجموعه داده‌های بزرگ و پیچیده اومیکس همانند مجموعه‌ای از داده‌های ژنتیکی و زیستی از

جمله جایگاه ژن ها و نشانگرهای زیستی برای اختلالات ناحیه جمجمه و صورت می باشد. هدف این کتاب بررسی سیستم های بالینی فعلی و تحقیقات دندانپزشکی شامل ابزارهای یادگیری ماشین و جایگاه آن در میان تخصص های مختلف دندانپزشکی است. نمونه هایی که در این کتاب ذکر شده، نمایانگر فرصت ها و چالش های مسیر به کارگیری رویکرد یادگیری ماشینی در دندانپزشکی معاصر میباشند. ما از کارشناسان دعوت کرده ایم تا در بررسی خود در چهار حوزه زیر مشارکت کنند.

### یادگیری ماشین برای عکس برداری دندانی

دندانپزشکان اغلب برای تشخیص ناهنجاری های ناحیه جمجمه و صورت و شناسایی مشکلات احتمالی به رادیوگرافی رجوع می کنند. با این حال، در تشخیص از روی تصاویر می توان اشتباهاتی را مرتکب شد و دقت این نوع از تشخیص به تجربه دندانپزشک بستگی دارد. با تنها یک تصویر سه بعدی، این فرآیند به یک کار استرس زا تبدیل می شود زیرا بر اساس داده های بزرگ و تجربه کاربر است. با استفاده از ماشین لرنینگ می توان با تقویت تصویر، تشخیصی دقیق تر و عینی تر و درمانی شخصی سازی شده انجام داد.

کامپیوتر از کارهای طاقت فرسا خسته نمی شود و می تواند حجم زیادی از داده ها را دریافت و اطلاعات را جذب کند و اطلاعات را خیلی سریع پردازش کند. ابتدا کامپیوتر مجموعه ای از رادیوگرافی های مختلف با برچسب آناتومی سالم و ناسالم دریافت می کند. سپس، هنگامی که داده های تشخیص متخصصان به رایانه داده می شود، کامپیوتر می تواند الگوهای مرتبط با بیماری خاص یا آناتومی سالم را طبقه بندی کند. بنابراین، با توجه به رادیوگرافی بیمار جدید، دستگاه می تواند به راحتی آن را با الگوهایی که در مجموعه آموزشی تشخیص متخصص یافت شده است، مطابقت دهد. در حال حاضر برنامه های طراحی شده بر اساس یادگیری ماشینی همانند `dentistry.ai` و `denti.ai` در بازار وجود دارند که می توانند ویژگی های تصاویر پانورامیک دوبعدی را شناسایی کنند. در این کتاب، ما عمیق تر به نقش کامپیوتر برای تقسیم بندی تصویر سه بعدی و تشخیص لندمارک با استفاده از یادگیری ماشینی و یادگیری عمیق می پردازیم. فصل های ۱ تا ۵ الگوریتم ها را تشریح می کنند و مثال هایی برای تقویت ساختارهای اسکلتی کرانیوفیشیال، تشخیص سطح صورت، و کاربردها در شبیه سازی جراحی ارتوگناتیک (اصلاح فک) ارائه می کنند.

### یادگیری ماشینی در تشخیص بیماری دهان و بیان طرح درمان

هنگام انجام تشخیص پزشکی، دندانپزشک با شنیدن شکایت اصلی، مطالعه سابقه پزشکی، گفتگو با بیمار و مشاهده تصاویر رادیوگرافی، تشخیص را قطعی می کند. برخی از این اطلاعات می تواند توصیفی باشد و به همین دلیل، دندانپزشک باید بسیار با تجربه و در شرایط عالی باشد تا به هر کلمه و نکات ظریف آن از روایت بیمار توجه دقیق داشته باشد. زیرا این کلمات را برای تشخیص مناسب جمع آوری می کند، دندانپزشکان ممکن است به راحتی بیماری بیمار خود را اشتباه تشخیص دهند. در سال ۲۰۱۱، دندانپزشکان ۴۳ درصد تشخیص اشتباه ضایعات دهانی داشتند (بر اساس مطالعه صورت گرفته توسط کوندوری و همکاران). این عدد به بسیار بالاست و جای پیشرفت را نشان می دهد. در پزشکی، نرم افزارهای تجاری مختلفی برای تفسیر به صورت خودکار در تصاویر آسیب شناسی وجود دارد. این کتاب بر تشخیص بالینی و برنامه ریزی درمان با استفاده از هوش مصنوعی تمرکز دارد.

الگوریتم زبان طبیعی بخشی از یادگیری ماشینی/عمیق است که می تواند از جستجوی کلمات کلیدی و شناسایی فراوانی و الگوهای عبارات توصیفی پشتیبانی کند. فصل های ۶-۹ پیشرفته ترین هوش مصنوعی را برای تشخیص و برنامه ریزی درمان ارتودنسی ارائه می کنند که شامل تشخیص چهره، تجزیه و تحلیل سفالومتری، تجزیه و تحلیل نمودار، تهیه لیست به صورت خودکار از مشکلات و برنامه ریزی درمان، شناسایی ناهنجاری های کرانیوفیشیال و تصمیم گیری برای خارج سازی دندان پیش

از درمان ارتودنسی می‌باشد. هوش مصنوعی می‌تواند در زمان صرفه‌جویی کند و هر فرآیندی را با دقت بهبود یافته در آینده ساده‌سازی کند.

### یادگیری ماشین و طراحی‌های دندان‌ی/ارزیابی نتیجه

استفاده از اسکنر داخل دهانی روز به روز همه‌گیرتر شده و چاپ سه‌بعدی، جریان کاری درمان ارتودنسی را بهبود بخشیده است. تا به امروز، استفاده از مدل دیجیتال سرفیس، گسترش چشمگیری از تشخیص تا برنامه‌ریزی درمان داشته است. برای ذکر مثال در این زمینه می‌توان به الاینرهای ارتودنسی اشاره کرد. بخش‌بندی خودکار دندان از ساختار آرک دندانی هم‌اکنون باعث بهبود طراحی ترمیم‌ها، نصب و تراز کردن دندان‌ها، ایجاد طرح درمان‌های شخصی‌سازی شده، و ارزیابی نتایج با تمرکز بر روی بیمار شده است. فصل ۱۰ فناوری‌های فعلی هوش مصنوعی را برای جداسازی دندان از مدل سطح سه‌بعدی به روز می‌کند. تخصص‌های دندانپزشکی در استفاده از استراتژی‌های تحلیلی هوش مصنوعی برای استفاده از مزایای «داده‌های بزرگ» برای شخصی‌سازی مداخلات درمانی، مانند درمان الاینرها، پیشرو بوده‌اند. فصل ۱۱ مروری بر یادگیری ماشین و نحوه استفاده از آن در ارزیابی نتایج ارائه می‌کند. در این فصل به طور خاص، ما بر پیشرفت‌های اخیر در ژنومیک مجموعه و صورت و نتایج مربوط به تصاویر تمرکز خواهیم کرد.

### یادگیری ماشینی در حمایت از تحقیقات دندانپزشکی

سلامت سیستمیک دهان ارتباط تنگاتنگی با تحقیقات مناسب دندانپزشکی دارد. تحقیقات بالینی به منظور توسعه دستورالعمل‌های مبتنی بر شواهد و تأثیر بالقوه آن‌ها بر سلامت و رفاه بخش بزرگی از جمعیت است. ارزش تفسیری این مطالعات به طور قابل توجهی بر اثربخشی مرور سیستمیک متکی است. فصل ۱۲ مروری بر استفاده از یادگیری ماشین برای systemic review ارائه می‌دهد. نویسندگان همچنین در مورد کاستی‌ها و مشکلات احتمالی استفاده از هوش مصنوعی (AI) در فرآیند بررسی که عمدتاً توسط متخصصان انسانی در گذشته هدایت می‌شد، بحث می‌کنند. ژنومیک انسانی یکی از اولین حوزه‌های تحقیقاتی بود که از داده‌های بزرگ استفاده کرد.

در فصل ۱۳، محققان نحوه استفاده از الگوریتم‌های یادگیری ماشین و یادگیری عمیق را در مطالعات اومیکس دندانی برای تجزیه و تحلیل ارتباط بین SNP و بیماری‌های پیچیده، فراخوانی CNV و SNV و داده‌های متیلانسیون DNA معرفی می‌کنند. در پایان، ما در مورد جهت بالقوه در حال توسعه یادگیری ماشین (عمیق) در بیومکانیک در سلامت دهان بحث می‌کنیم (فصل ۱۴). ما از اسپرینگر و همه مشارکت‌کنندگان برای مقالات جمعی‌شان، از دکتر تای هسین وو و دکتر چونفنگ لیان برای برقراری ارتباط با مشارکت‌کنندگان و خانم دون برای مدیریت دقیق مطالب ارسالی و همچنین از دکتر پستویت، پیرس و چین و خانم ژنگ برای بررسی نسخه‌های خطی تشکر می‌کنیم. ما معتقدیم این کتاب تنها یک شروع بر سری کتاب‌ها با محوریت هوش مصنوعی در دندانپزشکی معاصر می‌باشد.

Columbus, OH  
Shanghai, China  
Chapel Hill, NC

Ching-Chang Ko  
Dinggang Shen  
Li Wang

---

بخش اول

ماشین لرزینگ در تصویربرداری دندانپزشکی

# یادگیری ماشین برای CBCT

## تقسیم بندی ساختارهای استخوانی فک و صورت

### مقدمه

توموگرافی کامپیوتری با پرتو مخروطی (CBCT) به طور معمول در تشخیص و درمان بیماران مبتلا به ناهنجاری‌های فک و صورت (CMF) استفاده می‌شود. این فناوری دوز و هزینه کمتری نسبت به توپوگرافی کامپیوتری چند برشی ماریچپی معمولی (MSCT) دارد [۲۱]. تقسیم‌بندی دقیق CBCT از استخوان‌های CMF (به عنوان مثال، فک بالا و فک پایین) برای ساخت یک مدل اسکلتی سه‌بعدی دقیق برای ارزیابی کمی ناهنجاری‌های مختلف ضروری است [۳۲]. با این حال، تقسیم‌بندی تصاویر CBCT فک و صورت چالش‌برانگیز است، عمدتاً با توجه به این که (الف) تصاویر CBCT معمولاً حاوی عوامل مخدوش‌کننده قابل توجهی هستند، (ب) CBCT به دلیل استفاده از تابش با دوز پایین نسبت سیگنال به نویز پایینی دارد، و (ج) دندان‌های فک بالا و فک پایین در تصاویر CBCT به دلیل نیاز به حداکثر فشردگی دندان (Maximum Intercuspation) برای اهداف تشخیصی به صورت مقطعی همپوشانی دارند. با توجه به این چالش‌ها و همچنین اندازه بزرگ حجمه‌ای CBCT، تفسیر دستی استخوان‌های CMF کار فشرده و وابسته به تجربه است، که اهمیت توسعه روش‌های خودکار برای این منظور را نشان می‌دهد.

روش‌های خودکار مرسوم برای تقسیم‌بندی CBCT شامل روش‌های آستانه‌ای و مورفولوژیکی، روش‌های تکراری و روش‌های مبتنی بر مدل است. روش‌های آستانه‌گذاری [۱۱] معمولاً از آستانه شدت ساده و معیارهای مورفولوژیکی کرانیوفیشیال برای استخراج استخوان‌هایی که به عوامل مخدوش‌کننده تصویر CBCT حساس

هستند، استفاده می‌کنند. روش‌های تکراری نیمه خودکار [۱۵، ۲۵] تقسیم‌بندی خودکار را با مداخله دستی متخصصان برای تفسیر استخوان ترکیب می‌کنند. عملکرد آن‌ها نیز تا حد زیادی تحت تأثیر عوامل مخدوش‌کننده تصویری است، به عنوان مثال، آن‌هایی که توسط ایمپلنت‌های دندان‌ی ایجاد می‌شوند [۲۸]. روش‌های مبتنی بر مدل [۹، ۱۲، ۱۴، ۲۸] معمولاً تقسیم‌بندی‌ها را بر اساس مدل‌های شکل آماری (SSM) یا اطلس انجام می‌دهند. به عنوان مثال، گولمر و همکاران [۹] پیشنهاد دادند تا کمینه کردن یک تابع هدف تحت شرایط محدود کننده‌ای از فرم آماری پیش از تقسیم‌بندی مندیبل صورت گیرد. با در نظر گرفتن این که مورد مذکور فقط برای اجسامی با اشکال نسبتاً ساده (مانند فک پایین)، به جای آن‌هایی که اشکال پیچیده دارند (مانند فک بالا)، کار می‌کند، وانگ و همکاران [۲۸] یک روش کدگذاری پراکنده مبتنی بر پچ (patch-based) برای استخراج قوی فک بالا و فک پایین از بافت‌های نرم پیشنهاد کردند. با این حال، از آنجایی که کدگذاری پراکنده مبتنی بر پچ بر ثبت تغییر شکل پذیر (بین اطلس هدف و چندین اطلس دیگر) و همچنین بهینه‌سازی در هر وکسل (کوچک‌ترین جز تصویر سه‌بعدی) متکی است، روش مبتنی بر مدل ارائه شده در [۲۸] در هر دو مرحله آموزش و استنتاج زمان‌بر است.

در سال‌های اخیر، الگوریتم‌های یادگیری ماشین با موفقیت در کارهای مختلف محاسباتی تصویر پزشکی، مانند بازسازی/تولید [۳۴، ۱۰]، ثبت [۵، ۲۴]، بخش‌بندی [۳۰، ۱۹، ۱۸]، تشخیص [۸] و عیب‌شناسی [۱۶، ۱۷]، به کار گرفته شده است. [۳۳، ۲۶] به عنوان

## ۱.۲ پیش زمینه

### ۱.۲.۱ Random Forest (رندوم فورست یا RF)


به عنوان یک روش یادگیری تحت نظارت (Supervised) با کارایی و مقیاس پذیری قابل قبول، RF می تواند به عنوان میانگینی از چند Decision Tree (درخت تصمیم گیری) در نظر گرفته شود. هر یک از آن Decision Tree ها از دو نوع Node تشکیل شده است، هر یک از این Decision Tree ها از دو نوع Node تشکیل شده است، این دو نوع عبارتند از Split Node ها و Leaf Node ها. همانطور که در شکل ۱،۱ نشان داده شده است، Split Node ها، داده های دریافتی را به سمت Child Node چپ یا راست خود هدایت می کنند. هر یک از Leaf Node ها یک ترمینال از تقسیم های باینری (جفتی) سریالی است که اطلاعات نمونه های آموزشی هدایت شده به آن از دسته های مختلف را ذخیره می کند. همه Decision Tree ها به طور مستقل با داده های آموزشی یک نمونه گیری تصادفی (یعنی نمونه های راه انداز) آموزش داده می شوند و ... می شوند و Split Node های مربوط به هر یک از آن ها از نظر زیرمجموعه ی ویژگی/واصف که به شیوه ای تصادفی نمونه برداری شده اند، با یک تابع تقسیم خاص (Specific Split Function) مرتبط هستند. (ویژگی = Feature) در بخش باقی مانده از این بخش، پیشینه ای در مورد RF، از جمله ساخت یک درخت تصمیم گیری باینری و آموزش RF برای طبقه بندی، معرفی می کنیم.

### ۱.۲.۱.۱ ساخت Binary Decision Tree

به وسیله مجموعه ای از نمونه های آموزشی (مثلاً وکسل های CBCT) و مجموعه ای از فیچرهای قابل استخراج (مانند فیچرهای Haar مانند)، یک درخت انتخاب آموزش داده می شود تا به صورت بازگشتی، نمونه ها را به Leaf Node های مختلف، با به حداکثر رساندن خلوص هر زیرمجموعه (در جریان هر تقسیم باینری) هدایت کند. در مورد طبقه بندی (به عنوان مثال، پیش بینی اینکه آیا یک وکسل CBCT از فک بالا، فک پایین، یا پس زمینه است)، خلوص یک زیرمجموعه بر اساس برچسب های نمونه های آموزشی اختصاص داده شده به آن تعریف می شود. یعنی، تابع تقسیم مربوطه باید با تقسیم یک مجموعه آموزشی به زیرمجموعه هایی با همان برچسب تقویت شود. فرض کنید S مجموعه ای از نمونه های آموزشی باشد که به یک Split Node تبدیل شود و هر نمونه دارای یک برچسب کلاس در مجموعه {C, ..., ۱} است. یک مجموعه تصادفی از فیچرها

مثال، رندوم فورست (Random Forest) به عنوان یک شیوه یادگیری انباشتی (Ensemble) غیرپارامتری عملکردی رقابتی در بسیاری از اعمال تقسیم بندی از خود نشان می دهد. [۷، ۱۳، ۳۰، ۳۱]. ویژگی های تصویربرداری و نمونه های آموزشی با الهام از آن کاربردهای موفق، یک مدل متوالی مبتنی بر رندوم فورست های جدید در [۲۹] پیشنهاد شد که ترکیبی از ویژگی های تصویربرداری آناتومیک با کیفیت بالا (و به تدریج اصلاح شده) با ویژگی های تصویربرداری ظاهری برای ساخت یک سری رندوم فورست های برای تقسیم بندی کارآمد و کاملاً خودکار CBCT فک بالا و فک پایین از بافت نرم به کار گرفته شود. ... به طور خلاصه، متدهای رندوم فورست هدایت شده، شامل یک مرحله آموزشی و یک مرحله آزمایشی می باشند. در مرحله آموزش، هم ویژگی های ظاهری از تصاویر CBCT و هم ویژگی های زمینه ای از probability maps تقسیم بندی اولیه (فک بالا و فک پایین) استخراج می شوند که بر اساس آن رندوم فورست های (RF) متوالی برای انتخاب ویژگی های متمایز ... برای اصلاح Probability Map های تقسیم بندی آموزش داده می شوند. در مرحله آزمایش، با استفاده از همان ورودی های اولیه استخراج شده از هر تصویر آزمایشی، RF های متوالی آموخته شده به طور منظم برای اصلاح Probability Map های فک بالا و فک پایین برای تصویر آزمایشی اعمال می شوند.

در این فصل، این روش رادیویی متوالی هدایت شده قبلی را به تفصیل معرفی خواهیم کرد. بخش باقی مانده از این فصل به شرح زیر سازماندهی شده است. در بخش ۱،۲، ما پیشینه اساسی رندوم فورست ها RF و استخراج ویژگی های تصویربرداری را ارائه می دهیم. در بخش ۱،۳، نحوه عملکرد RF متوالی که قبلاً هدایت شده است را معرفی می کنیم. در بخش ۱،۴، ما برخی از نتایج تجربی را بر روی دیتابیس های از تصاویر CBCT تهیه شده از بیماران مبتلا به ناهنجاری های دندانی - صورتی ارائه می دهیم و در نهایت فصل در بخش ۱،۵ خاتمه می یابد.



شکل ۱،۱. نمودار ساده شده درخت تصمیم مضاعف (باینری) با عمق ۳



و همچنین انتخاب تصادفی فیچرها که می‌تواند تا حد زیادی تنوع مدل را برای بهبود ظرفیت تعمیم افزایش دهد، آموزش داده می‌شوند [۴، ۷]

Leaf Node هر درخت آموزش دیده توزیع نمونه‌های آموزشی (از نظر لیبل کلاس) را ذخیره می‌کند. در طول نتیجه‌گیری، هر نمونه آزمایشی به یک Leaf Node در هر درخت می‌رسد و توزیع لیبل مربوطه از نمونه‌های آموزشی برای استنتاج کلاس احتمالی این نمونه آزمایشی استفاده می‌شود. ما در نهایت مقادیر توزیع لیبل را از همه درختان به عنوان کلاس احتمالی برای هر نمونه آزمایشی، استاندارد و نرمالایز می‌کنیم و آن لیبل به عنوان کلاس با حداکثر احتمال تعیین می‌شود.

شایان ذکر است که در مقایسه با سایر مدل‌های طبقه‌بندی (به عنوان مثال، ماشین بردار پشتیبانی (Support Vector Machine)، Random Forest، از مزیت بهره‌وری بالا برای پردازش داده‌ها با فیچرهای ورودی در ابعاد بزرگ در طول استنتاج برخوردار هستند. این عمدتاً به این دلیل است که هر نمونه آزمایشی فقط از یک مسیر از Root Node به یک Leaf Node خاص در هر درخت می‌گذرد، به این معنی که ما فقط باید فیچرهایی را که در این مسیر خاص برای این نمونه آزمایشی استفاده می‌شود را استخراج کنیم (به جای همه فیچرهای ورودی مورد استفاده در طول آموزش).

## ۱.۲.۲ استخراج ویژگی (فیچر - Feature)

در جوامع کامپیوتر ویزن (بینایی کامپیوتر) و محاسبات تصویر پزشکی، انواع مختلفی از فیچرها با توجه به خصوصیت‌های وظایف (Tasks) مختلف مهندسی شده است. متداول‌ترین فیچرهای مورد استفاده شامل تبدیل تغییرناپذیر مقیاس (-Scale-Invariant Feature Transform) (SIFT) [۲۲]، فیچرهای هار مانند (Haar-like) [۲۰]، الگوی باینری محلی (Local Binary Pattern) (LBP) [۲] و هیستوگرام گرادیان‌های جهت‌یافته (-Histogram of Oriented Gradients) (HOG) [۶] است.

با در نظر گرفتن کارایی محاسباتی، ما از ویژگی‌های سه‌بعدی هار مانند (Haar-like) [۲۹] برای ساخت RF متوالی هدایت شده قبلی استفاده می‌کنیم. برای هر وکسل در یک حجم، ویژگی‌های هار مانند آن بر حسب یک پیچ سه‌بعدی یا دو تکه سه‌بعدی نامتقارن که به طور تصادفی از وکسل جابه‌جا می‌شوند، محاسبه می‌شود. از نظر ریاضی، با توجه به وکسل  $v$  و دو وصله  $P_1$  و  $P_2$  که به طور

توسط یک مجموعه دیگر شاخص‌دار (indexed) می‌شوند. تقسیم در Node به این صورت عمل می‌کند:

$$\arg \max_{\phi \in \Phi, S_L, S_R} \frac{1}{|S_L|} \sum_c p_c^L \log p_c^L + \frac{1}{|S_R|} \sum_c p_c^R \log p_c^R, \quad (1.1)$$

که در آن  $SR = \{s \in S | f(s, \phi) > t\phi\}$  و  $SL = \{s \in S | f(s, \phi) \leq t\phi\}$  هستند که  $s \in S$  یک نمونه آزمایشی خاص است. ضرایب  $p_c^L$  و  $p_c^R$  به ترتیب نشان دهنده نسبت نمونه‌های کلاس  $c$  در  $SL$  و  $SR$  است. عملیات  $f(s, \phi)$  استخراج فیچر  $\phi$ -امین نمونه  $s$  را نشان می‌دهد و  $t\phi$  آستانه مربوطه است که به طور تصادفی تعیین می‌شود.

از Node ریشه (یعنی اولین Split Node) تا Leaf Node، مرحله فوق به صورت بازگشتی با نمونه‌برداری تصادفی از یک زیرمجموعه فیچر در هر Node تقسیم شده تا زمانی که یکی از معیارهای زیر برآورده شود [۷]. یعنی (i) درخت انتخاب به حداکثر عمق درخت که از پیش تعریف شده می‌رسد (به عنوان مثال، عمق درخت در شکل ۱،۱ برابر با ۳ است)، یا (ii) زیرمجموعه آموزشی که به یک Node می‌رسد بسیار کوچک است که نمی‌تواند بیشتر تقسیم شود، یا (iii) خلوص یک Node بالاتر از یک آستانه از پیش تعریف شده است. هنگامی که یک تقسیم متوقف می‌شود، Node مربوطه به عنوان یک Leaf Node ساخته می‌شود و اطلاعات لیبل مربوط به دسته آموزشی که به آنجا می‌رسد ذخیره می‌شود.

پس از آموزش، هر نمونه آزمایشی به Node ریشه می‌آید و سپس به صورت بازگشتی به Node‌های تقسیم شده بعدی مطابق با توابع تقسیم مرتبط می‌شود تا زمانی که به یک Leaf Node برسد. احتمال تعلق نمونه آزمایشی به هر کلاسی با توجه به اطلاعات لیبل نمونه‌های آموزشی که در Leaf Node مربوطه ذخیره شده‌اند تعیین می‌شود.

## ۱.۲.۱.۲ ساختمان Random Forest (رندوم فورست)

Random Forest مجموعه‌ای از درختان تصمیم‌گیری باینری است. درختان به طور مستقل با نمونه‌برداری تصادفی از زیرمجموعه‌های آموزشی مختلف به وسیله جایگزین کردن از مجموعه آموزشی اصلی (به عنوان مثال، نمونه‌گیری بوت استرپ)

### ۱.۳.۱.۱ نقشه‌های احتمال اولیه

چندین تصویر CBCT قطعه‌بندی شده توسط متخصص به عنوان اطلس برای تخمین نقشه‌های احتمال اولیه فک بالا و فک پایین استفاده می‌شود. این نقشه‌های احتمال اولیه می‌توانند مقدمات آناتومیکی مهمی را برای راهنمایی در ساخت یک مدل تقسیم‌بندی خودکار فراهم کنند [۲۶]. به طور خاص، اطلس‌ها (همراه با نقشه‌های تقسیم‌بندی دستی مربوطه) دقیقاً بر روی هر تصویر آموزشی ردیف شده‌اند. پس از آن، برای هر وکسل در یک تصویر آموزشی، تعداد برجسب‌ها (مانند فک بالا، فک پایین و پس‌زمینه) را در مکان‌های مربوطه از تمام اطلس‌های موجود می‌شماریم و سپس آن‌ها را نرمال می‌کنیم (Normalize) (به دنبال آن صافی گاوسی با  $\delta = 2$  میلی‌متر [۲۵]) به عنوان احتمالات اولیه که وکسل متعلق به دسته‌های مختلف را توصیف می‌کند. این استراتژی ساده و کارآمد می‌تواند نقشه‌های احتمال اولیه معقول را تولید کند، مانند آنچه در شکل ۱،۲ نشان داده شده است.

### ۱.۳.۱.۲ فیچرهای تصویربرداری مکمل

برای توصیف جامع هر وکسل تصویر CBCT برای ساخت یک مدل طبقه‌بندی وکسل‌وایز (Voxelwise) قابل اعتماد، ما ویژگی‌های تصویربرداری (یعنی ویژگی‌های تصادفی شبه‌هار [۲۷]) را از هر دو تصویر اصلی CBCT و نقشه‌های احتمال تقسیم‌بندی (شده) مربوطه استخراج می‌کنیم. مرحله قبل شایان ذکر است که ویژگی‌های تصویربرداری از تصویر اصلی و نقشه‌های احتمال اطلاعات متفاوت و (در عین حال) کاملی را ارائه می‌دهند. به طور کلی، تصویر اصلی، اطلاعات ظاهری سطح پایینی را ارائه می‌کند، در حالی که نقشه‌های احتمال تقسیم‌بندی شده اطلاعات زمینه‌ای/معنایی سطح بالایی را ارائه می‌کنند. یک طبقه‌بندی‌کننده که به با ویژگی‌های استخراج شده از هر دو تصویر اصلی و نقشه‌های احتمالی (Proba-bility Maps) ساخته شده است، معمولاً مدل خودفهم (auto-con-text model) نامیده می‌شود، که کاربردهای بسیار موفقی را هم در جوامع بینایی کامپیوتر [۳] و هم در محاسبات تصویر پزشکی نشان داده است [۱۹،۳۰].

تصادفی جابجا شده‌اند، ویژگی‌های Haarlike بدین صورت تعریف می‌شوند:

$$f(v) = \frac{1}{|P_1|} \sum_{u \in P_1} I(u) - b \frac{1}{|P_2|} \sum_{w \in P_2} I(w), \quad (1.2)$$

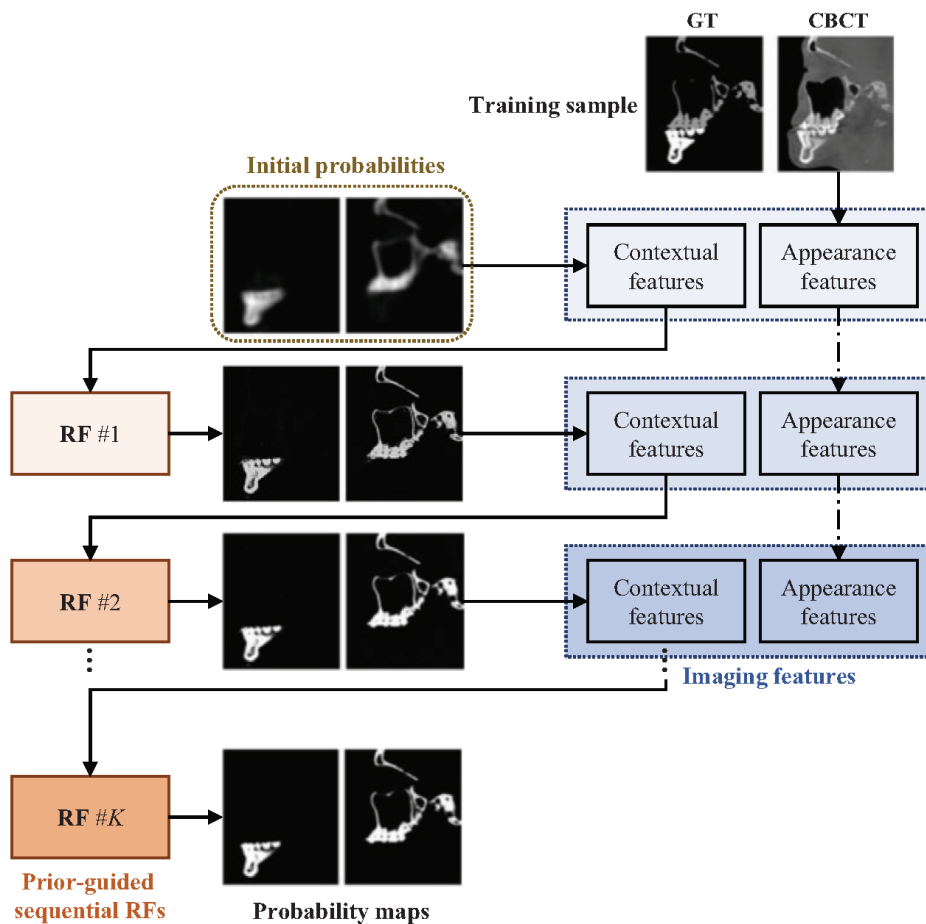
که در آن  $I(u)$  نشان دهنده شدت تصویر یک وکسل  $u$  و  $b \in \{0, 1\}$  است. در [۲۹]، فیچرهای Haar-like از هر دو تصویر اصلی CBCT و تقسیم‌بندی نقشه‌های احتمالی استخراج شدند و تکه‌های  $P_1$  و  $P_2$  در یک مجاورت  $17 \times 17 \times 17$  نمونه‌برداری شدند. همانطور که در بخش بعدی معرفی خواهد شد، ویژگی‌های یکسانی از ورودی‌های مختلف در واقع اطلاعات مکمل اما متفاوتی را ارائه می‌دهند.

## ۱.۳ رندوم فورست‌های (Random Forests) متوالی از پیش هدایت شده

در این فصل، تقسیم‌بندی CBCT فک بالا و فک پایین را به عنوان یک کار طبقه‌بندی وکسل در نظر می‌گیریم. یعنی ویژگی‌های تصویربرداری برای هر وکسل استخراج می‌شود تا یک مدل طبقه‌بندی، یعنی RF‌های متوالی از پیش هدایت‌شده، که احتمالات مربوط به وکسل متعلق به فک بالا، فک پایین و پس‌زمینه را پیش‌بینی می‌کند، استخراج می‌شود. بخش‌بندی نهایی با اختصاص برجسبی (لیبل) با بیشترین مقدار احتمال در مکان هر وکسل انجام می‌شود. همانند سایر رویکردهای یادگیری ماشینی تحت نظارت (Supervised)، روش RF متوالی از پیش هدایت شده شامل یک مرحله آموزشی و یک مرحله آزمایشی است که جزئیات آن در زیر توضیح داده شده است.

### ۱.۳.۱ مرحله آموزشی

با توجه به مجموعه‌ای از اطلس‌ها (یعنی تصاویر CBCT قطعه‌بندی شده توسط متخصص) و مجموعه‌ای از نمونه‌های آموزشی، مدل تقسیم‌بندی به دنبال پایپ لاین (Pipeline) نشان داده شده در شکل ۱،۲ ساخته شده است. مرحله آموزش شامل سه جزء مهم: (۱) برآورد نقشه‌های احتمال (Probability Maps) اولیه برای هر تصویر آموزشی، (۲) استخراج هر دو فیچر زمینه‌ای و ظاهری از نقشه‌های احتمالی و تصویر اصلی، و (۳) ساخت یک سری از RF‌های auto-context برای اصلاح تدریجی نقشه‌های احتمال برای تصویر آموزشی، است.



شکل ۱.۲ نمودار شماتیک آموزش RF متوالی از پیش هدایت شده برای تقسیم‌بندی استخوانی CMF در تصاویر CBCT. سه جزء مهم وجود دارد، به عنوان مثال، تعریف نقشه‌های احتمال اولیه برای یک نمونه آموزشی، استخراج ویژگی‌های تصویربرداری، و ساخت یک سری از RF‌های متن خودکار. GT مخفف داده مرجع (Ground Truth) است. (لطفاً توجه داشته باشید که این شکل از [۲۹] کپی شده است)

ability Maps) که توسط آخرین RF با مدل auto-context پیش‌بینی شده‌اند و بیشتر با ویژگی‌های ظاهری برای آموزش یک RF با مدل auto-context جدید ترکیب می‌شوند، به طور مکرر تحت به‌روزرسانی قرار می‌گیرند. به طور کلی، عملکرد بخش‌بندی کل مدل می‌تواند در تکرارهای محدود همگرا شود.

### ۱.۳.۲ استنتاج - نتیجه‌گیری

پس از آموزش، RF‌های متوالی از پیش هدایت شده به طور منظم بر روی تصاویر CBCT آزمایشی اعمال می‌شوند تا نقشه‌های احتمال فک بالا و فک پایین ... با کیفیت‌هایی که به طور فزاینده بهبود می‌یابند تولید شوند. مانند مثال نشان داده شده در شکل ۱.۳ به طور خاص، برای یک تصویر CBCT ورودی نشان داده شده در شکل ۱.۳a، همان اطلس‌هایی که در مرحله آموزش مورد استفاده قرار گرفتند با دقت تراز می‌شوند تا نقشه‌های احتمال در تصویر

### ۱.۳.۱ RF‌های متوالی

فیچرهای تصویربرداری متنی و ظاهری برای هر وکسل به‌عنوان یک حامل (vector) فیچر واحد برای آموزش یک مدل طبقه‌بندی auto-context ترکیب می‌شوند. به جای دیگر طبقه‌بندی‌کننده‌های کلاسیک (مانند Support Vector Machine و پرسپترون چند لایه)، RF در اینجا عمدتاً به این دلیل استفاده می‌شود ... که می‌تواند به طور مؤثر نمونه‌های آموزشی در مقیاس بزرگ (به عنوان مثال، وکسل‌های تصویری) را مدیریت کرده و می‌تواند ویژگی‌های متمایز را از فضای فیچر ورودی با ابعاد بالا (High-dimensional Input Feature Space) به طور مؤثر انتخاب کند.

برای بهبود تدریجی کیفیت فیچرهای زمینه‌ای برای تقسیم‌بندی دقیق‌تر، چندین RF با auto-context به صورت سریالی تا زمان همگرایی (Convergence) آموزش داده می‌شوند. به این معنا که ویژگی‌های متنی با استخراج آن‌ها از نقشه‌های احتمال تقسیم‌بندی (segmentation probability Prob-) می‌شوند.