

پردازش تصویر بین دامنه‌ای با استفاده از تحلیل

تفکیک خطی و تطبیق دامنه مبتنی بر نمونه

مژده زندی فر و جعفر طهمورث نژاد*

دانشکده مهندسی فناوری اطلاعات و کامپیوتر، دانشگاه صنعتی ارومیه، ارومیه، ایران

چکیده

پردازش تصویر روشی برای اعمال برخی عملیات‌ها بر روی یک تصویر است به طوری که با استفاده از آن، تصاویری با کیفیت بالاتر به دست آمده با برخی اطلاعات مفید از تصویر استخراج می‌شود. الگوریتم‌های سنتی پردازش تصویر در شرایطی که تصاویر آموزشی (دامنه منبع) که برای یادداهنی مدل استفاده می‌شوند، توزیع متفاوتی از تصاویر آزمایش (دامنه هدف) داشته باشند، نمی‌توانند عملکرد خوبی داشته باشند. با این حال، بسیاری از برنامه‌های کاربردی دنیای واقعی به علت کمبود داده‌های برچسب‌دار آموزشی دارای محدودیت هستند؛ از این‌رو از داده‌های برچسب‌دار دامنه‌های دیگر استفاده می‌کنند. به این ترتیب به خاطر اختلاف توزیع بین دامنه‌های منبع و هدف، طبقه‌بند یادگرفته شده براساس مجموعه آموزشی بر روی داده‌های آزمایشی عملکرد ضعیفی خواهد داشت. یادگیری انتقالی و انتباق دامنه، با به کارگیری مجموعه داده‌های موجود دو راه بر جسته برای مقابله با این چالش هستند، و حتی با وجود اختلاف توزیع قابل ملاحظه بین دامنه‌ها می‌توانند دانش را از دامنه‌های مرتبط به دامنه هدف انتقال دهند. فرض اصلی در مسأله تغییر دامنه این است که توزیع حاشیه‌ای یا توزیع شرطی داده‌های منبع و هدف متفاوت باشد. تطبیق دامنه به‌طور صریح با استفاده از معیار فاصله از پیش تعیین شده تفاوت در توزیع حاشیه‌ای، توزیع شرطی یا هر دو توزیع را کاهش می‌دهد. در این مقاله، ما به یک سناریوی چالش‌برانگیز می‌پردازیم که در آن تصاویر دامنه‌های منبع و هدف در توزیع‌های حاشیه‌ای متفاوت بوده و تصاویر هدف دارای برچسب نیستند. بیش تر روش‌های قبلی دو استراتژی یادگیری تطبیق ویژگی‌ها و وزن‌دهی مجدد نمونه‌ها را به‌طور مستقل برای تطبیق دامنه‌ها مورد بررسی قرار داده‌اند. در این مقاله، ما نشان می‌دهیم زمانی که تفاوت دامنه‌ها به‌طور قابل توجهی بزرگ باشد، هر دو استراتژی مهم و اجتناب‌پذیر هستند. روش پیشنهادی ما تحت عنوان تطبیق دامنه مبتنی بر نمونه برای طبقه‌بندی تصاویر (DAIC)، یک فرایند کاهش بُعد بوده که با کاهش اختلاف توزیع تصاویر آموزشی و آزمایشی و به کارگیری هم‌زمان تطبیق ویژگی‌ها و وزن‌دهی مجدد کارایی مدل را افزایش می‌دهد. ما با گسترش واگرایی برگمن غیرخطی برای اندازه‌گیری تفاوت توزیع قابل ملاحظه بین دامنه‌ها استفاده می‌کنیم؛ همچنین، DAIC از مزیت برچسب‌گذاری اولیه برای داده‌های هدف به صورت تکرارشونده برای هم‌گرایی مدل استفاده می‌کند. آزمایش‌های گسترش‌دهنده ما نشان می‌دهد که DAIC به‌طور قابل توجهی بهتر از الگوریتم‌های یادگیری ماشین پایه و دیگر روش‌های یادگیری انتقالی در نه مجموعه داده بصری تحت سناریوهای مختلف عمل می‌کند.

واژگان کلیدی: پردازش تصویر، یادگیری انتقالی، واگرایی برگمن، کاهش اختلاف توزیع حاشیه‌ای، کاهش ابعاد

Sample-oriented Domain Adaptation for Image Classification

Mojdeh Zandifar & Jafar Tahmoresnezhad*

Faculty of IT & Computer Engineering, Urmia University of Technology, Urmia, Iran

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

* Corresponding author

*نویسنده عهده‌دار مکاتبات

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). Also, many real world applications suffer from a limited number of training labeled data and therefore benefit from the related available labeled datasets to train the model. In this way, since there is the distribution difference across the source and target domains (domain shift problem), the learned classifier on the training set might perform poorly on the test set. Transfer learning and domain adaptation are two outstanding solutions to tackle this challenge by employing available datasets, even with significant difference in distribution and properties, to transfer the knowledge from a related domain to the target domain. The main assumption in domain shift problem is that the marginal or the conditional distribution of the source and the target data is different. Distribution adaptation explicitly minimizes predefined distance measures to reduce the difference in the marginal distribution, conditional distribution, or both. In this paper, we address a challenging scenario in which the source and target domains are different in marginal distributions, and the target images have no labeled data. Most prior works have explored two following learning strategies independently for adapting domains: feature matching and instance reweighting. In the instance reweighting approach, samples in the source data are weighted individually so that the distribution of the weighted source data is aligned to that of the target data. Then, a classifier is trained on the weighted source data. This approach can effectively eliminate unrelated source samples to the target data, but it would reduce the number of samples in adapted source data, which results in an increase in generalization errors of the trained classifier. Conversely, the feature-transform approach creates a feature map such that distributions of both datasets are aligned while both datasets are well distributed in the transformed feature space. In this paper, we show that both strategies are important and inevitable when the domain difference is substantially large. Our proposed using sample-oriented Domain Adaptation for Image Classification (DAIC) aims to reduce the domain difference by jointly matching the features and reweighting the instances across images in a principled dimensionality reduction procedure, and construct new feature representation that is invariant to both the distribution difference and the irrelevant instances. We extend the nonlinear Bregman divergence to measure the difference in marginal, and integrate it with Fisher's linear discriminant analysis (FLDA) to construct feature representation that is effective and robust for substantial distribution difference. DAIC benefits pseudo labels of target data in an iterative manner to converge the model. We consider three types of cross-domain image classification data, which are widely used to evaluate the visual domain adaptation algorithms: object (Office+Caltech- 256), face (PIE) and digit (USPS, MNIST). We use all three datasets prepared by and construct 34 cross-domain problems. The Office-Caltech-256 dataset is a benchmark dataset for cross-domain object recognition tasks, which contains 10 overlapping categories from following four domains: Amazon (A), Webcam (W), DSLR (D) and Caltech256 (C). Therefore $4 \times 3 = 12$ cross domain adaptation tasks are constructed, namely A → W, ..., C → D. USPS (U) and MNIST (M) datasets are widely used in computer vision and pattern recognition tasks. We conduct two handwriting recognition tasks, i.e., usps-mnist and mnist-usps. PIE is a benchmark dataset for face detection task and has 41,368 face images of size 32x32 from 68 individuals. The images were taken by 13 synchronized cameras and 21 flashes, under varying poses, illuminations, and expressions. PIE dataset consists five subsets depending on the different poses as follows: PIE1 (C05, left pose), PIE2 (C07, upward pose), PIE3 (C09, downward pose), PIE4 (C27, frontal pose), PIE5 (C29, right pose). Thus, we can construct 20 cross domain problems, i.e., P1 → P2, P1 → P3, ..., P5 → P4. We compare our proposed DAIC with two baseline machine learning methods, i.e., NN, Fisher linear discriminant analysis (FLDA) and nine state-of-the-art domain adaptation methods for image classification problems (TSL, DAM, TJM, FIDOS and LRSR). Due to these methods are considered as dimensionality reduction approaches, we train a classifier on the labeled training data (e.g., NN classifier), and then apply it on test data to predict the labels of the unlabeled target data. DAIC efficiently preserves and utilizes the specific information among the samples from different domains. The obtained results indicate that DAIC outperforms several state of-the-art adaptation methods even if the distribution difference is substantially large.

Keywords: Image processing, Transfer learning, Bregman divergence, Marginal distribution difference reduction, Dimensionality reduction

کم داده‌های برچسب‌دار^۱ موجود، برای آموزش محدود می‌شود. از طرف دیگر هزینه برچسب‌زن داده‌ها با توجه به دخالت‌داشتن انسان در این زمینه، مقرنون به صرفه نبوده و از لحاظ زمانی وقت‌گیر است؛ در حالی که جمع‌آوری اطلاعات تصویری بدون برچسب به مرأت ساده‌تر بوده و در واقع داده‌های بدون برچسب به طور مداوم در حال تولیدشدن هستند.

¹ Label

۱- مقدمه

پردازش تصویر یکی از مسائل مهم در هوش مصنوعی و یادگیری ماشین است، که هدف اصلی آن طراحی و ساخت سامانه‌های خبره مبتنی بر هوش مصنوعی و بینایی ماشین است. الگوریتم‌های پردازش تصویر موجود، منجر به توسعه روش‌های قوی در زمینه‌های یادگیری ماشین و بینایی رایانه‌ای شده‌اند. اگرچه این الگوریتم‌ها تاکنون به طور قابل توجهی پیشرفت داشته‌اند، اما عملکرد آن‌ها با توجه به تعداد



توزيع داده‌های آموزشی و آزمایشی با یادگیری متفاوت است. در انطباق دامنه، به جای فرض یکسان بودن توزیع داده‌ها در دو مجموعه آموزشی و آزمایشی، فرض می‌شود که دارای توزیع متفاوت ولی مرتبط هستند؛ سپس، سعی می‌شود تا با توجه به ارتباط بین داده‌های آموزشی و آزمایشی، طبقه‌بندی آموزش داده شود که بر روی داده‌های آزمایشی از دقت قابل قبولی برخوردار باشد. تطبیق دامنه در انواع مسائل بازناسی الگو^{۱۱}، پردازش زبان طبیعی^{۱۲}، پردازش گفتار^{۱۳}، مکان‌یابی WI-FI^{۱۴}، زمینه بینایی ماشین در تشخیص چهره، آشکارسازی اشیا، تشخیص عابر پیاده^{۱۵} و بازناسی رویداد^{۱۶} کاربرد دارد. مسئله تطبیق دامنه تاکنون در حوزه پردازش زبان طبیعی بسیار موفق بوده، اما تلاش‌هایی که برای این مسئله در حوزه بینایی رایانه‌ای شده، محدود بوده و قابل گسترش است [۳].

مهم‌ترین چالش در انتقال مفاهیم یادگرفته شده جلوگیری از بروز انتقال منفی^{۱۷} است، به این معنی که استفاده از روش‌های تطبیق دامنه نه تنها مفید نبوده بلکه باعث کاهش کیفیت فرآیند یادگیری شده است. مهم‌ترین کاری که باید انجام شود، این است که از انتقال منفی پیش‌گیری شود. چالش دیگری که در تطبیق دامنه وجود دارد، اندازه‌گیری اختلاف توزیع (تفاوت) بین دامنه‌های منبع و هدف است [۴]؛ زیرا با توجه به این تفاوت می‌توان از انتقال منفی جلوگیری کرد. بنابراین معیار اندازه‌گیری اختلاف توزیع دامنه‌ها با یادگیر بسیار مهم است؛ یعنی با چه معیاری فاصله بین دامنه‌ها و میزان تفاوت آن‌ها با یادگیر را می‌توان اندازه گرفت. اختلاف توزیع بین دامنه‌های منبع و هدف، شامل اختلاف در توزیع حاشیه‌ای^{۱۸} و شرطی^{۱۹} است. برای مثال می‌توان گفت اگر مسئله یک مسئله دسته‌بندی استناد باشد، اختلاف توزیع حاشیه‌ای منتظر با حالتی است که دو مجموعه استناد منبع و هدف روی موضوع‌های^{۲۰} متفاوتی متمرکز شده باشند. همچنین برای اختلاف توزیع شرطی می‌توان حالتی را درنظر گرفت که استناد دو دامنه منبع و هدف از لحاظ دسته‌های تعریف شده توسط کاربران بسیار نامتوازن^{۲۱} باشند. در سامانه‌های یادگیری ماشین، وجود اختلاف توزیع حاشیه‌ای و

الگوریتم‌های یادگیری موجود اغلب با این پیش‌فرض عمل می‌کنند که داده‌های آموزشی^۱ و داده‌های آزمایشی^۲ هر دو از یک توزیع^۳ و فضای ویژگی^۴ یکسانی هستند [۱]. با این حال در عمل و در بسیاری از برنامه‌های کاربردی دنیا واقعی، این فرض همواره نقض می‌شود و عملکرد این روش‌ها برای داده‌هایی از دامنه‌های متفاوت کاهش می‌یابد که این امر ناشی از وجود تفاوت در توزیع داده‌های آموزشی استفاده شده برای آموزش طبقه‌بند با توزیع داده‌های آزمایشی است. تفاوت در توزیع نمونه‌های آموزشی و آزمایشی می‌تواند ناشی از شرایط تهیه و یا گردآوری آن‌ها باشد. تفاوت در روش‌نایابی، زاویه دید، دقت، تصویر زمینه و شرایط عکس‌برداری می‌تواند منجر به تغییر در توزیع نمونه‌های دو مجموعه داده شود. به عنوان مثال مسئله تشخیص اشیا^۵ یکی از مسائل پرکاربرد حوزه بینایی ماشین و پردازش تصویر به شمار می‌رود. امروزه با رشد روزافزون سامانه‌های بینایی ماشین در کاربردهای روزمره، تشخیص اشیا بیش از پیش مورد توجه قرار گرفته است. به عبارتی، تفاوت در توزیع نمونه‌های آموزشی و آزمایشی (برای نمونه تفاوت در روش‌نایابی، زاویه دید، دقت، تصویر زمینه و شرایط عکس‌برداری تصاویر) می‌تواند منجر به افت کارایی و مدل‌های تشخیص اشیا در پردازش تصویر شود. برای نمونه اگر یک مدل با استفاده از تصاویر سی‌تی اسکن^۶ و ایکس-ری^۷ آموزش دیده باشد و از آن جهت تشخیص اعضای بدن در یک تصویر ام آر آی^۸ استفاده شود، به طور طبیعی در شرایط عادی مدل کارایی قابل قبولی نخواهد داشت [۲]؛ در چنین شرایطی اگر بتوان از دانش به دست آمده از داده‌های آموزشی (که دارای توزیع یا فضای ویژگی متفاوتی با داده‌های آزمایشی است) به نحوی برای داده‌های آزمایشی استفاده کرد، می‌توان عملکرد مدل ایجاد شده را در فضای آزمون بهبود بخشید. راه حلی که در سال‌های اخیر مورد توجه قرار گرفته، انطباق دامنه است.

انطباق دامنه^۹ یکی از زمینه‌های یادگیری انتقالی^{۱۰} است و یک مسئله مهم در یادگیری ماشین محسوب می‌شود که هدف آن یادگیری طبقه‌بند مناسبی است که بتواند دقت قابل قبولی بر روی داده‌های آزمایشی داشته باشد، در حالی که

^۱ Training data

^۲ Testing data

^۳ Distribution

^۴ Feature space

^۵ Object detection

^۶ CT scan

^۷ X-Ray

^۸ MRI

^۹ Domain adaptation

^{۱۰} Transfer learning

^{۱۱} Pattern recognition

^{۱۲} Natural-language processing(NLP)

^{۱۳} Speech processing

^{۱۴} WI-FI localization

^{۱۵} Pedestrian detection

^{۱۶} Event recognition

^{۱۷} Negative transfer

^{۱۸} Marginal distribution

^{۱۹} Conditional distribution

^{۲۰} Topic

^{۲۱} Unbalanced

(۱) تطبیق دامنه نیمه‌نظرارت شده^۹: که در آن، دامنه هدف شامل تعداد کمی داده برچسبدار است، یعنی اگر تعداد داده‌های دامنه منبع n_s باشد، دامنه منبع به صورت $D_s = \{x_i, y_i\}_{i=1}^{n_s}$ و دامنه هدف به صورت $D_t = T_u \cup T_l$ تعریف می‌شوند. اگر تعداد داده‌های برچسبدار و بدون T_l برچسب دامنه هدف به ترتیب n_{tu} و n_{tu} فرض شود، $T_l = \{x_i, y_i\}_{i=1}^{n_{tl}}$ مجموعه داده‌های بدون برچسب دامنه هدف است. همچنین در این مسائل فرض می‌شود تعداد زیادی داده بدون برچسب در دامنه هدف موجود است؛ به طوری که $n_{tu} \ll n_{tl}$ و علاوه‌بر این فرض می‌شود داده‌های برچسبدار دامنه هدف به تنها یکی برای ساخت یک طبقه‌بند مناسب، مفید نیستند.

(۲) تطبیق دامنه بدون نظارت^{۱۰}: که در آن، هیچ یک از داده‌های دامنه هدف، برچسب ندارند، یعنی اگر تعداد داده‌های دامنه‌های منبع و هدف به ترتیب n_s و n_t باشد، $D_s = \{x_i, y_i\}_{i=1}^{n_s}$ و $D_t = \{x_i\}_{i=1}^{n_t}$ تعریف می‌شوند [۶]. در این پژوهش، مسأله تطبیق دامنه بدون نظارت مورد بررسی قرار گرفته است، به عبارتی فرض شده است، فضای ویژگی دامنه‌های منبع و هدف یکسان هستند ($X_s = X_t$) و فقط توزیع آن‌ها با یکدیگر متفاوت است. هدف یادگیری یکتابع پیش‌بینی f_t برای دامنه هدف، با استفاده از داده‌های برچسبدار دامنه منبع است؛ به طوری که تابع پیش‌بینی حاصل، عملکرد مطلوبی روی دامنه هدف داشته باشد. در روش پیشنهادی برای ایجاد تطبیق بین دامنه‌ها از روش‌های تطبیق خصوصیات استفاده می‌شود. روش‌های تطبیق خصوصیات، الگوریتم‌هایی هستند که می‌توانند نمایش خصیصه‌ای نمونه‌ها در فضای اصلی یا در فضای پنهان را تغییر دهند؛ این نوع الگوریتم‌ها در بخش‌های بعدی به تفصیل توضیح داده می‌شوند.

روش پیشنهادی این مقاله با عنوان DAIC^{۱۱}، یک روش بدون نظارت با بهره‌گیری از تطبیق خصوصیات و وزن دهنده نمودن نمونه‌ها است. DAIC با استفاده از الگوریتم FLDA^{۱۲} و اگرایی برگمن یک نمایش جدید از داده‌ها ایجاد می‌کند تا اختلاف توزیع حاشیه‌ای دامنه‌ها را کاهش داده و به صورت همزمان از روش وزن دهنده مجدد برای انتخاب

شرطی بین دامنه‌های منبع و هدف موجب می‌شود، مدل طبقه‌بند ایجادشده در دامنه منبع، دقت پایینی در پیش‌بینی برچسب‌های نمونه‌های دامنه هدف داشته باشد [۴].

بیشتر روش‌های یادگیری انتقالی موجود، از فاصله اقلیدسی^۱ یا روش بیشینه اختلاف میانگین‌ها^۲ (MMD) برای محاسبه اختلاف توزیع بین نمونه‌های دامنه منبع و هدف استفاده می‌کنند. این دو متريک دارای محدودیت‌های هستند که ممکن است، روی انتقال دانش تاثیر منفی بگذارند. به عنوان مثال توابع هدفی که با استفاده از فاصله اقلیدسی تعریف می‌شوند، ممکن است به خوبی بهینه نشوند و دچار مشکل زیربهینه^۳ شوند. در واقع فاصله اقلیدسی در فضای داده‌های ورودی، لزوماً نمی‌تواند به خوبی عدم شباهت داده‌ها را نشان دهد، زیرا ممکن است برخی از ویژگی‌ها نسبت به بقیه اهمیت بیشتری داشته باشند. علاوه‌بر این روش بیشینه اختلاف میانگین‌ها نمی‌تواند برای مسائل رگرسیون مناسب باشد؛ چون ممکن است، داده‌های برچسبدار از یک جامعه آماری بزرگ برآورد شده باشند. همچنین این دو متريک نمی‌توانند اطلاعات تفکیک‌کننده اولیه (به عنوان مثال اطلاعات هندسی و اطلاعات آماری داده‌ها) به دست آمده از دامنه منبع را به این‌گونه مسائل از واگرایی برگمن^۴ برای سنجش و کاهش اختلاف توزیع بین دامنه‌های منبع و هدف استفاده می‌شود. واگرایی برگمن [۵] یک واگرایی جامع است که تعداد زیادی از فواصل معروف و پرکاربرد از جمله تابع هزینه جمع مربعات^۵، و اگرایی کولبک – لاپلر^۶، تابع هزینه منطقی^۷، فاصله ماهalanobis^۸ را شامل می‌شود. واگرایی برگمن با کاهش تفاوت بین توزیع نمونه‌های آموزشی و آزمایشی می‌تواند دانش تفکیک‌کننده به دست آمده از نمونه‌های آموزشی را به نمونه‌های آزمایش انتقال دهد. همچنین واگرایی برگمن، اطلاعات تفکیک‌کننده به دست آمده از نمونه‌های آموزشی را برای تفکیک‌پذیری هرچه بهتر رده‌های دامنه هدف، حفظ می‌کند.

در مسائل یادگیری انتقالی می‌توان از یک یا چندین دامنه منبع دانش موردنیاز را به دامنه هدف انتقال داد که در این پژوهش فرض شده است برای هر مسئله تنها یک دامنه منبع D_s و یک دامنه هدف D_t وجود دارد. مسائل تطبیق دامنه می‌توانند در دو حالت کلی زیر مورد بررسی قرار بگیرند:

¹ Euclidean distance

² Maximum mean discrepancy (MMD)

³ Suboptimal

⁴ Bregman divergence

⁵ Squared loss

⁶ Kullback-Leibler (KL)

⁷ Logistic loss

⁸ Mahalanobis distance

⁹ Semi-supervised

¹⁰ Unsupervised

¹¹ Sample-oriented Domain Adaptation for Image Classification (DAIC)

¹² Fisher's linear discriminant analysis

۲- کارهای پیشین

رویکردهای یادگیری انتقالی را می‌توان به سه دسته کلی تقسیم کرد:

- رویکردهای مبتنی بر انتقال پارامتر
- رویکردهای مبتنی بر نمونه
- رویکردهای مبتنی بر ویژگی

رویکردهای مبتنی بر انتقال پارامتر فرض می‌کنند که دو وظیفه^۱ در دامنه منبع و هدف دارای تعدادی پارامتر یکسان یا توزیع پیشین^۲ با ابر پارامترهای^۳ یکسان است. بدین ترتیب با پیدا کردن این پارامترها یا توزیع‌های پیشین مشترک می‌توان یادگیری را به دامنه جدید انتقال داد. از کارهای انجام شده در این دسته می‌توان به ARTL^۴ [۷] و JACRL [۳۱] اشاره کرد. ARTL یک روش تنظیم تطبیقی است که برای یادگیری یک طبقه‌بند انطباقی با کاهش خطای طبقه‌بند در دامنه منبع، افزایش انطباق هندسی دامنه‌ها در فضای جدید و ایجاد تطبیق در توزیع مشترک بین دامنه‌ها یک مدل مقاوم در برابر تغییرات ایجاد می‌کند. در این روش هدف ساخت یک رده‌بند انطباقی است؛ به طوری که این معیارها محقق شوند: ۱) اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌های منبع و هدف کاهش یابد، ۲) ریسک ساختاری مدل در داده‌های برچسب‌دار دامنه منبع کمینه شود، و ۳) نرخ سازگاری مدل و ساختار هندسی داده‌ها بیشینه شود.

JACRL یک رویکرد دومرحله‌ای مبتنی بر مدل برای حل مشکل اختلاف توزیع بین دامنه‌ها است. در مرحله نخست، JACRL با بهره‌گیری از تطبیق خصوصیات، داده‌های منبع و هدف براساس تجزیه و تحلیل اجزای اصلی (PCA) به یک زیرفضای مشترک با بعد کم نکاشت می‌شوند؛ سپس در این فضای استفاده از معیار بیشینه اختلاف میانگین (MMD)، اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها کاهش می‌یابد. در مرحله دوم، یک رده‌بند انطباقی بر روی داده‌های منبع و هدف به منظور کمینه کردن ریسک تحریبی تابع پیش‌بینی در داده‌های برچسب‌دار دامنه منبع و همچنین بیشینه کردن نرخ سازگاری تابع پیش‌بینی و ساختار هندسی داده‌ها، ایجاد می‌شود.

رویکردهای مبتنی بر نمونه براساس وزن‌دهی مجدد نمونه‌ها و یا انتخاب نمونه‌هایی که تفاوت بین توزیع دامنه‌های منبع و هدف را کمینه می‌سازند، عمل می‌کنند. روش‌های مبتنی بر نمونه با تخصیص وزن به نمونه‌ها، تابع ضرر^۵ را روی

نمونه‌هایی از دامنه منبع که بیشترین شباهت را به نمونه‌های دامنه هدف دارند (برای ایجاد تطبیق‌بازیری بیشتر بین دامنه‌ها) استفاده کند.

اهداف اصلی رویکرد پیشنهادی بدین صورت خلاصه شده است: ۱) حفظ ساختار اصلی داده‌ها: DAIC به کمک فرآیند FLDA، داده‌های دامنه منبع و هدف را به یک زیرفضای ویژگی کم‌بعد نگاشت می‌کند به طوری که ساختار اصلی داده‌ها حفظ شود، ۲) تطبیق توزیع حاشیه‌ای: DAIC با استفاده از واگرایی برگمن اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف را در زیرفضای نگاشتشده کاهش می‌دهد، و ۳) انتخاب نمونه: با کاهش اختلاف توزیع حاشیه‌ای بین نمونه‌ها، همچنان ممکن است، نمونه‌هایی در دامنه منبع وجود داشته باشند که مرتبط با نمونه‌های هدف نباشند. برای حل این مشکل DAIC با کمینه کردن نرم $\ell_{2,1}$ بر روی داده‌های دامنه منبع، نمونه‌هایی از دامنه منبع را که مرتبط با دامنه هدف است، انتخاب می‌کند. در نهایت، تمامی این اهداف با یکدیگر ادغام می‌شوند و یک نمایش ویژگی جدید به دست می‌آید؛ به طوری که در مقابل اختلاف توزیع بین دامنه‌ها مقاوم باشد.

در این مقاله یک چارچوب جدید برای تطبیق دامنه‌های بصری پیشنهاد شده است که در آن تطبیق خصوصیات و وزن‌دهی به نمونه‌ها به طور همزمان بهینه می‌شوند. DAIC با استفاده از تطبیق خصوصیات و واگرایی برگمن یک زیرفضای جدید به دست می‌آورد که در آن خصوصیات مشترک دو دامنه منبع و هدف حفظ می‌شوند و سپس با استفاده از ماتریس وزن‌دهی به نمونه‌ها و به کارگیری نرم $\ell_{2,1}$ نمونه‌هایی را از دامنه منبع که مرتبط و نزدیک به دامنه هدف هستند، انتخاب می‌کند؛ به طوری که اختلاف توزیع حاشیه‌ای بین دامنه‌ها به کمینه می‌رسد و زمینه برای اجرای الگوریتم‌های کلاسیک یادگیری ماشین فراهم می‌شود.

ساختار ادامه مقاله بدین صورت است: در بخش ۲ پژوهش‌های مرتبط مورد بررسی قرار می‌گیرند. در بخش ۳ روش پیشنهادی آورده شده و بخش ۴ شامل پیگاه داده‌های مورد ارزیابی و فرضیات آزمایش‌ها است. در بخش ۵ نتایج حاصل از عملکرد الگوریتم پیشنهادی و مقایسه آن با دیگر روش‌های موجود قرار دارد. و در نهایت در بخش ۶ نتیجه‌گیری و کارهای پیشنهادی آینده ارائه شده است.

¹ 12,1 norm

² Task

³ Prior Distribution

⁴ Hyperparameters

⁵ Adaptation regularization for transfer learning

⁶ Loss function

رویکردهای کاهش بُعد از جمله روش‌های یادگیری بازنمایی جدید از داده‌ها هستند که اختلاف توزیع بین دامنه‌های منبع و هدف را کاهش می‌دهند تا خطای دسته‌بندی برای مدل کاهش یابد؛ به طور کلی، رویکردهای کاهش بُعد از دو چارچوب اصلی پیروی می‌کنند: (۱) الگوریتم‌هایی که براساس روش PCA هستند و داده‌ها را به یک فضای کم‌بعد نگاشت می‌کنند؛ به طوری که واریانس داده‌های نگاشتشده بیشینه شود. از جمله این الگوریتم‌ها می‌توان به VDA [۹]، JDA [۱۰] و CLGA [۲۲] اشاره کرد که از PCA برای نگاشت داده‌ها به یک زیرفضای کم‌بعد استفاده می‌کنند. CLGA یک رویکرد تطبیق دامنه بدون نظرات چندمنبعی است که به بررسی نحوه بهره‌گیری مؤثر و هم‌زمان از اطلاعات رده‌ها و دامنه‌ها می‌پردازد. CLGA به منظور افزایش انطباق دامنه‌ها، ابتدا چند دامنه را به عنوان یک دامنه در نظر می‌گیرد، سپس هم‌زمان اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌های منبع و هدف را به کمینه می‌رساند (تطبیق‌پذیری کلی). علاوه‌بر این، CLGA به منظور افزایش قابلیت تفکیک‌پذیری، ارتباط بین رده‌ها و دامنه‌های معجزا را بررسی و از ساختار CLGA به منظور افزایش قابلیت تفکیک‌پذیری، فاصله بین نمونه‌های متعلق به یک رده اما دامنه متفاوت را کاهش می‌دهد، و فاصله بین نمونه‌های متعلق به یک دامنه اما رده متفاوت را افزایش می‌دهد (تطبیق‌پذیری محلی). (۲) الگوریتم‌هایی که براساس روش FLDA عمل می‌کنند. این الگوریتم‌ها در تلاش هستند داده‌ها را به گونه‌ای به فضای کم‌بعد نگاشت کنند که رده‌های مختلف تفکیک‌پذیری بیشتری نسبت به هم داشته باشند. از جمله این الگوریتم‌ها می‌توان به SCA [۱۱] اشاره کرد که این روش با استفاده از FLDA یک نمایش جدید از نمونه‌های دامنه منبع و هدف ایجاد می‌کند که در آن فاصله بین رده‌های مختلف (تفکیک‌پذیری) بیشینه شده و اختلاف توزیع بین دامنه‌ها کمینه شود. گفتنی است که PCA بر روی خود داده‌ها عمل می‌کند در حالی که FLDA براساس پیداکردن روابط بین رده‌های متفاوت داده، انجام می‌پذیرد.

در این مقاله، یک روش تطبیق دامنه بدون نظرات برای حل مسئله یادگیری انتقالی ارائه شده است. درواقع یک چارچوب کلی با ترکیبی از دو روش مبتنی بر خصوصیت و مبتنی بر نمونه پیشنهاد می‌شود. در این روش داده‌های دامنه

توزیع داده‌ها کمینه می‌کنند. وزن‌دهی مجدد نمونه^۱ و نمونه‌برداری اهمیت^۲ دو روش مهم مبتنی بر این رویکرد هستند. از جمله این روش‌ها می‌توان به^۳ SSSC [۸] و LSSA [۳۰] اشاره کرد.

روش SSSC ابتدا نمونه‌های غیر مرتبط دامنه منبع را حذف کرده، سپس با یافتن یک ماتریس انتخاب، اختلاف توزیع بین داده‌های منبع و هدف را کاهش می‌دهد. از SSSC کدگذاری تُنک^۴ برای انتخاب نمونه‌های دامنه منبع استفاده کرده و هر نمونه دامنه هدف را با کمینه تعداد نمونه دامنه منبع نمایش می‌دهد.

LSSA یک رویکرد جدید دومرحله‌ای برای تطبیق دامنه بدون نظرات است که از مفهوم لندمارک استفاده می‌کند. در مرحله نخست لندمارک‌ها شناسایی می‌شوند؛ برای این کار هر نمونه چه از دامنه منبع باشد و چه از دامنه هدف به عنوان یک نامزد لندمارک در نظر گرفته می‌شود؛ سپس یک معیار کیفی برای هر نامزد محاسبه می‌شود که اگر مقدار این معیار بزرگ‌تر از مقدار آستانه تعریف شده باشد، می‌توان نتیجه گرفت که این نامزد لندمارک است. در مرحله دوم با استفاده از یک کرنل گوسی و با توجه به لندمارک‌های انتخاب شده در مرحله قبل، تمام نقاط دامنه منبع و دامنه هدف به یک فضای مشترک تصویر می‌شوند.

بیشتر روش‌های موجود در زمینه تطبیق دامنه بدون نظرات روش‌های مبتنی بر ویژگی هستند که ایده کلی این روش‌ها تغییر ویژگی‌های اولیه و به دست آوردن یک نمایش جدید برای داده‌ها است، با این هدف که ویژگی‌های جدید، بازنمایی^۵ بهتری برای خصوصیات مشترک دامنه‌های منبع و هدف ارائه دهند. درواقع روش‌های مبتنی بر ویژگی بر دو فرض کلی استوارند: (۱) برخی ویژگی‌های مختص یک دامنه^۶ و برخی مستقل از دامنه^۷ هستند. (۲) از فضای ویژگی اصلی به فضای ویژگی نهان^۸ که توسط دامنه منبع و دامنه هدف به اشتراک گذاشته شده، یک نگاشت وجود دارد.

در این شاخه از روش‌های انطباقی، فرض می‌شود، دامنه‌های منبع و هدف در یک فضای ویژگی جدید دارای توزیع حاشیه‌ای و یا توزیع شرطی مشابه هستند. هدف اصلی در این شاخه از الگوریتم‌ها، یافتن تبدیلی است؛ به‌نحوی که نمایش فضای ویژگی را عوض کرده و داده‌ها را به فضایی ببرد که در آن تشابه توزیع دامنه منبع و هدف وجود داشته باشد.

¹ Instance Reweighting

² Importance Sampling

³ Sample selection sparse coding

⁴ Sparse coding

⁵ Representation

⁶ Domain-specific

⁷ Domain-invariant

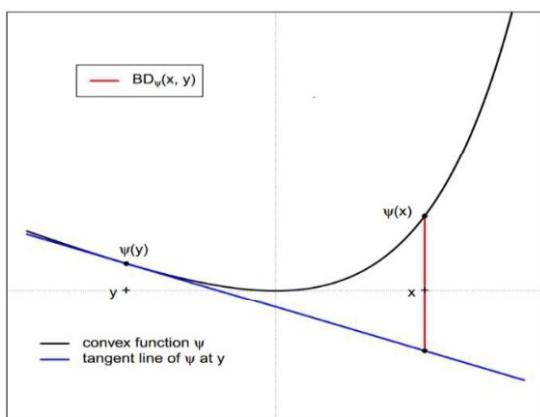
⁸ Latent space

[32]، [33]، [23]. بیشتر روش‌های یادگیری انتقالی از فاصله اقلیدسی برای اندازه‌گیری تفاوت بین نمونه‌ها در دامنه منبع و هدف استفاده می‌کنند [34]، [35]، [36]، [37]. با این حال، در بسیاری از کاربردهای دنیای واقعی، ممکن است فاصله اقلیدسی نتواند شباهت‌های ذاتی یا ناهمانگی‌های بین نمونه‌ها را انتقال دهد. واگرایی برگمن^۱ یکی از معیارهای اندازه‌گیری فاصله بین دو توزیع احتمال است که دامنه گستردگی از فاصله‌ها از جمله تابع هزینه جمع مربعات، واگرایی کولبک – لایبلر، تابع هزینه منطقی، فاصله ماهalanobis را در بر می‌گیرد. واگرایی برگمن با کاهش اختلاف بین توزیع نمونه‌های آموزشی و آزمایشی می‌تواند داشت تفکیک‌کننده به دست آمده از نمونه‌های آموزشی را به نمونه‌های آزمایش انتقال دهد.

تعویف: فرض کنید $\Psi: \Omega \rightarrow \mathbb{R}$: یک تابع بطور محدب در مجموعه محدب $\Omega \subseteq \mathbb{R}^m$ است که فرض می‌شود ناتهی و تمایزپذیر است. بنابراین برای $x, y \in \mathbb{R}^m$ واگرایی برگمن با توجه به $\nabla \Psi$ به صورت زیر تعریف می‌شود:

$$BD_{\Psi}(x, y) = \Psi(x) - \Psi(y) - \langle x - y, \nabla \Psi(y) \rangle \quad (1)$$

که در آن $(y) \nabla \Psi$ ، نشان‌دهنده گرادیان Ψ در نقطه y و $\langle \dots \rangle$ ضرب داخلی است. واگرایی برگمن تعريف شده در (1) را می‌توان تفاوت بین مقدار تابع محدب در x و نخستین مرتبه بسط تیلور² آن در نقطه y ، تفسیر کرد، به طور معادل، بخش باقی‌مانده از نخستین مرتبه بسط تیلور $\nabla \Psi$ در y است. مفهوم هندسی واگرایی برگمن در شکل (1) نشان داده شده است. براساس شکل (1) واضح است که واگرایی برگمن فاصله بین مقدار تابع محدب در x و تائزانت آن در y است.



(شکل ۱): تصویر هندسی واگرایی برگمن

(Figure-1): Geometrical illustration of Bregman divergence

¹ Bregman divergence

² Taylor expansion

منبع و هدف توسط ترکیبی از روش FLDA و متريک واگرایی برگمن، به یک زيرفضاي جديid که در آن اختلاف توزيع حاشيه‌ای بین دامنه‌های منبع و هدف کمينه شده، نگاشت می‌شوند. همچنین به طور همزمان نمونه‌هایی از دامنه منبع که شباهت بيشتری با نمونه‌های دامنه هدف دارند، انتخاب و مدل براساس اين نمونه‌های انتخاب شده ايجاد می‌شود.

۳- روش پيشنهادي

در اين بخش، جزئيات الگوريتم پيشنهادي DAIC برای حل مسائل تطبيق دامنه بدون نظارت شرح داده می‌شود.

۱-۳- تعریف مسئله

مسئله شيفت در دامنه‌ها زمانی رخ می‌دهد که دامنه‌های آموزشی و آزمایشی توزیع متفاوتی داشته باشند؛ بنابراین طبقه‌بند ساخته شده روی داده‌های دامنه آموزشی صحت خوبی روی داده‌های دامنه آزمایش نخواهد داشت.

با توجه به دامنه منبع برچسب‌دار $D_s = \{(x_{s_1}, y_{s_1}), \dots, (x_{s_n}, y_{s_n})\}$ و یک دامنه هدف بدون برچسب $D_t = \{x_{t_1}, \dots, x_{t_m}\}$ تحت شرایط $X_s = X_t$ و $Y_s = Y_t$ ، $P_s(x_s) \neq P_t(x_t)$ ، دو دامنه از توزیع حاشيه‌ای متفاوتی برخوردار هستند، هدف ما در اين مقاله اين است که مدلی طراحی کنيم که توزیع حاشيه‌ای داده‌های آموزشی و آزمایشی را تقریباً برابر کند؛ یعنی $P_s(x_s) \sim P_t(x_t)$ اختلاف توزیع حاشيه‌ای بین دامنه‌های منبع و هدف را با یادگیری يك نمایش جدید کاهش می‌دهد. درواقع DAIC با استفاده توان از روش کاهش بعد FLDA و وزن‌دهی به نمونه‌های دامنه منبع دقت مدل ايجاد شده را برای نمونه‌های دامنه هدف به طور قابل ملاحظه‌ای افزایش می‌دهد.

در نمایش جدید، به صورت همزمان اختلاف توزیع حاشيه‌ای بین دامنه‌ها کمينه شده و از روش وزن‌دهی به نمونه‌های دامنه منبع، برای بهبود عملکرد مدل طبقه‌بند در پيش‌بنني برچسب‌ها استفاده شده است.

۲-۳- واگرایی برگمن

بيشتر مطالعات قبلی در حوزه یادگیری انتقالی یا براساس ارزش‌گذاري مجدد نمونه‌های دامنه منبع مطابق با توزیع دامنه هدف [24]، [25]، [26] و یا براساس یافتن يك نمایه جدید برای نمونه‌های دامنه منبع و هدف، به منظور کاهش اختلاف توزیع بین دامنه‌های منبع و هدف عمل می‌کنند

اطلاعاتی خاصی ندارند؛ لذا نیاز به روش‌هایی جهت بهینه‌سازی و کاهش ابعاد داده‌ها قبل از ورود به سامانه‌های طبقه‌بند احساس می‌شود. این مسئله در بسیاری از کاربردها (مانند طبقه‌بندی) اهمیت بهسزایی دارد؛ زیرا در این کاربردها تعداد زیادی ویژگی وجود دارد، که بسیاری از آنها یا بلاستفاده هستند و یا اینکه بار اطلاعاتی چندانی ندارند. حذف نکردن این ویژگی‌ها مشکلی از لحاظ اطلاعاتی ایجاد نمی‌کند؛ ولی باز محاسباتی را برای کاربرد مورد نظر بالا می‌برد؛ و علاوه‌بر این باعث می‌شود که اطلاعات غیر مفید زیادی را به همراه داده‌های مفید ذخیره کنیم [38]. الگوریتم تحلیل جداکننده فیشر خطی (FLDA) [12] یکی از روش‌های معروف و پرکاربرد کاهش بُعد خطی است. روش FLDA داده‌های پرکاربرد کاهش بُعد خطی را به فضایی با ابعاد کمتر نگاشت می‌کند؛ به‌طوری که داده‌های نگاشتشده دارای بیشترین پراکندگی بین‌ردهای و FLDA کمترین پراکندگی درون‌ردهای هستند. درواقع به‌دلیل پیداکردن ماتریس نگاشت (W) است که نسبت دترمینان S_b (ماتریس پراکندگی بین‌ردهای) به S_w (ماتریس پراکندگی درون‌ردهای) بیشینه شود، دراصللاح به این ماتریس، مقیاس فیشر می‌گویند که به‌صورت زیر تعریف می‌شود:

$$W = \underset{W}{\operatorname{argmax}} \frac{|W^T S_b W|}{|W^T S_w W|} \quad (5)$$

دترمینان ماتریس کواریانس میزان پراکندگی یک رده را بیان می‌کند. دترمینان تنها ضرب مقادیر قطر اصلی بوده که مقادیر مستقل واریانس‌ها هستند. دترمینان تحت هر نگاشت متعامد نرمالی مقدار برابر دارد؛ بنابراین مقیاس فیشر، سعی می‌کند تا واریانس میانگین رده‌ها بیشینه و واریانس داده‌های هر رده کمینه شوند. S_b ماتریس پراکندگی بین‌ردهای و S_w ماتریس پراکندگی درون‌ردهای داده‌های اصلی بوده و بدین صورت تعریف می‌شوند:

$$S_b = \sum_{i=1}^C n_i (\vec{m}^{(i)} - \vec{m})(\vec{m}^{(i)} - \vec{m})^T \quad (6)$$

$$S_w = \sum_{i=1}^C \sum_{j=1}^{n_i} (x_j^{(i)} - \vec{m}^{(i)}) (x_j^{(i)} - \vec{m}^{(i)})^T \quad (7)$$

در اینجا \vec{m} و $\vec{m}^{(i)}$ به ترتیب نشان‌دهنده میانگین کل داده‌ها و میانگین داده‌های رده i است. روش جداکننده خطی به‌دلیل یافتن ماتریس $W \in \mathbb{R}^{D \times d}$ است که رابطه (1) را بیشینه کند. در این صورت هر داده $x \in \mathbb{R}^D$ به‌صورت $y = W^T x$ به یک فضای کم‌بعد d به‌صورت خطی منتقل می‌شود.

درواقع واگرایی برگمن با توجه به نوع تابع محدب ψ انتخاب شده، تابع ضرر را کاهش می‌دهد. به عنوان مثال اگر $W(x) = x^T W x - y^T W y$ یک ماتریس قطعی مثبت^۱ باشد، واگرایی برگمن به صورت رابطه (۲) تعریف می‌شود:

$$\begin{aligned} BD_\psi(x, y) &= x^T W x - y^T W y - \\ &< x - y, 2W y > \\ &= (x - y)^T W (x - y) \end{aligned} \quad (2)$$

که W معکوس ماتریس کواریانس است. بنابراین با توجه به رابطه (۲) به این نوع واگرایی برگمن فاصله ماهالاتویس بین x و y گویند. درصورتی که W یک ماتریس همانی باشد، واگرایی برگمن به مربع فاصله اقلیدسی بین x و y تبدیل، که به صورت زیر نوشته می‌شود:

$$BD_\psi(x, y) = \|x - y\|^2 \quad (3)$$

به‌طوری که $\|x\| = \sqrt{x^T x}$ تعریف می‌شود. بنابراین با توجه به رابطه (۳)، واگرایی برگمن که فاصله بین P_s و P_t را بر طبق فاصله مربع اقلیدسی محاسبه می‌کند، به صورت زیر تعریف می‌شود:

$$\begin{aligned} D_W(P_s \| P_t) &= \frac{1}{n_s^2} \sum_{s=1}^{n_s} \sum_{t=1}^{n_s} G_{\Sigma_{11}}(\vec{y}_s - \vec{y}_t) \\ &+ \frac{1}{n_t^2} \sum_{s=n_s^2+1}^{n_s+n_t} \sum_{t=n_t+1}^{n_s+n_t} G_{\Sigma_{22}}(\vec{y}_s - \vec{y}_t) \\ &- \frac{1}{n_s n_t} \sum_{s=1}^{n_s} \sum_{t=n_t+1}^{n_s+n_t} G_{\Sigma_{12}}(\vec{y}_s - \vec{y}_t) \end{aligned} \quad (4)$$

برای تخمین مقادیر P_s و P_t از روش برآورد تراکم هسته^۲ استفاده شده است که تراکم را در $y \in \mathbb{R}^d$ به عنوان مجموع کرنل‌های بین y و هر نمونه \bar{y}_i تخمین می‌زنند؛ به عنوان مثال $(\bar{y}_i - \bar{y}) p(\bar{y}) = (\frac{1}{n}) G_{\Sigma}(\bar{y} - \bar{y}_i)$ که در آن n تعداد نمونه‌ها و G_{Σ} کرنل گوسی d بعدی با ماتریس کواریانس Σ است. که در این رابطه $\Sigma_{11} = \Sigma_1 + \Sigma_2$ ، $\Sigma_{22} = \Sigma_2 + \Sigma_{12}$ و $\Sigma_{12} = \Sigma_1 + \Sigma_2$ است.

از واگرایی برگمن جهت اندازه‌گیری و کاهش اختلاف توزیع بین دامنه‌های منبع و هدف استفاده می‌کند.

۳-۳- کاهش بُعد براساس الگوریتم جداکننده

فیشر خطی

استفاده از تمام ویژگی‌های داده در بیشتر موارد بسیار پرهزینه و وقت‌گیر است، از طرفی همه این ویژگی‌ها ارزش

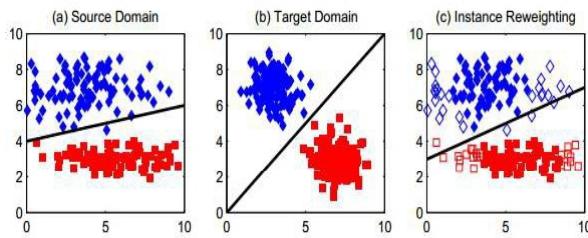
^۱ Positive definite matrix

^۲ Kernel density estimation (KDE)

فضای نگاشت شده W محاسبه می‌کند و λ پارامتر تنظیم است که بین $F(W)$ و $P_t \parallel P_s$, تنظیم ایجاد می‌کند.

۳-۵- وزن دهی به نمونه‌های دامنه منبع

با این حال، تطبیق توزیع ویژگی‌های داده براساس کمینه‌سازی واگرایی برگمن در معادله (۱۰) بهنهایی برای مسائل شیفت دامنه‌ها مناسب نیست و به طور کامل نمی‌تواند اختلاف توزیع بین دامنه‌های منبع و هدف را کاهش دهد. درواقع، اگر اختلاف توزیع بین دامنه‌های منبع و هدف زیاد باشد، حتی در زیرفضای نگاشت شده نیز همواره نمونه‌هایی از دامنه منبع وجود دارند که با نمونه‌های دامنه هدف مرتبط نیستند و این باعث کاهش تطبیق پذیری مدل می‌شود. شکل (۲) بهخوبی این مشکل را نشان می‌دهد. در این شرایط، تطبیق ویژگی و وزن دهی مجدد نمونه‌ها به طور مشترک برای ایجاد سازگاری و تطبیق دامنه بسیار مهم و اجتناب ناپذیر است.



(شکل-۲): (a) دامنه منبع پس از تطبیق ویژگی؛ (b) دامنه هدف پس از تطبیق ویژگی با توجه به نمونه‌های منبع نامرتبط (نشان داده شده در \square)، اختلاف دامنه پس از تطبیق ویژگی‌ها هنوز بزرگ است. (c) دامنه منبع پس از تطبیق ویژگی و وزن دهی و وزن دهی مجدد به نمونه‌ها. در حال حاضر نمونه‌های نامناسب دامنه منبع دارای وزن کمتری هستند تا اختلاف دامنه کاهش یابد (b vs c).

(Figure-2): (a) source domain after feature matching; (b) target domain after feature matching. Due to the irrelevant source instances (shown as unfilled markers in c), the domain difference is still large after feature matching. (c) source domain after joint feature matching and instance reweighting. The irrelevant source instances are now down-weighted to further reduce domain difference (b vs c).

بنابراین، با ترکیب یک روش کاهش بعد و یک روش وزن دهی مجدد، نمونه‌هایی از دامنه منبع را در زیرفضای مشترک انتخاب می‌کنیم که تطبیق پذیری مدل را افزایش دهد. درواقع با استفاده از دو ماتریس انتخاب A_s (ماتریس تبدیل متناظر با نمونه‌های دامنه هدف) و A_t (ماتریس تبدیل متناظر با نمونه‌های دامنه هدف) و به کارگیری نرم $\ell_{2,1}$ و نرم فروbenius^۳ $\parallel F \parallel^2$. نمونه‌هایی از دامنه منبع که مرتبط و نزدیک

³ Frobenius norm

۳-۴- الگوریتم جداکننده فیشر خطی با

استفاده از متریک واگرایی برگمن

چنان‌که در بخش قبلی دیده شد در روش جداکننده فیشر خطی نیاز به حل مسأله بیشینه کردن تریس^۱ بهصورت (۵) بهدفات زیاد است:

$$\arg \max_{W^T W} \frac{\text{tr}(W^T S_b W)}{\text{tr}(W^T S_w W)} \quad (8)$$

روش متداول برای بیشینه کردن نسبت تریس یادشده با استفاده از بردارهای ویژه حاصل از مسأله مقادیر ویژه تعمیم یافته است؛ پس درواقعتابع هدف الگوریتم FLDA برابر است با

$$F(W) = \text{tr}^{-1}(W^T S_b W) \text{tr}(W^T S_w W) \quad (9)$$

که $(x)^{-1}$ معکوس $\text{tr}(x)$ است.

نکته مهم در مورد روش FLDA این است که در مسائلی مانند تشخیص الگو و طبقه‌بندی تصویر که با ابعاد بزرگ داده مواجه هستیم، ممکن است ماتریس نگاشت W روی داده‌های آموزشی دچار زیادآموزی شود. همچنین FLDA کلاسیک بدلیل اینکه اطلاعات اولیه را در مورد تفاوت بین توزیع نمونه‌های آموزشی و آزمایشی درنظر نمی‌گیرد، بهنهایی نمی‌تواند پاسخ‌گوی مسأله شیفت دامنه‌ها باشد؛ با این حال برای اجتناب و یا کاهش مشکل زیادآموزی، ما اطلاعات اولیه نمونه‌های آموزشی را با اضافه کردن یک بخش تنظیم^۲ منطقی به رابطه (۹) درنظر می‌گیریم. بدین ترتیب، روش پیشنهادی DAIC یک زیرفضای مطلوب پیدا می‌کند که در آن اختلاف توزیع حاشیه‌ای کمینه شده و رده داده‌های آموزشی و آزمایشی به صورت مستقل از هم جدا می‌شوند. DAIC علاوه‌بر این که اطلاعات تفکیک کننده موجود در نمونه‌های آموزشی را درنظر می‌گیرد، توزیع بیانس بین نمونه‌های آموزشی و آزمایشی را نیز بررسی می‌کند. از این‌رو واگرایی برگمن و تابع هدف الگوریتم FLDA را ترکیب می‌کنیم؛ پس با توجه به رابطه‌های (۴) و (۸) خواهیم داشت:

$$W = \underset{W \in \mathbb{R}^{D \times d}}{\operatorname{argmin}} F(W) + \lambda D_W(P_s \parallel P_t) \quad (10)$$

$F(W)$ تابع هدف الگوریتم در زیرفضای نگاشت شده، $D_W(P_s \parallel P_t)$ واگرایی برگمن که فاصله بین P_s و P_t را در

¹ Trace

² Regularization

$$\begin{aligned} W = \operatorname{argmin}_{W} & \operatorname{tr}^{-1}(W^T S_b W) \operatorname{tr}(W^T S_w W) \\ & + \lambda D_W(P_s \| P_t) \\ & + \tau(\|A_s\|_{2,1} + \|A_t\|_F^2) \end{aligned} \quad (12)$$

۷ پارامتر تنظیم بین تطابق ویژگی و وزن دهی به نمونه‌ها است، علاوه بر این شرط $I = W^T W$ نیز باید برآورده شود. این شرط نشان‌دهنده این است که سطرها و یا ستون‌های ماتریس W مستقل از یکدیگر بوده و بهم عمودند و مجموع آن‌ها برابر یک است. با وجود این شرط در رابطه بهینه‌سازی، جواب‌های بدیهی در مجموعه جواب قرار نمی‌گیرند. برای بهدست آوردن زیرفضای خطی بهینه W با توجه به رابطه (۱۲) می‌توان از الگوریتم گرادیان نزولی^۳ استفاده کرد:

$$\begin{aligned} W_{k+1} = & W_k - \eta(k) \frac{\partial F(W)}{\partial W} \\ & + \lambda \sum_{i=1}^{n_s+n_t} \frac{\partial D_W(P_s \| P_t)}{\partial \vec{y}_i} \frac{\partial \vec{y}_i}{\partial W} \end{aligned} \quad (13)$$

η گرادیان نسبت به W و η نرخ یادگیری در k امین تکرار است، بدین ترتیب با درنظر گرفتن رابطه (۸) مشتق $F(W)$ بر حسب W برابر است با:

$$\begin{aligned} \frac{\partial F(W)}{\partial W} = & 2 \operatorname{tr}^{-1}(W^T S_b W) S_w W \\ & - 2 \operatorname{tr}^{-2}(W^T S_b W) \operatorname{tr}(W^T S_w W) S_b W \end{aligned} \quad (14)$$

با توجه به رابطه (۱۴) مشتق $D_W(P_s \| P_t)$ را نسبت به W می‌توان به صورت زیر نوشت:

$$\begin{aligned} \sum_{i=1}^{n_s+n_t} & \frac{\partial D_W(P_s \| P_t)}{\partial \vec{y}_i} \frac{\partial \vec{y}_i}{\partial W} \\ = & \sum_{i=1}^{n_s} \frac{D_W(P_s \| P_t)}{\partial \vec{y}_i} \vec{x}_i^T \\ & + \sum_{i=n_s+1}^{n_s+n_t} \frac{D_W(P_s \| P_t)}{\partial \vec{y}_i} \vec{x}_i^T \end{aligned} \quad (15)$$

در این مقاله، هدف ما کاهش اختلاف توزیع بین دامنه‌ها با استفاده همزمان از تطبیق ویژگی‌ها و وزن دهی مجدد نمونه‌های دامنه منبع (برای ایجاد تطبیق پذیری بیشتر) است، تا زمینه‌ای مناسب برای اجرای الگوریتم‌های کلاسیک یادگیری ماشین فراهم شود. مزیت اصلی DAIC، بهینه‌سازی همزمان تطبیق ویژگی و وزن دهی مجدد نمونه‌ها است؛ به طوری که اختلاف توزیع بین دامنه‌ها کمینه شده و اطلاعات تفکیک‌کننده نمونه‌های دامنه منبع و هدف به خوبی حفظ شود. در ادامه شکل (۳) روش پیشنهادی را با جزئیات بیشتر نشان می‌دهم.

³ Gradient descent

به دامنه هدف هستند انتخاب می‌شوند. درواقع نرم $\ell_{2,1}$ می‌تواند تنظیم‌کننده تُنکی^۱ را روی ماتریس A اعمال کرده و ماتریس A را با سطرهای تُنک نشان دهد. از آنجا که هر سطر ماتریس A مربوط به یک نمونه است، سطر تُنکی^۲ می‌تواند وزن دهی نمونه‌ها را تسهیل کند. رابطه زیر ماتریس انتخاب A را به دست می‌آورد که اختلاف توزیع بین داده‌های دامنه منبع و هدف را در زیرفضای نگاشت شده کمینه می‌سازد.

$$\|A_s\|_{2,1} + \|A_t\|_F^2 \quad (11)$$

با استفاده از نرم $\ell_{2,1}$ می‌توان هر نمونه هدف را با حداقل تعداد نمونه منبع نمایش داد. نرم $\ell_{2,1}$ را فقط روی نمونه‌های دامنه منبع اعمال می‌کنیم؛ زیرا هدف ما اضافه کردن وزن نمونه‌هایی از دامنه منبع است که شباهت و ارتباط بیشتری با نمونه‌های دامنه هدف دارند. با به کمینه‌رساندن رابطه (۱۰) رابطه (۱۱) نیز کمینه شده و در این صورت در نمایش جدید نمونه‌هایی از دامنه منبع که مرتبط با نمونه‌های دامنه هدف هستند اهمیت دارند. با استفاده از این تنظیم‌کننده (رابطه (۱۱))، DAIC نسبت به اختلاف توزیع ناشی از نمونه‌های نامرتبط دامنه‌های منبع و هدف مقاوم می‌شود.

۶-۳-تابع هدف نهایی و بهینه‌سازی

روش DAIC، یک روش ترکیبی از روش‌های مبتنی بر نمونه و مبتنی بر خصوصیت است که برای مسائلی که دارای اختلاف توزیع زیادی هستند، پیشنهاد شده است. در این روش، ابتدا یک نمایش کم‌بعد از دامنه‌های منبع و هدف ایجاد می‌شود که در این نمایش جدید با برهه‌گیری از واگرایی برگمن اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف کاهش می‌یابد؛ سپس به طور همزمان، به نمونه‌هایی از دامنه منبع که دارای کمترین مشابهت از نظر توزیع با نمونه‌های دامنه هدف هستند، وزن کمتری در ایجاد مدل طبقه‌بند اختصاص داده می‌شود. درواقع مدل طبقه‌بند براساس نمونه‌هایی از دامنه منبع که بیشترین شباهت را به نمونه‌های دامنه هدف دارند، آموزش می‌یابند؛ در این صورت تطبیق پذیری داده‌ها با یکدیگر افزایش می‌یابد و مدل مقاوم‌تری در مقابل اختلاف توزیع بین دامنه‌های منبع و هدف ایجاد می‌شود. بدین ترتیب با ترکیب رابطه‌های (۱۰) و (۱۱) به معادله (۱۲) می‌رسیم که تابع هدف نهایی DAIC است:

¹ Sparsity regularizer

² Row-sparsity

۲۸×۲۸ پیکسل است. این پایگاه داده شامل ده رده مختلف است و به منظور آزمایش هر دو دامنه در شرایط یکسان، دامنه USPS_vs_MNIST(U-M) ایجاد شده است که به طور تصادفی ۱۸۰۰ نمونه از داده‌های دامنه USPS به عنوان داده‌های آموزشی و دوهزار نمونه از داده‌های دامنه MNIST به عنوان داده‌های آزمایش به کار گرفته می‌شود. با جایه‌جایی نمونه‌های آموزشی و آزمایشی دامنه MNIST_vs_USPS (M-U) برای یک آزمایش دیگر ایجاد شده است.

مجموعه‌داده آفیس شامل مجموعه تصاویر از اشیای مختلف است که تصاویر از نظر کیفیت، روشنایی، رنگ و نوع زمینه با هم متفاوت هستند. این مجموعه‌داده شامل سه دامنه Amazon (تصاویر اشیای دانلودشده از سایت‌های تجاری Webcam (A)، DSLR (تصاویر اشیا با وضوح پایین که توسط دوربین وب گرفته شده‌اند (W))، (تصاویر اشیا با وضوح بالا که با استفاده از دوربین‌های دیجیتالی گرفته شده‌اند (D)) و کالتك (C) یک مجموعه‌داده استاندارد برای تشخیص اشیا است که شامل ۳۰۶۷ تصویر و ۲۵۶ رده از تصاویر است. در دامنه‌های مجموعه‌داده آفیس و کالتك مجموعه‌داده آفیس و مجموعه‌داده کالتك استفاده شده است. در هریک از آزمایش‌های طراحی شده یکی از مجموعه‌داده‌ها به عنوان دامنه منبع و یکی دیگر از مجموعه‌داده‌ها به عنوان دامنه هدف انتخاب می‌شوند؛ به عنوان مثال (C→A, C→W, C→D, ..., D→W).

مجموعه‌داده پای شامل ۴۱۳۶۸ تصویر از ۶۸ شخص متفاوت با وضوح ۳۲×۳۲ پیکسل است که این تصاویر از لحاظ روشنایی، جهت تصویربرداری و حالت چهره با یکدیگر متفاوت هستند. این مجموعه‌داده دارای پنج دامنه متفاوت است که هر دامنه نشان‌دهنده یک حالت تصویربرداری است، PIE1 حالت چپ (P1)، PIE2 حالت بالا (P2)، PIE3 حالت پایین (P3)، PIE4، PIE5 حالت روبرو (P4) و PIE5 حالت راست (P5). در این مجموعه‌داده، آزمایش بر روی ۵×۴=۲۰ مجموعه بین دامنه‌ای مختلف طراحی شده است که از بین این پنج دامنه، دو دامنه مختلف به عنوان دامنه‌های منبع و هدف انتخاب می‌شوند؛ به عنوان مثال (P1→ P2, P1→ P3, ..., P5→ P4).

۴-۲- ارزیابی الگوریتم‌ها

در این بخش، عملکرد روش پیشنهادی را با هفت الگوریتم نادگیری ماشین و یادگیری انتقالی بدون نظارت مقایسه

³ PIE

۴-۳-۷- پیچیدگی زمانی

در این بخش، پیچیدگی زمانی روش پیشنهادی نسبت به روش‌های مورد مقایسه، مورد ارزیابی قرار می‌گیرد. پیچیدگی محاسباتی الگوریتم DAIC با علامت O بزرگ تحلیل می‌شود. تحدب تابع هدف که در رابطه (۱۰) تعریف می‌شود، به $F(W)$ و $D(W)$ وابسته است. تحدب $F(W)$ وابسته به یک الگوریتم خاص یادگیری زیرفضا مانند FLDA است. در حالی که تحدب $D(W)$ به مدل توزیع مجموعه نمونه‌های آموزشی و آزمایشی بستگی دارد. اگر N تعداد کل نمونه‌ها و D واگرایی برگمن باشد رابطه (۱۲) دارای پیچیدگی زمانی $O((D+N)^2)$ است. پس به طور کلی پیچیدگی زمانی DAIC برابر با $O((D+N)^2)$ است. اگر d و C به ترتیب اندازه ابعاد فضای اصلی، اندازه بعد ابعاد فضای جدید و تعداد رده‌ها باشند، روش NN (با در نظر گرفتن تعداد همسایگی برابر با یک برای نمونه‌ها)، دارای پیچیدگی زمانی $O(mN)$ است. روش TJM یک روش ترکیبی از روش‌های مبتنی بر نمونه و مبتنی بر خصوصیت است، دارای پیچیدگی $O(m^2d+CN^2)$ است. روش NN جزو سریع‌ترین روش‌ها است؛ اما تطبیق دامنه انجام نمی‌دهد. DAIC در مقایسه با روش TJM دارای پیچیدگی زمانی کمتری بوده، زیرا یک کرنل بهنسبه پیچیده و حل تابع هدف آن دشوار و زمان بر است.

۴-۴- آزمایش‌ها

در این بخش، آزمایش‌های گسترده‌ای برای مسئله طبقه‌بندی تصویر برای ارزیابی رویکرد DAIC انجام شده است.

۴-۱- معرفی مجموعه‌داده‌ها

مجموعه‌داده آفیس و کالتك [13]، اعداد ^۱[14,15] و پای ^۲[16]، یازده مجموعه‌داده استاندارد هستند که به طور گسترده برای ارزیابی الگوریتم‌های دامنه بصری مورد استفاده قرار می‌گیرند.

مجموعه‌داده اعداد شامل دو دامنه USPS و MNIST است. دامنه USPS حاوی اعداد دستنویس پویش شده نامدهای اداره پست آمریکا است که شامل ۷۲۹۱ تصویر آموزشی و ۲۰۰۷ تصویر آزمایشی با اندازه 16×16 پیکسل است. مجموعه‌داده MNIST حاوی اعداد دستنویس پویش شده دانش‌آموزان دبیرستانی آمریکا است که شامل شصت هزار نمونه آموزشی و ده هزار نمونه آزمایشی با اندازه

¹ Office+Caltech-256

² USPS+MNIST

می‌کنیم. گفتنی است که FLDA^m نشان‌دهنده کاهش اختلاف حاشیه‌ای بین دامنه‌های منبع و هدف با استفاده از الگوریتم کاهش بعد FLDA و واگرایی برگمن بدون وزن‌دهی نمونه‌ها است.

تشخیص شیء: دقت طبقه‌بندی DAIC و سایر روش‌ها در مجموعه‌داده‌های Office + Caltech در جدول (۲) گزارش شده است. به‌منظور تفسیر بهتر، نتایج در شکل (۴) به تصویر کشیده شده است. نتایج حاصل از آزمایش‌ها حاکی از آن است که متوسط بهبود دقت روش DAIC در پایگاه‌داده آفیس و کالتك ۵۲/۲۱٪ است. علاوه‌براین، بهبود عملکرد DAIC برای طبقه‌بندی تصاویر در دامنه‌های متفاوت می‌تواند مؤثر باشد؛ همچنین متوسط بهبود دقت روش DAIC نسبت به روش FLDA در مجموعه‌داده آفیس و کالتك ۱۰/۸۳٪ است. DAIC بهبود خوبی (۱۸٪) نسبت به متوسط دقت بهترین الگوریتم مورد مقایسه (يعني CLGA) دارد.

تشخیص چهره: دقت طبقه‌بندی DAIC و سایر روش‌ها در مجموعه‌داده‌های PIE در جدول (۳) گزارش شده و به‌منظور تفسیر بهتر، نتایج در شکل (۵) نشان شده است. DAIC دارای (۷/۸۶٪) بهبود از لحاظ متوسط دقت طبقه‌بندی در مقایسه با بهترین الگوریتم مورد مقایسه (يعني CLGA) است؛ همچنین، DAIC بهبود (۴۵/۲۵٪) را نسبت به NN به‌دست می‌آورد. DAIC بهبود قابل ملاحظه‌ای (۴۵/۷۱٪) نسبت به متوسط دقت الگوریتم FLDA دارد.

تشخیص اعداد: دقت طبقه‌بندی DAIC و سایر روش‌ها در مجموعه‌داده‌های USPS+MNIST در جدول (۴) گزارش شده و به‌منظور تفسیر بهتر، نتایج در شکل (۶) آورده شده است. نتایج حاصل از آزمایش‌ها حاکی از متوسط بهبود دقت روش DAIC در مجموعه‌داده اعداد (۷۵/۷۵٪) است. متوسط بهبود دقت روش DAIC نسبت به روش‌های NN و FLDA و CDDA به ترتیب برابر (۲۰/۴۳٪)، (۱۷/۴۴٪) و (۶/۶۲٪) است. در ادامه روش DAIC به تفکیک با تمام روش‌ها مقایسه شده است.

NN-1 طبقه‌بند نزدیک‌ترین همسایگی: این الگوریتم بروی ویژگی‌های اصلی داده‌ها، بدون اعمال هیچ‌گونه انطباقی براساس نزدیک‌ترین همسایگی برچسب داده‌های آزمایش از دامنه هدف را بر طبق داده‌های آموزشی از دامنه منبع پیش‌بینی می‌کند.

می‌کنیم. روش‌هایی که DAIC با آن‌ها مقایسه شده است، عبارتند از: طبقه‌بند نزدیک‌ترین همسایه (1-NN)، FLDA، LRSR، [19] TJM، [18] DAM، [17] FIDOS، [5] TSL و [23] CDDA [22] CLGA، [21] VDA، [20]

مهم‌ترین دلیل برتری DAIC نسبت به روش‌های دیگر، استفاده از اطلاعات اولیه دامنه منبع است، که به صورت حداکثری به دامنه هدف انتقال می‌یابد. در ضمن اطلاعات خاص داده‌ها (به عنوان مثال ساختار منیفلد داده‌ها) را نیز حفظ می‌کند.

(جدول-۱): توضیحات پایگاه‌داده‌ها

(Table-1): Description of Databases

اختصار	تعداد کلاس‌ها	تعداد ابعاد	تعداد نمونه‌ها	پایگاه داده
U	10	256	1800	USPS
M	10	256	2000	MNIST
A	10	800	958	Amazon
W	10	800	295	Webcam
D	10	800	157	Dslr
C	10	800	1123	Caltech256
P1	68	1024	3332	PIE1
P2	68	1024	1629	PIE2
P3	68	1024	1632	PIE3
P4	68	1024	3329	PIE4
P5	68	1024	1632	PIE5

اطلاعات جزئی‌تر از پایگاه‌داده‌ها در جدول (۱) نشان داده شده است.

۴-۳- مفروضات پیاده‌سازی

الگوریتم پیشنهادی DAIC شامل سه پارامتر زیر است که مقادیر بهینه آن‌ها در بخش بعدی آورده شده است: ۱) λ پارامتر تنظیم در رابطه (۱۰)، ۲) η نرخ یادگیری در رابطه (۱۳) و ۳) τ پارامتر تنظیم بین طبیق خصوصیات و وزن‌دهی به نمونه‌ها است. مقدار بهینه پارامترها در روش DAIC، برای پایگاه داده‌های بصری برای تمامی آزمایش‌ها انجام گرفته و درنهایت از طبقه‌بند استاندارد NN برای پیش‌بینی برچسب‌های داده‌های دامنه هدف استفاده شده است.

۵- نتایج و بحث‌ها

در این بخش، نتایج روش پیشنهادی DAIC و الگوریتم‌های شناخته‌شده حوزه تطبیق دامنه توسط طراحی آزمایش‌های بدون نظارت مورد ارزیابی و مقایسه قرار گرفته است.

۱-۵- ارزیابی نتایج

در این بخش، عملکرد روش پیشنهادی را با هفت الگوریتم یادگیری ماشین و یادگیری انتقالی بدون نظارت مقایسه



دقت (۹/۶۶٪) در پایگاهداده آفیس و کالتک، (۲۷/۹۹٪) در پایگاهداده اعداد و (۰/۳۰/۶۵۱) در پایگاهداده پای است. روش TJM از جمله جدیدترین روش‌های ایجاد تطبیق بین دامنه‌ها توسط ایجاد یک نمایش مشترک بین دامنه‌های منبع و هدف است. روش TJM توسط یک مسئله بهینه‌سازی پیچیده، اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف را کمینه می‌سازد. همچنین TJM بهدلیل استفاده از الگوریتم PCA و نادیده‌گرفتن بخشی از داده ورودی ساختار اصلی داده‌ها را حفظ نمی‌کند و زیرفضای جدید را با بخشی از نمونه‌های دامنه منبع ایجاد می‌کند، در حالی که روش DAIC با استفاده از واگرایی برگمن ساختار داده‌های ورودی را حفظ می‌کند. روش DAIC به تفکیک نسبت به روش TJM دارای متوسط بهبود دقต (۷/۸٪) در پایگاهداده آفیس و کالتک، (۰/۴۴/۴۸٪) در پایگاهداده پای است.

LRSR با استفاده از یک ماتریس انتقال، نمونه‌های دامنه منبع و هدف را به یک زیرفضای مشترک نگاشت می‌کند که در آن هر نمونه دامنه هدف می‌تواند به طور خطی توسط داده‌های دامنه منبع بازسازی شود. به این ترتیب، اختلاف دامنه‌های منبع و هدف کاهش می‌یابد و با اعمال تأم محدودیت‌های تُنُک و سطح پایین روی ماتریس نگاشت ساختار کلی و محلی داده‌ها حفظ می‌شود. مهم‌ترین دلیل برتری روش پیشنهادی نسبت به روش LRSR، کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌ها و انتقال حداقلی اطلاعات تفکیک‌کننده نمونه‌های دامنه منبع برای DAIC تفکیک‌پذیری بهتر رده‌های مختلف است. روش LRSR به تفکیک نسبت به روش LRSR دارای متوسط بهبود دقت (۶/۱۸٪) در پایگاهداده آفیس و کالتک، (۱۱/۵۹٪) در پایگاهداده اعداد و (۱۸/۴۸٪) در پایگاهداده پای است.

CDDA از جمله روش‌های شناخته‌شده در حوزه یادگیری انقلالی بدون نظرارت است که با ایجاد یک نمایش کم‌بعد از دامنه‌های منبع و هدف، به طور همزمان اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها را کاهش می‌دهند. بهدلیل خصوصیات متفاوت داده‌های آموزشی و آزمون در دامنه‌های منبع و هدف، طبقه‌بندی ایجادشده در نمایش جدید توسط روش CDDA نمی‌تواند با صحت بالایی برچسب داده‌های دامنه هدف را پیش‌بینی کند. دلیل برتری DAIC CDDA این است که DAIC علاوه‌بر اینکه ساختار داده‌ها را حفظ می‌کند، اطلاعات تفکیک‌کننده اولیه داده‌های ورودی را نیز در نظر می‌گیرد که این باعث کاهش اختلاف

FLDA یک روش انتقال داده‌ها به یک فضای کم‌بعد است که ایده اصلی آن حفظ ساختار رده‌ها برای طبقه‌بندی است. از آنجا که FLDA اختلاف توزیع بین دامنه‌ها را در نظر نمی‌گیرد، نمی‌تواند عملکرد خوبی در برابر مسائل تطبیق دامنه داشته باشد. با این وجود FLDA عملکرد بهتری نسبت به الگوریتم NN دارد.

TSL یکی از روش‌های تطبیق دامنه بدون نظرارت است که اختلاف توزیع حاشیه‌ای دامنه منبع و هدف را براساس تخمین تراکم هسته کاهش می‌دهد. TSL به اندازه مجموعه داده‌ها حساس است در صورتی که دامنه هدف حاوی داده‌های کم باشد، تخمین تراکم هسته نمی‌تواند توصیف دقیقی از داده‌ها داشته باشد؛ علاوه‌بر این برای داده‌هایی در مقیاس بالا (مانند مجموعه داده PIE) TSL دچار مشکل هم‌گرایی می‌شود. DAIC بر روی هردو مجموعه داده کوچک و بزرگ به خوبی کار می‌کند و دارای بهبود قابل توجه در مقایسه با TSL است. مهم‌ترین علت برتری DAIC نسبت به TSL استفاده از تطبیق خصوصیات برای کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف است. روش DAIC به تفکیک نسبت به روش TSL دارای متوسط بهبود دقت (۱۵٪/۱۲٪) در پایگاهداده آفیس و کالتک، (۲۰/۵۸٪) در پایگاهداده اعداد و (۴۲/۵۵٪) در پایگاهداده پای است.

FIDOS یک چارچوب جدید براساس تعمیم الگوریتم FLDA است. FIDOS یک زیرفضای کم‌بعد را ایجاد می‌کند که اختلاف توزیع بین دامنه‌ها را کاهش می‌دهد. FIDOS مشابه DAIC یک رویکرد مبتنی بر FLDA است، اما فقط برای مجموعه داده‌های مرتبط عملکرد خوبی دارد؛ در واقع برای مسائل چند دامنه‌ای بهدلیل استخراج ویژگی‌های بیشتر، بهتر عمل می‌کند. این در حالی است DAIC برای مسائلی که دارای اختلاف توزیع زیادی هستند، پیشنهاد شده است. روش DAIC به تفکیک نسبت به روش FIDOS دارای متوسط بهبود دقت (۱۲/۳٪) در پایگاهداده آفیس و کالتک، و (۴۴/۰٪) در پایگاهداده پای است.

DAM، یک روش تطبیق دامنه بدون نظرارت است که به طور مستقیم یک طبقه‌بند سازگار با دامنه هدف را به دست می‌آورد. DAM از طبقه‌بندی‌های پیش‌آموخته با استفاده از نمونه‌های برچسب‌دار دامنه منبع، استفاده می‌کند. علاوه‌بر این DAM براساس فرضیه مسطح‌سازی یک شرایط تنظیمی را به وجود می‌آورد که طبقه‌بند دامنه هدف مجبور به تصمیم‌گیری مشابه با طبقه‌بند پیش‌آموخته می‌شود. روش DAIC به تفکیک نسبت به روش DAM دارای متوسط بهبود

می‌کند. تعداد نمونه‌های انتخاب شده با توجه به τ در جدول (۵) گزارش شده است.

به عنوان مثال هنگامی که $\tau = 100$ است در مجموعه‌داده اعداد هیچ نمونه‌ای از دامنه منبع انتخاب نمی‌شود؛ اما زمانی که τ مقدار کوچکی دارد، ماتریس A تنکی کمتری دارد و بنابراین نمونه‌های منبعی که توزیع نزدیک‌تری با نمونه‌های هدف دارند، انتخاب می‌شوند.

(جدول-۵): تأثیر پارامتر تنظیم تنبع

۲ بر تعداد نمونه‌های انتخاب شده از دامنه منبع
(Table-5): Influence of tensile setting parameter τ on the number of samples selected from the source domain

τ	0.01	0.1	1	10	100
U-M#	890	430	98	39	0
P1-P5#	1800	1800	1800	780	40
C-A#	1068	646	494	73	2

۵-۳- بررسی ضرورت کاهش اختلاف توزیع حاشیه‌ای

در روش پیشنهادی DAIC برای کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف از روش غیر پارامتری واگرایی برگمن استفاده شده است. واگرایی برگمن قادر است اطلاعات به دست آمده از نمونه‌های دامنه منبع را، با به کمینه‌رساندن اختلاف توزیع حاشیه‌ای بین دامنه‌ها به نمونه‌های دامنه هدف منتقل کند که باعث تکیک‌پذیری بهتر رده‌های مختلف در فضای جدید می‌شود. در صورتی که در تابع هدف (رابطه ۱۲) پارامتر λ را برابر صفر در نظر بگیریم (طبق نتایج گزارش شده در جداول ۲ الی ۴)، فیلد (FLDA) دقت مدل به دلیل وجود اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف به شدت کاهش می‌یابد. در شرایطی که دامنه‌های منبع و هدف دارای مجموعه خصوصیات یکسان باشند، اختلاف در احتمال وقوع مقدارهای هر کدام از این خصوصیات در هر دامنه، موجب ایجاد اختلاف توزیع حاشیه‌ای بین دامنه‌ها خواهد شد.

روش‌های کاهش بعد به تنها یکی پاسخ‌گوی مسائل شیفت دامنه‌ها نیستند و به دلیل نادیده‌گرفتن اطلاعات اولیه در مورد اختلاف توزیع بین نمونه‌های دامنه منبع و هدف، مدل روی نمونه‌های دامنه منبع دچار زیادآموزی شده و عملکرد مدل به شدت کاهش می‌یابد. برای اجتناب از مشکل زیادآموزی و بهبود عملکرد مدل یادگیری، ما اطلاعات اولیه را

توزیع حاشیه‌ای و شرطی بین دامنه‌ها می‌شود. روش DAIC به تفکیک نسبت به روش CDDA دارای متوسط بهبود دقت (۶۶٪/۹۹) در پایگاه‌داده آفیس و کالتک، (۶۶٪/۹۶) در پایگاه‌داده اعداد، و (۶۶٪/۹۱) در پایگاه‌داده پای است.

روش VDA علاوه‌بر تطبیق توزیع‌های حاشیه‌ای و شرطی شرطی از یک خوشبندی مستقل از دامنه برای بهبود صحت طبقه‌بند استفاده می‌کند؛ با این حال، به دلیل ویژگی‌های متفاوت داده‌های آموزشی و آزمون در دامنه‌های منبع و هدف، صحت بالایی در پیش‌بینی داده‌های دامنه هدف را ندارد.

روش CLGA یک رویکرد تطبیق دامنه بدون نظارت چند منبعی است که به بررسی نحوه بهره‌گیری مؤثر و همزمان از اطلاعات رده‌ها و دامنه‌ها می‌پردازد. روش DAIC به تفکیک نسبت به روش CLGA دارای متوسط بهبود دقت (۹۸٪/۱۳) در پایگاه‌داده آفیس و کالتک و (۸۶٪/۷) در پایگاه‌داده پای است.

۵-۴- ارزیابی پارامترها

برای به دست آوردن تنظیمات مدل، روش DAIC با مقادیر مختلف پارامترها مورد ارزیابی قرار می‌گیرد. در روش‌های یادگیری ماشین، یک اصل مهم در فرآیند بهینه‌سازی انتخاب نرخ یادگیری مناسب است (k) در رابطه (۱۳). اگر مقدار پایینی برای (k) انتخاب شود، سرعت هم‌گرایی بسیار کاهش می‌یابد، در حالی که اگر (k) مقدار بالایی داشته باشد، فرآیند هم‌گرایی چار جهش شده و از محدوده مورد انتظار فراتر می‌رود و الگوریتم در تعداد تکرار معقول همگرا نمی‌شود. در این چارچوب پیشنهادی به طور تجربی $k = 0.01$ در نظر گرفته شده که نرخ یادگیری با افزایش تعداد تکرار کاهش یابد. جهت محاسبه مقدار بهینه W از بیست تکرار برای به دست آوردن نتایج الگوریتم استفاده شده است؛ در بیشتر موارد DAIC در بیست تکرار اولیه به هم‌گرایی رسیده و تعداد تکرار بیشتر، تأثیری در افزایش دقت الگوریتم ندارد. λ پارامتر تنظیم بین واگرایی برگمن (D_w) و تابع هدف ($F(W)$) است و در محدوده $[0.0001, 10]$ بررسی می‌شود، مقدار بهینه پارامتر λ برای تمامی پایگاه‌داده‌ها برابر 0.1 است. علاوه‌براین پارامتر τ در محدوده $[0.01, 100]$ در نظر گرفته می‌شود. τ یکی از پارامترهای تاثیرگذار در DAIC است، در واقع ضرایب ماتریس A را کنترل و تعداد نمونه‌های منبع مرتبط را تعیین

بین دامنه‌ها، دقت پایینی در تمام پایگاه‌داده‌های مورد آزمایش دارد.

با استفاده از واگرایی برگمن درنظر می‌گیریم. بهمین ترتیب براساس نتایج نشان داده شده در شکل (۷) نمودار FLDA بهدلیل عدم بهره‌گیری از اطلاعات تفکیک‌کننده اولیه داده‌های دامنه منبع و نادیده‌گرفتن اختلاف توزیع حاشیه‌ای

(جدول-۲): دقت (%) طبقه‌بند در مجموعه‌داده آفیس و کالتک

(Table-2): Classification accuracy (%) on Office and Caltech-256 datasets.

Dataset	NN	FLDA	TJM	TSL	DAM	FIDOS	LRSR	VDA	CLGA	CDDA	FLDA _m	DAIC
C-A	23.7	40.22	46.76	32.78	42.69	44.78	51.25	46.14	48.02	48.33	52.3	53.03
C-W	25.76	40.11	39.98	44.07	34.58	38.64	38.64	46.1	42.37	44.75	41.8	48.81
C-D	25.48	39.99	44.59	49.04	33.12	42.68	47.13	51.59	49.04	48.41	38.86	47.13
A-C	26	41.36	39.45	21.1	35.35	39.63	43.37	42.21	42.30	42.12	41.85	41.5
A-W	29.83	41.65	42.03	24.34	31.86	37.29	36.61	51.19	41.36	41.69	31.39	51.86
A-D	25.48	40.89	45.22	49.04	36.31	32.48	38.85	48.41	36.31	97.58	40.95	50.32
W-C	19.86	40	30.19	22.53	33.84	25.29	29.83	27.6	32.95	31.97	33.39	34.55
W-A	22.96	42.90	29.96	27.24	37.58	31.32	34.13	26.1	34.75	37.27	37.68	42.90
W-D	59.24	41.52	89.17	61.78	80.87	70.7	82.80	89.18	92.36	87.9	60.43	90.45
D-C	26.27	43.21	31.43	22.71	32.41	27.69	31.61	31.26	33.66	34.64	33.04	31.97
D-A	28.5	42.56	32.78	19.83	34.34	28.6	33.19	37.68	35.99	33.51	32.43	41.75
D-W	63.39	42.91	85.42	60.68	77.63	58.98	77.29	90.85	89.83	90.51	69.97	92.88
Average	31.37	41.38	44.41	37.09	42.55	39.84	45.39	49.03	48.23	47.22	42.84	52.21

(جدول-۳): دقت (%) طبقه‌بند در مجموعه‌داده پای

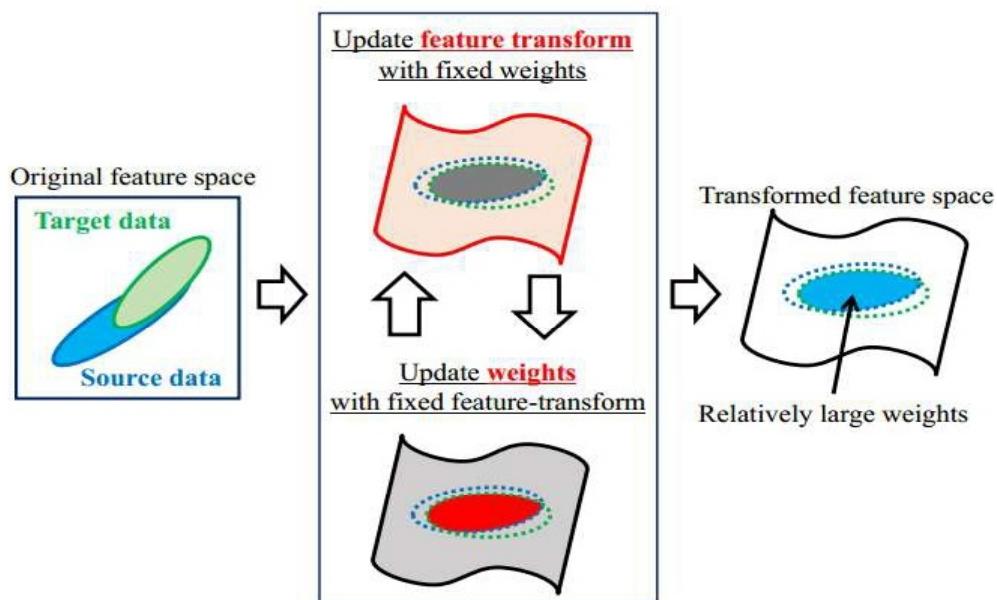
(Table-3): Classification accuracy (%) on PIE datasets.

Dataset	NN	FLDA	TJM	TSL	DAM	FIDOS	LRSR	VDA	CLGA	CDDA	FLDA _m	DAIC
P1_P2	26.09	33.89	23.87	33.46	46.65	20.87	65.87	40.09	67.83	60.22	37.63	82.63
P1_P3	26.59	33.56	28.86	33.58	45.04	27.51	64.09	45.22	63.85	58.7	47.55	78.06
P1_P4	30.67	32.93	43.37	35.27	68.52	39.62	82.03	71.64	88.95	83.48	69.18	92.67
P1_P5	16.67	38.79	19.3	26.78	28.74	22.79	54.90	33.33	61.76	54.17	36.09	64.95
P2_P1	24.49	35.29	26.14	45.47	35.32	27.79	45.54	55.58	71.40	62.33	38.6	76.65
P2_P3	46.63	34.78	37.93	42.59	35.78	34.8	53.49	57.23	72.98	64.64	44.91	77.7
P2_P4	54.07	35.17	50.53	45.63	72.33	46.59	71.43	68.82	86.24	79.9	69.84	89.67
P2_P5	26.53	32.41	21.63	31.43	35.11	27.63	47.97	35.23	51.23	44	34.01	64.22
P3_P1	21.37	37.36	28.66	42.44	41	33.19	52.49	46.64	70.17	58.46	44.48	71.58
P3_P2	41.01	37.03	35.97	37.02	59.36	36.28	55.56	53.04	73.48	59.73	40.7	82.26
P3_P4	46.53	38.45	51.97	41.12	72.33	53.08	77.50	62.75	89.31	77.2	69.42	88.22
P3_P5	26.23	32.59	25.31	30.27	40.32	35.29	54.11	39.22	55.51	47.24	46.81	72.49
P4_P1	32.95	34.53	45.71	36.49	69.36	51.35	81.54	71.55	89.56	83.1	72.09	93.88
P4_P2	62.68	35.21	57.58	39.29	77.29	51.87	58.39	75.51	92.94	82.26	65.56	95.27
P4_P3	73.22	34.96	71.63	43.01	76.72	66.05	82.23	80.21	93.08	86.64	72.79	93.81
P4_P5	37.19	34.80	30.94	32.11	61.15	42.65	72.61	53.06	71.63	58.33	59.25	84.99
P5_P1	18.49	31.81	27.13	37.39	30.52	21.13	52.19	49.01	57.68	48.02	39.83	59.03
P5_P2	24.1	29.28	22.65	34.62	37.14	22.9	49.41	38.67	55.43	45.61	34.62	71.09
P5_P3	28.31	34.06	28.86	35.11	41.11	26.41	58.45	36.4	58.03	52.02	50.67	74.45
P5_P4	31.24	29.12	32.59	46.08	39.14	31.12	64.31	46.11	71.85	55.99	62.06	86.57
Average	34.76	34.30	35.53	37.46	49.5	35.95	61.53	52.97	72.15	63.1	51.81	80.01

(جدول-۴): دقت (%) طبقه‌بند در مجموعه‌داده اعداد

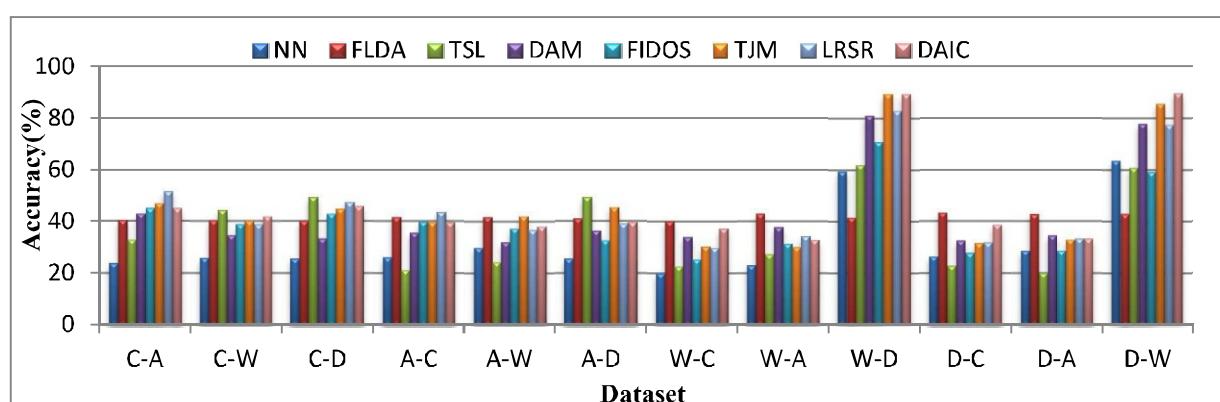
(Table-4): Classification accuracy (%) on USPS+ MNIST datasets

Dataset	NN	FLDA	TJM	TSL	DAM	LRSR	VDA	CDDA	FLDA _m	DAIC
U-M	44.7	73.51	52.25	50.74	42.69	54.51	62.95	62.05	60.54	68.50
M-U	65.94	64.89	63.28	59.6	52.83	73.82	74.72	76.22	73.21	83.00
Average	55.32	58.31	57.76	55.17	47.76	64.16	68.84	69.13	66.87	75.75



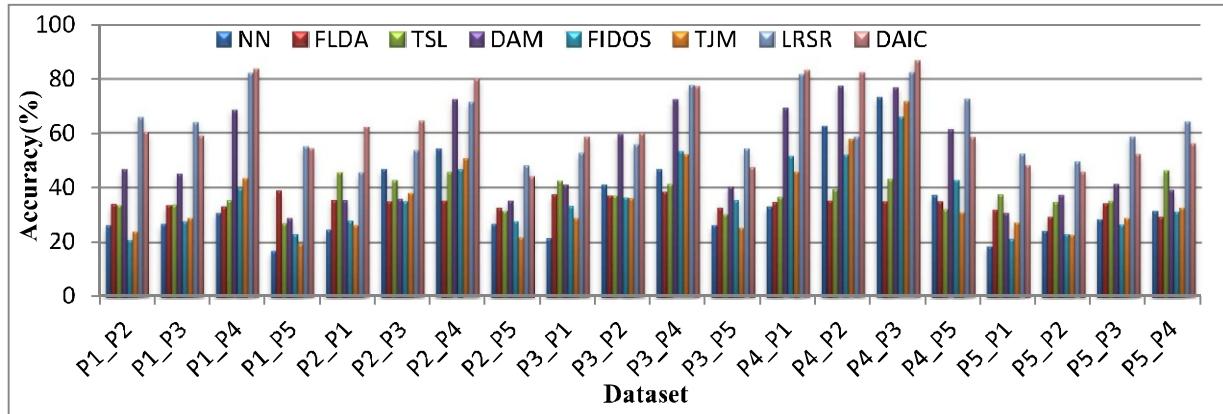
(شکل-۳): روش پیشنهادی DAIC داده‌های منبع و هدف را که در فضای اصلی دارای توزیع متفاوت هستند با استفاده از ماتریس تبدیل FLDA و واگرایی برگمن به یک زیرفضای جدید نگاشت می‌کند تا اختلاف توزیع آن‌ها را کاهش دهد، هم‌زمان با این کار با استفاده از یک ماتریس وزن تأثیر نمونه‌های نامرتبط دامنه منبع را کم می‌کند. از آنجایی که پیدا کردن هم‌زمان ماتریس تبدیل و ماتریس وزن کار دشواری است DAIC ابتدا در مرحله نخست ماتریس وزن را ثابت در نظر می‌گیرد و ماتریس تبدیل پهینه را به دست می‌آورد و در مرحله دوم ماتریس تبدیل به دست آمده را ثابت در نظر می‌گیرد و ماتریس وزن پهینه را به دست می‌آورد.

(Figure-3): An overview of the proposed method. DAIC projects the source and target data into a shared low dimensional subspace based on Bregman divergence minimization and FLDA criteria and at the same time, the use of a weight matrix reduces the impact of unrelated instances on the source domain. Since it is mathematically difficult to optimize them simultaneously, we adopt an interactive approach in which the optimization of feature transform and that of instance weight are conducted alternately.



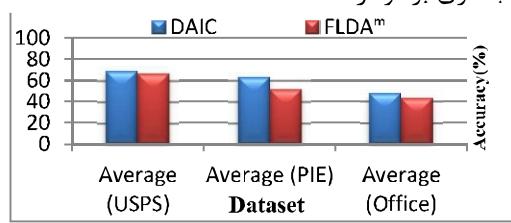
(شکل-۴): صحت طبقه‌بندی در مجموعه‌داده‌های آفیس و کالتك با استفاده از روش‌های مختلف NN, FLDA, TSL, DAM, FIDOS, TJM, LRSR و DAIC.

(Figure-4): Classification accuracy (%) on Office and Caltech-256 datasets using different methods NN, FLDA, TSL, DAM, FIDOS, TJM, LRSR and DAIC.



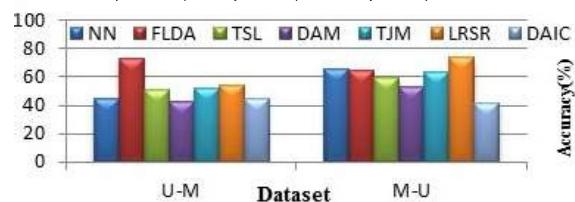
(شکل-۵): صحت طبقه‌بندی در مجموعه‌دادهای پای با استفاده از روش‌های مختلف DAIC، LRSR، TJM، FIDOS، DAM، TSL، FLDA، NN (Figure-5): Classification accuracy (%) on PIE datasets using different methods NN, FLDA, TSL, DAM, FIDOS, TJM, LRSR and DAIC.

(۸) نمودار DAIC در مقایسه با FLDA^m به دلیل بهره‌گیری همزمان از تطبیق خصوصیات و روش وزن‌دهی به نمونه‌ها از دقت بالاتری برخودار است.



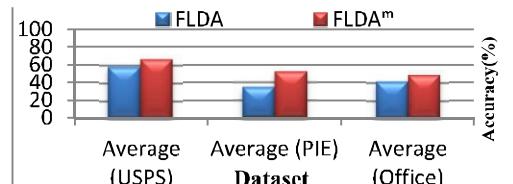
(شکل-۶): مقایسه دقت (%) مدل پیشنهادی با توجه به کاهش اختلاف توزیع حاشیه‌ای و وزن‌دهی به نمونه‌ها

(Figure-6): Comparison of the accuracy (%) of the proposed model with respect to the reduction of marginal distribution and sample reweighting



(شکل-۷): صحت طبقه‌بندی در مجموعه‌دادهای اعداد با استفاده از روش‌های مختلف TJM، FIDOS، DAM، TSL، FLDA، NN، DAIC و LRSR

(Figure-7): Classification accuracy (%) on Digit datasets using different methods NN, FLDA, TSL, DAM, TJM, LRSR and DAIC.



(شکل-۸): مقایسه دقت (%) مدل پیشنهادی با توجه به کاهش FLDA

(Figure-8): Comparison of the accuracy (%) of the proposed model with regard to the reduction of the marginal distribution gap and the FLDA method

۴-۵-۴- بررسی ضرورت وزن‌دهی مجدد به نمونه‌ها

در شرایطی که اختلاف توزیع دامنه‌های منبع و هدف زیاد باشد، فقط با کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف، نمی‌توان باعث ایجاد تطبیق‌پذیری طبقه‌بند ایجاد شده بر روی دامنه منبع با دامنه هدف شد (جداول ۲) الی ۴ فیلد (FLDA^m). در چنین شرایطی، حتی با ایجاد تفکیک‌پذیری بین رده‌ها، به علت اینکه ساختار داده‌های دامنه هدف با داده‌های دامنه منبع متفاوت است، یک طبقه‌بند تطبیق‌پذیر بین دامنه‌ای ایجاد نخواهد شد. به همین دلیل روش DAIC، به نمونه‌هایی از دامنه منبع که دارای کمترین مشابهت از نظر توزیع با نمونه‌های دامنه هدف هستند، وزن کمتری در ایجاد مدل طبقه‌بند اختصاص می‌دهد. در شکل

۶- نتیجه‌گیری و کارهای آینده

پردازش تصویر به عنوان ابزار قدرتمند برای درک تصاویر توسط رایانه است که توانایی استخراج اطلاعات و ویژگی‌های تصاویر را دارد. یادگیری ماشین یکی از شاخه‌های پرکاربرد هوش مصنوعی بوده که در زمینه پردازش تصویر به دنبال یافتن الگوریتم‌هایی برای طبقه‌بندی تصاویر با دقت بالا است. در این مقاله، روش تطبیق دامنه بدون نظارت DAIC برای ایجاد تطبیق در دامنه‌های بصری و کاهش اختلاف توزیع حاشیه‌ای 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 حاشیه‌ای بین دامنه‌های منبع و هدف را کاهش می‌دهد. در واقع این روش با استفاده از اطلاعات تفکیک‌کننده اولیه داده‌های ورودی، مدلی را ایجاد می‌کند که مقاومت بیشتری در برابر اختلاف توزیع داده‌های منبع و هدف داشته باشد؛ سپس به طور همزمان، به نمونه‌هایی از دامنه منبع که دارای کمترین مشابهت از نظر توزیع با نمونه‌های دامنه هدف

- work for transfer learning”, *IEEE Trans. Knowl. Data Eng.*, vol. 26, pp. 1076–1089, 2013.
- [8] X. Li, M. Fang, J. J. Zhang, and J. Wu, “Sample selection for visual domain adaptation via sparse coding”, *Signal Processing: Image Communication*, vol 44, pp. 92-100, 2016.
- [9] J. Tahmoresnezhad and S. Hashemi, “Visual domain adaptation via transfer feature learning”, *Knowl Inf Syst*, vol. 50, no. 2, pp. 585-605, 2016.
- [10] M. Long, J. Wang, G. Ding, J. Sun, and P. Yu, “Transfer feature learning with joint distribution adaptation,” in *Proc IEEE International Conference on Computer Vision*, pp. 2200–2207, 2013.
- [11] 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*, vol. PP, no. 99, pp. 1–1, 2016.
- [12] R. A. Fisher, “The use of multiple measurements in taxonomic problems,” *Annals of eugenics*, vol. 7, no. 2, pp. 179–188, 1936.
- [13] K. Saenko, B. Kulis, M. Fritz and T. Darrell, “Adapting visual category models to new domains”, *Proceedings of the European Conference on Computer Vision*, pp. 213-226, 2010.
- [14] J. J. Hull, “A database for handwritten text recognition research”, *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 16, no. 5, pp. 550–554, 1994.
- [15] 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.
- [16] 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.
- [17] Cuong V Dinh, Robert PW Duin, Ignacio Piquerias-Salazar, and Marco Loog. Fidos: A generalized fisher based feature extraction method for domain shift. *Pattern Recognition*, 46(9):2510–2518, 2013.
- [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, pp. 504–518, 2012.
- [19] M. Long, J. Wang, G. Ding, J. Sun, and P. S. Yu, “Transfer joint matching for unsupervised domain adaptation,” in *Proc. IEEE Conference on Computer Vision and Pattern Recognition*, IEEE, pp. 1410–1417 , 2014.

هستند، وزن کمتری در ایجاد مدل طبقه‌بند اختصاص داده می‌شود.

DAIC با افزایش تطبیق‌پذیری بین ساختار دامنه‌های منبع و هدف، باعث افزایش دقت طبقه‌بند در پیش‌بینی برچسب برای داده‌های بدون برچسب دامنه هدف می‌شود. روش DAIC بر روی ۳۴ 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 DAIC نسبت به جدیدترین روش‌های حوزه یادگیری ماشین و یادگیری انتقالی بر روی دامنه‌های مختلف است. برای ادامه کار، ما در حال برنامه‌ریزی جهت گسترش DAIC برای کاهش هم‌زمان توزیع اختلاف‌های حاشیه‌ای و شرطی و علاوه بر این در تلاش جهت توسعه روش DAIC برای سامانه‌های چندمنبعی هستیم. در این راستا، به دنبال انتقال دانش از چند منبع مرتبط به یک منبع هدف هستیم تا بتوانیم صحت پیش‌بینی برچسب دامنه هدف را هرچه بیشتر ارتقا بخشیم.

۷- مراجع

- [1] S. J. Pan and Q. Yang, “A survey on transfer learning,” *IEEE Transactions on Knowledge and Data Engineering*, vol. 22, no. 10, pp. 1345–1359, 2010.
- [2] L. Shao, F. Zhu, and X. Li, “Transfer learning for visual categorization: A survey,” *IEEE transactions on neural networks and learning systems*, vol. 26, no. 5, pp. 1019–1034, 2015.
- [3] S. Ben-David, J. Blitzer, K. Crammer, A. Kulcsza, F. Percira, and J. W. Vaughan, “A theory of learning from different domains,” *Machine learning*, vol. 79, no. 1-2, pp. 151–175, 2010.
- [4] 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.
- [5] S. Si, D. Tao, and B. Geng, “Bregman divergence-based regularization for transfer subspace learning”, *IEEE TKDE*, 2010.
- [6] L. M. Bregman, “The relaxation method of finding the common points of convex sets and its application to the solution of problems in convex programming”, *USSR Computational Mathematics and Mathematical Physics*, vol, 7, pp. 200–217, 1967.
- [7] M. Long, J. Wang, G. Ding, S. J. Pan and P. Yu, “Adaptation regularization: a general frame-



- [32] Z. Ding, M. Shao, and Y. Fu, "Deep low-rank coding for transfer learning," in Proceedings of the 24th International Conference on Artificial Intelligence. AAAI Press, 2015, pp. 3453–3459.
- [33] M. Long, J. Wang, G. Ding, J. Sun, and P. Yu, "Transfer feature learning with joint distribution adaptation," in Proceedings of the IEEE International Conference on Computer Vision, 2013, pp. 2200–2207.
- [34] H. Li, T. Jiang, and K. Zhang, "Efficient and robust feature extraction by maximum margin criterion," *IEEE Transactions on Neural Networks*, vol. 17, no. 1, pp. 157–165, 2006.
- [35] M. Long, J. Wang, G. Ding, S. J. Pan, and P. S. Yu, "Adaptation regularization: A general framework for transfer learning," *IEEE Transactions on Knowledge and Data Engineering*, vol. 26, no. 5, pp. 1076–1089, 2014.
- [36] Y. Xu, S. J. Pan, H. Xiong, Q. Wu, R. Luo, H. Min, and H. Song, "A unified 310 fied framework for metric transfer learning," *IEEE Trans. Knowl. Data Eng.*, vol. 29, no. 6, pp. 1158–1171, 2017.
- [۳۷] سیدصالحی سیده زهره، سیدصالحی سید علی، ببهود مدل تفکیک کننده منیفلد های غیرخطی به منظور بازشناسی چهره یا یک تصویر از هر فرد. پردازش علائم و داده ها، ۱۳۹۴، ۱۲ (۱) : ۳-۱۶.
- [37] S. Z. Seyyedsalehi, S. A. Seyyedsalehi, "Improving nonlinear manifold separator model to the face recognition by a single image of per person", *Signal and Data Processing*, vol. 12, no. 1, pp. 3–16, 2015.
- [۳۸] احمدخانی سمیه، ادبی پیمان. مدل ترکیبی تحلیل مؤلفه اصلی احتمالاتی بانظارت در چارچوب کاهش بعد بدون اتلاف برای شناسایی چهره. پردازش علائم و داده ها، ۱۳۹۴، ۱۲ (۴) : ۵۳-۶۵.
- [38] S. Ahmadkhani, and P. Adibi, "Supervised Probability Component Analysis Mixture Model in a Lossless Dimensionality Reduction Framework for Face Recognition", *Signal and Data Processing*, vol. 12, no. 4, pp. 53–65, 2016.
- جعفر طهمورث‌نژاد مدرک دکترای**
مهندسی کامپیووتر-هوش مصنوعی خود را در سال ۱۳۹۴ از دانشگاه شیراز دریافت کرددند. ایشان در راستای فعالیت‌های علمی خود، در حال حاضر به عنوان استادیار دانشگاه صنعتی ارومیه در حال فعالیت و عالیق پژوهشی



سال ۱۳۹۸ شماره ۳ پیاپی ۴۱

ایشان شامل حوزه‌های یادگیری ماشین، یادگیری انتقالی،
داده کاوی و سامانه‌های امنیتی است.
نشانی رایانمه ایشان عبارت است از:
j.tahmores @it.uut.ac.ir

مژده زندی فر دانشجوی کارشناسی ارشد
مهندسی فناوری اطلاعات، مدرک
کارشناسی خود را در رشته مهندسی
کامپیوتر-نرم‌افزار در سال ۹۴ دریافت
کردند.

نشانی رایانمه ایشان عبارت است از:
mozhdeh.zandifar @it.uut.ac.ir