

## Kernelized Domain Adaptation and Balanced Distribution Alignment for Image Classification

Shiva Noori Saray<sup>1</sup>, Jafar Tahmoresnezhad<sup>2\*</sup>

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

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

<sup>1</sup> shivanoorisaray@it.uut.ac.ir, <sup>2\*</sup> j.tahmores@it.uut.ac.ir

Corresponding author's address: Jafar Tahmoresnezhad, Faculty of IT and Computer Engineering, Urmia University of Technology, Urmia, Iran.

**Abstract-** Transfer learning and domain adaptation are effective solutions for performance improvement of image classifiers where the source domain (training set) and target domain (test set) have substantial probability distribution differences. In fact, collecting input data in various conditions (such as lighting or temperature), different equipment with variable characteristics (such as number of input ports or resolution quality) and different views (such as dimensions or environment) results domain shift problem. Semi-supervised domain adaptation is a leading solution for domain shift problem, where the source domain and a small part of target domain are labeled. In this paper, we propose Kernelized Domain Adaptation and balanced distribution alignment (KEDA) to adapt the source and target domains in a semi-supervised manner. KEDA preserves the topology of domains via creating a Laplacian matrix and similarity and dissimilarity views. Moreover, KEDA adapts the regularized conditional and marginal distributions across domains. Ultimately, the sum of these solutions leads to a good classification function for labeling the unlabeled images. The proposed method is compared with the state-of-the-art methods of domain adaptation on Office-Caltech-10, Digits, Pie, and Coil datasets where results show considerable performance improvement of our proposed method.

**Keywords-** Image classification, Domain adaptation, Manifold matching, Balanced distribution adaptation, Transfer learning.

## انطباق دامنه کرنلی و تطبیق توزیع متعادل برای طبقه‌بندی تصاویر

شیوا نوری سرای<sup>۱</sup>، جعفر طهمورث نژاد<sup>۲\*</sup>

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

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

<sup>۱</sup> shivanoorisaray@it.uut.ac.ir, <sup>۲\*</sup> j.tahmores@it.uut.ac.ir

\* نشانی نویسنده مسئول: جعفر طهمورث نژاد، ارومیه، دانشگاه صنعتی ارومیه، دانشکده مهندسی فناوری اطلاعات و کامپیوتر.

چکیده- یادگیری انتقالی و انطباق دامنه از جمله راه حل‌های موثر در بهبود عملکرد طبقه‌بندی تصاویر هستند که در آن دامنه منبع (مجموعه آموزشی) و دامنه هدف (مجموعه آزمایشی) از اختلاف توزیع احتمال قابل توجهی برخوردارند. در واقع، نظر به اینکه جمع‌آوری داده‌های ورودی در شرایط مختلف (مانند وضعیت نور یا درجه حرارت)، تجهیزات مختلف با ویژگی‌های متغیر (مانند تعداد پورت‌های ورودی یا کیفیت رزولوشن) و دیدگاه‌های مختلف (مانند ابعاد و محیط) انجام می‌شود، منجر به مسئله‌ی تغییر دامنه می‌شود. انطباق دامنه نیمه نظارت شده، راه حلی پیشنهادی برای مسئله‌ی تغییر دامنه است که در آن، دامنه منبع و بخش کوچکی از دامنه هدف دارای برچسب هستند. در این مقاله انطباق دامنه کرنلی و تطبیق توزیع متعادل (KEDA) را برای انطباق دامنه‌های منبع و هدف، به صورت نیمه نظارتی پیشنهاد می‌کنیم. KEDA توپولوژی دامنه‌ها را از طریق ایجاد ماتریس لاپلاسی و از نقطه نظرهای شباهت و تفاوت حفظ می‌کند. علاوه بر این، KEDA توزیع شرطی و حاشیه‌ای بین دامنه‌ها را تطبیق می‌دهد. در نهایت، مجموع این راه حل‌ها، تابع طبقه‌بندی خوبی برای برچسب زدن تصاویر بدون برچسب نتیجه می‌دهد. روش پیشنهادی با روش‌های پیشرفته انطباق دامنه بر روی دیتاست‌های آفیس-کلتک-۱۰<sup>۱</sup>، اعداد<sup>۲</sup>، پای<sup>۳</sup> و کویل<sup>۴</sup> مقایسه شده است که نتایج، بهبود عملکرد قابل توجه روش پیشنهادی را نشان می‌دهد.

واژه‌های کلیدی: کلاسه‌بندی تصاویر، انطباق دامنه، تطبیق هندسی، انطباق توزیع متعادل، یادگیری انتقالی.

### ۱- مقدمه

دارند. برای آموزش یک مدل یادگیری ماشین جهت طبقه‌بندی داده‌ها، به تعداد کافی داده برچسب دار نیاز است ولی متأسفانه یافتن داده‌های برچسب‌دار اغلب زمان‌بر و پرهزینه است و به مهارت‌های انسانی نیاز دارد. بنابراین برای طبقه‌بندی داده‌های بدون برچسب، یک مدل بر روی داده‌های برچسب‌دار و در دسترس، آموزش داده و از دانش حاصل شده برای برچسب‌گذاری داده‌های بدون برچسب استفاده می‌شود. روش‌های یادگیری ماشین برای مسائلی که داده‌های منبع و هدف، فضای ویژگی یکسان با توزیع ثابت دارند، بیشتر کاربرد دارد. ولی اگر اختلافی در فضای ویژگی و/یا توزیع

در دنیای امروز نیاز به تحلیل و طبقه‌بندی داده‌ها (تصاویر، فیلم و متن) با توجه به رشد سریع حجم اطلاعات از طریق برنامه‌های کاربردی و رسانه‌های اجتماعی بیش از پیش احساس می‌شود [۱]. یادگیری ماشین<sup>۵</sup> و یادگیری انتقالی<sup>۶</sup> برای تشخیص و طبقه‌بندی داده‌ها، از شاخه‌های پرکاربرد هوش مصنوعی به حساب می‌آیند که در زمینه‌های مختلف همچون تجارت الکترونیک [۲]، بینایی کامپیوتری<sup>۷</sup> [۳]، بازیابی اطلاعات [۴] و پردازش گفتار [۵] کاربرد

روش KEDA<sup>۱۲</sup>، روش پیشنهادی این مقاله است که در انطباق دامنه‌های منبع و هدف برای طبقه‌بندی بهینه تصاویر، عملکرد بسیار خوبی دارد و برخلاف بسیاری از روش‌های انطباق توزیع که توزیع‌های شرطی و حاشیه‌ای را با اهمیت یکسان در انطباق دامنه‌ها در نظر می‌گیرند، این روش، توزیع‌های شرطی و حاشیه‌ای را با ضریب تاثیر متمایز در انطباق دامنه‌ها در نظر می‌گیرد.

نوآوری‌های پیشنهاد شده در این مقاله به شرح زیر است:

(۱) در این مقاله جهت پیاده‌سازی روش انطباق ویژگی‌ها، از انطباق هندسی کرنلی برای یافتن زیرفضای جدید به منظور یکسان کردن فضای ویژگی دامنه‌های منبع و هدف و از تطبیق توزیع متعادل برای کاهش اختلاف توزیع‌های شرطی و حاشیه‌ای دامنه‌ها استفاده می‌شود.

(۲) ساختار هندسی داده‌ها در دو مرحله‌ی انطباق هندسی کرنلی و یافتن طبقه‌بند بهینه حفظ می‌شود.

(۳) ماهیت کرنلی انطباق هندسی استفاده شده در این مقاله این امکان را می‌دهد که طبقه‌بند روی دامنه منبع با ماهیت و ویژگی‌های متفاوت از دامنه هدف آموزش ببیند و نتایج قابل قبولی در طبقه‌بندی دامنه هدف ارائه دهد. زیرا برای نگاشت هر کدام از دامنه‌ها به زیرفضای مشترک جدید، تابع کرنلی مختلف استفاده می‌کند. مثلاً اگر دامنه منبع عکس و دامنه هدف متن باشد، برای نگاشت هر کدام، تابع کرنلی متفاوت استفاده می‌کند.

(۴) کارایی روش پیشنهاد شده در این مقاله، بر روی پایگاه داده‌های شناخته شده بصری<sup>۱۳</sup> با پارامترهای مختلف مورد آزمایش قرار گرفته و نتایج آن‌ها با جدیدترین روش‌ها در حوزه یادگیری انتقالی مقایسه شده است. نتایج حاصل، نشان دهنده بهبود عملکرد قابل توجه الگوریتم پیشنهادی در مقایسه با روش‌های شناخته شده جدید در حوزه یادگیری انتقالی است.

در ادامه، مقاله به صورت زیر سازماندهی شده است. در بخش دوم مقاله، مروری بر کارهای پیشین در این حوزه گنجانده شده است. در بخش سوم، روش پیشنهادی به تفصیل شرح داده شده است. در بخش چهارم، پایگاه داده‌های مورد ارزیابی با جزئیات معرفی شده‌اند. در بخش پنجم، نتایج ارزیابی عملکرد الگوریتم پیشنهادی در مقایسه با روش‌های دیگر یادگیری ماشین و یادگیری انتقالی گزارش شده است. در انتها، مقاله با نتیجه‌گیری و ارائه پیشنهادهایی برای ادامه کار در آینده به اتمام رسیده است.

داده‌ها به وجود آید، برای مثال در بینایی کامپیوتری، شرایط نور، تجهیزات مورد استفاده یا پس زمینه بین تصاویر منبع و هدف تغییر کند یا در زمینه پردازش گفتار، داده‌های منبع و هدف از نظر سر و صدای پس زمینه، تن صدا و جنسیت گوینده متفاوت باشند، مدلی که روی داده‌های منبع ساخته می‌شود به راحتی نمی‌تواند روی داده‌های هدف مورد استفاده قرار گیرد. در این حالت دو راه حل وجود دارد: (۱) مدل (طبقه‌بند) برای هر شرایط (داده) جدید دوباره ایجاد شود، (۲) نمایش داده‌های منبع و هدف انطباق داده شود، که به انطباق دامنه یا یادگیری انتقالی معروف است [۶].

به طور کلی، دو نوع مسئله در انطباق دامنه یا یادگیری انتقالی مطرح است [۷]: (۱) مسائلی که فضای ویژگی داده‌های منبع و هدف یکسان است و اختلاف داده‌ها به اختلاف توزیع حاشیه‌ای<sup>۸</sup> و شرطی<sup>۹</sup> آن‌ها مربوط می‌شود. بدین معنی که، اگر داده‌های منبع و هدف فضای ویژگی یکسان داشته باشند ولی احتمال وقوع هر یک از ویژگی‌ها در دو دامنه منبع و هدف مختلف باشد، آن دو دامنه اختلاف توزیع حاشیه‌ای دارند. اختلاف توزیع شرطی نیز به صورت اختلاف در احتمال وقوع هر کدام از کلاس‌ها در دو دامنه منبع و هدف به ازای نمونه‌های یکسان تعریف می‌شود. انطباق دامنه، فاصله‌ی توزیع‌ها را در فضای اصلی ویژگی‌ها کم می‌کند ولی مسئله انحراف ویژگی‌ها وجود دارد که کاهش اختلاف توزیع را کمی سخت می‌کند [۸]. (۲) مسائلی که دامنه‌های منبع و هدف، فضای ویژگی یکسان ندارند، مانند مسائل داده‌های مالی مودال<sup>۱۰</sup> و بازیابی بین زبانی<sup>۱۱</sup>. یک راه حل برای مشکل اختلاف فضای ویژگی‌ها در دامنه‌ها، یافتن زیرفضای جدید با بهترین ویژگی‌ها است که در این صورت فضای ویژگی دامنه‌های منبع و هدف یکسان می‌شود. اما یافتن زیرفضای جدید مسئله‌ی اختلاف توزیع‌های شرطی و حاشیه‌ای را حل نمی‌کند [۹]. بنابراین در این مقاله، از متد انطباق ویژگی‌ها برای حل مشکل انحراف ویژگی‌ها در فضای اصلی (مشکل مسئله (۱) انطباق دامنه) و کاهش اختلاف توزیع شرطی و حاشیه‌ای دامنه‌ها (مشکل مسئله (۲) انطباق دامنه) استفاده می‌شود که از مزایای هر دو روش یادگیری زیرفضای جدید و انطباق توزیع‌ها بهره می‌برد، به این صورت که یک زیرفضای جدید یافت می‌شود که در آن ویژگی‌های یکسان برای هر دو دامنه استخراج می‌شود و سپس برای کاهش اختلاف توزیع‌های شرطی و حاشیه‌ای بین دامنه‌های منبع و هدف، انطباق توزیع انجام می‌شود. انطباق هندسی کرنلی، روشی است که دامنه‌های منبع و هدف را به یک زیرفضای پنهان جدید نگاشت می‌کند. از ویژگی‌های مهم این روش، انطباق نمونه‌های با برچسب یکسان و جداسازی نمونه‌های با برچسب متفاوت همزمان با حفظ توپولوژی دامنه‌ها است.

## ۲- کارهای پیشین

متدهای زیادی برای یادگیری انتقالی وجود دارد که براساس نوع اطلاعات انتقالی به چهار دسته کلی زیر تقسیم می‌شوند [۱۰].

(۱) یادگیری انتقالی مبتنی بر نمونه<sup>۱۴</sup>: در این دیدگاه به جای کل دامنه منبع، بخشی از داده‌های دامنه منبع برای یادگیری مدل دامنه هدف استفاده می‌شود. یادگیری انتقالی مبتنی بر وزن‌دهی ترکیبی نمونه‌ها<sup>۱۵</sup> [۱۱] از جمله روش‌های پیشنهاد شده در این دیدگاه است. این روش علاوه بر این که مانند متدهای وزن‌دهی نمونه‌ها، شباهت داده‌های دامنه منبع به دامنه هدف را ارزیابی می‌کند، ارتباط این نمونه‌ها با وظیفه هدف را نیز ارزیابی می‌کند. بدین ترتیب از یک استراتژی وزن‌دهی احتمالی که هر دو عامل را شامل می‌شود، برای انتخاب اطلاعات از دامنه منبع، جهت یادگیری طبقه‌بند دامنه هدف استفاده می‌کند.

(۲) یادگیری انتقالی مبتنی بر ویژگی<sup>۱۶</sup>: در این دیدگاه جهت انتقال دانش<sup>۱۷</sup> بین دو دامنه منبع و هدف، یک ساختار ویژگی مشترک برای هر دو دامنه ایجاد می‌شود. روش‌های این دیدگاه از جهت تمرکز بر اختلاف توزیع شرطی  $w$  یا حاشیه‌ای به سه دسته کلی تقسیم می‌شوند: (۱) روش‌هایی که فقط بر کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌ها تمرکز دارند. متد انطباق زیرفضای وزن‌دار<sup>۱۸</sup> [۱۲]، زیرفضای وزن‌دار نمونه‌های منبع و هدف ایجاد شده توسط PCA<sup>۱۹</sup> وزن‌دار را با استفاده از ماتریس نگاشت، انطباق می‌دهد و اختلاف توزیع حاشیه‌ای دامنه‌های منبع و هدف را با نگاشت بردارهای ویژه دامنه منبع به بردارهای ویژه دامنه هدف کاهش می‌دهد. (۲) روش‌هایی که فقط بر کاهش اختلاف توزیع شرطی بین دامنه‌ها تمرکز دارند. متد OT<sup>۲۰</sup> [۱۳]، با انتقال محلی<sup>۲۱</sup> داده‌های برچسب‌دار دامنه‌ی منبع، اختلاف توزیع احتمال شرطی دامنه‌های منبع و هدف را حداقل کرده و تفکیک‌پذیری بین کلاس‌ها را افزایش می‌دهد. (۳) روش‌هایی که بر کاهش اختلاف توزیع‌های حاشیه‌ای و شرطی بین دامنه‌ها با وزن یکسان تمرکز دارند. متد JDA<sup>۲۲</sup> [۱۴]، با ایجاد یک نمایش کم بعد از داده‌های منبع و هدف، اختلاف توزیع شرطی و حاشیه‌ای بین دامنه‌ها را به حداقل می‌رساند و هر دو توزیع را با یک وزن انطباق می‌دهد. متد VDA<sup>۲۳</sup> [۱۵]، علاوه بر این که اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌های منبع و هدف را با یک نمایش کم بعد از داده‌ها کاهش می‌دهد، برای طبقه‌بندی بهتر از خوشه‌بندی مستقل از دامنه استفاده می‌کند که شکل هندسی دامنه‌های منبع و هدف نیز حفظ می‌شود.

(۳) یادگیری انتقالی مبتنی بر مدل / پارامتر<sup>۲۴</sup>: در این دیدگاه هدف

بهبود ساختار طبقه‌بند دامنه هدف با استفاده از انتقال پارامترهای طبقه‌بند دامنه منبع برای کاهش خطای طبقه‌بندی داده‌های جدید است. انتقال پارامتر ترانس‌داکتیو<sup>۲۵</sup> [۱۶] یکی از روش‌های موجود برای این دیدگاه است و عملکرد آن به این صورت است که در مرحله اول برای هر دامنه منبع، یک طبقه‌بند با پارامترهای مخصوص آن دامنه ایجاد می‌کند سپس با استفاده از چهارچوب رگرسیون بردار ارزشمند<sup>۲۶</sup> و بدون نیاز به داده‌های برچسب‌دار از دامنه هدف، یک نگاشت  $f(.)$  بین دامنه منبع و پارامترهای طبقه‌بند مربوطه یادگیری می‌کند و پس از به دست آوردن  $f(.)$ ، پارامترهای بهینه طبقه‌بند دامنه هدف را پیش‌بینی می‌کند.

(۴) یادگیری انتقالی مبتنی بر رابطه<sup>۲۷</sup>: در این دیدگاه توزیع‌های دامنه‌های منبع و هدف مشابه هستند و مستقل از یکدیگر نیستند و انتقال دانش از دامنه منبع به دامنه هدف براساس الگوی روابط آماری بین دامنه‌ها است. روش RAP<sup>۲۸</sup> [۱۷] یک روش انطباق دامنه تحت نظارت است که برای استخراج دانش از تحلیل احساسات<sup>۲۹</sup> استفاده کرده و با مشخص کردن و توسعه دادن کلمات احساسی<sup>۳۰</sup> و مبحث دامنه هدف، رابطه‌ی بین مبحث و احساسات را تعیین می‌کند.

بسته به داده‌های برچسب‌دار در دسترس در دامنه‌های منبع و هدف، روش‌های یادگیری انتقالی را می‌توان به دو صورت نیمه نظارت شده<sup>۳۱</sup> و بدون نظارت<sup>۳۲</sup> پیاده‌سازی کرد که به شرح زیر است [۱۹، ۱۸]: در روش نیمه نظارت شده، کل دامنه منبع و قسمت کوچکی از داده‌های دامنه‌ی هدف دارای برچسب هستند که در انطباق بهتر دامنه‌های منبع و هدف بسیار موثر است [۲۰]. در روش بدون نظارت، دامنه‌ی منبع از داده‌های برچسب‌دار و دامنه‌ی هدف از داده‌های بدون برچسب تشکیل شده‌اند [۲۱].

در این مقاله، یک روش نیمه نظارت شده با عنوان KEDA که ترکیبی از دو دیدگاه مبتنی بر ویژگی و مبتنی بر مدل است، پیشنهاد می‌شود. روش KEDA، از دیدگاه مبتنی بر ویژگی برای کاهش انحراف ویژگی داده‌ها در فضای اصلی، با یافتن نمایش جدیدی از داده‌ها، استفاده می‌کند. همچنین از دیدگاه مبتنی بر مدل، برای بهبود دقت طبقه‌بند دامنه هدف با استفاده از پارامترهای طبقه‌بند دامنه منبع در فضای هندسی و کاهش تعادلی اختلاف توزیع شرطی و حاشیه‌ای دامنه‌های منبع و هدف، بهره می‌برد. در هر دو مرحله ساختار هندسی داده‌ها حفظ می‌شود. هدف اصلی این مقاله، یافتن طبقه‌بند بهینه برای طبقه‌بندی تصاویر است که نسبت به کارهای موجود در شاخه‌ی مسائل نیمه نظارت شده، کارایی



### ۳-۱-۲- تنظیم لاپلاسی

برای حفظ ساختار هندسی مجموعه‌ی داده‌ها، ساختار زیرفضاها ی جهانی<sup>۲۴</sup> و ساختار هندسی محلی داده‌ها با یک ماتریس وابستگی  $L$  (رابطه‌ی (۱۴)) تعریف می‌شود. ماتریس وابستگی، نشان‌دهنده‌ی یک گراف لاپلاسی با  $p$  همسایه‌ی نزدیک و  $n$  رأس است که هر رأس یک نمونه را نشان می‌دهد. فرض می‌شود  $W$  ماتریس وزن گراف لاپلاسی است که توپولوژی هندسی دامنه‌ها را تعیین می‌کند و  $p$  داده‌ی نزدیک به هر داده را از نظر معیار شباهت نمایش می‌دهد. اگر نمونه‌ی  $x_i$  در میان  $p$  همسایه‌ی نزدیک نمونه‌ی  $x_j$  باشد و بالعکس،  $W_{ij}$  مقدار ۱ و در غیر اینصورت مقدار صفر می‌گیرد. پس داریم:

$$L = D - W \quad (14)$$

Subject to:

$$D = \text{diag}(d_1, \dots, d_n), \quad d_i = \sum_{j=1}^n W_{ij}$$

که  $D$  ماتریس قطری است و درجه‌ی هر نمونه را نشان می‌دهد. حفظ ساختار هندسی داده‌ها با حداقل کردن رابطه‌ی (۱۵) معادل است.

$$R_f(D_s, D_t) = \sum_{i,j=1}^{n+m} W_{ij} (f(g(x_i)) - f(g(x_j)))^2 \quad (15)$$

$$\sum_{i,j=1}^{n+m} W_{ij} (f(g(x_i)) - f(g(x_j)))^2 = \text{tr}(A^T K L K A) \quad (16)$$

رابطه‌ی (۱۶) فرم بسته‌ی رابطه‌ی (۱۵) است. بنابراین تنظیم لاپلاسی (رابطه‌ی (۱۶))، که هندسه‌ی داده‌ها را به هم نزدیک در دامنه‌ها را به دست می‌آورد و ساختار داده‌ها را حفظ می‌کند، را می‌توان به عنوان مولفه‌ی سوم به تابع هدف رابطه‌ی (۶) افزود که به شکل رابطه‌ی (۱۷) ظاهر می‌شود:

$$f = \underset{f \in \mathcal{H}_K}{\text{argmin}} \left( \frac{1}{n} \sum_{i=1}^n (y_i - f(g(x_i)))^2 + \eta \|f\|_K^2 + \rho \sum_{i,j=1}^{n+m} W_{ij} (f(g(x_i)) - f(g(x_j)))^2 \right) \quad (17)$$

که  $\rho$  پارامتر تنظیم لاپلاسی است. همچنین در بخش بعدی انطباق توزیع متعادل، که برای کاهش تعادلی اختلاف شرطی و حاشیه‌ای بین دامنه‌ها تعریف می‌شود، به رابطه‌ی (۱۷) اضافه می‌شود.

### ۳-۱-۳- انطباق توزیع متعادل

تا به امروز بسیاری از روش‌هایی که برای انطباق توزیع دامنه‌های منبع و هدف پیشنهاد شده اند یا یکی از دو توزیع حاشیه‌ای و شرطی را انطباق می‌دهند، مانند SDA<sup>43</sup> [۲۴] که فقط انطباق توزیع حاشیه‌ای انجام می‌دهد یا انطباق هر دو توزیع را با اهمیت یکسان در نظر می‌گیرند مانند VDA که هر دو توزیع شرطی و حاشیه‌ای را با وزن یکسان انطباق می‌دهد. در این مقاله هدف، انطباق هر دو

$$L = D - W \quad (9)$$

که  $W$  ماتریس همسایگی است و ارتباط بین  $k$  همسایه نزدیک به هر یک از نمونه‌ها را نشان می‌دهد درحالی که  $D$  ماتریس درجه‌ی قطری است و تعداد اتصالات هر نمونه با نمونه‌های دیگر را نشان می‌دهد. KMA همه‌ی داده‌ها را به فضای پنهان  $F$  نگاشت می‌کند که داده‌های متعلق به یک کلاس، به هم نزدیکتر و داده‌های متعلق به کلاس‌های متفاوت از هم دورتر می‌شوند در حالی که توپولوژی داده‌ها حفظ می‌شود. از رابطه‌ی (۱۰) جهت پیدا کردن بردارهای ویژه همه دامنه‌ها ( $U$ ) برای نگاشت داده‌ها به فضای پنهان استفاده می‌شود که  $\Phi_i$  داده‌های نگاشت شده دامنه‌ی  $i$  به فضای هیلبرت است.

$$\Phi(L + \gamma L_s) \Phi^T U = \delta \Phi L_a \Phi^T U \quad (10)$$

که  $L$  ماتریس لاپلاس گرافی شباهت است که توپولوژی دامنه را نشان می‌دهد.  $L_s$  نیز ماتریس لاپلاس گرافی شباهت است که نمونه‌های مربوط به یک کلاس را نشان می‌دهد در حالی که  $L_a$  ماتریس لاپلاس گرافی تفاوت است و نمونه‌هایی که مربوط به یک کلاس نیستند را نشان می‌دهد. همچنین  $\gamma$  و  $\delta$  پارامتر تنظیم هستند. چون  $U$  ممکن است بی نهایت بعد داشته باشد و محاسبه‌ی بی نهایت بعد، کار سختی است، از رابطه‌ی (۱۱) که صورت کرنلی رابطه‌ی (۱۰) است، استفاده می‌شود.

$$K(L + \gamma L_s) K B = \delta K L_a K B \quad (11)$$

$K$  ماتریس قطری شامل ماتریس‌های کرنل  $k_i$  (رابطه‌ی (۱۲)) است که شباهت بین نمونه‌ها را نشان می‌دهد و از ضرب نقطه‌ای (داخلی) نمونه‌های نگاشت شده‌ی  $\Phi_i$  به دست می‌آید:

$$k_i = \Phi_i^T \Phi_i \quad (12)$$

$B$  ماتریس ضرایب است و به صورت  $B = U \Phi^{-1}$  تعریف می‌شود. کرنلی بودن این انطباق هندسی باعث صرفه‌جویی محاسباتی در دامنه‌های با ابعاد زیاد می‌شود. انتقال به فضای پنهان  $F$  داده‌ها دو مرحله دارد: (۱) در مرحله اول داده‌های  $X_i$  به فضای هیلبرت معادل  $H_i$  نگاشت می‌شوند، (۲) در مرحله دوم داده‌های نگاشت شده‌ی  $\Phi_i$  به فضای هیلبرت  $H_i$ ، با بردار نگاشت  $u_i$  به فضای پنهان انتقال می‌یابد که به صورت رابطه‌ی (۱۳) تعریف می‌شود:

$$P_F(X_i) = u_i^T \Phi_i = \beta_i^T \Phi_i = \beta_i^T K_i \quad (13)$$

که  $\beta_i$  و  $K_i$  به ترتیب از روابط (۱۱) و (۱۲) به دست می‌آیند.

به عنوان تابع نگاشت در فضای بازسازی کرنلی هیلبرت  $\mathcal{H}_K$  می‌باشد. رابطه‌ی (۲۱) را می‌توان به صورت شکل بسته رابطه‌ی (۲۲) نوشت:

$$D(D_s, D_t) = \text{tr}(A^T K M K A) \quad (22)$$

که در آن  $M$  به صورت رابطه‌ی (۲۳) تعریف می‌شود:

$$M = (1 - \mu)M_0 + \mu \sum_{c=1}^C M_c \quad (23)$$

که مقادیر ماتریس  $M_0$  و  $M_c$  به صورت (۲۴) و (۲۵) به دست می‌آیند:

$$(M_0)_{ij} = \begin{cases} \frac{1}{n_s n_s}, & x_i, x_j \in D_s \\ \frac{1}{n_t n_t}, & x_i, x_j \in D_t \\ -\frac{1}{n_s n_t}, & \text{otherwise} \end{cases} \quad (24)$$

که  $n_s$  تعداد نمونه‌های دامنه‌ی منبع و  $n_t$  تعداد نمونه‌های دامنه‌ی هدف است.

$$(M_c)_{ij} = \begin{cases} \frac{1}{n_s^{(c)} n_s^{(c)}}, & x_i, x_j \in D_s^{(c)} \\ \frac{1}{n_t^{(c)} n_t^{(c)}}, & x_i, x_j \in D_t^{(c)} \\ -\frac{1}{n_s^{(c)} n_t^{(c)}}, & \begin{cases} x_i \in D_s^{(c)}, x_j \in D_t^{(c)} \\ x_j \in D_s^{(c)}, x_i \in D_t^{(c)} \end{cases} \\ 0, & \text{otherwise} \end{cases} \quad (25)$$

در رابطه‌ی (۲۵)  $D_s^{(c)}$  مجموعه‌ی نمونه‌های مربوط به کلاس  $c$  در دامنه‌ی منبع و  $n_s^{(c)}$  تعداد نمونه‌های مربوط به کلاس  $c$  در دامنه‌ی منبع است و متقابلاً  $D_t^{(c)}$  مجموعه‌ی نمونه‌های مربوط به کلاس  $c$  در دامنه‌ی هدف و  $n_t^{(c)}$  تعداد نمونه‌های مربوط به کلاس  $c$  در دامنه‌ی هدف است.

ضریب تأثیر متمایز توزیع‌های شرطی و حاشیه‌ای در انطباق، می‌تواند باعث بهبود چشمگیر در عملکرد طبقه‌بند شود. بنابراین انطباق توزیع متعادل را می‌توان به عنوان مولفه‌ی چهارم به تابع هدف رابطه‌ی (۱۷) اضافه کرد و رابطه‌ی (۲۶) را به دست آورد.

$$f = \underset{f \in \mathcal{H}_K}{\text{argmin}} \left( \frac{1}{n} \sum_{i=1}^n (y_i - f(g(x_i)))^2 + \eta \|f\|_K^2 + \rho \sum_{i,j=1}^{n+m} W_{ij} (f(g(x_i)) - f(g(x_j)))^2 + \lambda ((1 - \mu) \left\| \frac{1}{n} \sum_{i=1}^n f(g(x_{s_i})) - \frac{1}{m} \sum_{j=1}^m f(g(x_{t_j})) \right\|_{\mathcal{H}_K}^2 + \mu \sum_{c=1}^C \left\| \frac{1}{n_c} \sum_{x_{s_i} \in D_s^{(c)}} f(g(x_{s_i})) - \frac{1}{m_c} \sum_{x_{t_j} \in D_t^{(c)}} f(g(x_{t_j})) \right\|_{\mathcal{H}_K}^2 \right) \right) \quad (26)$$

از رابطه (۲۶)، برای یافتن بهترین طبقه‌بند  $f$  استفاده می‌شود. مولفه‌ی اول رابطه‌ی (۲۶) خطای طبقه‌بند در برچسب‌گذاری داده‌های  $x_i$  نگاشت شده با انطباق هندسی کرنلی است. مولفه دوم مربع نرم  $f$  است که از ایجاد جواب‌های بدیهی جلوگیری می‌کند.

توزیع شرطی و حاشیه‌ای دامنه‌های منبع و هدف به صورت تعادلی، با ارزش جداگانه است. با توجه به میزان اختلاف کلی توزیع‌های دامنه منبع و هدف، یکی از این توزیع‌های حاشیه‌ای و شرطی اهمیت زیادی در انطباق دامنه، نسبت به دیگری پیدا می‌کند. اگر اختلاف توزیع دامنه‌های منبع و هدف خیلی زیاد باشد انطباق توزیع حاشیه‌ای (P) ارجحیت زیادی نسبت به انطباق توزیع شرطی (Q) دارد در حالی که اگر توزیع‌های دامنه‌های منبع و هدف شبیه باشند، اختلاف توزیع در هر کلاس (انطباق توزیع شرطی Q) ارجحیت بیشتر دارد. انطباق توزیع متعادل با رابطه‌ی زیر نشان داده می‌شود.

$$D(D_s, D_t) \approx (1 - \mu)D(P(x_s), P(x_t)) + \mu D(Q(y_s|x_s), Q(y_t|x_t)) \quad (18)$$

که  $\mu \in [0, 1]$  فاکتور تعادل است و اگر  $\mu$  برابر ۰.۵ باشد هر دو توزیع اهمیت مساوی برای انطباق دارند.  $D(P(x_s), P(x_t))$  انطباق توزیع حاشیه‌ای و  $D(Q(y_s|x_s), Q(y_t|x_t))$  انطباق توزیع شرطی را نشان می‌دهد.

مسئله اصلی پیدا کردن  $\mu$  بهینه است. برای پیدا کردن  $\mu$  بهینه از ساختار محلی و عمومی دامنه‌ها استفاده می‌شود [۷]. در رابطه‌ی (۱۹) معیار  $A$ -distance [۲۵] به صورت خطای طبقه‌بند ( $\epsilon(h)$ ) در تفکیک بین دو دامنه تعریف می‌شود:

$$d_A(D_s, D_t) = 2(1 - 2\epsilon(h)) \quad (19)$$

فاکتور  $\mu$  با رابطه‌ی (۲۰) تخمین زده می‌شود که در آن  $d_M$   $A$ -distance بین توزیع‌های حاشیه‌ای دامنه‌های منبع و هدف و  $d_c$   $A$ -distance مربوط به توزیع‌های شرطی دامنه‌های منبع و هدف برای کلاس  $c$  است:

$$\hat{\mu} \approx 1 - \frac{d_M}{d_M + \sum_{c=1}^C d_c} \quad (20)$$

برای محاسبه‌ی اختلاف توزیع حاشیه‌ای و شرطی دامنه‌های منبع و هدف از حداکثر اختلاف میانگین<sup>۴۴</sup> (MMD) استفاده می‌شود، بنابراین رابطه‌ی (۱۸) را می‌توان به صورت رابطه‌ی (۲۱) تعریف کرد:

$$D(D_s, D_t) = (1 - \mu) \left\| \frac{1}{n} \sum_{i=1}^n f(g(x_{s_i})) - \frac{1}{m} \sum_{j=1}^m f(g(x_{t_j})) \right\|_{\mathcal{H}_K}^2 + \mu \sum_{c=1}^C \left\| \frac{1}{n_c} \sum_{x_{s_i} \in D_s^{(c)}} f(g(x_{s_i})) - \frac{1}{m_c} \sum_{x_{t_j} \in D_t^{(c)}} f(g(x_{t_j})) \right\|_{\mathcal{H}_K}^2 \quad (21)$$

که توابع  $g(\cdot)$  و  $f(\cdot)$  در رابطه‌ی (۲۱)، به ترتیب انطباق هندسی کرنلی KMA و طبقه‌بند را نشان می‌دهند که در این جا طبقه‌بند  $f$

آزمایش یکی از دو دامنه به عنوان دامنه منبع و دامنه‌ی دیگر به عنوان دامنه هدف در نظر گرفته می‌شود. توزیع هر عدد در دو دیتاست USPS و MNIST متفاوت است.

دیتاست کوپل شامل ۱۴۴۰ تصویر سیاه و سفید از ۲۰ شی است که برای هر شی ۷۲ تصویر با ۱۰۲۴ بعد وجود دارد. دیتاست کوپل، از دو دامنه کوپل ۱ و کوپل ۲ تشکیل می‌شود. بنابه اختلاف در زاویه‌ی تصاویر گرفته شده، این دو دامنه با هم اختلاف توزیع دارند. از ۱۴۴۰ تصویر، ۷۲۰ نمونه برای دامنه کوپل ۱ و ۷۲۰ نمونه برای دامنه کوپل ۲ است. با استفاده از این دو دامنه هم، دو آزمایش انجام می‌گیرد که در هر آزمایش یکی از دو دامنه به عنوان دامنه منبع و دامنه دیگر به عنوان دامنه هدف انتخاب می‌شود.

دیتاست پای نیز برای تشخیص چهره استفاده می‌شود. این دیتاست از ۵ دامنه با حالت‌های تصویربرداری مختلف برای هر دامنه تشکیل می‌شود. دامنه پای ۱ (تصویر چهره از سمت چپ)، دامنه پای ۲ (تصویر چهره از سمت بالا)، دامنه پای ۳ (تصویر چهره از سمت پایین)، دامنه پای ۴ (تصویر چهره از روبرو) و دامنه پای ۵ (تصویر چهره از سمت راست) است. از ۵ دامنه فوق، ۲۰ وظیفه برای ارزیابی عملکرد روش پیشنهادی مقاله به دست می‌آید که در هر وظیفه ۲ دامنه از ۵ دامنه به عنوان دامنه‌های منبع و هدف انتخاب می‌شود. روش KEDA با روش‌های دیگر یادگیری انتقالی و انطباق دامنه از جمله VDA [۱۵]، JDA [۱۴]، TJM [۳۲]، SSTCA [۳۳]، GFK [۳۴]، PCA [۳۵]، MMDT [۳۶]، OT [۱۳]، ILS [۳۷]، CDLS [۳۸]، SHFA [۳۹]، SSTS [۴۰]، KMA [۲۳]، SDA [۲۴]، DLPP [۴۱]، GLPP [۴۲]، FME [۴۳]، SLDA [۴۴] و SODA [۴۵] مقایسه شده است، که در ادامه به صورت اجمالی شرح داده خواهد شد. همچنین نتایج دقت طبقه‌بند روی دیتاست‌های ذکر شده در جدول‌های ۱، ۲، ۳ و ۴ نشان داده شده است. برای مقایسه منصفانه روش‌ها، از دیتاست‌ها با ویژگی‌ها و نمونه‌های یکسان استفاده شده است. در آزمایشات، برای روش‌های دیگر از طبقه‌بند نزدیکترین همسایه (NN) به دلیل عدم نیاز به تنظیم پارامتر اضافی استفاده می‌شود. معیار ارزیابی در این مقاله، به صورت دقت طبقه‌بند روی داده‌های آزمایشی از دامنه هدف  $D_t^T$  است که به صورت رابطه‌ی (۲۹) تعریف می‌شود:

$$Accuracy = \frac{|x: x \in D_t^T \wedge \hat{y}(x) = y(x)|}{|x: x \in D_t^T|} \quad (29)$$

که  $y(x)$  و  $\hat{y}(x)$  به ترتیب برچسب واقعی و برچسب پیش‌بینی شده روی داده‌های آزمایشی دامنه هدف  $D_t^T$  است. در پایگاه داده آفیس-کلتک-۱۰، روش پیشنهادی مقاله با روش‌های JDA، VDA، آفیس-کلتک-۱۰، روش پیشنهادی مقاله با روش‌های JDA، VDA، KMA و CDLS ILS، OT، MMDT، GFK، TJM

مولفه‌ی سوم، تنظیم‌گر لاپلاسی برای یافتن توپولوژی داده‌های شبیه به هم است و مولفه‌ی چهارم، انطباق توزیع متعادل است.  $\eta$ ،  $\rho$  و  $\lambda$  پارامترهای تنظیم‌کننده هستند و فضای بازسازی کرنلی هیلبرت است.

با جایگذاری رابطه‌های (۸)، (۱۶) و (۲۲) در رابطه‌ی (۲۶)، شکل بسته‌ی فرمول (۲۶) به صورت رابطه‌ی (۲۷) به دست می‌آید:

$$f = \underset{f \in \mathcal{H}_K}{\operatorname{argmin}} \| (Y - \Lambda^T K) A \|_F^2 + \eta \operatorname{tr}(\Lambda^T K \Lambda) + \operatorname{tr}(\Lambda^T K (\rho L + \lambda M) K \Lambda) \quad (27)$$

که با مشتق‌گیری از رابطه‌ی (۲۷) نسبت به  $\Lambda$  و مساوی قرار دادن آن با صفر،  $\Lambda$  بهینه به صورت زیر به دست می‌آید:

$$\Lambda^* = ((A + \rho L + \lambda M) K + \eta I)^{-1} A Y^T \quad (28)$$

در واقع، رابطه‌ی (۲۸) نشان می‌دهد که مدل بهینه بین دامنه‌ای برای طبقه‌بندی داده‌های آزمایشی، می‌تواند بدون نیاز به یادگیری طبقه‌بند واقعی به آسانی به دست آید.

#### ۴- آزمایش‌ها

در این مقاله از چهار دیتاست: (۱) آفیس-کلتک-۱۰ [۲۶-۲۷]، (۲) اعداد (USPS و MNIST) [۲۸-۲۹]، (۳) کوپل [۳۰]، (۴) پای (چهره) [۳۱]، برای ارزیابی عملکرد روش KEDA استفاده شده است. دیتاست آفیس-۱۰، از سه دامنه آمزون (A)، وب‌کم (W) و DLSR (D) تشکیل می‌شود که این دامنه‌ها شامل مجموعه‌ی تصاویر از اشیای گوناگون با کیفیت‌های متفاوت در هر دامنه هستند. دیتاست آفیس-۱۰، ۱۴۱۰ تصویر با ۸۰۰ ویژگی برای هر تصویر و ۱۰ کلاس دارد. دیتاست کلتک-۱۰ نیز پایگاه‌داده‌ی دیگری برای تشخیص اشیاست که ۱۱۲۳ تصویر با ۸۰۰ ویژگی برای هر تصویر و ۱۰ کلاس دارد. دیتاست‌های آفیس-کلتک-۱۰ از ۱۲ وظیفه تشکیل می‌شود که در هر یک از وظیفه‌ها، یکی از دامنه‌ها (مثلاً آمزون) به عنوان دامنه منبع و یکی دیگر از دامنه‌ها (مثلاً کلتک) به عنوان دامنه هدف در نظر گرفته می‌شود. تفاوت در توزیع دیتاست‌های آفیس و کلتک در ارزیابی عملکرد روش‌های انطباق دامنه، اثر مفیدی دارد.

دیتاست اعداد از دو دامنه USPS و MNIST تشکیل می‌شود که شامل عددهای دست‌نویس ۰ تا ۹ هستند. دیتاست USPS ۱۸۰۰ تصویر به ابعاد ۱۶\*۱۶ پیکسلی با ۲۵۶ ویژگی برای هر تصویر و ۱۰ کلاس دارد در حالی که دیتاست MNIST، ۲۰۰۰ تصویر به ابعاد ۲۸\*۲۸ پیکسلی با ۲۵۶ ویژگی برای هر تصویر و ۱۰ کلاس دارد. دو آزمایش با استفاده از این دو دامنه انجام می‌گیرد که در هر



روش‌های ILS و SHFA نیز انطباق دامنه‌ها را با استفاده از دو ماتریس نگاشت متفاوت برای انتقال داده‌های دامنه‌های منبع و هدف به فضای پنهان مشترک انجام می‌دهند که متد SHFA، براساس چهارچوب حداکثر حاشیه<sup>۶</sup> [۴۶] این انتقال را انجام می‌دهد. در ILS از معیار مهلنوبیس برای کاهش اختلاف بین داده‌های نگاشت شده استفاده می‌شود. روش MMDT برخلاف روش SHFA با یافتن ماتریس نگاشت ویژگی‌ها، نمایشی از داده‌ها به دست می‌آورد که برای طبقه‌بندی داده‌های دیده نشده<sup>۷</sup> بسیار مفید است. روش KMA، توپولوژی‌های پیچیده داده‌های با ابعاد مختلف را با حفظ ساختار داخلی توپولوژی انطباق می‌دهد و صورت عمومی متدهای انطباق هندسی است. در پایگاه داده پای، روش پیشنهادی مقاله با روش‌های VDA، JDA، SSTCA، GFK، SSTS، PCA و KMA مقایسه شده است. روش PCA، در حین حفظ ساختار اصلی داده‌ها، داده‌های با ابعاد مختلف را به یک فضای مشترک کم‌بعد بین دامنه‌ای انتقال می‌دهد.

است. روش GFK، با نگاشت داده‌های دامنه منبع و هدف به بی‌نهایت زیرفضای بین دامنه‌ای، اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف را کاهش می‌دهد ولی به دلیل کم شدن بعد زیرفضاها، نمایش درستی از داده‌ها به دست نمی‌آید. روش TJM فقط اختلاف توزیع حاشیه‌ای را در نظر می‌گیرد. روش TJM با وزن دهی بیشتر به داده‌های منبع شبیه به داده‌های هدف اختلاف توزیع را کاهش می‌دهد. روش‌های VDA و JDA برای کاهش اختلاف هر دو توزیع شرطی و حاشیه‌ای، یک نمایش کم بعد مشترک، برای داده‌ها ایجاد می‌کنند که JDA این دو توزیع را با وزن یکسان انطباق می‌دهد درحالی که VDA از خوشه‌بندی مستقل از دامنه برای حفظ شکل هندسی دامنه‌های منبع و هدف و بهبود دقت طبقه‌بند استفاده می‌کند. روش CDLS با یادگیری لندمارک‌های نمایشی بین دامنه‌ای، نمایش جدیدی برای داده‌های دامنه‌های ناهمگن ارائه می‌کند. روش OT با انتقال محلی داده‌های برچسب‌دار دامنه منبع، اختلاف توزیع شرطی دامنه‌های منبع و هدف را حداقل می‌کند و عملکرد طبقه‌بند را بهبود می‌دهد.

جدول ۱. دقت (%) طبقه‌بند در پایگاه داده آفیس و کلتک-۱۰

| KEDA            | KMA      | MMDT (2014) | CDLS (2016) | ILS (1NN) (2017) | OT-IT (2017) | OT-GL (2017)    | GFK      | TJM      | JDA      | VDA             | Dataset |
|-----------------|----------|-------------|-------------|------------------|--------------|-----------------|----------|----------|----------|-----------------|---------|
| <b>61.2±1.3</b> | 47.1±1.8 | 49.4±0.8    | 50.9        | 55.1             | 46.9±3.4     | 47.9±3.1        | 41.7±1.1 | 45±1.4   | 43.8±1.1 | 46.2±2.6        | C→A     |
| <b>76.2±1.7</b> | 66.4±2.4 | 63.8±1.1    | 66.3        | 62.9             | 64.8±3.0     | 65.0±3.1        | 45.3±0.9 | 47.2±2.3 | 47.4±0.9 | 51.1±2.9        | C→W     |
| 59±2.5          | 55.5±3.1 | 56.5±0.9    | 59.8        | 56.2             | 59.3±2.5     | <b>61.0±2.1</b> | 42.9±3   | 39±2     | 43±3.5   | 42±2.4          | C→D     |
| 42.1±0.9        | 30.7±1   | 36.4±0.8    | 35.3        | <b>43.6</b>      | 36.0±1.3     | 37.1±1.1        | 36.8±1   | 36.9±0.4 | 35.9±0.6 | 36.3±0.8        | A→C     |
| <b>77.6±1.4</b> | 66.7±2.3 | 64.6±1.2    | 68.7        | 59.7             | 63.7±2.4     | 64.6±1.9        | 39±0.4   | 40.1±1.3 | 40.2±1.6 | 43.1±1.8        | A→W     |
| 59.1±3.5        | 53±2.9   | 56.7±1.3    | <b>60.4</b> | 49.8             | 57.6±2.5     | 59.1±2.3        | 36.2±2.2 | 33.2±2   | 34.8±2   | 37.6±1.8        | A→D     |
| <b>42.2±0.8</b> | 31.2±1   | 32.2±0.8    | 33.5        | 38.6             | 38.4±1.5     | 38.8±1.2        | 32.8±1   | 32.9±1.1 | 32.3±0.7 | 30.9±1.3        | W→C     |
| <b>62.4±1.1</b> | 47.8±1.2 | 47.7±0.9    | 51.8        | 54.3             | 47.2±2.5     | 47.3±2.5        | 35.9±1.3 | 35±1.3   | 35.5±1.2 | 36.9±1.7        | W→A     |
| 62.1±2.4        | 58.6±2.9 | 67±1.1      | 60.7        | 70.8             | 79.0±2.8     | 79.4±2.8        | 87.7±1.6 | 89±0.7   | 88.9±1.4 | <b>91.2±0.7</b> | W→D     |
| <b>42.1±1.2</b> | 31.4±0.9 | 34.1±1.5    | 34.9        | 41               | 35.5±2.1     | 36.8±1.5        | 32.4±0.8 | 32.5±1.5 | 31.3±1   | 30.9±1.1        | D→C     |
| <b>62.8±0.8</b> | 48±1.7   | 46.9±1.0    | 50.7        | 55               | 45.8±2.6     | 46.3±2.5        | 36.6±0.9 | 36±1.1   | 35.1±1.6 | 34.6±1.9        | D→A     |
| 78.7±1.5        | 69.4±1.4 | 74.1±0.8    | 68.5        | 80.1             | 83.9±1.4     | 84.0±1.5        | 82.7±0.8 | 91±0.5   | 90±1.5   | <b>92.7±1.5</b> | D→W     |
| <b>60.4</b>     | 50.5     | 52.4        | 53.4        | 55.5             | 54.8         | 55.6            | 45.8     | 46.5     | 46.5     | 47.8            | Average |

جدول ۲. دقت (%) طبقه‌بند در پایگاه داده پای

| KEDA            | VDA             | SSTS        | KMA      | JDA      | TJM      | SSTCA | GFK      | PCA      | Dataset |
|-----------------|-----------------|-------------|----------|----------|----------|-------|----------|----------|---------|
| <b>88.9±1.1</b> | 82±0.5          | 83.7        | 86.6±0.5 | 62.6±5.8 | 12.2±0.2 | 34    | 28.8±0.5 | 24.9±0.5 | P1_P2   |
| <b>88.4±1.3</b> | 79.6±0.8        | 94.5        | 86.4±1.1 | 65.8±1.9 | 13.7±0.6 | 64.48 | 31.4±0.4 | 27.3±0.3 | P1_P3   |
| 90.8±0.7        | <b>93.7±0.6</b> | 77.6        | 86.2±0.8 | 86.9±0.7 | 20.1±0.3 | 31.72 | 32.9±0.7 | 30.6±0.7 | P1_P4   |
| <b>88±0.9</b>   | 68.1±0.7        | 55.3        | 86±1.1   | 53±1.4   | 11.8±0.5 | 20.59 | 25.8±1.1 | 24.3±0.9 | P1_P5   |
| <b>91.7±0.4</b> | 79.2±0.6        | 87.6        | 87.6±0.8 | 65.4±0.6 | 19.9±0.4 | 72.31 | 31.1±0.7 | 30.1±0.7 | P2_P1   |
| 87.6±1.2        | 82.1±0.8        | <b>94.8</b> | 86±1.1   | 69.3±0.9 | 24±0.8   | 80.45 | 40.2±0.4 | 36.7±0.8 | P2_P3   |
| 89.8±0.7        | <b>90±1.1</b>   | 80.2        | 86±0.8   | 78.1±1.2 | 29.6±0.6 | 45.03 | 51.1±0.5 | 50.3±0.4 | P2_P4   |
| <b>87.4±1.1</b> | 68.8±1.3        | 64.8        | 85.6±1.2 | 49.4±2.4 | 14.5±0.5 | 29.48 | 29.1±1   | 28±0.8   | P2_P5   |
| 91.6±0.5        | 75.8±1.3        | <b>91.8</b> | 87.6±0.8 | 60.9±1.4 | 18.7±0.5 | 73.88 | 30.3±0.6 | 29.8±0.6 | P3_P1   |
| <b>88.1±1</b>   | 76.2±1.5        | 96          | 86.1±0.5 | 60.1±1.7 | 27.7±0.8 | 75.09 | 37.3±1.2 | 33.7±0.7 | P3_P2   |
| 89.8±0.8        | 90±0.8          | <b>96.9</b> | 86.1±0.8 | 79.4±0.6 | 30.8±0.4 | 85.15 | 49.5±0.7 | 49.2±0.5 | P3_P4   |

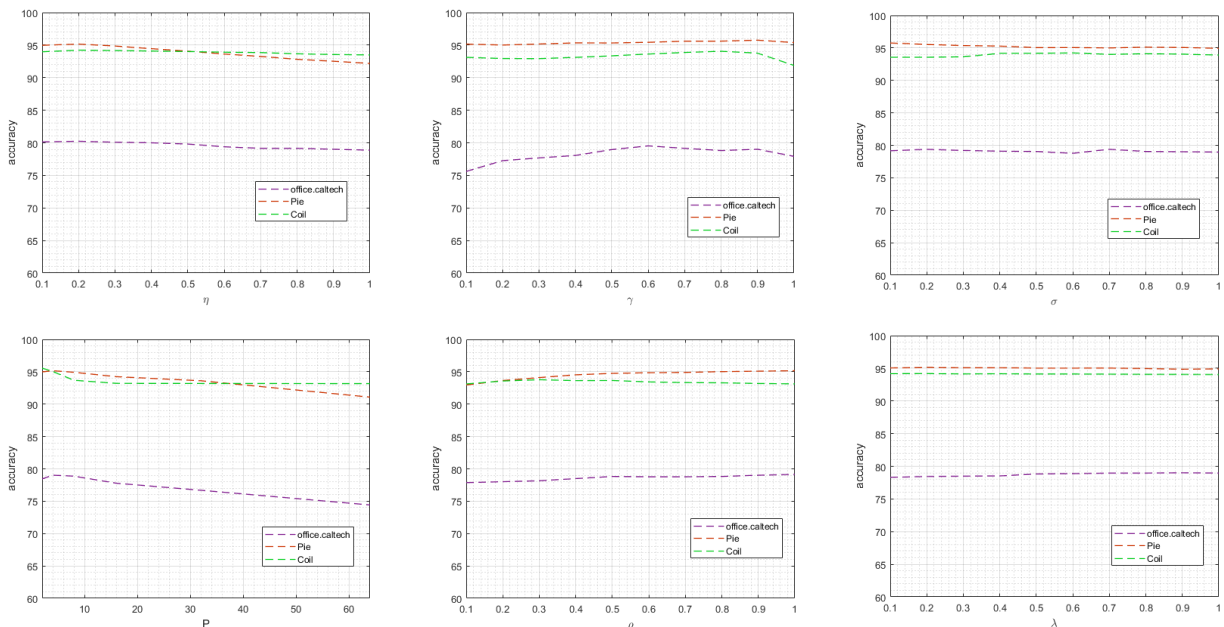
|                 |                  |             |          |           |          |       |          |          |         |
|-----------------|------------------|-------------|----------|-----------|----------|-------|----------|----------|---------|
| <b>87.3±0.9</b> | 64.6±1.7         | 74.5        | 85.6±1.2 | 48.1±1.5  | 13.5±0.6 | 34.45 | 29.4±0.8 | 26.4±0.5 | P3_P5   |
| <b>92.2±0.6</b> | 92±1             | 87.5        | 87.7±0.7 | 83.5±1.5  | 27.6±0.4 | 70.81 | 33±0.5   | 30.7±0.7 | P4_P1   |
| 88.8±1.1        | <b>93.3±0.38</b> | 87.5        | 86.7±0.4 | 84.9±0.8  | 30±0.4   | 36.14 | 58.2±1.1 | 54±0.7   | P4_P2   |
| 88.5±1.3        | 92.6±0.6         | <b>96.4</b> | 86.5±1.1 | 90.17±0.9 | 39.3±0.7 | 82.59 | 67.7±1   | 64.5±1   | P4_P3   |
| <b>88±1</b>     | 76.4±0.8         | 80.8        | 86.1±1   | 63.6±1.6  | 13.7±0.5 | 47.13 | 34.2±0.7 | 30.6±0.9 | P4_P5   |
| <b>91.6±0.5</b> | 74.8±1.1         | 79.6        | 87.7±0.7 | 56.1±2.5  | 15.2±0.3 | 72.22 | 28.7±0.8 | 28±0.8   | P5_P1   |
| <b>88.2±0.9</b> | 71.3±1.1         | 75.3        | 86.1±0.6 | 51.6±2.4  | 12.7±0.6 | 21.75 | 27.4±0.6 | 25.6±0.7 | P5_P2   |
| <b>87.7±1.2</b> | 69.6±0.8         | 78.6        | 85.9±1.1 | 45.3±2.3  | 12.5±0.5 | 28.85 | 30±0.4   | 27.9±0.4 | P5_P3   |
| 89.8±0.8        | 78.1±0.8         | <b>90.7</b> | 86±0.7   | 65.3±1    | 16±0.5   | 60.16 | 33.9±0.8 | 33±0.8   | P5_P4   |
| <b>89.2</b>     | 79.9             | 83.7        | 86.4     | 66        | 20.2     | 53.32 | 36.5     | 34.3     | Average |

جدول ۳. دقت (%) طبقه‌بند در پایگاه داده اعداد

| KEDA            | VDA    | JDA             | TJM      | SSTCA | KMA      | SHFA | SSTS | Dataset |
|-----------------|--------|-----------------|----------|-------|----------|------|------|---------|
| <b>78.8±0.4</b> | 62±1.8 | 61.1±2.1        | 53.9±1.1 | 61.9  | 69.4±0.7 | 63.9 | 67.1 | U-M     |
| <b>84.9±0.7</b> | 83±0.8 | <b>84.1±0.6</b> | 84.8±0.6 | 75    | 74.5±1   | 75.9 | 76.4 | M-U     |
| <b>81.9</b>     | 72.5   | 72.6            | 69.3     | 68.5  | 71.9     | 69.9 | 71.7 | Average |

جدول ۴. دقت (%) طبقه‌بند در پایگاه داده کویل

| KEDA        | SODA | SSTS | KMA  | SLDA | FME  | GLPP | DLPP | SDA  | SSTCA | Dataset |
|-------------|------|------|------|------|------|------|------|------|-------|---------|
| <b>93.3</b> | 68.8 | 91.5 | 88.7 | 74.9 | 69.9 | 68.1 | 66.6 | 66.6 | 89.9  | Average |



شکل ۱ - صحت طبقه‌بندی مربوط به پارامترهای  $\delta$ ,  $\rho$ ,  $\lambda$ ,  $\eta$  و  $P$  روی سه وظیفه ( $P4 \rightarrow P1$ ) از دیتاست پای، ( $D \rightarrow W$ ) از دیتاست آفیس-کلنک-10 و ( $Coil1 \rightarrow Coil2$ ) از دیتاست کویل را نشان می‌دهد.

درصد، (JDA) در دیتاست اعداد، ۹.۳ درصد و (SSTS) در دیتاست کویل، ۱.۸ درصد بهتر عمل می‌کند. با توجه به نتایج می‌توان نتیجه گرفت که KEDA قابلیت زیادی در کاهش اختلاف دامنه در مسائل انطباق دامنه دارد.

#### ۴-۱- حساسیت سنجی پارامترها

در روش پیشنهادی KEDA، شش پارامتر  $\rho$ ،  $\delta$ ،  $\lambda$ ،  $\eta$  و  $P$  متفاوت برای تنظیم وجود دارد: پارامترهای نسبت  $\gamma$  و  $\delta$  در رابطه‌ی (۱۱)، پارامترهای نسبت  $\rho$ ،  $\lambda$  و  $\eta$  در رابطه‌ی (۲۸) و پارامتر  $P$  (تعداد نزدیک‌ترین نمونه‌های همسایه‌ی هر نمونه در گراف همسایگی). حساسیت پارامترها روی سه وظیفه (P4→P1) از دیتاست پای، (D→W) از دیتاست آفیس-کلتک-۱۰ و (Coil1→Coil2) از دیتاست کویل ارزیابی شده است و نتایج ارزیابی‌ها نشان‌دهنده‌ی مقاومت عملکرد KEDA در مقابل تغییرات مقادیر پارامترها در محدوده وسیع است (شکل ۱). پارامترهای  $\rho$ ،  $\delta$ ،  $\lambda$  و  $\eta$  در محدوده ۰.۱ تا ۱.۰ و پارامتر  $P$  با مقادیر {۲، ۴، ۸، ۱۶، ۳۲، ۶۴} مورد ارزیابی قرار گرفته‌اند. پارامتر  $\delta$ ، ضریب ماتریس گرافی تفاوت در رابطه‌ی (۱۱) است. همانطور که در شکل (۱) دیده می‌شود در سه وظیفه (P4→P1) از دیتاست پای، (D→W) از دیتاست آفیس-کلتک-۱۰ و (Coil1→Coil2) از دیتاست کویل) دقت طبقه‌بندی برای مقادیر مختلف  $\delta$  تقریباً یکسان است و این حاکی از حساسیت پایین KEDA نسبت به این پارامتر است. پارامتر  $\gamma$ ، ضریب ماتریس لاپلاس گرافی شباهت در رابطه‌ی (۱۱) است. در وظیفه‌ی (D→W) از دیتاست آفیس-کلتک-۱۰، در مقادیر پایین  $\gamma$  دقت طبقه‌بندی پایین است و در واقع این موضوع را بیان می‌کند که شباهت داده‌ها در این پایگاه داده بیشتر است و وقتی فاکتور شباهت داده‌ها، ضریب بیشتری می‌گیرد نتیجه‌ی بهتری در طبقه‌بندی به دست می‌دهد. همچنین در دو وظیفه دیگر ((P4→P1) از دیتاست پای و (Coil1→Coil2) از دیتاست کویل) به جز در مقادیر نزدیک به ۱.۰ پارامتر  $\gamma$ ، دقت طبقه‌بندی تقریباً یکنواخت است. پارامتر  $\eta$ ، ضریب مربع نرم  $f$  است و همانطور که در شکل (۱) نیز مشاهده می‌شود در هر سه دیتاست دقت طبقه‌بندی با افزایش مقدار  $\eta$  کاهش می‌یابد ولی این کاهش، زیاد محسوس نیست. پارامتر  $\lambda$ ، ضریب انطباق توزیع متعادل است و همانطور که از شکل برمی‌آید دقت طبقه‌بندی در هر سه وظیفه برای مقادیر مختلف  $\lambda$  تقریباً یکنواخت است. این یکنواختی

روش SSTCA، علاوه بر حداقل کردن حداکثر اختلاف میانگین، یک نگاشت انجام می‌دهد که وابستگی بین ویژگی‌های استخراج شده و برچسب‌های کلاسی را افزایش می‌دهد و با حفظ ساختار هندسی محلی دامنه‌ها، از تغییر شکل زیاد توپولوژی دامنه‌ها ممانعت می‌کند. روش SSTS، داده‌های برچسب‌دار معادل در دامنه‌های منبع و هدف را به دست می‌آورد و با استفاده از ساختار کلی داده‌های بدون برچسب، زیرفضای مستقل از دامنه ایجاد می‌کند و دامنه‌ها را به این زیرفضا نگاشت می‌کند. در پایگاه‌داده اعداد، روش پیشنهادی مقاله با روش‌های JDA، TJM، VDA، SSTS، SHFA، SSTA، KMA مقایسه شده است. در پایگاه‌داده کویل، روش پیشنهادی مقاله با روش‌های SSTA، SODA، SDA، KMA، SLDA، FME، GLPP، DLPP و SODA مقایسه شده است. روش SLDA از دو مرحله تشکیل می‌شود که به صورت تکراری انجام می‌شوند: (۱) محاسبه‌ی ماتریس نگاشت، (۲) محاسبه‌ی ماتریس برچسب F داده‌های نگاشت شده. روش DLPP توسعه یافته‌ی الگوریتم LPP است که زیرفضایی را با افزایش فاصله‌ی بین کلاسی و کاهش فاصله‌ی داده‌های نزدیک به هم درون کلاسی ایجاد می‌کند و با استفاده از این زیرفضا، یک نگاشت محلی تفکیک‌کننده<sup>۵۸</sup> حافظ توپولوژی انجام می‌دهد. روش GLPP، توپولوژی داده‌ها را به دو زیر-توپولوژی<sup>۵۹</sup>، فاکتورهای آماری و فاکتورهای پویا<sup>۶۰</sup> تقسیم می‌کند و با استفاده از گراف لاپلاسی این دو فاکتور، هندسه‌ی محلی و جهانی داده‌ها را در انطباق حفظ می‌کند. روش‌های SODA و SDA شکل‌های نیمه نظارت شده روش LDA<sup>۶۱</sup> هستند. SDA از داده‌های برچسب‌دار برای افزایش تفکیک پذیری بین کلاسی و از داده‌های بدون برچسب برای یافتن ساختار هندسی داده‌ها استفاده می‌کند. روش SODA با انتشار برچسب مخصوص طراحی شده، اطلاعات داده‌های برچسب‌دار را به داده‌های بدون برچسب انتقال می‌دهد و یک ماتریس نگاشت داده‌ها از طریق حداکثر کردن تابع هدف آنالیز تفکیک‌کننده متعامد<sup>۶۲</sup> به دست می‌آورد. روش FME توسعه یافته‌ی الگوریتم LGC<sup>۶۳</sup> است که از اطلاعات داده‌های برچسب‌دار استفاده می‌کند، توپولوژی هندسی داده‌ها را از طریق نمونه‌های برچسب‌دار و بدون برچسب به دست می‌آورد و با تابع رگرسیون خطی، یک نگاشت برای داده‌های جدید دیده نشده ایجاد می‌کند.

KEDA در بیشتر وظیفه‌ها (۲۳ از ۳۶) بهترین عملکرد را نسبت به روش‌های دیگر دارد و میانگین عملکرد ۸۱.۲ درصدی دارد. KEDA نسبت به بهترین روش (OT-GL) در دیتاست آفیس+کلتک-۱۰، ۴.۸ درصد، (KMA) در دیتاست پای، ۲.۸

## مراجع

- [1] S.P. Singh and U.C. Jaiswal, "Machine Learning for Big Data: A New Perspective," International Journal of Applied Engineering Research, Vol.13, No.5, pp.2753-2762. 2018.
- [2] M. Qiu, L. Yang, F. Ji, W. Zhao, W. Zhou, J. Huang, H. Chen, W.B. Croft, and W. Lin, "Transfer Learning for Context-Aware Question Matching in Information-seeking Conversations in E-commerce," arXiv preprint arXiv: 1806.05434. 2018.
- [3] M. Müller, A. Dosovitskiy, B. Ghanem and V. Koltun, "Driving policy transfer via modularity and abstraction," arXiv preprint arXiv: 1804.09364. 2018.
- [4] J. Yu, M. Qiu, J. Jiang, J. Huang, S. Song, W. Chu and H. Chen, "Modelling domain relationships for transfer learning on retrieval-based question answering systems in e-commerce," In Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining, pp. 682-690, 2018.
- [5] S. Latif, R. Rana, S. Younis, J. Qadir, and J. Epps, "Transfer learning for improving speech emotion classification accuracy," arXiv preprint arXiv: 1801.06353, 2018.
- [6] A.M. Azab, J. Toth, L.S. Mihaylova and M. Arvaneh, "A review on transfer learning approaches in brain-computer interface," Signal Processing and Machine Learning for Brain-Machine Interfaces, pp.81-98, 2018.
- [7] J. Wang, W. Feng, Y. Chen, H. Yu, M. Huang, and P. S. Yu. "Visual domain adaptation with manifold embedded distribution alignment." In 2018 ACM Multimedia Conference on Multimedia Conference, pp. 402-410. ACM, 2018.
- [8] M. Baktashmotlagh, M.T. Harandi, B.C. Lovell, and M. Salzmann, "Unsupervised domain adaptation by domain invariant projection," In Proceedings of the IEEE International Conference on Computer Vision, pp.769-776, 2013.
- [9] M. Long, J. Wang, G. Ding, S.J. Pan, and S.Y. Philip, "Adaptation regularization: A general framework for transfer learning," IEEE Transactions on Knowledge and Data Engineering, Vol.26, No.5, pp.1076-1089. 2014.
- [10] M. Arvaneh, and T. Tanaka, "Brain-computer interfaces and electroencephalogram: basics and practical issues," Signal Processing and Machine Learning for Brain-Machine Interfaces, 2018.
- [11] A. Asgarian, P. Sobhani, J.C. Zhang, M. Mihailescu, A. Sibilila, A.B. Ashraf, and B. Taati, "A Hybrid Instance-based Transfer Learning Method," arXiv preprint arXiv: 1812.01063. 2018.
- [12] S. Chen, F. Zhou, and Q. Liao. "Visual domain adaptation using weighted subspace alignment." In 2016 IEEE Visual Communications and Image Processing (VCIP), pp. 1-4, 2016.
- [13] N. Courty, R. Flamary, D. Tuia, and A. Rakotomamonjy, "Optimal transport for domain adaptation," IEEE transactions on pattern analysis and machine intelligence, Vol.39, No.9, pp.1853-1865, 2017.
- [14] M. Long, J. Wang, G. Ding, J. Sun and S. YuPhilip, "Transfer feature learning with joint distribution adaptation", IEEE international conference on computer vision, pp. 2200-2207, 2013.
- [15] J. Tahmoresnezhad and S. Hashemi, "Visual domain adaptation via transfer feature learning", Knowledge and Information Systems, Vol.50, No.2, pp.585-605, 2016.
- [16] E. Sangineto, G. Zen, E. Ricci and N. Sebe, "We are not all equal: Personalizing models for facial expression analysis with

حاکمی از آن است که فاکتور انطباق توزیع متعادل در طبقه‌بندی دیتاست‌های مختلف با وجود مقادیر مختلف  $\lambda$  یکسان عمل می‌کند و با توجه به میزان اختلاف توزیع دامنه‌های منبع و هدف انطباق توزیع شرطی و حاشیه‌ای متناسب با آن اختلاف را انجام می‌دهد. پارامتر  $\rho$ ، نیز ضریب تنظیم لاپلاسی است. با افزایش مقدار  $\rho$ ، دقت طبقه‌بند در هر سه وظیفه افزایش می‌یابد و نشان دهنده‌ی آن است که فاکتور حفظ توپولوژی دامنه تاثیر مثبت در دقت طبقه‌بندی دارد. پارامتر  $P$  نیز تعداد نزدیک‌ترین نمونه‌های همسایه‌ی هر نمونه در گراف همسایگی است. همانطور که در شکل (۱) دیده می‌شود با افزایش مقدار  $P$ ، دقت طبقه‌بند در هر سه وظیفه کاهش می‌یابد زیرا نمونه‌های کاملاً متفاوت از هم در گراف به یکدیگر متصل می‌شوند.

## ۵- نتیجه گیری

در این مقاله، یک روش یادگیری انتقالی نیمه نظارت شده با عنوان انطباق دامنه کرنلی و تطبیق توزیع متعادل (KEDA) معرفی شد. این روش از چهار مولفه اصلی، برای یادگیری انتقالی بین دامنه‌های منبع و هدف به صورت نیمه نظارت شده، تشکیل شده است که هدف حداقل کردن مجموع این چهار مولفه‌ی اصلی روی داده‌های نگاشت شده با انطباق هندسی کرنلی است. این چهار مولفه عبارتند از: (۱) میانگین مربع خطا برای ارزیابی عملکرد طبقه‌بند، (۲) مربع نرم طبقه‌بند برای رده‌بندی طبقه‌بندها جهت انتخاب بهترین طبقه‌بند و جلوگیری از ایجاد جواب‌های بدیهی، (۳) گراف لاپلاسی برای حفظ ساختار هندسی و ماهیت دامنه‌ها در حین انطباق دامنه‌ها، (۴) انطباق توزیع متعادل برای انطباق توزیع‌های حاشیه‌ای و شرطی با دقت بالاتر و اهمیت خاص هر توزیع در تطبیق دامنه‌های منبع و هدف. این روش روی چهار دیتاست با اختلاف توزیع قابل توجه ارزیابی شده است و کارایی قابل ملاحظه‌ای نسبت به روش‌های جدید انطباق دامنه و یادگیری انتقالی دارد.

برای ادامه راه، می‌توان روش‌هایی را به عنوان پیش‌مرحله، برای انتخاب دامنه‌ی منبع بهینه برای دامنه‌ی هدف موردنظر، به کار برد تا از منابع مناسبی برای یادگیری طبقه‌بند جهت برچسب‌گذاری داده‌های بدون برچسب بهره گرفت و از انطباق دامنه‌هایی که اختلاف محسوسی در حوزه‌ی کاربرد و توزیع دارند، ممانعت شود.

- Transactions on Geoscience and Remote Sensing, Vol.53, No.7, pp.3550-3564, 2015.
- [34] B. Gong, Y. Shi, F. Sha, and K. Grauman, "Geodesic flow kernel for unsupervised domain adaptation," In 2012 IEEE Conference on Computer Vision and Pattern Recognition, pp.2066-2073, 2012.
- [35] I. Jolliffe, "Principal component analysis" Wiley, vol. 2, pp. 433-459, 2002.
- [36] J. Hoffman, E. Rodner, J. Donahue, T. Darrell and K. Saenko, "Efficient learning of domain-invariant image representations," *arXiv preprint arXiv: 1301.3224*, 2013.
- [37] S. Herath, M. Harandi, and F. Porikli, "Learning an invariant hilbert space for domain adaptation," In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 3845-3854, 2017.
- [38] Y.H. Hubert Tsai, Y.R. Yeh, and Y.C. Frank Wang, "Learning cross-domain landmarks for heterogeneous domain adaptation," In Proceedings of the IEEE conference on computer vision and pattern recognition, pp.5081-5090, 2016.
- [39] W. Li, L. Duan, D. Xu and I.W. Tsang, "Learning with augmented features for supervised and semi-supervised heterogeneous domain adaptation," IEEE Transactions on Pattern analysis and machine intelligence, Vol.36, No.6, pp.1134-1148, 2014.
- [40] L.A. Pereira, and R. da Silva Torres, "Semi-supervised transfer subspace for domain adaptation," Pattern Recognition, Vol.75, pp.235-249, 2018.
- [41] W. Yu, X. Teng, and C. Liu, "Face recognition using discriminant locality preserving projections," Image and Vision Computing, Vol.24, No.3, pp.239 – 248, 2006.
- [42] S. Huang, A. Elgammal, L. Huangfu, D. Yang, and X. Zhang, "Globality-locality preserving projections for biometric data dimensionality reduction," In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition Workshops (CVPRW), pp.15–20, 2014.
- [43] F. Nie, D. Xu, I.W.H Tsang, and C. Zhang, "Flexible manifold embedding: A framework for semi-supervised and unsupervised dimension reduction," IEEE Transactions on Image Processing, Vol.19, No.7, pp.1921–1932, 2010.
- [44] S. Wang, J. Lu, X. Gu, H. Du and J. Yang, "Semi-supervised linear discriminant analysis for dimension reduction and classification," Pattern Recognition, Vol.57, pp.179-189, 2016.
- [45] F. Nie, S. Xiang, Y. Jia, and C. Zhang, "Semi-supervised orthogonal discriminant analysis via label propagation," Pattern Recognition, Vol.42, No.11, pp.2615 – 2627, 2009.
- [46] J. Tahmoresnezhad and S. Hashemi. "Transductive transfer learning via maximum margin criterion." Scientia Iranica. Transaction D, Computer Science & Engineering, Electrical, Vol.23, no.3, pp.1239, 2016.
- transductive parameter transfer," In Proceedings of the 22nd ACM international conference on Multimedia, pp. 357-366, 2014.
- [17] F. Li, S.J. Pan, O. Jin, Q. Yang, and X. Zhu, "Cross-domain co-extraction of sentiment and topic lexicons," In Proceedings of the 50th Annual Meeting of the Association for Computational Linguistics: Long Papers, Vol.1, pp. 410-419, 2012.
- [۱۸] الهه قولنجی، جعفر طهمورث نژاد "تطبيق دامنه‌های بصری با استفاده از تطبيق خصوصيات و مدل"، مجله مهندسی برق دانشگاه تبریز. جلد ۴۹، شماره ۱، بهار ۱۳۹۸.
- [19] S. Rezaei, and J. Tahmoresnezhad, "Discriminative and domain invariant subspace alignment for visual tasks," Iran Journal of Computer Science, pp.1-12, 2019.
- [20] W. Wei, D. Meng, Q. Zhao, Z. Xu, and Y. Wu, "Semi-Supervised Transfer Learning for Image Rain Removal," In Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition, pp. 3877-3886, 2019.
- [21] P. U. Diehl, and M. Cook. "Unsupervised learning of digit recognition using spike-timing-dependent plasticity." Frontiers in computational neuroscience, Vol.9, pp.99, 2015.
- [22] M. Belkin, P. Niyogi, and V. Sindhwani, "Manifold regularization: A geometric framework for learning from labeled and unlabeled examples," Journal of machine learning research, No.Nov, pp.2399-2434. 2006.
- [23] D. Tuia, G. Camps-Valls, "Kernel manifold alignment for domain adaptation," PLoS ONE, Vol.11, No.2, 2016.
- [24] C. Deng, H. Xiaofoei, and H. Jiawei, "Semi-supervised discriminant analysis," IEEE 11th International Conference on Computer Vision (ICCV), pp.1–7, 2007.
- [25] S. Ben-David, J. Blitzer, K. Crammer, and F. Pereira, "Analysis of representations for domain adaptation," In Advances in neural information processing systems, pp.137–144, 2007.
- [26] 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.
- [27] G. Griffin, A. Holub and P. Perona, "Caltech-256 object category dataset", Technical Report 7694, 2007.
- [28] J. J. Hull, "A database for handwritten text recognition research", IEEE Trans. Pattern Anal. Mach. Intell, vol. 16, no. 5, pp. 550–554, 1994.
- [29] 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.
- [30] S. A. Nene, S. K. Nayar and H. Murase, "Columbia object image library (COIL-20)", Technical Report CUCS, 1996.
- [31] 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.
- [32] M. Long, J. Wang, G. Ding, J. Sun, and P.S. Yu, "Transfer joint matching for unsupervised domain adaptation," In Proceedings of the IEEE conference on computer vision and pattern recognition, pp.1410-1417, 2014.
- [33] G. Matasci, M. Volpi, M. Kanevski, L. Bruzzone, and D. Tuia, "Semi-supervised transfer component analysis for domain adaptation in remote sensing image classification," IEEE

## پاورقی‌ها:

- |  |   |
|--|---|
| <sup>33</sup> Task   | <sup>1</sup> Office-caltech-10                        |
| <sup>34</sup> Reproducing Kernel Hilbert Space                   | <sup>2</sup> Digits                                   |
| <sup>35</sup> Loss function                                      | <sup>3</sup> Pie                                      |
| <sup>36</sup> Laplacian graph                                    | <sup>4</sup> Coil                                     |
| <sup>37</sup> Mean Square Error                                  | <sup>5</sup> Machine learning                         |
| <sup>38</sup> Squared norm                                       | <sup>6</sup> Transfer learning                        |
| <sup>39</sup> Representer theorem                                | <sup>7</sup> Computer vision                          |
| <sup>40</sup> Frobenious norm                                    | <sup>8</sup> Marginal                                 |
| <sup>41</sup> Kernel Manifold Alignment                          | <sup>9</sup> Conditional                              |
| <sup>42</sup> Global   | <sup>10</sup> Multi modal                             |
| <sup>43</sup> Semi-supervised Discriminant Analysis              | <sup>11</sup> Cross-lingual retrieval                 |
| <sup>44</sup> Maximum Mean Discrepancy                           | <sup>12</sup> Kernelized Domain Adaptation            |
| <sup>45</sup> Semi-Supervised Transfer Component Analysis        | <sup>13</sup> Visual                                  |
| <sup>46</sup> Max-Margin Domain Transforms                       | <sup>14</sup> Instance-based                          |
| <sup>47</sup> Invariant Latent Space                             | <sup>15</sup> Hybrid instance-based transfer learning |
| <sup>48</sup> Cross-Domain Landmark Selection                    | <sup>16</sup> Feature-based                           |
| <sup>49</sup> Semi-supervised Heterogeneous Feature Augmentation | <sup>17</sup> Knowledge transfer                      |
| <sup>50</sup> Semi-Supervised Transfer Subspace                  | <sup>18</sup> Weighted subspace alignment             |
| <sup>51</sup> Discriminant Locality Preserving Projections       | <sup>19</sup> Principal Component Analysis            |
| <sup>52</sup> Globality-Locality Preserving Projections          | <sup>20</sup> Optimal Transport                       |
| <sup>53</sup> Flexible Manifold Embedding                        | <sup>21</sup> Local transfer                          |
| <sup>54</sup> Semi-supervised Linear Discriminant Analysis       | <sup>22</sup> Joint Distribution Adaptation           |
| <sup>55</sup> Semi-supervised Orthogonal Discriminant Analysis   | <sup>23</sup> Visual Domain Adaptation                |
| <sup>56</sup> Max-margin framework                               | <sup>24</sup> Model/Parameter-based                   |
| <sup>57</sup> Unseen   | <sup>25</sup> Transductive parameter transfer         |
| <sup>58</sup> Discriminant                                       | <sup>26</sup> Vector-valued                           |
| <sup>59</sup> Sub-manifold                                       | <sup>27</sup> Relational-based                        |
| <sup>60</sup> Dynamic  | <sup>28</sup> Relational Adaptive bootstrapping       |
| <sup>61</sup> Linear Discriminant Analysis                       | <sup>29</sup> Sentiment analysis                      |
| <sup>62</sup> Orthogonal discriminant analysis                   | <sup>30</sup> Sentiment words                         |
| <sup>63</sup> Local and Global Consistency                       | <sup>31</sup> Semi-supervised                         |
|  | <sup>32</sup> Unsupervised                            |