



مروری بر راهکارهای یادگیری عمیق برای تشخیص ناهنجاری داده

فاطمه نارویی^۱، احسان اسلامی^۲

^۱ دانشجوی کارشناسی مهندسی نرم افزار، دانشگاه ولایت ایران شهر، ایران شهر، fatemehnarouie@gmail.com

^۲ عضو هیات علمی، مربی، دانشگاه ولایت، ایران شهر، e.eslami@velayat.ac.ir

چکیده

تشخیص ناهنجاری که با نام تشخیص نقاط پرت نیز شناخته می شود، یک مسئله مهم است که از دیرباز مورد توجه خاص محققین قرار گرفته است و تاکنون یک حوزه تحقیقاتی فعال و ماندگار در جوامع تحقیقاتی مختلف برای چندین دهه بوده است. ناهنجاری ها می توانند ناشی از خطا در داده باشند، اما گاهی اوقات نشان دهنده یک فرایند جدید، ناشناخته و اساسی هستند؛ بنابراین هنوز پیچیدگی و چالش های منحصر به فردی وجود دارد که نیازمند رویکردهای پیشرفته است. هدف از ارائه این مقاله مروری جامع بر روش های تشخیص ناهنجاری مبتنی بر یادگیری عمیق است که تکنیک های تحقیقاتی تشخیص ناهنجاری را بر اساس مفروضات اساسی و رویکرد اتخاذ شده در دسته های مختلف گروه بندی کرده است. در هر دسته، تکنیک اصلی تشخیص ناهنجاری همراه با انواع آن، فرضیات کلیدی، نقاط قوت و ضعف نسبی ارائه شده است و در نهایت چالش های تحقیقاتی حل نشده در حین استفاده از تکنیک های تشخیص ناهنجاری در مدل های یادگیری عمیق برجسته خواهند شد.

واژه های کلیدی

تشخیص ناهنجاری، یادگیری عمیق، نقاط پرت

۱. مقدمه

در داده کاوی^۱، به فرایند شناسایی نمونه ها، رویدادها یا مشاهداتی که با الگوها یا دیگر نمونه های موجود در مجموعه داده مطابقت نداشته باشند، تشخیص ناهنجاری یا تشخیص دورافتادگی^۲ گفته می شود. یکی از چالش ها در دنیای داده ها، تعیین این است که کدام نمونه ها با بقیه متفاوت هستند. چنین نمونه هایی به عنوان ناهنجاری شناخته می شوند [۱] و هدف از تشخیص ناهنجاری تعیین چنین مواردی به روش داده محور است [۲]. ناهنجاری ها می توانند ناشی از خطا در داده ها باشند، اما گاهی اوقات نشان دهنده یک فرایند جدید، ناشناخته و اساسی هستند. نقطه پرت به عنوان مشاهده ای تعریف می شود که

به طور قابل توجهی از مشاهدات دیگر منحرف می شود. باعث ایجاد سوءظن می شود و توسط مکانیزم متفاوتی ایجاد شده است [۳]. با توجه به افزایش تقاضا و کاربردها در حوزه های گسترده، مانند مدیریت ریسک، انطباق، امنیت، نظارت مالی، خطر سلامت و پزشکی، ایمنی هوش مصنوعی، تشخیص ناهنجاری نقش های مهمی ایفا می کند که در حوزه های مختلف از جمله داده کاوی، یادگیری ماشین برجسته شده است. یادگیری عمیق و بینایی ماشین در سال های اخیر، قابلیت های فوق العاده ای را در یادگیری نمایش های بیانی داده های پیچیده مانند داده های با ابعاد بالا، داده های زمانی، داده های مکانی و داده های نموداری نشان داده است [۱].

تکنیک های یادگیری عمیق^۳ فرصت های باورنکردنی را برای پاسخ به برخی از مهم ترین و دشوارترین سؤالات در طیف وسیعی از کاربردها در علم و مهندسی فراهم می کند؛ بنابراین، دانشمندان و مهندسان به طور فزاینده ای استفاده از یادگیری عمیق را برای اتخاذ تصمیمات بالقوه مهم، در زمینه برنامه های کاربردی مورد علاقه، مانند بیوانفورماتیک، مراقبت های بهداشتی، امنیت سایبری و وسایل نقلیه کاملاً خودمختار اتخاذ می کنند. بسیاری از این برنامه ها اغلب متحمل هزینه های قابل توجهی می شوند. در چنین کاربردهایی، تصمیم گیری یا پیش بینی نادرست هزینه های هنگفتی از نظر منابع در هنگام آزمایش داروها، از دست دادن فرصت ها برای مشاهده پدیده های نادر و یا از نظر سلامت و ایمنی هنگام تأیید قطعات دارند. اکثر روش های یادگیری عمیق به طور ضمنی شرایط ایده آل را در نظر می گیرند و بر این فرض تکیه می کنند که داده های آزمون از «توزیع یکسان» داده های آموزشی می آیند. با این حال، این فرض در بسیاری از برنامه های کاربردی دنیای واقعی برآورده نمی شود [۲].

ناهنجاری، بسته به موقعیت ممکن است غیرعادی، نامنظم، غیرمعمول، ناسازگار، غیرمنتظره، نادر، اشتباه، معیوب، تقلبی، بدخواهانه، غیرطبیعی یا به سادگی عجیب نامیده شود. ^۴ AD (تشخیص پرت یا تشخیص تازگی) حوزه تحقیقاتی است که تشخیص چنین مشاهدات غیرعادی را از طریق روش ها، مدل ها و الگوریتم های

^۳ Deep Learning

^۴ Anomaly Detection

^۱ Data Mining

^۲ Outlier Detection

مبتنی بر داده‌ها مطالعه می‌کند. رویکردهای کلاسیک تشخیص ناهنجاری شامل PCA[۳]، OC-SVM[۴]، SVDD[۵] و الگوریتم‌های نزدیک‌ترین همسایه KDE[۶] است.

وجه اشتراک روش‌های فوق این است که همه بدون نظارت هستند. علت این است که در تنظیمات استاندارد تشخیص ناهنجاری، داده‌های غیرعادی برچسب‌گذاری شده اغلب وجود ندارند. وقتی در دسترس باشد، معمولاً برای توصیف کامل همه مفاهیم ناهنجاری کافی نیست که معمولاً یک رویکرد نظارت شده را ناکارآمد می‌کند. در عوض، یک ایده اصلی در تشخیص ناهنجاری این است که یک مدل نرمال از داده‌های عادی را به شیوه‌ای بدون نظارت یاد بگیریم تا ناهنجاری‌ها از طریق انحراف از مدل قابل تشخیص باشند. مطالعه تشخیص ناهنجاری سابقه طولانی دارد و رشته‌های مختلفی از جمله علوم و مهندسی، یادگیری ماشین و تحلیل داده را در برمی‌گیرد [۷]. به طور خلاصه تشخیص ناهنجاری عمیق، یادگیری بازنمایی ویژگی‌ها یا امتیازات ناهنجاری از طریق شبکه‌های عصبی را هدف قرار می‌دهد. تعداد زیادی از روش‌های تشخیص ناهنجاری عمیق معرفی شده‌اند که عملکرد بهتری نسبت به تشخیص ناهنجاری معمولی در پرداختن به مشکلات تشخیص چالش‌برانگیز در انواع برنامه‌های کاربردی در دنیای واقعی نشان می‌دهند. این کار با هدف ارائه یک بررسی جامع از این حوزه است. در اینجا ابتدا ماهیت مشکل تشخیص ناهنجاری و چالش‌های عمده حل نشده مورد بحث قرار می‌گیرد، سپس به طور سیستماتیک روش‌های عمیق فعلی و قابلیت‌های آن‌ها در رسیدگی به این چالش‌ها را بررسی می‌کنیم. تعدادی از مطالعات [۸] به طبقه‌بندی و بررسی تکنیک‌های تشخیص ناهنجاری اختصاص یافته است. با این حال، همه آنها فقط بر روش‌های مرسوم تشخیص ناهنجاری تمرکز می‌کنند. [۹] یکی از کارهای نزدیک به تحقیق ما است که خلاصه‌ای از برخی کاربردهای دنیای واقعی تشخیص ناهنجاری عمیق را ارائه می‌کند.

این بررسی روش‌های تشخیص عمیق فعلی و قابلیت‌های ذاتی و ضعف آن‌ها در پرداختن به برخی چالش‌های عمده حل نشده در تشخیص ناهنجاری را ترسیم می‌کند. این کار درک عمیقی از ماهیت مشکل و پیشرفت‌های روز را شکل می‌دهد و فرصت‌های باز واقعی را ایجاد می‌کند. همچنین به توضیح اینکه چرا ما به تشخیص ناهنجاری عمیق نیاز داریم کمک می‌کند.

در این مقاله تعداد زیادی از مطالعات مرتبط در کنفرانس‌ها و مجلات بررسی می‌شود تا یک مرور جامع از پیشرفت تحقیقات ارائه کنیم. برای ارائه مقدمه‌ای عمیق، مفروضات اساسی، توابع هدف، مشاهدات کلیدی و قابلیت‌های آن‌ها در پرداختن به برخی از چالش‌ها را با دسته‌بندی‌های روش‌ها مشخص خواهیم کرد. در بخش دوم این تحقیق ما تعریف جامعی از ناهنجاری را ارائه می‌کنیم و در بخش سوم جنبه‌های مختلف تشخیص ناهنجاری عمیق را مورد بحث قرار خواهیم داد. در بخش چهارم به روش‌های تشخیص ناهنجاری پرداخته خواهد شد. در بخش پنجم، کاربردهای تشخیص ناهنجاری را به صورت مختصر بررسی خواهیم کرد. در بخش ششم مدل‌های تشخیص ناهنجاری را

از سه جنبه مورد بحث قرار خواهیم داد. در بخش هفتم به تکنیک‌های متفرقه تشخیص ناهنجاری می‌پردازیم و در نهایت با پرداختن به نقاط قوت ضعف نسبی روش‌های تشخیص ناهنجاری عمیق بحث خود را به پایان می‌رسانیم.

۲. مفاهیم اولیه

۲.۱. ناهنجاری چیست؟

ناهنجاری‌ها نقاط داده‌ای هستند که در میان سایر نقاط داده در مجموعه داده برجسته‌اند و رفتار عادی در داده‌ها را تأیید نمی‌کنند. این نقاط داده یا مشاهدات از الگوهای رفتاری عادی مجموعه داده‌ها منحرف می‌شوند.

تشخیص ناهنجاری یک تکنیک پردازش داده بدون نظارت است. ناهنجاری‌ها را می‌توان به‌طور کلی به دسته‌های مختلفی طبقه‌بندی کرد:

- پرت: الگوهای ناهنجار کوتاه/کوچک که به صورت غیرسیستماتیک در جمع‌آوری داده‌ها ظاهر می‌شوند.
- تغییر در رویدادها: تغییر سیستماتیک یا ناگهانی نسبت به رفتار عادی قبلی.

- دریافت‌ها: تغییر آهسته، غیر جهت‌دار و طولانی‌مدت در داده‌ها. تشخیص ناهنجاری امروزه کاربردهای متعددی در انواع مختلف دارد. به‌عنوان مثال می‌توان به تشخیص نفوذ در امنیت سایبری، تشخیص تقلب در امور مالی، بیمه، مراقبت‌های بهداشتی و مخابرات تشخیص خطا و آسیب صنعتی، نظارت بر زیرساخت‌ها اشاره کرد و بازارهای سهام، تشخیص نقاط پرت صوتی، تشخیص پزشکی و تشخیص شیوع بیماری، تشخیص رویداد در علوم زمین، کشف علمی در شیمی، بیوانفورماتیک، ژنتیک، فیزیک و نجوم، حجم داده‌های موجود در این حوزه‌ها به طور مداوم در حال افزایش و گسترش است تا انواع داده‌های پیچیده مانند تصاویر، ویدئوها، فایل‌های صوتی، متن، نمودارها، سری‌های زمانی چندمتغیره و توالی‌های بیولوژیکی و غیره را شامل شود. برای موفقیت مدل‌ها در چنین داده‌های پیچیده و با ابعاد بالا، نمایش معنی‌دار داده‌ها بسیار مهم است [۱۰]. تشخیص ناهنجاری‌ها برای شناسایی تراکنش‌های تقلبی، تشخیص بیماری یا رسیدگی به هر گونه مطالعات موردی با عدم تعادل در کلاس‌های با ابعاد بالا بسیار مفید است. تکنیک‌های تشخیص ناهنجاری‌ها را می‌توان برای ساخت مدل‌های علمی داده قوی‌تر استفاده کرد [۱۱].

همان‌طور که در شکل ۱ نشان داده شده است، داده‌ها در دو ناحیه N_1 و N_2 به دلیل وجود بیشترین مشاهدات در این دو ناحیه، بهنجار محسوب می‌شوند، ولی نقاط O_1 و O_2 به میزان قابل توجهی از این دو ناحیه دور هستند و تعداد کمی از مشاهدات نیز در این نواحی وجود دارند و به همین دلیل ناهنجاری محسوب می‌شوند. ناهنجاری‌ها به دلایل مختلفی مانند اقدامات مخرب، خرابی سیستم، کلاهبرداری عمدی، نفوذ سایبری، وجود توده و تومور در بدن بیمار ایجاد می‌شود. اما ویژگی مشترک ناهنجاری‌ها که این مبحث را به حوزه‌ای جالب توجه برای تحلیلگران مبدل ساخته، ارتباط تنگاتنگ

در دسترس نبودن داده‌های برچسب‌گذاری شده در مقیاس بزرگ در اکثر برنامه‌ها می‌شود. عدم تعادل طبقاتی نیز به این دلیل است که طبقه‌بندی ناهنجاری‌ها معمولاً بسیار پرهزینه‌تر از نمونه‌های عادی است.

۳. تشخیص ناهنجاری مبتنی بر یادگیری عمیق

۳.۱. سابقه تحقیق:

روش‌های یادگیری عمیق برای مشکلات یادگیری ماشین تکنیک‌ها و الگوریتم‌های قابل توجهی را ارائه می‌کند. تشخیص ناهنجاری عمیق با استفاده از تبدیل‌های هندسی توسط من جولان و همکاران انجام شد [۱۲]. بررسی گسترده تکنیک‌های تشخیص ناهنجاری عمیق برای تشخیص نفوذ سایبری توسط کوون و همکاران [۱۳]، ارائه شده است. بررسی گسترده‌ای از استفاده از این تکنیک‌ها در حوزه پزشکی توسط لیتجنس و همکاران [۱۴]، ارائه شده است. مروری بر تکنیک‌های تشخیص ناهنجاری عمیق برای اینترنت اشیا و تشخیص ناهنجاری داده‌های بزرگ توسط محمدی و همکاران [۱۵] معرفی شده است. تشخیص ناهنجاری شبکه‌های حسگر توسط بال و همکاران [۱۶]، بررسی شده است و روش‌های پیشرفته مبتنی بر یادگیری عمیق برای تشخیص ناهنجاری ویدیویی همراه با دسته بندی‌های مختلف توسط کیران و همکاران [۱۷]، ارائه شده است. اگرچه برخی بررسی‌ها در استفاده از تکنیک‌های تشخیص ناهنجاری عمیق وجود دارد، اما کمبود تحلیل مقایسه‌ای معماری یادگیری عمیق که برای تشخیص موارد پرت اتخاذ شده است، وجود دارد اما بررسی جامع از معماری‌های عمیق مختلف که برای یک مجموعه داده و حوزه‌های کاربردی خاص مناسب هستند وجود ندارد. امید است که این مقاله این شکاف را پر کند و یک مرجع جامع برای محققان و مهندسانی که مشتاق استفاده از یادگیری عمیق برای تشخیص ناهنجاری هستند، ارائه دهد. در ادامه جنبه‌های مختلف تشخیص ناهنجاری مبتنی بر یادگیری عمیق را شناسایی و مورد بحث قرار می‌دهیم.


۳.۲. چالش‌های اصلی که با تشخیص ناهنجاری عمیق برطرف می‌شوند

در اینجا ما برخی از چالش‌های اصلی مسئله که با تشخیص ناهنجاری عمیق برطرف می‌شوند را ذکر خواهیم کرد. همه این چالش‌ها با یادگیری عمیق قابل حل هستند.


چالش ۱: نرخ یادآوری تشخیص ناهنجاری پایین، از آنجایی که ناهنجاری‌ها بسیار نادر و ناهمگن هستند، شناسایی همه ناهنجاری‌ها دشوار است. بسیاری از موارد عادی به اشتباه به عنوان ناهنجاری گزارش می‌شوند در حالی که ناهنجاری‌های واقعی و درعین حال پیچیده، نادیده گرفته می‌شوند.

چالش ۲: تشخیص ناهنجاری در داده‌های با ابعاد بالا و یا غیرمستقل. ناهنجاری‌ها اغلب ویژگی‌های غیرعادی آشکاری را در فضایی با ابعاد پایین نشان می‌دهند، اما در فضایی با ابعاد بالا پنهان


ناهنجاری‌های موجود در زمینه‌های گوناگون با مسائل جهان واقعی است؛ بنابراین، تشخیص ناهنجاری یک گام اساسی در سیستم‌های مختلف تصمیم‌گیری در نظر گرفته می‌شود. شکل‌های ۱، ۲ و ۳ چند مثال از ناهنجاری‌ها در حوزه‌های مختلف را نشان می‌دهند.



شکل ۱: تصویر ناهنجاری در مجموعه داده‌های دو بعدی



شکل ۲: تصویر ناهنجاری در لکه‌های خورشیدی



شکل ۳: تصویر ناهنجاری در ارزش گذاری سهام

۲.۲. تشخیص ناهنجاری

تشخیص ناهنجاری به رویدادهای اقلیت، غیرقابل پیش‌بینی، نامطمئن و نادر می‌پردازد که منجر به پیچیدگی‌های منحصربه‌فرد و مشکل برای همه روش‌های تشخیص (اعم از عمیق و کم‌عمق) می‌شود.

ناشناخته بودن ناهنجاری‌ها با بسیاری از مجهولات مرتبط هستند، به عنوان مثال، نمونه‌هایی با رفتارهای ناگهانی ناشناخته، ساختارهای داده و توزیع‌ها، تا زمانی که واقعاً رخ ندهند ناشناخته می‌مانند، مانند حملات تروریستی جدید، کلاهبرداری‌ها و نفوذهای شبکه.

ناهنجاری‌ها معمولاً نمونه‌های داده نادری در تضاد با نمونه‌های معمولی که اغلب بخش بزرگی از داده‌ها را تشکیل می‌دهند هستند؛ بنابراین، جمع‌آوری مقدار زیادی از نمونه‌های غیرعادی برچسب‌گذاری شده، اگر نگوییم غیرممکن، دشوار است که منجر به

و غیرقابل توجه می‌شوند. تشخیص ناهنجاری با ابعاد بالا یک مشکل طولانی‌مدت بوده است.

چالش ۳: یادگیری نرمال/ناهنجاری از نظر داده کارآمد. به دلیل دشواری و هزینه جمع‌آوری داده‌های ناهنجاری برچسب‌گذاری شده در مقیاس بزرگ، تشخیص ناهنجاری کاملاً نظارت شده اغلب غیرعملی است زیرا در دسترس بودن داده‌های آموزشی برچسب‌گذاری شده با کلاس‌های عادی و غیرعادی را فرض می‌کند.

چالش ۴: تشخیص ناهنجاری مقاوم در برابر نویز. بسیاری از روش‌های تشخیص ناهنجاری ضعیف/نیمه نظارت شده فرض می‌کنند که داده‌های آموزشی برچسب‌گذاری شده تمیز هستند که می‌توانند در برابر نمونه‌های نویزدار که به‌اشتباه به‌عنوان برچسب کلاس مخالف برچسب‌گذاری شده‌اند آسیب‌پذیر باشد. در چنین مواردی، ممکن است به‌جای آن از روش‌های بدون نظارت استفاده کنیم که این روش از داده‌های برچسب‌گذاری شده واقعی استفاده نمی‌کند.

روش‌های عمیق، بهینه‌سازی سرتاسر کل فرایند تشخیص ناهنجاری را ممکن می‌سازد. آنها همچنین یادگیری بازنمایی‌هایی را که به طور خاص برای تشخیص ناهنجاری طراحی شده‌اند را امکان‌پذیر می‌کنند. این دو قابلیت برای مقابله با چهار چالش فوق‌حیاتی هستند، اما روش‌های سنتی چنین نیستند. آنها به‌ویژه به بهبود استفاده از داده‌های عادی برچسب‌گذاری شده یا برخی از داده‌های ناهنجاری برچسب‌گذاری شده بدون توجه به نوع داده کمک می‌کنند.

۳.۳ ماهیت داده‌های ورودی

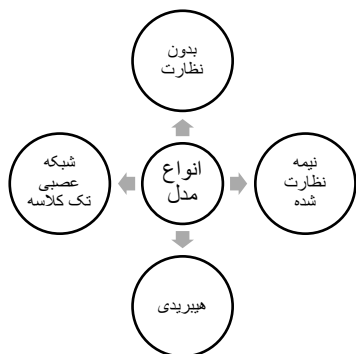
انتخاب یک معماری شبکه عصبی عمیق در روش‌های تشخیص ناهنجاری عمیق در درجه اول به ماهیت داده‌های ورودی بستگی دارد. داده‌های ورودی را می‌توان به‌طور کلی به ترتیبی (مانند صدا، متن، موسیقی، سری‌های زمانی، توالی پروتئین) یا داده‌های غیرمتوالی (مثلاً تصاویر، داده‌های دیگر) طبقه‌بندی کرد. تکنیک‌های تشخیص ناهنجاری عمیق برای یادگیری روابط، ویژگی‌های سلسله‌مراتبی پیچیده در داده‌های ورودی خام با ابعاد بالا بوده است [۱۸]. تعداد لایه‌های مورد استفاده در تکنیک‌های تشخیص ناهنجاری عمیق براساس بعد داده‌های ورودی هدایت می‌شود، شبکه‌های عمیق‌تر برای تولید عملکرد بهتر در داده‌های با ابعاد بالا نشان داده می‌شوند.

۳.۴ تشخیص ناهنجاری عمیق براساس در دسترس بودن

برچسب‌ها

برچسب‌ها بر اساس نوعشان ما را به سمت داده‌های معمولی یا داده‌های پرت هدایت می‌کنند. ناهنجاری‌ها موجودیت‌های نادری هستند، بنابراین به‌دست‌آوردن برچسب‌های آنها بحث‌برانگیز است. علاوه بر این، رفتار ناهنجار ممکن است در طول زمان تغییر کند. به‌عنوان مثال، ماهیت ناهنجاری به طور قابل توجهی در تصفیه‌خانه آب ماروچی تغییر کرده بود و برای مدت طولانی مورد توجه قرار نمی‌گرفت که منجر به نشت ۱۵۰ میلیون لیتر فاضلاب تصفیه نشده

به آبراه‌های محلی شد [۱۹]. مدل‌های تشخیص ناهنجاری عمیق را می‌توان به طور کلی براساس میزان در دسترس بودن برچسب‌ها به سه دسته طبقه‌بندی کرد. (۱) تشخیص ناهنجاری عمیق تحت نظارت. (۲) تشخیص ناهنجاری عمیق نیمه نظارت شده. (۳) تشخیص ناهنجاری عمیق بدون نظارت. در شکل ۴ نمایی شماتیک از مدل‌های یادگیری عمیق برای تشخیص ناهنجاری نشان داده شده است.



شکل ۴: طبقه‌بندی بر اساس نوع مدل‌های یادگیری عمیق برای تشخیص ناهنجاری

۳.۴.۱ تشخیص ناهنجاری عمیق تحت نظارت

تشخیص ناهنجاری عمیق تحت نظارت شامل آموزش یک طبقه‌بندی‌کننده باینری یا چند کلاسه با نظارت عمیق، با استفاده از برچسب‌های نمونه داده‌های معمولی و غیرعادی است [۹]. به عنوان مثال، مدل‌های تشخیص ناهنجاری عمیق تحت نظارت که به‌عنوان طبقه‌بند چند کلاسه در شناسایی مارک‌های کمیاب نام داروی ممنوعه و تراکنش‌های جعلی مراقبت‌های بهداشتی فرموله شده‌اند علیرغم بهبود عملکرد، به دلیل در دسترس نبودن نمونه‌های آموزشی برچسب‌دار، به اندازه روش‌های نیمه نظارت یا بدون نظارت محبوب نیستند. علاوه بر این، عملکرد طبقه‌بند با نظارت عمیق که از آشکارساز ناهنجاری استفاده می‌کند، به دلیل عدم تعادل کلاس، کمتر از حد بهینه است (تعداد کل نمونه‌های کلاس مثبت به مراتب بیشتر از تعداد کل کلاس منفی داده‌ها است).

۳.۴.۲ تشخیص ناهنجاری عمیق نیمه نظارت شده

برچسب نمونه‌های معمولی بسیار آسان‌تر از ناهنجاری‌ها به دست می‌آیند، در نتیجه، تکنیک‌های تشخیص ناهنجاری عمیق نیمه نظارت شده به طور گسترده‌تر مورد استفاده قرار می‌گیرند، این تکنیک‌ها از برچسب‌های موجود از تک کلاس (کلاس معمولاً مثبت) برای جداسازی نقاط پرت استفاده می‌کنند. یکی از روش‌های رایج استفاده از رمزگذارهای خودکار عمیق در تشخیص ناهنجاری، آموزش آن‌ها به روشی نیمه نظارت شده بر روی نمونه‌های داده بدون ناهنجاری است. با نمونه‌های آموزشی کافی، رمزگذارهای خودکار کلاس معمولی خطاهای بازسازی پایینی را برای نمونه‌های عادی، در رویدادهای غیرمعمول ایجاد می‌کنند [۲۰].

۳.۴.۳ تشخیص ناهنجاری عمیق بدون نظارت

تکنیک‌های تشخیص ناهنجاری عمیق بدون نظارت، نمونه‌های پرت را تنها بر اساس ویژگی‌های ذاتی نمونه‌های داده شناسایی می‌کنند. انواع مدل‌های تشخیص ناهنجاری عمیق بدون نظارت بهتر از روش‌های سنتی مانند تجزیه و تحلیل مؤلفه اصلی عمل می‌کنند. علاوه بر این، الگوریتم‌های یادگیری بدون نظارت مانند ماشین بولتزن محدود^۵، ماشین بولتزن عمیق^۶، شبکه باور عمیق، رمزگذارهای خودکار حذف نویز تعمیم‌یافته، شبکه عصبی بازگشتی^۷ و شبکه‌های حافظه کوتاه‌مدت برای تشخیص نقاط پرت استفاده می‌شوند [۲۱].

۳.۵ تشخیص ناهنجاری عمیق بر اساس هدف آموزشی

در این بررسی دودسته جدید از تکنیک‌های تشخیص ناهنجاری عمیق، بر اساس اهداف آموزشی به کار گرفته شده معرفی شده است: مدل‌های هیبریدی عمیق و شبکه‌های عصبی یک-کلاس^۸

۳.۵.۱ مدل‌های هیبریدی عمیق^۹

مدل‌های ترکیبی عمیق برای تشخیص ناهنجاری از شبکه‌های عصبی عمیق عمدتاً از رمزگذارهای خودکار به‌عنوان استخراج‌کننده ویژگی استفاده می‌کنند، ویژگی‌هایی که در بازنمایی‌های پنهان رمزگذارهای خودکار آموخته می‌شوند، به‌عنوان ورودی برای الگوریتم‌های تشخیص ناهنجاری سنتی مانند یک-کلاس برای شناسایی نقاط پرت می‌شوند [۲۲]. به دنبال موفقیت یادگیری انتقال برای به دست آوردن ویژگی‌های خوب از مدل‌های از پیش آموزش دیده در مجموعه داده‌های بزرگ، مدل‌های ترکیبی نیز از این مدل‌های یادگیری انتقال از پیش آموزش دیده به‌عنوان استخراج‌کننده ویژگی استفاده کرده‌اند. یک نوع مدل ترکیبی توسط ارگن و همکاران [۲۳] ارائه شد که آموزش مشترک استخراج‌کننده ویژگی همراه با روش سنتی یک-کلاس را برای به حداکثر رساندن عملکرد تشخیص در نظر می‌گیرد [۵].

۳.۵.۲ شبکه‌های عصبی یک-کلاس

شبکه عصبی یک-کلاس از روش‌های طبقه‌بندی یک-کلاس مبتنی بر هسته الهام گرفته است که توانایی شبکه‌های عمیق را برای استخراج یک بازنمایی غنی از داده‌ها با هدف یک کلاس را با ایجاد یک پوشش در اطراف داده‌های معمولی ترکیب می‌کند. بازنمایی داده در لایه پنهان توسط شبکه‌های عصبی یک-کلاس هدایت می‌شود بنابراین می‌تواند برای تشخیص ناهنجاری استفاده شود. این متفاوت از رویکردهای دیگر است که از یک رویکرد ترکیبی برای یادگیری ویژگی‌های عمیق با استفاده از رمزگذار خودکار استفاده


می‌کنند و سپس ویژگی‌ها را با یک روش تشخیص ناهنجاری جداگانه مانند روش‌های سنتی تک کلاس اضافه می‌کنند.

۳.۶ تشخیص ناهنجاری عمیق بر اساس نوع ناهنجاری

ناهنجاری‌ها را می‌توان در حالت کلی در سه دسته ناهنجاری‌های نقطه‌ای، ناهنجاری‌های زمینه‌ای و ناهنجاری‌های تجمعی قرارداد.

۳.۶.۱ تشخیص ناهنجاری‌های نقطه‌ای

اگر یک نمونه داده از اکثریت داده‌ها فاصله زیادی داشته باشد، ناهنجاری نقطه‌ای محسوب می‌شود. برای مثال در کارت‌های اعتباری می‌توان از ناهنجاری نقطه‌ای برای تشخیص برداشته‌های عجیب و احتمالاً مجرمانه استفاده کرد. در واقع، اگر اغلب برداشته‌های دارنده کارت در طیف مشخصی باشد و یک برداشت با تفاوت مبلغ بسیار زیاد (نسبت به سایر برداشته‌ها) انجام شود، به آن ناهنجاری نقطه‌ای گفته می‌شود. ناهنجاری‌های نقطه‌ای اغلب نشان‌دهنده یک بی‌نظمی یا انحراف است که به طور تصادفی اتفاق می‌افتد و ممکن است تفسیر خاصی نداشته باشد. شکل ۵ مثالی از ناهنجاری نقطه‌ای را در تراکنش‌های بانکی نشان می‌دهد.



شکل ۵: ناهنجاری نقطه‌ای در تراکنش بانکی

۳.۶.۲ تشخیص ناهنجاری زمینه‌ای

چنین ناهنجاری‌هایی وابسته به زمینه‌ای هستند که داده‌کاوی و تشخیص ناهنجاری در آن انجام می‌شود. وقوع چنین ناهنجاری‌هایی در داده‌های سری زمانی متداول است. برای مثال دمای هوای منفی بیست درجه (-۲۰) ممکن است در فصل زمستان کاملاً طبیعی باشد اما همین دما در فصل تابستان ناهنجاری در نظر گرفته می‌شود. ناهنجاری زمینه‌ای با در نظر گرفتن هر دو ویژگی زمینه‌ای و رفتاری شناسایی می‌شود. ویژگی‌های زمینه‌ای که معمولاً مورد استفاده قرار می‌گیرند زمان و مکان هستند. در حالی که ویژگی‌های رفتاری ممکن است الگویی از خرج کردن پول باشد، وقوع رویدادهای گزارش سیستم یا هر ویژگی که برای توصیف رفتار عادی، استفاده می‌شود.

^۸ OC-NN

^۹ DHM


^۵ RBM

^۶ DBM

^۷ RNN

در شکل ۶، دمای هوا در زمان t_1 مشابه t_2 است ولی در زمینه‌های متفاوتی به وقوع پیوسته‌اند؛ بنابراین، t_2 در زمینه به وقوع پیوسته برخلاف t_1 ، ناهنجاری محسوب می‌شود، زیرا چنین دمای کم و افت دمایی در ژوئن به طور معمول ناهنجاری است (البته بستگی به منطقه جغرافیایی که داده‌ها از آن تهیه شده‌اند نیز دارد).


درجه حرارت ماهانه



شکل ۶: تصویری از ناهنجاری زمینه ایی یا متنی

۳.۶.۳ تشخیص ناهنجاری جمعی یا گروهی

نمونه داده‌های جمعی به شناسایی ناهنجاری‌ها کمک می‌کنند. برای مثال، فعالیت شخصی که تلاش می‌کند داده‌ها را از یک ماشین دور به کامپیوتر خود منتقل کند ناهنجاری محسوب می‌شود. مجموعه‌های غیرعادی نقاط داده فردی به‌عنوان ناهنجاری‌های جمعی یا گروهی شناخته می‌شوند [۹]. مثال بهتری از ناهنجاری جمعی که در شکل ۷ نشان داده شده است، نوار قلب انسان است. وجود مقادیر پایین در نوار قلب به خودی خود ناهنجاری نیست، اما هنگامی که تعداد زیادی از این مقادیر پایین به صورت تجمعی اتفاق می‌افتند ناهنجاری در نظر گرفته می‌شوند.



شکل ۷: تصویری از ناهنجاری تجمعی در نوار قلب انسان

۳.۷ کاربرد تشخیص ناهنجاری عمیق

• **تشخیص نفوذ:** سیستم تشخیص نفوذ^{۱۰} به شناسایی فعالیت‌های مخرب در یک سیستم مرتبط با رایانه اشاره دارد. ممکن است در رایانه‌های منفرد^{۱۱} در شبکه‌های بزرگ شناسایی نفوذ شبکه^{۱۲} مستقر شود [۹].

• **تشخیص ناهنجاری‌های صنعتی:** سیستم‌های صنعتی متشکل از توربین‌های بادی، نیروگاه‌ها، سیستم‌های انرژی با دمای بالا، دستگاه‌های ذخیره‌سازی و دارای قطعات مکانیکی چرخشی روزانه در معرض تنش‌های بسیار زیادی هستند. آسیب به این نوع سیستم‌ها نه تنها باعث زیان اقتصادی بلکه از بین رفتن اعتبار می‌شود.

• **تشخیص تقلب:** تقلب یک عمل عمدی فریب برای دسترسی به منابع ارزشمند است. کشف تقلب به شناسایی فعالیت‌های غیرقانونی در صنایع تقلب در ارتباطات راه دور، بیمه مطالبات بانکی مشکلات قابل توجهی را هم در دولت‌ها و هم در مشاغل خصوصی نشان می‌دهد. بسیاری از الگوریتم‌های یادگیری ماشین سنتی با موفقیت در تشخیص تقلب به کار گرفته شده‌اند [۲۴] چالش مرتبط با کشف تقلب این است که نیاز به شناسایی و پیشگیری در زمان واقعی دارد.

• **تشخیص ناهنجاری در سری‌های زمانی:** داده‌هایی که به طور مداوم در طول مدت ثبت می‌شوند به‌عنوان سری‌های زمانی شناخته می‌شوند. داده‌های سری زمانی را می‌توان به‌طور کلی به سری‌های زمانی تک‌متغیره و چندمتغیره طبقه‌بندی کرد. در مورد سری‌های زمانی تک‌متغیره، تنها متغیر منفرد در طول زمان تغییر می‌کند. یکی از چالش‌های شناسایی ناهنجاری‌ها عبارت‌اند از: عدم وجود الگوی تعریف شده که در آن ناهنجاری رخ می‌دهد. مدل‌های تشخیص ناهنجاری عمیق باید قادر به تشخیص ناهنجاری‌ها در زمان واقعی باشند.

• **تشخیص بدافزار:** به‌منظور محافظت کاربران در برابر بدافزار، روش‌های تشخیص بدافزار کارآمد مبتنی بر یادگیری ماشینی پیشنهاد شده‌اند [۲۵]. عملکرد روش‌های تشخیص بدافزار سنتی به شدت به ویژگی‌های استخراج‌شده و روش‌های طبقه‌بندی یا خوشه‌بندی بستگی دارد. علاوه بر این، بدافزار ماهیت بسیار تطبیقی دارد، به طوری که مهاجمان از تکنیک‌های پیشرفته برای پنهان کردن رفتار مخرب استفاده می‌کنند.

• **یادگیری عمیق برای تشخیص ناهنجاری در شبکه‌های اجتماعی:** ناهنجاری در یک شبکه اجتماعی، الگوی رفتاری نامنظم و اغلب غیرقانونی افراد در یک شبکه اجتماعی است. چنین افرادی ممکن است به‌عنوان اسپمر، شکارچیان جنسی، کلاهبرداران آنلاین، کاربران جعلی یا شایعه‌ساز شناسایی شوند. ماهیت ناهمگن و پویای داده‌ها چالش‌های مهمی را برای تکنیک‌های تشخیص ناهنجاری عمیق ایجاد می‌کند.

• **تشخیص ناهنجاری پزشکی:** مطالعات متعددی برای درک کاربردهای نظری و عملی یادگیری عمیق در پزشکی و بیوانفورماتیک انجام شده است [۲۶]. یافتن رویدادهای نادر (ناهنجاری‌ها) در زمینه‌هایی مانند تجزیه و تحلیل تصویر پزشکی، سوابق الکتروانسفالوگرافی بالینی^{۱۳}، امکان تشخیص و ارائه درمان‌های پیشگیرانه را برای انواع شرایط پزشکی فراهم می‌کند.

^{۱۲} NIDS

^{۱۳} EEG

^{۱۰} IDS

^{۱۱} HIDS

• اینترنت اشیا^۴ تشخیص ناهنجاری داده‌های بزرگ: اینترنت اشیا به‌عنوان شبکه‌ای از دستگاه‌هایی شناخته می‌شود که با نرم‌افزارها، سرورها، حسگرها و غیره به هم متصل هستند. تشخیص ناهنجاری در این شبکه‌های اینترنت اشیا، رفتار تقلبی و معیوب این مقیاس عظیم از دستگاه‌های متصل به هم را شناسایی می‌کند. چالش تشخیص نقاط پرت این است که دستگاه‌های ناهمگن به هم متصل هستند که سیستم را پیچیده‌تر می‌کند [۱۵].

• نظارت تصویری: نظارت تصویری که عموماً به‌عنوان تلویزیون مداربسته^{۱۵} نیز شناخته می‌شود شامل نظارت بر مناطق مشخص شده موردنظر به‌منظور اطمینان از امنیت است. در برنامه‌های نظارت ویدئویی، داده‌های بدون برچسب در مقادیر زیادی در دسترس هستند. از این رو برنامه‌های نظارت تصویری به دلیل عدم دسترسی به داده‌های برچسب‌دار به‌عنوان مشکلات تشخیص ناهنجاری مدل‌سازی شده‌اند.

۴. مدل‌های تشخیص ناهنجاری‌های عمیق

در این بخش، مدل‌های مختلف تشخیص ناهنجاری عمیق طبقه‌بندی شده را بر اساس در دسترس بودن برچسب‌ها و هدف آموزشی موردبحث قرار می‌دهیم. برای هر حوزه از انواع مدل، سه جنبه زیر موردبحث قرار گرفته است:

- ✓ فرضیات
- ✓ پیچیدگی محاسباتی
- ✓ مزایا و معایب

۴.۱ تشخیص ناهنجاری عمیق تحت نظارت

تکنیک‌های تشخیص ناهنجاری تحت نظارت در عملکرد نسبت به تکنیک‌های تشخیص ناهنجاری بدون نظارت برتر هستند زیرا این تکنیک‌ها از نمونه‌های برچسب‌دار استفاده می‌کنند [۲۷]. تشخیص ناهنجاری تحت نظارت، مرز جداکننده را از مجموعه‌ای از نمونه‌های داده مشروح را یاد می‌گیرد و سپس، یک نمونه آزمون را با مدل آموخته‌شده به کلاس‌های عادی یا غیرعادی طبقه‌بندی می‌کند (تست).

مفروضات: روش‌های یادگیری با نظارت عمیق به جداکردن کلاس‌های داده بستگی دارد درحالی‌که تکنیک‌های بدون نظارت بر توضیح و درک ویژگی‌های داده تمرکز دارند. تکنیک‌های تشخیص ناهنجاری مبتنی بر طبقه‌بندی چند کلاس فرض می‌کند که داده‌های آموزشی حاوی نمونه‌های برچسب‌گذاری شده از چندین کلاس عادی است [۲۸]. تکنیک‌های تشخیص ناهنجاری چند کلاسه، یک طبقه‌بندی را یاد می‌گیرند تا بین کلاس غیرعادی از بقیه کلاس‌ها تمایز قائل شوند. به طور کلی، طرح‌های طبقه‌بندی مبتنی بر یادگیری عمیق نظارت شده برای تشخیص ناهنجاری دارای دو شبکه فرعی است، یک شبکه استخراج ویژگی و به دنبال آن یک شبکه طبقه‌بندی. مدل‌های عمیق به تعداد قابل توجهی از

نمونه‌های آموزشی (به ترتیب هزاران یا میلیون‌ها) برای یادگیری نمایش ویژگی‌ها برای تمایز مؤثر نمونه‌های کلاس مختلف نیاز دارند. پیچیدگی محاسباتی: پیچیدگی محاسباتی تکنیک‌های مبتنی بر روش‌های تشخیص ناهنجاری با نظارت عمیق به بعد داده‌های ورودی و تعداد لایه‌های پنهان آموزش داده‌شده با استفاده از الگوریتم انتشار پس‌انداز بستگی دارد. داده‌های ابعادی بالا معمولاً لایه‌های پنهان بیشتری دارند تا از یادگیری سلسله‌مراتبی کامل معنی‌دار ویژگی‌های ورودی اطمینان حاصل کنند. پیچیدگی محاسباتی نیز با تعداد لایه‌های پنهان به‌صورت خطی افزایش می‌یابد و به آموزش مدل و زمان به‌روزرسانی بیشتری نیاز دارد.

مزایا و معایب: مزایای تکنیک‌های تشخیص ناهنجاری عمیق نظارت شده به شرح زیر است:

• این تکنیک‌ها دقیق‌تر از مدل‌های نیمه نظارت و بدون نظارت است.

• مرحله آزمایش تکنیک‌های مبتنی بر طبقه‌بندی سریع است زیرا هر نمونه آزمایشی باید با مدل از پیش محاسبه شده مقایسه شود. معایب این تکنیک‌ها به شرح زیر است:

• تکنیک‌های نظارت شده چند کلاسه به برچسب‌های دقیق برای کلاس‌های عادی و نمونه‌های غیرعادی نیاز دارند که اغلب در دسترس نیستند.

اگر فضای ویژگی، بسیار پیچیده و غیرخطی باشد، تکنیک‌های تحت نظارت عمیق نمی‌توانند داده‌های عادی را از غیرعادی جدا کنند.

۴.۲ تشخیص ناهنجاری عمیق نیمه نظارت شده

تکنیک‌های تشخیص ناهنجاری عمیق نیمه نظارت‌شده یا (طبقه‌بندی تک کلاسی) فرض می‌کنند که همه نمونه‌های آموزشی فقط یک برچسب کلاس دارند. این تکنیک‌ها یک مرز متمایز در اطراف نمونه‌های عادی را یاد می‌گیرند. نمونه آزمایشی که به کلاس اکثریت تعلق ندارد به‌عنوان غیرعادی علامت‌گذاری می‌شود.

مفروضات: روش‌های تشخیص ناهنجاری عمیق نیمه نظارت شده برای تکیه بر یکی از مفروضات زیر برای امتیازدهی به یک نمونه داده به‌عنوان یک ناهنجاری پیشنهاد شده‌اند.

مجاورت و تداوم: نقاطی که هم در فضای ورودی و هم در فضای ویژگی‌های آموخته شده به یکدیگر نزدیک هستند، احتمالاً برچسب یکسانی دارند. ویژگی‌های قوی در لایه‌های پنهان لایه‌های شبکه عصبی عمیق آموخته می‌شوند و ویژگی‌های متمایز را برای جداسازی نقاط داده‌های معمولی از پرت حفظ می‌کنند.

پیچیدگی محاسباتی: پیچیدگی محاسباتی تکنیک‌های مبتنی بر روش‌های تشخیص ناهنجاری نیمه نظارت شده مشابه تکنیک‌های تشخیص ناهنجاری‌های نظارت شده است که در درجه اول به ابعاد داده‌های ورودی و تعداد لایه‌های پنهان مورد استفاده برای یادگیری ویژگی‌های نماینده بستگی دارد.

مزایا و معایب: مزایای تکنیک‌های تشخیص ناهنجاری عمیق نیمه نظارت شده به این شرح است: شبکه‌های متخاصم مولد^{۱۶} که در حالت یادگیری نیمه نظارتی آموزش دیده‌اند، حتی با داده‌های برچسب‌گذاری شده بسیار کمی، نویدبخشی خوبی از خود نشان داده‌اند. استفاده از داده‌های برچسب‌دار (معمولاً یک کلاس)، می‌تواند باعث بهبود عملکرد قابل توجهی نسبت به تکنیک‌های بدون نظارت شود. معایب اساسی تکنیک‌های نیمه نظارتی حتی در زمینه یادگیری عمیق قابل‌اجرا است. علاوه بر این، ویژگی‌های سلسله‌مراتبی استخراج‌شده در لایه‌های پنهان ممکن است نماینده نمونه‌های غیرعادی کمتری نباشند، از این رو مستعد مشکل بیش‌برازش هستند [۹].

۴.۳ تشخیص ناهنجاری عمیق هیبریدی

مدل‌های یادگیری عمیق به طور گسترده‌ای به‌عنوان استخراج‌کننده ویژگی برای یادگیری ویژگی‌های قوی استفاده می‌شوند. در مدل‌های هیبریدی عمیق، ویژگی‌هایی که در مدل‌های عمیق آموخته می‌شوند، به‌عنوان ورودی به الگوریتم‌های سنتی مانند طبقه‌بندی‌کننده‌های تابع پایه شعاعی^{۱۷}، ماشین بردار پشتیبانی داده می‌شوند. مدل‌های ترکیبی از یادگیری دومرحله‌ای استفاده می‌کنند و نشان داده شده‌اند که نتایج خوبی را تولید می‌کنند.

مفروضات: مدل‌های ترکیبی عمیق پیشنهادی برای تشخیص ناهنجاری بر یکی از مفروضات زیر برای تشخیص نمونه‌های پرت تکیه می‌کنند:

ویژگی‌های قوی در لایه‌های پنهان شبکه عصبی عمیق استخراج می‌شوند و به جداسازی ویژگی‌های نامربوط که می‌توانند وجود ناهنجاری‌ها را پنهان کنند، کمک می‌کنند.

ساخت یک مدل تشخیص ناهنجاری قوی در فضاهای پیچیده و با ابعاد بالا به استخراج‌کننده ویژگی و آشکارساز ناهنجاری نیاز دارد.

پیچیدگی محاسباتی: پیچیدگی محاسباتی یک مدل ترکیبی شامل پیچیدگی معماری‌های عمیق و همچنین الگوریتم‌های سنتی مورد استفاده در داخل می‌شود. علاوه بر این، یک مسئله ذاتی انتخاب معماری و پارامترهای شبکه عمیق که شامل جستجوی پارامترهای بهینه شده در یک فضای بسیار بزرگ‌تر است، پیچیدگی محاسباتی استفاده از لایه‌های عمیق در مدل‌های ترکیبی را تعیین می‌کند.

مزایا و معایب:

مزایای تکنیک‌های هیبریدی به شرح زیر است:

- استخراج‌کننده ویژگی به طور قابل توجهی «نفرین ابعاد» را کاهش می‌دهد، به‌خصوص در حوزه ابعاد بالا.
- مدل‌های ترکیبی مقیاس‌پذیرتر و از نظر محاسباتی کارآمدتر هستند، زیرا مدل‌های هسته خطی یا غیرخطی در ابعاد ورودی کاهش یافته عمل می‌کنند.

معایب قابل توجه تکنیک‌های هیبریدی عبارت‌اند از: رویکرد ترکیبی نابهنه است زیرا نمی‌تواند بر یادگیری بازنمایی در لایه‌های پنهان استخراج‌کننده ویژگی تأثیر بگذارد زیرا توابع ضرر عمومی به جای هدف سفارشی برای تشخیص ناهنجاری استفاده می‌شود.

مدل‌های ترکیبی عمیق‌تر تمایل به عملکرد بهتری دارند اگر لایه‌های منفرد باشند که هزینه‌های محاسباتی را تعیین می‌کند.

۴.۴ شبکه‌های عصبی یک-کلاس برای تشخیص ناهنجاری

شبکه‌های عصبی یک-کلاس توانایی شبکه‌های عمیق را برای استخراج یک نمایش غنی از داده‌ها را به طبقه بند یک کلاس مانند یک ابر صفحه [۱] یا ابر کره [۷] ترکیب می‌کند برای جداکردن تمام نقاط داده عادی از نقاط پرت. این رویکرد به این دلیل جدید است: نمایش داده‌ها در لایه پنهان با بهینه‌سازی تابع هدف سفارشی شده برای تشخیص ناهنجاری. همان‌طور که در نتایج تجربی نشان می‌دهد که شبکه عصبی یک-کلاس می‌تواند عملکرد قابل‌مقایسه یا بهتری نسبت به روش‌های پیشرفته موجود برای مجموعه داده‌های پیچیده داشته باشد، درحالی‌که زمان آموزش و آزمایش معقولی در مقایسه با روش‌های موجود دارد.

مفروضات: این مدل‌ها پیشنهادی برای تشخیص ناهنجاری بر مفروضات زیر برای تشخیص نقاط پرت متکی هستند:

- مدل‌های شبکه عصبی یک-کلاس فاکتورهای رایج در توزیع داده‌ها در لایه‌های پنهان شبکه عصبی عمیق را استخراج می‌کنند.
- آموزش بازنمایی ترکیبی را انجام می‌دهد و برای نمونه داده‌های آزمون، یک امتیاز پرت ایجاد می‌کند.

پیچیدگی محاسباتی: پیچیدگی محاسباتی این مدل در مقابل مدل ترکیبی فقط شامل پیچیدگی شبکه عمیق انتخابی است [۹]. مدل‌های شبکه عصبی تک کلاس برای پیش‌بینی نیازی به ذخیره داده ندارند، بنابراین پیچیدگی حافظه بسیار کمی دارند. با این حال، بدیهی است که زمان آموزش این مدل با بعد ورودی متناسب است.

مزایا و معایب: مزایای شبکه‌های عصبی تک کلاس به شرح زیر است:

- این مدل‌ها به طور مشترک یک شبکه عصبی عمیق را آموزش می‌دهند درحالی‌که یک ابر کره یا ابر صفحه محصور در فضای خروجی را بهینه می‌کنند.
- شبکه عصبی تک کلاس الگوریتم کمینه‌سازی متناوب را برای یادگیری پارامترهای این مدل پیشنهاد می‌کند.
- معایب قابل توجه شبکه‌های عصبی تک کلاس برای تشخیص ناهنجاری عبارت‌اند از:
 - زمان آموزش و زمان به‌روزرسانی مدل ممکن است برای داده‌های ورودی با ابعاد بالا طولانی‌تر باشد.
 - باتوجه به تغییر در فضای ورودی، به‌روزرسانی مدل نیز زمان بیشتری می‌برد.

۴.۵ تشخیص ناهنجاری عمیق بدون نظارت

تشخیص ناهنجاری عمیق بدون نظارت یک حوزه تحقیقاتی ضروری در تحقیقات اساسی یادگیری ماشین و کاربردهای صنعتی است. چندین چارچوب یادگیری عمیق که به چالش‌ها در تشخیص ناهنجاری بدون نظارت می‌پردازند، ارائه شده و نشان داده شده‌اند که عملکردی پیشرفته را ایجاد می‌کنند. رمزگذارهای خودکار، معماری‌های عمیق بدون نظارت اساسی هستند که در تشخیص ناهنجاری استفاده می‌شوند.

مفروضات: مدل‌های بدون نظارت عمیق پیشنهادی برای تشخیص ناهنجاری بر یکی از مفروضات زیر برای تشخیص موارد پرت متکی هستند:

- مناطق "عادی" در فضای ویژگی اصلی یا پنهان را می‌توان از مناطق "غیرعادی" در فضای ویژگی اصلی یا پنهان متمایز کرد.
- اکثر نمونه‌های داده در مقایسه با بقیه مجموعه داده‌ها عادی هستند.

- الگوریتم تشخیص ناهنجاری نظارت نشده بر اساس ویژگی‌های ذاتی مجموعه داده‌ها مانند فواصل یا چگالی، امتیازی خارج از نمونه‌های داده ایجاد می‌کند. لایه‌های پنهان شبکه عصبی عمیق باهدف ثبت این ویژگی‌های ذاتی در مجموعه داده‌ها است.

- **پیچیدگی محاسباتی:** رمزگذارهای خودکار رایج‌ترین معماری مورد استفاده در تشخیص نقاط پرت با هزینه درجه دوم هستند، مشکل بهینه‌سازی غیر محدب است، مشابه هر معماری شبکه عصبی دیگر. پیچیدگی محاسباتی مدل به تعداد عملیات، پارامترهای شبکه و لایه‌های پنهان بستگی دارد. با این حال، پیچیدگی محاسباتی آموزش رمزگذار خودکار بسیار بالاتر از روش‌های سنتی مانند تجزیه و تحلیل مؤلفه اصلی^{۱۸} است زیرا مبتنی بر تجزیه ماتریس است [۲۹].

- **مزایا و معایب:** مزایای تکنیک‌های تشخیص ناهنجاری عمیق بدون نظارت به شرح زیر است:

- ویژگی‌های ذاتی داده را برای جداسازی یک نقطه داده عادی از غیرعادی می‌آموزد. این تکنیک مشترکات درون داده‌ها را شناسایی می‌کند و تشخیص ناهنجاری را آسان می‌کند.
- روش مقرون به صرفه برای یافتن ناهنجاری‌ها، زیرا برای آموزش الگوریتم‌ها به داده‌های حاشیه‌نویسی نیاز ندارد.
- معایب قابل توجه تکنیک‌های تشخیص ناهنجاری عمیق بدون نظارت عبارت‌اند از:
 - اغلب یادگیری مشترکات درون داده‌ها در یک فضای پیچیده و با ابعاد بالا چالش برانگیز است.
 - در حین استفاده از رمزگذارهای خودکار، انتخاب درجه مناسب فشرده‌سازی، یعنی کاهش ابعاد اغلب یک پارامتر فوق‌العاده است که برای نتایج بهینه نیاز به تنظیم دارد.

- تکنیک‌های بدون نظارت نسبت به نویز و خرابی داده‌ها بسیار حساس هستند و اغلب دقت کمتری نسبت به تکنیک‌های نظارت شده یا نیمه نظارت دارند.

۵. روش‌های گوناگون تشخیص ناهنجاری عمیق

این بخش به بررسی تکنیک‌های مختلف تشخیص ناهنجاری عمیق می‌پردازد که نشان داده شده‌اند مؤثر و امیدوارکننده هستند، ایده کلیدی پشت آن تکنیک‌ها و حوزه کاربرد آن‌ها مورد بحث قرار گرفته است.



شکل ۸: نمایش شماتیک از برخی از تکنیک‌های متفرقه تشخیص ناهنجاری

۵.۱ مدل‌های Word2vec

Word2vec گروهی از مدل‌های شبکه عصبی عمیق است که برای تولید جاسازی‌های کلمه استفاده می‌شود. این مدل‌ها می‌توانند روابط متوالی را در نمونه داده‌ای مانند جملات، داده‌های توالی زمانی ثبت کنند. مدل‌های تشخیص ناهنجاری که از word2vec استفاده می‌کنند عملکرد را به طور قابل توجهی بهبود می‌بخشند.

۵.۲ تشخیص ناهنجاری مبتنی بر یادگیری انتقال

یادگیری عمیق برای مدت طولانی به دلیل نیاز به داشتن داده‌های کافی برای ایجاد نتایج خوب مورد انتقاد قرار گرفته است. یادگیری انتقالی یک ابزار ضروری در یادگیری ماشین برای حل مشکل اساسی داده‌های آموزشی ناکافی است. هدف آن انتقال دانش از دامنه مبدأ به دامنه هدف با تسهیل این فرض است که آموزش و داده‌های آینده باید در فضای ویژگی یکسان باشند و توزیع یکسانی داشته باشند. سؤالات تحقیق باز با استفاده از یادگیری انتقال برای تشخیص ناهنجاری، درجه توانایی انتقال است، به این معنی که مشخص می‌کند که چگونه ویژگی‌ها دانش را منتقل می‌کنند و عملکرد طبقه‌بندی را از یک کار به کار دیگر بهبود می‌بخشند.

۵.۳ تشخیص ناهنجاری مبتنی بر یادگیری شات صفر

هدف یادگیری شات صفر^{۱۹} شناسایی اشیایی است که قبلاً در مجموعه آموزشی دیده نشده بود [۳۰]. در دو مرحله به این امر دست می‌یابد: اولاً دانش مربوط به اشیاء در توصیفات یا ویژگی‌های زبان طبیعی (که معمولاً به عنوان فراداده شناخته می‌شوند) جمع‌آوری می‌شود. این تنظیم در دنیای واقعی مهم است زیرا ممکن است فرد نتواند تصاویری از تمام کلاس‌های ممکن در آموزش به دست آورد. چالش اصلی مرتبط با این رویکرد، به دست آوردن فراداده در مورد نمونه‌های داده است.

۵.۴ تشخیص ناهنجاری مبتنی بر مجموعه

یک مسئله قابل توجه در مورد شبکه‌های عصبی عمیق این است که آنها به نوبت در داده‌های ورودی حساس هستند و اغلب به داده‌های آموزشی گسترده برای عملکرد قوی نیاز دارند برای دستیابی به استحکام حتی در داده‌های نویزی، ایده تغییر تصادفی معماری اتصال رمزگذار خودکار برای دستیابی به عملکرد بسیار بهتر نشان داده شده است. مجموعه‌های رمزگذار خودکار متشکل از رمزگذارهای خودکار مختلف که به طور تصادفی متصل شده‌اند.

۵.۵ تشخیص ناهنجاری مبتنی بر خوشه

خوشه‌بندی شامل گروه‌بندی الگوهای مشابه بر اساس ویژگی‌های استخراج شده، شناسایی ناهنجاری‌های جدید است. پیچیدگی زمان و مکان به صورت خطی با تعداد کلاس‌هایی که باید خوشه‌بندی شوند رشد می‌کند که تشخیص ناهنجاری مبتنی بر خوشه‌بندی را برای کاربردهای عملی بلادرنگ ممنوع می‌کند. تشخیص ناهنجاری عمیق با رویکرد خوشه‌بندی فعال از مدل‌های [۳۱] word2vec، برای به دست آوردن نمایش معنایی داده‌ها و ناهنجاری‌ها برای تشکیل خوشه‌ها و تشخیص نقاط پرت استفاده می‌کند.

۵.۶ تکنیک‌های آماری تشخیص ناهنجاری عمیق

تبدیل هیلبرت یک تکنیک پردازش سیگنال آماری است که بازنمایی تحلیلی یک سیگنال بارزش واقعی را استخراج می‌کند. برای تشخیص بی‌درنگ ناهنجاری‌ها در مجموعه داده‌های سری زمانی مرتبط با سلامت استفاده می‌شود. این الگوریتم توانایی تجزیه و تحلیل موجک را دارد و شبکه‌های عصبی و تبدیل هیلبرت را به صورت متوالی برای تشخیص ناهنجاری‌های بلادرنگ ترکیب می‌کند.

۵.۷ تشخیص ناهنجاری مبتنی بر یادگیری تقویتی عمیق

روش‌های یادگیری تقویتی عمیق، به دلیل توانایی در یادگیری رفتارهای پیچیده در فضای داده با ابعاد بالا، توجه بسیاری را به خود جلب کرده است. آشکارساز ناهنجاری مبتنی بر یادگیری تقویتی عمیق هیچ فرضی را در مورد مفهوم ناهنجاری در نظر نمی‌گیرد و آشکارساز، ناهنجاری‌های جدید را به طور مداوم شناسایی می‌کند.

۵.۸ شبکه‌های زمانی فضایی

شبکه‌های زمانی فضایی از معماری‌های عصبی عمیق تشکیل شده‌اند که هر دو ویژگی‌های زمانی و ویژگی‌های فضایی را برای استخراج ویژگی‌های مکانی - زمانی ترکیب می‌کنند. ویژگی‌های زمانی (مدل‌سازی همبستگی‌های بین نقاط زمانی نزدیک)، ویژگی‌های

فضایی (مدل‌سازی همبستگی مکانی محلی) در تشخیص نقاط دورافتاده مؤثر هستند [۳۲].

۵.۹ شبکه‌های جمع‌آوری محصول

شبکه‌های جمع‌آوری محصول، گراف‌های جهت‌دار با متغیرهایی به‌عنوان برگ هستند و گره‌های داخلی و بال‌های وزن‌دار محصولات را تشکیل می‌دهند. این شبکه‌ها به‌عنوان ترکیبی از مدل‌های مخلوط در نظر گرفته می‌شوند که استنتاج احتمالی سریع و دقیق روی بسیاری از لایه‌ها دارند. مزیت اصلی این شبکه‌ها این است که بر خلاف مدل‌های گرافی، نسبت به مدل‌های با پهنای درخت بالا بدون نیاز به استنتاج تقریبی قابل ردیابی هستند.

۵.۱۰ مدل‌های مولد

هدف مدل‌های مولد یادگیری توزیع دقیق داده‌ها به‌منظور تولید نقاط داده جدید با برخی تغییرات است. دو روش متداول و کارآمد مولد عبارت‌اند از رمزگذارهای خودکار متغیر [۳۳] و شبکه‌های متخاصم مولد. گونه‌ای از معماری شبکه‌های متخاصم مولد که به نام رمزگذارهای خودکار متخاصم شناخته می‌شود از آموزش خصمانه برای تحمیل یک پیش‌فرض دلخواه بر روی کد پنهان آموخته شده در لایه‌های پنهان رمزگذار خودکار استفاده می‌کند.

۵.۱۱ شبکه‌های عصبی کانولوشنال

شبکه‌های عصبی کانولوشنال^{۲۳}، شبکه‌های عصبی محبوب برای تجزیه و تحلیل تصاویر بصری هستند. توانایی این شبکه‌ها برای استخراج ویژگی‌های پنهان پیچیده از داده‌های ابعاد بالا با ساختار پیچیده، استفاده از آن را به‌عنوان استخراج‌کننده ویژگی در تشخیص داده‌های متوالی و تصویری ممکن کرده است.

۵.۱۲ مدل‌های دنباله‌ای

شبکه‌های عصبی دنباله‌ای^{۲۴} برای گرفتن ویژگی‌های داده‌های سری زمانی نشان داده شده‌اند. محدودیت‌های این شبکه‌ها این است که با افزایش گام‌های زمانی، نمی‌توانند زمینه را ضبط کنند، برای حل این مشکل، شبکه‌های حافظه کوتاه‌مدت [۳۴] معرفی شدند، آنها نوع خاصی از مدل‌های دنباله‌ای هستند که شامل یک سلول حافظه که می‌تواند اطلاعات مربوط به مراحل قبلی را ذخیره کند. الگوریتم‌های مبتنی بر شبکه عصبی حافظه کوتاه‌مدت^{۲۵} برای تشخیص ناهنجاری، بررسی و گزارش شده‌اند که نسبت به روش‌های مرسوم دستاوردهای عملکردی قابل توجهی ایجاد می‌کنند.

۵.۱۳ رمزگذارهای خودکار

CNN^{۲۳}

RNN^{۲۴}

LSTM^{۲۵}

DRL^{۲۰}

STN^{۲۱}

SPN^{۲۲}

موجود در تشخیص ناهنجاری عمیق را مورد بحث قرار داده‌ایم. این مقاله برخی از راه‌حل‌های موجود برای این چالش‌ها نیز ارائه می‌کند. برای هر دسته از تکنیک‌های تشخیص ناهنجاری عمیق، فرضیات مربوط به مفهوم داده‌های عادی و غیرعادی را همراه باقوت و ضعف آن ارائه می‌کنیم. هدف از این مقاله بررسی و شناسایی مدل‌های مختلف یادگیری عمیق برای تشخیص ناهنجاری و ارزیابی مناسب بودن آن برای یک کاربرد معین بود. هنگام انتخاب یک مدل یادگیری عمیق برای یک حوزه یا داده خاص، این مفروضات می‌توانند به‌عنوان راهنمایی برای ارزیابی اثربخشی تکنیک در آن حوزه مورد استفاده قرار گیرند. تشخیص ناهنجاری مبتنی بر یادگیری عمیق هنوز یک تحقیق فعال است.

۸. منابع

- [۱] Pang, G., Shen, C., Cao, L., and Hengel, A. V. D. (۲۰۲۱). Deep learning for anomaly detection: A review. *ACM Computing Surveys (CSUR)*, ۵۴(۲), ۱-۳۸.
- [۲] Bulusu, S., Kailkhura, B., Li, B., Varshney, P. K., and Song, D. (۲۰۲۰). Anomalous example detection in deep learning: A survey. *IEEE Access*, ۸, ۱۳۲۲۳۰-۱۳۲۲۴۷.
- [۳] Mohri, M., Rostamizadeh, A., and Talwalkar, A. (۲۰۱۸). *Foundations of machine learning*: MIT press
- [۴] Aggarwal, C. C., "An introduction to outlier analysis," in *Outlier analysis*: Springer, ۲۰۱۷, pp. ۱-۳۴.
- [۵] Ruff, L. et al. (۲۰۱۸). Deep one-class classification. *International conference on machine learning*: PMLR, ۴۳۹۳-۴۴۰۲.
- [۶] Østmo, E. A., "A study of generative adversarial networks to improve classification of microscopic foraminifera," *UiT Norges arktiske universitet*, ۲۰۲۰.
- [۷] Ruff, L. et al. (۲۰۲۱). A unifying review of deep and shallow anomaly detection. *Proceedings of the IEEE*.
- [۸] Singh, K., Rajora, S., Vishwakarma, D. K., Tripathi, G., Kumar, S., and Walia, G. S. (۲۰۲۰). Crowd anomaly detection using aggregation of ensembles of fine-tuned convnets. *Neurocomputing*, ۳۷۱, ۱۸۸-۱۹۸.
- [۹] Chalapathy, R. and Chawla, S. (۲۰۱۹). Deep learning for anomaly detection: A survey. *arXiv preprint arXiv:1901.03407*.
- [۱۰] Havaei, M. et al. (۲۰۱۷). Brain tumor segmentation with deep neural networks. *Medical image analysis*, ۳۵, ۱۸-۳۱.
- [۱۱] Larin, A. O., Seredin, O. S., and Kopylov, A. V. (۲۰۲۱). One-Class Classification Criterion Robust to Anomalies in Training Dataset. *International Conference on Pattern Recognition*: Springer, ۱۵۵-۱۶۵.

رمزگذارهای خودکار^{۲۶} با یک‌لایه به همراه یک تابع فعال‌سازی خطی تقریباً معادل تجزیه و تحلیل مؤلفه اصلی هستند درحالی‌که مؤلفه‌های اصلی به کاهش ابعاد خطی محدود می‌شود، رمزگذارهای خودکار هر دو تبدیل خطی یا غیرخطی را فعال می‌کنند. یکی از کاربردهای محبوب رمزگذارهای خودکار تشخیص ناهنجاری است. اگرچه رمزگذارهای خودکار معماری ساده و مؤثری برای تشخیص نمونه‌های پرت دارند، با این حال عملکردشان به دلیل داده‌های آموزشی نوبیزی کاهش می‌یابد.

۶. نقاط قوت و ضعف نسبی روش‌های تشخیص ناهنجاری عمیق

هر یک از تکنیک‌های تشخیص ناهنجاری عمیق که در بخش‌های قبلی مورد بحث قرار گرفت، نقاط قوت و ضعف منحصر به فردی دارد. بسیار مهم است که بفهمیم کدام روش تشخیص ناهنجاری برای یک حوزه تشخیص ناهنجاری مناسب است. با توجه به این واقعیت که این تکنیک‌ها یک حوزه تحقیقاتی فعال است، ارائه چنین درکی برای هر مساله تشخیص ناهنجاری امکان‌پذیر نیست. از این رو در این بخش، نقاط قوت و ضعف نسبی دسته‌های مختلف تکنیک‌ها را برای چند تنظیمات ساده تحلیل می‌کنیم. پیچیدگی محاسباتی تکنیک تشخیص ناهنجاری عمیق نظارت شده یک جنبه کلیدی است، به خصوص زمانی که این تکنیک در یک حوزه واقعی اعمال شود. درحالی‌که تکنیک‌های مبتنی بر طبقه‌بندی، نظارت یا نیمه نظارت زمان آموزشی هزینه‌بری دارند، آزمایش معمولاً سریع است زیرا از یک مدل از پیش آموزش دیده استفاده می‌کند. تکنیک‌های بدون نظارت ارائه شده در این مقاله به طور گسترده مورد استفاده قرار می‌گیرند، زیرا بدست آوردن برجسب فرایندی پرهزینه و زمان‌بر است. تشخیص ناهنجاری عمیق بدون نظارت نیاز به پیش‌بینی در توزیع ناهنجاری دارد، بنابراین مدل‌ها در مدیریت داده‌های نوبیزی کمتر قوی هستند. مدل‌های ترکیبی بحث شده در این تحقیق ویژگی‌های قوی را در لایه‌های پنهان شبکه عصبی عمیق استخراج می‌کنند و به الگوریتم‌های تشخیص ناهنجاری کلاسیک تغذیه می‌کنند. رویکرد مدل ترکیبی نا بهینه است زیرا قادر به تأثیرگذاری بر یادگیری بازنمایی در لایه‌های پنهان نیست. شبکه‌های عصبی یک-کلاس که توضیح داده شد، توانایی شبکه‌های عمیق را برای استخراج یک بازنمایی غنی از داده‌ها را با طبقه بندی یک-کلاس مانند یک ابر صفحه ترکیب می‌کند یا هاپیر کره برای جدا کردن تمام نقاط داده عادی از نقاط داده غیرعادی استفاده می‌شود. تحقیقات و کاوش بیشتر برای درک بهتر مزایای این معماری جدید ضروری است.

۷. نتیجه

در این مقاله، روش‌های تحقیق مختلف در تشخیص ناهنجاری مبتنی بر یادگیری عمیق و کاربرد آن در حوزه‌های مختلف و چالش‌های

- [26] Khan, S. and Yairi, T. (2018). A review on the application of deep learning in system health management. *Mechanical Systems and Signal Processing*, 107, 241-260.
- [27] Zhang, C. et al. (2019). A deep neural network for unsupervised anomaly detection and diagnosis in multivariate time series data. *Proceedings of the AAAI conference on artificial intelligence*, 1409-1416.
- [28] Chakraborty, D., Narayanan, V., and Ghosh, A. (2019). Integration of deep feature extraction and ensemble learning for outlier detection. *Pattern Recognition*, 89, 161-171.
- [29] Meng, L. et al. (2018). Organic and solution-processed tandem solar cells with 17.3% efficiency. *Science*, 361(6407), 1094-1098.
- [30] Xian, Y., Lampert, C. H., Schiele, B., and Akata, Z. (2018). Zero-shot learning—a comprehensive evaluation of the good, the bad and the ugly. *IEEE transactions on pattern analysis and machine intelligence*, 41(9), 2201-2220.
- [31] Bojanowski, P., Grave, E., Joulin, A., and Mikolov, T. (2017). Enriching word vectors with subword information. *Transactions of the association for computational linguistics*, 5, 130-146.
- [32] SZEKÉR, M., "Spatio-temporal outlier detection in streaming trajectory data," ed, 2014.
- [33] Zhu, J.-Y., Park, T., Isola, P., and Efros, A. A. (2017). Unpaired image-to-image translation using cycle-consistent adversarial networks. *Proceedings of the IEEE international conference on computer vision*, 2223-2232.
- [34] Hu, J., Shen, L., and Sun, G. (2018). Squeeze-and-excitation networks. *Proceedings of the IEEE conference on computer vision and pattern recognition*, 7132-7141.
- [35] Golan, I. and El-Yaniv, R. (2018). Deep anomaly detection using geometric transformations. *Advances in neural information processing systems*, 31.
- [36] Kwon, D., Kim, H., Kim, J., Suh, S. C., Kim, I., and Kim, K. J. (2019). A survey of deep learning-based network anomaly detection. *Cluster Computing*, 22(1), 949-961.
- [37] Litjens, G. et al. (2017). A survey on deep learning in medical image analysis. *Medical image analysis*, 45, 130-148.
- [38] Mohammadi, M., Al-Fuqaha, A., Sorour, S., and Guizani, M. (2018). Deep learning for IoT big data and streaming analytics: A survey. *IEEE Communications Surveys & Tutorials*, 20(4), 2923-2960.
- [39] Ball, J. E., Anderson, D. T., and Chan Sr, C. S. (2017). Comprehensive survey of deep learning in remote sensing: theories, tools, and challenges for the community. *Journal of applied remote sensing*, 11(4), 042709.
- [40] Kiran, B. R., Thomas, D. M., and Parakkal, R. (2018). An overview of deep learning based methods for unsupervised and semi-supervised anomaly detection in videos. *Journal of Imaging*, 4(2), 36.
- [41] Sze, V., Chen, Y.-H., Yang, T.-J., and Emer, J. S. (2017). Efficient processing of deep neural networks: A tutorial and survey. *Proceedings of the IEEE*, 105(12), 2296-2329.
- [42] Ramotsoela, D., Abu-Mahfouz, A., and Hancke, G. (2018). A survey of anomaly detection in industrial wireless sensor networks with critical water system infrastructure as a case study. *Sensors*, 18(8), 2491.
- [43] Song, H., Jiang, Z., Men, A., and Yang, B. (2017). A hybrid semi-supervised anomaly detection model for high-dimensional data. *Computational intelligence and neuroscience*, 2017.
- [44] Patterson, J. and Gibson, A. (2017). Deep learning: A practitioner's approach: " O'Reilly Media, Inc."
- [45] Wang, H., Bah, M. J., and Hammad, M. (2019). Progress in outlier detection techniques: A survey. *Ieee Access*, 7, 107974-108000.
- [46] Ergen, T. and Kozat, S. S. (2019). Unsupervised anomaly detection with LSTM neural networks. *IEEE transactions on neural networks and learning systems*, 31(8), 3127-3141.
- [47] Carta, S., Fenu, G., Recupero, D. R., and Saia, R. (2019). Fraud detection for E-commerce transactions by employing a prudential Multiple Consensus model. *Journal of Information Security and Applications*, 47, 13-22.
- [48] Ye, Y., Li, T., Adjeroh, D., and Iyengar, S. S. (2017). A survey on malware detection using data mining techniques. *ACM Computing Surveys (CSUR)*, 50(3), 1-40.