

Unsupervised domain adaptation via Bregman Divergence minimization and Adaptive Classifier learning

Mozhdeh Zandifar¹, Jafar Tahmoresnezhad^{2*}

1- Faculty of IT & Computer Engineering, Urmia University of Technology, Urmia, Iran.

2*- Faculty of IT & Computer Engineering, Urmia University of Technology, Urmia, Iran.

¹ mozhdeh.zandifar @it.uut.ac.ir, ^{2*} j.tahmores @it.uut.ac.ir.com

Corresponding author address: Jafar Tahmoresnezhad, Faculty of IT & Computer Engineering, Urmia University of Technology, Urmia, Iran, Post Code: 57166–171765.

Abstract- In pattern recognition and image classification, the common assumption that the training set (source domain) and test set (target domain) share the same distribution is often violated in real-world applications. In this case, traditional learning models may not generalize well on test sets. To tackle this problem, domain adaptation try to exploit training data with same distribution from other related source domain to generalize model for target domain. This paper presents a domain adaptation method which learns to adapt the data distribution of the source domain to that of the target domain where no labeled data of the target domain is available. Our method jointly learns a low dimensional representation space and an adaptive classifier. In fact, we try to find a representation space and an adaptive classifier on this representation space such that the distribution gap between the two domains is minimized and the risk of the adaptive classifier is also minimized. In this paper, we propose a novel solution to tackle unsupervised domain adaptation for classification. In the unsupervised scenario where no labeled samples from the target domain is available, our model transforms data such that the source and target distributions become similar. To compare two distributions, our approaches make use of Bregman divergence. However, this does not suffice to generalize the model. Here, we propose to make better use model matching along with representation learning to tackle distribution mismatch across domains. The framework extends classification model by adding an adaptive classifier, which generalizes the target classifier far from the source data. Then this framework guarantees the target classifier minimizes the empirical risk in target domain and maximize manifold consistency with source data structure. Our empirical study on multiple open data sets validates that our proposed approach can consistently improve the classification accuracy compared to the basic machine learning and state-of-the-art transfer learning methods.

Keywords- Transfer learning, Bregman divergence, Dimensionality reduction, Adaptive classifier.

تطبيق دامنه بدون نظارت با واگرایی برگمن و طبقه‌بند انطباقی

مژده زندی فر^۱، جعفر طهمورث نژاد^{۲*}

۱- دانشکده مهندسی فناوری اطلاعات و کامپیوتر، دانشگاه صنعتی ارومیه، ارومیه، ایران.

۲- دانشکده مهندسی فناوری اطلاعات و کامپیوتر، دانشگاه صنعتی ارومیه، ارومیه، ایران.

^۱ mozhdeh.zandifar@it.uut.ac.ir, ^{۲*} j.tahmores@it.uut.ac.ir

* نشانی نویسنده مسئول: جعفر طهمورث نژاد، ارومیه، کیلومتر دو جاده بند، دانشگاه صنعتی ارومیه، دانشکده مهندسی فناوری اطلاعات و کامپیوتر، کد پستی: ۵۷۱۶۶-۱۷۱۷۶۵

چکیده- در تشخیص الگو و طبقه‌بندی تصویر، فرض معمول بر این است که مجموعه آموزشی (دامنه منبع) و مجموعه تست (دامنه هدف) توزیع یکسانی را به اشتراک می‌گذارند که در اغلب کاربردهای دنیای واقعی نقض می‌شود. در این صورت ممکن است مدل‌های یادگیری سنتی بر روی مجموعه‌های آموزشی به درستی تعمیم داده نشوند. برای مقابله با این مشکل، یادگیری انتقالی و تطبیق دامنه، سعی می‌کنند با بهره‌گیری از داده‌های آموزشی با توزیع مشابه با دامنه منبع، مدل را برای دامنه هدف تعمیم دهند. در این مقاله، ما یک راه حل جدید برای رویارویی با تطبیق دامنه بدون نظارت برای طبقه‌بندی پیشنهاد می‌دهیم. در سناریو بدون نظارت که در آن هیچ نمونه برجسب دار از دامنه هدف موجود نیست، مدل ما داده‌ها را به گونه‌ای تغییر می‌دهد که توزیع نمونه‌های دامنه منبع و هدف مشابه شوند. برای مقایسه دو توزیع، رویکرد ما از واگرایی برگمن استفاده می‌کند. با این وجود این رویکرد به تنهایی برای تعمیم مدل کافی نیست. در اینجا، ما یک مدل تطبیق‌پذیر برای یادگیری نمایش بهتر جهت مقابله با عدم توازن توزیع در دامنه‌های مختلف ارائه می‌دهیم. چارچوب مدل طبقه‌بندی با اضافه کردن یک طبقه‌بند سازگار برای طبقه‌بندی دامنه هدف تعمیم می‌یابد. بدین ترتیب، این چارچوب تضمین کننده طبقه‌بندی دامنه هدف بوده و خطر ریسک تجربی در دامنه هدف را به حداقل می‌رساند و سازگاری هندسی با ساختار داده‌های منبع را به حداکثر می‌رساند. مطالعه تجربی ما بر روی مجموعه داده‌های معتبر موید این است که رویکرد پیشنهادی ما می‌تواند به طور مداوم دقت طبقه‌بندی را در مقایسه با الگوریتم‌های یادگیری ماشین پایه و روش‌های تطبیق دامنه بهبود دهد.

واژه‌های کلیدی: یادگیری انتقالی، واگرایی برگمن، کاهش ابعاد، طبقه‌بند انطباقی.

۱- مقدمه

آن تبعیت می‌کنند. بر اساس این فرض، داده‌های آموزشی^۴ (دامنه منبع^۵) و آزمایشی^۶ (دامنه هدف^۷) در یک مدل بایستی از یک فضای ویژگی بوده و توزیع یکسانی داشته باشند، ولی در بسیاری از کاربردهای دنیای واقعی این فرض برقرار نیست و کارایی مدل کاهش می‌یابد [۲].

در شرایطی که نحوه توزیع داده‌های آموزشی و آزمایشی متفاوت باشد، می‌بایست مدل آماری با کمک داده‌های آموزشی جدید از نو ساخته شود که این کار بسیار هزینه‌بر و زمان‌گیر می‌باشد. انتقال دانش یا یادگیری انتقالی^۸ می‌تواند مدل‌هایی را ایجاد یا تطبیق

یادگیری ماشین، یکی از شاخه‌های پرکاربرد هوش مصنوعی است که به اکتشاف الگوریتم‌هایی می‌پردازد که بر اساس آن‌ها کامپیوترها توانایی یادگیری پیدا می‌کنند [۱]. در سال‌های اخیر، تکنولوژی‌های داده‌کاوی و یادگیری ماشین به موفقیت‌های چشم‌گیری در حوزه‌های طبقه‌بندی^۱، رگرسیون^۲ و خوشه‌بندی^۳ دست یافته‌اند. با این حال، در تمام این حوزه‌ها یک فرض کلی وجود دارد که بیشتر الگوریتم‌های داده‌کاوی و یادگیری ماشین از

را شامل می‌شود. واگرایی برگمن بوسیله کاهش تفاوت بین توزیع نمونه‌های آموزشی و تست می‌تواند دانش تفکیک کننده بدست آمده از نمونه‌های آموزشی را به نمونه‌های تست انتقال دهد. همچنین واگرایی برگمن، اطلاعات تفکیک کننده بدست آمده از نمونه‌های آموزشی را برای تفکیک پذیری هرچه بهتر کلاس‌های دامنه هدف، حفظ می‌کند.

در مسائلی که اختلاف توزیع بین دامنه‌های منبع و هدف زیاد باشد، تنها کاهش دادن اختلاف توزیع بین دامنه‌های منبع و هدف، برای ایجاد یک مدل طبقه‌بند تطبیق پذیر با تغییر دامنه‌ها کافی نیست؛ بنابراین، یک طبقه‌بند انطباقی^{۱۱} با هدف سازگاری بیشتر طبقه‌بند ایجاد شده در دامنه منبع با ساختار داده‌های دامنه هدف، ایجاد می‌شود که دارای عملکرد خوبی در مواجهه با شیفت دامنه بین دامنه‌های مختلف است. ایجاد یک طبقه‌بند انطباقی، با هدف بدست آوردن حداقل خطای طبقه‌بندی روی دامنه منبع و حداکثر انطباق تابع پیش‌بینی و ساختار منیفلد^{۱۲} داده‌های منبع و هدف انجام می‌گیرد. در واقع این مدل انطباقی، سعی دارد خطای پیش‌بینی مدل برای دامنه هدف را به حداقل برساند.

در الگوریتم‌های یادگیری ماشین چنانچه با ابعاد بالا سروکار داشته باشیم یا به عبارت دیگر تعداد ویژگی‌های داده ورودی زیاد باشد، با مشکلات عدیده‌ای مواجه خواهیم بود. برخی از این مشکلات عبارتند از: پیچیدگی محاسبات از نظر زمان و حافظه، فهم دشوار مسأله و دشواری استخراج دانش^{۱۱} و نیاز به کنترل پیچیدگی جهت جلوگیری از بیش‌برازش^{۱۲} در آموزش مدل، لذا با بکارگیری روش‌های متعددی تحت عنوان روش‌های کاهش ابعاد، می‌توان داده‌ها را به فضایی با بُعد کمتر تصویر کرد به گونه‌ای که در حد امکان خواص داده‌ها در فضای اولیه از بین نرود. کاهش ابعاد معمولاً به دو روش زیر صورت می‌پذیرد؛ انتخاب ویژگی‌ها [۹، ۱۰] و استخراج ویژگی‌ها [۱۱].


PCA^{۲۳} یک روش شناخته شده و اساسی در استخراج ویژگی‌ها و کاهش ابعاد فضای خصیصه‌ای داده‌ها است و به طور چشمگیری در مسائل با ابعاد بالا مانند تشخیص چهره و دامنه‌های بصری به کار گرفته می‌شود. FLDA^{۲۴} از دیگر روش‌های قدرتمند در زمینه کاهش ابعاد و استخراج ویژگی می‌باشد که به صورت گسترده در مسائل طبقه‌بندی مورد استفاده قرار می‌گیرد. این روش به دنبال یافتن یک ماتریس تبدیل بهینه بوده که از دو ماتریس پراکندگی درون کلاسی و بین کلاسی استفاده می‌کند. FLDA برای یافتن ماتریس نگاشت بهینه، نسبت بین ماتریس پراکندگی بین کلاسی و ماتریس پراکندگی درون کلاسی را مینیمم می‌نماید [۱۲ و ۱۳]. روش پیشنهادی این مقاله با عنوان BDAC^{۲۵}، یک روش بدون نظارت دو مرحله‌ای با بهره‌گیری از تطبیق خصوصیات و

دهد که نیاز به هزینه‌های اضافی جهت بازسازی یا مقاوم‌سازی نداشته باشند. یادگیری انتقالی یک مسأله تحقیقاتی در حوزه یادگیری ماشین است که تمرکز آن بر روی ذخیره کردن دانش بدست آمده از حل یک مسأله و به کار بردن آن برای حل مسائل متفاوت اما مرتبط است [۴، ۳]. اهمیت استفاده از یادگیری انتقالی زمانی افزایش می‌یابد که به اندازه کافی داده‌های آموزشی برچسب‌دار جهت آموزش یک مدل طبقه‌بند دقیق وجود نداشته باشد. تطبیق دامنه^{۱۳} این مشکل را توسط یادگیری طبقه‌بند در دامنه منبع برای استفاده در دامنه هدف، حل می‌کند. برای مثال، برای آموزش یک مدل تشخیص عابران پیاده بر اساس تصاویری که در شب گرفته شده‌اند می‌توانیم مدلی را که در یک دامنه مشابه (به عنوان مثال تصاویری که در روز گرفته شده‌اند) آموزش داده و مورد استفاده قرار دهیم.

اختلاف توزیع بین دامنه‌های منبع و هدف، شامل اختلاف در توزیع حاشیه‌ای^{۱۴} و توزیع شرطی^{۱۵} می‌باشد. در شرایطی که دامنه‌های منبع و هدف دارای مجموعه خصوصیات یکسان باشند، اختلاف در احتمال وقوع مقادیر هر کدام از این خصوصیات در هر دامنه، موجب ایجاد اختلاف توزیع حاشیه‌ای بین دامنه‌ها می‌شود؛ اما اختلاف توزیع شرطی بین دامنه‌ها زمانی ایجاد می‌شود که به ازای داده‌های یکسان از هر دو دامنه منبع و هدف، مجموعه برچسب‌های متفاوتی پیش‌بینی شود.

در سیستم‌های یادگیری ماشین، وجود اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌های آموزشی و آزمایشی موجب می‌شود، مدل طبقه‌بند ایجاد شده در دامنه منبع، دقت پایینی در پیش‌بینی برچسب‌های نمونه‌های دامنه هدف داشته باشد. روش‌های تطبیق دامنه، وابسته به نوع دامنه هدف می‌توانند به دو نوع نیمه نظارت‌شده^{۱۶} و بدون نظارت^{۱۷} تقسیم شوند [۵]. در تطبیق دامنه نیمه نظارت شده، برخی از داده‌های برچسب دار از دامنه هدف در دسترس می‌باشد ولی اغلب این داده‌ها برای ایجاد یک طبقه‌بند خوب، به صورت مستقل، مناسب نیستند؛ اما اگر هیچ داده برچسب‌داری از دامنه هدف موجود نباشد، مسأله تبدیل به تطبیق دامنه بدون نظارت می‌شود. در بسیاری از کاربردهای دنیای واقعی، به دلیل اینکه هیچ نمونه‌ی برچسب دار از دامنه هدف در دسترس نیست، از تطبیق دامنه بدون نظارت استفاده می‌شود.

برای سنجش و کاهش اختلاف توزیع بین دامنه‌های منبع و هدف، نیازمند یک معیار جهت اندازه‌گیری فاصله هستیم. واگرایی برگمن^{۱۴} [۶، ۴] یک واگرایی جامع است که تعداد زیادی از فواصل معروف و پرکاربرد از جمله تابع هزینه جمع مربعات^{۱۵}، واگرایی کولبک – لایبلر^{۱۶} [۷]، تابع هزینه منطقی^{۱۷}، فاصله مالهالانوبیس^{۱۸}



شکل ۱: مراحل روش BDAC (نمایش بهتر به صورت رنگی). در روش پیشنهادی، برای پیش‌بینی برجسب‌های نمونه‌های دامنه هدف، یک الگوریتم تکرارشونده بر روی داده‌های دامنه‌های منبع و هدف اعمال می‌شود. در هر تکرار، اختلاف توزیع دامنه هدف با دامنه منبع، کاهش یافته و در ادامه، با اعمال یک طبقه‌بند انطباقی، دقت مدل پیش‌بینی در دامنه هدف افزایش می‌یابد.

تابع چگالی احتمال داده‌های آموزشی و تست را در زیرفضای نگاشت‌شده با استفاده از روش برآورد تراکم هسته تخمین می‌زند و سپس واگرایی برگمن با انتقال اطلاعات به دست آمده از دامنه منبع، اختلاف توزیع بین دامنه‌ها را به طور قابل ملاحظه‌ای کاهش می‌دهد. در مرحله دوم از روش BDAC، یک طبقه‌بند انطباقی بر روی هر دو داده‌های دامنه‌های منبع و هدف ایجاد می‌شود. در واقع، طبقه‌بند انطباقی، برای ایجاد یک مدل تطبیق‌پذیر بین دامنه‌ای، ابعاد تفکیک‌کننده کلاس‌های دامنه منبع را با ساختار نمونه‌های دامنه هدف سازگار می‌سازد. این عمل، موجب افزایش دقت طبقه‌بند در پیش‌بینی برجسب نمونه‌های دامنه هدف می‌شود. بیشتر مطالعات قبلی در حوزه یادگیری انتقالی یا براساس ایجاد یک مدل انطباقی نمونه‌های دامنه منبع مطابق با توزیع دامنه هدف [۲۲]، [۲۳]، [۲۴] و یا براساس یافتن یک نمایه جدید برای نمونه‌های دامنه منبع و هدف، به منظور کاهش اختلاف توزیع بین دامنه‌های منبع و هدف عمل می‌کنند [۲۵]، [۲۶]. در این مقاله یک چارچوب جدید برای تطبیق دامنه‌های بصری پیشنهاد شده است که در آن تطبیق خصوصیات و تطبیق مدل به طور هم‌زمان بهینه می‌شوند. BDAC با استفاده از تطبیق خصوصیات و واگرایی برگمن یک زیرفضای جدید به دست می‌آورد که در آن خصوصیات مشترک دو دامنه منبع و هدف حفظ می‌شوند و سپس یک طبقه‌بند انطباقی با استفاده از داده‌های برجسب‌دار

طبقه‌بندی انطباقی است. BDAC در مرحله اول با استفاده از روش تطبیق خصوصیات و FLDA، یک نمایش کم بعد از دامنه‌های منبع و هدف ایجاد می‌کند که در نمایش جدید اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف کاهش می‌یابد. سپس در مرحله بعدی با استفاده از داده‌های برجسب‌دار دامنه منبع و داده‌های بدون برجسب دامنه هدف، یک طبقه‌بند انطباقی آموزش داده می‌شود. مدل انطباقی ایجاد شده بر روی نمایش جدید داده‌های منبع و هدف، سعی می‌کند خطای پیش‌بینی در دامنه هدف را به حداقل رساند. این طبقه‌بند انطباقی، با در نظر گرفتن حداکثر میزان انطباق مدل و حفظ ساختار هندسی داده‌ها بین دامنه‌های منبع و هدف، مدلی در جهت جبران اختلاف توزیع دامنه‌ها ایجاد کند.

در شکل ۱، مراحل روش پیشنهادی به صورت شماتیک نمایش داده شده است. در روش BDAC، ابتدا یک الگوریتم تکرارشونده، بر روی نمونه‌های دامنه منبع و هدف اعمال می‌شود تا نمایش تطبیق‌پذیری از دامنه‌های منبع و هدف ایجاد شود. در واقع روش پیشنهادی BDAC یک روش دو مرحله‌ای با بهره‌گیری از تطبیق خصوصیات و یک طبقه‌بند انطباقی است. در مرحله اول، سعی شده است با استفاده از تطبیق خصوصیات و واگرایی برگمن، یک نمایش جدید از داده‌های دامنه‌های منبع و هدف ایجاد شود که در این نمایش، توزیع شرطی دامنه‌های آموزشی و تست تطبیق‌پذیری دقیق‌تری با هم داشته باشند. BDAC

دامنه منبع و داده‌های بدون برچسب دامنه هدف به منظور ایجاد یک مدل قوی در برابر اختلاف توزیع دامنه‌ها، ساخته می‌شود.

اهداف اصلی رویکرد پیشنهادی بدین صورت خلاصه شده است:

- (۱) حفظ ساختار اصلی داده‌ها، BDAC به کمک فرآیند FLDA، داده‌های دامنه منبع و هدف را به یک زیرفضای ویژگی کم‌بعد نگاشت می‌کند به طوری که ساختار اصلی داده‌ها حفظ شود،
- (۲) تطبیق توزیع حاشیه‌ای، BDAC با استفاده از واگرایی برگمن اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف را در زیرفضای نگاشت‌شده کاهش می‌دهد، (۳) تطبیق مدل، BDAC با ایجاد یک مدل انطباقی بر روی نمایش جدید داده‌های منبع و هدف، سعی دارد خطای پیش‌بینی را در دامنه هدف حداقل سازد. در واقع BDAC با حداقل کردن خطای تجربی تابع پیش‌بینی در داده‌های برچسب‌دار دامنه منبع و حداکثر کردن نرخ سازگاری تابع پیش‌بینی و ساختار هندسی داده‌ها بین دامنه‌های منبع و هدف، سعی در ایجاد مدلی انطباق‌پذیر به منظور جبران اختلاف توزیع دامنه‌ها دارد، و (۴) همچنین BDAC به منظور تصحیح و بهبود برچسب اولیه داده‌های هدف، به صورت تکرارشونده طراحی شده است. ساختار ادامه مقاله به صورت زیر است. در بخش ۲ پژوهش‌های مرتبط مورد بررسی قرار می‌گیرند. در بخش ۳ تعاریف و روش پیشنهادی گنجانده شده است. بخش ۴ شامل پایگاه‌داده‌های مورد ارزیابی و فرضیات آزمایش‌ها می‌باشد. در بخش ۵ نتایج حاصل از عملکرد الگوریتم پیشنهادی و مقایسه آن با دیگر روش‌های موجود قرار دارد. و نهایتاً در بخش ۶ نتیجه‌گیری و کارهای پیشنهادی آتی ارائه شده است.

۲- کارهای پیشین

در حوزه یادگیری ماشین روش‌های بسیاری در زمینه تطبیق دامنه‌ها پیشنهاد شده است که تمرکز بیشتر آنها بر کاهش اختلاف توزیع بین دامنه‌های منبع و هدف می‌باشد. بطور کلی روش‌های موجود در تطبیق دامنه‌ها به سه دسته تقسیم می‌شوند. (۱) رویکردهای یادگیری انتقالی مبتنی بر مدل^{۲۶} که در این روش با تغییر در مدل از طریق پارامترهای اصلی یا مشترک، مدل را در مقابل اختلاف توزیع بین دامنه‌ها مقاوم می‌کنند. ARTL [۱۴] یکی از الگوریتم‌های شاخص در این دسته است. ARTL به دنبال یک طبقه‌بند انطباقی است که ۳ هدف را برآورده می‌کند: هدف اول) توزیع حاشیه‌ای داده‌های منبع و هدف را به یکدیگر نزدیک می‌کند، هدف دوم) اختلاف

توزیع شرطی داده‌های منبع و هدف را برهم منطبق می‌کند، هدف سوم) سازگاری مدل را با ساختار هندسی داده‌ها در فضای جدید افزایش می‌دهد. (۲) رویکردهای یادگیری انتقالی مبتنی بر ویژگی^{۲۷} که در این روش با نگاشت داده‌ها به فضای خصیصه‌ای دیگر، اختلاف توزیع بین دامنه‌های منبع و هدف را کاهش می‌دهند. VDA [۱۵] از جمله روش‌های بدون نظارت مبتنی بر خصیصیت است. VDA یک نمایش کم‌بعد از دامنه‌های منبع و هدف ایجاد می‌کند که در آن، علاوه بر کاهش اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها، از روش خوشه‌بندی مستقل از دامنه نیز برای ایجاد تفکیک‌پذیری بین کلاس‌های مختلف استفاده می‌کند. همچنین VDA با خوشه‌بندی مستقل از دامنه، با حفظ شکل هندسی و آماری بین دامنه‌های منبع و هدف در فضای جدید، باعث افزایش دقت طبقه‌بند در دامنه هدف می‌شود. CDDA [۱۶] نیز یک رویکرد تطبیق دامنه جدید است که یک فضای ویژگی مشترک با دو ویژگی مهم زیر بین دامنه‌های منبع و هدف ایجاد می‌کند: الف) از طریق معیار MMD²⁸، اختلاف توزیع حاشیه‌ای و شرطی بین دامنه منبع و هدف کاهش می‌یابد به طوری که دو دامنه از نظر توزیع به هم نزدیک شوند و ب) فاصله زیردامنه‌هایی با برچسب متفاوت افزایش می‌یابد که موجب می‌شود قدرت تفکیک‌پذیری زیرفضای جدید افزایش یابد و مدل آموزش داده‌شده در این زیرفضا عملکرد بهتری بر روی داده‌های هدف داشته باشد. علاوه بر این، با توجه به اینکه منیفولد داده‌ها می‌تواند ساختار هندسی پیچیده‌ای داشته باشد، CDDA از محدودیت‌های همواری برچسب و سازگاری ساختار هندسی برای انتشار برچسب استفاده می‌کند. و (۳) رویکردهای یادگیری انتقالی مبتنی بر نمونه^{۲۹} که در این روش با تغییر وزن نمونه‌های برچسب‌دار دامنه منبع، اختلاف توزیع بین دامنه‌های منبع و هدف را کاهش می‌دهند. از جمله جدیدترین روش‌های وزن‌دهی به نمونه‌ها می‌توان به روش FTIW [۱۷] اشاره کرد. روش FTIW داده‌های منبع و هدف را که در فضای اصلی دارای توزیع متفاوت هستند را با استفاده از یک ماتریس تبدیل به یک زیرفضای جدید نگاشت می‌کند که اختلاف توزیع آن‌ها را کاهش دهد همزمان با این کار با استفاده از یک ماتریس وزن تاثیر نمونه‌های نامرتبط دامنه هدف را کم می‌کند.

در این مقاله برای حل مسأله یادگیری انتقالی بدون نظارت، یک چارچوب جدید دو مرحله‌ای با ترکیبی از روش‌های مبتنی بر خصیصیت و مبتنی بر مدل پیشنهاد می‌شود. در مرحله اول، داده‌های دامنه منبع و هدف با استفاده از یک روش مبتنی بر

ازای مجموعه نمونه ورودی X مجموعه برچسب‌های Y را پیش‌بینی می‌کند که احتمال شرطی آن به صورت $P(Y|x)$ تعریف می‌شود. بنابراین، اگر دو وظیفه متفاوت باشند، ممکن است مجموعه برچسب‌های مختلفی داشته باشند یا توزیع احتمالی شرطی آنها متفاوت از یکدیگر باشد، بدین معنی که $Y_s \neq Y_t$ یا $P_s(Y|x) \neq P_t(Y|x)$.

حال فرض کنید l و u ، به ترتیب تعداد نمونه‌های دامنه منبع و هدف باشند. در تطبیق دامنه بدون نظارت، تمام نمونه‌های دامنه منبع دارای برچسب هستند که به صورت $D_s = \{(\vec{x}_1, y_1), \dots, (\vec{x}_l, y_l)\}$ تعریف می‌شوند و تمام نمونه‌های بدون برچسب دامنه هدف به صورت $D_t = \{\vec{x}_{l+1}, \dots, \vec{x}_{l+u}\}$ تعریف می‌شوند. همه نمونه‌ها از یک فضای خصیصه‌ای با ابعاد بالا R^D هستند، هدف پیدا کردن یک فضای خصیصه‌ای با ابعاد پایین R^d می‌باشد که در آن اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف کاهش یابد درحالی‌که اطلاعات خاص (مانند ساختار منیفلد داده‌ها) حفظ شود. برای نگاشت فضای خصیصه‌ای با ابعاد بالا R^D به فضای خصیصه‌ای با ابعاد پایین R^d از یک تابع خطی $\vec{y} = W^T \vec{x}$ استفاده می‌کنیم که ماتریس نگاشت W با ابعاد $W \in R^{D \times d}$ و $\vec{y} \in R^d$ تعریف می‌شوند. مقدار بهینه W بصورت زیر محاسبه می‌شود:

$$W = \arg \min_{W \in R^{D \times d}} F(W) \quad (1)$$

در واقع داده‌ها با کمک ماتریس نگاشت W از فضای اصلی به یک زیرفضا با ابعاد کم‌تر منتقل می‌شوند به شرطی که تابع هدف $F(W)$ حداقل شود و شرط $W^T W = I$ برآورده شود. این شرط نشان دهنده این است که سطرها و یا ستون‌های ماتریس W مستقل از یکدیگر بوده و برهم عمودند و مجموع آن‌ها برابر یک است. با وجود این شرط در رابطه بهینه‌سازی، جواب‌های بدیهی^{۳۲} در مجموعه جواب قرار نمی‌گیرند.

۳- روش پیشنهادی

در این بخش، روش BDAC برای حل مسأله یادگیری انتقالی بدون نظارت، با جزئیات بیشتر توضیح داده می‌شود.

۳-۱- چارچوب کلی

در یادگیری انتقالی یافتن یک راه حل برای کاهش اختلاف توزیع بین دامنه‌های منبع و هدف یک اصل اساسی و مهم است. هدف این مقاله، ارائه یک چارچوب دومرحله‌ای برای کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف است. روش‌های زیادی برای یادگیری یک نمایش خصیصه تطبیق‌پذیر جهت کاهش اختلاف توزیع بین دامنه‌های منبع و

تطبیق خصوصیات، به یک زیر فضای جدید که در آن اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف حداقل شده، نگاشت می‌شوند. در این مرحله از واگرایی برگمن برای ایجاد تفکیک‌پذیری بین کلاس‌های مختلف استفاده می‌شود تا با انتقال حداکثری اطلاعات تفکیک‌کننده دامنه منبع، عملکرد بهتری در پیش‌بینی برچسب داده‌های دامنه هدف ایجاد شود. در مرحله بعد، از یک طبقه‌بند انطباقی با هدف حداقل کردن خطای پیش‌بینی مدل روی داده‌های منبع و حداکثر کردن سازگاری بین ساختار منیفلد و مدل پیش‌بینی استفاده می‌شود.


۲-۱- هدف تحقیق

مشکل شیفت دامنه‌ها در بسیاری از مسائل دنیای واقعی وجود دارد و استفاده از الگوریتم‌های کلاسیک یادگیری ماشین نمی‌تواند پاسخگوی مسائل موجود باشد در چنین حالت‌هایی نیاز به استفاده از انتقال دانش یا یادگیری انتقالی به یک ضرورت اجتناب‌ناپذیر تبدیل می‌شود. اما یکی از چالش‌های مهمی که اعتماد استفاده از یادگیری را در بین کاربران از بین می‌برد، وقوع انتقال منفی است. انتقال منفی هنگامی رخ می‌دهد که توزیع دامنه‌های منبع و هدف تفاوت چشم‌گیری با یکدیگر داشته باشند. هدف از این تحقیق ارائه راه حلی است که بتواند بر محدودیت‌های الگوریتم‌های کلاسیک یادگیری ماشین غلبه کند، بازدهی روش‌های یادگیری انتقالی را افزایش داده و باعث کاهش اثرات انتقال منفی^{۳۰} در یادگیری انتقالی شود.

۲-۲- تعریف مسأله

در این بخش، مفاهیم و تعاریف اصلی برای مشکل شیفت دامنه‌ها تعریف شده و در ادامه مسأله به طور کامل شرح داده می‌شود.

در مسائل انتقال یادگیری، هر دامنه شامل دو مفهوم کلی فضای خصیصه‌ای X و توزیع احتمال حاشیه‌ای $P(x)$ برای هر $x \in X$ است، یعنی $D = \{X, P(x)\}$. بدین ترتیب، اگر دو دامنه متفاوت باشند، ممکن است فضای خصیصه‌ای مختلف و یا توزیع احتمال حاشیه‌ای متفاوت از یکدیگر داشته باشند. به طور دقیق‌تر، اگر X_s فضای خصیصه‌ای دامنه منبع، X_t فضای خصیصه‌ای دامنه هدف و $P_s(X_s)$ ، $P_t(X_t)$ به ترتیب، توزیع احتمال حاشیه‌ای دامنه‌های منبع و هدف باشند (برای هر نمونه، $x_s \in X_s$ و $x_t \in X_t$ ، دو دامنه زمانی متفاوت هستند که $X_s \neq X_t$ یا $P_s(X_s) \neq P_t(X_t)$ ، برای هر دامنه D ، یک وظیفه^{۳۱} شامل مجموعه برچسب‌های Y و تابع پیش‌بینی $f(x)$ وجود دارد که به صورت $T = \{Y, f(x)\}$ نشان داده می‌شود. تابع پیش‌بینی $f(x)$ ، به



شکل ۲: واگرایی برگمن بین دو نقطه x و y . $\nabla f(y)$ بردار گرادیان در نقطه y می‌باشد و d_ϕ میزان خطا در تخمین تابع ϕ در نقطه y را محاسبه می‌کند.

از خصوصیات واگرایی برگمن می‌توان به موارد زیر اشاره نمود. در واگرایی برگمن همواره $d_\phi(x, y) \geq 0$ می‌باشد و $d_\phi(x, y)$ بر روی نقطه x همواره محدب است اما بر روی نقطه y لزوماً محدب نیست. با تعمیم این رابطه می‌توان از آن برای محاسبه اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف استفاده کرد، بنابراین خواهیم داشت:

$$d_{U_{map}}(P_s(\vec{y}), P_t(\vec{y})) = \{U_{map}(P_s(\vec{y})) - U_{map}(P_t(\vec{y}))\} - \{ \langle P_s(\vec{y}) - P_t(\vec{y}), \nabla U_{map}(P_t(\vec{y})) \rangle \} \quad (4)$$

U_{map} یک تابع نگاشت است، P_t و P_s به ترتیب توزیع احتمال نمونه‌های دامنه منبع و هدف را نشان می‌دهند و $d_{U_{map}}(P_s, P_t)$ میزان خطا در تخمین تابع U_{map} در نقطه P_s را با استفاده از تانژانت تابع اندازه‌گیری می‌کند. با توجه به رابطه (۲)، واگرایی برگمن بر اساس تنظیم جدید که فاصله بین P_s و P_t را بر طبق فاصله مربع اقلیدسی محاسبه می‌کند به صورت زیر تعریف می‌شود.

$$D_W(P_s \parallel P_t) = \int (P_s(\vec{y}) - P_t(\vec{y}))^2 d\vec{y} = \int (P_s(\vec{y})^2 - 2P_s(\vec{y})P_t(\vec{y}) + P_t(\vec{y})^2) d\vec{y} \quad (5)$$

در آمار و احتمال، برآورد تراکم هسته^{۳۴} به فرآیند تخمین تابع چگالی احتمال یک متغیر تصادفی با استفاده از نمونه‌های مشاهده شده از آن متغیر گفته می‌شود. معمولاً فرض می‌شود نمونه‌های مشاهده شده به طور تصادفی و مستقل براساس تابع توزیع احتمال، توزیع شده‌اند. برای تخمین مقادیر P_t و P_s از روش برآورد تراکم هسته استفاده می‌کنیم که تراکم را $\gamma \in R^d$ به عنوان مجموع کرنل‌های بین γ و هر نمونه \vec{y}_i تخمین می‌زند، به عنوان مثال $p(\vec{y}) = \frac{1}{n} \sum G_\Sigma(\vec{y} - \vec{y}_i)$ که در آن n تعداد نمونه‌ها و $G_\Sigma(\vec{y})$ کرنل گوسی d بعدی با ماتریس کوواریانس Σ می‌باشد. با جایگذاری KDE در رابطه (۵) خواهیم داشت:

هدف در یادگیری انتقالی وجود دارد که از جمله این روش‌ها می‌توان به روش‌های مبتنی بر کاهش بعد اشاره کرد. در روش‌های کاهش بعد، داده‌ها از فضای اولیه به یک زیرفضای نگاشت شده منتقل می‌شوند به طوری که تابع هدف آن‌ها در زیرفضا (هزینه بازگرداندن داده‌ها به فضای اولیه^{۳۵}) حداقل شود. روش FLDA یکی از بهترین روش‌ها برای کاهش بعد و دسته‌بندی به طور هم‌زمان است که در ادامه با جزئیات کامل معرفی می‌شود ولی پیش از آن، واگرایی برگمن به عنوان یک معیار اندازه‌گیری فاصله بین دو دامنه معرفی می‌شود.

واگرایی برگمن، دامنه‌ی گسترده‌ای از فاصله‌ها از جمله فاصله اقلیدسی، واگرایی KL، فاصله مالهالانوبیس را در بر می‌گیرد. از این رو برای محاسبه فاصله بین توزیع داده‌های دامنه منبع و هدف مناسب می‌باشد. در تصویر (۱) واگرایی برگمن بین دو نقطه x و y وابسته به تابع ϕ نشان داده شده است. واگرایی برگمن به تابعی محدب و مشتق پذیر $\phi: X \rightarrow R$ یک تابع نگاشت از X به R وابسته است. واگرایی برگمن d که به تابع ϕ وابسته است بر روی مجموعه X بین نقاط $x, y \in X$ به صورت زیر تعریف می‌شود:

$$d_\phi = \phi(x) - \phi(y) - \langle x - y, \nabla \phi(y) \rangle \quad (2)$$

که در آن $\nabla \phi(y)$ بردار گرادیان تابع ϕ در نقطه y و $\langle \dots \rangle$ ضرب داخلی دو بردار است. برای بدست آوردن واگرایی برگمن، نقاط x و y را با تابع ϕ بر روی بردار گرادیان تابع در نقطه y تصویر می‌کنیم. بخش اول رابطه (۲) فاصله بین نقاط x و y را بر روی بردار گرادیان محاسبه می‌کند و بخش دوم خطای ناشی از تابع نگاشت را جبران می‌کند تا در نهایت فاصله دقیق بین دو نقطه x و y روی تابع محدب بدست آید. در تصویر (۲) واگرایی برگمن بین دو نقطه x و y وابسته به تابع ϕ نشان داده شده است. مربع فاصله اقلیدسی یکی از پرکاربردترین واگرایی‌های برگمن است. برای این فاصله تابع ϕ به صورت $\phi(x) = \langle x, x \rangle$ و $\phi(y) = \langle y, y \rangle$ تعریف می‌شود که اکیدا محدب و بر روی R^d مشتق‌پذیر است. در واقع d_ϕ میزان خطا در تخمین تابع ϕ در نقطه y را با استفاده از تانژانت تابع اندازه‌گیری می‌کند. فاصله مربع اقلیدسی بر اساس واگرایی برگمن به فرم رابطه (۳) تعریف می‌گردد:

$$d_\phi(x, y) = \langle x, x \rangle - \langle y, y \rangle - \langle x - y, \nabla \phi(y) \rangle = \langle x, x \rangle - \langle y, y \rangle - \langle x - y, 2y \rangle = \langle x - y, x - y \rangle = \|x - y\|^2 \quad (3)$$

است. در این روش سعی می شود به طور همزمان $Det(S_W)$ حداقل و $Det(S_B)$ حداکثر گردد. یکی از مناسب ترین معیارها جهت بیان تفکیک پذیری کلاسها استفاده از تریس^{۲۶} ماتریس می باشد که به صورت زیر تعریف می شود.

$$\begin{aligned} \operatorname{argmax} \frac{\operatorname{tr}(W^T S_B W)}{\operatorname{tr}(W^T S_W W)} \\ = \operatorname{argmin} \frac{\operatorname{tr}(W^T S_W W)}{\operatorname{tr}(W^T S_B W)} \end{aligned} \quad (10)$$

پس در واقع تابع هدف الگوریتم FLDA برابر است با $F(W) = \operatorname{tr}^{-1}(W^T S_B W) \operatorname{tr}(W^T S_W W)$ (۱۱) که $\operatorname{tr}^{-1}(X)$ معکوس $\operatorname{tr}(X)$ می باشد.

۳-۱-۲- تحلیل خطی بر اساس فیشر انتقال یافته

نکته مهم در مورد روش FLDA این است که در مسائلی مانند تشخیص الگو و طبقه بندی تصویر که با ابعاد بزرگ داده مواجه هستیم، ممکن است ماتریس نگاشت W روی داده های آموزشی دچار زیادآموزی شود. همچنین FLDA کلاسیک به دلیل اینکه اطلاعات اولیه را در مورد تفاوت بین توزیع نمونه های آموزشی و آزمایشی در نظر نمی گیرد، به طور کامل نمی تواند پاسخگوی مساله شیفت دامنه ها باشد. با این حال برای اجتناب و یا کاهش مشکل زیادآموزی، ما اطلاعات اولیه نمونه های آموزشی را با اضافه کردن یک بخش تنظیم منطقی^{۲۷} به رابطه (۱) در نظر می گیریم. روش پیشنهادی BDAC یک زیرفضای مطلوب پیدا می کند که در آن کلاس داده های آموزشی و آزمایشی به صورت مستقل از هم جدا می شوند. BDAC علاوه بر اینکه اطلاعات تفکیک کننده موجود در نمونه های آموزشی را در نظر می گیرد توزیع بایاس بین نمونه های آموزشی و آزمایشی را نیز بررسی می کند. بدین ترتیب با ترکیب واگرایی برگمن [۱۸] تابع هدف الگوریتم FLDA بدست می آید؛ پس با توجه به رابطه (۱) و (۷) خواهیم داشت:

$$W = \operatorname{argmin}_{W \in R^{D \times d}} \operatorname{argmin} F(W) + \lambda D_W(P_S \| P_T) \quad (12)$$

$F(W)$ تابع هدف الگوریتم FLDA در زیر فضای پیش بینی شده، $D_W(P_S \| P_T)$ واگرایی برگمن که فاصله بین P_S و P_T را در فضای پیش بینی شده W محاسبه می کند و λ پارامتر تنظیم است که بین $F(W)$ و $D_W(P_S \| P_T)$ ، تنظیم ایجاد می کند. برای بدست آوردن زیرفضای خطی بهینه W با توجه به رابطه (۱۲) می توانیم از الگوریتم گرادیان نزولی^{۲۸} استفاده کنیم.

$$W \leftarrow W - \eta (\partial_W F(W) + \lambda D_W(P_S \| P_T)) \quad (13)$$

∂_W گرادیان با توجه به W و η نرخ یادگیری در k امین تکرار است بنابراین، W_{k+1} بصورت زیر بدست می آید:

$$\begin{aligned} D_W(P_S \| P_T) = & \int \left(\frac{1}{l} \sum_{i=1}^l G_{\Sigma_1}(\vec{y} - \vec{y}_i) \right)^2 d\vec{y} \\ & + \int \left(\frac{1}{u} \sum_{j=l+1}^u G_{\Sigma_2}(\vec{y} - \vec{y}_j) \right)^2 d\vec{y} \\ & - \int \left(\frac{2}{lu} \sum_{i=1}^l \sum_{j=l+1}^u G_{\Sigma_1}(\vec{y} - \vec{y}_i) G_{\Sigma_2}(\vec{y} - \vec{y}_j) \right) d\vec{y} \end{aligned} \quad (6)$$

که برای دو کرنل گوسی دلخواه داریم، $\int G_{\Sigma_1}(\vec{y} - \vec{y}_s) G_{\Sigma_2}(\vec{y} - \vec{y}_t) d\vec{y} = G_{\Sigma_1 + \Sigma_2}(\vec{y}_s - \vec{y}_t)$ Σ_1 ماتریس کوواریانس نمونه های دامنه منبع و Σ_2 ماتریس کوواریانس نمونه های دامنه هدف می باشند.

بنابراین می توانیم در رابطه (۶) مقادیر را ادغام کرده تا در نهایت به رابطه (۷) برسیم.

$$\begin{aligned} D_W(P_S \| P_T) = & \frac{1}{l^2} \sum_{s=1}^l \sum_{t=1}^l G_{\Sigma_{11}}(\vec{y}_s - \vec{y}_t) \\ & + \frac{1}{u^2} \sum_{s=l+1}^{l+u} \sum_{t=l+1}^{l+u} G_{\Sigma_{22}}(\vec{y}_s - \vec{y}_t) \\ & - \frac{1}{lu} \sum_{s=1}^l \sum_{t=l+1}^{l+u} G_{\Sigma_{12}}(\vec{y}_s - \vec{y}_t) \end{aligned} \quad (7)$$

که در این رابطه $\Sigma_{12} = \Sigma_{22} = \Sigma_2 + \Sigma_2$ ، $\Sigma_{11} = \Sigma_1 + \Sigma_1$ و $\Sigma_1 + \Sigma_2$ است.

۳-۱-۱- کاهش بعد بر اساس الگوریتم تحلیل تفکیک خطی فیشر (FLDA)

FLDA یک روش انتقال داده ها به فضای کم بعد است که ایده اصلی آن، حفظ ساختار کلاسها برای طبقه بندی می باشد. ساختار کلاس داده ها با S_B ماتریس پراکندگی بین کلاس و S_W ماتریس پراکندگی درون کلاس توصیف می شود. S_B بیانگر تغییرات بردارهای امید^{۲۹} برای هر زوج کلاس می باشد در حالیکه S_W پراکندگی نمونه ها حول بردار امید کلاس آن نمونه داده ها می باشد. از لحاظ ریاضی ماتریس پراکندگی بین کلاس و ماتریس پراکندگی درون کلاس به ترتیب به صورت زیر تعریف می شوند؛

$$S_B = \sum_{i=1}^c n_i (\bar{m}^{(i)} - \bar{m})(\bar{m}^{(i)} - \bar{m})^T \quad (8)$$

$$S_W = \sum_{i=1}^c \sum_{j=1}^{n_i} (x_j^{(i)} - \bar{m}^{(i)})(x_j^{(i)} - \bar{m}^{(i)})^T \quad (9)$$

که در آن C تعداد کلاسها، n_i تعداد نمونه های کلاس i ام، $m^{(i)}$ میانگین نمونه های کلاس i ام و m میانگین کل نمونه ها

بین تابع پیش‌بینی و توزیع حاشیه‌ای بین دامنه‌های منبع و هدف است. l تابع خطای پیش‌بینی طبقه‌بند انطباقی در دامنه منبع بوده که خطای مدل پیش‌بینی را روی داده‌های منبع حداقل می‌کند و به شکل رابطه (۱۸) تعریف می‌شود.

$$l(f(g(x_i)), y_i) = \sum_{i=1}^{l+u} R_{ii}(-f(g(x_i)))^2 \quad (18)$$

$R \in R^{(l+u) \times (l+u)}$ یک ماتریس قطری است که عناصر روی قطر اصلی R_{ii} برابر یک است اگر x_i یک نمونه از دامنه منبع بوده و در غیراین صورت صفر است.

براساس فرضیات منیفلد، اگر دو داده از لحاظ ساختار هندسی در توزیع حاشیه‌ای نزدیک به هم باشند، توزیع شرطی دو نمونه نیز اختلاف کمی با یکدیگر خواهند داشت. به منظور بدست آوردن فاصله بین داده‌ها، از گراف نزدیک‌ترین همسایه که دارای $l+u$ راس است برای محاسبه فاصله بین نمونه‌ها استفاده می‌شود. برای محاسبه وزن بین هر دو نمونه از یک ماتریس A که به شکل رابطه زیر تعریف می‌شود استفاده شده است.

$$A_{ij} = e^{-\frac{\|x_i - x_j\|^2}{\sigma}} \quad (19)$$

تابع M_f سازگاری بین طبقه‌بند f و توزیع هندسی دامنه‌های منبع و هدف را حداکثر می‌سازد و به شکل رابطه (۲۰) تعریف می‌شود.

$$M_{f,k}(P_s, P_t) = \sum_{i,j=1}^{l+u} ((f(x_i) - f(x_j))^2) A_{ij} \\ = \sum_{i,j=1}^{l+u} f(x_i) \bar{L}_{ij} f(x_j) f(x_j) \quad (20)$$

که $\bar{L} = I - D^{-\frac{1}{2}} A D^{-\frac{1}{2}}$ ماتریس لاپلاسین نرمال شده است. این ماتریس، طبقه‌بند را براساس ساختار عمومی داده‌های دامنه منبع ایجاد می‌کند که با ساختار داده‌های دامنه هدف سازگار باشد. با استفاده از کرنل می‌توان رابطه (۱۸) را با ترفندهای کرنل حل کرد. تابع پیش‌بینی f به صورت $f(g(x_i)) = \varphi^T \varphi(g(x_i))$ تعریف می‌شود که A پارامترهای طبقه‌بند و φ تابع نگاشت است.

با تعریف کرنل به صورت $k(g(x_i), g(x_j)) = \varphi(g(x_i))^T \varphi(g(x_j))$ و با استفاده از تئوری رپرنتر^۹، تابع پیش‌بینی به شکل رابطه زیر تعریف می‌شود.

$$f(g(x)) = \sum_{i=1}^{l+u} \alpha_i k(g(x_i), g(x)) \quad (21)$$

$$W_{k+1} = W_k - \eta(k) \left(\frac{\partial F(W)}{\partial W} + \lambda \sum_{i=1}^{l+u} \frac{\partial D_W(P_s \| P_t)}{\partial \bar{y}_i} \frac{\partial \bar{y}_i}{\partial W} \right) \quad (14)$$

بدین ترتیب با در نظر گرفتن رابطه (۱۱) مشتق $F(W)$ برحسب W برابر است با

$$\frac{\partial F(W)}{\partial W} = 2tr^{-1}(W^T S_B W) S_W W - 2tr^{-2}(W^T S_B W) tr(W^T S_W W) S_B W \quad (15)$$

با توجه به رابطه (۷) مشتق $D_W(P_s \| P_t)$ را برحسب W می‌توان به صورت زیر نوشت:

$$\sum_{i=1}^{l+u} \frac{\partial D_W(P_s \| P_t)}{\partial \bar{y}_i} \frac{\partial \bar{y}_i}{\partial W} \\ = \sum_{i=1}^l \frac{D_W(P_s \| P_t)}{\partial \bar{y}_i} \bar{x}_i^T + \sum_{i=l+1}^{l+u} \frac{D_W(P_s \| P_t)}{\partial \bar{y}_i} \bar{x}_i^T \quad (16)$$

پس براساس روابط (۱۲) و (۱۶) می‌توانیم الگوریتم‌های یادگیری زیرفضا را توسعه داده به‌طوری‌که مسأله شیف‌ت دامنه‌ها را دربرگیرند، همچنین عملکرد خوبی بر روی دامنه‌های مختلف داشته باشند.

۳-۲- یادگیری یک طبقه‌بند انطباقی بین دامنه‌های منبع و

هدف

ایجاد یک طبقه‌بند انطباقی، با هدف بدست آوردن حداقل خطای طبقه‌بندی روی دامنه‌ی منبع و حداکثر انطباق بین تابع پیش‌بینی و منیفلد توزیع حاشیه‌ای داده‌های منبع و هدف انجام می‌گیرد. طبقه‌بند انطباقی با استفاده هم‌زمان از داده‌های برچسب‌دار دامنه منبع و داده‌های بدون برچسب دامنه هدف باعث تطبیق بهتر طبقه‌بند برای اختلاف بین دامنه‌های منبع و هدف می‌شود. بدین ترتیب، BDAC ابتدا یک طبقه‌بند استاندارد f روی دامنه منبع برای پیش‌بینی داده‌های بدون برچسب دامنه هدف ایجاد می‌کند. در واقع f تابع پیش‌بینی داده‌های بدون برچسب دامنه هدف است که باید دارای حداقل خطای پیش‌بینی در دامنه منبع باشد. اگر $g(x)$ تابع نگاشت به نمایش جدید با بردار خصوصیت x باشد؛ مسأله بهینه‌سازی برای یافتن تابع پیش‌بینی می‌تواند به صورت زیر تعریف شود.

$$\min_{f \in H_k} \sum_{i=1}^l l(g(x_i), y_i) + \sigma f_k^2 + \gamma M_f(P_s, P_t) \quad (17)$$

که H_k ، یک مجموعه از طبقه‌بندها، f^2 نرم مربع f در H_k ، σ و γ پارامترهای نسبت و M_f محاسبه‌کننده تابع عدم سازگاری

آزمایش‌های طراحی شده، یکی از مجموعه‌داده‌ها به عنوان دامنه منبع و یکی دیگر از مجموعه‌داده‌ها به عنوان دامنه هدف انتخاب می‌شود. بدین ترتیب ۱۲ آزمایش بر روی پایگاه‌داده‌های آفیس و کالتک طراحی می‌شود.

پایگاه‌داده اعداد شامل دو دامنه USPS و MNIST است، این مجموعه‌داده شامل اعداد دست‌نویس ۰ تا ۹ می‌باشد. دامنه USPS، شامل حدود ۹۰۰۰ تصویر با اندازه ۱۶×۱۶ پیکسلی است که ۷۲۶۱ داده آموزشی و ۲۰۰۷ داده تست دارد. دامنه MNIST، شامل ۷۰۰۰۰ تصویر با اندازه ۲۸×۲۸ پیکسلی است که ۶۰۰۰۰ داده آموزشی و ۱۰۰۰۰ داده تست دارد. این مجموعه‌داده شامل ۱۰ کلاس مختلف است و به منظور آزمایش هر دو دامنه در شرایط یکسان، دامنه USPS_vs_MNIST(U_M) ایجاد شده است که به‌طور تصادفی ۱۸۰۰ نمونه از داده‌های دامنه USPS به عنوان داده‌های آموزشی ۲۰۰۰ نمونه از داده‌های دامنه MNIST به عنوان داده‌های تست به کار گرفته می‌شود. با جابجایی نمونه‌های آموزشی و تست USPS_vs_MNIST برای آزمایش دیگر ایجاد می‌شود.

مجموعه داده پای، از مجموعه پایگاه‌داده‌های شناخته شده برای مساله تطبیق دامنه‌های بصری در زمینه تشخیص چهره است که شامل ۴۱۳۶۸ تصویر چهره از ۶۸ فرد مختلف با اندازه ۳۲×۳۲ است. پنج دامنه در این پایگاه داده وجود دارد که هرکدام مربوط به یک حالت تصویر برداری است: پای ۱ (حالت چپ (P1)، پای ۲ (حالت بالا) (P2)، پای ۳ (حالت پایین) (P3)، پای ۴ (حالت روبرو) (P4)، پای ۵ (حالت راست) (P5). در مجموع ۲۰ آزمایش بین دامنه‌ای بر روی پایگاه‌داده پای قابل طراحی است که از بین ۵ دامنه، دو دامنه مختلف به عنوان دامنه‌های منبع و هدف انتخاب می‌شوند.

۴-۲- ارزیابی الگوریتم‌ها

روش پیشنهادی BDAC با روش‌های زیر مورد مقایسه قرار می‌گیرد: طبقه‌بند نزدیک‌ترین همسایه (NN)، تمامی این الگوریتم‌های نامبرده شده جزء روش‌های کاهش بعد هستند که با استفاده از طبقه‌بند استاندارد NN روی داده‌های دامنه منبع برای پیش‌بینی برچسب داده‌های دامنه هدف مورد آزمایش قرار می‌گیرند. طبقه‌بند NN، در ابتدا فاصله اقلیدسی بین هر نمونه از دامنه هدف را نسبت به نمونه‌های دامنه منبع را محاسبه کرده سپس با توجه به درجه همسایگی، برچسب نزدیک‌ترین نمونه از دامنه منبع را به عنوان برچسب هر نمونه از دامنه هدف اختصاص می‌دهد.

در پایان تابع هدف طبقه‌بند انطباقی رابطه (۱۷) به شکل رابطه (۲۲) بازنویسی می‌شود.

$$\operatorname{argmin}_{\alpha \in R^l} (Y + \alpha^T) + \operatorname{argmin}_{\alpha \in R^{l+u}} \operatorname{tr}(Y\alpha^T K \bar{L} K \alpha + \sigma \alpha^T K \alpha) \quad (22)$$

بعد از مشتق‌گیری از رابطه (۲۲) پارامتر طبقه‌بندی α برابر است با:

$$\alpha = (\sigma I + (R + \gamma \bar{L})K)^{-1} R Y^T \quad (23)$$

استفاده از معادله بالا می‌توان پارامترهای طبقه‌بندی را محاسبه کرده و براساس تابع پیش‌بینی (رابطه ۲۱) برچسب‌های نمونه‌های دامنه هدف را بدست آورد. هدف BDAC بدست آوردن هم‌زمان ماتریس نگاشت و حداقل سازی تابع هدف است که در نهایت منجر به پیش‌بینی دقیق‌تر برچسب‌های داده‌های دامنه هدف می‌شود.

۴- تنظیمات اولیه محیط آزمایش

در این بخش، آزمایش‌های انجام گرفته برای ارزیابی و مقایسه روش پیشنهادی با دیگر الگوریتم‌های یادگیری انتقالی موجود به تفصیل بیان می‌شود.

۴-۱- معرفی مجموعه داده‌ها

جهت ارزیابی نتایج روش پیشنهادی BDAC از سه پایگاه‌داده دنیای واقعی که به‌طور گسترده برای ارزیابی الگوریتم‌های تطبیق دامنه بصری استفاده می‌شوند، بهره می‌بریم: (۱) پایگاه‌داده اشیاء [۹،۱۰] (آفیس^۴ و کالتک^۳)، (۲) پایگاه‌داده اعداد [۱۱،۱۲] (USPS و MNIST) و (۳) پایگاه‌داده چهره [۱۳] (پای^۳).

پایگاه‌داده آفیس، شامل مجموعه تصاویر از اشیای متفاوت است که از سه دامنه آمازون (A)، وبکم (W) و DSLR (D) جمع‌آوری شده است و تصاویر از نظر کیفیت، روشنایی، رنگ و نوع زمینه با هم متفاوت هستند. دامنه آمازون، شامل تصاویر اشیای دانه‌دانه از سایت‌های تجاری است. زمینه این تصاویر سفید بوده و اشیاء در مرکز آن‌ها قرار دارند و در شرایط نورپردازی استودیو تصویربرداری شده‌اند. دامنه وبکم، شامل تصاویر اشیاء با کیفیت پایین است که با دوربین وب گرفته شده و دامنه DSLR، شامل تصاویر اشیاء با کیفیت بالا است که با دوربین‌های دیجیتالی گرفته شده‌اند. مجموعه داده کالتک شامل ۳۰۶۰۷ تصویر و ۲۵۶ کلاس می‌باشد که تصاویر این دامنه از وب سایت گوگل جمع‌آوری شده است. با این حال، در آزمایش‌هایی که ما طراحی کرده‌ایم از ۱۰ کلاس مشترک بین پایگاه‌داده‌های آفیس و کالتک استفاده می‌شود. در هر یک از

۴-۳- مفروضات پیاده‌سازی

الگوریتم پیشنهادی شامل چهار پارامتر زیر است که مقادیر بهینه آن‌ها در ادامه آورده شده است: (۱) λ پارامتر تنظیم در رابطه (۱۰)، (۲) η نرخ یادگیری در رابطه (۱۱)، (۳) γ پارامتر نسبت در طبقه‌بند انطباقی، (۴) σ پارامتر تنظیم در طبقه‌بند انطباقی. الگوریتم پیشنهادی BDAC با پارامترهای بیان شده بر روی ۳۴ مجموعه داده مورد آزمایش قرار گرفته است.

۵- نتایج و بحث‌ها

در این بخش، عملکرد روش BDAC و الگوریتم‌های شناخته شده در حوزه یادگیری انتقالی مورد مقایسه و ارزیابی قرار می‌گیرد.

۵-۱- ارزیابی نتایج

جداول ۱ تا ۳، نشان دهنده نتایج بدست آمده از روش BDAC و الگوریتم‌های مورد مقایسه به ترتیب NN، TSL [۱۹]، JDA [۲۰]، LRSR [۲۱]، CDDA [۱۶] و VDA [۱۵] بر روی پایگاه‌داده آفیس و کالتک، پایگاه‌داده اعداد و پایگاه داده پای

است. همان‌طور که مشاهده می‌شود در تمام پایگاه‌داده‌ها BDAC کارایی بهتری نسبت به شش روش دیگر دارد. در پایگاه داده آفیس و کالتک، BDAC دارای ۳/۶۸٪ میانگین بهبود دقت نسبت به بهترین الگوریتم مورد مقایسه (یعنی VDA) و دارای ۳۸/۸۷٪ میانگین بهبود دقت نسبت به الگوریتم استاندارد NN است. در پایگاه داده اعداد، BDAC دارای بهبود عملکرد ۱/۷۴٪ نسبت به بهترین الگوریتم مورد مقایسه (یعنی VDA) و ۱۵/۲۶٪ نسبت به الگوریتم استاندارد NN می‌باشد. در پایگاه داده پای، میانگین بهبود دقت BDAC، ۲/۶۳٪ نسبت به بهترین الگوریتم مورد مقایسه (یعنی VDA) و ۳۸/۸۷٪ نسبت به الگوریتم استاندارد NN است. مهم‌ترین دلیل برتری BDAC نسبت به روش‌های دیگر، استفاده از اطلاعات اولیه دامنه منبع است، که به صورت حداکثری به دامنه هدف انتقال می‌یابد. ضمناً BDAC اطلاعات خاص داده‌ها (به عنوان مثال ساختار منیفلد داده‌ها) را حفظ کرده و از یک طبقه‌بند انطباقی برای کاهش خطای پیش‌بینی مدل بر روی داده‌ها استفاده می‌کند. در ادامه به تفصیل گزارش مقایسه BDAC با دیگر روش‌های مورد مقایسه ارائه شده است.

جدول ۱: دقت (%) طبقه‌بند در مجموعه‌داده آفیس و کالتک (FLDA_m تطبیق توزیع حاشیه‌ای روش پیشنهادی بدون تطبیق مدل، BDAC linear روش پیشنهادی با طبقه‌بند خطی، BDAC روش پیشنهادی با طبقه‌بند NN)

BDAC	BDAC linear	FLDA _m	VDA	CDDA	LRSR	JDA	TSL	FLDA	NN	Dataset
۴۳/۷۸	۵۳/۴۸	۵۲/۳	۴۶/۱۴	۴۸/۳۳	۵۱/۲۵	۴۴/۷۸	۴۴/۲	۴۰/۲۲	۲۳/۷	C-A
۵۳/۶۹	۴۸/۹۳	۴۱/۸	۴۶/۱	۴۴/۷۵	۳۸/۶۴	۴۱/۶۹	۴۵/۸	۴۰/۱۱	۲۵/۷۶	C-W
۵۵/۲۲	۴۶/۹۷	۳۸/۸۶	۵۱/۵۹	۴۸/۴۱	۴۷/۱۳	۴۵/۲۲	۶۰/۸	۳۹/۹۹	۲۵/۴۸	C-D
۴۵/۳۶	۴۲/۹۶	۴۱/۸۵	۴۲/۲۱	۴۲/۱۲	۴۳/۳۷	۳۹/۳۶	۳۶/۷	۴۱/۲۶	۲۶	A-C
۴۷/۹۷	۴۰/۵۲	۳۱/۳۹	۵۱/۱۹	۴۱/۶۹	۳۶/۶۱	۳۷/۹۷	۴۷/۱	۴۱/۶۵	۲۹/۸۳	A-W
۴۱/۴۹	۴۵/۹۶	۴۰/۹۵	۴۸/۴۱	۳۷/۵۸	۳۸/۸۵	۳۹/۴۹	۵۴/۹	۴۰/۸۹	۲۵/۴۸	A-D
۴۲/۷۸	۳۴/۴۷	۳۳/۳۹	۲۷/۶	۳۱/۹۷	۲۹/۸۳	۳۱/۱۷	۶۹/۵	۴۰	۱۹/۸۶	W-C
۷۹/۱۷	۳۹/۷۹	۳۷/۶۸	۲۶/۱	۳۷/۲۷	۳۴/۱۳	۳۲/۷۸	۳۵/۸	۴۲/۹۰	۲۲/۹۶	W-A
۴۱/۵۲	۷۰/۵۶	۶۰/۴۳	۸۹/۱۸	۸۷/۹	۸۲/۸۰	۸۹/۱۷	۳۶/۴	۴۱/۵۲	۵۹/۲۴	W-D
۴۳/۷۹	۳۴/۱۵	۳۳/۰۴	۳۱/۲۶	۳۴/۶۴	۳۱/۶۱	۳۱/۵۲	۴۱/۳	۴۳/۲۱	۲۶/۲۷	D-C
۸۴/۴۹	۳۷/۴۴	۳۲/۴۳	۳۷/۶۸	۳۳/۵۱	۳۳/۱۹	۳۳/۰۹	۵۷/۵	۴۲/۵۶	۲۸/۵	D-A
۵۳/۳۱	۷۹/۹۶	۶۹/۹۷	۹۰/۸۵	۹۰/۵۱	۷۷/۲۹	۸۹/۴۹	۳۶/۳	۴۲/۹۱	۶۳/۳۹	D-W
۵۲/۷۱	۵۱/۹۸	۴۲/۸۴	۴۹/۰۳	۴۷/۲۲	۴۵/۳۹	۴۶/۳۱	۴۷/۴۴	۴۱/۳۸	۳۱/۳۷	میانگین

جدول ۲. دقت (%) طبقه‌بند در مجموعه داده اعداد (FLDA_m) تطبیق توزیع حاشیه‌ای روش پیشنهادی بدون تطبیق مدل، BDAC linear روش

پیشنهادی با طبقه‌بند SVM با کرنل خطی، BDAC روش پیشنهادی با طبقه‌بند (NN)

BDAC	BDAC linear	FLDA _m	VDA	CDDA	LRSR	JDA	TSL	FLDA	NN	Dataset
۶۷/۱۱	۶۳/۴	۶۰/۵۴	۶۲/۹۵	۶۲/۰۵	۵۴/۵۱	۵۹/۶۵	۵۲/۶۵	۵۱/۷۳	۴۴/۷	U-M
۷۴/۰۵	۷۱/۵۶	۷۳/۲۱	۷۴/۷۲	۷۶/۲۲	۷۳/۸۲	۶۷/۲۸	۶۱/۸۳	۶۴/۸۹	۶۵/۹۴	M-U
۷۰/۵۸	۶۹/۴۶	۶۶/۸۷	۶۸/۸۴	۶۹/۱۳	۶۴/۱۶	۶۳/۴۷	۵۷/۲۴	۵۸/۳۱	۵۵/۳۲	میانگین

جدول ۳: دقت (%) طبقه‌بند در مجموعه داده پای (FLDA_m) تطبیق توزیع حاشیه‌ای روش پیشنهادی بدون تطبیق مدل، BDAC linear روش پیشنهادی

با طبقه‌بند SVM با کرنل خطی، BDAC روش پیشنهادی با طبقه‌بند (NN)

BDAC	BDAC linear	FLDA _m	VDA	CDDA	LRSR	JDA	TSL	FLDA	NN	Dataset
۶۹/۵۱	۷۰/۴۴	۳۷/۶۳	۷۳/۴۸	۶۰/۲۲	۶۵/۸۷	۵۸/۸۱	۴۴/۲	۳۳/۸۹	۲۶/۰۹	P1_P2
۶۱/۸۱	۶۱/۶۸	۴۷/۵۵	۶۲/۹۲	۵۸/۷	۶۴/۰۹	۵۴/۲۳	۴۵/۸	۲۳/۵۶	۲۶/۵۹	P1_P3
۴۶/۳۲	۴۷/۹۶	۶۹/۱۸	۹۰/۵۱	۸۳/۴۸	۸۲/۰۳	۸۴/۵	۶۰/۸	۳۲/۹۳	۳۰/۶۷	P1_P4
۶۱/۲	۶۲/۵۹	۳۶/۰۹	۵۷/۲۹	۵۴/۱۷	۵۴/۹۰	۴۹/۷۵	۳۶/۷	۳۸/۷۹	۱۶/۶۷	P1_P5
۷۶/۱۶	۷۵/۹۹	۳۸/۶	۷۰/۰۲	۶۲/۳۳	۴۵/۵۴	۵۷/۶۲	۴۷/۱	۳۵/۲۹	۲۴/۴۹	P2_P1
۶۸/۵۶	۶۹/۱۵	۴۴/۹۱	۷۳/۰۴	۶۴/۶۴	۵۳/۴۹	۶۲/۹۳	۵۴/۹	۳۴/۷۸	۴۶/۶۳	P2_P3
۸۲/۲	۸۲/۹	۶۹/۸۴	۸۴/۲۹	۷۹/۹	۷۱/۴۳	۷۵/۸۲	۶۹/۵	۳۵/۱۷	۵۴/۰۷	P2_P4
۶۴/۴۶	۶۵/۲۲	۳۴/۰۱	۵۴/۶۶	۴۴	۴۷/۹۷	۳۹/۸۹	۳۵/۸	۳۲/۴۱	۲۶/۵۳	P2_P5
۷۴/۵۸	۷۴/۷۸	۴۴/۴۸	۶۷/۳۵	۵۸/۴۶	۵۲/۴۹	۵۰/۹۶	۳۶/۴	۳۷/۳۶	۲۱/۳۷	P3_P1
۷۲/۹	۷۳/۰۲	۴۰/۷	۷۰/۴۱	۵۹/۷۳	۵۵/۵۶	۵۷/۹۵	۴۴/۳	۳۷/۰۳	۴۱/۰۱	P3_P2
۸۱/۱۹	۸۱/۶۹	۶۹/۴۲	۸۴/۴۷	۷۷/۲	۷۷/۵۰	۶۸/۴۵	۵۷/۵	۳۸/۴۵	۴۶/۵۳	P3_P4
۷۷/۱۸	۷۷/۶۸	۴۶/۸۱	۵۲/۳۹	۴۷/۲۴	۵۴/۱۱	۳۹/۹۵	۳۶/۳	۳۲/۵۹	۲۶/۲۳	P3_P5
۸۹/۴	۸۹/۳۳	۷۲/۰۹	۹۱/۶	۸۳/۱	۸۱/۵۴	۸۰/۵۸	۶۲/۶	۳۴/۵۳	۳۲/۹۵	P4_P1
۸۳/۰۱	۸۴/۵۵	۶۵/۵۶	۹۱/۴۷	۸۲/۲۶	۵۸/۳۹	۸۲/۶۳	۶۸/۱	۳۵/۲۱	۶۲/۶۸	P4_P2
۷۸/۵۷	۷۷/۸۷	۷۲/۷۹	۹۰/۹۳	۸۶/۶۴	۸۲/۲۳	۸۷/۲۵	۷۹/۸	۳۴/۹۶	۷۳/۲۲	P4_P3
۶۵/۱۷	۶۷/۳۶	۵۹/۲۵	۶۳/۳۶	۵۸/۳۳	۷۲/۶۱	۵۴/۶۶	۴۳/۹	۳۴/۸۰	۳۷/۱۹	P4_P5
۶۲/۵۸	۶۳	۳۹/۸۳	۵۵/۷	۴۸/۰۲	۵۲/۱۹	۴۶/۴۶	۳۲/۷	۳۱/۸۱	۱۸/۴۹	P5_P1
۷۱/۳	۷۱/۸	۳۴/۶۲	۶۱/۵۷	۴۵/۶۱	۴۹/۴۱	۴۲/۰۵	۳۱/۴	۲۹/۲۸	۲۴/۱	P5_P2
۶۸/۱۸	۶۹/۷۱	۵۰/۶۷	۵۵/۵۸	۵۲/۰۲	۵۸/۴۵	۵۳/۳۱	۳۳/۹	۳۴/۰۶	۲۸/۳۱	P5_P3
۷۸/۳۴	۷۹/۲۳	۶۲/۰۶	۶۸/۸۲	۵۵/۹۹	۶۴/۳۱	۵۷/۰۱	۳۸/۲	۲۹/۱۲	۳۱/۲۴	P5_P4
۷۳/۶۳	۷۲/۶۴	۵۱/۸۱	۷۰/۹۹	۶۳/۱	۶۳/۵۳	۶۰/۲۴	۴۷/۹۹	۳۴/۳۰	۳۴/۷۶	میانگین

روش‌های VDA و JDA از جمله روش‌های شناخته شده در حوزه یادگیری انتقالی بدون نظارت هستند که با ایجاد یک نمایش کم بعد از دامنه‌های منبع و هدف، به طور هم‌زمان اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها را کاهش می‌دهند. علاوه بر این روش VDA از یک خوشه‌بندی مستقل از دامنه برای بهبود دقت طبقه‌بند استفاده می‌کند. میانگین دقت روش BDAC نسبت به روش‌های VDA و JDA در مجموعه داده آفیس و کالتک به ترتیب ۳/۶۸٪ و ۶/۴٪ در مجموعه داده اعداد ۱/۷۴٪ و ۷/۱۱٪، در مجموعه داده پای ۲/۶۳٪ و ۱۲/۳۹٪


TSL، مجموعه‌ای از روش‌های کاهش بعد است که نمی‌تواند اختلاف توزیع بین دامنه‌های منبع و هدف را به طور قابل ملاحظه‌ای کاهش دهد، به همین دلیل عملکرد ضعیفی نسبت به دیگر الگوریتم‌های شناخته شده در حوزه تطبیق دامنه دارد. مهم‌ترین علت برتری BDAC نسبت به TSL استفاده از تطبیق خصوصیات برای کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف است. میانگین بهبود دقت BDAC نسبت به TSL در مجموعه داده آفیس ۵/۲۲٪، در مجموعه داده اعداد ۱۳/۳۴٪ و در مجموعه داده پای ۲۵/۶۴٪ است.

همگرایی بسیار کاهش می‌یابد، در حالی که اگر $\eta(k)$ مقدار بالایی داشته باشد فرآیند همگرایی دچار جهش شده و از محدوده مورد انتظار فراتر می‌رود و الگوریتم در تعداد تکرار معقول همگرا نمی‌شود. در این چارچوب پیشنهادی به‌طور تجربی $\eta(k) = \eta(0)/k$ در نظر گرفته شده که نرخ یادگیری با افزایش تعداد تکرار کاهش یابد. جهت محاسبه مقدار بهینه از ۳۰ تکرار برای بدست آوردن نتایج الگوریتم استفاده شده‌است. λ پارامتر تنظیم بین واگرایی برگمن (D_W) و تابع هدف ($F(W)$) است و در محدوده $[0.1, 0.00001]$ بررسی می‌شود. پارامترهای σ و γ که پارامترهای تنظیم در طبقه‌بند انطباقی هستند، در محدوده $[0.1, 0.00001]$ در نظر گرفته شده‌اند. مقدار بهینه پارامترها برای مجموعه داده‌های مختلف در جدول ۴ نشان داده شده است.

جدول ۴: مقدار بهینه پارامترها برای ۳ مجموعه داده بصری.

پارامتر	آفیس و کالتک	اعداد	پای
$\eta(k)$	۲۰	۲۰	۳۰
λ	۱۰	۱	۱۰
γ	۰/۵	۰/۰۰۰۵	۰/۰۰۰۵
σ	۰/۱	۰/۰۰۰۱	۰/۰۰۰۰۵

شکل‌های ۳ و ۴، به ترتیب نشان دهنده نتایج بدست آمده برای مقادیر مختلف γ و σ در پایگاه داده‌های U-M و M-U می‌باشند.



شکل ۳: ارزیابی دقت پایگاه داده‌های U-M و M-U با مقادیر مختلف γ بر اساس نتایج نشان داده شده در شکل ۳ پایگاه داده اعداد دقت پایینی در مقادیر پایین پارامتر γ دارد. مقدار پایین پارامتر γ باعث عدم استفاده از اطلاعات داده‌های بدون برچسب دامنه هدف در ایجاد طبقه‌بند انطباقی می‌شود.

است. دلیل برتری BDAC نسبت به VDA و JDA این است که BDAC علاوه بر اینکه ساختار داده‌ها را حفظ می‌کند اطلاعات تفکیک کننده اولیه داده‌های ورودی را نیز در نظر می‌گیرد و همچنین از یک طبقه بند انطباقی برای کاهش خطای پیش‌بینی مدل بر روی داده‌ها استفاده می‌کند.

CDDA از جمله روش‌های شناخته شده در حوزه یادگیری انتقالی بدون نظارت است که با ایجاد یک نمایش کم بعد از دامنه‌های منبع و هدف، به‌طور هم‌زمان اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها را کاهش می‌دهند. به دلیل خصوصیات متفاوت داده‌های آموزشی و تست در دامنه‌های منبع و هدف، طبقه‌بند ایجاد شده در نمایش جدید توسط روش CDDA نمی‌تواند با صحت بالایی برچسب داده‌های دامنه هدف را پیش‌بینی کند. دلیل برتری BDAC نسبت به CDDA این است که BDAC علاوه بر این که ساختار داده‌ها را حفظ می‌کند اطلاعات تفکیک کننده اولیه داده‌های ورودی را نیز در نظر می‌گیرد که این باعث کاهش اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها می‌شود. روش BDAC به تفکیک نسبت به روش CDDA دارای متوسط بهبود دقت ۴/۴۹٪ در پایگاه داده آفیس و کالتک، ۱/۴۵٪ در پایگاه داده اعداد، و ۱۰/۵۳٪ در پایگاه داده پای است.

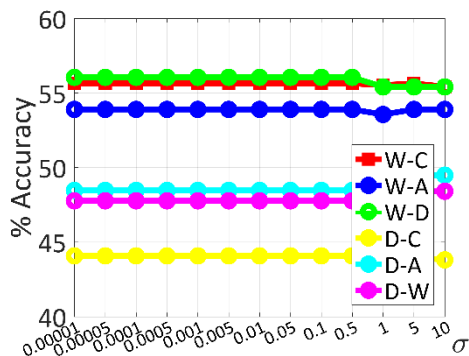
روش LRSR، با استفاده از یک ماتریس انتقال، نمونه‌های دامنه منبع و دامنه هدف را به یک زیرفضای مشترک نگاشت می‌کند که در آن هر نمونه دامنه هدف می‌تواند به‌طور خطی توسط داده‌های دامنه منبع بازسازی شود. به این ترتیب، اختلاف دامنه‌های منبع و هدف کاهش می‌یابد و با اعمال توأم محدودیت‌های تنک و سطح پایین روی ماتریس نگاشت ساختار کلی و محلی داده‌ها حفظ می‌شود. مهم‌ترین دلیل برتری روش پیشنهادی نسبت به روش LRSR، کاهش اختلاف توزیع شرطی بین دامنه‌ها و انتقال حداکثری اطلاعات تفکیک کننده نمونه‌های دامنه منبع برای تفکیک پذیری بهتر کلاس‌های مختلف است. میانگین بهبود دقت BDAC نسبت به LRSR در مجموعه داده آفیس ۷/۳۲٪، در مجموعه داده اعداد ۶/۴۲٪ و در مجموعه داده پای ۱۰/۱٪ می‌باشد.

۵-۲- ارزیابی پارامتر


روش پیشنهادی BDAC دارای چهار پارامتر مختلف بوده و در این بخش با مقادیر مختلف، پارامترها مورد ارزیابی قرار می‌گیرد. در روش‌های یادگیری ماشین، یک اصل مهم در پروسه بهینه‌سازی انتخاب نرخ یادگیری مناسب است ($\eta(k)$ در رابطه (۱۲)). اگر مقدار پایینی برای $\eta(k)$ انتخاب شود سرعت

نتایج بدست آمده بر روی پایگاه داده آفیس و کالتک در مقادیر مختلف γ در شکل‌های ۵ و ۶ نشان می‌دهد که مقادیر بالای این پارامتر باعث کاهش دقت مدل می‌شود. مقادیر بالای پارامتر γ باعث نادیده گرفتن اطلاعات داده‌های برچسب دار دامنه منبع در ایجاد طبقه‌بند انطباقی می‌شود.

شکل‌های ۷ و ۸ به ترتیب نشان دهنده نتایج بدست آمده برای مقادیر مختلف σ در پایگاه داده‌های W-D, W-A, W-C, D-W, D-A, D-C و در پایگاه داده‌های C-A, C-W, C-D, A-D و A-W هستند.




شکل ۷: ارزیابی دقت پایگاه داده آفیس و کالتک با مقادیر مختلف σ . دقت مدل در مقادیر بالای پارامتر σ کاهش می‌یابد به دلیل اینکه از ساختار اصلی داده‌ها، در ایجاد تطبیق بین دامنه‌های منبع و هدف استفاده نمی‌شود.




شکل ۸: ارزیابی دقت پایگاه داده آفیس و کالتک با مقادیر مختلف σ . نتایج بدست آمده بر روی پایگاه داده آفیس و کالتک در مقادیر مختلف σ در شکل‌های ۷ و ۸ نشان می‌دهد که مقادیر بالای σ پیچیدگی مدل را افزایش داده و باعث می‌شود تأثیر سایر عوامل در ایجاد طبقه‌بند انطباقی نادیده گرفته شود و در نهایت دقت مدل کاهش یابد.

نتایج بدست آمده از آزمایش‌های انجام گرفته (که به علت محدودیت صفحات تنها نتایج چهار پایگاه داده گزارش شده است) برای مقادیر مختلف γ و σ در پایگاه داده پای به ترتیب در شکل ۹ و ۱۰ نشان می‌دهد که پایگاه داده پای نسبت به هر دو




شکل ۴: ارزیابی دقت پایگاه داده‌های U-M و M-U با مقادیر مختلف σ . همچنین نتایج بدست آمده برای مقادیر مختلف پارامتر σ در پایگاه داده اعداد در شکل ۴ نشان می‌دهد دو پایگاه داده U-M و M-U رفتار متفاوتی در مورد مقادیر مختلف پارامتر σ دارند. U دارای حساسیت کمتری نسبت به مقادیر مختلف پارامتر σ است، همان‌طور که در شکل ۴ نشان داده شده است. در حالی که U-M در مقادیر بالای پارامتر σ دقت پایینی در بازسازی داده‌ها در فضای جدید دارد.

شکل‌های ۵ و ۶ به ترتیب نشان دهنده نتایج بدست آمده برای مقادیر مختلف γ در پایگاه داده‌های A-C, C-D, C-W, C-A, D-C, W-D, W-A, W-C, A-D و A-W هستند. D-W و D-A



شکل ۵: ارزیابی دقت پایگاه داده آفیس و کالتک با مقادیر مختلف γ . براساس نتایج بدست آمده مقادیر پایین پارامتر γ باعث عدم بهره‌گیری از اطلاعات داده‌های بدون برچسب دامنه هدف در ایجاد طبقه‌بند انطباقی می‌شود و دقت مدل کاهش می‌یابد.



شکل ۶: ارزیابی دقت پایگاه داده آفیس و کالتک با مقادیر مختلف γ

شکل ۱۱ نشان می‌دهد که افزایش تعداد همسایگی در الگوریتم NN تاثیر قابل ملاحظه‌ای در افزایش دقت الگوریتم پی‌شنهادی ندارد.


۳-۵- تحلیل زمان اجرا

در این بخش، پیچیدگی زمانی روش پیشنهادی BDAC بررسی می‌شود. تحدد تابع هدف که در رابطه (۱۲) تعریف می‌شود، به $F(W)$ و $D(W)$ وابسته است. تحدد $F(W)$ وابسته به یک الگوریتم خاص یادگیری زیرفضا مانند FLDA است. درحالی‌که تحدد $D(W)$ به مدل توزیع مجموعه نمونه‌های آموزشی و آزمایشی بستگی دارد. اگر N تعداد کل نمونه‌ها و D واگرایی برگمن که اختلاف توزیع بین دامنه‌های منبع و هدف را محاسبه می‌کند، باشند رابطه (۱۴) دارای پیچیدگی زمانی $O((D+N)^2)$ است. همچنین محاسبه پارامترهای طبقه‌بند در رابطه (۱۷) دارای پیچیدگی زمانی $O(N)$ است. پس بطور کلی پیچیدگی BDAC برابر با $O((D+N)^2)$ است.

۴-۵- بررسی ضرورت کاهش اختلاف توزیع حاشیه‌ای


در روش پیشنهادی BDAC برای کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف از روش غیر پارامتری واگرایی برگمن استفاده شده است. واگرایی برگمن قادر است اطلاعات به‌دست‌آمده از نمونه‌های دامنه منبع را، با به‌کمینه‌رساندن اختلاف توزیع حاشیه‌ای بین دامنه‌ها به نمونه‌های دامنه هدف منتقل کند که باعث تفکیک‌پذیری بهتر رده‌های مختلف در فضای جدید می‌شود. در صورتی که در تابع هدف (رابطه ۱۲) پارامتر λ را برابر صفر در نظر بگیریم (طبق نتایج گزارش شده در جداول (۱) الی (۳)، فیلد FLDA) دقت مدل به دلیل وجود اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف به شدت کاهش می‌یابد. در شرایطی که دامنه‌های منبع و هدف دارای مجموعه خصوصیات یکسان باشند، اختلاف در احتمال وقوع مقادیر هر کدام از این خصوصیات در هر دامنه، موجب ایجاد اختلاف توزیع حاشیه‌ای بین دامنه‌ها خواهد شد. روش‌های کاهش بُعد به‌تنهایی پاسخ‌گوی مسائل شیف‌ت دامنه‌ها نیستند و به دلیل نادیده‌گرفتن اطلاعات اولیه در مورد اختلاف توزیع بین نمونه‌های دامنه منبع و هدف، مدل روی نمونه‌های دامنه منبع دچار یادآموزی شده و عملکرد مدل به شدت کاهش می‌یابد. برای اجتناب از مشکل یادآموزی و بهبود عملکرد مدل یادگیری، ما اطلاعات اولیه را با استفاده از واگرایی برگمن در نظر می‌گیریم. به همین ترتیب براساس نتایج نشان داده شده در شکل ۱۲ نمودار FLDA به دلیل عدم بهره‌گیری از

پارامتر σ و γ حساسیت زیادی دارد و در محدوده بالا دقت مدل کاهش قابل توجهی پیدا می‌کند.



شکل ۹: ارزیابی دقت پایگاه داده پای با مقادیر مختلف γ

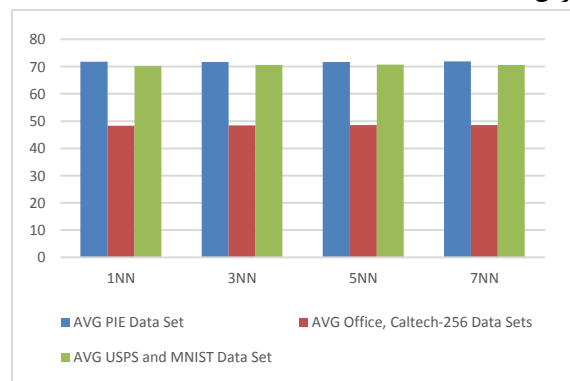
بر اساس نتایج بدست آمده محدوده بهینه برای پارامتر γ در تعداد بیشتری از پایگاه داده پای [۰/۰۰۰۵، ۰/۰۰۵] می‌باشد.



شکل ۱۰: ارزیابی دقت پایگاه داده پای با مقادیر مختلف σ

همچنین محدوده بهینه پایگاه داده پای برای پارامتر σ [۰/۰۵، ۰/۰۰۵] است. در این شرایط مدل طبقه‌بند بهترین عملکرد و بالاترین دقت پیش‌بینی را دارد.

الگوریتم پی‌شنهادی با تعداد هم‌سایگی های ۳، ۵ و ۷ مورد آزمایش قرار گرفته است که نتایج این آزمایش در شکل ۱۱ گزارش شده است.



شکل ۱۱: مقایسه دقت BDAC در تعداد همسایگی‌های متفاوت

شکل ۱۳: مقایسه دقت مدل پیشنهادی با توجه به کاهش اختلاف توزیع حاشیه‌ای و وزن دهی به نمونه‌ها


۶- نتیجه‌گیری و کارهای آتی

در این مقاله یک روش جدید یادگیری انتقالی بدون نظارت برای حل مسأله شیفت دامنه‌ها، با عنوان BDAC پیشنهاد می‌شود. BDAC یک چارچوب دومرحله‌ای با ترکیبی از روش‌های مبتنی بر خصوصیات و مبتنی بر مدل است. در مرحله اول، BDAC با استفاده از واگرایی برگمن یک زیر فضای جدید برای نمایش داده‌های دامنه منبع و هدف ایجاد می‌کند که اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف را کاهش می‌دهد. در واقع این روش با استفاده از اطلاعات تفکیک‌کننده اولیه داده‌های ورودی، مدلی را ایجاد می‌کند که مقاومت بیشتری در برابر اختلاف توزیع داده‌های منبع و هدف داشته باشد. در مرحله دوم، BDAC یک طبقه‌بند انطباقی با هدف افزایش مقاومت مدل در برابر تغییرات داده‌ها، بر روی نمونه‌های برچسب دار دامنه منبع و نمونه‌های بدون برچسب دامنه هدف در نمایش جدید ایجاد می‌کند. جهت ارزیابی، روش پیشنهادی BDAC بر روی ۳۴ مجموعه داده بصری که از اختلاف توزیع قابل توجهی نسبت به یکدیگر برخوردارند، مورد ارزیابی قرار گرفته است. نتایج بدست آمده حاکی از آن است که BDAC دارای بهبود عملکرد قابل ملاحظه‌ای نسبت به جدیدترین الگوریتم‌های تطبیق دامنه است. برای ادامه کار، در حال برنامه‌ریزی جهت گسترش BDAC برای کاهش هم زمان اختلاف توزیع حاشیه‌ای و شرطی هستیم.

مراجع

- [1] J. Li, Y. Wu, and K. Lu, "Structured domain adaptation," *IEEE Transactions on Circuits and Systems for Video Technology*, vol. 27, no. 8, pp. 1700–1713, 2017.
- [2] B. Gong, K. Grauman and F. Sha, "Connecting the dots with landmarks: discriminatively learning domain-invariant features for unsupervised domain adaptation", *Proceedings of the International Conference on Machine Learning*, vol. 28, no. 1, pp. 222-230, 2013.
- [3] H. Wang, H. Huang, F. Nie, and C. Ding, "Cross-language web page classification via dual knowledge transfer using nonnegative matrix tri-factorization," in *Proceedings of the 34th international ACM SIGIR conference on Research and development in Information Retrieval*, pp. 933–942, ACM, 2011.
- [4] H. Liu and L. Yu, "Toward integrating feature selection algorithms for classification and clustering," *IEEE Transactions on knowledge and data engineering*, vol. 17, no. 4, pp. 491502, 2005.
- [5] J. Tahmoresnezhad and S. Hashemi, "Diret: An effective discriminative dimensionality reduction approach for multi-source transfer learning," *Scientia Iranica. Transaction D, Computer Science & Engineering, Electrical*, vol. 24, no. 3, pp. 1303–1311, 2017.


اطلاعات تفکیک‌کننده اولیه داده‌های دامنه منبع و نادیده‌گرفتن اختلاف توزیع حاشیه‌ای بین دامنه‌ها، دقت پایینی در تمام پایگاه‌داده‌های مورد آزمایش دارد.



شکل ۱۲: مقایسه دقت مدل پیشنهادی با توجه به کاهش اختلاف توزیع حاشیه‌ای و روش FLDA

۵-۵- بررسی ضرورت تطبیق مدل

در بسیاری از موارد، تنها حداقل کردن اختلاف توزیع بین دامنه‌های منبع و هدف، برای ایجاد یک طبقه‌بند دارای دقت بالا در پیش‌بینی داده‌های بدون برچسب کافی نیست. در این شرایط، حتی با ایجاد تفکیک بین کلاس‌های دامنه منبع نیز، نمی‌توان یک طبقه‌بند تطبیق‌پذیر ایجاد کرد، زیرا ابعاد تفکیک‌کننده دامنه منبع و هدف نسبت به هم اختلاف قابل-توجهی دارند (جداول ۱ الی ۳ فیلد FLDA^m). به بیان دیگر، ابعاد تفکیک‌کننده ایجاد شده توسط طبقه‌بند در دامنه منبع، به دلیل عدم سازگاری ساختار داده‌های دامنه منبع و هدف، دارای خطای زیادی در ایجاد تفکیک در دامنه هدف می‌باشند. بدین ترتیب، در مرحله دوم، هدف ایجاد یک طبقه‌بند انطباقی، برای افزایش تطبیق‌پذیری دامنه‌های منبع و هدف است که دارای حداقل خطای پیش‌بینی برچسب باشد. طبقه‌بند انطباقی، با ایجاد سازگاری با ساختار هندسی داده‌های دامنه منبع و هدف در فضای جدید، باعث افزایش تطبیق‌پذیری ابعاد تفکیک‌کننده بین دامنه‌های منبع و هدف می‌شود. داده‌های بدون برچسب دامنه هدف، ساختار هندسی دامنه هدف را به خوبی نشان می‌دهند، بنابراین طبقه‌بند انطباقی، با بهره‌گیری از داده‌های برچسب‌دار دامنه منبع و داده‌های بدون برچسب دامنه هدف به صورت هم‌زمان، باعث تطبیق بهتر طبقه‌بند با اختلاف بین دامنه‌ها می‌شود. در شکل ۱۳ نمودار BDAC در مقایسه با FLDA^m به دلیل بهره‌گیری هم‌زمان از تطبیق خصوصیات و روش وزن دهی به نمونه‌ها از دقت بالاتری برخوردار است.



- [18] L. M. Bregman, "The relaxation method of finding the common point of convex sets and its application to the solution of problems in convex programming," *USSR computational mathematics and mathematical physics*, vol. 7, no. 3, pp. 200–217, 1967.
- [19] S. Si, D. Tao, and B. Geng, "Bregman divergence-based regularization for transfer subspace learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 7, p. 929, 2010.
- [20] M. Long, J. Wang, G. Ding, J. Sun and S. YuPhilip, "Transfer feature learning with joint distribution adaptation," *IEEE international conference on computer vision*, pp. 2200-2207, 2013.
- [21] Y. Xu, X. Fang, J. Wu, X. Li, and D. Zhang, "Discriminative transfer subspace learning via low-rank and sparse representation," *IEEE Transactions on Image Processing*, vol. 25, no. 2, pp. 850–863, 2016.
- [22] W. Dai, Q. Yang, G.-R. Xue, and Y. Yu, "Boosting for transfer learning," in *Proceedings of the 24th international conference on Machine learning*, 2007, pp. 193–200.
- [23] Y. Tsuboi, H. Kashima, S. Hido, S. Bickel, and M. Sugiyama, "Direct density ratio estimation for large-scale covariate shift adaptation," *Information and Media Technologies*, vol. 4, no. 2, pp. 529–546, 2009.
- [24] J. Quionero-Candela, M. Sugiyama, A. Schwaighofer, and N. D. Lawrence, "Dataset Shift in Machine Learning", The MIT Press, 2009.
- [25] Z. Ding, M. Shao, and Y. Fu, "Deep low-rank coding for transfer learning," in *Proceedings of the 24th International Conference on Artificial Intelligence*. AAAI Press, 2015, pp. 3453–3459.
- [26] M. Long, J. Wang, G. Ding, J. Sun, and P. Yu, "Transfer feature learning with joint distribution adaptation," in *Proceedings of the IEEE International Conference on Computer Vision*, 2013, pp. 2200– 2207.
- [6] M. Singha, D. Deb, and S. Roy, "Hybrid feature extraction method for partial face recognition," *Int. J. Emerg. Technol. Adv. Eng. Website*, vol. 4, pp. 308–312, 2014.
- [7] Saenko K, Kulis B, Fritz M, Darrell T. Adapting visual category models to new domains. *Computer Vision–ECCV 2010*. 2010:213-26.
- [8] K. Saenko, B. Kulis, M. Fritz, and T. Darrell, "Adapting visual category models to new domains," in *European conference on computer vision*, pp. 213–226, Springer, 2010.
- [9] M. Long, J. Wang, G. Ding, J. Sun and P. S. Yu, "Transfer joint matching for unsupervised domain adaptation," *IEEE conference on computer vision and pattern recognition*, pp. 1410-1417, 2014.
- [10] Y. Aytar and A. Zisserman, "Tabula rasa: Model transfer for object category detection," in *Computer Vision (ICCV), 2011 IEEE International Conference on*, pp. 2252–2259, IEEE, 2011.
- [11] G.Griffin, A. Holub and P. Perona, "Caltech-256 object category dataset", Technical Report7694, 2007.
- [12] J. J. Hull, "A database for handwritten text recognition research", *IEEE Trans. Pattern Anal. Mach. Intell*, vol. 16, no. 5, pp. 550–554, 1994.
- [13] T. Sim, S. Baker and M. Bsat, "The CMU pose, illumination, and expression (PIE) database", *Proceedings of Fifth IEEE International Conference on Automatic Face Gesture Recognition*, pp. 53-58, 2002.
- [14] M. Long, J. Wang, G. Ding, S. J. Pan, and S. Y. Philip, "Adaptation regularization: A general framework for transfer learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 26, no. 5, pp. 1076–1089, 2014.
- [15] J. Tahmoresnezhad and S. Hashemi, "Visual domain adaptation via transfer feature learning," *Knowledge and Information Systems*, vol. 50, no. 2, pp. 585– 605, 2017.
- [16] L. Luo, X. Wang, S. Hu, C. Wang, Y. Tang, and L. Chen, "Close yet distinctive domain adaptation," *IEEE Transactions on Image Processing*, vol. 25, no. 2, pp. 850–863, 2017.
- [17] Ggbdx

21 Knowledge extraction
 22 Over-fitting
 23 Principal components analysis (PCA)
 24 Fisher's linear discriminant analysis (FLDA)
 25 Unsupervised domain adaptation via Bregman Divergence minimization and Adaptive Classifier learning (BDAC)
 26 Model based
 27 Feature based
 28 Maximum mean discrepancy (MMD)
 29 Instance based
 30 Negative transfer
 31 Task
 32 Trivial
 33 Reconstruction error
 34 Kernel density estimation
 35 Expectation vectors
 36 Trace
 37 Regularization
 38 Gradient descent algorithm
 39 Representer
 40 Office
 41 Caltech
 42 Pie

زیرنویس‌ها:

1 Classification
 2 Regression
 3 Clustering
 4 Training data
 5 Source domain
 6 Testing data
 7 Target domain
 8 Transfer learning
 9 Domain adaptation
 10 Marginal distribution
 11 Conditional distribution
 12 Semi-supervised
 13 Unsupervised
 14 Bregman divergence
 15 Squared loss
 16 Kullback-Leibler (KL)
 17 Logistic loss
 18 Mahalanobis distance
 19 Adaptive Classifier
 20 Manifold structure