



## هوش مصنوعی در پرتودرمانی

زهرا قاسمی<sup>۱</sup>، محمد امین پیربنیه<sup>۲</sup>

دانشجوی کارشناسی ارشد، دانشکده فنی و مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران . gh.zahra21@gmail.com

استادیار گروه برق، دانشکده فنی و مهندسی، واحد کازرون، دانشگاه آزاد اسلامی، کازرون، ایران . pirbonyeh@gmail.com

### چکیده

در سال های اخیر هوش مصنوعی (AI) به طور گسترده ای در رشته پزشکی پیاده سازی شده است. این مقاله ابتدا مروری بر پیشینه AI و رادیوتراپی دارد. سپس مفاهیم اساسی الگوریتم های مختلف AI و روش های یادگیری ماشین مانند شبکه های عصبی که امروزه در دسترس ما هستند و چگونگی عملی کردن آنها در رادیوتراپی و فرآیندهای تشخیصی مانند تصویربرداری پزشکی، برنامه ریزی درمان، شبیه سازی بیمار و کیفیت تضمین و تحویل دوز پرتو افکنی را بررسی می کند. همچنین تحقیقات تکوینی روی روش های AI که قرار است در آینده در رادیوتراپی اجرا شود را مورد تحقیق قرار می دهد. این بررسی نشان می دهد که AI در زمینه های مختلف پرتودرمانی به طور گسترده ای پیشرفت کرده و آینده درخشانی دارد. با این حال بر اساس نگرانی های مختلف مانند در دسترس بودن، امنیت استفاده از داده های بزرگ و عملیات تکمیلی بر روی آزمایش و اصلاح الگوریتم های AI، مشخص شد که در این زمان امکان استفاده از AI در رادیوتراپی برای ما فراهم نیست.

واژه های کلیدی: پرتو درمانی ، هوش مصنوعی

## 1. مقدمه

### 1.1 هوش مصنوعی

گمان می رود که ایده هوش مصنوعی (AI) از ایده ربات ها گرفته شده باشد. این ایده با استفاده بیشتر از ماشین های بیوسنتزی که در زایمان به کار برده می شدند، بیش از پیش برجسته شد. AI را میتوان به عنوان توانایی یک ماشین در تقلید از هوش انسانی تعریف کرد. AI بر اساس کاربرد آن به دو شاخه مجازی و فیزیکی طبقه بندی می شود. اجزای فیزیکی را میتوان در دستگاه های پزشکی، ربات های پیشرفته ( ربات های مراقبت) و ربات های کمک کار با قدرت مانور محدود نشان داد. اجزای مجازی در یادگیری ماشین نشان داده می شوند. یادگیری ماشین یک الگوریتم ریاضی است که از طریق تجربه یاد می گیرد. برای یک پزشک، دو عامل دانش و تجربه مهمترین عوامل مراقبت از بیمار هستند. انسان ها از طریق جمع آوری مقدار زیادی از داده ها عمدتاً به خاطر محدودیت های زمانی در تنگنا قرار دارند. در فرآیند یادگیری انسان، هم دانش و هم تجربه مورد نیاز است که هر دو در طول زندگی حرفه ای به دست می آید. رایانه می تواند از الگوریتم ها برای به دست آوردن تجربه بیشتر استفاده کند و نسبت به انسان به مراتب در مدت زمان کوتاه تری داده ها را ذخیره کند. یک رادیولوژیست تقریباً 225000 آزمایش MRI/CT را در 40 سال بررسی می کند، در حالی که AI می تواند با 225000 اسکن شروع کند تا خود را آموزش دهد و در یک مدت زمان بسیار کوتاه به میلیون ها اسکن برسد. امروزه بیماران مراقبت سریع تر و خصوصی تری را درخواست می کنند، این امر پزشکان را ملزم می کند که مقدار زیادی از داده ها را در مدت زمان کوتاه تفسیر و تحلیل کنند. تحت این شرایط یادگیری ماشین می تواند با آنالیز داده ها به پزشک کمک کند و عملکرد بالینی کارآمدتر، راحت تر و شخصی شده تری را در زمانی کوتاه تر ارائه دهد. اکنون حجم عظیمی از داده ها برای آموزش الگوریتم ها و سخت افزارهای محاسباتی مدرن در دسترس است. این الگوریتم ها در بسیاری از زمینه ها مانند کشف دارو، تصویربرداری و تشخیص پزشکی، مراقبت از راه دور بیمار، مدیریت ریسک، دستیاران بیمارستان و کمک مجازی به کار گرفته می شوند. پیش بینی می شود مولفه هایی که به حجم زیادی از آنالیز داده ها نیاز دارند، مانند DNA و RNA از این الگوریتم های محاسباتی بهره مند شوند. قابلیت های یادگیری ماشین در سال های اخیر، با معرفی الگوریتم یادگیری عمیق پیشرفت چشمگیری داشته است.

### 1.2 رادیوتراپی

یکی از مولفه های مهم در درمان سرطان، رادیوتراپی است. به طور تخمینی تقریباً 50٪ از بیماران سرطانی در طول دوره بیماری خود رادیوتراپی دریافت می کنند. رادیوتراپی را میتوان به 7 بخش طبقه بندی کرد: تصویربرداری، برنامه ریزی درمان (TP)، شبیه سازی، لوازم جانبی رادیوتراپی، تحویل پرتو افکنی، کنترل رادیوتراپی و دستگاه مراقبت بیمار. اولین مرحله ای که پزشکان تومور بیمار را تشخیص می دهند، فرآیند تصویربرداری است. اگر تومور وجود داشته باشد اطلاعات مهم مرتبط با تومور برای استفاده بعدی جمع آوری می شود. فرآیند تصویربرداری، حجم تخمینی تومور، شکل، محل، اندام های اطراف تومور که در معرض خطر هستند و سایر اطلاعات مفیدی که برای تحویل دوز پرتوافکنی بسیار مهم هستند را در اختیار پزشکان قرار می دهد. روش های تصویربرداری پیشرفته تر، داده های دقیق تری را ارائه می دهند که درمان را واضح تر و تاثیرگذارتر می کند. در رادیوتراپی، متاستاز ( دگرنشینی ) از راه دور اغلب یک مشکل بزرگ است و اگر در فرآیند تصویربرداری به درستی شناسایی نشود تومور میتواند دوباره رشد کند و حتی در آینده تهدید بیشتری را ایجاد کند. هم اکنون روشهای تصویربرداری بسیار پیشرفته ای در دسترس ما قرار دارند که میتوانند تصاویر پزشکی ای را تهیه کنند که بسیار کم در معرض تابش قرار می گیرند، مانند توموگرافی رایانه ای (CT) توموگرافی گسیل پوزیترون (PET) و توموگرافی تک فوتونی (SPET). برخی از گزینه های غیر پرتوافکنی نیز در دسترس ما هستند که میتوانند تصویری با وضوح و دقت بالا بگیرند، مانند تصویربرداری تشدید مغناطیسی (MRI) و سونوگرافی. پیشرفت بیشتر در این روش ها، فناوری ای را برای ما فراهم کرده است که میتواند تصویر چهاربعدی (4D) بگیرد که قادر به محاسبه حرکات بیمار باشد. در طول فرآیند TP و شبیه سازی، داده های مختلف بیمار مانند توده تومور، قد، وزن، شاخص توده بدن، مواجهه قبلی با پرتوافکنی و تصویر پزشکی داخلی بیمار به دست آمده و آنالیز می شود تا با تغییر پارامترهای مختلف، روند درمان، شخصی سازی شده و بهترین نتیجه برای بیمار به دست آید. در

فرآیند TP پیش بینی خطر و احتمال عدم موفقیت دنبال می شود. همچنین محاسبه حرکت اندام، انتخاب تکنیک درمانی، اندازه گیری شدت پرتو، ذخیره برنامه ریزی و بهینه سازی برنامه ریزی درمان در فرآیند TP صورت می گیرد. اخیراً فرآیند TP به طور قابل توجهی تکامل یافته تا بتواند همراه با پیشرفت های روش های درمانی پیش برود؛ پیشرفتهایی مانند رادیوتراپی سه بعدی منسجم (3D-CRT) یا رادیوتراپی تنظیم شده شدت (IMRT) که بر طبق آن در حالی که دوز تابش بالا را به حجم مورد نظر می رساند، در عین حال دوز برای اندام های اطراف در معرض خطر، آن دوز به طور قابل توجهی کاهش می یابد. هر دو روش نیاز به برنامه درمانی بسیار دقیق، نظارت مکرر و ردیابی دقیق حجم هدف دارند که باید حرکت هدف را به دلیل حرکت اندام داخلی و پسرقت تومور در نظر بگیرند. TP را می توان به دسته های زیادی طبقه بندی کرد. مانند مبتنی بر دانش، مبتنی بر متخصص یا مبتنی بر هوش مصنوعی (AI). پس از مرحله شبیه سازی بیمار، برنامه ریزی درمان شروع شده و محاسبه دوز انجام می شود. شبیه سازی مونت کارلو (MC) به طور کلی به عنوان استاندارد طلایی برای محاسبه دوز در رادیوتراپی پذیرفته شده است؛ زیرا فرآیند فیزیکی واقعی درگیر در تعامل در بدن یا بافت عمومی را فراهم می کند. برخی از کدهای متداول MC عبارتند از EGSnrc، MCNP، PENELOPE و Geant4. این شبیه سازی های پیچیده علاوه بر این که زمان بر هستند، به حجم زیادی از محاسبات و قدرت ذخیره سازی داده نیز نیاز دارند. این ویژگی ها برای استفاده معمول بالینی مناسب نیستند بنابراین راه حل جایگزین CloudMC است که از جنبه هایی آسان تر و ارزان تر است. لوازم جانبی رادیوتراپی اغلب برای ثابت کردن بیمار به منظور محدود کردن حرکت او و ارزیابی دقیق تر هدف استفاده می شوند. پروسه ثابت کردن معمولاً در مرحله شبیه سازی انجام می شود. فرآیند رادیوتراپی فرآیندی است که در آن دوز پرتوافکنی به بیمار تحویل داده میشود. دوز انرژی است که در واحد جرم رسوب می کند. هدف اصلی فرآیند رادیوتراپی کشتن سلول های تومور با استفاده از پرتوهای یونیزان و در عین حال صرفه جویی یا به حداقل رساندن رسوب انرژی به سلول های سالم تا حد امکان است. هم اکنون روش های پرتو درمانی زیادی وجود دارد؛ مانند رادیوتراپی استریوتاکتیک بدن (SBRT) درمان با قوس الکتریکی تنظیم شده حجمی (VMAT)، IMRT، پورتن تراپی، الکترون تراپی و براکی تراپی. پس از ایجاد طرح درمان، طرح دوزیمتری توسط یک برنامه تضمین کیفیت مخصوص بیمار تایید می شود تا از دقت تحویل دوز قابل قبول اطمینان حاصل شود. هنگامی که رادیوتراپی انجام شد، بیمار برای مدت زمانی (ماه تا سال) تحت نظر قرار می گیرد تا عوارض جانبی و پیامدهای آن مشاهده شود.

## 2. روش

یادگیری ماشین از ایده یادگیری رایانه ای گرفته شده است که طبق آن برای انجام یک کار بر روی مجموعه ای از نمونه های آموزشی مطالعه می شود. یادگیری ماشین به طور کلی به دو دسته متفاوت تقسیم می شود: یادگیری نظارت شده و یادگیری بدون نظارت. در یادگیری نظارت شده مجموعه آموزشی حاوی داده ها و خروجی صحیحی است که رایانه هم از داده ها و هم از خروجی ها (برچسب داده) برای پیش بینی خروجی داده های آینده استفاده می کند. مشاهدات ورودی به عنوان علت، و مشاهدات خروجی همچون معلول شناخته می شوند. هدف از یادگیری نظارت شده به دست آوردن یک رابطه عملکردی از داده های آموزشی است که داده های تست را تعمیم می دهد. این رابطه می تواند به صورت معادله یا ضریب عددی باشد. الگوریتم های مختلفی بر اساس یادگیری نظارت شده توسعه یافته اند؛ مانند الگوریتم رگرسیون، طبقه بندی و یادگیری تقویتی. در یادگیری بدون نظارت، مجموعه آموزشی حاوی راه حل نیست بنابراین رایانه باید راه حل را به تنهایی پیدا کند و هم از داده ها و هم از راه حل به دست آمده برای پیش بینی نتیجه داده های آینده استفاده کند. هدف از یادگیری بدون نظارت، یافتن متغیر ناشناخته در پشت مشاهدات یا یافتن رابطه بین نمونه هاست. الگوریتم های متعددی وجود دارند که بر اساس یادگیری بدون نظارت استخراج شده اند. مانند الگوریتم های کاهش ابعاد، خوشه بندی، جدا سازی منبع بی هدف و تخمین چگالی. یادگیری نیمه نظارتی ترکیبی از روش های یادگیری تحت نظارت و بدون نظارت است. در یادگیری نیمه نظارتی یک مجموعه آموزشی حاوی داده های با راه حل و داده های بدون راه حل وجود دارد. در این روش از داده های

برچسب دار و بدون برچسب برای پیش بینی نتیجه آینده استفاده می کند. این روش نیاز به داده های برچسب دار را کاهش می دهد. برچسب گذاری داده ها اغلب بسیار گران است و همیشه امکان پذیر نیست. برخی از نمونه های یادگیری نیمه نظارت شده عبارتند از: سیستم معرفی اطلاعات و طبقه بندی نیمه نظارت شده. نگاهی عمیق به الگوریتم های مختلف یادگیری ماشین و کاربردهای آن در رادیوترایی و تصویربرداری پزشکی در زیر نشان داده شده است.

## 2.1 مدل خطی برای طبقه بندی و تحلیل رگرسیون

مدل خطی بر اساس رابطه خطی بین ورودی و خروجی مدل مبتنی است. به طور کلی مدل خطی در برنامه های کاربردی مورد استفاده قرار می گیرد که طبقه بندی کمک - رایانه ای در تحقیق و توسعه رادیوترایی داشته باشند. تشخیص تحلیل خطی (LDA) روشی برای استخراج ویژگی های متمایز در طبقه بندی الگوهاست. LDA به داده های برچسب دار برای یادگیری یک پیش بینی متمایز نیاز دارد که به طور قابل توجهی فاصله بین طبقات را افزایش و فاصله درون طبقات را کاهش دهد (فاصله به ترتیب متغیر اشاره دارد). LDA در نهایت دقت طبقه بندی را بهبود می بخشد. کشش های مختلف LDA برای برآوردن نیازهای متفاوت ویژه مانند آنالیز متمایز خطی دو بعدی برای اندازه نمونه کوچکی که عملکرد و قابلیت را بهبود بخشد، توسعه یافته است.

روابط پیچیده را نمیتوان با استفاده از LDA طبقه بندی کرد به خصوص زمانی که درگیر یک رابطه درجه دوم باشد. در چنین موردی از تحلیل تفکیک درجه دوم (QDA) استفاده می شود. QDA بسیار شبیه LDA و کشش از LDA است. QDA رابطه بین متغیر مستقل و وابسته را به تصویر می کشد و ابزار تشخیص قوی تری ارائه می دهد. QDA زمانی مطلوب است که بردار پیش بینی به طور معمول در هر دو گروه توزیع شده باشد و هر گروه ساختار کوواریانس متفاوتی داشته باشد. یکی از اشکالات QDA این است که ویژگی های بیشتری را نسبت به LDA ارزیابی می کند؛ با این حال در بیشتر موارد از LDA بهتر عمل می کند.

## 2.2 شبکه معمولی مصنوعی

شبکه عصبی مصنوعی (ANN) از ایده بنیادی نحوه عملکرد مغز ما نشئت گرفته است. ANN از گره ها و ارتباطات تشکیل شده است؛ که در آن گره ها قدرت محاسباتی محدودی دارند اما به عنوان یک مکانیسم محرک شبیه به نحوه عملکرد انتقال دهنده های عصبی عمل کرده و برای تحریک یک نرون تجمع می کنند؛ این تراکم و پیچیدگی ارتباط دهنده، قدرت محاسباتی شبکه را مشخص می کند. رابطه بین گره ها و اتصال دهنده ها (نرون ها) را می توان به صورت یک معادله نشان داد:

$$y_i = f_i \left( \sum_{j=1}^n w_{ij} x_j - \theta_i \right)$$

که  $y_i$  خروجی گره  $i$ ،  $w_{ij}$  ارتباط بین گره  $i$  و  $j$ ،  $x_j$  ورودی گره  $j$ ، و  $\theta_i$  آستانه گره است. ANN را می توان با توجه به اتصال آنها به دو طبقه تقسیم کرد: طبقات کنترل رو به جلو و طبقات متناوب. در گره های کنترل رو به جلو هیچ ارتباطی از یک گره با عدد بزرگتر با یک گره با عدد کوچکتر وجود ندارد، به گونه ای که یک طبقه متناوب است. نظم ANN با نظم گره ها در ANN مشخص می شود، برای مثال نظم بالاتر ANN تعداد بیشتری از گره های نظم بالاتر را شامل می شود. از مزایای اصلی ANN اینست که می تواند مسائلی را حل کند که به صورت خطی قابل تفکیک نیستند و می تواند بسیاری از مشکلات را حل کند. ANN را می توان به دلیل توانایی در آنالیز ساختارهای پیچیده، برای پیش بینی ساختار ثانویه پروتئین مورد استفاده قرار داد. انواع مختلفی از شبکه های عصبی وجود دارد، مانند ماشین های بولتزمن و شبکه های کوهونن.

## 2.3 هسته ها

روش هسته با استفاده از دو روش نظارت شده و بدون نظارت، ابزار قدرتمندی برای آنالیز داده ها فراهم می کند. هسته، عموماً در یک فضای ویژگی با ابعاد بالا، به یک محصول نقطه ای مطابقت دارد. این اندازه گیری شباهت، امکان می دهد که

الگوریتم هایی را در فضای محصول نقطه ای بسازیم. برای یک مجموعه داده معین  $(x_1, y_1), \dots, (x_n, y_n)$ ،  $X \times Y$  که در آن  $X$  دامنه ورودی ها یا متغیرهای پیش بینی،  $Y$  اهداف یا متغیرهای پاسخ هستند، با ورودی جدید  $x \in X$  مربوط به  $y \in \{\pm 1\}$  باید پیش بینی شود، بنابراین هسته برابر است با:

$$K = X \times X \rightarrow R, (x, x') \mapsto k(x, x') \\ k(x, x') = (\theta(x), \theta(x'))$$

که  $\theta$  در آن فضای محصول نقطه ای ( فضای ویژگی ) رسم می شود و  $K$  اندازه گیری هسته یا اندازه گیری شباهت است. مجموعه ای از روشهای یادگیری هسته مبتنی بر نظارت ماشین بردار پشتیبان (SVM) است که می تواند برای طبقه بندی و رگرسیون ( بازگشت به عقب ) به کار برده شود. SVM خطای طبقه بندی تجربی را به حداقل می رساند و حاشیه هندسی در مجموعه آموزشی را به حداکثری که توانایی تعمیم بالاتری را در نمونه جدید داشته باشد، می رساند. کارکردهای مورد استفاده متداول هسته، برپایه چند جمله ای، تک خطی و شعاعی گاوسی قرار دارند. هسته عمومی شباهت های نقطه به نقطه را به طور سیستماتیک ترسیم می کند، و به دلیل استفاده ای که در طبقه بندی تصاویر ابرطیفی از آن می شود، شناخته شده است.

## 2.4 مدل های احتمالی

مدل احتمالی به ما اجازه می دهد تا با استفاده از مشاهدات فعلی، رویدادهای آینده را پیش بینی کنیم. این مدل از توزیع احتمال استفاده می کند تا تمام کمیت های مشاهده نشده نامشخص را نشان داده و چگونگی ارتباط آنها با داده ها را توضیح دهد. برای یافتن داده های مشاهده نشده از داده های مشاهده شده، قوانین اساسی نظریه احتمال استفاده می شود. این روش یادگیری داده ها از تئوری احتمال را قانون بیز می نامند. قانون بیز ترکیبی از قاعده جمع و قاعده ضرب نظریه احتمال است:

$$P(y|x) = \frac{P(x|y)P(y)}{\sum_{y \in Y} P(x, y)}$$

که در آن  $x$  و  $y$  مجموعه ای از مقادیر مشاهده شده و مجهول هستند.  $P(y)$  احتمال وقوع  $y$ ،  $P(x|y)$  احتمال وقوع ترکیب  $x$  و  $y$  است و  $P(x|y)$  احتمال وقوع  $x$  و مشروط به رعایت مقدار  $y$  می باشد. در نهایت، قانون بیز این است،

$$P(m|D) = \frac{P(D|m)P(m)}{P(D)}$$

طبق آن از  $m$  می توان برای مقایسه مدل ها استفاده کرد و عبارت شرط است و  $D$  داده های مشاهده شده است. هنوز هم مدل های گرافیکی رایج ترین مدل های احتمالی هستند.

## 2.5 یادگیری گروهی

یکی دیگر از روش های یادگیری ماشین، یادگیری گروهی است که با آموزش زبان آموزان با افزایش تنوع سیستم طبقه بندی کننده گروه کار می کند. یکی از مزایای یادگیری گروهی این است که طبقه بندی کننده گروهی می تواند نسبت به یک طبقه بندی کننده به موفقیت بالایی دست یابد. به همین دلیل است که یادگیری گروهی به طور گسترده برای طبقه بندی تصاویر استفاده می شود. همچنین مکانیسم بسیار موثری برای اندازه گیری عدم قطعیت فضای پیش بینی کننده های آماری است. می تواند با ترکیب تخمین ها پیش بینی دقیقی ارائه دهد. مدل های پیش بینی با استفاده از زیر مجموعه های مختلف داده های آموزشی، آموزش داده می شوند. این داده ها به طور مناسب انتخاب می شوند تا از مقدار مناسبی تنوع در مدل های پیش بینی اطمینان حاصل شود. تجمیع بوت استرپ یا در کیسه ریختن یک روش انتخابی شناخته شده است. در این روش به وسیله نمونه گیری با جایگزینی از مجموعه داده های آموزشی بین پیش بینی کننده ها تنوع ایجاد می کند. یکی از اشکالات این روش انتخاب تصادفی یک موضوع در هر زیر مجموعه آموزشی است که می تواند به دلیل تفاوت بین موضوعی منجر به اختلاف زیادی در پیش بینی شود.

## 2.6 آنالیز خوشه ای

داده های خوشه بندی به طور گسترده و بسیار مکرر در پرتودرمانی و رادیولوژی استفاده می شود. داده های طبیعی عموماً دارای ویژگی خوشه بندی هستند و نمونه های داده متعلق به یک خوشه مشابه هستند یا فاصله کمتری نسبت به نمونه های

خوشه های مختلف تحت ماتریس های فاصله دارند. برخی از الگوریتم های خوشه بندی متداول عبارتند از: خوشه بندی سلسله مراتبی، خوشه بندی K - means، DBSCAN، گاوسی و برش نرمال شده.

### 2.6.1 الگوریتم K-means

الگوریتم K-means از پارامتر K استفاده می کند که با داشتن شباهت های زیاد در خوشه ها و شباهت های کم بین خوشه ها n تعداد شیء را به خوشه ها تقسیم می کند و در نهایت، فاصله کل بین مقادیر در هر خوشه تا مرکز را کاهش می دهد. Centroid مقدار متوسط یک خوشه است. برای اندازه گیری شباهت، فاصله اقلیدسی رفت و برگشتی استفاده می شود که طبق آن هر چه فاصله کمتر باشد تشابهات بیشتر است و بالعکس. فاصله اقلیدسی را می توان با استفاده از معادله زیر محاسبه کرد.

$$d(x_j, c_j) = \sqrt{\sum_{j=1}^n (x_j - c_j)^2}$$

### 2.6.2 DBSCAN

الگوریتم DBSCAN یک الگوریتم خوشه بندی مبتنی بر چگالی است که در آن خوشه ها ناحیه متراکمی از شیء هستند و شیء یک خوشه باید توسط اشیایی از همان خوشه احاطه شود. برخی از مفاهیم اصلی DBSCAN Eps-Neighbour است که d ابر کره بعدی است که جسم p هسته آن و Eps شعاع آن سایر مفاهیم رایج عبارتند از نقطه مرکزی، که یک شیء معین p نقاط داده بیش از minPts است و چگالی مستقیم و قابل دسترسی جایی که شیء p مستقیماً قابل دسترسی به چگالی است. زمانی که p به همسایگی Eps یک نقطه مرکزی q با توجه به مقادیر Eps و minPts تعلق دارد. در نهایت DBSCAN همسایگی هر نقطه داده را در ابر فضای بعدی بررسی می کند و به Eps دنبال نقطه هسته خوشه و اشیایی است که مستقیماً از نقطه هسته قابل دسترسی هستند.

### 2.6.3 مدل مخلوط گاوسی

مدل مخلوط گاوسی به عنوان ابزاری برای خوشه بندی مبتنی بر مدل به کار می رود و در بسیاری از زمینه ها مانند تشخیص الگو، آنالیز تصویر، داده کاوی و یادگیری ماشین استفاده می شود. مدل مخلوط گاوسی را با استفاده از مولفه های K می توان مدل سازی کرد

$$f(y_i; \theta) = \sum_{j=1}^k \pi_j \theta^p(y_i; \mu_j), \sum_j$$

که در آن  $1 = \sum_{j=1}^k \pi_j$  وزن های مثبت مشمول  $(; \mu_j), \sum_j$

پارامترهای مولفه های گاوسی هستند. آنالیز حجمی نکرور مغز در درمان پرتو پرتون با استفاده از یک مدل مخلوط بررسی می شود.

### 2.7 کاهش ابعاد و انتخاب ویژگی

AI برای همگام شدن با آخرین فناوری در رادیوتراپی، باید متغیرهای اضافی را محاسبه کند. ورودی متغیرهای اضافی در مسئله طبقه بندی یادگیری ماشین بر مبنای AI به دلیل زمان آموزش طولانی تر، اختلالات بیشتر، تعداد بیشتر داده های آموزشی مورد نیاز، پیش برآزش و تفسیر پذیری کمتر مدل، غیر قابل پیش بینی است. کاهش ابعاد تعداد متغیرهای ورودی مورد بررسی را تقلیل می دهد که باعث می شود بسیاری از عوارض جانبی دارای تعداد زیادی متغیر اولیه تقلیل یابد. کاهش ابعاد را می توان به دو دسته تقسیم کرد: انتخاب متغیر و استخراج ویژگی.

### 2.7.1 روش انتخاب متغیر

روش انتخاب متغیر یا انتخاب ویژگی به وسیله رسم نمودار و گرفتن بهترین زیر مجموعه از متغیرهای ورودی اصلی کار می کند. روش انتخاب ویژگی نمایش اصلی داده ها را تغییر نمی دهد. روش انتخاب متغیر بر روش استخراج ویژگی برای مدل

تشخیص ترجیح داده می شود؛ زیرا در مدل تشخیصی، متغیرها زمانی مفیدتر هستند که به ویژگی های غیر قابل تفسیر تبدیل شوند. روش های انتخاب ویژگی به سه دسته تقسیم می شوند: فیلتر، پوشش و تکنیک تعبیه شده. فیلتر ویژگی ها را بدون هیچ گونه یادگیری از داده ها استخراج می کند. پوشش از تکنیک های مختلف یادگیری برای ارزیابی ویژگی های مفید استفاده می کند. تکنیک های تعبیه شده مرحله انتخاب ویژگی و ساخت طبقه بندی کننده را ترکیب می کنند. برخی از نمونه های متداول روش های انتخاب متغیر در پرتودرمانی عبارتند از: انتخاب متغیر مبتنی بر ضریب همبستگی پیرسون، الگوریتم حداقل انتخاب ویژگی افزونگی (mRMR) و پتوی مارکوف.

### 2.7.1.1 ضریب همبستگی پیرسون

ضریب همبستگی پیرسون قدرت ارتباط خطی بین دو متغیر را اندازه گیری می کند. این یکی از ساده ترین رویکردها برای انتخاب متغیرهای مهم از متغیرهای ورودی مستقل و هدف است. متغیرهای ضریب همبستگی پیرسون را می توان با استفاده از فرمول اندازه گیری کرد.

$$r = \frac{\sum(R_i - R_{av})(G_i - G_{av})}{\sqrt{\sum(R_i - R_{av})^2 \sum(G_i - G_{av})^2}}$$

که در آن  $R_i$  اولین متغیر،  $R_{av}$  میانگین حسابی و  $G_i$  متغیر دوم و میانگین حسابی متناظر هستند  $G_{av}$

### 2.7.1.2 پتوی مارکوف

پتوی مارکوف (MB) اولین بار توسط Pear نامگذاری شد و نمایانگر بخش مهمی در شبکه بیزی است. MB از یک متغیر شامل والدین (علت مستقیم)، فرزندان (اثرات مستقیم) و همسران (سایر علل مستقیم از فرزندان متغیر) در شبکه بیزی تشکیل شده است. یک ویژگی منحصر به فرد MB این است که یک گره هدف دارد، و تمام گره های دیگر از گره هدف مستقل هستند. MB یک متغیر، تصویری کامل از ساختار علی محلی در اطراف متغیر ارائه می دهد. با محاسبه MB تمام متغیرها در مجموعه داده، MB ها می توانند به عنوان محدودیت برای کاهش فضاهای جستجو در یک شبکه بیزی در مقیاس بزرگ استفاده شوند.

### 2.7.1.3 الگوریتم حداقل انتخاب ویژگی افزونگی

وانگ و پنگ الگوریتم حداقل انتخاب ویژگی افزونگی (mRMR) را پیشنهاد کردند که یک رویکرد انتخاب متغیر است. این الگوریتم سعی می کند ویژگی هایی را با همبستگی بالا در طبقات خروجی و همبستگی کم بین طبقات انتخاب کند و معیاری از میزان مفید بودن یک ویژگی کاندید ارائه می کند (معیار امتیاز دهی) که احتمالاً در مدل طبقه بندی کننده با استفاده از فرمول پیشنهادی Battiti استفاده می شود. برای اجتناب از نیاز به یک آستانه از پیش تعریف شده، شرط پنگ را به کار می برد. mRMR را می توان به صورت زیر تعریف کرد.

$$f(x_i) = I(X_i; Y) - \frac{1}{|S|} \sum_{x_j \in S} I(X_i; X_j)$$

که در آن  $f$  معیار امتیاز دهی را تخمین می زند،  $X_i$  ویژگی کاندید است،  $Y$  صفت طبقه، و  $\frac{1}{|S|}$  تنظیم تفريق مقایسه ربط و افزونگی است. در مورد یک ویژگی پیوسته، همبستگی را می توان با استفاده از آمار  $F$  - و همبستگی بین طبقات (زیادی) را می توان با استفاده از همبستگی پیرسون محاسبه کرد. این ویژگی ها یکی یکی با جستجوی الگوریتم حریصانه انتخاب می شوند که تابع هدف (عملکرد ارتباط و افزونگی) را به حداکثر می رساند. در مورد داده های زمانی، mRMR ابتدا نیاز دارد که داده ها با استفاده از تکنیک های پیش پردازش در یک ماتریس منفرد صاف شوند. همچنین به دلیل احتمال از بین رفتن داده های مهم در طول فرآیند صاف کردن، ایراد دارد.

### 2.7.2 روش استخراج ویژگی

روش های استخراج ویژگی به دو دسته تقسیم می شوند: استخراج ویژگی خطی و استخراج ویژگی غیر خطی.



### 2.7.2.1 استخراج ویژگی خطی (آنالیز مولفه های اصلی)

ویژگی خطی زمانی کار می کند که داده ها در یک زیر فضای خطی با ابعاد پایین تر قرار گیرند. این داده ها را با استفاده از فاکتورسازی ماتریس بر روی فضای فرعی طرح ریزی می کند. در سال 1901 کارل پیرسون روش آنالیز مولفه های اصلی (PCA) را پیشنهاد کرد که به روش Karhunen-Loeve (K-L) نیز معروف است؛ که آن یکی از الگوریتم های شناخته شده کاهش ابعاد می باشد. PCA متعامد، فضای ویژگی های با ابعاد بالا را به فضای ویژگی های کم بعدی تبدیل می کند؛ که در آنجا ممکن است ابعاد فضای ویژگی کاهش یافته، برابر یا کمتر از فضای ویژگی اصلی باشد. تبدیل فضای ویژگی به گونه ای انجام می شود که بیشترین واریانس در مولفه اول باشد، سپس بیشترین واریانس بعدی در مولفه دوم و غیره. در PCA اولین متغیرهای محاسبه شده مولفه های اصلی نامیده می شوند که ترکیبی خطی از متغیرهای اصلی هستند. اولین مولفه های اصلی بیشترین واریانس ممکن را دارند. مولفه های دوم با محدودیت متعامد بودن نسبت به مولفه های اول محاسبه می شوند و بیشترین اینرسی ممکن را دارند. مقادیر متغیرهای جدید برای مشاهدات را نمرات عاملی می نامند و می توان آن ها را به صورت زیر محاسبه کرد

$$F = P\Delta = P\Delta Q^T Q = XQ$$

که در آن F امتیاز عامل یا ماتریکس طرح ریزی، X مجموعه داده، Q ضریب ترکیبات خطی،  $\Delta$  ماتریکس مورب مقادیر منفرد است.

### 2.7.2.2 استخراج ویژگی غیر خطی

کاهش ابعاد غیر خطی را می توان با استفاده از تکنیک ابعاد خطی انجام داد. اما ابتدا باید چند ترفند اعمال شود. سطح کم بعدی باید در فضایی با ابعاد بالا ترسیم شود تا یک رابطه غیر خطی بین آن ها به وجود آید که به راحتی قابل تشخیص باشد. تابع هسته را می توان برای ایجاد همان نتیجه بدون نیاز به محاسبه صریح تابع بالابر طراحی کرد. روش دیگر برای حل مسئله غیر خطی بودن این است که فرض کنیم خط داده ای که روی یک منیفولد غیر خطی تعبیه شده ابعاد کمتری نسبت به فضای داده خام دارد و درون آن قرار دارد. نقشه ایزومپ یک الگوریتم متداول است که منیفولد را با پیوستن به همسایگان به شکلی از نقشه ایجاد می کند. فاصله بین نقاط فاصله ژئودزیکی در نمودار خروجی است. سایر الگوریتم های مبتنی بر منیفولد که مورد استفاده قرار می گیرند، نقشه های ویژه لاپلاسی و تعبیه خطی محلی هستند.

### 2.8 یادگیری تقویتی

یادگیری تقویتی ابزارهایی را فراهم می کند تا توالی تصمیمات برای نتایج بلند مدت را بهینه سازی کند. الگوریتم های یادگیری تقویتی عموماً یک توالی ورودی از تعاملات معروف به تاریخچه بین تصمیم گیرنده و محیطشان را می گیرند. در هر نقطه تصمیم، الگوریتم، فعالیتی بر اساس خط مشی خود انتخاب می کند و مشاهدات جدید و نتایج فوری (پاداش) را دریافت می کند. آن را در بهینه سازی مراقبت های بهداشتی مانند درمان ضد ویروسی در HIV مورد استفاده قرار می دهند. یکی از رایج ترین الگوریتم های یادگیری تقویتی، الگوریتم یادگیری Q بر اساس استراتژی لحظه ای و مدل نامربوط است. یکی از مزایای اصلی این الگوریتم عدم نیاز به دانش قبلی است. این به طور مستقیم با محیط تعامل دارد و اطلاعاتی را از بازخورد وضعیت در فرآیند کنترل به دست می آورد. پیشرفت های کنونی در AI و یادگیری تقویتی یک شبکه Q عمیق ارائه می کند که می تواند خط مشی های موفقیت آمیزی را مستقیماً از ورودی های حسی با ابعاد بالا با استفاده از یادگیری تقویتی end to end بیاموزد و به کنترل سطح انسانی برسد.

### 2.9 یادگیری چند نمونه ای

یادگیری چند نمونه ای (MIL) برای اولین بار در سال 1997 توسط دیتیش معرفی شد و بیشتر برای شناسایی پروتئین ها و بازیابی تصویر مبتنی بر محتوا استفاده شد. MIL با عدم قطعیت در برچسب سر و کار دارد. چندین روش برای حل مسائل MIL موجود است، برخی از مثال های رایج عبارتند از: چگالی متنوع، SVM مبتنی بر هسته و الگوریتم K-nearest (K-NN).



در MIL، یک کیسه برای نشان دادن یک موضوع استفاده می شود و می تواند مدل سازی شود به عنوان:

$$B_i = \{x_{il} | l = 1, 2, \dots, n_i\} \in R^d$$

که در آن  $n_i$  تعداد بُردار ویژگی در کیسه  $B_i$  و  $R^d$  فضای ویژگی  $d$ -

است. مجموعه داده های آموزشی MIL را می توان در زیر نشان داد به عنوان:

$$T = \{(B_i, y_i) | i = 1, 2, \dots, N\}$$

که در آن  $y_i = (-1, +1)$  و برچسب طبقه مربوط به هر کیسه در مجموعه داده است. اگر کیسه حاوی حداقل یک نمونه مثبت باشد کیسه ها دارای برچسب  $+1$  هستند در غیر این صورت  $-1$  یا کیسه یا برچسب منفی است.

## 2.10.10 کاربرد تطبیق نمودار

نمودارها معمولاً به عنوان یک نمایش انتزاعی از یک ساختار پیچیده استفاده می شوند. تطبیق نمودار، یافتن تناظر بین گره های دو نمودار است. به گونه ای که وقتی رئوس آن ها بر اساس تناظر برچسب گذاری می شوند شبیه هم به نظر می رسند. گره ها ویژگی های محلی تصویر را نشان می دهند، که در آنجا لبه ها با یک جنبه رابطه ای بین تصاویر مطابقت دارند. مدل های زیادی وجود دارند که به روش های مختلف به تطبیق نمودار می پردازند. نمونه هایی از روش های مختلف عبارتند از روش های طیفی، برچسب گذاری آرامش، رویکردهای احتمالی، آرامش های نیمه معین، تخصیص درجه بندی شده، جستجوی درختی و معادلات تکراری. روش طیفی با مطالعه شباهت های بین طیف های مجاورت یا ماتریس لاپلاسی نمودارها و استفاده از آن اطلاعات برای تطبیق آن ها کار می کند. روش های احتمالی و آرام سازی ابتدا توزیع احتمال بر روی نقشه برداری را تعریف می کنند و با استفاده از الگوریتم های آرامش گسسته بهینه می شوند. جستجوی درختی، آزمایش های متوالی را برای سازگاری بخش های محلی نمودارها اجرا می کند. الگوریتم نقطه ثابت پیش بینی شده با عدد صحیح یکی دیگر از الگوریتم های تطبیق گراف رایج است که به طور گسترده برای تقسیم بندی تصویر استفاده می شود و کارایی بالایی دارد. تطبیق نمودار جزء ضروری تطبیق ویژگی های دو بعدی و سه بعدی و تشخیص اشیا است.

## 2.11.1 یادگیری عمیق

قدرت محاسباتی یادگیری عمیق پتانسیل بالایی دارد و در سال های اخیر منجر به ظهور بسیاری از شرکت های تحقیقاتی جدید در یک محیط راه اندازی شده است، مانند Deep Genomics. روش یادگیری عمیق از لایه های پردازشی متعدد برای کشف الگو در یک مجموعه داده بزرگ استفاده می کند. یادگیری عمیق شاخه ای از AI و مجموعه ای از مدل های محاسباتی است که چندین لایه پردازش داده را تشکیل می دهد. در طول مرحله آموزش، سیستم خطای بین خروجی مشاهده شده و خروجی مورد نظر را محاسبه می کند و پارامترهای داخلی خود را که به عنوان وزن شناخته می شوند، برای کاهش این خطا تنظیم می کند. این سیستم همچنین یک بُردار گرادیان را برای هر وزن محاسبه می کند که نشان دهنده انحراف خطا ناشی از تنظیم وزن است. بردار وزن در جهت مخالف بردار گرادیان تنظیم می شود. به طور کلی روشی به نام نزول گرادیان تصادفی (SGD) برای یافتن مجموعه ای موثر از وزن ها استفاده می شود. در این فرآیند سیستم بردار ورودی را برای چند مثال نشان می دهد و خروجی خطا و گرادیان میانگین را برای آن نمونه ها محاسبه می کند. کل فرآیند چندین بار با مجموعه ای کوچک از مثال ها تکرار می شود تا زمانی که میانگین عملکرد موضوع متوقف شود. بسیاری از شبکه های مبتنی بر یادگیری عمیق اخیراً در پرتو درمانی برای محاسبات پیچیده مانند شبکه عصبی عمیق و کانولوشن توسعه داده شده و به کار گرفته شده اند.

### 2.11.1.1 شبکه های عصبی عمیق (DNN)

می توانند تحت نظارت یا بدون نظارت باشند. در یادگیری ماشین، اغلب لازم است که پیچیدگی داده ها کاهش یابد و الگوی مربوط به الگوریتم یادگیری برجسته شود. در بیشتر موارد، تابع AI تا حد زیادی به عملکرد موثر الگوریتم یادگیری بستگی دارد. DNN ها ترکیبی از شبکه های عصبی چندگانه یا شبکه های عصبی چند لایه هستند. DNN ها ابتدا از همان اصول ANN برای محاسبه داده ها با استفاده از گره ها استفاده می کنند، پس از آن خروجی لایه اول به ورودی لایه زیر تبدیل می شود و فرآیند تکرار می شود. که در آن جا خروجی لایه نهایی خروجی مشتق شده برای سیستم است. در حالت بدون نظارت

DNN ها، اصول اولیه همان یادگیری بدون نظارت و ANN هستند. بنابراین در لایه اول خروجی ANN با استفاده از اصول یادگیری بدون نظارت تولید می شود، سپس نتیجه لایه اول به عنوان ورودی لایه دوم عمل می کند. الگوریتم های یادگیری عمیق بدون نظارت به دلیل نیاز به داده های دارای برچسب پایین تر بر DNN های نظارت شده ترجیح داده می شوند. یکی از اشکالات DNN های بدون نظارت این است که تضمین معنی دار بودن نمایش آموخته شده پیچیده تر است.

### 2.11.2. شبکه های عصبی کانولوشنال

شبکه های عصبی کانولوشن (CNN) برای پردازش داده هایی که در آرایه هایی مانند تصویر پزشکی می آیند، مناسب هستند. به طور معمول، CNN از سه نوع لایه تشکیل شده است: لایه کانولوشن، لایه ادغام و لایه کاملاً متصل. نقش لایه کانولوشن، شناسایی شباهت های ویژگی از لایه قبلی و یادگیری نمایش ویژگی ورودی است. تعداد لایه کانولوشن مربوط به تعداد هسته های کانولوشن است که برای محاسبه نقشه های ویژگی استفاده می شود. در نقشه ویژگی، هر نورون به یک نورون همسایه در لایه قبلی متصل است. نقش لایه ادغام، دستیابی به سیستم تغییر ناپذیر شیفت با کاهش وضوح نقشه ویژگی است. یک لایه ادغام به طور کلی بین دو لایه کانولوشن قرار می گیرد، که در آنجا نقشه آینده هر لایه به یک نقشه ویژگی مربوط به لایه کانولوشنی قبلی متصل می شود. نقش یک لایه کاملاً متصل این است که با گرفتن تمام نورون های لایه قبلی و اتصال آنها به تک تک نورون های لایه فعلی، استدلال سطح بالا را انجام دهد.

### 3. پیاده سازی الگوریتم های یادگیری ماشین در رادیوتراپی

#### 3.1. تصویربرداری پزشکی

روش های مختلف یادگیری ماشین در سیستم های تصویربرداری پزشکی مدرن، مانند توموگرافی کامپیوتری (CT) یا تصویربرداری تشدید مغناطیسی (MRI) در حال اجرا هستند. CT یک روش تصویربرداری رادیولوژیک است که می تواند اطلاعات حجمی و موفولوژیکی آناتومی بیمار را از طریق یک تصویر پزشکی به دست آورد. یک سی تی اسکنر مدرن می تواند بیمار را از سر تا پا با وضوح بالا اسکن کند. MRI می تواند بافت نرم را به خوبی متمایز کند که دیدن داخل مفصل یا رباط را ایده آل می کند. با این حال MRI می تواند برای به دست آوردن تصویر تقریباً در هر نقطه از بدن استفاده شود. اگر شامل تفاوت چگالی بافت نرم باشد. خطر قرار گرفتن در معرض تشعشع، با این حال MRI را نمی توان در حضور فلز مانند ایمپلنت فلزی استفاده کرد. زیرا با میدان مغناطیسی MRI تداخل خواهد داشت. در حالی که الگوریتم مبتنی بر AI راه حل های غیر تابشی ارزانی ارائه می دهد و در سال های اخیر به طور گسترده ای مورد تحقیق قرار گرفته است. الگوریتم مبتنی بر AI بدون هیچ خطری ارائه نمی شود آنها خطر خطاهای سیستماتیک با پیامدهای بالا را افزایش می دهند. که منجر به ادغام MRI و شتاب دهنده خطی شده است که می تواند رادیوتراپی با هدایت MRI را در زمان واقعی ارائه دهد. الگوریتم های مبتنی بر AI در درجه اول در سه جنبه تصویربرداری پزشکی اجرا می شوند که در زیر نشان داده شده است.

#### 3.1.1. تقسیم بندی تصویر

تقسیم بندی تصویر نقش حیاتی در تجزیه و تحلیل تصویر پزشکی ایفا می کند. روش های تقسیم بندی زیادی وجود دارد اما هیچ کدام جهانی نیستند. برخی از روش های متداول تقسیم بندی تصویر، مدل مار هستند که توسط کاس و دیگران معرفی شده اند. و روش تنظیم سطح را می توان به دو دسته تقسیم کرد: مدل های LMS مبتنی بر منطقه و مدل های مبتنی بر لبه. مدل مبتنی بر لبه از اطلاعات منطقه ای برای کنترل حرکت کانتور فعال استفاده می کند. مدل های مبتنی بر منطقه نسبت به شی با مرزهای تعریف نشده حساس نیستند با این حال به ناهمگنی شدت تصویر (همپوشانی دامنه های شدت) و چرخش پارامتر حساس هستند. برخی از رویکردهای دیگر برای تقسیم بندی تصویر SVM، KNN و یادگیری ماشین شدید هستند. آن ها می توانند الگوهای پیچیده را تجزیه و تحلیل کنند اما به پردازش پس از آن مانند عملیات مورفولوژی نیاز دارند. تقسیم بندی را می توان در بسیاری از ساختارها مانند استخوان ها، اندام ها، عضلات و شکستگی ها اعمال کرد. در تحقیقات اخیر، روش تقسیم بندی درختی به طور فشرده برای تصویربرداری مغز مورد مطالعه قرار گرفته است. شبکه های عصبی و الگوریتم های یادگیری عمیق نیز برای بخش بندی مغز استفاده می شوند. آن ها با هم یک روش نیمه خودکار برای طبقه

بندی MRI مغز به سلول های سرطانی و بافت سالم ارائه می دهند. مغز اولیه کنتراست بافتی کمتری دارد. که تقسیم آن را نسبت به مغز بالغ دشوارتر می کند. تصویر ناهمسان گردی کسری برای افتراق ماده خاکستری و سفید مناسب تر است. در حالی که تصویر وزنی T2 در گرفتن مایع مغزی نخاعی بهتر است. روش CNN می تواند داده های تصویری این روش های مختلف را برای افزایش برتری بخش بندی ترکیب کند. شبکه عصبی معمولاً برای انجام این کار به یک لایه کانولوشنال نیاز دارد. روش های یادگیری عمیق می توانند به طور خودکار تصاویر مغز MRI را تقسیم بندی کنند. روش های تقسیم بندی دیگری نیز برای MRI مغز وجود دارد مانند روش های مبتنی بر شدت (خوشه بندی، رشد آستانه، طبقه بندی) روش های مبتنی بر اطلس، روش های مبتنی بر سطح (کانتورها) و سطوح و خطوط غعال چند فاز (تقسیم بندی هیریدی. اکثر این روش ها از الگوریتم ها و تکنیک های قبلاً بررسی شده استفاده می کنند. مانند مورد میدان تصادفی مارکوف، نقطه  $k$ ، رگرسیون و خوشه بندی. یک روش تقسیم بندی قوی تر از دیگر روش های پیشرفته CNN معمولی. این روش نتیجه دقیق را با تعامل کمتر و زمان کمتر ارائه می دهد. سرطان سینه یکی از سرطان هایی است که معمولاً تشخیص داده می شود و مسئول 30 درصد از تشخیص های جدید سرطان در زنان است. اولتراسوند معمولاً برای تشخیص سرطان سینه استفاده می شود. و بهبود و بخش بندی تصاویر سونوگرافی پستان به بافت های عملکردی، محلی سازی بهتر تومور، ارزیابی پاسخ درمانی و اندازه گیری تراکم پستان را فراهم می کند. تقسیم بندی اولتراسوند برای رادیولوژیست بسیار زمان بر است و به مهارت و تجربه بستگی دارد. تقسیم بندی خودکار تصویر اولتراسوند به کاهش این مشکلات کمک می کند. مطالعه اخیر نشان می دهد که تقسیم بندی کانولوشن مبتنی بر CNN می تواند تصویر سه بعدی را به چهار بافت اصلی تقسیم کند: پوست، توده، بافت غددی فیبرو و بافت چربی با دقت بالا. این پتانسیل را برای ارائه تقسیم بندی در آینده در تشخیص بالینی سرطان پستان نشان می دهد. یک قطعه بندی تمام بدن کاملاً خودکار برای CT تشخیصی قبلاً پیشنهاد شده است. روش تقسیم بندی از الگوریتم های جنگل تصادفی استفاده کرد و دقت و محدودیت آن را بررسی کرد. بخش بندی بافت سی تی اسکن با آموزش مجموعه داده های مختلف و استفاده از آن ها در سی تی اسکن گردن، قفسه سینه، لگن و شکم انجام شد. سیستم تشخیصی کاملاً خودکار دیگری نیز برای بیماری شکم ارائه شده است. که از روش استخراج ویژگی برای طبقه بندی بیماران استفاده می کند. و از الگوریتم های ژنتیک SVM، ANN برای طبقه بندی بیماری از تصاویر CT استفاده می کند. مناطق مورد علاقه که از تصاویر CT تقسیم بندی شده اند، تومور، سنگ، کیست و سلول طبیعی کبد بودند.

### 3.1.2 ثبت تصویر پزشکی

ثبت تصویر یکی از کاربردهای یادگیری ماشین است. در مواردی که بیمار با روش های مختلف یا یکسان چندین بار از موقعیت های مختلف در زمان ها یا موقعیت های مختلف اسکن می شود. از الگوریتم های یادگیری ماشین برای ترکیب نتایج برای دستیابی به تشخیص دقیق تر استفاده می شود. این فرایند اغلب به عنوان ترکیب، تطبیق یا تاب برداشتن تصویر شناخته می شود. هدف این فرایند یافتن تبدیل بهینه ای است که ساختارهای مورد نظر را در تصاویر ورودی به بهترین نحو تراز می کند. ثبت تصویر یک مرحله بسیار مهم در تجزیه و تحلیل تصویر است. چند نمونه از روش های متداول فیوژن تصویر CT یا MRI یا PET یا SPECT هستند. در روش ثبت بر اساس شدت، الگوریتم به طور مکرر تبدیل هندسی را جستجو می کند تا زمانی که مورد تصویر متحرک را بهینه می کند (معیار تشابه یا تابع هزینه را به حداکثر یا حداقل می رساند). تابع هزینه به شدت و کسل مربوط می شود و در ناحیه همپوشانی تصویر ورودی محاسبه می شود. در روش ثبت بر اساس ویژگی، الگوریتم پس از ایجاد ویژگی ها، تبدیل بهینه را جستجو می کند. معیار مبتنی بر ویژگی های هندسی، فیزیکی یا آماری برای تطبیق بین ویژگی ها استفاده می شود. برای طبقه بندی ضایعه ریه با استفاده از ویژگی های رادیومیک LDA استفاده می شود.

### 3.1.3 تشخیص به کمک رایانه (CAD) و سیستم تشخیص

در سال های اخیر، عمدتاً به دلیل در دسترس بودن مجموعه داده ها در مقیاس بزرگ، تشخیص خودکار تصویر به طور قابل توجهی بهبود یافته است. CT شناسایی گره ریه یک مثال بهبود یافته در CAD است. imageNet شامل بیش از 1.2 میلیون

تصویر طبیعی طبقه بندی شده از بیش از 1000 طبقه که نقش مهمی در آموزش CNN پیچیده ایفا می کند. CNN مبتنی بر CAD که از imageNet در مورد غدد لنفاوی سینه ای شکمی و بیماری ریه بینابینی آموزش دیده است، نتایج امیدوار کننده ای را برای کاربردهای بالینی نشان می دهد. CAD همچنین پتانسیلی در تشخیص متاستازها و پولیپ های روده بزرگ نشان می دهد. برای کولونوسکوپی، به کمک عیب یابی و ردیابی رایانه ای (CADE و CADX) از الگوریتم های یادگیری عمیق استفاده می شود که به طور متداول مورد مطالعه قرار می گیرند. AI دو نقش اصلی در تشخیص دارد: عیب شناسی پولیپ (CADE) و ردیابی پولیپ (CADx). CADE میزان از دست دادن پولیپ را کاهش می دهد که منجر به تشخیص بهتر آدنوم می شود. CADX دقت تشخیص نوری پولیپ کولورکتال را بهبود می بخشد.

در جهان غرب یکی از علل اصلی مرگ و میر ناشی از سرطان در مردان، سرطان پروستات است. معمولاً برای تشخیص سرطان پروستات، بیوپسی اولتراسوند ترانس رکتال انجام می شود. یکی از اشکالات این تشخیص این است که ویژگی پایینی دارد. بنابراین، اخیر به طور فزاینده ای از MRI برای سرطان پروستات استفاده شده است. ولیکن، این نوع درمان نیاز به یک تیم رادیولوژیست بسیار متخصص برای تشخیص سرطان پروستات از تصویر MRI با مدت زمان طولانی دارد. CAD می تواند این مشکلات را حل کند. هم اکنون یک سیستم CAD جدید مورد مطالعه قرار گرفته است که از دو مرحله تشکیل شده است. در مرحله اول، نامزدهای اولیه با استفاده از تقسیم بندی پروستات مبتنی بر اطلس چندگانه، طبقه بندی، تشخیص حداکثر موضعی و استخراج ویژگی شناسایی می شوند. در مرحله دوم، احتمال سرطان هر نامزد فیلتر شده با استفاده از طبقه بندی پیش بینی می شود. این سیستم با 347 بیمار با بیوپسی هدایت شده MR به عنوان استاندارد مرجع ارزیابی شد. نتیجه این ارزیابی نشان داد که این سیستم به طور بالقوه می تواند به عنوان خواننده دوم یا برای بهبود حساسیت رادیولوژیست استفاده شود. این سیستم همچنین پتانسیل تنظیمات اولین خواننده را نشان می دهد. با این حال کارهای بیشتری باید انجام شود تا بتواند به طور موثر عمل کند.

سرطان سینه اگر در مراحل اولیه تشخیص داده شود میزان بقای قابل توجهی را نشان داده است. تنها در ایالات متحده سالانه نزدیک به 40 میلیون آزمایش ماموگرافی انجام می شود. تصویر ماموگرافی به تفسیر و آنالیز یک یا چند خواننده با تجربه نیاز دارد که بسیار زمان بر و مستعد خطا است. CAD به طور گسترده به عنوان خواننده دوم برای افزایش کارایی مورد مطالعه و به کار گرفته شده است. کامپیوتر حجم تمرکز را تحمل می کند. بعلاوه آنها می توانند تعداد باور نکردنی نمونه آزمایش ببینند، بیشتر از آنچه یک رادیولوژیست بتواند در طول عمر بیاورد. یک سیستم CAD مبتنی بر شبکه عصبی کانولوشنال می تواند تشخیص الگو و تشخیص شی را با دقت بالا انجام دهد. آن را در برابر مجموعه ای از ویژگی های طراحی شده دستی با 45000 تصویر آزمایش کرد و CNN عملکرد بهتری در حساسیت کم داشت و نتایج قابل مقایسه ای را در حساسیت بالا نشان داد. شبکه CNN همچنین با یک رادیولوژیست غربالگری تایید شده روی یک وصله اهرمی مقایسه شد و هیچ تفاوت قابل توجهی نشان نداد.

### 2.3. برنامه ریزی درمان

براکی تراپی پروستات با دوز پایین (LDR) یکی از بهترین روش های درمانی برای سرطان پروستات است. چندین کارازمایی ثابت کرده اند که کاشت دائمی منابع رادیواکتیو با دوز پایین نتایج عالی ارائه می دهد. هدف اصلی درمان به حداکثر رساندن است. دوز پروستات در حالی که با کاشت دانه های رادیواکتیو در یک الگوی سه بعدی بافت طبیعی را حفظ می کند. اجزای آن بذرها و محل دقیق بذرها بسیار مهم است و نیاز به یک تیم متخصص براکی تراپی دارد. از آنجایی که خطا در قرار دادن منبع سیستماتیک منجر به دوز ناکافی برای هدف می شود فرایند TP باید با دقت زیادی ساخته شود و به زمان زیادی نیاز دارد. الگوریتم های بهینه سازی شده رایانه ای برای TP در براکی تراپی LDR برای بهبود کارایی و کاهش بار کار معرفی شدند. برخی از نمونه های الگوریتم هایی که استفاده می شوند عبارتند از بازپخت شبیه سازی شده برنامه ریزی شده معکوس. (HIOP) و بهینه سازی برنامه ریزی معکوس ترکیبی (ISPA) نزدیکترین همسایه استفاده K- از روش های تطبیق شباهت و CAD میکند که در آنجا سعی می کنند وضعیت فعلی را با مشابه ترین داده های آموزشی قبلی مطابقت دهند. CAD ثابت

کرده است که می تواند برنامه های درمانی دقیقی را برای براکی تراپی LDR ایجاد کند که با طرح های درمان متخصص و رادیولوژیست مطابقت دارد. یک بیمار سرطان پروستات این کمک از شبکه بیزی در TP برای کنترل موضعی تومور، گسترش منطقه ای، متاستازهای دوردست و نیزه زدن بافت طبیعی استفاده کرد. در حالی که از روش ماکاروف برای به زندگی تعدیل شده با کیفیت استفاده شد. با ترکیب این دو نتیجه کمک یک تصمیم درمانی را ارائه می دهد. خوشه بندی را می توان به عنوان طبقه بندی کننده برای پرتودرمانی K-mean تطبیقی در سرطان پروستات استفاده کرد. این سیستم رادیوتراپی ارائه شده و برنامه ریزی شده را در بیماران مقایسه می کند و به طور خودکار آنهایی را که می توانند از درمان تطبیقی بهره مند شوند شناسایی می کند. هدف اصلی این سیستم مقابله با عدم قطعیت دزیمتری ناشی از حرکت اندام های توخالی است. الگوریتم خوشه بندی K-means برای ساخت یک ابزار پیش بینی نظارت نشده استفاده می شود که تنظیم نادرست را به دلیل تغییرات فیزیولوژیکی تصادفی تشخیص می دهد. روش خودکار مبتنی بر CNN برای پیش بینی واجد شرایط بودن دزیمتری بیماران مبتلا به سرطان پروستات که تحت IMRT قرار گرفته اند نتایج نسبتاً دقیقی را نشان داده و نشان داده است. پتانسیل در فرایند TP. در مطالعه در پرتودرمانی پروستات استفاده می شود. QDA و همکاران Coates. QDA برای پیش بینی پارامترهای پیامد های مختلف هم برای کنترل تومور و هم اثر بافت طبیعی ناشی از رادیوتراپی استفاده می شود. نتایج تجربی نشان داد که پیش بینی QDA با نتیجه مورد انتظار برای دوز پی رایی دقیقاً مطابقت دارد و شروع به انحراف قابل توجه در 6-8 گری استفاده می کنند. یک QDA اصلاح شده می تواند برای مقابله با سایر پارامترهایی که شروع به انحراف از نتیجه مورد انتظار می کنند استفاده شود.

روش های رادیوتراپی اخیر مانند VMAT مبتنی بر فوتون نیاز به برنامه ریزی زیادی قبل از تحویل دوز دارد. تخصیص دوز در VMAT بسیار پیچیده است و پیش بینی دقیق نتیجه طرح به انکولوژیست های پرتوی اجازه می دهد تا تصمیم بهتر و آگاهانه تری برای درمان بگیرند و در زمان صرفه جویی زیادی کنند. الگوریتم جدید یادگیری ماشینی می تواند توزیع دوز را برای اندام های در معرض خطر پیش بینی کرده و حجم هدف را برنامه ریزی کند. دقت الگوریتم بر روی 69 طرح برای SBRT ریه و 121 طرح سر و گردن تایید شد؛ این امر منجر به میانگین خطای زیر 2.5 گری شد. این مطلب پتانسیل مورد استفاده به عنوان طرح درمانی خودکار در SBRT برای درمان ریه و سر و گردن را نشان می دهد. چو و همکارانش در ANN قابلیت های پیش بینی نتیجه را برای سرطان سر و گردن را نشان دادند. ANN متغیرهای مرتبط را در یک مدل پیش بینی در طول آموزش ترکیب کرده و تمام همبستگی های ممکن متغیرها را آنالیز می کند. از 73 مورد آزمایش، 51 بیمار برای مجموعه آموزشی، 11 بیمار برای مجموعه آزمون و 11 بیمار باقی مانده برای مجموعه اعتبار سنجی استفاده شدند. نتایج نشان داد که برای کنترل هدف کانونی دقت برای همه مجموعه های ترکیبی 90.4 درصد و دقت نتیجه متاستاز دوردست 91.8 درصد وجود دارد که می تواند قابلیت آن را به عنوان یک ابزار پیش بینی اثبات کند. همچنین ANN اجازه پیش بینی بقای پرتودرمانی به تنهایی از سرطان دهانه رحم را به وسیله ارزیابی عوامل مهم پیش آگهی می دهد. ANN درجه بندی بافت شناسی اثر تشعشع از معاینه دوره ای بیوپسی و عوامل بنیادی اضافی را ترکیب می کند و یک پیش بینی دقیق ارائه می دهد. مدل پیش بینی سمیت دوز مقعدی مبنی بر CNN می تواند به عنوان ابزار قدرتمند کارآمد برای دوز مقعدی و آنالیز سمیت القایی برای براکی تراپی با سرعت دوز بالا در سرطان دهانه رحم عمل کند. ANN برای آنالیز عوامل پیش آگهی مرتبط با پنومونیت تشعشع در بیماران مبتلا به سرطان ریه نیز استفاده می شود. DNN ها می توانند برای طبقه بندی کمی داده های تصویربرداری و ادغام آنها با عوامل خطر بالینی برای پیش بینی نارسایی موضعی بدن پس از رادیوتراپی استریوتاکتیک مورد استفاده قرار گیرند.

اثر بخشی رادیوبیولوژیکی (RBE) یک کمیت مهم برای توصیف کارایی کشتن سلولی توسط پرتو است. در آزمایش فردریش و همکارانش رابطه بین RBE و انتقال انرژی خطی (LET) با استفاده از منحنی های بقا که با استفاده از مدل درجه دوم خطی (LQ) پارامترسازی شده است، آنالیز می شود. مقادیر RBE به دست آمده از آن مدل، می تواند وابستگی RBE به LET را نشان دهد. QDA می تواند در پیش بینی موقعیت بهینه برای حفظ کارآمدی ارگان های در معرض خطر در

رادیوتراپی کل پستان سمت چپ استفاده شود. الگوریتم رگرسیون خطی برای پیش بینی پارامترهای مختلف در TP، مثالی برای مدل رگرسیون خطی است که برای پیش بینی حجم اسفنجی اسکلتی خاص بیمار در دزیمتری رادیوتراپی مولکولی استفاده می شود. مدل رگرسیون خطی همچنین برای مطالعه پیش بینی کننده های دوز قلبی و ریوی به اندام در معرض خطر در روش نگه داشتن نفس دم عمیق برای درمان سرطان پستان چپ استفاده می شود.

یک ابزار بهینه سازی مبتنی بر هسته، برای یافتن ترکیب موثر پرتوهای کربن با جریان و انرژی ورودی برای ارائه توزیع دوز عمقی مورد نظر در منطقه اوج براگ گسترده در پرتودرمانی کربن ایجاد شد. این مطالعه نشان داد که آن یک ابزار موثر برای استفاده در فرآیند TP است که می تواند در نهایت جایگزین شبیه سازی مونت کارلو (MC) شود.

### 3.3. شبیه سازی

یک چارچوب ترکیبی از روش هسته نقطه دوز الکترونی برای تخمین توزیع دوز در اطراف نانو ذرات طلا (GNP) پیشنهاد شد. GNP برای افزایش دوز در پرتودرمانی استفاده می شود. این یک چارچوب محاسباتی ترکیبی است که با شبیه ساز Geant4 MC ترکیب شده است؛ که زمان محاسبه را در مقایسه با شبیه ساز کامل Geant4 MC به نصف کاهش می دهد و به طور موثری هزینه و زمان را کاهش می دهد.

در سرطان پروستات تشخیص گاز روده در پرتودرمانی با هدایت تصویر بسیار مهم است. میورا و همکارانش نشان دادند که یک شبکه عصبی کانولوشنال عمیق می تواند گاز روده را در ناحیه لگن بسیار موثر تشخیص دهد.

### 4.3. تحویل رادیوتراپی

در پرتودرمانی میکروبیوم (MRT) میدان درمان به آرایه هایی از چند ده پرتو مسطح عرض میکرومتر با دوزهای پیک بالا تقسیم می شود که توسط یک ناحیه با دوز پایین از هم جدا می شوند. MRT ثابت کرده است که نسبت به رادیوتراپی عمومی کارآمدتر از بافت طبیعی محافظت می کند. محاسبه دوز در MRT بر اساس شبیه سازی های MC است که زمان بر است. بنابراین دبوس و دیگران یک الگوریتم محاسبه دوز مبتنی بر هسته تهیه کردند که انتقال انرژی را با واسطه فوتون و الکترون جدا می کند و می تواند دوز دره و قله میدان MRT را در عرض چند دقیقه محاسبه کند. بجز منطقه نزدیک به رابط های مواد، مقدار دوز پیک با شبیه سازی MC در انحراف 4٪ و دوز دره در 8٪ مطابقت داشت.

روش کرنل یک راه حل محاسباتی ارزان قیمت برای ردیابی بدون نشانگر حرکت تومور ناشی از تنفس در توالی تصویر فلوروسکوپی کیلوولتاژ در پرتودرمانی هدایت شده با تصویر ارائه می دهد. این روش ابتدا مغایرت تصویر فلوروسکوپی کیلوولتاژ را با استفاده از یکسان سازی هیستوگرام افزایش می دهد؛ سپس ردیابی هدف به وسیله به حداکثر رساندن ضریب (فاصله) Bhattacharyya با استفاده از الگوریتم تغییر میانگین، فرموله می شود. نتیجه به دست آمده با چهار توالی تصویر فلوروسکوپی کیلوولتاژ بالینی و چهار روش تطبیق الگوی معمولی مقایسه شد. روش کرنل نسبت به روش تطبیق قالب معمولی برتری داشت. نشان دهنده نتایج قابل مقایسه با توالی تصویر فلوروسکوپی ردیابی. در IMRT زاویه پرتو بهینه سازی شده معمولاً در یک جهت مجزا جمع آوری می شود. بنابراین از یک الگوریتم K-means برای شناسایی مراکز خوشه ای به عنوان زاویه تابش یک طرح درمان IMRT استفاده می شود. زوایای پرتو بهینه شده در مورد سرطان لوزالمعده و داخل جمجمه، اندام های در معرض خطر را کاهش می دهد. در توسعه الگوریتم خوشه بندی ساختار مسیر تشعشع می توان از یک تحلیل مبتنی بر خوشه برای خوشه بندی رویدادهای یونیزاسیون در هر سلول به دو دسته استفاده کرد. شکست دو رشته ای ساده یا پیچیده که بعداً می تواند برای شناسایی رابطه RBE استفاده شود.

در پرتودرمانی کربن رسوب انرژی ناشی از قطعات خوشه بندی تولید شده از پرتو اصلی را می توان با استفاده از الگوریتم خوشه بندی DBSCAN نیز برای مطالعه آسیب خوشه DNA پس از تابش هسته سلول فیبروپلاست استفاده می شود. روش یادگیری عمیق برای پیش بینی کنترل موضعی در سرطان ریه سلول غیر کوچک در حال مطالعه است. جایی که داده های برجسته زیادی برای یادگیری ماشینی در دسترس نیست. نتیجه تجربی نشان داد که پیش بینی های کنترل محلی دقیق و قابل مقایسه با پرسپترون چند لایه است. در آینده روش یادگیری عمیق را می توان برای شخصی سازی آینده نگر دوز و هدایت



در تغییر درمان سیستمیک مورد استفاده قرار داد. DNNs نیز در روش های رادیوتراپی پیشرفته مانند رادیوتراپی بدن استریوناکتیک برای همگام شدن با محاسبه دوز، که می تواند دوز محاسبه شده در یک الگوریتم را با سرعت و دقت بالا به الگوریتم دیگری تبدیل کند، اجرا شود. CNN همچنین در حال مطالعه است تا در ادغام با CT معمولی بتواند جایگزینی بالقوه برای درمان پرتو پروتون پروستات مبتنی بر MRI باشد. CNN همچنین در حال مطالعه است تا برای ردیابی مرز تومور در MRI برای سرطان ریه اجرا شود.

### 5.3. تایید رادیوتراپی و نظارت بر بیمار

IMRT به شدت به دقت و موقعیت هر پرتو تابشی وابسته است. تجزیه و تحلیل گاما روش استاندارد برای تجزیه و تحلیل صحت IMRT است. از شاخص آماری گاما برای مقایسه توزیع دوز اندازه گیری شده با توزیع دوز برنامه ریزی شده استفاده می شود. تجزیه و تحلیل گاما با بسیاری از انحرافات مرتبط بالینی در دوز تحویلی ارتباطی ندارد و نسبت به خطاهای کوچک موقعیتی کولیماتور چند برگی توجهی ندارد. روشی برای تشخیص خطاهای خاص با استفاده از ویژگی های تصویر در تصویر گاما توسعه پیدا کرد. این روش توزیع گاما را به عنوان یک تصویر در نظر می گیرد و از ارزیابی ویژگی روی تصویر بیمار برای پیش بینی پیش آگهی ها، پاسخ به درمان و سایر پیامدها استفاده می کند. این مدل با استفاده از 186 پرتو IMRT از 23 بیمار مورد مطالعه قرار گرفت که نیمی از آنها سرطان سر و گردن و بقیه سرطان رکتوم، سرطان ریه، گلیوپلاستوما و سارکوم داشتند.

شبکه بیزی و میدان تصادفی مارکوف دو مدل گراف رایج کاربردی هستند. کالت و دیگران از مدل شبکه بیزی برای تشخیص خطا در رادیوتراپی TP استفاده کردند. مجموعه اطلاعات اولیه بالینی و سیستم پایگاه داده بالینی مبتنی بر آنکولوژی پرتوافکنی، با احتمال به دست آوردن برخی پارامترهای معین پرتودرمانی با استفاده از شبکه محاسبه می شود. یک احتمال ضعیف در سیگنال های شبکه تکثیر شده برای خطای ناشناخته علامتی است که باید بررسی شود. سپس عملکرد شبکه با متخصصان انسانی مقایسه شد و در مورد سرطان مغز، شبکه از متخصصان انسانی بهتر عمل کرد. روش شبکه بیزی را می توان برای تشخیص خطاهای دستور پزشک پرتودرمانی استفاده کرد. چانگ و دیگران نشان دادند که با استفاده از روش شبکه بیزی میانگین نرخ مثبت درست و غلط 98.72٪ و 1.99٪ خطا بوده است که قابل مقایسه با تشخیص خطای انسانی است و می تواند خطای دستور پزشک را به دقت تشخیص دهد.

کارارا و دیگران نشان دادند که ANN را می توان برای پیش بینی هر نقطه پایانی انتخاب شده حاد یا دیررس مسمومیت زایی پس از پرتودرمانی پروستات استفاده کرد. از LDA در مطالعات متعدد رادیوتراپی و کاربردهایی مانند شناسایی ژن های پیش گوینده با استفاده از داده های ریزآرایه ژنومی از بیماران مبتلا به سرطان پروستات تا مطالعه خستگی مرتبط با سرطان؛ و ارتباط بین میکروارگانیزم روده و اسهال ناشی از شیمی درمانی از رژیم غذایی CapeOX در بیماران سرطان روده بزرگ برداشته شده مرحله III استفاده می شود.

### 4. ایرادات فعلی و عملکردهای آینده

پیشرفت در الگوریتم های یادگیری عمیق به AI اجازه داده است تا مسافت چشمگیری جلو برود و در امور متعدد بالینی اجرا شوند. آنها از نظر آماری قابل ملاحظه هستند اما از نظر فردی به دلیل غیر قابل اعتماد بودن در موارد معینی از کامل بودن فاصله دارند و مستعد اشتباهاتی هستند که یک انسان مرتکب نمی شود. بسیاری از روش های یادگیری AI به مجموعه داده های بزرگی نیاز دارند و اغلب در دسترس نیستند یا بسیار گران هستند یا توسط حقوق مالکیت معنوی محافظت می شوند. این الگوریتم همچنین برای صحت کار قبل از اجرای بالینی به آزمایش گسترده نیاز دارد که اغلب وقت گیر و گران است؛ با این حال AI نوید بزرگی به آینده نشان می دهد. ایراد بزرگ دیگر برای اجرای روش AI در طب بالینی دلایل حقوقی و اخلاقی است: که اگر بنا به دلایلی AI در ارائه خروجی صحیح موفق نشود، چه کسی مسئولیت اشتباه را بر عهده خواهد گرفت؟ بسیاری از سیستم های CAD فعلی برای آزمایش و آموزش به تصویر تشخیصی با کیفیت بالا نیاز دارند که غالباً به دلیل هزینه و در دسترس بودن از یک انستیتو تهیه می شوند که این امر می تواند نتایج قابل قبول سیستم CAD را به خطر



بیندازد. انتظار می رود که در آینده روش یادگیری عمیق با سیستم های CAD که دقت و قابلیت اطمینان آن افزایش بیشتری یافته، اجرا شود. AI در ماموگرافی پیشرفت زیادی کرده است و نشان داده که اساساً ظرفیت بسیار امیدوارکننده ای را برای داشتن سیستم کاملاً خودکار CAD در کاربردهای بالینی دارد.

### ۵. نتیجه گیری

با وجود این که AI دارای ظرفیت نامحدودی در رادیوتراپی است؛ با این حال هنوز به طور کامل تنظیم نشده است تا بتواند به تنهایی و به طور گسترده در بالینی مورد استفاده قرار گیرد. هم اکنون در برخی از موارد تشخیصی عملی شده است؛ با این حال نیاز به کارهای بیشتری وجود دارد. در آینده با تحقیق و توسعه بیشتر انتظار می رود که AI حجم کار گسترده ای را از کادر پرتوافکنی شامل رادیوتراپیست ها، فیزیکدانان پزشکی و انکولوژیست های پرتوافکنی در پرتودرمانی بردارد.

### منابع و مراجع

1. Hamet P, Tremblay J. Artificial intelligence in medicine. *Metabolism*. 2017;69:S36–S40, <http://dx.doi.org/10.1016/j.metabol.2017.01.011>.
2. Mintz Y, Brodie R. Introduction to artificial intelligence in medicine. *Minim Invasive Ther Allied Technol*. 2019;28(2):73–81, <http://dx.doi.org/10.1080/13645706.2019.1575882>.
3. Johnson KW, Torres Soto J, Glicksberg BS, et al. Artificial intelligence in cardiology. *J Am Coll Cardiol*. 2018;71(23):2668–2679, <http://dx.doi.org/10.1016/j.jacc.2018.03.521>.
4. Hosny A, Parmar C, Quackenbush J, Schwartz LH, Aerts HJWL. Artificial intelligence in radiology. *Nat Rev Cancer*. 2018;18(8):500–510, <http://dx.doi.org/10.1038/s41568-018-0016-5>.
5. Steinberg MH. Clinical trials in sickle cell disease: adopting the combination chemotherapy paradigm. *Am J Hematol*. 2008;83(1):1–3, <http://dx.doi.org/10.1002/ajh.21033>.
6. Baskar R, Lee KA, Yeo R, Yeoh KW. Cancer and radiation therapy: current advances and future directions. *Int J Med Sci*. 2012;9(3):193–199, <http://dx.doi.org/10.7150/ijms.3635>.
7. Khoo VS. Radiotherapeutic techniques for prostate cancer, dose escalation and brachytherapy. *Clin Oncol*. 2005;17(7):560–571, <http://dx.doi.org/10.1016/j.clon.2005.07.006>.
8. Zaidi H, Veas H, Wissmeyer M. Molecular PET/CT imaging-guided radiation therapy treatment planning. *Acad Radiol*. 2009;16(9):1108–1133, <http://dx.doi.org/10.1016/j.acra.2009.02.014>.
9. Moody A, Brody H, Grayson M, et al. *OUTLOOK*; 2012:115.
10. De Felice F, Piccioli A, Musio D, Tombolini V. The role of radiation therapy in bone metastases management. *Oncotarget*. 2017;8(15):25691–25699, <http://dx.doi.org/10.18632/oncotarget.14823>.
11. Deshmukh P, Levy MS. Effective radiation dose in coronary imaging modalities: back to Basics. *Catheter Cardiovasc Interv*. 2015;85(7):1182–1183, <http://dx.doi.org/10.1002/ccd.26013>.
12. Weissleder R, Nahrendorf M. Advancing biomedical imaging. *Proc Natl Acad Sci USA*. 2015;112(47):14424–14428, <http://dx.doi.org/10.1073/pnas.1508524112>.
13. Li G, Citrin D, Camphausen K, et al. Advances in 4D medical imaging and 4D radiation therapy. *Technol Cancer Res Treat*. 2008;7(1):67–81, <http://dx.doi.org/10.1177/153303460800700109>.
14. Van De Bunt L, Van Der Heide UA, Ketelaars M, De Kort GAP, Jürgenliemk-Schulz IM. Conventional, conformal, and intensity-modulated radiation therapy treatment planning of external beam radiotherapy for cervical cancer: the impact of tumor regression. *Int J Radiat Oncol Biol Phys*. 2006;64(1):189–196, <http://dx.doi.org/10.1016/j.ijrobp.2005.04.025>.
15. Nwankwo O, Mekdash H, Sihono DSK, Wenz F, Glatting G. Knowledge-based radiation therapy (KBRT) treatment planning versus planning by experts: validation of a KBRT algorithm for prostate cancer treatment planning. *Radiat Oncol*. 2015;10(1):1–5, <http://dx.doi.org/10.1186/s13014-015-0416-6>.
16. Miras H, Jiménez R, Perales Á, et al. Monte Carlo verification of radiotherapy treatments with CloudMC. *Radiat Oncol*. 2018;13(1):1–9, <http://dx.doi.org/10.1186/s13014-018-1051-9>.

17. Wroe AJ, Bush DA, Schulte RW, Slater JD. Clinical immobilization techniques for proton therapy. *Technol Cancer Res Treat*. 2014;14(1):71–79, <http://dx.doi.org/10.7785/tcrt.2012.500398>.
18. Shaverdian N, Verruttipong D, Wang PC, et al. Exploring value from the patient's perspective between modern radiation therapy modalities for localized prostate cancer. *Int J Radiat Oncol Biol Phys*. 2017;97(3):516–525, <http://dx.doi.org/10.1016/j.ijrobp.2016.11.007>.
19. McDonald DG, Jacqmin DJ, Mart CJ, et al. Validation of a modern second-check dosimetry system using a novel verification phantom. *J Appl Clin Med Phys*. 2017;18(1):170–177, <http://dx.doi.org/10.1002/acm2.12025>.
20. Bzdok D, Krzywinski M, Altman N. Points of significance: machine learning: supervised methods. *Nat Methods*. 2018;15(1):5–6, <http://dx.doi.org/10.1038/nmeth.4551>.
21. Lopez C, Tucker S, Salameh T, Tucker C. An unsupervised machine learning method for discovering patient clusters based on genetic signatures. *J Biomed Inform*. 2018;85(2017):30–39, <http://dx.doi.org/10.1016/j.jbi.2018.07.004>.
22. Amari S. Machine learning. *Appl Math Sci*. 2016;194:231–278, [http://dx.doi.org/10.1007/978-4-431-55978-8\\_11](http://dx.doi.org/10.1007/978-4-431-55978-8_11).
23. Hoi SCH, Jin R, Zhu J, Lyu MR. Semisupervised SVM batch mode active learning with applications to image retrieval. *ACM Trans Inf Syst*. 2009;27(3):1–29, <http://dx.doi.org/10.1145/1508850.1508854>.
24. Wang S, Summers RM. Machine learning and radiology. *Med Image Anal*. 2012;16(5):933–951, <http://dx.doi.org/10.1016/j.media.2012.02.005>.
25. Wen J, Fang X, Cui J, et al. Robust sparse linear discriminant analysis. *IEEE Trans Circuits Syst Video Technol*. 2019;29(2):390–403, <http://dx.doi.org/10.1109/TCSVT.2018.2799214>.
26. Berrendero JR, Cárcamo J. Linear Components of Quadratic Classifiers. Berlin, Heidelberg: Springer; 2019:13, <http://dx.doi.org/10.1007/s11634-018-0321-6>.
27. Yao X. Evolving artificial neural networks. *Proc IEEE*. 1999;87(9):1423–1447, <http://dx.doi.org/10.1109/5.784219>.
28. Krogh A. What are artificial neural networks? *Nat Biotechnol*. 2008;26(2):195–197, <http://dx.doi.org/10.1038/nbt1386>.
29. Hofmann T, Schölkopf B, Smola AJ. Kernel methods in machine learning. *Ann Stat*. 2008;36(3):1171–1220 <http://www.jstor.org/stable/25464664>.
30. Peng J, Zhou Y, Chen CLP. Region-kernel-based support vector machines for hyperspectral image classification. *IEEE Trans Geosci Remote Sens*. 2015;53(9):4810–4824, <http://dx.doi.org/10.1109/TGRS.2015.2410991>.
31. Ghahramani Z. Probabilistic machine learning and artificial intelligence. *Nature*. 2015;521(7553):452–459, <http://dx.doi.org/10.1038/nature14541>.
32. Ergul U, Bilgin G. Multiple-instance ensemble learning for hyperspectral images. *J Appl Remote Sens*. 2017;11(4):1, <http://dx.doi.org/10.1117/1.jrs.11.045009>.
33. Simpson I.J.A., Woolrich M.W., Andersson J.R., Groves A.R., Schnabel J., Uncertain Registration 2013;32(4):748–756.
34. Dharshinni NP, Azmi F, Fawwaz I, Husein AM, Siregar SD. Analysis of accuracy K-means and apriori algorithms for patient data clusters. *J Phys Conf Ser*. 2019;1230:012020, <http://dx.doi.org/10.1088/1742-6596/1230/1/012020>.
35. Xie N, Miao Z, Wang J, Zhang Q. Adaptive DBSCAN algorithm based on sample density gradient. *J Phys Conf Ser*. 2019;1229(1), <http://dx.doi.org/10.1088/1742-6596/1229/1/012056>.
36. Viroli C, McLachlan GJ. Deep Gaussian mixture models. *Stat Comput*. 2019;29(1):43–51, <http://dx.doi.org/10.1007/s11222-017-9793-z>.
37. Niyazi M, Niemierko A, Paganetti H, et al. Volumetric and actuarial analysis of brain necrosis in proton therapy using a novel mixture cure model. *Radiother Oncol*. 2019, <http://dx.doi.org/10.1016/j.radonc.2019.09.008>.

38. Lee SD, Lee JH, Choi YG, You HC, Kang JH, Jun CH. Machine learning models based on the dimensionality reduction of standard automated perimetry data for glaucoma diagnosis. *Artif Intell Med*. 2019;94(2016):110–116, <http://dx.doi.org/10.1016/j.artmed.2019.02.006>.
39. Hira ZM, Gillies DF. A review of feature selection and feature extraction methods applied on microarray data. *Adv Bioinformatics*. 2015;2015(1), <http://dx.doi.org/10.1155/2015/198363>.
40. Williams S. Pearson's correlation coefficient. *N Z Med J*. 1996;109(1015):38, <http://dx.doi.org/10.1136/bmj.e4483>.
41. Adler J, Parmryd I. Quantifying colocalization by correlation: the pearson correlation coefficient is superior to the Mander's overlap coefficient. *Cytom Part A*. 2010;77(8):733–742, <http://dx.doi.org/10.1002/cyto.a.20896>.
42. Gao T, Ji Q. Efficient markov blanket discovery and its application. *IEEE Trans Cybern*. 2017;47(5):1169–1179, <http://dx.doi.org/10.1109/TCYB.2016.2539338>.
43. Yu K, Liu L, Li J, Chen H. Mining markov blankets without causal sufficiency. *IEEE Trans Neural Networks Learn Syst*. 2018;29(12):6333–6347, <http://dx.doi.org/10.1109/TNNLS.2018.2828982>.
44. Che J, Yang Y, Li L, Bai X, Zhang S, Deng C. Maximum relevance minimum common redundancy feature selection for nonlinear data. *Inf Sci (NY)*. 2017;409-410:68–86, <http://dx.doi.org/10.1016/j.ins.2017.05.013>.
45. Radovic M, Ghalwash M, Filipovic N, Obradovic Z. Minimum redundancy maximum relevance feature selection approach for temporal gene expression data. *BMC Bioinformatics*. 2017;18(1):1–15, <http://dx.doi.org/10.1186/s12859-016-1423-9>.
46. Bharti KK, Singh PK. Hybrid dimension reduction by integrating feature selection with feature extraction method for text clustering. *Expert Syst Appl*. 2015;42(6):3105–3114, <http://dx.doi.org/10.1016/j.eswa.2014.11.038>.
47. Rasmus Broa AKS. Principal component analysis Tutorial Review. *Anal Methods*. 2014;6:1–16, <http://dx.doi.org/10.1002/wics.101>.
48. Gottesman O, Johansson F, Komorowski M, et al. Guidelines for reinforcement learning in healthcare. *Nat Med*. 2019;25(1):16–18, <http://dx.doi.org/10.1038/s41591-018-0310-5>.
49. Wang L, Liu Y, Zhai X. Design of reinforce learning control algorithm and verified in inverted pendulum. *Chinese Control Conf CCC*. 2015:3164–3168, <http://dx.doi.org/10.1109/ChiCC.2015.7260128>.
50. Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning. *Nature*. 2015;518(7540):529–533, <http://dx.doi.org/10.1038/nature14236>.
51. Poursaeidi MH, Kundakcioglu OE. Robust support vector machines for multiple instance learning. *Ann Oper Res*. 2014;216(1):205–227, <http://dx.doi.org/10.1007/s10479-012-1241-z>.
52. Tomar D, Agarwal S. Multiple instance learning based on twin support vector machine. *Adv Intell Syst Comput*. 2017;553:497–507, [http://dx.doi.org/10.1007/978-981-10-3770-2\\_46](http://dx.doi.org/10.1007/978-981-10-3770-2_46).
53. Caetano TS, McAuley JJ, Cheng L, Le QV, Smola AJ. Learning graph matching. *IEEE Trans Pattern Anal Mach Intell*. 2009;31(6):1048–1058, <http://dx.doi.org/10.1109/TPAMI.2009.28>.
54. Leordeanu M, Sukthankar R, Hebert M. Unsupervised learning for graph matching. *Int J Comput Vis*. 2012;96(1):28–45, <http://dx.doi.org/10.1007/s11263-011-0442-2>.
55. Goodfellow I. Deep learning(working version). *Nat Publ Gr*. 2011;13(1):35, <http://dx.doi.org/10.1038/nmeth.3707>.
56. Lecun Y, Bengio Y, Hinton G. Deep learning. *Nature*. 2015;521(7553):436–444, <http://dx.doi.org/10.1038/nature14539>.
57. Schmidhuber J. Deep learning in neural networks: an overview. *Neural Networks*. 2015;61:85–117, <http://dx.doi.org/10.1016/j.neunet.2014.09.003>.
58. Meyer P, Noblet V, Mazzara C, Lallement A. Survey on deep learning for radiotherapy. *Comput Biol Med*. 2018;98(May):126–146, <http://dx.doi.org/10.1016/j.combiomed.2018.05.018>.

59. Sun Y, Yen GG, Yi Z. Evolving unsupervised deep neural networks for learning meaningful representations. *IEEE Trans Evol Comput.* 2019;23(1):89–103, <http://dx.doi.org/10.1109/TEVC.2018.2808689>.
60. Gu J, Wang Z, Kuen J, et al. Recent advances in convolutional neural networks. *Pattern Recognit.* 2018;77:354–377, <http://dx.doi.org/10.1016/j.patcog.2017.10.013>.
61. Heismann BJ, Schmidt BT, Flohr TG. Spectral Computed Tomography. *SPIE;* 2012, <http://dx.doi.org/10.1117/3.977546>.
62. Kilcoyne RF, Richardson ML, Porter BA, Olson DO, Greenlee TK, Lanzer W. Magnetic resonance imaging of soft tissue masses. *Clin Orthop Relat Res.* 1988;52(228):13–19, <http://dx.doi.org/10.1053/j.ro.2017.04.003>.
63. Ahrens ET, Bulte JWM. Tracking immune cells in vivo using magnetic resonance imaging. *Nat Rev Immunol.* 2013;13(10):755–763, <http://dx.doi.org/10.1038/nri3531>.
64. Koch KM, Hargreaves BA, Pauly KB, Chen W, Gold GE, King KF. Magnetic resonance imaging near metal implants. *J Magn Reson Imaging.* 2010;32(4):773–787, <http://dx.doi.org/10.1002/jmri.22313>.
65. Mushtaq N, To K, Gooding C, Khan W. Radiological imaging evaluation of the failing total hip replacement. *Front Surg.* 2019;6(June):1–13, <http://dx.doi.org/10.3389/fsurg.2019.00035>.
66. Geis JR, Brady AP, Wu CC, et al. Ethics of artificial intelligence in radiology: summary of the joint European and North American multisociety statement. *Can Assoc Radiol J.* 2019:1–6, <http://dx.doi.org/10.1016/j.carj.2019.08.010>.
67. Hall WA, Paulson ES, van der Heide UA, et al. The transformation of radiation oncology using real-time magnetic resonance guidance: a review. *Eur J Cancer.* 2019;122:42–52, <http://dx.doi.org/10.1016/j.ejca.2019.07.021>.
68. Pratondo A, Chui CK, Ong SH. Integrating machine learning with region-based active contour models in medical image segmentation. *J Vis Commun Image Represent.* 2017;43(1):1–9, <http://dx.doi.org/10.1016/j.jvcir.2016.11.019>.
69. Zhang Z, Sejdic' E. Radiological images and machine learning: trends, perspectives, and prospects. *Comput Biol Med.* 2019;108(2018):354–370, <http://dx.doi.org/10.1016/j.combiomed.2019.02.017>.
70. Despotovic' I, Goossens B, Philips W. MRI segmentation of the human brain: challenges, methods, and applications. *Comput Math Methods Med.* 2015;2015, <http://dx.doi.org/10.1155/2015/450341>.
71. Wang G, Li W, Zuluaga MA, et al. Interactive medical image segmentation using deep learning with image-specific fine tuning. *IEEE Trans Med Imaging.* 2018;37(7):1562–1573, <http://dx.doi.org/10.1109/TMI.2018.2791721>.
72. Xu Y, Wang Y, Yuan J, Cheng Q, Wang X, Carson PL. Medical breast ultrasound image segmentation by machine learning. *Ultrasonics.* 2019;91(2018):1–9, <http://dx.doi.org/10.1016/j.ultras.2018.07.006>.
73. Polan DF, Brady SL, Kaufman RA. Tissue segmentation of computed tomography images using a random forest algorithm: a feasibility study. *Phys Med Biol.* 2016;61(17):6553–6569, <http://dx.doi.org/10.1088/0031-9155/61/17/6553>.
74. Sethi G, Saini BS. Computer aided diagnosis system for abdomen diseases in computed tomography images. *Biocybern Biomed Eng.* 2016;36(1):42–55, <http://dx.doi.org/10.1016/j.bbe.2015.10.008>.
75. Oliveira FPM, Tavares JMRS, Oliveira FPM, Manuel J, Medical RST. Computer methods in biomechanics and biomedical engineering medical image registration: a review. *Comput Methods Biomech Biomed Engin.* 2016;17(2):73–93, <http://dx.doi.org/10.1080/10255842.2012.670855>.
76. Kirienko M, Cozzi L, Rossi A, et al. Ability of FDG PET and CT radiomics features to differentiate between primary and metastatic lung lesions. *Eur J Nucl Med Mol Imaging.* 2018;45(10):1649–1660, <http://dx.doi.org/10.1007/s00259-018-3987-2>.

77. Lu L, Shin H, Roth HR, et al. Deep convolutional neural networks for computer-aided detection : CNN architectures. IEEE Trans Med Imaging. 2016;35(5):1285–1298, <http://dx.doi.org/10.1109/TMI.2016.2528162>.
78. Roth HR, Lu L, Liu J, et al. Improving computer-aided detection using convolutional neural networks and random view aggregation. IEEE Trans Med Imaging. 2016;35(5):1170–1181, <http://dx.doi.org/10.1109/TMI.2015.2482920>.
79. Vinsard DG, Mori Y, Misawa M, et al. Quality assurance of computeraided detection and diagnosis in colonoscopy. Gastrointest Endosc. 2019;90(1):55–63, <http://dx.doi.org/10.1016/j.gie.2019.03.019>.
80. Litjens G, Debats O, Barentsz J, Karssemeijer N, Huisman H. Computeraided detection of prostate cancer in MRI. IEEE Trans Med Imaging. 2014;33(5):1083–1092, <http://dx.doi.org/10.1109/TMI.2014.2303821>.
81. Kooi T, Litjens G, van Ginneken B, et al. Large scale deep learning for computer aided detection of mammographic lesions. Med Image Anal. 2017;35:303–312, <http://dx.doi.org/10.1016/j.media.2016.07.007>.
82. Nicolae A, Morton G, Chung H, et al. Evaluation of a machine-learning algorithm for treatment planning in prostate low-dose-rate brachytherapy. Int J Radiat Oncol Biol Phys. 2017;97(4):822–829, <http://dx.doi.org/10.1016/j.ijrobp.2016.11.036>.
83. Smith WP, Doctor J, Meyer J, Kalet IJ, Phillips MH. A decision aid for intensity-modulated radiation-therapy plan selection in prostate cancer based on a prognostic Bayesian network and a Markov model. Artif Intell Med. 2009;46(2):119–130, <http://dx.doi.org/10.1016/j.artmed.2008.12.002>.
84. Guidi G, Maffei N, Vecchi C, et al. Expert system classifier for adaptive radiation therapy in prostate cancer. Australas Phys Eng Sci Med. 2017;40(2):337–348, <http://dx.doi.org/10.1007/s13246-017-0535-5>.
85. Kajikawa T, Kadoya N, Ito K, et al. Automated prediction of dosimetric eligibility of patients with prostate cancer undergoing intensity-modulated radiation therapy using a convolutional neural network. Radiol Phys Technol. 2018;11(3):320–327, <http://dx.doi.org/10.1007/s12194-018-0472-3>.
86. Coates J, Souhami L, El Naqa I. Big data analytics for prostate radiotherapy. Front Oncol. 2016;6(Jun):1–17, <http://dx.doi.org/10.3389/fonc.2016.00149>.
87. Valdes G, Wojtowicz L, Pattison AJ, et al. OC-0253: machine learning based enables data-driven radiotherapy treatment planning decision support. Radiother Oncol. 2017;123:S127–S128, [http://dx.doi.org/10.1016/s0167-8140\(17\)30696-5](http://dx.doi.org/10.1016/s0167-8140(17)30696-5).
88. Cho DD, Wernicke AG, Nori D, Chao KC, Chang J, Parashar B. Predicting radiation therapy outcome for head and neck cancer patients using artificial neural network (ANN). Int J Radiat Oncol. 2014;90(1):S852, <http://dx.doi.org/10.1016/j.ijrobp.2014.05.2442>.
89. Ochi T, Murase K, Fujii T, Kawamura M, Ikezoe J. Survival prediction using artificial neural networks in patients with uterine cervical cancer treated by radiation therapy alone. Int J Clin Oncol. 2002;7(5):294–300, <http://dx.doi.org/10.1007/s101470200043>.
90. Zhen X, Chen J, Zhong Z, et al. Deep convolutional neural networks with transfer learning for rectum toxicity prediction in combined brachytherapy and external beam radiation therapy for cervical cancer. Int J Radiat Oncol. 2017;99(2):S168, <http://dx.doi.org/10.1016/j.ijrobp.2017.06.386>.
91. Ju E, Kim KH, Chang KH, et al. Artificial neural network-based variable importance analysis of prognostic factors related to radiation pneumonitis in patients with lung cancer: preliminary study. J Korean Phys Soc. 2019;75(4):277–282, <http://dx.doi.org/10.3938/jkps.75.277>.
92. Aneja S, Shaham U, Kumar RJ, et al. Deep neural network to predict local failure following stereotactic body radiation therapy: integrating imaging and clinical data to predict outcomes. Int J Radiat Oncol. 2017;99(2):S47, <http://dx.doi.org/10.1016/j.ijrobp.2017.06.120>.
93. Friedrich T, Scholz U, Elsässer T, Durante M, Scholz M. Systematic analysis of RBE and related quantities using a database of cell survival experiments with ion beam irradiation. J Radiat Res. 2013;54(3):494–514, <http://dx.doi.org/10.1093/jrr/rrs114>.



94. Lin H, Liu T, Shi C, et al. Feasibility study of individualized optimal positioning selection for left-sided whole breast radiotherapy: DIBH or prone. *J Appl Clin Med Phys*. 2018;19(2):218–229, <http://dx.doi.org/10.1002/acm2.12283>.
95. Brindle JM, Trindade AA, Shah AP, et al. Linear regression model for predicting patient-specific total skeletal spongiosa volume for use in molecular radiotherapy dosimetry. *J Nucl Med*. 2006;47(11):1875–1883.
96. Cao N, Kalet AM, Young LA, et al. Predictors of cardiac and lung dose sparing in DIBH for left breast treatment. *Phys Medica*. 2019;67:27–33, <http://dx.doi.org/10.1016/j.ejmp.2019.09.240>.
97. Waligórski MPR, Grzanka L, Korcyl M, Olko P. A TPS kernel for calculating survival vs. depth: distributions in a carbon radiotherapy beam, based on Katz's cellular track structure theory. *Radiat Prot Dosimetry*. 2015;166(1- 4):347–350, <http://dx.doi.org/10.1093/rpd/ncv202>.
98. Jayarathna S, Manohar N, Ahmed MF, Krishnan S, Cho SH. Evaluation of dose point kernel rescaling methods for nanoscale dose estimation around gold nanoparticles using Geant4 Monte Carlo simulations. *Sci Rep*. 2019;9(1):3583, <http://dx.doi.org/10.1038/s41598-019-40166-9>.
99. Miura H, Ozawa S, Doi Y, et al. Automatic gas detection in prostate cancer patients during image-guided radiation therapy using a deep convolutional neural network. *Phys Medica*. 2019;64(1):24–28, <http://dx.doi.org/10.1016/j.ejmp.2019.06.009>.
100. Debus C, Oelfke U, Bartzsch S. A point kernel algorithm for microbeam radiation therapy. *Phys Med Biol*. 2017;62(21):8341–8359, <http://dx.doi.org/10.1088/1361-6560/aa8d63>.
101. Zhang X, Homma N, Ichiji K, et al. A kernel-based method for markerless tumor tracking in kV fluoroscopic images. *Phys Med Biol*. 2014;59(17):4897–4911, <http://dx.doi.org/10.1088/0031-9155/59/17/4897>.
102. Zhao W, Han B, Yang Y, et al. Incorporating imaging information from deep neural network layers into image guided radiation therapy (IGRT). *Radiother Oncol*. 2019;140:167–174, <http://dx.doi.org/10.1016/j.radonc.2019.06.027>.
103. Bangert M, Oelfke U. Spherical cluster analysis for beam angle optimization in intensity-modulated radiation therapy treatment planning. *Phys Med Biol*. 2010;55(19):6023–6037, <http://dx.doi.org/10.1088/0031-9155/55/19/025>.
104. Douglass M, Bezak E, Penfold S. Development of a radiation track structure clustering algorithm for the prediction of DNA DSB yields and radiation induced cell death in Eukaryotic cells. *Phys Med Biol*. 2015;60(8):3217–3236, <http://dx.doi.org/10.1088/0031-9155/60/8/3217>.
105. Francis Z, Seif E, Incerti S, et al. Carbon ion fragmentation effects on the nanometric level behind the Bragg peak depth. *Phys Med Biol*. 2014;59(24):7691–7702, <http://dx.doi.org/10.1088/0031-9155/59/24/7691>.
106. Meylan S, Incerti S, Karamitros M, et al. Simulation of early DNA damage after the irradiation of a fibroblast cell nucleus using Geant4-DNA. *Sci Rep*. 2017;7(1):1–16, <http://dx.doi.org/10.1038/s41598-017-11851-4>.
107. Cui S, Luo Y, Jolly S, Ten Haken RK, El Naqa I. Prediction of local control in non-small cell lung cancer patients after radiation therapy by composite deep learning neural networks. *Int J Radiat Oncol*. 2018;102(3):S4–S5, <http://dx.doi.org/10.1016/j.ijrobp.2018.06.107>.
108. Dong P, Xing L. DoseNet: A Deep neural network for accurate dosimetric transformation between different spatial resolutions and/or different dose calculation algorithms for precision radiation therapy. *Int J Radiat Oncol*. 2019;105(1):S255–S256, <http://dx.doi.org/10.1016/j.ijrobp.2019.06.2471>.
109. Yang X, Liu Y, Lei Y, et al. MRI-based proton radiotherapy for prostate cancer using deep convolutional neural networks. *Int J Radiat Oncol*. 2019;105(1):S200, <http://dx.doi.org/10.1016/j.ijrobp.2019.06.263>.
110. Tahmasebi N, Boulanger P, Noga M, Punithakumar K. A fully convolutional deep neural network for lung tumor boundary tracking in MRI. *Conf Proc. Annu Int Conf IEEE Eng Med Biol Soc IEEE Eng Med Biol Soc Annu Conf*. 2018;2018:5906–5909, <http://dx.doi.org/10.1109/EMBC.2018.8513607>.

111. Wootton LS, Nyflot MJ, Chaovalitwongse WA, Ford E. Error detection in intensity-modulated radiation therapy quality assurance using radiomic analysis of gamma distributions. *Int J Radiat Oncol Biol Phys*. 2018;102(1):219–228, <http://dx.doi.org/10.1016/j.ijrobp.2018.05.033>.
112. Kalet AM, Gennari JH, Ford EC, Phillips MH. Bayesian network models for error detection in radiotherapy plans. *Phys Med Biol*. 2015;60(7):2735–2749, <http://dx.doi.org/10.1088/0031-9155/60/7/2735>.
113. Chang X, Li HH, Kalet AM, Yang D. Development and validation of a bayesian network method to detect external beam radiation therapy physician order errors. *Int J Radiat Oncol Biol Phys*. 2019;105(2):423–431, <http://dx.doi.org/10.1016/j.ijrobp.2019.05.034>.
114. Carrara M, Rancati T, Fiorino C, et al. A method to develop reliable “ready to use” graphical tools based on artificial neural networks for the prediction of toxicities after high dose prostate radiation therapy. *Int J Radiat Oncol*. 2015;93(3):E610–E611, <http://dx.doi.org/10.1016/j.ijrobp.2015.07.2106>.
115. Feng LR, Fernández-Martínez JL, Zaal KJM, Deandrés-Galiana EJ, Wolff BS, Saligan LN. MGLuR5 mediates post-radiotherapy fatigue development in cancer patients. *Transl Psychiatry*. 2018;8(1), <http://dx.doi.org/10.1038/s41398-018-0161-3>.
116. Fei Z, Lijuan Y, Xi Y, et al. Gut microbiome associated with chemotherapy-induced diarrhea from the CapeOX regimen as adjuvant chemotherapy in resected stage III colorectal cancer. *Gut Pathog*. 2019;11(1):1–10, <http://dx.doi.org/10.1186/s13099-019-0299-4>.
117. McBee MP, Awan OA, Colucci AT, et al. Deep learning in radiology. *Acad Radiol*. 2018;25(11):1472–1480, <http://dx.doi.org/10.1016/j.acra.2018.02.018>.
118. Långkvist M, Jendeberg J, Thunberg P, Loutfi A, Lidén M. Computer aided detection of ureteral stones in thin slice computed tomography volumes using convolutional neural networks. *Comput Biol Med*. 2018;97(February):153–160, <http://dx.doi.org/10.1016/j.compbiomed.2018.04.021>.
119. Acharya UR, Hagiwara Y, Deshpande SN, et al. Characterization of focal EEG signals: A review. *Futur Gener Comput Syst*. 2019;91:290–299, <http://dx.doi.org/10.1016/j.future.2018.08.044>.
120. Fuchsjäger M. Is the future of breast imaging with AI? *Eur Radiol*. 2019;4822–4824, <http://dx.doi.org/10.1007/s00330-019-06286-6>.



## Artificial intelligence in radiotherapy

Zahra ghasemi<sup>1</sup>, mohammad amin pirbonyeh<sup>2</sup>

Master of student of engineers faculty of Islamic azad university of kazerun-iran ,  
gh,Zahra21@gmail.com

Assistant professor of electricity group, engineers faculty of Islamic azad university of  
kazerun-iran , pirbonyeh@gmail.com

**Abstract** Artificial intelligence (AI) has already been implemented widely in the medical field in the recent years. This paper first reviews the background of AI and radiotherapy. Then it explores the basic concepts of different AI algorithms and machine learning methods, such as neural networks, that are available to us today and how they are being implemented in radiotherapy and diagnostic processes, such as medical imaging, treatment planning, patient simulation, quality assurance and radiation dose delivery. It also explores the ongoing research on AI methods that are to be implemented in radiotherapy in the future. The review shows very promising progress and future for AI to be widely used in various areas of radiotherapy.

**Keywords:** Artificial intelligence Machine learning Radiotherapy Medical imaging