مقاله پژوهشی

مروری بر الگوریتم بهینه‌سازی ازدحام ذرات و کاربردهای آن در پزشکی

Doi: 10.30508/kdip.2025.524017.1142

محمد احسان بصیری[۱]
۱- دانشیارگروه مهندسی کامپیوتر، دانشگاه شهرکرد، شهرکرد، ایران
سعیده درویشی شیخ آبادی[۲]
۲- دانشجوی کارشناسی ارشدگروه مهندسی کامپیوتر، دانشگاه شهرکرد، شهرکرد، ایران

تاریخ دریافت: ۱۴۰۴/۰۲/۲۶
تاریخ پذیرش: ۱۴۰۴/۰۳/۰۱
صفحه: ۵۹ - ۵۰

چکیده

این مقاله به بررسی الگوریتم بهینه‌سازی ازدحام ذرات (PSO) و کاربردهای آن در زمینه پزشکی می‌پردازد. در ابتدا، اصول PSO و پارامترهای مرتبط توضیح داده شده و سپس با بررسی مقاله‌های مختلف، انواع کاربردهای این الگوریتم و ادغام آن با تکنیک‌های دیگر مانند شبکه‌های عصبی و یادگیری ماشین بررسی گردید. کاربردهای متنوع PSO شامل تشخیص بیماری‌ها، پردازش تصاویر، انتخاب ویژگی، کشف داروها، زمانبندی دارو و بیوانفورماتیک است. به‌ویژه، الگوریتم PSO به‌عنوان ابزاری موثر در تشخیص زودهنگام بیماری‌های قلبی-عروقی، کووید-۱۹ و شناسایی پولیپ‌ها و سرطان شناخته شده است. همچنین، PSO در بهینه‌سازی نانوذرات درمانی و برنامه‌ریزی پرتودرمانی نیز کاربردهای قابل توجهی دارد. این نتایج نشان‌دهنده قابلیت‌های بالای PSO در بهبود دقت و کارایی در تشخیص و درمان بیماری‌ها است و می‌تواند به‌عنوان مبنایی برای پژوهش‌های آینده مورد استفاده قرار گیرد. مقایسه‌ای نیز بین عملکرد ACO، PSO و ABC در تقسیم‌بندی تصاویر صورت گرفت که نشان می‌دهد دقت آن‌ها نزدیک به هم بوده و ممکن است در برخی معیارها برتری یا ضعف نشان دهند.

کلمات کلیدی: الگوریتم PSO، بهینه‌سازی ازدحام ذرات، پزشکی، تشخیص بیماری‌ها، پردازش تصاویر.

۱- مقدمه

امروزه الگوریتم‌های فراابتکاری به عنوان ابزارهای قدرتمند برای حل مسائل پیچیده و بهینه‌سازی در نظر گرفته می‌شوند. این الگوریتم‌ها به ویژه در حوزه‌های بهینه‌سازی، یادگیری ماشین، مهندسی و علوم کامپیوتر کاربرد گسترده‌ای دارند (کاوه و مسگری[1]، ۲۰۲۳). رویکرد این الگوریتم‌ها به گونه‌ای است که با الهام از فرآیندهای طبیعی و اجتماعی و شبیه‌سازی عملکرد آن‌ها، امکان جستجوی موثر در فضای حل مسائل با ابعاد بزرگ و غیرخطی را فراهم می‌سازند. با توجه به افزایش پیچیدگی مسائل در دنیای مدرن و نیاز به راه‌حل‌های بهینه‌تر، توجه به این الگوریتم‌ها و توسعه آن‌ها به یک ضرورت تبدیل شده است.

از جمله رویکردهای نوین در این زمینه، مفهوم هوش ازدحام (SI) است، که به مطالعه و شبیه‌سازی رفتار گروهی موجودات طبیعی می‌پردازد (کندی[2]، ۲۰۰۶). در تعریف مفهوم ازدحام می‌توان گفت به مجموعه‌ای از عوامل یا موجودات اطلاق می‌شود که به صورت جمعی و هماهنگ در یک محیط خاص عمل می‌کنند. در نهایت، هوش ازدحام به الگوریتم‌هایی اشاره دارد که بر اساس تعاملات محلی و تصمیم‌گیری جمعی شکل می‌گیرند و به جستجوی بهینه در فضای حل مسائل کمک می‌کنند. الگوریتم‌هایی مانند بهینه‌سازی ازدحام ذرات (PSO) (کندی و ایبرهارت[3]، ۱۹۹۵)، بهینه‌سازی کلونی مورچه‌ها (ACO) (دوریگو، بیراتاری، و استاتلز[4]، ۲۰۰۶) و الگوریتم بهینه سازی کلونی زنبور عسل (BCO) (تئودورویک[5]، ۲۰۰۹) از این رویکرد بهره‌برداری می‌کنند و با استفاده از اصول هوش جمعی، توانایی بالایی در یافتن راه‌حل‌های بهینه در زمان‌های کوتاه دارند. الگوریتم بهینه‌سازی ازدحام ذرات یکی از الگوریتم‌های فراابتکاری محبوب است که توسط کندی و ابرهارت در سال ۱۹۹۵ معرفی شد و به سرعت مورد توجه محققان در حوزه‌های مختلف قرار گرفت (کندی و ایبرهات، ۱۹۹۵). این الگوریتم از رفتار اجتماعی پرندگان و ماهی‌ها الهام گرفته و این پدیده‌های طبیعی را به یک چارچوب ریاضی برای بهینه‌سازی تبدیل کرده است. در PSO، هر ذره نماینده یک راه‌حل ممکن است و با حرکت در فضای جستجو، به دنبال بهترین راه‌حل می‌گردد. عملکرد PSO بر اساس تعاملات بین ذرات و به‌روزرسانی موقعیت و سرعت آن‌ها بر اساس بهترین موقعیت‌های شخصی و گروهی است.

برخلاف اکثر الگوریتم های فراابتکاری که با چالش‌هایی نظیر؛ نیاز به تنظیم تعداد زیاد پارامتر، پیاده‌سازی دشوار، و هزینه محاسباتی بالا مواجه هستند، الگوریتم PSO، ویژگی‌هایی دارد که آن را در میان سایر الگوریتم‌های فراابتکاری متمایز می‌کند. از مزایای این الگوریتم، می‌توان سهولت در پیاده‌سازی ، تعداد کمتر پارامترها، و انعطاف‌پذیری زیاد آن را نام برد. این الگوریتم با تنها سه پارامتر کنترلی اصلی، به نام‌های وزن اینرسی، نسبت شناختی، و نسبت اجتماعی، انعطاف‌پذیری و قابلیت انطباق را فراهم می‌کند که آن را برای طیف وسیع‌تری از کاربرها در دسترس می‌سازد (شامی و همکاران[6]، ۲۰۲۲).

با این حال، PSO نیز محدودیت‌هایی دارد که می‌توانند بر عملکرد آن تاثیر منفی بگذارند. موارد زیر برخی از چالش های الگوریتم PSO است:

- حساسیت تنظیم پارامترها، که می‌تواند تاثیر زیادی بر نتایج داشته باشد و انتخاب نادرست آن‌ها ممکن است منجر به کاهش کارایی الگوریتم شود.
- گیر کردن در بهینه های محلی در مسائل بهینه سازی با فضای جستجوی پیچیده و با ابعاد بالا، و در نهایت عدم دسترسی به بهینه ی جهانی.
- برای مقابله با این چالش‌ها، انواع مختلفی از PSO توسعه یافته‌اند که از تکنیک‌هایی مانند توسعه استراتژی‌های جدید برای پارامترهای کنترلی و ادغام با سایر الگوریتم‌های بهینه‌سازی (حبیب، الجراح، و میرجلیلی[7]، ۲۰۲۰؛ جی، لیو، ژوو، و ژانگ[8]، ۲۰۱۹) استفاده

1- Kaveh, & Mesgari
2- Kennedy
3- Kennedy & Eberhart
4- Dorigo, Birattari & Stutzle
5- Teodorovi
6- Shami etal
7- Habib, Aljarah, Faris, & Mirjalili
8- Ji, Liu, Zou, & Zhang

می‌کنند. این رویکردها با ادغام قابلیت‌های مختلف، موجب بهبود همگرایی و کیفیت نتایج در مسائل با ابعاد بالا و پیچیدگی‌های زیاد می‌شوند. موارد ذکر شده، موجب کاربرد گسترده‌ی الگوریتم PSO در صنایع و علوم مختلف شده است و این الگوریتم به‌عنوان یکی از تکنیک‌های موثر در حل مسائل بهینه‌سازی شناخته می‌شود (گاد[1]، ۲۰۲۲).

این مقاله به طور ویژه، کاربردهای وسیع این الگوریتم را در حوزه پزشکی مورد توجه قرار می‌دهد. پیرو بررسی‌ها و تحلیلات انجام‌شده، در مقالات متعدد به مباحثی چون انتخاب ویژگی‌ها برای تشخیص پزشکی (حبیب و همکاران، ۲۰۲۰)، تشخیص بیماری‌های پزشکی (پیروایز، ال قیوم، حیدربنگیل، گائو، و احمد[2]، ۲۰۲۳) و طبقه‌بندی داده‌های پزشکی (زیمال و همکاران[3]، ۲۰۲۰) پرداخته شده است، اما هر کدام از این بررسی‌ها به مسئله‌ای خاص محدود می‌شود. این مقاله به جمع‌آوری و ارائه جامع‌تری از کاربردهای متنوع PSO و انواع آن مانند MOPSO (لالوانی، سینگال، کومار و گوپتا[4]، ۲۰۱۳) در مسائل و حوزه‌های مختلف پزشکی می‌پردازد. با انجام این تحلیل فراگیر، تلاش می‌شود تا ابعاد نامشخص و مطالعات کم‌توجه‌شده در این زمینه آشکار و بررسی گردد. علاوه بر این، با توجه به اینکه الگوریتم BCO و ACO نیز در برخی کاربردهای پزشکی مانند پردازش تصاویر پزشکی و طبقه‌بندی داده‌های پزشکی کاربرد دارد، مقایسه عملکرد الگوریتم PSO با این دو الگوریتم در چنین مسائلی به‌عنوان نقطه قوت این مقاله مورد توجه قرار خواهد گرفت. این مقایسه می‌تواند به درک بهتر عملکرد الگوریتم PSO و انتخاب بهترین روش برای حل مسائل خاص پزشکی کمک کند و درک ما را از کارایی و تناسب آن‌ها در این زمینه عمیق‌تر کند.

در نهایت، نوآوری این مقاله‌ی مروری را می‌توان به طور خلاصه به شرح زیر بیان کرد:

۱- بررسی جامع الگوریتم PSO شامل مفاهیم اصلی و بنیادین، پارامترهای کلیدی موثر، مزایا و معایب آن با تأکید بر کاربردهای پزشکی الگوریتم.

۲- مرور کامل کاربردهای الگوریتم PSO و انواع آن در مسائل متنوع و گسترده‌ی پزشکی.

۳- تحلیل مقایسه‌ای عملکرد الگوریتم PSO با الگوریتم‌های BCO و ACO در مسائل تحلیل و تقسیم‌بندی تصاویر مربوط به MRI مغز.

۲- مبانی نظری

مرور جامع بر بهینه‌سازی با ازدحام ذرات (PSO)

الگوریتم بهینه‌سازی ازدحام ذرات با هدف کشف بهینه در فضای مسئله است. عملکرد آن شامل بهبود راه‌حل‌های کاندید به صورت تکراری و با تنظیم سرعت و موقعیت ذرات است. حرکت این ذرات در فضای جستجو وابسته به تجربیات خود ذره و ذرات همسایه آن است. با یک بررسی مروری، مفاهیم اصلی و بنیادی PSO، پارامترهای کلیدی موثر بر عملکرد آن، و همچنین مزایا و معایب آن بررسی می‌شود.

مفاهیم بنیادی PSO

در اصل، PSO رفتار دسته جمعی موجودات اجتماعی را تقلید می‌کند. هر ذره در ازدحام نشان‌دهنده یک راه‌حل ممکن برای مسئله بهینه‌سازی است و با موقعیت و سرعت خود در فضای جستجو مشخص می‌شود (کندی و ایبرهات، ۱۹۹۵). تنظیم سرعت و موقعیت ذرات با استفاده از دو مولفه صورت می‌گیرد:

- بهترین موقعیت شخصی کشف شده توسط خود ذره (PBest)
- بهترین موقعیت جهانی کشف شده توسط تمام ذرات ازدحام (GBest)
- مکانیزم ذکر شده با استفاده از معادلات زیر هدایت می‌شود:

به‌روزرسانی سرعت: سرعت هر ذره بر اساس سرعت قبلی، فاصله به بهترین موقعیت شناخته‌شده خود و فاصله به بهترین موقعیت شناخته‌شده کل ازدحام

1- Gad
2- Pervaiz, Ul-Qayyum, Haider Bangyal, Gao & Ahmad
3- Zemmal, Azizi, Sellami, Cheriguene, Ziani, AlDwair, & Dendani
4- Lalwani, Singhal, Kumar & Gupta

به‌روزرسانی می‌شود.

$$v_i^{t+1} = \omega v_i^t + r_1 c_1 (PBest_i - x_i) + r_2 c_2 (GBest - x_i) \quad (1)$$

در معادله‌ی عنوان شده، v_i سرعت ذره i، x_i موقعیت آن، ω وزن اینرسی، c_1 و c_2 ضرایب شناختی و اجتماعی، و در نهایت r_1 و r_2 مقادیر تصادفی در بازه‌ی [۰,۱] هستند.

به‌روزرسانی موقعیت: سپس موقعیت ذره براساس سرعت جدید به‌روزرسانی می‌شود:

$$x_i^{t+1} = x_i^t + v_i^{t+1} \quad (2)$$

این فرایند تا زمانی که یک معیار توقف برآورده شود تکرار می‌شود (گاد، ۲۰۲۲). معیار توقف می‌تواند رسیدن به حداکثر تعداد تکرارها یا دستیابی به سطح مطلوبی از تناسب باشد.

نمودار الگوریتم در شکل شماره (۱) قابل مشاهده است.

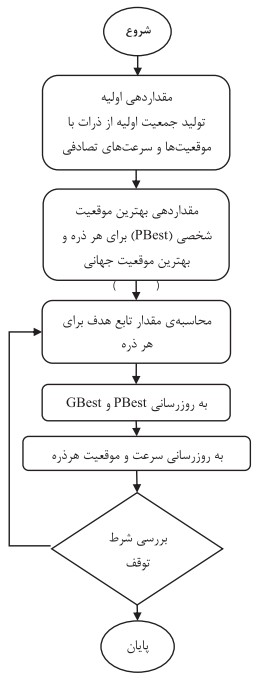

شکل (۱): نمودار الگوریتم PSO

همگرایی و جستجو

همگرایی در PSO به فرآیند حرکت ذرات به سمت یک راه‌حل در فضای جستجو اشاره دارد. این فرآیند می‌تواند به اشکال مختلفی اتفاق بیفتد: ذرات ممکن است به یک بهینه محلی همگرا شوند یا برای جلوگیری از همگرایی زودهنگام، فضای جستجو را بیشتر بررسی کنند. برای مدیریت این موضوع، PSO تکنیک‌هایی مانند محدود کردن سرعت را به کار می‌گیرد. این تکنیک حداکثر سرعت ذرات را تنظیم می‌کند و ثبات الگوریتم را در طول بهینه‌سازی افزایش دهد. همچنین مطالعات مختلف نشان داده‌اند که برخی پارامترها، به‌ویژه هنگام مواجهه با مسائل پرنویز یا متغیر در طول زمان، توانایی تغییر نرخ همگرایی و بهبود کیفیت راه‌حل را دارند (شامی و همکاران، ۲۰۲۲).

پارامترهای کنترلی موثر بر عملکرد PSO

عملکرد الگوریتم PSO به طور قابل توجهی تحت‌تاثیر چنین پارامترهایی قرار دارد.

وزن اینرسی: اولین پارامتر، وزن اینرسی ($\square$) است که بر به‌روزرسانی سرعت هر ذره در ازدحام تاثیر می‌گذارد، به همین دلیل دارای نقش حیاتی در اثربخشی و کارایی الگوریتم است. این پارامتر، تعیین می‌کند که سرعت قبلی ذره تا چه اندازه بر سرعت کنونی آن تاثیر می‌گذارد، به عبارتی تعادل بین اکتشاف و بهره‌برداری را برقرار می‌کند. وزن با مقدار بیشتر، باعث تقویت اکتشاف در فضای جستجو و حرکت تصادفی‌تر ذرات می‌شود. در نقطه ی مقابل، وزن با مقدار کمتر، منجر به تمرکز فرایند جستجو بر روی مناطقی با نتایج خوب خواهد شد و به عبارتی ذرات با یکدیگر تبادل اطلاعات بیشتری خواهند داشت. انتخاب وزن اینرسی بر سرعت همگرایی و دقت الگوریتم در یافتن راه‌حل موثر است. مقدار وزن اینرسی به صورت صعودی متغیر است، یعنی در ابتدا مقدار آن ۰/۴ در نظر گرفته می‌شود و تا پایان اجرای الگوریتم مقدار آن به ۰/۹ می‌رسد (شامی و همکاران، ۲۰۲۲).

ضرایب شناختی و اجتماعی: ضرایب c_1 و c_2 به ترتیب ضرایب شناختی و اجتماعی هستند. ضریب شناختی

میزان تاثیر بهترین موقعیتی که تاکنون توسط ذره[i] کشف شده را بر حرکت آن تعیین می‌کند. افزایش این ضریب باعث افزایش قابلیت اکتشاف می‌شود. ضریب اجتماعی نیز همانطور که از نامش پیداست، میزان تاثیر بهترین موقعیت جهانی را مشخص می‌کند. مقادیر بالاتر برای این ضریب، جاذبه‌ی ذره را به سمت بهترین موقعیت شناخته شده توسط گروه ذرات افزایش می‌دهد و همچنین منجر به ترویج یادگیری و بهره‌برداری می‌شود (شامی و همکاران، ۲۰۲۲).

اندازه‌ی ازدحام: گفته شد هر ذره موقعیت خود را براساس دو عامل تجربه‌ی خود و تجربه‌ی کل ذرات تعیین می‌کند. با تغییر تعداد ذرات در ازدحام، جستجو نتایج متفاوتی ارائه خواهد داد. تعداد بیشتر ذرات اغلب منجر به افزایش اکتشاف می‌شود، زیرا ذرات می‌توانند نواحی وسیع‌تری از فضای راه‌حل را پوشش دهند. این پوشش وسیع، امکان بررسی همزمان راه‌حل‌های بیشتری را فراهم می‌کند و درنهایت شانس یافتن بهینه جهانی نیز افزایش می‌یابد. با این حال، تعداد کم ذرات ممکن است اکتشاف ناکافی و احتمال همگرایی زودرس به بهینه‌های محلی را افزایش می‌دهد. همچنین ذرات بیشتر به منابع محاسباتی نیز نیاز دارند. موقعیت و سرعت هر ذره در هر تکرار به‌روزرسانی می‌شود که در مسائل بهینه‌سازی با ابعاد بالا ممکن است هزینه‌بر باشد. بنابراین ایجاد تعادل بین تعداد ذرات و کارایی بسیار مهم است. به طور کلی، اندازه‌ی ازدحام بین ۲۰ تا ۵۰ در نظر گرفته می‌شود که اکتشاف را تسهیل کرده و نیازهای محاسباتی سنگین ندارد (شامی و همکاران، ۲۰۲۲).

علاوه بر تنظیم تعداد ذرات، بررسی ساختار همسایگی نیز بسیار مهم است. همسایگی تعیین کننده‌ی نحوه اشتراک اطلاعات و اتصال بین ذرات است. به‌عنوان مثال، یک توپولوژی کاملا متصل (که در آن هر ذره می‌تواند با کلیه ذرات دیگر ارتباط برقرار کند) با یک توپولوژی محلی (که در آن تنها ذرات نزدیک به هم اطلاعات را به اشتراک می‌گذارند) تفاوت دارد و می‌تواند بر ویژگی‌های اکتشاف و همگرایی تاثیر بگذارد.

مکانیزم‌های تطبیقی

مکانیزم‌های تطبیقی جهت بهبود بخشیدن به عملکرد الگوریتم PSO معرفی شدند. این مکانیزم‌ها به الگوریتم اجازه می‌دهند تا به طور پویا پارامترهای خود را بر اساس فضای بهینه‌سازی یا عملکرد ازدحام تنظیم کند. چنین استراتژی‌هایی شامل تغییر وزن اینرسی و ضرایب شناختی و اجتماعی است که در نهایت ممکن است به بررسی بهتر فضای جستجو و بهبود همگرایی به راه‌حل‌های بهینه منجر شود (گاد، ۲۰۲۲).

مزایای PSO

PSO در مقایسه با سایر الگوریتم‌های فرابتکاری، پارامترهای کمتری برای تنظیم دارد، که این پدیده منجر به پیاده‌سازی آسان‌تر آن در برنامه‌های مختلف می‌شود (شامی و همکاران، ۲۰۲۲). ساختار الگوریتم PSO امکان موازی‌سازی را فراهم می‌کند. این امکان به هر ذره اجازه می‌دهد به طور مستقل از ذرات دیگر حرکت کند، این ویژگی به ویژه در سیستم‌های توزیع‌شده و محاسبات ابری بسیار سودمند است و می‌تواند زمان محاسبات را به طور قابل توجهی کاهش دهد. کاهش زمان محاسباتی، PSO را به ابزاری مناسب برای مسائل دنیای واقعی تبدیل کرده است. در نهایت توزیع محاسبات در میان چندین پردازنده، موجب تسریع همگرایی می‌شود. از دیگر دلایل همگرایی سریع، میتوان به استفاده از اطلاعات شخصی و و اطلاعات دیگر ذرات در ازدحام اشاره کرد (گاد، ۲۰۲۲).

همچنین PSO، با توجه به مقاومت بالایی که در برابر تغییرات و نوسانات داده‌ها و شرایط محیطی دارد، در مسائل پیچیده و غیرخطی عملکرد خوبی خواهد داشت. این الگوریتم به دلیل استفاده از اطلاعات اجتماعی و شخصی، احتمال بالایی برای یافتن نقاط بهینه جهانی، به ویژه در فضاهای جستجوی بزرگ و پیچیده دارد. علاوه بر این، عدم استفاده از تداخل یا جهش در PSO، سادگی و شفافیت الگوریتم را افزایش می‌دهد و نتایج قابل پیش‌بینی‌تری را به همراه دارد. در نهایت، PSO به عنوان ابزاری قدرتمند برای ساخت مدل‌های ریاضی دقیق در مسائل پیچیده‌ای مانند مهندسی، مالی و پزشکی عمل می‌کند و به بهینه‌سازی این مسائل کمک می‌کند (گاد، ۲۰۲۲).

معایب PSO

با وجود مزایای آن، این الگوریتم محدودیت‌های خاصی نیز دارد. علی‌رغم تعداد کم پارامترهای کنترلی، عملکرد الگوریتم به مقدار تنظیم شده برای این پارامترها بسیار حساس است تاثیر آنها بر الگوریتم پیچیده و غیر خطی است که این پدیده تنظیم مقدار مناسب برای این پارامترها را دشوار می‌سازد. انتخاب نادرست این پارامترها می‌تواند منجر به کاهش کارایی الگوریتم و عدم دستیابی به نقاط بهینه شود. به ویژه در مسائل مختلف، ممکن است نیاز به تنظیمات خاصی باشد که این امر می‌تواند زمان‌بر و نیازمند تجربه باشد. برای درک بهتر این موضوع، می‌توان به این مورد اشاره کرد که با توجه به اهمیت توازن بین اکتشاف و یا بهره‌برداری در هر مسئله، باید مقادیر وزن اینرسی و ضرایب شخصی و اجتماعی به گونه‌ای تنظیم شوند که راه‌حل‌های کشف شده، بهترین کارایی را داشته باشیم (شامی و همکاران، ۲۰۲۲). یکی دیگر از معایب اصلی PSO، همگرایی زودرس است. این وضعیت زمانی رخ می‌دهد که الگوریتم قبل از اینکه به نقطه بهینه جهانی دست یابد، در یک کمینه محلی متوقف می‌شود. این مشکل به ویژه در مسائل با ابعاد بالا و فضای جستجوی پیچیده بیشتر مشاهده می‌شود. در چنین شرایطی، PSO ممکن است به سرعت به یک راه‌حل غیر بهینه برسد و از جستجوی سایر نقاط ممکن در فضای جستجو باز بماند. این امر می‌تواند منجر به نتایج نامطلوب و عدم کارایی در حل مسائل پیچیده شود (حبیب و همکاران، ۲۰۲۰).

در عین حال، یکی از چالش‌های مهم در PSO، مشکل پراکندگی گروه (Swarm Scattering) است. این مشکل زمانی اتفاق می‌افتد که ذرات به دلیل پخش غیرموثر در فضای جستجو، نمی‌توانند به یکدیگر نزدیک شوند یا به یک نقطه بهینه مشترک دست یابند. این پراکندگی می‌تواند منجر به کاهش کارایی الگوریتم و افزایش زمان لازم برای یافتن بهینه شود. در برخی موارد، این مشکل می‌تواند به ناتوانی در کشف نقاط بهینه جهانی منجر شود (گاد، ۲۰۲۲).

۳- روش تحقیق

در این مطالعه، با توجه به ماهیت مقاله که مروری است، برای جمع‌آوری اطلاعات در بخش‌های مختلف، همچون معرفی الگوریتم، اصول و مفاهیم اصلی آن، و کاربردهای پزشکی از بررسی و تحلیل مقالات علمی معتبر و مرتبط به ویژه در سال‌های اخیر استفاده شده است. این رویکرد به ما این امکان را می‌دهد که به‌طور جامع و دقیق به بررسی الگوریتم PSO و کاربردهای مختلف آن به روش هایی مانند استفاده از تکنیک‌های ادغام الگوریتم‌ها و یا ترکیب با ابزارهای یادگیری ماشین در حوزه پزشکی بپردازیم و نتایج و یافته‌های موجود را به‌خوبی مستند کنیم.

از سوی دیگر، برای مقایسه عملکرد این الگوریتم بهینه‌سازی، با الگوریتم بهینه‌سازی کلونی مورچه‌ها و بهینه‌سازی زنبور عسل نیز، از مقالات پیشین بهره‌برداری شده است. در این مقالات، نتایج حاصل از ارزیابی‌های مختلف، از جمله دقت، یادآوری، امتیاز F، و همچنین مقادیر مربوط به نرخ مثبت کاذب (FDR) و نرخ مثبت واقعی (FOR) بررسی و تحلیل شده‌اند. اطلاعات و داده‌های جداول موجود در این مقالات به‌منظور مقایسه عملکرد الگوریتم‌ها در این مطالعه نیز گنجانده شده است تا به درک بهتری از کارایی و اثربخشی هر یک از روش‌ها دست یابیم.

همچنین در نمونه‌ای دیگر، برای ارزیابی کارایی الگوریتم‌ها از معیارهای زیر استفاده شده است:

$$Recall = \frac{TP}{TP + TN} \quad (4)$$

$$F - score = \frac{2 \times Percision \times Recall}{Percision + Recall} \quad (5)$$

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (6)$$

$$Jaccard = \frac{TP}{TP + FP + FN} \quad (7)$$

در معادله‌های بالا TP، FN، FP و TN به ترتیب به عنوان مثبت کاذب، منفی کاذب، مثبت واقعی و منفی واقعی شناخته می‌شوند. در اینجا، TP و TN تعداد پیکسل‌هایی هستند که به درستی به عنوان مثبت و منفی پیش‌بینی شده‌اند. در نقطه‌ی مقابل، FP و FN تعداد پیکسل‌هایی هستند که به اشتباه به عنوان مثبت و منفی پیش‌بینی شده‌اند. دقت (Precision)، معیاری است که نشان می‌دهد از تمام پیش‌بینی‌های مثبت مدل، چه درصدی واقعا مثبت بوده‌اند. یادآوری (Recall)، نشان‌دهنده‌ی

درصدی از تمام موارد مثبت واقعی است که توسط مدل به درستی شناسایی شده‌اند. امتیاز F- (F-score) یک معیار ترکیبی است که دقت و یادآوری را در یک عدد واحد ترکیب می‌کند. این امتیاز به ویژه در شرایطی که تعادل بین دقت و یادآوری مهم است، کاربرد دارد. دقت کلی (Accuracy) معیاری است که نشان می‌دهد چه درصدی از کل پیش‌بینی‌ها (شامل مثبت و منفی) به درستی انجام شده‌اند و در آخر، ضریب جاکارد (Jaccard) برای اندازه‌گیری شباهت بین دو مجموعه به کار گرفته می‌شود و در زمینه یادگیری ماشین، به‌ویژه در مسائل طبقه‌بندی، برای ارزیابی دقت تقسیم‌بندی‌ها به کار می‌رود.

این مطالعه، به ما این امکان را می‌دهد که بر اساس شواهد علمی و داده‌های معتبر، نتایج و تحلیل‌های دقیقی را ارائه دهیم و به بهبود فرآیندهای تصمیم‌گیری در زمینه ادغام تصاویر پزشکی کمک کنیم.

کاربردهای پزشکی PSO

الگوریتم PSO در زمینه‌های متنوعی از جمله مهندسی، اقتصاد، و علوم داده کاربرد دارد. همچنین، این الگوریتم به عنوان یک ابزار قدرتمند در کاربردهای مختلف پزشکی، به ویژه در تشخیص بیماری، تقسیم‌بندی تصاویر، برنامه‌ریزی درمان و تخصیص منابع، ظهور کرده است. در این مقاله به طور ویژه به کاربردهای پزشکی آن پرداخته شده است.

تشخیص بیماری

الگوریتم PSO به عنوان ابزاری موثر در تشخیص بیماری‌ها به کار می‌رود و می‌تواند به شناسایی الگوهای پیچیده در داده‌های پزشکی کمک کند.

یکی از کاربردهای شایع مربوط به تشخیص بیماری‌های قلبی-عروقی است که در ادامه چند مورد مختلف از ترکیب و ادغام PSO با سایر الگوریتم ها در این راستا به اختصار توصیف می‌شود. این الگوریتم در پیش‌بینی زودهنگام بیماری‌های قلبی-عروقی (CVD) با تحلیل داده‌های رتینوپاتی دیابتی (DR) به کار گرفته شده است. پژوهش‌ها نشان می‌دهد که تغییرات مورفولوژیکی در چشم می‌تواند به عنوان نشانگرهای پیش‌بینی‌کننده برای CVD در بیماران دیابتی نوع ۲ عمل کند. با استفاده از PSO، محققان توانسته‌اند انتخاب ویژگی‌های مرتبط از داده‌های تصویربرداری شبکیه را بهبود بخشند که منجر به بهبود طبقه‌بندی ریسک و تشخیص زودهنگام عوارض قلبی-عروقی شده است (ریواتی، استایبهاما، کلیرج، و سورش کومار[1]، ۲۰۲۵). در این رویکرد همچنین PSO با تکنیک‌های پیشرفته یادگیری ماشین، مانند شبکه‌های باور عمیق بهبود یافته (I-DBN)، ادغام شده که منجر به دقت قابل توجهی به میزان ۹۸/۹۵٪ در طبقه‌بندی بیماران در معرض خطر CVD شده است.

علاوه بر این، ادغام الگوریتم PSO با شبکه های مصنوعی عصبی (ANN)، الگوریتمی به نام PSO-ANN را تشکیل می‌دهد که علاوه بر شناسایی بیماری های قلبی-عروقی در تشخیص تب دنگی ()، نیز کاربرد داشته و عملکرد بسیار قوی و کارآمدی در تشخیص زودهنگام این بیماری‌ها ارائه می‌دهد. در نهایت این ترکیب موجب افزایش دقت پیش بینی می‌شود. این رویکرد شامل بهینه‌سازی عوامل انحراف و وزن‌های شبکه عصبی است که از طریق پارامترهای کلیدی مانند حساسیت، نرخ خطا، دقت، ویژگی و مساحت زیر منحنی (AUC) ارزیابی می‌شود.

در ادامه، الگوریتم QPSO-SVM نیز در این زمینه مورد استفاده قرار گرفته است. لازم به ذکر است که QPSO یک مدل جدید مبتنی بر الگوریتم بهینه‌سازی ازدحام ذرات با رفتار کوانتومی است. عملکرد مدل طبقه‌بندی QPSO-SVM، شامل آماده‌سازی و پیش پردازش داده‌ها و استخراج اطلاعات لازم برای تصمیم‌گیری است. پس از تنظیم پارامترها، QPSO مقدار تناسب را محاسبه کرده و جمعیت به‌طور کلی برای تولید راه‌حل‌های جدید تکامل می‌یابد. در نهایت، بهره‌گیری از ویژگی‌های SVM، مانند سادگی و سرعت طبقه‌بندی، و جلوگیری از همگرایی به بهینه محلی منجر به بهبود دقت پیش‌بینی می‌شود (السیدیمی، ابوهشیش، و القارنی[2]، ۲۰۲۴).

همچنین، PSO با سرعت محدود، مانند بهینه‌سازی ازدحام ذرات با سرعت محدود بهبود یافته (IVbBoPSO) و

1- Revathi, Sathiyabhama, Kaliraj & Sureshkumar
2- Elsedimy, AboHashish & Algarni

بهینه‌سازی ازدحام ذرات با سرعت محدود (VbBoPSO)، در تشخیص سرطان کلیه و کبد به کار رفته‌اند. این الگوریتم‌ها با بهینه‌سازی انتخاب ویژگی‌ها و پارامترهای مدل، منجر به حداکثر دقت طبقه‌بندی در تشخیص این نوع سرطان‌ها شده‌اند و بهبود قابل توجهی در نتایج تشخیصی ارائه داده‌اند (پیریوایز و همکاران، ۲۰۲۳).

پژوهش‌ها نشان‌دهنده‌ی این است که ترکیب هوش مصنوعی با نانوتکنولوژی می‌تواند به بهبود کارایی درمان و دقت در تشخیص بیماری‌ها کمک کند و نانوروبات‌ها به‌عنوان ابزارهای نوین در درمان سرطان و تشخیص مواد سمی دارای پتانسیل بالایی هستند (نارینان، دورگا، و نقالشیم[1]، ۲۰۲۲). در اینگونه مسائل شاهد کاربرد الگوریتم PSO به‌عنوان یک روش هوش جمعی برای هدایت نانوروبات‌ها هستیم. نمونه‌ای از این کاربرد استفاده از DPSO به همراه ANN برای کاهش زمان لازم برای استقرار نانوروبات‌ها به محل‌های خاص سرطان بهینه‌سازی شده است. مزایای استفاده از DPSO در چنین مسئله‌ای مزایای زیادی را برداشته که می‌توان به چند مورد از آن‌ها اشاره کرد:

- کاهش زمان لازم برای استقرار نانوروبات‌ها به محل‌های هدف
- افزایش دقت در تشخیص و درمان با استفاده از نانوروبات‌ها.
- بهینه‌سازی نانوذرات درمانی برای انواع خاص سلول‌ها و بیماران.

تشخیص بیماری‌های لنفی نیز با استفاده از ترکیب الگوریتم PSO و جنگل تصادفی (RF) انجام می‌شود. در مرحله اول، PSO به انتخاب ویژگی‌های مرتبط از داده‌ها می‌پردازد و در مرحله دوم، جنگل تصادفی به عنوان الگوریتم طبقه‌بندی استفاده می‌شود. این رویکرد ترکیبی منجر به دقت خوبی در تشخیص بیماری‌های لنفی می‌شود و به بهبود عملکرد مدل‌های پیش‌بینی کمک می‌کند (پیریوایز و همکاران، ۲۰۲۳).

در مطالعه‌ی دیگر (البدر، تینو، و الدیف[2]، ۲۰۲۴)، چالش‌های تشخیص کووید-۱۹ با استفاده از داده‌های صوتی از سیستم تنفسی بررسی شده است. این سیستم مبتنی بر الگوریتم PSO و ماشین‌های یادگیری شدید (ELM) است که از ویژگی‌های MFCC و داده‌های صوتی برای بهبود دقت و کارایی تشخیص استفاده می‌کند. در این روش، داده‌های صوتی شامل تنفس، سرفه، شمارش و حروف صدادار از افراد سالم و مبتلا به کووید-۱۹ جمع‌آوری شده و ویژگی‌های MFCC با مراحل مختلفی مانند پیش‌تاکید و FFT استخراج می‌شود. سپس، وزن‌های ورودی و بایاس‌های لایه پنهان به‌صورت تصادفی اولیه‌سازی شده و PSO برای بهینه‌سازی این وزن‌ها و بایاس‌ها به کار می‌رود. عملکرد سیستم در چهار سناریو اصلی (تنفس، سرفه، شمارش و حروف صدادار) ارزیابی شد و دقت‌های قابل توجهی به‌دست آمد: ۹۵/۸۳٪، ۹۱/۶۷٪ و ۸۹/۱۳٪ برای سناریو تنفس؛ ۹۶/۴۳٪، ۹۲/۸۶٪ و ۸۸/۸۹٪ برای سناریو سرفه؛ ۹۶/۱۵٪، ۹۶/۴۳٪ و ۸۸/۴۶٪ برای سناریو شمارش؛ و ۹۶/۱۵٪، ۹۵/۸۳٪ و ۸۲/۸۹٪ برای سناریو حروف صدادار. این سیستم همچنین با روش‌های دیگر مانند LSTM، RF، NN، ELM و XGBoost مقایسه شده و نتایج نشان‌دهنده برتری PSO-ELM در دقت تشخیص است، که بر اهمیت ترکیب PSO با ELM در بهبود دقت و کارایی تشخیص کووید-۱۹ تاکید می‌کند.

پردازش تصاویر پزشکی

در حوزه تحلیل تصویر پزشکی، الگوریتمPSO به‌طور موثری برای بهبود تکنیک‌های پردازش تصویر استفاده شده است. این الگوریتم با بهینه‌سازی انتخاب پارامترها در مدل‌های تقسیم‌بندی، دقت و کارایی شناسایی ساختارهای آناتومیکی در انواع مختلف روش‌های تصویربرداری پزشکی، مانند اسکن‌های سی‌تی (CT)، ام‌آرآی (MRI) و اشعه ایکس را بهبود می‌بخشد. با اصلاح روش‌های پیش‌پردازش متناسب با ویژگی‌های خاص مجموعه داده‌ها، PSO بهبودهای قابل توجهی در وضوح تصویر و استخراج ویژگی‌ها نشان داده است که برای دقت تشخیصی در کاربردهای بهداشتی بسیار حیاتی است. پیش از بررسی مطالعات، بهتر است در ابتدا روشهای

1- Narayanan, Durga, & Nagalakshmi
2- Albadr, Tiun, Ayob, & AL-Dhief

مختلف تقسیم‌بندی به صورت مختصر و کلی توصیف شوند (حسین، محمد، جنوری، وازری، و ابراهیم[1]، ۲۰۲۴). اولین روش، مبتنی بر آستانه‌گذاری است که به تقسیم پیکسل‌ها بر اساس سطح شدت آن‌ها می‌پردازد و به سه دسته اصلی تقسیم می‌شود. این روش‌ها به‌خصوص در تعداد آستانه‌های زیاد، از نظر محاسباتی پرهزینه هستند.

دومین روش مبتنی بر شبکه‌های عصبی مصنوعی (ANN) است که به یادگیری مناطق مورد نظر در تصویر با استفاده از گروهی از نورون‌ها می‌پردازد. این روش به منابع محاسباتی زیادی نیاز دارد و وابسته به داده‌های آموزشی است. روش مبتنی بر لبه نیز با تبدیل تصویر به تصویر لبه، تغییرات در شدت رنگ را شناسایی می‌کند. این روش‌ها برای شناسایی مرزهای اشیاء و کاربردهای مختلفی مانند تشخیص تومورهای مغزی و عروق خونی استفاده می‌شوند. روش مبتنی بر ناحیه، به گروه‌بندی پیکسل‌های مشابه به نواحی می‌پردازد و معمولا در تصاویر با نویز بالا عملکرد بهتری دارد (حسین و همکاران، ۲۰۲۴). یکی دیگر از روش‌های تقسیم‌بندی روش مبتنی بر آبراهه است که تصویر را به صورت توپولوژیکی تفسیر می‌کند و بر اساس گرادیان تصویر عمل می‌کند. روش مبتنی بر خوشه‌بندی نیز، به گروه‌بندی پیکسل‌ها به خوشه‌های مشابه می‌پردازد و شامل خوشه‌بندی سخت و نرم است. این متدها برای تقسیم‌بندی تصاویر به کار می‌روند و تکنیک‌های جدیدی مانند ترکیب الگوریتم‌های هوش جمعی با خوشه‌بندی فازی و K-means را شامل می‌شوند. در آخر، روش مبتنی بر معادلات دیفرانسیل جزئی قرار دارد که عنوان سریع‌ترین تکنیک برای تقسیم‌بندی تصویر شناخته می‌شود و شامل فیلترهای غیرخطی و مدل‌های بهبود تصویر هستند. این روش‌ها به‌ویژه برای کاربردهای زمان واقعی مناسب‌اند (حسین و همکاران، ۲۰۲۴)

اکنون می‌توانیم به بررسی مطالعات و پژوهش‌های مختلف در رابطه با نحوه‌ی استفاده از PSO و کاربرد آن در این زمینه بپردازیم. ازجمله کاربردها در این زمینه می‌توان به این مورد اشاره کرد که الگوریتم PSO چند هدفه که به عنوان MOPSO شناخته می‌شود، در توسعه یک سیستم تشخیص خودکار (CAD) برای شناسایی پولیپ‌ها از تصاویر CTC به کار گرفته شد. این الگوریتم بهینه‌سازی، با هدف بهینه‌سازی وزن‌ها و پارامترهای مدل‌های یادگیری ماشین، به ویژه شبکه‌های عصبی مصنوعی (ANN) طراحی شده است. در ، تصاویر CTC از ۳۵ بیمار جمع‌آوری و پس از پاک‌سازی و تقسیم‌بندی، ۱۶ ویژگی موثر از میان ۲۰ ویژگی استخراج شد که شامل قطر فعال، انحراف معیار، انرژی و آنتروپی بودند. در آخر مدل ANN با استفاده از MOPSO بهینه‌سازی شد (هارچگانی و مقدسی[2]، ۲۰۲۴). نتایج نشان داد که مدل ANN به دقت ۰/۹۲۹۸، حساسیت ۰/۹۸۸۹ و شفافیت ۰/۹۳۵۴ دست یافت. در مقایسه با تشخیص رادیولوژیست‌ها، سیستم CAD در بیمارستان لقمان حکیم ۸۵٪ و در بیمارستان الزهرا ۹۳٪ دقت داشت. این مطالعه به وضوح نشان‌دهنده توانایی PSO در بهبود دقت و کارایی در پردازش تصاویر پزشکی است و تاکید می‌کند که ترکیب MOPSO با مدل‌های یادگیری ماشین می‌تواند به تشخیص بهینه‌تر بیماری‌ها کمک کند.

پژوهش (بالرینی[3]، ۲۰۲۵) به بررسی سیستماتیک الگوریتم PSO در ثبت تصاویر پزشکی سه بعدی می‌پردازد. PSO به عنوان یک روش مؤثر برای بهبود دقت و کارایی ثبت تصاویر در کاربردهای پزشکی شناخته شده است. این پژوهش به تحلیل روش‌ها، چالش‌ها و روندهای آینده در استفاده از PSO در ثبت تصاویر پزشکی می‌پردازد و به نیاز به تحقیقات بیشتر برای بهینه‌سازی این روش در زمینه‌های بالینی اشاره می‌کند.

همچنین، الگوریتم SDPSO-SVM برای تشخیص بیماری آلزایمر (AD) از طریق پیش‌پردازش تصاویر MRI و تحلیل مولفه‌های اصلی به کار گرفته شد. در این روش، ابتدا تصاویر پردازش شده و سپس ویژگی‌های بافت استخراج می‌شوند که منجر به دقت بالایی در تشخیص می‌گردد. این رویکرد به عنوان یکی از موثرترین روش‌ها در تشخیص AD شناخته شده و نشان‌دهنده توانایی PSO در بهبود دقت مدل‌های یادگیری ماشین است (پیریوایزو

1- Houssein, Mohamed, Djenouri, Wazery & Ibrahim
2- Harchegani & Moghaddasi
3- Ballerini

همکاران، ۲۰۲۳).

پژوهش (ونگ، ژوو، و ژنگ[1]، ۲۰۲۵)، به طبقه‌بندی تصاویر اشعه ایکس با استفاده از ادغام اطلاعات دو مدل و الگوریتم PSO بهبود یافته می‌پردازد. روش پیشنهادی با ترکیب ویژگی‌های دو مدل مختلف، دقت طبقه‌بندی را افزایش می‌دهد. نتایج تجربی نشان می‌دهد که این رویکرد نسبت به روش‌های سنتی عملکرد بهتری در شناسایی ناهنجاری‌ها در تصاویر اشعه ایکس دارد و می‌تواند به تشخیص دقیق‌تر بیماری‌ها کمک کند.

ادغام تصاویر پزشکی چند حالته نیز، روشی موثر در تشخیص و برنامه‌ریزی درمانی است که به ترکیب داده‌های تصویری از روش‌های تصویربرداری مختلف مانند PET، CT، MRI و SPECT می‌پردازد. برای این هدف، روش جدیدی به نام ادغام وزن‌گذاری بهینه (OWAF) با استفاده از الگوریتم PSO، پیشنهاد شده است. این روش از تکنیک‌های مختلفی برای ادغام تصاویر چند حالته مغزی استفاده می‌کند که شامل تبدیل‌های فضایی مانند تبدیل کسینوس گسسته (DCT)، تبدیل فوریه سریع (FFT) و تبدیل موجک گسسته (DWT) استفاده شده است (شهناز، دانیل، گانتر، و ساتراسپالی[2]، ۲۰۲۱).

در این رویکرد، تصاویر ورودی به مولفه‌های تقریبی و جزئی تقسیم می‌شوند و وزن‌های بهینه برای مولفه‌های جزئی با استفاده از PSO محاسبه می‌شود. نتایج نشان می‌دهد که OWAF با PSO به‌طور قابل توجهی کیفیت تصویر ادغام شده را در مقایسه با روش‌های مرسوم بهبود می‌بخشد و در برابر نویزهای گوسی و لکه‌ای مقاوم است. همچنین، زمان محاسباتی این الگوریتم در مقایسه با الگوریتم‌های دیگر مانند الگوریتم ژنتیک (GA) بهتر ارزیابی شده است.

انتخاب ویژگی

الگوریتم PSO همچنین در فرآیندهای انتخاب ویژگی در تحلیل داده‌های بهداشتی و درمانی مورد توجه قرار گرفته است. این فرایند شامل تسهیل مدل‌سازی پیش بینی دقیق، با حذف ویژگی‌های غیرضروری و تکراری از مجموعه داده‌های بزرگ است (شامی و همکاران، ۲۰۲۲؛ لاوانی، سینگال، کومار و گوپتا[3]، ۲۰۱۳)، که برای رویکردهای پزشکی بسیار حیاتی است. این تکنیک بهینه‌سازی به‌ویژه در مدیریت مجموعه داده‌های پزشکی با ابعاد بالا مفید است و امکان طبقه‌بندی و تفسیر بهتر داده‌های بیماران را فراهم می‌آورد و در عین حال عملکرد کلی الگوریتم‌های یادگیری ماشین مورد استفاده در پیش‌بینی و مدیریت بیماری‌ها را بهبود می‌بخشد (ریواتی و همکاران، ۲۰۲۵).

پژوهش (وانگ، تاین، هوو، چن، و کوو[4]، ۲۰۲۵) به بهینه‌سازی منابع خدمات پزشکی در بخش‌های اورژانس با استفاده از الگوریتم PSO و مدل تصمیم‌گیری مارکوف می‌پردازد. هدف اصلی، مدیریت صف‌های بیماران دوکلاسه برای کاهش زمان انتظار و بهبود کیفیت خدمات است. نتایج نشان می‌دهد که این رویکرد می‌تواند به تخصیص بهینه منابع و افزایش کارایی در ارائه خدمات پزشکی در شرایط اضطراری کمک کند.

در مطالعه‌ای (کازرانی[5]، ۲۰۲۴) به بررسی انتخاب ویژگی‌ها برای بهبود دقت تشخیص سرطان سینه با استفاده از تکنیک‌های یادگیری ماشین و PSO پرداخته شده است. سرطان سینه که ۲۵/۱٪ از کل سرطان‌ها در زنان را تشکیل می‌دهد، نیازمند انتخاب موثر ویژگی‌ها برای کاهش ابعاد داده‌ها و افزایش دقت تشخیصی است. در این پژوهش، ده الگوریتم مختلف یادگیری ماشین از جمله AdaBoost، درخت تصمیم، KNN، LDA، رگرسیون لجستیک وANN بر روی سه مجموعه داده معروف WPBC، Coimbra و WDBC پیاده‌سازی شده‌اند. بهبود معیارهای عملکرد در الگوریتم‌های مختلف، در نتیجه ی استفاده از PSO برای فرایند انتخاب ویژگی، نشان‌دهنده‌ی افزایش دقت تشخیص سرطان سینه است. تکنیک‌های اعتبارسنجی متقاطع و معیارهای ارزیابی مانند دقت، حساسیت، خاصیت، Score-F1 و AUC نیز، به وضوح اثربخشی PSO را در افزایش دقت و کارایی تشخیص سرطان سینه با استفاده از الگوریتم‌های یادگیری ماشین تایید می‌کنند.

1- Weng, Zuo, & Zheng
2- Shehana, Daniel, Guntur, & Satrasupalli,
3- Lalwani, Singhal, Kumar, & Gupta
4- Wang, Tian, Hu, Chen, & Ku
5- Kazerani

طراحی و توسعه دارو

الگوریتم PSO در زمینه‌ی کشف و توسعه دارو همچون بهینه‌سازی خواص (ADMET) و به‌خصوص برای جستجوی مولکول‌های بهینه با خواص مطلوب استفاده شده است. عملکرد آن شامل بهینه‌سازی ویژگی‌های مولکولی مانند حلالیت، فعالیت بیولوژیکی و سایر خواص مرتبط با داروها به‌کار رفته است که در نهایت منجر به یافتن مولکول‌هایی می‌شود که هم خواص مطلوب را دارند و هم اثر بخشی بیولوژیکی خود را حفظ می‌کنند. به این منظور، ChemMORT به‌عنوان یک پلتفرم خودکار برای بهینه‌سازی خواص ADMET معرفی شده است. این پلتفرم شامل سه مولفه اصلی است: SMILES Encoder و Descriptor Decoder که توصیف عملکرد آن‌ها خارج از بحث مورد نظر است. سومین مولفه Molecular Optimizer است که برای بهینه‌سازی خواص مولکولی از PSO استفاده می‌کند. این مولفه به کاربر اجازه می‌دهد تا اطلاعات مربوط به مولکول و خواص هدف را وارد کند و از توابع هدف مختلف برای بهینه‌سازی استفاده کند (یای و همکاران[1]، ۲۰۲۴)

زمان‌بندی و رژیم دارویی

در حوزه‌ی پزشکی و درمان سرطان پژوهشی صورت گرفته که با طراحی یک پروتکل زمان‌بندی شیمی‌درمانی، به بررسی پویای تعاملات بین سلول‌های توموری، سلول‌های ایمنی مؤثر و داروهای مورد استفاده می‌پردازد. هدف بهینه‌سازی زمان‌بندی شیمی‌درمانی و رژیم دارویی به‌منظور کاهش اندازه سلول‌های توموری، مصرف دارو و مدت زمان کل درمان است. در این راستا، الگوریتم PSO به منظور شناسایی دوره‌های بهینه درمان و استراحت استفاده شده است و در مقایسه با SA، عملکرد بهتری در کاهش جمعیت تومور و زمان درمان نشان داده است. پروتکل طراحی شده شامل دوره‌های درمان و استراحت برای هر چرخه شیمی‌درمانی است. برای بهینه‌سازی این پروتکل، از الگوریتم PSO بهره‌برداری شده است که به شناسایی دوره‌های بهینه درمان و استراحت کمک می‌کند. این الگوریتم با تولید ذراتی که نمایانگر دوره‌های درمان و استراحت هستند، به حل مسئله کنترل بهینه و شبیه‌سازی تاثیرات درمان شیمیایی می‌پردازد. این روش در مقایسه با روش‌های سنتی شیمی‌درمانی مزایای قابل توجهی دارد، از جمله کاهش قابل توجه اندازه تومور به حدود ۰/۰۹ در مدت ۴۲ روز، کاهش زمان درمان نسبت به SA که به ۶۰ روز نیاز داشت و بهینه‌سازی همزمان دوز دارو و زمان‌بندی جلسات شیمی‌درمانی به‌گونه‌ای که به تکثیر سلول‌های طبیعی اجازه داده شود (دهبی، ابوالرشید، قضایی و مسعود[2]، ۲۰۲۳)

در تحقیق (لی، یائو، یائو و چن[3]، ۲۰۰۵) الگوریتم PSO به‌عنوان یک تکنیک موثر در برنامه‌ریزی پرتودرمانی مدولاسیون شدت (IMRT) معرفی شده است. این روش به‌ویژه در انتخاب زاویه‌های بهینه پرتو و بهینه‌سازی نقشه شدت پرتو کاربرد دارد. در این مطالعه، رویکرد جدیدی به نام BASPSO ارائه شده که شامل جداسازی مراحل بهینه‌سازی و استفاده از PSO برای انتخاب زاویه‌های پرتو و روش گرادیان مزدوج (CG) برای بهینه‌سازی نقشه شدت است. نتایج نشان می‌دهد که BASPSO در مقایسه با الگوریتم‌های ژنتیک (GA) عملکرد بهتری در کاهش زمان محاسبه و بهبود توزیع دوز دارد. در موارد شبیه‌سازی شده و بالینی، PSO زمان محاسبه را به‌طور قابل توجهی کاهش داده و به بهبود کارایی و دقت در برنامه‌ریزی پرتودرمانی کمک کرده است.

بیوانفورماتیک

در بیوانفورماتیک، الگوریتم‌های فرابتکاری در مواردی مانند داکینگ مولکولی، پیش‌بینی ساختار پروتئین و مسائل رشته‌ای کاربرد دارند. الگوریتم‌های فرابتکاری مانند PSO، به‌دلیل توانایی‌شان در حل مسائل پیچیده و بزرگ، به‌طور فزاینده‌ای مورد توجه قرار گرفته‌اند.

به‌عنوان مثال، در پیش‌بینی ساختار پروتئین، این دسته از الگوریتم‌ها می‌توانند به شناسایی بهترین ساختارها بدون نیاز به هموlوژی کمک کنند. همچنین، در مسائل داکینگ مولکولی، PSO می‌تواند به شناسایی بهترین شکل بین مولکول لیگاند و ماکرومولکول‌ها

1- Yi, etal
2- Dhieb, Abdulrashid, Ghazzai & Massoud
3- Li, Yao, Yao & Chen

کمک کند (کالویت، بنتیو، جان و پرادوس[1]، ۲۰۲۳). این الگوریتم با جستجوی فضای راه‌حل‌ها و تعادل بین تنوع و تمرکز، به بهبود دقت و کارایی در حل مسائل بیوانفورماتیک می‌پردازد. در نهایت، چالش‌ها و روندهای نوظهور مانند داده‌های بزرگ و نیاز به مدل‌سازی بهینه، پژوهشگران را به سمت استفاده بیشتر از الگوریتم‌های فرابتکاری و الگوریتم‌های ترکیبی سوق می‌دهد.

جدول ۱ و جدول ۲ شامل خلاصه‌ای از کاربرد انواع PSO و یا ترکیب آن با سایر تکنیک‌ها و روش‌ها در زمینه‌های مختلف پزشکی است.

مقایسه‌ی PSO با سایر الگوریتم‌های بهینه‌سازی

الگوریتم بهینه‌سازی کلونی مورچه (ACO) و الگوریتم بهینه‌سازی کلونی زنبور مصنوعی (ABC)، هر دو مبتنی بر هوش ازدحامی هستند. هر یک از این الگوریتم‌ها ویژگی‌های خاصی دارند که بر عملکرد آن‌ها در سناریوهای مختلف تاثیر می‌گذارد. برای درک بهتر، عملکرد هر کدام در ادامه به اختصار توضیح داده شده است.

بهینه‌سازی کلونی مورچه‌ها (ACO)

الگوریتم ACO یک الگوریتم فرابتکاری است که از رفتار جستجوی مورچه‌های واقعی الهام گرفته شده و توسط مارکو دوریگو در سال ۱۹۹۲ توسعه یافته است. این الگوریتم برای حل مسائل پیچیده بهینه‌سازی از طریق شبیه‌سازی جستجوی مورچه‌ها برای غذا عمل می‌کند. ACO بر اساس اصل واریز فرومون‌ها توسط مورچه‌ها در مسیرهایی که طی می‌کنند، کار می‌کند که به مورچه‌های بعدی کمک می‌کند تا به کارآمدترین مسیرها به منابع غذایی هدایت شوند. این ارتباط مبتنی بر فرومون، فرآیند یادگیری جمعی را امکان‌پذیر می‌سازد و به شناسایی مسیرهای بهینه کمک می‌کند (دوریگو، استاتلز و استاتلز[2]، ۲۰۰۶). الگوریتم ACO به‌صورت تصادفی راه‌حل‌هایی را ایجاد می‌کند. این الگوریتم به‌دلیل قابلیت تولید تنوع در راه‌حل‌ها و جستجوی فضای بزرگ‌تر نسبت به فرابتکاری‌های ساده، به‌ویژه در مسائل پیچیده و NP-hard، مورد توجه قرار گرفته است. ACO در مسائلی مانند فروشنده دوره‌گرد (TSP)، تاخیر وزنی در ماشین‌های منفرد (SMTWTP) و پوشش مجموعه (SCP) کاربرد دارد. همچنین، در مسائل پویا، مانند مسیریابی در شبکه‌های داده، نیز مورد استفاده قرار گرفته است (دوریگو و همکاران، ۲۰۰۶). با وجود قدرت ACO در حل مسائل، این الگوریتم شامل چالش‌هایی مانند پیچیدگی حافظه و عدم تضمین همگرایی به راه‌حل‌های بهینه، وجود دارد. در واقع، الگوریتم ACO به دلیل ماهیت تصادفی خود و به‌روزرسانی‌های فرومون، ممکن است به بهینه‌ترین راه‌حل دست نیابد و این مسئله می‌تواند منجر به عدم تضمین همگرایی به راه‌حل‌های بهینه شود. همچنین، نیاز به بهبود زمان محاسباتی و کارایی در حل مسائل بزرگ و پیچیده وجود دارد. شناخت این محدودیت‌ها برای استفاده موثر از ACO و بررسی روش‌های بهینه‌سازی جایگزین ضروری است (بلوم[3]، ۲۰۰۵).

بهینه‌سازی کلونی زنبور عسل (ABC)

الگوریتم ABC برای نخستین بار در سال ۲۰۰۷، توسط کارابوگا و باستورک معرفی شد. این الگوریتم بهینه‌سازی مبتنی بر رفتار زنبورهای عسل در طبیعت است و شامل زنبورهای کارگر (employed bees)، زنبورهای ناظر (onlooker bees) و زنبورهای کاوشگر (scout bees) است. وظیفه‌ی زنبورهای کارگر جستجوی منابع غذایی است و هر کدام از آن‌ها یک منبع غذایی را نمایندگی می‌کند. مقدار شهد در هر منبع غذایی نشان‌دهنده کیفیت راه‌حل مربوطه است. زنبورهای ناظر بر اساس میزان شهد منابع غذایی، به انتخاب منابع غذایی می‌پردازند و زنبورهای کاوشگر در صورتی فعال می‌شوند که زنبورهای کارگر توانایی بهبود راه‌حل‌های خود را نداشته باشند (الراسون، آلموش، نوراوی، السواتی، و مخادم[4]، ۲۰۲۱). الگوریتم شامل چند فاز اصلی است. در فاز اولیه، منابع غذایی به‌صورت تصادفی تعیین می‌شوند. پس از آن زنبورهای کارگر به جستجوی منابع غذایی جدید در نزدیکی منابع فعلی خود می‌پردازند. این

1- Calvet, Benitoa, Juan & Prados
2- Dorigo, Stützle, & Stützle
3- Blum
4- Alrosan, Alomoush, Norwawi, Alswaitti & Makhadmeh

زنبورها، در صورت پیدا کردن منابع بهتر، آن‌ها را به‌عنوان منابع جدید در نظر می‌گیرند. زنبورهای ناظر نیز با توجه به کیفیت منابع غذایی موجود، منابع غذایی را انتخاب می‌کنند و در صورت پیدا کردن منابع بهتر، به آن‌ها ملحق می‌شوند.

در پایان هر چرخه جستجو، فاز زنبورهای کاوشگر انجام می‌شود. در صورتی که زنبورهای کارگر نتوانند بهبود قابل توجهی در راه‌حل‌های خود ایجاد کنند، به زنبورهای کاوشگر تبدیل می‌شوند و به‌طور تصادفی به جستجوی منابع غذایی جدید می‌پردازند. این مراحل تا زمانی که یک معیار توقف مشخص شود، به‌طور مکرر تکرار می‌شوند (الراسون و همکاران، ۲۰۲۱).

الگوریتم ABC به دلیل سادگی و کارایی‌اش در حل مسائل بهینه‌سازی، به‌ویژه در مسائل با پارامترهای واقعی، مورد توجه محققان قرار گرفته است و نسخه‌های متعددی از آن برای بهبود عملکرد و کارایی آن پیشنهاد شده است. نسخه‌های بهبود یافته‌ای از الگوریتم ABC مانند GABC، MABC و EABC تاکنون ارائه شده‌اند که هدف اصلی آن‌ها افزایش توانایی الگوریتم در جستجوی بهینه و بهره‌وری بیشتر در فرآیند جستجو است. این نسخه‌ها با معرفی پارامترهای جدید و تغییر در معادلات جستجو، منجر به بهبودهای قابل توجهی در سرعت همگرایی و کیفیت راه‌حل‌ها به ارمغان آورده‌اند (Alrosan et al, 2021, pp. 1673-1675).

تقسیم بندی تصاویر MRI مغز

پژوهش سعیدی‌فر، یزدی و ذوالقدر اصلی[1] (۲۰۲۱)، با هدف تشخیص خودکار محل تومور در یک تصویر MRI مغز با دقت بالا صورت گرفته است و فرایند آن شامل سه مرحله‌ی پیش‌پردازش، تقسیم‌بندی و در آخر پس پردازش است. الگوریتم پیشنهادی، با جداسازی جمجمه از مغز توسط عملگرهای مورفولوژیکی، فرایند خود را آغاز می‌کند. پس از آن، با استفاده از الگوریتم های تکاملی مختلف همچون PSO و ABC، تقسیم‌بندی تصویر صورت می‌گیرد. در واقع الگوریتم PSO، برای یافتن بهترین مراکز خوشه‌ها در تقسیم‌بندی تصاویر استفاده می‌شود.

در این رویکرد، شدت پیکسل‌ها به عنوان ذرات در نظر گرفته می‌شوند و ذرات در هر تکرار به جستجوی بهترین همسایگی محلی و بهترین راه‌حل جهانی می‌پردازند. تابع هزینه پس از هر تکرار ارزیابی می‌شود و هدف الگوریتم کمینه‌سازی فاصله اقلیدسی درون خوشه‌ها است. تعداد ذرات اولیه در این پژوهش، ۱۰۰ در نظر گرفته شده و تابع هدف به صورت مجموع فاصله اقلیدسی تعریف می‌شود. معیار توقف الگوریتم زمانی است که بهترین هزینه در ۱۵ تکرار متوالی ثابت بماند. نمودار موجود در شکل شماره (۲)، خلاصه‌ای از این مراحل است.

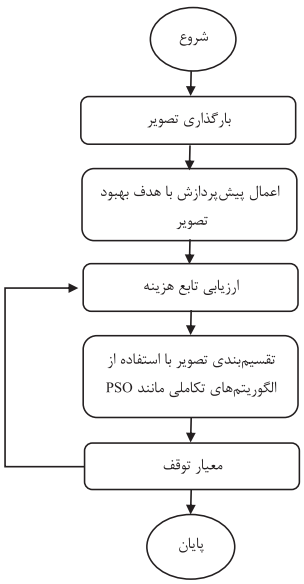

نمودار(۲): نحوه اجرای تقسیم‌بندی

به طور مشابه، الگوریتم ABC نیز برای تقسیم‌بندی تصویر به کار می‌رود. در این الگوریتم، زنبورهای کارگر و ناظر اطلاعات منابع غذایی را با یکدیگر به اشتراک می‌گذارند و بر اساس این اطلاعات، موقعیت‌های جدید را بررسی می‌کنند. تابع هدف و معیار توقف در این الگوریتم مشابه PSO است. برای استخراج تومور، چهار ویژگی از تصاویر تقسیم‌بندی شده استخراج می‌شود که شامل محیط و قطر معادل تومور و میانگین و واریانس ناحیه تومور است.

همچنین از مدل کانتور فعال (Active Contour Model)، به منظور بهبود عملکرد در تشخیص تومور استفاده شده است و این مدل اطلاعات غنی را از تصاویر پزشکی استخراج

1- Saeidifar, Yazdi, & Zolghadrasli

می‌کند. در این مدل، مرز اولیه به سمت شیء مورد نظر حرکت می‌کند و مرز استخراج‌شده از الگوریتم‌های قبلی به عنوان مرز اولیه برای مدل کانتور فعال استفاده می‌شود.

نتایج ارزیابی دو الگوریتم PSO و ABC با ارجاع به پژوهش سعیدی‌فر و همکاران (۲۰۲۱)، در جدول شماره (۲) قرار داده شده است. الگوریتم ABC با دقت ۹۷/۹۳٪ کمی بهتر از PSO با دقت ۹۷/۸۵ ٪ عمل کرده است. معیار یادآوری در PSO با مقدار ۸۰/۸۹ ٪، کمی بهتر از همین معیار در ABC با مقدار ۸۰/۷۰ ٪ است. در سایر معیارها نیز الگوریتم PSO نسبت به الگوریتم ABC عملکرد بهتری داشته است.

همچنین در تحقیق خرم و یزدی[1] (۲۰۱۸)، مراحل اصلی پردازش توسط الگوریتم ACO شامل پیش‌پردازش تصاویر MRI مغز، استخراج ویژگی‌های بافت و توزیع فرومون‌ها برای هدایت حرکت مورچه‌ها به سمت نواحی هدف است. در مرحله پیش‌پردازش، به کمک تحلیل هیستوگرام و الگوریتم‌های رشد ناحیه‌ای، جمجمه از بافت‌های غیرمغزی جداسازی می‌شود. سپس، ویژگی همگنی با استفاده از پنجره‌های ۳×۳ محاسبه می‌شود.

در مرحله بعد، مورچه‌ها با توجه به توزیع فرومون و همگنی، پیکسل‌های مناسب را برای تقسیم‌بندی انتخاب می‌کنند. در مرحله پس‌پردازش، پارامترها به گونه‌ای تعیین می‌شوند تا فقط پیکسل‌های همگن قابل توجه و همگن با سطح پایین هدف‌گذاری شوند. پیش‌بینی عملکرد الگوریتم با استفاده از معیارهای مختلفی مانند دقت، حساسیت، و نرخ مثبت صورت گرفته است. این الگوریتم نشان داده است که می‌تواند در شناسایی تومورها و تفکیک بافت‌های مغزی به طور موثری عمل کند و نتایج قابل قبولی ارائه دهد. این مطالعه عملکرد الگوریتم ACO پیشنهاد شده، PSO و ABC را بر مناطق و بافت‌های مختلف تست می‌کند. به عنوان نمونه، نتیجه‌ی یکی از این تست ها بر بافت‌های مختلف بازگو می‌شود. بافت خاکستری یا GM شامل سلول‌های عصبی و دندریت‌ها است. بافت سفید یا WM شامل الیاف عصبی است به‌وسیله میلین پوشیده شده‌اند. در نهایت، مایع مغزی-نخاعی یا CSF در فضای بین مغز و جمجمه و همچنین در کانال نخاعی وجود دارد. جهت بررسی بیشتر برخی یافته‌های پژوهش خرم و یزدی (۲۰۱۸) در قالب جدول شماره (۳) قرار گرفته است. مطابق این جدول، در بافت خاکستری (GM)، از منظر معیار FOR، الگوریتم ABC با داشتن کمترین مقدار برتر است؛ این در حالی است که الگوریتم PSO با داشتن دقت ۹۰/۳۷۲، نسبت به سایرین برتری نسبی دارد. اما با توجه به اطلاعات جدول ۵ در بافت سفید (WM)، با در نظر گرفتن معیار FOR، الگوریتم PSO برتر است، اما با معیار FDR و Percision، الگوریتم ABC عملکرد بهتری داشته است. در نهایت با ادامه‌ی بررسی این پژوهش، درمی‌یابیم که ACO برای کاربردهایی که تعادل بین Precision و Recall اهمیت بالایی دارد، می‌تواند انتخاب مناسبی باشد، اما PSO همچنان رقیب قدرتمندی با عملکرد پایدار در همه بافت‌هاست.

1- Khorram & Yazdi

جدول (۱): مرور کاربرد انواع الگوریتم PSO و ادغام آن با سایر الگوریتم‌ها و تکنیک‌ها در حوزه‌های مختلف پزشکی

	الگوریتم	کاربرد	مزایا
تشخیص بیماری	PSO+ANN	تشخیص تب دنگی و بیماری‌های قلبی-عروقی	عملکرد بسیار قوی و کارآمد در تشخیص زودهنگام
	PSO+I-DBN	تشخیص زودهنگام بیماری‌های قلبی-عروقی در بیماران دیابتی نوع ۲	دقت ۹۸/۹۵٪
	QPSO+SVM	تشخیص بیماری‌های قلبی-عروقی	بهبود دقت
	IVbBoPSO	تشخیص سرطان کلیه و کبد	حداکثر دقت طبقه بندی
	VbBoPSO		
	PSO+RF	تشخیص بیماری‌های لنفی	دقت مناسب و بهبود عملکرد مدل پیش‌بینی
	PSO-ELM	تشخیص کووید-۱۹	دقت سناریو تنفس: از ۸۳ تا بیشتر از ۹۵٪ دقت سناریو سرفه: از ۸۸ تا بیشتر از ۹۶٪ دقت سناریو شمارش: از ۸۸ تا بیشتر از ۹۶٪ دقت سناریو حروف صدادار: از ۸۲ تا بیشتر از ۹۶٪
		هدایت و استقرار نانوربات‌ها	کاهش زمان لازم برای استقرار نانوروبات‌ها به محل‌های هدف افزایش دقت در تشخیص و درمان با استفاده از نانوروبات‌ها. بهینه‌سازی نانوذرات درمانی برای انواع خاص سلول‌ها و بیماران.
	SDPSO-SVM	تشخیص بیماری آلزایمر (AD)	موثرترین رویکرد
پردازش تصاویر	MOPSO+ANN	شناسایی پولیپ‌ها و سرطان روده	دقت ۰/۹۲۹۸ حساسیت ۰/۹۸۸۹ شفافیت ۰/۹۳۵۴
	PSO+OWAF	ادغام تصاویر چند حالته مغزی	بهبود دقت مقوم در برابر نویز کاهش زمان محاسباتی
	SDPSO-SVM	مشترک	

جدول (۲): نتایج ارزیابی عملکرد دو الگوریتم PSO و ABC در تقسیم‌بندی تصاویر MRI مغز

	الگوریتم	کاربرد	مزایا
انتخاب ویژگی	PSO+ANN+ طبقه‌بندی‌های Machine Learning مانند SVM	تشخیص سرطان سینه	بهبود دقت طبقه بندی‌های Machine Learning مختلف از ۳ تا ۱۰٪

	PSO+RF		مشترک
	IVbBoPSO		
	VbBoPSO		
	PSO+I-DBN		
کشف و توسعه دارو	پلتفرم chemMort+PSO	بهنیه‌سازی خواص مولکولی	بهبود عملکرد (ایجاد ۱۷۱ مولکول بهینه با ویژگی‌های بهتر از مولکول اولیه)
زمان‌بندی و رژیم دارویی	PSO+OCM	شناسایی دوره‌های بهینه درمان و استراحت	کاهش قابل توجه اندازه تومور کاهش زمان درمان بهینه‌سازی همزمان دوز دارو و زمان‌بندی جلسات شیمی‌درمانی
	BAPSO	برنامه‌ریزی و پرتودرمانی	عملکرد بهتر در کاهش زمان محاسبه و بهبود توزیع دوز کاهش زمان محاسبه به طور قابل توجه در موارد شبیه‌سازی شده و بالینی، بهبود کارایی و دقت در برنامه‌ریزی پرتودرمانی

جدول (۳): نتایج ارزیابی عملکرد الگوریتم‌های PSO و ABC در تقسیم‌بندی تصاویر MRI مغز (بافت خاکستری)

الگوریتم	score-F1 امتیاز-F1	Recall یادآوری	Percision دقت	Accuracy دقت کلی یا صحت	Jaccard
PSO	٪ ۸۸/۱۰	٪ ۸۰/۸۹	٪ ۹۷/۸۵	٪ ۹۹/۵۵	٪ ۷۹/۳۴
ABC	٪ ۸۸/۰۵	٪ ۸۰/۷۰	٪ ۹۷/۹۳	٪ ۹۹/۵۴	٪ ۷۹/۲۱

جدول (۳): نتایج ارزیابی عملکرد الگوریتم‌های PSO و ABC در تقسیم‌بندی تصاویر MRI مغز (بافت خاکستری)

بافت خاکستری (GM)	FOR	FDR	Accuracy
ACO پیشنهاد شده	۳/۱۶۴	۹/۸۹۴	۹۰/۱۰۶
PSO	۳/۴۸۷	۹/۶۲۸	۹۰/۳۷۲
ABC	۲/۵۱۰	۱۱/۷۷۷	۸۸/۲۲۳

بافت سفید (WM)	FOR	FDR	Accuracy
ACO پیشنهاد شده	۸۸/۹۸	۹۹/۸۱	۹۶/۳۱۹
PSO	۸۶/۰۷	۹۹/۹۷	۹۶/۷۹۳
ABC	۸۲/۷۷	۹۹/۹۵	۹۵/۶۸۸

۴- یافته‌های تحقیق

در این مطالعه، ابتدا به اصول و مفاهیم پایه‌ای PSO و پارامترهای مرتبط با آن به‌طور جامع پرداخته شد، و مروری بر روند الگوریتم، پارامترهای کنترلی، معادلات، مزایا و معایب آن صورت گرفت. سپس با بررسی مقالات مختلف و منابع معتبر، انواع کاربردهای این الگوریتم و ادغام آن با تکنیک‌های پیشرفته‌ای مانند شبکه‌های عصبی و یادگیری ماشین مورد بررسی قرار گرفت.

کاربردهای بررسی شده در این پژوهش شامل موارد زیر است:

- **تشخیص بیماری‌ها:** PSO به‌عنوان ابزاری موثر در شناسایی و تشخیص زودهنگام بیماری‌های مختلف، به‌ویژه بیماری‌های قلبی-عروقی و کووید-۱۹، شناخته شده است. این الگوریتم به پزشکان کمک می‌کند تا با تحلیل داده‌های پزشکی، الگوهای پنهان را شناسایی کنند و تصمیمات بهتری اتخاذ نمایند.
- **پردازش تصاویر پزشکی:** PSO در پردازش و تحلیل تصاویر پزشکی، به‌ویژه در شناسایی پولیپ‌ها و سرطان روده، کاربردهای قابل توجهی دارد. این الگوریتم به بهبود دقت در تشخیص ناهنجاری‌ها و تسهیل در تشخیص زودهنگام بیماری‌ها کمک می‌کند.
- **انتخاب ویژگی و کشف داروها:** PSO به‌عنوان ابزاری برای انتخاب ویژگی‌های مهم در داده‌های پزشکی و همچنین در فرآیند کشف داروها، به‌ویژه در شناسایی ترکیبات مؤثر، مورد استفاده قرار می‌گیرد.
- **زمانبندی دارو و بیوانفورماتیک:** این الگوریتم در بهینه‌سازی زمانبندی داروها و همچنین در تحلیل داده‌های بیوانفورماتیک، به‌ویژه در شبیه‌سازی و مدل‌سازی سیستم‌های زیستی، کاربرد دارد.

علاوه بر این، نتایج پژوهش نشان‌دهنده قابلیت‌های بالای PSO در بهبود دقت و کارایی در تشخیص و درمان بیماری‌ها است. این الگوریتم می‌تواند به‌عنوان مبنایی برای پژوهش‌های آینده در این حوزه مورد استفاده قرار گیرد.

در نهایت، مقایسه‌ای بین عملکرد PSO، الگوریتم بهینه‌سازی کلونی مورچه‌ها (ACO) و الگوریتم بهینه‌سازی زنبور عسل (ABC) در تقسیم‌بندی تصاویر پزشکی انجام شد. این مقایسه نشان می‌دهد که دقت این الگوریتم‌ها نزدیک به هم بوده و ممکن است در برخی معیارها نسبت به یکدیگر برتری یا ضعف نشان دهند. این یافته‌ها بر اهمیت انتخاب الگوریتم مناسب برای مسائل خاص در حوزه پزشکی تاکید دارد و می‌تواند راهنمایی برای پژوهش‌های آینده در این زمینه باشد.

۵- نتیجه‌گیری

بررسی انجام شده در این پژوهش نشان داد که الگوریتم PSO در میان کاربردهای مختلفی که در مسائل پزشکی دارد، در تحلیل و تقسیم‌بندی تصاویر پزشکی دقت مناسبی دارد؛ هرچند دقت اکثر الگوریتم‌های تکاملی در این زمینه بسیار به یکدیگر نزدیک است. همچنین ممکن است هرکدام از این الگوریتم‌ها در زمینه‌ی خاصی نسبت به دیگری برتری داشته باشد. به عنوان نمونه، با توجه به بررسی صورت گرفته، الگوریتم ABC در دقت کلی نسبت به الگوریتم PSO برتری دارد، در حالی که PSO در معیار یادآوری عملکرد بهتری را نشان می‌دهد. این نتایج به وضوح نشان‌دهنده قابلیت‌های PSO در کاربردهای پزشکی هستند.

البته با وجود دقت مناسب، کارایی الگوریتم در مواردی نیازمند بهبود است. بررسی‌ها نشان‌دهنده‌ی این است که کارایی الگوریتم PSO، در فضای جستجو با ابعاد بالا، به چالش کشیده می‌شود. همچنین، نیاز به حافظه و انتخاب صحیح پارامترها و توپولوژی‌ها از دیگر مسائل مهم و تاثیرگذار بر عملکرد آن است. در آینده، می‌توان استفاده از الگوریتم PSO در مسائل و کاربردهای متنوع و گسترده‌تری از مسائل پزشکی را بررسی کرد. به عنوان مثال، بهینه‌سازی درمان‌های شخصی‌سازی شده، تحلیل داده‌های ژنومی و پروتئومیک، بهینه‌سازی منابع بیمارستانی، بهینه‌سازی سیستم‌های پشتیبانی تصمیم‌گیری بالینی، بهینه‌سازی برنامه‌های مدیریت بیماری‌های مزمن و کشف زمان‌بندی بهینه برای جراحی‌ها کاربردهایی هستند که در پژوهش‌های پیشین کمتر به آن‌ها پرداخته شده است.

همچنین، پژوهش‌های آینده می‌توانند به بررسی بیشتر در زمینه‌ی ادغام PSO با الگوریتم‌ها و یا تکنیک‌های پیشرفته پرداخته و به بهبود عملکرد آن در تحلیل داده‌های پزشکی کمک کنند. همچنین، پیشنهاد می‌شود که

بهینه‌سازی پارامترهای PSO و بررسی تاثیر آن بر روی نتایج مختلف، به عنوان یک حوزه پژوهشی مهم در نظر گرفته شود.

منابع:

1- Albadr, M. A. A., Tiun, S., Ayob, M., & AL-Dhief, F. T. (2024). Particle Swarm Optimization-Based Extreme Learning Machine for COVID-19 Detection. *Cognitive Computation*, *16*(4), 1858–1873.
2- Alrosan, A., Alomoush, W., Norwawi, N., Alswaitti, M., & Makhadmeh, S. N. (2021). An improved artificial bee colony algorithm based on mean best-guided approach for continuous optimization problems and real brain MRI images segmentation. *Neural Computing and Applications*, *33*(5), 1671–1697.
3- Ballerini, L. (2025). Particle swarm optimization in 3D medical image registration: A systematic review. *Archives of Computational Methods in Engineering*, *32*(1), 311-318.
4- Calvet, L., Benito, S., Juan, A. A., & Prados, F. (2023). On the role of metaheuristic optimization in bioinformatics. *International Transactions in Operational Research*, *30*(6), 2909–2944.

5- Christian Blum, (2005), Ant colony optimization: Introduction and recent trends, *Physics of Life Reviews*, Volume 2, Issue 4, 353-373.
6- Dhieb, N., Abdulrashid, I., Ghazzai, H., & Massoud, Y. (2023). Optimized drug regimen and chemotherapy scheduling for cancer treatment using swarm intelligence. *Annals of Operations Research*, *320*(2), 757–770.
7- Dorigo, M., Birattari, M., & Stutzle, T. (2006). Ant colony optimization. IEEE Computational Intelligence Magazine, 1(4), 28–39.
8- Dorigo, M., Stützle, T., & Stützle, S. (2009). *Ant Colony Optimization: Overview and Recent Advances*.
9- Elsedimy, E. I., AboHashish, S. M. M., & Algarni, F. (2024). New cardiovascular disease prediction approach using support vector machine and quantum-behaved particle swarm optimization. *Multimedia Tools and Applications*, *83*(8), 23901–23928.
10-Gad, A. G. (2022). Particle Swarm Optimization Algorithm and Its Applications: A Systematic Review. *Archives of Computational Methods in Engineering 2022 29:5*, *29*(5), 2531–2561.
11-Habib, M., Aljarah, I., Faris, H., & Mirjalili, S. (2020). Multi-objective Particle Swarm Optimization: Theory, Literature Review, and Application in Feature Selection for Medical Diagnosis. 175–201.
12- Harchegani, H. B., & Moghaddasi, H. (2024). Designing a Hybrid Method of Artificial Neural Network and Particle Swarm Optimization to Diagnosis Polyps from Colorectal CT Images. *International Journal of Preventive Medicine*, *15*(1), 4.
13- Houssein, E. H., Mohamed, G. M., Djenouri, Y., Wazery, Y. M., & Ibrahim, I. A. (2024). Nature inspired optimization algorithms for medical image segmentation: a comprehensive review. *Cluster Computing*.
14-Ji, J., Liu, J., Zou, A., & Zhang, A. (2019). ACOEC-FD: Ant Colony Optimization for Learning Brain Effective Connectivity Networks From Functional MRI and Diffusion Tensor Imaging. *Frontiers in Neuroscience*, *13*, 475353.
15- Kaveh, M., Mesgari, M.S. Application of Meta-Heuristic Algorithms for Training Neural Networks and Deep Learning Architectures: A Comprehensive Review. Neural Process Lett 55, 4519–4622 (2023)
16-Kazerani, R. (2024). Improving Breast Cancer Diagnosis Accuracy by Particle Swarm Optimization Feature Selection. *International Journal of Computational Intelligence Systems*, *17*(1).
17-Kennedy, J. (2006). Swarm Intelligence. *Handbook of Nature-Inspired and Innovative Computing*, 187–219.
18-Kennedy, J., & Eberhart, R. (1995). Particle swarm optimization. Proceedings of ICNN'95 - International Conference on Neural Networks, Perth, WA, Australia, 1942-1948.
19- Khorram, B., & Yazdi, M. (2018). A New Optimized Thresholding Method Using Ant Colony Algorithm for MR Brain Image Segmentation. *Journal of Digital Imaging*, *32*(1), 162.
20- Lalwani, S., Singhal, S., Kumar, R., & Gupta, N. (2013). A comprehensive survey: Applications of multi-objective particle swarm optimization (MOPSO) algorithm. Transactions on Combinatorics, 2(1), 39–101.
21- Li, Y., Yao, D., Yao, J., & Chen, W. (2005). A particle swarm optimization algorithm for beam angle selection in intensity-modulated radiotherapy planning. *Physics in Medicine and Biology*, *50*(15), 3491–3514.
22- Narayanan, R., Durga, N., of, S. N.-I. J., & 2022. Impact of artificial intelligence (AI) on drug discovery and product development. *Ijper.OrgRR Narayanan, N Durga, S Nagalakshmi Indian Journal of Pharmaceutical Education and Research, 2022•ijper.Org*. Retrieved January 27, 2025,
23- Pervaiz, S., Ul-Qayyum, Z., Bangyal, W. H., Gao, L., & Ahmad, J. (2023). A Systematic Literature Review on Particle Swarm Optimization Techniques for Medical Diseases Detection. Computational and Mathematical Methods in Medicine, 2023.
24-Revathi, T. K., Sathiyabhama, B., Kaliraj, S., & Sureshkumar, V. (2025). Early Prediction of Cardio Vascular Disease (CVD) from Diabetic Retinopathy using improvised deep Belief Network (I-DBN)

with Optimum feature selection technique. *BMC Cardiovascular Disorders*, *25*(1), 30.
25- Saeidifar, M., Yazdi, M., & Zolghadrasli, A. (2021). Performance Improvement in Brain Tumor Detection in MRI Images Using a Combination of Evolutionary Algorithms and Active Contour Method. *Journal of Digital Imaging*, *34*(5), 1209–1224.
26- Shami, T. M., El-Saleh, A. A., Alswaitti, M., Al-Tashi, Q., Summakieh, M. A., & Mirjalili, S. (2022). Particle Swarm Optimization: A Comprehensive Survey. IEEE Access, 10, 10031–10061.
27- Shehanaz, S., Daniel, E., Guntur, S. R., & Satrasupalli, S. (2021). Optimum weighted multimodal medical image fusion using particle swarm optimization. *Optik*, *231*.
28- Teodorovi, D., Lui, P., Markovi, G., & Dell'Orco, M. (2006). Bee colony optimization: Principles and applications. 8th Seminar on Neural Network Applications in Electrical Engineering, Neurel-2006 Proceedings, 151–156.
29- Wang, C. H., Tian, R., Hu, K., Chen, Y. T., & Ku, T. H. (2025). A Markov decision optimization of medical service resources for two-class patient queues in emergency departments via particle swarm optimization algorithm. *Scientific Reports*, *15*(1), 2942.
30- Weng, Z., Zuo, H., & Zheng, Z. (2025). X-ray image classification with dual-model information fusion and improved PSO algorithm. *Signal, Image and Video Processing*, *19*(7), 526.
31- Yi, J. C., Yang, Z. Y., Zhao, W. T., Yang, Z. J., Zhang, X. C., Wu, C. K., Lu, A. P., & Cao, D. S. (2024). ChemMORT: an automatic ADMET optimization platform using deep learning and multi-objective particle swarm optimization. *Briefings in Bioinformatics*, *25*(2).
32- Zemmal, N., Azizi, N., Sellami, M., Cheriguene, S., Ziani, A., AlDwairi, M., & Dendani, N. (2020). Particle Swarm Optimization Based Swarm Intelligence for Active Learning Improvement: Application on Medical Data Classification. Cognitive Computation, 12(5), 991–1010.

©Authors, Published by Journal of Intelligent Knowledge Exploration and Processing. This is an open-access paper distributed under the CC BY (license http://creativecommons.org/licenses/by/4.0/).