

تاریخ دریافت مقاله: ۹۶/۱۲/۲۵

تاریخ پذیرش مقاله: ۹۷/۰۴/۰۲

کاهش خطای پیش‌بینی مدل‌های طبقه‌بند از طریق تطبیق توزیع عمومی و هندسی دامنه‌های بصری

الهه قولنجی

دانشجوی کارشناسی ارشد دانشکده مهندسی فناوری اطلاعات و کامپیوتر- دانشگاه صنعتی ارومیه- ارومیه- ایران
پست الکترونیکی: elahe.gholenjy@it.uut.ac.ir

جعفر طهمورث‌نژاد*

استادیار دانشکده مهندسی فناوری اطلاعات و کامپیوتر- دانشگاه صنعتی ارومیه- ارومیه- ایران
پست الکترونیکی: j.tahmores@it.uut.ac.ir

چکیده

کاهش خطای پیش‌بینی، تطبیق توزیع عمومی، تطبیق توزیع هندسی.

روش‌های تطبیق دامنه، با کاهش اختلاف بین دامنه‌ای، مدل‌هایی تطبیق‌پذیر بین نمونه‌های آموزشی و آزمون ایجاد می‌کنند. هدف این روش‌ها، یافتن یک طبقه‌بند بر اساس داده‌های آموزشی است به طوری که دارای بیشترین انطباق با نمونه‌های آزمون باشد. در این مقاله، یک روش دو مرحله‌ای با هدف حداقل‌سازی خطای طبقه‌بندی و حداکثرسازی سازگاری بین دامنه‌ای پیشنهاد شده است. روش پیشنهادی، ابتدا با ایجاد یک نمایش مشترک به کاهش اختلاف توزیع بین نمونه‌های آموزشی و آزمون پرداخته و سپس، یک مدل یادگیری با حداقل خطای پیش‌بینی در نمایش جدید ایجاد می‌کند. روش پیشنهادی، بر روی پایگاه داده‌های بصری شناخته‌شده از طریق طراحی آزمایش‌های مختلف مورد ارزیابی قرار گرفته است. نتایج نشان می‌دهند روش پیشنهادی عملکرد بهتری در پیش‌بینی برچسب نمونه‌های جدید، نسبت به روش‌های جدید حوزه تطبیق دامنه دارد.

واژه‌های کلیدی: طبقه‌بندی تصاویر، تطبیق دامنه،

۱- مقدمه

الگوریتم‌های طبقه‌بندی تصاویر و یادگیری ماشین، با ایجاد یک مدل بر روی داده‌های آموزشی، نمونه‌های موجود در مجموعه آزمون را برچسب‌گذاری می‌کنند. در این الگوریتم‌ها، توزیع داده‌های آموزشی و آزمون یکسان در نظر گرفته می‌شود. بنابراین، استفاده از الگوریتم‌های یادگیری ماشین در شرایطی که داده‌های آموزشی و آزمون دارای توزیع غیر یکسان باشند، به ایجاد مدل یادگیری بهینه منجر نمی‌شود. فرض کنید دامنه منبع^۱ شامل مجموعه نمونه‌های آموزشی و دامنه هدف^۲، شامل مجموعه تصاویر گرفته‌شده توسط یک دوربین معمولی باشد، برای ایجاد مدلی دقیق توسط الگوریتم‌های یادگیری ماشین، دامنه هدف نیز باید شامل تصاویر دیگری باشد

1- Source domain
2- Target domain

* نویسنده مسئول

که توسط همان دوربین معمولی گرفته شده است. در این شرایط خصوصیات تصویر مانند شفافیت، کیفیت و نور مربوط به تصاویر آموزشی و آزمون یکسان بوده و بنابراین، دامنه‌های هدف و منبع دارای توزیع یکسان می‌باشند. بدین ترتیب، اگر از تصاویر گرفته شده توسط یک دوربین حرفه‌ای به عنوان دامنه هدف استفاده شود، به دلیل خصوصیات متفاوت تصاویر در دامنه منبع و دامنه هدف، تغییر توزیع بین دامنه‌ای ایجاد شده و کارایی مدل ایجاد شده توسط الگوریتم‌های یادگیری ماشین به شدت کاهش می‌یابد [۱].

به طور کلی، در الگوریتم‌های طبقه‌بندی تصاویر و یادگیری ماشین نیاز است داده‌های برچسب‌داری از هر دامنه آموزشی که شامل مجموع داده‌هایی با توزیع مشخص است، در دسترس باشد تا بتوان مدل یادگیری با صحت مناسب برای داده‌های جدید از همان توزیع ایجاد کرد. این در حالی است که در بسیاری از موارد، نمونه‌های برچسب‌داری از دامنه‌های آموزشی در دسترس نبوده و همچنین، برچسب‌گذاری دستی نمونه‌ها، وقت‌گیر، پرهزینه و یا غیرممکن می‌باشد. در این شرایط استفاده از الگوریتم‌های یادگیری ماشین، کارآمد نبوده و چالش اصلی، یافتن روشی برای ایجاد یک مدل یادگیری سازگار با تغییرات توزیع بین دامنه‌ای می‌باشد. روش‌های تطبیق دامنه^۲ برای کاهش اختلاف توزیع بین دامنه‌های منبع و هدف پیشنهاد شده‌اند [۲]. در این روش‌ها، مدل یادگیری ایجاد شده بر روی نمونه‌های آموزشی، با ساختار داده‌های آزمون تطبیق می‌یابد. به عبارت دیگر، در این روش‌ها، دانش کسب شده توسط مدلی که بر روی داده‌های آموزشی ایجاد شده است، به یک دامنه دیگر که دارای داده‌های جدید با توزیع متفاوت است، انتقال می‌یابد.

در سال‌های اخیر، روش‌های تطبیق دامنه در حوزه‌های مختلف یادگیری ماشین، به دلیل وجود مسئله اختلاف توزیع بین دامنه‌ای و همچنین، کمبود یا عدم وجود داده برچسب‌دار در تمام دامنه‌ها، کاربردهای وسیعی داشته

3- Domain adaptation

است. از جمله این کاربردها می‌توان به حوزه‌های تحلیل احساسات [۳، ۴]، دسته‌بندی متون [۵، ۶]، تشخیص چهره [۷، ۸] و تشخیص رویداد [۹، ۱۰] اشاره کرد. مشکل تغییر بین دامنه‌ای در مسائل بینایی ماشین، شامل اختلاف در دو توزیع حاشیه‌ای و توزیع شرطی می‌باشد [۱۱، ۱۲]. در اختلاف توزیع حاشیه‌ای، دامنه‌های تصاویر دارای خصوصیات یکسانی می‌باشند، در حالی که احتمال وقوع هر یک از این خصوصیات در دو دامنه متفاوت می‌باشد. در اختلاف توزیع شرطی بین دامنه‌های بصری (دامنه‌های تصاویر)، با وجود این که دامنه‌ها دارای مجموعه برچسب‌های یکسانی می‌باشند، مدل یادگیری به دست آمده برچسب‌های متفاوتی برای نمونه‌های یکسان از دو دامنه منبع و هدف، پیش‌بینی می‌کند.

روش پیشنهادی در این مقاله، روش کاهش خطای پیش‌بینی مدل‌های طبقه‌بند از طریق تطبیق توزیع عمومی و هندسی دامنه‌ها^۴ (EMA) برای حل مشکل تغییر دامنه در دامنه‌های بصری می‌باشد. در این روش، با فرض وجود داده‌های آموزشی برچسب‌دار و داده‌های آزمون بدون برچسب، یک روش دو مرحله‌ای پیشنهاد شده است که به ایجاد یک مدل تطبیق‌پذیر بین دامنه‌ای با حداقل خطای پیش‌بینی می‌پردازد. در روش پیشنهادی، ابتدا، برای کاهش اختلاف توزیع بین دامنه‌های منبع و هدف، ساختار عمومی و محلی دامنه‌ها به‌طور هم‌زمان با یکدیگر تطبیق می‌یابند. ساختار عمومی دامنه‌ها، شامل اطلاعات آماری نمونه‌های دامنه مانند تعداد و میانگین نمونه‌ها و ساختار هندسی، شامل اطلاعات محلی نمونه‌ها (فاصله نمونه‌ها) می‌باشد. به‌طور کلی، مرحله اول شامل فرایندهایی به شرح زیر است: (۱) ایجاد تطبیق توزیع عمومی بین دامنه‌ای از طریق کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌های منبع و هدف، (۲) ایجاد تطبیق توزیع عمومی بین دامنه‌ای از طریق کاهش اختلاف توزیع شرطی بین دامنه‌های منبع و هدف، (۳) ایجاد تطبیق توزیع هندسی بین دامنه‌ها از

4- Prediction Error Minimization in classification models via global and geometrical distribution Adaptation (EMA)

طریق تطبیق ساختار هندسی داده‌های منبع و هدف. در مرحله دوم، روش پیشنهادی یک مدل طبقه‌بند با حداقل خطای پیش‌بینی بر روی داده‌های آموزشی ایجاد می‌کند. کارایی روش پیشنهادی بر روی انواع دامنه‌های بصری در شرایط مختلف مورد آزمایش قرار گرفته است و نتایج به‌دست آمده، با جدیدترین روش‌های حوزه تطبیق دامنه مقایسه شده است. نتایج، نشان‌دهنده برتری قابل‌ملاحظه الگوریتم پیشنهادی نسبت به انواع روش‌های شناخته‌شده در حوزه تطبیق دامنه می‌باشد.

در ادامه، بخش‌های مختلف مقاله به‌صورت زیر سازمان‌دهی شده است. بخش دوم، شامل مرور بر کارهای پیشین و بخش سوم، شامل شرح تفصیلی روش پیشنهادی می‌باشد. در بخش چهارم، پایگاه داده‌های مورد ارزیابی و در بخش پنجم، نتایج ارزیابی شرح داده شده است. در انتها، نتیجه‌گیری و ارائه پیشنهادهایی برای ادامه کار بیان شده است.

۲- کارهای پیشین

مسئله تطبیق دامنه، با هدف کاهش اختلاف توزیع بین دامنه‌ای در دو نوع تطبیق دامنه نیمه نظارت‌شده^۵ و تطبیق دامنه بدون نظارت^۶ انجام می‌گیرد. در تطبیق دامنه نیمه نظارت‌شده، تمام نمونه‌های دامنه منبع دارای برچسب می‌باشند، در حالی که تعداد محدودی از نمونه‌های دامنه هدف برچسب‌دار هستند. در مقابل، در تطبیق دامنه بدون نظارت، تمام نمونه‌های دامنه منبع برچسب‌دار و تمام نمونه‌های دامنه هدف، بدون برچسب می‌باشند. به‌طور کلی، روش‌های تطبیق دامنه، به سه دسته زیر تقسیم می‌شوند.

(۱) روش‌های تطبیق دامنه از طریق انتخاب نمونه [۱۳]. در این روش‌ها، برای کاهش اختلاف توزیع، برای ایجاد مدل یادگیری نمونه‌هایی از دامنه منبع انتخاب می‌شوند که دارای حداقل اختلاف توزیع با نمونه‌های دامنه هدف باشند. انتخاب لندمارک [۱۳]، نمونه‌ای از این روش‌هاست که

در آن، اختلاف توزیع بین دامنه‌های منبع و هدف توسط روش حداکثر اختلاف میانگین^۷ (MMD) محاسبه شده و سپس، نمونه‌هایی از دامنه منبع به عنوان مجموعه لندمارک انتخاب می‌شوند که بیشترین مشابهت را از نظر توزیع با نمونه‌های دامنه هدف داشته باشند.

(۲) روش‌های تطبیق دامنه از طریق تطبیق خصوصیات [۱۴-۱۹]. در روش‌های تطبیق خصوصیات، نمونه‌های دامنه‌های منبع و هدف به یک نمایش جدید نگاشت می‌شوند به طوری که در نمایش جدید، حداقل اختلاف توزیع بین دامنه‌ای وجود داشته باشد. روش‌های TCA [۱۴] و GFK [۱۵] نمونه‌های از روش تطبیق خصوصیات برای کاهش اختلاف توزیع حاشیه‌ای بین دامنه‌ای می‌باشند. در روش TCA، یک نمایش کم بعد مشترک بین دامنه‌ها ایجاد می‌شود که علاوه بر حداقل بودن اختلاف توزیع حاشیه‌ای بین دامنه‌ای در نمایش جدید، واریانس داده‌های دامنه‌های منبع و هدف نیز حداکثر می‌شود. روش GFK، زیرفضاهایی کم بعد از دامنه‌های منبع و هدف ایجاد می‌کند به طوری که اختلاف توزیع بین نمونه‌های دامنه منبع نسبت به نمونه‌های دامنه هدف در زیر فضاهای جدید، حداقل باشد. TJM [۱۷] یک روش تطبیق دامنه با ترکیبی از روش‌های انتخاب نمونه و تطبیق خصوصیات برای کاهش اختلاف توزیع حاشیه‌ای می‌باشد. در این روش، ابتدا نمایش کم بعدی از داده‌ها با حداقل سازی اختلاف توزیع حاشیه‌ای ایجاد شده و سپس، به نمونه‌هایی از دامنه منبع که دارای بیشترین مشابهت توزیع با نمونه‌های دامنه هدف باشند با استفاده از هنجار^۸، وزن بیشتری اختصاص داده می‌شود.

روش‌های JDA [۱۸] و VDA [۱۹] از جمله جدیدترین روش‌های تطبیق خصوصیات برای کاهش همزمان اختلاف توزیع مشترک (شرطی و حاشیه‌ای) بین دامنه‌های منبع و هدف می‌باشند. روش JDA، یک فضای کم بعد از دامنه‌های منبع و هدف توسط کاهش اختلاف توزیع مشترک بین دامنه‌ای ایجاد می‌کند. روش VDA، علاوه بر تطبیق

7- Maximum Mean Discrepancy (MMD)
8- Norm

5- Semi-supervised
6- Unsupervised

جدول ۱: متغیرها و تعاریف

| متغیر | تعریف | متغیر | تعریف | متغیر | تعریف |
|------------|-----------------------------------|------------------|--------------------------|-------------------------|------------------|
| X_s, X_t | نمونه‌های دامنه منبع و هدف | m | تعداد ابعاد فضای اصلی | M | ماتریس MMD |
| Y_s, Y_t | مجموعه برجسب‌های دامنه منبع و هدف | d | تعداد ابعاد فضای جدید | L | ماتریس لاپلاسیان |
| n_s, n_t | تعداد نمونه‌های دامنه منبع و هدف | K | ماتریس کرنل | H | ماتریس مرکزیت |
| X | مجموعه کل داده‌ها | $P_s(Y_s X_s)$ | توزیع شرطی دامنه منبع | I | ماتریس همانی |
| C | تعداد طبقاتی دامنه منبع و هدف | $P_t(Y_t X_t)$ | توزیع شرطی دامنه هدف | σ, β, θ | پارامترهای تنظیم |
| $Ps(Xs)$ | توزیع حاشیه‌ای دامنه منبع | $P_t(X_t)$ | توزیع حاشیه‌ای دامنه هدف | I | تابع خطا |

داده‌ها، جهت کاهش اختلاف توزیع هندسی بین دامنه‌ها بهره گرفته می‌شود. سپس، با تعریف یک تابع خطا، سعی شده است خطای پیش‌بینی مدل بر روی داده آموزشی، حداقل شود. در ادامه، مراحل روش پیشنهادی، به تفصیل بیان می‌شود. جدول ۱، شامل متغیرهای مورد استفاده در مقاله و تعاریف مربوطه است.

۳-۱. کاهش بعد توسط تطبیق توزیع عمومی و هندسی بین دامنه‌های منبع و هدف

در این مرحله، به دنبال یافتن یک نگاشت بهینه به فضای کم بعد هستیم که در این فضای کم بعد، به طور همزمان اختلاف توزیع عمومی و هندسی دامنه‌های منبع و هدف به حداقل رسانده شود. برای کاهش بعد، از روش تحلیل اجزای اصلی^۹ (PCA) [۲۴] که یک روش پایه برای کاهش بعد می‌باشد، استفاده شده است. روش PCA، با شرط حداقل‌سازی خطای بازسازی داده‌ها را به یک زیرفضای کم بعد نگاشت می‌دهد. شرط حداقل‌سازی خطا در روش PCA، با حداکثرسازی واریانس نمونه‌ها در زیرفضای جدید به دست می‌آید. با فرض تعریف تابع نگاشت AER^{m*d} برای نگاشت نمونه‌ها به زیرفضای جدید، تابع هدف روش PCA به صورت رابطه (۱) تعریف می‌شود.

$$\max \text{tr}(A^T X H X^T A) \quad (1)$$

بدین ترتیب، داده‌های ورودی $X = [X_s, X_t]$ $X \in \mathbb{R}^{n*m}$ که تعداد کل نمونه‌های دامنه‌های منبع و هدف است) توسط ماتریس نگاشت AER^{m*d} ، از فضای m بعدی به

توزیع مشترک بین دامنه‌ای، از خوشه‌بندی نمونه‌های دامنه منبع برای افزایش صحت مدل یادگیری بهره می‌برد [۲۰]. روش‌های تطبیق دامنه از طریق تطبیق مدل [۲۱]، [۲۲]، [۲۳]. در این روش‌ها، هدف، سازگاری طبقه‌بند ایجاد شده بر روی دامنه منبع با نمونه‌های دامنه هدف، بدون تغییر فضای نمایش می‌باشد. روش ARTL [۲۲] نمونه‌ای از روش‌های تطبیق مدل است که یک طبقه‌بند تطبیق‌پذیر ایجاد می‌کند که با توزیع مشترک و توزیع هندسی بین دامنه‌ای منطبق بوده و دارای حداقل خطای پیش‌بینی است.

روش پیشنهادی در این مقاله، یک روش تطبیق دامنه برای دامنه‌های بصری با بهره‌گیری از روش‌های تطبیق خصوصیات و تطبیق مدل می‌باشد. در این روش یک مدل طبقه‌بند تطبیق‌پذیر توسط کاهش اختلاف توزیع حاشیه‌ای و شرطی و همچنین، تطبیق ساختار هندسی نمونه‌های دامنه‌های منبع و هدف ایجاد می‌شود که دارای حداقل خطای پیش‌بینی می‌باشد.

۳- روش پیشنهادی

روش پیشنهادی EMA، یک روش دومرحله‌ای برای ایجاد یک مدل پیش‌بینی با حداقل خطا از طریق کاهش همزمان اختلاف توزیع عمومی و هندسی دامنه‌های منبع و هدف است. در این روش، ابتدا داده‌های دامنه‌های منبع و هدف به یک فضای کم بعد نگاشت می‌شوند که در این فضای جدید، از اطلاعات عمومی داده‌ها برای کاهش اختلاف توزیع شرطی و حاشیه‌ای و همچنین از اطلاعات محلی

9- Principle component analysis

10- Reconstruction error

که مقادیر ماتریس‌های ضرایب M_0 و M_c به ترتیب، به صورت رابطه (۴) و رابطه (۵) محاسبه می‌شوند.

$$(M_0)_{ij} = \begin{cases} \frac{1}{n_s n_t} & \text{if } x_i, x_j \in D_s \\ \frac{1}{n_t n_t} & \text{if } x_i, x_j \in D_t \\ -\frac{1}{n_s n_t} & \text{otherwise} \end{cases} \quad (4)$$

$$(M_c)_{ij} = \begin{cases} \frac{1}{n_s^c n_s^c} & \text{if } x_i, x_j \in D_s^c \\ \frac{1}{n_t^c n_t^c} & \text{if } x_i, x_j \in D_t^c \\ -\frac{1}{n_s^c n_t^c} & \text{otherwise} \end{cases} \quad (5)$$

که D_s و D_t ، دامنه‌های منبع و هدف هستند که به ترتیب، شامل تمام نمونه‌های منبع و هدف می‌باشند. همچنین، D_s^c و D_t^c نمونه‌هایی از دامنه‌های منبع و هدف هستند که متعلق به کلاس C بوده و n_s^c و n_t^c ، به ترتیب، تعداد نمونه‌های دامنه منبع و دامنه هدف در کلاس C می‌باشند. بدین ترتیب EMA، برای کاهش اختلاف توزیع عمومی بین دامنه‌های منبع و هدف، به دنبال یافتن ماتریس نگاشت A به صورتی است که بتواند روابط ۲ و ۳ را به حداقل رساند.

در روش EMA، برای محاسبه اختلاف توزیع شرطی بین دامنه‌های منبع و هدف توسط روش MMD، نیاز است تمامی برچسب‌های نمونه‌های منبع و هدف در دسترس باشد. این در حالی است که در آزمایش‌های بدون نظارت تمامی نمونه‌های هدف و در آزمایش‌های نیمه نظارت شده تعداد زیادی از نمونه‌های هدف بدون برچسب هستند. برای حل این مشکل، لازم است برچسب‌های اولیه‌ای برای نمونه‌های بدون برچسب هدف پیش‌بینی شود. از این رو، یک طبقه بند استاندارد (طبقه‌بند نزدیک‌ترین همسایه^{۱۲} (NN)) را بر روی داده‌های برچسب‌دار، آموزش داده شده و برای پیش‌بینی برچسب داده‌های بدون برچسب هدف مورد استفاده قرار می‌گیرد. به دلیل این‌که اختلاف توزیع زیادی بین دامنه‌های منبع و هدف وجود دارد، برچسب‌های پیش‌بینی شده برای دامنه هدف توسط طبقه‌بند استاندارد در ابتدای اجرای الگوریتم EMA، به احتمال زیاد نادرست می‌باشند. از این رو، برای بهبود صحت پیش‌بینی برچسب،

فضای d بعدی ($m > d$) نگاشت می‌شوند به طوری که در فضای جدید، واریانس داده‌های دامنه‌های منبع و هدف، به حداکثر رسانده شود (تعریف شده در رابطه (۱)). در رابطه (۱)، ماتریس مرکزیت H ، شامل اطلاعات مربوط به ساختار واریانس (پخشش) نمونه‌ها بوده و به صورت $H = I_{n_s+n_t} - \frac{1}{n_s+n_t} 11^T$ محاسبه می‌شود که I ماتریس همانی و 1، برداری از یک‌هاست.

برای تطبیق توزیع عمومی داده‌ها نیاز به محاسبه اختلاف توزیع حاشیه‌ای و شرطی بین دامنه‌های منبع و هدف در فضای جدید می‌باشد. توزیع حاشیه‌ای یک دامنه، به مجموعه احتمال وقوع مقادیر هر یک از خصوصیات نمونه‌های دامنه گفته می‌شود. همچنین، توزیع شرطی یک دامنه به مفهوم طبقه‌بند یا تابع پیش‌بینی به دست آمده برای یک دامنه است که به عبارت دیگر، به احتمال پیش‌بینی یک مجموعه برچسب به ازای یک مجموعه داده ورودی از یک دامنه گفته می‌شود. برای محاسبه اختلاف توزیع‌های حاشیه‌ای و شرطی، از روش غیر پارامتریک حداکثر اختلاف میانگین‌ها^{۱۱} (MMD) استفاده می‌شود. بر اساس روش MMD، برای تخمین اختلاف توزیع حاشیه‌ای در فضای جدید، اختلاف میانگین نمونه‌های نگاشت یافته دامنه منبع از میانگین نمونه‌های نگاشت یافته دامنه هدف است. همچنین، با در نظر گرفتن مجموعه کلاس C که شامل تمامی برچسب‌های متعلق به دامنه‌های منبع و هدف است (هر کلاس معادل یک برچسب است)، برای تخمین اختلاف توزیع شرطی در فضای جدید، اختلاف میانگین نمونه‌های نگاشت یافته دامنه منبع از میانگین نمونه‌های نگاشت یافته دامنه هدف در هر کلاس از مجموعه کلاس C محاسبه می‌شود. این محاسبات برای اختلاف توزیع حاشیه‌ای و شرطی به ترتیب با عناوین mrg و $cond$ توسط رابطه‌های (۲) و (۳) تعریف می‌شوند [۱۶، ۱۸].

$$mrg(P_s(X_s), P_t(X_t)) = \left\| \frac{1}{n_s} \sum_{i=1}^{n_s} A^T x_i - \frac{1}{n_t} \sum_{j=n_s+1}^{n_s+n_t} A^T x_j \right\|^2 = \text{tr}(A^T X M_0 X^T A) \quad (2)$$

$$cond(P_s(Y_s|X_s), P_t(Y_t|X_t)) = \left\| \frac{1}{n_s^c} \sum_{x_i \in X_s^c} A^T x_i - \frac{1}{n_t^c} \sum_{x_i \in X_t^c} A^T x_i \right\|^2 = \text{tr}(A^T X M_c X^T A) \quad (3)$$

11- Maximum mean discrepancy (MMD)

12- Nearest neighbor

الگوریتم پیشنهادی به صورت تکرار شونده می باشد. در هر تکرار با کاهش اختلاف بین دامنه های منبع و هدف، صحت پیش بینی برچسب برای نمونه های بدون برچسب هدف افزایش می یابد.

همچنین EMA، برای کاهش اختلاف توزیع هندسی بین دامنه ها، نیاز به جمع آوری اطلاعات محلی نمونه های هر دو دامنه دارد [۲۵]. براساس فرض منیفولد [۲۶]، نمونه هایی که در فضای نمایش از نظر توزیع هندسی به یکدیگر نزدیک می باشند، دارای برچسب یکسان هستند. بدین ترتیب در مرحله تطبیق توزیع هندسی بین دامنه های منبع و هدف، روش EMA به دنبال یافتن یک ماتریس نگاشت A است که نمونه های دامنه منبع و هدف را براساس ساختار هندسی به زیر فضای جدید انتقال دهد. از همین رو، یک گراف همسایگی بر روی تمامی نمونه ها ایجاد می شود که شامل $n_s + n_t$ گره می باشد. به عبارت دیگر، هر گره در گراف، نشانگر یک نمونه از مجموع نمونه های دامنه های منبع و هدف است. در این گراف، k نزدیک ترین همسایه هر گره مشخص شده و به گره مورد نظر وصل می شود. در ادامه، ماتریس وزن W با محاسبه فاصله اقلیدسی هر دو گره متصل به هم در گراف ایجاد می شود، بدین صورت که فاصله اقلیدسی برای دو گره x_i و x_j از گراف، به صورت $W_{ij} = e^{-\|x_i - x_j\|^2}$ محاسبه می شود. با در نظر گرفتن ماتریس قطری D به صورت، ماتریس لاپلاسین نمونه های دامنه های منبع و هدف به صورت تعریف می شود. $D_{ii} = \sum_{j=1}^{n_s+n_t} W_{ij}$ ، ماتریس لاپلاسین، شامل اطلاعات محلی تمامی نمونه ها می باشد. برای کاهش اختلاف توزیع هندسی بین دامنه های منبع و هدف، می بایست فاصله نمونه ها در زیر فضای جدید براساس فاصله محلی آن ها (جمع آوری شده در ماتریس وزن W) یا به عبارت بهتر، براساس ساختار لاپلاسین دامنه ها کاهش یابد. بدین ترتیب، محاسبه اختلاف توزیع هندسی دامنه های منبع و هدف به صورت $L=D-W$ رابطه (۶) تعریف می شود.

$$\text{lap}(X_s, X_t) = \sum_{i=1}^{n_s+n_t} (A^T x_i - A^T x_j) W_{ij} = \text{tr}(A^T X L X^T A) \quad (6)$$

روش EMA، برای کاهش اختلاف توزیع هندسی دامنه های منبع و هدف، به دنبال یافتن ماتریس نگاشت A به صورتی است که بتواند رابطه (۶) را به حداقل رساند. به طور کلی، با فرض $M = \sum_{i=0}^C M_i$ ، تابع هدف مرحله

$$\text{اول روش EMA، به صورت رابطه (۷) تعریف می شود.} \quad (7)$$

$$\min_{A^T X H X^T A = I} \text{tr}(A^T X (M + \theta L) X^T A + \beta \|A\|_F^2)$$

عبارت دوم در رابطه (۷)، نرم فریبینوس^{۱۳} تابع نگاشت بوده و برای کنترل پیچیدگی مدل، به تابع هدف اضافه شده و به صورت $\|A\|_F = \sqrt{\sum_{i=1}^n \sum_{j=1}^n |A_{ij}|^2}$ محاسبه می شود. برای حل راحت تر تابع هدف، می توان به جای حل مسئله در فضای جدید، به حل آن در فضای کرنلی پرداخت. اگر فرض شود تابع نگاشت برای نگاشت ω داده ها به فضای کرنلی است $(X \rightarrow \omega(X))$ ، در فضای کرنلی، نمایش کاملی از نمونه های توسط انجام ضرب داخلی روی نمونه ها در فضای اصلی نمونه ها ایجاد می شود. برای نمونه، در تابع کرنلی خطی^{۱۴} که در این مقاله مورد استفاده قرار گرفته شده است، ضرب داخلی نمونه ها نسبت به یکدیگر توسط $\omega(X) = X^T \cdot X$ محاسبه می شود. همچنین، در تابع کرنلی گوسی^{۱۵} نیز فاصله اقلیدسی بین نمونه ها به صورت $\omega(X) = e^{-\frac{\|x^T - x\|^2}{\sigma}}$ محاسبه می شود که σ ضریب نرمال سازی است. در این فضای کرنلی، با استفاده از ضرب داخلی شباهت بین داده ها بیشتر نشان داده شده و در نتیجه، ایجاد مدل در فضای کرنلی جدید، نسبت به فضای اصلی کارا تر خواهد بود. با تعریف تابع نگاشت جدید $V = A\omega(X)$ ، تابع هدف تعریف شده در رابطه (۷)، به صورت

$$\text{رابطه (۸) باز نویسی می شود.} \quad (8)$$

$$\min_{V K H K^T V = I} \text{tr}(V^T K (M + \theta L) K^T V + \beta \|V\|_F^2)$$

که θ پارامتر تنظیم برای تطبیق پذیری هندسی دامنه ها می باشد. همچنین، K ماتریس کرنل ایجاد شده بر روی تمامی نمونه های منبع و هدف است که به صورت خطی $K = X X^T$ محاسبه می شود. بنابراین، هدف EMA در مرحله اول روش پیشنهادی، یافتن تابع نگاشت V به طوری است

13- Frobenius norm

14- Linear

15- Gaussian

که بتواند اختلاف توزیع عمومی و هندسی بین دامنه‌های منبع و هدف (تعریف شده در رابطه (۸)) را به حداقل رساند. تابع نگاشت A ، با به دست آوردن d کوچکترین بردار ویژه توسط اعمال روش تجزیه مقادیر ویژه^{۱۶} بر روی تابع هدف تعریف شده در رابطه (۸) محاسبه می‌شود.

۳-۲. حداقل سازی خطای مدل پیش‌بینی

در مرحله اول از روش EMA، یک نمایش جدید از دامنه‌های منبع و هدف توسط کاهش اختلاف توزیع بین دامنه‌ای ایجاد شد. در مرحله دوم، برای بهبود دقت پیش‌بینی برچسب در روش EMA، به ایجاد یک تابع پیش‌بینی بهینه با حداقل سازی خطای پیش‌بینی پرداخته می‌شود. این تابع، در زیرفضای جدید، توسط نمونه‌های دامنه منبع آموزش داده شده و برای پیش‌بینی برچسب نمونه‌های دامنه هدف استفاده می‌شود. با کاهش خطای پیش‌بینی مدل در مرحله آموزش، پیش‌بینی برچسب داده‌های دامنه هدف توسط تابع پیش‌بینی به دست آمده، با دقت بالاتری انجام خواهد گرفت. بنابراین، هدف کلی مرحله دوم از روش EMA، یافتن تابع پیش‌بینی بهینه f به صورتی است که خطای پیش‌بینی بر روی نمونه‌های نگاشت یافته دامنه منبع به حداقل رسانده شود که این هدف، در رابطه

$$l = \sum_{x \in D_s} (\gamma(x) - f(x))^2 + \sigma \sum_{x \in X} \|f(x)\|_F^2 \quad (9)$$

که $\gamma(x)$ برچسب واقعی و $f(x)$ برچسب پیش‌بینی شده توسط تابع پیش‌بینی بهینه برای نمونه از دامنه منبع در زیرفضای جدید می‌باشد. همچنین، عبارت دوم برای کنترل پیچیدگی مدل به رابطه اضافه شده و σ ، پارامتر تنظیم است. برای حل رابطه (۹) در حالت کرنلی، تابع پیش‌بینی به صورت $f(x) = \sum_{i=1}^{n_s+n_t} \alpha_i k(x, x_i)$ [۲۷] تعریف می‌شود که پارامترهای طبقه‌بند و تابع کرنل می‌باشد. بنابراین، تابع هدف تعریف شده در رابطه (۹)، به صورت رابطه (۱۰) بازنویسی می‌شود.

$$l = (\gamma - \alpha K)^2 + \sigma \alpha K \alpha \quad (10)$$

که $\gamma = [\gamma_s] \in R^{(n_s+n_t) \times 1}$ شامل برچسب‌های دامنه

16- Eigendecomposition.

منبع و K ماتریس کرنل ایجاد شده بر روی نمونه‌های دامنه‌های منبع و هدف است. اگر مشتق رابطه (۱۰) نسبت به α ، گرفته شده و مساوی صفر قرار گیرد، تابع بهینه مرحله دوم، به صورت رابطه (۱۱) حاصل می‌شود.

$$\alpha = (K + \sigma I)^{-1} \gamma \quad (11)$$

هدف EMA در مرحله دوم روش پیشنهادی، یافتن پارامترهای طبقه‌بند α به صورتی است که بتواند خطای پیش‌بینی بر روی نمونه‌های آموزشی (تعریف شده در رابطه (۱۱)) را به حداقل رساند. خلاصه الگوریتم روش EMA در الگوریتم ۱ ارائه شده است.

۳-۳. تحلیل پیچیدگی زمانی

در این بخش پیچیدگی زمانی روش پیشنهادی، مورد ارزیابی قرار می‌گیرد. در مرحله اول، محاسبه ماتریس‌های M, K, L, H و a به پیچیدگی زمانی $O((n_s+n_t)^2)$ و حل رابطه بهینه مرحله اول (رابطه (۸)) توسط روش تجزیه مقادیر ویژه^{۱۷}، به پیچیدگی زمانی $O(m^2)$ نیاز دارد. همچنین، در مرحله دوم روش پیشنهادی، محاسبه ماتریس‌های a و K و همچنین یافتن پارامترهای طبقه‌بند α با پیچیدگی زمانی $O((n_s+n_t)^2)$ انجام می‌گیرد. به طور کلی، از آنجایی که $m \gg n_s+n_t$ ، پیچیدگی زمانی کلی روش EMA به صورت $O((n_s+n_t)^2)$ می‌باشد.

۴- تنظیمات اولیه محیط آزمایش

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

۴-۱. معرفی مجموعه داده‌ها

کارایی روش پیشنهاد شده در این مقاله، بر روی دو پایگاه داده بصری^{۱۸} شناخته شده ارزیابی شده است: (۱) پایگاه داده آفیس^{۱۹} [۱۱] و کالتک^{۲۰} [۲۷] که شامل

17- Eigenvalue decomposition

18- Visual

19- Office

20-Caltech

الگوریتم ۱- الگوریتم روش کاهش خطای پیش‌بینی مدل‌های طبقه‌بند از طریق تطبیق توزیع عمومی و هندسی

دامنه‌ها (EMA)

Input: Source data X_s , Target data X_t , Source label Y_s , Subspace dimension d

Output: prediction function l , Target labels L_t

%First step

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

$$2. H = I - \frac{1}{n_s + n_t} \mathbf{1}\mathbf{1}^T$$

3. Compute $W_{ij} = e^{-|x_i - x_j|^2}$ where $(x_i, x_j) \in (X_s \cup X_t)$

4. Compute D via $D_{ii} = \sum_{j=1}^{n_s + n_t} W_{ij}$

$$5. L = D - W$$

$$6. M = M_0$$

Repeat until converge

7. Solve $\min_{A^T X H X^T A = I} \text{tr}(A^T X (M + \theta L) X^T A) + \beta \|A\|_F^2$ by eigendecomposition

8. Update pseudo target labels using a standard classifier NN trained on projected source data $\{AX_s, Y_s\}$

$$9. (M_c)_{ij} = \begin{cases} \frac{1}{n_s^c n_s^c} & \text{if } x_i, x_j \in D_s^c \\ \frac{1}{n_t^c n_t^c} & \text{if } x_i, x_j \in D_t^c \\ \frac{-1}{n_s^c n_t^c} & \text{otherwise} \end{cases}$$

$$10. M = M_0 + M_c$$

End repeat

%Second step

$$11. Y = [Y_s; 0]$$

$$12. X = [X_s; X_t]$$

13. Compute Kernel matrix K via $K = X^T X$

$$14. \alpha = (K + \sigma I)^{-1} Y$$

15. Learn prediction function f by $f(x) = \alpha^T K$ according to Equation 9

Return target labels L_t using adaptive classifier f

دو مجموعه داده USPS [۲۹] و MNIST [۳۰] می‌باشد که با طراحی دو آزمایش در یکی از آن‌ها، USPS دامنه منبع و MNIST دامنه هدف (U_M) و در آزمایش دیگر بالعکس (M_U) می‌باشد، که کارایی الگوریتم در هر دو حالت مختلف مورد ارزیابی قرار گرفته است. نمونه‌ای از تصاویر پایگاه داده‌های آفیس و کالتک و اعداد در شکل ۱ نمایش داده شده است. به‌طور کلی، کارایی الگوریتم پیشنهادی بر روی ۱۴ مجموعه تصاویر بین‌دامنه‌ای مختلف مورد ارزیابی قرار می‌گیرد.

۴-۲. ارزیابی الگوریتم‌ها

روش‌هایی که الگوریتم EMA با آن‌ها مقایسه شده

تصاویر اشیای جمع‌آوری شده از دامنه‌های وبکم^{۲۱}، آمازون^{۲۲}، دی اس ال آر^{۲۳} و کالتک می‌باشد که تصاویر در این دامنه‌ها از نظر شرایط نور و پس‌زمینه با یکدیگر تفاوت قابل توجهی دارند. برای پایگاه داده آفیس، ۱۲ آزمایش طراحی شده است که در هر یک از آزمایش‌ها یکی از مجموعه داده‌ها (برای مثال وبکم)، به عنوان دامنه منبع و یکی دیگر از مجموعه داده‌ها (برای مثال آمازون)، به عنوان دامنه هدف انتخاب می‌شوند.

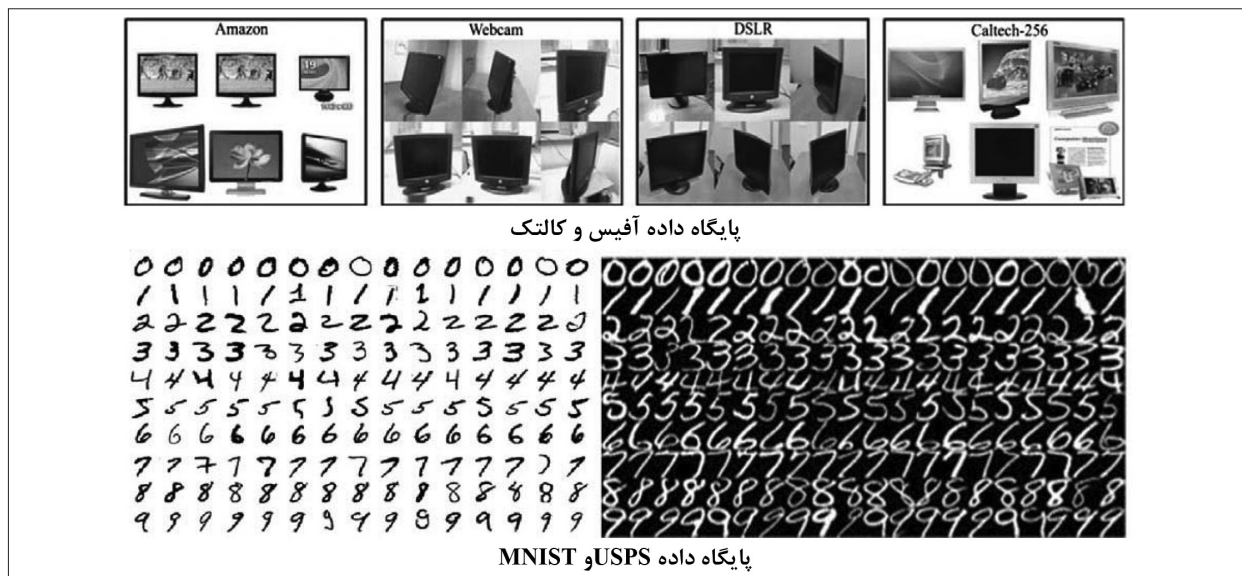
(۲) پایگاه داده اعداد^{۲۴} که شامل دو دامنه از تصاویر اعداد دست‌نویس انگلیسی می‌باشد. این پایگاه داده شامل

21- Webcam

22- Amazon

23- DSLR

24- Digits



شکل ۱: تصاویر نمونه از پایگاه داده‌های بصری

برای تمام پایگاه داده‌ها، تعداد بهینه ۵ در نظر گرفته شده است.

۵- نتایج و بحث‌ها

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

۵-۱- ارزیابی نتایج تطبیق دامنه بدون نظارت تک

منبعی

جدول ۳ و ۴، نشان‌دهنده نتایج روش پیشنهادی بر روی پایگاه داده‌های بصری آفیس و کالتک و اعداد در آزمایش‌های تطبیق دامنه بدون نظارت تک منبعی می‌باشند. در این آزمایش‌ها، یک دامنه به عنوان دامنه منبع و دامنه دیگری به عنوان دامنه هدف در نظر گرفته می‌شود. متوسط بهبود صحت الگوریتم پیشنهادی در ۱۲ پایگاه داده مورد آزمایش آفیس و کالتک، نسبت به بهترین روش مورد مقایسه ۲/۶۱٪ و نسبت به طبقه‌بند NN، ۲۰/۲۷٪ می‌باشد. همچنین، EMA در ۷ پایگاه داده از ۱۲ پایگاه داده مورد آزمایش، عملکرد بهتری نسبت به الگوریتم‌های مورد مقایسه از خود نشان داده است. متوسط بهبود

است، عبارت‌اند از: طبقه‌بند نزدیک‌ترین همسایه (NN)، PCA [۱۳]، TCA [۳]، GFK [۴]، TJM [۶]، JDA [۷] و VDA [۸]. عملکرد روش پیشنهادی، با بهترین نتایج گزارش شده از الگوریتم‌های مورد مقایسه، مورد ارزیابی قرار گرفته است.

۴-۳. مفروضات پیاده‌سازی

برای مقایسه روش پیشنهادی با الگوریتم‌های شناخته شده در حوزه تطبیق دامنه، صحت مدل طبقه‌بند بر روی داده‌های آزمون به عنوان معیار ارزیابی روش پیشنهادی و به صورت رابطه (۱۲) محاسبه می‌شود.

$$Accuracy = \frac{| \{x: x \in D_t \cap f(x) = y(x) \} |}{n_t} \quad (12)$$

که D_t دامنه هدف، $f(x)$ تابع پیش‌بینی به دست آمده از رابطه ۹، $y(x)$ برچسب واقعی داده و n_t تعداد داده‌های دامنه هدف می‌باشد. در روش پیشنهادی ۴ پارامتر مختلف وجود دارد: (۱) پارامتر نسبت در رابطه (۸)، d تعداد ابعاد فضای جدید، (۲) پارامتر نسبت در رابطه (۹)، σ پارامتر نسبت در رابطه (۱۱). مقدار بهینه پارامترها در روش EMA، برای پایگاه داده‌های بصری برای تمامی آزمایش‌های انجام گرفته و در جدول ۲ نشان داده شده است. همچنین، تعداد بهینه تکرار الگوریتم در مرحله اول، ۱۰ و تعداد نزدیک‌ترین همسایه هر نمونه در گراف همسایگی

جدول ۲: مقدار بهینه پارامترها

| θ | σ | β | P | پایگاه داده | نوع نظارت | تعداد دامنه منبع |
|----------|----------|---------|-----|--------------|----------------|------------------|
| ۰/۰۰۰۱ | ۰/۵ | ۱ | ۱۴۰ | آفیس و کالتک | بدون نظارت | تک منبعی |
| ۰/۰۱ | ۰/۵ | ۰/۰۱ | ۱۰۰ | اعداد | | |
| ۰/۰۰۰۱ | ۰/۵ | ۱ | ۱۴۰ | آفیس و کالتک | نیمه نظارت شده | |
| ۰/۰۱ | ۰/۰۵ | ۰/۱ | ۱۰۰ | اعداد | | |
| ۰/۰۰۰۱ | ۰/۵ | ۱ | ۱۴۰ | آفیس و کالتک | بدون نظارت | چند منبعی |

هدف، به دلیل عدم توجه به تطبیق ساختار محلی داده‌ها در فضای جدید، داده‌ها در فضای جدید دارای اختلاف توزیع هندسی بوده و بنابراین، مدل ایجاد شده توسط روش پیشنهادی EMA دارای تطبیق پذیری بین دامنه‌ای بیشتری نسبت به روش‌های JDA و VDA می‌باشد. متوسط بهبود صحت روش پیشنهادی در پایگاه داده آفیس و کالتک و اعداد، نسبت به روش JDA، به ترتیب ۵/۳۳٪ و ۶/۷۷٪ و نسبت به روش VDA، به ترتیب ۲/۶۱٪ و ۱/۴٪ می‌باشد.

۵-۲. ارزیابی نتایج تطبیق دامنه بدون نظارت چند

منبعی

در آزمایش‌های چند منبعی، با بهره‌گیری از اطلاعات مربوط به چند دامنه به عنوان دامنه‌های آموزشی، انتقال دانش بین دامنه‌ای انجام می‌گیرد. در این آزمایش‌ها، چند دامنه به عنوان دامنه منبع و یک دامنه به عنوان دامنه هدف در نظر گرفته می‌شود. جداول ۵ و ۶، نشان‌دهنده نتایج به دست آمده از آزمایش‌های بدون نظارت چند منبعی طراحی شده بر روی پایگاه داده آفیس و کالتک می‌باشند. بر اساس نتایج، بهبود متوسط بهبود صحت الگوریتم پیشنهادی نسبت به بهترین الگوریتم مورد مقایسه در آزمایش‌های دو منبعی ۲/۷٪ و در آزمایش‌های سه منبعی ۳/۲۴٪ بوده و همچنین، الگوریتم پیشنهادی در ۱۲ آزمایش از ۱۶ آزمایش چند منبعی طراحی شده دارای عملکرد بهتری نسبت به الگوریتم‌های مورد مقایسه می‌باشد. متوسط بهبود صحت روش پیشنهادی در آزمایش‌های دو منبعی و سه منبعی طراحی شده نسبت به آزمایش‌های تک منبعی، به ترتیب، ۸/۴۷٪ و ۱۳/۸۹٪ می‌باشد. بنابراین،

صحت الگوریتم پیشنهادی در پایگاه داده اعداد، نسبت به بهترین روش مورد مقایسه ۱/۴٪ و نسبت به طبقه‌بند NN، ۱۴/۹۲٪ بوده و در هر دو پایگاه داده، عملکرد بهتری نسبت به الگوریتم‌های مورد مقایسه از خود نشان داده است. به طور کلی، می‌توان نتیجه گرفت الگوریتم پیشنهادی با تطبیق توزیع هندسی و عمومی بین دامنه‌های منبع و هدف و همچنین، کاهش خطای پیش‌بینی، مدل بهتری نسبت به الگوریتم‌های مورد مقایسه، ایجاد می‌کند. در ادامه، به ارزیابی عملکرد روش پیشنهادی نسبت به الگوریتم‌های مورد مقایسه، پرداخته می‌شود.

روش PCA، یک روش کاهش بعد می‌باشد و در این روش، به تطبیق توزیع بین دامنه‌ای پرداخته نشده است. روش‌های GFK، TCA و TJM، به عنوان روش‌های تطبیق خصوصیات، اختلاف توزیع حاشیه‌ای را به حداقل رسانده و از اطلاعات داده‌های برچسب‌دار دامنه منبع و همچنین، توزیع هندسی داده‌ها برای ایجاد نمایش کم بعد از داده‌ها بهره نمی‌گیرند. روش پیشنهادی EMA، در تمام ۱۴ پایگاه داده مورد آزمایش، بهبود صحت قابل توجهی نسبت به روش‌های GFK، TCA، PCA و TJM دارد. همچنین، متوسط بهبود صحت EMA در پایگاه داده آفیس و کالتک نسبت به روش PCA، ۱۱/۹۹٪ نسبت به روش TCA ۸/۶۱٪، نسبت به روش GFK ۸/۶۹٪ و نسبت به روش TJM، ۵/۲٪ و در پایگاه داده اعداد نسبت به روش PCA، ۱۴/۶۵٪، نسبت به روش TCA ۱۶/۵۷٪، نسبت به روش GFK ۱۳/۴٪ و نسبت به روش TJM، ۱۲/۴۷٪ می‌باشد. همچنین، در روش‌های JDA و VDA، با وجود ایجاد تطبیق توزیع عمومی بین دامنه‌های منبع و

جدول ۳: صحت (%) طبقه‌بند در پایگاه داده آفیس و کالتک در آزمایش‌های بدون نظارت تک منبعی

| EMA | VDA | JDA | TJM | GFK | TCA | PCA | NN | آزمایش |
|-------|-------|-------|-------|-------|-------|-------|-------|---------|
| ۵۷/۸۳ | ۴۶/۱۴ | ۴۴/۷۸ | ۴۶/۷۶ | ۴۱/۲ | ۴۵/۸۲ | ۳۶/۹۵ | ۲۳/۷ | C-A |
| ۵۵/۲۵ | ۴۶/۱ | ۴۱/۶۹ | ۳۹/۹۸ | ۴/۶۸ | ۳/۵۱ | ۳۲/۵۴ | ۲۵/۷۶ | C-W |
| ۵۵/۴۱ | ۵۱/۵۹ | ۴۵/۲۲ | ۴۴/۵۹ | ۳۸/۸۵ | ۳۵/۶۷ | ۳۸/۲۲ | ۲۵/۴۸ | C-D |
| ۴۶/۲۲ | ۴۲/۲۱ | ۳۹/۳۶ | ۳۹/۴۵ | ۴۰/۲۵ | ۴۰/۷ | ۳۴/۷۳ | ۲۶ | A-C |
| ۴۹/۴۹ | ۵۱/۱۹ | ۳۷/۹۷ | ۴۲/۳ | ۳۸/۹۸ | ۳۵/۲۵ | ۳۵/۵۹ | ۲۹/۸۳ | A-W |
| ۴۳/۹۵ | ۴۸/۴۱ | ۳۹/۴۹ | ۴۵/۲۲ | ۳۶/۳۱ | ۳۴/۳۹ | ۲۷/۳۹ | ۲۵/۴۸ | A-D |
| ۳۲/۱۵ | ۲۷/۶ | ۳۱/۱۷ | ۳۰/۱۹ | ۳۰/۷۲ | ۲۹/۹۲ | ۲۶/۳۶ | ۱۹/۸۶ | W-C |
| ۳۲/۱۵ | ۲۶/۱ | ۳۲/۷۸ | ۲۹/۹۶ | ۲۹/۷۵ | ۲۸/۸۱ | ۲۹/۳۵ | ۲۲/۹۶ | W-A |
| ۹۱/۰۸ | ۸۹/۱۸ | ۸۹/۱۷ | ۸۹/۱۷ | ۸/۸۹ | ۸۵/۹۹ | ۷۷/۷ | ۵۹/۲۴ | W-D |
| ۳۳/۲۱ | ۳۱/۲۶ | ۳۱/۵۲ | ۳۱/۴۳ | ۳/۲۸ | ۳۲/۶ | ۲۹/۶۵ | ۲۶/۲۷ | D-C |
| ۳۷/۱۶ | ۳۷/۶۸ | ۳۳/۹ | ۳۲/۷۸ | ۳۲/۵ | ۳۱/۴۲ | ۳۲/۵ | ۲۸/۵ | D-A |
| ۸۵/۷۶ | ۹۰/۸۵ | ۸۹/۴۹ | ۸۵/۴۲ | ۷۵/۵۹ | ۸۶/۴۴ | ۷۵/۹۳ | ۶۳/۳۹ | D-W |
| ۵۱/۶۴ | ۴۹/۰۳ | ۴۶/۳۱ | ۴۶/۴۲ | ۴۲/۹۵ | ۴۳/۰۳ | ۳۹/۶۵ | ۳۱/۳۷ | میانگین |

جدول ۴: صحت (%) طبقه‌بند در پایگاه داده اعداد در آزمایش‌های بدون نظارت تک منبعی

| EMA | VDA | JDA | TJM | GFK | TCA | PCA | NN | |
|-------|-------|-------|-------|-------|-------|-------|-------|---------|
| ۵۸/۷۰ | ۶۲/۹۵ | ۵۹/۶۵ | ۵۲/۲۵ | ۴۶/۴۵ | ۵۱/۵ | ۴۴/۹۵ | ۴۴/۷ | U_M |
| ۸۱/۷۸ | ۷۴/۷۲ | ۶۷/۲۸ | ۶۳/۲۸ | ۶۷/۲۲ | ۵۶/۲۸ | ۶۶/۲۲ | ۶۵/۹۴ | M_U |
| ۷۲/۲۴ | ۶۸/۸۴ | ۶۳/۴۷ | ۵۷/۷۷ | ۵۶/۸۴ | ۵۳/۶۷ | ۵۵/۵۹ | ۵۵/۳۲ | میانگین |

نیمه‌نظارت‌شده به ترتیب، بر روی پایگاه داده آفیس و کالتک و اعداد می‌باشند. به‌طور کلی، در پایگاه داده آفیس و کالتک، روش پیشنهادی با کسب متوسط بهبود صحت ۳/۸۴٪ نسبت به بهترین الگوریتم مورد مقایسه، در ۱۱ آزمایش از ۱۲ آزمایش طراحی‌شده مدل تطبیق‌پذیرتری ایجاد کرده است. به همین ترتیب، EMA با کسب ۴/۰۴٪ بهبود متوسط صحت، در هر دو آزمایش نیمه نظارت‌شده طراحی‌شده بر روی پایگاه داده اعداد، برچسب‌هایی با صحت بیشتری پیش‌بینی کرده است.

۵-۴. ارزیابی نتایج روش EMA+

همان‌طور که قبلاً اشاره شد، برای محاسبه اختلاف توزیع شرطی بین دامنه‌های منبع و هدف در روش EMA، نیاز به محاسبه برچسب‌های دامنه هدف می‌باشد. از

روش پیشنهادی در آزمایش‌های چند منبعی نسبت به آزمایش‌های تک منبعی، دارای توانایی بیشتر در ایجاد تطبیق‌پذیری بین‌دامنه‌ای می‌باشد. در واقع، افزایش تعداد نمونه‌های آموزشی، با بهبود یادگیری مدل، خطای پیش‌بینی برچسب نمونه‌های دامنه هدف را کاهش می‌دهد.

۵-۳. ارزیابی نتایج تطبیق دامنه نیمه نظارت‌شده

در مسائل تطبیق دامنه نیمه نظارت‌شده، تعداد محدودی از نمونه‌های برچسب‌دار در دامنه هدف در دسترس می‌باشد. در این بخش، آزمایش‌های نیمه نظارت‌شده‌ای طراحی می‌شوند که علاوه بر نمونه‌های آموزشی موجود در دامنه منبع، از نمونه‌های برچسب‌دار دامنه هدف نیز برای آموزش مدل طبقه‌بند بهره گرفته می‌شود. جداول ۷ و ۸، نشان‌دهنده نتایج به‌دست‌آمده از آزمایش‌های

جدول ۵: صحت (%) طبقه‌بند در پایگاه داده آفیس و کالتک در آزمایش‌های بدون نظارت دو منبعی

| EMA | VDA | JDA | TJM | GFK | TCA | PCA | NN | آزمایش |
|-------|-------|-------|-------|-------|-------|-------|-------|---------|
| ۵۷/۳۲ | ۴۵/۲۲ | ۴۶/۵ | ۵۲/۲۳ | ۳۹/۴۹ | ۵۱/۵۹ | ۳۷/۵۸ | ۲۷/۳۹ | A,C→D |
| ۵۱/۸۶ | ۴۴/۷۵ | ۴۶/۱ | ۳۹/۳۲ | ۳۸/۳۷ | ۳۸/۳۱ | ۳۲/۵۴ | ۲۷/۴۶ | A,C→W |
| ۴۹/۴۲ | ۴۲/۷۵ | ۴۱/۰۵ | ۴۰/۵۲ | ۳۷/۷۷ | ۴۰/۶۹ | ۳۵/۸ | ۳۶/۳۶ | A,D→C |
| ۷۹/۶۶ | ۸۱/۳۶ | ۹۳/۷۵ | ۷۵/۲۵ | ۵۴/۷۵ | ۶۹/۱۵ | ۶۴/۰۷ | ۴۱/۰۲ | A,D→W |
| ۴۷/۴۶ | ۴۱/۹۴ | ۴۱/۰۵ | ۳۹/۵۴ | ۳۸/۰۹ | ۳۹/۲۷ | ۳۶/۱۵ | ۲۶/۶۳ | A,W→C |
| ۸۶/۶۲ | ۸۷/۹ | ۸۴/۷۱ | ۸۲/۸ | ۶۶/۵۶ | ۷۱/۹۷ | ۶۶/۸۸ | ۴۹/۶۸ | A,W→D |
| ۵۶/۶۸ | ۵۱/۴۳ | ۴۴/۸۹ | ۴۵/۰۹ | ۳۸/۰۱ | ۴۳/۱۱ | ۳۶/۵۳ | ۲۴/۰۱ | C,D→W |
| ۸۱/۰۲ | ۷۸/۳۱ | ۷۱/۸۶ | ۷۳/۹ | ۵۵/۸۶ | ۶۸/۱۴ | ۵۹/۳۲ | ۳۲/۲ | C,D→D |
| ۵۶/۸۹ | ۴۹/۹ | ۴۴/۷۸ | ۴۵/۴۱ | ۳۸/۵ | ۴۴/۵۷ | ۳۷/۶۸ | ۲۴/۸۴ | C,W→A |
| ۸۱/۵۳ | ۷۹/۶۲ | ۷۹/۶۲ | ۸۰/۲۵ | ۶۶/۶۲ | ۷۵/۱۶ | ۷۲/۶۱ | ۴۵/۲۲ | C,W→D |
| ۳۸/۸۳ | ۳۷/۰۶ | ۳۵/۱۸ | ۳۵/۲۸ | ۳۵/۱۴ | ۳۴/۳۴ | ۳۶/۴۳ | ۲۹/۰۲ | D,W→A |
| ۳۴/۰۲ | ۳۶/۶۹ | ۳۵/۳۵ | ۳۴/۰۲ | ۳۱/۵۶ | ۳۳/۴۸ | ۳۰/۹ | ۲۴/۴۹ | D,W→C |
| ۶۰/۱۱ | ۵۶/۴۱ | ۵۳/۹۲ | ۵۳/۶۳ | ۴۵/۰۶ | ۵۰/۸۲ | ۴۵/۵۴ | ۳۱/۵۳ | میانگین |

جدول ۶: صحت (%) طبقه‌بند در پایگاه داده آفیس و کالتک در آزمایش‌های بدون نظارت سه منبعی

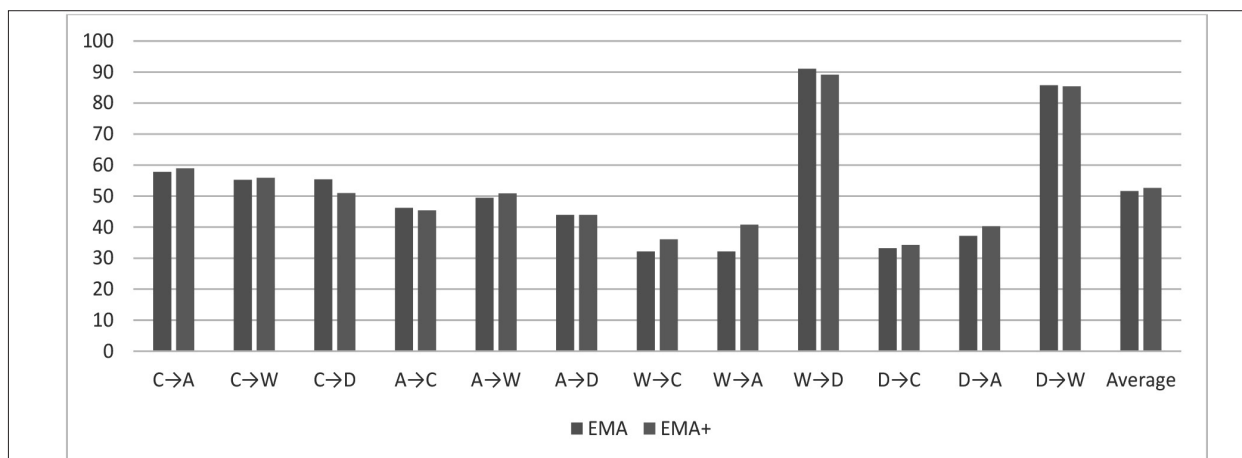
| EMA | VDA | JDA | TJM | GFK | TCA | PCA | NN | آزمایش |
|-------|-------|-------|-------|-------|-------|-------|-------|---------|
| ۴۸/۴۴ | ۴۱/۶۷ | ۴۱/۶۷ | ۴۰/۲۵ | ۳۷/۳۶ | ۳۹/۲۷ | ۳۷/۶۷ | ۲۶/۷۱ | A,W,D→C |
| ۵۷/۵۲ | ۵۰/۳۱ | ۴۵/۷۲ | ۴۴/۱۵ | ۴۰/۱۶ | ۴۴/۰۵ | ۳۸/۱ | ۲۴/۹۵ | C,W,D→A |
| ۷۵/۲۵ | ۷۶/۳۷ | ۶۹/۸۳ | ۷۲,۸۸ | ۳۸/۹۸ | ۶۰ | ۵۷/۲۹ | ۳۳/۲۲ | C,A,D→W |
| ۸۰/۸۹ | ۸۰/۸۹ | ۷۷/۰۷ | ۸۰/۸۹ | ۳۹/۳۶ | ۷۱/۳۴ | ۶۸/۷۹ | ۴۵/۲۲ | C,A,W→D |
| ۶۵/۵۳ | ۶۲/۲۹ | ۵۸/۵۷ | ۵۹/۵۴ | ۳۸/۹۷ | ۵۳/۶۷ | ۵۰/۴۶ | ۳۲/۵۳ | میانگین |

جدول ۷: صحت (%) طبقه‌بند در پایگاه داده آفیس و کالتک در آزمایش‌های نیمه نظارت‌شده

| EMA | VDA | JDA | TJM | GFK | TCA | PCA | NN | آزمایش |
|-------------|-------------|------------|------------|------------|------------|------------|------------|---------|
| ۶۴/۰۱±۰/۹۶ | ۵۳/۳۴±۳/۱۱ | ۵۰/۳۴±۱/۳۳ | ۵۰/۸۵±۱/۷۳ | ۴۷/۷۴±۱ | ۵۰/۷۷±۱/۳۲ | ۵۰/۶۴±۱/۰۹ | ۲۸/۰۸±۱/۱۲ | C-A |
| ۶۳/۰۶±۶/۲۵ | ۵۷/۹۲±۷/۶ | ۵۳/۰۹±۱۰/۶ | ۵۵/۸۱±۷/۲ | ۵۴/۷۹±۷/۹۴ | ۵۱/۸۵±۴/۰۹ | ۵۲/۵۳±۴/۱۱ | ۲۹/۰۲±۱/۱۵ | C-W |
| ۵۸/۸۳±۱۰/۶۸ | ۵۱/۳۹±۱۰/۹۲ | ۵۰/۳۳±۴/۵ | ۴۹/۹۳±۴/۵۲ | ۴۹/۸۵±۲/۲۷ | ۵۱/۸۲±۲/۹۶ | ۴۸/۱۸±۲/۱۳ | ۲۷/۳۷±۰/۸۶ | C-D |
| ۵۱/۵۶±۰/۴۹ | ۴۴/۴۳±۰/۹۱ | ۴۲/۷۹±۱/۲۲ | ۴۲±۰/۹۱ | ۴۲/۴۶±۰/۸۲ | ۴۲/۷±۱/۷ | ۴۳/۴۵±۱/۰۲ | ۲۸±۱/۰۶ | A-C |
| ۵۹/۸۵±۷/۵۴ | ۵۹/۴۳±۶/۹۴ | ۵۲/۲۶±۶/۳۷ | ۵۳/۴۷±۴/۲۴ | ۵۲/۹۴±۹/۱۲ | ۵۰/۸۷±۷/۵۳ | ۵۱/۰۶±۵/۱ | ۳۴/۳۸±۴/۹۲ | A-W |
| ۵۲/۸۵±۷/۱۳ | ۵۱/۴۶±۵/۵۹ | ۴۷/۰۸±۴/۰۶ | ۴۹/۴۹±۲/۳۴ | ۴۴/۲۳±۴/۵۲ | ۴۲/۱۲±۵/۴۵ | ۴۴/۰۱±۳/۳۲ | ۲۷/۵۲±۲/۳۷ | A-D |
| ۴۷/۲۱±۱/۰۸ | ۴۱/۵۵±۲/۷ | ۴۰/۶۲±۱/۶۴ | ۳۸/۵۹±۳/۲۵ | ۳۸/۷۲±۱/۰۹ | ۴۰/۰۴±۲/۸۵ | ۴۱/۰۳±۱/۹۸ | ۲۵/۳۵±۳/۴۱ | W-C |
| ۵۸/۹۵±۲/۸۶ | ۵۶/۹۵±۲/۷۳ | ۵۴/۳۹±۶/۳۴ | ۴۸/۶۹±۳/۲۲ | ۴۸/۵۸±۴/۸۱ | ۵۲/۵۴±۳/۵۴ | ۵۳/۲۸±۵/۰۸ | ۳۶/۵۵±۴/۱ | W-A |
| ۹۲/۵۵±۱/۵۲ | ۹۴/۸۲±۲/۸۹ | ۹۰/۳۶±۳/۱۷ | ۸۸/۳۲±۳/۵۵ | ۸۸/۶۹±۷/۴۹ | ۹۲/۷۷±۱ | ۹۱/۶۸±۰/۹۷ | ۶۰/۵۱±۲/۶۶ | W-D |
| ۴۸/۳۷±۱/۳۵ | ۴۰/۸۴±۴/۶۲ | ۳۹/۶۵±۳/۱۳ | ۳۷/۸۹±۱/۱۳ | ۳۷/۵۲±۱/۳۷ | ۳۹/۹۷±۱/۵۶ | ۴۱/۰۲±۱/۸۶ | ۲۵/۵±۵/۲۷ | D-C |
| ۶۲/۱۶±۵/۷۴ | ۵۷/۲±۱۰/۱۱ | ۵۲/۵۹±۸/۳ | ۴۸/۵۱±۳/۵۹ | ۴۶/۸۹±۷/۳۶ | ۵۲/۵۵±۷/۱۳ | 52/8±۴/۳۹ | ۳۷/۰۳±۷/۱۲ | D-A |
| ۹۰/۰۴±۱/۸۴ | ۹۳/۹۶±۰/۵۱ | ۹۱/۴۳±۰/۹۸ | ۸۸/۰۴±۵/۰۳ | ۸۷/۱۳±۷/۹۳ | ۹۰/۶۸±۰/۶۳ | ۸۹/۷۷±۱/۹۴ | ۶۴/۷۲±۹/۶۹ | D-W |
| ۶۲/۴۵±۳/۹۵ | ۵۸/۶۱±۴/۸۹ | ۵۵/۴۲±۴/۳ | ۵۴/۳±۳/۳۹ | ۵۳/۳±۴/۶۵ | ۵۴/۸۹±۳/۳۱ | ۵۴/۹۴±۲/۷۵ | ۳۵/۳۳±۳/۶۵ | میانگین |

جدول ۸: صحت (%) طبقه‌بند در پایگاه داده اعداد در آزمایش‌های نیمه نظارت‌شده

| EMA | VDA | JDA | TJM | GFK | TCA | PCA | NN | آزمایش |
|------------|------------|------------|------------|------------|------------|------------|------------|---------|
| ۸۵/۰۸±۱/۹۳ | ۷۳/۵۷±۱/۰۶ | ۸۰/۵۲±۰/۷۴ | ۷۵/۵۴±۱/۲۱ | ۷۸/۵۲±۱/۷۰ | ۸۰/۳۶±۱/۰۱ | ۷۷/۶۲±۱/۵۲ | ۷۹/۴۳±۱/۳۱ | U_M |
| ۸۷/۷۲±۰/۲۹ | ۸۰±۱/۲۲ | ۸۶/۲±۰/۵۸ | ۸۱/۹±۲/۰۶ | ۸۶/۳۵±۱/۰۶ | ۸۶/۳۱±۰/۷۹ | ۸۳/۶۵±۱/۱۴ | ۸۷/۱۳±۰/۹۹ | M_U |
| ۸۷/۴۰±۰/۹۹ | ۷۶/۷۹±۱/۱۴ | ۸۳/۳۶±۰/۶۶ | ۷۸/۹۲±۱/۶۳ | ۸۲/۴۴±۱/۳۸ | ۸۳/۳۴±۰/۹ | ۸۰/۶۴±۱/۳۳ | ۸۳/۲۸±۱/۱۲ | میانگین |



شکل ۲: صحت EMA+ بر روی پایگاه داده آفیس و کالتک

۶- نتیجه‌گیری و کارهای آتی

در این مقاله، روش تطبیق دامنه بدون نظارت EMA برای ایجاد تطبیق هندسی و عمومی در دامنه‌های بصری پیشنهاد شده است. روش پیشنهادی، در ابتدا یک نمایش تطبیق‌پذیر مشترک بین دامنه‌ها توسط کاهش همزمان اختلاف توزیع شرطی و حاشیه‌ای و همچنین، بهره‌گیری از اطلاعات محلی نمونه‌های دامنه‌های منبع و هدف ایجاد می‌کند. سپس در نمایش جدید، با حداقل‌سازی تابع خطای پیش‌بینی، صحت مدل طبقه‌بند را بهبود می‌بخشد. روش پیشنهادی، بر روی دامنه‌های بصری شناخته‌شده مورد آزمایش قرار گرفته و نتایج به‌دست‌آمده، حاکی از برتری روش پیشنهادی بر جدیدترین روش‌های حوزه تطبیق دامنه می‌باشد.

برای ادامه کار در آینده، از روش‌های انتخاب نمونه نیز برای کاهش اختلاف توزیع و ایجاد یک نمایش تطبیق‌پذیرتر بین دامنه‌های منبع و هدف بهره خواهیم جست. همچنین، برای افزایش کارایی مدل طبقه‌بند، از الگوریتم‌های خوشه‌بندی نمونه‌ها در فضای جدید استفاده خواهیم کرد.

این رو، در روش EMA از یک طبقه‌بند استاندارد برای پیش‌بینی برچسب‌های اولیه داده‌های دامنه هدف استفاده شد. در مرحله دوم روش EMA، یک طبقه‌بند حداقل‌سازی خطا پیشنهاد شده است که این طبقه‌بند به کاهش خطای پیش‌بینی در مرحله آموزش طبقه‌بند می‌پردازد و به همین دلیل دارای عملکرد بهتری نسبت به طبقه‌بندهای استاندارد، در پیش‌بینی برچسب است. در همین راستا، روش EMA+ برای بهبود عملکرد روش EMA پیشنهاد می‌شود. در روش EMA+، از تابع پیش‌بینی تعریف‌شده در مرحله دوم از روش EMA رابطه (۹)، برای پیش‌بینی برچسب‌های اولیه داده‌های دامنه هدف و محاسبه اختلاف توزیع شرطی استفاده می‌شود. در شکل ۲، نتایج به‌دست‌آمده توسط روش EMA و EMA+ در آزمایش‌های بدون نظارت تک منبعی پایگاه داده آفیس و کالتک نشان داده شده است. به‌طور کلی، در این آزمایش‌ها، روش EMA+ نسبت به روش EMA، متوسط بهبود صحت ۱/۰۴٪ داشته و در ۷ آزمایش از ۱۲ آزمایش طراحی‌شده دارای عملکرد بهتری می‌باشد.

- IEEE Conference on Computer Vision and Pattern Recognition, pp. 2066-2073, 2012.
- 14-S. Si, D. Tao and B. Geng, "Bregman divergence-based regularization for transfer subspace learning", *IEEE Trans Knowl Data Eng*, vol. 22, no. 7, pp. 929-942, 2010.
- 15-M. Long, J. Wang, G. Ding, J. Sun and P. S. Yu, "Transfer joint matching for unsupervised domain adaptation", *IEEE conference on computer vision and pattern recognition*, pp. 1410-1417, 2014.
- 16-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.
- 17-J. Tahmoresnezhad and S. Hashemi, "Visual domain adaptation via transfer feature learning", *KnowlInf Syst*, vol. 50, no. 2, pp. 585-605, 2016.
- 18-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.
- 19-L. Duan L, I. W. Tsang, D. Xu and S. J. Maybank, "Domain transfer SVM for video concept detection", *IEEE Conference on computer vision and pattern recognition*, pp. 1375-1381, 2009.
- 20-L. Bruzzone and M. Marconcini, "Domain adaptation problems: a DASVM classification technique and a circular validation strategy", *IEEE Trans Pattern Anal Mach Intell*, vol. 32, no. 5, pp. 770-787, 2010.
- 21-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.
- Jolliffe I, *Principal component analysis*, Wiley, vol. 2, pp. 433-459, 2002.
- 22-M. Belkin, P. Niyogi, V. Sindhwani, "Manifold regularization: a geometric framework for learning from labeled and unlabeled examples", *J. Mach. Learn. Res*, vpl. 7, pp. 2399-2434, 2006.
- 23-M. Belkin, P. Niyogi, V. Sindhwani, "Manifold regularization: a geometric framework for learning from labeled and unlabeled examples", *J. Mach. Learn. Res*, vpl. 7, pp. 2399-2434, 2006.
- 24-B. Schölkopf, R. Herbrich and A. J. Smola, "A generalized Representer theorem", *Proceedings of the Conference on Computational Learning Theory*, pp. 416-426, 2001.
- G.Griffin, A. Holub and P. Perona, "Caltech-256 object category dataset", *Technical Report7694*, 2007.
- 25-J. J. Hull, "A database for handwritten text recognition research", *IEEE Trans. Pattern Anal. Mach. Intell*, vol. 16, no. 5, pp. 550-554, 1994.
- 26-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.
- 1- B. Gong, K. Grauman and F. Sha, "Reshaping visual datasets for domain adaptation", *Proceedings of the Advances in Neural Information Processing Systems*, vol. 26, pp. 1286-1294, 2013.
- 2- I.H. Jhuo, D. Liu, D.T. Lee and S.F. Chang, "Robust visual domain adaptation with low-rank reconstruction", in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2012.
- 3-J. Blitzer, M. Dredze and F. Pereira, *Biographies*, "bollywood, boom-boxes and blenders: domain adaptation for sentiment classification", in: *Proceedings of the 45th Annual Meeting of the Association of Computational Linguistics*, 2007.
- 4-X. Glorot, A. Bordes and Y. Bengio, "Domain adaptation for large-scale sentiment classification: a deep learning approach", in: *Proceedings of the International Conference on Machine Learning*, 2011.
- 5-G. R. Xue, W. Dai, Q. Yang and Y. Yong, "Topic-bridged PLSA for cross-domain text classification", in: *Proceedings of the ACM Annual International Conference on Research and Development in Information Retrieval*, 2008.
- 6-L. Shi, R. Mihalcea and M. Tian, "Cross language text classification by model translation and semi-supervised learning", in: *Proceedings of the Empirical Methods in Natural Language Processing*, 2010.
- 7-Shekhar, S., Patel, V., Nguyen, H., Chellappa, R., 2013. "Generalized domain-adaptive dictionaries". In: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*. pp. 361-368.
- 8- Xia, R., Zong, C., Hu, X., Cambria, E., 2013. "Feature ensemble plus sample selection: domain adaptation for sentiment classification". *IEEE Intell. Syst.* 28 (3), 10-18.
- 9-J. Yang, Y. Rong and A.G. Hauptmann, "Cross domain video concept detection using adaptive svms", in: *Proceedings of the International Conference on Multimedia*, 2007.
- 10- L. Duan, D. Xu, I. Tsang and J. Luo, "Visual event recognition in videos by learning from web data", in: *Proceedings of the IEEE Conference on Computer Vision and Pattern Recognition*, 2010.
- 11-Saenko, K., Kulis, Fritz, B., M., Darrell, T., 2010. "Adapting visual category models to new domains". In: *Proceedings of the European Conference on Computer Vision*.
- Patel, V.M., Gopalan, R., Li, R., Chellappa, R., 2015. *Visual Domain Adaptation: a survey of recent advances*. *IEEE Signal Process. Mag.* 32 (3), 53-69.
- 12-B. Gong, K. Grauman and F. Sha, "Connecting the dots with landmarks: discriminatively learning domain-invariant features for unsupervised domain adaptation", *Proceedings of the International Conference on Machine Learning*, vol. 28, no. 1, pp. 222-230, 2013.
- 13-S. J. Pan, I. W. Tsang, J. T. Kwok and Q. Yang, "Domain adaptation via transfer component analysis", *IEEE Trans. Neural Netw*, vol. 22, pp. 199-210, 2011.
- B. Gong, Y. Shi, F. Sha and K. Grauman, "Geodesic flow kernel for unsupervised domain adaptation", *Proceedings of the*