سیستم های فازی و کاربردها
سال هفتم، شماره دوم (پائیز و زمستان ۱۴۰۳)
صص. ۳۳ تا ۶۳
شاپای چاپی: ۲۷۱۷-۴۴۰۹
شاپای الکترونیکی: ۲۷۱۷-۳۹۸۴
DOI:10.22034/JFSA.2024.467966.1234

بررسی روش‌های فازی و غیرفازی مبتنی بر الگوریتم بهینه‌سازی نهنگ و کاربردهای آن‌ها

امیرمحمد نعمتی* و مرجان کوچکی رفسنجانی

بخش علوم کامپیوتر، دانشکده ریاضی و کامپیوتر، دانشگاه شهید باهنر کرمان، کرمان، ایران

تاریخ دریافت: ۱۴۰۳/۰۴/۲۵ تاریخ پذیرش: ۱۴۰۳/۰۸/۱۸

نوع مقاله: علمی مروری

چکیده. در این مقاله، الگوریتم بهینه‌سازی نهنگ و تعدادی از الگوریتم‌های تعمیم یافته روی آن مورد بررسی قرار گرفته است. الگوریتم بهینه‌سازی نهنگ به‌عنوان یک روش فراابتکاری جدید، جایگاه برجسته‌ای در حل مسائل پیچیده بهینه‌سازی به دست آورده است. این الگوریتم که از رفتار اجتماعی نهنگ‌ها در طبیعت الهام گرفته شده، به دلیل توانایی‌های قابل توجه در یافتن بهینه‌های سراسری و محلی، مورد توجه قرار گرفته است. با این حال، الگوریتم بهینه‌سازی نهنگ با چالش‌هایی روبروست؛ نظیر نرخ همگرایی کند که می‌تواند منجر به افزایش زمان محاسباتی در حل مسائل شود، و همچنین پایبندی به برخی از راه‌حل‌های محلی، که این پایبندی به انتخاب تصادفی عوامل جستجو در مرحله اکتشاف برمی‌گردد. این محدودیت‌ها باعث شده است که پژوهشگران به توسعه و بهبود این الگوریتم با استفاده از ترکیب آن با روش‌ها و الگوریتم‌های مختلف بپردازند. در سال‌های اخیر، ترکیب الگوریتم بهینه‌سازی نهنگ با روش‌های فازی و غیرفازی موجب بهبود قابل‌توجهی در عملکرد آن، به‌ویژه در مسائلی مانند انتخاب ویژگی، خوشه‌بندی داده‌ها، و مسائل پیچیده مهندسی شده است. این ترکیب‌ها توانسته‌اند ضمن حفظ مزایای ذاتی الگوریتم بهینه‌سازی نهنگ، نقاط ضعف آن را کاهش داده و کارایی و(ادامه دارد)

2010 *Mathematics Subject Classification.* 03B52 ; 80M50 ; 97R40
* Corresponding author
E-mails: amirmohammadnemati74@gmail.com and kuchaki@uk.ac.ir.
عبارات و کلمات کلیدی. انتخاب ویژگی، الگوریتم بهینه‌سازی نهنگ، منطق فازی، خوشه‌بندی C-میانگین فازی.

© ۱۴۰۳ (انجمن سیستم‌های فازی)

دقت بیشتری در حل مسائل مختلف ارائه دهند. این مقاله به بررسی چندین نسخه بهبودیافته از الگوریتم بهینه‌سازی نهنگ می‌پردازد که با استفاده از راهکارهای مختلف توسعه یافته‌اند. این الگوریتم‌ها از جنبه‌های متعددی نظیر نرخ همگرایی، دقت، پیچیدگی، میانگین مقدار شایستگی، اجتناب از گیرافتادن در بهینه‌های محلی و کاربرد در مسائل عملی با یکدیگر مقایسه شده‌اند. علاوه بر این، نقاط قوت و ضعف هر یک از این نسخه‌ها تحلیل شده و کاربردهای آن‌ها در زمینه‌های مختلف علمی و صنعتی بررسی شده است. نتایج این پژوهش می‌تواند به‌عنوان یک مرجع جامع برای محققان و مهندسانی که در پی به‌کارگیری یا توسعه الگوریتم‌های بهینه‌سازی پیشرفته هستند، مورد استفاده قرار گیرد. همچنین، این مقاله به درک عمیق‌تر عملکرد الگوریتم بهینه‌سازی نهنگ و روش‌های بهبود آن کمک می‌کند و می‌توان از آن به‌عنوان پایه‌ای برای تحقیقات آتی در این حوزه استفاده کرد.

۱. سرآغاز

الگوریتم‌های بهینه‌سازی فراابتکاری روز به روز به علت سادگی مفاهیم، پیاده‌سازی آسان و دور زدن بهینه محلی محبوب‌تر می‌شوند. الگوریتم‌های فراابتکاری الهام گرفته از طبیعت، مسائل بهینه‌سازی را با تقلید از پدیده‌های بیولوژیکی یا فیزیکی حل می‌کنند. نهنگ‌ها از بزرگ‌ترین پستانداران جهان هستند که غالباً به صورت گروهی زندگی می‌کنند و هفت گونهٔ اصلی دارند که یکی از بزرگ‌ترین نوع آنها، نهنگ‌های گوژپشت[1] هستند. نهنگ‌های گوژپشت روش شکار خاصی دارند که شکار و تغذیه حباب تور[2] نامیده می‌شود و فقط در نهنگ‌های گوژپشت قابل مشاهده است. الگوریتم بهینه‌سازی نهنگ (WOA)[3] به علت توانایی اکتشاف و بهره‌برداری، یک بهینه‌ساز جهانی است. تغییر تطبیقی بردار جستجو A به الگوریتم WOA اجازه می‌دهد تا به آرامی بین اکتشاف و بهره‌برداری عبور کند: باکاهش A، برخی از تکرارها ($|A| \leq ۱$) به اکتشاف اختصاص داده می‌شوند و بقیه ($|A| > ۱$) به بهره‌برداری اختصاص می‌یابند. قابل توجه است که WOA فقط شامل دو پارامتر اصلی داخلی یعنی A و C است که باید در طول فرآیند تکراری خود تنظیم شوند [۱۹] که این تعداد کمِ پارامتر، یکی از مزیت‌های اصلی این الگوریتم است.

هر مجموعه داده حاوی ویژگی‌های اضافی و نامربوط است و برخی از آنها به دلیل اضافی بودن آنها بی‌اهمیت هستند. به دلیل دقت طبقه‌بندی ضعیف آنها، این ویژگی‌ها معمولاً مفید نیستند. هدف

[1] Humpback Whales
[2] Bubble-net attacking method
[3] Whale Optimization Algorithm (WOA)

اصلی انتخاب ویژگی[1] حذف این نوع ویژگی ها برای افزایش دقت طبقه‌بندی است [۱۷]. استفاده انتخاب ویژگی در الگوریتم WOA بر بهبود فرآیند یادگیری با حذف ویژگی‌های اضافی و جلوگیری از گیرکردن در بهینه محلی تمرکز دارد؛ در نهایت موجب عملکرد بهتر الگوریتم WOA می‌شود.

همچنین از طرفی استفاده از منطق فازی و ترکیب آن با الگوریتم WOA در بعضی کاربردها منجر به بهبود و عملکرد بهتر می‌شود. خوشه‌بندی C-میانگین فازی (FCM)[2] برای پیاده‌سازی آسان و کارآمد، بیشترین استفاده را در بین روش‌های مختلف خوشه‌بندی دارد. با این حال، به راحتی در بهینه محلی گیر می‌کند. الگوریتم WOA نسبت به برخی از الگوریتم‌های فراابتکاری معروف، مانند الگوریتم ژنتیک (GA)[3] و الگوریتم بهینه‌سازی ازدحام ذرات (PSO)[4] راه‌حل‌های کارآمدتری به دست آورده است. بنابراین با ترکیب FCM با WOA، مشکل خوشه‌بندی رفع می‌شود [۲۵، ۲۴، ۱۸].

الگوریتم بهینه‌سازی نهنگ به علت ماهیت تصادفی منحصر به فردش در تولید جعبه‌های جایگزینی (s-box) برای دستیابی به مقدار غیرخطی بهینه جهت اطمینان از محرمانه بودن و تأمین امنیت استفاده می‌شود [۴]، همچنین این الگوریتم برای رمزنگاری کلید متقارن و نامتقارن جهت انتخاب بهترین کلید پیشنهاد می‌شود و بهینه‌سازی برای ایجاد یک کلید تصادفی، غیرقابل شکست و غیرقابل پیش‌بینی را انجام می‌دهد و تولید چنین کلیدهایی که یک مسئلهٔ بهینه‌سازی زمان چندجمله‌ای غیرقطعی سخت (NP-Hard) است را حل می‌کند [۱۴]. بنابراین، الگوریتم WOA کاربردهای فراوانی دارد به عنوان مثال می‌توان به مسائل امنیتی و حفاظت از سیستم یا داده‌های حساس در برابر حملات در دستگاه‌های ابری و اینترنت اشیاء [۱۴، ۱۳، ۱۱، ۴]، حفظ حریم خصوصی [۲۳، ۱۶]، تشخیص حملات [۱۳]، تشخیص تقلب [۱۸]، تشخیص بدافزار [۳]، تشخیص خطا [۵]، تحلیل کلان‌داده [۲۱، ۱۱]، انتخاب ویژگی [۲۲، ۲۰، ۱۷، ۳، ۲]، بررسی وضعیت سلامت شخصی [۸]، طبقه‌بندی داده‌ها [۱۰]، خوشه‌بندی داده‌ها [۲۵]، تقسیم‌بندی تصاویر[5] [۲۴]، ژنراتورهای حرارتی و الکتریکی [۱۲] و بیوانفورماتیک [۲۲] اشاره کرد.

در این مقاله سعی شده که مقالات مهم و جدید مبتنی بر الگوریتم بهینه‌سازی نهنگ را از پایگاه‌های استنادی معتبر انتخاب کنیم. برای جستجوی مقالات از کلمات کلیدی "الگوریتم بهینه‌سازی نهنگ" و "منطق فازی" استفاده شد و تلاش کردیم مقالاتی که بیشترین ارجاعات، ارتباط با حوزه کاری ما و تأثیر را در حوزه‌های مورد نظر داشتند، انتخاب نماییم. از طرفی در مقایسه با مقالات مروری

---

[1] Feature Selection (FS)
[2] Fuzzy C-Means (FCM) clustering
[3] Genetic Algorithm (GA)
[4] Particle Swarm Optimization (PSO)
[5] Image segmentation

مشابه، مقاله حاضر تمرکز ویژه‌ای بر روی نسخه‌های تعمیم‌یافته الگوریتم نهنگ و کاربردهای خاص آن‌ها دارد. در حالی که مقالات مروری قبلی عمدتاً به بررسی کلی الگوریتم نهنگ پرداخته‌اند، مقاله فعلی به تحلیل دقیق‌تر روش‌های فازی و غیرفازی مبتنی بر این الگوریتم و ارزیابی عملکرد آن‌ها در زمینه‌های خاص پرداخته است. یکی از تفاوت های عمده این مقاله با مقالات مروری قبلی در تمرکز بر مقایسه روش‌های مبتنی بر منطق فازی است.

در ادامه این مقاله، در بخش دوم، مفاهیم پایه و پیش‌نیازهای تحقیقاتی توضیح داده شده است. بخش سوم به معرفی و توصیف کارهای مرتبط بهبودهای الگوریتم WOA با استفاده از روش‌های فازی و غیرفازی اختصاص دارد. در بخش چهارم، این روش‌های ترکیبی با معیارهای مختلفی از جمله سرعت همگرایی، دقت جستجو و اجتناب از گیرافتادن در بهینه‌های محلی و... مقایسه و به تحلیل مزایا و معایب هر روش پرداخته و کاربردهای آن‌ها را در مسائل مختلف علمی و صنعتی بررسی می‌کند. در نهایت، بخش پنجم به جمع‌بندی نتایج و پیشنهاداتی برای تحقیقات آینده می‌پردازد.

۲. پیش نیازها

۱.۲. انتخاب ویژگی (FS). انتخاب ویژگی فرآیندی است که زیرمجموعه‌ای از ویژگی‌ها را از بین تمام ویژگی‌های موجود انتخاب می‌کند، که در آن معیار خاصی برای ارزیابی خوب بودن زیرمجموعه‌های نامزد تولید شده استفاده می‌شود [۱۵]. انتخاب ویژگی به عنوان یک فرآیند پیش‌پردازش در یادگیری ماشین در نظر گرفته می‌شود. انتخاب زیرمجموعه ویژگی‌های بهینه یکی از سخت‌ترین کارها برای یک مجموعه دادهٔ کلان و پیچیده است. اهداف انتخاب ویژگی کاهش ابعاد داده‌ها و بهبود عملکرد است. ثابت شده که انتخاب ویژگی به طور موثر ویژگی‌های نامربوط و اضافی را حذف می‌کند [۱۰]. با توجه به معیارهای ارزیابی مختلف، همراه با روش‌های تولید مناسب زیرمجموعه، الگوریتم‌های انتخاب ویژگی را می‌توان به طور کلی به چهار دسته تقسیم کرد: روش‌های بسته‌بندی[1]، فیلتر، ترکیبی و توکار[2].

(آ) روش بسته‌بند: یک الگوریتم یادگیری را برای ارزیابی کیفیت زیرمجموعه‌های ویژگی انتخاب شده، یعنی دقت طبقه‌بندی در بیشتر موارد، معرفی می‌کند. به طور خاص، روش‌های بسته‌بند به طور مکرر زیرمجموعه‌های ویژگی کاندید متفاوتی را در برخی استراتژی‌ها تولید می‌کنند و از الگوریتم طبقه‌بندی به عنوان یک "جعبه سیاه" برای محاسبه دقت طبقه‌بندی مربوطه

[1] Wrapper
[2] Embedded

استفاده می‌کنند. به طور کلی، یک زیرمجموعه ویژگی تا زمانی که یک زیرمجموعه جدید با دقت طبقه‌بندی بالاتر جایگزین آن شود، حفظ می‌شود [۱۵]. با افزایش تعداد ویژگی، فضای جستجوی ویژگی زیرمجموعه‌ها به طور تصاعدی افزایش می‌یابد. تعامل بسته‌بندها با طبقه‌بندی‌کننده، آن‌ها را از نظر هزینهٔ محاسباتی گران‌تر از فیلترها می‌کند، اگرچه عملکرد بهتری نسبت به فیلترها دارند [۹].

(ب) روش فیلتر: روش‌های فیلتر، وظیفه انتخاب ویژگی را قبل از طبقه‌بندی یا خوشه‌بندی داده‌ها انجام می‌دهند و معمولاً در یک رویکرد دو مرحله‌ای اجرا می‌شوند. در مرحله اول تمامی ویژگی‌ها بر اساس معیارهای تعریف شده رتبه‌بندی می‌شوند و مرحله دوم شامل حفظ ویژگی‌های رتبه برتر می‌باشد [۹]. ویژگی‌های مجموعه داده برای ارزیابی اهمیت ویژگی استفاده می‌شود. به عنوان مثال، نظریه اطلاعات برای اندازه‌گیری ارتباط بین یک ویژگی و مفهوم هدف مورد استفاده قرار می‌گیرد. محاسبه مقادیر مربوطه نسبتاً ارزان است و مقادیر قابل استفاده مجدد هستند. بنابراین، روش‌های فیلتر معمولاً از نظر محاسباتی کارآمدتر از روش‌های بسته‌بند هستند. با این حال، به دلیل عدم وجود یک الگوریتم یادگیری خاص که مرحله انتخاب ویژگی را هدایت می‌کند، ویژگی‌های انتخاب شده ممکن است برای الگوریتم‌های یادگیری هدف بهینه نباشند [۱۵].

(پ) روش توکار: محاسن روش‌های بسته‌بندی و فیلتر را جذب می‌کنند، اما کاملاً با آنها متفاوت هستند. اکتشاف بهترین زیرمجموعه ویژگی‌ها در طول آموزش الگوریتم یادگیری (به عنوان مثال، در طول بهینه‌سازی وزن‌ها در یک شبکه عصبی) انجام می‌شود. به همین دلیل، رویکردهای توکار از نظر محاسباتی در مقایسه با بسته‌بندها هزینه کمتری دارند [۹]. الگوریتم یادگیری در فرآیند گنجانده شده است، اما ارزیابی‌های تکراری دقت طبقه‌بندی زیرمجموعه دیگر مانند آنچه در روش‌های بسته‌بند وجود دارد، مورد نیاز نیست. یک طبقه‌بندی، آموزش داده می‌شود و ضرایب ویژگی به طور همزمان با به حداقل رساندن خطاهای برازش تنظیم می‌شوند. زیرمجموعه ویژگی انتخاب شده را می‌توان از ضرایب ویژگی استخراج کرد. بنابراین، روش‌های توکار از نظر محاسباتی کارایی بیشتری دارند و برای موقعیت‌های انتخاب ویژگی با ابعاد بالا مناسب هستند، از این رو در سال‌های اخیر بیشتر مورد توجه قرار گرفته‌اند [۱۵].

(ت) روش ترکیبی: معمولاً دو یا چند الگوریتم انتخاب ویژگی از استراتژی جستجوی مختلف را به صورت متوالی ترکیب می‌کند. به عنوان مثال، یک الگوریتم محاسباتی با هزینهٔ کم، مانند فیلتر ممکن است ابتدا برای حذف برخی ویژگی‌ها اعمال شود و بعداً از یک الگوریتم پیچیده‌تر و پرهزینه‌تر (مانند بسته‌بند) برای تنظیم دقیق استفاده شود. روش ترکیبی یک رویکرد جدید است که سعی می‌کند مزایای هر دو تکنیک فیلتر و بسته‌بند را جستجو کند. رویکردهای ترکیبی برای داده‌های با ابعاد بالا (مانند مجموعه داده ریزآرایه[1]) مناسب هستند تا پیچیدگی زمانی انتخاب ویژگی‌های مرتبط از مجموعه داده را کاهش دهند. مفهوم پشت رویکرد ترکیبی این است که رویکرد فیلتر برای حذف ویژگی‌های نامربوط (کاهش ابعاد) از مجموعه داده اصلی استفاده می‌شود و هدف آن دستیابی به یک مبادله بین پیچیدگی زمانی و اندازه فضای ویژگی است. سپس، روش بسته‌بند برای یافتن بهترین زیرمجموعه ویژگی‌ها از مجموعه ویژگی‌های انتخاب شده استفاده می‌شود. این رویکرد، انتخاب ویژگی را سرعت می‌بخشد زیرا روش فیلتر به سرعت، ویژگی‌های نامربوط از مجموعه داده را کاهش می‌دهد [۹].

۲.۲. منطق فازی و خوشه‌بندی C-میانگین فازی (FCM). منطق به مطالعهٔ مفهوم‌های نتایج منطقی می‌پردازد و با گزاره‌ها و رابطهٔ نتیجه منطقی بین آن‌ها سروکار دارد. فازی بودن به معنی ابهام است یعنی یک گزارهٔ فازی دارای درجه‌ای از درستی است. منطق فازی به عنوان منطق مفاهیم مبهم است. در منطق فازی به معنای وسیع، مفاهیم مبهم و نادقیق را به وسیلهٔ زیرمجموعه‌های فازی مدل‌سازی کرده و با استفاده از جبر مجموعه‌های فازی، قواعد استنتاج فازی را مشخص نموده و با آن‌ها استدلال انجام می‌شود. در منطق فازی به معنای محدود، گزاره‌ها دارای درجه درستی در مجموعه‌های مناسب هستند و استدلال باتوجه به این ارزش‌ها در چارچوب جبرهای خاص صورت می‌گیرد [۱].

خوشه‌بندی داده‌ها در زمینه تحقیقاتی داده‌کاوی، در بسیاری از حوزه‌های تحقیقاتی از جمله بیوانفورماتیک، الگوکاوی[2]، تشخیص الگو، شبکه‌های حسگر، کمیت‌سازی بردار[3] و وب‌کاوی فازی کاربرد دارد. خوشه‌بندی برای تخصیص اشیاء داده بدون برچسب به گروه‌های معقول بر اساس معیارهای شباهت برای به حداقل رساندن فواصل درون خوشه‌ای و به حداکثر رساندن فواصل بین خوشه‌ای استفاده می‌شود. با الهام از نظریه مجموعه‌های فازی، مسئله خوشه‌بندی را می‌توان به دسته‌های خوشه‌بندی سخت و خوشه‌بندی نرم تقسیم کرد. در خوشه‌بندی سخت، اشیاء داده دقیقاً به یک خوشه اختصاص

[1] Microarray
[2] Pattern mining
[3] Vector quantization

داده می‌شوند، درحالی‌که اشیاء داده می‌توانند با توجه به تابع عضویت به خوشه‌های مختلف تعلق داشته باشند. تابع عضویت در خوشه‌های فازی به شباهت اشیاء داده و مراکز خوشه بستگی دارد [۲۵].

روش خوشه‌بندی C-میانگین فازی (FCM) که توسط دان[1] [۷] توسعه یافته و توسط بزدک[2] [۶] بهبود یافته است، داده‌ها می‌توانند باتوجه به اختصاص درجه‌ای از عضویت به هر داده، به بیش از یک خوشه تعلق داشته باشد. الگوریتم C-میانگین فازی از گرادیان نزولی برای یافتن راه‌حل بهینه در فضای جستجو استفاده می‌کند. در نتیجه، این احتمال وجود دارد که این الگوریتم در حداقل‌های محلی گیر بیافتد. سرعتی که الگوریتم در آن همگرا می‌شود، به مقدار زیادی به مقدار اولیه مراکز خوشه بستگی دارد، به خصوص زمانی که تعداد زیادی خوشه وجود داشته باشد [۱۸]. الگوریتم FCM یک رویکرد بهینه‌سازی تکراری است و هدف آن به حداقل رساندن تابع هدف است [۲۵].

۳.۲. الگوریتم بهینه‌سازی نهنگ (WOA). الگوریتم بهینه‌سازی نهنگ یکی از جدیدترین الگوریتم‌های فراابتکاری به‌شمار می‌رود که در سال ۲۰۱۶ میلادی توسط سید علی میرجلیلی [۱۹] ارائه شده است. این الگوریتم، یک الگوریتم مبتنی بر جمعیت تصادفی است که روش شکار و تغذیه حباب تور نهنگ‌های گوژپشت را هنگام شکار طعمهٔ خود، شبیه‌سازی می‌کند. اندازهٔ یک نهنگ گوژپشتِ بالغ، تقریباً به اندازهٔ یک اتوبوس مدرسه است، آن‌ها طعمهٔ مورد علاقهٔ خود را که کریل[3] و دسته‌های ماهی‌های کوچک هستند، ترجیحاً نزدیک به سطح آب شکار می‌کنند؛ این جستجوی غذا، با ایجاد حباب‌های متمایز در امتداد یک مسیر مارپیچ دایره‌ای یا به شکل‌ب9ا انجام می‌شود. همچنین این نهنگ‌ها به دو صورت، مارپیچ رو به بالا[4] و یا حلقه‌های دوگانه جباب ایجاد می‌کنند. در روش مارپیچ رو به بالا نهنگ‌های گوژپشت به اطراف شیرجه می‌زنند، ۱۲ متر به پائین می‌روند و سپس شروع به ایجاد حباب به شکل مارپیچ در اطراف طعمه کرده و به سمت سطح آب شنا می‌کنند. روش حلقه‌های دوگانه شامل سه مرحلهٔ حلقه مرجانی[5]، لوب‌تیل[6] و حلقه گرفتن[7] است.

الگوریتم نهنگ از سه مرحله تشکیل شده است:

---

[1] Dunn
[2] Bezdek
[3] Krill
[4] Upward-spirals
[5] Coral loop
[6] Lobtail
[7] Capture loop

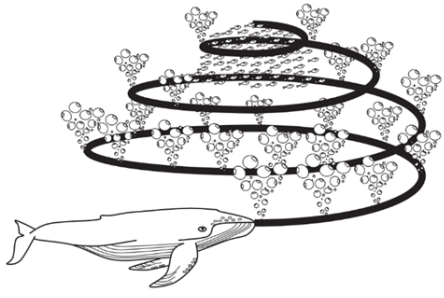

شکل ۱: رفتار تغذیه حباب‌دار نهنگ‌های گوژپشت [۱۹].

۱.۳.۲. احاطه‌کردن طعمه. نهنگ‌های گوژپشت می‌توانند محل طعمه را تشخیص دهند و آن‌ها را محاصره کنند. از آنجایی که موقعیت طراحی بهینه در فضای جستجو از قبل مشخص نیست، الگوریتم بهینه‌سازی نهنگ بهترین راه‌حل کاندید فعلی را به‌عنوان بهترین راه‌حل به‌دست آمده و نزدیک به راه‌حل بهینه در نظر می‌گیرد. بعد از اینکه بهترین عامل جستجو شناسایی شد، سایر عوامل جستجو سعی می‌کنند موقعیت خود را نسبت به بهترین عامل جستجو به‌روز کنند. این رفتار با معادله زیر نشان داده می‌شود [۱۹]:

$$\vec{X}_{(t+1)} = \vec{X}^*_{(t)} - \vec{A}.\vec{D} \qquad (۱.۲)$$

که در آن t تکرار فعلی، $\vec{X}$ بردار موقعیت، $\vec{X}^*$ بردار موقعیت بهترین راه‌حلی است که تاکنون به دست آمده، $\vec{A}$ بردار ضرایب است که از رابطهٔ $\vec{A} = 2\vec{a}.\vec{r} - \vec{a}$ بدست می‌آید؛ در این رابطه، $\cdot$ یک ضرب عنصر به عنصر است؛ و $\vec{a}$ به طور خطی از دو به صفر در طول تکرارها درون هر دومرحلهٔ اکتشاف و بهره‌برداری کاهش می‌یابد و از رابطهٔ $\vec{a} = 2 - t * \frac{2}{maxiter}$ بدست می‌آید؛ که t عدد تکرار و $maxiter$ حداکثر تعداد تکرار است. همچنین $\vec{D}$ از رابطهٔ $\vec{D} = |\vec{C}.\vec{X}^*_{(t)} - \vec{X}_{(t)}|$ بدست می‌آید؛ که در این رابطه، $\vec{C}$ بردار ضرایب است و از $\vec{C} = 2.\vec{r}$ حاصل می‌شود. $||$ قدرمطلق است. $\vec{r}$ در هر دو رابطهٔ $\vec{C}$ و $\vec{A}$، یک بردار دلخواه یا همان تصادفی در بازهٔ [۱و۰] است. باید به این نکته توجه داشت که در صورت وجود راه‌حل بهتر، $\vec{X}^*$ باید در هر تکرار به‌روز شود.

۲.۳.۲. مرحلهٔ استخراج یا بهره‌برداری: روش حمله حباب تور. برای مدل‌سازی ریاضی رفتار حباب تور نهنگ‌های گوژپشت، دو رویکرد زیر طراحی شده است:

(۱) مکانیسم احاطه کوچک‌شدن یا محاصرهٔ انقباضی[1]

این رفتار با کاهش مقدار $\vec{a}$ در معادلهٔ $\vec{A} = ۲\vec{a}.\vec{r} - \vec{a}$ حاصل می‌شود؛ و دامنهٔ نوسان $\vec{A}$ نیز با $\vec{a}$ کاهش می‌یابد. در واقع $\vec{A}$ یک مقدار تصادفی در بازهٔ $[-a, a]$ است؛ که در آن a در طول تکرارها از ۲ به ۰ کاهش می‌یابد. با تنظیم مقادیر تصادفی برای $\vec{A}$ در [۱و۱-]، موقعیت جدید یک عامل جستجو را می‌توان در هر جایی بین موقعیت اصلی عامل و موقعیت بهترین عامل فعلی تعریف کرد.

(۲) به‌روزرسانی موقعیت مارپیچی[2]

این رویکرد ابتدا فاصله بین نهنگ و طعمه را محاسبه می‌کند. سپس یک معادلهٔ مارپیچی بین موقعیت نهنگ و طعمه ایجاد می‌شود تا حرکت مارپیچ شکل نهنگ‌های گوژپشت را به صورت زیر تقلید کند [۱۹]:

$$\vec{X}_{(t+۱)} = \vec{D}'.e^{bl}.cos(۲\pi l) + \vec{X}^*_{(t)} \qquad (۲.۲)$$

که درآن $\vec{D}' = |\vec{X}^*_{(t)} - \vec{X}_{(t)}|$ فاصلهٔ نهنگ تا طعمه (بهترین راه حلی که تاکنون به دست آمده است) را نشان می‌دهد. b ثابتی برای تعریف شکل مارپیچ لگاریتمی است، l یک عدد تصادفی در [۱و۱-] و ۰ یک ضرب عنصر به عنصر است. نهنگ‌های گوژپشت به طور همزمان در یک دایرهٔ کوچک و در امتداد یک مسیر مارپیچی شکل در اطراف طعمه شنا می‌کنند. برای مدل‌سازی این همزمانی رفتار، فرض می‌شود که احتمال ۵۰% برای انتخاب بین مکانیسم احاطه کوچک‌شدن یا مدل مارپیچی برای به‌روزرسانی موقعیت نهنگ‌ها در طول بهینه‌سازی وجود دارد؛ مدل ریاضی به شرح زیر است [۱۹]:

که در آن p یک عدد تصادفی در [۱و۰] است.

$$\vec{X}_{(t+۱)} = \begin{cases} \vec{X}^*_{(t)} - \vec{A} \cdot \vec{D} & if p < ۰/۵ \\ \vec{D}' \cdot e^{bl} \cdot \cos(۲\pi l) + \vec{X}^*_{(t)} & if p \geq ۰/۵ \end{cases} \qquad (۳.۲)$$

۳.۳.۲. مرحلهٔ اکتشاف: جستجوی طعمه. نهنگ‌های گوژپشت به طور تصادفی بر اساس موقعیت یکدیگر، به جستجوی طعمه می‌پردازند. از همین رویکرد مبتنی بر تغییر بردار $\vec{A}$ می‌توان برای جستجوی طعمه (اکتشاف) استفاده کرد. بنابراین، از $\vec{A}$ با مقادیر تصادفی بزرگتر از ۱ یا کمتر از ۱- استفاده می‌شود تا عامل جستجو مجبور به دور شدن از یک نهنگ مرجع شود. برخلاف مرحلهٔ

[1] Shrinking encircling mechanism
[2] Spiral updating position

بهره‌برداری، موقعیت یک عامل جستجو در مرحلهٔ اکتشاف با توجه به یک عامل جستجوی انتخاب شده به طور تصادفی به جای بهترین عامل جستجوی یافت‌شده تاکنون به‌روز می‌شود. این مکانیسم و $|\vec{A}| > ۱$ بر اکتشاف تاکید می‌کند و به الگوریتم WOA اجازه می‌دهد تا یک جستجوی جهانی را انجام دهد. مدل ریاضی به صورت زیر است [۱۹]:

$$\vec{X}_{(t+۱)} = \vec{X}_{rand} - \vec{A}.\vec{D} \qquad (۴.۲)$$

در این رابطه، $\vec{X}_{rand}$ یک بردار موقعیت تصادفی (یک نهنگ تصادفی) است؛ که از جمعیت فعلی انتخاب شده است.

الگوریتم بهینه‌سازی نهنگ با مجموعه‌ای از راه‌حل‌های تصادفی شروع می‌شود. در هر تکرار، عوامل جستجو موقعیت‌های خود را با توجه به یک عامل جستجوی تصادفی انتخاب شده یا بهترین راه‌حل به دست آمده تا کنون به‌روز می‌کنند. پارامتر a به ترتیب از ۲ به ۰ کاهش می‌یابد تا اکتشاف و بهره‌برداری فراهم شود. یک عامل جستجوی تصادفی، زمانی که $|\vec{A}| > ۱$ باشد، انتخاب می‌شود؛ در حالی که بهترین راه‌حل زمانی که $|\vec{A}| < ۱$ باشد، برای به‌روزرسانی موقعیت عوامل جستجو انتخاب می‌شود. بسته به مقدار p، WOA قادر است بین یک حرکت مارپیچی یا دایره‌ای جابه‌جا شود. در نهایت، الگوریتم WOA با ارضای یک معیار خاتمه خاتمه می‌یابد.

۳. کارهای مرتبط

در این بخش، تعدادی از روش‌های مبتنی بر الگوریتم بهینه‌سازی نهنگ مورد بررسی قرار گرفته است. شمای کلی از کارهای مرتبط در شکل ۲ نشان داده شده است.

- آگراوال[1] و همکارانش [۲] با استفاده از ترکیب‌کردن مفاهیم کوانتومی و الگوریتم بهینه‌سازی نهنگ (WOA)، الگوریتمی به نام بهینه‌سازی نهنگ کوانتومی (QWOA)[2] برای انتخاب ویژگی ارائه کردند. این روش قدرت اکتشاف و بهره‌برداری الگوریتم بهینه‌سازی نهنگ کلاسیک را با استفاده از نمایش بیت کوانتومی جمعیت[3] و عملگرهای دروازه چرخش کوانتومی[4] به عنوان عملگرهای تغییر[5]، افزایش می‌دهد. عملگرهای اصلاح شده جهش و برش برای اکتشاف کوانتومی، کوچک‌شدن و حرکت مارپیچی نهنگ‌ها در QWOA معرفی شده‌اند که نمایش کوانتومی موقعیت نهنگ شانس

[1] Agrawal
[2] Quantum Whale Optimization Algorithm (QWOA)
[3] Population quantum bit representation
[4] Quantum rotation gate operators
[5] Switching operator

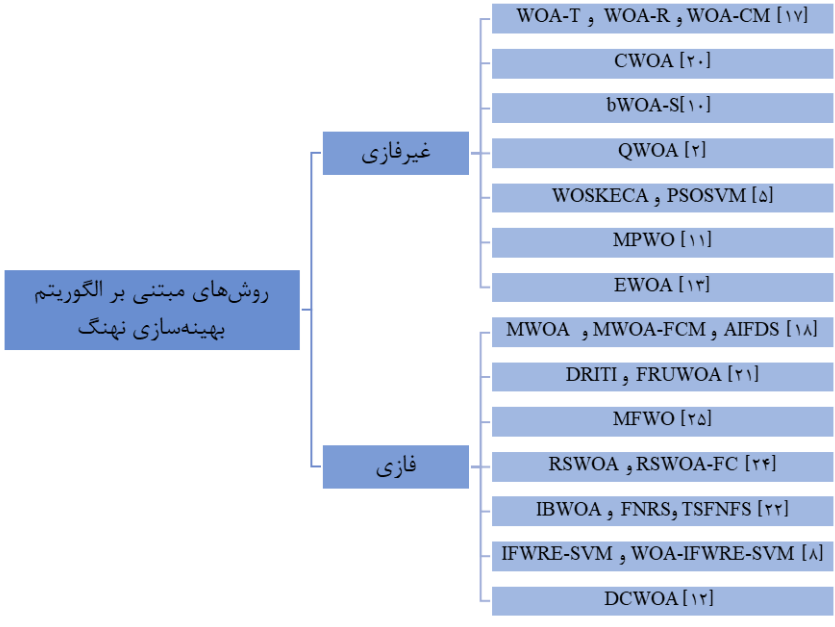

شکل ۲: دسته‌بندی روش‌های مورد بحث مبتنی بر الگوریتم بهینه‌سازی نهنگ.

بیشتری را برای تنوع جمعیت تسریع می‌کند و بنابراین اکتشاف بهتر را حتّی با اندازه جمعیت کوچک‌تر فراهم می‌کند.

با کاهش مجموعه ورودی ویژگی، خوشه‌بندی قبل از QWOA توسعه یک سیستم تصمیم‌گیری با عملکرد بالا را برای مجموعه داده‌های با ابعاد بالا تسهیل می‌کند. عملکرد بهتر روش‌های کوانتومی در مقایسه با نسخه‌های کلاسیک آن‌ها را می‌توان به نمایش بهتر جمعیت از نظر q-بیت‌ها و بهبود اکتشاف و بهره‌برداری به دلیل عملگرهای مشارکتی نسبت داد. نتایج اولیه و نهایی با بررسی AUC، مقدار شایستگی، دقت طبقه‌بندی و میانگین تعداد ویژگی‌های انتخاب شده نشان می‌دهد که روش QWOA بهتر از هشت الگوریتم فراابتکاری معروف، و همچنین الگوریتم ژنتیک کوانتومی (QGA)[1] و الگوریتم بهینه‌سازی ازدحام ذرات کوانتومی (QPSO)[2] بهتر از معادل‌های کلاسیک خود به ترتیب الگوریتم ژنتیک (GA) و الگوریتم بهینه‌سازی ازدحام ذرات (PSO) هستند.

[1] Quantum Genetic Algorithm (QGA)
[2] Quantum Particle Swarm Optimization (QPSO)

- بای[1] و همکارانش [۵] الگوریتمی مبتنی بر آنالیز مؤلفه‌های آنتروپی هسته نظارتی با الگوریتم بهینه‌سازی نهنگ (WOSKECA)[2] برای انتخاب ویژگی ارائه کردند. در اولین قدم، یک ماتریس ویژگی با ابعاد بالا بر اساس ماشین‌های دوّار و حوزه آنتروپی برای اطمینان از جمع‌آوری اطلاعات کافی ساخته می‌شود. در قدم دوم، هرگونه اطلاعات اضافی با استفاده از WOSKECA برای انتخاب ویژگی حذف می‌شوند. سپس، آنتروپی هسته به ترتیب نزولی مرتب می‌شود. با استفاده از اطلاعات کلاس به عنوان اطلاعات نظارت شده در تجزیه و تحلیل مؤلفه‌های آنتروپی هسته (KECA)[3]، ویژگی‌های کم بعد با قابلیت تشخیص را می‌توان از فضای ویژگی‌های با ابعاد بالا استخراج کرد. پارامتر هسته بهینه توسط PSO، GA و WOA به دست می‌آید به‌طوری‌که زمان اجرای بهینه‌سازی PSO و GA بیشتر از WOA است. همچنین مشاهده می‌شود که برای پارامترهای هسته یکسان، دقت تشخیص برای روش KECA باناظر (SKECA)[4] بالاتر است. بنابراین، انتخاب WOA برای بهینه‌سازی پارامتر هسته و استفاده از روش SKECA برای تشخیص الگو بسیار سودمند است. به عنوان آخرین مرحله، ماشین بردار پشتیبان مبتنی بر بهینه‌سازی ازدحام ذرات (PSOSVM)[5] برای طبقه‌بندی خودکار نوع خطا و همچنین ارزیابی شدت خطاها اعمال می‌شود. ارزیابی‌های تجربی و مقایسه‌ای بر روی الگوریتم استخراج ویژگی انجام می‌شود. این روش نشان می‌دهد که موفق‌تر و دقیق‌تر از یادگیری چندگانه سنتی در تشخیص و طبقه‌بندی خطاهای ماشین‌های دوّار است.

در نهایت، برای مقایسه، الگوریتم‌های LDA[6]، KECA، LE[7]، LLE[8]، SKECA و WOSKECA برای حذف ویژگی‌های مازاد و بهبود نرخ شناسایی حالت استفاده می‌شوند. نرخ تشخیص همه ویژگی‌های کم‌بعد، بالاتر از مجموعه ویژگی‌های اصلی است، که نشان می‌دهد الگوریتم استخراج ویژگی به طور قابل توجهی می‌تواند ویژگی‌های مازاد در فضای با ابعاد بالا را حذف کند و نرخ تشخیص حالت را بهبود بخشد. الگوریتم LDA بیشتر اطلاعات متمایز را در نظر می‌گیرد، اما نتیجه جداسازی رضایت بخش نیست. پس از استفاده از الگوریتم KECA، راندمان تشخیص تا ۱۲/۴۷ درصد بهبود می‌یابد، عمدتاً به این دلیل که KECA اطلاعات آنتروپی مجموعه داده‌های اصلی با ابعاد بالا را در فرآیند استخراج ویژگی در نظر می‌گیرد و حداقل از دست دادن آنتروپی را در فرآیند کاهش ابعاد تضمین می‌کند. کاهش روش‌های کلی یادگیری چندگانه، مانند LE و LLE، نمی‌توانند

[1] Bai
[2] Supervision Kernel Entropy Component Analysis with Whale Optimization Algorithm (WOSKECA)
[3] Kernel Entropy Component Analysis (KECA)
[4] Supervised KECA (SKECA)
[5] Support Vector Machine based on the Particle Swarm Optimization (PSOSVM)
[6] Linear Discriminant Analysis (LDA)
[7] Laplacian Eigenmaps (LE)
[8] Locally Linear Embedding (LLE)

تمام مشخصات سیگنال را شناسایی کنند.
الگوریتم SKECA الگوریتمی است که فقط اطلاعات کلاس را ادغام می‌کند و با بهینه‌سازی الگوریتم بهترین پارامترهای هسته را پیدا نمی‌کند و پارامتر هسته با اتخاذ معیار فیشر[1] به عنوان تابع شایستگی آن به دست می‌آید. الگوریتم WOSKECA از اطلاعات دسته‌ها استفاده می‌کند و از الگوریتم WOA برای جستجوی پارامترهای هسته بهینه استفاده می‌کند، بنابراین بالاترین نرخ تشخیص حالت را به دست می‌آورد که ثابت می‌کند تشخیص وضعیت چرخ‌دنده بسیار سودمند است.

- فَن[2] و گو[3] [۸]، یک رویکرد وزن فازی جدید برای بهبود پیش‌بینی چربی بدن با استفاده از اندازه‌گیری‌های بدنی که به راحتی قابل دسترسی هستند به شیوه‌ای مقرون‌به‌صرفه به نام WOA-IFWRE-SVM را ارائه کردند که ماشین بردار پشتیبان خطای نسبی با وزن فازی پیشرفته (IFW-RE-SVM)[4] توسط الگوریتم بهینه‌سازی نهنگ (WOA) بهینه‌سازی شده است. ارائه‌دهندگان این رویکرد، با توجه به مشکل داده‌های نویز، عملیات وزن‌دار فازی جدید را با گسترش مقادیر حداقل و حداکثر برای محاسبه وزن‌های فازی برای پوشش احتمالات بیشتر طراحی کردند. وزن‌های فازی در مدل ماشین بردار پشتیبان خطای نسبی گنجانده شدند تا استحکام آن در برابر داده‌های نویز را بهبود بخشد. علاوه بر این، برای بهبود بیشتر دقت پیش‌بینی، از الگوریتم بهینه‌سازی نهنگ برای بهینه‌سازی فراپارامترهای IFW-RE-SVM، یعنی پارامتر پنالتی و پهنای باند هسته گوسین[5] استفاده شد.
عملیات وزن فازی که در این روش استفاده شد با عملیات مورد استفاده در FW-RE-SVM و FWGK-FW-RE-SVM متفاوت بود. با افزایش ابعاد ورودی، FW-RE-SVM و FWGK-FW-RE-SVM با استفاده از تابع محصول دارای مشکل پراکندگی وزن بودند در حالی که در رویکرد پیشنهادی، وزن‌های فازی با مجموع و توابع نمایی محاسبه شدند. رویکرد فازی وزن پیشنهادی با پیشی گرفتن از سایر مدل‌های معروف یادگیری ماشین، نتایج عالی را برای پیش‌بینی چربی بدن ارائه داد. علاوه بر این، آزمون آماری بر اساس ۲۰ بار اجرای آزمایش‌ها نه تنها تأیید کرد که رویکرد ارائه شده می‌تواند به طور قابل توجهی بهتر از مدل‌های تحت مقایسه عمل کند، بلکه عملکرد وزن فازی و WOA را برای بهبود رویکرد پیشنهادی مؤثر نشان داد. این یک جایگزین مناسب برای

[1] Fisher criterion
[2] Fan
[3] Gou
[4] Improve Fuzzy-Weighted Relative Error Support Vector Machine (IFW-RE-SVM)
[5] Gaussian kernel bandwidth

پزشکان به‌منظور تشخیص زودهنگام و درمان زودهنگام بیماری‌های مرتبط با چربی بدن در زمانی که روش‌های اندازه‌گیری که عموماً پرهزینه هم هستند در دسترس نیست، ارائه می‌دهد.

- حسین[1] و همکارانش [۱۰]، به منظور حل مشکل انتخاب ویژگی، bWOA-S[2] را که یک نسخه باینری جدید از الگوریتم بهینه‌سازی نهنگ است، با اعمال یک تابع انتقال S شکل تبدیل WOA به نسخه باینری انجام می‌شود را ارائه کردند. در الگوریتم بهینه‌سازی نهنگ اولیه، نهنگ‌ها در فضای جستجو حرکت می‌کنند تا موقعیت خود را در هر نقطه‌ای از فضا تغییر دهند که به این فضای جستجو، فضای پیوسته می‌گویند. با توجه به ماهیت مسائل انتخاب ویژگی، راه‌حل‌ها به مقادیر فضای باینری {۰, ۱} محدود می‌شوند. برای حل مشکل انتخاب ویژگی، پیوسته (هر موقعیت) باید به راه‌حل‌های باینری متناظر {۰, ۱} تبدیل شود. احتمال تبدیل موقعیت بردارهای عناصر از ۰ به ۱ و بالعکس توسط توابع انتقال صورت گرفته و از این رو عوامل جستجو را مجبور می‌کند در یک فضای باینری جابه‌جا شوند.

برای کاهش ویژگی، N تعداد ترکیب ویژگی‌های مختلف ۲N خواهد بود که فضای بزرگی از ویژگی‌هاست و باید به طور کامل جستجو شود. بنابراین bWOA-S، رویکردی جدید بر اساس تابع سیگموئید است که برای تطبیق فضای جستجو اعمال می‌شود و بهترین ترکیب ویژگی را ارائه می‌کند. بهترین ترکیب ویژگی به طور خاص، و همچنین حداکثر دقت طبقه‌بندی با حداقل تعداد ویژگی‌های انتخاب‌شده به دست می‌آید. برروی مجموعه داده‌های مختلف، الگوریتم K نزدیک‌ترین همسایه (K-NN)[3] با استفاده از روش آزمایش و خطا اعمال می‌شود و بهترین انتخاب K=۵ است. در همین حال، هر موقعیت نهنگ از طریق فرآیند آموزش، یک زیرمجموعه ویژگی را تولید می‌کند. مجموعه آموزش برای ارزیابی عملکرد طبقه‌بندی‌کننده (K-NN) بر روی زیرمجموعه اعتبارسنجی در سراسر فرآیند بهینه‌سازی استفاده می‌شود و bWOA-S برای هدایت فرآیند انتخاب ویژگی به طور همزمان استفاده می‌شود.

- جَدهاو[4] و بورکار[5] [۱۱] به حفاظت از حریم خصوصی داده‌های حساس از طریق یک رویکرد جدید پاکسازی داده‌ها[6] با تمرکز بر تولید کلید بهینه برای رفع چالش‌های مدیریت کلان داده با توجه

---

[1] Hussien
[2] binary Whale Optimization Algorithm S-shaped (bWOA-S)
[3] K-Nearest Neighbor Algorithm (K-NN)
[4] Jadhav
[5] Borkar
[6] Data sanitization

به اندازه و پیچیدگی کلان داده، با کاهش ریسک و حفظ حریم خصوصی بالا پرداخته‌اند. پاکسازی داده‌ها به فرآیند تمیز کردن، اصلاح یا حذف اطلاعات حساس از مجموعه داده‌ها برای محافظت از حریم خصوصی و ناشناس بودن افراد مرتبط با آن داده‌ها اشاره دارد. این شامل حذف یا رمزگذاری اطلاعات قابل شناسایی شخصی از مجموعه داده‌ها برای محافظت از ناشناس بودن افراد در هنگام توصیف داده‌ها است. هدف اصلی جلوگیری از قرار گرفتن در معرض ناخواسته اطلاعات قابل شناسایی شخصی (PII)[۱] هنگام به اشتراک‌گذاری یا توزیع مجموعه داده‌ها است. این فرآیند تضمین می‌کند که جزئیات حساس مانند نام‌ها، آدرس‌ها و سایر اطلاعات قابل شناسایی، حذف یا رمزگذاری شده‌اند و ردیابی داده‌ها به افراد خاص را برای افراد غیرمجاز دشوار می‌کند.

مدل پیشنهادی با شناسایی داده‌ها به عنوان حساس و غیرحساس به این صورت عمل می‌کند که داده‌های حساس در ابتدا توسط شبه شناسه‌ها شناسایی می‌شوند و داده‌های حساس شناسایی شده با تولید یک کلید بهینه با استفاده از الگوریتم پیشنهادی بهینه‌سازی شکارچی دریایی نهنگ (MPWO)[۲] حفظ می‌شوند. برای انتخاب بهترین کلید برای پاکسازی داده‌ها، از الگوریتم MPWO استفاده شد. کلید بهینه برای اصلاح خوشه‌های داده استفاده می‌شود و پس از اطمینان از حفظ حریم خصوصی داده‌ها، داده‌ها در فضای ابری منتشر می‌شوند. الگوریتم پیشنهادی دنیای طبیعی را با قلمرو دیجیتال ادغام می‌کند و با ترکیبی از ویژگی‌های رفتارهای جستجوی غذای شکارچیان دریایی[۳] توسعه داده می‌شود و نهنگ‌ها برای تعیین کلید بهینه با آن پیوند داده می‌شوند. کلید بهینه تولید شده با استفاده از الگوریتم MPWO به طور مؤثر حریم خصوصی داده‌ها را حفظ می‌کند. کارایی روش با اندازه‌گیری مقادیر معیار اندازه کلاس معادل میانگین (CAVG)[۴]، قابل تشخیص (DM)[۵] و جریمه قطعی نرمال شده (NCP)[۶] برای حمله افشای ویژگی[۷]، حمله افشای هویت[۸] و بدون هیچ حمله‌ای بدست آمد.

- جادون[۹] و همکارانش [۱۲] الگوریتم بهینه‌سازی نهنگ کنترل‌شدهٔ پویا (DCWOA)[۱۰] را برای حل مسئله چندهدفه توزیع انتشار اقتصادی ترکیبی حرارت و نیرو (MO-CHPEED)[۱۱] غیرمحدب

[1] Personally Identifiable Information (PII)
[2] Marine Predator Whale Optimization (MPWO)
[3] Marine predators
[4] Average equivalent class size metric (CAVG)
[5] Discernibility Metric (DM)
[6] Normalized Certainty Penalty (NCP)
[7] Attribute disclosure attack
[8] Identity disclosure attack
[9] Jadoun
[10] Dynamically Controlled Whale Optimization Algorithm (DCWOA)
[11] Multi-Objective Combined Heat and Power Economic Emission Dispatch (MO-CHPEED)

در محیط فازی ارائه کردند. در این محیط، شایستگی هر روش بر اساس بهترین راه‌حل‌های بهینه آن‌ها محاسبه شد. DCWOA پیشنهادی یک نوع بهبودیافته و برای تنظیم دقیق عملکرد روش WOA با افزودن تابع رکود[1] کنترل‌شده پویا بود، که در نظر داشت یک راه‌حل بهینه برای معمای زمان‌بندی انتشار اقتصادی سیستم‌های تولید همزمان ارائه دهد. مسئله زمان‌بندی انتشار اقتصادی چندهدفه واحدهای ترکیبی حرارت و نیرو یک مسئله ترکیبی غیرمحدب، غیرخطی و سخت محدود بود. این معما پیچیده شد زیرا با دو هدف متضاد هزینه سوخت و جرم آلاینده‌ها[2] سروکار داشت. گرایش هر دو اهداف متضاد اینگونه بود که اگر یک هدف به حداقل برسد، هدف دیگر به حداکثر می‌رسد. بنابراین لازم است بین هر دو هدف تعادل برقرار شود. برای متعادل کردن اهداف از یک چارچوب فازی استفاده شد که در آن وزن یکسانی به هر دو هدف داده می‌شود. از تابع عضویت فازی ذوزنقه‌ای برای بدست آوردن بهترین مصالحه بین هزینه سوخت و جرم آلاینده‌ها استفاده گردید. این تابع عضویت ذوزنقه‌ای با حداقل و حداکثر حد (بین ۰ و ۱) محدود می‌شود. ارزیابی اهداف هزینه و انتشار با استفاده از چارچوب فازی به عنوان یک هدف واحد، پایین ترین و بالاترین مقادیر مرزی برای هزینه و انتشار مورد نیاز است.

سه مرحله برای حل این مشکل چندهدفه در نظر گرفته شد: گام اول یافتن برنامه زمان‌بندی بهینه توزیع با در نظر گرفتن مسئله به عنوان یک مسئله توزیع اقتصادی تک هدفه بود. این منجر به دستیابی به برنامه زمانی برای حداقل هزینه سوخت می‌شود. با استفاده از این، مرز پایین هدف هزینه سوخت و مرز بالای جرم هدف انتشار به دست آمد. گام دوم، یافتن برنامه زمان‌بندی بهینه توزیع با در نظر گرفتن مشکل به عنوان یک مسئله توزیع انتشار تک هدفی بود. این نتایج برای برنامه زمانی به حداقل رساندن جرم آلاینده سیستم بدست آمده است. با استفاده از این، مرز پایین جرم هدف آلاینده و مرز بالایی هدف هزینه سوخت بدست آمد. مرحله سوم و آخرین مرحله، شامل استفاده از این مقادیر مرزی هزینه سوخت و جرم اهداف آلاینده برای یافتن راه‌حل به خطر افتاده برای مشکل CHPEED چندهدفه بود. DCWOA پیشنهادی، با پایه WOA، بر روی سه مطالعه موردی مختلف آزمایش شد. محدودیت‌های در نظر گرفته شده در این کار محدود به محدودیت‌های نیرو، حداقل و حداکثر محدودیت ژنراتورهای الکتریکی، واحدهای ترکیبی حرارت و نیرو و واحدهای مولد حرارت است. نتایج کارایی روش DCWOA پیشنهادی به وسیلهٔ مقایسهٔ با FDO، DA، SSA و WOA استاندارد نشان دادند.

---

[1] Constriction function

[2] Emissions

- جیوتی[1] و همکارانش [۱۳] یک مدل تشخیص حمله مبتنی بر یادگیری ماشین با پشتیبانی بهینه‌سازی با یک مکانیسم احراز هویت مبتنی بر خوشه ترکیب کردند. در فرآیندهای تشخیص حمله و خوشه‌بندی هر دو از ایده بهینه‌سازی استفاده شد. رویکرد بهینه‌سازی جدید به نام الگوریتم بهینه‌سازی نهنگ پیشرفته (EWOA)[2] برای آموزش شبکه عصبی قرار داده شد. یکی از انواع حملات سایبری که به عنوان « پرکردن اعتبارنامه[3]» شناخته می‌شود، شامل استفاده از نام‌های کاربری و رمزهای عبور قبلی توسط مهاجمان برای دسترسی به حساب‌های کاربری در چندین وب‌سایت بدون مجوز است. این امکان پذیر است زیرا بسیاری از افراد از رمز عبور و نام کاربری مشابه در چندین وب سایت مختلف استفاده می‌کنند. حفظ امنیت حساب‌های برخط مستلزم دفاع در برابر حملات پرکردن اعتبارنامه است. مدل پیشنهادی EWOA-ANN توانست مشکلات مربوط به حملات پرکردن اعتبارنامه، تشخیص شکست[4] و پیش‌بینی را برطرف و مدیریت کند. با استفاده از این مدل جدید بهینه‌سازی نهنگ پیشرفته، سرخوشه‌ها (CH)[5] از بین گره‌ها انتخاب شدند. مکانیزم تشخیص حمله برای ارتباطات شبکه قابل اعتماد[6] و بدون تغییر[7] پیشنهاد شد. علاوه بر این، چهار معیار در هنگام تصمیم‌گیری در نظر گرفته شد: ”فاصله، جریمه، انرژی و تأخیر”. گره‌ای که بیشترین انرژی، کمترین فاصله، جریمه و تأخیر را دارد، این شانس را داشت که به عنوان یک CH عمل کند. در واقع، خوشه‌ها بر اساس CH از نظر نزدیکی به CH و انرژی زیرآستانه CH تولید شدند. خوشه‌ها برای کاهش بار شبکه تشکیل گردیدند، اگر یک گره مهاجم در این فرآیند پیدا می‌شد، پیدا کردن یک گره در بین همه این گره‌ها مشکل بود. در عوض، با ایجاد خوشه‌ها و انتخاب سرخوشه‌ها، زمان محاسبه برای یافتن گره، کاهش یافت زیرا اطلاعات گره مهاجم به سرخوشه‌ها به اشتراک گذاشته می‌شد. هر دو ارتباط CH و گره‌ها ادامه یافت و بعد تشخیص حمله با شبکه عصبی انجام شد، اگر مهاجم در مرحله شناسایی پیدا می‌شد، تابع جریمه با مقدار ۱ اضافه می گردید، در غیر این صورت صفر بود. درنهایت کارآمدی مدل تشخیص حمله ارائه شده نشان داده شد و مقایسه با توجه به تجزیه و تحلیل امنیتی خاص تکمیل گردید.

- مفرجا[8] و میرجلیلی [۱۷] یک رویکرد انتخاب ویژگی بسته‌بند جدید براساس الگوریتم بهینه‌سازی

[1] Jyothi
[2] Enhanced Whale Optimization Algorithm (EWOA)
[3] Credential stuffing
[4] Failure detection
[5] Cluster Heads (CH)
[6] Reliable
[7] Unaffected
[8] Mafarja

نهنگ ارائه کردند. هدف این روش بررسی دو جنبه از الگوریتم WOA است. دو نوع باینری از الگوریتم WOA برای اولین بار در این مطالعه به منظور جستجوی زیرمجموعه‌های ویژگی بهینه که برای طبقه‌بندی استفاده شده‌اند، به‌کار گرفته می‌شود. ابتدا، دو رویکرد WOA-T[۱] و WOA-R[۲] پیشنهاد شده است که به ترتیب تأثیر به‌کارگیری روش‌های انتخاب تورنمنت و انتخاب چرخ رولت به جای انتخاب تصادفی بر عملکرد WOA اصلی مورد مطالعه قرار می‌گیرد. سپس از WOA با ترکیب عملگرهای برش و جهش (WOA-CM)[۳] برای افزایش بهره‌برداری استفاده می‌شود. سازوکارهای تطبیقی[۴] در الگوریتم WOA-CM سرعت همگرایی را متناسب با تعداد تکرارها تسریع، و همچنین اکتشاف و بهره‌برداری را به طور مؤثر متعادل می‌کنند. این موضوع باعث میشود تا اولاً از تعداد زیادی بهینهٔ محلی در مسائل انتخاب ویژگی جلوگیری، و ثانیاً تخمینی دقیق برای بهترین راه‌حل ارائه کنند. روش‌های ارائه شده بر روی مجموعه داده‌های معیار استاندارد، آزمایش شده و سپس با سه الگوریتم مانند بهینه‌سازی ازدحام ذرات (PSO)، الگوریتم ژنتیک (GA)، بهینه‌سازی شیرمورچه (ALO)[۵]، و پنج روش استاندارد انتخاب ویژگی فیلتر مقایسه می‌شوند.

- ماجحی[۶] [۱۸]، یک روش خوشه‌بندی فازی با استفاده از نقاط قوت هر دو الگوریتم بهینه‌سازی نهنگ اصلاح‌شده (MWOA)[۷] و FCM، به نام MWOA-FCM[۸] ارائه کرد. الگوریتم بهینه‌سازی نهنگ اصلاح‌شده (MWOA) برای بهینه‌سازی مرکزهای خوشه‌ای به‌دست‌آمده و از خوشه‌بندی C-میانگین فازی به عنوان یک روش نمونه‌گیری استفاده می‌شود. FCM یکی از محبوب‌ترین تکنیک‌های خوشه‌بندی است؛ با این حال، به راحتی در بهینه محلی گیر می‌کند. الگوریتم بهینه‌سازی نهنگ (WOA) یک الگوریتم بهینه‌سازی جهانی تصادفی است که برای یافتن بهینه جهانی مجموعه داده ارائه شده، استفاده می‌شود. WOA بیشتر برای دستیابی به بهینه جهانی بهتر اصلاح شده است. در مرحلهٔ اول، روش خوشه‌بندی ترکیبی پیشنهادی بر اساس MWOA به عنوان یک روش نمونه‌گیری کم[۹] از کلاس اکثریت[۱۰] با حذف داده‌های پرت از نمونه‌های کلاس اکثریت برای بهینه‌سازی مرکزهای خوشه‌ها به‌کار رفت؛ در مرحلهٔ دوم طبقه‌بندی‌کننده‌های پیشرفته باناظر اخیر مانند CATBoost،

[1] Whale Optimization Algorithm with Tournament selection
[2] Whale Optimization Algorithm with Roulette wheel selection
[3] Whale Optimization Algorithm with Crossover and Mutation operators (WOA-CM)
[4] Adaptive mechanisms
[5] Ant Lion Optimizer (ALO)
[6] Majhi
[7] Modified Whale Optimization Algorithm (MWOA)
[8] Fuzzy Clustering algorithm using Modified Whale Optimization Algorithm (MWOA-FCM)
[9] Under-sampling
[10] Majority class

XGBoost، LightGBM، درخت تصمیم (DT)[۱] و جنگل تصادفی (RF)[۲] در سیستم تشخیص تقلب بیمه خودرو پیشنهادی (AIFDS)[۳] برای افزایش اثربخشی طبقه‌بندی‌کننده‌ها بکار گرفته شدند. طبقه‌بندی‌کننده‌ها با اندازه‌گیری پارامترهای عملکردی مانند حساسیت، خاصیت و دقت ارزیابی می‌شوند. MWOA-FCM فاصله هر نقطه داده را از مراکز خوشه مربوطه محاسبه می‌کند که بر اساس آن کلاس‌های مشکوک شناسایی می‌شوند. از آزمون‌های آماری یعنی آزمون فریدمن[۴] و آزمون هلمز[۵] برای ارزیابی اهمیت آماری روش خوشه‌بندی فازی پیشنهادی با سایر الگوریتم‌های خوشه‌بندی استفاده شده است. AIFDS متشکل از خوشه‌بندی فازی بر اساس MWOA و CATBoost بهتر از سایر روش‌های مقایسه شده عمل کرد.

ـ سید[۶] و همکارانش [۲۰]، الگوریتم بهینه‌سازی جدیدی برای انتخاب ویژگی بر اساس نظریه آشوب[۷] و WOA ارائه کردند و آن را الگوریتم بهینه‌سازی نهنگ بی‌نظم (CWOA)[۸] نامیدند؛ که عملکرد بهتری نسبت به الگوریتم‌های کلاسیک مانند WOA برای انتخاب ویژگی نشان داد. بنابراین، WOA با ده نقشه بی‌نظم[۹] برای دستیابی به عملکرد بهبود یافته انتخاب ویژگی از ده مجموعه داده مختلف استفاده می‌شود. نقشه‌های بی‌نظم سازگار با WOA بهتر از WOA سنتی از نظر کیفیت راه‌حل و اجتناب از گیرافتادن در بهینه محلی و همچنین به دست آوردن همگرایی سریع‌تر عمل می‌کنند. این نقشه‌های بی‌نظم برای دستکاری مقادیر پارامترهای تصادفی WOA استفاده می‌شود. از آنجایی که مقادیر اولیه نقشه‌های بی‌نظم ممکن است تأثیرات قابل توجهی بر الگوی نوسان[۱۰] داشته باشند، نویسندگان نقطه اولیه همه نقشه‌های بی‌نظم را ۰/۷ تعیین کردند. این پارامترها بر اساس آزمون و خطا بهترین هستند.

الگوریتم انتخاب ویژگی CWOA با عوامل جستجوی اولیه تصادفی با مجموعه‌ای از راه‌حل‌ها که زیرمجموعه ویژگی‌ها هستند، شروع می‌شود. هر زیرمجموعه ویژگی دارای ترکیب متفاوتی از ویژگی‌ها با اندازه‌های مختلف است. در هر تکرار، هر عامل جستجو، موقعیت خود را بر اساس یک تابع شایستگی از پیش تعریف شده، به‌روز می‌کند. عملکرد طبقه‌بندی به عنوان تابع شایستگی استفاده

---

[1] Decision Tree (DT)
[2] Random Forest (RF)
[3] Automobile insurance fraud detection system (AIFDS)
[4] Friedman test
[5] Holms test
[6] Sayed
[7] Chaos theory
[8] Chaotic Whale Optimization Algorithm (CWOA)
[9] Chaotic map
[10] Fluctuation pattern

می‌شود که در آن K=۵ نزدیکترین همسایه طبقه‌بندی‌کننده استفاده شده است. بهترین زیرمجموعه ویژگی زیرمجموعه‌ای است که دقت طبقه‌بندی را به حداکثر می‌رساند و ویژگی‌های انتخاب شده را به حداقل می‌رساند. نتایج مطالعه تطبیقی نسخه‌های مختلف CWOA با نقشه‌های بی‌نظم مختلف نشان می‌دهد که نقشه دایره بهترین نقشه است. همچنین نتایج نشان داد که نسخه بی‌نظم WOA با اصلاح تمامی پارامترها قادر به بهبود عملکرد WOA به طور قابل توجهی نیست. در نهایت، CWOA از سایر الگوریتم‌های بهینه‌سازی مورد مقایسه، بهتر عمل می‌کند.

- شارمیلا[1] و ویجایارانی[2] [۲۱] الگوریتم کاهش ابعاد در تراکنش و آیتم‌ها (DRITI)[3] را با استفاده از دو روش جدول هش[4] و فیلتر واریانس پایین برای شناسایی و کاهش آیتم‌ها و تراکنش‌های نامربوط از پایگاه داده ارائه کردند که تعداد اسکن‌ها را برای شناسایی موارد نامربوط کاهش داد. در الگوریتم DRITI، ابتدا از دو روش استفاده شد؛ از روش تک‌اسکن برای شناسایی مجموعه آیتم‌های تکراری با یک اسکن استفاده شد. این روش از جدول هش برای شناسایی رویدادهای مجموعه آیتم‌ها در یک اسکن استفاده کرد. به منظور کاهش تعداد اسکن‌ها، از جدول هش برای شناسایی موارد نامربوط از پایگاه داده تراکنش استفاده شد. در مرحله دوم، از فیلتر واریانس پایین استفاده شد که در آن ستون داده با واریانس کمتر از مقدار آستانه حذف گردید.

نویسندگان، روشی به نام قوانین فازی با استفاده از الگوریتم بهینه‌سازی نهنگ (FRUWOA)[5] ارائه کردند و از این روش برای کشف آیتم‌های تکراری فازی[6] و تولید قوانین فازی مرتبط استفاده گردید. در اینجا آیتم‌ها بر اساس فرآورده‌ها دسته‌بندی شدند و مقادیر آستانه منحصربفرد[7] به هر آیتم در پایگاه‌داده تراکنش کاهش یافته اختصاص داده شد. آیتم‌ها با مقادیر آستانه یکسان بر اساس این رویکرد گروه‌بندی شدند و مجموعه آیتم‌ها و قوانین تکراری فازی تولید گردیدند. مقادیر آستانه فردی بر اساس دسته‌بندی آیتم، برای کشف آیتم‌های تکراری مهم تخصیص داده شدند. الگوریتم با تخصیص مقدار آستانه فردی، آیتم‌های مهم‌تر و آیتم‌های حساس را شناسایی کرد. کارایی این روش با الگوریتم ژنتیک، بهینه‌سازی ازدحام ذرات و Itemset-Miner تکراری فازی مقایسه شد

. - سان[8] و همکارانش [۲۲]، یک مدل انتخاب ویژگی دو مرحله‌ای مبتنی بر مدل‌های بهبودیافتهٔ

---

[1] Sharmila
[2] Vijayarani
[3] Dimensionality Reduction in Transaction and items (DRITI)
[4] Hash table
[5] Fuzzy Rules Using Whale Optimization Algorithm (FRUWOA)
[6] Fuzzy frequent items
[7] Individual threshold values
[8] Sun

مجموعه‌های تقریبی همسایگی فازی (FNRS)[۱] و الگوریتم بهینه‌سازی نهنگ باینری (BWOA)[۲] به نام TSFNFS[۳] طراحی کردند. ابتدا، برای نمایش فازی بودن نمونه‌ها برای داده‌های مختلط با ویژگی‌های نمادین و عددی، شباهت همسایگی فازی برای مطالعه ماتریس شباهت و درجه عضویت فازی ارائه شد و تقریب‌های پایین‌تر و بالاتر را توانست برای ارائه یک مدل جدید FNRS جهت مقابله با داده‌های با ابعاد بالا توسعه دهد. معیارهای عدم قطعیت مبتنی بر همسایگی فازی مانند درجه وابستگی، دانه‌بندی دانش[۴] و معیارهای آنتروپی مورد مطالعه قرارگرفتند. با ترکیب دیدگاه‌های جبر و اطلاعات، آنتروپی شرطی دانه‌بندی دانش فازی برای تشکیل و ارزیابی زیرمجموعه کاهش ویژگی از پیش انتخاب شده در مرحله اول ارائه شد. تغییر منحنی کسینوس برای ایجاد یک عامل کنترلی جدید اضافه شد، که نرخ همگرایی BWOA را در تکرار اولیه کاهش داد تا به طور کامل بهینهٔ جهانی را کشف کند، و نرخ همگرایی را در تکرار دیرهنگام تسریع کرد. ادغام درجه وابستگی با آنتروپی شرطی دانه‌بندی دانش فازی، یک تابع شایستگی جدید برای انتخاب یک زیرمجموعه ویژگی بهینه در مرحله دوم طراحی کرد.

دو استراتژی برای جلوگیری از سقوط BWOA در بهینه محلی ترکیب شدند: استراتژی تفکیک جمعیت با شعاع جستجوی همسایگی تطبیقی برای تقسیم جمعیت نهنگ و استراتژی تداخل[۵] محلی زیرگروه برگزیده برای تنظیم به‌روزرسانی موقعیت نهنگ. زیرگروه‌های برگزیده براساس استراتژی تفکیک جمعیت با همسایگی تطبیقی تقسیم شدند. به‌روزرسانی موقعیت نهنگ برای سرعت بخشیدن به همگرایی و افزایش دقت طبقه‌بندی زیرمجموعه ویژگی انتخاب شده تنظیم شد. در نهایت، یک الگوریتم انتخاب ویژگی دو مرحله‌ای طراحی گردید، که در آن الگوریتم امتیاز فیشر برای حذف اولیه آن ویژگی‌های زائد مجموعه داده‌های با ابعاد بالا استفاده شد.

- ویشنوی[۶] و همکارانش [۲۴] یک نوع جدید از روش بهینه‌سازی نهنگ، یعنی RSWOA[۷] برای تقسیم‌بندی خودکار هسته‌ها[۸] در تصاویر هیستوپاتولوژیک[۹] معرفی کردند. برای تقسیم‌بندی تصویر، یک روش خوشه‌بندی فازی (RSWOA-FC)[۱۰] بر اساس بهینه‌سازی نهنگ مبتنی بر انتخاب چرخ

[1] Fuzzy neighborhood rough sets (FNRS)
[2] Binary whale optimization algorithm (BWOA)
[3] Two stage fuzzy neighborhood feature selection with binary whale optimization algorithm
[4] Knowledge granularity
[5] Interference
[6] Vishnoi
[7] Roulette Wheel Selection based Whale Optimization Algorithm (RSWOA)
[8] Nuclei
[9] Histopathological
[10] Fuzzy Clustering method based on the Roulette wheel Selection based Whale Optimization Algorithm (RSWOA-FC)

رولت برای انتخاب عوامل جستجو به جای انتخاب تصادفی برای کاوش کل فضای جستجو ارائه کردند. بنابراین، برای تقویت سرعت همگرایی جهانی و دستیابی به عملکرد بهتر WOA، از اپراتور انتخاب چرخ رولت استفاده شد. ابتدا، تصاویر هیستوپاتولوژیک رنگی توسط RSWOA در K خوشه بهینه گروه‌بندی شدند. روش خوشه‌بندی پیشنهادی، خوشه‌های بهینه را با استفاده از تابع هدف پیدا کرد که مجموع مربعات خطا یا فشردگی را کاهش داد. در مرحله بعد، از مراکز خوشهای بهینه برای تقسیم‌بندی هسته‌ها استفاده شد. از آنجایی که در تصاویر هیستوپاتولوژیک رنگ آمیزی شده H&E، نواحی (مناطق) تاریک عموماً هسته بودند، از این رو مرکز ثقل خوشه با کوچکترین مقادیر پیکسل، هسته‌های تقسیم‌بندی شده را توصیف کرد. بنابراین، ناحیه هسته از روی خوشه‌های فازی که حداقل مقدار مرکز خوشه را داشتند، مشخص شدند. نتایج، عملکرد بهتر روش RSWOA-FS نسبت به روش‌های K-Means، FCM و WOA-FC نشان دادند.

- وو[1] و همکارانش [۲۵] با ترکیب FCM و WOA، الگوریتم بهینه‌سازی نهنگ فازی ممتیک (MFWO)[2] را برای حل مشکل خوشه‌بندی داده‌ها ارائه کردند. الگوریتم MFWO الگوریتم‌های FCM و WOA را در هر تکرار ترکیب کرد به‌طوریکه مقدار شایستگی هر عامل را توانست کاهش دهد. این الگوریتم از مزایای استراتژی جستجو و پارامترهای کم WOA استفاده کرد. علاوه بر این، ماتریس عضویت فازی که همان الگوریتم FCM بود، برای رمزکردن عوامل WOA اتخاذ شد. در مرحله اول، هر عامل به صورت تصادفی تولید شد و در مرحله دوم، الگوریتم MFWO رویهٔ WOA را برای به‌روزرسانی مرکز خوشه و ماتریس عضویت اجرا کرد. در نهایت، پس از روند WOA، FCM با هر عامل به عنوان استراتژی جستجوی محلی برای پردازش تنظیم دقیق هر عامل ترکیب شد. الگوریتم MFWO در مقایسه با الگوریتم‌های FCM، بهینه‌سازی ازدحام ذرات فازی (FPSO)[3] و FCM-FPSO عملکرد بهتری را از نظر دستیابی به بهترین میانگین مقدار شایستگی نشان داد؛ بنابراین الگوریتم مؤثرتری برای مسائل خوشه‌بندی فازی بود. همچنین الگوریتم FCM بسیار قدرتمند یک جستجوی محلی را در الگوریتم‌های FCM-FPSO و MFWO انجام داد.

۴. مقایسه روش‌ها

در جدول ۱ مقایسه روش‌های بحث شده برحسب معیارهای متفاوت و در جدول ۲، مزایا، معایب و کاربردهای آنها بطور خلاصه آورده شده است.

---

[1] Wu

[2] Memetic fuzzy whale optimization (MFWO)

[3] Fuzzy particle swarm optimization (FPSO)

جدول۱ : **مقایسه روش‌های بحث شده**

روش	سال	هدف	مجموعه داده	نرم افزار	معیارها	دسته بندی
WOA-T و WOA-R و WOA-CM [۱۷]	۲۰۱۷	افزایش عملکرد WOA با اصلاح نحوه انتخاب، افزایش بهره‌برداری.	۱۸ مجموعه داده از UCI	متلب	دقت بالا و میانگین انتخاب نسبی.	غیرفازی
CWOA [۲۰]	۲۰۱۸	مقابله با دشواری انتخاب بهترین تنظیمات پارامتر برای عملکرد هر الگوریتم بهینه‌سازی، با استفاده از نقشه‌های بی‌نظم به جای این پارامترها.	۱۰ مجموعه داده پزشکی از UCI	متلب آر۲۰۱۲	دقت طبقه‌بندی بالا با تعداد ویژگی‌های کم.	غیرفازی
bWOA-S [۱۰]	۲۰۱۹	رفع مشکل انتخاب ویژگی، انتخاب زیرمجموعه ویژگی بهینه، کاهش بُعد.	۱۱ مجموعه داده معیار از UCI	-	دقت طبقه‌بندی خوب KNN با حداقل تعداد ویژگی‌های انتخاب‌شده.	غیرفازی
MFWO [۲۵]	۲۰۱۹	رفع مشکل خوشه‌بندی داده‌ها.	۸ مجموعه داده معیار از UCI	پایتون	بهترین میانگین مقدار شایستگی.	فازی
QWOA [۲]	۲۰۲۰	افزایش قدرت اکتشاف و بهره‌برداری WOA.	۱۴مجموعه داده از UCI	-	میانگین دقت طبقه‌بندی بالا، میانگین بهتر مقدار شایستگی،AUCوزیرمجموعه ویژگی‌های انتخاب شده.	غیرفازی
WOSKECA و PSOSVM [۵]	۲۰۲۰	یافتن یک روش علمی و مؤثر برای تشخیص خطا در ماشین‌های دوّار، انتخاب باارزش‌ترین ویژگی‌های خطا از کل مجموعه ویژگی.	Iris و Wine	-	توانایی تشخیص خوب، دقت خوب در تشخیص عیب.	غیرفازی

ادامه جدول ۱

روش	سال	هدف	مجموعه داده	نرم افزار	معیارها	دسته بندی
MWOA و MWOA-FCM و AIFDS [۱۸]	۲۰۲۱	یافتن و حذف داده‌های پرت، تشخیص تقلب.	Iris، Wine، Seed، Glass، E-Coli و CMC و carclaims.txt	متلب ۲۰۱۶ و پایتون	حساسیت (Sensitivity) ، خاصیت (Specifcity) و دقت (Accuracy).	فازی
DRITI و FRUWOA [۲۱]	۲۰۲۱	کاهش بُعد، کشف آیتم‌های تکراری فازی و تولید قوانین فازی	Food mart، Chain store، Connect، Mushroom و Chess	-	کاهش آیتم بیشتر، کاهش تراکنش بیشتر، زمان اجرای کمتر و تخصیص حافظه کم.	فازی
RSWOA و RSWOA-FC [۲۴]	۲۰۲۱	تقسیم‌بندی هسته‌های تصاویر هیستوپاتولوژیک.	تصویر هیستوپاتولوژی رنگ آمیزی شده H&E (Hema-toxylin and Eosin-stained histopathology image dataset).	متلب ۲۰۱۶آ	میانگین بهتر مقدار شایستگی، کاهش مجموع مربعات خطا [Sum of squared error(SSE)] خوشه‌ها، اندازه F1 measure بالا، مقدار Aggregated Jaccard index (AJI) بالا.	فازی
DCWOA [۱۲]	۲۰۲۲	تعیین خروجی بهینه ژنراتور سیستم‌های تولید همزمان (Co-generation systems) (متعادل کردن همزمان هزینه سوخت و جرم آلاینده‌ها).	-	متلب	جمعیت نهنگ‌ها، حداکثر تعداد تکرار، مقدار میانگین و انحراف استاندارد بهتر، معیار کمّی شایستگی، بالاترین مقدار شایستگی، میانگین زمان محاسباتی خوب، تعداد واحدهای نیرو، تولید همزمان، حرارت، مجموع کل واحدها، تقاضای نیرو، تقاضای حرارت، انتشار آلاینده.	فازی

ادامه جدول ۱

روش	سال	هدف	مجموعه داده	نرم افزار	معیارها	دسته بندی
IBWOA، FNRS و TSFNFS [۲۲]	۲۰۲۳	پیش‌پردازش داده‌ها در مسائل طبقه‌بندی و کاهش ابعاد برای مجموعه داده‌های بزرگ برای یافتن مجموعه ویژگی‌های بهینه.	شش مجموعه داده از UCI و پنج مجموعه داده بیان ژن (Gene expression)	متلب آر ۲۰۱۶ ب	دقت طبقه‌بندی بسیار خوب، مقدار میانگین (Mean) و انحراف استاندارد [Standard deviation (STD)] خوب.	فازی
IFWRE-SVM و WOA-IFWRE-SVM [۸]	۲۰۲۳	پیشگیری، تشخیص، درمان زودهنگام و مدیریت چربی بدن و کاهش خطر چاقی.	StatLib و NHANES	-	خطای میانگین مطلق [Mean Absolute Error (MAE)]، ریشه میانگین مربعات خطا [Root Mean Square Error (RMSE)]، انحراف معیار [Standard Deviation (SD)] و پایداری [Robustness (MAC)] بهتر.	فازی
EWOA [۱۳]	۲۰۲۴	حفظ امنیت حساب‌های برخط، افزایش تشخیص و پیش‌بینی حملات پر کردن اعتبارنامه.	KDD Cup	متلب	دقت، زمان محاسبات، طول عمر شبکه، گره‌های زنده، تعداد مهاجمان و تعداد CH.	غیرفازی
MPWO [۱۱]	۲۰۲۴	حفظ حریم خصوصی، شبه شناسایی و تولید کلید بهینه در چشم‌انداز گسترده کاربردهای کلان داده و مدیریت کارآمدتر آن و همچنین دستیابی کمتر به معیار اندازه کلاس معادل میانگین.	Adult income dataset و Mammographic Mass dataset (MGM) و Contra-ceptive Method Choice dataset (CMC)	پایتون	جریمه قطعی نرمال شده (NCP)، قابل تشخیص (DM) و معیار اندازه کلاس معادل میانگین (CAVG).	غیرفازی

جدول:۲ مقایسه روش های بحث شده

روش	مزایا	معایب	کاربرد
WOA-T و WOA-R و WOA-CM [۱۷]	جلوگیری از تعداد زیادی بهینهٔ محلی در مسائل انتخاب ویژگی، ارائه تخمینی دقیق برای بهترین راه‌حل.	پیچیدگی محاسباتی بالا، مقیاس‌پذیری کمتر برای مجموعه داده‌های بزرگ.	انتخاب ویژگی.
CWOA [۲۰]	زیرمجموعه ویژگی‌های بهینه، نیاز به پارامترهای کمتر برای تنظیم، استفاده از نقشه‌های بی‌نظم به جای پارامترها، حل بهتر مسائل انتخاب ویژگی، سرعت همگرایی بالاتر، جلوگیری از گیرافتادن در بهینه محلی.	پیچیدگی زمانی بالا، عدم توانایی در بهبود قابل توجه عملکرد WOA.	انتخاب ویژگی.
bWOA-S [۱۰]	فضای جستجو باینری، ارائه بهترین ترکیب ویژگی، یافتن ویژگی بهینه.	عدم بررسی با ANN و SVM و فقط بررسی با KNN.	طبقه‌بندی داده‌ها.
MFWO [۲۵]	جستجوی محلی قوی، عملکرد بهتر.	پیچیدگی بالا.	خوشه‌بندی داده‌ها.
QWOA [۲]	افزایش تنوع جمعیت، نمایش بهتر جمعیت با q-بیت‌ها، افزایش همگرایی با عملگر دروازه چرخش کوانتومی، اکتشاف کوانتومی بهتر با جمعیت کوچکتر، کوچک‌شدن و حرکت مارپیچی نهنگ‌ها.	عدم توجه به بهینه‌سازی مستمر و مسائل بهینه‌سازی چندهدفه، مؤثر فقط برای انتخاب ویژگی و مسائل بهینه‌سازی بدون محدودیت باینری.	انتخاب ویژگی.
WOSKECA و PSOSVM [۵]	تفکیک دقیق انواع مختلف خطا و شدت خطا، استخراج ویژگی های با بعد کم، حذف ویژگی‌های مازاد و بالاترین نرخ شناسایی حالت.	پیچیدگی زمانی بالا، احتمال رخداد بیش‌برازش (Overfitting).	تشخیص خطا در ماشین‌های دوّار.
MWOA و MWOA-FCM و AIFDS [۱۸]	دستیابی به بهینه جهانی بهتر، نمونه‌گیری کمتر، بهبود قابلیت اطمینان جستجو، بهبود دقت راه‌حل، بهبود سرعت همگرایی، دستیابی به مرکز خوشه بهینه.	پیچیدگی بالا.	سیستم‌های تشخیص تقلب.

ادامه جدول۲

روش	مزایا	معایب	کاربرد
DRITI و FRUWOA [۲۱]	عدم نیاز به تمام آیتم‌ها و تراکنش‌ها برای آنالیز داده‌ها، کاهش اندازه مجموعه داده، شناسایی مؤثر آیتم‌ها و تراکنش‌ها از پایگاه داده.	تمرکز فقط برروی روش Association rule mining (ARM) از داده‌کاوی، عدم بررسی روش‌های طبقه‌بندی و خوشه‌بندی، عدم پنهان‌سازی آیتم‌های حساس از نظر محدودیت‌های حریم خصوصی با طبقه‌بندی یا خوشه‌بندی آیتم‌های تکراری براساس چهار فصل.	تجزیه و تحلیل حجم عظیمی از مجموعه داده‌ها.
RSWOA و RSWOA-FC [۲۴]	مراکز خوشه بهینه، سرعت همگرایی بالا، دقت تقسیم‌بندی بهتر و بالا.	نیازمند به تنظیم پارامترهای مختلف برای دستیابی به دقت خوب.	تقسیم‌بندی تصویر
DCWOA [۱۲]	افزایش همگرایی، حفظ تعادل بین اکتشاف و بهره‌برداری در طول فرآیند جستجو، زمان کافی برای اکتشاف و بهره‌برداری مناسب، بهبود کارایی، دستیابی به شایستگی با کیفیت بهتر برای اهداف متضاد، دستیابی به بهینه جهانی بهتر، بهترین هزینه و بهترین انتشار.	عدم حضور منابع انرژی تجدیدپذیر.	ژنراتورهای حرارتی و الکتریکی (ژنراتورهای سیستم تولید همزمان).
IBWOA، FNRS و TSFNFS [۲۲]	پیچیدگی کم، سرعت همگرایی سریعتر، صرفه‌جویی در زمان اجرا، عملکرد محاسباتی بهتر، کارآیی و پایداری بهینه‌سازی عالی، دستیابی به مقدار بهینهٔ برتر، گیر نکردن در بهینهٔ محلی و انتخاب ویژگی‌های کمتر و مهم‌تر از مجموعه داده‌ها و حفظ تعادل بین جستجوی محلی و جهانی با استفاده از استراتژی‌های بهبود یافته.	عدم درنظر گرفتن توزیع ویژگی‌ها، پایین بودن اثربخشی محاسباتی و کارایی طبقه‌بندی مجموعه‌های داده در مقیاس بزرگ و مختلط (مقیاس‌پذیری پایین) و نیازمند بودن به تنظیم پارامترهای کنترلی برای بهبود عملکرد الگوریتم.	بیوانفورماتیک (به عنوان مثال، تجزیه و تحلیل داده‌های بیان ژن) و انتخاب ویژگی.

ادامه جدول۲

IFWRE-SVM و WOA-IFWRE-SVM [۸]	بهبود عملکرد، جستجوی بهینهٔ فراپارامترها، قابلیت اطمینان، افزایش دقت پیش‌بینی با استفاده از WOA و وزن‌های فازی و بهبود پایداری و مقاومت مدل در برابر داده‌های نویزی.	نیازمند به تنظیم پارامترها، وابستگی عملیات وزن فازی با تعداد ویژگی‌های ورودی و پیچیدگی محاسباتی بالا.	بررسی وضعیت سلامت شخصی.
EWOA [۱۳]	بهبود کارایی، کاهش زمان محاسبات، افزایش تعداد گره‌های زنده، افزایش دقت تشخیص حمله، افزایش عمر شبکه و پایداری شبکه.	پیچیدگی محاسباتی بالا و عدم سازگاری مناسب با تغییرات پویا در پیکربندی سیستم و استراتژی‌های حمله جدید به علت بهینه‌سازی ایستای WOA.	تشخیص حملات سایبری و افزایش امنیت در دستگاه‌های اینترنت اشیاء.
MPWO [۱۱]	مقیاس‌پذیری و انعطاف‌پذیری بالا، بهبود کیفیت، ایجاد تعادل بین کیفیت و مدیریت کارآمد اطلاعات، حداقل معیارهای قابل تشخیص، حفظ داده‌های حساس شناسایی شده از طریق تولید کلیدهای بهینه، دستیابی به مقدار کمتر جریمه قطعی نرمال شده برای به حداقل رساندن از دست دادن اطلاعات، قابلیت اطمینان، کارایی بالا، غلبه بر دشواری رمزگذاری ویژگی‌ها.	پیچیدگی محاسباتی بالا و احتمال نیاز به بهینه‌سازی بیشتر و عدم توسعهٔ مکانیسم‌های کنترل حریم خصوصی تطبیقی.	تحلیل کلان داده، امنیت و حفاظت از داده‌های حساس.

۵. نتیجه‌گیری و جهت‌گیری آینده

در این مقاله، تعدادی از روش‌های فازی و غیرفازی که روی الگوریتم نهنگ کار کرده‌اند بررسی گردید و نشان می‌دهد نسخه‌های مختلف الگوریتم نهنگ دارای مزایا و معایب خاص خود هستند. استفادهٔ به تنهایی از انتخاب ویژگی و خوشه‌بندی فازی مشکلاتی ازجمله گیرافتادن در بهینه محلی دارند که با ترکیب با الگوریتم WOA رفع می‌شوند. مقایسه روش‌های فازی و غیرفازی مبتنی بر

الگوریتم نهنگ نشان دادند که روش‌های فازی از دقت بالاتری برخوردارند و در کاربردهای خاص، عملکرد بهتری دارند اما باید به حساسیت این روش‌ها به تنظیم دقیق پارامترها نیز توجه داشت. الگوریتم WOA، به‌خودی‌خود دارای محدودیت‌هایی مانند نرخ همگرایی کند و گیر افتادن در بهینه‌های محلی است؛ این مشکلات به‌ویژه در مسائلی با ابعاد بالا بروز می‌کند. در تمامی روش‌های ترکیبی با الگوریتم WOA سعی بر بهبود عملکرد و افزایش سرعت همگرایی الگوریتم WOA کلاسیک شد اما در اکثر موارد منجر به افزایش پیچیدگی روش ترکیبی گردید. استفاده از روش‌های خوشه‌بندی C-میانگین فازی (FCM) و سرخوشه‌ها (CH) هر دو نقش مهمی در تشخیص تقلب و تشخیص حملات داشتند. نکته جالب توجه این است که روش‌های فازی و غیرفازی، به طور مشترک به کاهش ابعاد پرداخته و توانسته‌اند به بهبود کارایی WOA در مسائل پیچیده کمک کنند. با این حال، پیچیدگی اضافی ایجاد شدهٔ روش‌های ترکیبی ممکن است در برخی کاربردها منجر به چالش‌های جدیدی شود.

در نهایت، نتایج این تحقیق تأکید می‌کند که استفاده از روش‌های فازی و غیرفازی در ترکیب با الگوریتم WOA می‌تواند به بهبود عملکرد آن در حل مسائل بهینه‌سازی کمک کند، اما نیاز به دقت و بررسی بیشتر در زمینه مدیریت پیچیدگی‌های اضافی و ارزیابی عملی این ترکیب‌ها وجود دارد. همچنین، تحقیقات در زمینه توسعه و پیاده‌سازی تکنیک‌های جدید برای تنظیم بهتر پارامترها و کاهش نیاز به منابع محاسباتی می‌تواند به ارتقاء بیشتر این الگوریتم‌ها کمک کند. تحقیق بر روی تکنیک‌های بهینه‌سازی، تنظیم پارامترها و کاهش پیچیدگی می‌تواند به بهبود کارایی الگوریتم‌های ترکیبی کمک کند. استفاده از روش‌های بهینه‌سازی منابع و بهبود الگوریتم‌ها برای کاهش زمان اجرای الگوریتم‌ها و افزایش کارایی ضروری است. برای مقابله با پیچیدگی‌های محاسباتی در الگوریتم‌های ترکیبی، تحقیق و توسعهٔ الگوریتم‌های مقیاس‌پذیر که به‌طور مؤثر قادر به پردازش داده‌های بزرگ و پیچیده باشند، ضروری است. این الگوریتم‌ها باید قادر به کاهش زمان اجرای الگوریتم بدون کاهش دقت باشند.

این تحقیق می‌تواند به عنوان مبنایی برای پژوهش‌های آینده در حوزه بهینه‌سازی و توسعه الگوریتم‌های فراابتکاری مورد استفاده قرار گیرد. به‌علاوه، بررسی کاربردهای جدید و ارزیابی عملکرد این الگوریتم‌ها در زمینه‌های مختلف علمی و صنعتی (همچون در حوزه بسترهای کاری هوشمند مانند شهرهای هوشمند، صنعت هوشمند و یا حتی مباحثی مانند بهبود امنیت و مسیریابی در شبکه‌های خاص)، می‌تواند به‌عنوان یک مسیر تحقیقاتی ارزشمند مورد توجه قرار گیرد. تحقیقات در این زمینه‌ها می‌تواند به توسعه الگوریتم‌های بهینه‌سازی پیشرفته‌تر و بهبود نتایج در مسائل پیچیده کمک کند و به‌طور کلی به پیشرفت علم و فناوری در زمینه بهینه‌سازی و تحلیل داده‌ها منجر شود.

مراجع

[۱] اسلامی، ا. (۱۳۹۱) منطق فازی و کاربردهای آن، انتشارات دانشگاه شهید باهنر کرمان.

[2] Agrawal, R.K., Kaur, B. and Sharma, S. (2020), Quantum based Whale Optimization Algorithm for wrapper feature selection, Applied Soft Computing Journal, 89, 106092.

[3] Al Ogaili, R.R.N., Alomari, E.S., Alkorani, M.B.M. and et al. (2023), Malware cyberattacks detection using a novel feature selection method based on a modified whale optimization algorithm, Wireless Networks.

[4] Artuğer, F. (2023), A new S-box generator algorithm based on 3D chaotic maps and whale optimization algorithm, Wireless Personal Communications, 131, 835ت853.

[5] Bai, L., Han, Z., Ren, J. and Qin, X. (2020), Research on feature selection for rotating machinery based on Supervision Kernel Entropy Component Analysis with Whale Optimization Algorithm, Applied Soft Computing, 92, 106245.

[6] Bezdek, J.C. (1981), Objective function clustering. In: Pattern recognition with fuzzy objective function algorithms. Advanced Applications in Pattern Recognition, Springer, Boston, 43ت93.

[7] Dunn, J.C. (1973), A fuzzy relative of the ISODATA process and its use in detecting compact well-separated clusters. Journal of Cybernetics, 3, 32ت57.

[8] Fan, Z. and Gou, J. (2023), Predicting body fat using a novel fuzzy-weighted approach optimized by the whale optimization algorithm, Expert Systems with Applications, 217, 119558.

[9] Hambali, M.A., Oladele, T.O. and Adewole, K.S. (2020), Microarray cancer feature selection: Review, challenges and research directions, International Journal of Cognitive Computing in Engineering, 1, 78-97.

[10] Hussien, A.G., Hassanien, A.E., Houssein, E.H., Bhattacharyya, S. and Amin, M. (2019), S-shaped Binary Whale Optimization Algorithm for Feature Selection. In: S. Bhattacharyya, A. Mukherjee, H. Bhaumik, S. Das and K. Yoshida, (eds) Recent Trends in Signal and Image Processing. Advances in Intelligent Systems and Computing, Springer, Singapore, 727.

[11] Jadhav, P.S. and Borkar, G.M. (2024), Optimal key generation for privacy preservation in big data applications based on the marine predator whale optimization algorithm, Annals of Data Science.

[12] Jadoun, V.K., Prashanth, G.R., Joshi, S.S., Narayanan, K., Malik, H. and Mعrquez, F.P.G. (2022), Optimal fuzzy based economic emission dispatch of combined heat and power units using dynamically controlled Whale Optimization Algorithm, Applied Energy, 315, 119033.

[13] Jyothi, K.K., Borra, S.R., Srilakshmi, K. and et al. (2024), A novel optimized neural network model for cyber attack detection using enhanced whale optimization algorithm, Scientific Reports, 14, 5590.

[14] Jawed, M.S. and Sajid, M. (2024), Enhancing the cryptographic key using sample entropy and whale optimization algorithm, International Journal of Information Technology, 16, 1733ت1741.

[15] Liu, W. and Wang, J. (2019), A Brief Survey on Nature-Inspired Metaheuristics for Feature Selection in Classification in this Decade, In Proceedings of the 2019 IEEE 16th International Conference on Networking, Sensing and Control (ICNSC), Banff, AB, Canada, 424-429.

[16] Liu, Z., Wang, J., Gao, Z. and et al. (2023), Privacy-preserving edge computing offloading scheme based on whale optimization algorithm, The Journal of Supercomputing, 79, 3005ت3023.

[17] Mafarja, M.M. and Mirjalili, S. (2017), Whale Optimization Approaches for Wrapper Feature Selection, Applied Soft Computing Journal, 62, 441-453.

[18] Majhi, S.K. (2021), Fuzzy clustering algorithm based on modified whale optimization algorithm for automobile insurance fraud detection. Evolutionary Intelligence, 14, 35ت46.

[19] Mirjalili, S. and Lewis, A. (2016), The Whale Optimization Algorithm, Advances in Engineering Software, 95, 51-67.

[20] Sayed, G.I., Darwish, A. and Hassanien, A.E. (2018), A New Chaotic Whale Optimization Algorithm for Features Selection, Journal of Classification, 35, 300ت344.

[21] Sharmila, S. and Vijayarani, S. (2021), Association rule mining using fuzzy logic and whale optimization algorithm. Soft Computing, 25, 1431ت1446.

[22] Sun, L., Wang, X., Ding, W., Xu, J. and Meng, H. (2023), TSFNFS: two-stage-fuzzy-neighborhood feature selection with binary whale optimization algorithm. International Journal of Machine Learning and Cybernetics. 14, 609ت631.

[23] Uke, N.J., Lokhande, S.A., Kale, P. and et al. (2024), Distributed privacy preservation for online social network using flexible clustering and whale optimization algorithm, Cluster Computing, 27, 5995ت6012.

[24] Vishnoi, S., Jain, A.K. and Sharma, P.K. (2021), An efficient nuclei segmentation method based on roulette wheel whale optimization and fuzzy clustering. Evolutionary Intelligence, 14, 1367ت1378.

[25] Wu, Z. -X., Huang, K. -W., Chen, J. -L. and Yang, C. -S. (2019), A Memetic Fuzzy Whale Optimization Algorithm for Data Clustering, In Proceedings of the 2019 IEEE Congress on Evolutionary Computation (CEC), Wellington, New Zealand, 1446-1452.