

حداقل سازی خطای پیش‌بینی مدل‌های طبقه‌بندی تصویر با استفاده از کدگذاری تنک و تطبیق دامنه

فریمه شرافتی^۱، دانشجوی کارشناسی ارشد؛ جعفر طهمورث نژاد^۲، استادیار

۱- دانشکده مهندسی فناوری اطلاعات و کامپیوتر- دانشگاه صنعتی ارومیه- ارومیه- ایران - farimah.sherafati@it.uut.ac.ir

۲- دانشکده مهندسی فناوری اطلاعات و کامپیوتر- دانشگاه صنعتی ارومیه- ارومیه- ایران - j.tahmores@it.uut.ac.ir

چکیده: تطبیق دامنه می‌تواند دانش را از یک مجموعه آموزشی (دامنه منبع) به یک مجموعه آزمایشی (دامنه هدف) انتقال دهد تا بازدهی مدل یادگرفته‌شده از داده‌های آموزشی افزایش یابد. علاوه بر این، استفاده از کدگذاری تنک، مدل یادگرفته‌شده را بسیار مختصر نموده و کنترل آن را ساده می‌نماید. با این حال، اختلاف توزیع بین دامنه‌های منبع و هدف بازدهی مدل را کاهش می‌دهد. در این مقاله، ما یک مدل تطبیق دامنه بدون نظارت پیشنهاد می‌دهیم تا خطای پیش‌بینی مدل‌های طبقه‌بندی تصاویر را کاهش دهیم. از وزن‌دهی مجدد نمونه‌ها برای مدیریت داده‌های اضافه و اطلاعات بلااستفاده داده‌های منبع در نمایش جدید استفاده می‌شود. همچنین، اختلاف توزیع شرطی بین دامنه‌های منبع و هدف با استفاده از روی هم‌گذاری زیرفضاها کاهش داده می‌شود. روش پیشنهادی ما یک طبقه‌بند مستقل از دامنه تنک در زیرفضای به‌دست‌آمده می‌باشد که ساختار داده‌های ورودی را حفظ می‌کند. آزمایشات گسترده نشان می‌دهد که روش پیشنهادی ما بر روی پایگاه‌داده‌های واقعی در مقایسه با روش‌های به روز در حوزه یادگیری ماشین و تطبیق دامنه، ۴/۴۹٪ بهبود در صحت طبقه‌بندی دارد.

واژه‌های کلیدی: پردازش تصویر، تطبیق دامنه، کدگذاری تنک، اختلاف توزیع شرطی، تطبیق زیرفضا.

Prediction Error Minimization of Image Classification Models via Sparse Coding and Domain Adaptation

F. Sherafati¹, MSc student; J. Tahmoresnezhad², Assistant professor

1- Faculty of IT & Computer Engineering, Urmia University of Technology, Urmia, Iran, Email: farimah.sherafati@it.uut.ac.ir

2- Faculty of IT & Computer Engineering, Urmia University of Technology, Urmia, Iran, Email: j.tahmores@it.uut.ac.ir

Abstract: Domain adaptation can transfer knowledge from a training set (source domain) to a test set (target domain), promoting the performance of the model learned from the training set. In addition, sparse coding makes the learned model more succinct and easy to manipulate. However, the existence of the distribution mismatch across the source and target domains reduce the performance of model. In this paper, we propose an unsupervised domain adaptation model to minimize the prediction error of image classification. Sample reweighting is utilized to handle redundant and useless information of source data in the new representation. Moreover, the difference of the conditional distributions across the source and target domains is reduced along with the subspace alignment. Our proposed approach learns a sparse domain-invariant classifier in a latent subspace with preserving the structure of the input data. Extensive experiments demonstrate that our proposed approach shows 4.49% improvement in classification accuracy on real-world datasets compared to state-of-the-art machine learning and domain adaptation methods.

Keywords: Image processing, domain adaptation, sparse coding, conditional distribution difference, subspace alignment.

تاریخ ارسال مقاله: ۱۳۹۷/۰۱/۱۸

تاریخ اصلاح مقاله: ۱۳۹۷/۰۶/۲۸ و ۱۳۹۷/۰۹/۰۹

تاریخ پذیرش مقاله: ۱۳۹۷/۱۰/۰۱

نام نویسنده مسئول: جعفر طهمورث نژاد

نشانی نویسنده مسئول: ایران - ارومیه - دانشگاه صنعتی ارومیه - دانشکده مهندسی فناوری اطلاعات و کامپیوتر.

۱- مقدمه

استاندارد نزدیک‌ترین همسایه^۱ برای برچسب‌گذاری اولیه داده‌های هدف استفاده می‌کند و با استفاده از MMD اختلاف توزیع داده‌ها را کاهش می‌دهد. علاوه بر این، SCDA از یک روند تکرار شونده برای بهبود برچسب‌گذاری نمونه‌های هدف بهره می‌برد و در هر مرحله با اندازه‌گیری اختلاف توزیع شرطی بین نمونه‌های انتخاب‌شده، فاصله دامنه‌های منبع و هدف را کاهش می‌دهد. در نهایت، SCDA با بر روی هم‌گذاری زیرفضاهای به‌دست‌آمده، فاصله دامنه‌ها را به حداقل می‌رساند.



شکل ۱: توزیع متفاوت از تصاویر دامنه‌های متفاوت

عملکرد روش پیشنهادی بر روی پایگاه‌داده‌های واقعی اشیاء و اعداد در شرایط مختلف مورد ارزیابی قرار گرفته است. نتایج آزمایش‌ها حاکی از بهبود قابل‌ملاحظه میانگین صحت طبقه‌بندی ۴۹/۴٪ الگوریتم پیشنهادی در مقایسه با جدیدترین روش‌ها در حوزه یادگیری ماشین و یادگیری انتقالی می‌باشد.

ادامه مقاله به‌صورت زیر سازماندهی شده است. در بخش دوم برخی از کارهای گذشته بررسی شده است. در بخش سوم روش پیشنهادی آورده شده است. پایگاه‌داده‌های مورد ارزیابی و نتایج ارزیابی در بخش چهارم بیان شده است. در انتها، نتیجه‌گیری و کارهای آتی آورده شده است.

۲- کارهای پیشین

در سال‌های اخیر تکنیک‌های تطبیق دامنه به‌وفور مورد مطالعه قرار گرفته و رویکردهای زیادی برای آن پیشنهاد شده است. به‌طور کلی روش‌های موجود در این حوزه بر روی دو رویکرد اصلی زیر تمرکز دارند، رویکردهای مبتنی بر نمونه^۲، رویکردهای مبتنی بر خصوصیت^۳.

هدف رویکردهای مبتنی بر نمونه، کاهش اختلاف توزیع دامنه‌های منبع و هدف با وزن‌دهی مجدد نمونه‌های منبع مطابق با شباهت آنها با نمونه‌های هدف می‌باشد. روش SSTS^۴ [۴] تعدادی محدودیت متقابل بین دامنه منبع و داده‌های برچسب‌دار دامنه هدف ایجاد می‌کند و از ساختار کلی داده‌های بدون برچسب برای ایجاد یک زیرفضای مستقل از دامنه استفاده می‌کند. روش بهینه‌سازی همزمان تبدیل خصوصیت و وزن نمونه‌ها برای تطبیق دامنه^۵ [۵] به‌طور همزمان از نگاهت خصوصیات و وزن‌دهی نمونه‌های برای حذف نمونه‌های غیرمرتبط دامنه منبع استفاده می‌کند.

اما هدف رویکردهای مبتنی بر خصوصیت، کاهش اختلاف توزیع با یادگیری یک نمایش خصوصیت جدید می‌باشد. روش‌های مبتنی بر خصوصیت را می‌توان به سه دسته کلی زیر تقسیم کرد:

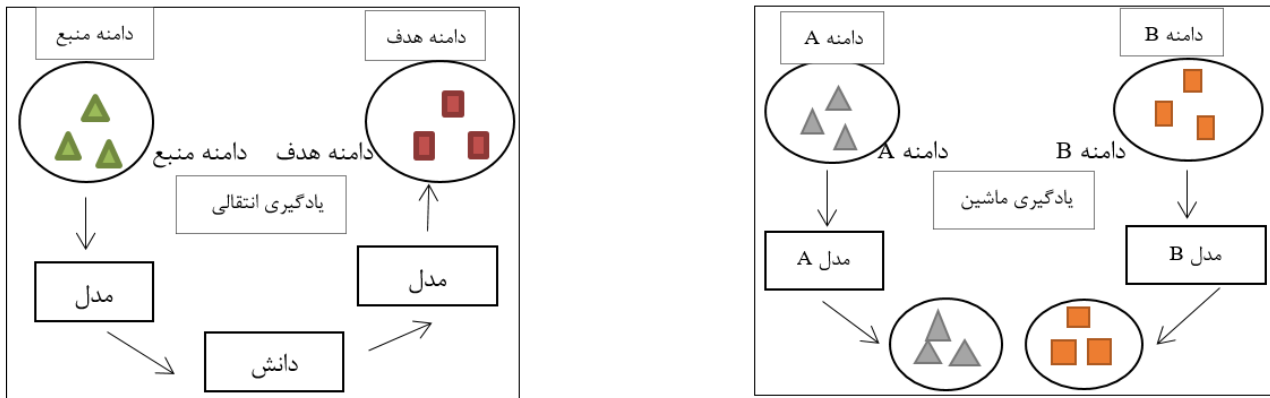
تغییر دامنه^۱ به‌عنوان اختلاف توزیع احتمال بین دامنه‌های منبع و هدف تعریف می‌شود که یک مساله رایج در یادگیری ماشین می‌باشد. یک فرض اصلی در بسیاری از الگوریتم‌های یادگیری ماشین و داده‌کاوی این است که داده‌های آموزشی و آزمایشی باید در فضای خصوصیت یکسان باشند. با این حال، در بسیاری از برنامه‌های دنیای واقعی، این فرض ممکن است برقرار نباشد. به‌عنوان نمونه، شکل ۱ چهار تصویر مشابه در دو دامنه مختلف را نشان می‌دهد. بدیهی است که به‌دلیل وجود اختلاف توزیع بین دامنه‌ها، مدل ایجادشده بر روی دامنه منبع نمی‌تواند کارایی خوبی جهت طبقه‌بندی تصاویر دامنه هدف داشته باشد [۱].

یادگیری انتقالی^۲ یک راه حل بهینه برای مواجهه با تغییر در مسائل یادگیری ماشین است که بر روی ذخیره کردن دانش به‌دست‌آمده در حل یک مساله و به‌کارگیری آن در یک مساله متفاوت، اما مرتبط تأکید دارد. برای مثال در تشخیص چهره، خصوصیات صورت انسان با تغییر سن یا عوامل دیگری نظیر میزان نور و یا حتی آرایش کردن تغییر می‌کند. یادگیری انتقالی از دانش موجود در یک مجموعه برچسب‌دار برای برچسب‌گذاری یک مجموعه بدون برچسب با توزیع احتمال متفاوت استفاده می‌کند. مراحل یادگیری ماشین و یادگیری انتقالی و تفاوت‌های آن‌ها در شکل ۲ آورده شده است.

اختلاف توزیع شرطی بین دامنه‌های منبع و هدف زمانی رخ می‌دهد که به ازای داده‌های یکسان از دو دامنه، توزیع مجموعه برچسب‌ها متفاوت باشد. برای سنجش اختلاف توزیع شرطی بین دامنه‌ها معیارهای فراوانی وجود دارد که می‌توان به MMD^۳ که یک معیار غیرپارامتری می‌باشد اشاره کرد. MMD داده‌های منبع و هدف را به یک زیرفضای RKHS نگاشت می‌کند و با محاسبه میانگین عناصر^۴ هر کدام از دامنه‌ها در فضای جدید، اختلاف میانگین بین دو دامنه را به‌دست می‌آورد.

در سال‌های اخیر نمایش تنک به دلیل قابلیت‌های منحصر به فرد آن توجه بسیاری از محققین را در حوزه‌های پردازش سیگنال، بینایی ماشین و تشخیص الگو به‌خود جلب کرده است. نمایش تنک، شامل یک واژه‌نامه می‌باشد که یک ترکیب خطی متناظر از داده‌های ورودی است [۳]، و هر نمونه دامنه هدف را با یک ترکیب خطی از نمونه‌های دامنه منبع قابل بازسازی می‌نماید. در واقع نمایش تنک می‌تواند نمونه‌های منبعی را که به نمونه‌های هدف شباهت بیشتری دارند را شناسایی نموده و از پردازش مازاد و مخرب بر روی تمام نمونه‌های منبع جلوگیری نماید. در این مقاله یک روش نوین بدون نظارت برای کاهش اختلاف توزیع

بین دامنه‌ها با عنوان حداقل‌سازی خطای پیش‌بینی مدل‌های طبقه‌بندی تصاویر با استفاده از کدگذاری تنک و تطبیق دامنه^۵ (SCDA) پیشنهاد شده است. روش پیشنهادی، داده‌های منبع و هدف را به یک زیرفضای مشترک نگاهت داده و با استفاده از نرم $l_{2,1}$ و نمایش تنک، نمونه‌هایی از دامنه منبع که توزیع مشابهی با نمونه‌های هدف دارند را انتخاب می‌کند. SCDA برای کاهش اختلاف توزیع شرطی، از یک طبقه‌بند



شکل ۲: تفاوت یادگیری ماشین و یادگیری انتقالی. در یادگیری انتقالی از دانش دامنه منبع برای برچسب گذاری نمونه های هدف استفاده شده است، در صورتی که در یادگیری ماشین هیچ گونه دانشی وجود ندارد.

یادگیری انتقال قوی از طریق محدودیت رتبه پایین ایجاد کرده و توزیع حاشیه ای و شرطی بین دامنه ها را به حداقل می رساند. علاوه بر این RTML از دو استراتژی زیر جهت مقاوم سازی مدل در مقابل تغییرات داده ها استفاده می کند: محدودیت رتبه پایین روی متریک و طرح رفع انزوا^۲ در حین بازسازی داده ها.

در این مقاله، یک روش بدون نظارت مبتنی بر خصوصیت و نمونه پیشنهاد می شود که با نگاشت داده ها به یک فضای مشترک و انتخاب نمونه های مرتبط با استفاده از کدگذاری تنک اختلاف توزیع بین دامنه های منبع و هدف را به حداقل می رساند.

۳- روش پیشنهادی

۳-۱- هدف تحقیق

تطبیق دامنه یکی از مسائل مطرح در حوزه یادگیری ماشین می باشد. این مقاله، به دنبال پیشنهاد روشی است که بتواند بر محدودیت های الگوریتم های یادگیری ماشین کلاسیک غلبه کند. در سال های اخیر استفاده از نمایش تنک در کاربردهای مختلف پردازش تصویر رواج زیادی پیدا کرده است. بنابراین، نمایش تنک به عنوان مدلی مناسب جهت مدل سازی داده ها در فضای جدید استفاده می شود.

۳-۲- نمادها و تعاریف

در این مقاله دامنه های منبع و هدف با زیرنویس S و T و به ترتیب با $X_S \in R^{d \times n_s}$ و $X_T \in R^{d \times n_t}$ نشان داده می شوند. $D_T = \{X_T\}$ و $D_S = \{X_S, Y_S\}$ نشان دهنده تعداد نمونه های منبع و n_T تعداد نمونه های هدف را نشان می دهد. برخی از نمادهای استفاده شده در مقاله و توضیحات آنها در جدول ۱ آورده شده است. ترانهاده ماتریس با استفاده از بالانویس ' نشان داده شده است و tr نشان دهنده حاصل جمع عناصر قطر اصلی ماتریس می باشد. داده های منبع به عنوان واژه نامه در نظر گرفته می شوند، بنابراین ابعاد واژه نامه برابر $n_s \times d_s$ می باشد.

(۱) روش هایی که فقط اختلاف توزیع حاشیه ای بین دامنه ها را کاهش می دهند. روش ^{۱۱} GFK [۶] از جمله این روش ها می باشد. GFK برای محاسبه تغییرات بین دامنه های منبع و هدف، آنها را به یک زیرفضای جدید بر روی منیفولد گرسمن^{۱۲} که در آن توزیع دامنه های منبع و هدف به هم نزدیک هستند، نگاشت می دهد ولی به دلیل این که اندازه زیرفضا را کوچک در نظر می گیرد بخشی از اطلاعات ورودی از بین می برد. روش ^{۱۳} DMM [۷] با استفاده از اصل حداقل سازی ریسک ساختاری، یک یادگیرنده انتقال را با استخراج نمایش ویژگی مستقل یاد می گیرد و وزن نمونه های غیرمستقیم را برآورد می کند که به طور مشترک اختلاف توزیع بین دامنه را به حداقل می رساند. روش یادگیری یک فضای هیلبرت ثابت برای تطبیق دامنه^{۱۴} [۸] یک روش برای مساله تطبیق دامنه نیمه نظارت شده و بدون نظارت می باشد که یک فضای نگاشتی را پیدا می کند که در آن اختلاف دامنه ها به حداقل می رسد. ^{۱۵} SCA [۹] با حداکثر سازی اختلاف بین نمونه ها در کلاس های مختلف و حداقل سازی اختلاف بین نمونه های هر کلاس، دامنه ها را به زیرفضای جدید نگاشت می دهد. ^{۱۶} SDA [۱۰] همزمان با ایجاد تطبیق بین زیرفضاهای دامنه منبع و هدف، اختلاف توزیع بین دامنه ها را از طریق تطبیق واریانس مولفه های اساسی دامنه ها به حداقل می رساند.

(۲) روش هایی که فقط اختلاف توزیع شرطی را کاهش می دهند. روش تطبیق احتمال شرطی بین دامنه ها از طریق دسته بندی خصوصیات^{۱۷} [۱۱] از جمله این روش ها می باشد. در این روش، آن دسته از خصیصه هایی انتخاب می شوند که به طور همزمان، اختلاف توزیع شرطی بین دامنه های منبع و هدف را کاهش و مشابهت بین داده های برچسب دار را افزایش دهند. چالش اصلی در این روش، محاسبه اختلاف توزیع بین دامنه های منبع و هدف در شرایطی است که خصیصه ها فقط در یکی از دامنه های منبع یا هدف تعریف شده باشند.

(۳) روش هایی که همزمان اختلاف توزیع حاشیه ای و شرطی را کاهش می دهند. ^{۱۸} VDA [۱۲] یکی از این روش ها می باشد که یک نمایش کم بعد از دامنه های منبع و هدف ایجاد می کند تا هر دو اختلاف توزیع حاشیه ای و شرطی را کاهش دهد. ^{۱۹} RTML [۱۳] یک چارچوب

$$\arg \min_{\mathbf{A}} \|\mathbf{P}_t' \mathbf{X}_t - \mathbf{P}_s' \mathbf{X}_s \mathbf{A}\|_F^2 + \rho \|\mathbf{A}\|_{2,1} \quad (1)$$

با استفاده از رابطه ۱ ماتریس انتخاب $\mathbf{A} \in \mathbb{R}^{n_s \times n_t}$ به دست می آید که فاصله بین داده های منبع و هدف را در زیرفضای جدید کاهش داده و با استفاده از نرم $l_{2,1}$ نمونه های منبعی که توزیع نزدیک تری به نمونه های هدف دارند را انتخاب می کند. نرم $l_{2,1}$ می تواند هر سطر ماتریس را همزمان صفر یا غیر صفر کند. سطرهای غیر صفر، هر نمونه هدف را با حداقل تعداد نمونه های منبع نشان می دهند، بنابراین سطرهای غیر صفر به عنوان نمونه های منبع مرتبط انتخاب می شوند. نمونه های انتخاب شده با X_{S1} نشان داده می شوند.

۳-۴- کاهش اختلاف توزیع شرطی و حفظ ساختار هندسی دامنه ها

برای محاسبه اختلاف توزیع بین دامنه های منبع و هدف از روش MMD تغییر یافته استفاده می شود. این روش، یک روش غیر پارامتری برای محاسبه اختلاف توزیع بین دامنه ها در مسائل با ابعاد بالا (مانند مسائل بینایی ماشین) می باشد. در روش MMD برای محاسبه اختلاف توزیع دامنه ها، داده های دامنه منبع و هدف به فضای هیلبرت^{۲۳} نگاشت می شوند. با به کارگیری روش MMD، مجموع اختلاف شرطی میانگین نمونه های هر کلاس در دامنه های منبع و هدف، با استفاده از رابطه زیر محاسبه خواهد شد.

$$Cond(X_S, X_T) = \left\| \frac{1}{n_S^c} \sum_{x_i \in X_S^c} P_{X_i} - \frac{1}{n_T^c} \sum_{x_j \in X_T^c} P_{X_j} \right\|^2 = tr(P' X M_c X' P) \quad (2)$$

که ماتریس M ماتریس ضرایب بوده و به صورت زیر محاسبه می شود. اگر $x_i, x_j \in X_S^c$ باشد $(M_c)_{ij} = \frac{1}{n_S^c n_S^c}$ و اگر $x_i, x_j \in X_T^c$ باشد آن گاه $(M_c)_{ij} = \frac{1}{n_T^c n_T^c}$ و در غیر این صورت $(M_c)_{ij} = \frac{-1}{n_S^c n_T^c}$ می باشد. به علت این که روش پیشنهادی ما یک روش بدون نظارت می باشد و هیچ داده برچسب داری از دامنه هدف در دسترس نمی باشد، برای کاهش اختلاف توزیع شرطی، با استفاده از یک طبقه بند NN که بر روی داده های انتخاب شده منبع ایجاد می شود برچسب های اولیه نمونه های هدف پیش بینی می شوند. بدین ترتیب در یک روند تکرار شونده و تکاملی اختلاف توزیع شرطی بین نمونه های انتخاب شده از منبع و نمونه های هدف کاهش می یابد.

در روش پیشنهادی به دلیل این که داده ها به یک زیرفضای جدید مشترک نگاشت می شوند، هندسه هر دامنه نیز بایستی حفظ شود تا کارایی مدل کاهش نیابد. به منظور حفظ ساختار هندسه هر دامنه، از فرضیات منیفلد^{۲۴} استفاده می شود. بدین ترتیب، اگر دو داده X_{sj} و X_{si} در فضای اصلی به یکدیگر نزدیک باشند، آنگاه در زیرفضای مشترک

$$W_s(i, j) = e^{-\frac{\|x_{si} - x_{sj}\|_F^2}{\delta^2}} \quad \text{کم بعد نیز به یکدیگر نزدیک خواهند بود.}$$

در مسائل یادگیری انتقالی، دامنه و وظیفه به صورت زیر تعریف می شوند. دامنه D به صورت $D = \{X, P(X)\}$ بیان می شود که X فضای خصیصه ای و $P(X)$ توزیع احتمال حاشیه ای می باشد. با این تعریف، در صورتی دامنه های منبع و هدف با یکدیگر متفاوت هستند که فضای خصیصه ای و یا توزیع حاشیه ای متفاوتی داشته باشند.

برای هر دامنه D یک وظیفه T وجود دارد که به صورت $T = \{Y, f(x)\}$ تعریف می شود که Y مجموعه برچسب و $f(x)$ تابع پیش بینی می باشد، تابع $f(x)$ برای نمونه های ورودی X مجموعه برچسب Y را پیش بینی می کند و می توان آن را به صورت توزیع احتمال شرطی $P(Y|x)$ بیان کرد. با این تعریف، زمانی دو وظیفه متفاوت هستند که مجموعه برچسب و یا تابع توزیع احتمال شرطی متفاوتی داشته باشند؛ بدین معنی که $Y_s \neq Y_t$ یا $P_t(Y_t | X_t) \neq P_s(Y_s | X_s)$.

جدول ۱: نمادهای پرکاربرد و توضیحات آن ها

نمادها	توضیحات
D_s, D_t	دامنه های منبع و هدف
X_s, X_t	نمونه های منبع و هدف
Y_s, Y_t	برچسب های منبع و هدف
P_s, P_t	ماتریس های نگاشت منبع و هدف
D	ابعاد نمونه ها
M	ابعاد زیرفضا
n_s, n_t	تعداد نمونه های منبع و هدف
ρ	پارامتر تنظیم تنگی
$P_s(Y_s X_s)$	توزیع شرطی دامنه منبع
$P_t(Y_t X_t)$	توزیع شرطی دامنه هدف
C	تعداد کلاس ها
X_s^c, X_t^c	نمونه های منبع و هدف در کلاس C
n_s^c, n_t^c	تعداد نمونه های منبع و هدف در کلاس C

هدف ما در این مقاله، طراحی مدلی است که شرط زیر را برآورده سازد: $P_s(Y_s | X_s) \approx P_t(Y_t | X_t)$ ، یعنی اختلاف توزیع شرطی بین داده های آموزشی و آزمایشی را به حداقل رساند.

۳-۳- انتخاب نمونه های منبع با استفاده از کدگذاری تنگ^{۲۱}

تنگی یک ویژگی بسیار مفید در برخی از الگوریتم های یادگیری ماشین است که از بین همه ضرایبی که مدل را توصیف می کنند فقط تعداد کمی غیر صفر هستند و از ترکیب خطی ضرایب غیر صفر برای توصیف نمونه های هدف استفاده می شود. بدین ترتیب، برای انتخاب نمونه ها از کدگذاری تنگ استفاده می شود و داده ها با استفاده از PCA^{۲۲} [۱۴] به یک زیرفضای مشترک نگاشت داده می شوند و نمونه ها در زیرفضای جدید انتخاب می شوند. شمای از نحوه انتخاب نمونه ها در زیرفضا در شکل ۳ نشان داده شده است. نمایش تنگ به صورت زیر به دست می آید:

۳-۶- الگوریتم روش پیشنهادی

با توجه به اینکه در روش پیشنهادی بایستی سه ماتریس به صورت همزمان به دست آیند، بهینه‌سازی پارامترهای مدل به صورت یک به یک انجام می‌گیرد. هدف SCDA محاسبه همزمان ماتریس‌های P_T و P_S است. برای محاسبه ماتریس A رابطه (۱) با فرض ثابت بودن P_T و P_S استفاده می‌شود که نسبت به A مشتق گرفته و برابر با صفر قرار داده می‌شود. مقدار بهینه A با استفاده از رابطه زیر به دست می‌آید:

$$A = (\rho N + X_S' P_S' X_S)^{-1} X_S' P_S' X_T \quad (6)$$

که در رابطه فوق، $N = \frac{1}{2 \|A^i\|_2}$ یک ماتریس قطری و وابسته به A است و A با یک روش تکراری به دست می‌آید.

همچنین، با فرض اینکه متغیر A در رابطه (۵) ثابت باشد، برای به دست آوردن متغیر P بایستی نسبت به آن مشتق گرفته شود. با توجه به این که محدودیت مسأله خود بر حسب متغیر P می‌باشد به کمک لاگرانژ مقدار بهینه P به دست می‌آید. مقدار تابع لاگرانژ به صورت زیر محاسبه می‌شود:

$$L = (P' X (M + S) X' P) - tr((P' XVX' P - I) Q) \quad (7)$$

که $Q = \text{diag}(q_1, \dots, q_p) \in \mathbf{R}^{p \times p}$ ضرایب لاگرانژ بوده و یک ماتریس قطری است. برای به دست آوردن P از رابطه فوق مشتق گرفته و برابر صفر قرار داده می‌شود:

$$X (\delta M + S) X' P = XVX' P Q \quad (8)$$

که $S = \begin{bmatrix} I + \mu L_S & -I \\ -I & \eta I + \mu L_T \end{bmatrix}$ است، μ پارامتر تنظیم گراف، δ ضریب ماتریس M و $M = M_c$ است.

در انتها، با استفاده از روش تطبیق زیرفضا، زیرفضاهای به دست آمده با یکدیگر تطبیق می‌یابند. تطبیق زیرفضاهای منبع (P_S) و هدف (P_T) با استفاده از ماتریس نگاشت M با یکدیگر انجام می‌شود. ماتریس نگاشت M با حداقل‌سازی رابطه زیر به دست می‌آید که زیرفضای منبع را بر روی زیرفضای هدف تطبیق می‌دهد:

$$F(M) = \|P_S M - P_T\|_F^2 \quad (9)$$

مقدار بهینه ماتریس تطبیق M^* از رابطه زیر به دست می‌آید:

$$M^* = \underset{M}{\operatorname{argmin}} (F(M)) \quad (10)$$

به دلیل این که نرم فروبنیوس برای عملیات متعامد بودن^{۲۷} ثابت است، فرمول (۹) را می‌توان به صورت زیر بازنویسی کرد:

$$F(M) = \|P_S' P_S M - P_S' P_T\|_F^2 = \|M - P_S' P_T\|_F^2 \quad (11)$$

شبهات دو نمونه منبع X_{si} و X_{sj} را نشان می‌دهد که δ میانگین فاصله از تمام نمونه‌های منبع است. $D = \text{diag}(d_1, \dots, d_{n_s})$ یک ماتریس قطری است که d_i مجموع i امین سطر از W_S را نشان می‌دهد و $L_S = D - W_S$ ماتریس لاپلاسیان^{۲۵} است. با استفاده از رابطه زیر ساختار و هندسه داده‌ها در فضای نگاشت شده حفظ شده و کارایی مدل به صورت قابل توجهی افزایش می‌یابد:

$$\min_P \operatorname{tr}(P' XLX' P) \quad (3)$$

که در آن L ماتریس لاپلاسیان نمونه‌های منبع و هدف، $P = [P_S, P_T]$ و $X = [X_S, X_T]$ است.

۳-۵- نگاشت داده‌ها به زیرفضای جدید

روش SCDA پیشنهادی، یک روش دو مرحله‌ای می‌باشد که از PCA برای نگاشت اولیه داده‌ها به یک زیرفضای پیش فرض استفاده می‌کند. PCA با یافتن اجزای اصلی در فضای نگاشت شده واریانس نمونه‌های منبع و هدف را ماکزیمم می‌نماید. واریانس داده‌های ورودی به صورت XVX' محاسبه می‌شود که با نگاشت P به زیرفضای جدید به صورت زیر نمایش داده می‌شود:

$$\operatorname{argmax}_P (P' XVX' P) \quad (4)$$

با فرض $V = \begin{bmatrix} V_S & 0 \\ 0 & V_T \end{bmatrix}$ که $V_S = I - \frac{1}{n_s} \mathbf{1}\mathbf{1}'$ و

$V_T = I - \frac{1}{n_t} \mathbf{1}\mathbf{1}'$ ماتریس‌های هم‌مرکز نمودن بوده و از پراکندگی

داده‌ها جلوگیری می‌کنند و I یک ماتریس همانی و $\mathbf{1}$ بردار یک‌ها است. بدین ترتیب برای یافتن زیرفضای مطلوب که در آن توزیع داده‌های منبع و هدف به هم نزدیک باشد و تنها بخشی از نمونه‌های منبع در ایجاد مدل استفاده شود، بایستی یک تابع هدف با استفاده از روابط (۱)، (۲)، (۳) و (۴) ایجاد نماییم. اما از آنجایی که روابط (۱)، (۲) و (۳) به دنبال یافتن یک نقطه مینیمم و رابطه (۴) به دنبال یافتن یک نقطه ماکزیمم است، با استفاده از قضیه رایلی^{۲۶} روابط (۱)، (۲) و (۳) را با ثابت در نظر گرفتن رابطه (۴) مینیمم می‌کنیم. بدین ترتیب تابع هدف به صورت زیر خواهد بود:

$$\min_{P, P} \operatorname{tr}(P' XLX' P) + \|P\|_2^2 + \delta \operatorname{tr}(P' X M_c X' P)$$

که در رابطه بالا هر بخش به طور جداگانه موجب کاهش اختلاف توزیع بین دامنه‌ها می‌شود. بخش اول هندسه هر دامنه در فضای نگاشت شده را حفظ می‌کند، بخش دوم از به دست آمدن جواب‌های بدیهی جلوگیری می‌کند، بخش سوم اختلاف توزیع شرطی را کاهش می‌دهد و در نهایت، شرط رابطه برای ماکزیمم کردن واریانس داده‌ها است تا کلاس‌ها به خوبی از یکدیگر متمایز شوند.

۱۴. به دست آوردن برچسب نمونه‌های هدف با استفاده از طبقه‌بند KNN روی

$$(X_S, X_T, Y_S)$$

پایگاه‌داده آفیس و کالتک از مجموعه پایگاه‌داده‌های شناخته‌شده در حوزه تطبیق دامنه‌های بصری است. پایگاه‌داده آفیس شامل تصاویری با سه دامنه مجزای زیر می‌باشد: آمازون^{۲۵}، دی اس ال آر^{۲۶}، وبکم^{۲۷}. دامنه آمازون شامل تصاویر دانلودشده از وبسایت تجاری آنلاین (amazon.com)، دامنه دی اس ال آر شامل تصاویری با وضوح بالا می‌باشد که در محیط‌های واقعی و نور طبیعی با دوربین SLR دیجیتال گرفته شده‌اند و در نهایت، دامنه وبکم شامل تصاویر با وضوح پایین می‌باشد که توسط دوربین‌های وبکم گرفته شده است. برای تنوع بیشتر آزمایشات ۱۲ مسأله تطبیق دامنه بر اساس چهار حوزه C (Caltech-256)، A (Amazon)، W (Webcam) و D (DSLR) با انتخاب هر جفت از دامنه‌های متفاوت به‌عنوان دامنه منبع و هدف انجام گرفته است. پایگاه‌داده آفیس و کالتک شامل ۱۰ کلاس می‌باشند. شکل ۴ نمونه‌ای از تصاویر این پایگاه‌داده‌ها را نشان می‌دهد.

۴-۲- تشخیص اعداد دست‌نوشته بین دامنه‌ها

دو پایگاه‌داده اعداد USPS (U)^{۳۸} و MNIST (M)^{۳۹} شامل ۱۰ کلاس از اعداد ۰ تا ۹ می‌باشد که برای ارزیابی روش پیشنهادی SCDA استفاده شده است. پایگاه‌داده USPS شامل ۷۲۹۱ تصویر آموزشی و ۲۰۰۷ تصویر آزمایش با اندازه ۱۶×۱۶ می‌باشد. پایگاه‌داده MNIST شامل مجموعه آموزشی با ۶۰۰۰۰ تصویر و مجموعه آزمایش با ۱۰۰۰۰ تصویر با اندازه ۲۸×۲۸ می‌باشد. آزمایش USPS_MNIST با انتخاب تصادفی ۱۸۰۰ تصویر از USPS به‌عنوان منبع و ۲۰۰۰ تصویر از MNIST به‌عنوان هدف انجام شده و به‌طور مشابه آزمایش MNIST_USPS با جابجایی دامنه منبع و دامنه هدف انجام می‌شود. همه تصاویر به اندازه ۱۶×۱۶ درآمده‌اند. شکل ۵ نمونه‌ای از تصاویر این پایگاه‌داده را نشان می‌دهد. اطلاعات دقیق‌تر از پایگاه‌داده‌ها در جدول ۲ آورده شده است.

۴-۳- تنظیمات آزمایش

الگوریتم روش پیشنهادی شامل پنج پارامتر مختلف می‌باشد که مقادیر برخی از آن‌ها به دلیل حساس نبودن مدل به مقادیر مختلف آنها ثابت در نظر گرفته شده است. η ضریب ماتریس همانی است که ۰/۰۰۱ و μ ضریب ساختار هندسی هر دامنه می‌باشد که به‌صورت تجربی برای پایگاه‌داده آفیس و کالتک ۰/۰۵ و برای پایگاه‌داده اعداد ۰/۰۰۵ در نظر گرفته شده است. پارامتر ρ ، پارامتر تنظیم تنگی است که نقش به‌سزایی در انتخاب نمونه‌ها را دارا می‌باشد که در محدوده [۰/۰۰۱، ۰/۵] مورد ارزیابی قرار گرفته است. k ابعاد زیرفضای جدید می‌باشد که برای هر دو پایگاه‌داده آفیس و کالتک و اعداد در محدوده [۲۰، ۲۲۰] و δ ضریب MMD است که اختلاف توزیع شرطی را کاهش می‌دهد و در محدوده [۰/۰۰۱، ۱/۰] در نظر گرفته شده است.

با توجه به رابطه (۱۱)، می‌توان نتیجه گرفت که M^* بهینه با استفاده از رابطه $M^* = P_S^* P_T^*$ به دست می‌آید و مقدار $X_a = P_S P_S^* P_T^*$ می‌باشد که X_a دامنه منبع نگاشت شده و تطبیق شده با دامنه هدف می‌باشد. روش SCDA با جزئیات کامل در الگوریتم ۱ ارائه شده است. SCDA با مقداردهی اولیه ماتریس نگاشت P ماتریس انتخاب A را به دست می‌آورد. سپس، با استفاده از یک طبقه‌بند NN برچسب‌های اولیه نمونه‌های هدف را به دست آورده و اختلاف توزیع شرطی بین نمونه‌های انتخاب شده و نمونه‌های هدف را کاهش می‌دهد. SCDA در یک فرایند تکرار شونده مقدار دقیق ماتریس نگاشت P را به دست می‌آورد. در انتها، زیرفضاهای به دست آمده با یکدیگر تطبیق شده و با استفاده از طبقه‌بند NN برچسب نمونه‌های هدف پیش‌بینی می‌شود.

۴-۴- آزمایش‌ها

این بخش شامل آزمایش‌های متعددی بوده که بر روی پایگاه‌داده‌های شناخته‌شده تشخیص اشیا بین دامنه‌های آفیس^{۲۸} و کالتک^{۲۹} و تشخیص اعداد دست‌نویس (USPS و MNIST) انجام گرفته است. روش پیشنهادی با چندین روش بدون نظارت مانند: NN [۱۵]، PCA، TSL^{۲۰} [۱۶]، TCA^{۳۱} [۱۷]، DAM^{۳۲} [۱۸]، SA^{۳۳} [۱۹] و LRSR^{۳۴} [۲۰] مقایسه شده است.

۴-۱- تشخیص اشیا بین دامنه‌ها

الگوریتم ۱: حداقل‌سازی خطای پیش‌بینی مدل‌های طبقه‌بندی تصویر با استفاده از کدگذاری تنک و تطبیق دامنه

۱. ورودی: داده منبع X_S ، داده هدف X_T ، ابعاد زیرفضا p ، برچسب داده منبع Y_S خروجی: برچسب دامنه هدف L_1
۲. پارامترها: پارامترهای تنظیم η, ρ, μ, δ
۳. مقداردهی تصادفی $P \in \mathbf{R}^{(d_S+d_T)^*k}$
۴. تکرار مراحل ۵ تا ۹ تا زمانی که حداکثر تعداد تکرارها یا بالاترین مقدار به دست آید.
۵. محاسبه ماتریس انتخاب با استفاده از حل معادله (۶)

$$۶. \text{ محاسبه ماتریس قطری } N = \frac{1}{2 \|A\|_2} \text{ بر اساس } A.$$

$$۷. X_{S1} = X_S A.$$

۸. به دست آوردن برچسب اولیه هدف با استفاده از یک طبقه‌بند KNN

$$\text{روی } (X_{S1}, X_T, Y_S)$$

۹. محاسبه ماتریس نگاشت P با استفاده از حل معادله (۸)

۱۰. انتهای حلقه

$$۱۱. \text{ محاسبه } X_a = P_S^* P_S P_T^*$$

$$۱۲. \text{ محاسبه } X_{S1}' = X_{S1} X_a$$

$$۱۳. \text{ محاسبه } X_T' = X_T P_T^*$$

۴-۴- ارزیابی پارامترها

در SCDA، سه پارامتر مختلف مورد ارزیابی قرار گرفته است که مقادیر بهینه آن‌ها در جدول ۳ آورده شده است.

نتایج به دست آمده برای مقادیر مختلف k بر روی پایگاه داده های آفیس و کالتک و اعداد در شکل ۶ نشان داده شده است. نتایج حاکی آن است که پایگاه داده آفیس و کالتک حساسیت کمی نسبت به مقادیر مختلف k دارد. برای بیشتر پایگاه داده ها محدوده بهینه پارامتر k [۸۰، ۶۰] می باشد. اما پایگاه داده اعداد دارای حساسیت زیادی نسبت به مقادیر مختلف P می باشد. بهترین محدوده برای پارامتر k در پایگاه داده اعداد، [۱۲۰، ۱۰۰] می باشد.

نتایج به دست آمده برای مقادیر مختلف δ در شکل ۷ نشان داده شده است. نمودارها بیانگر تأثیر پارامتر δ در هر دو پایگاه داده به خصوص پایگاه داده اعداد می باشد.

پارامتر ρ ، نقش به سزایی در انتخاب نمونه ها با استفاده از کدگذاری تنک و نرم $l_{2,1}$ را دارا می باشد. شکل ۸ تعداد نمونه های انتخاب شده برای پایگاه داده U_M را نشان می دهد. همچنین شکل ۹ تعداد نمونه های انتخاب شده برای پایگاه داده C_A را نشان می دهد. به عنوان نمونه در پایگاه داده U_M زمانی که $\rho = 0/001$ است همه نمونه ها انتخاب می شوند اما زمانی که $\rho = 0/5$ است تنها ۴۵۴ نمونه از ۱۸۰۰ نمونه انتخاب می شوند که این بیانگر اهمیت این پارامتر می باشد.

۴-۵- اهمیت کدگذاری تنک و حفظ ساختار هندسی

اهمیت وجودی برخی از پارامترهای مدل در این بخش گنجانده شده است و نتایج قابل تأمل آن در جدول ۴ آورده شده است. ابتدا دو معیار مقایسه در زیر تعریف شده است.

۱. استفاده از همه نمونه های منبع (Orj): برای آموزش مدل به جای انتخاب برخی از نمونه های منبع از همه نمونه های دامنه منبع استفاده شده است.

۲. حذف پارامتر تنظیم گراف ($SCDA_{\mu}$): با حذف این پارامتر

اهمیت نگهداری ساختار هندسی هر دامنه مشخص می شود.

با مقایسه نتایج به دست آمده در جدول ۴ می توان نتیجه گرفت که زمانی که از نمونه های انتخاب شده منبع برای ساخت مدل استفاده شود صحت مدل بالا می رود. به عنوان نمونه در پایگاه داده C_W زمانی که از کدگذاری تنک برای انتخاب نمونه ها استفاده شود، صحت مدل ۱/۰۲ افزایش می یابد.

زمانی که پارامتر μ که اهمیت به سزایی در حفظ ساختار هندسی دامنه ها در زیر فضای جدید دارد از الگوریتم حذف شود، صحت مدل به طور قابل توجهی پایین می آید. برای نمونه در پایگاه داده C_W با حذف پارامتر μ صحت مدل از ۴۳/۳۹٪ به ۳۷/۹۷٪ کاهش می یابد یعنی ۵/۴۲٪ عملکرد مدل کاهش می یابد، که این تأکیدی بر نگهداری ساختار هندسی دامنه ها می باشد.

۴-۶- اهمیت استفاده از تطبیق زیرفضا و اختلاف توزیع شرطی

در این بخش ضرورت تطبیق زیرفضاها و اختلاف توزیع شرطی با طراحی آزمایش بر روی پایگاه داده های آفیس و کالتک و اعداد بررسی شده و نتایج آن در صورت عدم استفاده از تطبیق زیرفضا ($SCDA_{-subspace}$) و عدم استفاده از اختلاف توزیع شرطی ($SCDA_{-conditional}$) در شکل ۱۰ نشان داده شده است. همان طور که در شکل مشاهده می شود کاهش اختلاف توزیع شرطی تأثیر قابل توجهی در هر دو پایگاه داده دارد. به عنوان نمونه در پایگاه داده اعداد صحت مدل از ۵۵/۶۷٪ به ۶۴/۳۱٪ افزایش یافته است یعنی مدل پیشنهادی با کاهش اختلاف توزیع شرطی بین دامنه ها ۸/۶۴٪ بهبود داشته است. همچنین، تأثیر تطبیق زیرفضا نیز به وضوح در شکل نمایان است. به عنوان نمونه در پایگاه داده آفیس و کالتک زمانی که زیرفضاها با یکدیگر تطبیق می یابند صحت مدل از ۴۳/۱۳٪ به ۴۹/۱۶٪ افزایش می یابد که افزایش ۶/۰۳٪ نشان دهنده اهمیت تطبیق زیرفضا می باشد.

۴-۷- ارزیابی نتایج

صحت عملکرد مدل پیشنهادی SCDA با هشت روش دیگر بر روی پایگاه داده های آفیس و کالتک و اعداد در جدول ۵ نشان داده شده است. همان طور که مشاهده می شود SCDA عملکرد قابل ملاحظه ای نسبت به جدیدترین روش ها در حوزه تطبیق دامنه بدون نظارت از خود نشان داده است.

جدول ۲: چهار پایگاه داده تطبیق دامنه بصری

پایگاه داده	تعداد نمونه ها	تعداد خصوصیات	تعداد کلاس ها	اختصار	دامنه
آفیس	۱۴۱۰	۸۰۰	۱۰	A, W, D	اشیا
کالتک-۲۵۶	۱۱۲۳	۸۰۰	۱۰	C	اشیا
USPS	۱۸۰۰	۲۵۶	۱۰	U	اعداد
MNIST	۲۰۰۰	۲۵۶	۱۰	M	اعداد

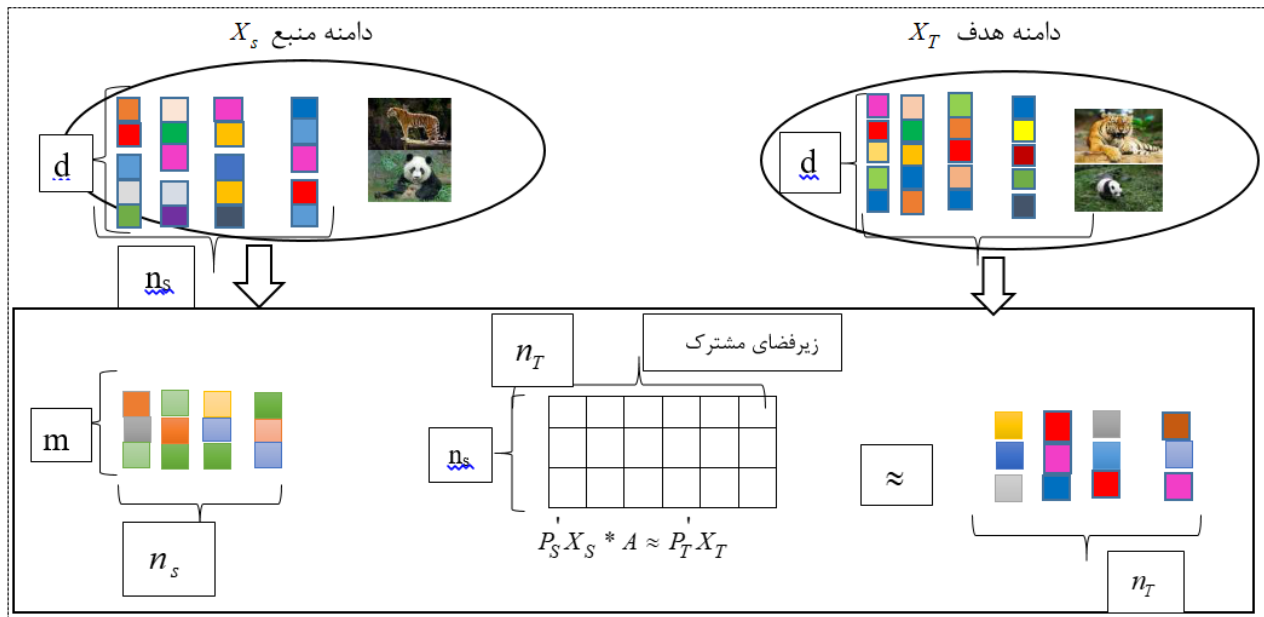
جدول ۳: مقادیر بهینه پارامترها برای دو پایگاه داده بصری (آفیس و کالتک، اعداد). k : ابعاد زیرفضای جدید، ρ : پارامتر تنظیم تنکی، δ

ضریب MMD:

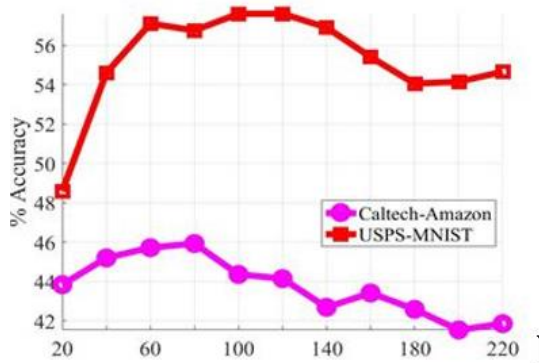
پارامترهای بهینه	k	ρ	δ
آفیس و کالتک	۶۰	۰/۰۰۵	۰/۰۰۱
اعداد	۶۰	۰/۰۰۵	۰/۵

جدول ۴: ضرورت هر پارامتر در الگوریتم

S-T	Orj	$SCDA_{\mu}$	SCDA
C-A	۴۴/۲۶	۴۳/۴۲	۴۴/۵۷
C-A #	۱۱۲۳	۱۱۲۳	۱۰۴۶
C-W	۴۲/۳۷	۳۷/۹۷	۴۳/۳۹
C-W#	۱۱۲۳	۱۰۶۹	۷۵۸

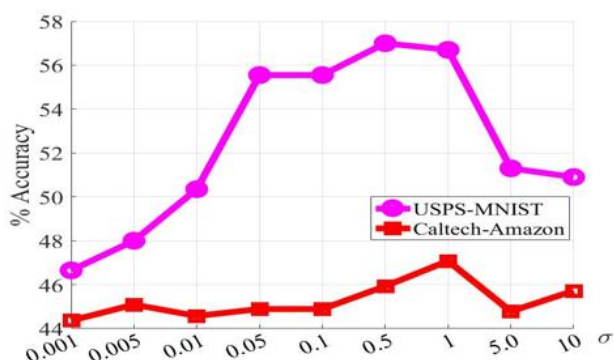


شکل ۳: انتخاب نمونه با استفاده از کدگذاری تنک در زیرفضای جدید. هر نمونه هدف X_T با ترکیب خطی تنک (A) از نمونه منبع X_S نمایش داده می‌شود.




شکل ۴: تصاویر نمونه از پایگاه داده آفیس و کالتک ۲۵۶

شکل ۶: ارزیابی صحت پایگاه داده‌های C_A و U_M با مقادیر مختلف پارامتر $k \times k$ ابعاد زیرفضای جدید



شکل ۷: ارزیابی صحت پایگاه داده‌های C_A و U_M با مقادیر مختلف پارامتر δ . δ ضریب MMD



شکل ۵: تصاویر نمونه از پایگاه داده اعداد

۴-۷-۱- مقایسه با روش‌های موجود

(۱) I-NN: در این روش ویژگی‌های اصلی بدون هیچ‌گونه تطبیقی مورد استفاده قرار می‌گیرند و برچسب نزدیک‌ترین همسایه با مقایسه داده آزمایش از دامنه هدف با داده آموزشی از دامنه انتخاب می‌شود. SCDA در پایگاه داده آفیس و کالتک ۱۷/۷۹٪ و در پایگاه داده اعداد ۸/۹۹٪ نسبت به NN بهبود داشته است و دلیل برتری آن هم نگاشت داده‌ها به یک زیرفضای مشترک می‌باشد.

دامنه چندمنبعی استفاده می‌شود. نتایج حاصل از آزمایش‌ها حاکی از بهبود ۱۶/۵۵٪ SCDA در پایگاه‌داده اعداد و ۶/۶۱٪ در پایگاه‌داده آفیس و کالتک است. از جمله دلایل بهبود SCDA نسبت به DAM کاهش اختلاف توزیع شرطی بین دامنه‌ها می‌باشد.


۶) GFK: GFK نیز یکی از روش‌های تطبیق دامنه می‌باشد که اختلاف توزیع حاشیه‌ای داده‌های منبع و هدف را کاهش می‌دهد. به این صورت که GFK داده‌های منبع و هدف را بر روی منیفولد گرسمن^{۴۰} نگاشت می‌کند. اما از آنجایی که GFK اندازه زیرفضا را کوچک در نظر می‌گیرد بخشی از داده‌های ورودی از بین می‌روند. متوسط بهبود صحت SCDA به ترتیب در پایگاه‌داده‌های اعداد و آفیس و کالتک، ۷/۴۷٪ و ۶/۲۱٪ است. دلیل برتری SCDA نسبت به GFK این است که SCDA با به‌کارگیری تطبیق خصوصیات، اختلاف توزیع شرطی را کاهش می‌دهد و علاوه بر آن با تطبیق زیرفضاهای به‌دست‌آمده نیز اختلاف توزیع بین دامنه منبع و هدف را کاهش می‌دهد.

۷) SA: یکی از روش‌های کاهش بعد در تطبیق بین دامنه‌ها است که زیرفضاهای به‌دست‌آمده را با یکدیگر تطبیق می‌دهد. در پایگاه‌داده اعداد، SCDA دارای ۱۱/۵۸٪ متوسط بهبود صحت نسبت به SA و در پایگاه‌داده آفیس و کالتک، دارای ۴/۴۴٪ متوسط بهبود صحت می‌باشد. دلیل بهبود SCDA نسبت به SA این است که از کدگذاری تنک برای انتخاب نمونه‌های منبع استفاده می‌کند.


۸) LRSR: LRSR برای حل مسأله یادگیری انتقالی از محدودیت‌های تنک و رتبه پایین^{۴۱} استفاده کرده است که داده‌های منبع و هدف به یک زیرفضای مشترک نگاشت داده می‌شوند که در آن اختلاف بین دو دامنه تا حد زیادی کاهش می‌یابد. در پایگاه‌داده اعداد، SCDA دارای ۸/۸۷٪ متوسط بهبود صحت نسبت به LRSR و در پایگاه‌داده آفیس و کالتک، دارای ۳/۷۷٪ متوسط بهبود صحت می‌باشد. مهم‌ترین دلیل برتری SCDA نسبت به LRSR، کاهش اختلاف توزیع شرطی بین دامنه‌ها می‌باشد. میانگین بهبود صحت کل SCDA نسبت به بهترین الگوریتم مورد مقایسه ۴/۴۹٪ می‌باشد. نمودارهای مربوط به مقایسه صحت طبقه‌بند بر روی ۱۴ پایگاه‌داده با تمام روش‌های مورد مقایسه در شکل ۱۱ نشان داده شده‌است.

۵- نتیجه‌گیری و کارهای آتی

در این مقاله، روش تطبیق دامنه بدون نظارت SCDA برای ایجاد تطبیق در دامنه‌های بصری و کاهش اختلاف توزیع شرطی بین دامنه‌ها پیشنهاد شده‌است. روش پیشنهاد شده در ابتدا با استفاده از کدگذاری تنک، برخی از نمونه‌های منبع را که شباهت بیشتری به نمونه‌های دامنه هدف دارند را انتخاب کرده و نمونه‌های غیرمرتبط از دامنه منبع را حذف می‌کند. SCDA برای کاهش اختلاف توزیع شرطی بین نمونه‌های انتخاب شده منبع و نمونه‌های هدف از روش غیرپارامتری MMD بهره می‌برد. علاوه بر این، SCDA با تطبیق زیرفضاهای ایجاد شده اختلاف توزیع بین زیرفضاها را به حداقل رسانده و با افزایش تطبیق‌پذیری بین ساختار



شکل ۸: تعداد نمونه‌های انتخاب‌شده از پایگاه‌داده U_M



شکل ۹: تعداد نمونه‌های انتخاب‌شده از پایگاه‌داده C_A

۲) PCA: این روش به‌منظور کاهش ابعاد مورد استفاده قرار می‌گیرد اما به دلیل این که اختلاف توزیع بین دامنه‌ها آن‌چنان کاهش نمی‌یابد، در تطبیق بین دامنه‌ها جایگاه چندانی ندارد. SCDA کارایی بهتری نسبت به PCA از خود نشان داده به‌طوری که در پایگاه‌داده اعداد ۸/۷۲٪ و در پایگاه‌داده آفیس و کالتک ۹/۵۱٪ بهبود داشته است. عمده‌ترین دلیل برتری SCDA استفاده از تطبیق خصوصیات برای کاهش اختلاف توزیع شرطی بین دامنه‌ها می‌باشد.


۳) TSL: این روش از جمله روش‌های کاهش بعد است که در کاهش اختلاف توزیع بین دامنه‌های منبع و هدف عملکرد خوبی از خود نشان نداده است و جایگاه پایینی بین روش‌های تطبیق دامنه دارا می‌باشد. میانگین بهبود صحت SCDA در پایگاه‌داده اعداد ۴/۴۱٪ و در پایگاه‌داده آفیس و کالتک ۶/۷۹٪ می‌باشد. دلیل بهبود SCDA نسبت به TSL استفاده از تطبیق خصوصیات برای کاهش اختلاف توزیع بین دامنه‌ها می‌باشد.

۴) TCA: TCA نیز از جمله روش‌های تطبیق دامنه بدون نظارت می‌باشد که فقط اختلاف توزیع حاشیه‌ای بین دامنه‌ها را کاهش می‌دهد و واریانس داده‌ها را به‌منظور حفظ ویژگی‌های داده‌های اصلی حداکثر می‌سازد. SCDA بهبود قابل‌ملاحظه‌ای نسبت به TCA از خود نشان داده است و در هر دو پایگاه‌داده اعداد و آفیس و کالتک به‌ترتیب ۱۰/۶۴٪ و ۶/۱۳٪ بهبود عملکرد داشته است. دلیل عملکرد بهتر آن نیز استفاده از کدگذاری تنک برای انتخاب نمونه‌ها و تطبیق خصوصیات برای کاهش اختلاف توزیع شرطی می‌باشد.


۵) DAM: یکی از روش‌های متداول تطبیق دامنه می‌باشد که مستقیماً با استفاده از طبقه‌بندهای پیشین یک طبقه‌بند برای تطبیق

یادگیری انتقالی بر روی دامنه‌های مختلف می‌باشد. SCDA با بهره‌گیری همزمان از وزن دهی داده‌ها و تطبیق خصوصیت عملکرد بسیار خوبی در مقایسه با روش‌های موجود از خود نشان می‌دهد. با این حال، تعداد پارامترهای آزاد SCDA زیاد می‌باشد که برای ادامه کار، با استفاده از روش‌هایی نظیر محدودیت رتبه پایین به مدیریت پارامترها خواهیم پرداخت.

دامنه‌های منبع و هدف، باعث افزایش صحت طبقه‌بند در پیش‌بینی برچسب برای داده‌های بدون برچسب دامنه هدف می‌شود. روش SCDA بر روی ۱۶ مجموعه داده بصری مورد آزمایش قرار گرفته که این مجموعه داده‌ها، دارای اختلاف توزیع قابل توجهی نسبت به یکدیگر هستند. نتایج به دست آمده نشان‌دهنده بهبود قابل ملاحظه‌ای از کارایی روش SCDA نسبت به جدیدترین روش‌های حوزه یادگیری ماشین و



شکل ۱۰: مقایسه کارایی روش پیشنهادی (SCDA) در صورت عدم استفاده از تطبیق زیرفضا (SCDA^{-subspace}) و عدم استفاده از اختلاف توزیع شرطی (SCDA^{-conditional}) (نمایش بهتر به صورت رنگی)



شکل ۱۱: صحت طبقه‌بندی در پایگاه داده‌های آفیس و کالتک و اعداد با استفاده از روش‌های NN، PCA، TSL، TCA، DAM، GFK، SA، LRSR و SCDA (نمایش بهتر به صورت رنگی)

جدول ۵: صحت (%) طبقه‌بندی تصویر بر روی ۱۶ پایگاه داده

SCDA	LRSR (2016)	SA (2013)	GFK (2012)	DAM (2012)	TCA (2011)	TSL (2010)	PCA (2002)	NN	Dataset
۵۷	۵۲/۳۳	۴۱/۵۰	۴۶/۴۵	۴۲/۶۹	۵۱/۰۵	۵۳/۷۵	۴۴/۹۵	۴۴/۷	USPS_MNIST
۷۱/۶۱	۵۸/۵۵	۶۳/۹۵	۶۷/۲۲	۵۲/۸۳	۵۶/۲۸	۶۶/۰۶	۶۶/۲۲	۶۵/۹۴	MNIST_USPS
۴۴/۵۷	۵۱/۲۵	۴۹/۲۷	۴۱/۰۲	۴۲/۶۹	۴۵/۸۲	۴۴/۴۷	۳۶/۹۵	۲۳/۷	C_A
۴۳/۳۹	۳۸/۶۴	۴۰	۴۰/۶۸	۳۴/۵۸	۳۰/۵۱	۳۴/۲۴	۳۲/۵۴	۲۵/۷۶	C_W
۵۵/۴۱	۴۷/۱۳	۳۹/۴۹	۳۸/۸۵	۳۳/۱۲	۳۵/۶۷	۴۳/۳۱	۳۸/۲۲	۲۵/۴۸	C_D
۴۰/۴۳	۴۳/۳۷	۳۹/۹۸	۴۰/۲۵	۳۵/۳۵	۴۰/۰۷	۳۷/۵۸	۳۴/۷۳	۲۶	A_C
۴۸/۸۱	۳۶/۶۱	۳۳/۲۲	۳۸/۹۸	۳۱/۸۶	۳۵/۲۵	۳۳/۹۰	۳۵/۵۹	۲۹/۸۳	A_W
۴۲/۰۴	۳۸/۸۵	۳۳/۷۶	۳۶/۳۱	۳۶/۳۱	۳۴/۳۹	۲۶/۱۱	۲۷/۳۹	۲۵/۴۸	A_D
۳۱/۴۳	۲۹/۸۳	۳۵/۱۷	۳۰/۷۲	۳۳/۸۴	۲۹/۹۲	۲۹/۸۳	۲۶/۳۶	۱۹/۸۶	W_C
۳۷/۳۷	۳۴/۱۳	۳۹/۲۵	۲۹/۷۵	۳۷/۵۸	۲۸/۸۱	۳۰/۲۷	۲۹/۳۵	۲۲/۹۶	W_A
۹۲/۳۶	۸۲/۸۰	۷۵/۱۶	۸۰/۸۹	۸۰/۸۹	۸۵/۹۹	۸۷/۲۶	۷۷/۰۷	۵۹/۲۴	W_D

۳۱/۴۳	۳۱/۶۱	۳۴/۵۵	۳۰/۲۸	۳۲/۴۱	۳۲/۰۶	۲۸/۵۰	۲۹/۶۵	۲۶/۲۷	D_C
۳۲/۸۸	۳۳/۱۹	۳۹/۸۷	۳۲/۰۵	۳۴/۳۴	۳۱/۴۲	۲۷/۵۶	۳۲/۰۵	۲۸/۵	D_A
۸۹/۸۳	۷۷/۲۹	۷۶/۹۵	۷۵/۵۹	۷۷/۶۳	۸۶/۴۴	۸۵/۴۲	۷۵/۹۳	۶۳/۳۹	D_W
۶۴/۳۱	۵۵/۴۴	۵۲/۷۳	۵۶/۸۴	۴۷/۷۶	۵۳/۶۷	۵۹/۹۰	۵۵/۵۹	۵۵/۳۲	متوسط صحت اعداد
۴۹/۱۶	۴۵/۳۹	۴۴/۷۲	۴۲/۹۵	۴۲/۵۵	۴۳/۰۳	۴۲/۳۷	۳۹/۶۵	۳۱/۳۷	متوسط صحت آفیس و کالنتک
۵۱/۳۲	۴۶/۸۳	۴۵/۸۶	۴۴/۹۳	۴۳/۳	۴۴/۵۵	۴۴/۸۷	۴۱/۹۳	۳۴/۷۹	متوسط صحت کل

مراجعه

[11] S. Satpal and S. Sarawagi, "Domain adaptation of conditional probability models via feature subsetting", Proceedings of PKDD, vol. 4702, pp. 224-235, 2007.

[12] J. Tahmoresnezhad and S. Hashemi, "Visual domain adaptation via transfer feature learning", KnowlInf Syst, vol. 50, no. 2, pp. 585-605, 2016.

[13] Ding, Z., & Fu, Y., "Robust transfer metric learning for image classification", IEEE Transactions on Image Processing, vol. 26, no. 2, pp. 660-670, 2017.

[14] Jolliffe I, "Principal component analysis", Wiley, vol. 2, pp. 433-459, 2002.

[15] مهرداد حیدری ارجلو، سید قدرت اله سیف السادات و مرتضی رزاز، «یک روش هوشمند تشخیص جزیره در شبکه توزیع دارای تولیدات پراکنده مبتنی بر تبدیل موجک و نزدیک‌ترین k -همسایگی (kNN)»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۳، شماره ۱، صفحات ۱۵-۲۶، ۱۳۹۲.

[16] 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, pp. 929-942, 2010.

[17] S. J. Pan, I. W. Tsang, J. T. Kwok and Q. Yang, "Domain adaptation via transfer component analysis", IEEE Trans. Neural Netw, vol. 22, no. 2, pp. 199-210, 2011.

[18] L. Duan, D. Xu, I. W. Tsang, "Domain adaptation from multiple sources: a domain-dependent regularization approach", IEEE Trans. Neural Netw. Learn. Syst, vol. 23, no. 3, pp. 504-518, 2012.

[19] B. Fernando, A. Habrard, M. Sebban, and T. Tuytelaars, "Unsupervised visual domain adaptation using subspace alignment", in Proc. IEEE International Conference on Computer vision, pp. 2960-2967, 2013.

[20] 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.

[1] J. Tahmoresnezhad and S. Hashemi, "A generalized kernel-based random k -sample sets method for transfer learning", Iran J Sci Technol Trans Electrical Eng, vol. 39, pp. 193-207, 2015.

[2] J. Tahmoresnezhad and S. Hashemi S, "An Efficient yet Effective Random Partitioning and Feature Weighting Approach for Transfer Learning", International Journal of Pattern Recognition and Artificial Intelligence, vol. 30, no. 2, pp. 1651003, 2016.

[3] طاهره زارع بیدکی و محمدتقی صادقی، «پهنه‌سازی وزن‌ها در کرنل مرکب برای طبقه‌بند مبتنی بر نمایش تنک کرنلی»، مجله مهندسی برق دانشگاه تبریز، جلد ۴۷، شماره ۳، صفحات ۱۰۵۹-۱۰۷۲، ۱۳۹۶.

[4] Pereira, L. A., & da Silva Torres, R. "Semi-supervised transfer subspace for domain adaptation", Pattern Recognition, 75, pp. 235-249, 2018.

[5] Ishii, M., & Sato, A, "Joint optimization of feature transform and instance weighting for domain adaptation", In Neural Networks (IJCNN), International Joint Conference on IEEE, pp. 3793-3799, 2017.

[6] B. Gong, Y. Shi, F. Sha and K. Grauman, "Geodesic flow kernel for unsupervised domain adaptation", Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 2066-2073, 2012.

[7] Cao, Y., Long, M., & Wang, J. "Unsupervised Domain Adaptation with Distribution Matching Machines", In AAAI Conference on Artificial Intelligence, 2018.

[8] Herath, S., Harandi, M. T., & Porikli, F. "Learning an Invariant Hilbert Space for Domain Adaptation", In CVPR, pp. 3956-3965, 2017.

[9] M. Ghifary, D. Balduzzi, W. B. Kleijn, and M. Zhang, "Scatter component analysis: A unified framework for domain adaptation and domain generalization", IEEE Transactions on Pattern Analysis and Machine Intelligence, pp. 1-1, 2016.

[10] B. Sun and K. Saenko. "Subspace distribution alignment for unsupervised domain adaptation", in Proc. British Machine Vision Conference, 2015.

زیر نویس‌ها

- ¹¹ Geodesic flow kernel
- ¹² Grassman manifold
- ¹³ Unsupervised Domain Adaptation with Distribution Matching Machines
- ¹⁴ Learning an Invariant Hilbert Space for Domain Adaptation
- ¹⁵ Scatter Component Analysis
- ¹⁶ Subspace Distribution Alignment
- ¹⁷ Domain adaptation of conditional probability models via feature subsetting
- ¹⁸ Visual Domain Adaptation via transfer feature learning
- ¹⁹ Robust Transfer Metric Learning for Image Classification
- ²⁰ Marginalized denoising strategy

- ¹ Domain shift
- ² Transfer learning
- ³ Maximum mean discrepancy (MMD)
- ⁴ Element mean
- ⁵ Prediction Error Minimization of Image Classification Models via Sparse Coding and Domain Adaptation
- ⁶ Nearest neighbor
- ⁷ Instance-based approaches
- ⁸ Feature-based approaches
- ⁹ Semi-supervised transfer subspace for domain adaptation
- ¹⁰ Joint optimization of feature transform and instance weighting for domain adaptation

-
- ²¹ Sparse coding
- ²² Principal component analysis
- ²³ Hilbert
- ²⁴ Manifold assumptions
- ²⁵ Laplacian matrix
- ²⁶ Riley's Theorem
- ²⁷ Orthonormal operations
- ²⁸ <http://www.berkeley.edu/~mfritz/domainadaptation/>
- ²⁹ http://www.vision.caltech.edu/Image_Datasets/Caltech256/
- ³⁰ Bregman Divergence-Based Regularization for Transfer Subspace Learning
- ³¹ Transfer component analysis
- ³² Domain Adaptation Machine Method
- ³³ Subspace Alignment
- ³⁴ Discriminative Transfer Subspace Learning via Low-Rank and Subspace Representation
- ³⁵ Amazon
- ³⁶ DSLR
- ³⁷ Webcam
- ³⁸ <http://www-i6.informatik.rwth-aachen.de/~keysers/usps.html>
- ³⁹ <http://yann.lecun.com/exdb/mnist/>
- ⁴⁰ Grassman manifold
- ⁴¹ Low rank