

بهبود دقت دسته‌بندی داده‌های چند برچسبی با استفاده از رابطه فازی کلاسیک در بهینه‌ساز کلونی مورچه‌ها

سحر شمس بیرانوند، وحید مهرداد* و محمدباقر دولتشاهی

گروه مهندسی برق، دانشگاه لرستان، خرم آباد، ایران

تاریخ دریافت: ۱۴۰۳/۰۴/۰۷

تاریخ پذیرش: ۱۴۰۳/۰۷/۱۵

نوع مقاله: علمی-پژوهشی

چکیده. در این مقاله یک رویکرد جدید برای بهبود دقت طبقه‌بندی داده‌های چند برچسبی با استفاده از منطق فازی رابطه کلاسیک در چارچوب الگوریتم بهینه‌ساز کلونی مورچه‌ها مبتنی بر یادگیری تقویتی پیشنهاد شده است. افزایش کاربرد داده‌های چند برچسبی در حوزه‌های مختلف، نیاز به روش‌هایی موثر برای افزایش دقت طبقه‌بندی را ضروری می‌سازد. در این روش رابطه کلاسیک منطق فازی با الگوریتم بهینه‌ساز کلونی مورچه‌ها مبتنی بر یادگیری تقویتی ادغام شده است تا توانایی آن را برای مدیریت روابط پیچیده ذاتی در مجموعه داده‌های چند برچسبی افزایش دهد. علاوه بر این، از ترکیب تکنیک‌های انتخاب ویژگی و الگوریتم بهینه‌ساز کلونی مورچه‌ها مبتنی بر یادگیری تقویتی برای شناسایی و استفاده از مرتبط‌ترین ویژگی‌ها بهره گرفته شده است که در نتیجه باعث کاهش ابعاد و بهبود کارایی محاسباتی مدل شده است. از طریق آزمایش‌های گسترده بر روی مجموعه داده‌های استاندارد، اثربخشی این رویکرد در دستیابی به دقت بهتر در مقایسه با روش‌های رقیب نشان داده شده است. چارچوب پیشنهادی نه تنها عملکرد طبقه‌بندی را افزایش (ادامه دارد)

2010 Mathematics Subject Classification. 03B52 ; 68T27

* Corresponding author

E-mails: Shams.s@fe.lu.ac.ir, mehrdad.v@lu.ac.ir and Dowlatshahi.mb@lu.ac.ir.

عبارات و کلمات کلیدی. یادگیری ماشین، بهینه‌ساز کلونی مورچه‌ها، انتخاب ویژگی، الگوریتم فازی، داده‌های چند برچسبی.

داده است، بلکه بینش‌هایی در مورد تفسیرپذیری تصمیم‌های طبقه‌بندی ارائه می‌دهد، که به پیشرفت روش‌های طبقه‌بندی داده‌های چند برچسبی کمک می‌کند.

۱. مقدمه

پلتفرم‌های رسانه‌های اجتماعی باعث هجوم گسترده داده‌ها، از جمله مقدار قابل توجهی از اطلاعات نامربوط شده است و به طور مداوم محتوای تولید شده توسط کاربر را جمع‌آوری و تجزیه و تحلیل می‌کنند. در نتیجه، توانایی فیلتر کردن و انتخاب اطلاعات یا ویژگی‌های مربوطه از مقدار بسیار زیاد داده حیاتی می‌شود. انتخاب ویژگی یک فرآیند بسیار مهم در یادگیری ماشین و تجزیه و تحلیل داده‌ها است. این شامل انتخاب مرتبط‌ترین و آموزنده‌ترین ویژگی‌ها از یک مجموعه داده معین برای بهبود دقت و کارایی مدل‌های پیش‌بینی است. با انتخاب مجموعه مناسب از ویژگی‌ها ابعاد کاهش پیدا می‌کند، اطلاعات اضافی یا نامربوط حذف می‌شود و قابلیت تفسیر مدل افزایش می‌یابد [۱۱].

در یادگیری ماشین، داده‌های چند برچسبی به نوعی از مجموعه داده اشاره دارد که در آن هر نمونه می‌تواند به طور همزمان با چندین برچسب مرتبط شود. طبقه‌بندی داده‌های چند برچسبی به وظیفه اختصاص دادن چندین برچسب به یک نمونه در یک مجموعه داده اشاره دارد [۱۲]. الگوریتم بهینه‌ساز کلونی مورچگان^۱ (ACO)، که از رفتار مورچه‌ها در جستجوی مسیر الهام گرفته شده، به طور موفقیت‌آمیزی در مسائل بهینه‌سازی مختلفی مانند انتخاب ویژگی در داده‌های چندبرچسبی به کار می‌رود. این الگوریتم با تنظیم پارامترهایی مانند تبخیر فرومون و تعداد مورچه‌ها، راه‌حلی برای مسائل بهینه‌سازی ترکیبی ارائه می‌دهد [۱۳]. یادگیری تقویتی^۲ (RL) نیز یک شاخه مهم در یادگیری ماشین است که به عامل‌ها^۳ کمک می‌کند از طریق تعامل با محیط و دریافت پاداش^۴، تصمیم‌گیری بهینه را بیاموزند. در RL، عامل با انجام اقدامات مختلف و دریافت بازخورد از محیط، سیاستی برای به حداکثر رساندن پاداش کلی پیدا می‌کند. این روش در شرایط پویا و نامعلوم بسیار کارآمد است و در زمینه‌هایی مثل بازی‌های رایانه‌ای و رباتیک کاربرد دارد [۲۶].

منطق فازی توسط لطفی زاده برای مقابله با پیچیدگی‌ها و عدم قطعیت‌های موجود در سیستم‌های واقعی معرفی شد. برخلاف منطق کلاسیک که تنها دو حالت درست یا غلط را

^۱Ant Colony Optimization

^۲Reinforcement Learning

^۳Agent

^۴Reward

در نظر می‌گیرد، منطق فازی به صورت پیوسته و با درجات مختلف از درستی عمل می‌کند. این ویژگی منطق فازی را برای مدل‌سازی سیستم‌های غیرقطعی و پیچیده مناسب می‌سازد و به سیستم‌ها اجازه می‌دهد که با اطلاعات ناقص یا مبهم، تصمیم‌گیری‌های دقیق‌تری انجام دهند [۲۸]. ترکیب منطق فازی با الگوریتم‌های بهینه‌سازی مانند ACO و یادگیری تقویتی به بهبود عملکرد سیستم‌ها در مسائل پیچیده کمک می‌کند.

این مقاله با ترکیب زیر: در بخش ۲ مروری بر روش‌های موجود در زمینه انتخاب ویژگی برای مسائل دسته‌بندی چند برچسبی، در بخش ۳ توضیح مفاهیم و اصول الگوریتم پیشنهادی برای حل مسئله مورد بررسی، در بخش ۴ بررسی جزئیات و اجزای الگوریتم پیشنهادی به طور کامل، در بخش ۵ ارائه و بررسی نتایج به دست آمده از آزمایش‌ها و ارزیابی‌های صورت گرفته و در بخش ۶ به نتیجه‌گیری و آینده پیش رو برای روش ارائه شده، به بیان ایده خود می‌پردازد.

۲. کارهای مرتبط

در سال‌های اخیر با توجه به اهمیت انتخاب ویژگی، تحقیقات بسیاری در این حوزه انجام شده است. روش MLACO یک رویکرد جدید برای انتخاب ویژگی چندبرچسبی با استفاده از الگوریتم ACO ارائه می‌دهد که از توابع اکتشافی نظارت‌شده و بدون نظارت برای یافتن ویژگی‌های مرتبط با افزونگی کم استفاده می‌کند [۱۹]. در روش Ant-TD نیز از ترکیب الگوریتم کلونی مورچه‌ها و یادگیری تقویتی تفاوت زمانی (TD) برای بهبود جستجوی ویژگی‌ها و استفاده از تجربیات گذشته در پیش‌بینی ارزش آینده اقدامات بهره گرفته شده است [۲۰]. روش دیگری که در مرجع [۵] ارائه شده است، یک انتخاب ویژگی بدون نظارت است که با استفاده از اصول تصمیم‌گیری چندمعیاره فازی (MCDM) به ارزیابی اهمیت ویژگی‌ها پرداخته و با استفاده از منطق فازی به مدیریت عدم قطعیت‌ها کمک می‌کند. همچنین، در مرجع [۹] برای حل چالش انتخاب ویژگی در داده‌های جریان آنلاین، از یک رویکرد بهینه‌سازی چندهدفه مبتنی بر تسلط پارتو فازی استفاده شده است که با در نظر گرفتن اهداف متضاد و عدم قطعیت‌ها، به انتخاب موثر ویژگی‌ها می‌پردازد.

مقاله MFS-MCDM نیز یک الگوریتم انتخاب ویژگی فیلتر برای یادگیری چندبرچسبی را ارائه می‌دهد که با تبدیل مسئله به یک فرآیند تصمیم‌گیری چندمعیاره و استفاده از روش TOPSIS، به رتبه‌بندی ویژگی‌ها بر اساس همبستگی آن‌ها با برچسب‌ها می‌پردازد [۱۰]. علاوه بر این، در مرجع [۲۷] یک الگوریتم ACO برای ثبت تصاویر سنجش از دور معرفی شده است که با بهینه‌سازی مستمر مورچه‌ها و جستجوی محلی، دقت و کارایی را افزایش می‌دهد. مقاله

[۱۸] به بهبود روش‌های انتخاب ویژگی چندبرچسبی در طبقه‌بندی متن از طریق شمارش وزنی بردا پرداخته و مقاله [۷] نیز یک رویکرد انتگرال فازی برای ترکیب چندین الگوریتم انتخاب ویژگی بدون نظارت ارائه می‌کند، که با استفاده از انتگرال فازی، دقت و استحکام انتخاب ویژگی را افزایش می‌دهد.

جدول ۱. مقایسه روش‌های موجود بر اساس مفاهیم اساسی

مرجع	Multi-label data	Feature selection	fuzzy	ACO	RL
[۱۹]	✓	✓		✓	
[۲۰]	✓	✓		✓	✓
[۵]		✓	✓		
[۹]		✓			
[۱۰]	✓	✓			
[۲۷]				✓	
[۱۸]	✓	✓			
[۷]			✓		

جدول ۱ نشان می‌دهد که، علی‌رغم کارهای زیادی که در هریک از زمینه‌های انتخاب ویژگی در داده‌های چند برچسبی، الگوریتم ACO، یادگیری تقویتی و منطق فازی تاکنون مورد بحث و بررسی قرار گرفته است، توجهی به ارتباط میان آنها نشده است. در این مقاله روشی پیشنهاد می‌شود که با استفاده از منطق فازی در الگوریتم ACO مبتنی بر یادگیری تقویتی معیارهای بررسی انتخاب ویژگی در داده‌های چند برچسبی بهبود داده شوند.

۳. مفاهیم پایه

در این بخش به بررسی دقیق‌تر مفاهیم و روش‌های استفاده شده در روش پیشنهادی می‌پردازیم.

۱.۳. الگوریتم ACO. الگوریتم ACO معمولاً برای حل مسائل بهینه‌سازی ترکیبیاتی مانند مسئله فروشنده دوره‌گرد^۱ (TSP)، مسئله مسیریابی وسایل نقلیه^۲ (VRP) و مسئله تخصیص مربعی^۳ (QAP) استفاده می‌شود. این الگوریتم با مقداردهی اولیه به جمعیتی از مورچه‌های

^۱Traveling Salesman Problem

^۲Vehicle Routing Problem

^۳Quadratic Assignment Problem

مصنوعی آغاز می‌شود که به صورت تصادفی یا در مکان‌های از پیش تعریف شده در فضای جستجو قرار می‌گیرند. هر مورچه با انتخاب‌های متوالی بر اساس یک قانون احتمالی، یک راه حل می‌سازد. پس از اینکه همه مورچه‌ها راه حل‌های خود را ساختند، فرومون‌ها بر اساس کیفیت راه حل‌ها به روزرسانی می‌شوند [۳]. به طور معمول، مسیرهایی که بخشی از راه حل‌های بهتر هستند، فرومون بیشتری دریافت می‌کنند. مورچه‌هایی که راه حل‌های با کیفیت بالاتری پیدا می‌کنند، فرومون بیشتری بر روی مسیرهایی که طی کرده‌اند ترشح می‌کنند. برای جلوگیری از ایستایی و تشویق به اکتشاف، فرومون‌ها با نرخ مشخصی تبخیر می‌شوند. این مراحل برای چندین تکرار انجام می‌شوند تا زمانی که یک معیار خاتمه‌دهنده مانند رسیدن به یک راه حل بهینه یا نزدیک به بهینه برآورده شود [۱۶]. به روزرسانی فرومون در ACO به دو شکل انجام می‌شود: به روزرسانی سراسری و محلی. در به روزرسانی سراسری، فرمول زیر استفاده می‌شود:

$$(۱.۲) \quad \tau_{ij}^{(t+1)} = (1 - \rho) \cdot \tau_{ij}^{(t)} + \sum_{k=1}^N \Delta \tau_{ij}^k$$

که در آن:

- τ_{ij}^k سطح فرومون بر روی لبه (i, j) در تکرار t است،
- ρ نرخ تبخیر است که مقدار فرومونی که از ردپای تبخیر می‌شود را نشان می‌دهد،
- $\Delta \tau_{ij}^k$ مقدار فرومونی است که توسط مورچه k بر روی لبه (i, j) ترشح می‌شود،
- N تعداد کل مورچه‌ها است [۸].

در به روزرسانی محلی، مقدار کمی فرومون بلافاصله پس از عبور مورچه‌ها از لبه‌ها ترشح می‌شود، بدون توجه به کیفیت راه حل. فرمول به روزرسانی محلی به این صورت است:

$$(۲.۳) \quad \tau_{ij}^{(t+1)} = (1 - \alpha) \cdot \tau_{ij}^{(t)} + \alpha \cdot \tau.$$

که در آن:

- α ضریب به روزرسانی محلی است که مقدار فرومونی که به صورت محلی ترشح میشود را تعیین می‌کند،
- τ یک ثابت است که نشان‌دهنده سطح اولیه فرومون بر روی لبه‌ها است،
- $\tau_{ij}^{(t)}$ سطح فرومون بر روی لبه (i, j) قبل از به روزرسانی محلی است.

تعادل بین به روزرسانی‌های سراسری و محلی، و همچنین انتخاب پارامترهایی مانند نرخ تبخیر و ضریب به روزرسانی محلی، نقش‌های مهمی در همگرایی و عملکرد الگوریتم ACO ایفا

می‌کنند. این پارامترها اغلب به صورت تجربی تنظیم می‌شوند تا نتایج بهینه برای موارد خاص مسئله به دست آید [۲۱].

۲.۳. یادگیری تقویتی. یادگیری تفاوت زمانی^۱ (TD Learning) یک مفهوم کلیدی در یادگیری تقویتی است که عناصری از برنامه‌ریزی پویا و روش‌های مونت کارلو را ترکیب می‌کند. این روش برای برآورد تابع ارزش یک سیاست بر اساس تجربیات جمع‌آوری شده از تعاملات با محیط استفاده می‌شود. در یادگیری TD، یک عامل با به‌روزرسانی تخمین‌های ارزش خود بر اساس تفاوت زمانی بین تخمین‌های متوالی، یاد می‌گیرد. این تفاوت، که اغلب به صورت δ نشان داده می‌شود، نمایانگر اختلاف بین ارزش پیش‌بینی شده و ارزش واقعی مشاهده شده از محیط است [۱]. خطای TD (δ) معمولاً به‌عنوان تفاوت بین مجموع پاداش فوری و ارزش تخمینی حالت بعدی، منهای ارزش تخمینی حالت فعلی تعریف می‌شود. به‌طور ریاضی، این خطا به‌صورت زیر بیان می‌شود:

$$\delta = r + \gamma V(s') - V(s) \quad (۳.۳)$$

که در آن:

- γ خطای تفاوت زمانی است.
- r پاداش فوری دریافت شده پس از انتقال از حالت s به حالت s' است.
- δ ضریب تخفیف است که اهمیت پاداش‌های آینده را تعیین می‌کند.
- $V(s)$ و $V(s')$ ارزش تخمینی حالت‌های s و s' هستند [۲۲].

الگوریتم‌های یادگیری TD، مانند TD(0) و Q-learning، از این خطای TD برای به‌روزرسانی تخمین‌های ارزش به‌صورت تکراری استفاده می‌کنند. با به‌روزرسانی تخمین‌های ارزش بر اساس پاداش‌های مشاهده شده و پیش‌بینی‌ها، یادگیری TD به عامل اجازه می‌دهد تا به‌طور کارآمد از تجربیات خود یاد بگیرد، بدون نیاز به دانش کامل از دینامیک‌های محیط. این ویژگی باعث می‌شود که یادگیری TD در بسیاری از مسائل یادگیری تقویتی که شامل تعاملات پیوسته با محیط هستند، کاربردی و مؤثر باشد [۶].

۳.۳. اطلاعات متقابل. اطلاعات متقابل^۲ (MI) یک مفهوم اساسی در تئوری اطلاعات است که میزان اطلاعاتی را که یک متغیر تصادفی در مورد متغیر تصادفی دیگر در خود دارد اندازه‌گیری می‌کند. میزان وابستگی یا همبستگی بین دو متغیر تصادفی را تعیین می‌کند. از

^۱Temporal Difference

^۲Mutual Information

نظر ریاضی، اطلاعات متقابل $I(X; Y)$ بین دو متغیر تصادفی X و Y به صورت زیر تعریف می‌شود:

$$(۴.۳) \quad I(X; Y) = \sum_{x \in X} \sum_{y \in Y} p(x, y) \log\left(\frac{p(x, y)}{p(x) \cdot p(y)}\right)$$

یا به طور معادل از نظر آنتروپی:

$$(۵.۳) \quad I(X; Y) = H(X) + H(Y) - H(X, Y)$$

که در این فرمول:

- $p(x, y)$ تابع جرم (یا چگالی) مشترک X و Y است.
- $p(x)$ و $p(y)$ به ترتیب توابع جرم (یا چگالی) احتمال حاشیه‌ای X و Y هستند.
- $H(X)$ و $H(Y)$ به ترتیب آنتروپی‌های X و Y هستند.
- $H(X, Y)$ آنتروپی مشترک X و Y است [۲].

۴.۳. تشابه کسینوسی. تشابه کسینوس^۱ که یک مفهوم ریاضی است که اغلب برای تعیین کمیت شباهت بین دو بردار در فضایی با ابعاد بالا استفاده می‌شود. شباهت کسینوس به ویژه در زمینه تجزیه و تحلیل داده‌ها، متن کاوی و سیستم‌های توصیه محبوب است. با توجه به دو بردار A و B در یک فضای n بعدی، شباهت کسینوس بین آنها به عنوان کسینوس زاویه بین دو بردار محاسبه می‌شود. از نظر ریاضی به صورت زیر تعریف می‌شود [۲]:

$$(۶.۳) \quad Sc(A, B) = \frac{A \cdot B}{\|A\| \cdot \|B\|}$$

که در این فرمول:

- نشان دهنده حاصلضرب نقطه بین دو بردار است.
- $\| \|$ نشان دهنده هنجار (یا قدر) اقلیدسی بردار است.

۵.۳. منطق فازی. منطق فازی با ارائه چارچوبی برای کار با عدم قطعیت و ابهام، امکان تحلیل و کنترل سیستم‌های پیچیده را فراهم می‌کند و به طراحی سیستم‌هایی کمک می‌کند که بهتر با شرایط واقعی و غیرقطعی سازگار شوند. این منطق شامل چند مؤلفه اصلی است؛ مجموعه‌های فازی که به عناصر اجازه می‌دهند به درجات مختلفی عضو یک مجموعه باشند [۱۴]، توابع عضویت که تعیین می‌کنند هر عنصر چه درجه‌ای از عضویت را دارد، و قواعد

¹Cosine Similarity

فازی که روابط بین ورودی‌ها و خروجی‌ها را به صورت "اگر-آنگاه" تعریف می‌کنند. همچنین، استنتاج فازی به کمک این قواعد و توابع عضویت، خروجی‌های سیستم را محاسبه می‌کند که در روش رایج برای آن وجود دارد: استنتاج ممدانی و تاکاگی-سوگنو. در نهایت، دیفازی‌سازی خروجی‌های فازی را به مقادیر دقیق تبدیل می‌کند تا بتوان از نتایج در دنیای واقعی استفاده کرد. این منطق به طور گسترده در کنترل سیستم‌ها، تشخیص الگو، تصمیم‌گیری و پیش‌بینی به کار می‌رود [۱۵].

۴. روش پیشنهادی

در این بخش، الگوریتم پیشنهادی برای انتخاب ویژگی بین داده‌های چند برچسبی با استفاده از روش الگوریتم ACO مبتنی بر یادگیری تقویتی ارائه می‌شود. همانطور که در بخش ۳ گفته شد در الگوریتم ACO با استفاده از به‌روزرسانی مقادیر فرمون‌ها، مورچه‌ها و راه‌حل‌ها بهترین ویژگی‌ها انتخاب می‌شوند.

به طور کلی، مورچه‌ها در ACO از یک گراف کاملاً متصل بدون جهت عبور می‌کنند. در اینجا، گره‌های گراف ویژگی‌های داده‌ها هستند و یال‌ها ارتباط بین ویژگی‌ها را نشان می‌دهند. روش پیشنهادی شامل هیچ الگوریتم یادگیری نیست، و بنابراین، یک رویکرد فیلتر است. مدل فرومونی جزء اصلی الگوریتم‌های ACO است که برای ساخت راه‌حل‌های خوب استفاده می‌شود [۴]. در روش پیشنهادی، هر مورچه مقدار فرمون خود را روی گره‌های گراف (ویژگی‌ها) ذخیره می‌کند و یک بردار d بعدی به نام دنباله فرمون تشکیل می‌دهد. مقدار اولیه دنباله فرمون بر عملکرد ACO تأثیر می‌گذارد. به طور معمول، مقداردهی اولیه دنباله فرمون با همان مقدار ثابت، همگرایی ACO را کند می‌کند. در اینجا برای سرعت بخشیدن به همگرایی الگوریتم و بهبود عملکرد الگوریتم، به جای مقداردهی اولیه بردار فرمون و ماتریس V با یک مقدار ثابت با استفاده از روابط تشابه کسینوسی و ارتباط متقابل مقادیر اولیه را محاسبه می‌کنیم، به این ترتیب هر مورچه مسیریابی بهتری خواهد داشت. این روش انتخاب نشان داده است هرچه دقیق‌تر بتوان میزان همبستگی و ارتباط داده‌های ماتریس فرمون و V را حساب کرد ACO با بهتری خواهد داشت.

شکل ۱ فلوچارت الگوریتم پیشنهادی FCR-ACO را نشان می‌دهد که با استفاده از الگوریتم ACO و منطق فازی برای انتخاب ویژگی‌های چندبرچسبی طراحی شده است. ابتدا، مجموعه داده ورودی پردازش شده و ویژگی‌های اولیه برای بررسی انتخاب می‌شوند. سپس با استفاده از تشابه کسینوسی، ارتباط و اطلاعات متقابل بین ویژگی‌ها محاسبه می‌شود و از این اطلاعات برای

به روزرسانی فرمونها در الگوریتم کلونی مورچگان استفاده می‌گردد. در هر تکرار، الگوریتم به انتخاب ویژگی‌های بهینه می‌پردازد. در نهایت، ویژگی‌های انتخاب شده برای ارزیابی و بهبود دقت دسته‌بندی مورد استفاده قرار می‌گیرند و نتایج نهایی ارائه می‌شود.

روش به روزرسانی فرمون با تعریف یک بردار d بعدی به نام شمارش ویژگی مورچه انجام شده است که وقتی هر مورچه از یک ویژگی بازدید می‌کند، افزایش می‌یابد. ماتریس فرمون برای الگوریتم براساس تصمیم‌گیری هر مورچه برای به روزرسانی فرمون ساخته می‌شود که در این مرحله برای هر مورچه مقدار فرمون با توجه به ارتباط کلاسیک فازی محاسبه می‌شود. به عبارت دیگر رابطه کلاسیک فازی محاسبه شده برای یک مورچه با دیگر مورچه‌ها در هر مرحله متفاوت می‌باشد و همین امر باعث می‌شود که بر پایه این ارتباط جزئی‌ترین تصمیم‌ها الگوریتم گرفته شود. پس از اینکه مورچه‌ها راه حل‌های خود را به طور کامل ساختند، با استفاده از ارتباط فازی بین داده‌های به دست آمده در به روزرسانی فرمون از الگوریتم ۱ برای به روزرسانی مقدار فرمون برای هر ویژگی استفاده می‌شود.

الگوریتم شماره ۱: به روزرسانی فرمون

به روزآوری فرمون

برای هر مورچه رابطه کلاسیک فازی را محاسبه کنید

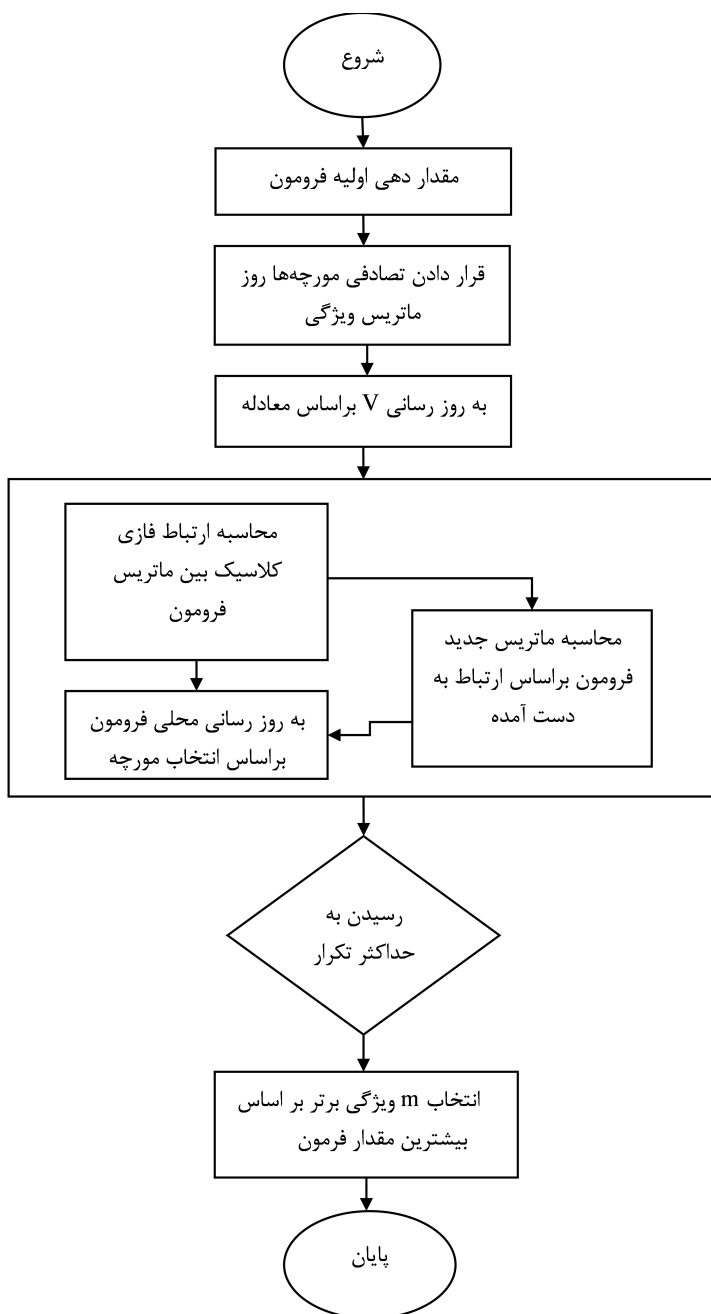
به روزرسانی مقدار فرمون بر اساس مقدار فازی آن با دیگر یال‌های گراف

انتخاب مسیر برای هر مورچه براساس فرمون به دست آمده

تبخیر فرمون

پایان به روزرسانی فرمون

همچنین با استفاده از مفهوم یادگیری تقویتی در هر بار تکرار حرکت مورچه ماتریس V به روزرسانی می‌شود. این یک تابع فراابتکاری در الگوریتم ACO می‌باشد. در روش پیشنهادی، در ابتدا، مورچه‌ها به طور تصادفی روی ویژگی‌ها قرار می‌گیرند و هر مورچه با بازدید از ویژگی‌های مختلف در فضای جستجو با استفاده از قوانین انتقال حالت حریصانه و احتمالی، راه حلی را می‌سازد. بر اساس قوانین تنظیم شده، ارتباط بین اکتشاف و بهره‌برداری را با اعمال اطلاعات اکتشافی و فرمونی متعادل می‌کند. در الگوریتم شماره ۲ نحوه حرکت مورچه‌ها برای رسیدن به نتیجه نشان داده شده است.



شکل ۱. فلوجارت الگوریتم پیشنهادی

الگوریتم شماره ۲: الگوریتم FCR-ACO
<p>ورودی‌ها:</p> <ul style="list-style-type: none"> - دیتاست D با ویژگی‌های X و برجسب‌های Y - تعداد مورچه‌ها N - تعداد تکرارها T - پارامترهای ACO (ρ, β, α) - پارامترهای یادگیری تقویتی (ϵ, γ) - پارامترهای منطق فازی <p>خروجی:</p> <ul style="list-style-type: none"> - مجموعه ویژگی‌های انتخاب شده S
<p>شروع:</p> <p>۱. مقداردهی اولیه:</p> <ul style="list-style-type: none"> - مقداردهی اولیه فرمون‌ها برای هر ویژگی در X (معادله (۴.۳)) - ایجاد ماتریس ارزش (V) با مقادیر اولیه (معادله (۶.۳)) - تعریف قوانین فازی برای به‌روزرسانی فرمون‌ها - ایجاد جمعیت اولیه مورچه‌ها <p>۲. برای هر تکرار t از ۱ تا T:</p> <p>۱.۲. برای هر مورچه i از ۱ تا N:</p> <ul style="list-style-type: none"> - انتخاب ویژگی‌ها بر اساس فرمون‌ها و ماتریس (V): - به‌روزرسانی فرمون‌ها (معادله (۲.۳)) و ماتریس (V) بر اساس یادگیری تقویتی (معادله (۳.۳)) و منطق فازی: - محاسبه پاداش بر اساس اکیورسی - به‌روزرسانی فرمون‌ها برای ویژگی‌های انتخاب شده با استفاده از α و ρ - استفاده از منطق فازی برای تنظیم میزان به‌روزرسانی فرمون‌ها: - ورودی‌های سیستم فازی: اکیورسی، تعداد ویژگی‌های انتخاب شده - محاسبه خروجی فازی: مقدار تنظیم فرمون - به‌روزرسانی فرمون‌ها بر اساس خروجی فازی (معادله (۱.۳)) - به‌روزرسانی مقادیر (V) بر اساس پاداش دریافت شده: <p>۲.۲. کاهش مقدار ϵ برای اکتشاف کمتر و بهره‌برداری بیشتر</p> <p>۳. انتخاب بهترین مجموعه ویژگی‌ها بر اساس بیشترین مقدار فرمون‌ها و ماتریس (V)</p> <p>پایان</p>

۵. نتایج شبیه‌سازی

در این بخش به بررسی نتایج برای و خروجی الگوریتم FCR-ACO^۱ در قالب نمودار می‌پردازیم.

۱.۵. مجموعه داده‌ها. برای بررسی عملکرد الگوریتم پیشنهادی در مقایسه با روش‌های دیگر از پنج داده چند برچسبی استفاده شده است. در جدول ۲ اطلاعات داده‌ها مشاهده می‌شود:

جدول ۲. مشخصات مجموعه داده‌ها

نام مجموعه داده	تعداد نمونه‌های آموزشی	تعداد ویژگی‌ها	تعداد برچسب‌ها	مرجع
Birds	۶۴۵	۲۵۸	۲۱	[۲۴]
Art	۵۰۰۰	۴۶۸	۲۶	[۲۴]
Scene	۲۴۰۷	۲۹۴	۶	[۲۵]
Science	۵۰۰۰	۷۴۳	۴۰	[۲۴]
Chess	۱۶۷۵	۸۱۲	۲۲۷	[۲۴]
Coffee	۲۲۵	۱۷۶۳	۱۲۳	[۲۴]
language	۱۴۵۹	۱۰۰۴	۷۵	[۲۵]
Image	۲۰۰۰	۲۹۴	۵	[۲۵]

۲.۵. تنظیم پارامترها. برای پیش‌بینی برچسب‌های مرتبط با استفاده از الگوهای ضمنی میان داده‌ها، از کلاس‌بندی‌کننده معروف و پرکاربرد چندبرچسبی^۲ (MLKNN) استفاده کردیم. این کلاس‌بندی‌کننده از روش نزدیکترین KNN که به‌طور خاص برای داده‌های چندبرچسبی طراحی شده است، استفاده می‌کند و مجموعه برچسب‌های یک نمونه دیده‌نشده را بر اساس اطلاعات به‌دست‌آمده از همسایگی آن نمونه پیش‌بینی می‌کند. عناصر کلیدی استفاده‌شده در این الگوریتم شامل آمارهای تعداد عضویت و کاربرد اصل حداکثر احتمال پسینی است. در مطالعه ما، اندازه همسایگی را $K = 10$ تنظیم کردیم که تعادلی بین اطلاعات محلی و سراسری برای پیش‌بینی برچسب‌ها فراهم می‌کند.

الگوریتم‌های RL و ACO شامل چندین پارامتر هستند که برای دستیابی به عملکرد بهینه باید به‌دقت تنظیم شوند. از طریق آزمایش‌های گسترده، مقادیر مناسب برای این پارامترها را

^۱Fuzzy Classic Relation – Ant Colony Optimization

^۲Multi Label K-Nearest Neighbors

تعیین کردیم که در جدول ۳ برای مجموعه داده‌های استفاده شده در این مطالعه فهرست شده‌اند. برای الگوریتم ACO، پارامترهای مهم شامل تعداد مورچه‌ها (nAnt)، تعداد چرخه‌های عبور گرافی که هر مورچه انجام می‌دهد (nCycle)، تعداد ویژگی‌هایی که هر مورچه می‌تواند در هر چرخه مشاهده کند (NF)، و نرخ تبخیر فرومون در هر حرکت (ρ) است. این پارامترها تعادل بین اکتشاف و بهره‌برداری را در چارچوب ACO تحت تأثیر قرار می‌دهند.

در تابع اکتشافی و بخش یادگیری تقویتی، پارامترهای اساسی شامل نرخ یادگیری (α)، نرخ تخفیف (γ)، و پارامتر β هستند. این مقادیر دینامیک‌های یادگیری و فرآیند به‌روزرسانی در چارچوب RL را کنترل می‌کنند. پارامتر m نشان‌دهنده ارزش ویژگی‌های نهایی منتخب است که منعکس‌کننده مهم‌ترین ویژگی‌های شناسایی شده از طریق فرآیند یادگیری نیمه‌نظارتی است.

جدول ۳. تنظیم پارامتر الگوریتم پیشنهادی

پارامتر	توضیحات	مقدار
α	The Learning rate of TD(0)	0.5
ρ	Pheromone decay rate	0.2
γ	The Discount rate of TD(0)	0.8
nCycle	Number of iteration that the algorithm should repeat	25
nAnt	Number of ants that search the features space	5
NF	Number of features each ant should traverse	$\frac{1}{8}d \leq NF \leq \frac{1}{6}d$
q	Exploration-exploitation coefficient	0.7
β	The trade-off between heuristic information and pheromone	1
m	Number of top features that should be selected	$10 < m < 100$

۳.۵. معیارهای ارزیابی. در زبان ماشینی، دو مفهوم مهم به نام‌های “دقت” (Accuracy) و “زیان همینگ” (Hamming Loss) وجود دارد که در ارزیابی عملکرد مدل‌های آموزش دیده برای مسائل دسته‌بندی چند برجسی مورد استفاده قرار می‌گیرند. دقت به عنوان یک معیار ساده و متداول برای ارزیابی عملکرد مدل استفاده می‌شود. این معیار نسبت تعداد نمونه‌هایی را که به درستی دسته‌بندی شده‌اند به کل تعداد نمونه‌ها نشان می‌دهد. به طور ریاضی دقت به صورت زیر تعریف می‌شود [۱۷]:

$$(۱.۵) \quad Accuracy = \frac{\text{تعداد نمونه درست‌های دسته‌بندی شده}}{\text{تعداد کل نمونه‌ها}} \times ۱۰۰$$

دقت به عنوان یک معیار ساده و متداول استفاده می‌شود در حالی که زیان همینگ برای مواردی که برچسب‌ها چندین برچسب دارند مفیدتر است، زیرا دقت ممکن است در مواقعی که داده‌ها دارای چندین برچسب هستند، به خوبی نشان دهنده‌ی عملکرد مدل نباشد. زیان همینگ یک معیار برای اندازه‌گیری عملکرد مدل در مسائل دسته‌بندی چند برچسبی است. این معیار میزان اختلاف بین برچسب‌های واقعی و پیش‌بینی شده را اندازه‌گیری می‌کند. این معیار مقداری بین ۰ و ۱ دارد، که مقادیر کمتر نشان دهنده عملکرد بهتر مدل هستند. به طور ریاضی همینگ باخت به صورت زیر تعریف می‌شود که در آن (N) تعداد نمونه‌ها است [۲۳]:

$$(۲.۵) \quad Hamming\ loss = \frac{۱}{N} \sum_{i=1}^N \frac{\text{برچسب واقعی‌ها و پیش‌بینی شده متفاوت}}{\text{تعداد کل برچسب‌ها}} \times ۱۰۰$$

۴.۵. نتایج شبیه‌سازی. روش پیشنهاد شده در این مقاله را با ۶ الگوریتم دیگر، شامل MSSL، MCLS، PPT-MI، Ant-TD، Cluster، LRFS و برای داده‌های یکسان در معیارهای دقت و زیان همینگ مقایسه کرده‌ایم. به این منظور همسایگی را برای محاسبه همبستگی‌ها ۱۰ در نظر گرفته‌ایم. همچنین از ۶۰ درصد داده‌ها به صورت تصادفی برای آموزش و از ۴۰ درصد باقیمانده برای تست استفاده کرده‌ایم. برای بررسی عملکرد روش پیشنهادی برای تعداد ویژگی‌های {۱۰، ۲۰، ۳۰، ۴۰، ۵۰، ۶۰، ۷۰، ۸۰، ۹۰، ۱۰۰} تایی از هر مجموعه داده را تحت نظر گرفته‌ایم که در این روش تعداد ویژگی‌های انتخابی توسط کاربر می‌تواند تغییر کند.

جدول ۴ به بررسی دقت میانگین ۱۰ دسته‌بندی بالا برای روش پیشنهادی ۶ الگوریتم معرفی شده پرداخته است. همانطور که مشاهده می‌شود استفاده از رابطه فازی کلاسیک در ACO مبتنی بر یادگیری تقویتی علاوه بر بهبود دقت، باعث برتری آن نسبت به سایر روشهای انتخاب ویژگی در داده‌های چند برچسبی شده است.

شکل ۲ نشان دهنده نمودار مقایسه دقت انتخاب ویژگی در داده‌های چند برچسبی برای روش پیشنهادی با ۶ روش معرفی شده دیگر را نشان می‌دهد. این شکل نشان‌دهنده آن می‌باشد که در اکثر موارد الگوریتم پیشنهادی برتر از سایر روش‌های معرفی شده می‌باشد.


جدول ۴. میانگین دقت ۱۰ زیر دسته (عدد بزرگتر نشان دهنده دقت بالاتر می‌باشد)

	FCR-ACO	Ant-TD	PPT-MI	MSSL	Cluster	LRFS	MCLS
Coffee	0.0485	0.0463	0.0033	0.0064	0.0057	0.0042	0.0207
Chess	0.1553	0.1496	0.0782	0.1068	0.0700	0.0701	0.0593
Arts	0.1122	0.1038	0.0415	0.1109	0.0244	0.0139	0.0520
Language	0.1598	0.1551	0.1252	0.0018	0.0243	0.0057	0.0182
Science	0.0360	0.0339	0.0113	0.0229	0.0111	0.0026	0.0110
Scene	0.4131	0.4019	0.0952	0.2863	0.1821	0.1984	0.1277
Birds	0.4234	0.4156	0.3085	0.2171	0.2279	0.3055	0.2290
Image	0.2980	0.2933	0.1246	0.2007	0.1861	0.2364	0.1445
Average	0.2058	0.1999	0.0984	0.1191	0.0914	0.1046	0.0828


جدول ۵ به بررسی میانگین ۱۰ زیر دسته انتخاب شده در معیار زیان همینگ می‌پردازد. با توجه به جدول مشاهده می‌شود استفاده از منطق فازی در ACO مبتنی بر یادگیری تقویتی باعث کاهش زیان همینگ در مقایسه با سایر روش‌های انتخاب ویژگی در داده‌های چند برچسبی شده است.

جدول ۵. میانگین زیان همینگ برای ۱۰ زیر دسته (عدد کمتر نشان‌دهنده زیان کمتر می‌باشد)


	FCR-ACO	Ant-TD	PPT-MI	MSSL	Cluster	LRFS	MCLS
Coffee	0.0138	0.0142	0.0161	0.0163	0.0163	0.0163	0.0162
Chess	0.0071	0.0071	0.0101	0.0100	0.0103	0.0102	0.0103
Arts	0.0613	0.0621	0.0619	0.0594	0.0626	0.0622	0.0617
Language	0.0155	0.0154	0.0158	0.0158	0.0158	0.0158	0.0157
Science	0.0360	0.0361	0.0430	0.0429	0.0429	0.0431	0.0430
Scene	0.1252	0.1300	0.2845	0.2393	0.2645	0.2590	0.2803
Birds	0.0528	0.0533	0.0523	0.0618	0.0621	0.0522	0.0611
Image	0.1998	0.2098	0.3499	0.3290	0.3341	0.3290	0.3500
Average	0.0639	0.0660	0.1042	0.0968	0.1010	0.0984	0.1047




ب) Birds




ا) Image




د) Coffee




ج) Science




و) Chess



ه) Language



ح) Scene



ز) Arts

شکل ۲. نمودار دقت بر حسب تعداد ویژگی‌های انتخاب شده

شکل ۳ شامل ۸ نمودار برای دیتاست‌های معرفی شده برای مقایسه الگوریتم پیشنهادی با ۶ روش دیگر انتخاب ویژگی در داده‌های چند برجسبی می‌باشد. همانطور که در شکل مشاهده می‌شود الگوریتم پیشنهادی زیان همینگ کمتری نسبت به سایر روش‌ها از خود نشان داده است.


در جدول ۶، پیچیدگی زمانی روش‌های مختلف برای انتخاب ویژگی‌های چند برجسبی به تفکیک آورده شده است:

جدول ۶. مقایسه پیچیدگی محاسباتی روش پیشنهادی با سایر روش‌ها

روش	پیچیدگی محاسباتی
FCR-ACO	$O(N \cdot T \cdot M + S \cdot A \cdot T + F \cdot N \cdot M)$
Ant-TD	$O(N \cdot T \cdot M + S \cdot A \cdot T + F \cdot M)$
Cluster	$O(N^2 \cdot K)$
PPT-MI	$O(N^2 + N \cdot M)$
LRFS	$O(NML + N \cdot M^2)$
MCLS	$O(N^2(M+K) + N^2 \cdot M)$
MSSL	$O(N \cdot M^2)$

- N: تعداد نمونه‌های داده‌ها.
- T: تعداد تکرارهای الگوریتم.
- M: تعداد ویژگی‌ها یا ابعاد داده.
- S: تعداد وضعیت‌ها یا حالت‌ها در الگوریتم یادگیری تقویتی.
- A: تعداد اقدامات یا عمل‌های ممکن در الگوریتم یادگیری تقویتی.
- F: تعداد ویژگی‌های فازی یا تعداد قوانین فازی در سیستم فازی.
- K: تعداد خوشه‌ها در الگوریتم خوشه‌بندی.
- L: تعداد برجسب‌ها.

روش پیشنهادی با ترکیب ACO، یادگیری تقویتی، و سیستم‌های فازی، دارای پیچیدگی محاسباتی بالاتری نسبت به اکثر روش‌های دیگر است. این پیچیدگی بالا به دلیل نیاز به هماهنگی میان الگوریتم‌های مختلف و پردازش داده‌های پیچیده است. روش پیشنهادی می‌تواند نیاز به منابع محاسباتی بیشتری داشته باشد، اما در عوض، توانایی‌های بهینه‌سازی و دقت بالاتری را ارائه می‌دهد.



Birds (ب)







Image (ا)




Coffee (د)




Science (ج)




Chess (و)



Language (ه)



Scene (ح)



Arts (ز)

شکل ۳. نمودار زیان همینگ بر حسب تعداد ویژگی‌های انتخاب شده

در داده‌های Chess و Coffee، که بیشترین تعداد برچسب را در میان مجموعه‌های معرفی شده دارند، مشاهده می‌شود که با افزایش تعداد نمونه‌های مورد بررسی، الگوریتم کندتر می‌شود. این امر نشان‌دهنده پیچیدگی بالای این داده‌ها به دلیل تعداد زیاد برچسب‌هاست که پردازش و تحلیل آن‌ها زمان بیشتری می‌طلبد. در مقابل، در مجموعه داده‌های Birds، Scene، Arts، Image و Science، که تعداد برچسب‌های کمتری دارند، با افزایش تعداد ویژگی‌های انتخاب شده، نمودار دقت به صورت صعودی و نمودار زیان همینگ به صورت نزولی پیش می‌رود. این نشان می‌دهد که الگوریتم با انتخاب ویژگی‌های مناسب‌تر در این مجموعه‌ها عملکرد بهتری از نظر دقت دارد. در مجموعه داده Language که تعداد برچسب‌ها در حد واسطه بین دو گروه قبلی قرار دارد، نمودار دقت صعودی و نمودار زیان همینگ به صورت نزولی می‌باشد، اما سرعت افزایش دقت در مقایسه با داده‌های دارای برچسب کمتر، پایین‌تر است. این نشان می‌دهد که هرچه تعداد برچسب‌ها افزایش یابد، سرعت بهبود دقت کاهش می‌یابد، اما همچنان الگوریتم با انتخاب ویژگی‌های صحیح عملکرد خود را بهبود می‌بخشد، اگرچه شیب کمتری نسبت به داده‌ها با تعداد برچسب پایین‌تر دارد.

بر اساس نتایج به دست آمده در مقایسه معیار دقت و زیان همینگ مشاهده می‌شود روش پیشنهادی FCR-ACO بهتر از سایر روش‌های معرفی شده عمل کرده است. علت این امر به عقیده ما استفاده از ارتباط فازی در هنگام به‌روزرسانی فرامون‌ها در ACO مبتنی بر یادگیری تقویتی می‌باشد. الگوریتم Ant-TD کارایی خود را نسبت به دیگر روش‌های دسته‌بندی داده‌های چند برچسبی نشان داده است. در روش پیشنهاد شده هنگام به‌روزرسانی فرامون برای محاسبه مسیر توسط مورچه‌ها ارتباط فازی را تاثیر داده‌ایم که با توجه به نتایج به دست آمده استنباط می‌شود هنگام بررسی داده‌ها برای به‌روزرسانی مسیر حرکت مورچه‌ها استفاده همزمان از چند همبستگی داده‌ها بسیار بهتر عمل میکند. ارتباط و همبستگی خطی بخشی از قدرت تصمیم‌گیری الگوریتم می‌باشد و ارتباط و همبستگی فازی در داده‌ها بسیار مفیدتر عمل می‌کند. این عامل در هیچ یک از روش‌های دیگر لحاظ نشده است و همین امر باعث برتری روش استفاده از ارتباط فازی بین داده‌ها در الگوریتم ACO مبتنی بر یادگیری تقویتی نسبت به سایر روش‌های گفته شده می‌باشد.

استفاده از منطق فازی در به‌روزرسانی فرامون‌ها باعث شده است که این فرآیند با دقت بیشتری انجام شود. منطق فازی با در نظر گرفتن عدم قطعیت‌ها و درجات مختلف عضویت، به بهبود دقت انتخاب ویژگی‌ها کمک می‌کند. به این ترتیب، سیستم فازی می‌تواند به طور دقیق‌تر و انعطاف‌پذیرتری تغییرات لازم در فرامون‌ها را اعمال کند. علاوه بر این، ACO که بر

اساس یادگیری تقویتی تنظیم شده است، باعث شده که فرآیند جستجوی ویژگی‌ها بهینه‌تر انجام شود. یادگیری تقویتی به مورچه‌ها کمک می‌کند که از تجربیات گذشته خود بیاموزند و به سمت انتخاب ویژگی‌هایی حرکت کنند که بیشترین پاداش را دارند. این امر باعث افزایش کارایی در انتخاب ویژگی‌های مهم و کاهش تداخل ویژگی‌های نامربوط می‌شود. ترکیب این دو روش به گونه‌ای است که:

(۱) افزایش دقت انتخاب ویژگی‌ها: منطق فازی با در نظر گرفتن تمامی شرایط ممکن،

انتخاب ویژگی‌ها را بهبود می‌بخشد.

(۲) کاهش تداخل ویژگی‌ها: ACO با یادگیری تقویتی، ویژگی‌های کم‌اهمیت را حذف

کرده و تنها ویژگی‌های مهم را انتخاب می‌کند.

(۳) بهینه‌سازی بهتر: ترکیب منطق فازی و ACO با یادگیری تقویتی باعث می‌شود که

فرآیند بهینه‌سازی با دقت و سرعت بیشتری انجام شود.

این دلایل توضیح می‌دهند که چرا روش پیشنهادی ما توانسته است در تمامی دیتاست‌ها به طور مداوم بهترین نتایج را در مقایسه با سایر روش‌ها به دست آورد.

یکی از محدودیت‌های اصلی روش پیشنهادی برای انتخاب ویژگی در داده‌های چندبرجسی با استفاده از الگوریتم کلونی مورچگان و منطق فازی، پیچیدگی بالای محاسباتی آن است. این الگوریتم‌ها به دلیل نیاز به جستجوی وسیع در فضای ویژگی‌ها و به‌روزرسانی‌های مکرر، ممکن است زمان و منابع زیادی را مصرف کنند. همچنین، این روش به تنظیم دقیق پارامترهای فازی و الگوریتم کلونی مورچگان حساس است و انتخاب نادرست این پارامترها می‌تواند به عملکرد ضعیف یا عدم همگرایی صحیح منجر شود. علاوه بر این، داده‌های بسیار نویزی یا غیرقابل پیش‌بینی می‌توانند چالش‌هایی را در دقت انتخاب ویژگی ایجاد کنند، و پیاده‌سازی و تنظیم دقیق این الگوریتم‌ها ممکن است پیچیده و نیازمند تخصص‌های خاص باشد.

۶. نتیجه‌گیری

در این مقاله روش انتخاب ویژگی FCR-ACO بر اساس ارتباط فازی داده‌ها برای داده‌های چند برجسی ارائه شد. در این مقاله با استفاده از همبستگی کسینوسی، ارتباط و همبستگی متقابل و ارتباط فازی به عنوان عوامل محاسبه‌گر فرمون در ACO به انتخاب ویژگی پرداختیم. در ادامه نشان دادیم این روش از لحاظ معیارهای دقت و زیان همینگ نسبت به ۶ روش دیگر عملکرد بهتری از خود نشان داده است که این کارایی و بهینه بودن روش ما را نسبت به سایر رقیبان نشان می‌دهد. در سطر آخر جدول‌های شماره ۴ و ۵، میانگین دقت و زیان همینگ برای

۸ مجموعه داده محاسبه شده است. این مقایسه نشان می‌دهد که روش پیشنهادی، FCR-ACO، از لحاظ دقت به طور قابل توجهی بهتر از روش Ant-TD عمل کرده است و همچنین نسبت به سایر روش‌ها افزایش دقتی در حدود ۸ تا ۱۲ درصد را نشان می‌دهد. از لحاظ زیان همینگ نیز، FCR-ACO در مقایسه با Ant-TD عملکرد بهتری داشته و کاهش زیان ۳ تا ۴ درصدی را نسبت به سایر روش‌ها به ثبت رسانده است. این نتایج تأکید بر برتری عملکرد روش پیشنهادی در بهبود دقت و کاهش زیان نسبت به روش‌های دیگر دارد.

شایان ذکر است که داده‌های مورد استفاده در این مقاله واقعی بوده‌اند. به عنوان مثال، داده‌های Birds به شناسایی گونه‌های مختلف پرندگان در محیط‌های نویزی مربوط می‌شود که کاربردهایی در زمینه زیست‌شناسی و محیط‌زیست دارد. همچنین، داده‌های Scene مربوط به تشخیص الگوها و صحنه‌های مختلف است که در زمینه‌های بینایی ماشین و پردازش تصویر کاربرد دارد. این داده‌های واقعی به ما اجازه داده‌اند تا عملکرد الگوریتم پیشنهادی را در شرایط واقعی و پیچیده ارزیابی کنیم.

تحقیقات آینده با تمرکز بر بهبود روش‌های انتخاب ویژگی در داده‌های چندبرچسبی از طریق استفاده گسترده‌تر از منطق فازی می‌تواند مسیرهای جدیدی را در این حوزه ایجاد کند. به ویژه، توسعه و بهبود قواعد فازی برای به‌روزرسانی ماتریس فرمون در الگوریتم‌های کلونی مورچگان، با استفاده از قواعد فازی تطبیقی و سیستم‌های فازی هیبریدی، می‌تواند سرعت همگرایی و دقت الگوریتم را بهبود بخشد. همچنین، ادغام منطق فازی با یادگیری تقویتی می‌تواند دقت به‌روزرسانی‌ها را افزایش دهد و به کاهش نویز در محیط‌های پیچیده کمک کند. علاوه بر این، استفاده از مدل‌های فازی برای مدیریت عدم قطعیت در داده‌های نویزی و چندبرچسبی می‌تواند به نتایج بهتری در انتخاب ویژگی منجر شود. ترکیب منطق فازی با الگوریتم‌های بهینه‌سازی دیگر مانند الگوریتم‌های ژنتیک و شبکه‌های عصبی نیز می‌تواند به بهبود عملکرد و دقت مدل‌ها کمک کند. این مسیرهای تحقیقاتی می‌توانند به توسعه روش‌های پیشرفته‌تر و کاربردی‌تر در انتخاب ویژگی و بهینه‌سازی در محیط‌های پیچیده منجر شوند.

مراجع

- [1] Barto, A. G. (1997). Reinforcement Learning. In *Neural Systems for Control*, O. Omidvar & D. L. Elliott (Eds.). Academic Press.
- [2] Dempster, P., Laird, N. M., & Rubin, D. B. (1977). Maximum likelihood from incomplete data via the EM algorithm. *Journal of the Royal Statistical Society: Series B (Methodological)*, 39(1).
- [3] Dorigo, M., & Stützle, T. (2004). *Ant Colony Optimization*, vol. 2. MIT Press.

- [4] Dorigo, M., Maniezzo, V., & Coloni, A. (1996). Ant system: Optimization by a colony of cooperating agents. *IEEE Transactions on Systems, Man, and Cybernetics: Part B (Cybernetics)*, 26(1).
- [5] Dowlatshahi, M. B., & Hashemi, A. (2023). Unsupervised feature selection: A fuzzy multi-criteria decision-making approach. *Iranian Journal of Fuzzy Systems*.
- [6] François-Lavet, V., Henderson, P., Islam, R., Bellemare, M. G., & Pineau, J. (2018). An Introduction to Deep Reinforcement Learning. *Foundations and Trends® in Machine Learning*, 11(3-4).
- [7] Hashemi, A., & Dowlatshahi, M. B. (2023). A Fuzzy Integral Approach for Ensembling Unsupervised Feature Selection Algorithms. In *2023 28th International Computer Conference, Computer Society of Iran (CSICC)*, Tehran, Iran.
- [8] Hashemi, A., Joodaki, M., Joodaki, N. Z., & Dowlatshahi, M. B. (2022). Ant colony optimization equipped with an ensemble of heuristics through multi-criteria decision making: A case study in ensemble feature selection. *Applied Soft Computing*, 124, 109046.
- [9] Hashemi, A., Pajoohan, M. R., & Dowlatshahi, M. B. (2024). A Multi-Objective Optimization Approach for Online Streaming Feature Selection Using Fuzzy Pareto Dominance. *Journal of Mahani Mathematical Research Center*, 13(1), 467.
- [10] Hashemi, A., Dowlatshahi, M. B., & Nezamabadi-Pour, H. (2020). MFS-MCDM: Multilabel feature selection using multi-criteria decision making. *Knowledge-Based Systems*, 206, 106365.
- [11] Hashemi, A., Dowlatshahi, M. B., & Nezamabadi-Pour, H. (2022). Ensemble of feature selection algorithms: A multi-criteria decision-making approach. *International Journal of Machine Learning and Cybernetics*, 13(1), 49–69.
- [12] Hashemi, A., Dowlatshahi, M. B., & Nezamabadi-Pour, H. (2020). A bipartite matching-based feature selection for multi-label learning. *International Journal of Machine Learning and Cybernetics*.
- [13] Hashemi, A., & Dowlatshahi, M. B. (2024). Exploring Ant Colony Optimization for Feature Selection: A Comprehensive Review. In N. Dey (Ed.), *Applications of Ant Colony Optimization and its Variants*, Springer Tracts in Nature-Inspired Computing. Springer, Singapore.
- [14] Hashemi, A., & Dowlatshahi, M. B. (2022). An Ensemble Of Feature Selection Algorithms Using OWA Operator. In *2022 9th Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS)*, Bam, Iran.
- [15] Hashemi, A., Pajoohan, M. -R., & Dowlatshahi, M. B. (2022). Online streaming feature selection based on Sugeno fuzzy integral. In *2022 9th Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS)*, Bam, Iran.
- [16] Karimi, F., Dowlatshahi, M. B., & Hashemi, A. (2023). SemiACO: A semi-supervised feature selection based on ant colony optimization. *Expert Systems with Applications*, 214, 119130.

- [17] Li, Y., et al. (2013). Parallel ant colony optimization on graphics processing units. *IEEE Transactions on Evolutionary Computation*, 17(5).
- [18] Miri, M., Dowlatshahi, M. B., & Hashemi, A. (2022). Evaluation of multi-label feature selection for text classification using weighted Borda count approach. In 2022 9th Iranian Joint Congress on Fuzzy and Intelligent Systems (CFIS), Bam, Iran.
- [19] Paniri, M., Dowlatshahi, M. B., & Nezamabadipour, H. (2020). MLACO: A multi-label feature selection algorithm based on ant colony optimization. *Knowledge-Based Systems*, 192, 105285.
- [20] Paniri, M., Dowlatshahi, M. B., & Nezamabadipour, H. (2021). Ant-TD: Ant colony optimization plus temporal difference reinforcement learning for multi-label feature selection. *Swarm and Evolutionary Computation*, 64, 100892.
- [21] Pei, Y., Wang, W., & Zhang, S. (2012). Basic Ant Colony Optimization. In Proc. 2012 International Conference on Computer Science and Electronics Engineering (ICCSEE), Hangzhou, China.
- [22] Sutton, R. S., & Barto, A. G. (2018). *Reinforcement Learning: An Introduction*, 2nd ed. Cambridge, MA, USA: A Bradford Book.
- [23] Socha, K., & Dorigo, M. (2008). Ant colony optimization for continuous domains. *European Journal of Operational Research*, 185(3).
- [24] Tsoumakas, G., Katakis, I., & Vlahavas, I. (2009). Mining multi-label data. In *Data Mining and Knowledge Discovery Handbook*.
- [25] Tsoumakas, G., Spyromitros-Xioufis, E., Vilcek, J., & Vlahavas, I. (2011). Mulan: A Java Library for Multi-Label Learning. *Journal of Machine Learning Research*, 12.
- [26] Wiering, M. A., & Van Hasselt, H. (2007). Two novel on-policy reinforcement learning algorithms based on TD (λ)-methods. In 2007 IEEE International Symposium on Approximate Dynamic Programming and Reinforcement Learning.
- [27] Wu, Y., Ma, W., Miao, Q., & Wang, S. (2019). Multimodal continuous ant colony optimization for multisensor remote sensing image registration with local search. *Swarm Evolutionary Computation*.
- [28] Zadeh, L. A. (2008). Is there a need for fuzzy logic? *Information Sciences*, 178(13), 2751–2779.