

مروری بر روش‌های تشخیص و طبقه‌بندی سرطان پوست با استفاده از مدل‌های یادگیری عمیق

الهه جعفری، دانشجوی کاردانی گروه کامپیوتر (نرم‌افزار)، دانشگاه فنی حرفه‌ای، آموزش‌شده فنی حرفه‌ای دختران
نجف‌آباد (سمیه)، Elahej1318@gmail.com

مهشید دهقانپور*، دانشجوی دکترای هوش مصنوعی، استاد گروه کامپیوتر دانشگاه فنی حرفه‌ای، آموزش‌شده فنی -
حرفه‌ای دختران نجف‌آباد (سمیه)، Mahshid.Dehghanpour@shahroodut.ac.ir

هستی شهیدی، دانشجوی کاردانی گروه کامپیوتر (نرم‌افزار)، دانشگاه فنی حرفه‌ای، آموزش‌شده فنی حرفه‌ای دختران
نجف‌آباد (سمیه)، Hasti81h@gmail.com

احمد محمدی، کارشناسی ارشد نرم‌افزار، استاد گروه کامپیوتر دانشگاه فنی حرفه‌ای، آموزش‌شده فنی حرفه‌ای دختران
نجف‌آباد (سمیه)، Ahmadmohammadi59it@gmail.com

چکیده

سرطان پوست یکی از شایع‌ترین انواع سرطان بوده و سالانه میلیون‌ها نفر به این بیماری مبتلا می‌گردند که در این بین ملانوما به عنوان خطرناک‌ترین نوع سرطان پوست در میان مردم جهان تشخیص داده شده است. از آنجائیکه تشخیص زود هنگام سرطان پوست موجب کاهش مرگ و میر در جهان گردیده، لذا روش مرسوم برای تشخیص این سرطان، روش سنتی بیوپسی^۱ توسط پزشکان است. این تشخیص با نمونه برداری از ضایعه پوستی انجام شده که طی آن، نمونه اخذ شده تحت بررسی‌های گوناگون آزمایشگاهی قرار می‌گیرد. نظریه آنکه این روش برای بیماران دردناک و برای پزشکان بسیار وقت‌گیر می‌باشد، لذا تشخیص سرطان پوست به کمک الگوریتم‌های پردازش تصویر برای پزشکان و بیماران سودمندتر است. با توجه به اهمیت این مسئله، محققان در این زمینه روش‌های تشخیص زود هنگام مختلفی را توسعه داده‌اند. در این مقاله ابتدا به شرح مبانی تشخیص سرطان پوست (شامل مراحل تشخیص بیماری) پرداخته و در ادامه به بررسی روش‌های طبقه‌بندی^۲ آن می‌پردازد. از جمله روش‌های طبقه‌بندی سرطان پوست به کمک الگوریتم‌های پردازش تصویر در این پژوهش می‌توان از قانون ABCDE، روش چک لیست هفت نقطه‌ای، روش منزیس و تحلیل الگو یاد کرده و سپس مدل‌های تشخیص سرطان پوست به کمک الگوریتم‌های یادگیری عمیق از جمله ANN، CNN، KNN و GAN را مورد بحث و ارزیابی قرار می‌دهد. باتوجه به مطالعات اخیر مرتبط در این حوزه، به نظر می‌رسد قانون ABCDE یکی از پرکاربردترین روش‌های طبقه‌بندی تصاویر بوده و مدل^۳ CNN به عنوان بهترین مدل تشخیص سرطان پوست معرفی گردیده.

واژه‌های کلیدی: سرطان پوست، ملانوما، یادگیری عمیق، مدل CNN

* نویسنده مسئول

¹ Biopsy

² Classification

³ Techniques

۱- مقدمه

سرطان پوست یکی از فعال‌ترین انواع سرطان در دهه حاضر است [۱] و شایع‌ترین نوع سرطان بوده چرا که پوست بزرگترین اندام بدن می‌باشد [۲]. به طور کلی سرطان پوست به دو دسته ملانوما و غیرملانوما طبقه‌بندی می‌شود [۳]. ملانوما نوزدهمین سرطان شایع است و تعداد موارد آن، سالانه ۵۳ درصد افزایش یافته، یکی از دلایل آن قرار گرفتن در معرض اشعه ماوراء بنفش است [۴، ۵]. ملانوما یک نوع سرطان پوست نادر، خطرناک و کشنده است. با توجه به آمار انجمن سرطان آمریکا، موارد سرطان پوست ملانوم فقط ۱ درصد از کل موارد را تشکیل می‌دهد، اما میزان مرگ و میر آن بیشتر است [۶]. ملانوم در سلول‌هایی به نام ملانوسیت ایجاد می‌شود و زمانی شروع می‌شود که ملانوسیت‌های سالم شروع به رشد غیرقابل کنترل می‌کنند و تومور سرطانی ایجاد می‌کنند که می‌تواند هر ناحیه‌ای از بدن انسان را تحت تاثیر قرار دهد. معمولاً در نواحی مانند دست‌ها، صورت، گردن، لب‌ها و موارد دیگر که در معرض اشعه خورشید هستند ظاهر می‌شود. ملانوما را تنها در صورتی می‌توان درمان کرد که زود تشخیص داده شود، در غیر این صورت به دیگر اعضای بدن سرایت کرده و باعث مرگ دردناک بیمار می‌شود [۷]. ملانوما انواع مختلفی دارد، از جمله: ملانوم ندولر^۴، ملانوم سطحی گسترش یافته^۵، عدسی آکرال^۶ و لنتیگو بدخیم^۷ [۳]. اکثر موارد سرطان غیرملانومایی شامل کارسینوم سلول بازال^۸، کارسینوم سلول سنگفرشی^۹ و کارسینوم غدد سباسه^{۱۰} می‌باشد. سلول‌های سرطانی غیر ملانوما بسیار کم به سایر قسمت‌های بدن منتشر می‌شوند و در مقایسه با سرطان‌های ملانوما به آسانی قابل درمان هستند. بنابراین تشخیص زود هنگام سرطان پوست برای افزایش میزان بقا ضروری است [۸].

معمولاً معاینه بصری و مدل‌های دستی برای تشخیص سرطان استفاده می‌شود اما این تفسیر دستی از تصاویر پزشکی زمان‌بر و بسیار مستعد اشتباه است. به همین دلیل، در اوایل دهه ۱۹۸۰ سیستم‌های تشخیص کامپیوتری (CAD) برای کمک به پزشکان و بهبود کارایی تفسیر تصویر پزشکی ارائه شد [۹]. یکی از مزیت‌های یادگیری این است که مستقیماً از تصاویر خام ویژگی‌های سطح بالا ایجاد کند و نمایش دهد. علاوه بر یادگیری عمیق، از واحدهای پردازش گرافیکی (GPU) به صورت موازی برای استخراج ویژگی و تشخیص تصویر استفاده می‌شود [۱۰]. یادگیری عمیق در طول دهه‌های اخیر کل چشم‌انداز یادگیری ماشین را متحول کرده است و پیچیده‌ترین زیرشاخه یادگیری ماشینی است که با الگوریتم‌های شبکه عصبی مصنوعی مرتبط است. این الگوریتم‌ها از عملکرد و ساختار مغز انسان الهام گرفته‌اند. مدل‌های یادگیری عمیق در زمینه‌هایی مانند تشخیص گفتار [۲۳]، تشخیص الگو [۲۴] و بیوانفورماتیک [۲۵] اجرا می‌شوند. سیستم‌های یادگیری عمیق، در مقایسه با سایر رویکردهای کلاسیک یادگیری ماشین نتایج چشمگیری به دست آورده‌اند. در سال‌های اخیر از روش‌های یادگیری عمیق مختلفی برای تشخیص سرطان پوست مبتنی بر رایانه استفاده شده است [۸].

در این مقاله، مدل‌های تشخیص و طبقه‌بندی سرطان پوست با استفاده از الگوریتم‌های یادگیری عمیق، برای آسان‌تر شدن مسیر پژوهش محققان مورد بحث قرار داده شده است. هدف این مقاله مرور رویکردهای کلاسیک یادگیری عمیق برای تشخیص سرطان پوست و ارائه بهترین رویکرد است. این روش‌ها شامل شبکه‌های عصبی مصنوعی^{۱۱}، شبکه‌های عصبی کانولوشنال^{۱۲}، شبکه عصبی خودسازمانده کوهونن^{۱۳} و شبکه عصبی متخاصم مولد^{۱۴} می‌باشد.

به صورت خلاصه در این مقاله ابتدا مراحل تشخیص سرطان پوست و به دنبال آن روش‌های طبقه‌بندی سرطان پوست معرفی شده و مدل‌های یادگیری عمیق این بیماری شرح داده شده است، همچنین کارهای مرتبط با روش‌ها و رویکردهای تشخیص سرطان پوست ارائه شده

⁴ Nodular Melanoma

⁵ Superficial Spreading Melanoma

⁶ Acral Lentiginous

⁷ Lentigo Maligna

⁸ Basal Cell Carcinoma(BCC)

⁹ Squamous Cell Carcinoma(SCC)

¹⁰ Sebaceous Gland Carcinoma(SGC)

¹¹ Artificial Neural Network(ANN)

¹² Convolutional Neural Network(CNN)

¹³ Kohonen self-organizing Neural Network(KNN)

¹⁴ Generative Adversarial Network (GAN)

است. در بخش بعدی به معرفی معیارهای ارزیابی پرداخته شده، سپس دیتاست‌های سرطان پوست به صورت خلاصه معرفی گردیده و مطالعات اخیر محققان در به کارگیری از این دیتاست‌ها ارائه شده و در آخر مدل‌های یادگیری عمیق مورد ارزیابی قرار گرفته و بهترین مدل ارائه شده است.

۲- تئوری و پیشینه

۲-۱-۲- مراحل تشخیص سرطان پوست

۲-۱-۲-۱- پیش پردازش

تصاویر خام حاوی نویز هستند، بنابراین اولین مرحله در تشخیص سرطان پیش پردازش است، یعنی برای بهبود کیفیت تصویر، یکسری اطلاعات تصویر، که به عنوان نویزهای تصویر شناخته می‌شود حذف شود. اگر این موضوع به درستی انجام نشود، ممکن است چندین اشتباه در طبقه‌بندی رخ دهد. نویزهای تصویر با انجام کارهای پیش پردازشی مانند تنظیم کنتراست، حذف افکت رنگبندی، تصحیح رنگ، صاف کردن تصویر، حذف مو، نرمال سازی و محلی سازی، حذف یا تنظیم می‌شوند [۱۱].

۲-۱-۲-۲- تقسیم‌بندی تصویر

تقسیم تصویر ورودی به مناطقی که می‌توان اطلاعات لازم برای پردازش بیشتر را استخراج کرد، تقسیم‌بندی نامیده می‌شود. تقسیم‌بندی اساساً، جداسازی بخشی از تصویر که می‌خواهیم از آن استفاده کنیم (ROI) از پس زمینه تصویر است. در مورد تصاویر سرطانی، ما به قسمت ضایعه نیاز داریم تا ویژگی‌های آن را استخراج کنیم [۱۲].

۲-۱-۳- پس پردازش

پس از گذراندن مراحل پیش پردازش و تقسیم‌بندی تصویر، مرحله پس پردازش است که ویژگی‌ها در آن قرار می‌گیرند. رایج‌ترین روش‌های پس پردازش: عملیات باز و بسته شدن، حذف جزیره، ادغام منطقه، گسترش حاشیه و هموارسازی است. برخی از مدل‌های مورد استفاده برای استخراج ویژگی عبارتند از: تجزیه و تحلیل مؤلفه‌های اصلی^{۱۵}، تبدیل بسته موجک^{۱۶} [۱۴، ۱۳]، ماتریس همزمانی سطح خاکستری^{۱۷} [۱۵]، طیف توان فوریه^{۱۸} [۱۶]، هسته‌های مشتق گوسی^{۱۹} [۱۷] و ویژگی‌های مرز تصمیم^{۲۰} [۱۸].

۲-۱-۴- قانون ABCDE

تجزیه و تحلیل قانون ABCD به عدم تقارن^{۲۱}، حاشیه^{۲۲}، رنگ^{۲۳}، قطر^{۲۴} و تکامل^{۲۵} تصویر ضایعه اشاره دارد.

- عدم تقارن: تصویر ورودی به یک محور عمود بر هم تقسیم می‌شود به گونه‌ای که کمترین مقدار ممکن را برای نمره عدم تقارن می‌دهد. اگر عدم تقارن نسبت به محورها باشد، امتیاز ۲ خواهد بود. اگر روی یک محور نامتقارن باشد، امتیاز آن ۱ خواهد بود. هیچ نامتقارنی ۰ امتیاز نمی‌دهد.

¹⁵ Principle Component Analysis (PCA)

¹⁶ Wavelet Packet Transform (WPT)

¹⁷ Grey Level Co-occurrence Matrix (GLCM)

¹⁸ Fourier Power Spectrum (FPS)

¹⁹ Gaussian derivative kernels

²⁰ Decision boundary features

²¹ Asymmetry (A)

²² Border (B)

²³ Color (C)

²⁴ Diameter (D)

²⁵ Evolution (E)

- حاشیه: تصویر به هشت تقسیم می‌شود و برای تغییرات واضح و ناگهانی بررسی می‌شود. سپس، امتیاز بررسی می‌شود، جایی که یک برش تیز باشد نمره ۱ و به تدریج نمره ۰ می‌گیرد.
- رنگ: طیف‌هایی از رنگ‌ها برای تشخیص سرطان پوست وجود دارد: این رنگ‌ها سیاه و قهوه‌ای هستند، اما گاهی اوقات رنگ‌های سفید، قرمز یا صورتی نیز جزء طیف رنگ‌های تشخیص سرطان به شمار می‌روند.
- قطر: قطر ضایعه به دقت بررسی می‌شود. اگر قطر آن بزرگتر از ۶ میلی‌متر باشد، ملانوما است [۶۶].
- تکامل: ملانوما اغلب ویژگی‌هایی مانند اندازه، شکل یا رنگ را تغییر می‌دهد. برخلاف اکثر خال‌های خوش‌خیم، ملانوما در طول زمان تغییر می‌کند.

۲-۱-۵- روش چک لیست هفت نقطه ای^{۲۶}

طبقه‌بندی بر اساس معیارهای اصلی و فرعی انجام می‌شود. معیارهای اصلی دارای ۳ امتیاز هستند و هر امتیاز دارای ارزش ۲ امتیازی است، در حالی که معیارهای فرعی دارای ۴ امتیاز با ارزش ۱ امتیازی هستند. اگر مقدار امتیاز حداقل ۳ باشد، نتیجه طبقه‌بندی ملانوم بدخیم خواهد بود [۲۰].

۲-۱-۵-۱- معیارهای اصلی:

- حجاب آبی-سفید^{۲۷}: این‌ها لکه‌های آبی یا مه سفید در اطراف آن هستند که ساختار مشخصی ندارند.
- شبکه رنگدانه آتیپیک^{۲۸}: در این شبکه، ضایعه دارای توزیع نامتقارن همراه با خطوط مشبک در داخل خود است، در حالی که رنگ و ضخامت ماهیت ناهمگن دارند.
- الگوی عروقی آتیپیک^{۲۹}: این عروق کروی یا نقطه‌دار نامنظم هستند که دارای خطی بودن هستند.

۲-۱-۵-۲- معیارهای جزئی:

- گلبول‌ها/نقاط نامنظم: نقاط دارای شکل، رنگ و توزیع نامنظم با اندازه کمتر از ۰ و ۱ میلی‌متر هستند، در حالی که اندازه گلبول‌ها باید بیشتر از ۰ و ۱ میلی‌متر باشد.
- لکه‌های نامنظم: این مناطق دارای رنگ‌های مختلف سفید، سیاه یا قهوه‌ای و بدون شکل و ساختار مشخص هستند.
- رگ‌های نامنظم: هنگامی که ملانوم به صورت شعاعی شروع به رشد می‌کند، الگوی رگ‌های شعاعی و شبه‌پایه را تشکیل می‌دهد که در لبه‌های ضایعه قرار دارند.
- ساختارهای رگ‌سیون: ضایعه‌های پوستی سفید یا بدون رنگ هستند.

۲-۱-۶- روش منزیس

در روش منزیس چند ویژگی مثبت و ویژگی منفی وجود دارد. وجود هرگونه ویژگی منفی ملانوم بدخیم را اعلام می‌کند. اگر هر دو ویژگی منفی وجود نداشته باشد و یک یا چند ویژگی مثبت وجود داشته باشد، ملانوما خوش‌خیم خواهد بود [۲۰].

²⁶ Seven-Point Checklist Method

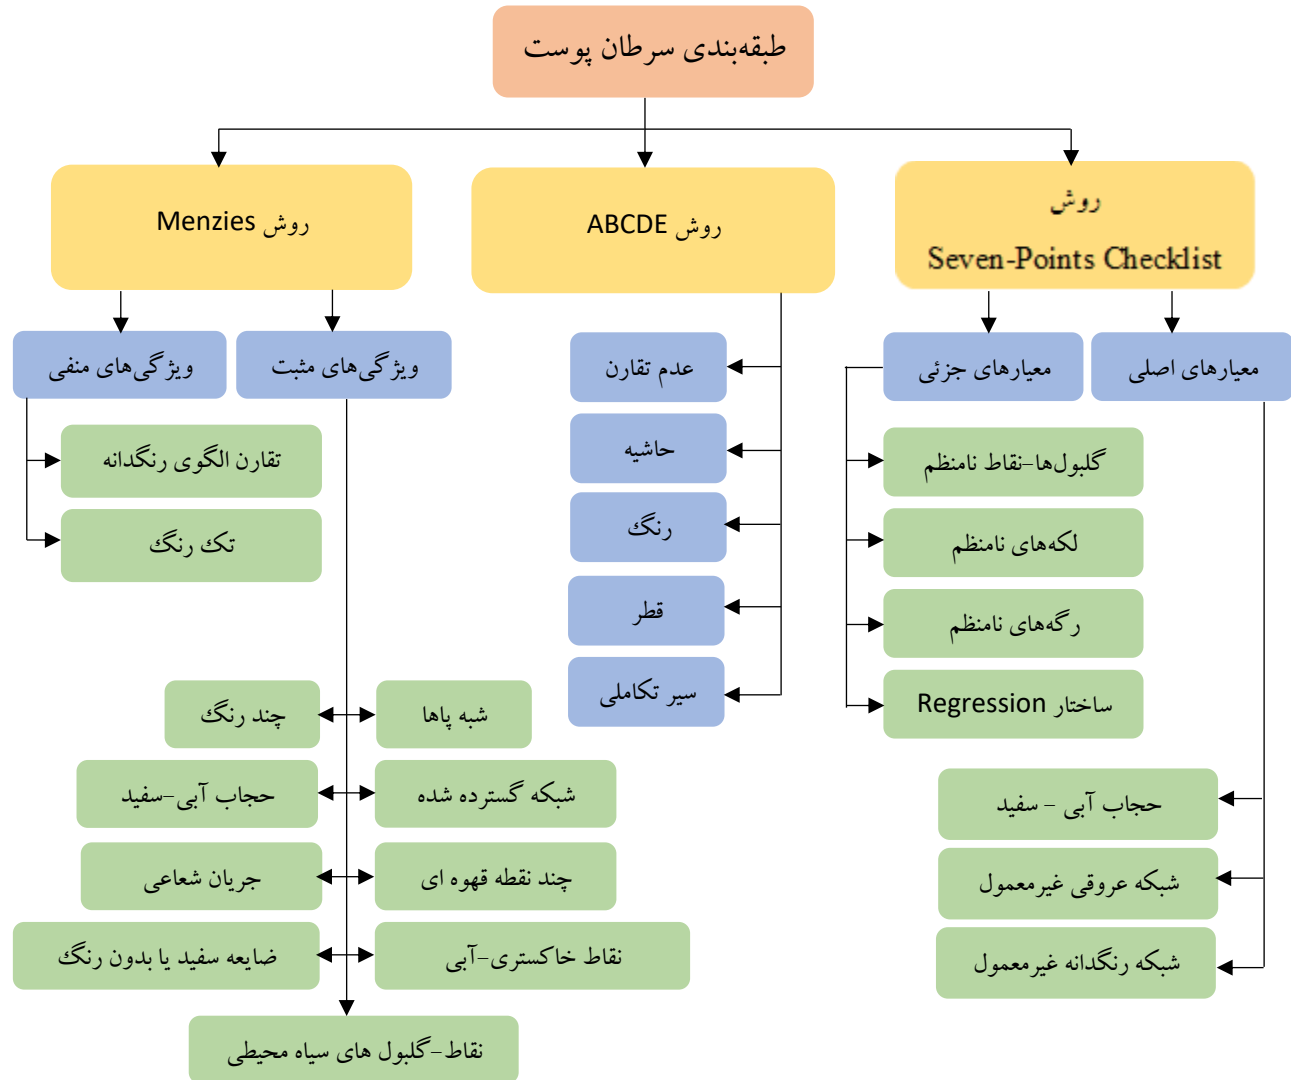
²⁷ Blue-white veil

²⁸ Atypical pigment network

²⁹ Atypical vascular pattern

- ویژگی‌های مثبت: حجاب آبی- سفید، ضایعه‌های سفید یا بدون رنگ^{۳۰}، چند رنگ، نقاط خاکستری و آبی، شبکه‌های گسترده، شبه پاها^{۳۱}، گلبول‌ها، جریان شعاعی، نقاط/گلبول‌های سیاه محیطی^{۳۲}، چند نقطه قهوه‌ای^{۳۳} [۶۷].
- ویژگی‌های منفی: تقارن ضایعه، حضور تک‌رنگ^{۳۴}.

شکل 1 بلوک دیاگرام خلاصه‌ای از روش‌های طبقه‌بندی سرطان پوست که معمولاً مورد استفاده قرار می‌گیرند را نشان می‌دهد.



شکل ۱- بلوک دیاگرام روش‌های طبقه‌بندی سرطان پوست

۷-۱-۲- تحلیل الگو

³⁰ Depigmentation like scars

³¹ Psuedopods

³² Peripheral Black Dots/Globules

³³ Multiple Brown Dots

³⁴ Single color presence

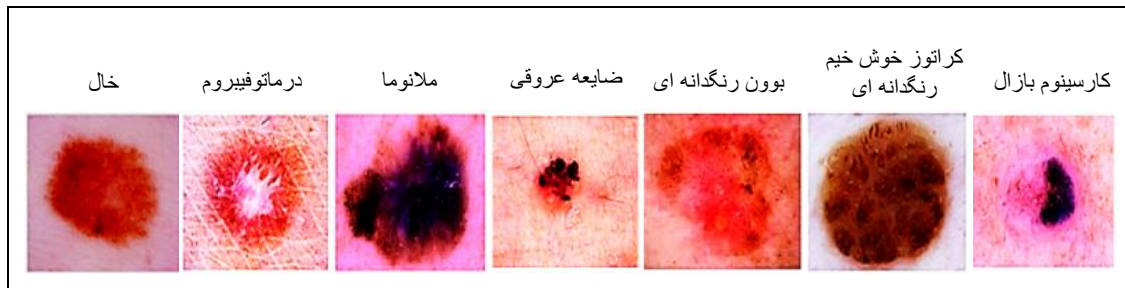
روشی مبتنی بر یافتن الگوهای محلی یا جهانی وجود دارد. الگوهای جهانی می‌توانند همگن، کروی، ستاره باران، مشبک، موازی چند جزئی یا سنگفرش^{۳۵} باشند. الگوهای محلی می‌تواند استیک‌های نامنظم^{۳۶}، رنگدانه ناکافی^{۳۷}، شبکه رنگدانه، ساختارهای رگرسیون، گلبول‌ها، نقاط سیاه، ساختارهای عروقی یا حجاب آبی-سفید باشد. اساس این روش ارزیابی کیفی معیارهای درموسکوپي به صورت جداگانه می‌باشد.

۳- مرور دسته‌بندی، تحلیل و مقایسه روش‌های انجام شده

۳-۱- مدل‌های یادگیری عمیق برای تشخیص سرطان پوست

شبکه‌های عصبی عمیق نقش مهمی در تشخیص سرطان پوست دارند. آنها مجموعه‌ای از گره‌های به هم پیوسته هستند. ساختار آنها از نظر ارتباط عصبی مشابه مغز انسان است. گره‌های آنها برای حل مشکلات خاص به طور مشترک کار می‌کنند. شبکه‌های عصبی برای وظایف خاصی آموزش دیده‌اند و به عنوان متخصص در حوزه‌هایی که در آن آموزش دیده‌اند کار می‌کنند.

انواع مختلف ضایعات پوستی از دیتاست‌های ISIC در شکل ۲ ارائه شده است.



شکل ۲- دسته بندی بیماری‌های پوستی از دیتاست‌های ISIC [۸]

۳-۱-۱- مدل‌های تشخیص سرطان پوست مبتنی بر شبکه عصبی مصنوعی^{۳۸}

شبکه عصبی مصنوعی یک روش پیش‌بینی غیرخطی و آماری است و ساختار آن از ساختار بیولوژیکی مغز انسان گرفته شده است. یک ANN از سه لایه نورون تشکیل شده است. لایه اول به عنوان لایه ورودی شناخته می‌شود. این نورون‌های ورودی داده‌ها را به لایه دوم یا میانی منتقل می‌کنند. لایه‌های میانی را لایه‌های پنهان می‌نامند. در یک ANN معمولی، چندین لایه پنهان می‌تواند وجود داشته باشد. نورون‌های میانی داده‌ها را به لایه سوم نورون‌های خروجی ارسال می‌کنند. محاسبات در هر لایه با استفاده از پس انتشار خطا آموخته می‌شوند، که برای یادگیری روابط پیچیده بین لایه‌های ورودی و خروجی استفاده می‌شود. این شبیه شبکه عصبی است. در حال حاضر در علوم کامپیوتر، اصطلاح شبکه عصبی و شبکه عصبی مصنوعی به جای یکدیگر استفاده می‌شود. ساختار اصلی یک شبکه ANN در شکل ۳ ارائه شده است.


ANN برای طبقه‌بندی ویژگی‌های استخراج شده در سیستم‌های تشخیص سرطان پوست استفاده می‌شود. تصاویر ورودی پس از آموزش (طبقه‌بندی موفق، مجموعه آموزشی) به عنوان ملانوم یا غیرملانوم طبقه‌بندی می‌شوند. تعداد لایه‌های پنهان در یک شبکه عصبی مصنوعی به تعداد تصاویر ورودی بستگی دارد. لایه ورودی ANN با لایه پنهان توسط دیتاست ورودی متصل می‌شود. دیتاست‌ها می‌توانند با برچسب یا بدون برچسب باشند، که می‌توان آن را با استفاده از یک مکانیسم یادگیری تحت نظارت پردازش کرد. یک شبکه عصبی برای یادگیری وزن‌های موجود در هر اتصال شبکه از پس انتشار خطا یا معماری feed-forward استفاده می‌کند. هر دو معماری از الگوی متفاوتی برای دیتاست‌های زیرین استفاده می‌کنند. شبکه‌های عصبی مبتنی بر معماری feed-forward، داده‌ها را تنها در یک جهت انتقال می‌دهند، یعنی داده‌ها فقط از لایه ورودی به خروجی جریان می‌یابد.

³⁵ Cobblestone

³⁶ Irregular steaks

³⁷ Inadequate pigmentation

³⁸ Artificial Neural Network(ANN)



شکل ۳- ساختار شبکه ANN [۲۸]

محققان روش جدیدی را برای تشخیص سرطان پوست بر اساس الگوریتم ژنتیک (GA) و الگوریتم‌های ANN توصیف کردند. تصاویر برای حذف موهای زائد با نرم‌افزار تصویربرداری پزشکی به نام Dull-Rozar و ناحیه موردنظر (ROI) پیش پردازش شده، و با روش Otsu thresholding استخراج شدند. علاوه بر این، مدل GLCM برای استخراج ویژگی‌های منحصر به فرد تصاویر تقسیم‌بندی شده به کار گرفته شد. پس از آن، یک طبقه‌بندی ترکیبی ANN و GA برای طبقه‌بندی تصاویر ضایعه به دو گروه سرطانی و غیرسرطانی استفاده شد. سیستم پیشنهادی به نمره دقت ۸۸٪ دست یافت [۲۹].

یک سیستم خودکار تشخیص سرطان پوست مبتنی بر پس انتشار خطا شبکه عصبی مصنوعی پیشنهاد شد. این سیستم از مدل موجک دوبعدی^{۳۹} برای استخراج ویژگی استفاده می‌کند [۳۰]. شکل ۴ تشخیص یک ضایعه پوستی را نشان می‌دهد.

تصویر اصلی	تصویر پردازش شده	تشخیص:
		<p>Asymmetry: کاملاً نامتقارن</p> <p>Border: نامنظم</p> <p>Color: سفید، مشکی، قهوه ای تیره</p> <p>Diameter: ۲۹.۶۹۴۵۴۰ میلی متر</p> <p>نتیجه: ملانوما</p>

شکل ۴- تشخیص سرطان پوست با استفاده از ANN [۳۱]

کانیموژی و همکاران مدلی را برای استخراج ویژگی با ANN و الگوریتم پس انتشار خطا ارائه کردند. سیستم پیشنهادی بر روی دیتاست ۳۱ تصویر درموسکویی مورد ارزیابی قرار گرفت و به ۹۶.۹٪ دقت برای تشخیص ملانوم دست یافت [۴۳].

عقیب و همکاران در سال ۲۰۱۸ یک مدل با مدل ANN meta-ensemble متشکل از BPN و شبکه عصبی فازی ارائه کردند که برای استخراج ضایعه از شبکه عصبی self-generating استفاده شد. این مدل بر روی دیتاست Caucasian race و xanthous-race مورد ارزیابی قرار گرفت و به ۹۴.۱۷٪ دقت، ۹۵٪ حساسیت و ۹۳.۷۵٪ ویژگی برای تشخیص خوش خیم یا بدخیم بودن ضایعه دست یافت [۲۸].

³⁹ 2D-wavelet transform

جلیل و همکاران مدل GLCM را برای استخراج ویژگی با شبکه عصبی مصنوعی و الگوریتم پس انتشار خطا بر روی دیتاست ۵۰ تصویر درموسکویی آزمایش کردند و به ۸۸٪ دقت برای تشخیص سرطانی یا غیرسرطانی بودن ضایعه دست یافتند [۴۴].

در جدول ۱ جزئیات جامع سیستم‌های مختلف تشخیص سرطان پوست ملانوما مبتنی بر ANN ارائه شده است.

نویسنده	سال انتشار	طبقه بندی کننده و الگوریتم آموزشی	دیتاست	دقت
مولر و همکاران [۶۹]	۱۹۹۳	Feed-forward BPNN	۲۰۰ تصویر درموسکویی	۹۷.۵۱٪
جلیل و همکاران [۳۰]	۲۰۱۲	ANN با الگوریتم backpropagation	۹۰ تصویر درموسکویی	۸۶.۶۶٪
کانیموزی و همکاران [۴۳]	۲۰۱۶	ANN با الگوریتم backpropagation	۳۱ تصویر درموسکویی	۹۶.۹٪
زی و همکاران [۷۲]	۲۰۱۷	ANN با الگوریتم‌های یادگیری - Levenberg resilient backpropagation Marquardt (LM), scaled conjugate gradient (GCG) و (RBP)	۱۳۵ تصویر ضایعه	SCG: ۹۱.۹٪ LM: ۹۵.۱٪ RBP: ۸۸.۱٪
تومپا و همکاران [۷۳]	۲۰۲۱	Maximum Gradient Intensity و Otsu Thresholding	دیتاست ترکیبی archive-ISIC، پایگاه داده PH2 تصاویر درموسکویی	۹۷.۷٪
الساد و همکاران [۷۴]	۲۰۲۱	ANN	ISIC 2018 و PH2	PH2: ۹۷.۵٪ ISIC 2018: ۹۸.۳۵٪

جدول ۱- تجزیه و تحلیل مقایسه‌ای تشخیص سرطان پوست ملانوما با استفاده از رویکردهای مبتنی بر ANN

۳-۱-۲- مدل‌های تشخیص سرطان پوست مبتنی بر شبکه عصبی کانولوشنال^{۴۰}

شبکه عصبی کانولوشنال یک نوع شبکه عصبی عمیق است که به طور موثر در بینایی کامپیوتر استفاده می‌شود. برای طبقه‌بندی تصاویر، جمع‌آوری گروهی از تصاویر ورودی و تشخیص تصویر استفاده می‌شود. CNN یک ابزار فوق‌العاده برای جمع‌آوری و یادگیری داده‌های جهانی و همچنین داده‌های محلی، با جمع‌آوری ویژگی‌های ساده‌تر مانند منحنی‌ها و لبه‌ها برای تولید ویژگی‌های پیچیده مانند اشکال و گوشه‌ها است [۳۲]. لایه‌های پنهان CNN از لایه‌های پیچشی، لایه‌های ادغام غیرخطی و لایه‌های کاملاً متصل تشکیل شده‌اند [۳۳]. CNN می‌تواند حاوی چندین لایه پیچشی باشد که توسط چندین لایه کاملاً متصل دنبال می‌شوند. سه نوع اصلی از لایه‌هایی که در ساخت CNN وجود دارند، لایه‌های کانولوشنال، لایه‌های ترکیبی و لایه‌های کاملاً متصل هستند [۳۴].

الگوریتم‌های یادگیری عمیق خودکار مبتنی بر CNN عملکرد قابل توجهی در عملیات تشخیص، تقسیم‌بندی و طبقه‌بندی تصویربرداری پزشکی به دست آورده‌اند [۳۵]. لکوان و همکاران یک CNN بسیار عمیق برای تشخیص ملانوما پیشنهاد کردند. یک شبکه باقیمانده کاملاً کانولوشنال^{۴۱} دارای ۱۶ بلوک باقیمانده در فرآیند تقسیم‌بندی برای بهبود عملکرد استفاده شد. مدل پیشنهادی برای طبقه‌بندی، از میانگین طبقه‌بندی‌های SVM^{۴۲} و softmax استفاده می‌کند. در طبقه‌بندی ملانوم با تقسیم‌بندی، دقت ۸۵.۵٪ و در طبقه‌بندی ملانوم بدون تقسیم‌بندی ۸۲.۸٪ را نشان داد [۳۶].


درجی و همکاران یک مدل برای طبقه‌بندی چهار نوع مختلف از تصاویر ضایعه پوستی ارائه کردند. یک CNN عمیق از پیش آموزش دیده به نام AlexNet برای استخراج ویژگی استفاده شد، پس از آن SVM کدگذاری خروجی تصحیح خطا به عنوان یک طبقه‌بندی‌کننده کار کرد.

⁴⁰ Convolutional Neural Network(CNN)

⁴¹ Fully Convolutional Residual Network(FCRN)

⁴² Support Vector Machine

سیستم پیشنهادی بالاترین امتیاز میانگین حساسیت، ویژگی و دقت را برای SCC^{43} ، کراتوز اکتینیک⁴⁴ و BCC^{45} به ترتیب: ۹۸.۹٪ و ۹۴.۱۷٪ ایجاد کرد [۳۷]. شکل ۵ یک روش تشخیص سرطان پوست با استفاده از CNN را نشان می‌دهد.



شکل ۵- تشخیص سرطان پوست با استفاده از CNN [۳۸].

سینگ و همکاران مدلی را با افزایش داده‌ها برای تعادل داده‌ها و با استفاده از CNN عمیق ارائه کردند. سیستم پیشنهادی با دیتاست ISIC مورد ارزیابی قرار گرفت و به ۸۰.۳٪ دقت، ۸۱٪ صحت و ۶۹٪ AUC برای تشخیص خوش خیم یا بدخیم بودن ضایعه دست یافت [۴۵].

مهبد و همکاران در سال ۲۰۱۹ یک مدل با استفاده از طبقه‌بندی SVM با ویژگی‌های استخراج شده توسط مدل‌های عمیق از پیش آموزش دیده به نام‌های AlexNet، ResNet-18 و VGG16 ارائه کردند. این سیستم پیشنهادی بر روی دیتاست ISIC آزمایش شد و به ۹۰.۶۹٪ میانگین AUC برای تشخیص ملانوم بدخیم و SK^{46} دست یافت. نمرات SVM برای ارزیابی به احتمالات تابع regression logistic نوشته شدند [۴۶].

دوریس و همکاران در سال ۲۰۲۱ یک مدل با استفاده از CNN چند مقیاسی عمیق ارائه کردند. سیستم پیشنهادی بر روی دیتاست ISIC مورد ارزیابی قرار گرفت و به ۹۰.۳٪ دقت و ۹۴.۳٪ AUC برای تشخیص ملانوما و SK دست یافت. سیستم پیشنهادی از مدل Inception-v3 استفاده کرد که در ImageNet آموزش داده شده است [۴۷].

هارنگی بررسی کرد که آیا مجموعه‌ای از CNN می‌تواند عملکرد طبقه‌بندی‌کننده عمیق فردی را برای جبران کمبود تعداد زیادی از تصاویر ملانوما برچسب‌گذاری شده افزایش دهد. چهار CNN از انواع مختلف از جمله GoogLeNet، AlexNet، ResNet و VGGNet ترکیب شدند. تنها ۲۰۰۰ تصویر برای آموزش، ۱۵۰ تصویر برای اعتبارسنجی و ۶۰۰ تصویر برای آزمایش، مربوط به سه نوع سرطان پوست (نوس⁴⁷، ملانوم و کراتوز سبورئیک) استفاده شد. با استفاده از تبدیل تصویر، تصاویر به ۱۴۳۰۰ افزایش یافت. یک طرح رای گیری وزنی برای جمع‌آوری نتایج CNN های فردی استفاده شد. این گروه به میانگین دقت ۰.۸۶۶، حساسیت متوسط ۰.۵۵۶ و میانگین ویژگی ۰.۷۸۵ دست یافت [۶۳].

در جدول ۲ جزئیات جامع سیستم‌های مختلف تشخیص سرطان پوست ملانوما مبتنی بر CNN ارائه شده است.

⁴³ Squamous Cell Carcinoma

⁴⁴ Actinic Keratosis(AK)

⁴⁵ Basal Cell Carcinoma

⁴⁶ Seborrheic Keratosis

⁴⁷ Nevus

نویسنده	سال انتشار	طبقه بندی کننده و الگوریتم آموزشی	دیتاست	دقت
نصر اصفهانی و همکاران [۷۴]	۲۰۱۶	طبقه بندی کننده CNN	۱۷۰ تصویر ضایعه پوستی	٪۸۱
شویب و همکاران [۷۵]	۲۰۱۶	ویژگی های استخراج شده، SVM-trained، با CNN	دیتاست DermIS و داده های DermQues	٪۹۳.۷۵
کالوش و همکاران [۷۶]	۲۰۱۶	CNN و VGG-16	دیتاست ISIC	٪۷۸
استوا و همکاران [۷۷]	۲۰۱۷	Deep CNN	ISIC-Dermoscopic Archive	٪۷۲.۱
آتیا و همکاران [۷۸]	۲۰۱۷	ترکیبی از CNN با رمزگذار و رمزگشای خودکار و RNN	دیتاست ISIC	٪۹۸
دوریس و همکاران [۷۹]	۲۰۱۷	Deep multi-scale CNN	دیتاست ISIC	٪۹۰.۳
هارنگی و همکاران [۸۰]	۲۰۱۸	CNN به عنوان معماری single neural-net	دیتاست ISIC-2017	٪۸۳.۸
ناموزو و همکاران [۸۱]	۲۰۱۸	مدل CNN با رویکرد LeNet	دیتاست ISIC	٪۹۵.۸۶
نیدا و همکاران [۷۱]	۲۰۱۹	CNN مبتنی بر Deep region و خوشه بندی fuzzy C means	دیتاست ISIC	٪۹۴.۸
ساغر و همکاران [۷۰]	۲۰۲۰	ResNet-50 با deep transfer learning	۳۶۰۰ تصویر ضایعه از دیتاست ISIC	۹۳.۵٪
سالیان و همکاران [۴۴]	۲۰۲۰	Own CNN	دیتاست های PH2 و HAM10000	HAM10000: ٪۸۳.۱۵۲ PH2: ۹۷.۲۵٪
فؤاده و همکاران [۴۲]	۲۰۲۰	CNN	دیتاست ISIC	۹۹٪

جدول ۲- تجزیه و تحلیل مقایسه‌ای تشخیص سرطان پوست ملانوما با استفاده از رویکردهای مبتنی بر CNN


۳-۱-۳- مدل های تشخیص سرطان پوست مبتنی بر شبکه عصبی خودسازماندهی کوهونن^{۴۸}

نقشه خود سازماندهی کوهونن یک نوع بسیار معروف از شبکه عصبی عمیق است. CNN ها بر اساس یادگیری بدون نظارت آموزش می بینند، یعنی یک KNN نیازی به مداخله توسعه دهنده در فرآیند یادگیری و همچنین نیاز به اطلاعات کمی در مورد ویژگی های داده های ورودی ندارد. یک KNN به طور کلی از دو لایه تشکیل شده است. در صفحه دوبعدی، اولین لایه یک لایه ورودی، و لایه دیگر یک لایه رقابتی نامیده می شود. این لایه ها از بعد لایه اول تا دوم کاملاً به هم متصل هستند. یک KNN می تواند برای خوشه بندی داده ها بدون اطلاع از روابط بین اعضای داده ورودی استفاده شود. همچنین به عنوان نقشه خود سازماندهی شناخته می شود. KNN ها حاوی لایه خروجی نیستند و هر گره در لایه رقابتی به عنوان خود گره خروجی عمل می کند.

یک KNN به عنوان کاهش دهنده ابعاد کار می کند. این می تواند داده های با ابعاد بالا را به یک بعد کم، مانند یک صفحه دوبعدی، کاهش دهد. بنابراین، انواع گسسته ای از نمایش دیتاست ورودی را فراهم می کند. KNN ها از نظر استراتژی یادگیری با انواع دیگر NN متفاوت هستند زیرا از یادگیری رقابتی به جای یادگیری مبتنی بر تصحیح خطا در BPN یا یادگیری feed-forward استفاده می کنند. یک KNN ساختار توپولوژیکی فضای داده ورودی را در طول ابعاد نقشه برداری از بالا به پایین (فاصله نسبی بین نقاط داده در فضا) حفظ می کند. نقاط داده ای که در فضای داده ورودی نزدیکتر هستند در این طرح به یکدیگر نزدیکتر می شوند. نقاط دور، دور از یکدیگر و همچنین با توجه به فاصله نسبی موجود بین آنها نقشه برداری می شوند. در نتیجه، KNN بهترین ابزار برای داده های با ابعاد بالا است. یکی دیگر از ویژگی های مهم ارائه شده توسط KNN، توانایی تعمیم آن است. این شبکه توانایی شناسایی و سازماندهی داده های ورودی ناشناخته را دارد. کیفیت اصلی KNN، توانایی آن در ترسیم روابط پیچیده نقاط داده است که روابط غیرخطی بین نقاط داده در آن وجود دارد. با توجه به این مزایا، امروزه از KNN ها در

⁴⁸ Kohonen Self-Organizing Neural Network(KNN)

سیستم‌های تشخیص سرطان پوست استفاده می‌شود. در شکل ۶ معماری KNN نشان داده شده و اجزاء این معماری مانند بردار ورودی، سلول BMU⁴⁹ و همسایگی⁵⁰، شبکه دو بعدی و وزن های نورون⁵¹ مشخص شده است.



شکل ۶- ساختار پایه KNN [۴۹]

لنهارت و همکاران مدلی را با تجزیه و تحلیل مولفه اصلی (PCA⁵²) برای کاهش ابعاد طیف و با استفاده از SOM⁵³ و شبکه عصبی feed-forward ارائه کردند. سیستم پیشنهادی با دیتاست ۵۰ تصویر ضایعه پوستی ارزیابی شد و به ۹۶ تا ۹۸٪ دقت برای تشخیص ملانوم، خال و پوست طبیعی دست یافت [۴۸].

منگیستو و همکاران با استفاده از الگوریتم SOM و RBF⁵⁴، ۱۵ ویژگی متشکل از ویژگی های مورفولوژیکی و رنگی GCM⁵⁵ استخراج کردند. این مدل بر روی دیتاست DermQuest و Dermnet ارزیابی شد و به ۹۳.۱۵٪ دقت برای تشخیص SCC, BCC و ملانوما دست یافت [۴۹].

ساجید و همکاران در سال ۲۰۱۸ مدلی با استفاده از الگوریتم KNN اصلاح شده ارائه کردند. این مدل بر روی دیتاست ۵۰۰ تصویر ضایعه ارزیابی شد و به ۹۸.۳٪ دقت برای تشخیص سرطانی یا غیرسرطانی بودن ضایعه دست یافت [۵۰].

در جدول ۳ جزئیات جامع سیستم‌های مختلف تشخیص سرطان پوست ملانوما مبتنی بر KNN ارائه شده است.

نویسنده	سال انتشار	طبقه بندی کننده و الگوریتم آموزشی	دیتاست	دقت
لنهارت و همکاران [۴۸]	۲۰۱۲	feed-forward NN و SOM	50 تصویر درموسکوپي	۹۶-۹۸٪
منگیستو و همکاران [۴۹]	۲۰۱۵	SOM و RBF	دیتاست‌های DermQuest و Dermnet	۹۳.۱۵٪

جدول ۳- تجزیه و تحلیل مقایسه‌ای تشخیص سرطان پوست ملانوما با استفاده از رویکردهای مبتنی بر KNN

⁴⁹ Best Matching Unit

⁵⁰ BMU cell and its neighborhood

⁵¹ Neuron Weights

⁵² Principal Component Analysis

⁵³ Self organizing map

⁵⁴ Radial Basis Function

⁵⁵ Generalized Co-occurrence Matrices

۳-۱-۴- مدل‌های تشخیص سرطان پوست مبتنی بر شبکه‌ی مولد متخاصم^{۵۶}

یک شبکه عصبی متخاصم مولد یک کلاس قدرتمند از DNN است که از نظریه بازی‌های حاصل جمع صفر الهام گرفته شده است [۴۰]. GAN ها بر این ایده مبتنی هستند که دو شبکه عصبی، مانند یک مولد و یک تشخیص دهنده، برای تجزیه و تحلیل و گرفتن واریانس در یک پایگاه داده با یکدیگر رقابت می‌کنند. ماژول مولد از توزیع داده برای تولید نمونه‌های جعلی داده استفاده می‌کند و سعی می‌کند ماژول تشخیص دهنده را به اشتباه هدایت کند. از سوی دیگر، هدف ماژول تشخیص دهنده، تمایز بین نمونه داده‌های واقعی و جعلی است [۴۱]. در مرحله آموزش، هر دوی این شبکه‌های عصبی این مراحل را تکرار می‌کنند و پس از هر رقابت، عملکرد آنها بهبود می‌یابد. توانایی تولید نمونه‌های جعلی شبیه به نمونه واقعی با استفاده از توزیع داده‌های مشابه، مانند تصاویر واقعی، قدرت اصلی یک شبکه GAN است. همچنین می‌تواند یک مشکل عمده در یادگیری عمیق که مشکل مثال‌های آموزشی ناکافی می‌باشد را حل کند.

محققان تحقیقاتی انواع مختلفی از GAN ها را پیاده‌سازی کرده‌اند، مانند Vanilla GAN⁵⁷، CGAN⁵⁸، DCGAN⁵⁸، SRGAN⁵⁹ و LPGAN⁶⁰. امروزه GAN ها با موفقیت در سیستم‌های تشخیص سرطان پوست استفاده می‌شوند.

رشید و همکاران در سال ۲۰۱۹ یک مدل با استفاده از GAN ارائه کردند. سیستم پیشنهادی از شبکه deconvolutional و CNN به عنوان ماژول مولد و تفکیک‌کننده استفاده می‌کند. مدل ارائه شده بر روی دیتاست ISIC 2018 مورد ارزیابی قرار گرفت و به ۸۶.۱ درصد دقت برای تشخیص K، BCC، کراتوز خوش خیم، درماتوفیبروم، ملانوم، خال ملانوسیتیک و ضایعه عروقی دست یافت [۲۳].

بیسلا و همکاران در سال ۲۰۲۱ یک مدل با استفاده از deep convolutional GANs ارائه کردند. deep convolutional GANs برای تقویت داده‌ها جدا شدند. سیستم پیشنهادی بر روی دیتاست ISIC 2017، ISIC 2018، PH2 مورد ارزیابی قرار گرفت و به ۹۱.۵٪ ROC AUC و ۸۶.۱٪ دقت برای تشخیص ملانوم، خال و SK دست یافت [۲۴].

علی و همکاران در سال ۲۰۲۱ یک مدل مولد با مدل تثبیت بهبود یافته و با استفاده از Self-attention-based PGAN ارائه کردند. سیستم پیشنهادی بر روی دیتاست ISIC 2018 آزمایش شد و به ۷۰.۱٪ دقت برای تشخیص BCC، عروقی، کراتوز خوش خیم رنگدانه، بوون رنگدانه، خال، درماتوفیبروم دست یافت [۵۱].

در جدول ۴ جزئیات جامع سیستم‌های مختلف تشخیص سرطان پوست ملانوما مبتنی بر GAN ارائه شده است.

دقت	دیتاست	طبقه بندی کننده و الگوریتم آموزشی	سال انتشار	نویسنده
۸۶.۱٪	دیتاست ISIC 2018	GAN	۲۰۱۹	رشید و همکاران [۲۳]
۸۶.۱٪	دیتاست‌های ISIC-2017 و PH2 و ISIC-2018	Deep convolutional GAN	۲۰۱۹	بیسلا و همکاران [۲۴]
۹۲.۵٪	دیتاست HAM10000	TED-GAN	۲۰۲۱	احمد و همکاران [۲۶]

جدول ۴- تجزیه و تحلیل مقایسه‌ای تشخیص سرطان پوست ملانوما با استفاده از رویکردهای مبتنی بر GAN

۳-۲- معیارهای ارزیابی

⁵⁶ Generative Adversarial Network(GAN)

⁵⁷ Condition GAN

⁵⁸ Deep Convolutional GAN

⁵⁹ Super-Resolution GAN

⁶⁰ Laplacian Pyramid GAN

مثبت صحیح^{۶۱} (TP): کلاس منفی به درستی توسط مدل طبقه‌بندی کننده پیش‌بینی می‌شود، به عنوان مثال اگر یک تصویر حاوی سلول‌های سرطانی باشد و مدل بخش سرطانی را با موفقیت تقسیم می‌کند و نتیجه آن را وجود سرطان طبقه‌بندی می‌کند.

منفی صحیح^{۶۲} (TN): کلاس مثبت به درستی توسط مدل طبقه‌بندی کننده پیش‌بینی می‌شود. به عنوان مثال هیچ سرطانی در تصویر وجود ندارد و مدل پس از طبقه بندی اعلام می‌کند که سرطان وجود ندارد.

مثبت غلط^{۶۳} (FP): کلاس مثبت به اشتباه توسط مدل طبقه‌بندی کننده پیش‌بینی می‌شود، به عنوان مثال تصویر دارای سلول‌های سرطانی است اما مدل طبقه‌بندی می‌کند که تصویر حاوی سرطان در آن نیست.

منفی غلط^{۶۴} (FN): کلاس منفی به اشتباه توسط مدل طبقه‌بندی کننده پیش‌بینی می‌شود، مثلاً سرطان در تصویر وجود ندارد اما مدل می‌گوید یک تصویر سرطانی است.

۳-۲-۱- منحنی مشخصه عملکرد گیرنده^{۶۵}

منحنی مشخصه عملکرد گیرنده، عملکرد مدل پیشنهادی را در تمام آستانه‌های طبقه‌بندی نشان می‌دهد. این نمودار نرخ مثبت صحیح در مقابل منفی صحیح است. (TPR در مقابل FPR)

$$FPR = \frac{FP}{FP + TN} \quad (16) \quad TPR = \frac{TP}{TP + FN} \quad (15)$$

۳-۲-۲- ناحیه زیر منحنی ROC (AUC)

AUC ناحیه زیر منحنی ROC را از (۰، ۰) تا (۱، ۱) یکپارچه می‌کند. این معیار نشان‌دهنده مجموع تمام آستانه‌های طبقه‌بندی ممکن است. AUC دارای محدوده‌ای از ۰ تا ۱ است. یک نسخه طبقه‌بندی ۱۰۰٪ صحیح دارای مقدار AUC 1.0 خواهد بود و اگر طبقه‌بندی ۱۰۰٪ اشتباه باشد، ۰.۰ خواهد بود. این به دو دلیل جذاب است: ۱- مقیاس ناپذیر است، یعنی به جای بررسی مقادیر مطلق، بررسی می‌کند که مدل چقدر خوب پیش‌بینی شده است ۲- آستانه طبقه‌بندی ثابت است زیرا عملکرد مدل را بدون توجه به آستانه انتخاب شده بررسی می‌کند.

۳-۲-۳- تابع F1-Score

مفهوم Precision نسبت آیت‌های مثبت به درستی پیش‌بینی شده به کل آیت‌های پیش‌بینی شده است (فرمول شماره ۱۷) و Recall محاسبه می‌کند که مدل چند نکته مثبت صحیح را ثبت کرده و آنها را به عنوان موارد مثبت برچسب‌گذاری می‌کند (فرمول شماره ۱۸).

$$Recall = \frac{TP}{TP + FN} \quad (18) \quad Precision = \frac{TP}{TP + FP} \quad (17)$$

F1-Score تابع Precision و recall است. زمانی که تعادل بین Precision و recall لازم است محاسبه می‌شود.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (19)$$

⁶¹ True Positive

⁶² True Negative

⁶³ False Positive

⁶⁴ False Negative

⁶⁵ Receiver Operating Characteristic Curve (ROC-Curve)

۳-۲-۴- دقت ۶۶

دقت تعیین می‌کند که چند مثبت صحیح (TP)، منفی صحیح (TP)، مثبت غلط (FP) و منفی غلط (FN) به درستی طبقه بندی شده‌اند.

$$ACC. = \frac{TP + TN}{TP + TN + FN + FP} \quad (20)$$

۳-۲-۵- توضیح مفاهیم ویژگی و حساسیت^{۶۸}

ویژگی میزان شناسایی صحیح موارد منفی است (فرمول شماره ۲۱) و حساسیت مقدار موارد مثبتی است که به درستی شناسایی شده‌اند (فرمول شماره ۲۲)

$$Sens. = \frac{TP}{TP + FN} \quad (22) \quad Spof. = \frac{TN}{TN + FN} \quad (21)$$

[۵۳، ۵۲]

۴- دیتاست‌ها

۴-۱- HAM10000

یک دیتاست انسان در برابر ماشین با ۱۰۰۰۰ تصویر آموزشی وجود دارد که HAM10000 نامیده می‌شود. این آخرین دیتاست ضایعات پوستی در دسترس عموم است و بر مشکل کمبود تنوع غلبه می‌کند. دیتاست نهایی HAM10000، شامل ۱۰۰۱۵ تصویر پوستی است [۵۴].

۴-۲- PH2

تصاویر درموسکوپی در دیتاست PH2 در مرکز پوست بیمارستان پدرو هیسپانو پرتغال جمع‌آوری شد. این تصاویر با استفاده از سیستم Tuebinger Mole-Analyzer در شرایط یکسان و نرخ بزرگنمایی ۲۰× به دست آمد. دیتاست PH2 شامل تصاویر رنگی RGB، ۸ بیتی با وضوح ۵۶۰ × ۷۶۸ پیکسل است. این دیتاست شامل ۲۰۰ تصویر درموسکوپی است که به ۸۰ تصویر از خال‌های معمولی، ۸۰ تصویر از خال‌های غیر معمول و ۴۰ تصویر از سرطان‌های پوست ملانوم تقسیم شده است [۵۵].

۴-۳- ISIC archive

ISIC Archive مجموعه‌ای از دیتاست‌های مختلف ضایعات پوستی است [۵۶]. دیتاست ISIC در ابتدا توسط همکاری بین‌المللی تصویربرداری پوست در چالش سمپوزیوم بین‌المللی تصویربرداری زیست‌پزشکی^{۶۹} (ISBI) در سال ۲۰۱۶ با نام ISIC2016 منتشر شد. ISIC2016 شامل ۳۷۹ تصویر ISIC به دو بخش آموزش و تست تقسیم می‌شود. زیرمجموعه آموزشی ISIC شامل ۹۰۰ تصویر و زیرمجموعه تست شامل ۳۷۹ تصویر درموسکوپی است. این شامل تصاویری از دو دسته ملانوم‌های بدخیم و خال‌های خوش‌خیم است. تقریباً ۳۰٪ از تصاویر دیتاست‌ها مربوط به ضایعات ملانوما و بقیه تصاویر متعلق به دسته خال‌های خوش‌خیم هستند. ISIC هر سال تعداد تصاویر را در آرشیو خود افزایش می‌دهد و یک

⁶⁶ Accuracy⁶⁷ Specificity⁶⁸ Sensitivity⁶⁹ International Symposium on Biomedical Imaging

چالش طراحی برای توسعه سیستمی برای تشخیص خودکار سرطان پوست ایجاد کرده است [۵۷]. در سال ۲۰۲۰، ISIC-2020 منتشر شد. این دیتاست شامل ۳۳۱۲۶ تصویر آموزشی درموسکوپی از ضایعات پوستی خوش خیم و بدخیم منحصر به فرد از بیش از ۲۰۰۰ بیمار است.

۴-۴- DermQuest

دیتاست‌های عمومی Derm Quest حاوی ۲۲۰۸۲ تصویر درموسکوپی بود. در میان تمام دیتاست‌های درموسکوپی، تنها دیتاست‌های DermQuest حاوی برچسب‌های ضایعه برای ضایعات پوستی بود. ۱۳۴ برچسب ضایعه برای همه تصاویر در دیتاست وجود داشت. دیتاست DermQuest در سال ۲۰۱۸ به Derm101 هدایت شد [۵۸].

۴-۵- DermIS

سیستم اطلاعات درماتولوژی دیتاست Dermoscopic معمولاً به عنوان DermIS شناخته می‌شود [۵۹]. این دیتاست با همکاری گروه پوست دانشگاه ارلانگن و گروه پزشکی اجتماعی بالینی دانشگاه هایدلبرگ ساخته شده است و شامل ۶۵۸۸ تصویر است.

۴-۶- AtlasDerm

دیتاست Atlas of Dermoscopy معمولاً AtlasDerm نامیده می‌شود [۶۰]. این یک ترکیب منحصربه‌فرد و به خوبی سازماندهی شده از یک کتاب و تصاویر در CD-ROM به همراه نمونه‌هایی برای آموزش است. در ابتدا به عنوان ابزاری برای کمک به پزشکان در تشخیص ضایعات پوستی و شناخت معیارهای درموسکوپی مربوط به ملانوم طراحی شد. دیتاست AtlasDerm موارد مختلفی از ضایعات پوستی را با تصاویر درموسکوپی مربوطه برای هر مورد در نظر می‌گیرد که شامل ۵ تصویر از AK، ۴۲ تصویر از BCC، ۷۰ تصویر از کراتوز خوش خیم، ۲۰ تصویر از درماتوفیبروما، ۲۷۵ تصویر از خال ملانوسیتیک، ۵۸۲ تصویر از ملانوم، و ۳۰ تصویر از ضایعات پوستی عروقی است.

۴-۷- Dermnet

دیتاست اطلس بیماری پوستی Dermnet معمولاً به عنوان Dermnet شناخته می‌شود [۶۱]. این در سال ۱۹۹۸ توسط دکتر توماس حبیب در Portsmouth، New Hampshire ساخته شد. این شامل بیش از ۲۳۰۰۰ تصویر درموسکوپی است. این پایگاه حاوی تصاویر ۶۴۳ نوع مختلف بیماری پوستی است.

در جدول ۵ دیتاست‌های سرطان پوست ارائه شده است.


نام دیتاست	سال انتشار	تعداد تصاویر	وضوح تصاویر	لینک دسترسی
دیتاست Dermnet	۱۹۹۸	۲۳۰۰۰	-	https://github.com/topics/dermnet
دیتاست DermQuest	۱۹۹۹	۲۲۰۸۲	-	https://www.derm101.com/dermquest/
دیتاست AtlasDerm	۲۰۰۰	۱۰۲۴	-	www.atlasdermatologico.com.br
دیتاست PH2	۲۰۱۳	۲۰۰	۵۶۰ × ۷۶۸	https://www.kaggle.com/datasets/synked/ph2-modified
دیتاست DermIS	-	۶۵۸۸	-	http://biogps.org/dataset/tag/dermis/
دیتاست ISIC archive	۲۰۱۶	۲۵۳۳۱	۵۷۶ × ۷۶۸ الی ۲۸۴۸ × ۴۲۸۸	https://challenge.isic-archive.com/data/
دیتاست HAM10000	۲۰۱۸	۱۰۰۱۵	۶۰۰ × ۸۰۰	https://github.com/johnyquest7/HAM10000

جدول ۵- دیتاست‌های سرطان پوست


خان و همکاران در سال ۲۰۱۹ یک سیستم هوشمند برای تشخیص و تمایز بین موارد ملانوما و خال پیشنهاد کرد. از یک فیلتر گاوسی برای حذف نویز از ضایعه پوستی استفاده شد و از خوشه‌بندی improved K-means برای تقسیم ضایعه استفاده شد. ویژگی‌های متنی و رنگی پس از آن استخراج شد. دستگاه بردار پشتیبان (SVM) برای طبقه‌بندی سرطان پوست به ملانوم و خال استفاده شد. دیتاست DERMIS با تعداد

کل ۳۹۷ تصویر سرطان پوست ۱۴۶ تصویر ملانوم و ۲۵۱ تصویر از نوع خال استفاده شد. این سیستم به ۹۶٪ دقت، ۹۷٪ حساسیت، ۹۶٪ ویژگی و ۹۷٪ Precision دست یافت [۶۴]. شکل ۷ میزان دقت، حساسیت، ویژگی و Precision روش ارائه شده را بر روی نمودار نشان داده است.

عامری یک CNN را بر اساس یک مدل AlexNet از پیش آموزش دیده ساخت که برای طبقه‌بندی باینری با استفاده از یادگیری انتقالی اصلاح شد. اندازه همه تصاویر به 227×227 تغییر داده شد تا با اندازه ورودی مدل AlexNet مطابقت داشته باشد. این مدل با استفاده از الگوریتم، SGDGM با نرخ یادگیری اولیه 0.0001 و اندازه کوچک دسته‌های ۳۰ و ۴۰ دوره آموزش داده شد. در مجموع ۳۴۰۰ تصویر (۱۷۰۰ تصویر خوش‌خیم و ۱۷۰۰ تصویر بدخیم) از دیتاست HAM10000 استفاده شد و ۹۰٪ به صورت تصادفی به عنوان مجموعه آموزشی و بقیه به عنوان مجموعه تست انتخاب شدند. دقت طبقه‌بندی ۸۴٪، حساسیت ۸۱٪ و ویژگی ۸۸٪ به دست آمد [۶۵]. شکل ۸ میزان دقت، حساسیت و ویژگی روش ارائه شده را بر روی نمودار نشان می‌دهد.



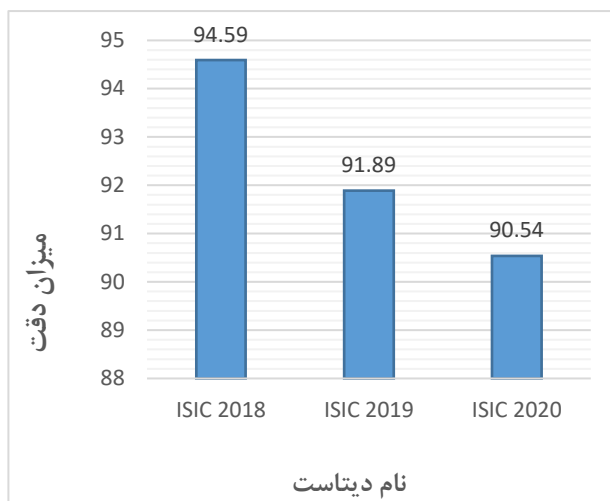
شکل ۸- میزان دقت، حساسیت و ویژگی روش ارائه شده



شکل ۷- میزان دقت، حساسیت، ویژگی و Precision روش ارائه شده


اخیرا محققان یک روش کاملاً خودکار برای تقسیم‌بندی ملانوم پوست در ابتدایی‌ترین مرحله آن با استفاده از یک رویکرد مبتنی بر یادگیری عمیق، یعنی شبکه‌های عصبی کانولوشنال مبتنی بر ناحیه سریع‌تر (faster RCNN) همراه با خوشه‌بندی Fuzzy k-means (FKM) ارائه کردند. عملکرد روش ارائه شده بر روی سه دیتاست استاندارد، یعنی ISIC-2016، ISIC-2017، و PH2 مورد ارزیابی قرار گرفته است و نتایج نشان داد که روش ارائه شده بهتر از رویکردهای پیشرفته عمل می‌کند. روش ارائه شده به ترتیب به دقت متوسط ۹۵.۴، ۹۳.۱ و ۹۵.۶ درصد در دیتاست‌های ISIC-2016، ISIC-2017، و PH2 می‌رسد که نشان‌دهنده استحکام آن در تشخیص و تقسیم‌بندی ضایعات پوستی است [۲۱]. شکل ۹ میزان دقت روش انجام شده با استفاده از الگوریتم faster RCNN همراه با خوشه‌بندی Fuzzy K-means بر روی دیتاست‌های ISIC-2016، ISIC-2017، و PH2 را بر روی نمودار نشان می‌دهد.

همچنین محققان در سال ۲۰۲۲، InSiNet، یک شبکه عصبی کانولوشنال مبتنی بر یادگیری عمیق را برای تشخیص ضایعات خوش‌خیم و بدخیم پیشنهاد کردند. عملکرد این روش بر روی (International Skin Imaging Collaboration HAM10000 images (ISIC 2018)، ISIC 2019 و ISIC 2020، تحت شرایط مشابه آزمایش شده است. زمان محاسبه و تحلیل مقایسه دقت بین الگوریتم پیشنهادی و سایر مدل‌های یادگیری ماشین (GoogleNet)، DenseNet-201، ResNet152V2، EfficientNetB0، logistic support vector machine (RBF)، regression و random forest) انجام شد. نتایج نشان داد که معماری InSiNet توسعه یافته با دستیابی به دقت ۹۴.۵۹٪، ۹۱.۸۹٪ و ۹۰.۵٪ در دیتاست‌های ISIC 2018، ۲۰۱۹ و ۲۰۲۰ از روش‌های دیگر بهتر عمل می‌کند. از آنجایی که الگوریتم‌های یادگیری عمیق عامل انسانی را در حین تشخیص حذف می‌کنند، علاوه بر روش‌های سنتی می‌توانند نتایج قابل اعتمادی نیز ارائه دهند [۲۲]. شکل ۱۰ میزان دقت روش ارائه شده بر روی دیتاست‌های ISIC-2018، ISIC-2019، و ISIC-2020 را بر روی نمودار نشان می‌دهد.



شکل ۱۰- میزان دقت روش ارائه شده بر روی

دیتاست های ISIC-2020 و ISIC-2019



شکل ۹- میزان دقت روش ارائه شده بر روی

دیتاست های ISIC-2016، ISIC-2017 و PH2

۵- نتایج و بحث

این مقاله مروری مراحل تشخیص سرطان و معیارهای ارزیابی را به مبتدیان این رشته معرفی می‌کند. تشخیص سرطان پوست به مراحل متعددی مانند پیش پردازش، تقسیم‌بندی و پس پردازش و همچنین استخراج و طبقه‌بندی ویژگی نیاز دارد. این بررسی بر روی مدل‌های ANN، CNN، KNN و GAN برای طبقه‌بندی تصاویر ضایعه متمرکز شده است. هر الگوریتم مزایا و معایب خود را دارد. انتخاب مناسب مدل طبقه‌بندی، نقطه اصلی برای بهترین نتایج است. با این حال، با بررسی‌های انجام شده CNN نتایج بهتری نسبت به سایر انواع شبکه‌های عصبی در هنگام طبقه‌بندی داده‌های تصویری داشته، چرا که بیشتر از سایرین با بینایی کامپیوتر مرتبط است. در جدول ۶ دو مورد از بهترین رویکردهای تشخیص سرطان پوست ملانوما مبتنی بر چهار مدل ANN، CNN، KNN و GAN ارائه گردیده است.

دقت	دیتاست	مدل تشخیص و طبقه بندی	سال انتشار	نویسنده
۹۷.۵٪ ۹۸.۳۵٪	PH2 ISIC2018	ANN	۲۰۲۱	الساد و همکاران [۷۴]
۹۷.۷٪	PH2 و ISIC	ANN	۲۰۲۱	تومیا و همکاران [۷۳]
۹۷.۲۵	PH2	CNN	۲۰۲۰	سالیان و همکاران [۴۴]
۹۹٪	ISIC	CNN	۲۰۲۰	فؤاده و همکاران [۴۲]
۹۳.۱۵٪	۵۰ تصویر ضایعه پوستی	KNN	۲۰۱۵	منگیستو و همکاران [۴۹]
۹۶-۹۸٪	Dermnet و DermQuest	KNN	۲۰۱۳	لنهارت و همکاران [۴۸]
۸۶.۱٪	ISIC2018	GAN	۲۰۱۹	رشید و همکاران [۲۳]
۹۲.۵٪	دیتاست HAM10000	TED-GAN	۲۰۲۱	احمد و همکاران [۲۶]

جدول ۶- بهترین رویکردهای مبتنی بر مدل‌های یادگیری عمیق

بیشتر تحقیقات مربوط به تشخیص سرطان پوست بر روی سرطانی بودن تصویر ضایعه متمرکز دارد. با این حال، هنگامی که بیمار می‌پرسد که آیا یک علامت خاص سرطان پوست در قسمتی از بدن او ظاهر می‌شود، تحقیقات فعلی نمی‌تواند پاسخی ارائه دهد. تا کنون، پژوهش بر روی

مشکل محدود طبقه‌بندی تصویر سیگنال متمرکز شده است. تحقیقات آینده می‌تواند شامل عکاسی از تمام بدن برای یافتن پاسخ سؤالی باشد که معمولاً مطرح می‌شود. عکاسی مستقل تمام بدن، مرحله ثبت تصویر را خودکار و سرعت می‌بخشد.

ایده سازماندهی خودکار اخیراً در حوزه یادگیری عمیق ظاهر شده است. سازماندهی خودکار به فرآیند یادگیری بدون نظارت اشاره دارد که هدف آن شناسایی ویژگی‌ها و کشف روابط یا الگوها در نمونه‌های تصویری دیتاست است. مدل‌های سازمان‌دهی خودکار تحت نظارت شبکه‌های عصبی کانولوشنال، سطح بازنمایی ویژگی‌هایی را که توسط سیستم‌های خبره بازمایی می‌شود، افزایش می‌دهند [۶۸]. در حال حاضر، خودسازماندهی مدلی است که هنوز در حال تحقیق و توسعه است. با این حال، مطالعه آن می‌تواند دقت سیستم‌های پردازش تصویر را در آینده بهبود بخشد، به‌ویژه در حوزه تصویربرداری پزشکی، جایی که کوچک‌ترین جزئیات ویژگی‌ها برای تشخیص صحیح بیماری بسیار حیاتی می‌باشد.

مراجع

- [1]. Ashraf, R., Afzal, S., Rehman, A. U., Gul, S., Baber, J., Bakhtyar, M., ... & Maqsood, M. (2020). Region-of-interest based transfer learning assisted framework for skin cancer detection. *IEEE Access*, 8, 147858-147871.
- [2]. Byrd, A. L., Belkaid, Y., & Segre, J. A. (2018). The human skin microbiome. *Nature Reviews Microbiology*, 16(3), 143-155.
- [3]. Elgamal, M. (2013). Automatic skin cancer images classification. *International Journal of Advanced Computer Science and Applications*, 4(3).
- [4]. Nami, N., Giannini, E., Burrioni, M., Fimiani, M., & Rubegni, P. (2012). Tele dermatology: state-of-the-art and future perspectives. *Expert Review of Dermatology*, 7(1), 1-3.
- [5]. Fabbrocini, G., Triassi, M., Mauriello, M. C., Torre, G., Annunziata, M. C., De Vita, V., ... & Monfrecola, G. Epidemiology of skin cancer: Role of some environmental factors. *Cancers(Basel)* 2010 Nov 24; 2 (4): 1980–1989. doi: 10.3390/cancers2041980.
- [6]. Key Statistics for Melanoma Skin Cancer. Am. Cancer Soc. Available online: <https://www.cancer.org/content/dam/CRC/PDF/Public/8823.00.pdf> (accessed on 8 February 2021)
- [7]. Khan, M. Q., Hussain, A., Rehman, S. U., Khan, U., Maqsood, M., Mehmood, K., & Khan, M. A. (2019). Classification of melanoma and nevus in digital images for diagnosis of skin cancer. *IEEE Access*, 7, 90132-90144.
- [8]. Dildar, M., Akram, S., Irfan, M., Khan, H. U., Ramzan, M., Mahmood, A. R., ... & Mahnashi, M. H. (2021). Skin cancer detection: a review using deep learning techniques. *International journal of environmental research and public health*, 18(10), 5479.
- [9]. Doi, K. (2007). Computer-aided diagnosis in medical imaging: historical review, current status and future potential. *Computerized medical imaging and graphics*, 31(4-5), 198-211.
- [10]. Xu, B., Wang, N., Chen, T., & Li, M. (2015). Empirical evaluation of rectified activations in convolutional network. *arXiv preprint arXiv:1505.00853*.
- [11]. Messadi, M., Bessaid, A., & Taleb-Ahmed, A. (2009). Extraction of specific parameters for skin tumour classification. *Journal of medical engineering & technology*, 33(4), 288-295.
- [12]. Emre Celebi, M., Kingravi, H. A., Iyatomi, H., Alp Aslandogan, Y., Stoecker, W. V., Moss, R. H., ... & Menzies, S. W. (2008). Border detection in dermoscopy images using statistical region merging. *Skin Research and Technology*, 14(3), 347-353.
- [13]. Sikorski, J. (2004). Identification of malignant melanoma by wavelet analysis. *Proceedings of Student/Faculty Research Day, CSIS, Pace University*.
- [14]. Chiem, A., Al-Jumaily, A., & Khushaba, R. N. (2007, December). A novel hybrid system for skin lesion detection. In *2007 3rd International Conference on Intelligent Sensors, Sensor Networks and Information* (pp. 567-572). IEEE.
- [15]. Maglogiannis, I., Zafiroopoulos, E., & Kyranoudis, C. (2006, May). Intelligent segmentation and classification of pigmented skin lesions in dermatological images. In *Hellenic Conference on Artificial Intelligence* (pp. 214-223). Springer, Berlin, Heidelberg.
- [16]. Tanaka, T., Torii, S., Kabuta, I., Shimizu, K., & Tanaka, M. (2008). Pattern classification of nevus with texture analysis. *IEEJ Transactions on Electrical and Electronic Engineering*, 3(1), 143-150.
- [17]. Zhou, H., Chen, M., & Reh, J. M. (2009, June). Dermoscopic interest point detector and descriptor. In *2009 IEEE International Symposium on Biomedical Imaging: From Nano to Macro* (pp. 1318-1321). IEEE.
- [18]. Lee, C., & Landgrebe, D. A. (1993). Feature extraction based on decision boundaries. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 15(4), 388-400.
- [19]. Garbaj, M., & Deshpande, A. S. (2015). Detection and analysis of skin cancer in skin lesions by using segmentation. *IJARCCCE*.
- [20]. Johr, R. H. (2002). Dermoscopy: alternative melanocytic algorithms—the ABCD rule of dermatoscopy, menzies scoring method, and 7-point checklist. *Clinics in dermatology*, 20(3), 240-247.
- [21]. Nawaz, M., Mehmood, Z., Nazir, T., Naqvi, R. A., Rehman, A., Iqbal, M., & Saba, T. (2022). Skin cancer detection from dermoscopic images using deep learning and fuzzy k-means clustering. *Microscopy Research and Technique*, 85(1), 339-351.

- [22]. Reis, H. C., Turk, V., Khoshelham, K., & Kaya, S. (2022). InSiNet: a deep convolutional approach to skin cancer detection and segmentation. *Medical & Biological Engineering & Computing*, 60(3), 643-662.
- [23]. Rashid, H., Tanveer, M. A., & Khan, H. A. (2019, July). Skin lesion classification using GAN based data augmentation. In *2019 41st Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 916-919). IEEE.
- [24]. Bisla, D., Choromanska, A., Berman, R. S., Stein, J. A., & Polsky, D. (2019). Towards automated melanoma detection with deep learning: Data purification and augmentation. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp. 0-0).
- [25]. Farag, A., Lu, L., Roth, H. R., Liu, J., Turkbey, E., & Summers, R. M. (2016). A bottom-up approach for pancreas segmentation using cascaded superpixels and (deep) image patch labeling. *IEEE Transactions on Image Processing*, 26(1), 386-399.
- [26]. Ahmad, B., Jun, S., Palade, V., You, Q., Mao, L., & Zhongjie, M. (2021). Improving Skin Cancer Classification Using Heavy-Tailed Student T-Distribution in Generative Adversarial Networks (TED-GAN). *Diagnostics*, 11(11), 2147
- [27]. Milton, M. A. A. (2019). Automated skin lesion classification using ensemble of deep neural networks in ISIC 2018: Skin lesion analysis towards melanoma detection challenge. *arXiv preprint arXiv:1901.10802*.
- [28]. Aqib, M., Mehmood, R., Albeshri, A., & Alzahrani, A. (2017, November). Disaster management in smart cities by forecasting traffic plan using deep learning and GPUs. In *International Conference on Smart Cities, Infrastructure, Technologies and Applications* (pp. 139-154). Springer, Cham.
- [29]. Aswin, R. B., Jaleel, J. A., & Salim, S. (2014, July). Hybrid genetic algorithm—Artificial neural network classifier for skin cancer detection. In *2014 International Conference on Control, Instrumentation, Communication and Computational Technologies (ICCICCT)* (pp. 1304-1309). IEEE.
- [30]. Jaleel, J.A.; Salim, S.; Aswin, R. Artificial Neural Network Based Detection of Skin Cancer. *Int. J. Adv. Res. Electr. Electron. Instrum. Eng.* 2012, 1, 200–205.
- [31]. Cueva, W. F., Muñoz, F., Vásquez, G., & Delgado, G. (2017, August). Detection of skin cancer” Melanoma” through computer vision. In *2017 IEEE XXIV International Conference on Electronics, Electrical Engineering and Computing (INTERCON)* (pp. 1-4). IEEE.
- [32]. ur Rehman, M., Khan, S. H., Rizvi, S. D., Abbas, Z., & Zafar, A. (2018, July). Classification of skin lesion by interference of segmentation and convolution neural network. In *2018 2nd International Conference on Engineering Innovation (ICEI)* (pp. 81-85). IEEE.
- [33]. Harley, A. W. (2015, December). An interactive node-link visualization of convolutional neural networks. In *International Symposium on Visual Computing* (pp. 867-877). Springer, Cham.
- [34]. Zeiler, M.D.; Fergus, R. Visualizing and Understanding Convolutional Networks. *arXiv 2013*, arXiv:1311.2901. Available online: <http://arxiv.org/abs/1311.2901> (accessed on 15 February 2021).
- [35]. Nasr-Esfahani, E., Samavi, S., Karimi, N., Sorousmehr, S. M. R., Jafari, M. H., Ward, K., & Najarian, K. (2016, August). Melanoma detection by analysis of clinical images using convolutional neural network. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 1373-1376). IEEE.
- [36]. Yu, L., Chen, H., Dou, Q., Qin, J., & Heng, P. A. (2016). Automated melanoma recognition in dermoscopy images via very deep residual networks. *IEEE transactions on medical imaging*, 36(4), 994-1004.
- [37]. Dorj, U. O., Lee, K. K., Choi, J. Y., & Lee, M. (2018). The skin cancer classification using deep convolutional neural network. *Multimedia Tools and Applications*, 77(8), 9909-9924.
- [38]. Kalouche, S. Vision-Based Classification of Skin Cancer Using Deep Learning. 2016. Available online: <https://www.semanticscholar.org/paper/Vision-Based-Classification-of-Skin-Cancer-using-Kalouche/b57ba909756462d812dc20fca157b3972bc1f533> (accessed on 10 January 2021).
- [39]. Burguillo, J. C., & Dorronsoro, B. (2013). Using complex network topologies and self-organizing maps for time series prediction. In *Nostradamus 2013: Prediction, Modeling and Analysis of Complex Systems* (pp. 323-332). Springer, Heidelberg.
- [40]. Gonog, L., & Zhou, Y. (2019, June). A review: generative adversarial networks. In *2019 14th IEEE conference on industrial electronics and applications (ICIEA)* (pp. 505-510). IEEE.

- [41]. Goodfellow, I. NIPS 2016 Tutorial: Generative Adversarial Networks. arXiv 2017, arXiv:1701.00160. Available online: <http://arxiv.org/abs/1701.00160> (accessed on 25 January 2021).
- [42]. Fu'adah, Y. N., Pratiwi, N. C., Pramudito, M. A., & Ibrahim, N. (2020, December). Convolutional neural network (cnn) for automatic skin cancer classification system. In *IOP Conference Series: Materials Science and Engineering* (Vol. 982, No. 1, p. 012005). IOP Publishing.
- [43]. Kanimozhi, T.; Murthi, D.A. Computer-Aided Melanoma Skin Cancer Detection Using Artificial Neural Network Classifier. *J. Sel. Areas Microelectron.* 2016, 8, 35–42.
- [44]. Salian, A. C., Vaze, S., Singh, P., Shaikh, G. N., Chapaneri, S., & Jayaswal, D. (2020, April). Skin lesion classification using deep learning architectures. In *2020 3rd International conference on communication system, computing and IT applications (CSCITA)* (pp. 168-173). IEEE.
- [45]. Singh, V., & Nwogu, I. (2018, October). Analyzing skin lesions in dermoscopy images using convolutional neural networks. In *2018 IEEE International Conference on Systems, Man, and Cybernetics (SMC)* (pp. 4035-4040). IEEE.
- [46]. Mahbod, A., Schaefer, G., Wang, C., Ecker, R., & Ellinge, I. (2019, May). Skin lesion classification using hybrid deep neural networks. In *ICASSP 2019-2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)* (pp. 1229-1233). IEEE.
- [47]. DeVries, T., & Ramachandram, D. (2017). Skin lesion classification using deep multi-scale convolutional neural networks. *arXiv preprint arXiv:1703.01402*.
- [48]. Lenhardt, L., Zeković, I., Dramićanin, T., & Dramićanin, M. D. (2013). Artificial neural networks for processing fluorescence spectroscopy data in skin cancer diagnostics. *Physica Scripta*, 2013(T157), 014057.
- [49]. Mengistu, A. D., & Alemayehu, D. M. (2015). Computer vision for skin cancer diagnosis and recognition using RBF and SOM. *International Journal of Image Processing (IJIP)*, 9(6), 311-319.
- [50]. Sajid, P. M., & Rajesh, D. A. (2018). Performance evaluation of classifiers for automatic early detection of skin cancer. *J. Adv. Res. Dyn. Control. Syst*, 10, 454-461.
- [51]. Ali, I.S.; Mohamed, M.F.; Mahdy, Y.B. Data Augmentation for Skin Lesion Using Self-Attention Based Progressive Generative Adversarial Network. arXiv 2019, arXiv:1910.11960. Available online: <http://arxiv.org/abs/1910.11960> (accessed on 22 January 2021).
- [52]. Manne, R., Kantheti, S., & Kantheti, S. (2020). Classification of Skin cancer using deep learning, Convolutional Neural Networks-Opportunities and vulnerabilities-A systematic Review. *International Journal for Modern Trends in Science and Technology*, ISSN, 2455-3778.
- [53]. Munir, K., Elahi, H., Ayub, A., Frezza, F., & Rizzi, A. (2019). Cancer diagnosis using deep learning: a bibliographic review. *Cancers*, 11(9), 1235.
- [54]. Tschandl, P., Rosendahl, C., & Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific data*, 5(1), 1-9.
- [55]. Mendonça, T., Ferreira, P. M., Marques, J. S., Marcal, A. R., & Rozeira, J. (2013, July). PH 2-A dermoscopic image database for research and benchmarking. In *2013 35th annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 5437-5440). IEEE.
- [56]. ISIC Archive. Available online: <https://isic-archive.com/> (accessed on 1 January 2021).
- [57]. Codella, N. C., Gutman, D., Celebi, M. E., Helba, B., Marchetti, M. A., Dusza, S. W., ... & Halpern, A. (2018, April). Skin lesion analysis toward melanoma detection: A challenge at the 2017 international symposium on biomedical imaging (isbi), hosted by the international skin imaging collaboration (isic). In *2018 IEEE 15th international symposium on biomedical imaging (ISBI 2018)* (pp. 168-172). IEEE.
- [58]. Boer, A., & Nischal, K. C. (2007). Get set for the net-www. derm101. com: A growing online resource for learning dermatology and dermatopathology.
- [59]. DermIS. Available online: <https://www.dermis.net/dermisroot/en/> (accessed on 5 January 2021)
- [60]. Argenziano, G., Soyer, H. P., De Giorgio, V., Piccolo, D., Carli, P., Delfino, M., ... & Wolf, I. H. (2000). Interactive atlas of dermoscopy.

- [61]. Dermnet. Available online: <http://www.dermnet.com/dermatology-pictures-skin-disease-pictures/> (accessed on 8 January 2021).
- [62]. https://www.researchgate.net/figure/The-specific-information-of-the-ISIC-2016-dataset-ISIC-2017-dataset-and-PH2_tbl1_350026178
- [63]. Harangi, B. (2018). Skin lesion classification with ensembles of deep convolutional neural networks. *Journal of biomedical informatics*, 86, 25-32.
- [64]. Khan, M. Q., Hussain, A., Rehman, S. U., Khan, U., Maqsood, M., Mehmood, K., & Khan, M. A. (2019). Classification of melanoma and nevus in digital images for diagnosis of skin cancer. *IEEE Access*, 7, 90132-90144.
- [65]. Ameri, A. (2020). A deep learning approach to skin cancer detection in dermoscopy images. *Journal of biomedical physics & engineering*, 10(6), 801.
- [66]. Garbaj, M., & Deshpande, A. S. (2015). Detection and analysis of skin cancer in skin lesions by using segmentation. *IJARCCCE*.
- [67]. https://dermosclopedia.org/Menzies_Method
- [68]. Mahecha, M. S. S., Parra, O. J. S., & Velandia, J. B. (2018, October). Design of a System for Melanoma Detection Through the Processing of Clinical Images Using Artificial Neural Networks. In *Conference on e-Business, e-Services and e-Society* (pp. 605-616). Springer, Cham.
- [69]. Møller, M. F. (1993). A scaled conjugate gradient algorithm for fast supervised learning. *Neural networks*, 6(4), 525-533.
- [70]. Sagar, A., & Jacob, D. (2021). Convolutional neural networks for classifying melanoma images. *bioRxiv*, 2020-05.
- [71]. Nida, N., Irtaza, A., Javed, A., Yousaf, M. H., & Mahmood, M. T. (2019). Melanoma lesion detection and segmentation using deep region based convolutional neural network and fuzzy C-means clustering. *International journal of medical informatics*, 124, 37-48.
- [72]. Tumpa, P. P., & Kabir, M. A. (2021). An artificial neural network based detection and classification of melanoma skin cancer using hybrid texture features. *Sensors International*, 2, 100128.
- [73]. Alsaade, F. W., Aldhyani, T. H., & Al-Adhaileh, M. H. (2021). Developing a recognition system for diagnosing melanoma skin lesions using artificial intelligence algorithms. *Computational and mathematical methods in medicine*, 2021.
- [74]. Nasr-Esfahani, E., Samavi, S., Karimi, N., Sorousmehr, S. M. R., Jafari, M. H., Ward, K., & Najarian, K. (2016, August). Melanoma detection by analysis of clinical images using convolutional neural network. In *2016 38th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)* (pp. 1373-1376). IEEE.
- [75]. Shoieb, D.A.; Aly, W.M.; Youssef, S.M. Basal Cell Carcinoma Detection in Full-Field OCT Images Using Convolutional Neural Networks. *JOIG* 2016, 4, 122–129.
- [76]. Kalouche, S. Vision-Based Classification of Skin Cancer Using Deep Learning. 2016. Available online: <https://www.semanticscholar.org/paper/Vision-Based-Classification-of-Skin-Cancer-using-Kalouche/b57ba909756462d812dc20fca157b3972bc1f533> (accessed on 10 January 2021).
- [77]. Esteva, A., Kuprel, B., Novoa, R. A., Ko, J., Swetter, S. M., Blau, H. M., & Thrun, S. (2017). Dermatologist-level classification of skin cancer with deep neural networks. *nature*, 542(7639), 115-118.
- [78]. Attia, M., Hossny, M., Nahavandi, S., & Yazdabadi, A. (2017, April). Skin melanoma segmentation using recurrent and convolutional neural networks. In *2017 IEEE 14th International Symposium on Biomedical Imaging (ISBI 2017)* (pp. 292-296). IEEE.
- [79]. DeVries, T., & Ramachandram, D. (2017). Skin lesion classification using deep multi-scale convolutional neural networks. *arXiv preprint arXiv:1703.01402*.
- [80]. Harangi, B., Baran, A., & Hajdu, A. (2018, July). Classification of skin lesions using an ensemble of deep neural networks. In *2018 40th annual international conference of the IEEE engineering in medicine and biology society (EMBC)* (pp. 2575-2578). IEEE.
- [81]. Namozov, A., Ergashev, D., & Im Cho, Y. (2018, December). Adaptive activation functions for skin lesion classification using deep neural networks. In *2018 Joint 10th International Conference on Soft Computing and Intelligent Systems (SCIS) and 19th International Symposium on Advanced Intelligent Systems (ISIS)* (pp. 232-235). IEEE.