پردازش تصویر بین‌دامنه‌ای با استفاده از تحلیل تفکیک خطی و تطبیق دامنه مبتنی‌بر نمونه

مژده زندی‌فر و جعفر طهمورث‌نژاد*

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

چکیده

پردازش تصویر روشی برای اعمال برخی عملیات‌ها بر روی یک تصویر است به‌طوری‌که با استفاده از آن، تصاویری با کیفیت بالاتر به‌دست آمده یا برخی اطلاعات مفید از تصویر استخراج می‌شود. الگوریتم‌های سنتی پردازش تصویر در شرایطی‌که تصاویر آموزشی (دامنه منبع) که برای یاددهی مدل استفاده می‌شوند، توزیع متفاوتی از تصاویر آزمایش (دامنه هدف) داشته باشند، نمی‌توانند عملکرد خوبی داشته باشند. با این‌حال، بسیاری از برنامه‌های کاربردی دنیای واقعی به‌علت کمبود داده‌های برچسب‌دار آموزشی دارای محدودیت هستند؛ ازاین‌رو از داده‌های برچسب‌دار دامنه‌های دیگر استفاده می‌کنند. به‌این ترتیب به‌خاطر اختلاف توزیع بین دامنه‌های منبع و هدف، طبقه‌بند یادگرفته‌شده براساس مجموعه آموزشی بر روی داده‌های آزمایشی عملکرد ضعیفی خواهد داشت. یادگیری انتقالی و انطباق دامنه، با به‌کارگیری مجموعه‌داده‌های موجود دو راه حل برجسته 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 مسألهٔ 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 ازپیش تعیین‌شده 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. بیش‌تر روش‌های قبلی دو استراتژی یادگیری تطابق 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 اجتناب‌ناپذیر هستند. روش پیشنهادی ما تحت عنوان تطبیق دامنه مبتنی‌بر نمونه برای طبقه‌بندی تصاویر (DAIC)، یک فرایند کاهش بُعد بوده که با کاهش اختلاف توزیع تصاویر آموزشی و آزمایشی و به‌کارگیری هم‌زمان تطابق ویژگی‌ها و وزن‌دهی مجدد کارایی مدل را افزایش می‌دهد. ما با گسترش واگرایی برگمن غیرخطی برای اندازه‌گیری تفاوت توزیع حاشیه‌ای و اعمال آن به الگوریتم کاهش بُعد آنالیز تفکیک خطی فیشر، از آن برای ساخت یک نمایش ویژگی مؤثر و قوی برای تفاوت‌های توزیع قابل ملاحظه بین دامنه‌ها استفاده می‌کنیم؛ همچنین، DAIC از مزیت برچسب‌گذاری اولیه برای داده‌های هدف به‌صورت تکرارشونده برای هم‌گرایی مدل استفاده می‌کند. آزمایش‌های گستردهٔ ما نشان می‌دهد که DAIC به‌طور قابل توجهی بهتر از الگوریتم‌های یادگیری ماشین پایه و دیگر روش‌های یادگیری انتقالی در نُه 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

*نویسندهٔ عهده‌دار مکاتبات

● تاریخ ارسال مقاله: ۱۳۹۶/۱۲/۲۲ ● تاریخ پذیرش: ۱۳۹۸/۴/۱۲ ● تاریخ انتشار: ۱۳۹۸/۱۰/۰۷ ● نوع مطالعه: پژوهشی

[DOI: 10.29252/jsdp.16.3.148]

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 × 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 3232 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

۱- مقدمه

پردازش تصویر یکی از مسائل مهم در هوش مصنوعی و یادگیری ماشین است، که هدف اصلی آن طراحی و ساخت سامانه‌های خبره مبتنی‌بر 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 به‌طور قابل توجهی پیشرفت داشته‌اند، اما عملکرد آن‌ها با توجه به تعداد کم داده‌های برچسب‌دار[1] موجود، برای آموزش محدود می‌شود. از طرف دیگر هزینه برچسب‌زدن داده‌ها با توجه به دخالت‌داشتن انسان در این زمینه، مقرون به‌صرفه نبوده و از لحاظ زمانی وقت‌گیر است؛ درحالی‌که جمع‌آوری اطلاعات تصویری بدون برچسب به‌مراتب ساده‌تر بوده و درواقع داده‌های بدون برچسب به‌طور مداوم در حال تولیدشدن هستند.

[1] Label

[DOI: 10.29252/jsdp.16.3.148]

الگوریتم‌های یادگیری موجود اغلب با این پیش‌فرض عمل می‌کنند که داده‌های آموزشی[1] و داده‌های آزمایشی[2] هر دو از یک توزیع[3] و فضای ویژگی[4] یکسانی هستند [1]. با این‌حال درعمل و در بسیاری از برنامه‌های کاربردی دنیای 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 استفاده‌شده 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 روشنایی، زاویه دید، دقت، تصویر زمینه و شرایط عکس‌برداری می‌تواند منجربه تغییر در توزیع نمونه‌های دو مجموعه‌داده شود. به‌عنوان مثال مسأله تشخیص اشیا[5] یکی از مسائل پرکاربرد حوزه بینایی ماشین و پردازش تصویر به‌شمار می‌رود. امروزه با رشد روزافزون سامانه‌های بینایی ماشین در کاربردهای روزمره، تشخیص اشیا بیش از پیش مورد توجه قرار گرفته است. به‌عبارتی، تفاوت در توزیع نمونه‌های آموزشی و آزمایشی (برای نمونه تفاوت در روشنایی، زاویه دید، دقت، تصویر زمینه و شرایط عکس‌برداری تصاویر) می‌تواند منجربه افت کارایی مدل های تشخیص اشیا در پردازش تصویر شود. برای نمونه اگر یک مدل با استفاده از تصاویر سی تی اسکن[6] و ایکس- ری[7] آموزش دیده باشد و از آن جهت تشخیص اعضای بدن در یک تصویر ام آر آی[8] استفاده شود، به‌طورطبیعی در شرایط عادی مدل کارایی قابل قبولی نخواهد داشت [2]؛ در چنین شرایطی اگر بتوان از دانش به‌دست‌آمده از داده‌های آموزشی (که دارای توزیع یا فضای ویژگی متفاوتی با داده‌های آزمایشی است) به‌نحوی برای داده‌های آزمایشی استفاده کرد، می‌توان عملکرد مدل ایجادشده را در فضای آزمون بهبود بخشید. راه حلی که در سال‌های اخیر مورد توجه قرار گرفته، انطباق دامنه است.

انطباق دامنه[9] یکی از زمینه‌های یادگیری انتقالی[10] است و یک مسأله مهم در یادگیری ماشین محسوب می‌شود که هدف آن یادگیری طبقه‌بند مناسبی است که بتواند دقت قابل قبولی بر روی داده‌های آزمایشی داشته باشد، درحالی‌که توزیع داده‌های آموزشی و آزمایشی با یکدیگر متفاوت است. در انطباق دامنه، به جای فرض یکسان‌بودن 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 بازشناسی الگو[11]، پردازش زبان طبیعی[12]، پردازش گفتار[13]، مکان‌یابی WI-FI[14]، زمینه بینایی ماشین در تشخیص چهره، آشکارسازی اشیا، تشخیص عابر پیاده[15] و بازشناسی رویداد[16] کاربرد دارد. مسأله تطبیق دامنه تاکنون در حوزهٔ پردازش زبان طبیعی بسیار موفق بوده، اما تلاش‌هایی که برای این مسأله در حوزه بینایی رایانه‌ای شده، محدود بوده و قابل گسترش است [3].

مهم‌ترین چالش در انتقال مفاهیم یادگرفته‌شده جلوگیری از بروز انتقال منفی[17] است، به این معنی که استفاده از روش‌های تطبیق دامنه نه‌تنها 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 [4]؛ زیرا با توجه به این تفاوت می‌توان از انتقال منفی جلوگیری کرد. بنابراین معیار اندازه‌گیری اختلاف توزیع دامنه‌ها با یکدیگر بسیار مهم است؛ یعنی با چه معیاری فاصله بین دامنه‌ها و میزان تفاوت آن‌ها با یکدیگر را می‌توان اندازه گرفت. اختلاف توزیع بین دامنه‌های منبع و هدف، شامل اختلاف در توزیع حاشیه‌ای[18] و شرطی[19] است. برای مثال می‌توان گفت اگر مسأله یک مسأله دسته‌بندی اسناد باشد، اختلاف توزیع حاشیه‌ای متناظر با حالتی است که دو مجموعه اسناد منبع و هدف روی موضوع‌های[20] متفاوتی متمرکز شده باشند. همچنین برای اختلاف توزیع شرطی می‌توان حالتی را درنظر گرفت که اسناد دو دامنه منبع و هدف از لحاظ دسته‌های تعریف‌شده توسط کاربران بسیار نامتوازن[21] باشند. در سامانه‌های یادگیری ماشین، وجود اختلاف توزیع حاشیه‌ای و

[1] Training data
[2] Testing data
[3] Distribution
[4] Feature space
[5] Object detection
[6] CT scan
[7] X-Ray
[8] MRI
[9] Domain adaptation
[10] Transfer learning
[11] Pattern recognition
[12] Natural-language processing(NLP)
[13] Speech processing
[14] WI-FI localization
[15] Pedestrian detection
[16] Event recognition
[17] Negative transfer
[18] Marginal distribution
[19] Conditional distribution
[20] Topic
[21] Unbalanced

[DOI: 10.29252/jsdp.16.3.148]

شرطی بین دامنه‌های منبع و هدف موجب می‌شود، مدل طبقه‌بند ایجادشده در دامنه منبع، دقت پایینی در پیش‌بینی برچسب‌های نمونه‌های دامنه هدف داشته باشد [4].

بیش‌تر روش‌های یادگیری انتقالی موجود، از فاصله اقلیدسی[1] یا روش بیشینه اختلاف میانگین‌ها[2] (MMD) برای محاسبه اختلاف توزیع بین نمونه‌های دامنه منبع و هدف استفاده می‌کنند. این دو متریک دارای محدودیت‌هایی هستند که ممکن است، روی انتقال دانش تأثیر منفی بگذارند. به‌عنوان مثال توابع هدفی که با استفاده از فاصله اقلیدسی تعریف می‌شوند، ممکن است به‌خوبی بهینه نشوند و دچار مشکل زیربهینه[3] شوند. درواقع فاصله اقلیدسی در فضای داده‌های ورودی، لزوما نمی‌تواند به‌خوبی عدم شباهت داده‌ها را نشان دهد، زیرا ممکن است برخی از ویژگی‌ها نسبت به بقیه اهمیت بیشتری داشته باشند. علاوه‌براین 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 متریک نمی‌توانند اطلاعات تفکیک‌کننده اولیه (به‌عنوان مثال اطلاعات هندسی و اطلاعات آماری داده‌ها) به‌دست‌آمده از دامنه منبع را به دامنه هدف انتقال دهند. در این پژوهش برای اجتناب از این‌گونه مسائل از واگرایی برگمن[4] برای سنجش و کاهش اختلاف توزیع بین دامنه‌های منبع و هدف استفاده می‌شود. واگرایی برگمن [5] یک واگرایی جامع است که تعداد زیادی از فواصل معروف و پرکاربرد از جمله تابع هزینه جمع مربعات[5]، واگرایی کولبک – لایبلر[6]، تابع هزینه منطقی[7]، فاصله ماهالانوبیس[8] را شامل می‌شود. واگرایی برگمن با کاهش تفاوت بین توزیع نمونه‌های آموزشی و آزمایشی می‌تواند دانش تفکیک‌کننده به‌دست‌آمده از نمونه‌های آموزشی را به نمونه‌های آزمایش انتقال دهد. همچنین واگرایی برگمن، اطلاعات تفکیک‌کننده به‌دست‌آمده 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 مسأله 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:

(۱) تطبیق دامنه نیمه‌نظارت شده[9]:که در آن، دامنه هدف شامل تعداد کمی داده برچسب‌دار است، یعنی اگر تعداد داده‌های دامنه منبع n_s باشد، دامنه منبع به‌صورت $D_s = \{(x_i, y_i)\}_{i=1}^{n_s}$ و دامنه هدف به‌صورت $D_t = T_u \cup T_l$ تعریف می‌شوند. اگر تعداد داده‌های برچسب‌دار و بدون برچسب دامنه هدف به‌ترتیب n_{tl} و n_{tu} فرض شود، $T_l = \{(x_i, y_i)\}_{i=1}^{n_{tl}}$ مجموعه داده‌های برچسب‌دار دامنه هدف و $T_u = \{(x_i)\}_{i=1}^{n_{tu}}$ مجموعه داده‌های بدون برچسب دامنه هدف هستند. همچنین در این مسائل فرض می‌شود تعداد زیادی داده بدون برچسب در دامنه هدف موجود است؛ به‌طوری‌که $n_{tl} \ll n_{tu}$ و علاوه‌براین فرض می‌شود داده‌های برچسب‌دار دامنه هدف به‌تنهایی برای ساخت یک طبقه‌بند مناسب، مفید نیستند.

(۲) تطبیق دامنه بدون نظارت[10]: که در آن، هیچ یک از داده‌های دامنه هدف، برچسب ندارند، یعنی اگر تعداد داده‌های دامنه‌های منبع و هدف به‌ترتیب n_s و n_t باشد، دامنه‌های منبع و هدف به‌ترتیب به‌صورت $D_s = \{(x_i, y_i)\}_{i=1}^{n_s}$ و $D_t = \{(x_i)\}_{i=1}^{n_t}$ تعریف می‌شوند [6]. در این پژوهش، مسأله تطبیق دامنه بدون‌نظارت مورد بررسی قرار گرفته است، به‌عبارتی 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 یک تابع پیش‌بینی f_t برای دامنه هدف، با استفاده از داده‌های برچسب‌دار دامنه منبع است؛ به‌طوری‌که 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 به‌تفصیل توضیح داده می‌شوند.

روش پیشنهادی این مقاله با عنوان DAIC[11]، یک روش بدون نظارت با بهره‌گیری از تطبیق خصوصیات و وزن‌دهی مجدد نمونه‌ها است. DAIC با استفاده از الگوریتم FLDA[12] و واگرایی برگمن یک نمایش جدید از داده‌ها ایجاد می‌کند تا اختلاف توزیع حاشیه‌ای دامنه‌ها را کاهش داده و به‌صورت هم‌زمان از روش وزن‌دهی مجدد برای انتخاب

[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

[DOI: 10.29252/jsdp.16.3.148]

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

اهداف اصلی رویکرد پیشنهادی بدین صورت خلاصه شده است: ۱) حفظ ساختار اصلی داده‌ها: DAIC به‌کمک فرآیند FLDA، داده‌های دامنه منبع و هدف را به یک زیرفضای ویژگی کم‌بُعد نگاشت می‌کند به‌طوری‌که 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 کمینه‌کردن نرم $\ell_{2,1}$ بر روی داده‌های دامنه منبع، نمونه‌هایی از دامنه منبع را که مرتبط با دامنه هدف است، انتخاب می‌کند. درنهایت، تمامی این اهداف با یکدیگر ادغام می‌شوند و یک نمایش ویژگی جدید به دست می‌آید؛ به‌طوری‌که 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 به‌طور هم‌زمان بهینه می‌شوند. DAIC با استفاده از تطبیق خصوصیات و واگرایی برگمن یک زیرفضای جدید به‌دست می‌آورد که در آن خصوصیات مشترک دو دامنه منبع و هدف حفظ می‌شوند و سپس با استفاده از ماتریس وزن‌دهی به نمونه‌ها و به‌کارگیری نرم[1] $\ell_{2,1}$ نمونه‌هایی را از دامنه منبع که مرتبط و نزدیک به دامنه هدف هستند، انتخاب می‌کند؛ به‌طوری‌که 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 پایگاه‌داده‌های 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 درنهایت در بخش ۶ نتیجه‌گیری و کارهای پیشنهادی آینده ارائه شده است.

[1] l2,1 norm
[2] Task
[3] Prior Distribution

۲- کارهای پیشین

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

- رویکردهای مبتنی‌بر انتقال پارامتر
- رویکردهای مبتنی‌بر نمونه
- رویکردهای مبتنی‌بر ویژگی

رویکردهای مبتنی‌بر انتقال پارامتر فرض می‌کنند که دو وظیفه[2] در دامنه منبع و هدف دارای تعدادی پارامتر یکسان یا توزیع پیشین[3] با ابر پارامترهای[4] یکسان است. بدین‌ترتیب با پیداکردن این پارامترها یا توزیع‌های پیشین مشترک می‌توان یادگیری را به دامنه جدید انتقال داد. از کارهای انجام‌شده در این دسته می‌توان به ARTL[5] [7] و JACRL [31] 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؛ به‌طوری‌که 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 مبتنی‌بر 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 بُعد کم نگاشت می‌شوند؛ سپس در این فضا با 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 به‌منظور کمینه‌کردن ریسک تجربی تابع پیش‌بینی در داده‌های برچسب‌دار دامنه منبع و همچنین بیشینه‌کردن نرخ سازگاری تابع پیش‌بینی و ساختار هندسی داده‌ها، ایجاد می‌شود.

رویکردهای مبتنی‌بر نمونه براساس وزن‌دهی مجدد نمونه‌ها و یا انتخاب نمونه‌هایی که تفاوت بین توزیع دامنه‌های منبع و هدف را کمینه می‌سازند، عمل می‌کنند. روش‌های مبتنی‌بر نمونه با تخصیص وزن به نمونه‌ها، تابع ضرر[6] را روی

[4] Hyperparameters
[5] Adaptation regularization for transfer learning
[6] Loss function

توزیع داده‌ها کمینه می‌کنند. وزن‌دهی مجدد نمونه[1] و نمونه‌برداری اهمیت[2] دو روش مهم مبتنی‌بر این رویکرد هستند. از جملهٔ این روش‌ها می‌توان به SSSC[3] [8] و LSSA [30] 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. SSSC از کدگذاری تُنُک[4] 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 بدون‌نظارت است که از مفهوم لَندمارک استفاده می‌کند. در مرحله نخست لندمارک‌ها شناسایی می‌شوند؛ برای این کار هر نمونه چه از دامنه منبع باشد وچه از دامنه هدف به‌عنوان 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 انتخاب‌شده در مرحله قبل، تمام نقاط دامنه منبع و دامنه هدف به یک فضای مشترک تصویر می‌شوند.

بیشتر روش‌های موجود در زمینه تطبیق دامنه بدون نظارت روش‌های مبتنی‌بر ویژگی هستند که ایده کلی این روش‌ها تغییر ویژگی‌های اولیه و به‌دست‌آوردن یک نمایش جدید برای داده‌ها است، با این هدف که ویژگی‌های جدید، بازنمایی[5] بهتری برای خصوصیات مشترک دامنه‌های منبع و هدف ارائه دهند. درواقع روش‌های مبتنی‌بر ویژگی بر دو فرض کلی استوارند: (۱) برخی ویژگی‌های مختص یک دامنه[6] و برخی مستقل از دامنه[7] هستند. (۲) از فضای ویژگی اصلی به فضای ویژگی نهان[8] 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.

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؛ به‌طور کلی، رویکردهای کاهش بُعد از دو چارچوب اصلی پیروی می‌کنند: (۱) الگوریتم‌هایی که براساس روش PCA هستند و داده‌ها را به یک فضای کم‌بُعد نگاشت می‌کنند؛ به‌طوری‌که واریانس داده‌های نگاشت‌شده بیشینه شود. از جمله این الگوریتم‌ها می‌توان به VDA [9]، JDA [10] و CLGA [22] اشاره کرد که از PCA برای نگاشت داده‌ها به یک زیرفضای کم‌بُعد استفاده می‌کنند. CLGA یک رویکرد تطبیق دامنه بدون‌نظارت چندمنبعی است که به بررسی نحوه بهره‌گیری مؤثر و هم‌زمان از اطلاعات رده‌ها و دامنه‌ها می‌پردازد. CLGA به‌منظور افزایش افزایش انطباق دامنه‌ها، ابتدا چند دامنه را به‌عنوان یک دامنه در نظر می‌گیرد، سپس هم‌زمان اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌های منبع و هدف را به کمینه می‌رساند (تطبیق‌پذیری کلی). علاوه‌براین، CLGA به‌منظور افزایش قابلیت تفکیک‌پذیری، ارتباط بین رده‌ها و دامنه‌های مجزا را بررسی و از ساختار هندسی دامنه‌ها و رده‌ها استفاده می‌کند. درواقع، CLGA به‌منظور افزایش قابلیت تفکیک‌پذیری ،فاصلهٔ بین نمونه‌های متلعق به یک رده اما دامنه متفاوت را کاهش می‌دهد، و فاصله بین نمونه‌های متعلق به یک دامنه اما ردهٔ متفاوت را افزایش می‌دهد (تطبیق‌پذیری محلی). (۲) الگوریتم‌هایی که براساس روش FLDA عمل می‌کنند. این الگوریتم‌ها در تلاش هستند داده‌ها را به‌گونه‌ای به فضای کم‌بُعد نگاشت کنند که رده‌های مختلف تفکیک‌پذیری بیشتری نسبت به هم داشته باشند. از جمله این الگوریتم‌ها می‌توان به SCA [11] 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 حالی‌که FLDA براساس پیداکردن روابط بین رده‌های متفاوت داده، انجام می‌پذیرد.

دراین مقاله، یک روش تطبیق دامنه بدون نظارت برای حل مسأله یادگیری انتقالی ارائه شده است. درواقع یک چارچوب کلی با ترکیبی از دو روش مبتنی‌بر خصوصیت و مبتنی‌بر نمونه پیشنهاد می‌شود. در این روش داده‌های دامنه

[1] Instance Reweighting
[2] Importance Sampling
[3] Sample selection sparse coding
[4] Sparce coding

[5] Representation
[6] Domain-specific
[7] Domain-invariant
[8] Latent space

[DOI: 10.29252/jsdp.16.3.148]

منبع و هدف توسط ترکیبی از روش FLDA و متریک واگرایی برگمن، به یک زیرفضای جدید که در آن اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف کمینه‌شده، نگاشت می‌شوند. همچنین به‌طور هم‌زمان نمونه‌هایی از دامنه منبع که شباهت بیشتری با نمونه‌های دامنه هدف دارند، انتخاب و مدل براساس این نمونه‌های انتخاب‌شده ایجاد می‌شود.

۳- روش پیشنهادی

در این بخش، جزئیات الگوریتم پیشنهادی DAIC برای حل مسائل تطبیق دامنه بدون‌نظارت شرح داده می‌شود.

۳-۱- تعریف مسأله

مسأله شیفت در دامنه‌ها زمانی رخ می‌دهد که دامنه‌های آموزشی و آزمایشی توزیع متفاوتی داشته باشند؛ بنابراین طبقه‌بند ساخته‌شده 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 $X_s = X_t$، $Y_s = Y_t$ و $P_s(x_s) \neq P_t(x_t)$، دو دامنه از توزیع حاشیه‌ای متفاوتی برخوردار هستند، هدف ما در این مقاله این است که مدلی طراحی کنیم که توزیع حاشیه‌ای داده‌های آموزشی و آزمایشی را تقریبا برابر کند؛ یعنی $P_s(x_s) \sim P_t(x_t)$ DAIC اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف را با یادگیری یک نمایش جدید کاهش می‌دهد. درواقع DAIC با استفاده توأم از روش کاهش بعد FLDA و وزن‌دهی به نمونه‌های دامنه منبع دقت مدل ایجادشده را برای نمونه‌های دامنه هدف به‌طور قابل ملاحظه‌ای افزایش می‌دهد.

در نمایش جدید، به‌صورت هم‌زمان اختلاف توزیع حاشیه‌ای بین دامنه‌ها کمینه شده و از روش وزن‌دهی به نمونه‌های دامنه منبع، برای بهبود عملکرد مدل طبقه‌بند در پیش‌بینی برچسب‌ها استفاده شده است.

۳-۲- واگرایی برگمن

بیشتر مطالعات قبلی در حوزه یادگیری انتقالی یا براساس ارزش‌گذاری مجدد نمونه‌های دامنه منبع مطابق با توزیع دامنه هدف [24]، [25]، [26] و یا براساس یافتن یک نمایه جدید برای نمونه‌های دامنه منبع و هدف، به منظور کاهش اختلاف توزیع بین دامنه‌های منبع و هدف عمل می‌کنند [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 ناهماهنگی‌های بین نمونه‌ها را انتقال دهد. واگرایی برگمن[1] یکی از معیارهای اندازه‌گیری فاصله بین دو توزیع احتمال است که دامنه گسترده‌ای از فاصله‌ها از جمله تابع هزینه جمع مربعات، واگرایی کولبک – لایبلر، تابع هزینه منطقی، فاصله ماهالانوبیس را در بر می‌گیرد. واگرایی برگمن با کاهش اختلاف بین توزیع نمونه‌های آموزشی و آزمایشی می‌تواند دانش تفکیک‌کنندهٔ به‌دست‌آمده از نمونه‌های آموزشی را به نمونه‌های آزمایش انتقال دهد.

تعریف: فرض کنید $\psi : \Omega \rightarrow R$ یک تابع بطور محدب در مجموعه محدب $\Omega \subseteq R^m$ است که فرض می‌شود ناتهی و تمایزپذیر است. بنابراین برای $x,y \in R^m$ واگرایی برگمن با توجه به ψ به‌صورت زیر تعریف می‌شود:

$$BD_\psi(x,y) = \psi(x) - \psi(y) - < x - y, \nabla\psi(y) > \quad (۱)$$

که درآن $\nabla\psi(y)$، نشان‌دهنده گرادیان ψ در نقطه y و $<\dots>$ ضرب داخلی است. واگرایی برگمن تعریف‌شده در (۱) را می‌توان تفاوت بین مقدار تابع محدب در x و نخستین مرتبه بسط تیلور[2] آن در نقطه y، تفسیر کرد، به‌طور معادل، بخش باقی‌مانده از نخستین مرتبه بسط تیلور ψ در y دانست. مفهوم هندسی واگرایی برگمن در شکل (۱) نشان داده شده است. براساس شکل (۱) واضح است که واگرایی برگمن فاصله بین مقدار تابع محدب در x و تانژانت آن در y است.

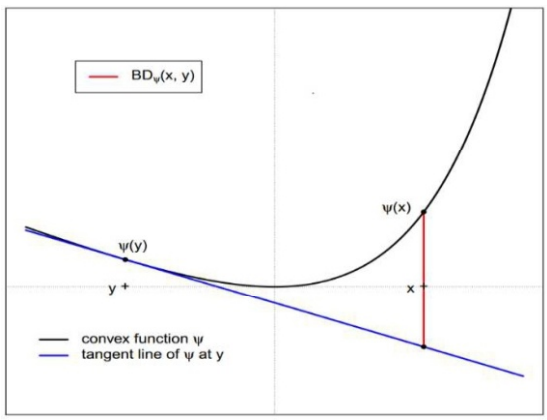

(شکل-۱): تصویر هندسی واگرایی برگمن
(Figure-1): Geometrical illustration of Bregman divergence

[1] Bregman divergence
[2] Taylor expansion

درواقع واگرایی برگمن با توجه به نوع تابع محدب ψ انتخاب‌شده، تابع ضرر را کاهش می‌دهد. به‌عنوان مثال اگر $\psi(x) = x^T Wx$ و W یک ماتریس قطعی مثبت[1] باشد، واگرایی برگمن به صورت رابطه (۲) تعریف می‌شود:

$$\begin{aligned} BD_\psi(x,y) &= x^T Wx - y^T Wy - \\ &< x - y, 2Wy > \\ &= (x - y)^T W(x - y) \end{aligned} \quad (۲)$$

که W معکوس ماتریس کوواریانس است. بنابراین باتوجه به رابطه (۲) به این نوع واگرایی برگمن فاصله ماهالانوبیس بین x و y گویند. درصورتی‌که W یک ماتریس همانی باشد، واگرایی برگمن به مربع فاصله اقلیدسی بین x و y تبدیل، که به‌صورت زیر نوشته می‌شود:

$$BD_\psi(x,y) = \| x - y \|^2 \quad (۳)$$

به‌طوری‌که $\| x \| = \sqrt{x^T x}$ 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، به‌صورت زیر تعریف می‌شود:

$$\begin{aligned} D_W(P_s \| P_t) = &\frac{1}{{n_s}^2} \sum_{s=1}^{n_s} \sum_{t=1}^{n_s} G_{\Sigma_{11}}(\overrightarrow{y_s} - \overrightarrow{y_t}) \\ &+ \frac{1}{{n_t}^2} \sum_{s={n_s}^2+1}^{n_s+n_t} \sum_{t=n_t+1}^{n_s+n_t} G_{\Sigma_{22}}(\overrightarrow{y_s} - \overrightarrow{y_t}) \\ &- \frac{1}{n_s n_t} \sum_{s=1}^{n_s} \sum_{t=n_t+1}^{n_s+n_t} G_{\Sigma_{12}}(\overrightarrow{y_s} - \overrightarrow{y_t}) \end{aligned} \quad (۴)$$

برای تخمین مقادیر $\mathbf{P_s}$ و $\mathbf{P_t}$ از روش برآورد تراکم هسته[2] استفاده شده است که تراکم را در $\mathbf{y} \in \mathbf{R^d}$ به‌عنوان مجموع کرنل‌های بین $\mathbf{y}$ و هر نمونه $\overrightarrow{\mathbf{y_i}}$ تخمین می‌زند؛ به‌عنوان مثال $p(\vec{y}) = (\frac{1}{n}) G_\Sigma(\vec{y} - \overrightarrow{y_i})$ که در آن $\mathbf{n}$ تعداد نمونه‌ها و $G_\Sigma(\vec{y})$ کرنل گوسی $\mathbf{d}$ بُعدی با ماتریس کوواریانس Σ است. که در این رابطه $\Sigma_{11} = \Sigma_1 + \Sigma_1$، $\Sigma_{22} = \Sigma_2 + \Sigma_2$ و $\Sigma_{12} = \Sigma_1 + \Sigma_2$ است.

DAIC 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 اطلاعاتی خاصی ندارند؛ لذا نیاز به روش‌هایی جهت بهینه‌سازی و کاهش ابعاد داده‌ها قبل از ورود به سامانه‌های طبقه‌بند احساس می‌شود. این مسأله در بسیاری از کاربردها (مانند طبقه‌بندی) اهمیت به‌سزایی دارد؛ زیرا در این کاربردها تعداد زیادی ویژگی وجود دارد، که بسیاری از آنها یا بلااستفاده هستند و یا اینکه بار اطلاعاتی چندانی ندارند. حذف‌نکردن این ویژگی‌ها مشکلی از لحاظ اطلاعاتی ایجاد نمی‌کند؛ ولی بار محاسباتی را برای کاربرد مورد نظر بالا می‌برد؛ و علاوه‌بر این باعث می‌شود که اطلاعات غیر مفید زیادی را به‌همراه 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 برداری را به فضایی با ابعاد کم‌تر نگاشت می‌کند؛ به‌طوری‌که داده‌های نگاشت‌شده دارای بیشترین پراکندگی بین‌رده‌ای و کم‌ترین پراکندگی درون‌رده‌ای هستند. درواقع FLDA به‌دنبال پیداکردن ماتریس نگاشت (W) است که نسبت دترمینان S_b (ماتریس پراکندگی بین‌رده‌ای) به S_w (ماتریس پراکندگی درون‌رده‌ای) بیشینه شود، دراصطلاح به این ماتریس، مقیاس فیشر می‌گویند که به‌صورت زیر تعریف می‌شود:

$$W = \underset{W}{\operatorname{argmax}} \frac{|W^T S_b W|}{|W^T S_w W|} \quad (۵)$$

دترمینان ماتریس کوواریانس 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. $\mathbf{S_b}$ ماتریس پراکندگی بین‌رده‌ای و $\mathbf{S_w}$ ماتریس پراکندگی درون‌رده‌ای داده‌های اصلی بوده و بدین‌صورت تعریف می‌شوند:

$$S_b = \sum_{i=1}^{C} n_i (\overrightarrow{m^{(i)}} - \overrightarrow{m})(\overrightarrow{m^{(i)}} - \overrightarrow{m})^T \quad (۶)$$

$$S_w = \sum_{i=1}^{C} \sum_{j=1}^{n_i} (x_j^{(i)} - \overrightarrow{m^{(i)}})(x_j^{(i)} - \overrightarrow{m^{(i)}})^T \quad (۷)$$

در اینجا $\overrightarrow{m}$ و $\overrightarrow{m^{(i)}}$ به‌ترتیب نشان‌دهنده میانگین کل داده‌ها و میانگین داده‌های رده iام هستند. روش جداکننده خطی به‌دنبال یافتن ماتریس $W \in \mathbb{R}^{D \times d}$ است که رابطه (۱) را بیشینه کند. در این‌صورت هر داده $\mathbf{x} \in \mathbb{R}^{\mathbf{D}}$ به‌صورت $y = W^T x$ به یک فضای کم‌بُعد d به‌صورت خطی منتقل می‌شود.

[1] Positive definite matrix
[2] Kernel density estimation (KDE)

[DOI: 10.29252/jsdp.16.3.148]

۴-۳- 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 بیشینه‌کردن تریس[1] به‌صورت (۵) به‌دفعات زیاد است:

$$\arg\max_{W^TW} \frac{\mathrm{tr}(W^T S_b W)}{\mathrm{tr}(W^T S_w W)} \qquad (۸)$$

روش متداول برای بیشینه‌کردن نسبت تریس یادشده با استفاده از بردارهای ویژه حاصل از مسأله مقادیر ویژه تعمیم یافته است؛ پس درواقع تابع هدف الگوریتم FLDA برابر است با

$$F(W) = \mathrm{tr}^{-1}(W^T S_b W)\mathrm{tr}(W^T S_w W) \qquad (۹)$$

که $\mathrm{tr}^{-1}(x)$ معکوس $\mathrm{tr}(x)$ 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 به‌دلیل اینکه اطلاعات اولیه را در مورد تفاوت بین توزیع نمونه‌های آموزشی و آزمایشی درنظر نمی‌گیرد، به‌تنهایی نمی‌تواند پاسخ‌گوی مسأله شیفت دامنه‌ها باشد؛ با این‌حال برای اجتناب و یا کاهش مشکل زیادآموزی، ما اطلاعات اولیه نمونه‌های آموزشی را با اضافه‌کردن یک بخش تنظیم[2] منطقی به رابطه (۹) درنظر می‌گیریم. بدین‌ترتیب، روش پیشنهادی DAIC یک زیرفضای مطلوب پیدا می‌کند که در آن اختلاف توزیع حاشیه‌ای کمینه‌شده و رده داده‌های آموزشی و آزمایشی به‌صورت مستقل از هم جدا می‌شوند. DAIC علاوه‌بر این‌که اطلاعات تفکیک‌کنندهٔ موجود در نمونه‌های آموزشی را درنظر می‌گیرد، توزیع بایاس بین نمونه‌های آموزشی و آزمایشی را نیز بررسی می‌کند. ازاین‌رو واگرایی برگمن و تابع هدف الگوریتم FLDA را ترکیب می‌کنیم؛ پس با توجه به رابطه‌های (۴) و (۸) خواهیم داشت:

$$W = \underset{W\in R^{D\times d}}{\mathrm{argmin}}\, F(W) + \lambda D_W(P_s \,\|\, P_t) \qquad (۱۰)$$

$F(W)$ تابع هدف الگوریتم در زیرفضای نگاشت‌شده، $D_W(P_s \,\|\, P_t)$ واگرایی برگمن که فاصله بین P_s و P_t را در فضای نگاشت‌شده W محاسبه می‌کند و λ پارامتر تنظیم است که بین $F(W)$ و $D_W(P_s \,\|\, P_t)$، تنظیم ایجاد می‌کند.

[1] Trace
[2] Regularization

۵-۳- وزن‌دهی به نمونه‌های دامنه منبع

با این حال، تطبیق توزیع ویژگی‌های داده براساس کمینه‌سازی واگرایی برگمن در معادله (۱۰) به‌تنهایی برای مسائل شیفت دامنه‌ها مناسب نیست و به‌طور 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 نگاشت‌شده نیز همواره نمونه‌هایی از دامنه منبع وجود دارند که با نمونه‌های دامنه هدف مرتبط نیستند و این باعث کاهش تطبیق‌پذیری مدل می‌شود. شکل (۲) به‌خوبی این مشکل را نشان می‌دهد. در این شرایط، تطبیق ویژگی و وزن‌دهی مجدد نمونه‌ها به‌طور مشترک برای ایجاد سازگاری و تطبیق دامنه بسیار مهم و اجتناب ناپذیر است.

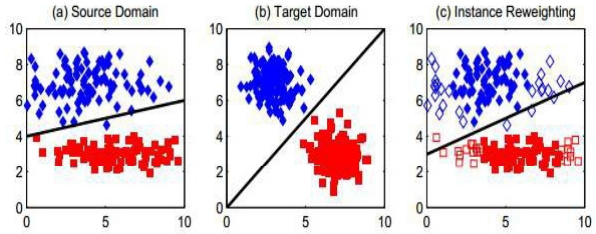

(شکل-۲): (a) دامنه منبع پس از تطابق ویژگی؛ (b) دامنه هدف پس از تطابق ویژگی با توجه به نمونه‌های منبع نامرتبط (نشان داده شده در c، اختلاف دامنه پس از تطابق ویژگی‌ها هنوز بزرگ است. (c) دامنه منبع پس از تطبیق ویژگی و وزن‌دهی مجدد به نمونه‌ها. در حال حاضر نمونه‌های نامناسب دامنه منبع دارای وزن کم‌تری هستند تا اختلاف دامنه کاهش یابد (b نسبت به 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 وزن‌دهی مجدد، نمونه‌هایی از دامنه منبع را در زیرفضای مشترک انتخاب می‌کنیم که تطبیق‌پذیری مدل را افزایش دهد. درواقع با استفاده از دو ماتریس انتخاب A_s (ماتریس تبدیل متناظر با نمونه‌های دامنه منبع) و A_t (ماتریس تبدیل متناظر با نمونه‌های دامنه هدف) و به‌کارگیری نرم $\ell_{2,1}$ و نرم فروبنیوس[3] $\|.\|_F^2$ نمونه‌هایی از دامنه منبع که مرتبط و نزدیک

[3] Frobenius norm

[DOI: 10.29252/jsdp.16.3.148]

به دامنه هدف هستند انتخاب می‌شوند. درواقع نرم $\ell_{2,1}$ می‌تواند تنظیم‌کنندهٔ تُنکی[1] 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[2] می‌تواند وزن‌دهی نمونه‌ها را تسهیل کند. رابطه زیر ماتریس انتخاب A را به‌دست می‌آورد که اختلاف توزیع بین داده‌های دامنه منبع و هدف را در زیرفضای نگاشت شده کمینه می‌سازد.

$$\| A_s \|_{2,1} + \| A_t \|_F^2 \qquad (۱۱)$$

با استفاده از نُرم $\boldsymbol{\ell_{2,1}}$ می‌توان هر نمونه هدف را با حداقل تعداد نمونه منبع نمایش داد. نُرم $\boldsymbol{\ell_{2,1}}$ را فقط روی نمونه‌های دامنه منبع اعمال می‌کنیم؛ زیرا هدف ما اضافه‌کردن وزن نمونه‌هایی از دامنه منبع است که شباهت و ارتباط بیشتری با نمونه‌های دامنه هدف دارند. با به کمینه‌رساندن رابطه (۱۱) رابطه (۱۰) نیز کمینه شده و دراین‌صورت در نمایش جدید نمونه‌هایی از دامنه منبع که مرتبط با نمونه‌های دامنه هدف هستند اهمیت بیشتری 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 مبتنی‌بر نمونه و مبتنی‌بر خصوصیت است که برای مسائلی که دارای اختلاف توزیع زیادی هستند، پیشنهاد شده است. در این روش، ابتدا یک نمایش کم‌بُعد از دامنه‌های منبع و هدف ایجاد می‌شود که در این نمایش جدید با بهره‌گیری از واگرایی برگمن اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف کاهش می‌یابد؛ سپس به‌طور 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 می‌بینند؛ دراین‌صورت تطبیق‌پذیری داده‌ها با یکدیگر افزایش می‌یابد و مدل مقاوم‌تری در مقابل اختلاف توزیع بین دامنه‌های منبع و هدف ایجاد می‌شود. بدین‌ترتیب با ترکیب رابطه‌های (۱۰) و (۱۱) به معادله (۱۲) می‌رسیم که تابع هدف نهایی DAIC است:

$$\begin{aligned} W = \operatorname{argmin} & \operatorname{tr}^{-1}(W^T S_b W)\operatorname{tr}(W^T S_w W) \\ & +\lambda D_W(P_s \| P_t) \\ & +\tau(\| A_s \|_{2,1} + \| A_t \|_F^2) \end{aligned} \qquad (۱۲)$$

τ پارامتر تنظیم بین تطابق ویژگی و وزن‌دهی به نمونه‌ها است، علاوه‌براین شرط $W^T W = I$ نیز باید برآورده شود. این شرط نشان‌دهندهٔ 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. برای به‌دست‌آوردن زیرفضای خطی بهینه W با توجه به رابطه (۱۲) می‌توان از الگوریتم گرادیان نزولی[3] استفاده کرد:

$$\begin{aligned} W_{k+1} = W_k - \eta(k)\Big(&\frac{\partial F(W)}{\partial W} \\ &+\lambda \sum_{i=1}^{n_s+n_t} \frac{\partial D_W(P_s \| P_t)}{\partial \overrightarrow{y_i}} \frac{\partial \overrightarrow{y_i}}{\partial W}\Big) \end{aligned} \qquad (۱۳)$$

∂_W گرادیان نسبت به W و η نرخ یادگیری در k امین تکرار است، بدین‌ترتیب با درنظرگرفتن رابطه (۸) مشتق $F(W)$ برحسب W برابر است با:

$$\begin{aligned} \frac{\partial F(W)}{\partial W} &= 2\operatorname{tr}^{-1}(W^T S_b W) S_w W \\ &-2\operatorname{tr}^{-2}(W^T S_b W)\operatorname{tr}(W^T S_w W) S_b W \end{aligned} \qquad (۱۴)$$

با توجه به رابطه (۴) مشتق $D_W(P_s \| P_t)$ را نسبت به W می‌توان به‌صورت زیر نوشت:

$$\begin{aligned} \sum_{i=1}^{n_s+n_t} \frac{\partial D_W(P_s \| P_t)}{\partial \overrightarrow{y_i}} \frac{\partial \overrightarrow{y_i}}{\partial W} &= \sum_{i=1}^{n_s} \frac{D_W(P_s \| P_t)}{\partial \overrightarrow{y_i}} \vec{x}_i^T \\ &+ \sum_{i=n_s+1}^{n_s+n_t} \frac{D_W(P_s \| P_t)}{\partial \overrightarrow{y_i}} \vec{x}_i^T \end{aligned} \qquad (۱۵)$$

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

[1] Sparsity regularizer
[2] Row-sparsity
[3] Gradient descent

[DOI: 10.29252/jsdp.16.3.148]

۷-۳- 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. درحالی‌که 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 به‌طورکلی پیچیدگی زمانی DAIC برابر با $O((D+N)^2)$ است. اگر m، d و C به ترتیب اندازه ابعاد فضای اصلی، اندازه ابعاد فضای جدید و تعداد رده‌ها باشند، روش NN (با درنظرگرفتن 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 TJM، دارای یک کرنل به‌نسبه پیچیده و حل تابع هدف آن دشوار و زمان‌بر است.

۴- آزمایش‌ها

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

۴-۱- معرفی مجموعه‌داده‌ها

مجموعه‌داده آفیس و کالت[1] [13]، اعداد[2] [14,15] و پای[3] [16]، یازده مجموعه‌داده استاندارد هستند که به‌طور گسترده برای ارزیابی الگوریتم‌های دامنه بصری مورد استفاده قرار می‌گیرند.

مجموعه‌داده اعداد شامل دو دامنه USPS و MNIST است. دامنه USPS حاوی اعداد دست‌نویس پویش‌شده نامه‌های اداره پست آمریکا است که شامل ۷۲۹۱ تصویر آموزشی و ۲۰۰۷ تصویر آزمایشی با اندازه ۱۶×۱۶پیکسل است. مجموعه‌داده MNIST حاوی اعداد دست‌نویس پویش‌شده دانش‌آموزان دبیرستانی آمریکا است که شامل شصت‌هزار نمونه آموزشی و ده‌هزار نمونه آزمایشی با اندازه ۲۸×۲۸ پیکسل است. این پایگاه داده شامل ده رده مختلف است و به‌منظور آزمایش هر دو دامنه در شرایط یکسان، دامنه USPS_vs_MNIST(U-M) ایجاد شده است که به‌طور تصادفی ۱۸۰۰ نمونه از داده‌های دامنه USPS به‌عنوان داده‌های آموزشی و دوهزار نمونه از داده‌های دامنه MNIST به‌عنوان داده‌های آزمایش به کارگرفته می‌شود. با جابه‌جایی 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 (A))، Webcam (تصاویر اشیا با وضوح پایین که توسط دوربین وب گرفته شده‌اند (W))، DSLR (تصاویر اشیا با وضوح بالا که با استفاده از دوربین‌های دیجیتالی گرفته شده‌اند (D)) و کالتک (C) یک مجموعه‌داده استاندارد برای تشخیص اشیا است که شامل ۳۰۶۰۷ تصویر و ۲۵۶ رده از تصاویر است. در دامنه‌های مجموعه‌داده آفیس و کالتک ۱۲=۳×۴ آزمایش طراحی شده که از ده رده مشترک بین مجموعه‌داده آفیس و مجموعه‌داده کالتک استفاد شده است. در هریک از آزمایش‌های طراحی‌شده یکی از مجموعه‌داده‌ها به‌عنوان دامنه منبع و یکی دیگر از مجموعه‌داده‌ها به‌عنوان دامنه هدف انتخاب می‌شوند؛ به‌عنوان 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 حالت روبه‌رو (P4) و PIE5 حالت راست (P5). در این مجموعه‌داده، آزمایش بر روی ۲۰=۴×۵ مجموعه بین‌دامنه‌ای مختلف طراحی شده است که از بین این پنج دامنه، دو دامنهٔ مختلف به‌عنوان دامنه‌های منبع و هدف انتخاب می‌شوند؛ به‌عنوان مثال (P1→ P2, P1→ P3, … , P5→ P4).

۴-۲- ارزیابی الگوریتم‌ها

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

[1] Office+Caltech-256
[2] USPS+MNIST
[3] PIE

[DOI: 10.29252/jsdp.16.3.148]

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

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

(جدول-۱): توضیحات پایگاه‌داده‌ها

(Table-1): Description of Databases

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

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 تطبیق خصوصیات و وزن‌دهی به نمونه‌ها است. مقدار بهینه پارامترها در روش DAIC، برای پایگاه داده‌های بصری برای تمامی آزمایش‌ها انجام‌گرفته 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 حوزهٔ تطبیق دامنه توسط طراحی آزمایش‌های بدون‌نظارت مورد ارزیابی و مقایسه قرارگرفته است.

۵-۱- ارزیابی نتایج

دراین بخش، عملکرد روش پیشنهادی را با هفت الگوریتم یادگیری ماشین و یادگیری انتقالی بدون‌نظارت مقایسه می‌کنیم. گفتنی است که $FLDA^m$ نشان‌دهنده کاهش اختلاف حاشیه‌ای بین‌دامنه‌های منبع و هدف با استفاده از الگوریتم کاهش بعد FLDA و واگرایی برگمن بدون وزن‌دهی نمونه‌ها است.

تشخیص شئ: 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 کالتک ٪۵۲/۲۱ است. علاوه‌براین، بهبود عملکرد DAIC، ٪۱۶/۰۵ بیش از طبقه‌بند NN است، این ثابت می‌کند که DAIC برای طبقه‌بندی تصاویر در دامنه‌های متفاوت می‌تواند مؤثر باشد؛ همچنین متوسط بهبود دقت روش DAIC نسبت به روش FLDA در مجموعه‌داده آفیس و کالتک ٪۱۰/۸۳ است. DAIC بهبود خوبی (٪۱/۱۸) نسبت به متوسط دقت بهترین الگوریتم مورد مقایسه (یعنی 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 (یعنی 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، FLDA و CDDA به‌ترتیب برابر (٪۲۰/۴۳)، (٪۱۷/۴۴) و (٪۶/۶۲) است. در ادامه روش DAIC به‌تفکیک با تمام روش‌ها مقایسه شده است.

1-NN طبقه‌بند نزدیک‌ترین همسایگی: این الگوریتم برروی 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.

[DOI: 10.29252/jsdp.16.3.148]

FLDA یک روش انتقال داده‌ها به یک فضای کم‌بُعد است که ایده اصلی آن حفظ ساختار رده‌ها برای طبقه‌بندی است. از آنجا که FLDA اختلاف توزیع بین دامنه‌ها را درنظر 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 تطبیق‌دامنه بدون‌نظارت است که اختلاف توزیع حاشیه‌ای دامنه منبع و هدف را براساس تخمین تراکم هسته کاهش می‌دهد. TSL به اندازهٔ مجموعه‌داده‌ها حساس است درصورتی‌که دامنه هدف حاوی داده‌های کم باشد، تخمین تراکم هسته نمی‌تواند توصیف دقیقی از داده‌ها داشته باشد؛ علاوه‌براین برای داده‌هایی در مقیاس بالا (مانند مجموعه‌داده PIE) TSL دچار مشکل هم‌گرایی می‌شود. DAIC بر روی هردو مجموعه‌داده کوچک و بزرگ به‌خوبی 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 به‌تفکیک 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 کم‌بُعد را ایجاد می‌کند که اختلاف توزیع بین دامنه‌ها را کاهش می‌دهد. FIDOS مشابه DAIC یک رویکرد مبتنی‌بر FLDA است، اما فقط برای مجموعه‌داده‌های مرتبط عملکرد خوبی دارد؛ درواقع برای مسائل چند دامنه‌ای به‌دلیل استخراج ویژگی‌های بیشتر، بهتر عمل می‌کند. این درحالی است DAIC برای مسائلی که دارای اختلاف توزیع زیادی هستند، پیشنهاد شده است. روش DAIC به‌تفکیک نسبت به روش FIDOS دارای متوسط بهبود دقت (۱۲/۳۷٪) در پایگاه‌داده آفیس و کالتک، و (۴۴/۰۶٪) در پایگاه‌داده پای است.

DAM، یک روش تطبیق دامنه بدون‌نظارت است که به‌طور مستقیم یک طبقه‌بند سازگار با دامنه هدف را به‌دست می‌آورد. DAM از طبقه‌بندهای پیش‌آموخته با استفاده از نمونه‌های برچسب‌دار دامنه منبع، استفاده می‌کند. علاوه‌براین DAM براساس فرضیه مسطح‌سازی یک شرایط تنظیمی را به‌وجود می‌آورد که طبقه‌بند دامنه هدف مجبور به تصمیم‌گیری مشابه با طبقه‌بند پیش‌آموخته می‌شود. روش DAIC به تفکیک نسبت به روش DAM دارای متوسط بهبود دقت (۹/۶۶٪) در پایگاه‌داده آفیس و کالتک، (۲۷/۹۹٪) در پایگاه‌داده اعداد و (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 مسأله بهینه‌سازی پیچیده، اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف را کمینه می‌سازد. همچنین TJM به‌دلیل استفاده از الگوریتم PCA و نادیده‌گرفتن بخشی از دادهٔ ورودی ساختار اصلی داده‌ها را حفظ نمی‌کند و زیرفضای جدید را با بخشی از نمونه‌های دامنه منبع ایجاد می‌کند، درحالی‌که روش DAIC با استفاده از واگرایی برگمن ساختار داده‌های ورودی را حفظ می‌کند. روش DAIC به‌تفکیک نسبت به روش TJM دارای متوسط بهبود دقت (۷/۸٪) در پایگاه‌داده آفیس و کالتک، (۱۷/۹۹٪) در پایگاه‌داده اعداد و (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 به‌طور خطی توسط داده‌های دامنه منبع بازسازی شود. به این‌ترتیب، اختلاف دامنه‌های منبع و هدف کاهش می‌یابد و با اعمال توأم 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 حداکثری اطلاعات تفکیک‌کننده نمونه‌های دامنه منبع برای تفکیک‌پذیری بهتر رده‌های مختلف است. روش DAIC به‌تفکیک نسبت به روش LRSR دارای متوسط بهبود دقت (۶/۸۲٪) 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 انتقالی بدون‌نظارت است که با ایجاد یک نمایش کم‌بُعد از دامنه‌های منبع و هدف، به‌طور هم‌زمان اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌ها را کاهش می‌دهند. به‌دلیل خصوصیات متفاوت داده‌های آموزشی و آزمون در دامنه‌های منبع و هدف، طبقه‌بند ایجادشده در نمایش جدید توسط روش CDDA نمی‌تواند با صحت بالایی برچسب داده‌های دامنه هدف را پیش‌بینی کند. دلیل برتری DAIC نسبت به CDDA این است که DAIC علاوه‌بر اینکه ساختار داده‌ها را حفظ می‌کند، اطلاعات تفکیک‌کننده اولیه داده‌های ورودی را نیز درنظر می‌گیرد که این باعث کاهش اختلاف

[DOI: 10.29252/jsdp.16.3.148]

توزیع حاشیه‌ای و شرطی بین دامنه‌ها می‌شود. روش DAIC به تفکیک نسبت به روش CDDA دارای متوسط بهبود دقت (۴/۹۹٪) در پایگاه‌داده آفیس و کالتک، (۶/۶۲٪) در پایگاه‌داده اعداد، و (۱۶/۹۱٪) در پایگاه‌داده پای است.

روش VDA علاوه‌بر تطبیق توزیع‌های حاشیه‌ای و شرطی شرطی از یک خوشه‌بندی مستقل از دامنه برای بهبود صحت طبقه‌بند استفاده می‌کند؛ با این حال، به‌دلیل 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 بدون‌نظارت چند منبعی است که به بررسی نحوه بهره‌گیری مؤثر و هم‌زمان از اطلاعات رده‌ها و دامنه‌ها می‌پردازد. روش DAIC به‌تفکیک نسبت به روش CLGA دارای متوسط بهبود دقت (۱۳/۹۸٪) در پایگاه‌داده آفیس و کالتک و (۷/۸۶٪) در پایگاه‌داده پای است.

۵-۲- ارزیابی پارامترها

برای به‌دست‌آوردن 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 ($\eta(k)$ در رابطه (۱۳)). اگر مقدار پایینی برای $\eta(k)$ انتخاب شود، سرعت هم‌گرایی بسیار کاهش می‌یابد، درحالی‌که اگر $\eta(k)$ مقدار بالایی داشته باشد، فرآیند هم‌گرایی دچار جهش شده و از محدوده مورد انتظار فراتر می‌رود و الگوریتم در تعداد تکرار معقول همگرا نمی‌شود. در این چارچوب پیشنهادی به‌طور تجربی $\eta(k) = \eta(0)/k$ در نظر گرفته شده که نرخ یادگیری با افزایش تعداد تکرار کاهش یابد. جهت محاسبه مقدار بهینه W از بیست تکرار برای به‌دست‌آوردن 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 [۱۰، ۰/۰۰۰۰۱] بررسی می‌شود، مقدار بهینه پارامتر λ برای تمامی پایگاه‌داده‌ها برابر ۰/۱ است. علاوه‌براین پارامتر τ در محدوده [۱۰۰ ۰/۰۱] در نظر گرفته می‌شود. τ یکی از پارامترهای تاثیرگذار درDAIC است، درواقع ضرایب ماتریس A را کنترل و تعداد نمونه‌های منبع مرتبط را تعیین می‌کند. تعداد نمونه‌های انتخاب‌شده با توجه به τ در جدول (۵) گزارش شده است.

به‌عنوان مثال هنگامی‌که τ=۱۰۰ است در مجموعه‌داده اعداد هیچ نمونه‌ای از دامنه منبع انتخاب نمی‌شود؛ اما زمانی‌که 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 تنکی τ 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 به‌دست‌آمده از نمونه‌های دامنه منبع را، با به‌کمینه‌رساندن اختلاف توزیع حاشیه‌ای بین دامنه‌ها به نمونه‌های دامنه هدف منتقل کند که باعث تفکیک‌پذیری بهتر رده‌های مختلف در فضای جدید می‌شود. درصورتی‌که در تابع هدف (رابطه ۱۲) پارامتر λ را برابر صفر درنظر بگیریم (طبق نتایج گزارش‌شده در جداول (۲ الی ۴)، فیلد FLDA) دقت مدل به‌دلیل وجود اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف به‌شدت کاهش می‌یابد. در شرایطی‌که دامنه‌های منبع و هدف دارای مجموعه خصوصیات یکسان باشند، اختلاف در احتمال وقوع مقادیر هرکدام از این خصوصیات در هر دامنه، موجب ایجاد اختلاف توزیع حاشیه‌ای بین دامنه‌ها خواهد شد.

روش‌های کاهش بُعد به‌تنهایی پاسخ‌گوی مسائل شیفت دامنه‌ها نیستند و به‌دلیل نادیده‌گرفتن اطلاعات اولیه در مورد اختلاف توزیع بین نمونه‌های دامنه منبع و هدف، مدل روی نمونه‌های دامنه منبع دچار زیادآموزی شده و عملکرد مدل به‌شدت کاهش می‌یابد. برای اجتناب از مشکل زیادآموزی و بهبود عملکرد مدل یادگیری، ما اطلاعات اولیه را

[DOI: 10.29252/jsdp.16.3.148]

با استفاده از واگرایی برگمن درنظر می‌گیریم. به‌همین ترتیب براساس نتایج نشان داده‌شده در شکل (۷) نمودار FLDA به‌دلیل عدم بهره‌گیری از اطلاعات تفکیک‌کننده اولیه داده‌های دامنه منبع و نادیده‌گرفتن اختلاف توزیع حاشیه‌ای بین دامنه‌ها، دقت پایینی در تمام پایگاه‌داده‌های مورد آزمایش دارد.

(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**

[DOI: 10.29252/jsdp.16.3.148]

(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

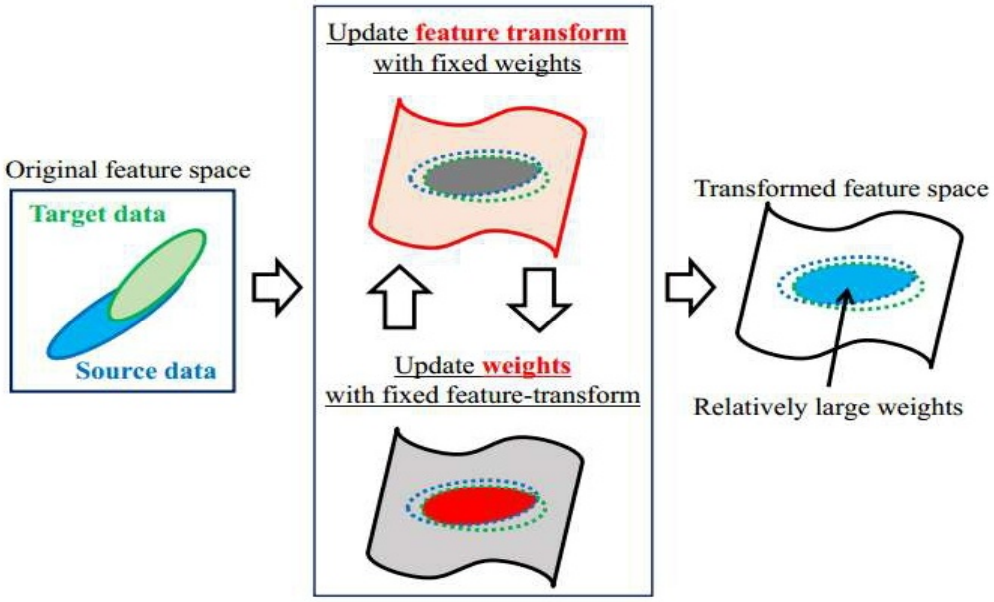

(شکل-۳): روش پیشنهادی DAIC داده‌های منبع و هدف را که در فضای اصلی دارای توزیع متفاوت هستند با استفاده از ماتریس تبدیل FLDA و واگرایی برگمن به یک زیرفضای جدید نگاشت می‌کند تا اختلاف توزیع آن‌ها را کاهش دهد، هم‌زمان با این کار با استفاده از یک ماتریس وزن تأثیر نمونه‌های نامرتبط دامنه منبع را کم می‌کند. از آنجایی‌که پیداکردن هم‌زمان ماتریس تبدیل و ماتریس وزن کار دشواری است DAIC ابتدا در مرحله نخست ماتریس وزن را ثابت در نظر می‌گیرد و ماتریس تبدیل بهینه را به‌دست می‌آورد و در مرحله دوم ماتریس تبدیل به‌دست‌آمده را ثابت در نظر می‌گیرد و ماتریس وزن بهینه را به‌دست 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 interative approach in which the optimization of feature transform and that of instance weight are conducted alternately.

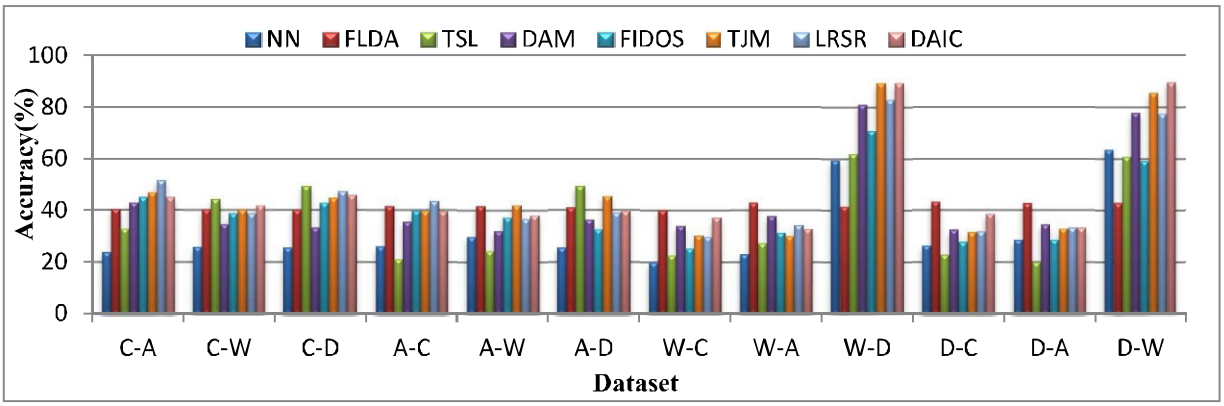

(شکل-۴): صحت طبقه‌بندی در مجموعه‌داده‌های آفیس و کالتک با استفاده از روش‌های مختلف NN، FLDA، TSL، DAM، FIDOS، TJM، LRSR و DAIC

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

[DOI: 10.29252/jsdp.16.3.148]

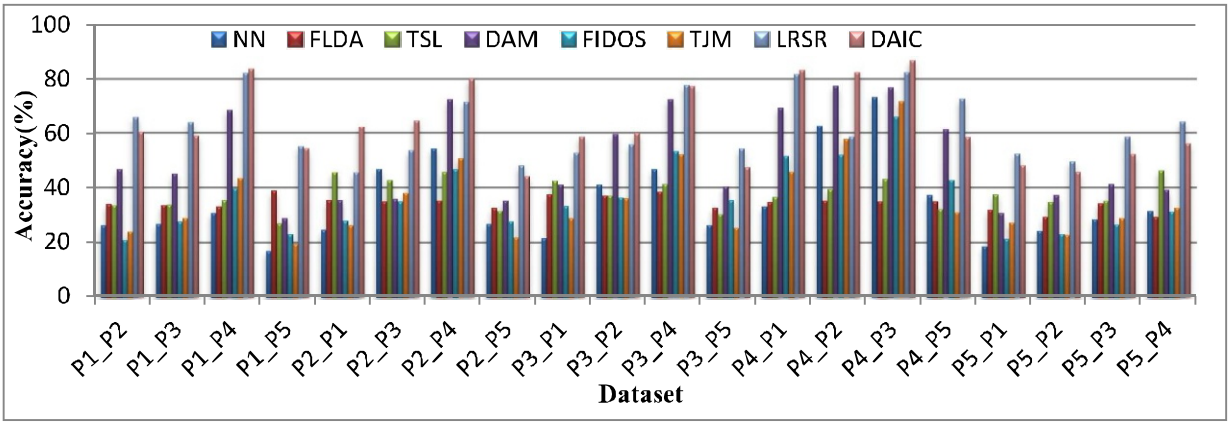

(شکل-۵): صحت طبقه‌بندی در مجموعه‌داده‌های پای با استفاده از روش‌های مختلف NN، FLDA، TSL، DAM، FIDOS، TJM، LRSR و DAIC

(Figure-5): Classification accuracy (%) on PIE datasets using different methods NN, FLDA, TSL, DAM, FIDOS, TJM, LRSR and DAIC.

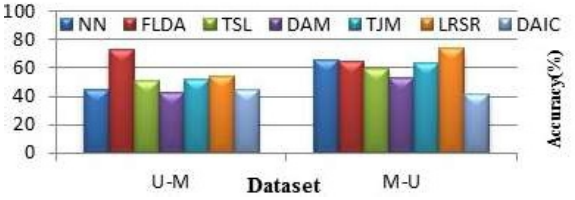

(شکل-۶): صحت طبقه‌بندی در مجموعه‌داده‌های اعداد با استفاده از روش‌های مختلف NN، FLDA، TSL، DAM، FIDOS، TJM، LRSR و DAIC

(Figure-6): Classification accuracy (%) on Digit datasets using different methods NN, FLDA, TSL, DAM, TJM, LRSR and DAIC.

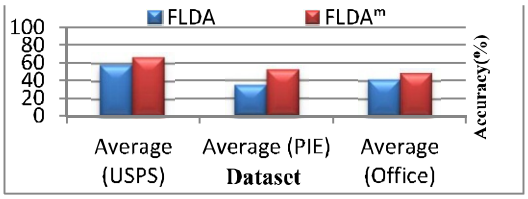

(شکل-۷): مقایسه دقت (٪) مدل پیشنهادی با توجه به کاهش اختلاف توزیع حاشیه‌ای و روش FLDA

(Figure-7): Comparison of the accuracy (%) of the proposed model with regard to the reduction of the marginal distribution gap and the FLDA method

۴-۵- بررسی ضرورت وزن‌دهی مجدد به نمونه‌ها

در شرایطی‌که اختلاف توزیع دامنه‌های منبع و هدف زیاد باشد، فقط با کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف، نمی‌توان باعث ایجاد تطبیق‌پذیری طبقه‌بند ایجادشده بر روی دامنه منبع با دامنه هدف شد (جداول ۲ الی ۴ فیلد $FLDA^m$). در چنین شرایطی، حتی با ایجاد تفکیک‌پذیری بین رده‌ها، به‌علت 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 (۸) نمودار DAIC در مقایسه با $FLDA^m$ به‌دلیل بهره‌گیری همزمان از تطبیق خصوصیات و روش وزن‌دهی به نمونه‌ها از دقت بالاتری برخودار است.

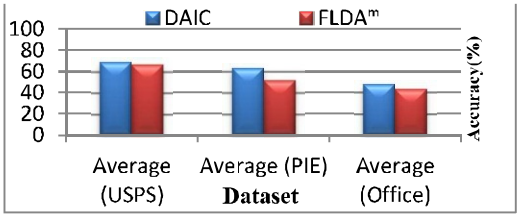

(شکل-۸): مقایسه دقت (٪) مدل پیشنهادی با توجه به کاهش اختلاف توزیع حاشیه‌ای و وزن‌دهی به نمونه‌ها

(Figure-8): Comparison of the accuracy (%) of the proposed model with respect to the reduction of marginal distribution and sample reweighting

۶- نتیجه‌گیری و کارهای آینده

پردازش تصویر به‌عنوان 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 به‌دنبال یافتن الگوریتم‌هایی برای طبقه‌بندی تصاویر با دقت بالا است. در این مقاله، روش تطبیق دامنه بدون‌نظارت 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. درواقع 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 به‌طور همزمان، به نمونه‌هایی از دامنه منبع که دارای کم‌ترین مشابهت از نظر توزیع با نمونه‌های دامنه هدف

[DOI: 10.29252/jsdp.16.3.148]

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 مجموعه‌داده بصری مورد آزمایش قرار گرفته که این مجموعه‌داده‌ها، دارای اختلاف توزیع قابل توجهی نسبت به یکدیگر هستند. نتایج به‌دست‌آمده، نشان‌دهندهٔ 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 علاوه‌براین در تلاش جهت توسعه روش DAIC برای سامانه‌های چندمنبعی هستیم. در این راستا، به‌دنبال 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 7- References

[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. Pereira, 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 framework 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", KnowlInf 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 Piqueras-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.

[DOI: 10.29252/jsdp.16.3.148]

[DOI: 10.29252/jsdp.16.3.148]

[20] Y. Xu, X. Fang, J. Wu, X. Li, and D. Zhang, "Discriminative transfer subspace learning via low-rank and sparse representation," *IEEE Transactions on Image Processing*, vol. 25, no. 2, pp. 850–863, 2016.

[21] J. Tahmoresnezhad and S. Hashemi, "Visual domain adaptation via transfer285 feature learning," *Knowledge and Information Systems*, vol. 50, no. 2, pp. 585– 605, 2017.

[22] J. Liu, J. Li, and K. Lu, "Coupled local–global adaptation for multi-source transfer learning," *Neurocomputing*, vol. 275, pp. 247–254, 2018.

[23] L. Luo, X. Wang, S. Hu, C. Wang, Y. Tang, and L. Chen, "Close yet distinctive domain adaptation," arXiv preprint arXiv: 1704.04235, 2017.

[24] W. Dai, Q. Yang, G.-R. Xue, and Y. Yu, "Boosting for transfer learning," in *Proceedings of the 24th international conference on Machine learning*, 2007, pp. 193–200.

[25] Y. Tsuboi, H. Kashima, S. Hido, S. Bickel, and M. Sugiyama, "Direct density ratio estimation for large-scale covariate shift adaptation." *Information and Media Technologies*, vol. 4, no. 2, pp. 529–546, 2009.

[26] J. Quionero-Candela, M. Sugiyama, A. Schwaighofer, and N. D. Lawrence, "Dataset Shift in Machine Learning", The MIT Press, 2009.

[27] S. J. Pan, X. Ni, J.-T. Sun, Q. Yang, and Z. Chen, "Cross-domain sentiment classification via spectral feature alignment," in *Proceedings of the 19th international conference on World Wide Web. ACM*, pp. 751–760, 2010.

[28] 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.

[29] X. Shi, Q. Liu, W. Fan, and P. S. Yu, "Transfer across completely different feature spaces via spectral embedding," *IEEE Transactions on Knowledge and Data Engineering*, vol. 25, no. 4, pp. 906–918, 2013.

[30] R. Aljundi, R. Emonet, D. Muselet, and M. Sebban, "Landmarks-based kernelized subspace alignment for unsupervised domain adaptation," in *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, pp. 56–63, 2015.

[31] M. Gheisari and M. S. Baghshah, "Joint predictive model and representation learning for visual domain adaptation," *Engineering Applications of Artificial Intelligence*, vol. 58, pp. 157–170, 2017.

[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 uni- 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، بهبود مدل تفکیک‌کننده منیفلدهای غیرخطی به منظور بازشناسی چهره یا یک تصویر از هر فرد. پردازش علائم و داده‌ها.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، ادیبی پیمان. مدل ترکیبی تحلیل مؤلفه اصلی احتمالاتی بانظارت در چارچوب کاهش بعد بدون اتلاف برای شناسایی چهره. پردازش علائم و داده‌ها.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 کامپیوتر-هوش مصنوعی خود را در سال ۱۳۹۴ از دانشگاه شیراز دریافت کردند. ایشان در راستای فعالیت‌های علمی خود، در حال حاضر به‌عنوان استادیار دانشگاه صنعتی ارومیه در حال فعالیت و علایق پژوهشی

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

مژده زندی‌فر دانشجوی کارشناسی ارشد مهندسی فناوری اطلاعات، مدرک کارشناسی خود را در رشته مهندسی کامپیوتر-نرم‌افزار در سال ۹۴ دریافت کردند.
نشانی رایانامه ایشان عبارت است از:
mozhdeh.zandifar @it.uut.ac.ir

[DOI: 10.29252/jsdp.16.3.148]