

پردازش تصویر بین‌دامنه‌ای با استفاده از تحلیل تفکیک خطی فیشر و واگرایی برگمن

مژده زندی فر^۱، دانشجوی کارشناسی ارشد؛ جعفر طهمورث نژاد^۲، استادیار

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

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

چکیده: پردازش تصویر روشی برای اعمال برخی عملیات‌ها بر روی تصویر، برای به‌دست‌آوردن تصاویری با کیفیت بالاتر یا استخراج برخی اطلاعات مفید می‌باشد. الگوریتم‌های سنتی پردازش تصویر در شرایطی که تصاویر آموزشی (دامنه منبع) که برای یاددهی مدل استفاده می‌شوند توزیع متفاوتی از تصاویر آزمایشی (دامنه هدف) داشته، نمی‌توانند عملکرد خوبی داشته. در واقع، وجود اختلاف توزیع شرطی بین دامنه‌های منبع و هدف، بازدهی مدل را کاهش می‌دهد. تطبیق دامنه و یادگیری انتقالی راه‌حل‌های امیدبخشی هستند که هدف آن‌ها تعمیم‌دادن یک مدل یادگیری بین داده‌های آموزشی و تست با توزیع‌های متفاوت است. در این مقاله، مسئله پردازش تصویر بین‌دامنه‌ای بدون نظارت مورد توجه قرار گرفته است که هیچ برچسبی برای داده‌های تست در دسترس نمی‌باشد. در واقع، روش پیشنهادی دامنه‌های منبع و هدف را به یک زیرفضای کم‌بعد مشترک براساس FLDA به‌صورت بدون نظارت منتقل می‌کند. روش پیشنهادی ما، اختلاف احتمال توزیع شرطی در داده‌های منبع و هدف را از طریق واگرایی برگمن حداقل می‌کند. یک ماتریس نگاشت به‌دست می‌آید که داده‌های منبع و هدف را به یک زیرفضای مشترک انتقال می‌دهد که در آن فضا ماتریس پراکندگی بین‌کلاسی حداکثر شده و ماتریس پراکندگی درون‌کلاسی و توزیع‌های بین‌دامنه‌ای حداقل می‌شود. آزمایشات متنوع بر روی ۵۸ عملیات طبقه‌بندی بین‌دامنه‌ای بر روی شش پایگاه‌داده همگانی نشان می‌دهد که روش پیشنهادی ما بهتر از روش‌های پردازش تصویر جدید ارائه شده در حوزه بین‌دامنه‌ای عمل می‌کند.

واژه‌های کلیدی: پردازش تصویر، یادگیری انتقالی، واگرایی برگمن، کاهش اختلاف توزیع شرطی، کاهش ابعاد.

Cross Domains Image Processing via Fisher Linear Discriminative Analysis and Bregman Divergence

M. Zandifar¹, MSc Student; J. Tahmoresnezhad², Assistant Professor

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

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

Abstract: Image processing is a method to perform some operations on an image, in order to get an enhanced image or to extract some useful information from it. The conventional image processing algorithms cannot perform well in scenarios where the training images (source domain) that are used to learn the model have a different distribution with test images (target domain). In fact, the existence of conditional distribution difference across the source and target domains degrades the performance of model. Domain adaptation and transfer learning are promising solutions that aim to generalize a learning model across training and test data with different distributions. In this paper, we address the problem of unsupervised cross domain image processing in which no labels are available in test images. In fact, the proposed method transfers the source and target domains into a shared low dimensional FLDA-based subspace in an unsupervised manner. Our proposed method minimizes the conditional probability distribution difference of the source and target data via Bregman divergence. We provide a projection matrix to map the source and target data into a common subspace on which the between class scatter matrix is maximized and within class scatter matrix and cross domain distributions are minimized. Extensive experiments on 58 cross-domain image classification tasks over six public datasets reveal that our proposed method outperforms the state-of-the-art cross domain image processing approaches.

Keywords: Image processing, transfer learning, bregman divergence, conditional distribution difference reduction, dimensionality reduction.

تاریخ ارسال مقاله: ۱۳۹۶/۱۰/۱۰

تاریخ اصلاح مقاله: ۱۳۹۷/۰۳/۲۸

تاریخ پذیرش مقاله: ۱۳۹۷/۰۶/۰۹

نام نویسنده مسئول: جعفر طهمورث نژاد

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

۱- مقدمه

کاربردهای دنیای واقعی، به دلیل این که هیچ نمونه برجسب‌دار از دامنه هدف در دسترس نیست، از تطبیق دامنه بدون نظارت استفاده می‌شود. اختلاف توزیع در یادگیری‌های بدون نظارت و نیمه‌نظارت‌شده، شامل اختلاف در توزیع حاشیه‌ای^۱ و توزیع شرطی^۲ 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 به‌ازای داده‌های یکسان از هر دو دامنه منبع و هدف، مجموعه برجسب‌های متفاوتی پیش‌بینی شود. در سیستم‌های یادگیری ماشین، وجود اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌های آموزشی و آزمایشی موجب می‌شود، مدل طبقه‌بند ایجادشده در دامنه منبع، دقت پایینی در پیش‌بینی برجسب‌های نمونه‌های دامنه هدف داشته باشد.

بسترهای داده‌ای که دارای ابعاد زیادی هستند علی‌رغم فرصت‌هایی که به‌وجود می‌آورند، چالش‌های محاسباتی زیادی را نیز تجربه می‌کنند. یکی از مشکلات داده‌های با ابعاد زیاد این است که در بیش‌تر مواقع تمام ویژگی‌های داده‌ها برای یافتن دانشی که در داده‌ها نهفته است مهم و حیاتی نیستند. به‌همین دلیل در بسیاری از زمینه‌ها از جمله در مسئله تطبیق دامنه، کاهش ابعاد داده یکی از مباحث قابل توجه است. روش‌های کاهش ابعاد داده به دو دسته کلی تقسیم می‌شوند [۴]:

(۱) روش‌های مبتنی بر استخراج ویژگی: این روش‌ها یک فضای چندبعدی را به یک فضای با ابعاد کمتر نگاهت می‌کنند. در واقع با ترکیب مقادیر ویژگی‌های موجود، تعداد کمتری ویژگی به‌وجود می‌آورند به طوری که این ویژگی‌ها دارای تمام (یا بخش اعظمی از) اطلاعات موجود در ویژگی‌های اولیه باشند. این روش‌ها به دودسته^۳ خطی و غیرخطی تقسیم می‌شوند.

(۲) روش‌های مبتنی بر انتخاب ویژگی: این روش‌ها سعی می‌کنند با انتخاب زیرمجموعه‌ای از ویژگی‌های اولیه، ابعاد داده‌ها را کاهش دهند. در پاره‌ای از اوقات تحلیل‌های داده‌ای نظیر طبقه‌بندی بر روی فضای کاسته‌شده نسبت به فضای اصلی بهتر عمل می‌کند.

روش‌های مبتنی بر استخراج ویژگی، یک فضای چندبعدی را به یک فضای با ابعاد کمتر نگاهت می‌دهند. این روش‌ها به دو دسته^۴ خطی و غیرخطی تقسیم می‌شوند. روش‌های خطی که ساده‌ترند و فهم آن‌ها راحت‌تر است به دنبال یافتن یک زیرفضای تخت محلی می‌باشند. از روش‌های خطی می‌توان به PCA^۵ و LDA^۶ اشاره کرد که آن‌ها را به ترتیب در ادامه توضیح خواهیم داد. از روش‌های غیرخطی نیز می‌توان به RP^۷ و ICA^۸ اشاره کرد [۵].

تکنیک PCA یکی از بهترین روش‌ها برای کاهش ابعاد داده به‌صورت خطی می‌باشد. یعنی با حذف ضرایب کم‌اهمیت به‌دست‌آمده

موجودات هوشمند با داشتن هوش طبیعی در تعامل با محیط یاد می‌گیرند که در برابر هر شرایطی از محیط چگونه رفتار کنند. در شاخه‌های مختلف هوش مصنوعی نیز سعی شده است که با الهام‌گرفتن از نحوه تعامل سیستم‌های هوشمند طبیعی با محیط، روش‌هایی برای توسعه سیستم‌های هوشمند مصنوعی ارائه شود. در اکثر الگوریتم‌های یادگیری ماشین و تشخیص الگو اغلب فرض می‌شود که داده‌های آموزشی^۱ و آزمایشی^۲ دارای توزیع مشابه و فضای ویژگی یکسانی هستند. باین‌حال، به دلیل فقدان داده‌های آموزشی برجسب‌دار جهت آموزش مدل در یک حوزه یا دامنه به‌ناچار از داده‌های برجسب‌دار دامنه‌های مرتبط دیگر استفاده می‌شود که موجب نقض فرض مدل‌های یادگیری ماشین شده و کارایی آن‌ها را کاهش می‌دهد [۱]. در چنین حالت‌هایی انتقال دانش یا یادگیری انتقالی با هدف ایجاد تطبیق بین دامنه‌ها پیشنهاد شده است. هدف یادگیری انتقالی، استخراج دانش از یک یا چند دامنه منبع مرتبط و اعمال دانش به‌دست‌آمده به دامنه هدف است. یادگیری انتقالی می‌تواند مدل‌هایی را ایجاد یا تطبیق دهد که نیاز به هزینه‌های اضافی جهت بازسازی یا مقاوم‌سازی نداشته باشند.

مثال‌های زیادی در مهندسی دانش می‌توان یافت که یادگیری انتقالی می‌تواند در آن زمینه‌ها سودمند واقع شود. یکی از این مثال‌ها دسته‌بندی اسناد وب است [۲]، که هدف آن‌ها دسته‌بندی صفحات وب به دسته‌های مختلف از پیش‌تعیین شده می‌باشد. به‌عنوان مثال، در حوزه دسته‌بندی اسناد وب ممکن است نمونه‌های برجسب‌دار مربوط به یک سایت دانشگاهی باشند که آن صفحات وب با دسته اطلاعاتی که از طریق برجسب‌گذاری دستی قبلی به‌دست آمده‌اند در ارتباط باشند. حال اگر روی وب‌سایت دیگری که جدیداً ساخته‌شده عملیات دسته‌بندی انجام شود، وضعیت ایجاد می‌شود که ویژگی داده‌ها و یا نحوه توزیع داده‌ها با نمونه‌های برجسب‌دار موجود متفاوت است. در نتیجه، چنین حالتی ممکن است منجر به کمبود داده‌های آموزشی برجسب‌دار گردد. بنابراین طبقه‌بند صفحه وبی که روی صفحات وب دانشگاه آموزش دیده شده است را نمی‌توان مستقیماً به صفحه وب دیگری اعمال کرد. در مواردی از این قبیل، استفاده از یادگیری انتقالی جهت انتقال دانش به‌دست‌آمده به حوزه جدید سودمند خواهد بود.

روش‌های یادگیری انتقالی بسته به نوع دامنه هدف به دو دسته تقسیم می‌شود: (۱) یادگیری بدون نظارت^۳ و (۲) یادگیری نیمه‌نظارت‌شده^۴؛ یادگیری بدون نظارت هنگامی است که همه داده‌های دامنه منبع^۵ دارای برجسب بوده و تمامی داده‌های دامنه هدف^۶ بدون برجسب هستند. یادگیری نیمه‌نظارت‌شده هنگامی است که همه داده‌های دامنه منبع برجسب دارند و فقط برخی داده برجسب‌دار از دامنه هدف در دسترس است و اغلب این داده‌ها برای ایجاد یک طبقه‌بند خوب، به‌صورت مستقل مناسب نیستند [۳]. در بسیاری از

است. در مرحله اول، سعی شده‌است 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 باهم داشته. CIFAB تابع چگالی احتمال داده‌های آموزشی و تست را در زیرفضای نگاشت‌شده با استفاده از روش برآورد تراکم هسته^{۲۳} تخمین می‌زند و سپس واگرایی برگمن با انتقال اطلاعات به‌دست‌آمده از دامنه منبع، اختلاف توزیع شرطی بین دامنه‌ها را به‌طور قابل‌ملاحظه‌ای کاهش می‌دهد. در مرحله دوم CIFAB از دو طبقه‌بند استاندارد نزدیک‌ترین همسایه^{۲۴} (NN) [۷] و ماشین بردار پشتیبان^{۲۵} (SVM) به‌صورت مجزا برای پیش‌بینی برچسب نمونه‌های تست استفاده می‌کند.

کارایی روش پیشنهادشده در این مقاله، بر روی پایگاه‌داده‌های شناخته‌شده بصری تحت شرایط مختلف مورد آزمایش قرار گرفته و نتایج آن‌ها، با جدیدترین روش‌ها در حوزه یادگیری انتقالی مقایسه شده‌است. نتایج حاصل، نشان‌دهنده برتری قابل‌ملاحظه الگوریتم پیشنهادی نسبت به روش‌های شناخته‌شده در حوزه یادگیری انتقالی است.

ساختار ادامه مقاله به‌صورت زیر است. در بخش ۲ پژوهش‌های مرتبط مورد بررسی قرار می‌گیرند. در بخش ۳ تعاریف و روش پیشنهادی گنجانده شده‌است. 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 شده‌است.

۲- کارهای پیشین

در حوزه یادگیری ماشین روش‌های بسیاری در زمینه تطبیق دامنه‌ها پیشنهاد شده‌است که تمرکز بیشتر آن‌ها بر کاهش اختلاف توزیع بین دامنه‌های منبع و هدف می‌باشد. به‌طور کلی روش‌های موجود در تطبیق دامنه‌ها به سه دسته کلی تقسیم می‌شوند. (۱) روش‌های مبتنی بر نمونه^{۲۶} [۸]، (۲) روش‌های مبتنی بر خصوصیت^{۲۷} [۹] و (۳) روش‌های مبتنی بر مدل^{۲۸} [۱۰].

رویکردهای مبتنی بر نمونه براساس وزن‌دهی مجدد نمونه‌ها و یا انتخاب نمونه‌هایی که تفاوت بین توزیع دامنه‌های منبع و هدف را حداقل می‌سازند، عمل می‌کنند. TJM [۱۱] یکی از الگوریتم‌های شاخص در این دسته است. عملکرد TJM به این صورت است که داده‌های منبعی که با داده‌های هدف اختلاف توزیع دارند کنار گذاشته می‌شوند یا ارزش آن‌ها کم می‌شود و روی داده‌های منبعی که از لحاظ توزیع به داده‌های هدف نزدیک‌ترند مدل ایجاد می‌شود. ایراد روش TJM این است که اولاً نیاز دارد یک کرنل نسبتاً پیچیده‌ای را در زمان آزمایش محاسبه کند، ثانیاً TJM به یک تابع هدف پیچیده نیاز دارد و ثالثاً چون TJM یک بخشی از داده‌ها را حذف می‌کند نمی‌تواند خاصیت داده‌ها را حفظ کند.

از این تبدیل، اطلاعات از دست‌رفته نسبت به روش‌های دیگر کمتر است. البته کاربرد PCA محدود به کاهش ابعاد داده نمی‌شود و در زمینه‌های دیگری مانند شناسایی الگو و تشخیص چهره نیز مورد استفاده قرار می‌گیرد. در این روش محورهای مختصات جدیدی برای داده‌ها تعریف شده و داده‌ها براساس این محورهای مختصات جدید بیان می‌شوند. اولین محور باید در جهتی قرارگیرد که واریانس داده‌ها بیشینه شود (یعنی در جهتی که پراکندگی داده‌ها بیش‌تر است). دومین محور باید عمود بر محور اول به‌گونه‌ای قرارگیرد که واریانس داده‌ها بیشینه شود. به‌همین ترتیب محورهای بعدی عمود بر تمامی محورهای قبلی به‌گونه‌ای قرار می‌گیرند که داده‌ها در آن جهت دارای بیش‌ترین پراکندگی باشند.

یکی دیگر از روش‌های قدرتمند در تکنیک‌های کاهش بعد، LDA یا تحلیل جداسازی خطی است. LDA یکی از روش‌های کلاسیک در زمینه کاهش ابعاد و استخراج ویژگی می‌باشد که به‌صورت گسترده در مسائل طبقه‌بندی مورد استفاده قرار می‌گیرد. این روش به‌دنبال یافتن یک ماتریس تبدیل بهینه است و بدین‌منظور از دو ماتریس پراکندگی درون‌کلاسی و بین‌کلاسی استفاده می‌کند. برای یافتن یک ماتریس بهینه باید نسبت بین ماتریس پراکندگی بین‌کلاسی و ماتریس پراکندگی درون‌کلاسی، کمینه گردد.

هنگامی که توزیع نمونه‌های تست و نمونه‌های آموزشی متفاوت از یکدیگر باشند، کاهش بعد به‌تنهایی پاسخگوی مسئله تغییر دامنه‌ها نیست زیرا از اطلاعات اولیه^{۲۹} تفاوت بین توزیع نمونه‌های تست و نمونه‌های آموزشی چشم‌پوشی می‌کند و این باعث زیادآموزی^{۳۰} نمونه‌های آموزشی در بعد جدید می‌شود. برای اجتناب از این مشکل باید در اطلاعات اولیه، اختلاف توزیع بین دامنه‌ها نیز در نظر گرفته شود، بنابراین برای سنجش و کاهش اختلاف توزیع بین دامنه‌های منبع و هدف، به یک معیار جهت اندازه‌گیری فاصله نیاز است. واگرایی برگمن^{۱۴} [۶] یک واگرایی جامع می‌باشد که تعداد زیادی از فواصل معروف و پرکاربرد از جمله تابع هزینه جمع مربعات^{۱۵}، واگرایی کولیک - لایبلر^{۱۶}، تابع هزینه منطقی^{۱۷}، فاصله مالهالانوبیس^{۱۸} را شامل می‌شود. واگرایی برگمن به‌وسیله کاهش تفاوت بین توزیع نمونه‌های آموزشی و تست می‌تواند دانش تفکیک‌کننده به‌دست‌آمده از نمونه‌های آموزشی را به نمونه‌های تست انتقال دهد. همچنین واگرایی برگمن، اطلاعات تفکیک‌کننده به‌دست‌آمده از نمونه‌های آموزشی را برای تفکیک‌پذیری هرچه بهتر کلاس‌های دامنه هدف، حفظ می‌کند. در روش پیشنهادی برای ایجاد تطبیق بین دامنه‌ها از روش‌های تطبیق خصوصیات استفاده می‌شود. روش‌های تطبیق خصوصیات، الگوریتم‌هایی هستند که می‌توانند نمایش خصیصه‌ای^{۱۹} نمونه‌ها در فضای اصلی^{۲۰} یا در فضای پنهان^{۲۱} را تغییر دهند؛ این نوع الگوریتم‌ها در بخش‌های بعدی به‌تفصیل توضیح داده می‌شوند.

روش پیشنهادی در این مقاله با عنوان CIFAB^{۲۲} یک روش دومرحله‌ای با بهره‌گیری از تطبیق خصوصیات و یک طبقه‌بند استاندارد

انتقال می‌یابد که در این حالت، طبقه‌بند آموزش‌داده‌شده در دامنه منبع دارای عملکرد بهتری در پیش‌بینی برچسب داده‌های دامنه هدف خواهد بود. هدف از این تحقیق ارائه راه‌حلی است که بتواند بر محدودیت‌های الگوریتم‌های کلاسیک یادگیری ماشین غلبه کرده و بازدهی روش‌های یادگیری انتقالی را افزایش دهد.

۳-۲- تعریف مسئله

در این بخش، مفاهیم و تعاریف اصلی برای حل مشکل شیفت دامنه‌ها ارائه شده و در ادامه تعریف مسئله به‌طور کامل شرح‌داده شده‌است. در مسائل یادگیری انتقالی، هر دامنه شامل دو مفهوم کلی فضای خصیصه‌ای X و توزیع احتمال حاشیه‌ای $P(x)$ برای هر $x \in X$ می‌باشد، 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، به‌طور 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 T 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 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 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 دامنه‌های منبع و هدف باشند. در تطبیق دامنه بدون نظارت، تمام نمونه‌های دامنه منبع دارای برچسب هستند که به صورت $D_S = \left\{ (\vec{x}_1, y_1), \dots, (\vec{x}_l, y_l) \right\}$ تعریف می‌شوند و تمام نمونه‌های بدون برچسب دامنه هدف به صورت $D_T = \left\{ \vec{x}_{l+1}, \dots, \vec{x}_{l+u} \right\}$ 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 شرطی 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 می‌شود که ماتریس نگاشت W با ابعاد $W \in R^{D \times d}$ و $\vec{y} \in R^d$ تعریف می‌شوند. مقدار بهینه W به صورت زیر محاسبه می‌شود:

روش‌های مبتنی بر خصوصیت یا تطبیق خصوصیات، فضای خصیصه‌ای را برای ایجاد یک نمایش تطبیق‌پذیر از دامنه‌های منبع و هدف تغییر می‌دهند. سپس در فضای جدید، یک طبقه‌بند استاندارد روی داده‌های دامنه منبع، آموزش داده و به دامنه هدف اعمال می‌کنند. VDA [۱۲] از جمله روش‌های بدون نظارت مبتنی بر خصوصیت 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.

هدف روش‌های مبتنی بر مدل پیدا کردن یک طبقه‌بند انطباقی است که عملکرد خوبی در دامنه هدف داشته‌باشد. این کار توسط انتقال پارامترهای مدل آموزش‌داده‌شده روی دامنه منبع به دامنه هدف، بدون تغییر فضای خصیصه‌ای انجام می‌شود. یکی از روش‌های پیشنهادی در این زمینه، روش ARTL [۱۳] است که هدف آن ایجاد یک طبقه‌بند انطباقی توسط کاهش خطای طبقه‌بند در دامنه منبع، افزایش انطباق هندسی دامنه‌ها در فضای جدید و ایجاد تطبیق در توزیع مشترک بین دامنه‌ها می‌باشد.

در این مقاله، برای حل مسئله یادگیری‌های انتقالی بدون نظارت، یک چارچوب دومرحله‌ای با ترکیبی از روش‌های مبتنی بر خصوصیات و الگوریتم‌های طبقه‌بندی کلاسیک یادگیری ماشین پیشنهاد داده می‌شود. در مرحله اول، داده‌های دامنه منبع و دامنه هدف توسط یک روش تطبیق خصوصیات، به فضای جدید که در آن اختلاف توزیع شرطی بین دامنه‌های منبع و هدف، به‌طور هم‌زمان حداقل شده، نگاشت می‌شوند و سپس در مرحله بعدی برای پیش‌بینی برچسب نمونه‌های دامنه هدف از طبقه‌بندهای کلاسیک یادگیری ماشین استفاده می‌شود.

۳- روش پیشنهادی


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

۳-۱- هدف تحقیق

این مقاله به دنبال آن است که روشی برای دسته‌بندی تصاویر یا متون ارائه‌کند تا کاربران با اطمینان از برچسب نسبت‌داده‌شده به هر تصویر، بتوانند در کاربردهای مختلف از آن تصاویر استفاده کنند. بدین ترتیب، با استفاده از روش‌های تطبیق خصوصیات، یک نمایش کم‌بعد از داده‌های دامنه‌های منبع و هدف ایجاد می‌شود که در این نمایش، اختلاف توزیع شرطی بین دامنه‌های منبع و هدف، حداقل می‌شود. علاوه بر آن، اطلاعات تفکیک‌کننده بین دامنه‌ها به صورت حداکثری

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 به‌دست‌آید. در تصویر (۱) واگرایی برگمن بین دو نقطه x و y وابسته به تابع ϕ نشان داده شده‌است. 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 اکیداً 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 براساس واگرایی برگمن به‌فرم رابطه (۳) تعریف می‌گردد:

$$\begin{aligned} d_\phi(x, y) &= \langle x, x \rangle - \langle y, y \rangle - \langle x - y, \nabla \phi(y) \rangle \\ &= \langle x, x \rangle - \langle y, y \rangle - \langle x - y, 2y \rangle = \langle x - y, x - y \rangle \\ &= \|x - y\|^2 \end{aligned} \quad (3)$$



شکل ۱: واگرایی برگمن بین دو نقطه x و y . بردار گرادیان در نقطه y می‌باشد و d_ϕ میزان خطا در تخمین تابع ϕ در نقطه y را محاسبه می‌کند.

با توجه به رابطه (۲)، واگرایی برگمن براساس تنظیم جدید که فاصله بین P_t و P_s را بر طبق فاصله مربع اقلیدسی محاسبه می‌کند به‌صورت زیر تعریف می‌شود:

$$\begin{aligned} D_W(P_s \| P_t) &= \int (P_s(\bar{y}) - P_t(\bar{y}))^2 d\bar{y} \\ &= \int (P_s(\bar{y})^2 - 2P_s(\bar{y})P_t(\bar{y}) + P_t(\bar{y})^2) d\bar{y} \end{aligned} \quad (4)$$

در آمار و احتمال، برآورد تراکم هسته به فرآیند تخمین تابع چگالی احتمال یک متغیر تصادفی با استفاده از نمونه‌های مشاهده‌شده از آن متغیر گفته می‌شود. معمولاً فرض می‌شود نمونه‌های مشاهده‌شده به‌طور تصادفی و مستقل براساس تابع توزیع احتمال، توزیع شده‌اند. برای تخمین مقادیر P_t و P_s از روش برآورد تراکم هسته استفاده می‌شود که تراکم را در $y \in R^d$ به‌عنوان مجموع کرنل‌های بین y و

هر نمونه \bar{y}_i تخمین می‌زند، به‌عنوان مثال $p(\bar{y}) = \frac{1}{n} G_{\sum}(\bar{y} - \bar{y}_i)$ که در آن n تعداد نمونه‌ها، $G_{\sum}(\bar{y})$ کرنل گوسی d بعدی با ماتریس کوواریانس Σ می‌باشد و n_s^c و n_t^c به ترتیب تعداد نمونه‌های

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

درواقع داده‌ها با کمک ماتریس نگاشت W^* از فضای اصلی به یک زیرفضا با ابعاد کمتر منتقل می‌شوند به‌شرطی که تابع هدف $F(W)$ حداقل شود و شرط $W^T W = I$ برآورده شود. این شرط نشان‌دهنده 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 در مجموعه جواب قرار نمی‌گیرند.


۳-۳- چهارچوب کلی

در یادگیری انتقالی یافتن یک راه‌حل برای کاهش اختلاف توزیع بین دامنه‌های منبع و هدف یک اصل اساسی و مهم است. هدف این مقاله، ارائه یک چهارچوب دو مرحله‌ای برای کاهش اختلاف توزیع شرطی بین دامنه‌های منبع و هدف می‌باشد. روش‌های زیادی برای یادگیری یک نمایش خصیصه تطبیق‌پذیر جهت کاهش اختلاف توزیع بین دامنه‌های منبع و 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 نگاشت‌شده منتقل می‌شوند به‌طوری که تابع هدف آن‌ها در زیرفضا (هزینه بازگرداندن داده‌ها به فضای اولیه) حداقل شود. روش FLDA^۹ یکی از بهترین روش‌ها برای کاهش بعد و دسته‌بندی به‌طور هم‌زمان است که در ادامه با جزئیات کامل معرفی می‌شود ولی پیش از آن، واگرایی برگمن به‌عنوان یک معیار اندازه‌گیری فاصله بین دو دامنه معرفی می‌شود.

واگرایی برگمن، دامنه گسترده‌ای از فاصله‌ها از جمله فاصله اقلیدسی، واگرایی KL، فاصله ماهالانوبیس را در برمی‌گیرد. از این رو برای محاسبه فاصله بین توزیع داده‌های دامنه منبع و هدف مناسب می‌باشد. مربع فاصله اقلیدسی یکی از پراستفاده‌ترین معیارهای واگرایی برگمن است که پیچیدگی زمانی کمتری نسبت به سایر روش‌های واگرایی برگمن داشته و با استفاده از تخمین توزیع داده‌های ورودی میزان اختلاف توزیع نمونه‌های منبع و هدف را محاسبه می‌نماید. این درحالی است که معیارهای دیگر واگرایی برگمن نظیر ماهالانوبیس از پیچیدگی زمانی بالایی برخوردار بوده و نیاز دارند تا توزیع دقیق داده‌ها را برای محاسبه فاصله بین دامنه‌های ورودی داشته. در تصویر (۱) واگرایی برگمن بین دو نقطه x و y وابسته به تابع ϕ نشان داده شده‌است. واگرایی برگمن به تابعی محدب و مشتق‌پذیر $\phi: X \rightarrow R$ یک تابع نگاشت از X به R وابسته است. واگرایی برگمن d که به تابع ϕ وابسته است بر روی مجموعه X بین نقاط $x, y \in X$ به‌صورت 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 $\langle \cdot, \cdot \rangle$ ضرب داخلی دو بردار است. برای به‌دست‌آوردن واگرایی برگمن، نقاط x و y با تابع ϕ بر روی بردار گرادیان تابع در نقطه y تصویر می‌شوند.



شکل ۲: مقایسه نگاشت داده‌های ورودی با استفاده از روش‌های FLDA و CIFAB. در زیرفضای ایجادشده توسط الگوریتم FLDA کلاس‌های ۱ و ۲ با یکدیگر هم‌پوشانی قابل‌ملاحظه‌ای دارند، درحالی‌که در زیرفضای ایجادشده توسط CIFAB تفکیک‌پذیری کلاس‌های مختلف افزایش یافته و طبقه‌بندی با دقت بالاتری انجام می‌گیرد.

ساختار کلاس داده‌ها با S_B ، ماتریس پراکندگی بین‌کلاس و S_W ، ماتریس پراکندگی درون‌کلاس توصیف می‌شود. بیان‌گر تغییرات بردارهای امید برای هر زوج کلاس می‌باشد درحالی‌که S_W پراکندگی نمونه‌ها حول بردار امید کلاس آن نمونه داده‌ها می‌باشد. از لحاظ ریاضی ماتریس پراکندگی بین‌کلاس و ماتریس پراکندگی درون‌کلاس به ترتیب به صورت زیر تعریف می‌شوند:

$$S_B = \sum_{i=1}^C n_i (\bar{m}^{(i)} - \bar{m})(\bar{m}^{(i)} - \bar{m})^T \quad (7)$$

$$S_W = \sum_{i=1}^C \sum_{j=1}^{n_i} (x_j^{(i)} - \bar{m}^{(i)})(x_j^{(i)} - \bar{m}^{(i)})^T \quad (8)$$

که در آن C تعداد کلاس‌ها، n_i تعداد نمونه‌های کلاس i ام، $m^{(i)}$ میانگین نمونه‌های کلاس i ام و m میانگین کل نمونه‌ها است. در این روش سعی می‌شود به‌طور هم‌زمان $Det(S_W)$ حداقل و $Det(S_B)$ حداکثر گردد. یکی از مناسب‌ترین معیارها جهت بیان تفکیک‌پذیری کلاس‌ها استفاده از تریس^{۳۰} ماتریس می‌باشد که به‌صورت زیر تعریف می‌شود:

$$\operatorname{argmax} \frac{\operatorname{tr}(W^T S_B W)}{\operatorname{tr}(W^T S_W W)} = \operatorname{argmin} \frac{\operatorname{tr}(W^T S_W W)}{\operatorname{tr}(W^T S_B W)} \quad (9)$$

پس درواقع تابع هدف الگوریتم FLDA برابر است با:

$$F(W) = \operatorname{tr}^{-1}(W^T S_B W) \operatorname{tr}(W^T S_W W) \quad (10)$$

که $\operatorname{tr}^{-1}(X)$ معکوس $\operatorname{tr}(X)$ می‌باشد.

۳-۳-۲- تحلیل خطی براساس فیشر انتقال یافته جهت انطباق

توزیع شرطی

نکته مهم درمورد روش FLDA این است که در مسائلی مانند تشخیص الگو و طبقه‌بندی تصویر که با ابعاد بزرگ داده مواجه است، ممکن است ماتریس نگاشت W روی داده‌های آموزشی دچار بیش‌برازش شود.

کلاس C دامنه منبع و هدف هستند. باجای‌گذاری KDE در رابطه (۴) خواهیم داشت:

$$D_W(P_s \| P_t) = \int \left(\frac{1}{n_s^c} \sum_{i=1}^{n_s^c} G_{\Sigma_1}(\bar{y} - \bar{y}_i) \right)^2 d\bar{y} + \int \left(\frac{1}{n_t^c} \sum_{j=t+1}^{n_t^c} G_{\Sigma_2}(\bar{y} - \bar{y}_j) \right)^2 d\bar{y} - \int \left(\frac{2}{n_s^c n_t^c} \sum_{i=1}^{n_s^c} \sum_{j=t+1}^{n_t^c} G_{\Sigma_1}(\bar{y} - \bar{y}_i) G_{\Sigma_2}(\bar{y} - \bar{y}_j) \right) d\bar{y} \quad (5)$$

که برای دو کرنل گوسی دلخواه داریم، $\int G_{\Sigma_1}(\bar{y} - \bar{y}_s) G_{\Sigma_1}(\bar{y} - \bar{y}_t) d\bar{y} = G_{\Sigma_1 + \Sigma_2}(\bar{y} - \bar{y}_s)$ در این رابطه Σ_1 ماتریس کوواریانس نمونه‌های دامنه منبع و Σ_2 ماتریس کوواریانس نمونه‌های دامنه هدف می‌باشند. بنابراین می‌توان در رابطه (۵) مقادیر را ادغام کرده تا درنهایت به رابطه (۶) رسید.

$$D_W(P_s \| P_t) = \frac{1}{(n_s^c)^2} \sum_{s=1}^{n_s^c} \sum_{t=1}^{n_t^c} G_{\Sigma_{11}}(\bar{y}_s - \bar{y}_t) + \frac{1}{(n_t^c)^2} \sum_{s=n_s^c+1}^{n_s^c+n_t^c} \sum_{t=n_s^c+1}^{n_t^c+n_s^c+1} G_{\Sigma_{22}}(\bar{y}_s - \bar{y}_t) - \frac{1}{n_s^c n_t^c} \sum_{s=1}^{n_s^c} \sum_{t=n_s^c+1}^{n_t^c+n_s^c+1} G_{\Sigma_{12}}(\bar{y}_s - \bar{y}_t) \quad (6)$$

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

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

FLDA یک روش انتقال داده‌ها به فضای کم‌بعد است که ایده اصلی آن، حفظ ساختار کلاس‌ها برای طبقه‌بندی می‌باشد. الگوریتم FLDA یک روش کاهش بعد است که داده‌های ورودی را به یک زیرفضای مشترک کم بعد بین دامنه‌های منبع و هدف نگاشت می‌کند. FLDA در مدل‌های کلاسیک یادگیری ماشین در شرایطی که داده‌های منبع و هدف از توزیع یکسانی برخوردار باشند، بازدهی خوبی از خود نشان داده‌است. اما همان‌طور که در شکل ۲ قابل مشاهده است، FLDA در مواجهه با مسائل تغییر دامنه‌ها از تفکیک کلاس‌های مختلف در فضای نگاشت‌شده ناتوان می‌باشد. از این‌رو در این مقاله، روش CIFAB پیشنهاد می‌شود که با افزودن یک معیار تنظیم فاصله با استفاده از واگرایی برگمن به FLDA آن را در مواجهه با مسائل شیفت دامنه‌ها توانمندتر می‌سازد. درواقع روش پیشنهادشده در این مقاله، زیرفضای مشترک بین دامنه‌ای را به‌نحوی به‌دست می‌آورد که فاصله توزیع داده‌های منبع و هدف حداقل شده و تفکیک‌پذیری کلاس‌های مختلف حداکثر شود.

$$\frac{\partial F(W)}{\partial W} = 2tr^{-1}(W^T S_B W) S_W W - 2tr^{-2}(W^T S_B W) tr(W^T S_W W) S_B W \quad (14)$$

با توجه به رابطه (۶) مشتق $D_W(P_S \| P_T)$ را برحسب W که اختلاف توزیع شرطی بین دامنه‌های منبع و هدف را به‌ازای کلاس‌های مختلف کاهش می‌دهد را می‌توان به‌صورت زیر نوشت:

$$\sum_{i=1}^{n_s+n_t} \frac{\partial D_W(P_S \| P_T)}{\partial \bar{y}_i} \frac{\partial \bar{y}_i}{\partial W} = \sum_{i=1}^{n_s} \frac{D_W(P_S \| P_T)}{\partial \bar{y}_i} \bar{x}_i^T + \sum_{i=1}^{n_s+n_t} \frac{D_W(P_S \| P_T)}{\partial \bar{y}_i} \bar{x}_i^T \quad (15)$$

بنابراین براساس روابط (۱۰) و (۱۴) می‌توان الگوریتم‌های یادگیری زیرفرض را توسعه داده به‌طوری که مسئله شیفت دامنه‌ها را دربرگیرند، همچنین عملکرد خوبی بر روی دامنه‌های مختلف داشته. درنهایت پس از نگاشت داده‌های منبع و هدف به یک زیرفرض که اختلاف توزیع شرطی بین دامنه‌ها کمینه است با استفاده از طبقه‌بندهای کلاسیک NN و SVM به‌طور مجزا برچسب نمونه‌های هدف پیش‌بینی می‌شوند.

۴- تنظیمات اولیه محیط آزمایش

در این بخش، مجموعه داده‌های ارزیابی شده، الگوریتم‌های مورد مقایسه و مفروضات پیاده‌سازی شرح داده می‌شود.

۴-۱- معرفی مجموعه داده‌ها

کارایی روش پیشنهاد شده در این مقاله بر روی شش پایگاه داده بصری شناخته شده ارزیابی شده است: (۱) پایگاه داده آفیس [۱۴] و کالتک [۱۵] که شامل تصاویر اشیای جمع‌آوری شده از دامنه‌های وبکم، آمازون، دی اس ال آر و کالتک می‌باشد که تصاویر در این دامنه‌ها از نظر شرایط نور و پس‌زمینه با یکدیگر تفاوت قابل توجهی دارند. برای پایگاه داده آفیس، ۱۲ آزمایش طراحی شده است که در هر یک از آزمایش‌ها یکی از مجموعه داده‌ها (برای مثال وبکم)، به‌عنوان دامنه منبع و یکی دیگر از مجموعه داده‌ها (برای مثال آمازون) به‌عنوان دامنه هدف انتخاب می‌شوند. (۲) پایگاه داده اعداد که شامل دو دامنه از تصاویر اعداد دست‌نویس انگلیسی می‌باشد. این پایگاه داده شامل دو مجموعه داده USPS [۱۶] و MNIST [۱۷] می‌باشد که با طراحی دو آزمایش، در یکی از آن‌ها، USPS دامنه منبع و MNIST دامنه هدف (U_M) و در آزمایش دیگر بالعکس (M_U) می‌باشد، که کارایی الگوریتم در هر دو حالت مختلف مورد ارزیابی قرار گرفته است. (۳) مجموعه داده پای [۱۸]، از مجموعه پایگاه داده‌های شناخته شده برای مسئله تطبیق دامنه‌های بصری در زمینه تشخیص چهره است که شامل ۴۱۳۶۸ تصویر چهره از ۶۸ فرد مختلف است. پنج دامنه در این پایگاه داده وجود دارد که هر کدام مربوط به یک حالت تصویربرداری است: پای ۱ (حالت چپ) (P1)، پای ۲ (حالت بالا) (P2)، پای ۳ (حالت پایین) (P3)، پای ۴ (حالت روبه‌رو) (P4)، پای ۵ (حالت راست) (P5). در مجموع ۲۰ آزمایش بین‌دامنه‌ای بر روی پایگاه داده پای قابل طراحی

همچنین FLDA کلاسیک به‌دلیل این که اطلاعات اولیه را در مورد تفاوت بین توزیع نمونه‌های آموزشی و آزمایشی در نظر نمی‌گیرد، به‌طور کامل نمی‌تواند پاسخگوی مسئله شیفت دامنه‌ها باشد. با این حال برای اجتناب و یا کاهش مشکل زیادآموزی، اطلاعات اولیه نمونه‌های آموزشی با اضافه کردن یک بخش تنظیم منطقی به رابطه (۱) در نظر گرفته می‌شود. در واقع، روش‌های کاهش بعد به‌تنهایی پاسخ‌گوی مسائل شیفت دامنه‌ها نیستند و به‌دلیل نادیده گرفتن اطلاعات اولیه در مورد اختلاف توزیع بین نمونه‌های دامنه منبع و هدف، مدل ایجاد شده روی نمونه‌های دامنه منبع دچار بیش‌برازش شده و عملکرد مدل به‌شدت کاهش می‌یابد. برای اجتناب از مشکل بیش‌برازش و بهبود عملکرد مدل یادگیری، اطلاعات اولیه با استفاده از واگرایی برگمن در نظر گرفته می‌شود. واگرایی برگمن قادر است اطلاعات به‌دست آمده از نمونه‌های دامنه منبع را، با به‌حداقل رساندن اختلاف توزیع شرطی بین دامنه‌ها به نمونه‌های دامنه هدف منتقل کند که باعث تفکیک پذیری بهتر کلاس‌های مختلف در فضای جدید می‌شود. در واقع واگرایی برگمن می‌تواند اطلاعات اولیه نمونه‌های آموزشی را که همان اطلاعات تفکیک‌کننده از جمله ساختار داده‌ها می‌باشد را حفظ کرده و برای تفکیک پذیری بهتر به نمونه‌های آزمایشی انتقال می‌دهد. بدین ترتیب، روش پیشنهادی CIFAB یک زیرفضای مطلوب پیدا می‌کند که در آن اختلاف توزیع شرطی کمینه شده و کلاس داده‌های آموزشی و آزمایشی به‌صورت مستقل از هم جدا می‌شوند. CIFAB علاوه بر این که اطلاعات تفکیک‌کننده موجود در نمونه‌های آموزشی را در نظر می‌گیرد توزیع بایاس بین نمونه‌های آموزشی و آزمایشی را نیز بررسی می‌کند. از این‌رو واگرایی برگمن [۶] و تابع هدف الگوریتم FLDA ترکیب می‌شوند؛ پس با توجه به رابطه‌های (۱) و (۵) خواهیم داشت:

$$W = \underset{W \in R^{D \times d}}{\operatorname{argmin}} F(W) + \lambda D_W(P_S \| P_T) \quad (11)$$

$F(W)$ تابع هدف الگوریتم در زیرفضای پیش‌بینی شده، $D_W(P_S \| P_T)$ واگرایی برگمن که فاصله بین P_S و P_T را در فضای پیش‌بینی شده W محاسبه می‌کند و λ پارامتر تنظیم است که بین $F(W)$ و $D_W(P_S \| P_T)$ تنظیم ایجاد می‌کند. برای به‌دست آوردن زیرفضای خطی بهینه W با توجه به رابطه (۱۰) می‌توان از الگوریتم گرادینت نزولی استفاده کرد.

$$W \leftarrow W - \eta (\partial_W F(W) + \lambda D_W(P_S \| P_T)) \quad (12)$$

∂_W گرادینت با توجه به W ، η نرخ یادگیری در k امین تکرار است، بنابراین، W_{k+1} به‌صورت زیر به‌دست می‌آید:

$$W_{k+1} = W_k - \eta(k) \left(\frac{\partial F(W)}{\partial W} + \lambda \sum_{i=1}^{n_s+n_t} \frac{\partial D_W(P_S \| P_T)}{\partial \bar{y}_i} \frac{\partial \bar{y}_i}{\partial W} \right) \quad (13)$$

بدین ترتیب با در نظر گرفتن رابطه (۹) مشتق $F(W)$ برحسب W برای به‌دست آوردن ماتریس نگاشت بهینه برابر است با:

عملکرد روش پیشنهادی با بهترین نتایج گزارش شده از الگوریتم‌های مورد مقایسه، مورد ارزیابی قرار گرفته‌است. تمامی این الگوریتم‌های نامبرده شده (به جز DAM و NN) 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 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. DAM، یک روش تطبیق دامنه است که به طور مستقیم یک طبقه‌بند سازگار با دامنه هدف را به دست می‌آورد. روش‌های TCA، GFK و TJM به عنوان روش‌های تطبیق خصوصیات، اختلاف توزیع حاشیه‌ای را به حداقل رسانده و از اطلاعات داده‌های برچسب‌دار دامنه منبع و همچنین توزیع هندسی داده‌ها برای ایجاد نمایش کم‌بعد، از داده‌ها بهره نمی‌گیرند. LRSR، یک روش تطبیق دامنه بدون نظارت است که نمونه‌های دامنه منبع و دامنه هدف را به یک زیرفضای مشترک نگاشت می‌کند.

۴-۳- مفروضات پیاده‌سازی

برای مقایسه روش پیشنهادی با الگوریتم‌های شناخته شده در حوزه یادگیری انتقالی، دقت طبقه‌بند بر روی داده‌های دامنه هدف محاسبه می‌شود. این دقت توسط محاسبه خطای پیش‌بینی در دامنه هدف به صورت رابطه زیر تعریف می‌شود:

$$Accuracy = \frac{|\{x : x \in D_i \wedge f(x) = y(x)\}|}{n_i}$$

که D_i دامنه هدف، $f(x)$ تابع پیش‌بینی به دست آمده، $y(x)$ برچسب واقعی داده و n_i تعداد داده‌های دامنه هدف می‌باشد. الگوریتم پیشنهادی شامل دو پارامتر زیر است که مقادیر بهینه آن‌ها در ادامه آورده شده‌است: (۱) پارامتر تنظیم در رابطه (۱۰)، (۲) نرخ یادگیری در رابطه (۱۱). مقدار بهینه پارامترها در روش CIFAB، برای پایگاه داده‌های بصری برای تمامی آزمایش‌ها انجام گرفته و از دو طبقه‌بند استاندارد SVM و NN به صورت مجزا برای پیش‌بینی برچسب‌های داده‌های دامنه هدف استفاده می‌شود. در آزمایشات انجام گرفته شده با استفاده از طبقه‌بند SVM از کرنل RBF و Linear استفاده شده‌است، که تغییر محسوسی در نتایج ایجاد نشده‌است. همچنین، تعداد بهینه تکرار الگوریتم ۲۰ در نظر گرفته شده‌است. الگوریتم پیشنهادی با تعداد همسایگی‌های ۳، ۵ و ۷ مورد آزمایش قرار گرفته‌است که نتایج این آزمایش در شکل ۳ گزارش شده‌است.

۵- نتایج و بحث‌ها

در این بخش، نتایج روش پیشنهادی CIFAB و الگوریتم‌های شناخته شده حوزه تطبیق دامنه توسط طراحی آزمایش‌های بدون نظارت مورد ارزیابی و مقایسه قرار گرفته‌است.

است که از بین ۵ دامنه، دو دامنه مختلف به عنوان دامنه‌های منبع و هدف انتخاب می‌شوند. (۴) پایگاه داده کویل، شامل ۱۴۴۰ تصویر سیاه و سفید از ۲۰ شی با زمینه سیاه در زاویه‌های مختلف است که هر تصویر در اندازه ۳۲×۳۲ پیکسلی نمایش داده می‌شود. پایگاه داده کویل، شامل دو دامنه کویل ۱ و کویل ۲ است که کویل ۱، مجموعه تصاویر اشیاء گرفته شده در زاویه‌های [۰، ۸۵] و [۱۸۰، ۲۶۵] (ربع اول و سوم) و کویل ۲، مجموعه تصاویر اشیاء گرفته شده در زاویه‌های [۹۰، ۱۷۵] و [۲۷۰، ۳۵۵] (ربع دوم و چهارم) هستند. بدین ترتیب، وجود اختلاف توزیع بین دامنه‌های کویل ۱ و کویل ۲، مشهود است. دامنه COIL1_vs_COIL2 (C1_C2) که ۷۲۰ نمونه از دامنه کویل ۱ را به عنوان داده آموزشی و ۷۲۰ نمونه از دامنه کویل ۲ را به عنوان داده تست شامل شده‌است، به عنوان آزمایش اول از پایگاه داده کویل در نظر گرفته می‌شود. به طور مشابه، دامنه COIL2_vs_COIL1 (C2_C1)، با جابه‌جایی نمونه‌های آموزشی و تست دامنه COIL1_vs_COIL2 ایجاد شده و به عنوان آزمایش دوم در نظر گرفته می‌شود. (۵) مجموعه داده MSRC حاوی ۴۳۲۳ تصویر با برچسب ۱۸ کلاس است که توسط میکروسافت تحقیقات کمبریج ارائه شده‌است. مجموعه داده VOC 2007 شامل ۵۰۱۱ تصویر حاوی ۲۰ موضوع است. این دو مجموعه داده، ۶ طبقه کلاس را تقسیم می‌کنند: هواپیما، دوچرخه، پرند، ماشین، گاو، گوسفند. برای ساخت مجموعه داده MSRC vs VOC (M → V) تمام ۱۲۶۹ تصویر در MSRC را به عنوان دامنه منبع و همه ۱۵۳۰ تصویر در VOC 2007 به عنوان دامنه هدف در نظر گرفته شده‌است، سپس مجموعه داده‌ها با یکدیگر تغییر داده شده‌است VOC (V → M) vs MSRC (۶) پایگاه داده YALE B شامل ۲/۴۱۴ تصویر از ۳۸ فرد متفاوت در شرایط مختلف نورپردازی است و هر تصویر ۳۲×۳۲ پیکسل است، پایگاه داده به ۵ زیرمجموعه تقسیم شده‌است. زیرمجموعه ۱ شامل ۲۶۶ تصویر (هفت تصویر در هر موضوع) در شرایط نوری مختلف است. زیرمجموعه‌های ۲ و ۳ هر کدام شامل ۱۲ تصویر در هر موضوع، تغییرات نورانی کم و متوسط را مشخص می‌کنند. در حالی که زیرمجموعه ۴ (۱۴ عکس در هر شخص) و زیرمجموعه ۵ (۱۹ عکس در هر شخص) تغییرات شدید نور را نشان می‌دهد. این زیرمجموعه‌ها به ترتیب از Y1 تا Y2 نامگذاری شده‌اند. در این مجموعه داده، آزمایش بر روی ۲۰=۴×۵ مجموعه بین دامنه‌ای مختلف طراحی شده‌است که از بین این ۵ دامنه، دو دامنه مختلف به عنوان دامنه‌های منبع و هدف انتخاب می‌شوند به عنوان مثال (Y1 → Y2, Y1 → Y3, ..., Y5 → Y4).

به طور کلی کارایی الگوریتم پیشنهادی بر روی ۵۸ مجموعه تصاویر بین دامنه‌های مختلف مورد ارزیابی قرار می‌گیرد.

۴-۲- ارزیابی الگوریتم‌ها


روش‌هایی که الگوریتم CIFAB با آن‌ها مقایسه شده‌است، عبارتند از: طبقه‌بند نزدیک‌ترین همسایه (NN)، TSL [۱۹]، GFK [۱]، DAM [۲۰]، TCA [۲۱]، JDA [۲۲]، CDCA [۲۵]، TJM [۱۱] و LRSR [۲۳].

کاهش دهد، به‌همین دلیل عملکرد ضعیفی نسبت به دیگر الگوریتم‌های شناخته‌شده در حوزه تطبیق دامنه دارد. مهم‌ترین علت برتری CIFAB نسبت به TSL استفاده از تطبیق خصوصیات برای کاهش اختلاف توزیع شرطی بین دامنه‌های منبع و هدف است. میانگین بهبود دقت CIFAB نسبت به TSL در مجموعه‌داده آفیس ۰/۸۷٪، در مجموعه‌داده اعداد ۱۲/۸۴٪ و در مجموعه‌داده پای ۲۴/۲۵٪ می‌باشد.

TCA، یکی از روش‌های مبتنی بر خصوصیات است که از برجسب‌های دامنه منبع برای تطبیق دامنه‌ها استفاده نمی‌کند و تنها اختلاف توزیع حاشیه‌های بین دامنه‌های منبع و هدف را با استفاده از MMD کاهش می‌دهد و برای حفظ ویژگی‌های اصلی داده‌های ورودی واریانس داده‌ها را افزایش می‌دهد. در این روش به اختلاف توزیع شرطی بین دامنه‌های منبع و هدف توجهی نشده و همچنین از داده‌های برجسب‌دار دامنه منبع در ایجاد فضای جدید استفاده نمی‌شود. در حالی که در روش CIFAB، اختلاف توزیع شرطی حداقل شده و از برجسب‌های نمونه‌های دامنه منبع برای ایجاد تفکیک‌پذیری بهتر بین کلاس‌ها استفاده می‌شود. میانگین بهبود دقت CIFAB نسبت به TCA در مجموعه‌داده آفیس و کالتک ۵/۲۸٪، در مجموعه‌داده اعداد ۱۶/۴۱٪ و در مجموعه‌داده پای ۲۷/۴۹٪ می‌باشد. همچنین میانگین بهبود دقت CIFAB نسبت به TCA در مجموعه‌داده در مجموعه‌داده کویل ۱۱/۴۷٪، در مجموعه‌داده VOC ۲۶/۲۳٪ و در مجموعه‌داده YALE B ۳۵/۷۲٪ می‌باشد.

JDA و TJM از جمله روش‌های شناخته‌شده در حوزه یادگیری انتقالی بدون نظارت هستند که با ایجاد یک نمایش کم‌بعد 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 ایجادشده در نمایش جدید توسط روش‌های TJM و JDA نمی‌تواند با دقت بالایی برجسب داده‌های دامنه هدف را پیش‌بینی کند. دلیل برتری CIFAB نسبت به JDA و TJM این است که CIFAB علاوه بر این که ساختار داده‌ها را حفظ می‌کند اطلاعات تفکیک‌کننده اولیه داده‌های ورودی را نیز در نظر می‌گیرد که این باعث کاهش اختلاف توزیع شرطی بین دامنه‌ها می‌شود. در واقع کاهش اختلاف توزیع شرطی بین دامنه‌های منبع و هدف منجر به پیش‌بینی دقیق‌تر برجسب نمونه‌های دامنه هدف می‌شود. میانگین بهبود دقت روش CIFAB نسبت به روش JDA در مجموعه‌داده آفیس و کالتک ۲٪، در مجموعه‌داده اعداد ۶/۶۱٪، در مجموعه‌داده پای ۱۲٪ می‌باشد. علاوه بر این میانگین بهبود دقت روش CIFAB نسبت به روش JDA در مجموعه‌داده کویل ۹/۷۳٪، در مجموعه‌داده VOC ۵/۹۲٪ و در مجموعه‌داده YALE B ۲۹/۱٪ می‌باشد.

میانگین بهبود دقت روش CIFAB نسبت به روش TJM در مجموعه‌داده آفیس و کالتک ۱/۸۹٪، در مجموعه‌داده اعداد ۱۲/۳۱٪، در مجموعه‌داده پای ۳۶/۲۲٪ می‌باشد. همچنین میانگین بهبود دقت روش



شکل ۳: مقایسه دقت CIFAB در تعداد همسایگی‌های متفاوت

شکل ۳ نشان می‌دهد که افزایش تعداد همسایگی در الگوریتم NN

تأثیر قابل‌ملاحظه‌ای در افزایش دقت الگوریتم پیشنهادی ندارد.

۵-۱- ارزیابی نتایج

جدول ۲ تا ۷، نشان‌دهنده نتایج به‌دست‌آمده از روش CIFAB و الگوریتم‌های مورد مقایسه به ترتیب، بر روی پایگاه‌داده آفیس و کالتک، پایگاه‌داده اعداد، پایگاه‌داده پای، پایگاه‌داده کویل، پایگاه‌داده VOC و پایگاه‌داده YALE B است. از آنجایی که ارزیابی نتایج آزمایشات با طبقه‌بندهای NN و SVM تقریباً مشابه است فقط در مورد نتایج آزمایشات با طبقه‌بند NN بحث شده‌است. همان‌طور که مشاهده می‌شود در تمام پایگاه‌داده‌ها CIFAB کارایی بهتری نسبت به روش دیگر دارد. در پایگاه‌داده آفیس و کالتک، CIFAB دارای ۱/۸۹٪ میانگین بهبود دقت نسبت به بهترین الگوریتم مورد مقایسه (یعنی TJM) و دارای ۱۶/۹۴٪ میانگین بهبود دقت نسبت به الگوریتم استاندارد NN است. در پایگاه‌داده اعداد، CIFAB دارای بهبود عملکرد ۱۲/۳۱٪ نسبت به بهترین الگوریتم مورد مقایسه (یعنی TJM) و ۱۴/۷۶٪ نسبت به الگوریتم استاندارد NN می‌باشد. در پایگاه‌داده پای، میانگین بهبود دقت CIFAB ۸/۲۲٪، نسبت به بهترین الگوریتم مورد مقایسه (یعنی LRSR) و ۳۶/۹۹٪ نسبت به الگوریتم استاندارد NN است.

مهم‌ترین دلیل برتری CIFAB نسبت به روش‌های دیگر، استفاده از اطلاعات اولیه دامنه منبع است، که به‌صورت حداکثری به دامنه هدف انتقال می‌یابد. ضمناً CIFAB اطلاعات خاص داده‌ها (به‌عنوان مثال ساختار منیفلد داده‌ها) را حفظ می‌کند. در ادامه به تفصیل گزارش مقایسه CIFAB با دیگر روش‌های مورد مقایسه ارائه شده‌است. نتایج گزارش‌شده نشان می‌دهد که روش پیشنهادی CIFAB در تمام مجموعه‌داده‌ها نسبت به دیگر روش‌های مورد مقایسه، نه تنها بر روی طبقه‌بندهای محلی مانند NN بلکه بر روی طبقه‌بندهای سراسری مانند SVM نیز بهتر عمل می‌کند.

TSL، مجموعه‌ای از روش‌های کاهش‌بعد است که نمی‌تواند اختلاف توزیع بین دامنه‌های منبع و هدف را به‌طور قابل‌ملاحظه‌ای

CDDA از جمله روش‌های شناخته‌شده در حوزه یادگیری انتقالی بدون نظارت است که با ایجاد یک نمایش کم‌بعد 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 CIFAB نسبت به CDDA این است که CIFAB علاوه بر این که ساختار داده‌ها را حفظ می‌کند اطلاعات تفکیک‌کننده اولیه داده‌های ورودی را نیز در نظر می‌گیرد که این باعث کاهش اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها می‌شود. روش CIFAB به تفکیک نسبت به روش CDDA دارای متوسط بهبود دقت $1/0.9\%$ در پایگاه‌داده آفیس و کالتک، $0/9.5\%$ در پایگاه‌داده اعداد، $5/9.1\%$ در پایگاه‌داده کوپل و $8/6.5\%$ در پایگاه‌داده پای است.

۵-۲- ارزیابی پارامتر

روش پیشنهادی CIFAB دارای دو پارامتر بوده که در این بخش با مقادیر مختلف، مورد ارزیابی قرار می‌گیرد. در روش‌های یادگیری ماشین، یک اصل مهم در پروسه بهینه‌سازی، انتخاب نرخ یادگیری مناسب است ($\eta(k)$ در رابطه (۱۰)). اگر مقدار پایینی برای $\eta(k)$ انتخاب شود سرعت 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، بنابراین روش پیشنهادی به دنبال به دست آوردن مقدار مناسب برای $\eta(k)$ می‌باشد. در این چارچوب پیشنهادی به‌طور تجربی $\eta(k) = \eta(0) / k$ در نظر گرفته شده که نرخ یادگیری با افزایش تعداد تکرار کاهش یابد. λ پارامتر تنظیم بین واگرایی برگمن $D(W)$ و تابع هدف $F(W)$ است و در محدوده $[0, 1]$ بررسی می‌شود. مقدار بهینه پارامتر λ برای تمامی پایگاه‌داده‌ها برابر $0/1$ می‌باشد.

برای بررسی همگرایی روش CIFAB در تکرارهای مختلف، یک آزمایش دیگر نیز ترتیب داده شده است. از آنجایی که روش CIFAB یک روش تکرارشونده است، بررسی شده است که در پایگاه‌داده‌های مختلف میزان تکرار بهینه الگوریتم چقدر می‌باشد. شکل ۴، الگوریتم CIFAB را با روش‌های TJM، JDA و TCA در ۲۰ تکرار مقایسه می‌کند. چنانچه از نتایج برمی‌آید، در بیشتر موارد، CIFAB در ۲۰ تکرار اولیه به همگرایی رسیده است و تعداد تکرار بیشتر، تأثیری در افزایش دقت الگوریتم ندارد. از این رو، تمام نتایج گزارش شده برای CIFAB حاصل انجام ۲۰ تکرار بر روی الگوریتم می‌باشند.

۵-۳- تحلیل زمان اجرا

در این بخش، پیچیدگی زمانی روش پیشنهادی CIFAB بررسی می‌شود. تحدد تابع هدف که در رابطه (۱۰) تعریف می‌شود، به $F(W)$ و $D(W)$ وابسته است. تحدد $F(W)$ وابسته به یک الگوریتم خاص

CIFAB نسبت به روش TJM در مجموعه‌داده کوپل $7/0.2\%$ و در مجموعه‌داده YALE B $6/1.5\%$ می‌باشد.

DAM از طبقه‌بندهای پیش‌آمخته^{۳۱} با استفاده از نمونه‌های برچسب‌دار دامنه منبع، استفاده می‌کند. علاوه بر این DAM بر اساس فرضیه مسطح‌سازی^{۳۲} یک شرایط تنظیمی^{۳۳} را به وجود می‌آورد که طبقه‌بند دامنه هدف مجبور به تصمیم‌گیری مشابه با طبقه‌بند پیش‌آمخته می‌شود. مهم‌ترین دلیل برتری روش پیشنهادی نسبت به روش DAM، کاهش اختلاف توزیع شرطی بین دامنه‌ها و انتقال حداکثری اطلاعات تفکیک‌کننده نمونه‌های دامنه منبع برای تفکیک‌پذیری بهتر کلاس‌های مختلف دامنه هدف است. میانگین بهبود دقت CIFAB نسبت به DAM در مجموعه‌داده آفیس و کالتک $5/7.6\%$ ، در مجموعه‌داده اعداد $22/3.2\%$ و در مجموعه‌داده پای $22/7.4\%$ می‌باشد. همچنین میانگین بهبود دقت CIFAB نسبت به DAM در مجموعه‌داده در مجموعه‌داده کوپل $26/2.6\%$ ، در مجموعه‌داده VOC $13/4.4\%$ و در مجموعه‌داده YALE B $30/9.7\%$ می‌باشد.

در روش GFK به منظور کاهش اختلاف توزیع حاشیه‌ای، داده‌های منبع و هدف به یک زیرفضای کوچک‌تری در منیفولد گرسمن نگاشت می‌شوند، اما به دلیل این که زیر فضای نگاشت شده دارای ابعاد بسیار کمی می‌باشد باعث از بین رفتن بخشی از داده شده و نمایش خوبی از داده‌ها ایجاد نمی‌شود. در حالی که در مرحله اول روش CIFAB، یک فضای مشترک بین دامنه‌های منبع و هدف، با شرط حداقل کردن اختلاف توزیع شرطی ایجاد می‌شود که بدین ترتیب، ساختار داده اصلی در فضای جدید حفظ می‌شود. نتایج حاصل از آزمایشات حاکی از این است که متوسط بهبود دقت روش CIFAB به تفکیک نسبت به روش GFK در پایگاه‌داده آفیس و کالتک $5/3.6\%$ ، در پایگاه‌داده اعداد $13/2.4\%$ و در پایگاه‌داده پای $36/1.9\%$ است. میانگین بهبود دقت CIFAB نسبت به GFK در مجموعه‌داده در مجموعه‌داده کوپل $25/2.8\%$ ، در مجموعه‌داده VOC $8/4.2\%$ و در مجموعه‌داده YALE B $5/5.9\%$ می‌باشد.

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^{۳۴} [۲۴] و سطح پایین^{۳۵} 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 تفکیک‌کننده نمونه‌های دامنه منبع برای تفکیک‌پذیری بهتر کلاس‌های مختلف است. میانگین بهبود دقت CIFAB نسبت به LRSR در مجموعه‌داده آفیس $2/9.2\%$ ، در مجموعه‌داده اعداد $5/9.2\%$ و در مجموعه‌داده پای $8/2.2\%$ می‌باشد. همچنین میانگین بهبود دقت CIFAB نسبت به LRSR در مجموعه‌داده کوپل $14/2.2\%$ ، در مجموعه‌داده VOC $3/0.7\%$ و در مجموعه‌داده YALE B $10/2.7\%$ می‌باشد.

پیچیدگی زمانی روش‌های TJM و JDA به صورت کلی $O(cN^2)$ می‌باشد.

نمودارهای مربوط به مقایسه دقت طبقه‌بند بر روی پایگاه داده‌های آفیس، کالتک، اعداد و پای با روش‌های NN، GFK، TCA، JDA، TJM، DAM، TSL و CIFAB به ترتیب در شکل‌های ۵ و ۶ نشان داده شده‌است. شکل ۵ نشان می‌دهد که CIFAB نسبت به دیگر روش‌های کاهش بعد و یادگیری انتقالی در ۹ آزمایش از ۱۲ آزمایش پایگاه داده آفیس و کالتک عملکرد بهتری دارد. شکل ۶ نشان می‌دهد که CIFAB نسبت به دیگر روش‌های کاهش بعد و یادگیری انتقالی در ۱۵ آزمایش از ۲۰ آزمایش پایگاه داده پای عملکرد بهتری دارد.

روش CIFAB، یک الگوریتم تکرارشونده است که بر روی هر دو نمونه‌های دامنه منبع و دامنه هدف اعمال می‌شود تا نمایش تطبیق‌پذیری از دامنه‌های منبع و هدف ایجاد شود. این الگوریتم در هر تکرار، برای کاهش اختلاف توزیع شرطی بین دامنه‌های منبع و هدف، اختلاف توزیع بین نمونه‌های متعلق به کلاس c در دامنه منبع را از نمونه‌های متعلق به کلاس c در دامنه هدف را کاهش می‌دهد. تکرار این عمل موجب افزایش دقت طبقه‌بند در پیش‌بینی برجسب‌های نمونه‌های دامنه هدف می‌شود. شکل ۷، عملکرد روش پیشنهادی بر روی داده‌ها و ورودی را به صورت شماتیک نمایش می‌دهد.

یادگیری زیرفضا مانند FLDA است. درحالی‌که تحدب $D(W)$ به مدل توزیع مجموعه نمونه‌های آموزشی و آزمایشی بستگی دارد. اگر N تعداد کل نمونه‌ها، M اندازه ابعاد فضای اصلی، c تعداد کلاس‌ها و D واگرایی برگمن (که اختلاف توزیع شرطی بین دامنه‌های منبع و هدف را محاسبه می‌کند) باشند، رابطه (۱۲) دارای پیچیدگی زمانی $O((D+N)^2)$ است. همچنین روش NN (با در نظر گرفتن تعداد همسایگی برابر با ۱ برای نمونه‌ها)، دارای پیچیدگی زمانی $O(MN)$ می‌باشد.

جدول ۱: جدول پیچیدگی زمانی CIFAB در مقایسه با سایر الگوریتم

الگوریتم	پیچیدگی زمانی
TCA	$O(MN^2)$
TJM	$O(cN^2)$
JDA	$O(cN^2)$
NN	$O(MN)$
CIFAB	$O((D+N)^2)$

پس به‌طور کلی پیچیدگی CIFAB برابر با $O((D+N)^2)$ است. در مقایسه با روش CIFAB، روش TCA، با وابستگی نسبت به تعداد داده‌ها، با پیچیدگی $O(MN^2)$ انجام می‌گیرد. به همین ترتیب،

جدول ۲: دقت (%) طبقه‌بند در مجموعه داده آفیس و کالتک

SVM classifier			NN classifier											Dataset
CIFAB linear	CIFAB RBF	LRSR	CIFAB	CDDA	LRSR	TJM	JDA	TCA	DAM	GFK	TSL	NN	FLDA	
۵۳/۴۸	۵۳/۴	۵۳/۳۴	۵۳/۴	۴۸/۳۳	۵۱/۲۵	۴۶/۷۶	۴۴/۷۸	۴۵/۸۲	۴۲/۶۹	۴۱/۰۲	۴۴/۲	۲۳/۷	۴۰/۲۲	C-A
۴۸/۹۳	۴۸/۹	۴۵/۷۶	۴۸/۹	۴۴/۷۵	۳۸/۶۴	۳۹/۹۸	۴۱/۶۹	۳۰/۵۱	۳۴/۵۸	۴۰/۶۸	۴۵/۸	۲۵/۷۶	۴۰/۱۱	C-W
۴۶/۹۷	۴۶/۹۷	۵۰/۹۶	۴۷/۶	۴۸/۴۱	۴۷/۱۳	۴۴/۵۹	۴۵/۲۲	۳۵/۶۷	۳۳/۱۲	۳۸/۸۵	۶۰/۸	۲۵/۴۸	۳۹/۹۹	C-D
۴۲/۹۶	۴۲/۹۶	۴۴/۷۰	۴۲/۸۷	۴۲/۱۲	۴۳/۳۷	۳۹/۴۵	۳۹/۳۶	۴۰/۰۷	۳۵/۳۵	۴۰/۲۵	۳۶/۷	۲۶	۴۱/۳۶	A-C
۴۰/۵۲	۴۰/۵۲	۳۸/۳۱	۴۰/۴۳	۴۱/۶۹	۳۶/۶۱	۴۲/۰۳	۳۷/۹۷	۳۵/۲۵	۳۱/۸۶	۳۸/۹۸	۴۷/۱	۲۹/۸۳	۴۱/۶۵	A-W
۴۵/۹۶	۴۵/۹۶	۳۹/۴۹	۴۵/۰۵	۳۷/۵۸	۳۸/۸۵	۴۵/۲۲	۳۹/۴۹	۳۴/۳۹	۳۶/۳۱	۳۶/۳۱	۵۴/۹	۲۵/۴۸	۴۰/۸۹	A-D
۳۴/۴۷	۳۴/۴۵	۳۰/۲۸	۳۵/۴۸	۳۱/۹۷	۲۹/۸۳	۳۰/۱۹	۳۱/۱۷	۲۹/۹۲	۳۳/۸۴	۳۰/۷۲	۶۹/۵	۱۹/۸۶	۴۰	W-C
۳۹/۷۹	۳۹/۷۹	۳۴/۶۶	۳۸/۷۹	۳۷/۲۷	۳۴/۱۳	۲۹/۹۶	۳۲/۷۸	۲۸/۸۱	۳۷/۵۸	۲۹/۷۵	۳۵/۸	۲۲/۹۶	۴۲/۹۰	W-A
۷۰/۵۶	۷۰/۵۴	۸۲/۸۰	۷۳/۷۲	۸۷/۹	۸۲/۸۰	۸۹/۷۱	۸۹/۱۷	۸۵/۹۹	۸۰/۸۷	۸۰/۸۹	۳۶/۴	۵۹/۲۴	۴۱/۵۲	W-D
۳۴/۱۵	۳۴/۱۵	۳۰/۷۲	۳۴/۱۵	۳۴/۶۴	۳۱/۶۱	۳۱/۴۳	۳۱/۵۲	۳۲/۰۶	۳۲/۴۱	۳۰/۲۸	۴۴/۳	۲۶/۲۷	۴۳/۲۱	D-C
۳۷/۴۴	۳۷/۵۴	۳۳/۱۹	۳۷/۵۵	۳۳/۵۱	۳۳/۱۹	۳۲/۷۸	۳۳/۰۹	۳۱/۴۲	۳۴/۳۴	۳۲/۰۵	۵۷/۵	۲۸/۵	۴۲/۵۶	D-A
۷۹/۹۶	۷۹/۹۸	۷۶/۶۱	۸۱/۷۹	۹۰/۵۱	۷۷/۲۹	۸۵/۴۲	۸۹/۴۹	۸۶/۴۴	۷۷/۶۳	۷۵/۵۹	۳۶/۳	۶۳/۳۹	۴۲/۹۱	D-W
۴۷/۹۸	۴۷/۹۳	۴۶/۷۳	۴۸/۳۱	۴۷/۲۲	۴۵/۳۹	۴۶/۴۲	۴۶/۳۱	۴۳/۰۳	۴۲/۵۵	۴۲/۹۵	۴۷/۴۴	۳۱/۳۷	۴۱/۳۸	میانگین

جدول ۳: دقت (%) طبقه‌بند در مجموعه داده اعداد

SVM classifier			NN classifier											Dataset
CIFAB linear	CIFAB RBF	LRSR	CIFAB	CDDA	LRSR	TJM	JDA	TCA	DAM	GFK	TSL	NN	FLDA	
۶۳/۴	۶۳/۱۵	۵۳/۸۳	۶۶/۰۵	۶۲/۰۵	۵۴/۵۱	۵۲/۲۵	۵۹/۶۵	۵۱/۰۵	۴۲/۶۹	۴۶/۴۵	۵۲/۶۵	۴۴/۷	۵۱/۷۳	U-M
۷۱/۵۶	۷۱/۰۶	۷۱/۹۸	۷۴/۱۱	۷۶/۳۲	۷۳/۸۲	۶۳/۲۸	۶۷/۲۸	۵۶/۲۸	۵۲/۸۳	۶۷/۲۲	۶۱/۸۳	۶۵/۹۴	۶۴/۸۹	M-U
۶۷/۴۶	۶۷/۱	۶۲/۹۰	۷۰/۰۸	۶۹/۱۳	۶۴/۱۶	۵۷/۷۷	۶۳/۴۷	۵۳/۶۷	۴۷/۷۶	۵۶/۸۴	۵۷/۲۴	۵۵/۳۲	۵۸/۳۱	میانگین

جدول ۴: دقت (%) طبقه‌بند در مجموعه داده پای


SVM classifier			NN classifier											Dataset
CIFAB linear	CIFAB RBF	LRSR	CIFAB	CDDA	LRSR	TJM	JDA	TCA	DAM	GFK	TSL	NN	FLDA	
۷۰/۴۴	۷۰/۵۸	۶۵/۴۴	۶۹/۶۱	۶۰/۲۲	۶۵/۸۷	۲۳/۸۷	۵۸/۸۱	۴۰/۷۶	۴۶/۶۵	۲۶/۱۵	۴۴/۲	۲۶/۰۹	۳۳/۸۹	P1_P2
۶۱/۶۸	۶۱/۸	۶۲/۸۷	۶۱/۷۱	۵۸/۷	۶۴/۰۹	۲۸/۸۶	۵۴/۲۳	۴۱/۷۹	۴۵/۰۴	۲۷/۲۷	۴۵/۸	۲۶/۵۹	۳۳/۵۶	P1_P3
۴۷/۹۶	۴۷/۸۶	۸۱/۲۹	۴۷/۳۲	۸۳/۴۸	۸۲/۰۳	۴۳/۳۷	۸۴/۵	۵۹/۶۳	۶۸/۵۲	۳۱/۱۵	۶۰/۸	۳۰/۶۷	۳۲/۹۳	P1_P4
۶۲/۵۹	۶۲/۵۱	۵۴/۲۳	۶۱/۴۲	۵۴/۱۷	۵۴/۹۰	۱۹/۳	۴۹/۷۵	۲۹/۳۵	۲۸/۷۴	۱۷/۵۹	۳۶/۷	۱۶/۶۷	۳۸/۷۹	P1_P5
۷۵/۹۹	۷۵/۹۸	۴۵/۵۹	۷۶/۳۶	۶۲/۳۳	۴۵/۵۴	۲۶/۱۴	۵۷/۶۲	۴۱/۸۱	۳۵/۳۲	۲۵/۲۴	۴۷/۱	۲۴/۴۹	۳۵/۲۹	P2_P1
۶۹/۱۵	۶۹/۰۵	۵۲/۷۰	۶۸/۶۷	۶۴/۶۴	۵۳/۴۹	۳۷/۹۳	۶۲/۹۳	۵۱/۴۷	۳۵/۷۸	۴۷/۳۷	۵۴/۹	۴۶/۶۳	۳۴/۷۸	P2_P3
۸۲/۹	۸۲/۸۹	۷۲/۲۴	۸۲/۴۱	۷۹/۹	۷۱/۴۳	۵۰/۵۳	۷۵/۸۲	۶۴/۷۳	۷۲/۳۳	۵۴/۲۵	۶۹/۵	۵۴/۰۷	۳۵/۱۷	P2_P4
۶۵/۲۲	۶۵/۱۱	۴۸/۴۱	۶۴/۵۶	۴۴	۴۷/۹۷	۲۱/۶۳	۳۹/۸۹	۳۳/۷	۳۵/۱۱	۲۷/۰۸	۳۵/۸	۲۶/۵۳	۳۲/۴۱	P2_P5
۷۴/۷۸	۷۴/۷۵	۵۳/۳۰	۷۴/۶۱	۵۸/۴۶	۵۲/۴۹	۲۸/۶۶	۵۰/۹۶	۳۴/۶۹	۴۱	۲۱/۸۲	۳۶/۴	۲۱/۳۷	۳۷/۳۶	P3_P1
۷۳/۰۲	۷۳/۰۲	۵۶/۹۷	۷۲/۹۳	۵۹/۷۳	۵۵/۵۶	۳۵/۹۷	۵۷/۹۵	۴۷/۷	۵۹/۳۶	۴۳/۱۶	۴۴/۳	۴۱/۰۱	۳۷/۰۲	P3_P2
۸۱/۶۹	۸۱/۶۹	۷۵/۹۴	۸۱/۲۳	۷۷/۲	۷۷/۵۰	۵۱/۹۷	۶۸/۴۵	۵۶/۲۳	۷۲/۳۳	۴۶/۴۱	۵۷/۵	۴۶/۵۳	۳۸/۴۵	P3_P4
۷۷/۶۸	۷۷/۶۸	۵۳/۴۳	۷۷/۵۴	۴۷/۲۴	۵۴/۱۱	۲۵/۳۱	۳۹/۹۵	۳۳/۱۵	۴۰/۳۲	۲۶/۷۸	۳۶/۳	۲۶/۲۳	۳۲/۵۹	P3_P5
۸۹/۳۳	۸۹/۳۳	۷۹/۷۱	۸۹/۴۱	۸۳/۱	۸۱/۵۴	۴۵/۷۱	۸۰/۵۸	۵۵/۶۴	۶۹/۳۶	۳۴/۲۴	۶۲/۶	۳۲/۹۵	۳۴/۵۳	P4_P1
۸۴/۵۵	۸۴/۵۵	۸۷/۳۳	۸۳/۱۱	۸۲/۲۶	۵۸/۳۹	۵۷/۵۸	۸۲/۶۳	۶۷/۸۳	۷۷/۲۹	۶۲/۹۲	۶۸/۱	۶۲/۶۸	۳۵/۲۱	P4_P2
۷۷/۸۷	۷۷/۸۷	۸۱/۱۳	۷۸/۵۶	۸۶/۶۴	۸۲/۲۳	۷۱/۶۳	۸۷/۲۵	۷۵/۸۶	۷۶/۷۲	۷۳/۳۵	۷۹/۸	۷۳/۲۲	۳۴/۹۶	P4_P3
۶۷/۳۶	۶۷/۳۶	۷۱/۰۲	۶۵/۲۸	۵۸/۳۳	۷۲/۶۱	۳۰/۹۴	۵۴/۶۶	۴۰/۲۶	۶۱/۱۵	۳۷/۳۸	۴۳/۹	۳۷/۱۹	۳۴/۸۰	P4_P5
۶۳	۶۲/۳۳	۵۱/۸۰	۶۲/۴۸	۴۸/۰۲	۵۲/۱۹	۲۷/۱۳	۴۶/۴۶	۲۶/۹۸	۳۰/۵۲	۲۰/۳۵	۳۲/۷	۱۸/۴۹	۳۱/۸۱	P5_P1
۷۱/۸	۷۱/۷۹	۵۰/۰۹	۷۱/۳۲	۴۵/۶۱	۴۹/۴۱	۲۲/۶۵	۴۲/۰۵	۲۹/۹	۳۷/۱۴	۲۴/۶۲	۳۱/۴	۲۴/۱	۲۹/۲۸	P5_P2
۶۹/۷۱	۶۹/۵۸	۵۸/۰۹	۶۸/۲۶	۵۲/۰۲	۵۸/۴۵	۲۸/۸۶	۵۳/۳۱	۲۹/۹	۴۱/۱۱	۲۸/۴۹	۳۳/۹	۲۸/۳۱	۳۴/۰۶	P5_P3
۷۹/۳۳	۷۹/۲۴	۶۶/۰۹	۷۸/۳۸	۵۵/۹۹	۶۴/۳۱	۳۲/۵۹	۵۷/۰۱	۳۲/۶۴	۳۹/۱۴	۳۱/۳۳	۲۸/۲	۳۱/۲۴	۲۹/۱۲	P5_P4
۷۲/۶۴	۷۲/۲۴	۶۳/۳۸	۷۱/۷۵	۶۳/۱	۶۳/۵۳	۳۵/۵۳	۶۰/۲۴	۴۴/۷۵	۴۹/۵	۳۵/۳۵	۴۷/۹۹	۳۴/۷۶	۳۴/۳۰	میانگین

جدول ۵: دقت (%) طبقه‌بند در مجموعه داده COIL 20

CIFAB	LRSR	CDDA	JDA	TJM	TCA	DAM	GFK	FLDA	NN	
۹۹/۳۱	۸۴/۵۸	۹۱/۵۳	۸۹/۳۱	۹۱/۶۷	۸۸/۴۷	۷۳/۴۷	۷۲/۵	۸۴/۷۲	۸۳/۶۱	C1_C2
۹۷/۹۲	۸۴/۱۷	۹۳/۸۹	۸۸/۴۷	۹۱/۵۳	۸۵/۸۳	۷۱/۲۵	۷۴/۱۷	۸۴/۰۳	۸۲/۷۸	C2_C1
۹۸/۶۲	۸۴/۳۸	۹۲/۷۱	۸۸/۸۹	۹۱/۶	۸۷/۱۵	۷۲/۳۶	۷۳/۳۴	۸۴/۳۸	۸۳/۲	میانگین

جدول ۶: دقت (%) طبقه‌بند در مجموعه داده VOC 2007


CIFAB	LRSR	JDA	TJM	TCA	DAM	GFK	FLDA	NN	
۴۸/۰۴	۳۴/۵۱	۲۷/۲۶	۳۲/۷۵	۳۰/۹۲	۲۹/۷۴	۲۸/۷۶	۲۸/۸۲	۲۸/۶۳	M_V
۵۶/۴۲	۵۳/۸۲	۵۶/۳۴	۴۹/۴۱	۴۷/۴۴	۳۷/۹۳	۴۸/۸۶	۴۹/۰۹	۴۸/۹۴	V_M
۴۷/۲۳	۴۴/۱۶	۴۱/۳۱	۴۱/۰۸	۳۹/۱۸	۳۳/۸۳	۳۸/۸۱	۳۸/۹۵	۳۸/۷۹	میانگین




شکل ۴: ارزیابی دقت روش‌های CIFAB و TCA، JDA، TJM در پایگاه‌داده‌های P3-P5، C-A، U-M در ۲۰ تکرار

جدول ۷: دقت (%) طبقه‌بند در مجموعه داده YALE B

CIFAB	LRSR	JDA	TCA	DAM	GFK	TSL	NN	FLDA	Dataset
۱۰۰/۰۰	۱۰۰/۰۰	۱۰۰/۰۰	۴۰/۷۶	۴۶/۶۵	۱۰۰/۰۰	۱۰۰/۰۰	۹۸/۹۲	۹۸/۹۲	Y1_Y2
۱۰۰/۰۰	۹۸/۳۹	۷۵/۵۴	۴۱/۷۹	۴۵/۰۴	۸۹/۵۲	۸۴/۶۸	۸۷/۹۰	۸۷/۹۰	Y1_Y3
۷۴/۸۹	۳۱/۸۰	۱۳/۸۲	۵۹/۶۳	۶۸/۵۲	۳۰/۸۸	۲۲/۸۱	۲۷/۶۵	۲۷/۶۵	Y1_Y4
۲۴/۲۸	۴/۰۷	۶/۱۱	۲۹/۳۵	۲۸/۷۴	۱۵/۹۶	۸/۴۹	۱۴/۶۰	۱۴/۶۰	Y1_Y5
۱۰۰/۰۰	۱۰۰/۰۰	۱۰۰/۰۰	۴۱/۸۱	۳۵/۳۲	۱۰۰/۰۰	۱۰۰/۰۰	۹۹/۰۰	۱۰۰/۰۰	Y2_Y1
۹۹/۷۳	۹۶/۲۴	۹۰/۳۲	۵۱/۴۷	۳۵/۷۸	۹۹/۷۳	۹۷/۸۵	۹۹/۷۳	۹۹/۷۳	Y2_Y3
۷۸/۸۰	۳۳/۸۷	۲۴/۴۲	۶۴/۷۳	۷۲/۳۳	۷۶/۷۳	۴۷/۴۷	۷۴/۶۵	۷۴/۶۵	Y2_Y4
۲۶/۱۵	۵/۲۶	۷/۹۸	۳۳/۷	۳۵/۱۱	۳۳/۴۵	۱۳/۴۱	۳۰/۹۰	۳۰/۹۰	Y2_Y5
۱۰۰/۰۰	۹۹/۶۲	۸۰/۱۸	۳۴/۶۹	۴۱	۹۸/۶۲	۱۰۰/۰۰	۹۹/۰۸	۹۹/۰۸	Y3_Y1
۱۰۰/۰۰	۹۹/۹۷	۹۲/۷۴	۴۷/۷	۵۹/۳۶	۱۰۰/۰۰	۱۰۰/۰۰	۹۹/۷۳	۹۹/۷۳	Y3_Y2
۹۵/۶۲	۸۷/۷۹	۸۴/۱۰	۵۶/۲۳	۷۲/۳۳	۹۷/۰۰	۸۳/۴۱	۹۶/۳۱	۹۶/۵۶	Y3_Y4
۴۷/۸۸	۲۱/۰۵	۲۵/۶۴	۳۳/۱۵	۴۰/۳۲	۶۰/۲۷	۴۱/۰۹	۵۸/۵۷	۵۸/۵۷	Y3_Y5
۹۹/۵۴	۹۹/۵۴	۷/۸۳	۵۵/۶۴	۶۹/۳۶	۸۲/۴۹	۹۷/۷۰	۸۲/۴۹	۸۲/۴۹	Y4_Y1
۹۹/۷۳	۱۰۰/۰۰	۲۶/۰۸	۶۷/۸۳	۷۷/۲۹	۹۴/۳۵	۹۷/۳۱	۹۳/۵۵	۹۳/۵۵	Y4_Y2
۹۸/۶۶	۹۹/۴۶	۸۵/۴۸	۷۵/۸۶	۷۶/۷۲	۹۳/۸۲	۹۸/۹۲	۹۳/۵۵	۹۳/۵۵	Y4_Y3
۹۱/۶۸	۵۵/۵۲	۶۴/۸۶	۴۰/۲۶	۶۱/۱۵	۷۹/۹۷	۸۴/۵	۷۹/۶۳	۷۹/۶۳	Y4_Y5
۴۹/۷۷	۹۴/۰۱	۲۲/۵۸	۲۶/۹۸	۳۰/۵۲	۳۷/۳۳	۳۷/۳۳	۳۶/۸۷	۳۷/۳۳	Y5_Y1
۵۴/۰۳	۸۸/۴۴	۸/۳۳	۲۹/۹	۳۷/۱۴	۵۰/۰۰	۴۱/۶۷	۴۶/۲۴	۴۶/۲۴	Y5_Y2
۷۳/۱۲	۹۳/۸۲	۲۷/۹۶	۲۹/۹	۴۱/۱۱	۶۸/۸۲	۵۵/۳۸	۶۵/۳۲	۶۵/۳۲	Y5_Y3
۹۵/۶۲	۹۴/۷۰	۸۳/۴۰	۳۳/۶۴	۳۹/۱۴	۸۸/۷۱	۷۸/۸۰	۸۸/۴۸	۸۸/۴۸	Y5_Y4
۸۰/۴۷	۷۵/۲۰	۵۱/۳۷	۴۴/۷۵	۴۹/۵	۷۴/۸۸	۶۹/۵۴	۷۳/۷۱	۷۳/۷۴	میانگین




شکل ۵: دقت طبقه‌بندی در پایگاه‌داده‌های آفیس و کالکت و اعداد با استفاده از روش‌های NN، GFK، TCA، TJM، JDA، DAM، TSL، CIFAB+NN، CIFAB+SVM (نمایش بهتر به صورت رنگی)




شکل ۶: دقت طبقه‌بندی در پایگاه‌داده پای با استفاده از روش‌های NN، GFK، TCA، TJM، JDA، DAM، TSL، CIFAB+NN، CIFAB+SVM (نمایش بهتر به صورت رنگی)

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 CIFAB نسبت به جدیدترین روش‌های حوزه یادگیری ماشین و یادگیری انتقالی بر روی دامنه‌های مختلف می‌باشد. برای ادامه کار، ما در حال برنامه‌ریزی جهت گسترش CIFAB برای کاهش هم‌زمان توزیع اختلاف‌های حاشیه‌ای و شرطی می‌باشیم. علاوه بر این در تلاش جهت توسعه روش CIFAB برای سیستم‌های چندمنبعی هستیم. در این راستا، به دنبال انتقال دانش از چند منبع مرتبط به یک منبع هدف می‌باشیم تا بتوانیم صحت پیش‌بینی برچسب دامنه هدف را هر چه بیشتر ارتقا بخشیم.



شکل ۷: عملکرد روش پیشنهادی بر روی داده‌های ورودی. دایره‌های ۱ و ۲ کلاس‌های نمونه‌های آموزشی هستند و دایره‌های A، B و C کلاس‌های نمونه‌های آزمایشی می‌باشند. دو کلاس A و C در زیرفضایی که با استفاده از الگوریتم FLDA به دست آمده است ادغام شده‌اند و قابل تفکیک پذیری نیستند اما در زیر فضایی که CIFAB با استفاده از الگوریتم FLDA و واگرایی برگمن به دست می‌آورد کلاس‌های A، B و C به خوبی قابل تفکیک هستند چون واگرایی برگمن علاوه بر این که اختلاف توزیع شرطی بین نمونه‌های آموزشی و آزمایشی را کاهش می‌دهد اطلاعات اولیه تفکیک‌کننده نمونه‌ها را از جمله ساختار منیفولد داده‌ها را حفظ می‌کند.



شکل ۸: مقایسه دقت (%) مدل پیشنهادی با توجه به کاهش اختلاف توزیع شرطی و روش FLDA

۵-۴- بررسی ضرورت کاهش اختلاف توزیع شرطی

در صورتی که در تابع هدف (رابطه ۱۲) پارامتر λ برابر صفر در نظر گرفته شود (طبق نتایج گزارش شده در جداول ۲ الی ۴، فیلد FLDA) دقت مدل به دلیل وجود اختلاف توزیع شرطی بین دامنه‌های منبع و هدف به شدت کاهش می‌یابد. منظور از توزیع شرطی همان تابع پیش‌بینی است که در دامنه منبع ایجاد می‌شود و باید با دامنه هدف تطبیق یابد تا برچسب‌های نمونه‌های دامنه هدف را پیش‌بینی کند. در واقع CIFAB به دنبال پیش‌بینی برچسب یکسان به ازای داده‌های یکسان در دو دامنه مختلف است. در شرایطی که اختلاف توزیع شرطی بین دامنه‌های منبع و هدف زیاد باشد، روش‌های کاهش بعد به تنهایی پاسخ‌گوی مسائل شیفت دامنه‌ها نیستند و به دلیل نادیده گرفتن 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، اطلاعات اولیه با استفاده از واگرایی برگمن در نظر گرفته می‌شود. واگرایی برگمن قادر است اطلاعات به دست آمده از نمونه‌های دامنه منبع را، با به حداقل رساندن اختلاف توزیع شرطی بین دامنه‌ها به نمونه‌های دامنه هدف منتقل کند که باعث تفکیک پذیری بهتر کلاس‌های مختلف در فضای جدید می‌شود. به همین ترتیب براساس نتایج نشان داده شده در شکل ۸ نمودار FLDA به دلیل عدم بهره‌گیری از اطلاعات تفکیک‌کننده اولیه داده‌های دامنه منبع و نادیده گرفتن اختلاف توزیع شرطی بین دامنه‌ها دقت پایینی در تمام پایگاه داده‌های مورد آزمایش دارد.

۶- نتیجه‌گیری و کارهای آتی

پردازش تصویر به عنوان ابزار قدرتمند برای درک تصاویر توسط کامپیوتر است که توانایی استخراج اطلاعات و ویژگی‌های تصاویر را دارا می‌باشد. یادگیری ماشین یکی از شاخه‌های پرکاربرد هوش مصنوعی بوده که در زمینه پردازش تصویر به دنبال یافتن الگوریتم‌هایی برای طبقه‌بندی تصاویر با دقت بالا می‌باشد. در این مقاله، روش تطبیق دامنه بدون نظارت CIFAB برای ایجاد تطبیق در دامنه‌های بصری و کاهش اختلاف توزیع شرطی بین دامنه‌ها پیشنهاد شده است. روش پیشنهادی، در ابتدا با استفاده از واگرایی برگمن یک نمایش تطبیق‌پذیر مشترک بین دامنه‌های منبع و هدف ایجاد می‌کند که اختلاف توزیع شرطی 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.

CIFAB با افزایش تطبیق‌پذیری بین ساختار دامنه‌های منبع و هدف، باعث افزایش دقت طبقه‌بندی در پیش‌بینی برچسب برای داده‌های بدون برچسب دامنه هدف می‌شود. روش CIFAB بر روی ۵۸

مراجع

- [12] J. Tahmoresnezhad and S. Hashemi, "Visual domain adaptation via transfer feature learning," *Knowledge and Information Systems*, vol. 50, no. 2, pp. 585–605, 2017.
- [13] M. Long, J. Wang, G. Ding, S. J. Pan and P. Yu, "Adaptation regularization: a general framework for transfer learning", *IEEE Trans. Knowl. Data Eng.*, vol. 26, pp. 1076–1089, 2013.
- [14] 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.
- [15] G.Griffin, A. Holub and P. Perona, "Caltech-256 object category dataset", Technical Report7694, 2007.
- [16] J. J. Hull, "A database for handwritten text recognition research", *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 16, no. 5, pp. 550–554, 1994.
- [17] Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, "Gradient-based learning applied to document recognition", *Proc. IEEE*, vol. 86, no. 11, pp. 2278–2324, 1998.
- [18] 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.
- [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] L. Duan, D. Xu, and I. W.-H. Tsang, "Domain adaptation from multiple sources: A domainindependent regularization approach," *IEEE Transactions on Neural Networks and Learning Systems*, vol. 23, no. 3, pp. 504–518, 2012.
- [21] S. J. Pan, I. W. Tsang, J. T. Kwok, and Q. Yang, "Domain adaptation via transfer component analysis," *IEEE Transactions on Neural Networks*, vol. 22, no. 2, pp. 199–210, 2011.
- [22] 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.
- [23] 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.
- [۲۴] طاهره زارع بیدکی و محمدتقی صادقی، «بهینه‌سازی وزن‌ها در کرنل مرکب برای طبقه‌بند مبتنی بر نمایش تنک کرنلی»، *مجله مهندسی برق دانشگاه تبریز*، جلد ۴۷، شماره ۳، صفحات ۱۰۵۹–۱۰۷۲، ۱۳۹۶.
- [25] 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.
- [1] 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.
- [2] 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.
- [3] 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.
- [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] I. K. Fodor, "A survey of dimension reduction techniques," *Center for Applied Scientific Computing, Lawrence Livermore National Laboratory*, vol. 9, pp. 1–18, 2002.
- [6] 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.
- [۷] مهرداد حیدری ارجلو، سید قدرت‌اله سیف‌السادات و مرتضی رزاز، «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.
- [8] 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.
- [9] Saenko K, Kulis B, Fritz M, Darrell T. Adapting visual category models to new domains. *Computer Vision–ECCV 2010*. 2010:213-26.
- [10] 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.
- [11] 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.

زیر نویس‌ها

⁹ Principal components analysis

¹⁰ Linear discriminant analysis

¹¹ Random Projection

¹² Independent Component Analysis

¹³ Overfit

¹⁴ Bregman Divergence

¹⁵ Squared loss

¹⁶ Kullback-Leibler (KL)

¹ Training data

² Testing data

³ Unsupervised

⁴ Semi-supervised

⁵ Source domain

⁶ Target domain

⁷ Marginal distribution

⁸ Conditional distribution

-
- | | |
|---|---|
| <p>17 Logistic loss</p> <p>18 Mahalanobis distance</p> <p>19 Feature representation</p> <p>20 Original space</p> <p>21 Latent space</p> <p>22 Cross domains Image Processing via Fisher Linear Discriminative Analysis and Bregman Divergence</p> <p>23 Kernel density estimation (KDE)</p> <p>24 Nearest neighbor</p> <p>25 Support vector machine</p> | <p>26 Instance based</p> <p>27 Feature based</p> <p>28 Model based</p> <p>29 Fisher's linear discriminant analysis</p> <p>30 Trace</p> <p>31 Pre-learnt</p> <p>32 Smoothness</p> <p>33 Regularization</p> <p>34 Sparse constraints</p> <p>35 Low-Rank</p> |
|---|---|