

بِسْمِ اللَّهِ الرَّحْمَنِ الرَّحِيمِ



وزارت علوم، تحقیقات و فناوری
موسسه آموزش عالی سلمان
تهران - ایران

موسسه آموزش و عالی سلمان
دانشکده مهندسی

پایان نامه کارشناسی ارشد رشته مهندسی کامپیوتر گرایش شبکه های کامپوتری

بهبود دقت تشخیص نفوذ در شبکه به کمک یادگیری عمیق با الگوریتم بهینه ADAM و تابع فعالساز LEAKY RELU

نگارش

مریم مهدوی

استاد راهنما

آقای دکتر سید رضا کامل طبخ فریضنی

استاد مشاور

شهریور ۱۴۰۱

(برگه اصالت یا مالکیت پایان نامه)

اینجانب مریم مهدوی دانش آموخته کارشناسی ارشد مهندسی کامپیوتر دانشکده کامپیوتر موسسه آموزش عالی سلمان پدیدآور پایان نامه با عنوان بهبود دقت تشخیص نفوذ به کمک یادگیری عمیق با الگوریتم بهینه ADAM و تابع فعالساز LEAKY RELU با راهنمایی جناب آقای دکتر سید رضا کامل طبخ فریضنی گواهی و تعهد می‌دهم که بر پایه قوانین و مقررات، از جمله بررسی تخلفات پژوهشی و همچنین مصادیق تخلفات پژوهشی، مصوب وزارت علوم تحقیقات و فناوری در تاریخ ۲۵ اسفند ۹۳:

- پایان نامه دستاورد پژوهش اینجانب و محتوای آن از درستی و اصالت برخوردار است.
- حقوق معنوی همه کسانی که در بدست آمدن نتایج اصلی پایان نامه تاثیرگذار بوده‌اند، رعایت کرده‌ام و هنگام کاربرد دستاورد پژوهش‌های دیگران در آن، با دقت و درستی به آن استناد کرده‌ام.
- این پایان نامه و محتوای آن را تاکنون اینجانب یا کس دیگری برای دریافت هیچگونه مدرک یا امتیازی در هیچ جا ارائه نکرده‌ام.
- همه حقوق معنوی این پایان نامه از آن موسسه آموزش و عالی سلمان است و آثار برگرفته از آن با وابستگی سازمانی موسسه سلمان منتشر خواهد شد.
- در همه گام‌های انجام این پایان نامه هرگاه به اطلاعات شخصی افراد یا اطلاعات سازمان‌ها دسترسی داشته یا آنها را به کار برده‌ام، رازداری و اخلاق پژوهش را رعایت کرده‌ام.

تاریخ امضا

حقوق موسسه آموزش عالی سلمان ۱۳۹۶

این گزارش و همه حقوق مادی و محصولات آن (مقاله‌ها، کتاب‌ها، پروانه‌های اختراع، برنامه‌های رایانه‌ای، نرم‌افزارها تجهیزات ساخته شده و مانند آن‌ها) بر پایه قانون حمایت حقوق مولفان و مصنفان و هنرمندان مصوب سال ۱۳۴۸ و اصلاحیه‌های بعدی آن و همچنین آیین‌نامه‌های اجرای این قانون از آن موسسه آموزش و عالی سلمان است. هرگونه استفاده از همه یا پاره‌ای از آن شامل نقل قول‌ها، تکثیر، انتشار، کاربرد نتایج تکمیل و مانند آن‌ها به صورت چاپی الکترونیکی یا وسایل دیگر، تنها با اجازه نوشتاری موسسه آموزش و عالی سلمان شدنی است. نقل قول محدود در انتشارات علمی مانند کتاب و مقاله یا پایان نامه‌های دیگر با نوشتن اطلاعات کاملی کتاب شناختی، نیازی به مجوز موسسه آموزش عالی سلمان ندارد.

برگه تایید هیئت داوران / صورت جلسه دفاع

تقدیم

این پایان نامه را با نهایت سپاس و تشکر پیشکش می‌کنم

به بارگاه مقدس امام هشتم امام رضا (ع) که همواره از برکات وجود ایشان بی‌نیصیب مانده‌ام.

و تقدیم میکنم

به دریای بی‌کران فداکاری و پستیانی

مهرم

و تقدیم می‌کنم

به وجود پرصلابت که همواره راحما و حامی من بوده‌اند

پدرم

و تقدیم می‌کنم

به مهربان‌تر از جانم که همیشه مهربانی و دعای خالصانه‌اش شامل حال من شده است

مادرم

و تقدیم می‌کنم

به زیباترین هدیه زندگیم، عطر خوش محبت و فرشته‌ی رویایی من که از بدو شروع این راه در وجود من ریشه زد و همراه، دگر می‌من بود

دخترم

مشکر و قدردانی

حال که به لطف و عنایت حق تعالی مراحل این پایان نامه رو به اتمام نهاده بر خود لازم می دانم از همه کسانی که در پیشبرد اهدای من را یاری نموده اند
پاسنژاری و قدردانی کنم

از استاد راهنمای گرانقدرم جناب آقای دکتر سید رضا کامل که وجودشان قوت قلبم بوده و همواره از دانش و راهنمایی ها و حمایت های در ایشان نهایت تشکر
را دارم

و از سرکار خانم دکتر توونیان که همواره مساعدت های لازم را باینده داشته اند

و از جناب آقای مهندس الیاس یاری و جناب آقای مهندس سید علی کلامی نهایت تشکر بابت تجربیاتشان که بی منت در اختیار اینجانب قرار دادند
و از کتابخانه آستان قدس رضوی مشهد و دانشکده آزاد اسلامی واحد مشهد که امکانات لازم را در اختیار اینجانب قرار دادند.

چکیده

یکی از مسائل مهم با توجه به استفاده گسترده از شبکه‌های کامپیوتری، حملات سایبری و بحث امنیت در این شبکه‌ها و پایگاه داده‌ها است. نفوذ به شبکه‌های کامپیوتری با انگیزه‌های مختلف از جمله سیاسی، نظامی، مالی و یا نشان دادن سستی و ضعف امنیتی در برنامه‌های موجود می‌باشد. از اینرو، تکنیک‌های متداول با توجه به ویژگی‌های مخرب جدید که به طور تصاعدی در حال افزایش می‌باشد بی‌اثر شده و روش‌های سنتی قادر به حفظ امنیت نمی‌باشد. در نتیجه سیستم‌های تشخیص نفوذ عهده دار شناسایی تهدیدات و حملات از سوی هر دو دسته کاربران داخلی و خارجی و ابزاری جهت تامین امنیت در سیستم‌های اطلاعاتی می‌باشند که هدف اصلی آنها جلوگیری از حمله نیست، بلکه شناسایی حملات و یادگیری الگوی رفتاری آنها از وظایف این سیستم می‌باشد. یکی از موضوعات پرچالش در این سیستم‌ها "دقت" می‌باشد که توجه محققان را در این زمینه جلب کرده است و با بهبود هرچه بیشتر "دقت" در این سیستم‌ها کارایی نیز افزایش می‌یابد.

جهت بهبود "دقت" سیستم‌های تشخیص نفوذ روش‌های متعددی ارائه شده است اما همچنان این زمینه نیاز به پژوهش و مطالعه می‌باشد. در این پایان‌نامه روشی جهت حل مسأله "دقت" از طریق کاهش ابعاد مجموعه داده NSL-KDD با تحلیل مولفه‌های اساسی (PCA) که به طور موثری در بهبود سرعت پردازش داده تاثیر می‌گذارد و استفاده از شبکه‌های پرسپترون چندلایه که یکی از روش‌های یادگیری عمیق (DL) می‌باشد با افزایش تعداد لایه‌های پنهان، از یک لایه [۱] به دو لایه پنهان که معماری این پرسپترون چهار لایه (MLP) شامل یک لایه ورودی و دو لایه پنهان و یک لایه خروجی می‌باشد سبب یادگیری کارآمدتر در این شبکه‌ها می‌شود و با الگوریتم بهینه ADAM و انتخاب تابع فعالساز LEAKY RELU در این شبکه سعی در بهبود دقت تشخیص نفوذ داریم. روش ارائه شده در شبیه‌ساز Python اجرا شده است و با آخرین کارهای انجام شده مقایسه شده است. روش پیشنهادی نشان می‌دهد دقت برای شناسایی ۵ کلاس در مجموعه داده NSL-KDD به ۹۳ درصد افزایش یافته است که کارایی بیشتر روش پیشنهادی را در مقایسه با کار انجام شده نشان می‌دهد.

کلیدواژه: سیستم تشخیص نفوذ (IDS)، یادگیری عمیق (DL) پرسپترون چندلایه (MLP)، الگوریتم ADAM، تحلیل مولفه‌های

اساسی (PCA)، مجموعه داده NSL-KDD، دقت

۱۵.....	۱. کلیات تحقیق.....
۱۵.....	۱-۱ مقدمه.....
۱۶.....	۲-۱ مسأله پژوهش.....
۱۶.....	۳-۱ اهمیت و هدف و جنبه های نوآوری پژوهش.....
۱۷.....	۴-۱ فرضیه های پژوهش.....
۱۷.....	۵-۱ دامنه تحقیق.....
۱۹.....	۵-۱ مختصری بر روش تحقیق.....
۱۹.....	۶-۱ ساختار پایان نامه.....
۱۹.....	۲. پیشینه تحقیق و مروری بر کارهای انجام شده.....
۲۰.....	۱-۲ مقدمه.....
۲۰.....	۲-۲ مروری بر سیستم تشخیص نفوذ.....
۲۱.....	۱-۲-۲ تشخیص نفوذ.....
۲۱.....	۲-۲-۲ معماری سیستم های تشخیص نفوذ.....
۲۱.....	۱-۲-۲-۲ سیستم های تشخیص نفوذ مبتنی بر میزبان (HIDS).....
۲۲.....	۲-۲-۲-۲ سیستم های تشخیص نفوذ مبتنی بر شبکه (NIDS).....
۲۲.....	۳-۲-۲-۲ سیستم های تشخیص نفوذ توزیع شده (DIDS).....
۲۲.....	۳-۲-۲ روش های تشخیص نفوذ.....
۲۲.....	۱-۳-۲-۲ روش تشخیص نفوذ مبتنی بر سوءاستفاده.....
۲۳.....	۲-۳-۲-۲ روش تشخیص نفوذ مبتنی بر ناهنجاری.....
۲۳.....	۳-۲ مروری بر روش های و اصطلاحات رایج شبکه های عصبی جهت تشخیص نفوذ.....
۲۴.....	۱-۳-۲ هوش مصنوعی.....
۲۴.....	۲-۳-۲ یادگیری ماشین.....
۲۴.....	۳-۳-۲ یادگیری عمیق.....
۲۵.....	۴-۳-۲ شبکه های مصنوعی.....
۲۵.....	۱-۴-۳-۲ مقدمات شبکه های عصبی.....
۲۵.....	۲-۴-۳-۲ نرون.....
۲۶.....	۳-۴-۳-۲ وزن.....
۲۶.....	۴-۴-۳-۲ بایاس.....

۲۶.....	۵-۴-۳-۲ توابع فعالساز.....
۲۷.....	۶-۴-۳-۲ لایه‌های ورودی و خروجی و مخفی.....
۲۷.....	۷-۴-۳-۲ مدل‌های شبکه عصبی.....
۲۷.....	۸-۴-۳-۲ شبکه‌های پروسپترون چندلایه.....
۲۷.....	۹-۴-۳-۲ روش یادگیری.....
۲۸.....	۱-۹-۴-۳-۲ یادگیری کاهشی گرادیان.....
۲۸.....	۱۰-۴-۳-۲ انتشار رو به جلو.....
۲۸.....	۱۱-۴-۳-۲ انتشار به عقب.....
۲۸.....	۱۲-۴-۳-۲ تابع هزینه.....
۲۹.....	۱۳-۴-۳-۲ معیار عملکرد.....
۲۹.....	۱۴-۴-۳-۲ بهینه‌سازی وزن‌ها.....
۲۹.....	۱۵-۴-۳-۲ نرخ یادگیری.....
۲۹.....	۱۶-۴-۳-۲ بسته‌ها.....
۲۹.....	۱۷-۴-۳-۲ دوره‌ها.....
۲۹.....	۵-۳-۲ چالش‌های آموزش در شبکه‌های عمیق.....
۳۰.....	۱-۵-۳-۲ محو گرادیان و انفجار گرادیان.....
۳۰.....	۲-۵-۳-۲ شناسایی محو گرادیان و انفجار گرادیان.....
۳۰.....	۶-۲-۳ تفاوت پارامترها و ابرپارامترها.....
۳۱.....	۴-۲ کاهش ویژگی.....
۳۱.....	۵-۲ مروری بر کارهای انجام شده.....
۳۶.....	۶-۲ جمع‌بندی.....
۳۷.....	۳. روش پیشنهادی.....
۳۷.....	۱-۳ مقدمه.....
۳۷.....	۲-۳ الگوریتم روش پیشنهادی.....
۳۸.....	۳-۳ جزئیات روش پیشنهادی.....
۴۰.....	۱-۳-۳ گام اول.....
۴۰.....	۲-۳-۳ گام دوم.....
۴۴.....	۳-۳-۳ گام سوم.....
۴۴.....	۴-۳ جمع‌بندی.....
۴۶.....	۴. روش تحلیل و ارزیابی.....

۴-۱	مقدمه	۴۶
۴-۲	روش ارزیابی	۴۶
۴-۳	تحلیل ارزیابی	۴۹
۴-۳-۱	خطا (Loos)	۴۹
۴-۳-۲	صحت (Accuracy):	۵۰
۴-۳-۳	یادآوری (Recall)	۵۱
۴-۳-۴	دقت (Precisions)	۵۲
۴-۳-۶	گزارش طبقه‌بندی	۵۳
۴-۴	مقایسه دقت	۵۵
۴-۴	نتیجه‌گیری	۵۵
۵	نتیجه‌گیری و پیشنهاد کار آینده	۵۶
۵-۱	نتیجه‌گیری و جمع‌بندی	۵۶
۵-۲	پیشنهاد کار آینده	۵۶
۶	منابع	۵۷

IDS(Intrusion Detection System)
MLP(Multi Layer Perceptron)
FSL(Few Shot Learning)
RNN(Recurrent Neural Network)
RF(Random Forest)
NB(Naive Bayes)
AE(Auto Encoder)
SCM(Support Vector Machine)
ML (Machine Learning)
DL(Deep Learning)
CART(Classification And Regression Tree)
GDM/AG(Gradient Descent Momentum /Adaptive Gain)
GDM(Gradient Descent with Momentum)
HIDS(Host intrusion detection systems)
NIDS(Network intrusion detection systems)
DIDS(Distributed intrusion detection systems)

جدول ۲-۱. مقایسه الگوریتم های مرور شده.....	۳۶
جدول ۴-۱. توزیع انواع حملات در مجموعه داده NSL-KDD [۳۳].....	۴۶
جدول ۴-۲. تنظیم ابر پارامترها در شبکه mlp.....	۴۹
جدول ۴-۳. گزارش طبقه بندی برای مجموعه داده آموزش.....	۵۴
جدول ۴-۴. گزارش طبقه بندی برای مجموعه داده اعتبارسنجی.....	۵۴
جدول ۴-۵. گزارش طبقه بندی برای مجموعه داده آزمایش.....	۵۴
جدول ۴-۶. مقایسه دقت الگوریتم pca-dl و الگوریتم پیشنهادی.....	۵۵

فهرست شکل

- شکل ۱-۱. سیستم تشخیص نفوذ..... ۱۵
- شکل ۱-۲. دامنه تحقیق ۱۸
- شکل ۱-۳. ساختار کلی پایان نامه ۱۹
- شکل ۲-۱. ارتباط بین هوش مصنوعی و یادگیری ماشین و یادگیری عمیق و شبکه‌های عصبی و شبکه‌های پروسپترون چندلایه mlp..... ۲۴
- شکل ۲-۲. نمایی از یک شبکه عصبی واقعی [۱۴]..... ۲۵
- شکل ۲-۳. معماری یک شبکه پروسپترون تمام متصل [۱۴]..... ۲۷
- شکل ۳-۱. نمای کلی الگوریتم پیشنهادی ۳۸
- شکل ۳-۲. فلوجارت الگوریتم پیشنهادی ۳۹
- شکل ۳-۳. تابع فعالساز یکسوساز خطی رخنه دار [۱۴] ۴۲
- شکل ۴-۱. نمونه رکورد از مجموعه داده NSL-KDD [۳۴]..... ۴۷
- شکل ۴-۲. نمودار همبستگی بین ویژگی‌های مجموعه داده..... ۴۷

فهرست نمودار

۵۰.....	نمودار ۴-۱. خطا در طول آموزش مدل
۵۱.....	نمودار ۴-۲. صحت در طول آموزش مدل
۵۲.....	نمودار ۴-۳. معیار یادآوری در طول آموزش مدل
۵۳.....	نمودار ۴-۴. نمودار دقت در طول آموزش مدل

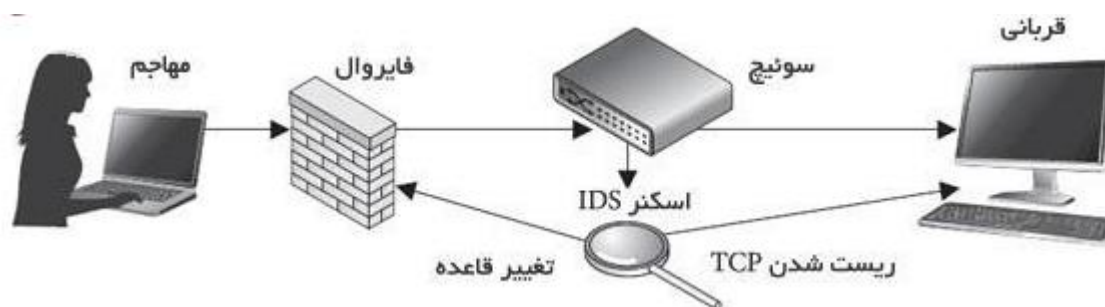
۱. کلیات تحقیق

۱-۱ مقدمه

حفظ امنیت اطلاعاتی و حفظ کارایی در شبکه‌های کامپیوتری، یکی از ضروری‌ترین مسائل در سیستم‌های مخابراتی و شبکه‌های کامپیوتری می‌باشد [۲] از گذشته روش‌هایی مانند احراز هویت کاربر، رمزگذاری داده‌ها، دیواره آتش و غیره جهت برقراری امنیت در شبکه‌های کامپیوتری مورد استفاده بوده است. سیستم‌های تشخیص نفوذ به عنوان یکی از عناصر اصلی زیرساخت‌های امنیت در بسیاری از سازمان‌ها می‌باشد. این سیستم‌ها با استفاده از روش‌های تحلیلی به کشف حملات می‌پردازند و منابع حمله را شناسایی می‌کنند و هشدارهای لازم را برای مدیران شبکه ارسال می‌کنند [۳].

از آنجا که طراحی سیستم‌های کامپیوتری به شکل ایده‌آل امکان‌پذیر نیست، باید تکنیک‌های حفظ اطلاعات در شبکه به کار گرفته شود. در این راستا تشخیص نفوذ در سیستم‌های کامپیوتری دارای اهمیت ویژه‌ای است [۲].

نفوذ مجموعه اقدامات غیر قانونی است که صحت و محرمانگی به یک منبع را به خطر می‌اندازد. تشخیص نفوذ عبارت است از فرآیند شناسایی و پاسخ به فعالیت‌های مخرب که به شکل هدفمند منابع شبکه را مورد حمله قرار می‌دهد از این رو وجود سیستم‌های تشخیص نفوذ کارآمد برای تامین امنیت شبکه از اهمیت بسیار زیادی برخوردار است. نفوذ می‌تواند به دو دسته داخلی و خارجی تقسیم شود. نفوذهای خارجی به آن دسته نفوذهایی گفته می‌شود که توسط افراد مجاز و یا غیرمجاز از خارج از شبکه به درون شبکه داخلی صورت می‌گیرد و نفوذهای داخلی توسط افراد مجاز در سیستم شبکه داخلی از درون خود شبکه انجام می‌پذیرد [۲]. یکی از مزایای این سیستم‌ها توانایی مستند کردن نفوذ یا تهدید تشخیص داده شده است در نتیجه جدیدترین الگوهای حمله برای عموم قابل شناسایی و پیشگیری خواهد بود. در واقع هدف سیستم‌های تشخیص نفوذ جلوگیری از حمله نمی‌باشد بلکه هدف کشف و شناسایی حملات و تشخیص اشکالات امنیتی در شبکه‌های کامپیوتری و اعلام آن به مدیر سیستم است [۳].



شکل ۱-۱. سیستم تشخیص نفوذ

در سیستم‌های تشخیص نفوذ معیار دقت که مربوط به شناسایی الگوی رفتارهای نرمال و حمله است یکی از چالش‌های حیاتی مطرح در این حوزه می‌باشد روش‌های بسیار زیادی از جمله روش‌های یادگیری عمیق، روش‌های ترکیبی برای بهبود این معیار ارائه شده است.

۲-۱ مسأله پژوهش

نفوذ در شبکه‌های کامپیوتری با هدف‌های متفاوتی از جمله سیاسی، مالی، نظامی و یا نمایان کردن سستی‌های امنیتی موجود در برنامه‌های کاربردی صورت می‌گیرد. مقصود اصلی سیستم‌های تشخیص نفوذ پیشگیری از حمله نمی‌باشد بلکه شناسایی و کشف حملات و تشخیص مشکلات امنیتی است.

داده‌کاوی و یادگیری ماشین از راه‌های حیاتی یافتن علم سودمند اطلاعات در داده‌ها می‌باشد که در تحلیل انواع ترافیک شبکه کاربرد دارد چندین الگوریتم داده‌کاوی مانند منطق فازی، شبکه‌های عصبی، دستگاه بردار پشتیبان، k نزدیکترین همسایه و غیره در زمینه تشخیص نفوذ شبکه‌های کامپیوتری به کار رفته است [۴].

مهم‌ترین مسأله و چالشی که در این روش‌ها وجود دارد جداسازی فعالیت‌های نرمال از حملات است که باتوجه به روش‌های ارائه شده دارای نرخ هشدار کاذب و دقت متفاوتی بوده‌اند، کارهای زیادی در زمینه افزایش دقت شناسایی حملات صورت گرفته است [۵][۱][۶][۷][۸][۹][۱۰] از آخرین کارهای انجام شده در این زمینه [۱][۱۱][۱۲][۸][۱۳] بوده‌اند که از روش‌های یادگیری عمیق استفاده کرده‌اند.

در مقاله [۱] برای بهبودی دقت تشخیص نفوذ از روش پروپسترون چندلایه (MLP) که یکی از روش‌های یادگیری عمیق است به کار برده است و در لایه اول و دوم از تابع فعالساز [۱] RELU استفاده می‌کنند که مشکل مرگ RELU دارد یعنی وقتی ورودی‌ها به صفر نزدیک می‌شوند یا صفر هستند گرادیان تابع صفر می‌شود بنابراین برای حل این مشکل در این پژوهش پیشنهاد شده است که از تابع فعالساز [۱۴] LEAKY RELU که با معرفی یک پارامتر α که اجازه می‌دهد گرادیان‌های کوچک در صورت عدم فعالسازی، فعال شوند و مزایای استفاده از این تابع از لحاظ محاسباتی سریع‌تر است و همینطور استفاده از الگوریتم بهینه [۱۴] ADAM به جای استفاده از الگوریتم گرادیان کاهشی [۱] که مهم‌ترین نقطه ضعف این الگوریتم انتخاب درست نرخ یادگیری است که کار آسانی نیست را با الگوریتم [۱۴] ADAM که دارای نرخ یادگیری تطبیقی است شبکه را سریع‌تر همگرا کرد و با اضافه کردن یک لایه پنهان به شبکه، تعداد لایه-ها از ۳ لایه به ۴ لایه تغییر پیدا می‌کند که معماری شبکه شامل یک لایه ورودی، دو لایه پنهان و یک لایه خروجی می‌باشد که با عمیق شدن شبکه باعث کارآمدتر شدن شبکه می‌شود.

باتوجه به ماهیت الگوریتم بهینه‌ساز [۱۴] ADAM که سرعت همگرایی زیادی دارد و مشکل کاهش نرخ یادگیری را حل می‌کند و ماهیت تابع فعالساز [۱۴] LEAKY RELU که مشکل مرگ نرون‌ها را از بین می‌برد و افزایش تعداد لایه‌های مخفی شبکه، پیش‌بینی می‌کنیم که مدل پیشنهادی دقت بیشتری نسبت به آخرین کار انجام شده [۱] داشته باشد.

۳-۱ اهمیت و هدف و جنبه‌های نوآوری پژوهش

به طور کلی اهمیت اصلی پژوهش به منظور بهبود دقت تشخیص نفوذ در شبکه‌های کامپیوتری می‌باشد که نوآوری این پژوهش برای حل این مسأله استفاده از یادگیری عمیق می‌باشد با توجه به اینکه حملات و روش‌های نفوذ از سوی هکرها هرروزه در حال پیشرفت و گسترش می‌باشد. فعالیت در این حوزه نیز باتوجه به اهمیت بالا اطلاعات در حوزه‌های نظیر نظامی، پزشکی، سیاسی و بانکداری و امور مالی نیازمند شناسایی و روش‌های مقابله با آن بسیار هائز اهمیت است. برای بهبود

چالش دقت در این شبکه‌ها طراحی شبکه پرسپترون را با چهار لایه که شامل یک لایه ورودی و دو لایه پنهان و یک لایه خروجی انجام شده است تا یادگیری را کارآمدتر کند و از الگوریتم [۱۴] ADAM برای به روزرسانی وزن‌ها و رسیدن به تابع هدف و استفاده از تابع فعال ساز [۱۴] LEAKY RELU که مشکل مرگ نرون‌ها را رفع می‌کند استفاده کرده است تا به هدف پرچالش این حوزه بهبود دقت سیستم تشخیص نفوذ کمی شود. در نهایت با افزایش دقت به ۹۳ درصد کارایی مدل پیشنهادی در مقابل سایر روش‌ها به اثبات می‌رسد.

۱-۴ فرضیه‌های پژوهش

پیش‌بینی می‌کنیم که با افزایش دادن لایه‌های مخفی از یک لایه به دو لایه و استفاده از الگوریتم [۱۴] ADAM جهت یادگیری خودکار نرخ یادگیری که سبب افزایش سرعت همگرایی می‌شود و استفاده از تابع [۱۴] LEAKY RELU در نرون‌های لایه ورودی و مخفی که از مرگ نرون‌ها جلوگیری می‌کند در طراحی شبکه‌های پرسپترون چند لایه و شاهد بهبود معیار دقت در این شبکه‌ها باشیم.

۱-۵ دامنه تحقیق

دامنه تحقیق در شکل ۱-۲ نمایش داده شده است. همانطور که در شکل ۱-۲ دیده می‌شود تحقیقات در سیستم‌های تشخیص نفوذ از پنج دیدگاه یک مبتنی بر منبع اطلاعات (Information Source)، دوم معماری سیستم (Architecture)، سوم واکنش به نفوذ (Architecture)، چهارم روش تشخیص (Detection Methodology) و پنجم جنبه زمانی (Time Aspect) قابل بررسی می‌باشد.

از دیدگاه نوع روش تشخیص شامل دو تکنیک است که یکی مبتنی بر تطابق الگو یا سوءاستفاده در این روش از الگوهای حملات شناخته شده، برای شناسایی و تشخیص نفوذ استفاده می‌کند. در این روش الگوهای نفوذ از پیش ایجاد شده و به صورت قانون نگهداری می‌شوند و روش دوم ناهنجاری آماری که این روش رفتار کاربر را با رفتار نرمالی که در پایگاه داده ذخیره شده است، مقایسه می‌کند و از آن برای تشخیص حملات شناخته شده استفاده می‌کند و با استفاده از روش آماری سعی در پیدا کردن فعالیت‌هایی دارد که با الگوی رفتار نرمال تطابق ندارند و ناهنجار و غیر نرمال به نظر می‌رسند. برای تشخیص نفوذ معمولاً از الگوریتم‌های داده‌کاوی جهت تشخیص حمله استفاده می‌شود. الگوریتم‌های مربوطه نیز به دو گروه نظارت شده و نظارت نشده طبقه‌بندی می‌شوند. در سیستم‌های تشخیص نفوذ معمولاً از روش یادگیری ماشین به شکل طبقه‌بندی یا خوشه‌بندی استفاده می‌شود، که پیش‌بینی برای داده‌های آینده بر اساس داده‌های گذشته است این روش در مجموعه یادگیری نظارت شده جای دارد. میتوان از الگوریتم‌های معروف در این خصوص ماشین بردار پشتیبان (SVM)^۱ درخت تصمیم (DT)^۲، شبکه‌های بیزین (BN)^۳، شبکه‌های عصبی مصنوعی (NN)^۴ را نام برد [۱۵] از جمله پرکاربردترین

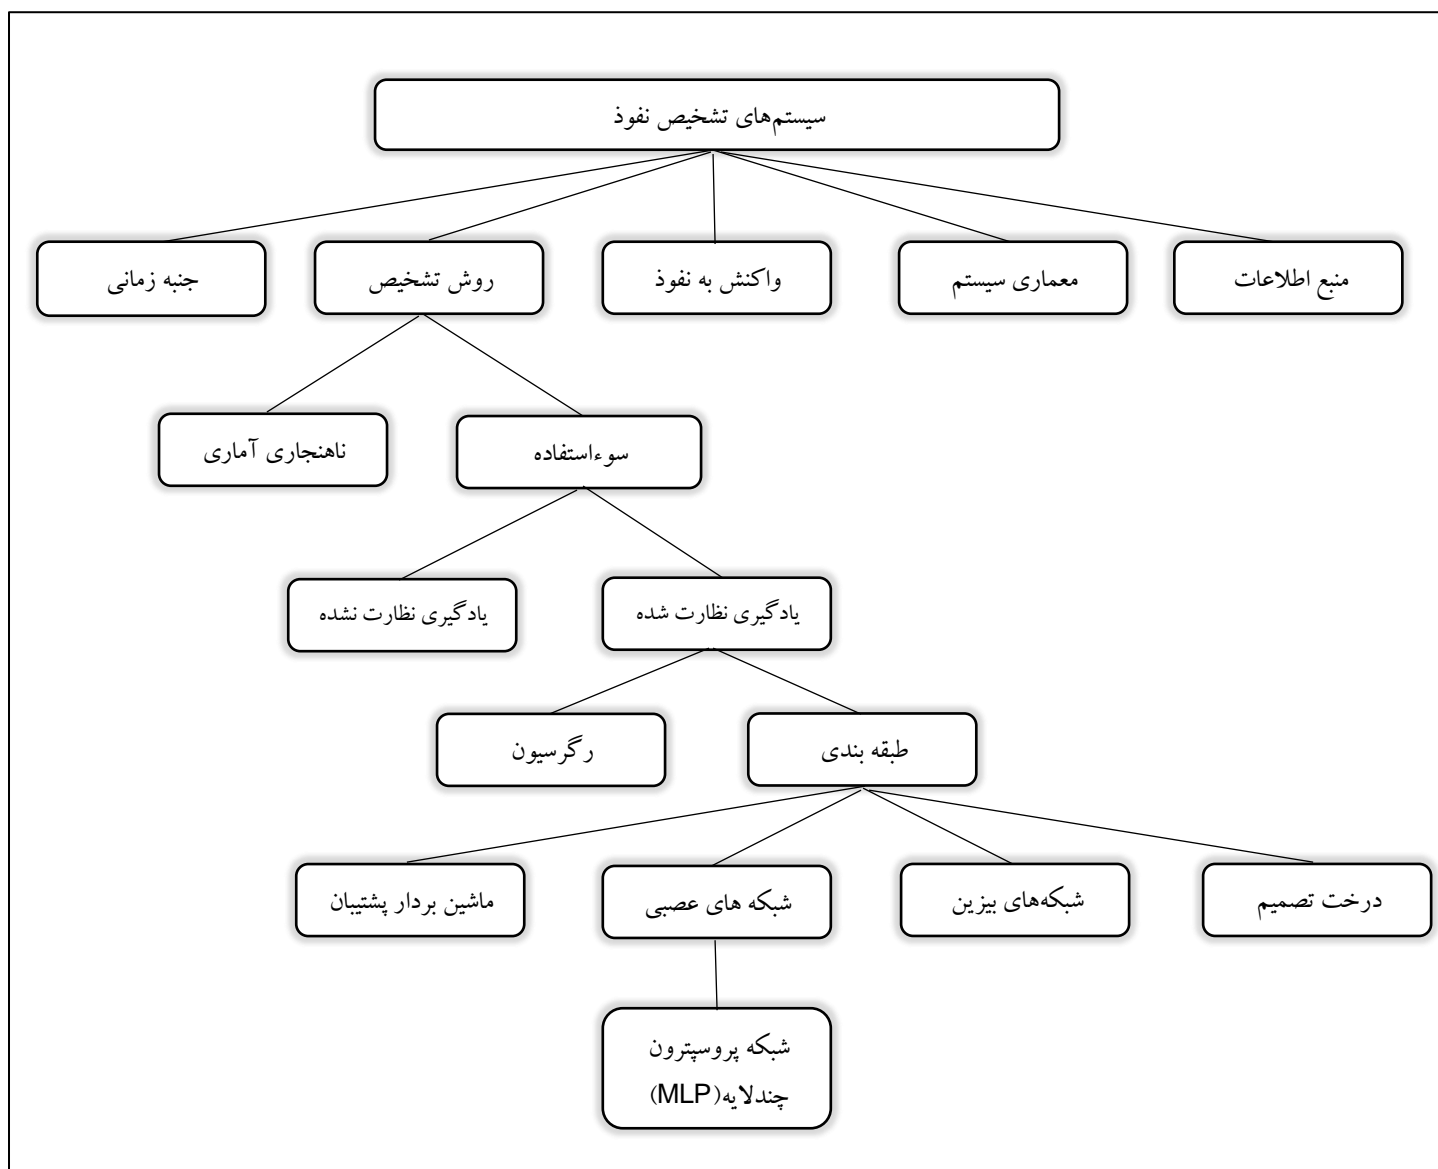
¹ Support vector machine

² Decision Trees

³ Bayesian Networks

⁴ Neural Networks

الگوریتم‌های شبکه‌های عصبی می‌توان به الگوریتم شبکه‌های پرسپترون چند لایه (MLP^۱)، شبکه‌های عصبی بازگشتی (RNN^۲)، شبکه‌های خود رمزگذار (AE^۳) و غیره می‌توان نام برد. در این تحقیق ما در زیر شاخه شبکه‌های پرسپترون چند لایه تلاش می‌کنیم تا با الگوریتم [۱۴] ADAM بتوانیم دقت را در سیستم‌های تشخیص نفوذ [۱] بهبود دهیم.



شکل ۱-۲. دامنه تحقیق

¹ Multi Layer Perceptron

² Recurrent Neural Network

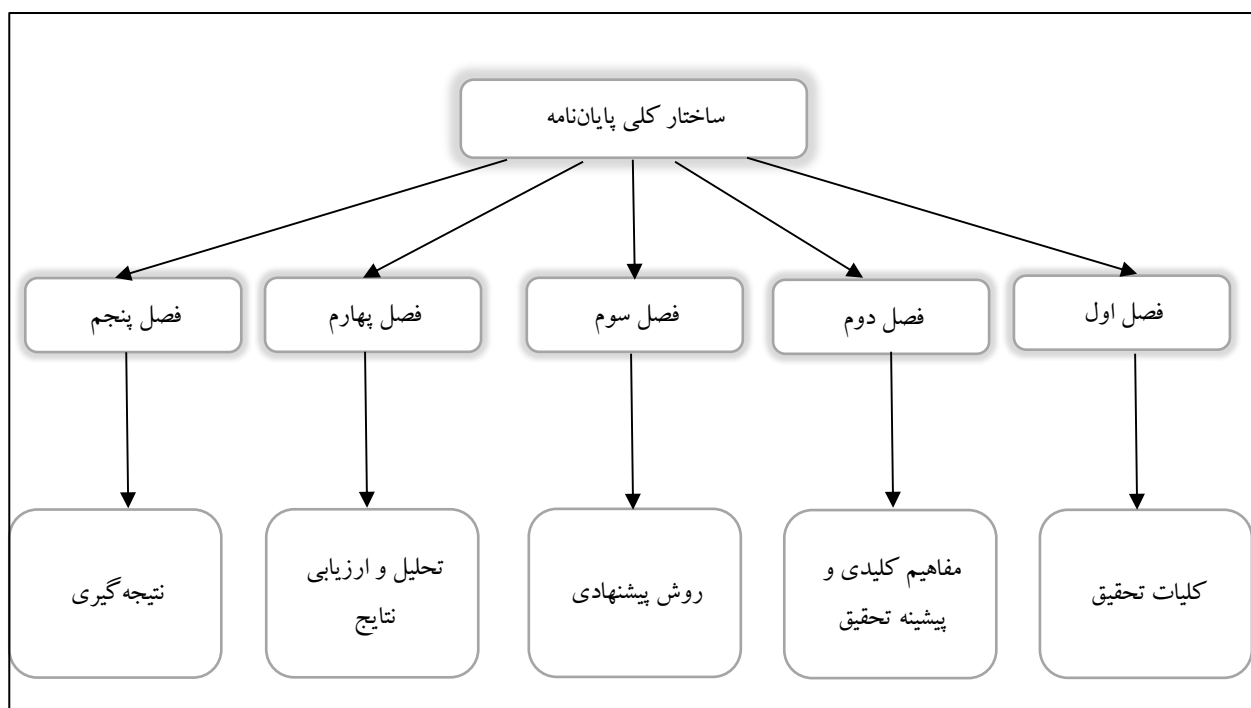
³ Auto Encoder

۵-۱ مختصری بر روش تحقیق

در ابتدا مجموعه داده NSL-KDD را با روش تحلیل مولفه‌های اساسی (PCA) که یکی از روش‌های کاهش ویژگی به روش استخراج ویژگی می‌باشد، کاهش ابعاد می‌دهیم و در مرحله بعدی مجموعه داده را به شبکه پرسپترون ۴ لایه که با الگوریتم [۱۴] ADAM جهت به روزسانی وزن‌ها و استفاده از تابع فعالساز [۱۴] LEAKY RELU در لایه اول، دوم و سوم طراحی کرده‌ایم تزریق می‌کنیم و در نهایت با مقایسه مقدار بدست آمده با تابع هدف از طریق تابع ضرر دقت را محاسبه می‌کنیم و نسبت به کار پایه [۱] ارزیابی می‌کنیم

۶-۱ ساختار پایان نامه

در شکل ۱-۳ یک ساختار کلی از پایان‌نامه را نمایش داده‌ایم در بخش اول از فصل دوم سعی در آشنایی خوانندگان با سیستم‌های تشخیص نفوذ و مقدمه ای بر یادگیری عمیق و مفاهیم کلیدی این شبکه با یک معرفی کلی و اجمالی پرداخته شده است و در بخش دوم از این فصل به کارهای انجام شده در این زمینه می‌پردازیم و در فصل سوم به ارائه استراتژی پیشنهادی پرداخته خواهد شد و نوآوری پژوهش در این بخش مطرح می‌شود و در فصل چهارم از این پایان‌نامه به انجام آزمایش در راستای این استراتژی پیشنهادی و بررسی نتایج حاصل از آن مورد بررسی قرار خواهد گرفت و در فصل پایانی جمع‌بندی نهایی ذکر خواهد شد.



شکل ۱-۳. ساختار کلی پایان نامه

۲. پیشینه تحقیق و مروری بر کارهای انجام شده

۲-۱ مقدمه

با افزایش روز افزون شبکه‌های کامپیوتری و ایجاد مشکلات امنیتی، روش‌های جهت تشخیص، جلوگیری و مقابله با حملات ارائه شده است که در بحث تشخیص با عنوان سیستم‌های تشخیص نفوذ جهت شناسایی تهدیدات عنوان می‌شود. که یا توجه به تغییر کردن نوع حملات در شبکه‌ها و پایگاه داده‌ها این حوزه نیازمند به روزرسانی هرروزه در جهت بهبود عملکرد خود می‌باشد. یکی از مسائل مهم در این حوزه بهبود دقت تشخیص این سیستم‌ها می‌باشد از این رو تحقیقات زیادی در صورت گرفته است. در ادامه این فصل در ابتدا به اصطلاحات رایج در زمینه شبکه‌های عصبی می‌باشد می‌پردازیم و در بخش بعدی به کارهای انجام شده توسط محققان در این زمینه که به اختصار توضیح داده خواهد شد. و در انتها یک جمع‌بندی از این فصل را خواهیم داشت.

۲-۲ مروری بر سیستم تشخیص نفوذ

از یک سو افزایش روز افزون حملات به شبکه‌های کامپیوتری و از سوی دیگر وابستگی شدید فعالیت‌های حوزه‌های مختلف صنعتی و بازرگانی و نظامی و پزشکی و آموزشی و غیره به سرویس‌های که توسط شبکه‌های کامپیوتری ارائه می‌شود تلاش برای جلوگیری و نفوذ به این شبکه‌ها امری حیاتی و ضروری می‌باشد. تشخیص نفوذ به این معنا می‌باشد که فرایند شناسایی و پاسخ به فعالیت‌های مخرب که به صورت هدفمند حمله می‌کنند وجود سیستم تشخیص نفوذ کارآمد بسیار در بحث امنیت مهم تلقی می‌شود. راه‌های نفوذ به هر شبکه تا حد زیادی به تشخیص و شناسایی نقاط ضعف آن شبکه بستگی دارد. نوع طراحی و اشکالات نرم‌افزاری داخل شبکه موجب نفوذ به آن شود و امنیت شبکه را تهدید کند. در سیستم‌های تشخیص نفوذ، تشخیص رفتارهای غیرعادی با جمع‌آوری مقدار کافی از داده‌ها، تجزیه و تحلیل شبکه‌ها قابل بررسی می‌باشد. سیستم‌های تشخیص نفوذ سبب شناسایی و مستند سازی تهدیدات موجود شده و مانع از شکل‌گیری کامل یک حمله می‌شود و می‌تواند با هشدار از حملات مشابه جلوگیری کند.

به‌طور کلی هدف سیستم‌های تشخیص نفوذ را می‌توان به صورت زیر خلاصه کرد:

- امکان برقراری ارتباط بین یک واقعه و شخص مسئول آن واقعه
- امکان شناسایی حمله و واکنش قابل قبول برا مقابله یا توقف آن و جلوگیری از تکرار حمله
- فرایند تولید، ثبت و مرور یک سابقه از عملکرد سیستم

سه عملکرد پایه می‌توان برای سیستم‌های تشخیص نفوذ در نظر گرفت:

۱. نظارت و ارزیابی رفتار شبکه
۲. کشف و تشخیص الگوهای منطبق با حملات شناخته شده
۳. واکنش و تحلیل الگوی رفتارهای ناهنجار

بر همین اساس هر سیستم تشخیص نفوذ را می‌توان بر اساس روش‌های تشخیص نفوذ، معماری سیستم، منبع اطلاعات، واکنش به نفوذ و جنبه زمانی دسته‌بندی کرد.

۱-۲-۲ تشخیص نفوذ

نفوذ فعالیتی است که توسط آن محرمانگی، صحت یا دسترسی پذیری به منابع دچار اختلال می‌شود. تشخیص نفوذ در واقع شناسایی دستیابی‌های غیر مجاز به حملات انجام شده به شبکه است. سامانه تشخیص نفوذ وظیفه نظارت بر فعالیت سامانه، تجزیه و تحلیل بسته‌های شبکه، تعیین الگوی حملات و ارزیابی صحت و یک پارچگی فایل‌ها را بر عهده دارد. معمولاً سامانه‌های تشخیص نفوذ با یک ساختار سه سطحی توصیف می‌شوند که عبارتند از:

- واحد نظارت: که وظیفه ثبت رخدادها را بر عهده دارد. رخداد‌های سامانه توسط این واحد جهت تشخیص و تحلیل ثبت می‌شوند. همچنین نمایش هشدار به مدیر شبکه یا مسئول نظارت و پیگیری رویداد‌های شبکه بر عهده این واحد است.
- واحد تشخیص و تحلیل: اطلاعات ثبت شده توسط واحد نظارت را به عنوان ورودی دریافت می‌کند و سپس بر اساس این اطلاعات به یکی از روش‌های مبتنی بر سوءاستفاده یا مبتنی بر ناهنجاری، مدل ساخته می‌شود. حملات و تهدیدات امنیتی به کمک مدل ساخته شده تمایز داده می‌شوند.
- واحد هشدار: وظیفه دارد که متناسب با نوع حمله رفتار مناسب را انجام دهد. این واحد در صورت نیاز اخطارهای مناسب را برای ثبت یا نمایش به واحد نظارت ارسال می‌کند [۱۶]، [۱۷]

۲-۲-۲ معماری سیستم‌های تشخیص نفوذ

سیستم‌های تشخیص نفوذ بر اساس مکان قرارگیری در سیستم شبکه و دامنه فعالیت به دو گروه سیستم‌های تشخیص نفوذ مبتنی بر میزبان (HIDS)^۱ سیستم‌های تشخیص نفوذ مبتنی بر شبکه (NIDS)^۲ طبقه‌بندی می‌شوند. معمولاً برای دستیابی به حداکثر کارایی و امنیت این سیستم‌ها به صورت ترکیبی نیز مورد استفاده قرار می‌گیرند که با نام سیستم‌های تشخیص نفوذ توزیع شده (DIDS)^۳ شناخته می‌شوند [۱۸]

۱-۲-۲-۲ سیستم‌های تشخیص نفوذ مبتنی بر میزبان (HIDS)

این سیستم‌ها شناسایی و تشخیص فعالیت‌های غیر مجاز بر روی کامپیوتر میزبان را به عهده دارند. سیستم‌های تشخیص نفوذ مبتنی بر میزبان می‌توانند حملات و تهدیداتی مانند دسترسی به فایل‌ها، اسب‌های تراوا و... را روی کامپیوتر میزبان تشخیص دهند. سیستم‌های تشخیص نفوذ مبتنی بر میزبان تنها بر روی کامپیوتر میزبان و یا کامپیوترهای منفرد اجرا می‌شوند و از کل شبکه اطلاع ندارند. این نوع سیستم‌ها فقط بسته‌های ورودی و خروجی به یک کامپیوتر را بررسی و نظارت کرده و هنگام تشخیص نفوذ و یا فعالیت مشکوک به مدیر شبکه و یا کاربر کامپیوتر هشدار می‌دهد. [۱۸]

¹ Host intrusion detection systems

² Network intrusion detection systems

³ Distributed intrusion detection systems

۲-۲-۲-۲ سیستم‌های تشخیص نفوذ مبتنی بر شبکه (NIDS)

سیستم‌های NIDS به منظور شناسایی تهدیدات، به نظارت و تجزیه و تحلیل ترافیک در سراسر شبکه می‌پردازند. این سیستم‌ها فعالیت‌های مخربی مانند حملات انکار سرویس DOS اسکن پورت و غیره را در کل شبکه شناسایی می‌کنند. سیستم‌های NIDS به صورت سخت‌افزار یا نرم‌افزار برای پایش ترافیک عبوری و کامپیوترهای موجود در شبکه، در مکان یا مکان‌های خاصی از شبکه قرار داده می‌شوند، تا ترافیک شبکه را مورد تحلیل قرار داده و هنگامی که حمله یا رفتار غیرعادی تشخیص داده می‌شود یک پیغام هشدار برای مدیر شبکه ارسال نمایند. [۱۸]

۲-۲-۲-۳ سیستم‌های تشخیص نفوذ توزیع شده (DIDS)

سیستم‌های تشخیص نفوذ ترکیبی که با نام توزیع شده نیز شناخته می‌شوند از چندین سیستم تشخیص نفوذ مبتنی بر شبکه یا سیستم تشخیص نفوذ مبتنی بر میزبان یا ترکیبی از این دو نوع تشکیل شده‌اند. این سیستم‌ها از انعطاف‌پذیری بالایی برخوردار هستند و سطح امنیت را افزایش می‌دهند. [۱۸]

۲-۲-۳ روش‌های تشخیص نفوذ

به طور کلی روش‌های تشخیص نفوذ در میزبان و شبکه به دو دسته مبتنی بر سوءاستفاده یا امضاء و روش مبتنی بر ناهنجاری طبقه‌بندی می‌شود. در هر دو روش تشخیص نفوذ مبتنی بر امضاء و تشخیص نفوذ مبتنی بر ناهنجاری از روش‌ها و الگوریتم‌های داده‌کاوی به منظور تشخیص حملات استفاده می‌شود. الگوریتم‌های داده‌کاوی و یادگیری ماشین به دو گروه عمده نظارت‌شده و نظارت‌نشده طبقه‌بندی می‌شوند. در زمینه‌ی تشخیص نفوذ، یادگیری ماشین عبارت است از یک روش یادگیری کامپیوتری مبتنی بر طبقه‌بندی یا خوشه‌بندی که بر اساس داده‌های گذشته برای داده‌های آینده که به سیستم وارد می‌شود، پیش‌بینی انجام می‌دهد. در یادگیری نظارت‌شده از ابتدا دسته‌ها مشخص هستند و هر یک از داده‌های آموزشی به دسته‌های خاص نسبت داده شده است. در این نوع یادگیری مجموعه داده آموزشی در دسترس است که فرآیند یادگیری بر اساس آن انجام می‌شود. روش طبقه‌بندی از جمله روش‌های یادگیری نظارت‌شده است. برای تشخیص نفوذ در شبکه می‌توان از الگوریتم‌های طبقه‌بندی مانند شبکه‌های عصبی، نزدیکترین همسایه، بیزین، درخت‌های تصمیم و غیره جهت آموزش سیستم برای تشخیص حمله‌های از قبل شناخته شده استفاده کرد [۱۸]

۲-۲-۳-۱ روش تشخیص نفوذ مبتنی بر سوءاستفاده

این روش از الگوهای حملات شناخته شده، برای شناسایی و تشخیص نفوذ استفاده می‌کند. در این روش الگوهای نفوذ از پیش ایجاد شده و به صورت قانون نگهداری می‌شوند از این رو برای تشخیص حملاتی که الگوهای حملات آن در پایگاه داده‌ی الگوهای حمله ذخیره شده، روش مناسبی است. اشکال این روش ناتوانی در تشخیص حملات جدیدی است که الگوی آن در پایگاه داده مبتنی بر امضاء وجود ندارد و برای تشخیص این نوع حملات باید پایگاه داده با امضای حملات جدید به روزرسانی شود. از آنجاییکه در روش مبتنی بر امضاء نیاز به یادگیری از محیط وجود ندارد، پیاده‌سازی این روش ساده است.

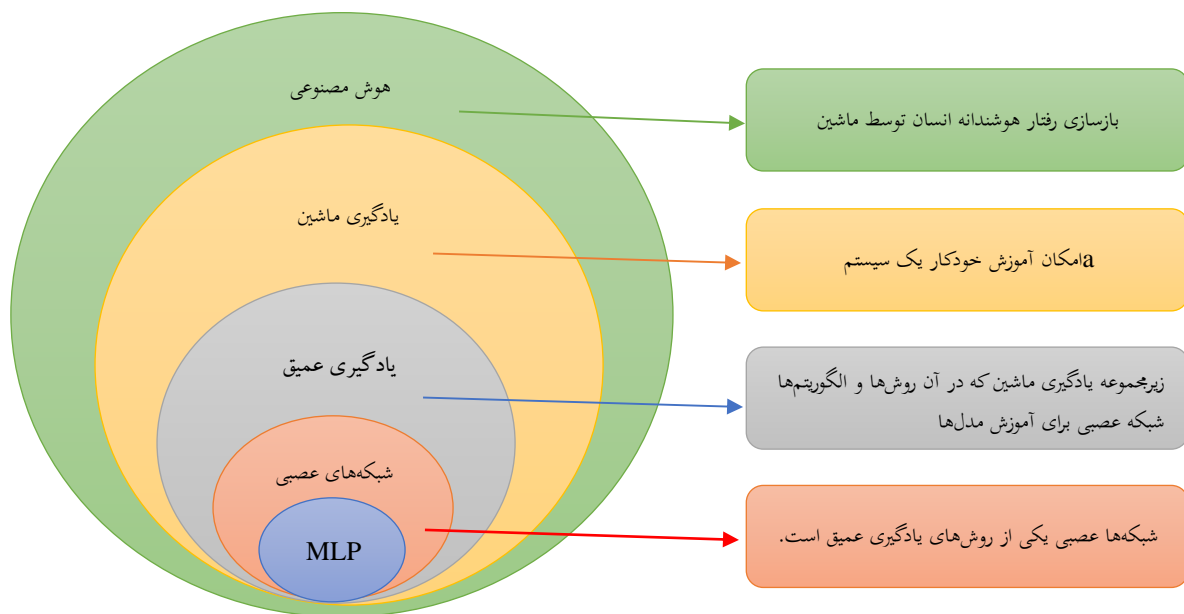
این روش بر اساس این معماری از پیش پردازش برای پیدا کردن و مقایسه الگوی فعالیت مشاهده شده در محیط شبکه با امضاءهای موجود در پایگاه داده سیستم تشخیص نفوذ استفاده می کند. اگر بین فعالیت مشاهده شده در شبکه با امضاءهای موجود در پایگاه داده تطبیقی مشاهده شود یک پیام هشدار صادر میشود. به دلیل اینکه روش تشخیص نفوذ مبتنی بر امضا حملات شناخته شده را با قابلیت اطمینان بالا و نرخ هشدار نادرست پایین شناسایی می کند. در بسیاری از سیستم های تشخیص نفوذ تجاری از این روش استفاده می شود [۱۸]

۲-۳-۲ روش تشخیص نفوذ مبتنی بر ناهنجاری

این روش رفتار کاربر را با رفتار نرمالی که در پایگاه داده ذخیره شده است، مقایسه می کند و از آن برای تشخیص حملات شناخته شده استفاده می کند و با استفاده از روش آماری سعی در پیدا کردن فعالیت هایی دارد که با الگوی رفتار نرمال تطابق ندارند و ناهنجار و غیر نرمال به نظر می رسند. در واقع برای تشخیص ناهنجاری باید الگوهای خاصی را پیدا کرد و رفتارهایی که از الگو پیروی می کنند، نرمال و رویدادهای انحرافی به عنوان ناهنجاری تشخیص داده می شوند. در این روش مسئله مهم ایجاد نما از رفتار نرمال است زیرا رفتار نرمال کاربران ممکن است تغییر کند و لذا سیستم تشخیص نفوذی که از این روش استفاده می کند باید خود را با این تغییرات بروز کند. مسئله دیگری که در ساخت مدل رفتار نرمال وجود دارد انتخاب ویژگی هایی است که به عنوان ورودی برای ساخت مدل از آن استفاده می شود. در مدل های فعلی پارامترهای ورودی توسط کارشناس امنیت تعیین می شود و تضمینی وجود ندارد که همه ویژگی هایی که در تشخیص نفوذ مؤثر هستند به درستی انتخاب شوند. چنانچه ویژگی های مهم وابسته به نفوذ به اشتباه کنار گذاشته شوند تشخیص حمله از رفتار نرمال بسیار مشکل خواهد بود. همچنین عدم حذف ویژگی هایی که مرتبط با نفوذ نیستند می تواند باعث کاهش کارایی در تشخیص نفوذ شود. نقطه قوت این روش توانایی تشخیص حملات جدید است و ضعف این روش نرخ هشدار نادرست بالای آن است [۱۸]

۲-۳-۳ مروری بر روش های و اصطلاحات رایج شبکه های عصبی جهت تشخیص نفوذ

اگرچه اصطلاح هوش مصنوعی، یادگیری ماشین و یادگیری عمیق در بیشتر اوقات به جای هم مورد استفاده قرار می گیرند و به یکدیگر مرتبط هستند، اما به طور کامل به موارد مشابهی اشاره نمی کنند. در شکل ۲-۱ نحوی ارتباط آنها با یکدیگر قابل نمایش است و همانطور که مشاهده می شود، یادگیری عمیق زیرمجموعه های از یادگیری ماشین و همچنین هوش مصنوعی است. [۱۹]



شکل ۲-۱. ارتباط بین هوش مصنوعی و یادگیری ماشین و یادگیری عمیق و شبکه‌های عصبی و شبکه‌های پروسپترون چندلایه mlp

در ادامه مروری بر هوش مصنوعی، یادگیری ماشین، روش‌های یادگیری عمیق و در ادامه اصطلاحات رایج که باید برای فعالیت در این زمینه با آن‌ها آشنا باشیم را به صورت مختصر توضیح خواهیم داد.

۲-۳-۱ هوش مصنوعی

همانطور که از نام آن پیداست هوش مصنوعی ترکیب هوش انسانی در ماشین است، به نحوی که رفتاری همانند انسان را تقلید و خلاقانه مسائل را حل کند. به طور دقیق‌تر هوش مصنوعی، در تلاش برای روشی است که رونوشتی از مغز انسان را پیاده‌سازی کند، یعنی همانگونه که یک انسان فکر می‌کند و عمل می‌کند. [۱۴]

۲-۳-۲ یادگیری ماشین

یادگیری ماشین که زیرمجموعه‌های از هوش مصنوعی است، رایانه را به گونه‌ای توانمند می‌سازد که قادر به یادگیری از طریق تجربه و بدون برنامه‌ریزی صریح می‌شود. این یادگیری توسط داده‌های که مناسب به هر مسئله به آن داده می‌شود. رابطه‌های را میان ورودی و خروجی مسئله پیدا می‌کند تا در مواجهه با مسئله‌های مشابه از آن استفاده کند. یادگیری ماشین اینگونه آموزش می‌بیند که، چگونه یک تصمیم‌گیری برای مسئله انجام دهد، و روشی برای تحقق بخشیدن به هوش مصنوعی است. [۱۴]

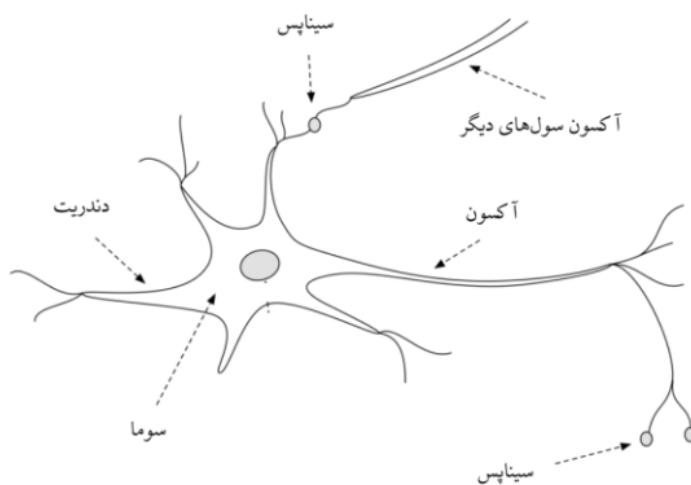
۲-۳-۳ یادگیری عمیق

یادگیری عمیق زیرمجموعه‌ای از یادگیری ماشین بوده و از ساختار شبکه‌های عصبی برای تقلید در تصمیم‌گیری حل یک مسئله مشابه مغز انسان استفاده می‌کند، و همان کار یادگیری ماشین را انجام می‌دهد، ولی قابلیت‌های متفاوتی در آن

وجود دارد. در مقایسه یادگیری ماشین با یادگیری عمیق اینگونه می توان بیان کرد، در حالیکه یادگیری عمیق به طور خودکار ویژگی ها را از ساختار داده ها استخراج می کند، این عمل توسط یادگیری ماشین باید به صورت دستی انجام گیرد [۱۴].

۲-۳-۴ شبکه های مصنوعی

شبکه های عصبی مصنوعی مدل های محاسباتی بوده که سازوکار یادگیری را همانند شبکه عصبی طبیعی از ساختار مغز انسان شبیه سازی می کند. ساختار مغز انسان که همان شبکه عصبی طبیعی است از تعداد زیادی واحد به نام نرون تشکیل شده است ساختار نرون در شکل ۲-۲ نمایش داده شده است.



شکل ۲-۲. نمایی از یک شبکه عصبی واقعی [۱۴]

۲-۳-۴-۱ مقدمات شبکه های عصبی

در این بخش به معرفی مختصری از اصطلاحاتی که در این شبکه مورد نیاز است می پردازیم

۲-۳-۴-۲ نرون

نرون ها همان گره ها در طراحی شبکه می باشد که ورودی را می گیرند و بعد از پردازش به یک خروجی تبدیل می کند. در طراحی مدل شبکه عصبی تعداد نرون ها در هر لایه بسیار مهم است تعداد نرون های ورودی معمولاً همان ویژگی ها و ابعاد مسئله می باشد و تعداد نرون ها در لایه خروجی همان تعداد خروجی مسئله می باشد و اما تعداد نرون ها در لایه مخفی متفاوت تر است در زیر سه روش جهت انتخاب صحیح تعداد نرون ها ارائه شده است باید به این نکته توجه داشت که انتخاب صحیح جهت کارایی مدل توسط تست تعداد آن به صورت عملی با آزمون و خطا در سیستم بدست می آید اما خب در ابتدا اینکه تصادفی این تعداد انتخاب شود بسیار زمان بر و سخت می باشد روش اول با در نظر گرفتن S نرون در لایه مخفی، می توان 2^S کلاس را طبقه بندی کرد. روش دوم که نسبتاً کاربردی نیز است به صورت زیر می باشد

$$N_n = \sqrt{(N_i + N_o)} \quad (2-1)$$

N_n : تعداد مناسب نرون در لایه پنهان

N_i : نرون‌های لایه ورودی

N_o : نرون‌های لایه خروجی

روش سوم: روش دیگری جهت تخمین تعداد نرون‌ها در لایه پنهان در معادله (2-2) نمایش داده شده است که a عامل مقیاس پذیری دلخواه بین (10-2) می‌باشد.

$$N_n = \frac{N_s}{(a * (N_i + N_o))} \quad (2-2)$$

N_n : تعداد نرون‌ها در هر لایه

N_s : تعداد نمونه‌های موجود در داده‌های آموزشی

N_o : تعداد نرون در خروجی

N_i : تعداد نرون‌های ورودی

a : عامل مقیاس‌بندی

2-3-4-3 وزن

وزن یک متغیر می‌باشد زمانی که مقادیر ورودی به نرون اعمال می‌شود از طریق ضرب در نرون، آن نرون، وزن‌دار می‌شود. ایده اصلی شبکه‌های عصبی این است که با تغییر مقادیر وزن و بایاس شبکه یک رفتار بهینه در جهت تابع هدف به ما بدهد. مقداردهی اولیه وزن‌ها برای دستیابی به همگرایی شبکه بسیار مهم است که روش‌های مختلفی از جمله مقداردهی اولیه ثابت، مقداردهی اولیه نرمال یا یکنواخت، مقداردهی LeCun نرمال و یکنواخت، مقداردهی Glorot یکنواخت و نرمال، مقداردهی He می‌توان اشاره کرد.

2-3-4-4 بایاس

بایاس یکی دیگر از اجزاء خطی که روی ورودی تاثیر می‌گذارد که به حاصل ضرب ورودی در وزن اضافه می‌شود. یک متغیر قابل تنظیم برای نرون‌ها می‌باشد و در هر لایه ممکن است مقادیر متفاوتی داشته باشد.

2-3-5 توابع فعالساز

یکی از اجزا بسیار مهم در معماری یک مدل از شبکه‌های عصبی توابع فعالساز می‌باشد که در واقع راهی برای معرفی غیرخطی می‌باشد. از این توابع جهت تعیین خصوصیات نرون در راستای حل مسائل استفاده می‌شود که با توجه ماهیت هر تابع برای مسئله انتخاب می‌شود و وظیفه انتشار خروجی از یک لایه به لایه دیگر بعد از انجام مرحله محاسباتی در هر نرون را به عهده دارد. از توابع پرکاربرد می‌توان به Relu، Sigmoid، Tanh، Softmax، و... می‌توان نام برد.

۲-۳-۶- لایه‌های ورودی و خروجی و مخفی

در طراحی شبکه‌های عصبی یک لایه جهت دریافت ورودی‌ها لایه اول شبکه می‌باشد و یک یا چند لایه مخفی جهت پردازش با توجه به پیچیدگی مساله انتخاب می‌شود باید توجه داشت که افزایش بی‌مورد لایه مخفی بار محاسباتی را افزایش می‌دهد و اینکه این لایه برای ما قابل مشاهده نمی‌باشد و در انتها انتخاب یک لایه خروجی که خروجی را تولید می‌کند برای ما قابل مشاهده می‌باشد در نظر گرفته می‌شود.


۲-۳-۷- مدل‌های شبکه عصبی

بهترین تعریف از شبکه‌های عصبی را Liping Yang ارائه داده است به این صورت که «شبکه‌های عصبی از چندین نرون مصنوعی تشکیل شده است که اطلاعات را بین یکدیگر رد و بدل می‌کنند، و هر کدام وزن‌هایی دارند که براساس «تجربه‌ی» شبکه شکل می‌گیرند. نرون‌ها یک نقطه‌ی فعال‌سازی دارند که اگر مجموع وزن و داده‌های ارسال شده به آن‌ها از آن نقطه عبور کند، آن‌ها فعال می‌شوند. مجموعه‌ای از نرون‌های فعال شده منجر به «یادگیری» می‌شوند.»

شبکه‌های عصبی انواع مختلفی از جمله شبکه‌های پروسپترون چندلایه (MLP)، شبکه‌های بازگشتی (RNN) و غیره دارد.

۲-۳-۸- شبکه‌های پروسپترون چندلایه

شبکه‌های پروسپترون چند لایه که با عنوان شبکه‌های پیش‌خور عمیق نیز یاد می‌شود دو یا چند نرون می‌توانند باهم در قالب یک لایه ترکیب شوند و یک شبکه خود می‌تواند از چند لایه تشکیل شده باشد در شبکه‌های پروسپترون هر نرون در هر لایه به تمام نرون‌ها لایه بعدی متصل است و به اصطلاح اتصال در این شبکه‌ها به صورت تمام متصل است. در این شبکه‌ها با رفتن به هر لایه دیگر، جمع وزن‌دار مجموعه نرون‌های لایه قبلی محاسبه شده و پس از اعمال تابع فعال‌ساز غیرخطی به لایه دیگر منتقل می‌شوند تا در نهایت به لایه خروجی برسند. در شکل ۲-۳ شمایی از یک شبکه عصبی پیش‌خور عمیق تماماً متصل قابل مشاهده است. [۱۴]



شکل ۲-۳. معماری یک شبکه پروسپترون تمام متصل [۱۴]

۲-۳-۴-۹ روش یادگیری

روش‌های یادگیری در شبکه‌های عصبی را می‌توان به سه نوع اصلی نظارتی، غیرنظارتی، تقویتی طبقه‌بندی کرد که در یادگیری نظارتی برای هر الگوی ورودی که در آموزش شبکه استفاده می‌شود یک الگوی خروجی مطلوب یا همان هدف در نظر گرفته می‌شود. یادگیری غیرنظارتی خروجی هدف در شبکه مشخص نمی‌باشد و روش تقویتی خروجی مطلوب مشخص نمی‌باشد بلکه فقط مشخص می‌کند خروجی درست است یا نه و در پاسخ‌های درست پاداش در مقابل پاسخ‌های اشتباه جریمه می‌شوند. نمونه یادگیری می‌توان به Hebbian، یادگیری کاهش گرادیان، یادگیری رقابتی، یادگیری تصادفی اشاره کرد.

۲-۳-۴-۱-۹ یادگیری کاهش گرادیان

این روش بر اساس کمینه کردن خطای E ، که بر حسب وزن‌ها فعالسازی شبکه بیان می‌شود، عمل می‌کند. همچنین لازم است تابع فعالسازی که در شبکه استفاده می‌شود، قابل مشتق‌گیری باشد. چون به‌روزرسانی وزن‌ها بر اساس گرادیان خطای E است بنابراین، اگر Δw_{ij} وزن به‌روز شده لینک نرون i امین دولا به مجاور باشد. Δw_{ij} به صورت زیر تعریف می‌شود

$$\Delta w_{ij} = \eta \frac{\partial E}{\partial w_{ij}} \quad (3-2)$$

که در آن η پارامتر نرخ یادگیری و $\partial E / \partial w_{ij}$ گرادیان خطاست که نسبت به وزن w_{ij} محاسبه می‌شود. روش‌های دلتای Hoff و Windrow و یادگیری پس انتشار مثال‌هایی از این مکانیزم یادگیری هستند. [۱۹]

۲-۳-۴-۱۰ انتشار رو به جلو

به حرکت ورودی از لایه مخفی به سمت لایه خروجی یعنی ابتدا داده‌ها وارد لایه ورودی و سپس بعد از گذر از لایه‌های مخفی به لایه خروجی می‌رسند را انتشار رو به جلو گفته می‌شود

۲-۳-۴-۱۱ انتشار به عقب

در ابتدای طراحی شبکه مقدار وزن‌ها و بایاس را با توجه به مسئله یکی از روش‌های مقدار دهی اولیه در نظر می‌گیریم زمانی که خروجی مدل را می‌گیریم و با تابع هدف مقایسه و توسط تابع هزینه‌های مقدار را پیش‌بینی می‌کنیم سپس این مقدار را به شبکه بر می‌گردانیم تا مقدار وزن‌ها و بایاس به‌روزرسانی شوند این وزن‌ها به گونه‌ای به‌روزرسانی می‌شوند که خطای شبکه را کاهش دهد. به این عمل انتشار رو به عقب گفته می‌شود.

۲-۳-۴-۱۲ تابع هزینه

یک شبکه را به گونه‌ای طراحی می‌کنیم که خروجی دقیقی را پیش‌بینی کند میزان دقت شبکه توسط تابع هزینه بدست می‌آید. این تابع به نام‌های تابع ضرر یا تابع زیان هم شناخته شده است هدف از طراحی یک شبکه این است که دقت پیش‌بینی را افزایش و خطاها را کاهش دهیم. نمایش مقدار کم این تابع نشان از عملکرد بهینه شبکه می‌دهد.

۲-۳-۴-۱۳ معیار عملکرد

برای ارزیابی عملکرد الگوریتم ها، معیار کمی برای باید تعریف شود نمونه ای از آن ها صحت، دقت، هشدار نرخ کاذب و بار محاسباتی و... است که با آن ها عملکرد شبکه را مورد ارزیابی قرار می دهیم.

۲-۳-۴-۱۴ بهینه سازی وزن ها

بهینه سازی الگوریتم هایی هستند که از طریق به هنگام سازی وزن ها در شبکه سعی در به حداقل رساندن تابع زیان دارند، یعنی همان هدف اصلی ما از آموزش شبکه ها برای مسئله مورد نظر که سعی داریم، وزن های شبکه به گونه ای تنظیم تا شبکه توانایی یادگیری را بدست آورد. انتخاب الگوریتم بهینه سازی مناسب نقش مهمی در سرعت همگرایی شبکه دارد. روش های مختلفی برای بهینه سازی وجود دارد. [۱۴]

گرایان کاهش یکی از محبوب ترین و متداول ترین این الگوریتم ها در شبکه عصبی است نمونه های دیگر می توان به روش نیوتن، Adam و... می توان نام برد.

۲-۳-۴-۱۵ نرخ یادگیری

میزان کاهش هزینه در هر تکرار را نرخ یادگیری می نامند یا به عبارتی دیگر سرعت کاهش هزینه که باید به دقت مشخص شود چرا که انتخاب مقدار زیاد ممکن است حالت بهینه را رد کند و مقدار کم آن سبب طولانی شدن روند یادگیری شبکه شود.

۲-۳-۴-۱۶ بسته ها

در زمان آموزش شبکه به جای اینکه کل ارسال کل ورودی آن ها را به بسته های کوچک با اندازه یکسان تقسیم می کنیم این کار سبب جامع تر از مدلی که تمام داده ها به صورت یکجا به شبکه تزریق شود دارد.

۲-۳-۴-۱۷ دوره ها

به انتشار روبه جلو و رو به عقب در شبکه یک دوره می گوئیم که تنظیم تعداد آن توسط خود طراح صورت می گیرد و برای یادگیری شبکه به تکرارهای مناسب احتیاج است اما باید توجه داشت که تعداد زیاد دوره ها سبب **overfit** شدن شبکه می شود.

۲-۳-۵ چالش های آموزش در شبکه های عمیق

فرآیند آموزش در شبکه های عمیق شامل یافتن مجموعه ای از وزن ها در شبکه است، این وزن ها نمایانگر یادگیری در شبکه برای مسئله مورد نظر هستند آموزش در شبکه های عصبی روندی تکرار شونده است، یعنی گام به گام با بروزرسانی های کوچک در وزن ها و با تکرار این عمل، عملکرد مدل در حل مسئله بهبود پیدا می کند. این فرآیند، یک مسئله بهینه سازی را بوجود می آورد، چرا که شبکه سعی می کند براساس وزن ها تابع زیان را حداقل کند. همین مسئله بهینه سازی سبب ایجاد چالش هایی در شبکه می شود. سوال اینجاست که دقیقا چه چیزی در این مسئله بهینه سازی چالش برانگیز می باشد؟ [۱۴]

۲-۳-۱-۵ محو گرادیان و انفجار گرادیان

هنگام استفاده از الگوریتم پس‌انتشار، در فاز عقب‌گرد محاسبه گرادیان کوچک و کوچک‌تر می‌شود. این اتفاق به این دلیل بوجود می‌آید که، گرادیان کاهشی در هر تکرار مشتقات جزئی را با طی کردن از لایه پایانی به سمت لایه ابتدایی با استفاده از قانون زنجیرهای می‌یابند. در شبکه‌ای با داشتن n لایه پنهان، مشتقات این n لایه در یکدیگر ضرب می‌شود. حال اگر این مشتقات کوچک باشند، با رفتن به لایه‌های اولیه به صورت نمایی کاهش پیدا و (یا در بدترین حالت صفر می‌شوند و یادگیری شبکه متوقف می‌شود) همین امر سبب پدیده محو گرادیان می‌شود. از آنجایی که این گرادیان کوچک در تکرار الگوریتم به هنگام‌سازی نمی‌شوند و این لایه‌های اولیه اغلب در شناخت داده‌ها موثر هستند، منجر به عدم دقت کافی شبکه می‌شوند. در مقابل این اگر این مقادیر مشتقات بزرگ باشند با رشد نمایی از طریق انتقال به لایه‌ها، سبب سرریز شده و وزن‌ها دیگر توانایی به هنگام‌سازی نخواهند داشت، و شبکه‌ای ناپایدار را پدید می‌آورد که با عنوان انفجار گرادیان شناخته می‌شود. [۱۴]

۲-۳-۲ شناسایی محو گرادیان و انفجار گرادیان

راه‌های شناسایی هر کدام از این چالش‌ها در زیر شرح داده شده است:

شناسایی انفجار گرادیان

- به دلیل عدم ثبات مدل، تغییرات زیادی در به هنگام‌سازی وزن‌ها مشاهده شود. وزن‌ها در هنگام آموزش به صورت نمایی رشد می‌کنند.

- در طول فرآیند آموزش تابع هزینه مقدار NaN بگیرد.

- مدل اطلاعات زیادی را در طول فرآیند آموزش فرا نمی‌گیرد، بنابراین تابع هزینه ضعیفی دارد.

شناسایی محو گرادیان

- در طول فرآیند آموزش بهبود مدل بسیار آهسته می‌باشد، و ممکن است فرآیند آموزش خیلی زود متوقف شود یعنی، هیچ آموزش دیگری سبب بهبود مدل نمی‌شود.

- وزن‌های نزدیک به لایه خروجی شاهد تغییراتی بیشتری نسبت به لایه‌های نزدیک به ورودی دارند.

- وزن‌های مدل به صورت نمایی کاهش پیدا کند.

- وزن مدل در هنگام آموزش صفر شود.

با توجه به مشکلاتی که در حین آموزش شبکه روبه‌رو می‌شویم می‌توانیم شناسایی کنیم که درگیر انفجار گرادیان شدیم یا محو گرادیان که با توجه به آن راهی را جهت مقابله انتخاب کنیم.

۳-۲-۶ تفاوت پارامترها و ابرپارامترها

در آموزش شبکه‌های عصبی دو نوع پارامتر نقش دارند که با یکدیگر متفاوت هستند در زیر به صورت خلاصه ایی در مورشان توضیح خواهم داد

پارامترهای مدل: مقادیری هستند که از مجموعه داده‌ها در حین آموزش خود شبکه تخمین می‌زند و به صورت دستی قابل تنظیم نمی‌باشد و متغیرهای داخلی شبکه هستند. مدل از این پارامترها جهت پیش‌بینی استفاده می‌کند. ابرپارامترها: متغیرهای خارجی در در مدل‌سازی شبکه هستند که قبل از شروع یادگیری تعیین می‌شوند. ابرپارامترها تأثیر به‌سزایی در سرعت و عملکرد شبکه دارند. به طور کلی هر پارامتری را که مجبور شویم قبل از آموزش شبکه تعیین کنیم شامل ابرپارامترها می‌شود.

۲-۴ کاهش ویژگی

کاهش ویژگی به دو روش انتخاب ویژگی و استخراج ویژگی تقسیم می‌شود که در انتخاب ویژگی یکسری از ویژگی‌های کم اهمیت به طور کامل حذف می‌شوند اما در روش استخراج ویژگی، ویژگی‌ها با هم ادغام و ویژگی جدیدی را که برای ما قابل فهم نیست تولید می‌کند. به برخی از دلایل کاهش ابعاد می‌توان به سرعت الگوریتم با داده‌هایی با ابعاد کم بیشتر ای و نیاز به فضای ذخیره‌سازی کمتری است و احتمال overfit را کاهش می‌دهد. روش تحلیل مولفه‌های اساسی (PCA) یکی از روش استخراج ویژگی که براساس تعیین مولفه‌های اساسی (PC) در داده‌ها کار می‌کند. مولفه‌های اساسی در حقیقت همان بردار ویژه‌های ماتریس کوواریانس داده‌ها هستند. بیشترین واریانس داده‌ها در راستایی قرار دارد که بردار ویژه‌ی متناظر با بزرگترین مقدار ویژه در آن راستا قرار دارد. به همین ترتیب هر چقدر مقدار ویژه کوچکتر شود واریانس داده‌ها در راستای بردار ویژه متناظر با آن کمتر می‌شود.

۲-۵ مروری بر کارهای انجام شده

کارهای زیادی در خصوص سیستم‌های تشخیص نفوذ انجام شده است که در ادامه به بررسی برخی از مقالاتی که در زمینه یادگیری عمیق کار کرده‌اند و معیار دقت تشخیص نفوذ که یکی از چالش‌های پراهمیت در این حوزه که بسیار مورد توجه محققان قرار گرفته است می‌پردازیم.

در این تحقیق [20] از مفهوم انباشته‌شدن (تعمیم پشته) با استفاده از داده‌های ناهمگن برای شناسایی موثر نفوذ شبکه ارایه کرده‌اند. در این روش از دو مجموعه داده ناهمگن UNSSB-15 (شبیه‌سازی شده) و UGR16 (در زمان واقعی) ترکیب الگوریتم‌های جنگل تصادفی، رگرسیون لجستیک، نزدیکترین همسایه K و ماشین بردار پشتیبانی منجر به پیش‌بینی‌های برتر باتوجه به یک مجموعه داده در زمان واقعی نسبت به یک مجموعه شبیه‌سازی شده است. اهداف اصلی محققان افزایش سرعت و دقت تشخیص نفوذ شبکه بوده است که نتایج مطلوبی حاصل شده است.

در تحقیقی دیگر [۶] ارایه یک روش تشخیص نفوذ با استفاده از یادگیری مجموعه داده محدود است. عملکرد تعیبه، عملکرد فاصله و عملکرد از دست دادن جنبه‌های اصلی است که بر نتایج طبقه‌بندی با استفاده از FSL¹ تأثیر می‌گذارد. در این روش از کمترین میزان داده برای آموزش استفاده شده است. از مجموعه داده UNSW-NB15 و NSL-KDD جهت تشخیص

¹ Few Shot Learning

نفوذ استفاده شده است، روش پیشنهادی در این تحقیق با الگوریتم‌هایی از جمله (RNN^1) ، (RF^2) ، (NB^3) ، (SVM^4) ، (MLP^5) مقایسه شده است که برتری الگوریتم FSL نسبت به سایر الگوریتم‌ها اثبات شد.

در این پژوهش [21] یک مدل مجموعه‌ای را پیشنهاد می‌کنند که بهترین مدل‌های ML^6 و DL^7 را برای دستیابی به معیارهای عملکرد بالا ترکیب می‌کند. در نهایت بهترین مدل‌ها را با مجموعه داده CIC-IDS2017 مقایسه کردند و آنها را با مدل‌های مدرن مورد قبلی قرار دادند. در این تحقیق، یک معیار با عملکرد بالا با زمان آموزش نسبتاً کم برای هر دو مدل ML و DL در تشخیص نفوذ شبکه به دست آمد و $CART^8$ بهترین عملکرد را داشت، مدل‌های ML به دلیل ابهام کمتر بردارهای ویژگی در مجموعه داده، توانستند عملکرد خوبی داشته باشند. با مجموعه پیچیده‌تر، مدل‌های DL ممکن است از مدل‌های ML بهتر عمل کنند. با این حال مدل‌های ML مزیت کنترل بر ویژگی دارند که در روش‌های DL وجود ندارد. اهمیت ویژگی به انتخاب بهترین ویژگی‌های مربوط به داده‌ها با معیار اطلاعات متقابل و کاهش مجموعه ویژگی‌ها برای دقت بهتر و محاسبات سریعتر در عملکرد کمک کنند.

در این پژوهش [22] از الگوریتم شبکه عصبی در یادگیری عمیق جهت تشخیص نفوذ و افزایش امنیت در وسایل نقلیه مورد مطالعه قرار می‌دهند. الگوریتم نزول گرادینان با تکانه و بهره تطبیقی (GDM/AG^9) می‌تواند در مقایسه با الگوریتم شیب نزول با تکانه سنتی (GDM^{10}) در تشخیص ناهنجاری خودرو سریعتر به همگرایی دست یابد و می‌تواند داده‌های ناهنجار را در میلی ثانیه تشخیص دهد. مدل پیشنهادی جیایان ژانگ می‌تواند خود را برای تشخیص حملات ناشناخته در زمان واقعی به میزان صحت ۹۷ تا ۹۸ درصد در جهت سازگاری با انواع حملات ناشناخته تطبیق دهد.

در پژوهشی دیگر [23] در ابتدا یک بررسی از رویکردهای یادگیری عمیق برای تشخیص نفوذ امنیت سایبری و سپس ۳۵ مجموعه داده سایبری معروف را توصیف کرده‌اند و در هفت دسته مجموعه داده‌های مبتنی بر ترافیک شبکه، مجموعه داده‌های مبتنی بر شبکه الکتریکی، مجموعه داده‌های مبتنی بر ترافیک اینترنتی، مجموعه داده‌های مجازی مبتنی بر شبکه خصوصی، مجموعه داده‌های مبتنی بر برنامه‌های اندروید، مجموعه داده‌های مبتنی بر ترافیک اینترنت اشیا و مجموعه داده‌های مبتنی بر دستگاه‌های متصل به اینترنت طبقه‌بندی کرده‌اند و هفت مدل یادگیری عمیق شامل شبکه‌های عصبی مکرر، شبکه‌های عصبی عمیق، شبکه‌های عصبی متحرک، رمزگذاری خودکار عمیق، ماشین‌های محدود شده بولترمن، ماشین‌های عمیق بولترمن، شبکه‌های اعتقادی عمیق ارایه داده‌اند و عملکرد این هفت رویکرد را در دو مجموعه داده ترافیک واقعی شامل CSE-CIC-IDS2018 و BOT-IOT مورد بررسی قرار گرفته است و در نهایت با چهار رویکرد یادگیری ماشین یعنی بیز ساده، شبکه‌ی عصبی مصنوعی، جنگل تصادفی و ماشین بردار پشتیبان سنجش می‌کنند.

1 Recurrent neural network

2 Random Forest

3 Naive Bayes

4 Support vector machine

5 Multi layer perceptron

6 Machine learning

7 Deep learning

8 Classification and regression tree

9 gradient descent momentum /adaptive gain

10 gradient descent with momentum

در این تحقیق [۲۴] با توجه به اهمیت امنیت اینترنت اشیا (IOT) یک استراتژی تشخیص حملات سبک با استفاده از یک ماشین بردار پشتیبان مبتنی بر یادگیری (SVM) برای تشخیص حملات DOS در نظر گرفته‌اند. تنها ویژگی در نظر گرفته شده در این مقاله میزان ورود بسته به گره است. برای طبقه‌بندی از یک طبقه‌بندی کننده SVM با ورودی در قالب دو یا سه ویژگی غیر مجتمع استفاده می‌شود و با سایر طبقه‌بندی کننده‌های مبتنی بر یادگیری ماشین از جمله: NN، K-NN، DT مقایسه شده است تا زمان تشخیص و دقت طبقه‌بندی با SVM را با ترکیبی از دو یا سه ویژگی پیچیده رضایت بخش را نشان دهد.

در این مقاله [۲۵] کاهش بعد و طبقه‌بندی دو لایه برای تشخیص حملات با فرکانس پایین در ستون فقرات IOT هدف محققان در این تحقیق تشخیص دقیق حملات (R2L)، (U2R) بدون کاهش عملکرد و پایین بودن نرخ مثبت کاذب به دلیل استفاده از ویژگی اصلاح و نرخ تشخیص کلی بالاتر به دلیل استقرار طبقه‌بندی کننده چند لایه و پیچیدگی محاسباتی کمتر به دلیل استقرار کاهش ابعاد در دو لایه بوده است و مجموعه داده مورد استفاده NSL-KDD بوده است. مدل پیشنهادی از مدل‌های مشابه موجود بهتر عمل کرده است و میزان تشخیص برای هر دو حملات فرکانس پایین و معمولی می‌باشد.

در مطالعه پژوهش [۲۶] یک چارچوب جدید یادگیری ماشین نیمه سطحی (MSML) برای سیستم تشخیص نفوذ ارائه داده‌اند که دو مشکل عدم تعادل ترافیک شبکه و توزیع غیر یکسان بین مجموعه آموزش و مجموعه آزمون که بر استحکام مدل خیلی تاثیر می‌گذارد. مدل MSML با بهبود الگوریتم K-MEANS الگوریتم نوین تری به نام HSK-MEANS ارائه داده‌است که برای یکسان سازی داده‌ها از نرمال سازی لگاریتمی استفاده می‌کند. اما در گزینش پارامترها منعطف نمی‌باشد. برای ارزیابی این مدل از مجموعه داده KDDCPU99 استفاده شده است. نتایج بدست آمده نشان می‌دهد که از نظر دقت کلی به میزان ۹۶.۶ درصد نسبت به مدل‌های دیگر تشخیص نفوذ کارا تر است.

در مقاله پیش‌رو [۱۱] سیستم تشخیص نفوذ شبکه مبتنی بر شبکه عصبی عمیق با واحدهای مکرر دروازه دار (GRU¹) که از GRU به عنوان واحد حافظه اصلی، همراه با MLP برای شناسایی نفوذهای شبکه استفاده می‌کند. آزمایش بر روی مجموعه داده‌های معروف KDD99 و NSL-KDD است. میزان تشخیص کلی ۹۹.۹۴ در KDD99 و ۹۹.۳۱ در NSL-KDD بود. آزمایشات مقایسه ای روش GRU در مقابل LSTM² نشان داده که سیستم دارای عملکرد پیشرو است.

در پژوهشی دیگر [۱۲] محققان در این تحقیق یک روش تشخیص نفوذ شبکه مبتنی بر یادگیری خودآموز بر اساس چارچوب STL³ با ترکیب دو الگوریتم SVM، SAE⁴ پیشنهاد کرده‌اند. مدل پیشنهادی با استفاده از مکانیزم خودکار رمزگذار که یک الگوریتم یادگیری موثر برای ویژگی‌های جدید و کاهش ابعاد به صورت بدون نظارت است و استفاده از SVM به جای SOFT-MAX برای طبقه‌بندی استفاده شده است که عملکرد خوبی در طبقه‌بندی باینری و چند کلاسه نسبت به روش‌های قبلی مانند بیز ساده، J48، RF، از خود نشان داده است و استفاده از مجموعه داده NSL-KDD برای آزمایش است. روش پیشنهادی STL-IDS باعث افزایش دقت طبقه‌بندی و سرعت آزمایش شده که تشخیص نفوذ شبکه را بهبود بخشیده است.

¹ Gated recurrent units

² Long short-term memory

³ Self taught learning

⁴ sparse auto encoder

در این تحقیق [27] یک روش جدید کاهش ابعاد را پیشنهاد می کنند که در آن دو تکنیک انتخاب ویژگی و استخراج باهم ادغام شده است. در این روش رویکرد کسب اطلاعات (IG^1) و تجزیه و تحلیل مولفه های اصلی (PCA^2) برای کاهش ویژگی ها و استخراج مجموعه جدیدی از ویژگی ها غیر مرتبط استفاده شده است در حالی که طبقه بندی کننده گروهی بر اساس SVM³، IBK³، MLP برای ساخت مدل طبقه بندی استفاده می شود. سپس از الگوریتم AOP برای به دست آوردن تصمیم نهایی برای تشخیص طبیعی بودن یا حمله بودن یک نمونه استفاده شده است عملکرد این روش IG-PCA بر اساس سه مجموعه داده معروف ISCX2012، NSL-KDD، Kyoto2006+ ارزیابی می شود. تجزیه و تحلیل مقایسه ای روش پیشنهادی نشان می دهد که عملکرد بهتری در مورد دقت طبقه بندی و میزان تشخیص و میزان هشدارهای کاذب نسبت به اکثر رویکردهای مدرن موجود دارد.

در این مقاله [13] برای تشخیص نفوذ شبکه از رمزگذار خود کار پراکنده ($SSAE^4$) که نمونه ای از یک استراتژی یادگیری عمیق، برای استخراج ویژگی های پراکنده با ابعاد بالا استفاده کرده اند. نتایج تجربی بر روی مجموعه داده NSL-KDD نشان می دهد که SSAE با ساختار بهینه می تواند ویژگی های اصلی را بدون ازدست دادن مقدار اطلاعات موجود بین داده های اصلی تا 5 بعد فشرده کند. عیب روش پیشنهادی که محقق به آن اشاره کرده است این روش نمی تواند به طور موثر نمونه های حمله با فرکانس پایین U2R و R2L را تشخیص دهد یعنی نمی تواند بر عوارض ناشی از توزیع نامتعادل داده ها غلبه کند.

در مقاله ای دیگر [5] رویکرد ترکیبی تشخیص نفوذ مبتنی بر شبکه عصبی با استفاده از ANN و FCM برای طبقه بندی الگوهای عادی و حمله و نوع حمله ارائه داده اند شبکه های عصبی مصنوعی از فرایندهای یادگیری که در سیستم های بیولوژیکی اتفاق می افتد الهام گرفته شده است سلول های عصبی سعی می کند مکانیسم های عملکرد بیولوژیکی خود را تقلید کنند. یادگیری را می توان به عنوان یک فرایند بهینه سازی درک کرد. از پرسپترون چندلایه (MLP) برای سیستم تشخیص نفوذ استفاده می شود نتایج نشان می دهد که سیستم پیاده سازی شده و طراحی شده حملات را شناسایی و در پنج گروه (NORMAL، DOS، U2R، R2L، PROBE) طبقه بندی می کند و از مجموعه داده KDD برای آموزش و ارزیابی طبقه بندی کننده ANN استفاده شده است. الگوی ورودی به پنج خوشه که نمایانگر پنج کلاس هستند تبدیل شده است. مقادیر مرکز و مقادیر شاخص برای هر خوشه با استفاده از خوشه بندی میانگین C فازی محاسبه شده است.

در این بررسی [10] الگوریتم های شبکه عصبی مصنوعی (ANN) به عنوان طبقه بندی کننده برای تشخیص سوابق عادی و حمله مورد بررسی قرار داده اند و از مجموعه داده KDD CUP 99 برای محقق کردن رساله خود استفاده کرده اند در این تحقیق ثابت شده است که FFNN با 10 نورون و 2 لایه نسبت به FFNN با تعداد مختلف نورون و 2 لایه بهتر عمل کرده است. در بررسی دیگر [28] یک IDS برای ترافیک شبکه بی سیم همراه با تکنیک استخراج ویژگی های مبتنی بر پوشش ارائه داده اند که روش استخراج بهینه ویژگی با استفاده از الگوریتم درختان اضافی (ET) پیاده سازی شده است. اثر بخشی و کارایی

1 information gain

2 principal component analysis

3 Instance-based learning

4 stacked sparse auto encoder

این روش با استفاده از مجموعه داده UNSW-NB15 و AWID مورد مطالعه قرار گرفته است علاوه بر این wfef-dnn با الگوریتم های استاندارد یادگیری ماشین شامل بیز ساده (NB)، جنگل تصادفی (RF)، ماشین بردار پشتیبان (SVM)، درخت تعمیم (DT) و نزدیکترین همسایه K (KNN) مقایسه می شود. مطالعات تجربی شامل انواع حملات دو تایی و چند کلاسی است. نتایج نشان داد که WFEU-FFDNN پیشنهادی دقت تشخیص بیشتری نسبت به سایر روش ها دارد.

در این مطالعه [۲۹] روش AdaBoost را برای بهبود عملکرد سیستم تشخیص نفوذ پیشنهاد داده اند که از تکنیک ابر نمونه گیری اقلیت مصنوعی (SMOTE)، تجزیه و تحلیل اجزای اصلی (PCA) و انتخاب ویژگی های مجموعه (EFS) در مجموعه داده CIC-IDS-2017 ثابت شده است. مطالعات تجربی نشان می دهد روش پیشنهادی عملکردی بهتری از خود نشان می دهد.

در مطالعه ای دیگر [۳۰] با استفاده از روش سیستم تشخیص نفوذ جرقه یادگیری عمیق (DLS-IDS¹) که شامل چهار قسمت اصلی می باشد انتخاب و کاوش، پیش پردازش، راه حل عدم تعادل کلاس و در نهایت آموزش بر روی آپاچی جرقه است. در مجموعه داده NSL-KDD جهت افزایش دقت استفاده می کند که برای کاهش ویژگی مجموعه داده از روش ابر نمونه گیری اقلیت مصنوعی (SMOTE) به کار می برند که در نهایت دقت به ۸۳.۵۷ درصد بهبود می یابد.

در مقاله [۷] به معرفی یک الگوریتم تشخیص نفوذ ترکیبی مبتنی بر RF، k-means و یادگیری عمیق برای حل مسئله IDS پرداختند که از دو مجموعه داده NSL-KDD و CIC-IDS2017 برای ارزیابی دقت تشخیص نفوذ استفاده کرده اند که به ترتیب شامل ۸۵.۲۴ درصد برای مجموعه داده NSL-KDD و ۹۹.۹۱ درصد برای مجموعه داده CIC-IDS2017 بدست آمده است. روش پیشنهادی سرعت پیش پردازش داده سریع تر و زمان آموزش بالقوه کمتری داشت.

در پژوهش [۸] یک IDS بر پایه یادگیری عمیق به کمک شبکه های عصبی عمیق (FFDNN²) همراه با یک الگوریتم انتخاب ویژگی مبتنی بر فیلتر پیشنهاد می کنند. FFDNN-IDS با استفاده از مجموعه داده های شناخته شده NSL-KDD ارزیابی می کنند و با روش های یادگیری ماشین مورد مقایسه قرار می دهند. که دقت تشخیص نفوذ در این الگوریتم ۹۹.۳۷ درصد است. و نسبت به سایر روش های یادگیری ماشین برتری دارد.

در پژوهشی دیگر [۹] یک سیستم هشدار تشخیص نفوذ ترکیبی را با مدل یلد گیری عمیق و با شبکه های عصبی عمیق پیشنهاد کرده اند که یک ارزیابی جامع از آزمایش های DNN را بر روی مجموعه داده KDDCUP 2017، NSL-KDD، UNSW-N B15، WSN-DS، KYTON، CICIDS 2017 صورت گرفته است که دقت تشخیص نفوذ به ترتیب به صورت NSL-KDD و KDDCUP99 در محدوده ۹۵ درصد تا ۹۹ درصد می باشد و برای UNSW-NB15 و WSN-DS در محدوده ۶۵ درصد تا ۷۵ درصد است.

در این مقاله [۱] با استفاده از روش ترکیبی تحلیل مولفه های اصلی (PCA) و یادگیری عمیق (DL) روش (PCA-DL³) را ارائه داده اند که دقت تشخیص حملات در مجموعه داده NSL-KDD به میزان ۹۲ درصد رسیده است و با سایر الگوریتم از

¹ Deep Learning Spark-Intrusion Detection System

² feed forward deep neural networks

³ Principle Component Analysis-Deep learning

قیل جنگل تصادفی، درخت تصمیم، بیز ساده، رگرسیون لجستیک، شبکه‌های عصبی مصنوعی، الگوریتم نزدیکترین همسایه، الگوریتم ماشین بردار پشتیبان (SVM) مقایسه کرده‌اند و نسبت به دیگر الگوریتم‌ها از دقت بالاتری برخوردار است.

جدول ۲-۱. مقایسه الگوریتم‌های مرور شده

ردیف	سال-تحقیق	روش انجام پژوهش	مجموعه داده
۱	۲۰۲۱-۷	الگوریتم ترکیبی مبتنی بر K-MEANS توزیع‌شده، RF و یادگیری عمیق	NSL-KDD CIC-IDS2017
۲	۲۰۲۰-۱۱	الگوریتم PCA-DL: تجزیه و تحلیل مولفه‌های اصلی با یادگیری عمیق	NSL-KDD
۳	۲۰۲۰-۶	الگوریتم FSL: یادگیری مجموعه داده محدود	NSL-KDD UNSW-NB15
۴	۲۰۲۰-۳۰	الگوریتم DLS-IDS: تشخیص نفوذ با جرعه یادگیری عمیق	NSL-KDD
۵	۲۰۱۹-۸	الگوریتم FFDNN: مبتنی بر یادگیری عمیق و شبکه‌های عصبی عمیق	NSL-KDD
۶	۲۰۱۹-۹	الگوریتم ترکیبی با مدل یادگیری عمیق و شبکه‌های عصبی عمیق	NSL-KDD KDDCUP99 UNSW-NB15 WSN-DS
۷	۲۰۱۸-۱۱	الگوریتم GRU: مبتنی بر شبکه‌های عصبی عمیق با واحدهای مکرر	NSL-KDD KDD 99
۸	۲۰۱۸-۱۲	الگوریتم STL: مبتنی بر خودرمزگذار	NSL-KDD
۹	۲۰۱۸-۱۳	الگوریتم SSAE: رمزگذار خود کار پراکنده	NSL-KDD
۱۰	۲۰۱۸-۲۷	الگوریتم IG-PCA: رویکرد کسب اطلاعات با تجزیه و تحلیل مولفه‌های اصلی	ISCX 2012 NSL-KDD +KYOTO 2006

۶-۲ جمع‌بندی

تکنیک‌ها و الگوریتم‌های متفاوتی برای توسعه یک سیستم تشخیص نفوذ برای شناسایی و طبقه‌بندی حملات سایبری استفاده می‌شود. با این وجود از آنجایی که حملات مخرب مداوم در حال تغییر هستند و در حجم عظیمی از داده‌ها رخ می‌دهد که نیازمند راه‌حلی مقیاس پذیر است چالش‌های زیادی به وجود می‌آید. مجموعه داده‌های بدافزار برای تحقیقات بیشتر توسط جامعه امنیت سایبری به صورت عمومی ارائه شده است. با این حال هیچ تجزیه و تحلیل دقیقی از عملکرد الگوریتم‌ها در مجموعه داده‌های مختلف در دسترس عموم قرار داده نشده است و با توجه به ماهیت پویایی بدافزارها با روش‌های حمله‌ایی که به صورت مداوم تغییر می‌کند نیازمند تحقیقات خواهد بود.

۳. روش پیشنهادی

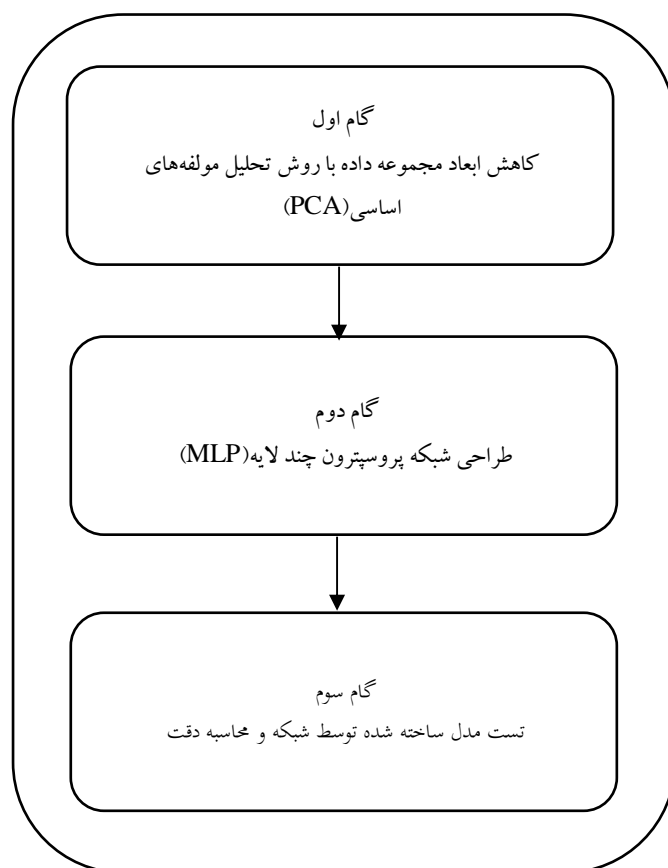
۳-۱ مقدمه

در فصل قبل درباره روش‌های افزایش دقت در سیستم‌های تشخیص نفوذ [۵]، [۷]، [۸]، [۱۱]، [۱۳] بحث کردیم. همانگونه که گفته شد در طی این چندسال تحقیقات بسیار زیادی در زمینه‌های مختلف برای افزایش دقت سیستم‌های تشخیص نفوذ انجام شده است. یکی از روش‌ها در این سیستم‌ها شبکه‌های پروپسترون چندلایه (MLP)، که یکی از روش‌های یادگیری عمیق است، برای حل چالش دقت ارائه شده است. افزایش تعداد لایه‌ها در MLP کارایی این شبکه را بهبود می‌بخشد. با اضافه کردن هر لایه به شبکه و به اصطلاح عمیق‌تر کردن شبکه که برای حل مسائل پیچیده‌تر مورد استفاده قرار می‌گیرد. اما از افزایش بار محاسباتی که متحمل می‌شود نباید غافل بود پس در انتخاب لایه با توجه به مساله باید دقت کافی به عمل آید. یکی از الگوریتم‌های مرسوم بهینه‌سازی وزن‌ها در MLP روش گرادیان کاهشی ریز دسته‌ای می‌باشد که یکی از معایب این الگوریتم یادگیری نرخ یادگیری می‌باشد که سبب کاهش همگرایی می‌شود و همچنین در طراحی شبکه برای هر لایه تابعی را در نظر می‌گیریم. تابع فعالساز جزء اصلی گره‌های شبکه‌های عصبی محسوب می‌شود. توابع فعالساز در شبکه‌های عصبی تعیین می‌کند که آیا گره باید فعال شود یا غیرفعال باشد یکه از توابع فعالساز پرکاربرد تابع RELU می‌باشد که در کنار مزایای مثل از لحاظ محاسباتی کاراتر از توابع دیگر است و همینطور به دلیل ویژگی خطی بودن تابع، همگرایی الگوریتم گرادیان کاهشی را سریع‌تر می‌کند اما مشکلی که دارند مشکل مرگ نرون‌ها در حالتی که خروجی چندین تابع RELU به طور متوالی برابر با صفر باشد.

بنابراین باید الگوریتم بهینه‌سازی وزن‌ها و تابع فعالساز به گونه‌ای انتخاب شود که مشکل نرخ یادگیری در گرادیان کاهشی و مرگ نرون‌ها در تابع فعالساز RELU را حل کند و در نهایت سبب سرعت همگرایی و بهبود دقت در سیستم‌های تشخیص نفوذ شود. در ادامه این فصل یک نمای کلی از الگوریتم پیشنهادی را نمایش می‌دهیم. سپس مراحل الگوریتم پیشنهادی خود را توضیح داده و در نهایت مطالب گفته شده را جمع‌بندی می‌کنیم.

۳-۲ الگوریتم روش پیشنهادی

در این بخش یک نمای کلی از الگوریتم پیشنهادی خود را جهت بهبود افزایش دقت در سیستم‌های تشخیص نفوذ با روش PCA کار کاهش ویژگی را در مجموعه داده NSL-KDD اعمال می‌کنیم و با طراحی شبکه‌های عصبی پروپسترون چندلایه، که در آن از الگوریتم [۱۴] ADAM جهت بهینه‌سازی وزن‌ها و استفاده از تابع فعالساز RELU LEAKY [۱۴] بکار رفته است شرح می‌دهیم. همانطور که در شکل ۳-۱ مشاهده می‌کنید در ابتدای فاز اول از الگوریتم تحلیل مولفه‌های اساسی (PCA) جهت کاهش ابعاد مجموعه داده استفاده می‌کنیم. در فاز دوم از شبکه‌های پروپسترون چندلایه جهت تشخیص حملات از داده‌های نرمال مورد استفاده قرار می‌گیرد و در آخرین گام یعنی گام سوم در مدل ساخته شده با داده‌های آزمایشی جهت بررسی عملکرد دقت در الگوریتم پیشنهادی اجرا می‌گیریم تا میزان دقت بررسی شود.



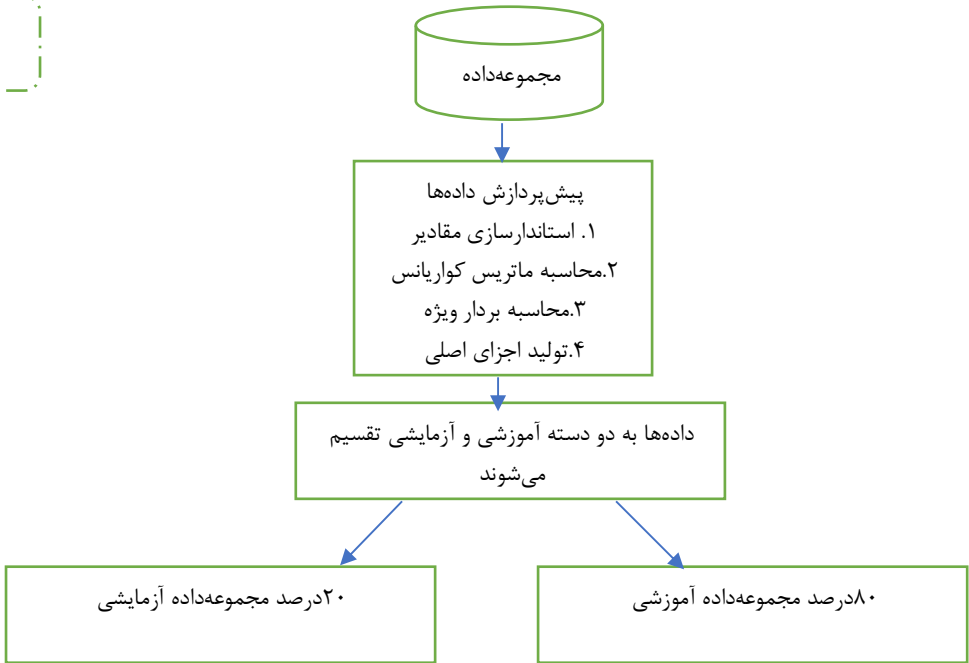
شکل ۳-۱. نمای کلی الگوریتم پیشنهادی

۳-۳ جزئیات روش پیشنهادی

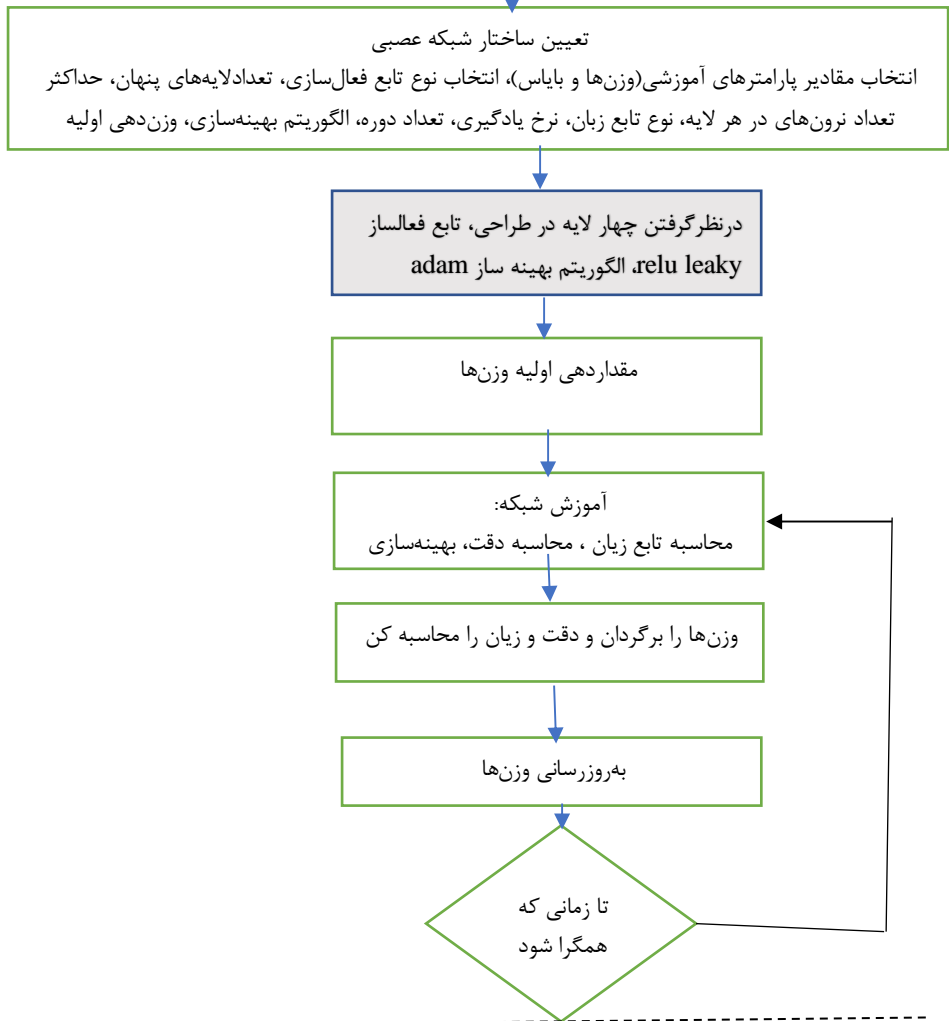
در این بخش ما برای بهبود دقت سیستم‌های تشخیص نفوذ از یک‌ه از روش‌های یادگیری عمیق بهنام شبکه‌های پرسپترون چند لایه که در طراحی آن از تابع فعال‌ساز [14] LEAKY RELU به جای [1] RELU و الگوریتم بهینه [14] ADAM به جای الگوریتم گرادیان کاهشی [1] استفاده کنیم که به طور مفصل توضیح داده خواهد شد. در ادامه فصل در گام اول با الگوریتم تجزیه و تحلیل مولفه‌های اصلی (PCA^1) کار کاهش بعد را برای افزایش بهبود سرعت پردازش داده‌ها صورت می‌گیرد که توضیح داده خواهد شد و در گام دوم از شبکه‌های عصبی عمیق پرسپترون چند لایه استفاده می‌شود تا نرمال یا حمله بودن رفتار شبکه مشخص شود

¹ Principal Component Analysis

گام اول



گام دوم



فاز سوم

پایان

شکل ۳-۲. فلوچارت الگوریتم پیشنهادی

هدف حیاتی تحلیل و تجزیه مولفه‌های اساسی کاهش ویژگی یک مجموعه داده متشکل از تعداد زیادی متغیر مرتبط با یکدیگر است، در حالی که تا حد امکان تغییرات موجود در مجموعه داده را حفظ می‌کند. این امر با تبدیل به مجموعه جدیدی از متغیرهای مولفه اصلی (PC¹) که همبستگی ندارند و مرتب شده‌اند به دست می‌آید که چند نفر اول بیشترین تغییرات موجود در همه متغیرهای اصلی را حفظ می‌کند. [۳۱]

تمرکز اصلی PCA تأکید بر هویت ها و واریانس ها در داده ها و شناخت الگوهای موجود در داده ها در مجموعه داده است. اساساً PCA در چهار مرحله کاهش ابعاد را انجام می‌دهد که در زیر به این چهار مرحله اشاره‌ای می‌کنیم. اولین قدم استانداردسازی مقادیر در ویژگی‌های مجموعه داده برای از بین بردن نتایج مغرضانه است. به عنوان مثال، در یک مجموعه داده می‌توان مقادیر دامنه بزرگتر (۰ تا ۱۰۰) را به عنوان دامنه کوچکتر (۰ تا ۱۰) کنترل کرد. با محاسبه میانگین و واریانس هر صفت حاصل خواهد شد. این ممکن است منجر به نتایج مغرضانه شود. برای جلوگیری از این PCA تمام مقادیر صفات را در یک مقیاس یکسان نشان می‌دهد.

دومین قدم ماتریس کوواریانس را محاسبه می‌کنیم PCA برای یافتن ویژگی‌های همبسته ماتریس کوواریانس را محاسبه می‌کند. ورودی‌های ماتریس کوواریانس مثبت یا منفی هستند. اگر مثبت باشد، ویژگی‌های مربوطه با یکدیگر در ارتباط هستند. این بدان معناست که هر دو ورودی می‌توانند برای هر پارامتری افزایش یا کاهش پیدا کنند. اگر مقدار ورودی منفی باشد، ویژگی‌ها با یکدیگر رابطه معکوس دارند یعنی یک مقدار کاهش می‌یابد و مقدار دیگر افزایش می‌یابد.

سومین مرحله مقدار ویژه و بردارهای ویژه برای محاسبه واریانس بین ویژگی‌های مجموعه داده را از ماتریس کوواریانس بدست می‌آوریم. که بردارهای ویژه جهات را چهارمین و آخرین مرحله تولید اجزای اصلی است. هر جزء اصلی مقدار واریانس صفات موجود در مجموعه داده را حمل می‌کند. حداکثر واریانس مجموعه داده در مؤلفه اصلی اول ذخیره می‌شود. حداکثر واریانس دوم در جزء اصلی دوم و غیره ذخیره می‌شود. هدف از این بخش بهبود سرعت پردازش داده هاست. [۱]

در بخش دوم با طراحی شبکه با داده‌های آموزشی به شبکه آموزش حمله بودن یا نبودن داده‌ها را می‌دهیم. الگوهای یادگیری عمیق با تحلیل پایدار داده‌ها و با پیدا کردن ساختارها و الگوها در داده‌ها آموزش را فرامی‌گیرند. فرایند آموزش با الگوهای محاسباتی به نام شبکه عصبی که از بنیاد مغز الهام گرفته شده، فراهم می‌شود. بنیاد این شبکه از تعدادی لایه پردازشی تشکیل شده است. در این بنیاد هر چه به لایه‌های بالاتر می‌رود قادر به حل مسائل سخت‌تری می‌شود. لایه ورودی داده‌های خام را پردازش و لایه‌های بعدی توانایی استفاده از اطلاعات نرون‌هایی که در لایه قبلی

¹ Principal Component

بدست آمده است را جهت به دست آوردن اطلاعات پیچیده تر از داده ها را فراهم می سازد و نتایج در لایه خروجی قابل مشاهده می باشد

فریضه ی شبکه ی عصبی، یادگیری میزان صحیح وزن ها و انحرافات در شبکه است به گونه ای که به طور مثال بتواند حمله و نرمال را از یکدیگر تفکیک کند. این کار با تکرار در شبکه های عصبی انجام می شود. این گونه است که چندین مرتبه داده هایی به الگوریتم داده می شود و در هر تکرار الگوریتم باید مقادیر بایاس و وزن ها را به هنگام سازی کند. نخستین بار که الگوریتم شبکه عصبی اجرا می شود، این الگوریتم یک دنباله از مقادیر وزن ها و انحراف را به بردارهای وزن ها و انحراف می دهد اینکار سبب می شود تا بردارها یک دنباله مقدار اولیه داشته باشند. در این صورت در هر بار اجرا، شبکه ی عصبی اشتباه خود را محاسبه می کند و با استفاده از آن مقادیر وزن ها و انحراف و خطا را به روزرسانی می کند. کار محاسبه خطا با تابع هزینه یا تابع ضرر است. در حقیقت شبکه عصبی با هر بار اجرا که شاهد مقدار ضرری می شود می آموزد که به چه میزان باید وزن ها و بایاس را به روزرسانی کند.


معماری شبکه عصبی پیشنهادی دارای چهار لایه که در لایه ورودی یک لایه، دو لایه در لایه پنهان و در لایه خروجی هم دارای یک لایه می باشد. لایه ورودی اطلاعات را دریافت و لایه پنهان اطلاعات را پردازش و لایه خروجی نتایج را نشان می دهد. در ادامه بخش به توضیح فرآیندهای که قبل از آموزش شبکه باید مشخص شوند می پردازیم.

توابع فعالساز از جمله فرآیندهایی است که باید قبل از آموزش شبکه مشخص شود این توابع در تمام لایه های شبکه باید مشخص شود برای انتخاب توابع فعالساز پرسپترون چندلایه نمی توان از هر تابعی استفاده کرد بلکه باید حتما ماهیت مشتق پذیری، پیوسته، یکنوا نزولی را داشته باشد و همچنین مشتق اول آن به راحتی قابل محاسبه باشد. مانند RELU، LEAKY RELU می توان نام برد. (۳-۱)

تابع یکسوساز خطی رخنه دار (LeakyRelu): این تابع فعالسازی مشکل مرگ نرون ها در طول فرایند آموزش را از بین می برد [۱۴]. برای افزایش سرعت مدل می توان از این تابع در لایه ورودی و دو لایه پنهان استفاده کرد.

$$LeakyRelu = \begin{cases} x & \text{اگر: صفر} \geq x \\ ax & \text{اگر: صفر} < x \end{cases} \quad (۱-۳)$$

شمایی از این تابع در شکل ۳-۳ قابل مشاهده است



شکل ۳-۳. تابع فعالساز یکسوساز خطی رخنه دار [۱۴]

مزایا:

- مشکل مرگ RELU رافع می کند. چرا که هنگام محاسبه مشتق اجازه یک گرادیان کوچک را می دهد.
- از لحاظ محاسباتی سریعتر عمل می کند. [۱۴]

تابع SOFTMAX این تابع که از آن در لایه خروجی استفاده می شود، تعمیم یافته های از تابع فعالساز سیگموئید بوده و برای حل مشکلات مربوط به دسته بندی از آن استفاده می شود. این امکان را فراهم می سازد که یک پیش بینی احتمالاتی را برای مسئله دسته بندی بیش از دو دسته انجام دهد و به صورت معادله (۲-۳) تعریف می شود.

$$S(y_i) = \frac{e^{y_i}}{\sum_j e^{y_j}}$$

(۲-۳)

تابع زیان از جمله فرایارامترهای می باشد که با توجه به ماهیت مسئله قابل انتخاب می باشد. برای محاسبه تابع زیان از تابع آنتروپی متقاطع که در مسائل گسسته دسته بندی استفاده می شود این تابع فاصله بین دو احتمال را محاسبه می کند و به صورت معادله (۳-۳) تعریف می شود. [۱۴]

$$cross\ Entropy(y, \hat{y}) = \frac{1}{n} \sum_{i=1}^n (y_i \log(\hat{y}_i))$$

(۳-۳)

y : مقدار واقعی مسئله

\hat{y} : خروجی تخمین زده شده از مسئله

y_i : خروجی هر نرون

مقداردهی اولیه یکنواخت گلوروت: مقداردهی اولیه یکنواخت گلوروت که همچنین با نام مقداردهی اولیه خاویر^۲ هم شناخته می‌شود، وزن‌های لایه L را براساس توزیع با میانگین صفر و انحراف معیار خاص در شبکه، به صورت یکنواخت در بازه:

$$\left[\sqrt{\frac{6}{(n_{l-1} + n_l)}}, \sqrt{\frac{6}{(n_{l-1} + n_l)}} \right]$$

(۴-۳)

مقداردهی می‌کند. که در این معادله n_l و n_{l-1} تعداد نرون‌ها در لایه $L-1$ و L می‌باشد [۱۴]

الگوریتم بهین‌سازی و به‌روزرسانی وزن‌ها: بهین‌سازها الگوریتم‌هایی هستند که به واسطه به‌روزرسانی وزن‌ها در شبکه تلاش در جهت کم کردن تابع ضرر دارد. برای بهینه کردن مقدار وزن‌ها و بایاس در این پژوهش از الگوریتم ADAM استفاده می‌شود.

برآورد تکانه تطبیقی یا به اختصار (ADAM)، این روشی جهت محاسبه نرخ یادگیری تطبیقی برای هر پارامتر می‌باشد. این الگوریتم از مزایای الگوریتم‌های Adagrad و RMSprop استفاده می‌کند و میانگین فروپاشی نمایی از گرادیان‌های گذشته را در v_t ذخیره می‌کند. علاوه بر این ADAM، میانگین تکان‌های دوم گرادیان را در m_t ذخیره می‌کند.

m_t و v_t به ترتیب مقادیر میانگین (۳-۵) و واریانس (۳-۶) غیرمتمرکز هستند [۱۴]

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (۵-۳)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (۶-۳)$$

ADAM میانگین‌های حرکت نمایی گرادیان و گرادیان مربع را توسط معادلات (۳-۷) و (۳-۸) کنترل می‌کند [۱۴]

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t}$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t}$$

که ابرپامترهایی با مقادیر $\beta_2, \beta_1 \in [0, 1]$ است. معادله نهایی به هنگام سازی به صورت معادله (۳-۹) می باشد [۱۴]

$$w_{t+1} = w_t - \frac{\eta}{\sqrt{\hat{v}_t}} \odot \hat{m}_t$$

w_{t+1} : وزن جدید

w_t : وزن قبلی

η : نرخ یادگیری

\hat{v}_t : گرادیان مربع

\hat{m}_t : تحرک نمایی گرادیان

الگوریتم ADAM از سایر روش های تطبیقی بهتر عمل می کند و خیلی سریع همگرا می شود. همچنین بر سایر مشکلاتی که الگوریتم های بهینه سازی همانند فروپاشی نرخ یادگیری، واریانس بالا در به هنگام سازی و همگرایی آهسته غلبه کرده اند، غلبه می کند [۱۴].

۳-۳-۳ گام سوم

در این بخش مدل سازی شبکه عصبی صورت گرفته است و با مجموعه داده آزمایشی مدل را مورد آزمایش قرار می هیم و معیار پر چالش دقت را بدست می آوریم.

۳-۴ جمع بندی

در این فصل ما الگوریتم پیشنهادی خود را شرح دادیم. همانطور که گفته شد الگوریتم تجزیه و تحلیل مولفه اساسی با یادگیری عمیق (PCA-DL) [۱] با استفاده از تحلیل مولفه اساسی ویژگی های مجموعه داده را کاهش می دهد و با شبکه پرسپترون چندلایه (MLP) جهت تشخیص فعالیت نرمال از حمله مورد استفاده قرار می گیرد که با توجه به دقت بدست آمده ما الگوریتم پیشنهادی خود را که در طراحی آن تعداد لایه ها را افزایش داده ایم و از الگوریتم بهینه ADAM جهت به روزرسانی استفاده کرده ایم و در لایه اول و دوم و سوم از طراحی شبکه از تابع فعالساز RELU.LAEKY جهت جلوگیری از مرگ نرون ها استفاده شده است. بنابراین ما در گام اول کار استاندارد سازی مجموعه داده انجام دادیم و مجموعه داده را به دو قسمت جهت آموزش و آزمایش تقسیم کردیم در گام دوم کار طراحی شبکه را با در نظر گرفتن چهار لایه یکی در لایه ورودی و دو تا در لایه خروجی و یکی در لایه خروجی و مشخص کردن ابر پارامترها مثل تعداد نرون در هر لایه، الگوریتم بهینه سازی وزن ها، تابع زیان و توابع فعالساز در هر لایه انجام می دهیم و با هشتاد درصد مجموعه داده شبکه را مورد آموزش قرار داده تا مقادیر پارامترها از قبیل وزن نرون ها و بایاس را در این مرحله به

صورت بهینه مشخص شود و در انتها در گام سوم با بیست درصد دیگر از مجموعه داده شبکه مدل سازی شده را مورد
آزمون قرار می دهیم تا دقت روش پیشنهادی در این مرحله مشخص شود

۴. روش تحلیل و ارزیابی

۴-۱ مقدمه

در این فصل قصد داریم تا الگوریتم پیشنهادی خود را شبیه سازی کرده و با الگوریتم PCA-DL [۱] مورد مقایسه قرار دهیم و نتایج حاصل شده از روش خود را مورد بررسی قرار دهیم برای این کار ابتدا در محیط شبیه ساز python براساس مجموعه داده [1] NSL-KDD با تنظیم فرآیندها الگوریتم پیشنهادی خود را طراحی می کنیم پس از پیاده سازی الگوریتم را از نظر معیارهای دقت، صحت، خطا و یادآوری مورد بررسی قرار می دهیم و در انتها از لحاظ دقت با الگوریتم [1] PCA-DL مورد مقایسه قرار می دهیم.

۴-۲ روش ارزیابی

مجموعه داده [1] NSL-KDD که شامل ۴۱ ویژگی و ۱۶۰۳۶۷ رکورد است. یک مجموعه داده ایست که به منظور رفع تعدادی از مشکلات مجموعه داده KDD99 مطرح شده است که در [۳۲] ذکر شده است. این مجموعه داده شامل پنج کلاس است که یک کلاس نرمال و چهار کلاس حمله DOS^1 , $R2L^2$, $U2R^3$, $PROB^4$ است. که تعداد رکورد ها در جدول ۴-۱ مشخص شده است.

جدول ۴-۱. توزیع انواع حملات در مجموعه داده NSL-KDD [۳۳]

دسته بندی داده ها	چند کلاسه				
	نرمال	Dos	Probe	R2L	U2R
آموزشی	۶۷۳۴۳	۴۵۹۲۷	۱۱۶۵۶	۹۹۲	۵۲
آزمایشی	۹۷۱۱	۷۴۵۸	۲۴۲۱	۲۷۵۴	۲۰۰
کل	۷۷۰۵۴	۵۳۳۸۵	۱۴۰۷۷	۳۷۴۶	۲۵۲

در شکل ۴-۱ نمونه رکورد از مجموعه داده NSL-KDD نمایش داده شده است. که باید دقت داشت سه ویژگی در این مجموعه داده به صورت عددی نیست و برای قابل فهم بودن شبکه باید تبدیل به عددی شود

¹ Denial of Service

² Remote to User

³ User to Root

⁴ Probing

```

0, tcp, ftp_data, SF, 491, 0, 0, 2, 2, 0.00, 25, 0.17, 0.03, 0.1
0, udp, other, SF, 146, 0, 0, 13, 1, 0.00, 0, 0.00, 0.60, 0.88, 0
0, tcp, private, S0, 0, 0, 0, 123, 6, 1.00, 26, 0.10, 0.05, 0.00
0, tcp, http, SF, 232, 8153, 0, 5, 5, 0.20, 55, 1.00, 0.00, 0.03
0, tcp, http, SF, 199, 420, 0, 30, 32, 0.00, 255, 1.00, 0.00, 0.
0, tcp, private, REJ, 0, 0, 0, 121, 19, 0.05, 19, 0.07, 0.07, 0.
0, tcp, private, S0, 0, 0, 0, 166, 9, 1.00, 9, 0.04, 0.05, 0.00,
0, tcp, private, S0, 0, 0, 0, 117, 16, 1.00, 15, 0.06, 0.07, 0.0
0, tcp, remote_job, S0, 0, 0, 0, 270, 23, 1255, 23, 0.09, 0.05,

```

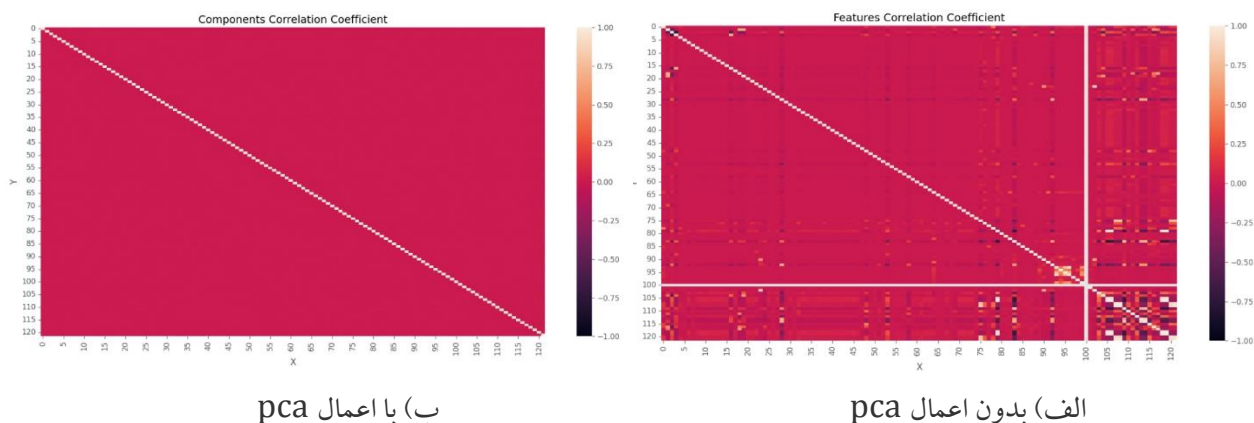
شکل ۴-۱. نمونه رکورد از مجموعه داده NSL-KDD [۳۴]

فرایند اعمال [۱] PCA که به طور کامل در قسمت ۳-۳-۱ شرح داده شد به طور خلاصه می توان گفت طی فرآیند کاهش ابعاد در مجموعه داده [۱] NSL-KDD می توان گفت روش PCA مواردی را به دنبال دارد از جمله:

- چگونگی ارتباط هر یک از متغیرها با یکدیگر به وسیله ایجاد ماتریس کوواریانس می توان پی برد.
- داده ها در چه جهاتی پراکنده هستند از طریق بردار ویژگی بدست می آید.
- مقدار اهمیت هر یک از جهات ها که با مقادیر ویژه مشخص می شود

در نهایت این روش با ادغام ویژگی ها به ما اجازه می هد بردار ویژه هایی که نسبتا کم اهمیت هستند را حذف کنیم.

در شکل ۴-۲ الف همبستگی بین ویژگی های اولیه مجموعه داده قبل از اعمال pca می باشد همانطور که مبینید شامل ۱۲۲ ویژگی است که همبستگی مناسبی بین ویژگی ها دیده نمی شود و در شکل ۴-۲ ب میزان همبستگی بین ویژگی های اعمال شده با روش pca نشان می دهد در صورتی که تنها با انتخاب یک ویژگی می توان پوشش دهی خوبی روی مجموعه داده داشته باشیم.



ب) با اعمال pca

الف) بدون اعمال pca

شکل ۴-۲. نمودار همبستگی بین ویژگی های مجموعه داده

برای سنجش میزان کارایی مدل می توان مجموعه داده را به سه قسمت داده های آموزشی و داده های اعتبارسنجی و داده های آزمایشی تقسیم کنیم. که ابتدا آموزش را در بخش بزرگی از داده ها انجام می دهیم و سپس برای سنجش میزان کارایی مدل و قابلیت تعمیم دهی آن از داده های آزمایشی استفاده می کنیم. تعمیم دهی نشان دهنده ی میزان عملکرد مدل در برخورد با داده هایی است که تاکنون مدل آنها را در فرایند آموزش مشاهده نکرده است.

جهت اجرای دقیق شبکه در محیط برنامه نویسی پایتون با پردازنده xeon2core و ROM 8 صورت می گیرد و تنظیمات ابرپارامترها در شبکه عصبی عمیق به این صورت است که از چهار لایه که شامل یک لایه ورودی و دو لایه پنهان و یک لایه آخر تشکیل شده است تعداد نرون ها در لایه ورودی همان تعداد ویژگی ها در شبکه است و به صورت برداری به شبکه تزریق می شود تعداد نرون ها در لایه پنهان اول ۸۶ و در لایه دوم ۲۵۶ و در لایه سوم ۱۲۸ در لایه آخر یعنی لایه خروجی شامل ۵ نرون می باشد. اندازه دسته ۳۲ در نظر گرفته ایم و همه ی لایه ها تماما بایکدیگر متصل هستند. تابع فعالساز برای لایه ورودی و دو لایه پردازش LeakyRelu و برای لایه خروجی softmax است. از الگوریتم بهینه ساز ADAM برای پیدا کردن وزن ها و بایاس بهینه استفاده می کنیم. در جدول ۴-۲ تنظیم مقادیر فرایارامترها درج شده است

در جهت تعیین بهینه ترین مقادیر فرایارامترهای جهت رسیدن به بهترین دقت از انواع روش های مقداردهی اولیه در مدل از قبیل تصادفی، انتقالی، یکنواخت Glorot و He که بهترین مقادیر از نظر دقت و بار محاسباتی مربوط به روش he و یکنواخت Glorot می باشد و اندازه های دسته متفاوت و همین طور دوره و نرخ یادگیری مختلف استفاده شد و با آزمون و خطا نسبت به تعداد لایه ها و تعداد نرون ها تست و اجرا از شبکه گرفتیم که در هر کدام بهینه ترین ها را انتخاب و در جدول درج کردیم.

جدول ۴-۲. تنظیم ابرپارامترها در شبکه mlp

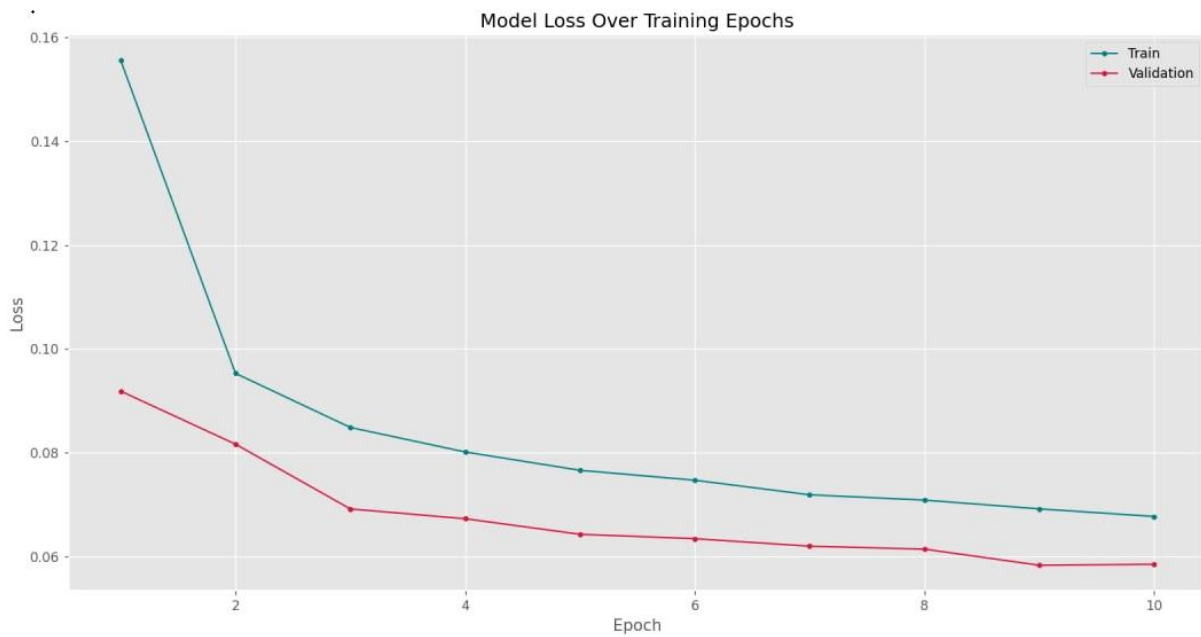
مقدار	نوع ابرپارامتر
۴	تعداد لایه
۸۶	تعداد نرون در لایه اول
۲۵۶	تعداد نرون در لایه دوم
۱۲۸	تعداد نرون در لایه سوم
۵	تعداد نرون در لایه چهارم
Leaky relu, softmax	توابع فعالساز
cross entropy	تابع زیان
adam	الگوریتم بهینه‌سازی
مقداردهی اولیه یکنواخت گلوروت	وزن‌دهی اولیه
۱۰	دوره
۶۴	اندازه دسته
۰.۰۰۰۲	نرخ یادگیری

۴-۳ تحلیل ارزیابی

در زیر به تعدادی از معیارها که با آنها می‌توان عملکرد الگوریتم‌ها را مورد بررسی قرار داد اشاره و نتایج بدست آمده حاصل از مدلسازی روش پیشنهادی مورد تحلیل قرار می‌گیرد

۴-۳-۱ خطا (Loos)

به اختلاف بین مقدار بدست آمده از مدل و مقدار واقعی خطا می‌گوییم همانطور که در نمودار ۴-۱ مشاهده می‌کنید خطا در این مدل به بعد از طی کردن ۱۰ دوره به میزان قابل توجهی کاهش یافته‌است



نمودار ۴-۱. خطا در طول آموزش مدل

۴-۳-۲ صحت (Accuracy):

تعداد پیش‌بینی‌های درست بازگردانده شده توسط مدل را می‌توان با صحت عنوان کرد. به صورت معادله در ۴-۱ نشان می‌دهیم و با نمودار ۴-۲ می‌توان نحوه عملکرد و بهبود آن را در ۱۰ دوره مشاهده کرد.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$$

(۴-۱)

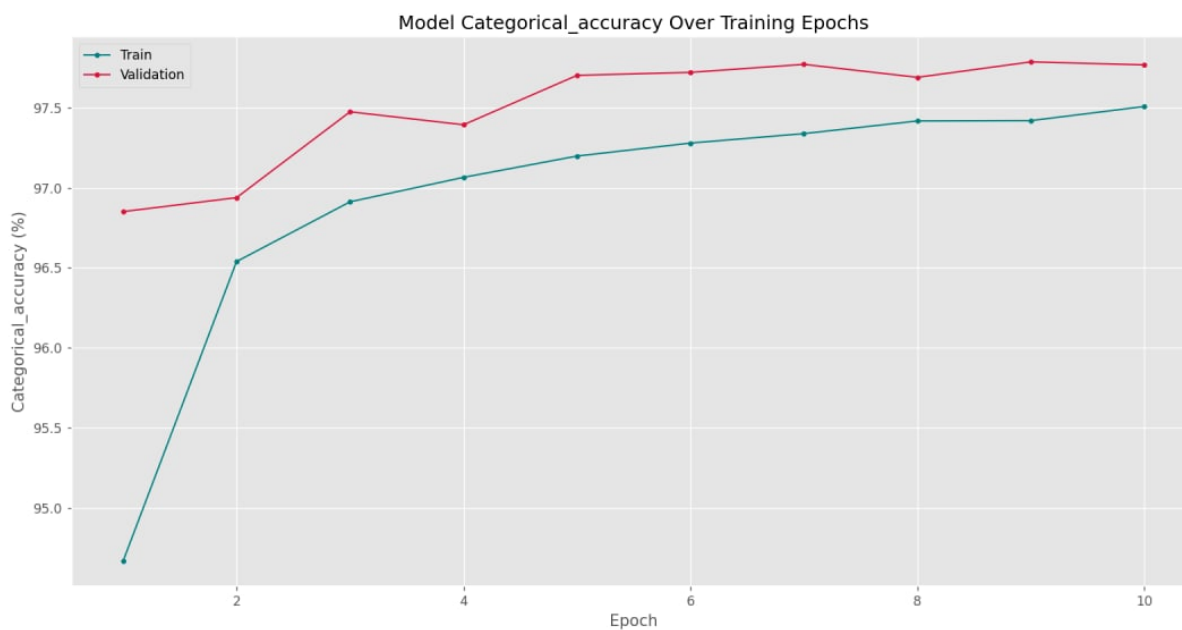
TP^۱: مثبت واقعی (پیش‌بینی‌های درست)

FP^۲: مثبت کاذب (مواردی که مدل به غلط پیش‌بینی کرده است)

FN^۳: منفی کاذب (مواردی که انتظار پیش‌بینی داشته ایم اما مدل پیش‌بینی نکرده است)

TN^۴: منفی واقعی (پیش‌بینی‌های نادرست) [۳۴]

¹ True Positive
² False Positive
³ False Negative
⁴ True Negative



نمودار ۴-۲. صحت در طول آموزش مدل

۴-۳-۴ یادآوری (Recall)

تعداد مثبت‌های برگردانده شده توسط مدل را می‌توان با عنوان یادآور (recall) یا حساسیت (sensitivity) نام برد که فرمول آن به صورت زیر می‌باشد

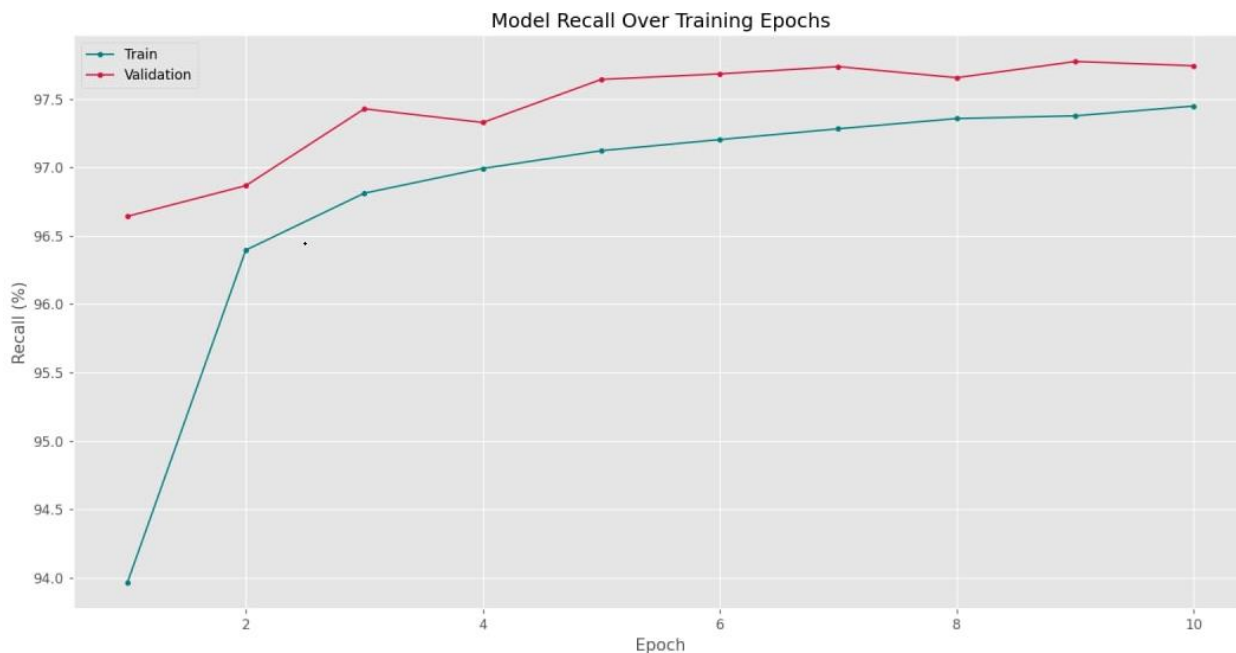
$$Recall = \frac{TP}{TP + FN}$$

(۲-۴)

TP: مثبت واقعی (پیش‌بینی‌های درست)

FN: منفی کاذب (مواردی که انتظار پیش‌بینی داشته ایم اما مدل پیش‌بینی نکرده است) [۳۴]

همانطور که در شکل ۴-۳ مشاهده می‌کنید



نمودار ۴-۳. معیار یادآوری در طول آموزش مدل

۴-۳-۴ دقت (Precisions)

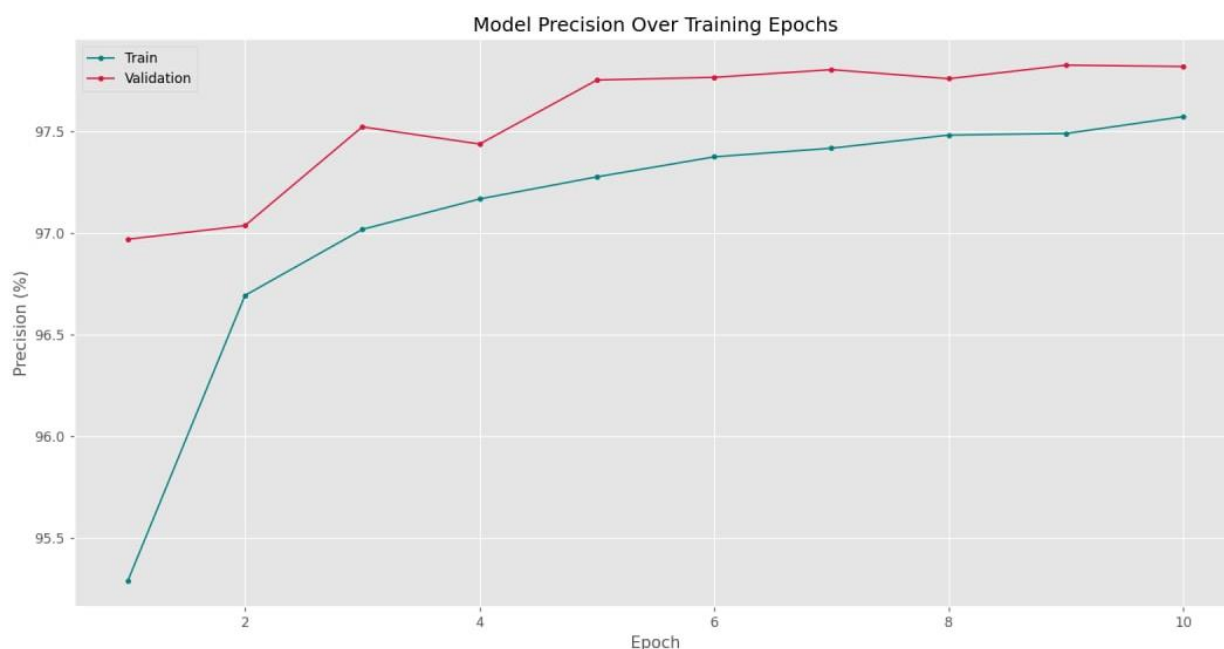
تعداد مقادیر صحیح برگردانده شده توسط مدل را می توان دقت نام برد. در واقع نرخ تشخیص هم می توان گفت که به صورت فرمولی زیر نمایش داده می شود:

$$Precisions = \frac{TP}{TP + FP} \quad (3-4)$$

TP: مثبت واقعی (پیش بینی های درست)

FP: مثبت کاذب (مواردی که مدل به غلط پیش بینی کرده است [۳۴])

همانگونه که در شکل ۴-۴ می بینید دقت



نمودار ۴-۴. نمودار دقت در طول آموزش مدل

۴-۳-۶ گزارش طبقه‌بندی

این گزارش براساس امتیاز دقت (percision)، یادآوری (recall)، پشتیبان (support) و F1-score است. پشتیبان را میتوان اینگونه تفسیر کرد در قالب تعداد نمونه‌های پاسخ صحیح که در هر کلاس از مقادیر هدف قرار می‌گیرد.

F1-SCORE: این معیار میانگین بین دو مقدار یادآوری و دقت را در نظر می‌گیرد که در بهترین حالا یک و بدترین حالت صفر می‌باشد و معیاری مناسب جهت ارزیابی دقت یک آزمایش است.

در جدول ۲-۴ و ۳-۴ و ۴-۴ گزارش طبقه‌بندی مربوط به مجموعه داده آموزش و اعتبار سنجی و آزمایش می‌باشد که به تفکیک برای هر کلاس معیارهای مختلف ارزیابی شده است که میانگین دقت (macro avg) برای مجموعه داده آموزشی و اعتبار سنجی و آزمایشی به ترتیب ۰.۹۴ درصد و ۰.۹۴ درصد و ۰.۹۳ درصد می‌باشد و همینطور معیار F1-score نیز برای سه مجموعه داده آموزش و اعتبار سنجی و آزمایش شامل ۰.۹۳ درصد است.

جدول ۴-۳. گزارش طبقه بندی برای مجموعه داده آموزش

Model Classification Report on Train Dataset				
	percision	recall	F1-score	support
0	0.98	0.98	0.98	47395
1	0.99	1.00	1.00	34870
2	0.87	0.83	0.85	3794
3	0.89	0.81	0.85	272
4	0.97	0.98	0.97	9888
accuracy			0.98	96219
Macro avg	0.94	0.92	0.93	96219
Weghted avg	0.98	0.98	0.98	96219

جدول ۴-۴. گزارش طبقه بندی برای مجموعه داده اعتبارسنجی

Model Classification Report on Validatin Dataset				
	percision	recall	F1-score	support
0	0.98	0.98	0.98	15963
1	0.99	1.00	0.99	11299
2	0.87	0.82	0.84	1399
3	0.90	0.79	0.84	87
4	0.97	0.98	0.97	3326
accuracy			0.98	32074
Macro avg	0.94	0.91	0.93	32074
Weghted avg	0.98	0.98	0.98	32074

جدول ۴-۵. گزارش طبقه بندی برای مجموعه داده آزمایش

Model Classification Report on Test Dataset				
	percision	recall	F1-score	support
0	0.98	0.98	0.98	15848
1	0.99	1.00	1.00	11558
2	0.90	0.83	0.87	1310
3	0.83	0.82	0.82	93
4	0.96	0.97	0.97	3265
accuracy			0.98	32074
Macro avg	0.93	0.92	0.93	32074
Weghted avg	0.98	0.98	0.98	32074

۴-۴ مقایسه دقت

دقت مورد مقایسه در روش پیشنهادی ما با پروسپترون ۴ لایه و روش pca-dl [۱] شامل Macro avg می باشد که در جدول ۴-۵ قابل مشاهده می باشد

Macro avg: برای محاسبه این معیار ابتدا مقدار recall یا percision را بدست می آوریم در نهایت میانگین

آن را محاسبه کرد:

$$\text{macro average recall} = \frac{\sum_{i=1}^n \text{recall}_i}{n} \quad (4-4)$$

$$\text{macro average percision} = \frac{\sum_{i=1}^n \text{percision}_i}{n} \quad (4-5)$$

جدول ۴-۶. مقایسه دقت الگوریتم pca-dl و الگوریتم پیشنهادی

نام الگوریتم	دقت
الگوریتم pca-dl	۹۲ درصد
الگوریتم پیشنهادی	۹۳ درصد

۴-۴ جمع بندی

ما در این فصل مدل پیشنهادی خود را در محیط برنامه نویسی python شبیه سازی کردیم سپس نتایج شبیه سازی را مورد نقد قرار دادیم و با الگوریتم pca-dl [۱] مورد مقایسه قرار دادیم. با توجه به نتایج بدست آمده ما توانستیم دقت را به ۹۳ درصد افزایش دهیم. تعداد نرون ها را می توان گفت در بدست آوردن مقدار بهینه دقت فرارامتر باهمیتی است. در بخش بعدی به جمع بندی و همچنین پیشنهاد کار آینده می پردازیم.

۵. نتیجه‌گیری و پیشنهاد کار آینده

۵-۱ نتیجه‌گیری

در این پایان‌نامه مسئله بهبود دقت در سیستم‌های تشخیص نفوذ مطرح شده است. با توجه به افزایش استفاده از شبکه‌ها، امنیت اطلاعات در حین رد و بدل کردن آن‌ها بسیار حائز اهمیت می‌باشد روش‌های مختلفی جهت شناسایی، تشخیص و جلوگیری ارائه شده است اما با توجه به اینکه راه‌های نفوذ در حال تغییر است و هرروزه هکرها در پی حملات جدیدی به سیستم‌ها با اهداف مختلفی هستند این حوزه نیازمند فعالیت و به‌روزرسانی می‌باشد. در فصل دوم به تعدادی از این روش‌ها از جمله الگوریتم‌های یادگیری عمیق [۱۲]، [۱۳]، [۱۶]، [۱۱] و روش‌های ترکیبی [۷] [۲۷] [۱۱] توضیح داده شد. در اکثر این روش‌ها تلاش شده تا دقت تشخیص نفوذ بهبود یابد یکی از کارای انجام شده در این زمینه [۱] می‌باشد که از روش ترکیبی `pca-dl` کاهش بعد و الگوریتم یادگیری عمیق پرسپترون چندلایه جهت افزایش دقت استفاده می‌کنیم این روش به این صورت کار می‌کند که ابتدا با `pca` یک پیش‌پردازش روی مجموعه داده `nsf-kdd` اعمال می‌کنیم و سپس با الگوریتم پرسپترون چندلایه فعالیت‌های نرمال و حمله را تشخیص می‌دهد.

در این پایان‌نامه جهت حل مسئله بهبود دقت تشخیص نفوذ از روش تحلیل مولفه‌های اساسی و در طراحی شبکه `mlp` تعداد لایه‌ها را جهت بهبود عملکرد شبکه افزایش دادیم و با چهار لایه طراحی صورت گرفت که در طراحی شبکه از الگوریتم `adam` جهت بهینه‌سازی وزن‌ها و تابع فعال‌ساز `leakly relu` جهت جلوگیری از مرگ نرون انجام داده‌ایم. ما روش پیشنهادی را به همراه تحلیل مولفه‌های اساسی و شبکه پرسپترون چهار لایه در محیط برنامه‌نویسی `python` اجرا کرده ایم با مقایسه نتایج پیاده‌سازی می‌توان دریافت که روش پیشنهادی با افزایش لایه‌های پنهان که کار پردازش را انجام می‌دهد توانستیم دقت تشخیص نفوذ را به ۹۳ درصد افزایش دهیم. این بهبود دقت نشان می‌دهد که روش پیشنهادی در مقایسه با روش [۱] عملکرد بهتری در رسیدن به افزایش دقت سیستم‌های تشخیص نفوذ داشته‌است.

۵-۲ پیشنهاد کار آینده

از آنجایی که روش پیشنهادی ما کاهش ویژگی مجموعه داده `nsf-kdd` را از طریق تحلیل مولفه‌های اساسی `pca` استخراج ویژگی صورت می‌گرفت این روش محدودیت‌هایی دارد از جمله تفسیرپذیری پایین اجزای اصلی در این روش و اجزای اصلی ترکیبی خطی از ویژگی‌های داده‌های اصلی هستند، اما تفسیر آنها به آسانی نیست از دیگر معایب آن می‌توان به مبادله بین از دست دادن اطلاعات و کاهش ابعاد اشاره کرد پیشنهاد می‌شود از دیگر روش‌های کاهش بعد برای پیش‌پردازش مجموعه داده شامل `kernel-pca` استفاده کرد. در طراحی شبکه تعداد لایه‌ها افزایش داده شد و از الگوریتم‌های بهینه `adam` در طراحی آن استفاده کردیم و انواع روش‌های مقداردهی را امتحان، پیشنهاد می‌کنیم از دیگر روش‌های یادگیری عمیق استفاده شود.

۶. منابع

- [1] H. Rajadurai and U. D. Gandhi, "An empirical model in intrusion detection systems using principal component analysis and deep learning models," *Comput. Intell.*, vol. 37, no. 3, pp. 1111–1124, 2021, doi: 10.1111/coin.12342.
- [2] M. E. Elhamahmy, H. N. Elmahdy, and I. A. Saroit, "A New Approach for Evaluating Intrusion Detection System," [1] *M. E. Elhamahmy, H. N. Elmahdy, I. A. Saroit, "A New Approach Eval. Intrusion Detect. Syst. vol. 2, no. 11, 2010.*, vol. 2, no. 11, 2010.
- [3] W. C. Lin, S. W. Ke, and C. F. Tsai, "CANN: An intrusion detection system based on combining cluster centers and nearest neighbors," *Knowledge-Based Syst.*, vol. 78, no. 1, pp. 13–21, 2015, doi: 10.1016/j.knosys.2015.01.009.
- [4] "م. لطیف, بررسی و مقایسه روش های تشخیص نفوذ در شبکه های کامپیوتری"
- [5] S. Sunita, B. J. Chandrakanta, and R. Chinmayee, "A Hybrid Approach of Intrusion Detection using ANN and FCM," *Eur. J. Adv. Eng. Technol.*, vol. 3, no. 2, pp. 6–14, 2016.
- [6] Y. Yu and N. Bian, "An Intrusion Detection Method Using Few-Shot Learning," *IEEE Access*, vol. 8, no. 1, pp. 49730–49740, 2020, doi: 10.1109/ACCESS.2020.2980136.
- [7] C. Liu, Z. Gu, and J. Wang, "A Hybrid Intrusion Detection System Based on Scalable K-Means+ Random Forest and Deep Learning," *IEEE Access*, vol. 9, pp. 75729–75740, 2021, doi: 10.1109/ACCESS.2021.3082147.
- [8] S. M. Kasongo and Y. Sun, "A Deep Learning Method With Filter Based Feature Engineering for Wireless Intrusion Detection System," *IEEE Access*, vol. 7, pp. 38597–38607, 2019, doi: 10.1109/ACCESS.2019.2905633.
- [9] R. Vinayakumar, M. Alazab, K. P. Soman, P. Poomachandran, A. Al-Nemrat, and S. Venkatraman, "Deep Learning Approach for Intelligent Intrusion Detection System," *IEEE Access*, vol. 7, pp. 41525–41550, 2019, doi: 10.1109/ACCESS.2019.2895334.
- [10] B. Singh and A. Kr Ahlawat, "Innovative Empirical Approach for Intrusion Detection Using ANN," *Int. J. Innov. Res. Comput. Sci. Technol.*, no. 4, pp. 2347–5552, 2016.
- [11] C. Xu, J. Shen, X. Du, and F. Zhang, "An Intrusion Detection System Using a Deep Neural Network with Gated Recurrent Units," *IEEE Access*, vol. 6, pp. 48697–48707, 2018, doi: 10.1109/ACCESS.2018.2867564.
- [12] M. Al-Qatf, Y. Lasheng, M. Al-Habib, and K. Al-Sabahi, "Deep Learning Approach Combining Sparse Autoencoder with SVM for Network Intrusion Detection," *IEEE Access*, vol. 6, pp. 52843–52856, 2018, doi: 10.1109/ACCESS.2018.2869577.
- [13] B. Yan and G. Han, "Effective Feature Extraction via Stacked Sparse Autoencoder to Improve Intrusion Detection System," *IEEE Access*, vol. 6, pp. 41238–41248, 2018, doi: 10.1109/ACCESS.2018.2858277.
- [14] م. وزان, یادگیری عمیق: اصول, مفاهیم و رویکردها, چاپ اول. تهران: ميعاد اندیشه, ۲۰۲۱.
- [15] "Wknn. استنادرحيمي, "تشخيص نفوذ در شبکه بر اساس روش"
- [16] Y. Al-Nashif, A. A. Kumar, S. Hariri, G. Qu, Y. Luo, and F. Szidarovsky, "Multi-level intrusion detection system (ML-IDS)," *5th Int. Conf. Auton. Comput. ICAC 2008*, pp. 131–140, 2008, doi: 10.1109/ICAC.2008.25.
- [17] M. Ahmed, A. Naser Mahmood, and J. Hu, "A survey of network anomaly detection techniques," *J. Netw. Comput. Appl.*, vol. 60, pp. 19–31, 2016, doi: 10.1016/j.jnca.2015.11.016.
- [18] ز. استنادرحيمي, "تشخيص نفوذ در شبکه بر اساس روش" Wknn.
- [19] ه. د. م. ه. مارک, طراحی شبکه های عصبی. .
- [20] S. Rajagopal, P. P. Kundapur, and K. S. Hareesha, "A Stacking Ensemble for Network Intrusion Detection Using Heterogeneous Datasets," *Secur. Commun. Networks*, vol. 2020, 2020, doi: 10.1155/2020/4586875.
- [21] N. Thapa, Z. Liu, D. B. Kc, B. Gokaraju, and K. Roy, "Comparison of machine learning and deep learning models for network intrusion detection systems," *Futur. Internet*, vol. 12, no. 10, pp. 1–16, 2020, doi: 10.3390/fi12100167.

- [22] J. Zhang, F. Li, H. Zhang, R. Li, and Y. Li, "Intrusion detection system using deep learning for in-vehicle security," *Ad Hoc Networks*, vol. 95, p. 101974, 2019, doi: 10.1016/j.adhoc.2019.101974.
- [23] M. A. Ferrag, L. Maglaras, S. Moschoyiannis, and H. Janicke, "Deep learning for cyber security intrusion detection: Approaches, datasets, and comparative study," *J. Inf. Secur. Appl.*, vol. 50, p. 102419, 2020, doi: 10.1016/j.jisa.2019.102419.
- [24] S. U. Jan, S. Ahmed, V. Shakhov, and I. Koo, "Toward a Lightweight Intrusion Detection System for the Internet of Things," *IEEE Access*, vol. 7, pp. 42450–42471, 2019, doi: 10.1109/ACCESS.2019.2907965.
- [25] H. Pajouh and A. Choo, "A two-layer dimension reduction and two-tier classification model for anomaly-based intrusion detection in IoT backbone networks Title A two-layer dimension reduction and two-tier classification model for anomaly-based intrusion detection in IoT backbon," *Ieeexplore.Ieee.Org*, 2016, [Online]. Available: <https://ieeexplore.ieee.org/abstract/document/7762123/>.
- [26] H. Yao, D. Fu, P. Zhang, M. Li, and Y. Liu, "MSML: A novel multilevel semi-supervised machine learning framework for intrusion detection system," *IEEE Internet Things J.*, vol. 6, no. 2, pp. 1949–1959, 2019, doi: 10.1109/JIOT.2018.2873125.
- [27] F. Salo, A. B. Nassif, and A. Essex, "Dimensionality reduction with IG-PCA and ensemble classifier for network intrusion detection," *Comput. Networks*, vol. 148, no. November, pp. 164–175, 2019, doi: 10.1016/j.comnet.2018.11.010.
- [28] S. M. Kasongo and Y. Sun, "A deep learning method with wrapper based feature extraction for wireless intrusion detection system," *Comput. Secur.*, vol. 92, p. 101752, 2020, doi: 10.1016/j.cose.2020.101752.
- [29] A. Yulianto, P. Sukarno, and N. A. Suwastika, "Improving AdaBoost-based Intrusion Detection System (IDS) Performance on CIC IDS 2017 Dataset," *J. Phys. Conf. Ser.*, vol. 1192, no. 1, 2019, doi: 10.1088/1742-6596/1192/1/012018.
- [30] M. Haggag, M. M. Tantawy, and M. M. S. El-Soudani, "Implementing a deep learning model for intrusion detection on apache spark platform," *IEEE Access*, vol. 8, no. D1, pp. 163660–163672, 2020, doi: 10.1109/ACCESS.2020.3019931.
- [31] D. J. Bartholomew, "Principal components analysis," *Int. Encycl. Educ.*, pp. 374–377, 2010, doi: 10.1016/B978-0-08-044894-7.01358-0.
- [32] M. Tavallaee, E. Bagheri, W. Lu, and A. A. Ghorbani, "A Detailed Analysis of the KDD CUP 99 Data Set," no. Cisd, pp. 1–6, 2009.
- [33] س. پوستفروشان and م. آ. صرام, "به کارگیری الگوریتم بهینه سازی Pso به منظور بهبود طول عمر شبکه های حسگر بیسیم," *مجله علمی رایانش نرم و فناوری اطلاعات*, vol. 5, no. 3, pp. 55–64, 2016, [Online]. Available: http://jscit.nit.ac.ir/article_51679.html%0Ahttp://jscit.nit.ac.ir/article_51679_90b6a5fc53f91219539365dc1f843f6e.pdf.
- [34] Q. A. Al-Hajja and S. Zein-Sabatto, "An efficient deep-learning-based detection and classification system for cyber-attacks in iot communication networks," *Electron.*, vol. 9, no. 12, pp. 1–26, 2020, doi: 10.3390/electronics9122152.

Abstract

One of the important issues with regard to the widespread use of computer networks is cyber attacks and the discussion of security in these networks and databases. Penetration into computer networks with various motives including political, military, financial or showing laxity and weakness in security in There are existing programs that other common techniques become ineffective due to the volume and new malicious features that are increasing exponentially, and traditional methods are not able to maintain security. As a result, intrusion detection systems are used to detect threats and identify attacks from both sides. It has been introduced that it is a tool used to provide communication in information systems, whose main purpose is not to prevent attacks, but to identify attacks and learn their behavior patterns is one of the tasks of this system. One of the most challenging issues in these systems is accuracy, which has attracted the attention of researchers in this field, and with the improvement of accuracy in these systems, the efficiency also increases.

In order to improve the accuracy of intrusion detection systems, several methods have been presented, but there is still a need for research and study in the field of accuracy. In this thesis, a method to solve the problem of accuracy by reducing the dimensions of the NSL-KDD data set with principal component analysis (PCA) which effectively affects the improvement of data processing speed through feature extraction and the use of multi-layer propstern networks, which is one of the learning methods It is deep (DL) by increasing the number of hidden layers from one layer [1] to two hidden layers, which the architecture of this four-layer proceptron (MLP) includes one input layer, two hidden layers and one output layer, causes more efficient learning in these networks and We are trying to improve the accuracy of intrusion detection in this network with the optimal ADAM algorithm and the selection of the LEAKY RELU activator function. The proposed method has been implemented in the Python simulator and compared with the latest works. The proposed method shows that the accuracy for identifying 5 classes in the NSL-KDD dataset has increased to 93%, which shows the greater efficiency of the proposed method compared to the work done.

Key words: Intrusion Detection System (IDS), Deep Learning (DL), Multilayer Proceptron (MLP), ADAM Algorithm, Principal Component Analysis (PCA), NSL-KDD Dataset, Accuracy



Salman Higher Education Institute
Faculty of Engineering

Master's thesis in the field of computer engineering, majoring in computer networks

Improving the accuracy of intrusion detection in the network with the help of deep learning with ADAM optimal algorithm and LEAKY RELU activation function

by
Maryam Mahdavi

Supervisor
Mr. Dr. Seyed Reza Kamel Tabakh Farizani

September2022