



Spring 2023, 4 (1), 27-37

DOI: [10.71856/impcs.2023.903575](https://doi.org/10.71856/impcs.2023.903575)

Received: 12 Feb 2023

Accepted: 9 Apr 2023

مقاله پژوهشی

Unsupervised Domain Adaptation for Image Classification Based on Deep Neural Networks

Amirfarhad Farhadi¹, Mitra Mirzarezaee^{2*}, Arash Sharifi³, Mohammad Teshnehlab⁴

1. Ph.D. Student, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran. amir.farhadi@srbiau.ac.ir
2. Assistant professor, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran. (*Corresponding Author*), mirzarezaee@srbiau.ac.ir
3. Assistant professor, Department of Computer Engineering, Science and Research Branch, Islamic Azad University, Tehran, Iran. a.sharifi@srbiau.ac.ir
4. Professor, Department of Control Engineering, K.N. Toosi University of Technology, Tehran, Iran. teshnehlab@eed.kntu.ac.ir

Abstract

Introduction: Domain adaptation has become an important issue today. A high percentage of data processing domain adaptation is done with a significant percentage of studies related to deep learning. Traditional methods often ignore the distance between the intra-class in source domain and target domain. As a result, models can be sensitive to outliers and noisy data, additionally increasing the negative transfer in the model. This method applied GAN to extract appropriate features and then used Fuzzy c-means to cluster train datasets in the target domain. Finally, based on the WMMD metric and CNN, the model estimates the final label data. Five real datasets are selected to generate eight transfer tasks. The results show that the superiority of the proposed model lies in transferring more knowledge from the source domain to the target domain.

Method: In this approach, firstly based on GAN extracting features from source domains and the target domain (without labels), then label estimation by Fuzzy c-means clustering, finding the center of Fuzzy c-means on target domain data, new data points with labels in target domain as a new input to feature extraction module and regenerate features by GAN based on new pseudo labels. Afterward, we apply WMMD metrics based on CNN to ultimately assign labels for the target domain. Consequently, classification tasks have been done.

Results: Empirical results on various benchmark datasets showcase the exceptional performance of the proposed method compared to state-of-the-art DA approaches, validating the proposed Deep-Learning Unsupervised Domain Adaptation approach efficacy. Overall, the approach shows potential for advancing domain adaptation research by offering an efficient and resilient approach for addressing domain shifts in real-world applications. Experimental results on visual object recognition and a digit dataset reveal that the proposed algorithm is robust, flexible, and significantly superior regarding accuracy compared to the baseline DA approaches. Based on the three and combined digit datasets, 1.7% and 2.4% accuracy improvement are achieved, respectively, compared to the best baseline DA approach results.

Discussion: In this research, we addressed the challenging issues of outlier and negative transfer in the context of domain adaptation. Despite significant progress in domain adaptation techniques, outliers and negative transfer instances continue to hinder models' generalization performance across different domains. Based on DNNs and the WMMD metric, our proposed method was designed to mitigate these issues and effectively enhance knowledge transfer between domains.

Keywords: Domain adaptation, fuzzy clustering, CNN, GAN, WMMD.



فصلنامه سیستم‌های پردازشی و ارتباطی چندرسانه‌ای هوشمند

Intelligent Multimedia Processing and Communication Systems (IMPCS)



تطبیق دامنه بدون نظارت جهت طبقه‌بندی تصاویر با استفاده از شبکه‌های عصبی عمیق

تاریخ دریافت: ۲۳ / ۱۱ / ۱۴۰۱
دوره چهارم، بهار ۱۴۰۲
تاریخ پذیرش: ۲۰ / ۰۱ / ۱۴۰۲
شماره اول، صص ۲۷-۳۷

امیرفرهاد فرهادی^۱، میترا میرزازایی^{۲*}، آرش شریفی^۳، محمد تشنه‌لب^۴

۱. دانشجوی دکتری، گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

amir.farhadi@srbiau.ac.ir

۲. استادیار، گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران. (نویسنده مسئول)

mirzarezaee@srbiau.ac.ir

۳. استادیار، گروه مهندسی کامپیوتر، واحد علوم و تحقیقات، دانشگاه آزاد اسلامی، تهران، ایران.

a.sharifi@srbiau.ac.ir

۴. استاد، گروه مهندسی کنترل، دانشگاه صنعتی خواجه نصیرالدین طوسی، تهران، ایران.

teshnehlab@eetd.kntu.ac.ir

چکیده: تطبیق دامنه می‌تواند دانش را از یک مجموعه آموزشی (دامنه منبع) به یک مجموعه آزمایشی (دامنه هدف) انتقال دهد تا بازدهی مدل یادگرفته‌شده از داده‌های آموزش، افزایش یابد. در حیطه تطبیق دامنه مسائل به دو بخش با نظارت و بدون نظارت تقسیم‌بندی می‌شود. در این پژوهش دامنه‌های بدون نظارت مورد بررسی قرار می‌گیرد. یکی از چالش‌ها در تطبیق دامنه که به آن کمتر توجه شده‌است، عدم توجه به زیرفضا دامنه (فشردگی درون کلاسی) و همچنین تاثیر مخرب داده‌های نویزی و خارج از محدوده است، که موجب انتقال منفی و در نهایت موجب کاهش دقت طبقه‌بندی می‌شود. در این مقاله با استفاده از شبکه تخصصی مولد جهت استخراج ویژگی‌ها با در نظر گرفتن فشردگی درون-کلاسی دامنه‌ها بر مبنای تخمین اولیه برچسب‌ها با کمک الگوریتم خوشه‌بندی فازی c-means در گام اول و در گام دوم با کمک شبکه‌های عصبی پیچشی و متریک WMMD جهت طبقه‌بندی تصاویر با خطای کمتر ارائه شده‌است. ارزیابی و نتایج به‌دست‌آمده در ۵ مجموعه داده محک استاندارد و مقایسه آن با روش‌های پیشین نشان‌دهنده عملکرد بهتر نسبت به رهیافت‌های مشابه می‌باشد.

واژه‌های کلیدی: تطبیق دامنه، خوشه‌بندی فازی، شبکه عصبی پیچشی، شبکه‌های تخصصی مولد، WMMD.

۱. مقدمه

استفاده از روش‌های انتقال یادگیری به واسطه افزایش هزینه برچسب-گذاری از یک سو و از طرف دیگر افزایش روزافزون داده‌ها در فضای مجازی و اینترنت در چند سال اخیر از سوی دیگر موجب شده که پژوهش‌های قابل توجهی معطوف به حوزه انتقال یادگیری شود [۲، ۳]. یکی از رهیافت‌های اصلی انتقال یادگیری تطبیق دامنه می‌باشد [۴]. تطبیق دامنه خود به دو بخش بدون-نظارت و با-نظارت تقسیم‌بندی می‌شود [۵]. در صورتی که داده‌های با-برچسب در دامنه هدف وجود نداشته باشد، به آن تطبیق دامنه بدون-نظارت گفته می‌شود و اگر داده‌های با-برچسب موجود باشد، روش با-نظارت می‌باشد. در این پژوهش روش بدون-نظارت مدنظر است [۵].

از سال ۲۰۱۲ و با شروع روش‌های جدید شبکه‌های عصبی عمیق و بهبود قابل توجهی که در عملکرد روش‌های یادگیری ماشین و به تبع آن، در روش‌های تطبیق دامنه ایجاد گردیده است [۶]. به طور کلی تطبیق دامنه در حوزه‌های مختلفی مورد استفاده قرار می‌گیرد. که از آن جمله می‌توان به پردازش تصویر، پردازش زبان‌های طبیعی، تشخیص خطا و غیره اشاره نمود [۷].

در مسئله تطبیق دامنه همان‌طور که در شکل ۱ مشخص می‌باشد، انتقال دانش از دامنه منبع به دامنه هدف در نگاشتی در فضای مشترک صورت می‌پذیرد که در جهت یافتن ویژگی‌های یکسان بین دو دامنه می‌باشد. کمینه‌سازی توزیع داده‌ها، بین دامنه منبع و هدف یکی از اهداف اصلی پژوهش‌های اخیر در این حوزه است. که در نهایت موجب کسب کمترین خطا و بیشینه‌سازی دقت طبقه‌بند دامنه هدف، خواهد شد.

این پژوهش بر مبنای روش‌های بدون-نظارت تطبیق دامنه در مسئله طبقه‌بندی تصاویر می‌باشد. به طور کلی در پژوهش‌های پیشین بیشتر تمرکز بر روی تطبیق دامنه فراگیر^۱ بین دامنه منبع و هدف بوده است. به عبارت دیگر، عدم توجه به زیر-دامنه‌ها در فضای مسئله، موجب کاهش تطبیق-معنایی^۲ در فرآیند تطبیق دامنه شده است.

در روش پیشنهادی بر مبنای مراکز خوشه‌های فازی و تخمین اولیه برچسب‌های دامنه هدف می‌باشد که موجب توجه بیشتر به تراکم درون-کلاسی می‌شود.

استفاده از شبکه‌های تخصصی مولد [۱] در نقش استخراج‌کننده ویژگی‌ها و در نهایت طبقه‌بندی تصاویر بر مبنای متریک WMMD^[11] موجب ارتقای دقت طبقه‌بند و کاهش انتقال منفی خواهد شد. خروجی نهایی این تحقیق، طبقه‌بندی تصاویر با دقت بالاتر نسبت به پژوهش‌های پیشین و روش‌های مشابه می‌باشد. لازم به ذکر است مقایسه نتایج بر پایه چند مجموعه داده محک استاندارد صورت می‌پذیرد که در بخش نتایج به بررسی کامل آن خواهیم پرداخت.

نوآوری در این پژوهش شامل موارد زیر خواهد بود:

- ارائه مدل پیشنهادی بر پایه شبکه تخصصی مولد و متریک WMMD
- تطبیق-معنایی در مسئله تطبیق دامنه بر پایه خوشه‌بندی فازی
- مقایسه نتایج به دست آمده با روش‌های پیشین که نشان دهنده کارایی مدل پیشنهادی است.


استفاده از مدل پنج‌لایه پیچشی مشابه AlexNet [6] و سه لایه تمام متصل^۴ در روش DAN^۵ توسط لانگ [۸] مورد استفاده قرار گرفت. در این پژوهش با استفاده از متریک MK-MMD^۶ که بر مبنای نگاشت چند تابع کرنل^۷ متفاوت و قابلیت اجماع چندین ویژگی اختلاف توزیع‌ها، در قالب یکپارچه می‌باشد که موجب قابلیت بیشتر مدل نسبت به روش‌های پیشین در هنگام فشرده‌سازی توزیع ویژگی‌ها می‌شود. یکی از ضعف‌های این شبکه وابستگی بالا به داده‌های برچسب در منبع می‌باشد. علاوه بر آن استفاده از کمینه‌سازی اختلاف دامنه مبتنی بر MK-MMD یکی دیگر از ضعف‌های این روش است که در روش پیشنهادی با کمک متریک WMMD مشکلات فوق برطرف می‌شود.

در سال ۲۰۱۶ گنین [۹] در پژوهشی به ارائه معماری جدید با نام DANN^۸ پرداخته است. این روش با استفاده از یک لایه معکوس گرادیان^۹ می‌باشد؛ که هم در شبکه‌های عصبی مصنوعی و شبکه‌های عمیق پیاده‌سازی شده است. لایه معکوس گرادیان بر پایه یادگیری گرادیان (پس-انتشار و گرادیان کاهش اتفاقی) می‌باشد. در این رهیافت، ابتدا به استخراج ویژگی‌های عمیق پرداخته و در مرحله بعد به پیش‌بینی برچسب‌ها می‌پردازد که در نهایت به طبقه‌بندی دامنه می‌انجامد. لازم به ذکر است در مرحله آخر خروجی طبقه‌بند دامنه به لایه معکوس گرادیان، به صورت بازگشتی انتقال می‌یابد. مشکل اصلی این روش در پایداری ضعیف در برابر داده‌های نویزی و نامرتب است. در روش پیشنهادی استفاده از خوشه‌بند فازی تا حد قابل ملاحظه‌ای این ضعف را پوشش می‌دهد.

استفاده از روش‌های هندسی در تطبیق دامنه یکی از رهیافت‌های اخیر می‌باشد. از آن جمله می‌توان به الگوریتم GFK^{۱۰} اشاره نمود. الگوریتم^{۱۱} MEDA [10] بر اساس فاصله ژئودسیک بین دامنه منبع و هدف در فضای منیفلد گرسمن^{۱۲} است به طوری که با کمک این روش، تصویرکردن چندین زیردامنه اشتراکی جهت جلوگیری از انتقال ویژگی‌های نامطلوب از دامنه منبع به دامنه هدف در جهت کاهش انتقال منفی پرداخته است. اما به واسطه کوچکی زیرفضا قسمتی از اطلاعات ورودی در نظر گرفته نمی‌شود.

استفاده از روش تقابلی بین دو بخش مستقل در یک معماری توسط یانگ [۱۲] در سال ۲۰۲۲ مطرح شد. در الگوریتم دو-واحدی^{۱۳} با استفاده از معماری دوگانه که به ترتیب در واحد اول بر مبنای ویژگی‌های یکسان

نفرین ابعاد^{۱۵} اشاره نمود و همچنین به واسطه استفاده از ساختار اولیه (بدون تغییر) MMD، نسبت به داده‌های نامتوازن عملکرد ضعیفی دارد. این ضعف در روش پیشنهادی، به واسطه استفاده از WMMD تا حد قابل قبولی بهبود می‌یابد.



شکل ۱: تطبیق دامنه بین دامنه منبع و دامنه هدف

بین دامنه‌های منبع، هدف و همچنین لایه معکوس گرادیان طراحی شده‌است. اما در واحد دوم یادگیری بر مبنای تفاوت ویژگی‌ها صورت پذیرفته‌است. یادگیری در این روش تقابل بین دو واحد مذکور، مشابه شبکه تخصصی مولد می‌باشد. در این شبکه رقابت بین واحد مولد و ممیز صورت می‌گیرد. که با توجه به استفاده همزمان از ویژگی مشترک و تمایز ویژگی‌ها، موجب افزودن در مدل می‌شود.

استفاده از خودرمزگذار در تطبیق دامنه غیرنظارتی بر پایه متریک MMD در پژوهش سال ۲۰۲۳ ژو [۱۳] بررسی شده‌است. در این مقاله با استفاده از چند رمزگذار به صورت مجتمع و یکپارچه در کنار هم، با نام IAUDA طراحی شده‌است. در این روش ابتدا از رمزگذار بر مبنای MMD و سپس از رمزگذار پیچشی برای به دست آوردن ویژگی‌های سطح بالاتر^{۱۴} (نسبت به روش‌های پیشین رمزگذار) استفاده شده‌است. از جمله نقاط ضعف این روش می‌توان به

جدول ۱: مقایسه روش‌ها

نام روش	سال	روش پیشنهادی	نقاط قوت	نقاط ضعف	نوآوری	نوع متریک
DAN	۲۰۱۵	شبکه عصبی پیچشی AlexNet در کنار MK-MMD	قابلیت اجماع چند تابع کرنلی به صورت یکپارچه	وابستگی به داده‌های برجسب در دامنه منبع	استفاده از متریک جدید	MK-MMD
DANN	۲۰۱۶	استفاده از شبکه عصبی کم عمق و شبکه عصبی عمیق در کنار هم	استفاده از لایه معکوس گرادیان	پایداری ضعیف در برابر داده‌های نویزی و نامرتب	لایه معکوس گرادیان	استفاده از روش‌های غیر متریک
MEDA	۲۰۱۸	استفاده از الگوریتم GFK	استفاده از فاصله ژئودسیک بین دامنه منبع و هدف	به واسطه کوچکی زیرفضا قسمتی از اطلاعات ورودی در نظر گرفته نمی‌شود	فاصله ژئودسیک بین دامنه منبع و هدف	MMD
Dual-Module	۲۰۲۲	استفاده از معماری دوگانه و لایه معکوس گرادیان در شبکه عصبی پیچشی	استفاده از روش‌های تقابلی	افزودگی بالا در مدل	معماری دوگانه و ترکیب روش تقابلی با لایه معکوس گرادیان	استفاده از روش‌های تقابلی
IAUDA	۲۰۲۳	استفاده از رمزگذار و شبکه عصبی پیچشی	استفاده از معماری یکپارچه	عملکرد ضعیف نسبت به داده‌های نامتوازن	استفاده از چند رمزگذار به صورت پی‌درپی	MMD

۲. روش تحقیق

۱.۱،۲ مفاهیم اولیه

شبکه تخصصی مولد توسط گودفلو و همکارانش مطرح شد. در این شبکه یادگیری بر مبنای رقابت بین مولد^{۱۶} و ممیز^{۱۷} است؛ مطابق شکل ۲، خروجی مولد (داده‌های جعلی) و همچنین داده‌های واقعی به‌عنوان ورودی‌های ممیز هستند.

پس از آن، ممیز به تشخیص داده‌های اصلی از جعلی می‌پردازد. شبکه مولد با تابع G^{18} و شبکه ممیز با تابع D^{19} شناخته می‌شوند. تابع هزینه کلی $V(G,D)$ به‌صورت زیر تعریف می‌شود:

$$V(D,G) \min_G \max_D = \int_{x \sim P_{data}(x)} [\log D(x)] + \int_{z \sim p(z)} [\log (1 - D(G(z)))] \quad (1)$$

خصوصیت مولدی و همچنین رقابتی این شبکه و به‌ویژه قابلیت‌های آن در یادگیری ویژگی‌های یکسان بین دامنه منبع و هدف موجب استفاده از این ساختار در پژوهش حاضر شده است. در بخش بعد با جزئیات بیشتر به آن خواهیم پرداخت.

در سال ۲۰۱۲ گریتون^[۱۳] به معرفی متریکی در تطبیق دامنه پرداخت، اختلاف توزیع شرطی بین دامنه‌های منبع و هدف زمانی رخ می‌دهد که به‌ازای داده‌های یکسان از دو دامنه، توزیع مجموعه برچسب‌ها متفاوت باشد. برای سنجش اختلاف توزیع شرطی بین دامنه‌ها معیارهای فراوانی وجود دارد که از آن جمله می‌توان به آنتروپی متقاطع^{۲۰}، واگرایی^{۲۱} KL اشاره کرد.

در روش MMD، برای محاسبه اختلاف توزیع دامنه‌ها، داده‌های دامنه‌های منبع و هدف به فضای هیلبرت نگاشت می‌شوند. روش MMD یک معیار غیرپارامتری بوده و به‌عنوان معیاری برای اندازه‌گیری بین دو توزیع احتمال متفاوت به‌کار می‌رود. این روش، داده‌های منبع و هدف را به یک زیرفضای RKHS نگاشت می‌کند و با محاسبه میانگین عناصر هر کدام از دامنه‌ها در فضای جدید، اختلاف میانگین دو دامنه را به دست می‌آورد.

$$D_{\mathcal{H}}(p, q) \triangleq \sup \| \mathbb{E}_{x_s \sim s} [f(x_s)] - \mathbb{E}_{x_t \sim t} [f(x_t)] \|_{\mathcal{H}} \quad (2)$$

ایده اصلی روش MMD در این نکته است که اگر توزیع‌ها یکسان باشد، تمام خصوصیت‌های آماری یکسان بوده و مقدار رابطه ۲ برابر صفر خواهد شد. همان‌طور که در رابطه ۲ مشخص است، هنگامی که \mathcal{H} طبقه تابع RKHS باشد. \mathcal{H} آنقدر غنی است که قابلیت یافتن تمایز بین دو توزیع را دارد.

$$\begin{aligned} \hat{D}_{\mathcal{H}}(p, q) & \quad (3) \\ \triangleq & \frac{1}{n^2 s} \sum_{i=1}^{ns} \sum_{j=1}^{ns} k(X_i^s, X_j^s) \\ + & \frac{1}{n^2 t} \sum_{i=1}^{nt} \sum_{j=1}^{nt} k_i(X_i^t, X_j^t) \\ - & \frac{2}{ns nt} \sum_{i=1}^{ns} \sum_{j=1}^{nt} k_i(X_i^s, X_j^t) \end{aligned}$$

همان‌طور که در رابطه ۳ مشخص است، $\hat{D}_{\mathcal{H}}(p, q)$ یک تخمین‌زن بدون خطا برای $D_{\mathcal{H}}(p, q)$ می‌باشد. یکی از نکاتی که در MMD در نظر گرفته نشده است، بایاس نسبت به یک کلاس خاص در مجموعه داده‌ها می‌باشد. این مسئله ناشی از عدم توازن داده‌ها است. که می‌تواند موجب کاهش دقت مدل شود. روش WMMD با کمک وزن دهی (بر اساس بایاس هر کلاس) در دامنه، موجب می‌شود که تأثیر بایاس در نظر گرفته شود. بر این اساس متغیر w_c^s به‌عنوان ضریب وزن بر اساس توزیع پیشین دامنه منبع و متغیر w_c^t ضریب وزن بر اساس توزیع پیشین دامنه هدف در نظر گرفته می‌شوند. متغیر α_c را به‌عنوان نرخ وزن توزیعی در کلاس c در نظر گرفته و نرخ وزن از رابطه ۴ در نظر گرفته می‌شود.

$$\alpha_c = \frac{w_c^t}{w_c^s} \quad (4)$$

روش MMD با فرض $w_c^s = w_c^t$ در واقع بایاس کلاس‌ها را نادیده گرفته که خود باعث افزایش خطا در طبقه‌بند می‌شود. حال، نگاشت جدیدی از توزیع احتمال در دامنه منبع با نماد $p_{s,\alpha}(x_s)$ تعریف می‌کنیم.

$$p_{s,\alpha}(x_s) = \sum_{c=1}^C \alpha_c w_c^s p_s(x_s | y_s = c) \quad (5)$$

که در آن $p_s(x_s | y_s = c)$ احتمال شرطی و C نیز تعداد کلاس‌ها می‌باشند. حال به‌جای استفاده از دامنه منبع از توزیع $p_{s,\alpha}(x_s)$ در رابطه ۱ استفاده می‌شود.

$$\text{WMMD}^2(D_s, D_t) = \left\| \frac{1}{\sum_{i=1}^M \alpha_{y_i^s}} \sum_{i=1}^M \alpha_{y_i^s} \varphi(x_i^s) - \frac{1}{N} \sum_{i=1}^N \varphi(x_i^t) \right\|_{\mathcal{H}}^2 \quad (6)$$

که در رابطه بالا M تعداد نمونه‌های منبع و N تعداد نمونه‌های هدف می‌باشد. فضای هیلبرت با توجه به تعریف اولیه MMD می‌باشد. در بخش WMMD تطبیق دامنه بر مبنای متریک WMMD و رابطه ۶ که در قسمت قبلی به آن اشاره شد و با کمک شبکه عصبی پیچشی عمیق صورت می‌گیرد. طبق شکل ۲، در این شبکه مجموعاً ۲۱ لایه

خوشه‌ها است و در این مقاله بر اساس فاصله اقلیدسی در نظر گرفته شده است.

نکته‌ای که در پژوهش‌های پیشین مورد توجه قرار نگرفته فشرده‌گی درون-کلاسی است که به صورت افزاز زیردامنه‌ای و محلی برای هر کلاس در دامنه منبع و هدف بررسی شده است. پس در نتیجه پیدا کردن مرکز خوشه در دامنه منبع و انتقال آن به عنوان شبه-برچسب به عنوان ورودی بخش استخراج ویژگی‌ها در نظر گرفته می‌شود. رابطه کلی خوشه‌بندی فازی c-means بر اساس تابع هدف رابطه ۸ می‌باشد.

$$\sum_{i=1}^c \sum_{k=1}^n u_{ik}^m \|x_k - v_i\|_A^2 = \sum_{i=1}^c u_{ik}^m d_{ik}^2 \quad (8)$$

که در آن m یک عدد حقیقی بزرگتر از ۱ (معمولاً ۲ است) d_{ik}^2 معیار شباهت، n تعداد ابعاد، x_k داده k ام و v_i مرکز خوشه i ام می‌باشند. پس هدف کمینه‌سازی فاصله بین ویژگی‌های و مراکز مشترک است که موجب تعمیم آن از فضای محلی به فراگیر و در نتیجه موجب فاصله بیشتر داده‌ها با مرز تصمیم^{۲۳} می‌شود. در این پژوهش در واقع از اطلاعات کلاس‌ها دامنه منبع و هدف در جهت پایداری بیشتر نسبت به داده‌ها و برچسب‌های نویز در دامنه هدف استفاده شده است. همان‌طور که از رابطه ۹ مشخص است، c_{y_i} مرکز مشترک آن برچسب می‌باشد؛ همچنین x_i ویژگی i ام داده می‌باشد. هدف کمینه‌سازی رابطه ۹ می‌باشد.

$$\mathcal{L}_c = \frac{1}{2} \sum_{i=1}^m \|x_i - c_{y_i}\|_2^2 \quad (9)$$

۴.۲. استخراج ویژگی‌ها

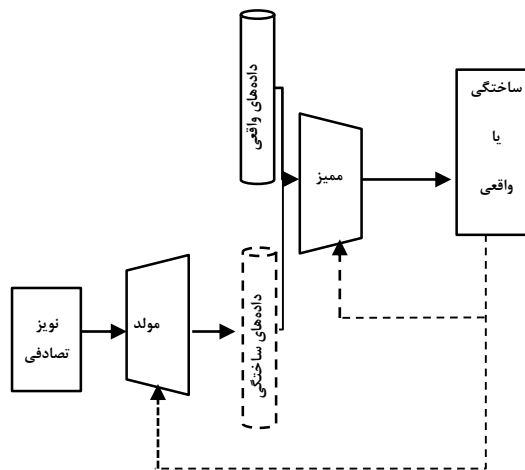
در روش پیشنهادی برای استخراج ویژگی‌ها از شبکه تخصصی مولد در فضای واسراشتاین^{۲۴} یا^{۲۵} [17] WGAN استفاده شده است. دلیل استفاده از این روش پایداری بالاتر در ساختار پیشنهادی نسبت به شبکه پایه‌ای GAN می‌باشد. تابع هزینه مولد و ممیز به ترتیب از رابطه ۱۰، ۱۱ می‌باشد.

$$D_{loss} = \mathbb{E}_{z \sim p_z(z)} [D(G(z))] - \mathbb{E}_{x \sim p_{data}(x)} [D(x)] \quad (10)$$

$$G_{loss} = -\mathbb{E}_{z \sim p_z(z)} [D(G(z))] \quad (11)$$

در رابطه ۱۱ برای جلوگیری از بیش-برازش یک ترم اضافه می‌کنیم در نهایت رابطه تابع هزینه در رابطه ۱۲ مشخص می‌باشد.

استفاده شده است. در معماری شبکه عصبی پیچشی پیشنهادی لایه آخر تمام-متصل به عنوان طبقه‌بند در مرحله نهایی فرآیند می‌باشد. خروجی این بخش همان y_i^f یا برچسب‌ها در دامنه هدف است.



شکل ۲: ساختار شبکه تخصصی مولد [۱]

۲.۲. طرح مسئله

در مسئله تطبیق دامنه بدون مجموعه داده‌ها در دامنه منبع به صورت:

$$D_s = \{x_i^s, y_i^s\}_{i=1}^{n_s} \quad (7)$$

که در آن x_i^s به عنوان داده‌های دامنه منبع، y_i^s به عنوان برچسب داده‌های منبع، n_s تعداد نمونه‌ها می‌باشند. همچنین $D_t = \{x_j^t\}_{j=1}^{n_t}$ به عنوان مجموعه داده‌های دامنه هدف می‌باشند. پارامتر x_j^t به عنوان داده‌های دامنه هدف می‌باشد و n_t تعداد نمونه‌ها است. به دست آوردن برچسب‌های دامنه هدف، خروجی بخش نهایی پژوهش می‌باشد.

در مسئله تطبیق دامنه بدون نظارت توزیع حاشیه‌ای^{۲۲} دامنه منبع و هدف متفاوت است و به صورت $P(x^s) \neq Q(x^t)$ نمایش داده می‌شود.

۳.۲. خوشه‌بندی فازی

یکی از کاربردهای منطق فازی پوشش عدم قطعیت در مدل می‌باشد [۱۴]. در این پژوهش از الگوریتم فازی c-means [15] استفاده شده است. الگوریتم فازی c-means یکی از متداول‌ترین الگوریتم‌های خوشه‌بندی است [۱۶]. این روش یک الگوریتم تکرار شونده می‌باشد که معمولاً به یک نقطه کمینه محلی یا زینی همگرا می‌شود. این الگوریتم با هدف یک تقسیم‌بندی فازی بهینه است. معیار اصلی این خوشه‌بندی بر اساس فاصله و فشرده‌گی می‌باشد که معمولاً بر اساس ساختار هندسی

شبکه تخصصی مولد صورت می‌پذیرد. یک خروجی از بخش استخراج ویژگی‌ها به قسمت خوشه‌بند انتقال می‌یابد. اساس الگوریتم این بخش، الگوریتم فازی c-means می‌باشد و بر اساس این الگوریتم مراکز خوشه دامنه منبع به عنوان مراکز اولیه دامنه هدف در نظر گرفته شده و خوشه‌بندی بر آن مبنای دامنه هدف صورت می‌گیرد تا در نهایت به تخمین شبه برچسب در دامنه هدف منجر شود. به عبارت دیگر، نگاشتی از دامنه منبع به روی دامنه هدف به کمک الگوریتم فازی c-means نقش تخمین‌زن اولیه را برای برچسب‌های دامنه هدف دارد. در مرحله بعد تخمین برچسب‌های دامنه هدف که توسط خوشه‌بند فازی صورت گرفته است به عنوان ورودی جدید برای بخش استخراج ویژگی‌ها (ورودی جدید شبکه تخصصی مولد) در نظر گرفته می‌شود. در مرحله نهایی خروجی بخش استخراج ویژگی‌ها به عنوان ورودی شبکه CNN در نظر گرفته می‌شود و با اعمال متریک WMMD و طبق رابطه ۶ بهینه می‌گردد، در نهایت خروجی این بخش برچسب‌های دامنه هدف می‌باشند.

$$D_{loss} = \mathbb{E}_{z \sim p_z(z)} [D(G(z))] - \mathbb{E}_{x \sim p_{data}(x)} [D(x)] + \lambda \mathbb{E}_{x \sim \Omega} [|\nabla D(x)|_p - 1]^2 \quad (12)$$

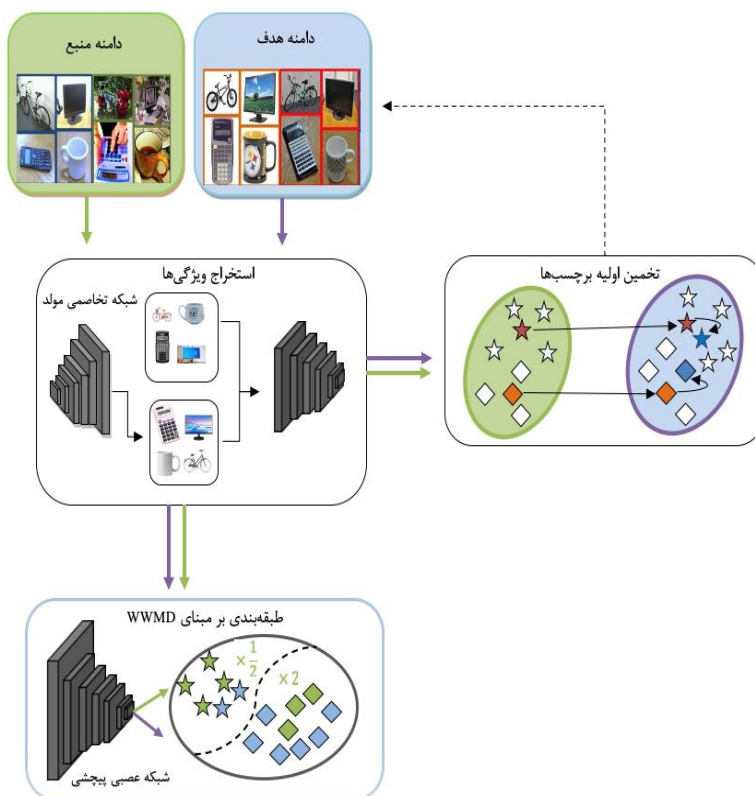
در رابطه فوق Ω ورودی فضای نمونه، $|\nabla D(x)|_p$ - نرم گرادیان ممیز و λ پارامتر جریمه می‌باشد.

شبکه مورد استفاده برای ممیز و مولد CNN است.

در شکل ۶ مؤلفه‌ها و ساختار معماری با جزئیات بیشتر نشان داده شده است. به طور کلی یادگیری در این شبکه بر مبنای گرادیان کاهش است و همچنین از الگوریتم بهینه سازی Adam [18]^{۲۶} به دلیل سرعت بالای همگرایی استفاده شده است.

۵.۲. ساختار مدل پیشنهادی

مطابق شکل ۳، ابتدا نمونه‌های ورودی از دامنه منبع (با برچسب) و دامنه هدف (بدون برچسب) به عنوان ورودی‌های اولیه بخش استخراج ویژگی‌ها در نظر گرفته شده‌اند. در این مدل همانطور که در بخش قبلی چنانچه اشاره شد استخراج ویژگی‌ها با استفاده از



شکل ۳: چارچوب کلی روش پیشنهادی

۳. آزمایش‌ها

۱.۳. داده‌های محک

مطابق شکل ۴، در ساختار پیشنهادی از پنج مجموعه داده با ویژگی SURF^{TV} جهت ارزیابی روش پیشنهادی استفاده می‌شود. مجموعه داده‌ها از: آمازون^{۲۸}، کلتک^{۲۹}، USPS، DSLR و MNIST تشکیل شده‌اند. مجموعه داده‌های آمازون، کلتک و DSLR شامل مجموعه تصاویر از اشیاء گوناگون با کیفیت‌های متفاوت در هر دامنه هستند. آمازون دارای ۹۵۸ تصویر، DSLR دارای ۱۵۷ تصویر و کلتک ۱۱۲۳ تصویر می‌باشند.



شکل ۴: نمونه مجموعه محک

تمام تصاویر این مجموعه‌ها دارای ۸۰۰ ویژگی و ۱۰ کلاس‌اند. در هر بار تطبیق دامنه یک دامنه به‌عنوان دامنه منبع و دامنه دیگر به‌عنوان دامنه هدف و بالعکس در نظر گرفته می‌شود. لازم به ذکر است تفاوت در توزیع بین مجموعه داده‌ها اثر مثبتی بر ارزیابی عملکرد تطبیق دامنه خواهد داشت.

جهت ارزیابی دقیق‌تر از مجموعه داده‌های اعداد از دو دامنه USPS و MNIST، که شامل عددهای دست‌نویس ۰ تا ۹ هستند نیز جهت ارزیابی الگوریتم پیشنهادی استفاده شده‌است. مجموعه داده USPS، ۱۸۰۰ تصویر به ابعاد ۱۶×۱۶ پیکسلی با ۲۵۶ ویژگی برای هر تصویر و ۱۰ کلاس دارد. در حالی که مجموعه داده MNIST متشکل از ۲۰۰۰ تصویر به ابعاد ۲۸×۲۸ پیکسلی با ۲۵۶ ویژگی برای هر تصویر و ۱۰ کلاس است. دو آزمایش با استفاده از این دو دامنه انجام می‌گیرد. جهت ارزیابی دقیق الگوریتم پیشنهادی، در هر آزمایش یکی از دو دامنه به عنوان دامنه منبع و دیگری به عنوان دامنه هدف (و بالعکس) در نظر گرفته می‌شود. در جدول ۲ مشخصات این مجموعه‌های محک به-تفکیک آمده‌است. لازم به ذکر است، توزیع هر عدد در دو مجموعه داده USPS و MNIST متفاوت است.

جدول ۲: مجموعه داده‌های محک

MNIST	USPS	کلتک	DSLR	آمازون	مجموعه داده
۲۰۰۰	۱۸۰۰	۱۱۲۳	۱۵۷	۹۵۸	تعداد نمونه
۱۰	۱۰	۱۰	۱۰	۱۰	تعداد کلاس
۲۵۶	۲۵۶	۸۰۰	۸۰۰	۸۰۰	تعداد ویژگی‌ها
M	U	C	D	A	نماد مجموعه

۲.۳. الگوریتم و ابزارهای پیاده‌سازی

مطابق شکل ۵، از الگوریتم خوشه‌بندی فازی c-means برای یافتن مراکز خوشه $\{c_i^s\}_{i=1}^{n_s}$ و تخمین اولیه برجسب‌های D_t استفاده شده‌است. الگوریتم پیشنهادی بر مبنای فاصله اقلیدسی می‌باشد. استخراج ویژگی‌های جدید توسط شبکه تخصصی مولد بر پایه شبه-برجسب‌ها در خوشه‌بندی فازی در گام ۱ صورت می‌پذیرد. گام ۲ بر مبنای رابطه ۴ است که از متریک WMMD استفاده شده‌است و بر مبنای الگوریتم Adam نیز بهینه‌سازی می‌شود. در انتها الگوریتم که همان خروجی گام ۲ می‌باشد، برجسب‌ها متناسب $\{y_j^t\}_{j=1}^{n_t}$ بر روی دامنه هدف قرار می‌گیرد.

۱- ورودی: داده‌های منبع $D_s = \{x_i^s, y_i^s\}_{i=1}^{n_s}$ و دامنه هدف $\{x_j^t\}_{j=1}^{n_t}$

۲- محاسبه مراکز خوشه‌ها $\{c_i^s\}_{i=1}^{n_s}$ با الگوریتم خوشه‌بندی فازی

۳- ایجاد حلقه:

۴- محاسبه فاصله بین $\{c_i^s\}_{i=1}^{n_s}$ و $\{x_j^t\}_{j=1}^{n_t}$ بر مبنای رابطه (۹)

۵- تخصیص برجسب بر مبنای نزدیک‌ترین فاصله اقلیدسی $\{x_j^t\}_{j=1}^{n_t}$ به

$$\{c_i^s\}_{i=1}^{n_s}$$

۶- تخمین اولیه برجسب‌های $\{\hat{x}_j^t, \hat{y}_j^t\}_{j=1}^{n_t}$

۷- انتهای حلقه

۸- محاسبه α_c بر مبنای رابطه (۳)

۹- کمینه‌سازی WMMD بر مبنای رابطه (۴)

۱۰- یادگیری شبکه بر مبنای الگوریتم Adam

۱۱- خروجی: $\{y_j^t\}_{j=1}^{n_t}$

شکل ۵: الگوریتم تطبیق دامنه بر مبنای خوشه‌بندی فازی و

شبه-برجسب

یکی از مسائل مهم پژوهش در حوزه یادگیری ماشین، بحث پیاده‌سازی الگوریتم‌ها است. زبان پایتون یک برنامه‌نویسی شیء‌گرا،

پیش‌بینی‌های یک مدل می‌باشد که با واقعیت مدل‌سازی شده هم‌خوانی دارد. دقت طبقه‌بندی از تقسیم تعداد اشیائی که درست طبقه‌بندی شده‌اند به تعداد کل اشیا و از رابطه ۱۳ حاصل می‌شود [۱۹].

$$Accuracy = \frac{TN + TP}{TN + FN + TP + FP} \quad (13)$$

دو معیار دقت و F1score به‌عنوان معیار جهت ارزیابی و مقایسه بین روش‌ها مورد استفاده قرار می‌گیرد. مقدار F1score (تشکیل شده از دو مؤلفه صحت^{۲۱} و پوشش^{۲۲}) از رابطه ۱۴ به‌دستی می‌آید.

$$F1score = \frac{پوشش \times صحت \times 2}{پوشش + صحت} \quad (14)$$

صحت و پوشش: صحت و پوشش معیارهای کاربردی در حوزه بازیابی اطلاعات هستند که میزان تناسب اسناد بازیابی شده توسط سیستم را با نیاز کاربر تعریف می‌کنند. این دو مؤلفه به‌ترتیب از رابطه ۱۵ و ۱۶ به‌دستی می‌آیند. در این دو رابطه منظور از:

TP: بیانگر تعداد رکوردهایی است که دسته واقعی آن مثبت بوده و الگوریتم به‌درستی مثبت تشخیص داده‌است [۱۹].

FN: بیانگر تعداد رکوردهایی است که دسته آن مثبت بوده و الگوریتم به‌اشتباه منفی تشخیص داده‌است.

FP: بیانگر تعداد رکوردهایی است که دسته واقعی آن منفی بوده ولی الگوریتم به‌اشتباه دسته آن را مثبت تشخیص داده‌است.

TN: بیانگر تعداد رکوردهایی است که دسته واقعی آن منفی بوده و الگوریتم نیز به‌درستی منفی تشخیص داده‌است.

$$Recall = \frac{TP}{FN + TP} \quad (15)$$

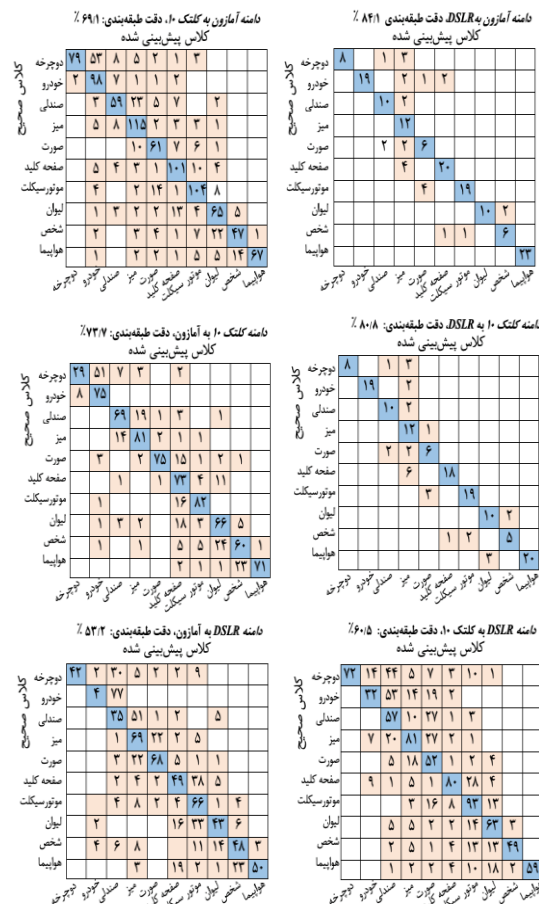
$$Precision = \frac{TP}{TP + FP} \quad (16)$$

تفسیری، سطح بالا و همه‌منظوره است و همچنین قابلیت‌های فراوانی در یادگیری ماشین داراست. برای پیاده‌سازی ساختار پیشنهادی از زبان برنامه‌نویسی پایتون از نسخه ۳.۹.۲ بر روی سیستم عامل مک BIG SUR نسخه ۱۱.۲.۳ استفاده می‌شود. کتابخانه‌های Tensorflow, Numpy, Keras, Pytorch، از جمله کتابخانه‌های اصلی مورد استفاده در پیاده‌سازی می‌باشند. مشخصات سخت‌افزاری سیستم جهت پیاده‌سازی نیز به شرح زیر می‌باشد:

IMAC- CORE I5- 8G RAM DDR4, PROCESSOR: 2.3 GHz, model: MMQA2 - 2017, eGPU RX 6800

۳.۳. ارزیابی و مقایسه نتایج

ارزیابی و مقایسه نتایج، با پنج روش پیشین شامل: DAN, MEDA, IAUDA و DANN, Dual Model با جزئیات کامل در شکل ۷ مشاهده می‌شود؛ مقایسه‌ها روش‌ها بر مبنای ماتریس درهم‌ریختگی^{۲۰} و دقت طبقه‌بندی می‌باشند.



شکل ۷: ماتریس درهم ریختگی

جدول ۴ نشان‌دهنده مقایسه روش پیشنهادی با پنج روش پیشین در انتقال دامنه از مجموعه داده‌های اعداد MNIST و USPS می‌باشد. روش پیشنهادی با میانگین دقت طبقه‌بند 83/2% با اختلاف 2/4% بهبود نسبت به بالاترین دقت روش‌های پیشین در رتبه اول و پس از آن MEDA در رتبه دوم با میانگین 80/8% قرار گرفته‌است. همچنین روش پیشنهادی نسبت میانگین ۵ روش دیگر که 71/2% است ۱۳ درصد بهبود داشته‌است. همچنین بر مبنای شاخص F1score روش پیشنهادی نسبت به روش MEDA حدود ۳ درصد بهبود داشته‌است و در رتبه اول قرار گرفته‌است.

۴.۳. ارزیابی پارامترهای شبکه

برای پیاده‌سازی، شبکه پیچشی در مجموع از ۲۱ لایه تشکیل شده‌است. این لایه‌ها شامل ۱۳ لایه پیچشی، ۵ لایه پولینگ^{۳۳} (بیشینه) و ۳ لایه تماماً متصل می‌باشد. در این شبکه از کرنل ۳×۳ استفاده شده‌است. مطابق شکل ۳، ۳ لایه اول دارای عمق ۶۴ و ۳ لایه دوم ۱۲۸، چهار لایه سوم ۲۵۶ و ۸ لایه آخر دارای عمق ۵۱۲ می‌باشند. یادگیری شبکه بر مبنای الگوریتم SGD^{۳۴} با تکانه^{۳۵} ۰/۹ و اندازه گروهی^{۳۶} ۲۵۶ صورت-پذیرفته‌است. تابع فعال‌سازی مورد استفاده RELU و Softmax می‌باشند. گام^{۳۷} مورد استفاده در این شبکه از بالا به پایین به صورت یک در میان ۱ و ۲ می‌باشد لازم به ذکر است که در ۳ لایه تمام-متصل پایانی، از تنظیم‌کننده^{۳۸} نرم L_2 استفاده شده‌است. مقدار λ برابر با ۰/۰۰۰۰۱، همچنین نرخ ۰/۵ برای حذف تصادفی^{۳۹} دو لایه اول، تماماً متصل در نظر گرفته شده‌است.

۴. جمع‌بندی و کارهای آتی

تطبيق دامنه بدون نظارت بر مبنای ساختار پیشنهادی شامل استفاده از شبکه تخصصی مولد برای استخراج ویژگی‌های تصاویر می‌باشد. همچنین استفاده از رهیافت زیر-دامنه با کمک روش خوشه‌بندی فازی و یافتن مراکز خوشه و توجه به فاصله درون کلاسی دامنه منبع و هدف و استفاده از شبکه‌های عصبی پیچشی عمیق در کنار متریک WMMD بر مبنای وزن‌دهی بر روی کلاس‌های دامنه منبع و هدف می‌باشد. پیاده-سازی روش پیشنهادی بر روی ۵ مجموعه داده محک استاندارد و مقایسه آن با روش‌های مطرح پیشین تطبيق دامنه بدون نظارت، نشان‌دهنده بهبود نتایج نسبت به پژوهش‌های پیشین می‌باشد. پیاده‌سازی روش پیشنهادی بر روی داده‌های متنی و همچنین استفاده از این روش در معماری چند-دامنه‌ای (که شامل بیش از یک دامنه منبع و هدف است) را می‌توان در ادامه این پژوهش به‌عنوان کارهای آتی در نظر گرفت.

جدول ۳: مقایسه نتایج تصاویر با شاخص دقت

روش پیشنهادی	IAUDA	Dual-Module	DANN	MEDA	DAN	دامنه منبع و هدف
۶۹/۱	۶۷/۹	۵۱/۳	۵۸/۳	۶۵/۳	۵۵/۲	A → C
۸۴/۱	۶۳/۸	۷۴/۶	۶۹/۸	۸۱/۴	۸۱/۱	A → D
۷۳/۷	۷۰/۸	۷۲/۸	۵۸/۵	۷۸/۳	۵۱/۱	C → A
۸۰/۸	۵۵/۲	۸۰/۲	۶۷/۳	۷۵/۶	۷۱/۳	C → D
۵۳/۲	۴۲/۳	۵۶/۴	۴۱/۴	۵۰/۸	۴۵/۵	D → A
۶۰/۵	۴۹/۹	۵۹/۱	۴۲/۹	۵۹/۹	۶۲/۳	D → C
۷۰/۲	۵۸/۳	۶۵/۷	۵۶/۳	۶۸/۵	۶۱/۱	میانگین

مطابق جدول ۳، روش پیشنهادی با ۵ روش پیشین و طبق معیار دقت مقایسه شده‌است. روش پیشنهادی از بین ۶ دامنه محک مورد ارزیابی در ۳ مورد بالاترین دقت را داشته و در مجموع با میانگین ۷۰/۲ رتبه اول در بین این مقایسه را داشته و نسبت به رتبه دوم بالاترین دقت روش MEDA با میانگین 68/5% به اندازه 1/7% بهبود داشته‌است. همچنین روش پیشنهادی نسبت به میانگین ۵ روش مورد مقایسه که 61/9% می‌باشد 8/3% رشد داشته‌است.

جدول ۴: مقایسه نتایج (اعداد) با شاخص دقت و F1score

روش پیشنهادی	میانگین	USPS	MNIST	دامنه منبع
		MNIST	USPS	دامنه هدف
DAN	۵۸/۱	۵۹/۲	۵۶/۹	
MEDA	۸۰/۸	۸۹/۵	۷۲/۱	
DANN	۶۷/۷	۶۵/۳	۷۰/۱	
Dual-Module	۷۹/۳	۸۰/۷	۷۷/۹	
IAUDA	۷۰/۱	۷۹/۴	۶۰/۸	
روش پیشنهادی	۸۳/۲	۸۲/۳	۸۴/۲	

- Distribution Alignment," in *26th ACM international conference on Multimedia*, 2018.
- [11]. Y. D. Hongliang Yan, Peihua Li, Qilong Wang, Yong Xu, Wangmeng Zuo, "Mind the Class Weight Bias: Weighted Maximum Mean Discrepancy for Unsupervised Domain Adaptation," presented at the IEEE Conference on Computer Vision and Pattern Recognition (CVPR), 2017.
- [12]. T. Z. Yiju Yang, Guanyu Li, Taejoon Kim, Guanghui Wang, "An unsupervised domain adaptation model based on dual-module adversarial training," *Neurocomputing*, vol. 475, pp. 102-111, 2022.
- [13]. K. M. B. Arthur Gretton, Malte J. Rasch, Bernhard Schölkopf, Alexander Smola, "A Kernel Two-Sample Test," *Journal of Machine Learning Research*, vol. 13, pp. 723-773, 2012.
- [14]. L. Zadeh, "Fuzzy Sets," *Information and Control*, vol. 8, pp. 338-353, 1965.
- [15]. R. E. James C. Bezdek, William Full, "FCM: The fuzzy c-means clustering algorithm," *Computers & Geosciences*, vol. 10, no. 2-3, pp. 191-203, 1984.
- [16]. M. T. S. Lida Naderlou, "Presenting a model for Multi-layer Dynamic Social Networks to discover Influential Groups based on a combination of Developing Frog Leaping Algorithm and C-means Clustering," *Intelligent Multimedia processing and Communication Systems (IMPCS)*, vol. 3, no. 3, pp. 29-39, 2022.
- [17]. S. C. Martin Arjovsky, and Léon Bottou, "Wasserstein GAN," *arXiv:1701.07875v3*, 2017.
- [18]. J. L. B. Diederik P. Kingma, "ADAM: A METHOD FOR STOCHASTIC OPTIMIZATION," *arXiv:1412.6980v9*, 2015.
- [19]. H. N. Mahdi Hariri, "Improve the Quality of Mammogram Images by Image Processing Techniques," *Intelligent Multimedia processing and Communication Systems (IMPCS)*, vol. 3, no. 1, pp. 57-69, 2022.
- [1]. J. P.-A. I. Good fellow, M. Mirza, B. Xu, D. Warde-Farley, S. Ozair, A. and a. Y. B. Courville, "Generative adversarial nets," presented at the 27th Advances in Neural Information Processing Systems, 2014.
- [2]. A. C. Yoshua Bengio, Pascal Vincent, "Representation Learning: A Review and New Perspectives," *IEEE transactions on pattern analysis and machine intelligence*, vol. 35, no. 8, pp. 1798-1828, 2013.
- [3]. Y. B. Yann LeCun, Geoffrey Hinton, "Deep learning," *Nature*, vol. 521, pp. 436-444, 2015.
- [4]. X. Z. Rongrong Peng, and Peiming Shi "Multi-Representation Domain Adaptation Network with Duplex Adversarial Learning for Hot-Rolling Mill Fault Diagnosis," *Entropy*, vol. 25, no. 1, p. 83, 2023.
- [5]. C. Z. Peiyi Wei, Yanping Tang, Zhixin Li, Zhiwen Wang, "Reinforced domain adaptation with attention and adversarial learning for unsupervised person Re-ID," *Applied Intelligence*, vol. 53, pp. pages4109-4123, 2023.
- [6]. I. S. Alex Krizhevsky, Geoffrey E. Hinton, "ImageNet Classification with Deep Convolutional Neural Networks," presented at the 25th Advances in Neural Information Processing Systems 2012.
- [7]. R. W. PEEYUSH SINGHAL, SHEELA RAMANNA, and A. K. KOTTECHA, "Domain Adaptation: Challenges, Methods, Datasets, and Applications," *IEEE Access*, vol. 11, 2023.
- [8]. Y. C. Mingsheng Long, Jianmin Wang, Michael I. Jordan, "Learning Transferable Features with Deep Adaptation Networks," presented at the 32nd International Conference on Machine Learning, Lille, France, 2015.
- [9]. E. U. Yaroslav Ganin, Hana Ajakan and P. Germain, "Domain-Adversarial Training of Neural Networks," *Journal of Machine Learning Research*, vol. 17, pp. 1-35, 2016.
- [10]. W. F. Jindong Wang, Yiqiang Chen, Han Yu, Philip S. Yu, "Visual Domain Adaptation with Manifold Embedded

پی نوشت

21 KL divergence
22 Marginal distribution
23 Decision boundary
24 Wasserstein
25 Wasserstein-GAN
26 Adaptive moment
27 Speeded Up Robust Features
28 Amazon
29 Caltech 10
30 Confusion Matrix
31 Precision
32 Recall
33 Max-pooling
34 Stochastic Gradient Descent
35 Momentum
36 Batch size
37 Stride
38 Regularizer
39 dropout

1 Global
2 Semantic alignment
3 Weighted MMD
4 Fully connected
5 Deep Adaptation Network
6 Multiple Kernel MMD
7 Kernel Function
8 Domain Adversarial neural networks
9 Gradient Reversal Layer
10 Geodesic Flow Kernel
11 Manifold Embedded Distribution Alignment
12 Grassmann manifolds
13 Dual-Module
14 High-level
15 Curse of dimensionality
16 Generator
17 Discriminator
18 Generator
19 discriminator
20 Cross entropy