

روش جدید دسته‌بندی خودکار تصاویر مبنی بر الگوریتم بهبود یافته ازدحام سالپ

احمد کاظمی^۱، مهدی صادق‌زاده^۲، امیر شیخ‌احمدی^۳

^۱ دانشجوی، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی واحد سنندج، سنندج، ایران.
^۲ استادیار، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی واحد ماهشهر، ماهشهر، ایران.
^۳ استادیار، گروه مهندسی کامپیوتر، دانشگاه آزاد اسلامی واحد سنندج، سنندج، ایران.

نام نویسنده مسئول:

احمد کاظمی

چکیده

اکثر پژوهش‌ها بر روی استخراج ویژگی‌ها در دامنه فرکانس، مکان و کاهش ابعاد ویژگی تمرکز دارند. هدف اصلی عمده آنها استفاده از روش‌های مکاشفه‌ای برای افزایش کارکرد برآوردگر الگوریتم یادگیری و ادامه دستیابی به وضعیت مطلوب و همچنین دسته‌بندی بدون تداخل کاربر و اجرای خودکار آن از طریق مدل ایجادشده در مراحل بالا است. در این مقاله، روش یادگیری جدیدی مبتنی بر الگوریتم بهبود یافته ازدحام سالپ پیشنهاد شده است که در درخت تصمیم، نزدیک‌ترین همسایه‌های **K** و نایو بیز پیاده‌سازی و ارزیابی شده است. نتایج نشان‌دهنده بهبود عملکرد الگوریتم مورد نظر در مقایسه با الگوریتم‌های یادگیری سنتی است. از لحاظ دقت، حساسیت و خطای دسته‌بندی، بهترین عملکرد مدل پیشنهادی از روش یادگیری درخت تصمیم با مقادیر به ترتیب ۹۹٫۱۸٪، ۱۰۰٪ و ۰٫۸۶٪ بهره می‌گیرد. از لحاظ معیار ویژگی، بهترین عملکرد مدل پیشنهادی مبتنی بر روش یادگیری نزدیک‌ترین همسایه‌های **K** با مقدار ۱۰۰٪ است.

واژگان کلیدی: دسته‌بندی تصویر، الگوریتم یادگیری، الگوریتم ازدحام سالپ.

مقدمه

تصویربرداری پزشکی از یکی از مهم‌ترین ابزارهای پزشکی مدرن محسوب می‌شود. انواع مختلف تکنیک‌های تصویربرداری برای تشخیص انواع بیماری‌ها به کار می‌روند. تصاویر پزشکی مهم می‌توانند نقش مهمی در کمک به تشخیص پزشکی ایفا کنند. با این حال، در کاربردهای بالینی، بررسی دستی تصاویر معمولاً زمان زیادی می‌گیرد. بنابراین، روش تشخیص خودکار برای پزشکان مفید خواهد بود. در رابطه با نیاز به تحلیل پزشکی، دسته‌بندی تصاویر خودتصادم^۱ یکی از مهم‌ترین مسائل به شمار می‌رود [۴، ۵]. عمدتاً، تصاویر MRI به‌منظور تشخیص وجود تومور در مغز به کار می‌روند. اطلاعات دریافتی از تصویر مورد نظر در درمان بیمار اهمیت بسیار زیادی دارد. تصویرکاوی دانش ضمنی تصاویر را به کار می‌گیرد. یکی از مهم‌ترین تکنیک‌های تصویرکاوی عبارت است از دسته‌بندی تصاویری که تصاویر موجود را به چند دسته از پیش تعیین شده تصاویری که به آن‌ها تعلق دارند اختصاص می‌دهد. بدین منظور، دسته‌بندی‌ها باید ابتدا توسط متخصص مشخص و برچسب‌زنی شوند. سپس، ویژگی‌های اصلی این تصاویر استخراج می‌شوند و با استفاده از یادگیری ماشین به سیستم آموزش داده می‌شود که دفعه بعد تصاویری که وارد سیستم می‌شوند در گروه درست دسته‌بندی شوند [۶-۸].

دسته‌بندی نوعی مسأله یادگیری ماشین است که در مورد نحوه تخصیص تگ‌ها به داده‌های جدید بر اساس مجموعه‌ای از داده‌های تگ‌شده بحث می‌کند. نتیجه توسط ورودی ارائه می‌شود. به‌منظور پیش‌بینی نتیجه، الگوریتم مجموعه آموزش حاوی مجموعه‌ای از خصیصه‌ها و نتیجه را پردازش می‌کند. الگوریتم دسته‌بندی پیکسل‌های تصویر را به مجموعه‌ها یا کلاس‌های مطلوب تخصیص می‌دهد. مراحل اصلی در فرایند دسته‌بندی تصاویر عبارتند از: استخراج ویژگی‌ها، کاهش ابعاد ویژگی‌ها، دسته‌بندی و ارزیابی [۱].

به‌طور کلی، روش‌های یادگیری ماشین را می‌توان به دو گروه یادگیری تحت نظارت و یادگیری بدون نظارت تقسیم کرد. در یادگیری بدون نظارت مجموعه داده‌های آموزش با دسته‌بندی‌های از پیش تعریف شده به کار نمی‌رود. در یادگیری نظارت‌شده یا یادگیری از نمونه‌ها، کاربر نقش آموزگار را ایفا می‌کند و باید نمونه‌هایی برای هر کلاس ارائه کند [۲، ۳].

تاکنون، پژوهش‌های متعددی به‌منظور دسته‌بندی تصاویر MRI صورت گرفته است. اکثر پژوهش‌ها روی استخراج ویژگی‌ها در دامنه فرکانس، مکان و کاهش ابعاد ویژگی تمرکز دارند. هدف این پژوهش‌ها ایجاد نوعی مدل دسته‌بندی به‌منظور افزایش بازدهی دسته‌بندی تصاویر مربوط بوده است. لازم به ذکر است که روش‌های پیشنهادشده، علاوه بر نقاط قوت‌شان، محدودیت‌هایی هم دارند. با در نظر گرفتن اهمیت این موضوع در این پژوهش، سعی می‌کنیم از نقاط قوت روش‌های قبلی نفع ببریم و بر محدودیت‌ها و کاستی‌های‌شان غلبه کنیم و، در نهایت، دقت درست در روش پیشنهادی را بیابیم. در این پژوهش هدف استفاده از روش‌های مکاشفه‌ای برای افزایش کارکرد برآوردگر الگوریتم یادگیری و ادامه دستیابی به وضعیت مطلوب و همچنین دسته‌بندی بدون تداخل کاربر و اجرای خودکار آن از طریق مدل ایجادشده در مراحل بالا است. در پژوهش حاضر، از الگوریتم ازدحام سالپ به‌منظور بهبود عملکرد الگوریتم‌های یادگیری استفاده شده است. در نهایت، انتظار می‌رود مدل پیشنهادی در داده‌های آزمایشی، که هنوز در مدل تولیدشده دیده نشده‌اند، عملکرد خوبی داشته باشد. به‌منظور پیاده‌سازی و به‌کارگیری مدل پیشنهادی، الگوریتم‌ها و روش‌های یادگیری ماشین نظیر KNN، نایو بیز و درخت تصمیم به کار خواهند رفت. با توجه به این‌که روش‌های یادگیری سنتی هستند و نتایج ایجادشده توسط این روش‌ها ممکن است اطمینان‌پذیری بالایی داشته باشند، این مطالعه روی بهبود عملکرد مرحله یادگیری تمرکز دارد، تا مدلی کارآمد و قابل اطمینان به دسته‌بندی درست داده‌ها دست یابد. نتایج نشان‌دهنده بهبود عملکرد یادگیری الگوریتم‌ها در مقایسه با الگوریتم‌های یادگیری سنتی است.

کارهای تحقیقاتی مرتبط

نویسنده‌های مطالعه [۹] در سال ۲۰۱۸ بر روی تشخیص الگوی شبکه رنگ‌دانه در تصاویر درماتوسکوپی بر اساس طبقه‌بندی فازی پیکسل‌ها کار کرده‌اند. یکی از مهم‌ترین الگوهای درماتوسکوپی شبکه رنگ‌دانه است. یک روش ابتکاری برای تشخیص الگو برای تشخیص آن در تصاویر پوستی ارائه شده است. روش‌ها شامل دو مرحله است. در مرحله اول، با استفاده از یک فرآیند یادگیری ماشین تحت نظارت و پس از انجام استخراج ویژگی‌های رنگ و بافت‌های مختلف، طبقه‌بندی فازی پیکسل‌ها به سه دسته موجود در تعریف الگوی ("خالص"، "سوراخ" و "دیگر") انجام شده است.

در دسته‌بندی تصاویر، یک پیکسل یا گروهی از پیکسل‌ها بر اساس مقدار خاکستری تگ‌گذاری می‌شوند. دسته‌بندی یکی از روش‌های رایج استخراج اطلاعات به شمار می‌رود. در دسته‌بندی، معمولاً چند ویژگی برای مجموعه‌ای از پیکسل‌ها به کار می‌روند (مثلاً، تعداد زیادی تصویر شیئی بخصوص لازم است) [۴، ۱۰]. ویژگی‌های مهم تصاویر از مجموعه داده‌ها استخراج می‌شوند و توسط الگوریتم‌های یادگیری ماشین به کار می‌روند و به سیستم آموزش می‌دهد تا تصاویر در دفعات بعد در گروه درست دسته‌بندی شوند. مراحل پایه فرایند

¹ self-colliding

دسته‌بندی تصاویر عبارتند از: آموزش سیستم و آزمایش سیستم. سیستم ابتدا ویژگی‌های پایه را از داده‌های ورودی استخراج می‌کند و بعد ابعاد مجموعه ویژگی را به‌منظور تسریع عملکرد سیستم کاهش می‌دهد. در مرحله بعد با استفاده از الگوریتم یادگیری ماشین مدلی برای دسته‌بندی داده‌ها ایجاد می‌کند.

اکثر مطالعات روی استخراج و کاهش ویژگی‌های تصاویر در زمینه یادگیری تمرکز داشته‌اند. در مطالعه [۱۱]، نویسنده‌ها تحلیل جزء اصلی در مرحله انتخاب ویژگی و ماشین بردار پشتیبان^۲ در مرحله یادگیری را ایجاد کرده‌اند. نویسنده‌های مذکور در روش پیشنهادی با استفاده از PCA ابعاد ویژگی‌ها را تا ۱۰۲۴ ویژگی کاهش داده‌اند. سپس، با استفاده از DWT، PCA و KSVM با کرنل GRB به عملکرد بهتر در دسته‌بندی تصاویر دست یافته‌اند.

نویسنده‌های مطالعه [۱۲] بر روی الگوریتم خوشه‌بندی فازی برای دسته‌بندی تصویر میکرو ارگانی کار کرده‌اند. تصویر میکرو آهن cDNA اطلاعاتی مفصل درباره هزاران عبارات ژنی را به‌طور هم‌زمان فراهم می‌کند. از این رو میکرو آرایه تقسیم‌بندی تصویر یک کار مهم است. در این مقاله، روش‌های تقسیم‌بندی تصویر خوشه‌ای فازی موجود برای سازگاری با تصاویر میکرو ارگانیک cDNA مورد آزمایش قرار گرفته است. الگوریتم‌های موردنظر برای این هدف شامل روش مبتنی بر خوشه‌بندی فازی می‌باشد. نتایج تقسیم‌بندی نشان می‌دهد که روش خوشه‌بندی فازی در تقسیم نقاط میکروسکوپ نسبت به دیگر روش‌ها تحت تصاویر نویزدار بهتر است.

نویسنده‌های مطالعه [۱۳] روش خود را تحلیل خوشه‌بندی طیفی اجزاء مستقل برای دسته‌بندی بافت از MRI مغز شرح می‌دهند. این نویسندگان از روش خوشه‌بندی ویژگی پراکنندگی طیفی زاویه‌دار-طیفی استفاده کرده‌اند. روش پیشنهادی اولویت‌بندی یکسانی برای ویژگی‌های عمومی و محلی ارائه می‌کند. بنابراین، به دنبال کسب بازدهی روش‌های معمول برای استخراج بافت‌های غیرعادی است. ابتدا، MRI چندطیفی با استفاده از خوشه‌بندی مبتنی بر فاصله به دسته‌بندی‌های مختلف تقسیم می‌شود. سپس، تحلیل جزء مستقل به‌منظور خوشه کردن داده‌ها به کار می‌رود. علاوه بر این، ماشین بردار پشتیبان به‌منظور تحلیل بافت به کار می‌رود. نتایج نشان می‌دهند که دسته‌بندی بافت مغز با این روش عملکرد بالا، مخصوصاً برای ضایعات و تومورهای کوچک، تحلیل بالینی فراهم می‌سازد.

متدلوژی نویسندگان در مقاله منبع [۱۴] روش فازی می‌باشد. طبقه‌بندی فازی پیکسل‌های تصویری را که مربوط به تنوع سطحی خاک در جهت‌های مختلف است تشخیص می‌دهد. از یک تابع گسترده به‌عنوان یک تابع عضویت فازی برای هر کلاس استفاده می‌کند، جایی که کلاس اختصاص داده‌شده به هر پیکسل، دارای بیشترین حقیقت فازی عضویت است. این دسته‌بندی برای اولین بار انجام می‌شود، پس‌از آن یک رقابت به‌عنوان گامی دوم برای نازک شدن لبه‌ها اجرا می‌شود؛ عملکرد الگوریتم تا حدودی شبیه الگوریتم لبه‌یابی canny است، اما بسیار سریع‌تر عمل می‌کند. برای هر دو، سطح مناسب حساسیت باید توسط کاربر برای بهترین نتایج انتخاب شود، زیرا لبه‌های بیشتر با نویز بیشتری نسبت به لبه‌های کمتر و نویز کمتر است.

متدلوژی نویسندگان در مقاله منبع [۱۵] دسته‌بندی MRI به عادی یا یکی از هفت بیماری مختلف است. در ابتدا، دو سطح تبدیل موجک دوبعدی گسسته (DWT 2D) از تصویر ورودی محاسبه می‌شود. بازگشت به تعمیم ناهمگن مشروط آن، که نوعی روش آماری است، پارامترهای این مدل بردارهای ویژگی اصلی را شکل می‌دهد. بعد از نرمال‌سازی این ویژگی‌ها، LDA و PCA ابعاد را کاهش می‌دهد و سپس تصاویر با استفاده از الگوریتم‌های KNN و الگوریتم‌های بردار پشتیبانی دسته‌بندی می‌شوند.

در روش منبع [۱۶]، به‌منظور تشخیص سرطان مغز با استفاده از کامپیوتر برای پیش‌بینی اولیه، نویسنده‌ها از ویژگی‌های بافت و منطق دسته‌بندی شبکه عصبی مصنوعی استفاده کرده‌اند. این امر شامل استخراج ویژگی‌های بافت از نمونه MRI مغز می‌شود که با بهره‌گیری از تبدیل موجک گسسته و ویژگی‌های مورفولوژیکی، و برای دسته‌بندی شبکه عصبی به کار رفته است. در این روش، با استفاده از تکنیک‌های پردازش تصویر، دسته‌بندی بسیار مناسبی صورت گرفته است.

نویسنده‌های مطالعه منبع [۱۷] روشی تحت عنوان «بهبود عملکرد» (شبکه‌های عصبی مصنوعی برای دسته‌بندی تصاویر MRI دو پارامتر مهم در شبکه‌های عصبی) پیشنهاد کرده‌اند که منجر به افزایش دقت و همگرایی شده است. مشکل اصلی در شبکه‌های عصبی این است که شبکه‌های دقت‌بالا مستلزم زمان همگرایی زیاد هستند، و شبکه‌هایی که زمان همگرایی پایین دارند نیز دقت کمتری دارند. بنابراین، اهمیت همگرایی و دقت بالا است. این نویسندگان در شبکه عصبی و شبکه کوهن بهبودهایی در روش آموزش این شبکه‌ها با استفاده از تکرار آزاد داشته‌اند و نهایتاً منجر به بهبود سرعت همگرایی و دقت شده‌اند. نتایج روش مذکور بهبود بهره‌وری در مقایسه با شبکه‌های مرسوم نشان می‌دهد. نتایج نشان می‌دهد که سرعت تقریباً ۵ تا ۱۰ برابر بیشتر است و پیچیدگی محاسباتی این شبکه‌ها کاهش یافته است.

² Support vector machine

در منبع [۱۸]، نویسندگان سیستمی ترکیبی برای تشخیص تومور در تصاویر MRI استفاده کرده‌اند و دسته‌بندی‌شان به کمک شبکه‌های عصبی مصنوعی و نزدیک همسایه صورت گرفته است. در روش پیشنهادی، نویسندگان ویژگی‌ها را با استفاده از تبدیل موجک گسسته استخراج کرده‌اند و سپس به منظور انتخاب بهترین ویژگی‌ها روش PCA را به کار برده‌اند. خصیصه‌های انتخاب‌شده به‌عنوان ورودی‌های دسته‌بندها به کار می‌روند.

روش پیشنهادی

اکثر پژوهش‌ها روی انتخاب ویژگی‌ها و کاهش ابعاد آنها تمرکز داشته‌اند و، از طرف دیگر، با توجه به این‌که روش‌های یادگیری فعلی قدیمی هستند، نتایج حاصل از این روش‌ها ممکن است نرخ خطای بالا و اطمینان‌پذیری پایینی داشته باشد. بنابراین، مطالعه حاضر روی بهبود عملکرد مرحله یادگیری تمرکز دارد تا مدل کارآمد و قابل اطمینان را بتوان برای دسته‌بندی درست داده‌ها به کار برد. روش پیشنهادی تصاویر را به صورت خودکار بر اساس دسته‌ها دسته‌بندی می‌کند. در این پژوهش، روش‌های الگوریتم ازدحام سالپ به منظور جستجوی فضای پارامترها برای انتخاب مقادیر بهینه برای تابع ارزیاب روش یادگیری به کار رفته است [۳].

با توجه به این‌که روش‌های یادگیری سنتی هستند و نتایج ایجادشده توسط این روش‌ها ممکن است خطاهای زیادی داشته باشند، این مطالعه روی بهبود عملکرد مرحله یادگیری تمرکز دارد، تا به مدلی کارآمد و قابل اطمینان برای دسته‌بندی درست داده‌ها دست یابد. جنبه نوآوری و تازگی را می‌توان به صورت زیر شرح داد:

- دسته‌بندی خودکار تصاویر به دسته‌های مربوطه.
- استفاده از روش مکاشفه‌ای به منظور جستجوی فضای پارامترها.
- آزمایش خروجی مدل ایجادشده و انتخاب مقادیر مناسب برای پارامترها.
- ایجاد مدل یادگیری کارآمد برای جمع‌آوری خودکار داده‌های تصویر با استفاده از روش‌های یادگیری ماشین بر اساس روش‌های مکاشفه‌ای.

در دسته‌بندی پیشنهادی تصاویر، مجموعه داده مناسب انتخاب خواهد شد. سپس باید دسته‌بندی هر تصویر مشخص می‌شود، یعنی عمل تگ‌گذاری انجام خواهد گرفت. پس از آن، به منظور به‌کارگیری تصاویر در مراحل بعدی، تصاویر به بردار ویژگی تبدیل می‌شود، و با استفاده از روش انتخاب ویژگی‌های غیرمفید شناسایی می‌شوند و سعی می‌شود تعداد محدودی از ویژگی‌هایی که اهمیت بیشتری دارند انتخاب شود. این امر می‌تواند منجر به افزایش دقت دسته‌بندی نهایی می‌شود [۳].

بعد از تعیین ویژگی‌های مناسب، عملیات دسته‌بندی انجام خواهد شد. روش‌های مختلفی برای دسته‌بندی با عملکردهای مختلف وجود دارد. در این پژوهش، هدف استفاده از روش SSA، افزایش کارکرد برآوردگر الگوریتم یادگیری و دستیابی به وضعیت مطلوب و همچنین دسته‌بندی بدون تداخل کاربر است. این امر با استفاده از مدل تست‌شده با معیارهای مختلف انجام می‌شود که نهایتاً منجر به ایجاد روشی قابل اطمینان می‌شود. در این پژوهش، در مرحله یادگیری الگوریتم‌های نایویز، نزدیکترین همسایگی و درخت تصمیم به کار رفته‌اند که با استفاده از الگوریتم ازدحام سالپ بهبود یافته‌اند. جزئیات روش پیشنهادی در ادامه آمده است [۷].

در این پژوهش از ۱۰۰ تصویر MRI با اندازه ۲۵۶×۲۵۶ پیکسل و ۸۰ تصویر MRI با اندازه ۵۱۲×۵۱۲ پیکسل استفاده شده است [۲۰]. همه این تصاویر توسط افراد متخصص برجسب‌گذاری شده‌اند. هر تصویر یک وضعیت دارد: عادی یا غیرعادی. در سوی دیگر، مغز سالم یا بیمار و نوع بیماری‌اش برجسب‌گذاری شده است. در این مجموعه داده، ۱۰ درصد از تصاویر عادی و ۹۰ درصد از تصاویر غیرعادی هستند که شرایط مغزی مختلفی دارند.

به منظور استخراج ویژگی، ضرایب تبدیل موجک گسسته به‌عنوان بردار ویژگی به کار رفته‌اند. تبدیل موجک ابزار ریاضی قدرتمندی برای استخراج ویژگی‌ها محسوب می‌شود و می‌تواند برای استخراج ضرایب موجک از تصاویر MRI به کار رود. موجک‌ها توابع محلی پایه هستند. مزیت اصلی موجک این است که اطلاعات فراوان محلی درباره عملکرد سیگنال‌ها، مخصوصاً برای دسته‌بندی‌های مفید، فراهم می‌سازد. نمونه داده‌ها در شکل ۱ نشان داده شده است [۱۹].



شکل ۱- نمونه داده‌ها با اندازه ۲۵۶×۲۵۶

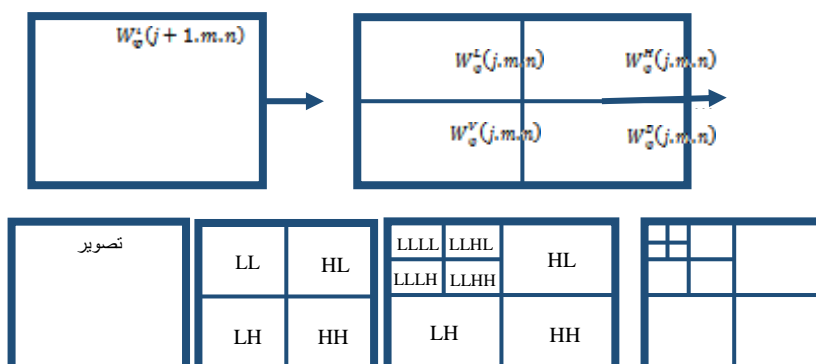
استخراج و کاهش ویژگی

یکی از موجک‌های گسسته موجک هار می‌باشد که به سبب نوعی تناوب موج مربعی و سادگی آن، بیشترین کاربرد را در انتخاب ویژگی داراست. با استفاده از این موجک، تابع مورد نظر را می‌توان در سطوح مختلف تحلیل کرد. موجک گسسته توانایی تحلیل سیگنال‌ها در دامنه‌های فضایی و زمانی و همچنین انعطاف‌پذیری بیشتر، فشرده‌سازی بهتر و عملکرد بالا را متحول می‌سازد. تبدیل موجک گسسته را می‌توان با استفاده از فرمول ۱ شرح داد.

$$DWT_{x(n)} = \left\{ \begin{array}{l} d_{j,k} = \sum x(n) h_j^*(n - 2jk) \\ a_{j,k} = \sum x(n) g_j^*(n - 2jk) \end{array} \right. \quad (1)$$

ضریب‌های $d_{j,k}$ بیانگر اجزاء سیگنال $x(n)$ و برابر با تابع موجک هستند، در حالی که $a_{j,k}$ بیانگر ضریب‌های تقریب در سیگنال $x(n)$ است. توابع $h(n)$ و $g(n)$ در معادله ضریب‌های فیلترهای بالاگذر و پایین‌گذر هستند. پارامترهای j و k به ترتیب مقیاس و فرستنده موجک هستند. در مرحله قبلی، تعدادی از ویژگی‌ها از تصاویری استخراج شده‌اند که مستقیماً روی تابع دسته‌بندی تأثیر می‌گذارند. اگر قرار باشد ابعاد داده‌ها کاهش یابد، عملکرد نهایی دسته‌بندی می‌تواند بهبود یابد.

در روش به کار رفته، عملیات تجزیه سه‌سطحی در هر تصویر مطابق با به کارگیری موجک تصادفی انجام می‌شود. در مطالعه حاضر، از آنجایی که دو نوع از ابعاد تصویر وجود دارد، در مرحله اول ماتریس مورد نظر به صورت یک دوم اندازه تصویر برآورد می‌شود، در مرحله دوم یک چهارم و در مرحله سوم یک هشتم که در نتیجه، در این مرحله، برای یک تصویر ماتریس خطی برآورد شده ایجاد خواهد شد. این ماتریس خطی به عنوان ماتریس ویژگی تصویر در نظر گرفته می‌شود. با این کار ماتریس جزئیات تصویر نادیده گرفته خواهد شد. یکی از دلایل نادیده گرفتن ماتریس جزئیات تفاوت در ساختار تصاویر MRI مغز سالم با تصاویر MRI نواحی غیرضروری مغز است. در نتیجه، نیازی به دانستن لبه‌های عمودی، افقی و مورب نیست. شکل ۲ مراحل تبدیل شکل موج موجک در سه سطح را نشان می‌دهد.




شکل ۲- مراحل تبدیل موجک ورتکس در سه سطح

پس از استخراج ویژگی‌ها از تصاویر، داده‌های یادگیری و آزمایش همه بردارهای ویژگی در ماتریس در ابعاد زیر، تحت انواع ماتریس ویژگی‌ها، وجود خواهد داشت.

$$(۲) \quad \text{ماتریس ویژگی‌ها} = [\text{تعداد تصاویر یادگیری و آزمایش} * \text{تعداد ویژگی‌ها}]$$

با داشتن تعداد ۱۰۰ و ۸۰ تصویر و ۱۰۲۴ خصیصه، دو ماتریس ویژگی استخراج شده با اندازه‌های 1024×100 و 1024×80 وجود خواهد داشت. تعداد ویژگی‌های تولیدی بسیار زیاد است و این تعداد ویژگی‌ها در عملکرد نهایی تأثیر منفی خواهد داشت در نتیجه باید ابعاد ویژگی‌ها کاهش یابد. یکی از برجسته‌ترین روش‌های انتخاب ویژگی روش PCA می‌باشد. این ابزار به منظور تبدیل ویژگی‌های ورودی موجود به فضایی جدید از ویژگی‌هایی با ابعاد کمتر به کار می‌رود. ایده اصلی پشت استفاده از PCA در روش مورد نظر کاهش ابعاد ضرب‌های موجک استخراج شده در مرحله استخراج ویژگی است، که دقت و بازدهی در نتایج در دسته مورد نظر را نتیجه می‌دهد. شکل ۳ این نکته را نشان می‌دهد [۱۱].



شکل ۳- کاهش ویژگی

روش PCA همبستگی بین متغیرهای داده را نشان می‌دهد و، از آن جایی که تصاویر MRI همبستگی بالایی دارند، این روش به منظور کاهش فضای داده به فضای ویژگی به کار می‌رود.

ابتدا، PCA ناحیه‌ای را پیدا می‌کند که در آن مجموعه‌های داده تصویر نقاط داده در آن بیشترین فاصله را دارند. به بیان دیگر، واریانس این تصاویر تا حد ممکن بزرگ است. محور دوم به همین شکل به دست می‌آید، به این شرط که عمود بر محور اول باشد. این دو محور با هم بهترین تطابق در صفحه‌ها را نتیجه می‌دهند. این روش در ادامه همه اجزاء جزء اصلی را پیدا می‌کند. کارکرد کاهش ابعاد از طریق به کارگیری تحلیل اجزاء اصلی به صورت زیر است [۱۱]:

مجموعه داده X با N نقطه را در نظر بگیرید، که هر کدام دارای p بعد است:

$$X = \begin{matrix} X_1 & x_{1,1} & x_{1,2} & \dots & x_{1,p} \\ X_2 & x_{2,1} & x_{2,2} & \dots & x_{2,p} \\ X_3 & x_{3,1} & x_{3,2} & \dots & x_{3,p} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ X_n & x_{n,1} & x_{n,2} & \dots & x_{n,p} \end{matrix}$$

الف) مطابق معادله (۳) میانگین ماتریس محاسبه می‌شود (میانگین هر بعد)

$$\bar{X} = \frac{1}{N} \sum_{i=1}^N X_i \quad (۳)$$

ب) سپس انحراف میانگین داده‌ها حساب شده تا هر ستون از میانگین آن ستون کسر شود. سپس، طبق معادله (۴) در ماتریس ذخیره می‌شود.

$$XM = X - \bar{X} \quad (۴)$$

ج) کوواریانس ماتریس XM ، که ماتریس $p \times p$ با نام C_{XM} را محاسبه می‌کند. مطابق معادله (۵) در ماتریس ذخیره می‌شود.

$$C_{XM} = \frac{\sum_{i=1}^n ((X_i - \bar{X})^T \cdot (X_i - \bar{X}))}{N - 1} \quad (۵)$$

در این معادله، $C_{XM}(i,j)$ بیانگر همبستگی بین دو بعد i و j است. مطابق معادله (۶)

$$C_{XM}(i,j) = C_{XM}(j,i) = \frac{\sum_{k=1}^n (XM(k,i) \cdot XM(k,j))}{N-1} \quad (۶)$$

اگر $C_{XM}(i,j) > 0$ باشد، i و j به‌طور یکسان تغییر می‌کنند، اگر $C_{XM}(i,j) < 0$ باشد، i و j معکوس خواهند بود، و اگر $C_{XM}(i,j) = 0$ باشد، می‌توان نتیجه گرفت i و j مستقل از هم هستند.

(د) سپس مقادیر و بردارهای کوواریانس ماتریس C_{XM} محاسبه می‌شود. طبق قواعد جبر خطی، ماتریس متقارن $n \times n$ دارای n بردار ویژه و n مقدار ویژه است.


(ه) بردارها و مقادیر ویژه به‌ترتیب نزولی مرتب می‌شوند. اجزاء اصلی اهمیت به ترتیب از اهمیت زیاد به کم مرتب می‌شوند. به‌منظور کاهش ابعاد، می‌توان اجزاء جزئی، که با کاهش مقدار کوچک اطلاعات در ارتباطند، را از میان برد. مطابق معادله (۷)

$$\text{FeatureVector} = (egi_1 \ egi_2 \ egi_3 \ \dots \ egi_n) \quad (۷)$$

در روش پیشنهادی، ۱۰ مقدار ویژه و بردار ویژه انتخاب خواهد شد که اهمیت بیشتری داشتند. دلیل انتخاب این رقم این است که با ۱۰ مقدار ویژه، پیش‌بینی‌های داده‌ها می‌تواند بیانگر بیش از ۵۰ درصد داده‌ها باشد.

الگوریتم ازدحام سالپ

سالپ عضوی از خانواده سالپ با بدن بشکه‌شکل شفاف مشابه با عروس دریایی است. به‌علاوه، سالپ‌ها همانند عروس‌های دریایی حرکت می‌کنند؛ به‌طوری که در حرکت به جلو آب از طریق بدن پمپاژ می‌شود [۷]. شکل سالپ در تصویر ۴ (الف) آمده است. محققان زیست‌شناسی اطلاعات دقیقی درباره این موجود زنده فراهم نمی‌سازد، زیرا در محیط‌های زیست دور از دسترس زندگی می‌کنند و به‌سختی در محیط آزمایشگاهی قابل نگهداری هستند [۱۹]. رفتار ازدحام سالپ‌ها از ویژگی‌های برجسته و جالب‌توجه‌شان است. در اعماق اقیانوس‌ها، سالپ‌ها معمولاً زنجیره سالپ مبتنی بر ازدحام را تشکیل می‌دهند. این رفتار ازدحام در شکل ۴ (ب) نشان داده شده است. رفتار زندگی‌شان هنوز دقیقاً گزارش نشده است، اما بعضی از محققان معتقدند که با شکار و تغییرات هماهنگ سریع به بهترین جنبش و تحرک دست می‌یابند [۷].



شکل ۴- رفتار ازدحام سالپ‌ها

موقعیت سالپ‌ها از طریق معادله (۸) به‌روزرسانی شده است:

$$x_j^1 = \begin{cases} F_j + C_1 ((ub_j + lb_j)C_2 + lb_j)C_2 > 0 \\ F_j - C_1 ((ub_j + lb_j)C_2 + lb_j)C_2 < 0 \end{cases} \quad (۸)$$

در این معادله، x_j^1 بیانگر موقعیت سالپ رهبر در بعد j ام، F_j موقعیت منبع غذا در بعد j ام، ub_j بیانگر کران بالای بعد j ام، lb_j بیانگر کران پایین بعد j ام، و C_1 ، C_2 و C_3 اعداد تصادفی هستند. معادله ۸ نشان می‌دهد که سالپ رهبر صرفاً موقعیتش را مطابق با منبع غذا تنظیم می‌کند. C_1 ضریب اصلی SSA برای ایجاد توازن در اکتشاف و بهره‌برداری است که به‌صورت معادله (۹) تعریف می‌شود:

$$C_1 = 2e^{-(4l/L)^2} \quad (9)$$

در این معادله، تکرارهای فعلی و حداکثر تکرارها به ترتیب با l و L نشان داده شده‌اند. C_2 و C_3 اعداد تصادفی هستند که به‌طور یکنواخت بین $[0, 1]$ ایجاد شده‌اند. به‌روزرسانی موقعیت دنبال‌کننده‌ها از طریق معادله (۱۰) انجام می‌شود:

$$x_j^i = \frac{1}{2at^2} + v_0 t \quad (10)$$

از آن جایی که مدت بهینه‌سازی به معنی تکرار است، تفاوت بین تکرارها برابر است با ۱، و با در نظر گرفتن $v_0=0$ ، این معادله به‌صورت زیر (۱۱) ارائه می‌شود:

$$x_j^i = \frac{1}{2(x_j^i + x_j^{i-1})} \quad (11)$$

در این معادله، $i \geq 2$ و x_j^i بیانگر موقعیت ژامین سالپ دنبال‌کننده در ژامین بعد است. به در نظر گرفتن معادله (۸) و معادله (۱۱)، زنجیره‌های سالپ را می‌توان شبیه‌سازی کرد.

ارزیابی و نتایج

برای ارزیابی مدل‌های دسته‌بندی تصویر چند معیار وجود دارد که می‌توان به‌صورت معادلات (۱۴) تا (۱۹) محاسبه کرد.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (14)$$

$$Sensitivity(Recall) = \frac{TP}{TP + FN} \quad (15)$$

$$Specificity = \frac{TN}{TN + FP} \quad (16)$$

$$ER = \frac{FN + FP}{TP + FP + FN + TN} = 1 - Accuracy \quad (17)$$

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

در این معادله، TP مثبت صحیح، FP مثبت غلط، TN منفی صحیح و FN منفی غلط است. و به صورت جدول زیر تشریح خواهند شد [۷].

جدول ۱: سناریوهای مختلف برای دسته‌بندی‌ها و تصاویر

	پیش‌بینی شده	
	مثبت	منفی
مثبت	TP	FN
منفی	FP	TN

در این مرحله، مدل‌های پیشنهادی با استفاده از معیار بالا در نرم‌افزار متلب نسخه ۲۰۱۷ پیاده‌سازی و ارزیابی شده‌اند. معیارها عبارتند از صحت، حساسیت، خطا و دقت. همه نتایج به درصد هستند.

به‌منظور ارزیابی روش پیشنهادی بایستی مدل به هرکدام از دسته‌بندی‌های مورد نظر اعمال شود تا نتیجه روند دسته‌بندی مشخص شود. الگوریتم ازدحام سالپ با توجه به دو نوع از تصاویر با اندازه‌های مختلف در اختیار دسته‌بندی‌های مختلف قرار می‌گیرد. جدول ۲ نتایج

ارزیابی روش پیشنهادی با استفاده از دسته‌بندها برای تصاویر با اندازه 256×256 را نشان می‌دهد. محور افقی نشان‌دهنده معیار ارزیابی و محور عمودی نشان‌دهنده عملکرد روش پیشنهادی با استفاده از دسته‌بند درخت تصمیم در وضعیت پایه است.

جدول ۲- نتایج ارزیابی روش پیشنهادی با استفاده از دسته‌بندهای مختلف برای تصاویر با اندازه 256×256

	Precision	Error	Recall	Accuracy
dt	67.1	2.9	100	89.1
KNN	71.1	2.6	96.9	77.5
NB	45.3	4.1	90.99	78.1
DT+SSA	92.18	0.081	100	99.23
KNN+SSA	90.11	0.09	89.99	96.8
NB+SSA	90.34	0.089	100	98.1

نتایج نشان‌دهنده بازدهی بالای روش پیشنهادی با استفاده از درخت تصمیم با الگوریتم SSA با معیار حساسیت ۱۰۰٪، معیار خاصیت ۹۹٫۲۳٪، معیار خطای ۰٫۰۸۱٪، معیار دقت ۹۲٫۱۸٪ است. همان‌طور که می‌توان دید، روش پیشنهادی برای درخت تصمیم در مقایسه با روش‌های یادگیری دیگر در همه معیارهای پیشنهادی کارآمدتر است.

جدول ۳ نتایج ارزیابی روش پیشنهادی با استفاده از دسته‌بندها برای تصاویر با اندازه 512×512 را نشان می‌دهد.

جدول ۳- نتایج ارزیابی روش پیشنهادی با استفاده از دسته‌بندهای مختلف برای تصاویر با اندازه 512×512

	Precision	Error	Recall	Accuracy
dt	60.6	6.1	90	66.2
KNN	55.9	7.2	77.1	44.5
NB	23.6	8.1	76.39	54.1
DT+SSA	90.11	0.096	100	97.44
KNN+SSA	86.36	0.19	89.92	90.1
NB+SSA	79.12	0.18	100	91.3

نتایج نشان‌دهنده بازدهی بالای روش پیشنهادی با استفاده از درخت تصمیم با الگوریتم SSA با معیار حساسیت ۱۰۰٪، معیار خاصیت ۹۷٫۴۴٪، معیار خطای ۰٫۰۹۶٪، معیار دقت ۹۰٫۱۱٪ است. همان‌طور که می‌توان دید، روش پیشنهادی برای درخت تصمیم در مقایسه با روش‌های یادگیری دیگر در همه معیارهای پیشنهادی کارآمدتر است.

جمع‌بندی

در این مقاله، روش یادگیری جدید مبتنی بر الگوریتم ازدحام سالپ پیشنهاد شده است که در الگوریتم یادگیری درخت تصمیم، نزدیکترین همسایگی و نایو بیس پیاده‌سازی و ارزیابی شده‌اند. نتایج نشان‌دهنده بهبود عملکرد یادگیری الگوریتم‌ها در همه معیارهای به‌دست‌آمده با استفاده از الگوریتم SSA در مقایسه با الگوریتم‌های یادگیری سنتی است.

از لحاظ معیار دقت، بهترین عملکرد مدل پیشنهادی با استفاده از روش یادگیری درخت تصمیم با مقدار ۹۲٫۱۸٪ برای تصاویر با اندازه 256×256 در مقایسه با روش‌های پیشنهادی دیگر و همچنین در میان دو اندازه معرفی شده می‌باشد. از لحاظ معیار صحت، بهترین عملکرد مدل پیشنهادی با استفاده از روش یادگیری درخت تصمیم با مقدار ۱۰۰٪ برای تصاویر با اندازه 256×256 در مقایسه با روش‌های پیشنهادی دیگر و همچنین در میان دو اندازه معرفی شده می‌باشد. از لحاظ معیار خطا، بهترین عملکرد مدل پیشنهادی با استفاده از روش یادگیری درخت تصمیم با مقدار ۰٫۰۸۱ برای تصاویر با اندازه 256×256 در مقایسه با روش‌های پیشنهادی دیگر و همچنین در میان دو اندازه معرفی شده می‌باشد. از لحاظ معیار دقت، بهترین عملکرد مدل پیشنهادی با استفاده از روش یادگیری درخت تصمیم با مقدار ۹۹٫۲۳٪ برای تصاویر با اندازه 256×256 در مقایسه با روش‌های پیشنهادی دیگر و همچنین در میان دو اندازه معرفی شده می‌باشد.

منابع و مراجع

- [1] Pang, B., Lee, L., & Vaithyanathan, S. (2002, July). Thumbs up? sentiment classification using machine learning techniques. In Proceedings of the ACL-02 conference on Empirical methods in natural language Processing-Volume 10(pp. 79-86). Association for Computational Linguistics.
- [2] Dietterich, T. G. (2000, June). Ensemble methods in machine learning. In International workshop on multiple classifier systems (pp. 1-15). Springer, Berlin, Heidelberg.
- [3] Bishop, C. M. (2006). Pattern recognition and machine learning. springer.
- [4] Arridge, S. R. (1999). Optical tomography in medical imaging. *Inverse problems*, 15(2), R41.
- [5] Bushberg, J. T. (Ed.). (2002). The essential physics of medical imaging. Lippincott Williams & Wilkins.
- [6] Kak, A. C., Slaney, M., & Wang, G. (2002). Principles of computerized tomographic imaging. *Medical Physics*, 29(1), 107-107.
- [7] Hegazy, A. E., Makhlof, M. A., & El-Tawel, G. S. (2018). Improved salp swarm algorithm for feature selection. *Journal of King Saud University-Computer and Information Sciences*.
- [8] Betzig, E., Patterson, G. H., Sougrat, R., Lindwasser, O. W., Olenych, S., Bonifacino, J. S., ... & Hess, H. F. (2006). Imaging intracellular fluorescent proteins at nanometer resolution. *Science*, 313(5793), 1642-1645.
- [9] Garcia-Arroyo, J. L., & Garcia-Zapirain, B. (2018). Recognition of pigment network pattern in dermoscopy images based on fuzzy of pixels. *Computer methods and programs in biomedicine*, 153, 61-69.
- [10] Orlov, T., Yakovlev, V., Hochstein, S., & Zohary, E. (2000). Macaque monkeys categorize images by their ordinal number. *Nature*, 404(6773), 77.
- [11] Zabalza, J., Ren, J., Yang, M., Zhang, Y., Wang, J., Marshall, S., & Han, J. (2014). Novel folded-PCA for improved feature extraction and data reduction with hyperspectral imaging and SAR in remote sensing. *ISPRS Journal of Photogrammetry and Remote Sensing*, 93, 112-122.
- [12] Biju, V. G., & Mythili, P. (2015). Fuzzy clustering algorithms for cDNA microarray image spots segmentation. *Procedia Computer Science*, 46, 417-424.
- [13] Sindhumol, S., Kumar, A., & Balakrishnan, K. (2013). Spectral clustering independent component analysis for tissue classification from brain MRI. *Biomedical Signal Processing and Control*, 8(6), 667-674.
- [14] Liang, L. R., & Looney, C. G. (2003). Competitive fuzzy edge detection. *Applied soft computing*, 3(2), 123-137.
- [15] Moukaddam, H., Pollak, J., & Haims, A. H. (2009). MRI characteristics and classification of peripheral vascular malformations and tumors. *Skeletal radiology*, 38(6), 535-547.
- [16] El-Dahshan, E. S. A., Mohsen, H. M., Revett, K., & Salem, A. B. M. (2014). Computer-aided diagnosis of human brain tumor through MRI: A survey and a new algorithm. *Expert systems with Applications*, 41(11), 5526-5545.
- [17] Sapra, P., Singh, R., & Khurana, S. (2013). Brain tumor detection using neural network. *International Journal of Science and Modern Engineering (IJISME) ISSN*, 2319-6386.
- [18] Kircher, M. F., De La Zerda, A., Jokerst, J. V., Zavaleta, C. L., Kempen, P. J., Mitra, E., ... & Sinclair, R. (2012). A brain tumor molecular imaging strategy using a new triple-modality MRI-Photoacoustic-Raman nanoparticle. *Nature medicine*, 18(5), 829.
- [19] Tolba, M., Rezk, H., Diab, A., & Al-Dhaifallah, M. (2018). A novel robust methodology based Salp swarm algorithm for allocation and capacity of renewable distributed generators on distribution grids. *Energies*, 11(10), 2556..