

طبقه‌بندی تصویر مبتنی بر یادگیری انتقالی متخاصم بدون ناظر و حفظ فاصله‌ی بین کلاسی و درون کلاسی نمونه‌ها

ریام جبار سرخان^۱، دانشجو، محمدعلی بالافر^۱، استاد تمام^۲، محمدرضا فیضی درخشی^۳، استاد تمام، امین گلزاری اسکوئی^۴، دکتری

۱- دانشکده مهندسی برق و کامپیوتر- دانشگاه تبریز- تبریز- ایران - revamsarhan@gmail.com

۲- دانشکده مهندسی برق و کامپیوتر- دانشگاه تبریز- تبریز- ایران - balafarila@tabrizu.ac.ir

۳- دانشکده مهندسی برق و کامپیوتر- دانشگاه تبریز- تبریز- ایران - mfeizi@tabrizu.ac.ir

۴- گروه مهندسی نرم افزار، دانشکده مهندسی و علوم طبیعی، دانشگاه ایستینه، استانبول، ترکیه - a.golzari@tabrizu.ac.ir

چکیده: در سال‌های اخیر در کاربردهای بینایی ماشین به‌طور فزاینده‌ای از تکنیک‌های یادگیری عمیق استفاده می‌شود. اما در برخی از کاربردها، به دلیل داده‌های ناکافی، مدل به‌درستی آموزش داده نمی‌شود که منجر به کاهش تعمیم‌پذیری می‌شود. به‌طوری‌که وقتی یک مدل یادگیری عمیق بر روی یک مجموعه‌داده آموزش داده می‌شود و روی مجموعه‌داده مشابه دیگری آزمایش می‌شود، این مدل نتایج تقریباً تصادفی را پیش‌بینی می‌کند. در این مقاله با هدف برطرف کردن این مشکل، از یادگیری انتقالی متخاصم بدون ناظر چندمنبعی برای افزایش تعمیم‌پذیری مدل بر روی مجموعه‌داده‌های مختلف (مبدأ و مقصد) استفاده می‌شود. در تکنیک پیشنهادی، شبکه وادار می‌شود به‌جای یادگیری ویژگی‌های مختص یک دامنه خاص، ویژگی‌های مشترک بین مجموعه‌داده‌های مختلف (مبدأ و مقصد) را یاد بگیرد. همچنین از یک تابع خطای جدید مبتنی بر حفظ فاصله‌ی بین کلاسی و درون کلاسی استفاده می‌شود. با استفاده از تابع خطای پیشنهادی، شبکه بازنمایی‌های مشابه برای نمونه‌های متعلق به یک کلاس و بازنمایی‌های غیرمشابه برای نمونه‌های متعلق به کلاس‌های مختلف را به‌طور مؤثرتر یاد می‌گیرد. ارزیابی روش پیشنهادی با بررسی سناریوهای مختلف انتقال با چهار مجموعه‌داده‌ی MNIST، MNIST-M، SVHN، و USPS انجام گرفته و با نتایج سایر الگوریتم‌های موفق مقایسه می‌شود. دقت روش پیشنهادی به ازای مجموعه‌داده‌های MNIST، MNIST-M، SVHN، و USPS به ترتیب ۹۹٫۵، ۹۸٫۸، ۹۸٫۵ و ۹۸٫۲ درصد است.

واژه‌های کلیدی: طبقه‌بندی تصویر، یادگیری انتقالی، تطبیق دامنه متخاصم چندمنبعی، یادگیری عمیق

Image classification based on unsupervised adversarial transfer learning and preserving the inter-class and intra-class distance

Mohammadali Balafar, Full professor¹, Riyam Jabbar Sarhan, PhD student², Mohammad Reza Feizi Derakhshi, Full professor³, Amin Golzari Oskouei, PhD⁴

1- Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: riyamsarhan@gmail.com

2- Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: balafarila@tabrizu.ac.ir

3- Faculty of Electrical and Computer Engineering, University of Tabriz, Tabriz, Iran, Email: mfeizi@tabrizu.ac.ir

4- Department of software engineering, Faculty of Engineering and natural science, İstinye university, Istanbul, Türkiye, Email: a.golzari@tabrizu.ac.ir

Abstract: The paper explores the growing use of deep learning in machine vision, acknowledging challenges in model generalizability due to insufficient data. To address this issue, the proposed solution employs multi-source unsupervised adversarial transfer learning, enhancing adaptability across diverse datasets. This approach compels the network to learn shared features between different datasets rather than domain-specific ones. A novel loss function is introduced, emphasizing inter-class and intra-class distance preservation. This enhances the network's ability to learn similar representations for samples within the same class and dissimilar representations for instances across different classes. Evaluation involves testing on MNIST, MNIST-M, SVHN, and USPS datasets under various transmission scenarios. Comparative analysis with other algorithms demonstrates the effectiveness of the proposed approach, achieving accuracies of 99.5%, 98.8%, 98.5%, and 98.2% for MNIST, MNIST-M, SVHN, and USPS datasets, respectively. The results highlight the solution's success in addressing insufficient data challenges and improving model generalizability in machine vision applications.

Keywords: Deep learning, Image classification, Transfer learning, Multi-source Adversarial Domain Adaptation.

تاریخ ارسال مقاله: ۱۴۰۲/۱۰/۱۱

تاریخ اصلاح مقاله: ۱۴۰۳/۰۱/۲۲

تاریخ پذیرش مقاله: ۱۴۰۳/۰۲/۰۲

نام نویسنده مسئول: محمدعلی بالافر

نشانی نویسنده مسئول: ایران - تبریز - بلوار ۲۹ بهمن - دانشگاه تبریز - دانشکده مهندسی برق و کامپیوتر - گروه کامپیوتر.

۱- مقدمه

به‌تنهایی برای آموزش و تعمیم مدل کافی نباشد، با یادگیری انتقال چندمنبعی امکان‌پذیر می‌شود.

با این حال، ماهیت مجموعه‌داده‌های منبع ممکن است بسیار متنوع باشد، و میزان شباهت بین منبع و هدف به‌طور قابل توجهی بر کارایی انتقال تأثیر می‌گذارد؛ بنابراین، یادگیری انتقالی گاهی اوقات می‌تواند به ضرر آموزش مدل و تعمیم‌پذیری آن عمل کند. علاوه بر این، این احتمال وجود دارد که مدل ویژگی‌های منحصر به فرد هر مجموعه‌داده را به‌جای ویژگی‌های مشترک بین آن‌ها کشف کند. در نتیجه، مانع از توانایی الگوی آموخته‌شده برای تعمیم می‌شود.

در تحقیقات اخیر تمام تلاش‌ها حاصل برای طراحی معماری بهتر و در نتیجه آن یادگیری بهتر مدل و افزایش دقت پیش‌بینی‌های حاصل است. اما باید به این نکته توجه کرد که در مدل‌های یادگیری عمیق معماری مدل در کنار یک تابع خطا خوب، بهترین نتیجه را دارد. در این تحقیق علاوه بر استفاده از یک معماری بر پایه یادگیری انتقالی متخاصم چند منبعی (الهام گرفته‌شده از [۳۸]) از یک تابع خطا جدید استفاده می‌شود. این تابع خطا علاوه بر افزایش تعمیم‌پذیری و انتقال‌پذیری مدل، دقت پیش‌بینی‌های حاصل را نیز به‌طور فزاینده‌ای افزایش می‌دهد.

در [۳۸] از دو مجموعه‌داده برای آموزش شبکه بهره برده است. با الهام از مقاله مذکور، در این مقاله نیز برای افزایش تعمیم‌پذیری شبکه از دو مجموعه‌داده استفاده می‌شود. هدف این است که بازنمایی‌های یکسان از بین دو مجموعه‌داده یادگرفته شود. روش پیشنهادی با روش [۳۸] چند تفاوت اساسی دارد: ۱) روشی پیشنهادی از معماری ResNet50 استفاده می‌کند. در حالی که روش مقاله [۳۸] از معماری‌های قدیمی غیر از ResNet50 استفاده می‌کند مانند LeNet-5 یا معماری‌های تمام متصل که برای دسته‌بندی تصاویر مناسب نیستند (مانند معماری‌های تمام متصل) ۲) توابع هدف استفاده‌شده در هر دو روش متفاوت است. در روش پیشنهادی از توابعی استفاده می‌شود که برای تمیز بهتر تصاویر مناسب باشد. ۳) دقت و کارایی روش پیشنهادی بسیار بهتر از روش مقابل است.

در این مطالعه، یک استراتژی تطبیق دامنه بدون ناظر برای طبقه‌بندی تصویر با استفاده از تابع خطای مبتنی بر حفظ فاصله بین کلاسی و درون کلاسی برای پرداختن به مشکل مذکور ارائه می‌شود. در روش پیشنهادی بازنمایی‌های مشابه و مفید از بین دو مجموعه‌داده مجزا (مبدأ و مقصد)، بدون توجه به دامنه هر مجموعه‌داده یادگرفته می‌شود. مجموعه‌داده مقصد برای بهبود قابلیت انتقال و تعمیم‌پذیری استفاده می‌شود در حالی که مجموعه‌داده مبدأ برای آموزش شبکه استفاده می‌شود. در روش پیشنهادی، یک ماژول جدید استفاده می‌شود که منبع داده‌های ورودی را بر اساس ویژگی‌های استخراج‌شده آن تمیز و جدا می‌کند. بر اساس تئوری ارائه‌شده، پس از آموزش شبکه، بازنمایی‌ها با تعمیم‌پذیری بالا برای اهداف دیگر بهتر یادگرفته

بینایی ماشین یکی از زمینه‌های هوش مصنوعی است که به ماشین‌ها قدرت مشاهده محیط اطراف و تجزیه و تحلیل و پردازش اطلاعات اطراف را می‌دهد [۱، ۲]. تأکید سیستم‌های بینایی ماشین بیشتر بر قابلیت تحلیل تصاویر و استخراج اطلاعات مفید از آن‌ها برای یک کاربرد خاص است [۳-۸]. بینایی ماشین در کاربردهای مختلفی مانند طبقه‌بندی تصاویر رنگی [۹، ۱۰]، پردازش تصاویر پزشکی [۲، ۱۱-۱۸] تشخیص اشیا [۱۹] تشخیص چهره [۴] و تشخیص اثر انگشت [۲۰] استفاده می‌شود. در بینایی ماشین، فرایند شناسایی و برچسب‌گذاری یک تصویر بر اساس قوانین خاص به‌عنوان طبقه‌بندی تصویر شناخته می‌شود. طبقه‌بندی تصویر در بسیاری از کاربردهای بینایی ماشین، از جمله پردازش تصویر پزشکی [۲۱، ۲۲]، تشخیص آتش [۲۳]، تشخیص جعل اسناد [۲۴] و طبقه‌بندی تصاویر ماهواره‌ای [۲۵] و غیره [۱۰، ۲۲، ۲۶-۳۳] استفاده می‌شود. الگوریتم‌های یادگیری ماشین برای کاربردهای نظارت‌شده مانند طبقه‌بندی تصویر از مقدار زیادی داده‌ی برچسب‌گذاری شده استفاده می‌کنند. سپس داده‌های بدون برچسب با استفاده از مدل آموزش‌دیده طبقه‌بندی می‌شوند. در این الگوریتم‌ها داده‌های زیادی برای آموزش مؤثر مدل مورد نیاز است، به‌خصوص زمانی که از مدل‌های یادگیری عمیق استفاده می‌شود. در برخی کاربردها، ممکن است به دست آوردن داده‌هایی که به‌اندازه کافی برچسب‌گذاری شده باشند، چالش‌برانگیز باشد. این به این دلیل است که برچسب زدن آن‌ها هزینه‌بر و زمان‌بر است. رویکردهای متعددی از جمله [۳۴-۳۷] برای برطرف کردن این مشکل ارائه شده‌اند. داده‌افزایی یکی از این استراتژی‌هاست. با استفاده از تکنیک‌های تبدیل داده‌ها مانند چرخش تصویر، جابه‌جایی افقی یا عمودی و چرخش افقی یا عمودی، می‌توان تعداد داده‌ها را با این روش افزایش داد [۳۶]. در برخی تکنیک دیگر کارایی داده می‌تواند بهبود یابد، مانند یادگیری چند شات [۳۴].

برخی تکنیک‌ها نیز، دانش قبلی را به مدل‌های عمیق القا می‌کنند. هدف از این کار این است که مدل را با داده کم آموزش داد. این دانش می‌تواند برای دامنه خاص و دانش تخصصی باشد، یا می‌تواند با آموزش مدل بر روی سایر داده‌های نیمه مرتبط و سپس تنظیم دقیق آن با داده‌های مورد مطالعه به دست آید که تکنیک اخیر با عنوان یادگیری انتقالی شناخته می‌شود. یادگیری انتقالی این مشکل را دارد که توزیع دامنه‌های آموزشی و آزمون ممکن است یکسان نباشد که دقت رویکرد یادگیری عمیق را در طبقه‌بندی داده‌های آزمون کاهش می‌دهد. یادگیری انتقال چندمنبعی را می‌توان برای ترکیب بسیاری از منابع و استخراج دانش از آن‌ها برای برطرف کردن این مشکل استفاده کرد [۳۵]. یادگیری ویژگی‌های مشترک و انتقال دانش بین مجموعه‌داده‌های متعدد می‌تواند تعمیم‌پذیری یک مدل را افزایش دهد. استفاده از مجموعه‌های داده مختلف که ممکن است هر یک

آزمایشی تأکید می‌کند. این روش همچنین ضریب اهمیت توزیع شرطی را در تطبیق دامنه در نظر می‌گیرد.

JDS [46]، دو ضریب اهمیت جداگانه را برای انطباق دامنه اصلی برای توزیع‌های حاشیه‌ای و شرطی در نظر می‌گیرد. علاوه بر این، برخلاف تمام روش‌های قبلی که از یک طبقه‌بندی کننده ساده مانند نزدیک‌ترین همسایه استفاده می‌کنند، این روش طبقه‌بندی کننده‌ای را پیشنهاد می‌کند که بر کاهش خطا طبقه‌بندی و حفظ ساختار دامنه‌ها متکی است.

در تحقیق [21] تنها کاهش فاصله توزیع شرطی و افزایش فاصله بین کلاسی دامنه مجموعه داده منبع در نظر گرفته شده و از فاصله کرنل برای تطبیق داده‌های دامنه‌ها در فضای غیرخطی پیشنهاد شده است. اگرچه دو توزیع حاشیه‌ای و شرطی مهم هستند، اما کاهش فاصله بین نمونه‌ها در یک کلاس نیز تأثیر قابل توجهی در تطبیق دامنه دارد که در این روش در نظر گرفته نشده است.

ADCDA [47]، علاوه بر در نظر گرفتن افزایش واریانس هر دو دامنه آموزشی و آزمایشی مانند روش CS-DDA، اطلاعات متمایزکننده هندسی دامنه آموزشی را از طریق روش توسعه یافته برای کاهش فاصله بین نمونه‌های درون کلاسی و افزایش فاصله بین نمونه‌های بین کلاسی حفظ می‌کند. در این روش اهمیت متمایزکننده توزیع شرطی و حاشیه‌ای و حفظ ساختار حوزه‌ها در نظر گرفته نمی‌شود.

روش UDAGM [48] همه اهداف لازم را در نظر گرفته است (یعنی هم‌ترازی زیر فضا؛ به حداقل رساندن واگرایی توزیع با استفاده از معیار حداکثر میانگین فاصله؛ حفظ اطلاعات متمایزکننده دامنه منبع؛ حفظ اطلاعات اصلی شباهت نمونه‌های داده؛ به حداقل رساندن واریانس دامنه هدف). چارچوب پیشنهادی قادر به یادگیری زیر فضای ویژگی مشترک بین هر دو دامنه با تفکیک‌پذیری بین کلاسی و فشردگی درون کلاسی است. از این رو، طبقه‌بندی اشتباه نمونه‌های دامنه هدف به حداقل می‌رسد. این روش از به حداقل رساندن واریانس دامنه منبع غفلت می‌کند و اهمیت متمایز توزیع‌های حاشیه‌ای و شرطی را در نظر نمی‌گیرد. آزمایش‌های گسترده بر روی شناسایی چهره مجموعه داده PIE و مجموعه داده‌های Office-Caltech اثربخشی UDAGM را در مقایسه با سایر روش‌های تطبیق دامنه پیشرفته و سایر روش‌های ابتدایی تأیید می‌کند.

همان‌طوری که در این قسمت بحث شد روش‌های موجود در این حوزه اغلب به‌نوعی در یادگیری ویژگی‌های مشترک بین دو مجموعه داده منبع و هدف با مشکل مواجه هستند و نمی‌توانند ویژگی‌های مشترک بین دو مجموعه داده را به‌خوبی فراگیرند. همچنین برخی از این روش فقط بر روی مجموعه داده منبع یا مجموعه داده هدف عملکرد بهتری دارند. از این رو ارائه یک روش جامع که بتواند به‌خوبی ویژگی‌های مشترک دو مجموعه داده را یاد گرفته و ویژگی‌های جداکننده بین کلاسی را در نظر بگیرد حائز اهمیت است.

می‌شوند. مدل ارائه شده می‌تواند داده‌ها را بدون توجه به ویژگی‌های منحصر به فرد هر دامنه داده ورودی به‌درستی طبقه‌بندی کند.

سه هدف این مطالعه به شرح زیر است:

(۱) رویکرد انطباق دامنه بدون ناظر معرفی شده تأثیر تفاوت‌های ساختاری و درونی در تصاویر را به حداقل می‌رساند.

(۲) مدل پیشنهادی از قابلیت انتقال و تعمیم‌پذیری بالایی به سایر مجموعه داده‌های جدید برخوردار است.

(۳) تابع خطای مبتنی بر حفظ فاصله بین کلاسی و درون کلاسی پیشنهادی به یادگیری بازنمایی‌های دقیق‌تر و جدا پذیر تر کمک می‌کند.

بخش‌های دیگر مقاله به این شرح سازمان‌دهی شده است: بخش ۲ تحقیقات مرتبط را مرور می‌کند. بخش ۳ چارچوب پیشنهادی را معرفی می‌کند. بخش ۴ آزمایش‌ها را شرح می‌دهد و بخش ۶ به نتیجه‌گیری می‌پردازد.

۲- کارهای مرتبط

این بخش بیشتر بر روی روش‌های تطبیق دامنه تمرکز خواهد داشت. JGSA [39] یکی از روش‌هایی است که دو ماتریس نگاشت متفاوت برای دو دامنه ایجاد می‌کند. این روش تطبیق دامنه را با به حداقل رساندن معیار حداکثر اختلاف میانگین [40]، افزایش واریانس مجموعه دامنه هدف، کاهش فاصله بین نمونه‌های درون کلاسی، افزایش فاصله بین نمونه‌های بین کلاسی دامنه منبع انجام می‌دهد. مشکل این روش این است که حفظ ساختار اصلی داده‌ها در حین تطبیق در نظر گرفته نشده است که موضوع مهمی است.

DISA [41]، علاوه بر استفاده از تمامی مؤلفه‌های تحقیق قبلی، به حفظ ساختار هر دامنه در حین انطباق نیز توجه دارد، اما به ساختار هندسی بین دامنه‌ای، و همچنین انطباق هندسی دامنه‌ها توجهی ندارد و از این نظر ایراد این روش محسوب می‌شود.

LPJT [42] برای کاهش تفاوت بین توزیع شرطی و حاشیه‌ای، وزن نمونه‌ها را نیز در نظر می‌گیرد. همچنین به کاهش فاصله بین نمونه‌های درون کلاسی و افزایش فاصله بین نمونه‌های بین کلاسی در دو دامنه مبدأ و مقصد توجه دارد. اما در این روش به ساختار هندسی بین دامنه‌ها و همچنین انطباق هندسی حوزه‌ها توجهی نمی‌شود.

GEDA [43]، مانند روش قبلی، از نمودار لاپلاس برای کاهش فاصله درون کلاسی و افزایش فاصله بین کلاسی در هر دامنه استفاده می‌کند، اما برخلاف روش قبلی از یک طبقه‌بند ساده استفاده می‌کند. به‌عنوان مثال، از نزدیک‌ترین همسایه برای پیش‌بینی برچسب‌های داده‌های آزمایشی استفاده می‌کند، این روش از الگوریتمی به نام EasyTL [44] استفاده می‌کند که هیچ پارامتری ندارد و پیاده‌سازی آن آسان است.

CS-DDA [45]، برخلاف روش‌های قبلی که اغلب فقط واریانس دامنه هدف را افزایش می‌دادند، بر افزایش واریانس هر دو دامنه آموزشی و

۳- روش پیشنهادی

در شکل ۱، چارچوب پیشنهادی به صورت گرافیکی نشان داده شده است. این شکل نشان می‌دهد که چگونه مدل پیشنهادی از دو مجموعه داده مجزا برای یادگیری بازنمایی‌های مشترک و مستقل از دامنه هر مجموعه داده استفاده می‌کند. مجموعه داده هدف برای بهبود تعمیم‌پذیری استفاده می‌شود در حالی که مجموعه داده منبع برای آموزش شبکه استفاده می‌شود. سه مؤلفه معماری پیشنهادی عبارت‌اند از استخراج‌کننده ویژگی، طبقه‌بندی‌کننده و متمایزکننده. بلوک استخراج‌کننده برای استخراج ویژگی‌ها مستقل از دامنه ورودی، بلوک طبقه‌بندی‌کننده برای دسته‌بندی تصاویر ورودی و بلوک متمایزکننده برای جداسازی داده‌های منبع از داده‌های هدف استفاده می‌شود. هدف نهایی روش پیشنهادی، نزدیک‌تر کردن بازنمایی تصاویر متعلق به دو دامنه مختلف با کلاس شبیه به هم است به نحوی که بدون توجه به منبع ورودی و ویژگی‌های خاص هر توزیع ورودی، تشخیص درستی انجام شود. در عین حال روش پیشنهادی سعی می‌کند فاصله بین کلاسی را به حداکثر و فاصله درون کلاسی را به حداقل برساند؛ بنابراین، بازنمایی‌های آموخته‌شده مبتنی بر ویژگی‌های کلی دامنه‌های ورودی، مستقل از هر یک از دامنه‌ها و مجموعه داده خاص هستند، یعنی بازنمایی‌هایی هستند که هم برای مجموعه داده‌های منبع و هم برای مجموعه داده هدف مفید هستند.

معماری ResNet50 [۴۹] از قبل آموزش‌دیده را روی مجموعه داده imagenet در بلوک استخراج ویژگی استفاده می‌شود. در این معماری، پارامترهای شبکه به جز دو بلوک (دو لایه کانولوشنی) آخر ثابت هستند. وزن‌های دو بلوک آخر دز طی آموزش شبکه، یادگرفته می‌شوند. خروجی این بلوک به عنوان ورودی بلوک‌های طبقه‌بندی‌کننده و متمایزکننده استفاده می‌شود. دو ماژول متوالی از لایه‌های Dense، Relu، Batch-normalization و Dropout بلوک طبقه‌بندی‌کننده و متمایزکننده را تشکیل می‌دهند. پس از آن تابع فعال‌سازی مناسب را در بالای این دو بلوک اعمال می‌شود (با توجه به تعداد کلاس‌ها از sigmoid یا softmax استفاده می‌شود). احتمال انتصاب هر نمونه به یک کلاس خاص توسط خروجی بلوک طبقه‌بندی‌کننده مدل تعیین می‌شود. بلوک متمایزکننده از نظر معماری شبیه به بلوک طبقه‌بندی‌کننده است، با این تفاوت که خروجی احتمال تخصیص هر تصویر به هر مجموعه داده (منبع یا هدف) است.

در این مقاله برای افزایش تعمیم‌پذیری و قابلیت انتقال مدل، چارچوب یادگیری انتقال متخاصم چندمنبعی پیشنهاد می‌شود. پیش‌بینی‌کننده خروجی و طبقه‌بندی‌کننده دامنه هر دو به طور کلاسیک پس انتشار کردن خطا مربوطه خود، آموزش داده می‌شوند. هنگام رسیدن به ماژول استخراج ویژگی، خطا متمایزکننده دامنه با استفاده از لایه معکوس‌کننده گرادیان (GRL) معکوس می‌شود (در منفی یک ضرب می‌شود). در نتیجه، در عین حال که استخراج‌کننده ویژگی بازنمایی‌هایی را یاد می‌گیرد که برای پیش‌بینی خروجی مفید است،

همچنین ویژگی‌هایی یاد گرفته می‌شود که مستقل از دامنه‌ی داده‌ها است؛ بنابراین این ویژگی‌ها کلی هستند و می‌توان در دامنه‌های مختلف بدون آنکه تعمیم‌پذیری مدل کاهش یابد، از آن‌ها استفاده کرد. رابطه ۱ نشان‌دهنده تابع خطای روش پیشنهادی است. این تابع خطا ترکیبی از خطا طبقه‌بندی‌کننده خروجی و خطا طبقه‌بندی‌کننده دامنه است. λ_d ضریبی است که به خطا طبقه‌بندی‌کننده دامنه داده می‌شود و λ_y ضریب خطای طبقه‌بندی‌کننده خروجی است. هدف از این وزن‌دهی یافتن تعادل بهینه بین واریانس و بایاس برای تعمیم‌پذیری بهتر مدل است.

$$\mathcal{L} = \lambda_y \mathcal{L}_y + \lambda_d \mathcal{L}_d \quad (1)$$

$\mathcal{L}_d$ تابع خطای Cross-entropy است که از طریق رابطه ۲ محاسبه می‌شود. در این رابطه y_d نشان‌دهنده کلاس صحیح (مجموعه داده هدف یا منبع) و $\hat{y}_d$ نشان‌دهنده پیش‌بینی مدل است که آیا داده ورودی متعلق به مجموعه داده هدف است یا مجموعه داده منبع.

$$\mathcal{L}_d = -y_d \log(\hat{y}_d) \quad (2)$$

$\mathcal{L}_y$ تابع خطای پیشنهادی است که از طریق رابطه ۳ محاسبه می‌شود. این تابع خطا ترکیبی از تابع خطای Cross-entropy، تابع خطای مرکزی و تابع خطای Kullback-Leibler Divergence (KLD) (رابطه ۴) است. در این رابطه y_c نشان‌دهنده کلاس صحیح و $\hat{y}_c$ نشان‌دهنده پیش‌بینی مدل است.

$$\mathcal{L}_y = -y_c \log(\hat{y}_c) + \frac{1}{2} (\|x_i - C_{y_c}\|^2 + KLD) \quad (3)$$

$$KLD = y_c \log \frac{\hat{y}_c}{y_c} \quad (4)$$

C_{y_i} مرکز کلاس y_c است. ایده اصلی استفاده از این تابع خطا این است که نمونه‌ها در یک کلاس باید بازنمایی‌های شبیه به هم و نمونه‌ها در کلاس‌های مختلف باید بازنمایی‌های متفاوتی در فضای تعبیه‌شده داشته باشند. بر این اساس تابع خطا دو هدف دارد که هم‌زمان برای بهینه‌سازی آن‌ها تلاش می‌کند: (۱) کاهش واریانس درون کلاسی و (۲) افزایش واریانس بین کلاسی. هدف اول با رابطه $\frac{1}{2} (\|x_i - C_{y_i}\|^2 + KLD)$ تحقق می‌یابد یعنی کاهش فاصله نمونه‌های یک کلاس با مرکز آن کلاس و ترکیب با تابع خطای KLD. هدف دوم با رابطه CrossEntropy تحقق می‌یابد یعنی افزایش فاصله بین کلاسی.

باید به این نکته توجه کرد که تابع خطای KLD فاصله درون کلاسی را به خوبی مدل می‌کند ولی نمی‌تواند فاصله بین کلاسی را مدل کند. برخلاف تابع خطای KLD، تابع خطای Cross-entropy فاصله بین کلاسی را به خوبی مدل می‌کند ولی نمی‌تواند فاصله درون کلاسی را مدل کند. این توابع به تنهایی قادر نیستند فاصله بین و درون کلاسی را به خوبی حفظ کنند؛ بنابراین ترکیب این دو تابع در کنار تابع خطای مرکزی باعث می‌شود برای تمامی نمونه‌ها فاصله بین کلاسی به طور کارا زیاد و فاصله درون کلاسی کم شود. استفاده از تابع پیشنهادی می‌تواند به بهبود طبقه‌بندی داده‌ها کمک کند. نتایج عالی به کارگیری این تابع در کاربرد مورد بحث اعتبار این فرض را تأیید می‌کند.

علت استفاده از یک معیار ارزیابی این است که در اکثر روش‌های مشابه، اغلب از مجموعه‌داده‌های استاندارد بالانس استفاده می‌شود که در این مجموعه‌داده‌ها معیار دقت بهترین معیار است [۵۷-۵۹]. بنابراین در این تحقیق نیز از معیار دقت استفاده می‌شود.

۴-۲- مجموعه‌داده

در تحقیقات اخیر، مجموعه‌داده‌های زیر اغلب برای ارزیابی عملکرد مدل استفاده می‌شود: MNIST، MNIST-M، SVHN، USPS. در این تحقیق نیز عملکرد روش پیشنهادی را روی این مجموعه‌داده‌ها آزمایش می‌شود. جزئیات این مجموعه‌داده‌ها در جدول ۲ گزارش شده است.

جدول ۲- مجموعه‌داده

نمونه‌های آزمایش	نمونه‌های آموزش	تعداد نمونه	مجموعه‌داده
۱۰۰۰۰	۶۰۰۰۰	۷۰۰۰۰	MNIST
۱۰۰۰۰	۶۰۰۰۰	۷۰۰۰۰	MNIST-M
۲۶۰۳۲	۷۳۲۵۷	۹۹۲۸۹	SVHN
۲۰۰۷	۷۲۹۱	۹۲۹۸	USPS

۴-۳- داده‌افزایی

داده‌افزایی شامل افزایش نمونه‌های آموزش از طریق تبدیل تصاویر بدون از دست دادن اطلاعات معنایی است. در این کار، ما از پنج تغییر که به‌طور تصادفی روی نمونه‌های مجموعه‌داده آموزشی اعمال می‌شود، استفاده می‌کنیم. داده‌افزایی در حین آموزش شبکه انجام می‌شود، یعنی در هر تکرار (Epoch) داده‌های جدید تولید و به شبکه داده می‌شوند؛ بنابراین در هر تکرار تصاویری که به شبکه داده می‌شود متفاوت است. جدول ۳ جزئیات این تغییرات را نشان می‌دهد.

جدول ۳- شرح تکنیک‌ها و پارامترهای داده‌افزایی

تغییر	بازه/نوع
درخشندگی	20% تا ۲۰٪
کنتراست	20% تا ۲۰٪
چرخش (Rotation)	20- تا ۲۰+ درجه
چرخش (Flip)	افقی

این جدول نشان می‌دهد درخشندگی و کنتراست تصویر در بازه ۲۰- تا ۲۰+ درصد تغییر می‌کند. اگر درخشندگی بیش از ۲۰ درصد برسد تصویر حاصل تقریباً متمایل به سفید می‌شود که این امر ممکن است برای تشخیص درست مناسب نباشد و شبکه به‌درستی آموزش نبیند. از چرخش تصویر (Rotation) نیز برای تولید داده‌های جدید استفاده شده است. بازه چرخش تصویر ۲۰- تا ۲۰+ درجه انتخاب شده است. چرخش بیش‌تر از ۲۰ درجه یا کمتر از آن ممکن است باعث تغییر فرم شکل تصاویر شود و ممکن است به آموزش درست شبکه آسیب بزند.

باید به این نکته توجه داشت که در خطا مربوط به دامنه (I_d) هدف کمینه کردن خطا نیست. حالت ایده آل این است که این خطا بیشتر باشد. یعنی ویژگی‌هایی در مرحله استخراج ویژگی یاد گرفته شوند که شبکه به‌وسیله این ویژگی‌ها قادر نباشد نمونه‌های دو مجموعه‌داده ورودی (منبع و هدف) را از هم تشخیص دهد. به عبارتی هدف روش پیشنهادی این است که ویژگی‌های مشترک دو مجموعه‌داده یاد گرفته شود و نه ویژگی‌های مختص یک دامنه ورودی خاص. شاید این سؤال مطرح باشد که این امر ممکن است به بهینه‌سازی پارامترهای شبکه آسیب بزند. باید به نکته توجه کرد که در پس انتشار کردن خطا، خطا مربوط به دامنه (I_d) هنگام رسیدن به مازول استخراج ویژگی، به‌وسیله لایه معکوس کننده گرادیان (GRL) معکوس می‌شود. بنابراین مشکلی در بهینه‌سازی شبکه به وجود نمی‌آید. بنابراین با استفاده از این تکنیک ویژگی‌هایی یاد گرفته می‌شوند که مختص دامنه یک مجموعه‌داده خاص نباشند.

در آموزش شبکه برای مجموعه‌داده منبع از برجسب کلاس و برجسب دامنه ورودی (منبع و هدف) استفاده می‌کنیم و برای مجموعه‌داده هدف فقط از برجسب دامنه ورودی (منبع و هدف) استفاده می‌شود. داده‌های ورودی شبکه ترکیبی از داده‌های مجموعه‌داده هدف و مجموعه‌داده منبع است

۴-۴- آزمایش‌ها

اثربخشی رویکرد پیشنهادی در این بخش ارزیابی شده و با روش‌های دیگر مقایسه می‌شود. پارامترها و مقادیر برای تکنیک پیشنهادی در جدول ۱ فهرست شده است.

جدول ۱- پارامترها

مقدار	پارامتر
۳۲	اندازه دسته
۴	λ_y
۱	λ_d
۰/۵	Dropout
۰/۰۱	نرخ یادگیری (بهینه‌ساز adam)
۲۰۰۰۰	تعداد تکرار

۴-۱- معیار ارزیابی

در آزمایش‌ها، الگوریتم‌ها با استفاده از معیارهای دقت ارزیابی می‌شوند. معادله (۵) این معیارهای ارزیابی را نشان می‌دهد، در این رابطه TP، FN، TN، و FN به ترتیب مخفف True Positive، False Positive، True Negative و False Negative هستند. دقت به‌عنوان تعداد نمونه‌هایی که به‌درستی طبقه‌بندی شده‌اند تقسیم‌بر تعداد همه نمونه‌ها تعریف می‌شود [۹، ۱۰، ۲۲، ۳۱، ۵۰-۵۶].

$$Accuracy = \frac{TN+TP}{TN+TP+FN+FP} \quad (5)$$

عملکرد رویکرد پیشنهادی در بین همه رویکردها بهترین است. نتایج نشان می‌دهد که استراتژی پیشنهادی بهتر از سایر روش‌های شناخته‌شده در این زمینه عمل می‌کند. به دنبال روش ما، روش‌های DIRT-T (IN)، DIRT-T و SWD نسبتاً خوب عمل می‌کنند، و روش‌های DAN، DANN و DSN بدترین نتایج را در بین همه روش‌ها دارند. میانگین دقت روش پیشنهادی ۹۸٫۹٪ است. میانگین معیار دقت برای دومین رویکرد برتر (SHOT)، که بعد از روش پیشنهادی آمده است، ۹۸٫۴۳٪ است. این تفاوت دقت نشان می‌دهد روش پیشنهادی توانسته به‌خوبی ویژگی‌های مشترک دو مجموعه داده را یاد بگیرد و تعمیم‌پذیری مدل افزایش دهد.

۴-۵- آزمایش ۲: ارزیابی عملکرد تابع خطا

برای بررسی تأثیرگذاری تابع خطای اتخاذشده در روش پیشنهادی و مقایسه آن با تابع خطای CE، روش پیشنهادی یک بار با تابع خطای CE (معادل (۲)) و یک بار با تابع خطای پیشنهادی، به ازای λ_d و λ_y ارزیابی می‌شود. در این آزمایش، دقت روش پیشنهادی برای هر دو حالت محاسبه می‌شود. جدول ۵ نتایج را نشان می‌دهد.

جدول ۵- ارزیابی عملکرد تابع خطا

روش	SVHN MNIST	MNIST USPS	USPS MNIST	MNIST MNIST-M
روش پیشنهادی با تابع خطای CE	۹۸٫۹	۹۵٫۹	۹۷٫۱	۹۷٫۶
روش پیشنهادی با تابع خطای معرفی‌شده	۹۹٫۵	۹۸٫۲	۹۹٫۴	۹۸٫۸

همان‌طور که در جدول ۵ نشان داده شده است، برای همه مجموعه‌داده‌ها، روش پیشنهادی با استفاده از تابع خطای پیشنهادی دقت بالایی دارد. در مقابل، روش پیشنهادی با استفاده از CE دقت بالایی ندارد. نتایج نشان می‌دهد وقتی مدل پیشنهادی بر روی مجموعه‌داده USPS آموزش می‌بیند و بر روی مجموعه‌داده MNIST آزمایش می‌شود نتایج بهتری دارد. پس از مجموعه‌داده MNIST، USPS به ترتیب بیشترین دقت را دارند. متوسط اختلاف دقت ۱/۴۵ درصدی بین دو حالت نشان می‌دهد روش پیشنهادی با استفاده از تابع خطای پیشنهادی می‌تواند فاصله بین کلاسی و درون کلاسی را بسیار بهتر از تابع خطای CE حفظ کند.

۵- نتیجه‌گیری

در این تحقیق، یک چارچوب یادگیری عمیق برای طبقه‌بندی تصاویر ارائه شده است. در این روش تکنیک انطباق دامنه بدون ناظر چندمنبعی را برای بهینه‌سازی یادگیری انتقالی و تعمیم‌پذیری بیشتر بین چندین منبع داده را پیشنهاد کردیم. در مازول جدید برای عدم

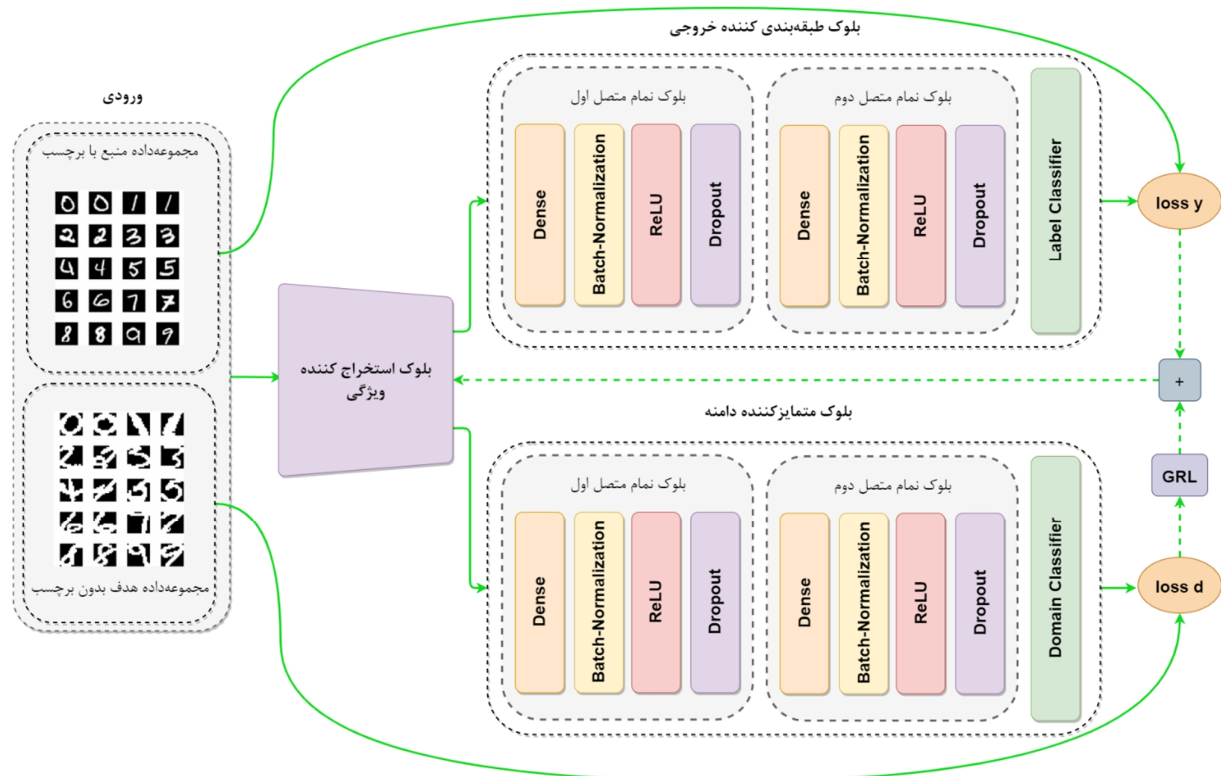
تفسیر شبیه به چرخش (Rotation) برای چرخش (flip) نیز صادق است. بنابراین تمام تغییرات اعمال‌شده بر روی تصاویر به‌گونه‌ای است که باعث تفسیر متفاوت نمی‌شود و به آموزش شبکه آسیب نمی‌زند.

۴-۴- آزمایش ۱: ارزیابی بین مجموعه‌داده‌ای

در اینجا، رویکرد پیشنهادی با استفاده از مجموعه‌داده‌های منبع و هدف ارزیابی شده و با سایر رویکردهای موفق مقایسه می‌شود. جدول ۴ نتایج روش پیشنهادی و سایر روش‌ها را نشان می‌دهد. همین‌طوری که از این جدول مشخص است روش پیشنهادی زمانی که روی مجموعه‌داده غنی‌تر از نظر تعداد داده آموزش می‌بیند و روی مجموعه‌داده کوچک‌تر ارزیابی می‌شود نسبت به حالت برعکس آن عملکرد بهتری دارد. برای هر جفت مجموعه داده منبع و هدف انتخابی (بالا و پایین به ترتیب)، در فاز آموزش شبکه، مجموعه داده منبع در واقع کل نمونه‌ها (آموزشی و آزمایش) و مجموعه داده هدف فقط نمونه‌های مجموعه آموزش است. در فاز آزمایش، نتایج فقط روی نمونه‌های آزمایشی مجموعه داده هدف انجام شده است.

جدول ۴- مقایسه روش پیشنهادی با روش‌های دیگر

روش	SVHN MNIST	MNIST USPS	USPS MNIST	MNIST MNIST-M
ASSOCDA [۶۰]	۹۷٫۶	-	-	۸۹٫۵
CYCADA [۶۱]	۹۰٫۴	۹۵٫۶	۹۶٫۵	-
DAN [۶۲]	۷۱٫۱	۸۱٫۱	-	۷۶٫۹
DANN [۶۳]	۷۳٫۸	۸۵٫۱	۷۳٫۰	۷۷٫۴
DIRT-T (IN) [۶۴]	۹۹٫۴	-	-	۹۸٫۷
DIRT-T [۶۴]	۹۹٫۴	-	-	۹۸٫۹
DSN [۶۵]	۸۲٫۷	۹۱٫۳	-	۸۳٫۲
GENTOADAPT [۶۶]	۹۲٫۴	۹۵٫۳	۹۰٫۸	-
MCD [۶۷]	۹۶٫۲	۹۴٫۲	۹۴٫۱	-
PIXELDA [۶۸]	-	۹۵٫۹	-	۹۸٫۲
SHOT [۶۹]	۹۸٫۹	۹۸٫۰	۹۸٫۴	-
SIMDA [۷۰]	-	۹۶٫۴	۹۵٫۶	۹۰٫۵
SWD [۷۱]	۹۸٫۹	۹۸٫۱	۹۷٫۱	-
UDATSS [۷۲]	۸۵٫۸	۹۶٫۵	۹۰٫۲	۹۸٫۹
UNIT [۷۳]	۹۰٫۵	۹۵٫۹	۹۳٫۵	-
VADA (IN) [۶۴]	۹۴٫۵	-	-	۹۵٫۷
VADA [۶۴]	۹۷٫۹	-	-	۹۷٫۷
VADA [۶۴]	۹۷٫۹	-	-	۹۷٫۷
روش پیشنهادی	۹۹٫۵	۹۸٫۲	۹۹٫۴	۹۸٫۸



شکل ۱- چارچوب پیشنهادی. گذر روبه جلو (خط توپر)، گذر رو به عقب (خط چین)، GRL (لایه معکوس کننده گرادیان)، + (مجموع وزنی گرادیان‌ها)

- Research International, vol. 2021, p. 9942873, 2021/08/26 2021, doi: 10.1155/2021/9942873.
- [3] V. Esmaili, M. Mohassel Fegghi, and S. O. Shahdi, "Spotting micro-movements in image sequence by introducing intelligent cubic-LBP," *IET Image Processing*, vol. 16, no. 14, pp. 3814-3830, 2022, doi: <https://doi.org/10.1049/ipr2.12596>.
- [4] V. Esmaili, M. Mohassel Fegghi, and S. O. Shahdi, "A comprehensive survey on facial micro-expression: approaches and databases," *Multimedia Tools and Applications*, vol. 81, no. 28, pp. 40089-40134, 2022/11/01 2022, doi: 10.1007/s11042-022-13133-2.
- [5] A. N. Hassan, M. Mohassel Fegghi, and V. Esmaili, "A Fast Automatic Modulation Classification Based on STFT Using Hybrid Deep Neural Network," *Journal of Communication Engineering*, vol. 10, no. 2, pp. -, 2021, doi: 10.22070/jce.2023.17933.1250.
- [6] V. Esmaili and M. Mohassel Fegghi, "Real-time Authentication for Electronic Service Applicants using a Method Based on Two-Stream 3D Deep Learning," *Soft Computing Journal*, pp. -, 2023, doi: 10.22052/scj.2023.246701.1086.
- [7] A. Farhad et al., "Artificial intelligence in estimating fractional flow reserve: a systematic literature review of techniques," *BMC Cardiovascular Disorders*, vol. 23, no. 1, p. 407, 2023/08/18 2023, doi: 10.1186/s12872-023-03447-w.
- [8] M. Ghaderzadeh, M. Aria, A. Hosseini, F. Asadi, D. Bashash, and H. Abolghasemi, "A fast and efficient CNN model for B-ALL diagnosis and its subtypes classification using peripheral blood smear images," *International Journal of Intelligent Systems*, vol. 37, no. 8, pp. 5113-5133, 2022, doi: <https://doi.org/10.1002/int.22753>.
- [9] A. Golzari Oskouei, M. Hashemzadeh, B. Asheghi, and M. A. Balafar, "CGFFCM: Cluster-weight and Group-local Feature-weight learning in Fuzzy C-Means clustering algorithm for color image segmentation," *Applied Soft*

یادگیری ویژگی‌ها منحصر به فرد هر منبع از لایه معکوس کننده گرادیان استفاده شد. با استفاده از این تکنیک، بازنمایی‌های یاد گرفته شده به طور مؤثرتری در بین منابع تعمیم داده شدند. به عبارت دیگر، بازنمایی‌هایی که تولید شدند، عمومی و مستقل از دامنه یک مجموعه داده خاص بودند. در مرحله آموزش، یک تابع خطای جدید نیز اعمال شد. با توجه به تشابه ساختاری بسیار زیاد تصاویر، تابع خطای پیشنهادی به یادگیری بازنمایی‌های یکسان برای نمونه‌های متعلق به یک کلاس و بازنمایی‌های مختلف برای نمونه‌های متعلق به کلاس‌های مختلف کمک می‌کند.

بر اساس آزمایش‌ها، مدل ارائه شده تعمیم‌پذیری و قابلیت انتقال مدل را به طور مؤثری افزایش داد. همچنین مدل پیشنهادی با مدل‌های پیشرفته متعددی مقایسه شد. یافته‌ها نشان می‌دهد که مدل پیشنهادی دقت طبقه‌بندی را تا ۲ درصد بهبود می‌بخشد.

مراجع

- [1] V. Esmaili, M. Mohassel Fegghi, and S. O. Shahdi, "Applying Partial Differential Equations on Cubic Uniform Local Binary Pattern to Reveal Micro-Changes," *Journal of Electrical and Computer Engineering Innovations (JECEI)*, vol. 12, no. 1, pp. 259-270, 2024, doi: 10.22061/jecei.2023.9600.639.
- [2] M. Ghaderzadeh, M. Aria, and F. Asadi, "X-Ray Equipped with Artificial Intelligence: Changing the COVID-19 Diagnostic Paradigm during the Pandemic," *BioMed*

- [26] A. G. Oskouei, M. A. Balafar, and T. Akan, "A Brain MRI Segmentation Method Using Feature Weighting and a Combination of Efficient Visual Features," in *Applied Computer Vision and Soft Computing with Interpretable AI*: Chapman and Hall/CRC, 2024, pp. 15-34.
- [27] J. N. Khirak et al., "KartalOL: a new deep neural network framework based on transfer learning for iris segmentation and localization task—new dataset for iris segmentation," *Iran Journal of Computer Science*, 2023/04/13 2023, doi: 10.1007/s42044-023-00141-0.
- [28] A. Golzari Oskouei, M. A. Balafar, and C. Motamed, "RDEIC-LFW-DSS: ResNet-based deep embedded image clustering using local feature weighting and dynamic sample selection mechanism," *Information Sciences*, vol. 646, p. 119374, 2023/10/01/ 2023, doi: <https://doi.org/10.1016/j.ins.2023.119374>.
- [29] A. Golzari Oskouei, M. A. Balafar, and C. Motamed, "EDCWRN: efficient deep clustering with the weight of representations and the help of neighbors," *Applied Intelligence*, vol. 53, no. 5, pp. 5845-5867, 2023/03/01 2023, doi: 10.1007/s10489-022-03895-5.
- [30] A. G. Oskouei, M. Hashemzadeh, B. Asheghi, and M. A. Balafar, "CGFFCM: Cluster-weight and Group-local Feature-weight learning in Fuzzy C-Means clustering algorithm for color image segmentation," *Applied Soft Computing*, vol. 113, p. 108005, 2021.
- [31] A. Golzari Oskouei, M. A. Balafar, and C. Motamed, "FKMAWCW: Categorical fuzzy k-modes clustering with automated attribute-weight and cluster-weight learning," *Chaos, Solitons & Fractals*, vol. 153, p. 111494, 2021/12/01/ 2021, doi: <https://doi.org/10.1016/j.chaos.2021.111494>.
- [32] M. Hashemzadeh, A. G. Oskouei, and N. Farajzadeh, "New fuzzy C-means clustering method based on feature-weight and cluster-weight learning," *Applied Soft Computing*, vol. 78, pp. 324-345, 2019.
- [33] K. Berahmand, F. Daneshfar, M. Dorosti, and M. J. Aghajani, "An Improved Deep Text Clustering via Local Manifold of an Autoencoder Embedding," 2022.
- [34] H. Altae-Tran, B. Ramsundar, A. S. Pappu, and V. Pande, "Low data drug discovery with one-shot learning," *ACS central science*, vol. 3, no. 4, pp. 283-293, 2017.
- [35] S. Christodoulidis, M. Anthimopoulos, L. Ebner, A. Christe, and S. Mouggiakakou, "Multisource transfer learning with convolutional neural networks for lung pattern analysis," *IEEE journal of biomedical and health informatics*, vol. 21, no. 1, pp. 76-84, 2016.
- [36] N. Dhungel, G. Carneiro, and A. P. Bradley, "A deep learning approach for the analysis of masses in mammograms with minimal user intervention," *Medical Image Analysis*, vol. 37, pp. 114-128, 2017/04/01/ 2017, doi: <https://doi.org/10.1016/j.media.2017.01.009>.
- [37] Y. Bar, I. Diamant, L. Wolf, and H. Greenspan, "Deep learning with non-medical training used for chest pathology identification," in *Medical Imaging 2015: Computer-Aided Diagnosis*, 2015, vol. 9414: International Society for Optics and Photonics, p. 94140V.
- [38] Y. Ganin et al., "Domain-adversarial training of neural networks," *Journal of machine learning research*, vol. 17, no. 59, pp. 1-35, 2016.
- [39] M. R. Samsudin, S. A. Abu-Bakar, and M. M. Mokji, "Balanced Weight Joint Geometrical and Statistical Alignment for Unsupervised Domain Adaptation," *Journal of Advances in Information Technology Vol.*, vol. 13, no. 1, 2022.
- [40] A. Gretton, K. M. Borgwardt, M. J. Rasch, B. Schölkopf, and A. Smola, "A kernel two-sample test," *The Journal of Machine Learning Research*, vol. 13, no. 1, pp. 723-773, 2012.
- [41] S. Rezaei and J. Tahmoresnezhad, "Discriminative and domain invariant subspace alignment for visual tasks," *Iran Journal of Computer Science*, vol. 2, no. 4, pp. 219-230, 2019.
- [42] J. Li, M. Jing, K. Lu, L. Zhu, and H. T. Shen, "Locality preserving joint transfer for domain adaptation," *IEEE Computing*, vol. 113, p. 108005, 2021/12/01/ 2021, doi: <https://doi.org/10.1016/j.asoc.2021.108005>.
- [10] A. Golzari Oskouei and M. Hashemzadeh, "CGFFCM: A color image segmentation method based on cluster-weight and feature-weight learning," *Software Impacts*, vol. 11, p. 100228, 2022/02/01/ 2022, doi: <https://doi.org/10.1016/j.simpa.2022.100228>.
- [11] M. Ghaderzadeh and M. Aria, "Management of Covid-19 Detection Using Artificial Intelligence in 2020 Pandemic," presented at the 2021 5th International Conference on Medical and Health Informatics, Kyoto, Japan, 2021. [Online]. Available: <https://doi.org/10.1145/3472813.3472820>.
- [12] A. Bayani et al., "Performance of machine learning techniques on prediction of esophageal varices grades among patients with cirrhosis," *Clinical Chemistry and Laboratory Medicine (CCLM)*, 2022, doi: doi:10.1515/cclm-2022-0623.
- [13] M. A. Balafar, "Gaussian mixture model based segmentation methods for brain MRI images," *Artificial Intelligence Review*, vol. 41, no. 3, pp. 429-439, 2014/03/01 2014, doi: 10.1007/s10462-012-9317-3.
- [14] M. A. Balafar, A. R. Ramli, M. I. Saripan, and S. Mashohor, "Review of brain MRI image segmentation methods," *Artificial Intelligence Review*, vol. 33, no. 3, pp. 261-274, 2010/03/01 2010, doi: 10.1007/s10462-010-9155-0.
- [15] M. A. Balafar, "Fuzzy C-mean based brain MRI segmentation algorithms," *Artificial Intelligence Review*, vol. 41, no. 3, pp. 441-449, 2014/03/01 2014, doi: 10.1007/s10462-012-9318-2.
- [16] A. Bouyer, "Breast cancer diagnosis using data mining methods, cumulative histogram features, and gary level co-occurrence matrix," *Current Medical Imaging*, vol. 13, no. 4, pp. 460-470, 2017.
- [17] M. Ghaderzadeh, F. Asadi, R. Jafari, D. Bashash, H. Abolghasemi, and M. Aria, "Deep Convolutional Neural Network-Based Computer-Aided Detection System for COVID-19 Using Multiple Lung Scans: Design and Implementation Study," *J Med Internet Res*, vol. 23, no. 4, p. e27468, 2021/4/26 2021, doi: 10.2196/27468.
- [18] F. Dashti, A. Ghaffari, A. Seyfollahi, and B. Arasteh, "A self-predictive diagnosis system of liver failure based on multilayer neural networks," *Multimedia Tools and Applications*, 2024/03/22 2024, doi: 10.1007/s11042-024-18945-y.
- [19] F. Yang, H. Fan, P. Chu, E. Blasch, and H. Ling, "Clustered object detection in aerial images," in *Proceedings of the IEEE/CVF International Conference on Computer Vision*, 2019, pp. 8311-8320.
- [20] R. P. Sharma and S. Dey, "Two-stage quality adaptive fingerprint image enhancement using Fuzzy C-means clustering based fingerprint quality analysis," *Image and Vision Computing*, vol. 83, pp. 1-16, 2019.
- [21] V. Gulshan et al., "Development and validation of a deep learning algorithm for detection of diabetic retinopathy in retinal fundus photographs," *Jama*, vol. 316, no. 22, pp. 2402-2410, 2016.
- [22] M. Aria, E. Nourani, and A. Golzari Oskouei, "ADA-COVID: Adversarial Deep Domain Adaptation-Based Diagnosis of COVID-19 from Lung CT Scans Using Triplet Embeddings," *Computational Intelligence and Neuroscience*, vol. 2022, p. 2564022, 2022/02/08 2022, doi: 10.1155/2022/2564022.
- [23] S. Majid, F. Alenezi, S. Masood, M. Ahmad, E. S. Gündüz, and K. Polat, "Attention based CNN model for fire detection and localization in real-world images," *Expert Systems with Applications*, vol. 189, p. 116114, 2022.
- [24] M. Aria, M. Hashemzadeh, and N. Farajzadeh, "QDL-CMFD: A Quality-independent and deep Learning-based Copy-Move image forgery detection method," *Neurocomputing*, vol. 511, pp. 213-236, 2022/10/28/ 2022, doi: <https://doi.org/10.1016/j.neucom.2022.09.017>.
- [25] T. Ahmed and N. H. N. Sabab, "Classification and Understanding of Cloud Structures via Satellite Images with EfficientUNet," *SN Computer Science*, vol. 3, no. 1, p. 99, 2021/12/12 2021, doi: 10.1007/s42979-021-00981-2.

- consumption with deep learning models," *Sustainable Computing: Informatics and Systems*, vol. 38, p. 100863, 2023/04/01/ 2023, doi: <https://doi.org/10.1016/j.suscom.2023.100863>.
- [58] H. Fanai and H. Abbasimehr, "A novel combined approach based on deep Autoencoder and deep classifiers for credit card fraud detection," *Expert Systems with Applications*, vol. 217, p. 119562, 2023/05/01/ 2023, doi: <https://doi.org/10.1016/j.eswa.2023.119562>.
- [59] H. Abbasimehr and R. Paki, "Prediction of COVID-19 confirmed cases combining deep learning methods and Bayesian optimization," *Chaos, Solitons & Fractals*, vol. 142, p. 110511, 2021/01/01/ 2021, doi: <https://doi.org/10.1016/j.chaos.2020.110511>.
- [60] P. Haeusser, T. Frerix, A. Mordvintsev, and D. Cremers, "Associative domain adaptation," in *Proceedings of the IEEE international conference on computer vision*, 2017, pp. 2765-2773.
- [61] J. Hoffman *et al.*, "Cycada: Cycle-consistent adversarial domain adaptation," in *International conference on machine learning*, 2018: Pmlr, pp. 1989-1998.
- [62] M. Long, Y. Cao, J. Wang, and M. Jordan, "Learning transferable features with deep adaptation networks," in *International conference on machine learning*, 2015: PMLR, pp. 97-105.
- [63] Y. Ganin *et al.*, "Domain-adversarial training of neural networks," *The journal of machine learning research*, vol. 17, no. 1, pp. 2096-2030, 2016.
- [64] R. Shu, H. H. Bui, H. Narui, and S. Ermon, "A dirt-t approach to unsupervised domain adaptation," *arXiv preprint arXiv:1802.08735*, 2018.
- [65] K. Bousmalis, G. Trigeorgis, N. Silberman, D. Krishnan, and D. Erhan, "Domain separation networks," *Advances in neural information processing systems*, vol. 29, 2016.
- [66] S. Sankaranarayanan, Y. Balaji, C. D. Castillo, and R. Chellappa, "Generate to adapt: Aligning domains using generative adversarial networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 8503-8512.
- [67] K. Saito, K. Watanabe, Y. Ushiku, and T. Harada, "Maximum classifier discrepancy for unsupervised domain adaptation," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 3723-3732.
- [68] K. Bousmalis, N. Silberman, D. Dohan, D. Erhan, and D. Krishnan, "Unsupervised pixel-level domain adaptation with generative adversarial networks," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2017, pp. 3722-3731.
- [69] J. Liang, D. Hu, and J. Feng, "Do we really need to access the source data? source hypothesis transfer for unsupervised domain adaptation," in *International Conference on Machine Learning*, 2020: PMLR, pp. 6028-6039.
- [70] P. O. Pinheiro, "Unsupervised domain adaptation with similarity learning," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2018, pp. 8004-8013.
- [71] C.-Y. Lee, T. Batra, M. H. Baig, and D. Ulbricht, "Sliced wasserstein discrepancy for unsupervised domain adaptation," in *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*, 2019, pp. 10285-10295.
- [72] Y. Sun, E. Tzeng, T. Darrell, and A. A. Efros, "Unsupervised domain adaptation through self-supervision," *arXiv preprint arXiv:1909.11825*, 2019.
- [73] M.-Y. Liu, T. Breuel, and J. Kautz, "Unsupervised image-to-image translation networks," *Advances in neural information processing systems*, vol. 30, 2017.
- [43] Transactions on Image Processing, vol. 28, no. 12, pp. 6103-6115, 2019.
- [44] Y. Huang, J. Peng, Y. Ning, W. Sun, and Q. Du, "Graph embedding and distribution alignment for domain adaptation in hyperspectral image classification," *IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing*, vol. 14, pp. 7654-7666, 2021.
- [45] J. Wang, Y. Chen, H. Yu, M. Huang, and Q. Yang, "Easy transfer learning by exploiting intra-domain structures," in *2019 IEEE international conference on multimedia and expo (ICME)*, 2019: IEEE, pp. 1210-1215.
- [46] J. Zhang, J. Liu, B. Pan, and Z. Shi, "Domain adaptation based on correlation subspace dynamic distribution alignment for remote sensing image scene classification," *IEEE Transactions on Geoscience and Remote Sensing*, vol. 58, no. 11, pp. 7920-7930, 2020.
- [47] S. Noori Saray and J. Tahmoresnezhad, "Joint distinct subspace learning and unsupervised transfer classification for visual domain adaptation," *Signal, Image and Video Processing*, vol. 15, no. 2, pp. 279-287, 2021.
- [48] D. Zheng, K. Zhang, J. Lu, J. Jing, and Z. Xiong, "Active discriminative cross-domain alignment for low-resolution face recognition," *IEEE Access*, vol. 8, pp. 97503-97515, 2020.
- [49] R. K. Sanodiya, J. Mathew, R. Aditya, A. Jacob, and B. Nayanar, "Kernelized unified domain adaptation on geometrical manifolds," *Expert Systems with Applications*, vol. 167, p. 114078, 2021.
- [50] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," in *Proceedings of the IEEE conference on computer vision and pattern recognition*, 2016, pp. 770-778.
- [51] M. Hashemzadeh, A. Golzari Oskoue, and N. Farajzadeh, "New fuzzy C-means clustering method based on feature-weight and cluster-weight learning," *Applied Soft Computing*, vol. 78, pp. 324-345, 2019/05/01/ 2019, doi: <https://doi.org/10.1016/j.asoc.2019.02.038>.
- [52] A. Golzari Oskoue, M. A. Balafar, and C. Motamed, "EDCWRN: efficient deep clustering with the weight of representations and the help of neighbors," *Applied Intelligence*, 2022/07/05 2022, doi: 10.1007/s10489-022-03895-5.
- [53] A. Noori, M. A. Balafar, A. Bouyer, and K. Salmani, "Review of heterogeneous graph embedding methods based on deep learning techniques and comparing their efficiency in node classification," *Social Network Analysis and Mining*, vol. 14, no. 1, p. 17, 2024/01/03 2024, doi: 10.1007/s13278-023-01178-6.
- [54] H. Roghani and A. Bouyer, "A Fast Local Balanced Label Diffusion Algorithm for Community Detection in Social Networks," *IEEE Transactions on Knowledge and Data Engineering*, vol. 35, no. 6, pp. 5472-5484, 2023, doi: 10.1109/TKDE.2022.3162161.
- [55] A. Bouyer, K. Azad, and A. Rouhi, "A fast community detection algorithm using a local and multi-level label diffusion method in social networks," *International Journal of General Systems*, vol. 51, no. 4, pp. 352-385, 2022/05/19 2022, doi: 10.1080/03081079.2022.2025794.
- [56] A. Bouyer, M. Mohammadi, and B. Arasteh, "Identifying influential nodes based on new layer metrics and layer weighting in multiplex networks," *Knowledge and Information Systems*, vol. 66, no. 2, pp. 1011-1035, 2024/02/01 2024, doi: 10.1007/s10115-023-01983-7.
- [57] H. A. Beni, A. Bouyer, S. Azimi, A. Rouhi, and B. Arasteh, "A fast module identification and filtering approach for influence maximization problem in social networks," *Information Sciences*, vol. 640, p. 119105, 2023/09/01/ 2023, doi: <https://doi.org/10.1016/j.ins.2023.119105>.
- [58] H. Abbasimehr, R. Paki, and A. Bahrini, "A novel XGBoost-based featurization approach to forecast renewable energy