

یادگیری انتقالی چندمنبعی مبتنی بر قواعد

فازی برای بهبود دقت طبقه‌بندی تصاویر



معصومه قلیزاده^۱، هادی سلطانی‌زاده^{۲*}، محمد رحمانی منش^۳

دانشجوی دکتراى هوش مصنوعى دانشکده مهندسى برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران^۱

دانشیار دانشکده مهندسى برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران^{۲*}

دانشیار دانشکده مهندسى برق و کامپیوتر، دانشگاه سمنان، سمنان، ایران^۳

چکیده

در طبقه‌بندی تصاویر، فراهم کردن تعداد کافی برچسب برای آموزش مدل‌ها، اغلب پرهزینه و زمان‌بر است؛ به همین دلیل، الگوریتم‌های یادگیری انتقالی به دلیل قابلیت استفاده از دانش موجود، مورد توجه بسیاری قرار گرفته‌اند. بیشتر رویکردهای یادگیری انتقالی بر روی تطبیق دامنه با یک منبع واحد تمرکز دارند؛ با این حال، تعداد اندکی از پژوهش‌ها به مسئله تطبیق دامنه چندمنبعی پرداخته‌اند، که در عین واقع‌گرایی بیشتر، چالش‌های پیچیده‌تری را نیز به همراه دارد. ترکیب دانش از منابع مختلف می‌تواند ابهام و عدم قطعیت را افزایش دهد؛ از این رو، قوانین فازی که در مدیریت عدم قطعیت مؤثرند، می‌توانند گزینه‌ای مناسب برای این مسئله باشند. در یادگیری انتقالی چندمنبعی مبتنی بر قوانین فازی، از این قوانین برای انتقال دانش میان منابع مختلف استفاده می‌شود؛ با این حال، چالش اصلی، نحوه ترکیب و بهره‌برداری بهینه از دانش موجود در این منابع است. این پژوهش یک روش یادگیری انتقالی چندمنبعی مبتنی بر قوانین فازی را پیشنهاد می‌کند. نتایج آزمایش‌ها بر روی مجموعه داده‌های تصویری نشان می‌دهند که روش پیشنهادی در مقایسه با سایر روش‌های پیشرفته یادگیری انتقالی عملکرد بهتری ارائه می‌دهد.

واژگان کلیدی: یادگیری ماشین، یادگیری انتقالی، قواعد فازی، تطبیق دامنه چندمنبعی.

Multi-Source Transfer Learning Based on Fuzzy Rules for Improving Image Classification Accuracy

Masoume Gholizade¹, Hadi Soltanizadeh^{2*}, Mohammad Rahmanimanesh³

Ph.D. Candidate in Artificial Intelligence, Faculty of Electrical and Computer Engineering,
Semnan University, Semnan, Iran¹

Associate Professors, Faculty of Electrical and Computer Engineering,
Semnan University, Semnan, Iran^{2*}

Associate Professors, Faculty of Electrical and Computer Engineering,
Semnan University, Semnan, Iran³

Abstract

Image classification tasks often involve the challenge of acquiring a sufficient number of labeled training samples, a process that is not only expensive but also time-consuming. In response to this issue, researchers have focused on transfer learning algorithms, which capitalize on prior knowledge to enhance a model training. While numerous existing transfer learning methods concentrate on knowledge transfer between a single-source domain and a single-target domain, the complexity of real-world scenarios is often underestimated. Limited studies have delved into domain adaptation within multi-source environments, where transferring knowledge from multiple sources introduces ambiguity and uncertainty into the learning process. To address this challenge, this study proposes the application of fuzzy rule-based transfer learning, leveraging the inherent ability of fuzzy rules to effectively handle uncertainty.

* Corresponding author

* نویسنده عهده‌دار مکاتبات

سال ۱۴۰۳ شماره ۴ پیاپی ۶۲

• تاریخ ارسال مقاله: ۱۴۰۲/۷/۲۲ • تاریخ پذیرش: ۱۴۰۳/۹/۱۴ • تاریخ انتشار: ۱۴۰۳/۱۲/۳۰ • نوع مطالعه: پژوهشی

One notable aspect of fuzzy transfer learning, and transfer learning in general, is the unresolved question of effectively combining and utilizing knowledge when multiple source domains are available. This issue is particularly pertinent in scenarios involving diverse datasets from various sources. Consequently, the present study introduces a novel approach to multi-source transfer learning anchored in fuzzy rules. By integrating fuzzy logic, the proposed method aims to provide a robust solution to the challenges posed by knowledge transfer in scenarios with multiple source domains. This research contributes to advancing transfer learning methodologies, offering a nuanced perspective on handling uncertainty in multi-source environments by applying fuzzy rule-based techniques.

In conclusion, the significance of transfer learning in image classification tasks is underscored by the inherent challenges of acquiring labeled training data. The conventional focus on single-source to single-target domain transfer has limitations, prompting a shift towards addressing the more realistic and challenging scenarios of multi-source domain adaptation. This study introduces a pioneering approach to multi-source transfer learning, utilizing fuzzy rule-based techniques to effectively navigate the complexities introduced by knowledge transfer from multiple sources. Through this contribution, the research aims to propel advancements in transfer learning methodologies and foster a more comprehensive understanding of handling uncertainty in multi-source environments.

Keywords: Machine learning, transfer learning, fuzzy rules, multi-source domain adaptation.

می‌توان گفت که انطباق دامنه به‌منظور کاهش تأثیر شکاف بین دامنه در طول انتقال دانش اهمیت دارد [۶]. به‌دلیل علاقه‌مندی گسترده پژوهش‌گران به این حوزه، الگوریتم‌های متنوعی برای حل مسائل یادگیری انتقالی در حال توسعه‌اند و مقالات علمی به بررسی وظایف مختلف در حوزه‌های تخصصی نظیر تشخیص صدا [۷]، شناسایی اشیا [۸] و شناسایی تصویر [۹] پرداخته‌اند [۱۰].

یانگ و همکاران در مقاله [۲]، یک الگوریتم تطبیق دامنه عمومی‌تر از چند منبع را برای طبقه‌بندی تصاویر پیشنهاد کردند، که در آن مجموعه برچسب‌های دامنه‌های منبع متعدد می‌تواند متفاوت باشد و مجموعه برچسب دامنه هدف به طور کامل ناشناخته است. چالش اصلی در این پژوهش شناسایی مجموعه برچسب مشترک بین هر منبع و دامنه هدف و مقیاس‌پذیر نگاه داشتن مدل با افزایش تعداد دامنه‌های منبع است.

مقاله [۱۱] یکی دیگر از مقالاتی است که از انطباق دامنه برای طبقه‌بندی تصویر استفاده می‌کند؛ نویسندگان این مقاله یک شبکه انطباق زیردامنه عمیق^۱ (DSAN) را برای طبقه‌بندی تصویر پیشنهاد کردند که توزیع‌های زیردامنه‌های مربوطه را در دامنه‌های مختلف تراز می‌کند. در این کار آن‌ها یک شبکه انطباق زیردامنه عمیق را ارائه می‌کنند که یک شبکه انتقال را با تراز کردن توزیع‌های زیردامنه مربوطه از فعال‌سازی لایه‌های خاص در دامنه‌های مختلف بر اساس اختلاف بیشینه میانگین محلی^۲ (LMMD) یاد می‌گیرد، درحالی‌که روش‌های موجود در حل مسائل تطبیق دامنه تا حدی موفق بوده‌اند، بیشتر آن‌ها به پدیده عدم قطعیت ذاتی در طول انتقال

¹ Deep subdomain adaptation network for image classification

² Local Maximum Mean Discrepancy

۱- مقدمه

در دهه‌های اخیر، پیشرفت در الگوریتم‌های یادگیری به‌طور قابل توجهی پژوهش‌های مربوط به طبقه‌بندی تصاویر تحت نظارت را گسترش داده‌است. الگوریتم‌های یادگیری ماشین و یادگیری عمیق از حجم بالایی از داده‌های برچسب‌گذاری شده به‌عنوان مجموعه داده‌های آموزشی برای آموزش مدل استفاده می‌کنند و سپس مدل آموزش‌دیده را بر روی مجموعه داده‌های آزمون بدون برچسب که فضای ویژگی و توزیع احتمالی مشابه با مجموعه داده‌های آموزشی دارند، به‌کار می‌گیرند [۱]. از آنجایی که مجموعه‌های کلان داده برای طبقه‌بندی تصاویر در دسترس عموم هستند، مدل‌های یادگیری در بسیاری از حوزه‌ها به‌خوبی عمل می‌کنند؛ با این حال، برچسب‌گذاری داده‌های تصویر در مقیاس بزرگ زمان‌بر و پیچیده است [۲]؛ به بیانی دیگر، در مسائل دنیای واقعی، به‌دلیل پرهزینه بودن یا مشکلات مربوط به حریم خصوصی، جمع‌آوری داده‌های تصویر برچسب‌گذاری شده کافی که دارای فضای ویژگی یا توزیعی یکسانی با مجموعه آزمون باشد، دشوار است؛ این امر منجر به شکست الگوریتم‌های یادگیری می‌شود [۳].

در چنین شرایطی، یادگیری انتقالی [۴] به‌عنوان یک انتخاب مناسب برای حل مسئله انتقال اطلاعات از دامنه منبع برچسب‌گذاری شده به دامنه هدف دارای محدودیت برچسب، مطرح شده‌است که با الهام‌گرفتن از مکانیسم یادگیری انسان‌ها عمل می‌کند. درکل یادگیری انتقالی، به مسئله چگونگی استفاده از دانشی که پیش‌تر به‌دست آمده‌است، برای بهبود کارایی و دقت یادگیری در یک دامنه متفاوت، اما مرتبط می‌پردازد و درصدد کاهش تأثیر انفعال دامنه‌ها در طول انتقال دانش است [۵]؛ در نتیجه

با وجود پیشرفت‌های چشم‌گیر در روش‌های یادگیری انتقالی بر مبنای سیستم فازی، چالش اصلی همچنان چگونگی ادغام و انتقال دانش در زمانی است که چندین دامنه مبدأ وجود دارد. این نوع مسائل در دنیای واقعی بسیار متداول است؛ برای مثال، در حوزه تصاویر، تصور کنید که می‌خواهیم یک مدل تشخیص چهره ایجاد کنیم که هم بتواند چهره‌های افراد را در عکس‌های پرتره حرفه‌ای و هم در تصاویر دوربین‌های مداربسته تشخیص دهد؛ در این حالت، دو دامنه مبدأ متفاوت وجود دارد: یکی عکس‌های باکیفیت پرتره که شرایط نوری و وضوح بالایی دارند و دیگری تصاویر دوربین‌های مداربسته که بیشتر اوقات تاریک، کم کیفیت و دارای شرایط نوری نامناسب‌اند.

چالش این است که چگونه می‌توان این دو مجموعه داده با توزیع‌های ویژگی به‌طور کامل متفاوت را به‌گونه‌ای ادغام کرد که مدل بتواند به‌طور مؤثر از هر دو مجموعه داده یاد بگیرد و آن‌ها را برای تشخیص چهره در تصاویر دنیای واقعی (دامنه هدف) به‌کار بگیرد. در اینجا، مسئله اصلی تطبیق دامنه چندمنبعی است که باید بتواند تفاوت‌های بین این دو دامنه را در نظر گرفته و هم‌زمان از ویژگی‌های مشترک آن‌ها بهره‌برداری کند تا دقت تشخیص چهره در شرایط مختلف حفظ شود.

به‌تازگی، روش‌هایی برای حل این مشکل پیشنهاد شده‌است؛ برای مثال، لو و همکاران [۱۲] یک یادگیری انتقالی چندمنبعی فازی، بر مبنای مدل فازی تاکاگی-سوگنو ارائه کردند که برای تطبیق دامنه چندمنبعی به‌منظور مقابله با وظایف رگرسیونی است؛ به طوری که فضای ویژگی با ابعاد یکسان و متفاوت در نظر گرفته شده‌است. لی و همکاران [۲۰] یادگیری مشارکت چندمنبعی را برای تطبیق دامنه ارائه کردند، که شباهت‌ها و تفاوت‌های میان دامنه‌ها را هم‌زمان بررسی و یک راه‌کار تنظیم وزن را برای یادگیری اهمیت منابع تعریف می‌کند. مقالات دیگر نیز به رویکردهای منبع آزاد برای کاهش نگرانی‌های مرتبط با حریم خصوصی پرداخته‌اند؛ برای مثال، در یک مطالعه جدید [۲۱] روش تطبیق دامنه بدون منبع بر مبنای قواعد فازی تحت عنوان SF-FDN معرفی شده‌است که از سیستم‌های فازی برای سازگاری دامنه بدون نیاز به داده‌های منبع بهره می‌برد. این روش با استفاده از شبکه‌های عصبی عمیق مبتنی بر قوانین فازی، قادر است عدم قطعیت داده‌ها را در شرایطی که داده‌های منبع در دسترس نیستند، مدیریت کند.

دانش که عامل حیاتی در طول این فرایند است، توجه نکرده‌اند [۱۲]. وجود اطلاعات ناکافی منجر به افزایش درجه نبود قطعیت می‌شود؛ در صورتی که داده‌های برچسب‌دار در دامنه هدف کم یا غایب باشند، تنها مقدار محدودی اطلاعات قابل استخراج است و این موضوع، عدم قطعیت را تشدید می‌کند؛ با این حال، ظهور سیستم‌های فازی نتایج امیدوارانه‌ای در مواجهه با این چالش نشان داده‌است [۱۳، ۱۴، ۱۵].

ادغام منطق فازی با یادگیری انتقالی، توجه زیادی را در ادبیات پیشینه به خود جلب کرده‌است. انتقال دانش ضمنی و صریح از دامنه‌های مشابه و مرتبط به‌طور طبیعی با ابهام همراه است؛ در این راستا، استفاده از منطق فازی می‌تواند برای کنترل ابهام و عدم قطعیت مناسب باشد و در عین حال دقت انتقال را نیز بهبود بخشد [۱۶]؛ بنابراین، بسیاری از پژوهش‌گران به سیستم‌های فازی به‌عنوان یک راه حل معتبر برای مسائل یادگیری انتقالی با نتایج قابل اعتماد روی آورده‌اند. لیو و همکاران [۱] در مسائل تطبیق دامنه ناهمگن نظارت‌نشده تمرکز کرده و یک مدل یادگیری انتقالی جدیدی ارائه داده‌اند که شامل هندسه فازی چندبعدی و روابط معادلات فازی است؛ آن‌ها معیاری بر اساس هندسه فازی چندبعدی تعریف کرده‌اند تا شباهت ویژگی‌ها بین دامنه‌ها را اندازه‌گیری کنند.

مهر و همکاران در مقاله [۱۷] یک مدل یادگیری فازی مبتنی بر قانون قابل تفسیر^۱ (IRF) برای تطبیق دامنه در طبقه‌بندی تصاویر سنجش‌ازدور پیشنهاد کردند؛ به‌نوعی در این پژوهش استفاده از یک مدل یادگیری فازی مبتنی بر قانون قابل تفسیر پیشنهاد شده که با استفاده از پیشینه مقدار عضویت فازی ویژگی‌های مشخص شده به‌وسیله فازی‌سازی تعلق طبقاتی و دو ماتریس استخراج قانون استخراج شده‌است.

دنگ و همکاران [۱۸] مجموعه‌ای از روش‌های یادگیری انتقالی را بر پایه یک سیستم فازی ممدانی^۲ و مدل فازی تاکاگی-سوگنو^۳ ارائه کردند که شامل الگوریتم‌های جدید منطق فازی و تعریف دو تابع هدف است. آن‌ها روش‌های خود را در سناریوهایی با داده‌های محدود، مانند تشخیص سیگنال‌های الکتروانسفالوگرام (EEG) به‌کار بردند. بهبود و همکاران [۱۹] نیز رویکردی مبتنی بر یادگیری انتقالی فازی برای پیش‌بینی ورشکستگی بانک‌ها در بلندمدت پیشنهاد کردند.

¹ Interpretable Rule-Based Fuzzy

² Mamdani

³ Takagi-Sugeno



در این رویکرد، با تکیه بر یادگیری خودنظارتی و تنظیم مدل بر اساس داده‌های هدف، هم‌ترازی میان دامنه‌ها بهبود می‌یابد و عملکرد مدل به‌ویژه در سناریوهای چند دامنه‌ای و تطبیق با برجسب‌های نامتجانس به اثبات رسیده‌است.

در این مقاله، ما توانایی قواعد فازی را در مواجهه با مسائل یادگیری انتقالی بررسی می‌کنیم. هنگامی که چندین دامنه مبدأ برای انتقال دانش به دامنه هدف وجود دارد و یک الگوریتم جدید ارائه می‌کنیم که بر اساس آن دانش به‌واسطه قواعد فازی از دامنه‌های منبع به دامنه هدف منتقل می‌شود.

نوآوری خاص این مقاله در توصیف توانایی تطبیق دامنه با استفاده از قوانین فازی در محیط‌های چندمنبعی برای وظایف طبقه‌بندی تصویر است. استفاده از سیستم‌های فازی، قابلیت مدل را برای مدیریت عدم قطعیت در محیط‌هایی که دارای اطلاعات ناکافی است بهبود می‌بخشد و دقت پیش‌بینی را افزایش می‌دهد. در روش پیشنهادی برای طبقه‌بندی تصاویر، یک الگوریتم تطبیق دامنه چندمنبعی را پیشنهاد می‌کنیم که از ترکیب قوانین فازی و شبکه‌های عصبی عمیق الهام گرفته شده‌است. در روش پیشنهادی، ابتدا از یک شبکه از پیش آموزش‌دیده برای استخراج ویژگی‌های تصاویر منبع و هدف با تطبیق توزیع‌های دامنه‌ها استفاده می‌شود؛ سپس قوانین فازی بر اساس ویژگی‌های استخراج‌شده ساخته می‌شوند تا بتواند طبقه‌بندی جدیدی را برای منابع ایجاد کند؛ درنهایت، تمام طبقه‌بندی‌های منبع با استفاده از عضویت فازی که توسط یک تشخیص‌دهنده دامنه آموخته‌شده ترکیب می‌شوند تا کار هدف را تکمیل کنند. مشارکت‌های اصلی ما به شرح زیر است:

ما در این پژوهش یک روش نوین برای تطبیق دامنه چندمنبعی تصاویر ارائه داده‌ایم که از قواعد فازی و شبکه‌های عصبی عمیق به‌صورت ترکیبی استفاده می‌کند. این مدل ترکیبی، هم از قابلیت‌های قدرتمند شبکه‌های عصبی عمیق در استخراج ویژگی‌ها بهره می‌برد و هم با استفاده از منطق فازی، به کنترل عدم قطعیت‌های موجود در فرایند یادگیری انتقالی و تطبیق دامنه کمک می‌کند.

در این پژوهش از عضویت فازی برای تعریف سهم منبع در وظیفه هدف استفاده می‌شود. این ساختار فازی به مدل اجازه می‌دهد تا با وزن‌دهی پویا و انعطاف‌پذیر به منابع مختلف، سهم اطلاعاتی هر یک را در یادگیری نهایی مشخص کند. این رویکرد باعث می‌شود تا مدل بتواند

به‌شکلی هوشمند، اطلاعات مهم‌تر را از منابع مختلف استخراج کرده و آن‌ها را در انجام وظیفه هدف به‌طور بهینه ترکیب کند.

یک تشخیص‌دهنده خوشه‌ای طراحی شده‌است که با استفاده از فرایند یادگیری، نمونه‌ها را بر اساس سطح اطلاعاتی آن‌ها تقسیم‌بندی می‌کند. سطح اطلاعات به‌عنوان عاملی تعیین‌کننده در بهبود عملکرد مدل شناخته می‌شود؛ باین‌حال، در مطالعات پیشین کمتر موردتوجه قرار گرفته‌است. این تشخیص‌دهنده قادر است، نمونه‌ها را براساس اطلاعات کلیدی موجود در آن‌ها گروه‌بندی کند و در نتیجه، الگوریتم یادگیری با درک دقیق‌تری از ویژگی‌های داده‌ها، به نتایج دقیق‌تری دست یابد.

باقی محتوای این مقاله به شرح زیر ارائه شده‌است: بخش دوم روش پیشنهادی را شرح می‌دهد. بخش سوم نتایج آزمایش و تجزیه‌وتحلیل داده‌های تصویری را نشان می‌دهد. نتیجه‌گیری و کارهای آینده نیز در بخش چهارم ارائه شده‌است.

۲- مرور ادبیات

در این مقاله، ما با تطبیق دامنه چندمنبعی بدون ناظر و همگن سروکار داریم. نمای کلی از تطبیق دامنه چندمنبعی در شکل (۱) آورده شده‌است. در محیط‌های همگن، ویژگی‌های منابع با هم برابر است (در شکل مثلثی و دایره‌بودن ویژگی محسوب می‌شود که در تمام منابع وجود دارد و برابر است).

به‌طور معمول حذف کامل تغییر توزیع بین یک منبع واحد و دامنه هدف غیرممکن است. تلاشی که برای ترازکردن چندین دامنه منبع و هدف انجام می‌شود درجه‌های بیشتری از عدم تطابق را ایجاد می‌کند که منجر به کاهش عملکرد مدل می‌شود. از آنجایی که توزیع نمونه‌ها در منبع‌های مختلف با هم متفاوت است، ترکیب تمام نمونه‌ها و سپس جداسازی آن‌ها به‌عنوان تنها راه حل مناسب در نظر گرفته نمی‌شود؛ زیرا با این روش تفاوت توزیع ویژگی‌ها در منابع در نظر گرفته نمی‌شود. هدف اصلی در تطبیق دامنه‌های چندمنبعی چگونگی ترکیب و استفاده از دانش منابع مختلف است.

روش پیشنهادی به شرح زیر است: در ابتدا، از یک شبکه عمیق برای استخراج ویژگی‌های قابل انتقال در فضاهای ویژگی پنهان و طبقه‌بندی از پیش آموزش‌دیده استفاده می‌کنیم؛ سپس، طبقه‌بند از پیش آموزش‌دیده میزان شباهت یک نمونه از منبع به یک خوشه را تخمین

دارای طبقه‌های یکسانی هستند که این به معنای برابری تعداد طبقه‌ها در هر دو دامنه است. هدف اصلی پیش‌بینی برچسب برای دامنه هدف یعنی Y_t است. جدول (۱) نمادهای استفاده‌شده در مقاله را نمایش می‌دهد. روش پیشنهادی در این مقاله با الهام گرفتن از مقالات [۱۳، ۲۲-۲۵] ارائه شده است.

(جدول-۱): نمادهای استفاده‌شده در مقاله

(Table-1): Symbols Used in the Paper


نماد	توصیف
D_{s_k}, D_t	دامنه‌های منبع/هدف
X_{s_k}, X_t	نمونه‌ها در دامنه‌های منبع/هدف
n_{s_k}, n_t	تعداد نمونه‌ها در دامنه‌های منبع/هدف
Y_{s_k}	برچسب نمونه‌ها در دامنه‌های منبع
Φ	ساختار شبکه عمیق از پیش آموزش دیده
Φ_k	مین شبکه عمیق استخراج‌کننده ویژگی
$v_{s_k}^l, v_{s_k}^k$	پروتوتایپ قواعد فازی منبع/هدف متعلق به مجموعه فازی
$u_{s_k}^l, u_{s_k}^k$	درجه عضویت نمونه منبع/هدف متعلق به مجموعه فازی
f_{s_k}, f_t	ویژگی‌های منبع/هدف در فضای مشترک

۲-۲- استخراج ویژگی‌های قابل انتقال

هدف اصلی استخراج ویژگی‌ها، تقویت تمایزپذیری داده‌ها در فضای ویژگی مشترک و تسهیل یادگیری روابط میان ویژگی‌های دامنه‌های مختلف است. این امر به‌ویژه در مسائل تطبیق دامنه چندمنبعی اهمیت دارد؛ زیرا هر منبع می‌تواند اطلاعات منحصر به فردی برای تسهیل انتقال دانش ارائه دهد. در این پژوهش، ما از مفهوم هم‌افزایی میان ویژگی‌های مشترک و غیرمشترک استفاده می‌کنیم تا نمایشی جامع‌تر از داده‌ها فراهم کنیم؛ از این رو، در ابتدا برای هر دامنه منبع، یک شبکه عصبی عمیق به‌گونه‌ای آموزش داده می‌شود که با ویژگی‌های خاص آن دامنه سازگار باشد. با توجه به در دسترس بودن برچسب‌ها در هر دامنه منبع، هدف در این مرحله کاهش خطا بین پیش‌بینی‌های شبکه و برچسب‌های واقعی است؛ برای این منظور، از کمینه‌سازی خطای ساختاری بهره گرفته می‌شود.

در فرایند کمینه‌سازی خطای ساختاری، از توابع خطایی استفاده می‌شود که ضمن تقویت ویژگی‌های استخراج‌شده به‌وسیله مدل، با ساختار داده‌های ورودی نیز سازگارند.

می‌زند که به‌عنوان استراتژی تخمین شباهت در نظر گرفته می‌شود؛ با این کار نمونه‌های آموزشی در هر منبع به خوشه‌های متعدد تقسیم می‌شوند، در ادامه قوانین فازی مطابق با هر خوشه برای آموزش طبقه‌بندهای جدید منبع ساخته می‌شوند؛ در نهایت، تمام طبقه‌بندهای منبع برای تکمیل وظیفه تعریف‌شده برای دامنه هدف ترکیب می‌شوند. به‌منظور یادگیری وزن‌های ترکیبی، عضویت فازی با استفاده از تفکیک‌کننده دامنه تخمین زده می‌شود. کل چارچوب در شکل (۲) نشان داده شده است.

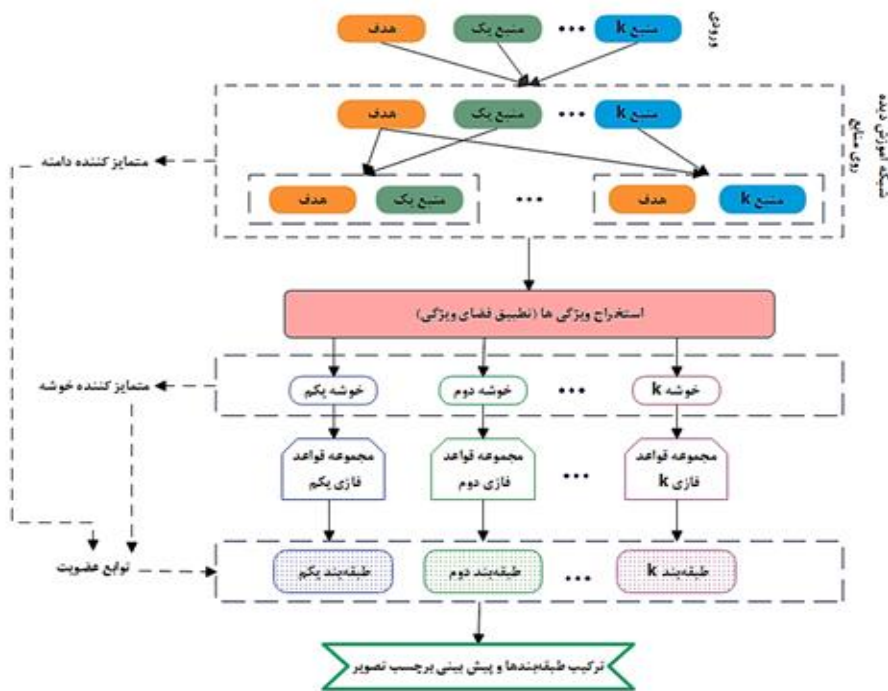


(شکل-۱): نمایی از عملکرد تطبیق دامنه

(Figure-1): A View of Domain Adaptation Performance

۲-۱- تنظیمات مسئله

در این پژوهش تمرکز اصلی در تطبیق دامنه چندمنبعی بدون نظارت و همگن است. در مسائل تطبیق دامنه چندمنبعی همگن، ابعاد ویژگی دامنه‌های منبع و دامنه هدف دارای ابعاد یکسانی هستند. k منبع برچسب‌دار داده شده است $\{D_{s_k}\}_{k=1}^K$. با توجه به دامنه‌های منبع برچسب‌گذاری شده، هر منبع با نماد D_{s_k} نمایش داده می‌شود که به صورت $\{(X_{s_k}^i, Y_{s_k}^i)\}_{i=1}^{n_{s_k}} = \{(x_{s_k}^i, y_{s_k}^i)\}_{i=1}^{n_{s_k}}$ است. در آن X_{s_k} نمونه‌های مشاهده‌شده را نشان می‌دهد که از توزیع \mathcal{P}_{s_k} پیروی می‌کنند و Y_{s_k} نشان‌دهنده برچسب‌های متناظر X_{s_k} است. n_{s_k} نشان‌دهنده تعداد نمونه‌های موجود در منبع k ام است. دامنه هدف به‌طور کامل بدون برچسب است و به صورت $D_t = \{(X_t^j)\}_{j=1}^{n_t} = \{(x_t^j)\}_{j=1}^{n_t}$ نمایش داده می‌شود که در آن X_t از توزیع \mathcal{P}_t پیروی می‌کند و n_t تعداد نمونه‌ها در دامنه هدف است. دامنه‌های مبدأ و هدف



(شکل-۲): نمایی از الگوریتم پیشنهادی
(Figure-2): An Overview of the Proposed Algorithm

$$\mathcal{L} = -\frac{1}{n_{s_k}} \sum_{i=1}^{n_{s_k}} y_{s_k}^i \log(P_{s_k}(\phi_k(x_{s_k}))) \quad (2)$$

برای تطابق توزیع دامنه‌ها، از اختلاف میانگین بیشینه^۳ (MMD) استفاده می‌کنیم. این معیار تفاوت میان توزیع‌های احتمال را با مقایسه میانگین‌های ویژگی‌های توزیع منبع و هدف در فضای هیلبرت بازتولید کمینه می‌کند.

$$\begin{aligned} &MMD(P_{s_k}, P_t) \\ &= \left\| \frac{1}{n_{s_k}} \sum_{i=1}^{n_{s_k}} \phi(f_{s_k}^i) - \frac{1}{n_t} \sum_{i=1}^{n_t} \phi(f_{t_k}^i) \right\|_{\mathcal{H}}^2 \end{aligned} \quad (3)$$

که در اینجا $\phi(\cdot)$ به‌عنوان استخراج‌کننده ویژگی نگاشت به فضای هیلبرت را نشان می‌دهد. از آنجایی که توزیع دامنه‌های منبع و هدف متفاوت است، برای کاهش فاصله توزیع ویژگی بین دامنه‌های منبع و هدف و نزدیک کردن توزیع آن‌ها، در این مرحله لازم است تا دامنه‌های منبع و هدف را تطبیق دهیم به طوری که ویژگی‌های استخراج‌شده دامنه منبع و هدف از توزیع‌های مشابه پیروی کنند، با این کار، طبقه‌بندی که بر روی دامنه منبع آموزش داده می‌شوند، این توانایی را دارند که برای هر دو دامنه اعمال شوند؛ از این رو در این مرحله، شبکه‌های عصبی در تطبیق دامنه همگن چندمنبعی مورد استفاده

این توابع خطا بر اساس توانایی مدل در پیش‌بینی ویژگی‌های جدید و هم‌بستگی میان ویژگی‌ها، تطابق با الگوهای معین و سایر خصوصیات مرتبط تعریف می‌شوند؛ بنابراین، کمینه‌سازی خطای ساختاری می‌تواند به‌طور چشم‌گیری عملکرد و کارایی مدل استخراج ویژگی را برای داده‌های دارای ساختار بهبود بخشد.

بر اساس این اصل، فرایند یادگیری برای طبقه‌بندی دامنه

$$P_{s_k} = \underset{P_{s_k} \in \mathcal{H}}{\operatorname{argmin}} \mathcal{L}(P_{s_k}(\phi_k(x_{s_k})), y_{s_k}) + \mathcal{E} \mathcal{R} \quad (1)$$

منبع k به‌صورت زیر قابل تعریف است:

ϕ_k عملگر استخراج ویژگی است، \mathcal{R} بیانگر عبارت تنظیم‌سازی است، \mathcal{H} نشان‌دهنده فضای هیلبرت با هسته بازتولید^۱ (RKHS) و \mathcal{E} یک پارامتر تبادل بهینه‌سازی است. در طول فرایند آموزش، n_{s_k} با اندازه خوشه جایگزین می‌شود. این عملگر برای معادلات دیگر این مقاله نیز اعمال می‌شود. \mathcal{L} خطای بین خروجی‌های پیش‌بینی شده و برچسب‌های واقعی تصاویر منبع است که در آن از هزینه آنتروپی متقابل^۲ برای محاسبه خطا استفاده می‌شود:

¹ Reproducing Kernel Hilbert Space

² Cross-entropy loss

³ Maximum Mean Discrepancy

MMD برای کاهش اختلاف بین توزیع‌های منبع و هدف به کار می‌رود. با مقایسه میانگین نمایندگی‌های دو توزیع در یک فضای هیلبرت، MMD روشی مؤثر برای هم‌راستایی توزیع‌های ویژگی‌های دامنه‌های منبع و هدف ارائه می‌دهد. این رویکرد به طور مؤثری انحراف بین دو توزیع را کاهش می‌دهد و به بهبود تعمیم‌پذیری مدل در هنگام اعمال آن بر روی دامنه هدف کمک می‌کند.

در عمل، کمینه‌سازی MMD به اطمینان از مرتبط‌بودن نمایندگی‌های یاد گرفته‌شده از دامنه منبع با دامنه هدف کمک می‌کند و در نتیجه عملکرد کلی مدل را بهبود می‌بخشد.

به طور معمول این اندازه‌گیری در حوزه یادگیری انتقالی برای مقایسه توزیع داده‌های دامنه‌ها به کار می‌رود. در این مرحله از MMD برای به کمترین حد رساندن اختلاف بین توزیع منبع و هدف در سطح دامنه استفاده می‌شود. به گونه‌ای که اختلاف میان دامنه‌های منبع را به بیشترین میزان رسانده و هم‌زمان توزیع‌های دامنه‌های منبع و هدف را هماهنگ سازد. این رویکرد می‌تواند مانع از ایجاد هم‌بستگی بالا میان ویژگی‌های مشترک و متنوع به طور هم‌زمان شود. تطبیق توزیع در سطح دامنه را می‌توان به صورت زیر بیان کرد؛ در این روش، معیار MMD به عنوان ابزار سنجش اختلاف انتخاب شده است و تابع هزینه مربوط به استخراج ویژگی‌های مشترک دامنه‌های منبع بر اساس آن تعریف می‌شود.

ψ یک تابع غیرخطی است که ویژگی‌های استخراج شده را به فضای RKHS تبدیل می‌کند. از

$$\mathcal{L}_{dom} = MMD(\mathcal{H}, \mathcal{P}_{s_k}, \mathcal{P}_t) = \left\| \frac{1}{n_{s_k}} \sum_{i=1}^{n_{s_k}} \psi(Ft_{s_k}^i) - \frac{1}{n_t} \sum_{i=1}^{n_t} \psi(Ft_t^i) \right\|_{\mathcal{H}}^2 \quad (7)$$

سویی دیگر شباهت و تفاوت بین دامنه‌های منبع نیز باید در نظر گرفته شود. برای این منظور، از ویژگی‌های دیدگاه مشترک برای نمایش شباهت و از ویژگی‌های دیدگاه متفاوت برای نمایش تفاوت استفاده می‌کنیم؛ بنابراین، تطبیق دامنه‌های منبع را می‌توان با کمینه‌سازی شباهت و بیشینه‌سازی تفاوت بیان کرد.

قرار می‌گیرد؛ زیرا توانایی استخراج اطلاعات فازی مشترک را از فضاهای ویژگی چندگانه دارد و از طرفی یک فضای ویژگی پنهان جدید ایجاد می‌کند تا اختلاف منابع متعدد و هدف تولید شده را به کمترین حد برساند [26]. در واقع با این کار برای تولید قوانین فازی در تطبیق دامنه چندمنبعی از شبکه‌های عصبی عمیق استفاده می‌شود و مدل فازی تاکاگی-سوگنوا¹ نمونه‌های منبع را در مجموعه‌های فازی با توجه به سطوح مختلف اطلاعات گروه‌بندی می‌کند.

استخراج ویژگی با استفاده از یک ساختار شبکه عصبی عمیق ϕ از پیش آموزش دیده انجام می‌شود که در آن f_{s_k} و f_t نشان‌دهنده ویژگی‌ها در فضای ویژگی مشترک است [20-22].

$$f_{s_k}^i = \phi(x_{s_k}^i, \theta), \quad f_t^j = \phi(x_t^j, \theta) \quad (4)$$

$$i = 1, 2, \dots, n_{s_k}, \\ j = 1, 2, \dots, n_t, \\ k = 1, 2, \dots, K$$

θ پارامتر شبکه عمیق ϕ است که استخراج ویژگی انجام می‌دهد.

به طور معمول، یک تصویر می‌تواند ویژگی‌های مختلفی مانند لبه‌ها، رنگ‌ها و روشنایی را از زوایای متفاوت نشان دهد. با توجه به این موضوع، دامنه هدف ممکن است دارای جنبه‌های مختلفی باشد که هر یک از این جنبه‌ها با یک دامنه منبع خاص شباهت بیشتری دارد. برای نمایش داده‌ها از جوانب مختلف، ویژگی‌های مشترک به دو دسته نمایش مشترک و غیرمشترک تقسیم می‌شوند. استخراج ویژگی متناظر می‌تواند به شکل زیر بیان شود:

$$Ft_{s_k} = [f_{com_{s_k}}, f_{div_{s_k}}] \\ = [\phi_{com_k}[f_{s_k}^i, \theta_{com_k}], \phi_{div_k}[f_{s_k}^i, \theta_{div_k}]], \\ Ft_{t_k} = [f_{com_{t_k}}, f_{div_{t_k}}] \\ = [\phi_{com_k}[f_{t_k}^j, \theta_{com_k}], \phi_{div_k}[f_{t_k}^j, \theta_{div_k}]] \quad (5)$$

θ_{div_k} و θ_{com_k} پارامترهای شبکه‌های عمیق ϕ_{c_k} و ϕ_{d_k} استخراج ویژگی هستند. از آنجایی که عملیات استخراج ویژگی با هدف جمع‌آوری ویژگی‌ها از دامنه‌ها انجام می‌شود؛ از این رو، برای دامنه منبع k^{th} عملگر استخراج ویژگی با نماد ϕ_k شامل استخراج ویژگی‌های مشترک ϕ_{com_k} و استخراج ویژگی غیرمشترک ϕ_{div_k} است.

$$f_{s_k}^i = \alpha \cdot f_{c_{s_k}}^i + (1 - \alpha) f_{d_{s_k}}^i \quad (6)$$

¹ Takagi-Sugeno

این کار به توزیع بهینه قوانین فازی در دامنه‌های مختلف کمک می‌کند. هر قانون IF-THEN در این مدل شامل دو بخش است: شرط و نتیجه. شرط به صورت یک فازی ساز از مقدار ورودی‌ها تشکیل شده‌است که با استفاده از توابع عضویت فازی محاسبه می‌شود. نتیجه نیز به صورت یک تابع خطی از متغیرهای ورودی تعریف می‌شود که پارامترهای آن با استفاده از الگوریتم‌های یادگیری بهینه‌سازی مانند خطای حداقل مربعات^۱ محاسبه می‌شوند. مدل فازی تاکاگی-سوگنو قابلیت تطبیق با داده‌های چندمنبعی را دارد؛ زیرا قوانین فازی نه تنها عدم قطعیت داده‌ها را مدل می‌کنند، بلکه امکان ایجاد تفاسیر روشن از تأثیر ویژگی‌ها را فراهم می‌آورند. این ویژگی به‌ویژه در کاربردهایی مانند پیش‌بینی‌های چندمعیاره یا مسائل کلاس‌بندی پیچیده مفید است.

با ترکیب تمام قوانین IF-THEN یک مدل فازی ساخته می‌شود به طوری که با بهینه‌سازی پارامترهای مدل، عملکرد بهتری نسبت به سایر روش‌های مدل‌سازی در مواردی مانند پیش‌بینی و کنترل دارد.

از آنجایی که منابع در دامنه مبدأ $\{D_{s_k}\}_{k=1}^K$ برای داده $x_{s_k} \in R^s$ با برجسب متناظر آن یعنی $y_{s_k} \in R^c$ در منبع k یک قانون به صورت:

$$\begin{aligned} & \text{if } x_{s_k} \text{ is } A_{kl} \left(\phi_k \left(\phi(x_{s_k}) \right) \right) \\ & \text{then } y_{s_k} \text{ is } P_{lk} \left(\phi_k \left(\phi(x_{s_k}) \right) \right), \\ & l = 1, 2, \dots, l_k \end{aligned} \quad (13)$$

عملگر استخراج ویژگی با نماد ϕ_k در k امین دامنه است. پارامترهای ϕ در بین همه دامنه‌ها به اشتراک گذاشته شده‌است. استخراج‌کننده‌های ویژگی، داده‌های اصلی را به ویژگی فضای R^d تبدیل می‌کنند. شرایط فازی قانون را نشان می‌دهد، P_{kl} تابعی به‌عنوان نتیجه است که داده‌ها را از R^c به R^d تبدیل می‌کند. l_k تعداد قوانین موجود در دامنه منبع k ام را نشان می‌دهد. مدل فازی تاکاگی - سوگنو در هر دامنه منبع، ترکیب خطی خروجی‌های تمام قوانین را به‌عنوان خروجی نهایی ارائه می‌کند که به صورت زیر است:

$$y_{s_k} = \sum_{l=1}^{l_k} u_{s_k}^l \cdot P_{lk} \left(\phi_k \left(\phi(x_{s_k}) \right) \right) \quad (14)$$

به صورت زیر محاسبه می‌شود:

¹ Least Square Estimate

$$\begin{aligned} \mathcal{L}_{sim} &= \frac{2}{k(k-1)} \sum_{k1=1}^{K-1} \sum_{k2=k1+1}^K (MMD(\mathcal{H}, \mathcal{P}_{s_{k1}}^{com}, \mathcal{P}_{s_{k2}}^{com}) \\ &\quad - MMD(\mathcal{H}, \mathcal{P}_{s_{k1}}^{div}, \mathcal{P}_{s_{k2}}^{div})) \\ &= \left\| \frac{1}{n_{s_k}} \sum_{i=1}^{n_{s_k}} \psi(Ft_{s_k}^i) - \frac{1}{n_t} \sum_{i=1}^{n_t} \psi(Ft_{t_k}^i) \right\|_{\mathcal{H}}^2 \end{aligned} \quad (8)$$

به طوری که:

$$\begin{aligned} MMD(\mathcal{H}, \mathcal{P}_{s_{k1}}^{\square}, \mathcal{P}_{s_{k2}}^{\square}) &= \\ &= \left\| \frac{1}{n_{s_{k1}}} \sum_{i=1}^{n_{s_{k1}}} \psi(Ft_{s_{k1}}^i) - \frac{1}{n_{s_{k2}}} \sum_{j=1}^{n_{s_{k2}}} \psi(Ft_{s_{k2}}^j) \right\|_{\mathcal{H}}^2 \end{aligned} \quad (9)$$

عملگر \square برای نمایش div و com به کار می‌رود. با اعمال محدودیت زیر این اطمینان حاصل می‌شود که طبقه‌بندی منابع متفاوت، برجسب‌های مشابهی را برای نمونه‌های هدف یکسان برمی‌گرداند:

$$\begin{aligned} \mathcal{L}_{cro} &= \frac{2}{K(K-1)} \sum_{k1=1}^{K-1} \sum_{k2=k1+1}^K \left(\frac{1}{n_t} \sum_{j=1}^{n_t} |P_{s_{k1}}(F_{t_{k1}}^j) \right. \\ &\quad \left. - P_{s_{k2}}(F_{t_{k2}}^j) \right) \end{aligned} \quad (10)$$

در نتیجه روند یادگیری طبقه‌بند منبع K را می‌توان به صورت زیر بازنویسی کرد:

$$\begin{aligned} P_{s_k} &= \underset{P_{s_k} \in \mathcal{H}}{\operatorname{argmin}} \mathcal{L}(P_{s_k}(\phi_k(x_{s_k})), y_{s_k}) \\ &\quad + \alpha \mathcal{L}_{dom} + \beta \mathcal{L}_{sim} + \gamma \mathcal{L}_{cro} \end{aligned} \quad (11)$$

تابع هزینه نهایی به صورت رابطه زیر است که در آن λ مجموع وزنی برای تنظیم اهمیت تطابق توزیع است.

$$\mathcal{L}_{total} = \mathcal{L} + MMD \cdot \lambda \quad (12)$$

۲-۳- ایجاد مدل بر مبنای قواعد فازی

مدل فازی تاکاگی-سوگنو یک روش مدل‌سازی فازی است که برای سامانه‌های پویا و غیرخطی استفاده می‌شود. در این مدل، سیستم فازی به صورت یک مجموعه از قوانین IF-THEN با فرضیات فازی مدل می‌شود. مدل فازی تاکاگی-سوگنو نه تنها به ما امکان می‌دهد که ویژگی‌های استخراج‌شده را به خوشه‌های متعدد تقسیم کنیم، بلکه می‌تواند میزان عدم اطمینان در داده‌ها را نیز مدل کند.

$$\mathcal{L}_{P_c} = -\frac{1}{n_{s_k}} \sum_{i=1}^{n_{s_k}} y_{c_k}^i \log(P_{c_k}(F_{s_k})) \quad (18)$$

صورت زیر تعریف می‌شود: $y_{c_k}^i$ برچسب کلاس i^{th} است. تابع عضویت نیز به صورت زیر تعریف می‌شود:

$$p_{c_k} = P_{c_k}(F_{s_k}) \quad (19)$$

بنابراین، قواعد فازی تعریف شده در ابتدای این زیر بخش می‌تواند به صورت زیر بازنویسی شود:

$$\text{if } F_{s_k} \text{ is } A_m \text{ then } y_{s_k} \text{ is } P_{s_k}(F_{s_k}), \quad (20)$$

$$m = 1, 2, \dots, M$$

و پیش‌بینی‌کننده برای دامنه منبع k^{th} به صورت زیر بیان می‌شود:

$$y_{s_k} = p_{c_k}^T \cdot P_{s_k}(F_{s_k}) = p_{c_k}^T \cdot \begin{bmatrix} P_{s_{k1}}(F_{s_k}) \\ \dots \\ P_{s_{kM}}(F_{s_k}) \end{bmatrix} \quad (21)$$

هزینه آنتروپی متقابل P_{s_k} به صورت زیر تعریف می‌شود:

$$\mathcal{L}_P = -\frac{1}{n_{s_k}} \sum_{i=1}^{n_{s_k}} y_{s_k}^i \log(p_{c_k}^T \cdot P_{s_k}(F_{s_k})) \quad (22)$$

معادله شماره (۱۰) برای محدودیت طبقه‌بندی منابع مختلف در مدل فازی پیشنهادی دوباره نوشته شده‌است:

$$\mathcal{L}_{crof} = \frac{2}{k(k-1)} \sum_{k1=1}^{K-1} \sum_{k2=k1+1}^K \left(\frac{1}{n_t} \sum_{j=1}^{n_t} \text{weight}(n_t(k1), n_t(k2)) \left| p_{c_{k1}}^T \cdot P_{s_{k1}}(F_{t_{k1}}^j) - p_{c_{k2}}^T \cdot P_{s_{k2}}(F_{t_{k2}}^j) \right| \right) \quad (23)$$

در معادله \mathcal{L}_{crof} ، به منظور در نظر گرفتن تأثیر توزیع نامتوازن داده‌ها در خوشه‌ها و کاهش وابستگی مدل به تعداد خوشه‌ها، محدودیت‌هایی اضافه شده‌است. این تغییرات شامل وزن‌دهی بر اساس توزیع نمونه‌ها در خوشه‌ها و نرمال‌سازی تأثیر تعداد خوشه‌هاست؛ همچنین، با اضافه کردن این وزن‌ها، تأثیر طبقه‌بندی‌های مختلف در خوشه‌ها به طور مستقیم با توزیع داده‌ها همسو می‌شود.

ضریب $\frac{2}{k(k-1)}$ برای جلوگیری از تأثیر نامتوازن تعداد خوشه‌ها در مقیاس کلی تابع هزینه اضافه شده‌است. وزن $\text{weight}(n_t(k1), n_t(k2))$ ، اثر توزیع داده‌ها میان خوشه‌ها را تنظیم می‌کند و برای جلوگیری از تأثیرگذاری بیش از حد خوشه‌های

$$u_{s_k}^l = \frac{1}{\sum_{i=1}^{l_k} \left(\frac{\|v_{s_k}^l - \phi_k(\phi(x_{s_k}))\|}{\|v_{s_k}^i - \phi_k(\phi(x_{s_k}))\|} \right)^{\frac{2}{m-1}}} \quad (15)$$

$v_{s_k}^l$ پروتوتایپ قواعد است. تعیین درجه عضویت برای هر قانون تأثیر بسزایی در حل مسئله دارد؛ زیرا از آنجایی که هر ورودی می‌تواند یک قانون را ارائه کند ممکن است قواعدی وجود داشته باشد که متضاد هم باشند؛ در چنین مواقعی قواعدی که درجه عضویت بالاتری دارند از بین قواعد متضاد انتخاب می‌شوند.

مقدار $u_{s_k}^l$ که با معادله (۱۵) محاسبه می‌شود، میزان شباهت نمونه‌ها به قوانین فازی را مشخص می‌کند. مقدار پارامتر m به عنوان یک تنظیم‌گر، حساسیت مدل نسبت به داده‌های پرت را کنترل می‌کند. مقادیر بالاتر m موجب کاهش تأثیر داده‌های غیرمتعارف می‌شوند.

سطح اطلاعات یک نمونه در بازنمایی‌های مختلف متفاوت است و نمونه‌هایی با سطح اطلاعات یکسان در مقایسه با نمونه‌هایی با سطوح اطلاعات مختلف شباهت بیشتری به یکدیگر دارند؛ از این رو، با توجه به سطح اطلاعات، برای ساخت یک مدل فازی، نمونه‌ها را به چند خوشه تقسیم می‌کنیم تا طبقه‌بندی‌های متعدد هر دامنه منبع را جداگانه یاد بگیرد که انتظار می‌رود این کار به نفع طبقه‌بندی باشد.

بر مبنای شباهتی که برای نشان دادن سطح اطلاعات موجود در یک نمونه تخمین زده شده‌است، شباهت هر نمونه متعلق به کلاس در دامنه منبع k^{th} را می‌توان توسط طبقه‌بندی از پیش آموزش دیده تخمین زد، به طوری که:

$$p_{s_k} = \max(P_{s_k}(F_{s_k}))$$

$$p_{s_k} \in [0, 1] \quad (16)$$

بازه بسته $[0, 1]$ را به M زیر بازه تقسیم می‌کنیم به طوری که $[0, a_1], \dots, [a_{M-1}, 1]$ ، نمونه‌های هر منبع بر مبنای شباهت تخمین زده شده به خوشه‌هایی تقسیم می‌شوند. به طوری که برای خوشه c^{th} ، طبقه‌بندی $P_{s_{k_m}}$ با به کمترین حد رساندن هزینه آنتروپی متقابل آموزش داده شده‌است:

$$\mathcal{L}_c = -\frac{1}{n_{s_{k_c}}} \sum_{i=1}^{n_{s_{k_c}}} y_{s_{k_c}}^i \log(P_{s_{k_c}}(F_{s_k})) \quad (17)$$

در اینجا s_{k_m} تعداد نمونه‌های خوشه است. یک متمایزکننده خوشه با استفاده از نمونه‌های هر خوشه برای تخمین مقدار عضویت نمونه‌های ورودی جدید آموزش داده می‌شود. مبنای تمایز خوشه c^{th} منبع P_{c_k} است که با پارامتر زیر تعیین می‌شود:



بزرگ تر بر عملکرد مدل استفاده می‌شود. این وزن را می‌توان به صورت معادله (۲۴) تعریف کرد:

$$\text{weight}(n_t(k1), n_t(k2)) \quad (24)$$

$$= \frac{1}{1 + (n_t(k2) - n_t(k1))}$$

این تعریف نشان می‌دهد که هر چه تفاوت تعداد نمونه‌های دو خوشه کمتر باشد، وزن بیشتری به آن‌ها اختصاص داده می‌شود.

در مدل فازی تاکاگی-سوگنو، هر نمونه ورودی می‌تواند به مجموعه‌ای از قوانین فازی تخصیص یابد که برای این قوانین، درجات عضویت محاسبه می‌شود؛ باین حال، در بسیاری از موارد، نمونه‌هایی وجود دارند که به دلیل پراکندگی داده‌ها، نوفه یا اطلاعات محدود، نمی‌توانند به طور قاطع به یک قانون خاص تخصیص داده شوند. این موارد نامطمئن (uncertain) نامیده می‌شوند. اگر چنین نمونه‌هایی به درستی مدیریت نشوند، ممکن است عملکرد مدل کاهش یابد یا نتایج نادرست ایجاد شود.

اضافه کردن هزینه‌ای مانند $\mathcal{L}_{uncertain}$ و ضریب تنظیم γ_3 به معادله یادگیری طبقه‌بند کمک می‌کند تا تأثیر این نمونه‌های نامطمئن بر قوانین فازی کاهش یابد. معادله هزینه نمونه‌های نامطمئن به شکل زیر تعریف می‌شود:

$$\mathcal{L}_{uncertain} = \frac{1}{n_{sk}} \sum_{i=1}^{n_{sk}} (1 - p_{sk}^i)^2 \quad (25)$$

در نتیجه، روند یادگیری طبقه‌بند منبع K را می‌توان بر مبنای دسته‌بند فازی به صورت زیر بازنویسی کرد:

$$P_{sk} = \underset{P_{sk} \in \mathcal{H}}{\operatorname{argmin}} \sum_{c=1}^M \mathcal{L}_c + \alpha \mathcal{L}_p + \beta \mathcal{L}_{crof} + \gamma \mathcal{L}_{uncertain} (x_{sk}, y_{sk}) \sim D_{sk} \quad (26)$$

۲-۴- پیش‌بینی دامنه هدف

برای تکمیل وظیفه هدف، تمام طبقه‌بندهای منبع که می‌توانند به‌عنوان یک مدل فازی بیان شوند، ترکیب‌شده و برچسب‌های دامنه هدف را پیش‌بینی می‌کنند. مدل فازی برای تسهیل تصمیم‌گیری در محیط‌های نامطمئن به کار می‌رود:

$$\text{if } F_t \text{ is } D_{sk} \text{ then } y_{sk} \text{ is } p_{ck}^T \cdot P_{sk}(F_t), \quad (27)$$

$$k = 1, 2, \dots, K$$

پیش‌بینی نهایی برای داده هدف با ترکیب خروجی‌های طبقه‌بندهای منبع و استفاده از بردار عضویت p_d محاسبه می‌شود. این بردار نشان‌دهنده

احتمال تعلق داده‌های هدف به هر یک از دامنه‌های منبع است. معادله به صورت معادله (۲۸) اصلاح شده است:

$$y_t = p_d^T \cdot \begin{bmatrix} p_{c1}^T \cdot P_{s1}(F_t) \\ \dots \\ p_{ck}^T \cdot P_{sk}(F_t) \end{bmatrix} + \lambda \cdot \Delta \quad (28)$$

λ وزن تنظیم‌کننده‌ای است که برای کنترل تأثیر عدم قطعیت در پیش‌بینی استفاده می‌شود و Δ یک ترم تنظیم‌کننده برای کاهش اختلاف میانگین پیش‌بینی‌ها بین دامنه منبع و هدف است. بردار عضویت p_d با استفاده از استراتژی‌های مبتنی بر شبه برچسب‌ها و ویژگی‌های مشترک تعیین می‌شود؛ ابتدا طبقه‌بندهای منبع داده‌های هدف را برچسب‌گذاری می‌کنند. تعداد نمونه‌های هدف با پیش‌بینی یکسان توسط طبقه‌بندهای منبع به‌عنوان a_c تعریف شده و فرکانس برابری به صورت $a_c = \frac{n_c}{n_b}$ محاسبه می‌شود. تعداد نمونه‌های هدف که نتایج یکسانی از طبقه‌بندهای منبع متعدد در هر دسته به دست می‌آورند n_c اندازه دسته n_b و فرکانس برابری a_c است.

اگر $a_c > a$ ، به این معنی که چندین دامنه منبع به طور مشابه به دامنه هدف کمک می‌کنند، پس از ترکیب میانگین استفاده می‌شود، مقدار عنصر p_d برابر با $\frac{1}{k}$ است. اگر $a_c \leq a$ باشد، از یک متمایزکننده دامنه برای تعیین مقدار p_d استفاده می‌شود.

برای تخمین بردار عضویت، تمایزدهنده دامنه p_d بر اساس داده‌های مشترک دامنه منبع و هدف تعریف می‌شود. تابع زیان آن به صورت زیر اصلاح شده است:

$$\mathcal{L}_{p_d} = -\frac{1}{n_s} \sum_{i=1}^{n_{sk}} \omega_i y_d^i \log(P_d(f_s)) \quad (29)$$

در اینجا ω_i یک وزن تطبیقی است که عدم توازن کلاس‌ها را در داده‌های هدف در نظر می‌گیرد و y_d^i و برچسب دامنه است. بردار عضویت به صورت زیر به دست می‌آید:

$$p_d = P_d(f_t), p_d = [p_{d1}, \dots, p_{dK}]^T \quad (30)$$

قوانین ترکیب برای پیش‌بینی نهایی به صورت زیر اصلاح شده‌اند:

$$y_t = \begin{cases} \frac{1}{k} \sum_{k=1}^K (p_{ck}^T \cdot P_{sk}(F_t) + \gamma \cdot \omega_k), & \text{if } a_c > a \\ \sum_{k=1}^K p_d \cdot (P_{sk}(F_t) + \gamma \cdot \omega_k), & \text{if } a_c \leq a \end{cases} \quad (31)$$

که در آن γ وزن تنظیم‌کننده برای کاهش تأثیر داده‌های ناسازگار است و ω_k خطای پیش‌بینی هر طبقه‌بند در دامنه منبع است.

برای تعیین پیچیدگی زمانی کلی این الگوریتم، باید پیچیدگی‌های زمانی اجزای جداگانه آن را در نظر بگیریم. برای هر دامنه منبع، یک شبکه عصبی با استفاده از

۳-۱- معرفی مجموعه داده‌ها

روش پیشنهادی بر روی مجموعه داده‌های دنیای واقعی ImageCLEF ، Office-31 ، ارزیابی شده است. ImageCLEF یک مجموعه داده عمومی و معتبر است که شامل ۱۸۰۰ تصویر جمع‌آوری شده با دوازده برچسب متفاوت است که هر برچسب در هر دامنه شامل پنجاه تصویر است؛ به عبارت دیگر هر دامنه شامل ششصد تصویر است که در دوازده دسته برچسب‌گذاری شده است. این مجموعه داده از سه دامنه تصویری (C) Caltech256 ، (I) ILSVRC2012 و (P) Pascal VOC 2012 تشکیل شده است. در مسائل مربوط به تطبیق دامنه هر گروه تصویر به‌عنوان یک دامنه در نظر گرفته می‌شود. شکل (۳) مجموعه‌ای تصادفی از تصاویر مجموعه داده ImageCLEF را نمایش می‌دهد. با توجه به اینکه هر گروه از تصاویر به‌عنوان یک دامنه در نظر گرفته می‌شود، مدل پیشنهادی را می‌توان در سه آزمایش مختلف و جداگانه پیاده‌سازی کرد.

{Caltech256 and ILSVRC 2012} → Pascal VOC 2012
 {ILSVRC 2012 and Pascal VOC 2012} → Caltech256
 {Caltech256 and Pascal VOC 2012} → ILSVRC 2012

که به صورت نمادین به شکل زیر نوشته می‌شود:
 (C and I → P), (I and P → C), (C and P → I)



(شکل-۳): تصاویر تصادفی از مجموعه داده ImageCLEF (Figure-3): A Random Sample of ImageCLEF Dataset Images

OfficeHome یک مجموعه داده عمومی برای ارزیابی الگوریتم‌های انتقال یادگیری و تطبیق دامنه است که شامل تصاویر متعلق به ۶۵ کلاس مختلف از اشیای روزمره در محیط‌های مختلف است. این مجموعه داده شامل چهار دامنه مختلف است: تصاویر طراحی شده یا نقاشی شده با دست (A)، تصاویر کارتونی و گرافیکی (C)، اجسام با زمینه سفید (P) و عکس‌های واقعی از اشیاء (R).

داده‌های آن دامنه آموزش داده می‌شود. اگر فرض کنیم که تعداد لایه‌ها و تعداد نورون‌ها در شبکه عصبی ثابت باشند، پیچیدگی زمانی آموزش شبکه برای هر دامنه به صورت $O(n_{s_k} \cdot d \cdot L)$ است که در آن n_{s_k} تعداد نمونه‌ها در هر دامنه منبع s_k ، d تعداد دامنه‌ها در دامنه هدف d و L تعداد ویزگی‌ها (ابعاد ورودی) و k تعداد دامنه‌های منبع مختلف است. L تعداد پارامترهای قابل تنظیم شبکه است؛ بنابراین، برای k دامنه منبع داریم $O(k \cdot n_{s_k} \cdot d \cdot L)$. در مرحله کمینه‌سازی خطای ساختاری که شامل محاسبه MMD بین ویزگی‌های استخراج‌شده دامنه‌های منبع و هدف است، پیچیدگی زمانی آن به صورت $O((n_{s_k} + n_t)^2 \cdot d)$ خواهد بود. در ادامه در مرحله محاسبه شباهت و تفاوت بین دامنه‌های منبع که شامل محاسبه MMD بین جفت دامنه‌های منبع است، برای k دامنه منبع، تعداد جفت‌ها برابر با $\frac{k(k-1)}{2}$ است؛ بنابراین، پیچیدگی زمانی این بخش به صورت $O(\frac{k(k-1)}{2} \cdot n_{s_k}^2 \cdot d)$ است. در مرحله ایجاد قوانین فازی و آموزش مدل تاکاگی-سوگنو پیچیدگی زمانی بستگی به تعداد قوانین و تعداد ویزگی‌ها دارد، به طوری که اگر فرض کنیم آموزش مدل فازی زمان‌بندی خطی داشته باشد، پیچیدگی زمانی آن به صورت $O(d \cdot L)$ خواهد بود؛ بنابراین پیچیدگی زمانی کل الگوریتم $O(k \cdot n_{s_k} \cdot d \cdot L + (n_{s_k} + n_t)^2 \cdot d + k^2 \cdot n_{s_k}^2 \cdot d)$ خواهد بود. در صورتی که k و n_{s_k} بزرگ باشند، بیشترین بخش محاسبات مربوط به مرحله سوم و محاسبه MMD برای جفت دامنه‌ها خواهد بود.

۳- نتایج و تحلیل

در این بخش، روش پیشنهادی تطبیق دامنه چندمنبعی مبتنی بر قوانین فازی، با هدف ارزیابی عملکرد و اعتبارسنجی آن بر روی مجموعه داده‌های تصویری دنیای واقعی بررسی می‌شود. ابتدا در زیر بخش ۳-۱، فرایند طراحی و پیاده‌سازی مجموعه داده‌های شبیه‌سازی شده به‌منظور ایجاد سناریوهای چندمنبعی توضیح داده شده است؛ سپس، در زیر بخش ۳-۲، تنظیمات پارامترهای کلیدی و نحوه انتخاب آن‌ها در راستای بهبود دقت و اثربخشی مدل معرفی می‌شود؛ در نهایت، در زیر بخش ۳-۳، نتایج حاصل از مقایسه روش پیشنهادی با چندین روش پیشرفته در زمینه تطبیق دامنه چندمنبعی ارائه شده است و عملکرد روش ما از نظر دقت و استحکام در شرایط مختلف با این روش‌ها مقایسه می‌شود.

داده‌های این مجموعه شامل بیش از ۱۵,۵۰۰ تصویر است که به طور ناموزون میان کلاس‌ها توزیع شده‌اند. این ویژگی، الگوریتم‌ها را به چالش می‌کشد تا با داده‌های نامتوازن و توزیع‌های متفاوت میان دامنه‌ها سازگار شوند و عملکرد خود را در مسائل دنیای واقعی بهبود بخشند. با توجه به اینکه هر گروه از تصاویر به‌عنوان یک دامنه در نظر گرفته می‌شود، مدل پیشنهادی را می‌توان در چهار آزمایش مختلف و جداگانه پیاده‌سازی کرد:

{Art, Clipart and Product} → Real-world
 {Art, Clipart and Real-world} → Product
 {Art, Real-world and Product} → Clipart
 {Real-world, Clipart and Product} → Art

که به صورت نمادین به شکل زیر نوشته می‌شود:


(A, C and P → R), (A, C and R → P), (A, R and P → C), (R, C and P → A)

Office-31 یک مجموعه داده نامتوازن است که شامل ۴۱۱۰ تصویر جمع‌آوری شده از ۳۱ دسته است و تعداد تصاویر در هر دسته متفاوت است؛ دارای سه گروه آمازون (A)، وب‌کم (W) و DSLR (D). تصاویر گروه آمازون دارای ۲۸۱۷ تصویر برگرفته از سایت آمازون، تصاویر گروه وب‌کم دارای ۷۹۵ تصویر است که با دوربین وب‌کم و تصاویر گروه DSLR که دارای ۴۹۸ تصویر است که با دوربین DSLR گرفته شده است. شکل (۴) مجموعه‌ای تصادفی از تصاویر مجموعه داده Office-31 را نمایش می‌دهد. با توجه به اینکه هر گروه از تصاویر به‌عنوان یک دامنه در نظر گرفته می‌شود، مدل پیشنهادی را می‌توان در سه آزمایش مختلف و جداگانه پیاده‌سازی کرد:

{Amazon and DSLR} → Webcam
 {Amazon and Webcam} → DSLR
 {DSLR and Webcam} → Amazon

که به صورت نمادین به شکل زیر نوشته می‌شود:

(A and D → W), (A and W → D), (D and W → A)



(شکل-۴): تصاویر تصادفی از مجموعه داده Office31
 (Figure-4): A Random Sample of Office 31 Dataset Images

۳-۲- تنظیمات پارامترها

در این مقاله، از شبکه ResNet50 به‌عنوان شبکه پایه برای استخراج ویژگی‌های مشترک و غیرمشترک استفاده

شده است. شبکه‌های استخراج ویژگی ϕ_{ck} و ϕ_{dk} شامل سه لایه کانولوشنی هستند و ابعاد ویژگی‌های مشترک را از ۲۰۴۸ به ۲۵۶ کاهش می‌دهند. سائز دسته $n_b = 32$ ؛ و نرخ یادگیری η برابر با $\frac{\eta_0}{(1+10\epsilon)^{0.75}}$ است و $\eta_0 = 0.01$ ؛ در طول آموزش از ۰ تا ۱ به صورت خطی تغییر می‌کند، مومنتوم ۰.۹ و نرخ کاهش وزن $5e-4$ هستند، نرخ تعادل $\alpha = 0.01$ است. مقدار آستانه $a = 0.5$ است. برای کاهش پیچیدگی پیاده‌سازی، a_c هر وظیفه با استفاده از طبقه‌بند منبع پیش آموزش دیده به جای طبقه‌بند منبع فازی محاسبه می‌شود و به طور مستقیم برای طبقه‌بندی هدف استفاده می‌شود. a_c در آزمایش‌های $I \rightarrow P$; $I, P \rightarrow C$; $C, P \rightarrow I$ و ImageCLEF-DA و $A \rightarrow W$ در Office-31 از ۰.۵ بزرگ‌تر است، در حالی که a_c در آزمایش‌های $A, W \rightarrow D$ و $A \rightarrow W$ کوچک‌تر از ۰.۵ است.

روش‌هایی که الگوریتم پیشنهادی با آن‌ها مقایسه شده‌اند، در جداول بخش بعدی ارائه شده‌اند؛ برخی از این روش‌ها به صورت تطبیق دامنه تک‌منبعی عمل می‌کنند؛ در چنین حالتی، بسته به مجموعه داده آزمایش، یکی از دو یا سه دامنه به‌عنوان منبع انتقال اطلاعات انتخاب می‌شود. در برخی پیاده‌سازی‌ها نیز، تمام دامنه‌ها با یکدیگر ترکیب شده‌اند و به‌عنوان یک دامنه واحد برای انتقال اطلاعات به‌کار می‌روند. در مقابل، روش‌های چندمنبعی از چندین دامنه به‌عنوان منابع انتقال اطلاعات استفاده می‌کنند.

۳-۳- نتایج

تمام آزمایش‌های روش پیشنهادی پنج بار تکرار شده و نتایج به صورت دقت میانگین محاسبه شده‌اند؛ علاوه بر این، برای بیان قابلیت اطمینان، واریانس نیز ارائه می‌شود. جدول (۲) و جدول (۳) به ترتیب نتایج Office-31 و ImageCLEF را نشان می‌دهند. در جداول عبارت تک‌منبع به این معنی است که از بین چند منبع، منبعی که بهترین عملکرد را دارد به‌عنوان منبع انتقال دانش در نظر گرفته می‌شود.

عبارت ترکیب منابع به معنای ترکیب همه منابع به صورت یک منبع واحد است. عبارت چندمنبعی به معنای استفاده از تمام منابع برای انتقال اطلاعات استفاده می‌شود. از آنجا که مجموعه داده ImageCLEF شامل سه دامنه است، برای پیاده‌سازی روش پیشنهادی، یک دامنه به‌عنوان دامنه هدف و دو دامنه دیگر به‌عنوان دامنه‌های منبع در نظر گرفته می‌شوند. این رویه برای مجموعه داده Office-31 نیز مشابه است؛ این مجموعه شامل سه دامنه Amazon، Webcam و DSLR است که برای پیاده‌سازی

پارامترهاست که می‌تواند در مواجهه با مجموعه داده‌های چندمنبعی، چالش‌هایی ایجاد کند. در روش پیشنهادی ما، به منظور بهبود تطبیق و انعطاف‌پذیری بیشتر، از قواعد فازی استفاده شده است که با کاهش پیچیدگی محاسبات و افزایش دقت تطبیق، عملکرد قابل قبولی را ارائه می‌دهد. از طرفی هنگامی که چندین منبع برای انتقال دانش وجود دارد اطلاعات و دانش غنی‌تری برای انتقال محیاست که سبب افزایش دقت الگوریتم‌ها می‌شود. می‌توان مشاهده کرد که روش پیشنهادی در اکثر وظایف به بهترین عملکرد دست می‌یابد. به‌طورکلی، انطباق دامنه چندمنبع بهتر از تطبیق دامنه تک‌منبع است. انتقال دانش در شرایطی که تغییر توزیع دامنه در نظر گرفته می‌شود بهتر از شرایطی است که تمام نمونه‌های آموزشی منابع را مخلوط می‌کند. جدول (۴) عملکرد روش‌های مختلف یادگیری انتقالی را در سناریوهای تطبیق دامنه با یک منبع، ترکیب منابع و منابع چندگانه روی منبع داده Office-Home مقایسه می‌کند. مقادیر ارائه‌شده میانگین دقت‌ها را برای جفت‌های مختلف دامنه ($R, C, A \rightarrow P$; $R, C, A \rightarrow A$; و غیره) و میانگین کلی برای هر روش نشان می‌دهند.

(جدول-۳): نتایج مجموعه داده ImageCLEF مقایسه‌ای

با سایر روش‌ها

(Table-3): ImageCLEF Dataset Results: Comparison of Different Methods

منبع	روش	I, C→P	I, P→C	P, C→I	میانگین
تک‌منبع	ResNet	۷۴.۸	۹۱.۵	۸۳.۹	۸۳.۴
	DAN[29]	۷۵.۰	۹۳.۳	۸۶.۲	۸۴.۸
	D-CORAL[31]	۷۶.۹	۹۳.۶	۸۸.۵	۸۶.۳
	RevGard[28]	۷۵.۰	۹۶.۲	۸۷.۰	۸۶.۱
	MRAN[30]	۷۸.۸	۹۵.۰	۹۳.۵	۸۹.۱
	MDDA[27]	۷۹.۸	۹۵.۷	۹۳.۰	۸۹.۲
	DDAN[27]	۷۸.۰	۹۴.۰	۹۱.۰	۸۷.۷
ترکیب منابع	DAN[29]	۷۷.۶	۹۳.۳	۹۲.۲	۸۷.۷
	D-CORAL[31]	۷۷.۱	۹۳.۶	۹۱.۷	۸۷.۵
	RevGard[28]	۷۷.۹	۹۳.۷	۹۱.۸	۸۷.۸
منابع چندگانه	DCTN[32]	۷۵.۰	۹۵.۷	۹۰.۳	۸۷.۰
	MFSAN[33]	۷۹.۱	۹۵.۴	۹۳.۶	۸۹.۴
	DFRE[34]	۷۹.۵	۹۵.۸	۹۳.۷	۸۹.۷
	MDA[25]	۷۹.۴	۹۶.۳	۹۴.۵	۹۰.۱
	روش پیشنهادی	۷۹.۷±۰.۱	۹۷.۱±۰.۳	۹۴.۸±۰.۲	۹۰.۹±۰.۸

ResNet (تک‌منبع) به‌عنوان پایه، دقت میانگین ۶۷.۵٪ را ارائه می‌دهد که نشان‌دهنده عملکرد پایه این شبکه در تطبیق دامنه است. روش‌های دیگر این قسمت با افزودن استراتژی‌های تطبیق دامنه بهبود یافته‌اند؛ برای مثال DAN دقت میانگین ۷۰.۲٪ و RevGard دقت ۷۰٪ را ارائه می‌دهد. این نشان‌دهنده بهبود نسبت به

آزمایش چندمنبعی، دو دامنه به‌عنوان دامنه منبع و یک دامنه به‌عنوان دامنه هدف انتخاب می‌شود.

در نتایج جدول (۲) مشاهده می‌شود که روش پیشنهادی بالاترین عملکرد را در بیشتر آزمایش‌ها به‌دست می‌آورد، این بدان معناست که روش پیشنهادی و نحوه استخراج قواعد و هم‌ترازی دامنه نقش مؤثری در تولید نتایج بهتر داشته‌است؛ در کل، تطبیق دامنه چندمنبعی بهتر از تطبیق دامنه تک‌منبعی است. الگوریتم‌هایی که در آن‌ها از یک منبع برای انتقال دانش استفاده می‌شود کمابیش عملکرد بهتری نسبت به زمانی دارند که در آن‌ها منابع با هم ترکیب و فرض اختلاف توزیع بین منابع ندیده گرفته می‌شود؛ همچنین در نتایج جدول (۲) مشاهده می‌شود که الگوریتم [۲۷] DDAN در پیاده‌سازی و انتقال یادگیری در محیط‌های تک‌منبعی به دقت صددرصد دست یافته‌است. این الگوریتم با ارزیابی کمی توزیع‌های حاشیه‌ای و شرطی به انتقال یادگیری در محیط‌های تک‌منبعی می‌پردازد؛ با این حال، این الگوریتم نسبت به الگوریتم پیشنهادی ما که بر پایه قواعد فازی طراحی شده‌است، دارای پیچیدگی بیشتری برای محیط‌های چندمنبعی است و در این محیط‌ها قابل پیاده‌سازی نیست؛ مگر اینکه از اختلاف توزیع صرف‌نظر شود و دامنه چندمنبعی با هم ادغام شود و در قالب یک دامنه تک‌منبعی ظاهر شود.

(جدول-۲): نتایج مجموعه داده Office-31 مقایسه‌ای با سایر روش‌ها

(Table-2): Office-31 Dataset Results: Comparison of Different Methods

منبع	روش	A, W→D	A, D→W	D, W→A	میانگین
تک‌منبع	RevGard[28]	۹۹	۹۶.۹	۶۸.۲	۸۸.۱
	DDAN[27]	۱۰۰.۰	۹۶.۷	۶۵.۳	۸۷.۳
	ResNet	۹۹.۳	۹۶.۷	۶۲.۵	۸۶.۲
	DAN[29]	۹۹.۵	۹۶.۸	۶۶.۷	۸۷.۷
	MRAN[30]	۹۹.۸	۹۶.۹	۷۰.۹	۸۹.۲
	D-CORAL[31]	۹۹.۷	۹۸.۰	۶۵.۳	۸۷.۷
	MDDA[27]	۹۹.۲	۹۷.۱	۷۳.۲	۸۹.۸
ترکیب منابع	D-CORAL[31]	۹۹.۳	۹۸.۰	۹۷.۱	۸۸.۱
	DAN[29]	۹۹.۶	۹۷.۸	۶۷.۶	۸۸.۳
	RevGard[28]	۹۹.۷	۹۸.۱	۶۷.۶	۸۸.۵
	DCTN[32]	۹۹.۳	۹۸.۲	۶۴.۲	۸۷.۲
منابع چندگانه	MFSAN[33]	۹۹.۵	۹۸.۵	۷۲.۷	۹۰.۲
	MDA[25]	۹۹.۶	۹۹.۰	۷۴.۰	۹۰.۹
	روش پیشنهادی	۹۹.۸±۰.۸	۹۹.۷±۰.۴	۷۵.۱±۰.۶	۹۲.۰±۰.۵

آزمایش دیگری که نتایج آن در جدول (۳) مشاهده می‌شود که روش MDDA[27] به دقت بالاتری نسبت به روش پیشنهادی در انتقال یادگیری تک‌منبعی دست یافته‌است. الگوریتم MDDA با حفظ ساختار منیفلد داده در فرایند تطبیق دامنه و سازگاری پویا با توزیع‌های مختلف، عملکرد قابل توجهی در انتقال داده تک‌منبعی نشان داده‌است؛ با این حال، MDDA نیازمند محاسبات پیچیده و انتخاب دقیق

روش پایه است، اما هنوز محدودیت‌هایی در بهینه‌سازی وجود دارد.


(جدول ۴): نتایج مجموعه داده Office-Home مقایسه‌ای با سایر روش‌ها
(Table-4): Office-Home Dataset Results: Comparison of Different Methods

منبع	روش	A,C,P→R	A,P,R→C	R,C,P→A	R,C,A→P	میانگین
روش‌های مبتنی بر شبکه عصبی عمیق	ResNet	۷۵.۴	۴۹.۶	۶۵.۳	۷۹.۷	۶۷.۵
	DAN[29]	۷۵.۹	۵۶.۵	۶۸.۲	۸۰.۳	۷۰.۲
	D-CORAL[31]	۷۶.۳	۵۳.۶	۶۷.۰	۸۰.۳	۶۹.۳
	RevGard[28]	۷۵.۸	۵۵.۹	۶۷.۹	۸۰.۴	۸۶.۱
	MRAN[30]	۷۷.۵	۶۰.۰	۷۰.۴	۸۲.۲	۷۲.۵
روش‌های مبتنی بر شبکه عصبی عمیق با انتقال دانش	DAN[29]	۸۲.۵	۵۹.۴	۶۸.۵	۷۹.۰	۷۲.۳
	D-CORAL[31]	۸۲.۷	۵۸.۶	۶۸.۱	۷۹.۵	۷۲.۲
	RevGard[28]	۸۲.۷	۵۹.۱	۶۸.۴	۷۹.۵	۷۲.۴
روش‌های مبتنی بر شبکه عصبی عمیق با انتقال دانش و فزونی	SSD[35]	۸۳.۲	۶۴.۵	۷۲.۵	۸۱.۲	۷۵.۳
	MFSAN[33]	۸۰.۸	۶۰.۷	۷۰.۰	۷۹.۰	۷۲.۶
	روش پیشنهادی	۸۴.۱	۶۴.۴	۷۳.۲	۸۲.۰	۷۵.۹


دقت میانگین روش MFSAN ۷۲.۶٪ است که نسبت به روش‌های ترکیب منابع کمی بهبود نشان می‌دهد. این روش از اطلاعات چند منبع برای استخراج ویژگی‌های جامع‌تر استفاده می‌کند. روش پیشنهادی با دقت میانگین ۷۵.۹٪ بهترین عملکرد را در میان تمامی روش‌ها دارد. تطبیق دامنه چندمنبع (مانند SSD و روش پیشنهادی) نسبت به روش‌های تک‌منبعی و ترکیب منابع عملکرد بهتری دارند؛ زیرا اطلاعات متنوع‌تر و کامل‌تری از دامنه‌های مختلف بهره‌برداری می‌کنند.

شکل (۵) و شکل (۶) دقت روش را بدون استفاده و با استفاده از سیستم فازی نشان می‌دهند. آزمایش‌هایی مانند $P \rightarrow I$ و $P \rightarrow C$ و... به معنای تک‌منبعی و آزمایش‌هایی مانند $C \rightarrow I$, P به معنای چندمنبعی است. این نشان می‌دهد که برای بسیاری از آزمایش‌ها، تطبیق دامنه تک‌منبعی و چندمنبعی با قوانین فازی بهتر از بدون قوانین فازی است. برای برخی از آزمایش‌ها مانند $W \rightarrow D$ دقت سامانه بدون قوانین فازی بالاتر است. دلیل این امر این است که دامنه‌های منبع سطوح مختلفی از هم‌بستگی را با دامنه هدف نشان می‌دهند و برای برخی از نمونه‌های منبع اطلاعات قابل انتقال از هر خوشه برای یادگیری کار هدف کافی نیست. ما علاوه بر استفاده از سیستم فازی، به توسعه استراتژی تخمین شباهت و تمایزدهنده خوشه‌ای پرداخته‌ایم. این استراتژی به ما امکان می‌دهد نمونه‌های منبع را بر اساس اطلاعات مشابه در خوشه‌های مختلف گروه‌بندی کنیم و به افزایش دقت مدل و بهبود شناسایی الگوهای پیچیده کمک می‌کند؛ همچنین، تمایزدهنده خوشه‌ای به تقسیم نمونه‌ها بر اساس سطح اطلاعاتشان کمک می‌کند که در محیط‌های چندمنبعی اهمیت ویژه‌ای دارد.

این نتایج به روشنی نشان می‌دهند که اگرچه سرعت یادگیری با افزودن قواعد فازی به طور قابل توجهی افزایش یافته‌است، اما در برخی موارد باید دقت مدل را در شرایط خاص و پیچیده‌تر به طور دقیق بررسی کرد تا از عملکرد مطلوب آن اطمینان حاصل شود. این نوآوری‌ها می‌توانند پایه‌گذار تحقیقات بیشتری در آینده باشند.

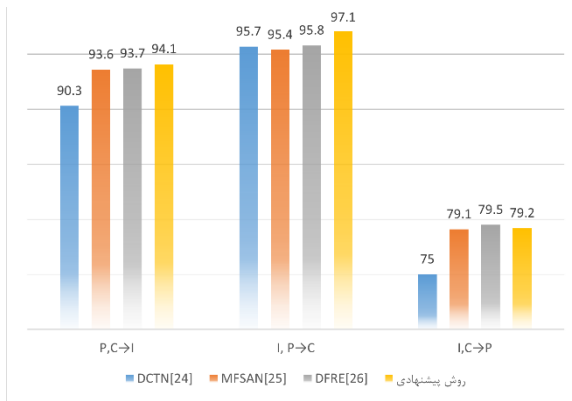


(شکل ۵): مقایسه دقت طبقه‌بندی درصد در مجموعه داده Office-31 با اعمال و بدون اعمال قوانین فازی
(Figure-5): Comparison of Percentage Classification Accuracy on Office-31 Dataset with and without Applying Fuzzy Rules




(شکل ۶): مقایسه دقت طبقه‌بندی درصد در مجموعه داده ImageCLEF با اعمال و بدون اعمال قوانین فازی
(Figure-6): Comparison of Percentage Classification Accuracy on ImageCLEF Dataset with and without Applying Fuzzy Rules

شکل (۷) و شکل (۸) یک گزارش تصویری از زمان اجرای الگوریتم پیشنهادی روی مجموعه داده ImageCLEF روی $P, C \rightarrow I$ و Office-31 روی $W, D \rightarrow A$ ارائه می‌کنند. هنگامی که در تطبیق دامنه چندمنبعی برای طبقه‌بندی تصاویر از قواعد فازی استفاده شده‌است در گام‌های کمتری سامانه به صحت بالاتری دست یافته‌است. در صورتی که در هنگام عدم استفاده از قواعد فازی سیستم دیرتر به نتایج مطلوب دست یافته‌است؛ به طوری که نتایج مطلوب آن نسبت به استفاده از قواعد فازی کمتر است.



(شکل-۱۰): نرخ دقت طبقه‌بندی (%) برای آزمایش‌ها روی مجموعه‌داده ImageCLEF در تنظیمات چندمنبعی (Figure-10): Classification accuracy rate (%) reported for experiments on ImageCLEF dataset in multi-source setting




(شکل-۱۱): هزینه آموزش رویکرد پیشنهادی، که با استفاده از Office-31 در مجموعه‌داده W, D → A (Figure-11): Training loss of the proposed approach, illustrated using the Amazon task in the Office-31 dataset.

شکل (۱۱)، مقدار هزینه آموزشی منبع را در یک آزمایش که با استفاده از روش پیشنهادی انجام شده‌است، نمایش می‌دهد. این نتایج نشان‌دهنده عملکرد مدل در حین آموزش بر روی داده‌های منبع است و به ما این امکان را می‌دهد تا فرایند یادگیری و تغییرات آن را در طول زمان مشاهده کنیم.

۴- جمع‌بندی

در این پژوهش، یک روش مبتنی بر سیستم‌های فازی برای تطبیق دامنه چندمنبعی پیشنهاد شد. ما از یک مدل پیش‌آموزش‌دیده برای استخراج ویژگی‌های قابل تطبیق از دامنه‌های منبع و هدف استفاده کردیم. برای ایجاد استراتژی تخمین شباهت، طبقه‌بندی‌های منبع پیش‌آموزش‌دیده به کار گرفته شدند تا نمونه‌های آموزشی هر دامنه منبع به خوشه‌های متعدد تقسیم شوند و بر اساس این خوشه‌ها، قواعد فازی ایجاد شوند؛ سپس، با استفاده از ویژگی‌های استخراج‌شده و قوانین فازی، در طبقه‌بندی‌های منبع دوباره آموزش داده می‌شوند. برای پیش‌بینی

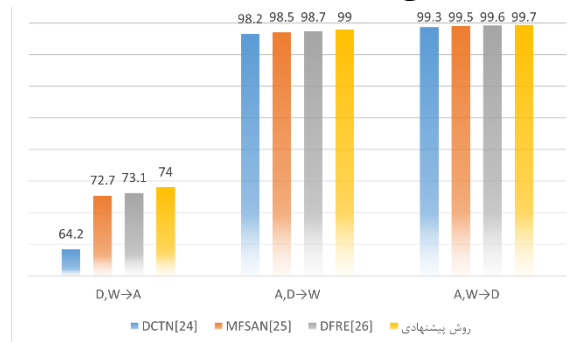


(شکل-۷): زمان اجرای الگوریتم پیشنهادی روی مجموعه‌داده P, C → I برای ImageCLEF (Figure-7): Execution time of the proposed algorithm on the ImageCLEF dataset for P, C → I



(شکل-۸): زمان اجرای الگوریتم پیشنهادی روی مجموعه‌داده W, D → A برای Office-31 (Figure-8): Execution time of the proposed algorithm on the Office-31 dataset for W, D → A

در شکل (۹) درصد دقت طبقه‌بندی در آزمایش‌های مجموعه‌داده Office-31 در حالت چندمنبعی گزارش شده‌است و در شکل (۱۰) درصد دقت طبقه‌بندی در آزمایش‌های از مجموعه‌داده ImageCLEF در حالت چندمنبعی گزارش شده‌است. نتایج نشان می‌دهد که با توجه به عدم قطعیت و ابهامی که در انتقال دانش از منابع مختلف به یک دامنه هدف با وجود توزیع‌های متفاوت، روش پیشنهادی بسیار موثر است. روش پیشنهادی توانایی مدیریت شرایط غیر قطعی و ایجاد تابع غیرخطی بین ورودی‌ها و خروجی را دارد.



(شکل-۹): نرخ دقت طبقه‌بندی (%) برای آزمایش‌ها روی مجموعه‌داده Office-31 در تنظیمات چندمنبعی (Figure-9): Classification accuracy rate (%) reported for experiments on Office-31 dataset in multi-source setting

- Syst. Sci. Oper. Logist.*, vol. 10, no. 1, 2023, doi: 10.1080/23302674.2023.2259293.
- [7] B. Tan, E. Zhong, E. W. Xiang, and Q. Yang, "Multi-transfer: Transfer learning with multiple views and multiple sources," *Stat. Anal. Data Min.*, vol. 7, no. 4, pp. 282–293, 2014, doi: 10.1002/sam.11226.
- [8] D. K. Nguyen, W. L. Tseng, and H. H. Shuai, "Domain-Adaptive Object Detection via Uncertainty-Aware Distribution Alignment," *MM 2020 - Proc. 28th ACM Int. Conf. Multimed.*, pp. 2499–2507, 2020, doi: 10.1145/3394171.3413553.
- [9] V. Chouhan *et al.*, "A Novel Transfer Learning Based Approach for Pneumonia Detection in Chest X-ray Images," *Appl. Sci.*, vol. 10, no. 2, p. 559, Jan. 2020, doi: 10.3390/app10020559.
- [10] S. F. Nourollahi, R. Baradaran, and H. Amirkhani, "Domain adaptation-based method for improving generalization of hate speech detection models," *Signal Data Process.*, vol. 21, no. 1, pp. 125–142, Jun. 2024, doi: 10.61186/jstdp.21.1.125.
- [11] Y. Zhu *et al.*, "Deep subdomain adaptation network for image classification," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 32, no. 4, pp. 1713–1722, 2021, doi: 10.1109/TNNLS.2020.2988928.
- [12] J. Lu, H. Zuo, and G. Zhang, "Fuzzy Multiple-Source Transfer Learning," *IEEE Trans. Fuzzy Syst.*, vol. 28, no. 12, pp. 3418–3431, 2020, doi: 10.1109/TFUZZ.2019.2952792.
- [13] H. Zuo, G. Zhang, W. Pedrycz, V. Behbood, and J. Lu, "Fuzzy Regression Transfer Learning in Takagi-Sugeno Fuzzy Models," *IEEE Trans. Fuzzy Syst.*, vol. 25, no. 6, pp. 1795–1807, 2017, doi: 10.1109/TFUZZ.2016.2633376.
- [14] H. Zuo, G. Zhang, W. Pedrycz, V. Behbood, and J. Lu, "Granular Fuzzy Regression Domain Adaptation in Takagi-Sugeno Fuzzy Models," *IEEE Trans. Fuzzy Syst.*, vol. 26, no. 2, pp. 847–858, 2018, doi: 10.1109/TFUZZ.2017.2694801.
- [15] H. Zuo, J. Lu, G. Zhang, and W. Pedrycz, "Fuzzy Rule-Based Domain Adaptation in Homogeneous and Heterogeneous Spaces," *IEEE Trans. Fuzzy Syst.*, vol. 27, no. 2, pp. 348–361, 2019, doi: 10.1109/TFUZZ.2018.2853720.
- [16] E. Khaleghi, H. Soltanzadeh, and M. Gholizadeh, "Recognition of gait disorder in people with knee joint disability using FUZZY system," *J. Mach. Vis. Image Process.*, vol. 9, no. 2, pp. 33–45, 2022, [Online]. Available: http://jmvip.sinaweb.net/article_139030.html
- [17] S. K. Meher and N. S. Kothari, "Interpretable Rule-Based Fuzzy ELM and Domain Adaptation for Remote Sensing Image Classification," *IEEE Trans. Geosci. Remote Sens.*, vol. 59, no. 7, pp. 5907–5919, 2021, doi: 10.1109/TGRS.2020.3024796.
- [18] Z. Deng, Y. Jiang, F. L. Chung, H. Ishibuchi, and S. Wang, "Knowledge-leverage-based fuzzy system and its

برچسب‌های هدف، از ترکیب قواعد برای اندازه‌گیری شباهت بین دامنه‌های منبع و مقصد استفاده می‌شود. نتایج آزمایش و تجزیه و تحلیل بر روی مجموعه داده‌های تصویری دنیای واقعی نشان می‌دهد که روش پیشنهادی عملکرد بهتری نسبت به سایر روش‌ها داشته‌است؛ با این حال، علاوه بر تأثیر قواعد فازی بر بهبود نتایج، باید خاطر نشان کنیم که علاوه بر سیستم فازی، نوآوری‌هایی مانند استراتژی تخمین شباهت و بهبود فرایند آموزش مجدد طبقه‌بندهای منبع، تأثیر قابل توجهی بر عملکرد کلی سامانه داشته‌اند.

این روش‌ها به ما این امکان را می‌دهند که از انتقال منفی جلوگیری کنیم و درصد دقت انتقال دانش را بهبود بخشیم؛ بنابراین، حتی اگر استفاده از قواعد فازی به تنهایی منجر به بهبود نشود، پیشنهادهای ما در ترکیب با این قواعد، نتایج مثبتی را به همراه داشته و به طور کلی به بهبود عملکرد سامانه کمک کرده‌است؛ به همین دلیل، ما به این نتیجه‌گیری رسیدیم که روش پیشنهادی عملکرد بهتری در مقایسه با سایر روش‌ها دارد و این موضوع می‌تواند به عنوان پایه‌ای برای تحقیقات آینده در زمینه جلوگیری از انتقال منفی و بهبود دقت در تطبیق دامنه چندمنبعی در نظر گرفته شود.

5-Reference

۵-مراجع

- [1] F. Liu, J. Lu, and G. Zhang, "Unsupervised Heterogeneous Domain Adaptation via Shared Fuzzy Equivalence Relations," *IEEE Trans. Fuzzy Syst.*, vol. 26, no. 6, pp. 3555–3568, Dec. 2018, doi: 10.1109/TFUZZ.2018.2836364.
- [2] Y. Yin, Z. Yang, H. Hu, and X. Wu, "Universal multi-Source domain adaptation for image classification," *Pattern Recognit.*, vol. 121, 2022, doi: 10.1016/j.patcog.2021.108238.
- [3] "Granular fuzzy regression domain adaptation in Takagi-Sugeno fuzzy models".
- [4] C. Yang, Y. M. Cheung, J. Ding, K. C. Tan, B. Xue, and M. Zhang, "Contrastive Learning Assisted-Alignment for Partial Domain Adaptation," *IEEE Trans. Neural Networks Learn. Syst.*, 2022, doi: 10.1109/TNNLS.2022.3145034.
- [5] M. Gholizade, H. Soltanzadeh, and M. Rahmanimanesh, "A Survey of Transfer Learning and Categories," *Model. Simul. Electr. Electron. Eng.*, vol. 1, no. 3, pp. 17–25, 2021, doi: 10.22075/msee.2021.23310.1062.
- [6] M. Gholizade, M. Rahmanimanesh, H. Soltanzadeh, and S. S. Sana, "Hesitant triangular fuzzy FlowSort method: the multi-criteria decision-making problems," *Int. J.*

- [31] B. Sun and K. Saenko, "Deep CORAL: Correlation alignment for deep domain adaptation," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 9915 LNCS, pp. 443–450, 2016, doi: 10.1007/978-3-319-49409-8_35.
- [32] R. Xu, Z. Chen, W. Zuo, J. Yan, and L. Lin, "Deep Cocktail Network: Multi-source Unsupervised Domain Adaptation with Category Shift," *Proc. IEEE Comput. Soc. Conf. Comput. Vis. Pattern Recognit.*, pp. 3964–3973, 2018, doi: 10.1109/CVPR.2018.00417.
- [33] Y. Zhu, F. Zhuang, and D. Wang, "Aligning domain-specific distribution and classifier for cross-domain classification from multiple sources," *33rd AAAI Conf. Artif. Intell. AAAI 2019, 31st Innov. Appl. Artif. Intell. Conf. IAAI 2019 9th AAAI Symp. Educ. Adv. Artif. Intell. EAAI 2019*, pp. 5989–5996, 2019, doi: 10.1609/aaai.v33i01.33015989.
- [34] K. Li, J. Lu, H. Zuo, and G. Zhang, "Multi-Source Domain Adaptation with Distribution Fusion and Relationship Extraction," *Proc. Int. Jt. Conf. Neural Networks*, 2020, doi: 10.1109/IJCNN48605.2020.9207556.
- [35] K. Li, J. Lu, H. Zuo, and G. Zhang, "Multidomain Adaptation with Sample and Source Distillation," *IEEE Trans. Cybern.*, vol. 54, no. 4, pp. 2193–2205, 2024, doi: 10.1109/TCYB.2023.3236008.
- modeling," *IEEE Trans. Fuzzy Syst.*, vol. 21, no. 4, pp. 597–609, 2013, doi: 10.1109/TFUZZ.2012.2212444.
- [19] V. Behbood, J. Lu, and G. Zhang, "Fuzzy refinement domain adaptation for long term prediction in banking ecosystem," *IEEE Trans. Ind. Informatics*, vol. 10, no. 2, pp. 1637–1646, 2014, doi: 10.1109/TII.2012.2232935.
- [20] K. Li, J. Lu, H. Zuo, and G. Zhang, "Multi-Source Contribution Learning for Domain Adaptation," *IEEE Trans. Neural Networks Learn. Syst.*, vol. 33, no. 10, pp. 5293–5307, 2022, doi: 10.1109/TNNLS.2021.3069982.
- [21] K. Li, J. Lu, H. Zuo, and G. Zhang, "Source-Free Multi-Domain Adaptation with Fuzzy Rule-based Deep Neural Networks," *IEEE Trans. Fuzzy Syst.*, 2023, doi: 10.1109/TFUZZ.2023.3276978.
- [22] K. Li, J. Lu, H. Zuo, and G. Zhang, "Multi-Source Contribution Learning for Domain Adaptation," *IEEE Trans. Neural Networks Learn. Syst.*, 2021, doi: 10.1109/TNNLS.2021.3069982.
- [23] K. Li, J. Lu, H. Zuo, and G. Zhang, "Dynamic Classifier Alignment for Unsupervised Multi-Source Domain Adaptation," *IEEE Trans. Knowl. Data Eng.*, vol. 35, no. 5, pp. 4727–4740, 2023, doi: 10.1109/TKDE.2022.3144423.
- [24] H. Zuo, J. Lu, G. Zhang, and F. Liu, "Fuzzy Transfer Learning Using an Infinite Gaussian Mixture Model and Active Learning," *IEEE Trans. Fuzzy Syst.*, vol. 27, no. 2, pp. 291–303, 2019, doi: 10.1109/TFUZZ.2018.2857725.
- [25] K. Li, J. Lu, H. Zuo, and G. Zhang, "Multi-Source Domain Adaptation with Fuzzy-Rule based Deep Neural Networks," *IEEE Int. Conf. Fuzzy Syst.*, vol. 2021-July, 2021, doi: 10.1109/FUZZ45933.2021.9494586.
- [26] F. Liu, G. Zhang, and J. Lu, "Multisource Heterogeneous Unsupervised Domain Adaptation via Fuzzy Relation Neural Networks," *IEEE Trans. Fuzzy Syst.*, vol. 29, no. 11, pp. 3308–3322, 2021, doi: 10.1109/TFUZZ.2020.3018191.
- [27] J. Wang, Y. Chen, W. Feng, Y. U. Han, M. Huang, and Q. Yang, "Transfer learning with dynamic distribution adaptation," *ACM Trans. Intell. Syst. Technol.*, vol. 11, no. 1, 2020, doi: 10.1145/3360309.
- [28] Y. Ganin and V. Lempitsky, "Unsupervised domain adaptation by backpropagation," *32nd Int. Conf. Mach. Learn. ICML 2015*, vol. 2, pp. 1180–1189, 2015.
- [29] M. Long, Y. Cao, J. Wang, and M. I. Jordan, "Learning transferable features with deep adaptation networks," *32nd Int. Conf. Mach. Learn. ICML 2015*, vol. 1, pp. 97–105, 2015.
- [30] Y. Zhu *et al.*, "Multi-representation adaptation network for cross-domain image classification," *Neural Networks*, vol. 119, pp. 214–221, 2019, doi: 10.1016/j.neunet.2019.07.010.



معصومه قلیزاده دارای مدرک کارشناسی مهندسی کامپیوتر (سخت‌افزار) از دانشگاه گیلان و کارشناسی‌ارشد هوش

مصنوعی است. او در حال حاضر در مقطع دکترا در دانشکده مهندسی برق و کامپیوتر دانشگاه سمنان مشغول به تحصیل است. زمینه‌های پژوهشی او شامل یادگیری ماشین، یادگیری انتقالی به‌ویژه تطبیق دامنه فازی و پردازش تصویر است.

نشانی رایانامه ایشان عبارت است از:

masoume_gholizade@semnan.ac.ir



هادی سلطانی‌زاده مدرک کارشناسی خود را در رشته مهندسی برق از دانشگاه بابل دریافت کرده‌است. او مدرک کارشناسی‌ارشد خود را در

رشته مهندسی برق از دانشگاه علم‌و‌صنعت ایران و مدرک دکتری خود را در رشته مهندسی الکترونیک



از همان دانشگاه دریافت کرده‌است و در حال حاضر دانشیار دانشکده مهندسی برق و کامپیوتر دانشگاه سمنان است. زمینه‌های پژوهشی او شامل پردازش تصویر و سیگنال، بینایی کامپیوتر و ماشین و هوش مصنوعی است.

نشانی رایانامه ایشان عبارت است از:

h_soltanizadeh@semnan.ac.ir



محمد رحمانی منش مدارک

کارشناسی ارشد و دکتری خود

را در رشته مهندسی کامپیوتر

از دانشگاه تربیت مدرس تهران

دریافت کرده‌است. او در حال

حاضر دانشیار دانشگاه سمنان، ایران است. وی عضو

IEEE بوده و زمینه‌های پژوهشی او شامل امنیت

شبکه، سیستم‌های فازی، محاسبات نرم و داده‌کاوی

است.

نشانی رایانامه ایشان عبارت است از:

Rahmanimanesh@semnan.ac.ir