

انطباق دامنه ماشین بردار پشتیبان دوقلو با ربع کره تطبیقی وزن‌دار: روشی بدون نیاز به داده منبع و مقاوم در برابر نویز

منا مرادی¹، استادیار، جواد حمیدزاده²، دانشیار

¹ گروه مهندسی کامپیوتر - دانشکده مهندسی - دانشگاه تربت حیدریه - تربت حیدریه - ایران - m.moradi@torbath.ac.ir

² گروه مهندسی کامپیوتر - دانشکده مهندسی کامپیوتر و فناوری اطلاعات - دانشگاه سجاد - مشهد - ایران -

J_Hamidzadeh@sadjad.ac.ir

چکیده: مشکل طبقه‌بندی داده‌های با برچسب کم را می‌توان با استفاده از دانش کسب شده از دامنه دیگر و انطباق آن با دامنه هدف برطرف کرد. با این حال، بیشتر این روش‌ها در محیط‌های دارای نویز، پایداری و مقاومت خود را از دست می‌دهند. این مقاله با هدف مدلسازی ابهام در مسائل طبقه‌بندی دودویی و غیرقابل تمایز بودن داده‌ها در فرآیند انطباق دامنه ارائه شده است. در مدل دوقلوی پیشنهادی برای هر کدام از داده‌های منبع و هدف دو طبقه‌بندی‌کننده ماشین بردار پشتیبان ربع کره در نظر گرفته شده و دو ربع کره به گونه‌ای آموزش می‌بینند که به جای حل یک مسأله برنامه‌ریزی درجه دوم (QPP)، دو معادله خطی حل شوند. در نتیجه، پیچیدگی زمانی مدل کاهش یابد. همچنین با استفاده از نظریه مجموعه‌های فازی راف در وزن‌دهی، نمونه‌های با اطمینان بالا در انطباق دامنه و طبقه‌بندی تأثیر بیشتری خواهند داشت ضمن آن‌که کلاس‌های اقلیت که معمولاً در داده‌ها کمتر حضور دارند، در فرآیند ساخت مدل نادیده گرفته نشوند. از نقاط قوت مدل پیشنهادی این است که پس از ساخت و آموزش طبقه‌بندی‌کننده‌های دامنه منبع، دسترسی به داده‌های منبع دیگر لازم نیست و تنها وجود پارامترهای ربع کره‌های دامنه منبع کفایت می‌کند. کارایی مدل پیشنهادی در مقایسه با روش‌های رقیب، در پانزده وظیفه برگرفته شده از دو مجموعه داده معیار ارزیابی شده است. نتایج آزمایش‌ها نشان می‌دهد که مدل پیشنهادی از نظر دقت طبقه‌بندی و زمان محاسباتی عملکرد برتری دارد. علاوه بر این، تحلیل نویز نشان می‌دهد که مدل پیشنهادی از پایداری بالایی در برابر نویز برخوردار است.

واژه‌های کلیدی: طبقه‌بندی، انطباق دامنه، نظریه مجموعه‌های فازی راف، داده‌های نویزی، ماشین بردار پشتیبان ربع کره، یادگیری انتقالی.

* نویسنده مسئول، ایمیل نویسنده

Adaptive Weighted Twin Quarter-Sphere SVM: A Source-Free and Robust to Noise Domain Adaptation Method

Mona Moradi ¹, Assistant Professor, Javad Hamidzadeh ², Associate Professor

¹ Department of Computer Engineering, University of Torbat Heydarieh, Torbat Heydarieh, Iran, Email: mmoradi0@gmail.com

² Faculty of computer engineering and information technology, Sadjad University, Mashhad, Iran, Email: J_Hamidzadeh@sadjad.ac.ir

Abstract: The challenge of data classification by insufficient labeled data can be solved by domain adaptation techniques and leveraging external knowledge. However, most of these techniques lose robustness in noisy environments where the labels and features become corrupted. Aiming to model the indiscernibility and vagueness in domain adaptation, the present paper introduces a twin model for domain adaptation that combines the quarter-sphere support vector machine data description (QS-SVM) with a new fuzzy rough set-based weighting approach. The proposed model learns two small hyperspheres per domain regarding binary classification by solving two linear equations rather than one Quadratic Programming Problem (QPP), unlike standard QS-SVM. Consequently, the time complexity is reduced by this strategy. The Benefit of the fuzzy rough set is that only the high-confidence samples influence the adaptation and classification results of the hyperspheres. The strength of the proposed model is that after constructing and training the source domain classifiers, accessibility to the source domain data is not required, and the existence of only the source domain hyperspheres is sufficient. Also, the proposed fuzzy rough set-based sample weighting method ensures that the minority classes that are often underrepresented in the dataset are not overlooked when constructing the model. The effectiveness of the proposed model has been compared to the state-of-the-art methods on fifteen tasks taken from two benchmark datasets. The experimental results demonstrate the superiority of the proposed model over state-of-the-art ones in terms of classification accuracy and computational time. Besides, the noise analysis proves the robustness of the proposed model.

Keywords: Classification; Domain adaptation; Fuzzy rough set theory; Noisy data; Quarter-sphere SVM; Transfer learning.

* Corresponding author

1. مقدمه

گرفته‌اند. به‌طور کلی، روش‌های انطباق دامنه را می‌توان در سه گروه طبقه‌بندی کرد: (1) یادگیری انتقالی مبتنی بر معیار فاصله، (2) تطبیق ویژگی‌ها، و (3) وزن‌دهی به نمونه‌ها. بیشتر این روش‌ها، پدیده عدم قطعیت ناشی از کمبود اطلاعات نظارتی را نادیده می‌گیرند. برای غلبه بر این مسئله، پژوهشگران روش‌های یادگیری انتقالی مبتنی بر قواعد فازی را توسعه داده‌اند که قادرند با ابهام و نامعینی داده‌ها در سناریوهای انطباق دامنه مقابله کنند.

در سال‌های اخیر، طبقه‌بندی‌کننده‌های مبتنی بر ماشین بردار پشتیبان (SVM) نیز در انطباق دامنه توسعه یافته‌اند. برای نمونه، ماشین بردار پشتیبان تطبیقی [4]، طبقه‌بندی‌کننده‌ای را آموزش می‌دهد که بتواند بر روی داده‌های دامنه هدف تعمیم یابد. با این حال، یکی از چالش‌های اصلی این طبقه‌بندی‌کننده، نیاز به حل مسأله پیچیده برنامه‌ریزی درجه دوم (QPP) است که هزینه محاسباتی بالایی دارد. در سال‌های اخیر، رویکرد حل دو مسأله QPP کوچکتر به جای یک مسأله بزرگتر مورد توجه قرار گرفته است. به عنوان مثال، مدل ماشین بردار پشتیبان دوقلو [5] و توسعه‌های بعدی آن [6] معرفی شدند که به جای یک ابرصفحه منفرد، دو ابرصفحه غیر موازی برای دو کلاس داده تولید می‌کنند. در نتیجه، به جای حل یک مسأله بهینه‌سازی بزرگ، دو مسأله کوچک‌تر حل می‌شود که در هرکدام تنها داده‌های یک کلاس در قیدهای بهینه‌سازی شرکت دارند. این ویژگی موجب افزایش سرعت آموزش و بهبود تعمیم مدل نسبت به SVM استاندارد می‌شود. در ادامه این رویکرد، دو روش جدید تحت عنوان ماشین بردار پشتیبان دوقلو تطبیقی A-TSVM و A-TSVM+ را برای انطباق دامنه پیشنهاد شد [7]. این روش‌ها نیز دو ابرصفحه غیرموازی در هر دامنه ایجاد می‌کنند، با این تفاوت

روش‌های یادگیری ماشین سنتی عموماً مبتنی بر دو پیش‌فرض اساسی هستند: (1) وجود مقدار کافی از داده‌های برچسب‌دار برای آموزش مدل، و (2) توزیع مشابه داده‌های آموزشی و آزمایشی. با این حال، در بسیاری از کاربردهای واقعی مانند شناسایی فعالیت انسانی، رانندگی خودکار و پردازش داده‌های چنددامنه‌ای، این فرضیات برقرار نیستند. در چنین شرایطی، یا داده‌های برچسب‌دار در دسترس نیستند، یا داده‌ها از دامنه‌هایی با توزیع‌های آماری متفاوت گردآوری می‌شوند. برای مقابله با این چالش، مفهوم یادگیری انتقالی¹ مطرح شده است که در سال‌های اخیر رشد چشمگیری در جامعه یادگیری ماشین یافته است [1]. در این رویکرد، دانش آموخته‌شده از یک دامنه (دامنه منبع) به‌منظور حل مسئله‌ای مرتبط در دامنه‌ای دیگر (دامنه هدف) مورد استفاده قرار می‌گیرد؛ حتی اگر این دو دامنه از فضاها و ویژگی متفاوت یا توزیع‌های آماری ناهمگون برخوردار باشند.

روش‌های یادگیری انتقالی را می‌توان به سه گروه اصلی تقسیم کرد: (1) یادگیری انتقالی استقرایی²، (2) یادگیری انتقالی فاقد ناظر³ و (3) یادگیری انتقالی استنتاجی⁴ [2, 3]. در یادگیری انتقالی استقرایی، داده‌های منبع بدون برچسب بوده و وظایف منبع و هدف متفاوت هستند. در مقابل، در یادگیری انتقالی فاقد ناظر، هر دو دامنه منبع و هدف فاقد برچسب‌اند اما وظایف مشابهی دارند. یادگیری انتقالی استنتاجی به حالتی اشاره دارد که داده‌های دامنه منبع کاملاً برچسب‌دار و داده‌های دامنه هدف بدون برچسب هستند. مفهوم انطباق دامنه⁵ در دسته یادگیری انتقالی استنتاجی جای می‌گیرد، زیرا فرض می‌کند که وظیفه در هر دو دامنه یکسان است اما داده‌ها از توزیع‌های متفاوت منشأ

⁴ Transductive

⁵ Domain Adaptation

¹ Transfer Learning

² Inductive

³ Unsupervised

که A-TSVM+ با بهره‌گیری از اطلاعات ممتاز⁶ نتایج بهتری ارائه می‌دهد. با این حال، ضعف عمده این روش‌ها آن است که مستقیماً در فضای ویژگی‌های اصلی دامنه‌های منبع و هدف عمل نموده و نتایج پیش‌بینی می‌تواند تحت تأثیر داده‌های ناخواسته قرار گیرد.

به منظور دستیابی به انطباق دامنه مقاوم در برابر نویز، مدل پیشنهادی در این پژوهش برای هر دامنه دو ربع کره⁷ (QS-SVM) تعریف می‌کند -مدل دو قلو- و آن‌ها را با روش وزن‌دهی مبتنی بر مجموعه‌های فازی راف⁸ ترکیب می‌نماید تا عملکرد انطباق دامنه و طبقه‌بندی در مسائل دودویی بهبود یابد. هر یک از ربع کره‌ها با حل دو معادله خطی (و نه یک مسأله QPP) آموخته می‌شوند. ایده اصلی این است که یک مرز تصمیم منفرد نمی‌تواند به خوبی یک کلاس داده را مدل‌سازی کند؛ از این رو، استفاده از دو مرز تصمیم برای پوشش بهتر داده‌های هر کلاس منطقی است. افزون بر این، طبقه‌بندی‌کننده‌های دو قلو در برابر داده‌های پرت یا تغییر یافته مقاوم‌تر از یک طبقه‌بندی‌کننده منفرد هستند، زیرا در صورت تأثیر نویز بر یکی از آن‌ها، دیگری همچنان ساختار داده را حفظ می‌کند. انتخاب مدل QS-SVM نیز به دلیل مزیت فرمول‌بندی خطی در مقایسه با بهینه‌سازی درجه دوم در SVM است که موجب کاهش چشمگیر پیچیدگی زمانی می‌شود.

مدل پیشنهادی برای جبران واگرایی میان دو دامنه، تابع اختلاف را معرفی می‌کند که از طریق داده‌های برچسب‌دار دامنه هدف آموزش داده شده و به صورت یک طبقه‌بندی‌کننده دودویی از دو ربع کره تشکیل می‌شود. همچنین، برای افزایش تنوع مدل،

پیش‌بینی‌ها از طریق یادگیری تجمعی⁹ ترکیب می‌شوند تا جنبه‌های مختلف توزیع داده‌ها بهتر پوشش داده شده و سوگیری کاهش یابد.

برای مقابله با عدم قطعیت نمونه‌ها در هر دامنه، مدل پیشنهادی از یک سازوکار وزن‌دهی مبتنی بر نظریه مجموعه‌های فازی راف استفاده می‌کند. در این روش، اعتماد به هر نمونه بر اساس فاصله آن تا مرکز کلاس و با استفاده از تقریب‌های بالا و پایین تعیین می‌شود؛ به گونه‌ای که نمونه‌های با اطمینان پایین وزن کمتری می‌گیرند و نمونه‌های قابل اعتماد با وزن بیشتر در فرآیند یادگیری مشارکت دارند.

نوآوری‌های مدل پیشنهادی به شرح زیر است:

- معرفی یک روش جدید انطباق دامنه دو قلو که برای هر یک از دامنه‌های منبع و هدف، دو کره جداکننده ایجاد می‌کند؛
- پیاده‌سازی در قالب انطباق دامنه بدون داده منبع¹⁰ که در آن، طبقه‌بندی‌کننده‌های دامنه منبع بدون نیاز به دسترسی مجدد به داده‌های اصلی منبع، به دامنه هدف انتقال می‌یابند؛
- یادگیری تابع اختلاف میان طبقه‌بندی‌کننده‌های دو دامنه برای انجام فرایند انطباق دامنه؛
- در نظر گرفتن عدم قطعیت در مرحله انطباق دامنه با استفاده از وزن‌دهی مبتنی بر مجموعه‌های فازی راف جهت بهره‌گیری از اطلاعات محلی نمونه‌ها؛
- ارزیابی مقاومت مدل در برابر نویز به منظور بررسی پایداری آن در شرایط داده‌های نامطمئن.

[^] Fuzzy rough

[^] Ensemble Learning

[^] Source-Free Domain Adaptation

[^] Privileged Information

[^] Quarter-Sphere Support Vector Machine

ساختار مقاله به این صورت است: بخش 2 به مرور مطالعات انجام شده می‌پردازد. بخش 3 مدل پیشنهادی را تشریح می‌کند. در بخش 4 آزمایش‌ها و نتایج آن‌ها گزارش می‌شود، و نهایتاً در بخش 5 نتیجه‌گیری و کارهای آینده پژوهش مطرح خواهند شد.

2. مطالعات انجام شده

انطباق دامنه به‌عنوان روشی بنیادی برای مقابله با تغییر توزیع داده‌ها بین دامنه آموزشی (منبع) و دامنه آزمایشی (هدف) مطرح شده است [8]. هدف آن انتقال دانش از یک دامنه منبع با برچسب‌گذاری کامل به دامنه هدف است که داده‌های آن از توزیعی متفاوت اما مرتبط استخراج شده‌اند. چالش اصلی در کاهش اختلاف بین توزیع‌های حاشیه‌ای و شرطی دو دامنه است که در صورت نادیده‌گرفتن این اختلاف، عملکرد مدل به‌طور چشمگیری کاهش می‌یابد. همچنین، انطباق دامنه در محیط‌های پرنویز که برچسب‌ها و ویژگی‌های نمونه‌ها دچار خرابی می‌شوند پیچیده‌تر می‌شود. نویز در دامنه منبع منجر به نمایش‌های بصری نادرست می‌شود و تخمین و کاهش اختلاف دامنه بین دامنه منبع و هدف را دشوارتر می‌کند، که نتیجه آن کاهش شدید عملکرد در دامنه هدف است. تحلیل‌های نظری نشان داده‌اند که نویزها به‌طور قابل توجهی بر انطباق دامنه بدون نظارت تأثیر می‌گذارند. در محیط‌های نایب¹¹، ماشین‌های یادگیری معمولاً با سناریوهای انطباق دامنه مواجه می‌شوند که در آن توزیع داده‌ها در طول زمان تغییر می‌کند. پژوهش‌ها دو نوع اصلی از نویز را در انطباق دامنه شناسایی کرده‌اند: (1) نویز برچسب که خرابی در برچسب‌های نمونه‌های دامنه منبع رخ می‌دهد [9, 10] و (2) نویز ویژگی که خرابی در ویژگی‌های نمونه‌ها مشاهده می‌شود [11]. هر دو نوع

نویز می‌توانند به‌طور همزمان وجود داشته باشند و چالش‌های قابل توجهی را برای الگوریتم‌های انطباق دامنه ایجاد کنند [12]. روش‌های مطرح برای انطباق دامنه مقاوم به نویز به صورت زیر است:

• رویکردهای مبتنی بر انتخاب نمونه

برای دستیابی به انتخاب قابل اعتماد نمونه، مدل‌سازی عدم قطعیت در پیش‌بینی‌های طبقه‌بندی‌کننده شبکه عصبی کانولوشنی CNN و وزن‌دهی مجدد تابع هزینه طبقه‌بندی بر اساس این عدم قطعیت پیشنهاد شده است [10, 13]. این مکانیزم وزن‌دهی مجدد، مشارکت نویز را کاهش می‌دهد و منجر به بهبود مقاومت در برابر نویز می‌شود.

• یادگیری برنامه‌ریزی شده آفلاین

برای حذف اثر نویز برچسب، یادگیری برنامه‌ریزی شده آفلاین برای کمینه‌سازی یک ریسک منبع تجربی جدید تعریف شده پیشنهاد شده است [14]. این روش با انتخاب نمونه‌های منبع آفلاین و سپس کاهش اختلاف دامنه، به چالش‌های محیط‌های پرنویز پاسخ می‌دهد.

• شبکه‌های تخصصی

در شبکه‌های تخصصی، مدل یادگیرنده در دو بخش آموزش می‌بیند که با هم در تضاد (تخاصم) هستند [15]: مولد ویژگی‌ها¹² که تلاش می‌کند ویژگی‌هایی از داده‌ها استخراج کند که برای تشخیص دامنه غیرقابل تشخیص باشند ولی برای طبقه‌بندی مفید بمانند. تشخیص‌دهنده دامنه¹³ که می‌کوشد تشخیص دهد هر نمونه ورودی از دامنه منبع است یا هدف. در هر گام فرایند یادگیری تخصصی، طبقه‌بندی‌کننده یاد می‌گیرد تا برچسب‌های

¹² Domain Discriminator

¹¹ Non-stationary

¹³ Feature Extractor

رویکردهای نوآورانه برای ارائه رویکردهای انطباق دامنه مقاوم به نویز است.

3. مدل پیشنهادی

در این بخش، ساختار و فرمول‌بندی مدل پیشنهادی موسوم به ماشین بردار پشتیبان ربع کره دوقلو تطبیقی وزن‌دار¹⁵ (AWTQS-SVM) ارائه می‌شود. این مدل با هدف انطباق دامنه بدون نیاز به داده‌های منبع طراحی شده و قادر است در شرایط داده‌های نویزی یا دارای ابهام، عملکردی پایدار و مقاوم ارائه دهد.

در مدل‌های کلاسیک مبتنی بر ماشین بردار پشتیبان، فرض بر آن است که دو کلاس داده به‌وسیله تنها یک ابرصفحه منفرد از هم جدا می‌شوند. با این حال، در مسائل واقعی، مرزهای تصمیم اغلب غیرخطی، نامنظم و تحت تأثیر نویز هستند. به همین دلیل، مدل دوقلو با ساختار ربع کره به‌جای یک مرز تصمیم در هر دامنه منبع و هدف، دو مرز تصمیم غیرموازی برای هر کلاس ایجاد نموده و با استفاده از اطلاعات فازی راف وزندهی می‌شوند تا سهم نمونه‌های قابل اعتماد بیشتر و سهم نمونه‌های مبهم یا نویزی کمتر گردد.

با در نظر گرفتن طبقه‌بندی کننده دودویی روی دامنه منبع D^S فرض کنید که نمونه‌های مثبت توسط $A^S \in R_+^{l_+^S \times d}$ نشان داده می‌شود که در آن l_+^S تعداد نمونه‌های مثبت و d بعد هر نمونه است. $B^S \in R_+^{l_-^S \times d}$ نمونه‌های آموزشی متعلق به کلاس منفی را نمایش می‌دهد. برای هر کلاس از نمونه‌های دامنه منبع ابرکره با کمینه شعاع ساخته شده و توسط مساله بهینه‌سازی خطی حل می‌گردد. رابطه (1) مسئله کمینه‌سازی برای یافتن ربع کره مثبت در دامنه منبع را نشان می‌دهد. پارامتر R_+^S شعاع این ربع کره

دامنه منبع را درست پیش‌بینی کند. از طرفی، تشخیص‌دهنده یاد می‌گیرد تا دامنه داده‌ها را درست تشخیص دهد. همچنین، استخراج‌کننده ویژگی یاد می‌گیرد تا تشخیص‌دهنده را فریب دهد و نمایش ویژگی‌هایی بیاموزد که در هر دو دامنه مشابه باشند. شبکه‌های تخصصی با ایجاد یک بازی دوطرفه بین استخراج‌کننده ویژگی و تشخیص‌دهنده دامنه، بازنمایی‌هایی تولید می‌کنند که از نظر دامنه بی‌طرف¹⁴ باشند، در نتیجه مدل می‌تواند دانش آموخته از دامنه منبع را به دامنه هدف منتقل کند. روش‌های شناخته شده این حوزه [16-18] می‌باشند.

• انطباق دامنه پیوسته

انطباق دامنه پیوسته یک موضوع چالش‌برانگیز در زمینه انطباق دامنه بدون منبع است که بر مساله انطباق دامنه اطلاعات چندرسانه‌ای بین دامنه‌ای در طول استنتاج با توزیع داده نایبناست تمرکز دارد. روش‌های قبلی فاقد مقاومت در برابر نویز بوده‌اند که منجر به افزایش قابل توجه خطاها در حضور نویز شدید می‌شود. راهکارهای سه‌گانه برای بهبود مقاومت در انطباق دامنه پیوسته به صورت زیر است:

سطح طبقه‌بندی‌کننده: استفاده از تابع هزینه آنتروپی متقاطع تیلور برای کاهش سوگیری دسته با اعتماد پایین [19, 20].
سطح نمونه: وزندهی مجدد نمونه‌های هدف بر اساس عدم قطعیت برای جلوگیری از بیش‌برازش مدل بر روی نمونه‌های پرنویز.

کاهش نویز شبه برچسب: مکانیزم یادگیری منفی جمعی نرم برای هدایت بهینه‌سازی مدل با استفاده از برچسب‌های شبه مکمل جمعی.

مطالعات نشان می‌دهند که انطباق دامنه در محیط‌های پرنویز همچنان یک حوزه تحقیقاتی فعال و چالش‌برانگیز است که نیازمند

قطعیت می‌شود. در رابطه (3) $R_S F(x_i)$ تقریب پایین فازی-راف برای نمونه x_i است. عملگر $S(\dots)$ نمادی کلی برای تابع ترکیب فازی (t-conorm) یا عملگر حداقل فازی و $N(\dots)$ نمایانگر نقیض فازی است. $R(x_i, x_+^C)$ معیار مشابهت یا شباهت بین x_i و مرکز کلاس مثبت x_+^C است. عبارت $\inf_{y \in U}$ نشان‌دهنده کمینه مقدار ترکیب بر روی فضای مرجع U است که منطبق با تعریف تقریب پایین در نظریه فازی-راف است؛ به عبارت دیگر، مقدار حداقلی اطمینان که x_i قطعاً متعلق به مجموعه کلاس مثبت است.

$$w_i = e^{-\left(\overline{R_S F}(x_i) - R_S F(x_i)\right)} \quad (3)$$

$$R_S F(x_i) = \inf_{y \in U} S\left(N(R(x_i, x_+^C)), F(x_+^C)\right) \quad (4)$$

$$\overline{R_S F}(x_i) = \sup_{y \in U} T\left(R(x_i, x_+^C), F(x_+^C)\right) \quad (5)$$

$$x_+^C = \frac{1}{l_+^S} \sum_{c \in A^S} x_c \quad (6)$$

$$R(x_i, x_+^C) = e^{-\frac{\sum_{a=1}^A \left(x_{ia} - \frac{1}{l_+^S} \sum_{c \in A^S} x_{ca}\right)^2}{\sigma}} \quad (7)$$

تابع لاگرانژ برای رابطه (1) به صورت زیر نوشته می‌شود:

$$L_+^S = R_+^S + \frac{c_1}{l_+^S} \sum_{i \in A^S} \xi_i^+ - \sum_{i \in A^S} \alpha_i^T \left[R_+^S + w_i \xi_i^+ - \left\| \phi(x) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i) \right\|^2 \right] - \beta^T R_+^S - \sum_{i \in A^S} \gamma_i^T \xi_i^+ \quad (8)$$

که در آن $\alpha, \beta, \gamma \geq 0$ ضرایب لاگرانژ هستند. با مشتق‌گیری از تابع لاگرانژ نسبت به R_+^S و l_+^S ، شرایط لازم و کافی کاروش-کوهن-تاکر (KKT) به صورت زیر است:

$$\frac{\partial L_+^S}{\partial R_+^S} = 1 - \sum_{i \in A^S} \alpha_i^T - \beta^T = 0 \quad (9)$$

$$\frac{\partial L_+^S}{\partial \xi_i} = \frac{c_1}{l_+^S} - w_i \alpha_i^T - \gamma^T = 0 \Rightarrow 0 \leq \alpha_i \leq \frac{c_1}{w_i l_+^S} \quad (10)$$

$$\alpha_i \left[R_+^S + w_i \xi_i^+ - \left\| \phi(x) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i) \right\|^2 \right] = 0 \quad (11)$$

و ξ_i^+ متغیرهای کمکی اسلک¹⁶ برای پوشش نمونه‌های دورافتاده یا نویزی هستند. ضریب c_1 وزن جریمه را مشخص می‌کند و l_+^S تعداد نمونه‌های مثبت در مجموعه A^S است. ضرایب w_i وزن‌های نمونه هستند که نقش آن‌ها کاهش تأثیر نمونه‌های با اطمینان پایین است. این وزن‌ها توسط رابطه (3) محاسبه می‌شوند. تابع $\phi(\cdot)$ نگاشت به فضای ویژگی با ابعاد بالا را نشان می‌دهد. قید اصلی تضمین می‌کند که فاصله هر داده (پس از متمرکز شدن نسبت به میانگین کلاس مثبت) از مرکز ربع‌کره از شعاع تجاوز نکند، مگر آنکه با ξ_i^+ پوشش داده شود.

$$\begin{aligned} \min R_+^S + \frac{c_1}{l_+^S} \sum_{i \in A^S} w_i \xi_i^+ \\ \text{s.t. } \left\| \phi(x) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i) \right\|^2 \leq R_+^S + \xi_i^+ \\ R_+^S \geq 0, \xi_i \geq 0 \end{aligned} \quad (1)$$

در رابطه (2) نیز مسئله کمینه‌سازی برای یافتن ربع‌کره کلاس منفی را نشان می‌دهد. R_-^S شعاع ربع‌کره مربوط به کلاس منفی، B^S مجموعه اندیس‌های نمونه‌های منفی، و c_2 پارامتر پنالتی متناظر است. هدف آن است که برای هر کلاس یک ربع‌کره بیابیم که نمونه‌های همان کلاس را پوشش دهد و وزن‌دهی w_i اثر نمونه‌های نامطمئن را کاهش دهد.

$$\begin{aligned} \min R_-^S + \frac{c_2}{l_-^S} \sum_{i \in B^S} w_i \xi_i^- \\ \text{s.t. } \left\| \phi(x) - \frac{1}{l_-^S} \sum_{i \in B^S} \phi(x_i) \right\|^2 \leq R_-^S + \xi_i^- \\ R_-^S \geq 0, \xi_i^- \geq 0 \end{aligned} \quad (2)$$

وزن هر نمونه w_i از اختلاف بین تقریب بالایی و تقریب پایینی فازی-راف برای نمونه x_i ناشی می‌شود. اگر فاصله بین تقریب بالایی و پایینی بزرگ باشد (ابهام بیشتر)، آنگاه $\overline{R_S F}(x_i) - R_S F(x_i)$ بزرگ و در نتیجه w_i کوچک می‌شود؛ بنابراین نمونه‌های با ابهام زیاد وزن کمتری در تابع هزینه خواهند داشت. این وزن‌دهی موجب افزایش مقاومت¹⁷ در برابر نمونه‌های با عدم

بر اساس شرایط KKT، چنانچه $0 \leq \alpha_i \leq \frac{c_1}{w_i l_+^S}$ باشد، پس صورت زیر است:

$$R_+^S = \frac{1}{|A^S|} \sum_{i \in A^S} \left\| \phi(x) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i^+) \right\|^2 \quad (19)$$

$$A^S = \left\{ i \mid 0 \leq \alpha_i \leq \frac{c_1}{w_i l_+^S}, i \in A^S \right\} \quad (20)$$

به طور مشابه برای کلاس منفی داریم:

$$\begin{aligned} \max \sum_{i,j \in B^S} \eta_i \eta_j k(x_i, x_j) - \frac{2}{l_-^S} \sum_{i \in B^T} \eta_i k(x_i, x) \\ + \left(\frac{1}{l_-^S} \right)^2 \sum_{i \in B^S} \eta_i k(x, x) \\ \text{s.t. } \sum_{i \in B^S} \eta_i = 1, 0 \leq \eta_i \leq l_-^S, i \in B^S \end{aligned} \quad (21)$$

که ضرایب لاگرانژ هستند.

$$R_-^S = \frac{1}{|B^S|} \sum_{i \in B^S} \left\| \phi(x) - \frac{1}{l_-^S} \sum_{i \in B^S} \phi(x_i^-) \right\|^2 \quad (22)$$

$$B^S = \left\{ i \mid 0 \leq \eta_i \leq \frac{c_2}{w_i l_-^S}, i \in B^S \right\} \quad (23)$$

با توجه به R_{\pm}^2 ، دو ربع کره به صورت زیر تعریف می‌شوند.

$$\begin{aligned} \left\| \phi(x) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i^+) \right\|^2 \leq R_+^S \\ \left\| \phi(x) - \frac{1}{l_-^S} \sum_{i \in B^S} \phi(x_i^-) \right\|^2 \leq R_-^S \end{aligned} \quad (24)$$

طبقه‌بندی نمونه x_{test} دامنه هدف به صورت زیر انجام می‌شود:

$$= \underset{+,-}{\operatorname{argmin}} \left\{ \frac{f^S(x_{test})}{\left\| \phi(x_{test}) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i) \right\|^2} \right\} \quad (25)$$

به منظور یادگیری تابع اختلاف بر روی داده‌های دامنه هدف مراحل زیر انجام می‌شود:

$$(26)$$

$$R_+^S + w_i \xi_i^+ - \left\| \phi(x) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i) \right\|^2 \geq 0 \quad (12)$$

$$\gamma_i^S \xi_i^+ = 0, \xi_i^+ \geq 0, \gamma_i \geq 0 \quad (13)$$

$$\beta_i^T R_+^S = 0, R_+^S \geq 0, \beta \geq 0 \quad (14)$$

رابطه (15) شکل کلی از تبدیل لاگرانژ به فرم دوگان/ماکزیم‌سازی را نشان می‌دهد. پس از اعمال شرایط ایستایی (مشتق‌ها) و حذف متغیرهای پریمال مثل R_+^S و ξ_i ، مسئله پریمال به مسئله دوگان در متغیرهای α_i تقلیل می‌یابد.

$$\begin{aligned} \max \left(1 - \sum_{i \in A^T} \alpha_i^T - \beta^T \right) R_+^S \\ + \sum_{i \in A^T} \left(\frac{c_1}{l_+^S} - w_i \alpha_i^T - \gamma^T \right) \xi_i \\ + \sum_{i \in A^S} \alpha_i \left(\left\| \phi(x) - \frac{1}{l_+^S} \sum_{i \in A^S} \phi(x_i) \right\|^2 \right) \\ \text{s.t. } \sum_{i \in A^S} \alpha_i = 1, 0 \leq \alpha_i \leq \frac{c_1}{l_+^S} \end{aligned} \quad (15)$$

با ساده‌سازی فرمول فوق و در نظر گرفتن ترفند کرنل داریم:

$$\begin{aligned} L_+^S = \max \sum_{i,j \in A^S} \alpha_i \alpha_j k(x_i, x_j) \\ - \frac{2}{l_+^S} \sum_{i \in A^S} \alpha_i k(x_i, x) \\ + \left(\frac{1}{l_+^S} \right)^2 \sum_{i \in A^S} \alpha_i k(x, x) \\ \text{s.t. } \sum_{i \in A^S} \alpha_i = 1, 0 \leq \alpha_i \leq \frac{c_1}{w_i l_+^S} \end{aligned} \quad (16)$$

به‌روزرسانی مبتنی بر گرادینان کاهش‌ی برای یافتن α تحت قیود فوق می‌تواند به صورت زیر نوشته شود:

$$\begin{aligned} \frac{\partial L_+^S}{\partial \alpha} = 2\alpha k(x_i, x_j) - \frac{2}{l_+^S} \sum_{i \in A^S} k(x_i, x) \\ + \left(\frac{1}{l_+^S} \right)^2 \sum_{i \in A^S} k(x, x) = 0 \end{aligned} \quad (17)$$

$$\begin{aligned} = \alpha^{old} \\ - \psi \frac{\frac{2}{l_+^S} \sum_{i \in A^S} k(x_i, x) - \left(\frac{1}{l_+^S} \right)^2 \sum_{i \in A^S} k(x, x)}{2k(x_i, x_j)} \end{aligned} \quad (18)$$

حال، فرم دوگان به صورت زیر نوشته میشود:

$$\begin{aligned} \max & \left(1 - \sum_{i \in A^T} \alpha_i^T - \beta^T \right) R_+^T \\ & + \sum_{i \in A^T} \left(\frac{c_1}{l_+^T} - w_i \alpha_i^T - \gamma^T \right) \xi_i \\ & + \sum_{i \in A^T} \alpha_i \left(f_+^S(x) \right. \\ & \left. + \left\| \phi(x) - \frac{1}{l_+^T} \sum_{i \in A^T} \phi(x_i) \right\|^2 \right) \\ \text{s. t.} & \sum_{i \in A^T} \alpha_i = 1, 0 \leq \alpha_i \leq \frac{c_1}{w_i l_+^T} \end{aligned} \quad (36)$$

با چشم‌پوشی از ضرایب ثابت داریم:

$$\begin{aligned} L_+^T = \max & \sum_{i \in A^T} \alpha_i f_+^S(x) + \sum_{i, j \in A^T} \alpha_i \alpha_j k(x_i, x_j) \\ & - \frac{2}{l_+^T} \sum_{i \in A^T} \alpha_i k(x_i, x) \\ & + \left(\frac{1}{l_+^T} \right)^2 \sum_{i \in A^T} \alpha_i k(x, x) \\ \text{s. t.} & \sum_{i \in A^T} \alpha_i = 1, 0 \leq \alpha_i \leq \frac{c_1}{w_i l_+^T}, i \in A^T \end{aligned} \quad (37)$$

مقدار بهینه α با استفاده از رابطه گرادیان کاهش می‌محاسبه می‌شود:

$$\begin{aligned} \frac{\partial L_+^T}{\partial \alpha} = f_+^S(x) + 2\alpha k(x_i, x_j) - \frac{2}{l_+^T} \sum_{i \in A^T} k(x_i, x) \\ + \left(\frac{1}{l_+^T} \right)^2 \sum_{i \in A^T} k(x, x) = 0 \end{aligned} \quad (38)$$

$$= \alpha^{old} \frac{\frac{2}{l_+^T} \sum_{i \in A^T} k(x_i, x) - f_+^S(x) - \left(\frac{1}{l_+^T} \right)^2 \sum_{i \in A^T} k(x, x)}{2k(x_i, x_j)} \quad (39)$$

برای محاسبه شعاع ربع کره کلاس مثبت داده‌های دامنه هدف داریم:

$$R_+^T = \frac{1}{|A^T|} \sum_{i \in A^T} \left\| \phi(x) - \frac{1}{l_+^T} \sum_{i \in A^T} \phi(x_i) \right\|^2 \quad (40)$$

$$A^T = \left\{ i \mid 0 \leq \alpha_i \leq \frac{c_1}{w_i l_+^T}, i \in A^T \right\} \quad (41)$$

به طور مشابه مساله بهینه سازی به صورت زیر تعریف می‌گردد:

$$\begin{aligned} \text{s. t. } f_+^S(x) + \left\| \phi(x) - \frac{1}{l_+^T} \sum_{i \in A^T} \phi(x_i) \right\|^2 \\ \leq R_+^T + \xi_i^+ \\ R_+^2 \geq 0, \xi_i^+ \geq 0 \end{aligned}$$

و

$$\begin{aligned} \min R_-^T + \frac{c_2}{l_-^T} \sum_{i \in B^T} w_i \xi_i^- \\ \text{s. t. } -f_-^S(x) - \left\| \phi(x) - \frac{1}{l_-^T} \sum_{i \in B^T} \phi(x_i) \right\|^2 \\ \leq R_-^T + \xi_i^- \\ R_-^2 \geq 0, \xi_i^- \geq 0 \end{aligned} \quad (27)$$

که در آن $f_+^S(x)$ و $f_-^S(x)$ توابع پیش بینی کلاس‌های مثبت و منفی دامنه منبع هستند. با در نظر گرفتن پرمال تابع لاگرانژ داریم:

$$\begin{aligned} L_+^T = R_+^T + \frac{c_1}{l_+^T} \sum_{i \in A^T} \xi_i^+ \\ - \sum_{i \in A^T} \alpha_i^T \left[R_+^2 + w_i \xi_i^+ \right. \\ \left. - f_+^S(x) \right. \\ \left. - \left\| \phi(x) - \frac{1}{l_+^T} \sum_{i \in A^T} \phi(x_i) \right\|^2 \right] \\ - \beta^T R_+^T - \sum_{i \in A^T} \gamma_i^T \xi_i^+ \end{aligned} \quad (28)$$

با در نظر گرفتن $\alpha_i \geq 0$ مشتق به صورت زیر است:

$$\frac{\partial L_+^T}{\partial (R_+^T)^2} = 1 - \sum_{i \in A^T} \alpha_i^T - \beta^T = 0 \quad (29)$$

$$\frac{\partial L_+^T}{\partial \xi_i^+} = \frac{c_1}{l_+^T} - w_i \alpha_i^T - \gamma^T = 0 \quad (30)$$

$$\begin{aligned} \alpha_i \left[R_+^T + w_i \xi_i^+ - f_+^S(x) \right. \\ \left. - \left\| \phi(x) - \frac{1}{l_+^T} \sum_{i \in A^T} \phi(x_i) \right\|^2 \right] \\ = 0, \alpha_i \geq 0 \end{aligned} \quad (31)$$

$$R_+^T + w_i \xi_i^+ - f_+^S(x) - \left\| \phi(x) - \frac{1}{l_+^T} \sum_{i \in A^T} \phi(x_i) \right\|^2 \geq 0 \quad (32)$$

$$\gamma_i^T \xi_i^+ = 0, \xi_i^+ \geq 0, \gamma_i \geq 0 \quad (33)$$

$$\beta_i^T R_+^T = 0, R_+^T \geq 0, \beta \geq 0 \quad (34)$$

براساس ترفند کرنل داریم:

$$\sum_{i \in A^T} \alpha_i = 1 \quad (35)$$

در این بخش، ابتدا مجموعه داده‌ها و تنظیمات آزمایشی معرفی می‌شوند، سپس نتایج حاصل از آزمایش و تحلیل‌های مربوط به پایداری مدل در برابر نویز ارائه می‌گردند.

1.4. مجموعه داده‌ها

به منظور ارزیابی، 15 وظیفه از دو مجموعه داده معیار 20newsgroup و Animal with Attributes (AWA) استخراج شد. مشخصات وظایف در جداول 1 و 2 آورده شده است.

جدول (1): مجموعه داده 20newsgroup

وظیفه	دامنه منبع		دامنه هدف		تعداد ابعاد
	نام	تعداد داده	نام	تعداد داده	
A	comp.graphic s comp.os.ms- windows.misc	1975 (+)	comp.sys.ibm.p c.hardware comp.sys.mac.h ardware comp.windows. x	1977 (+)	300
	sci.crypt sci.electronics	1958 (-)	sci.med sci.space	2993 (-)	
B	comp.graphic s comp.sys.mac .hardware comp.window s.x	1958 (+)	Comp.os.ms.wi ndows.misc comp.sys.ibm.p c.hardware	1685 (+)	300
	talk.politics.m isc talk.politics.m ideast	2924 (-)	talk.politics.mis c talk.politics.gun s	1967 (-)	
C	rec.autos rec.sport.base ball	1977 (+)	rec.sport.hockey rec.motorcycles	1975 (+)	300
	sci.med sci.space	1984(-)	sci.crypt sci.electronics	1995 (-)	
D	rec.autos rec. motorcycles	1685 (+)	rec.sport.hockey rec.sport.baseba ll	1715 (+)	400
	talk.politics.m isc talk.politics.g uns	1986 (-)	talk.politics.mis c talk.politics.mid east	1993 (-)	

$$\max \sum_{i,j \in B^T} \eta_i \eta_j k(x_i, x_j) - \frac{2}{|B^T|} \sum_{i \in B^T} \eta_i k(x_i, x) + \left(\frac{1}{|B^T|}\right)^2 \sum_{i \in B^T} \eta_i k(x, x)$$

$$s. t. \sum_{i \in B^T} \eta_i = 1, 0 \leq \eta_i \leq 1, i \in B^T \quad (42)$$

مربع شعاع مربوط به کلاس منفی به صورت زیر نوشته می‌شود:

$$R_-^T = \frac{1}{|B^T|} \sum_{i \in B^T} \left\| \phi(x) - \frac{1}{|B^T|} \sum_{i \in B^T} \phi(x_i^-) \right\|^2 \quad (43)$$

$$B^T = \left\{ i \mid 0 \leq \eta_i \leq \frac{c_2}{w_i |B^T|}, i \in B^T \right\} \quad (44)$$

دو ربع کره متعلق به کلاس‌های مثبت و منفی به صورت زیر است:

$$\left\| \phi(x) - \frac{1}{|B^T|} \sum_{i \in A^T} \phi(x_i^+) \right\|^2 \leq R_+^T \quad (45)$$

$$\left\| \phi(x) - \frac{1}{|B^T|} \sum_{i \in B^T} \phi(x_i^-) \right\|^2 \leq R_-^T \quad (46)$$

حال تابع اختلاف $\Delta f(x_{test})$ به صورت زیر محاسبه می‌شود.

$$\Delta f(x_{test}) = \operatorname{argmin}_{+,-} \left\{ \frac{\left\| \phi(x_{test}) - \frac{1}{|B^T|} \sum_{i \in A^T} \phi(x_i) \right\|^2}{R_+^T}, \frac{\left\| \phi(x_{test}) - \frac{1}{|B^T|} \sum_{i \in B^T} \phi(x_i) \right\|^2}{R_-^T} \right\} \quad (47)$$

در پایان، تصمیم‌گیری نهایی به صورت زیر است:

$$f^{ens}(x_{test}) = \omega f^S(x_{test}) + (1 - \omega) \Delta f(x_{test}) \quad (48)$$

این رابطه از تلفیق تصمیم دامنه منبع و دامنه هدف تشکیل شده است. پارامتر $\omega \in [0, 1]$ وزن مشارکت دامنه منبع را کنترل می‌کند: اگر ω بزرگ باشد، تصمیم دامنه منبع غالب است (یعنی انتقال دانش بیشتر)، و اگر ω کوچک‌تر انتخاب شود، تصمیم دامنه هدف (تطبیق شده با داده‌های جدید) نقش اصلی را ایفا می‌کند.

4. آزمایش‌ها و نتایج

آن تهیه برچسب‌های شبه‌تصادفی مطمئن برای نمونه‌های دامنه هدف است، (2) شبکه دامنه هدف (TNet) که با استفاده از نمونه‌های طبقه‌بندی شده به صورت شبه‌تصادفی آموزش داده می‌شود. (3) پالایش برچسب‌های نویزی که در آن LNet به‌طور تدریجی نمونه‌های غلط طبقه‌بندی شده در دامنه منبع را تشخیص و پالایش می‌کند تا از اثرات نویز برچسب کاسته شود. (4) متعادل‌سازی کلاس که به‌منظور مقابله با مسئله تغییر توزیع برچسب‌ها بین دامنه‌ها، استفاده می‌شود.

پژوهش [22] به مسئله انطباق دامنه بدون دسترسی به داده‌های منبع در تقسیم‌بندی معنایی تصاویر ماهواره‌ای می‌پردازد. بدین ترتیب، یک روش پالایش برچسب‌های شبه‌تصادفی مبتنی بر نمونه‌اولیه ارائه شده است که در آن از نمونه‌های اولیه کلاس (نقاط مرکزی ویژگی‌های هر کلاس) استفاده می‌شود تا برچسب‌های نویزی را اصلاح کند.

پژوهش [23] به مسئله انطباق دامنه بدون نظارت مبتنی بر ترنسفورمر می‌پردازد. این روش، از یک رویکرد نظارت دوگانه متقاطع استفاده نموده و با بهره‌گیری از ساختار ترنسفورمر سعی می‌کند تا تفاوت میان دامنه‌ها را کاهش دهد و عملکرد بهتری در وظایفی مانند تقسیم‌بندی معنایی و دیگر کاربردهای تطابق دامنه به دست آورد.

پژوهش [24] به مساله انطباق دامنه در شرایطی می‌پردازد که در دامنه هدف، کلاس‌هایی وجود دارند که در دامنه منبع دیده نشده‌اند (کلاس‌های «ناشناخته»). بنابراین مدل باید به گونه‌ای آموزش ببیند که علاوه بر یادگیری کلاس‌های مشترک، داده‌های ناشناخته را نیز شناسایی و جدا کند. براین اساس، از استراتژی خوشه‌بندی محلی k -NN برای کاهش انتقال منفی و همچنین

E	sci.med sci.electronics	1430	400	sci.crypt sci.space	1850(+)	400
	talk.politics.m isc talk.religion. misc	1974 (-)		talk.politics.mid east talk.politics.gun s	1978 (-)	

جدول (2): مجموعه داده AWA

ویژگی	منبع	تعداد داده	هدف	تعداد داده
F	all_except_bat	4737	bat	401
G	all_except_beaver	4953	beaver	185
H	all_except_blue-whale	4877	blue-whale	261
I	all_except_bobcat	4497	bobcat	641
J	all_except_buffalo	4578	buffalo	560
K	all_except_chihuahua	4445	chihuahua	693
L	all_except_chimpanzee	4437	chimpanzee	701
M	all_except_dalmatian	4549	dalmatian	589
N	all_except_dolphin	4457	dolphin	681
O	all_except_fox	4712	fox	426

2.4. تنظیمات آزمایش

پارامترهای مدل پیشنهادی به‌صورت تجربی انتخاب و مقادیر بهینه با استفاده از اعتبارسنجی متقابل¹⁸ انتخاب گردیدند. تابع کرنل مورد استفاده در روش پیشنهادی و روش‌های مقایسه‌ای، کرنل گاوسی شعاعی است. عملکرد مدل پیشنهادی با چند روش انطباق دامنه مقایسه شد که به صورت زیر است:

پژوهش [21] به مسئله انطباق دامنه بدون نظارت با وجود نویز برچسب در دامنه منبع و تغییر در توزیع برچسب‌ها بین دامنه‌ها می‌پردازد. این روش دارای اجزای زیر است: (1) شبکه برچسب‌دهی (LNet) که بر روی دامنه منبع کار می‌کند و وظیفه

F	72,73 (1)	63,61 (5)	63,63 (4)	64,88 (3)	69,36 (2)
G	77,28 (1)	68,69 (4)	69,81 (3)	67,27 (5)	70,24 (2)
H	68,27 (3)	70,87 (2)	67,72 (4)	63,38 (5)	79,93 (1)
I	66,55 (4)	68,00 (2)	66,94 (3)	64,05 (5)	71,42 (1)
J	66,54 (4)	67,32 (3)	65,32 (5)	67,60 (2)	75,66 (1)
K	72,31 (1)	65,76 (4)	65,52 (5)	66,33 (3)	67,74 (2)
L	71,06 (2)	67,18 (3)	65,23 (5)	66,30 (4)	75,67 (1)
M	69,99 (2)	69,48 (3)	63,30 (5)	67,27 (4)	70,32 (1)
N	73,38 (2)	71,86 (3)	69,58 (4)	66,86 (5)	76,34 (1)
O	76,71 (1)	66,47 (4)	67,49 (3)	65,68 (5)	72,15 (2)
Average rank	2,53 (2)	3,00 (3)	4,00 (4)	4,13 (5)	1,33 (1)
p-value	0,0466	0,001	0,00064	0,00064	
Wilcoxon test	h_1	h_1	h_1	h_1	

یادگیری تطابق متضاد¹⁹ استفاده می‌کند تا طبقه‌های "نامعلوم" متمایز شناسایی شوند.

3.4. نتایج

نتایج آزمایش‌های تجربی همراه با رتبه‌بندی از نظر دو معیار صحت در جداول 3-5 آورده شده است. همچنین، میانگین رتبه هر روش به همراه آزمون ناپارامتری ویلکاکسون با حد آستانه 0,05 گزارش شده است. آزمایش‌ها نشان می‌دهد که مدل پیشنهادی در مقایسه با روش‌های رقیب توانسته است در اغلب وظایف، به صحت بالا در طبقه‌بندی دست یابد. بهره‌گیری از منطق فازی راف و ساختار دوقلو، توانسته است در مواجهه با داده‌های دارای توزیع‌های متفاوت، عملکردی دقیق ارائه کند.

بررسی زمان اجرا در جداول 6-8 نشان می‌دهد که مدل پیشنهادی توانسته است به کارایی محاسباتی مطلوب دست یابد. این برتری ناشی از دو دلیل است: (1) AWTQS-SVM تنها به یک بار دسترسی به داده‌های منبع نیازمند است. (2) مدل پیشنهادی دو معادله خطی ساده را بهینه می‌کند. بنابراین، زمان آموزش و انطباق دامنه کاهش می‌یابد.

جدول (3): صحت (%). در دامنه هدف 30٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

جدول (4): صحت (%). در دامنه هدف 50٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

Task	[21]	[22]	[23]	[24]	AWTQS-SVM
A	60,73 (5)	67,18 (1)	65,29 (3)	62,77 (4)	65,90 (2)
B	65,75 (2)	64,00 (3)	63,38 (4)	63,07 (5)	69,90 (1)
C	66,18 (2)	64,81 (4)	64,92 (3)	62,99 (5)	72,09 (1)
D	61,86 (5)	68,39 (2)	63,80 (4)	63,81 (3)	70,75 (1)
E	64,36 (3)	69,72 (2)	63,15 (5)	64,13 (4)	72,85 (1)

Task	[21]	[22]	[23]	[24]	AWTQS-SVM
A	61,49 (5)	67,94 (1)	66,05 (3)	64,29 (4)	66,66 (2)
B	66,51 (2)	64,76 (4)	64,14 (5)	65,35 (3)	70,66 (1)
C	66,94 (2)	65,57 (4)	66,44 (3)	65,27 (5)	70,09 (1)
D	64,14 (4)	70,67 (2)	61,80 (5)	65,33 (3)	73,03 (1)

E	65,12 (4)	72,76 (2)	63,91 (5)	67,93 (3)	75,13 (1)
F	73,49 (1)	65,89 (5)	65,91 (4)	68,68 (3)	72,40 (2)
G	76,28 (1)	71,73 (3)	71,33 (4)	68,79 (5)	74,04 (2)
H	69,03 (4)	72,39 (2)	69,24 (3)	65,66 (5)	80,69 (1)
I	68,83 (3)	69,01 (2)	63,94 (5)	65,57 (4)	75,22 (1)
J	68,82 (3)	68,84 (2)	67,60 (4)	67,60 (4)	77,18 (1)
K	74,59 (1)	66,52 (4)	69,32 (3)	65,33 (5)	70,02 (2)
L	71,82 (2)	70,98 (3)	65,99 (5)	66,30 (4)	79,47 (1)
M	71,51 (2)	72,52 (1)	66,34 (5)	69,55 (3)	67,32 (4)
N	74,38 (3)	74,90 (2)	70,34 (4)	67,62 (5)	77,86 (1)
O	78,99 (1)	69,51 (3)	69,01 (4)	67,96 (5)	74,43 (2)
Average rank	2,73 (3)	2,47 (2)	3,93 (4)	4,20 (5)	(1) 1,60
<i>p</i> -value	0,0264 2	0,0075 8	0,0006 4	0,000 8	
Wilcoxon test	h_1	h_1	h_1	h_1	h_1

E	65,12 (4)	71,24 (2)	63,91 (5)	65,65 (3)	74,37 (1)
F	74,25 (1)	64,37 (5)	64,39 (4)	66,40 (3)	70,12 (2)
G	77,28 (1)	69,45 (5)	70,57 (3)	69,55 (4)	72,52 (2)
H	69,79 (4)	73,15 (2)	70,00 (3)	65,66 (5)	80,69 (1)
I	67,31 (3)	69,52 (2)	63,94 (5)	66,33 (4)	72,18 (1)
J	67,30 (4)	68,08 (3)	66,84 (5)	69,88 (2)	77,18 (1)
K	73,07 (1)	68,04 (3)	67,80 (4)	67,09 (5)	69,26 (2)
L	72,58 (2)	69,18 (3)	67,51 (4)	67,06 (5)	77,95 (1)
M	71,51 (2)	71,76 (1)	64,06 (5)	69,55 (4)	70,32 (3)
N	72,38 (3)	72,62 (2)	71,10 (4)	68,38 (5)	77,86 (1)
O	77,47 (1)	68,75 (3)	68,25 (4)	67,96 (5)	72,91 (2)
Average rank	2,60 (2)	2,80 (3)	4,13 (5)	4,00 (4)	(1) 1,47
<i>p</i> -value	0,0264 2	0,001 8	0,0006 4	0,0006 4	
Wilcoxon test	h_1	h_1	h_1	h_1	

جدول (6): زمان محاسبه (s). در دامنه هدف 30٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

Task	[21]	[22]	[23]	[24]	AWTQS-SVM
A	445,24 (3)	546,31 (5)	467,34 (4)	425,25 (1)	435,11 (2)
B	445,66 (3)	549,79 (5)	469,00 (4)	420,53 (1)	426,00 (2)
C	446,23 (2)	545,38 (5)	470,06 (4)	448,40 (3)	430,94 (1)
D	453,04 (3)	539,21 (5)	469,24 (4)	418,33 (1)	429,10 (2)

جدول (5): صحت (%). در دامنه هدف 70٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

Task	[21]	[22]	[23]	[24]	AWTQS-SVM
A	63,01 (5)	70,98 (1)	68,33 (3)	63,53 (4)	69,70 (2)
B	68,03 (2)	67,80 (3)	64,14 (5)	64,59 (4)	70,66 (1)
C	66,94 (4)	67,09 (3)	67,20 (2)	64,51 (5)	72,09 (1)
D	64,90 (5)	70,39 (1)	65,80 (3)	65,33 (4)	69,75 (2)

E	600,04 (1)	701,53 (5)	674,40 (2)	678,52 (3)	694,82 (4)
F	592,48 (3)	635,40 (5)	621,12 (4)	568,64 (2)	551,31 (1)
G	593,91 (2)	635,34 (5)	619,62 (3)	621,06 (4)	563,16 (1)
H	590,38 (1)	631,74 (5)	620,97 (3)	626,65 (4)	600,69 (2)
I	583,49 (2)	624,05 (5)	622,26 (4)	615,42 (3)	579,11 (1)
J	615,18 (1)	621,45 (3)	624,09 (4)	620,11 (2)	677,74 (5)
K	591,93 (2)	632,25 (5)	622,62 (4)	622,41 (3)	542,65 (1)
L	586,95 (2)	638,78 (5)	621,80 (4)	621,47 (3)	581,38 (1)
M	592,16 (1)	635,07 (4)	622,53 (3)	620,17 (2)	691,46 (5)
N	503,10 (1)	635,89 (4)	628,38 (3)	527,74 (2)	694,70 (5)
O	583,59 (1)	587,80 (2)	677,09 (5)	629,22 (4)	601,61 (3)
Average rank	1,40 (1)	4,53 (5)	3,20 (4)	3,00 (3)	(2) 2,87
p-value	0,0307 8	0,0891 4	0,5352 6	0,6527 2	
Wilcoxon test	h_1	h_0	h_0	h_0	

جدول (8): زمان محاسبه (s). در دامنه هدف 70٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

Task	[21]	[22]	[23]	[24]	AWTQS-SVM
A	938,31 (4)	900,2 (3) 4	890,34 (2)	972,11 (5)	780,25 (1)
B	944,79 (4)	899,6 (3) 6	893,00 (2)	961,00 (5)	772,53 (1)
C	944,38 (5)	898,2 (2) 3	900,06 (3)	907,94 (4)	804,40 (1)
D	934,21 (4)	900,0 (3) 4	896,24 (2)	961,10 (5)	773,33 (1)

E	444,40 (3)	506,53 (5)	471,52 (4)	423,04 (1)	427,82 (2)
F	437,12 (3)	539,40 (5)	443,64 (4)	417,48 (2)	411,31 (1)
G	437,62 (3)	536,34 (5)	443,06 (4)	413,91 (1)	426,16 (2)
H	434,97 (3)	534,74 (5)	445,65 (4)	416,38 (1)	419,69 (2)
I	439,26 (4)	493,05 (5)	438,42 (3)	409,49 (1)	423,11 (2)
J	435,09 (3)	494,45 (5)	445,11 (4)	414,18 (2)	412,74 (1)
K	436,62 (3)	534,25 (5)	442,41 (4)	412,93 (1)	424,65 (2)
L	436,80 (3)	539,78 (5)	443,47 (4)	411,95 (1)	430,38 (2)
M	438,53 (3)	538,07 (5)	442,17 (4)	413,16 (1)	422,46 (2)
N	442,38 (3)	534,89 (5)	443,74 (4)	415,10 (1)	428,70 (2)
O	497,09 (3)	488,80 (2)	509,22 (5)	504,59 (4)	472,61 (1)
Average rank	3,00 (3)	4,80 (5)	4,00 (4)	1,47 (1)	(2) 1,73
p-value	0,0006 4	0,0006 4	0,0006 4	0,1388 8	
Wilcoxon test	h_1	h_1	h_1	h_0	

جدول (7): زمان محاسبه (s). در دامنه هدف 50٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

Task	[21]	[22]	[23]	[24]	AWTQS-SVM
A	600,25 (1)	739,31 (5)	670,24 (2)	679,34 (3)	705,11 (4)
B	598,53 (1)	744,79 (5)	671,66 (2)	683,00 (3)	692,00 (4)
C	628,40 (1)	744,38 (5)	675,23 (3)	686,06 (4)	669,94 (2)
D	593,33 (1)	736,21 (5)	678,04 (2)	684,24 (3)	698,10 (4)

نادرست جلوگیری می‌نماید. بدین ترتیب، ترکیب نظریه مجموعه‌های فازی راف با ساختار دوقلو، مسیر جدیدی را برای یادگیری انتقالی در حضور نویز و عدم قطعیت می‌گشاید.

جدول (9): صحت (%) به ازای سطوح مختلف نویز. در دامنه هدف 50٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

Task	Noise (%)	[21]	[22]	[23]	[24]	AWTQS-SVM
A	0	61,49	67,94	66,05	64,29	66,66
	5	59,45	65,34	63,37	60,09	65,60
	10	55,97	63,84	56,65	57,95	62,33
	15	52,7	56,04	52,63	50,6	61,17
	20	50,46	52,44	48,01	45,7	57,99
	25	46,50	51,31	46,63	34,45	55,67
	30	37,72	47,62	37,21	20,2	53,29
B	0	66,51	64,76	64,14	65,35	70,66
	5	64,47	63,46	61,46	61,15	67,48
	10	62,15	58,96	59,22	59,01	65,30
	15	58,88	51,16	55,2	54,11	62,98
	20	57,76	49,36	52,12	46,76	59,80
	25	56,44	45,97	50,74	39,26	58,64
	30	47,66	44,74	47,61	25,01	56,26
C	0	66,94	65,57	66,44	65,27	70,09
	5	65,92	62,97	63,76	63,87	67,97
	10	62,44	58,47	57,04	61,73	66,88
	15	61,35	53,27	53,02	59,28	63,40
	20	57,99	47,87	48,40	54,38	62,34
	25	56,67	46,74	44,28	50,63	61,18
	30	47,89	44,28	41,14	45,88	59,99
D	0	64,14	70,67	61,8	65,33	73,03
	5	63,12	69,37	59,12	62,53	71,97
	10	59,64	66,37	54,64	61,46	69,79
	15	57,46	61,17	51,96	54,11	66,31
	20	55,22	55,77	47,34	46,76	63,13
	25	52,58	52,38	45,97	35,51	60,81
	30	48,19	49,92	36,57	21,26	57,24
E	0	65,12	71,24	63,91	65,65	74,37
	5	62,06	68,64	61,23	62,85	72,25
	10	58,58	67,14	58,99	61,78	70,07
	15	55,31	61,94	54,97	56,88	67,75

E	904,53 (4)	897,4 (3) 0	892,52 (2)	961,82 (5)	775,04 (1)
F	732,40 (3)	807,1 (5) 2	691,64 (1)	692,31 (2)	772,48 (4)
G	732,34 (2)	804,6 (5) 2	796,06 (4)	703,16 (1)	765,91 (3)
H	731,74 (1)	807,9 (5) 7	801,65 (4)	776,69 (3)	770,38 (2)
I	748,05 (2)	811,2 (5) 6	794,42 (4)	737,11 (1)	760,49 (3)
J	752,45 (1)	807,0 (3) 9	797,11 (2)	951,74 (5)	824,18 (4)
K	728,25 (2)	804,6 (5) 2	795,41 (4)	660,65 (1)	764,93 (3)
L	734,78 (2)	807,8 (5) 0	797,47 (4)	727,38 (1)	759,95 (3)
M	732,07 (1)	810,5 (4) 3	797,17 (3)	958,46 (5)	767,16 (2)
N	736,89 (3)	815,3 (4) 8	618,74 (2)	965,70 (5)	587,10 (1)
O	687,80 (2)	866,0 (5) 9	753,22 (4)	730,61 (3)	662,59 (1)
Average rank	2,67 (2)	4,00 (5)	2,87 (3)	3,40 (4)	(1) 2,07
p-value	0,3077 2	0,000 8	0,0045 2	0,0357 2	
Wilcoxon test	h_0	h_1	h_1	h_1	

4.4. تحلیل مقاومت در برابر نویز گاوسی بر ویژگی‌ها

به‌منظور بررسی پایداری مدل در شرایط داده‌های آلوده به نویز، آزمایش‌هایی با افزودن نویز گاوسی با واریانس‌های 5%-30% به داده‌های دامنه هدف انجام شد. نتایج نشان داد که با افزایش سطح نویز، عملکرد روش پیشنهادی به‌طور قابل توجهی پایدار می‌ماند. این پایداری را می‌توان به دو عامل اصلی نسبت داد: (1) مدل دوقلو که با ایجاد دو مرز تصمیم مستقل، اثر نمونه‌های پرت را کاهش می‌دهد؛ (2) وزن‌دهی فازی راف که وزن نمونه‌های غیر قابل اطمینان را در تابع هزینه کم می‌کند و از یادگیری

	10	68,57	62,44	58,40	64,62	62,81
	15	65,30	54,64	55,72	59,72	61,65
	20	61,94	52,84	52,64	54,82	58,47
	25	57,98	49,45	49,90	47,32	57,31
	30	44,81	46,99	46,75	42,57	56,12
L	0	72,58	69,18	67,51	67,06	77,95
	5	71,56	66,58	63,49	64,26	74,77
	10	68,08	65,08	59,01	62,12	71,5
	15	64,81	62,48	56,33	59,67	69,18
	20	63,69	58,88	51,71	52,32	66,00
	25	62,37	57,75	48,96	48,57	63,68
	30	49,20	54,06	45,82	43,82	60,11
M	0	71,51	71,76	64,06	69,55	70,32
	5	68,45	69,16	60,04	66,75	67,14
	10	64,97	66,16	53,32	64,61	64,96
	15	61,7	58,36	51,98	62,16	63,8
	20	59,46	54,76	48,9	54,81	62,74
	25	56,82	51,37	46,15	51,06	59,26
	30	52,43	50,14	43,01	41,56	55,69
N	0	72,38	72,62	71,1	68,38	77,86
	5	69,32	70,02	68,42	65,58	74,68
	10	68,16	67,02	61,70	64,51	72,50
	15	64,89	64,42	59,02	57,16	71,34
	20	63,77	62,62	54,40	52,26	70,28
	25	62,45	61,49	51,65	44,76	67,96
	30	49,28	57,8	48,51	35,26	64,39
O	0	77,47	68,75	68,25	67,96	72,91
	5	74,41	64,85	64,23	65,16	70,79
	10	72,09	61,85	57,51	64,09	67,52
	15	69,91	59,25	53,49	59,19	64,04
	20	68,79	53,85	51,95	51,84	62,98
	25	64,83	50,46	50,58	44,34	61,82
	30	56,05	48,00	41,16	34,84	60,63
Average reduction	20,67 (4)	19,46 (2)	20,55 (3)	29,74 (5)	(1) 13,48	

	20	53,07	56,54	51,89	49,53	65,63
	25	50,43	53,15	49,14	45,78	63,31
	30	46,04	49,46	46,00	36,28	62,12
F	0	74,25	64,37	64,39	66,40	70,12
	5	71,19	61,77	60,37	62,20	69,06
	10	68,87	60,27	58,13	60,06	67,97
	15	66,69	55,07	55,45	55,16	65,65
	20	63,33	51,47	52,37	52,71	62,47
	25	59,37	50,34	51,00	48,96	61,31
G	0	77,28	69,45	70,57	69,55	72,52
	5	74,22	68,15	66,55	66,75	71,46
	10	70,74	66,65	59,83	63,54	70,37
	15	67,47	58,85	57,15	61,09	69,21
	20	64,11	55,25	52,53	58,64	66,03
	25	60,15	54,12	48,41	51,14	63,71
H	0	69,79	73,15	70,00	65,66	80,69
	5	67,75	71,85	67,32	62,86	79,63
	10	65,43	67,35	62,84	59,65	77,45
	15	63,25	59,55	60,16	57,20	76,29
	20	61,01	54,15	55,54	54,75	73,11
	25	58,37	50,76	54,17	51,00	70,79
I	0	67,31	69,52	63,94	66,33	72,18
	5	65,27	66,92	61,26	63,53	71,12
	10	64,11	65,42	59,02	60,32	70,03
	15	61,93	57,62	55,00	55,42	67,71
	20	60,81	52,22	50,38	52,97	66,65
	25	56,85	49,96	49,01	45,47	63,17
J	0	67,30	68,08	66,84	69,88	77,18
	5	65,26	65,48	64,16	67,08	75,06
	10	61,78	60,98	59,68	63,87	71,79
	15	59,60	58,38	55,66	61,42	68,31
	20	56,24	54,78	54,12	54,07	67,25
	25	53,60	53,65	52,75	42,82	66,09
K	0	73,07	68,04	67,8	67,09	69,26
	5	72,05	65,44	65,12	65,69	66,08

5.4. تحلیل مقاومت در برابر نویز برچسب

شبیه‌سازی نویز برچسب به روش random label flipping بر

روی داده‌های دامنه هدف در سطوح {5، 10، 15، 20، 25، 30}

	25	42,67	45,77	40,77	38,63	56,34
	30	35,33	39,7	37,61	27,53	53,49
F	0	74,25	64,37	64,39	66,4	70,12
	5	69,51	59,38	57,75	59,75	67,62
	10	66,31	57,2	54,8	56,93	65,67
	15	62,05	51,26	50,86	51,56	62,14
	20	57,89	45,33	46,48	46,84	57,16
	25	51,31	42,29	43	40,94	54,31
	30	40,67	39,94	35,43	26,12	48,97
G	0	77,28	69,45	70,57	69,55	72,52
	5	72,44	66,24	64,62	64,57	69,48
	10	68,53	63,9	56,97	60,85	67,7
	15	63,19	55,34	52,58	56,85	65,34
	20	57,91	48,99	46,45	53,13	60,61
	25	52,61	46,11	40,48	43,89	56,85
	30	41,14	40,69	30,44	37,67	51,18
H	0	69,79	73,15	70	65,66	80,69
	5	65,27	69,9	65,34	60,78	78,26
	10	62,45	64,38	59,81	56,64	74,81
	15	58,88	55,62	56,41	53,18	72,55
	20	55,57	48,79	49,6	49,42	68,5
	25	51,14	43,12	46,15	42,93	63,79
	30	38,94	38,12	38,76	32,74	58,48
I	0	67,31	69,52	63,94	66,33	72,18
	5	63,42	64,37	59,36	61,97	69,62
	10	61,38	62,2	56,52	58,05	67,26
	15	57,88	53,87	50,88	51,29	64,23
	20	54,83	46,54	44,86	47,82	61,64
	25	49,63	42,27	40,41	37,52	55,85
	30	33,6	39,44	33,81	27,38	52,56
J	0	67,3	68,08	66,84	69,88	77,18
	5	63,39	62,88	61,43	64,79	73,78
	10	59,3	57,75	56,88	61,58	69,25
	15	55,42	55,16	51,37	57,13	65,17
	20	50,07	49,39	48,42	48,51	62,27
	25	46,17	45,9	43,95	34,97	58,99
	30	39,17	43,5	40,86	19,78	54,04
K	0	73,07	68,04	67,8	67,09	69,26
	5	69,97	62,94	62,57	63,22	64,58
	10	66,07	59,58	55,87	61,78	60,97

درصد انجام شده است. در این روش، برچسب‌ها به صورت کاملا تصادفی و مستقل از ویژگی‌ها از کلاس دیگر انتخاب می‌شوند.

جدول (9): صحت (%) به ازای سطوح مختلف نویز. در دامنه هدف 50٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

Task	Noise (%)	[21]	[22]	[23]	[24]	AWTQS-SVM
A	0	61,49	67,94	66,05	64,29	66,66
	5	57,62	62,51	61,33	58,16	64,17
	10	53,34	60,33	53,35	55,35	60,34
	15	48,29	52,92	48,27	46,69	57,82
	20	44,77	46,89	41,84	40,03	52,98
	25	38,88	43,83	38,67	26,61	48,71
	30	27,78	37,94	28,33	11,38	44,32
B	0	66,51	64,76	64,14	65,35	70,66
	5	62,74	60,68	59,26	59,16	65,56
	10	59,84	55,9	56,26	56,47	62,72
	15	54,38	47,12	50,88	50,65	59,47
	20	51,65	43,69	46,59	40,71	54,36
	25	48,96	37,91	42,3	31,49	52,03
C	0	66,94	65,57	66,44	65,27	70,09
	5	63,76	60,33	61,03	61,45	66,43
	10	59,84	55,38	54,44	59,37	64,88
	15	57,03	49,47	48,42	55,97	60,36
	20	52,74	42,02	42,02	48,65	57,51
	25	48,77	38,98	36,09	42,66	53,74
D	0	64,14	70,67	61,8	65,33	73,03
	5	60,82	66,91	57,18	60,42	70,19
	10	56,65	63,53	51,25	59,25	67,44
	15	53,06	57,16	47,51	50,19	62,36
	20	49,44	50,4	41,8	41,32	58,47
	25	45,26	44,72	37,71	28,35	53,92
E	0	65,12	71,24	63,91	65,65	74,37
	5	60,4	66,33	59,26	61,23	70,62
	10	55,66	64,37	55,51	59,47	67,59
	15	51,49	58,31	50,49	53,03	64,42
	20	46,94	50,7	45,49	43,64	60,78

آن توسط روش‌های وزندهی، انتخاب کرنل ترکیبی و اضافه کردن ضرایب تنظیم‌کننده قابل مدیریت است. در مقابل، نویز برچسب باعث گمراهی تابع اختلاف شده و انطباق را به سمت مرزهای تصمیم نادرست می‌برد به ویژه در روش پیشنهادی که از شبه‌برچسب‌ها جهت انطباق استفاده می‌گردد.

6.4. بررسی تاثیر وزن‌های به دست آمده از فازی راف-ست

به منظور بررسی سهم وزندهی مبتنی بر مجموعه‌های فازی-راف، عملکرد مدل با و بدون این وزندهی، مقایسه گردید که نتایج آن در جدول (11) نشان داده شده است. در این جدول، روش بدون در نظر گرفتن وزن با عنوان ATQS-SVM نام‌گذاری شده است. با مقایسه میانگین رتبه مشاهده می‌شود که در صورت نادید گرفتن ضرایب وزنی، عملکرد مدت کاهش یافته، نتیجه آزمون ویلکاکسون نیز بیان‌کننده وجود تفاوت معنادار میان دو روش است.

جدول (11): صحت (%). در دامنه هدف 50٪ از نمونه‌ها برای آموزش استفاده شده‌اند.

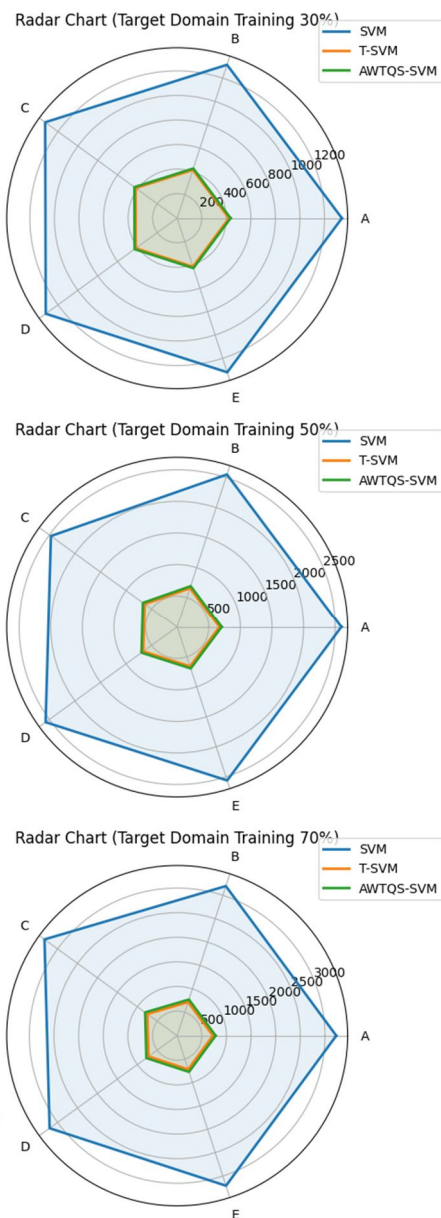
Task	ATQS-SVM	AWTQS-SVM
A	(2) 63,22	(1) 66,66
B	(1) 71,76	(2) 70,66
C	(2) 69,98	(1) 70,09
D	(2) 69,5	(1) 73,03
E	(2) 73,22	(1) 74,37
F	(2) 68,52	(1) 70,12
G	(2) 69,84	(1) 72,52
H	(2) 79,98	(1) 80,69
I	(2) 67,92	(1) 72,18
J	(2) 73,36	(1) 77,18
K	(1) 69,28	(2) 69,26
L	(2) 77,60	(1) 77,95
M	(2) 68,51	(1) 70,32
N	(2) 77,62	(1) 77,86
O	(2) 72,72	(1) 72,91
Average rank	(2) 1,87	(1) 1,13
p-value	0,00318	

	15	61,49	50,58	51,29	55,83	57,67
	20	55,87	46,71	46,36	49,3	53,78
	25	50,45	41,55	41,69	40,05	49,91
	30	34,55	37,41	38,3	34,31	47,79
L	0	72,58	69,18	67,51	67,06	77,95
	5	69,43	63,98	61,62	62,18	72,78
	10	65,81	62,1	56,4	59,33	69,65
	15	60,84	58,69	51,67	56,15	65,77
	20	58,4	53,42	45,63	46,74	60,76
	25	55,2	49,73	40,49	40,8	56,24
M	30	38,34	44,91	37,37	34,86	51,77
	0	71,51	71,76	64,06	69,55	70,32
	5	66,62	66,3	57,52	64,69	65,72
	10	62,68	63,1	50,4	62,25	62,39
	15	57,32	54,64	47,43	58,36	60,58
	20	53,99	49,36	42,88	49,4	57,37
N	25	48,99	43,42	37,87	43,46	52,07
	30	42,09	40,95	34,17	32,83	47,69
	0	72,38	72,62	71,1	68,38	77,86
	5	67,62	67,45	66,16	64,05	73,47
	10	65,09	63,79	58,71	61,88	69,92
	15	60,44	61,29	54,59	53,78	67,69
O	20	58,55	57,28	48,57	46,17	65,59
	25	55,34	54,07	42,91	36,85	60,9
	30	39,16	48,93	40,14	26,95	56,35
	0	77,47	68,75	68,25	67,96	72,91
	5	72,1	62,2	61,6	63,58	69,45
	10	69,46	59,09	54,07	61,03	65,05
	15	65,41	56,03	48,95	54,92	60,89
	20	62,88	47,9	45,84	45,81	57,51
	25	56,81	42,84	42,65	36,48	55,16
	30	45,93	39,16	32,04	25,79	51,74
Average reduction	31,82	28,89	31,39	39,92	(1) 21,96	
	(4)	(2)	(3)	(5)		

مقایسه جداول (9) و (10) نشان می‌دهد که نویز برچسب اثر مخرب‌تری بر روی عملکرد روش پیشنهادی دارد. اگرچه که نویز ویژگی بیشتر بر روی تابع اختلاف تاثیر منفی می‌گذارد اما تاثیر

Wilcoxon test	h_1	
---------------	-------	--

همچنین روش SVM طبقه‌بندی را در مدت زمان بیشتری انجام خواهند داد. با توجه به محاسبات لازم جهت شباهت‌سنجی میان داده‌ها و محاسبه وزن در روش پیشنهادی، AWTQS-SVM وظایف را در مدت زمان بیشتری را در مقایسه با T-SVM انجام می‌دهد.




شکل (2): مقایسه زمان محاسباتی (s) روش پیشنهادی با دو روش استاندارد به ازای 5 وظیفه A-E و سطوح مختلفی از داده آموزشی.

9,4 مقایسه با روش AWTQS-SVM

7,4 بررسی تاثیر پارامتر ω

با توجه به اهمیت پارامتر ω در کنترل وزن مشارکت دامنه منبع، حساسیت عملکرد مدل نسبت به این پارامتر بررسی گردید. بدین منظور، پارامتر ω با تغییر از مقدار 0,1 تا مقدار 1 (کاملاً متکی بر دامنه منبع) با اندازه گام 0,1 انتخاب گردید و میزان صحت برای 5 وظیفه اول (A-E) محاسبه و منحنی تغییرات آن در شکل (1) ترسیم شد.




شکل (1): منحنی تغییرات صحت (%) به ازای تغییر پارامتر ω در دامنه هدف 50% از نمونه‌ها برای آموزش استفاده شده‌اند.

بر این اساس، عملکرد روش پیشنهادی با افزایش پارامتر ω به تدریج بهتر می‌شود. در اکثر وظیفه‌ها، بیشینه عملکرد در وزن 0,6 رخ داده و پس از آن کمی افت ملائم عملکرد مشاهده می‌شود. کمترین عملکرد نیز زمانی است که تنها دامنه منبع به عنوان تابع تصمیم‌گیری نهایی در نظر گرفته شود.

8,4 مقایسه زمان محاسبه با الگوریتم‌های SVM و T-SVM

زمان محاسباتی روش پیشنهادی با دو روش استاندارد SVM و T-SVM در پنج وظیفه انتخابی اول و به ازای میزان داده‌های آموزشی متفاوت در دامنه هدف بررسی گردید و نتایج آن در نمودار شکل (2) آورده شده است. همان‌طور که مشاهده می‌شود با افزایش میزان داده‌های آموزشی زمان محاسبه هر سه روش افزایش یافته،




شکل (3): مقایسه صحت (F) عملکرد روش پیشنهادی با روش ABTQS-SVM به ازای میزان داده‌های آموزشی متفاوت (F).

صحت عملکرد و زمان محاسباتی روش پیشنهادی با پژوهش پیشین نویسندگان به نام ABTQS-SVM [25] مقایسه گردید. در روش مذکور وزن هر نمونه W_i با استفاده از رویکرد احتمالی تابع باور به دست می‌آید.

مقایسه معیار صحت نشان می‌دهد که در همه وظایف (A-E)، مدل AWTQS-SVM دقت بالاتری نسبت به ABTQS-SVM دارد، هر چند اختلاف در برخی موارد مثل وظیفه C در 50% بسیار کم است. افزایش درصد داده آموزشی (از 30% به 70% معمولاً باعث افزایش دقت هر دو مدل می‌شود، اما AWTQS-SVM رشد پایدارتری دارد.

مقایسه زمان محاسباتی نشان می‌دهد در صورتی که 30% داده‌های دامنه هدف داده‌های آموزشی باشند، هر دو مدل زمان محاسباتی تقریباً یکسانی دارند (حدود 426 تا 435 ثانیه) اما در صورتی که 50% داده‌های دامنه هدف داده‌های آموزشی باشند، تفاوت چشمگیر است و AWTQS-SVM عملکرد بهتری دارد. همچنین، چنانچه 70% داده‌های دامنه هدف داده‌های آموزشی باشند، اختلاف‌ها بسیار کم و در حد 1-3 واحد است، بنابراین هر دو مدل تقریباً مشابه عمل می‌کنند.

شکل (4): مقایسه زمان محاسباتی (s) عملکرد روش پیشنهادی با روش ABTQS-SVM به ازای میزان داده‌های آموزشی متفاوت (.)



پیشنهاد گردید. در این روش به جای یک مسأله پیچیده برنامه‌ریزی درجه دوم SVM کلاسیک، برای هر کلاس موجود یک مسأله بهینه‌سازی معادله خطی ساده در نظر گرفته شده که منجر به کاهش چشمگیر هزینه محاسباتی می‌گردد. همچنین، با بهره‌گیری از نظریه مجموعه‌های فازی راف، سهم نمونه‌های غیرقابل اعتماد در فرآیند یادگیری کاهش یافته و مدل از پایداری بالاتری در برابر داده‌های آلوده به نوبز برخوردار می‌شود. مدل پیشنهادی از حیث انطباق دامنه نیز دارای مزیت مهمی است: در مرحله انتقال، نیازی به دسترسی مجدد به داده‌های منبع وجود ندارد و تنها پارامترهای آموخته‌شده از آن (مراکز و شعاع کره‌ها) مورد استفاده قرار می‌گیرند. بدین ترتیب، انطباق دامنه در غیاب داده‌های منبع انجام شده و این ویژگی می‌تواند در سناریوهای واقعی — مانند حوزه‌های صنعتی، پزشکی یا امنیتی — که در آن‌ها به اشتراک‌گذاری داده‌های منبع امکان‌پذیر نیست، بسیار کاربردی باشد. نتایج آزمایش‌ها بر روی دو مجموعه داده معیار 20newsgroup و AWA نشان می‌دهند که روش پیشنهادی در مقایسه با روش‌های رقیب در اغلب وظایف عملکرد بهتری از نظر صحت طبقه‌بندی و پایداری در برابر نویز دارد. همچنین، تحلیل زمان اجرا نشان داد که به دلیل ساختار خطی مدل، سرعت یادگیری و همگرایی مطلوبی دارد.

اگرچه مدل AWTQS-SVM در مقایسه با روش‌های موجود نتایج قابل توجهی ارائه داده است، اما هنوز زمینه‌های متعددی برای توسعه و بهبود آن وجود دارد. در ادامه به برخی از مسیرهای آینده پژوهش اشاره می‌شود:

توسعه مدل به یادگیری چندمنبعی²⁰: در نسخه فعلی، مدل تنها یک دامنه منبع و یک دامنه هدف را در نظر می‌گیرد. توسعه

5. نتیجه‌گیری و کارهای آینده

در این مقاله، مدل انطباق دامنه شبه نظارتی با عنوان ماشین بردار پشتیبان ربع کره دو قلو تطبیقی وزن‌دار (AWTQS-SVM)

- svms ,۲۰۰۷ " ,pp. 188–197, doi: 10.1145/1291233.1291276 .
- [۵] R. Khemchandani and S. Chandra, "Twin support vector machines for pattern classification," *IEEE Transactions on pattern analysis and machine intelligence*, vol. 29, no. 5, pp. 905–910, 2007, doi: 10.1109/TPAMI.2007.1068.
- [۶] S. Ding, N. Zhang, X. Zhang, and F. Wu, "Twin support vector machine: theory, algorithm and applications," *Neural Computing and Applications*, vol. 28, no. 11, pp. 3119–3130, 2017, doi: 10.1007/s00521-016-2245-4.
- [۷] Y. Li, H. Sun, and W. Yan, "Domain adaptive twin support vector machine learning using privileged information," *Neurocomputing*, vol. 469, pp. 13–27, 2022, doi: 10.1016/j.neucom.2021.10.069.
- [۸] م. ابراهیمی "مروری بر رویکرد and م. رثوف مقدم (in fa), ییلوگ. ی عمیق در صنعت هوافضا," (vol. 11, no. 2, pp. 104–117, 2023, doi: 10.22052/scj.2023.243422.1036.
- [۹] Z. Han, X.-J. Gui, C. Cui, and Y. Yin, "Towards accurate and robust domain adaptation under noisy environments," *arXiv preprint arXiv:2004.12529*, 2020.
- [۱۰] J. Zhuo, S. Wang, and Q. Huang, "Uncertainty modeling for robust domain adaptation under noisy environments," *IEEE Transactions on Multimedia*, vol. 25, pp. 6157–6170, 2022, doi: 10.1109/TMM.2022.3205457.
- [۱۱] Q. Yang, Q. Cheng, H. Yue, L. Zhang, Y. Liu, and J. Yang, "Learning to See Low-Light Images via Feature Domain Adaptation," *IEEE Trans Image Process*, vol. 34, pp. 2680–2693, 2025, doi: 10.1109/TIP.2025.3563775.
- [۱۲] M. Moradi, M. Rahmanimanesh, and A. Shahzadi, "Transfer learning for concept drifting data streams in heterogeneous environments," *Knowledge and Information Systems*, vol. 66, no. 5, pp. 2799–2857, 2024, doi: 10.1007/s10115-023-02043-w.
- [۱۳] D. Guan, J. Huang, A. Xiao, S. Lu, and Y. Cao, "Uncertainty-aware unsupervised domain adaptation in object detection," *IEEE Transactions on Multimedia*, vol. 24, pp. 2502–2514, 2021, doi: 10.1109/TMM.2021.3082687.
- [۱۴] Y. Tan, B. Wu, J. Cao, and B. Jiang, "LLaMA-UTP: Knowledge-Guided Expert Mixture for Analyzing

مدل برای انطباق دامنه هم‌زمان میان چندین دامنه منبع می‌تواند توانایی تعمیم آن را افزایش دهد.

به‌کارگیری در داده‌های چندوجهی^{۲۱}: توسعه مدل برای داده‌هایی که شامل اطلاعات متنی، تصویری و صوتی به‌صورت هم‌زمان هستند، می‌تواند مسیر جدیدی در انطباق دامنه چندوجهی ایجاد کند.

بهینه‌سازی تطبیقی پارامترها: استفاده از روش‌های تکاملی یا یادگیری تقویتی برای تنظیم خودکار پارامترهای مدل می‌تواند پایداری و کارایی مدل را در سناریوهای واقعی افزایش دهد.

تعمیم به مسائل چند کلاسه^{۲۲}: اگرچه روش پیشنهادی برای وظایف طبقه‌بندی دودویی فرموله و ارزیابی شده است، اما می‌توان با اتخاذ رویکردهایی مانند یک در مقابل یک^{۲۳} یا یک در مقابل همه^{۲۴} مدل پیشنهادی را به مسائل چند کلاسه تعمیم داد.

مراجع

- [۱] م. زارع چاهوکی, "تحلیل and ک. جهان پ. . احساسات رمزرها با ییلوگ. ی انتقالی شات صفر," (vol. 14, no. 1, pp. 154–183, 2025, doi: 10.22052/scj.2025.255169.1258.
- [۲] M. Moradi, M. Rahmanimanesh, and A. Shahzadi, "Unsupervised domain adaptation by incremental learning for concept drifting data streams," *International Journal of Machine Learning and Cybernetics*, vol. 15, no. 9, pp. 4055–4078, 2024, doi: 10.1007/s13042-024-02135-1.
- [۳] M. Moradi, M. Rahmanimanesh, A. Shahzadi, and R. Monsefi, "Smooth unsupervised domain adaptation considering uncertainties," *Information Sciences*, vol. 648, p. 119602, 2023, doi: 10.1016/j.ins.2023.119602.
- [۴] J. Yang, R. Yan, and A. G. Hauptmann, "Cross-domain video concept detection using adaptive

- 11, pp. 10646–10663, 2025, doi: 10.1109/TPAMI.2025.3593669.
- [۲۵] M. Moradi and J. Hamidzadeh, "A domain adaptation method by incorporating belief function in twin quarter-sphere SVM," *Knowledge and Information Systems*, vol. 65, no. 7, pp. 3125–3163, 2023, doi: 10.1007/s10115-023-01857-y.
- Uncertain Tax Positions," *IEEE Access*, 2025, doi: 10.1109/ACCESS.2025.3571502.
- [۱۵] ن. طاهری جوان, "الگوریتم and کریمی بنماران هیلی. نوین برای شبکه های سگری. سیمز پر آب با استفاده از یادگیری تقوید و شبکه های سی. (محاسبات نرم, ۲۰۲۵, in fa متخصصی زاید, ") , doi: 10.22052/scj.2025.255711.128.۱
- [۱۶] M. Long, Z. Cao, J. Wang, and M. I. Jordan, "Conditional adversarial domain adaptation," *Advances in neural information processing systems*, vol. 31, 2018, doi: 10.5555/3326943.3327094.
- [۱۷] E. Tzeng, J. Hoffman, K. Saenko, and T. Darrell, "Adversarial discriminative domain adaptation," 2017, pp. 7167–7176, doi: 10.1109/CVPR.2017.316.
- [۱۸] Y. Ganin *et al.*, "Domain-adversarial training of neural networks," *Journal of machine learning research*, vol. 17, no. 59, pp. 1–35, 2016, doi: 10.5555/2946645.2.۹۴۶۷۰۴
- [۱۹] J. Zhu, B. Bolsterlee, Y. Song, and E. Meijering, "Improving cross-domain generalizability of medical image segmentation using uncertainty and shape-aware continual test-time domain adaptation," *Med Image Anal*, vol. 101, p. 103422, 2025, doi: /۱۰۰۱۰۱۶j.media.2024.103422.
- [۲۰] B. Chen, X. Zhang, C. Shen, Q. Li, and Z. Song, "CoUDA: Continual Unsupervised Domain Adaptation for Industrial Fault Diagnosis Under Dynamic Working Conditions," *IEEE Transactions on Industrial Informatics*, 2025, doi: 1/۰۰۱۱۰۹TII.2025.3538135.
- [۲۱] S.-Y. Li, S.-J. Zhao, Z.-T. Cao, S.-J. Huang, and S. Chen, "Robust domain adaptation with noisy and shifted label distribution," *Frontiers of Computer Science*, vol. 19, no. 3, p. 193310, 2025, doi: 10.1007/s11704-024-3810-0.
- [۲۲] B. Wang, F. Deng, Z. Chen, Z. Yu, and Y. Liu, "Prototype-Based Pseudo-Label Denoising for Source-Free Domain Adaptation in Remote Sensing Semantic Segmentation," *arXiv preprint arXiv:2509.16942*, 2025.
- [۲۳] Y. Cheng *et al.*, "DCST: Dual cross-supervision for transformer-based unsupervised domain adaptation," *Neural Networks*, vol. 181, p. 106749, 2025, doi: 10.1016/j.neunet.2024.106749.
- [۲۴] S. Qu *et al.*, "GLC++: Source-Free Universal Domain Adaptation Through Global-Local Clustering and Contrastive Affinity Learning," *IEEE Trans Pattern Anal Mach Intell*, vol. 47, no.