

سیستم تشخیص نفوذ در شبکه های نرم افزار محور

با استفاده از شبکه های عصبی عمیق

سمیه جعفری هرستانی^۱، سید امین حسینی سنو^۲

^۱دانشجوی کارشناسی ارشد، گروه مهندسی کامپیوتر، دانشگاه فردوسی مشهد، مشهد، ایران. Somayeh_mz@yahoo.com

^۲دانشیار گروه مهندسی کامپیوتر، دانشگاه فردوسی مشهد، مشهد، ایران. Hosseini@um.ac.ir

چکیده: در شبکه های کامپیوتری، سیستم های تشخیص نفوذ، ابزاری مفید برای نظارت بر فرآیندهای شبکه و اعلام تهدیدهای احتمالی بوده و معرفی یک سیستم با دقت و صحت بالا برای تشخیص نفوذ از غیر نفوذ، امری حیاتی برای شبکه محسوب می شود.

اما چارچوب کلی تمام راه حل های پیشنهادی برای حل مسئله تشخیص نفوذ، استفاده از طبقه بندی متن است و امروزه شبکه های عصبی عمیق، از برترین طبقه بندیها به شمار می آیند. بر این اساس، راهکار پیشنهادی این پژوهش، ارائه یک سیستم تشخیص نفوذ، در شبکه های نرم افزار محور، با استفاده از شبکه های عصبی عمیق می باشد. شبکه عصبی عمیق طراحی شده، مدلی با چیدمان ۱۲ لایه بوده و روی دو مجموعه داده جمع آوری شده از شبکه های نرم افزار محور، به نام های NSL-KDD و KDD99 به کار گرفته شده است. لازم به ذکر است، که چیدمان لایه ای منحصر به فرد مدل پیشنهادی برای هر دو مجموعه داده تغییر نکرده، که این از نقاط قوت مدل به شمار می رود. اما برای ارزیابی راهکار پیشنهادی، ۶ مدل شبکه عصبی دیگر طراحی و مقادیر معیارهای ارزیابی از جمله صحت، دقت، فراخوانی، معیار F و تابع زیان، در هر یک مورد بررسی قرار گرفته است. همچنین همه معیارها با مقاله وینیاکومار ۲۰۱۹، بهترین مقاله این حوزه، مقایسه شده و برتری راهکار پیشنهادی و بهبود همه نتایج نشان داده شده است. برای پیاده سازی راهکار پیشنهادی نیز، از بسته یادگیری عمیق تنسور فلو، کراس و زبان برنامه نویسی پایتون ۳، روی ابزار گوگل کولب بهره گرفته شده است.

کلمات کلیدی: سیستم تشخیص نفوذ، شبکه عصبی عمیق، شبکه نرم افزار محور، یادگیری عمیق، تشخیص ناهنجاری.

۱ مقدمه و کلیات پژوهش

نداشتن احتمالاً کارکردی خوب روی مجموعه داده های دیگر، بزرگتر و جدیدتر باشد. همچنین، بعضی از مقالات نیز مقادیر معیارهای گزارش داده خود را با کلاس بندهای ساده و معمولی مقایسه کرده و برتری خود را اینگونه سنجیده و اعلام داشته اند، که واضح است، این مقایسه از سطح خوب و کیفیت لازم برخوردار نمی باشد. به این ترتیب، با توجه به چالش های مطرح شده، هدف این پژوهش ارائه راهکاری مناسب برای تشخیص نفوذ، در شبکه های نرم افزار محور، با استفاده از شبکه های عصبی عمیق می باشد. در ادامه پیشینه ای از پژوهش جاری مطرح شده، راهکار پیشنهادی را شرح می دهیم و در انتها هم به ارزیابی و نتیجه گیری از پژوهش خواهیم پرداخت.

در تولید سیستم های کامپیوتری وجود ضعف امنیتی قابل چشم پوشی نیست و بر این اساس بررسی زمینه های مختلف تشخیص نفوذ در این سیستم ها دارای اهمیت می باشد. یک سیستم تشخیص نفوذ (IDS)، به صورت سخت افزاری و نرم افزاری قابل ارائه می باشد و عملکرد آن نظارت بر جریان ها و فعالیت های کل شبکه یا کامپیوتر میزبان بوده و اگر نقض سیاست های مدیریتی و امنیتی را تشخیص دهد، به مدیر شبکه گزارش خواهد داد [۳۰،۱۹،۱۱،۳،۲،۱].

در مقوله یادگیری ماشین، شبکه های عصبی، از پرکاربردترین طبقه بندیها هستند. این شبکه ها تکنیک های محاسباتی پیشرفته ای بوده که در بازنمایی دانش دریافتی و اعمال این دانش در جهت اعلام پیش بینی های مورد نیاز خروجی و تخمین توابع پیچیده ریاضی بسیار مورد استفاده قرار می گیرند. یادگیری عمیق (ژرف) [۲]، نیز یکی از زیر مجموعه های یادگیری ماشین بوده و از محبوب ترین و داغ ترین علوم حوزه هوش مصنوعی می باشد، که در آن شبکه سعی می کند داده ها را به کمک لایه های مخفی، از یک سطح به سطحی دیگر نگاشت کند، به گونه ای که بتوان به کمک یک خط، داده ها را از هم تفکیک کرد و روی آن ها طبقه بندی انجام داد. اما یادگیری عمیق یک مسئله کلاس بندی است. یعنی معمولاً در آن روی یک مسئله که ذاتاً بر پایه سیستم نظارت شده هست، تمرکز می شود و مجموعه داده های جمع آوری شده روی شبکه های نرم افزار محور (SDN) [۳] مثل NSL-KDD^۴، KDD99، UNSW-Kyoto، NB15، ISCX^{۱۴} و... در واقع مسئله کلاس بندی را توضیح داده اند، به این صورت که یک کلاس با عنوان Y و چندین ویژگی با عنوان X در آن ها آورده شده است. بر این اساس، سیستم پیشنهادی این پژوهش نیز بر پایه شبکه های نرم افزار محور انتخاب و ارائه شده است.

طی سال های اخیر، با به کارگیری تکنیک های مختلف نام برده شده، راهکارهای متعددی برای مسئله تشخیص نفوذ پیشنهاد شده است [۵۱-۹]، اما هر کدام از آن ها چالش ها و مشکلاتی به همراه داشته اند. به عنوان مثال اکثر پژوهش ها نرخ صحت خوبی گزارش داده اند، ولی معیارهای دیگر از جمله دقت، فراخوانی و... را گزارش نکرده اند، که این امر می تواند حاکی از آن باشد که احتمالاً مقادیر پایینی در این موارد به دست آورده اند. یا اینکه برخی پژوهش ها معیارهای دیگر هم گزارش کرده اند، ولی مقادیر بسیار پایینی می باشد. از چالش های دیگر راهکار پیشنهادی پژوهش ها، کار کردن روی فقط یک مجموعه داده می باشد، که یکی از دلایل این امر نیز می تواند

۲ مبانی نظری و پیشینه پژوهش

۲-۱ شبکه های نرم افزار محور (SDN)

این روزها نیز نوعی از شبکه ها گسترش پیدا کرده، که به شبکه های نرم افزار محور (SDN) معروف می باشد. به کمک شبکه های نرم افزار محور، مدیریتی آسان، منعطف و یکپارچه خواهیم داشت و اگر در ساختار شبکه تغییر یا ناهنجاری احتمالی رخ دهد، می توان به سرعت و در لحظه آن را تشخیص داده، مدیریت کرده و امنیت و پایداری شبکه را به خوبی تضمین نمود.

همچنین امروزه شبکه های بسیار زیادی وجود دارند، از جمله VANET، WSN، SDN، MPLS... که هر کدام مجموعه داده های مختلفی مختص به خود دارند و اکثر آنها روش، مدل و سیستم تشخیص نفوذ برای هر یک به صورت اختصاصی می باشد. به این ترتیب، ما نیز در این پژوهش سعی کردیم، روی مجموعه داده های مختص شبکه های نرم افزار محور (SDN) مثل NSL-KDD و KDD99 تمرکز کنیم. در ادامه به بررسی پژوهش های پیشین انجام شده روی تکنیک های مرتبط با پژوهش جاری خواهیم پرداخت.

۲-۲ پژوهش های پیشین

در این بخش پژوهش های پیشین را دسته بندی کرده و طی دو مبحث آن ها را ذکر می کنیم: (۱) مبحث پژوهش های انجام شده روی معماری های کم عمق و (۲) مبحث پژوهش های انجام شده روی معماری های عمیق.

جدول (۱)، پژوهش‌هایی که تکنیک تشخیص نفوذ خود را مبنی بر معماری‌های عمقی مانند: الگوریتم‌های ماشین بردار پشتیبان (SVM)، درخت تصمیم (DT)، جنگل‌های تصادفی (RF)، خوشه بندی (Clustering)، K امین نزدیک ترین همسایه (KNN)، بهینه سازی اجتماع ذرات (PSO)، شبیه سازی ذوب (SA)، شبکه‌های عصبی مصنوعی (ANN) و روش‌های Ensemble (جمععی) قرار داده اند [۴۵، ۱۸، ۱۵، ۱۴، ۱۲، ۱۱، ۱۰، ۶، ۵]. آورده شده و برتری‌ها و چالش‌های این دسته ذکر شده است:

جدول ۱: برتری‌ها و چالش‌های پژوهش‌های انجام شده روی معماری‌های کم عمق

معایب و چالش‌ها	مزایا و برتری‌ها	پژوهش‌های انجام شده روی معماری‌های کم عمق
<ul style="list-style-type: none"> گزارش فقط یک معیار صحت با دقت و عدم ارائه معیارهای دیگر به کارگیری فقط یک مجموعه داده برای ارزیابی مقایسه نتایج فقط با کلاس بندهای معمولی 	<ul style="list-style-type: none"> استفاده از مزیت‌های الگوریتم‌های کم عمق گزارش فاکتورهای صحت یا دقت تشخیص خوب 	<p>]</p> <p>۴۵، ۱۸، ۱۵، ۱۴، ۱۲</p> <p>[۱۱، ۱۰، ۶، ۵]</p>

اما پژوهش‌های انجام شده روی معماری‌های عمیق نیز در جدول (۲)، به صورت جداگانه دسته بندی شده و برتری‌ها و چالش‌های دسته‌ها نیز به ترتیب بیان شده است:

جدول ۲: برتری‌ها و چالش‌های پژوهش‌های انجام شده روی معماری‌های عمیق

معایب و چالش‌ها	مزایا و برتری‌ها	مراجع	دسته پژوهش‌های انجام شده روی تکنیک‌های CNN
<ul style="list-style-type: none"> گزارش یک یا دو معیار ارزیابی به کارگیری فقط یک مجموعه داده برای ارزیابی مقایسه نتایج با کلاس بندهای ساده و معمولی 	<ul style="list-style-type: none"> استفاده از تکنیکی خوب برای تشخیص و آماده سازی داده‌ها در برخی مقالات استفاده از لایه‌های کم و در نتیجه داشتن سرعت پردازش بالاتر و در نهایت ارائه میزان صحتی قابل قبول 	<p>۳۶، ۳۴]</p> <p>[۲۶، ۲۵، ۱۶]</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های CNN
<ul style="list-style-type: none"> استفاده از لایه‌های زیاد و نیاز به پردازش‌های فراوان به کارگیری مجموعه داده متفاوت که در مقالات اندکی استفاده شده گزارش فقط یک یا دو معیار ارزیابی 	<ul style="list-style-type: none"> بهره‌گیری از RNN های Gate دار ارائه میزان صحت بالا 	<p>]</p> <p>۲۲، ۳۹، ۳۱</p> <p>[۱۳]</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های RNN و یا GRU-RNN
<ul style="list-style-type: none"> گزارش نرخ صحت نسبتاً پایین به کارگیری فقط یک مجموعه داده 	<ul style="list-style-type: none"> استفاده از حافظه‌های کوتاه مدت شبکه‌های LSTM 	<p>[۳۲]</p>	دسته پژوهش‌های انجام شده روی تکنیک LSTM
<ul style="list-style-type: none"> استفاده از مجموعه داده‌ای خاص استفاده از کلاس بندی فقط باینری 	<ul style="list-style-type: none"> شرح بسیار خوب معماری و مدل تکنیک برخی مقالات 	<p>[۴۱، ۲۲]</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های CNN+RNN
<ul style="list-style-type: none"> به کارگیری فقط یک مجموعه داده برای ارزیابی به کارگیری مجموعه داده‌ای خاص 	<ul style="list-style-type: none"> به دست آوردن نرخ صحت بالا روی مجموعه داده انتخابی استفاده از حافظه‌های کوتاه مدت LSTM 	<p>]</p> <p>۴۰، ۲۱، ۱۷</p> <p>[</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های CNN+LSTM
<ul style="list-style-type: none"> گزارش یک معیار ارزیابی و عدم ارائه معیارهای دیگر 	<ul style="list-style-type: none"> استفاده از متدی هوشمند برای تشخیص حمله 	<p>[۳۰]</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های RNN+LSTM
<ul style="list-style-type: none"> استفاده از فقط یک مجموعه داده فقط مقایسه با کلاس بندهای معمولی ارائه نرخ متوسطی برای اکثر معیارها 	<ul style="list-style-type: none"> ارائه چهارچوبی همه جانبه گزارش صحت خوب و قابل قبول 	<p>۳۸، ۳۷]</p> <p>۳۵، ۲۹،</p> <p>[۲۷، ۲۳،</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های Auto Encoder
<ul style="list-style-type: none"> ذکر نکردن چیدمان لایه‌ها فقط استفاده از کلاس بندی باینری مقایسه نتایج با کلاس بندهای ساده و معمولی 	<ul style="list-style-type: none"> دستیابی به نرخ بالای صحت در اکثر مقالات این دسته استفاده از چندین مجموعه داده استفاده از لایه‌های معمولی که نیاز به پردازش زیادی ندارد و در نتیجه افزایش سرعت محاسبات 	<p>]</p> <p>۵۱، ۴۶، ۴۴،</p> <p>۴۳، ۲۴</p> <p>[۱۹، ۲۰،</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های DNN
<ul style="list-style-type: none"> فقط گزارش معیار صحت آزمایش فقط بر روی یک مجموعه داده پردازش‌های بیشتر به دلیل استفاده از کلاس‌بند‌های زیاد 	<ul style="list-style-type: none"> استفاده از تکنیک‌های Ensemble برای بهبود نرخ صحت استفاده از رای اکثریت به عنوان یک تصمیم‌گیرنده نهایی 	<p>]</p> <p>۵۰، ۴۹، ۴۸،</p> <p>۴۷، ۴۵</p> <p>۳۳، ۲۸،</p> <p>[۱۸]</p>	دسته پژوهش‌های انجام شده روی تکنیک‌های Ensemble

به این ترتیب و با توجه به راهکارهای مختلفی که در پژوهش‌های مذکور مطرح شده، ارائه مدل و چیدمان لایه‌ای منحصراً به فرد این پژوهش به کمک شبکه‌های عصبی عمیق (DNN)، برای مسئله تشخیص نفوذ در شبکه‌های نرم افزار محور (SDN)، نوآوری پژوهش جاری محسوب می‌شود و نمونه‌ی ترکیب و توالی لایه‌ها و چیدمان مدل DNN طراحی شده، در هیچ یک از پژوهش‌های پیشین مشاهده نشده است.

۳ راهکار پیشنهادی

در مدل و راهکار پیشنهادی، از یک شبکه عصبی عمیق منحصراً به فرد ۱۲ لایه برای هر دو مجموعه داده استفاده شده است. ترکیب لایه‌ها در این شبکه ۱۲ لایه به این صورت می‌باشد: لایه Dense، لایه Dense، لایه فعال ساز، لایه حذف تصادفی، لایه Dense، لایه فعال ساز، لایه حذف تصادفی، لایه Dense، لایه فعال ساز یا همان لایه کاملاً متصل (Fully Connected-FC) که بر حسب تعداد خروجی کلاس‌ها از توابع سافت مکس (Softmax) یا تانژانت هیپربولیک (Tanh) برای انتخاب کلاس متناسب، مورد استفاده قرار گرفته است. لازم به ذکر است، که معماری و چیدمان لایه‌ای مدل DNN پیشنهادی برای هر دو مجموعه داده، ۱۲ لایه بوده، که این از نقاط قوت مدل و راهکار پیشنهادی به شمار می‌رود. در واقع مدل پیشنهادی توانسته بدون تغییر تعداد و چیدمان لایه‌ها روی دو مجموعه داده مقادیر معیارهای ارزیابی را بهبود داده و بسیار خوب عمل کند.

اما در مورد لایه‌های مدل پیشنهادی باید عنوان کرد، که مقادیر لایه‌های Dense، با ورودی هر مجموعه داده (به تعداد ویژگی‌های هر مجموعه داده) متفاوت بوده و تابع فعال سازی را نیز یکی از بهترین توابع آزمایش شده برای شبکه عصبی، یعنی تابع غیر خطی Relu قرار داده ایم. در مدل پیشنهادی بعد از هر لایه Dense یک لایه Drop out با مقادیر ۰.۱۵ تا ۰.۵ در نظر گرفته شده، که در اصل لایه حذف تصادفی (Drop out)، به صورت اتفاقی برخی از نورون‌ها را حذف و رها کرده و از Overfit شدن شبکه جلوگیری می‌کند و لایه آخر که یک لایه کاملاً متصل (بر خلاف یک لایه Dense) می‌باشد، لایه‌ای است که به همه نورون‌های لایه قبل متصل می‌شود. در واقع این لایه، ورودی لایه قبلی را به عنوان یک پارامتر در نظر گرفته و تعداد کلاس‌ها را برای پیش بینی (برای هر مجموعه داده بر حسب تعداد خروجی) به کمک یک تابع فعال ساز، یعنی به وسیله یک تابع Softmax و یا Tanh بر روی شبکه اعمال می‌کند. لازم به ذکر است که، در بسته تنسورفلو به صورت پیش فرض تمامی بهینه‌سازها و توابع هزینه (زیان) تعریف شده‌اند و کافی است فراخوانی شده و مقداردهی شوند. در این پژوهش، بهینه‌ساز Adam، بنا به شرایط دو مجموعه داده مورد استفاده در تشخیص نفوذ، با نرخ یادگیری متفاوت و محبوب ترین تابع هزینه یعنی Cross Entropy، به کار گرفته شده است.

۴ ارزیابی راهکار پیشنهادی

۱-۴ معیارهای ارزیابی

مهم‌ترین و پرکاربردترین معیارهایی که تاکنون برای ارزیابی کیفیت نتایج روش‌های تشخیص نفوذ مورد استفاده قرار گرفته - اند [۵۱، ۴۸، ۴۷، ۳۷، ۳۱، ۳۰، ۲۹، ۲۲، ۲۱، ۱۸، ۱۵، ۱۳، ۱۰، ۷، ۶، ۵]، عبارتند از: (۱) صحت (۲) دقت (۳) فراخوانی، (۴) معیار F_۱ و (۵) تابع خطا یا زیان. در ابتدا لازم است، چهار اصطلاح پایه مورد استفاده در معیارهای مذکور را تعریف کنیم [۸]:

مثبت حقیقی " TP: بیانگر تعداد رکوردهای اتصالی که به طور صحیح در کلاس نرمال طبقه بندی شده‌اند.

منفی حقیقی " TN: بیانگر تعداد رکوردهای اتصالی که به طور صحیح در کلاس حمله طبقه بندی شده‌اند.

مثبت کاذب " FP: بیانگر تعداد رکوردهای اتصال حمله‌ای که به طور اشتباه در رکوردهای اتصال نرمال طبقه بندی شده‌اند.

منفی کاذب " FN: بیانگر تعداد رکوردهای اتصال نرمالی که به طور اشتباه در رکوردهای اتصال حمله طبقه بندی شده‌اند.

در ادامه به توضیح کاربرد این اصطلاحات پایه در معیارهای ارزیابی مذکور می‌پردازیم. صحت: این معیار نسبت رکوردهای اتصال درست تشخیص داده شده را به کل رکوردهای مجموعه داده مورد آزمایش تخمین می‌زند. به عبارت دیگر، معیار صحت، نشان می‌دهد

که چند درصد از داده ها درست دسته بندی شده اند، که این رابطه در ادامه آورده شده است:

$$Accuracy = \frac{TP+TN}{TP+FP+TN+FN} \quad \text{رابطه ۱}$$

دقت: این معیار نسبت رکوردهای اتصال حمله درست شناسایی شده، به تعداد کل رکوردهای اتصال حمله شناسایی شده را تخمین می زند، به عبارت دیگر، نسبت تعداد رکوردهای بازبایی شده مرتبط به تعداد کل رکوردهای بازبایی شده را به دست می آورد، که این رابطه نیز در ادامه آورده شده است:

$$Precision = \frac{TP}{TP+FP} \quad \text{رابطه ۲}$$

فراخوانی: این معیار، نسبت رکوردهای اتصال حمله که به طور صحیح طبقه بندی شده را به تعداد کل رکوردهای اتصال حمله تخمین می زند. به عبارت دیگر، نسبت تعداد رکوردهای بازبایی شده مرتبط به تعداد کل رکوردهای مرتبط واقعی در مجموعه داده را به دست می آورد، که این معیار را به نام نرخ تشخیص (Detection Rate-DR) یا نسبت مثبت حقیقی (TP Rate) نیز می شناسند [۱۳].

$$Recall = \frac{TP}{TP+FN} \quad \text{رابطه ۳}$$

معیار F: این معیار (که F-Score نیز نامیده می شود)، ترکیبی از (سازگار با) معیارهای فراخوانی و دقت است و سعی می کند trade off بین معیارهای دقت و فراخوانی برقرار کرده و نمایش دهد و در نتیجه به این معیار، میانگین هارمونیک نیز گفته می شود. در واقع هر چه این معیار بالاتر باشد، مدل یادگیری ماشین بهتری داریم، که از طریق این فرمول قابل محاسبه می باشد:

$$F - Score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad \text{رابطه ۴}$$

همچنین معیار دیگری نیز می توان در ارزیابی ها مدنظر قرار داد، که همان تابع زیان (Loss Function) است [۴۲،۲۰] و در واقع هزینه اینکه چقدر خروجی خطا دارد، را نشان می دهد و با بهینه کردن آن می توانیم به جواب های خوبی برسیم.

۲-۴ مجموعه داده های مورد استفاده در این پژوهش

در این پژوهش از دو مجموعه داده جمع آوری شده از شبکه های نرم افزار محور، برای مقایسه راهکار پیشنهادی با دیگر روش ها، از جمله مقاله پایه وینیاکومار [۱۹]۲۰۱۹ استفاده شده است که به نام های NSL-KDD و KDD۹۹ می باشند. مجموعه داده NSL-KDD، از پرکاربردترین مجموعه داده های مرتبط با سیستم های تشخیص نفوذ می باشد، که از شبکه های نرم افزار محور جمع آوری شده و در واقع برای حل بعضی از مشکلات مجموعه داده KDD۹۹ پیشنهاد شده است. لازم به ذکر است که در این پژوهش از آخرین نسخه این مجموعه داده با ۲۳ کلاس استفاده شده است [۷]. مجموعه داده KDD۹۹ نیز، از مجموعه داده های قدیمی شبکه های نرم افزار محور با ۴۱ کلاس بوده و در واقع الگویی است که قادر به تفکیک اتصالات "بد" با نام نفوذ یا حمله و اتصالات "خوب" با نام نرمال می باشد.

۳-۴ ابزارهای مورد استفاده برای پیاده سازی راهکار پیشنهادی

به منظور پیاده سازی راهکار پیشنهادی پژوهش، نرم افزار Jupyter Notebook به عنوان محیط توسعه و کدنویسی برای این پژوهش مورد استفاده قرار گرفته و این نرم افزار، روی ابزار رایگان Google Colaboratory^{۱۵} به صورت پیش فرض نصب می باشد. امروزه محبوب ترین و شاید بتوان گفت، تنها زبان برنامه نویسی برای یادگیری عمیق، زبان برنامه نویسی پایتون (Python) می باشد، یعنی هر دو مجموعه داده معرفی شده در این پژوهش، با استفاده از لینک گیتهاب در زبان پایتون دانلود شده، مورد بررسی قرار گرفته و پیاده سازی آن بر روی بسته یادگیری عمیق تنسورفلو (Tensorflow) [۴] با پشتیبانی کراس (Keras)، روی GPU های قدرتمند ابزار گوگل کولب (با توجه به محاسبات بسیار زیاد لایه های شبکه عصبی عمیق)، انجام می شود.

۴-۴ ارزیابی راهکار پیشنهادی این پژوهش

اما پژوهش های انجام شده در این حوزه، نتایج ارزیابی روش خود را با استفاده از معیارهای ارزیابی، با نتایج ارائه شده از پژوهش های معتبر موجود در حوزه مقایسه می کنند. در این میان، ما نیز نتایج پژوهش خود را با پژوهش ۲۰۱۹ وینیاکومار [۱۹]

مقایسه خواهیم کرد. به این ترتیب، در این پژوهش، ابتدا ۶ مدل شبکه عصبی دیگر برای انجام مقایسه روی هر دو مجموعه داده، طبق جدول (۳) طراحی شده و در ادامه، هر ۷ مدل با شرایط یکسان، مورد ارزیابی و بررسی قرار می گیرند.

جدول ۳: مقایسه مدل راهکار پیشنهادی با ۶ مدل شبکه عصبی دیگر

مدل پیشنهادی	مدل اول	مدل دوم	مدل سوم	مدل چهارم	مدل پنجم	مدل ششم
۱-دقت	Dense(۱۸)	Embedding	Embedding	Dense(۱۸)	Embedding	Dense(۱۴)
۲-دقت	Dense(۱۴)	Dropout	Dropout	Dense(۱۴)	Dropout	Dense(۴)
۳-دقت	Dense(۱۸)	Conv(۲*۶)	Conv(۳)	Dense(۱۸)	Conv(۲*۶)	Activation
۴-دقت	Dropout	Dense(۱۰۰)	Conv(۱۴)	Dense(۱۴)	Dense(۱۰۰)	Dropout
۵-دقت	Dense(۱۴)	Dropout	Conv(۱۶)	Dense(۱)	Dropout	Dense(۴)
۶-دقت	Dropout	Conv(۱۶)	LSTM(۱۶)	Dense(۱۸)	Conv(۱۶)	Dropout
۷-دقت	Dense(۶)	Dense(۱۰۰)	Dense(۱۰۰)	FC	Dense(۱۰۰)	Dropout
۸-دقت	Dropout	Dropout	Dropout	Dropout	LSTM(۲۰)	Dense(۴)
۹-دقت	FC	Conv(۲*۶)	Dense(۱۰۰)	Dense(۱۰۰)	Conv(۱۶)	Activation
۱۰-دقت	---	Dense(۱۰۰)	FC	Dense(۱۰۰)	Dropout	Dropout
۱۱-دقت	---	Dense(۲۰۰)	---	---	Dense(۱۰۰)	Dense(۴)
۱۲-دقت	---	Dropout	---	---	Conv(۳)	---
۱۳-دقت	---	---	---	---	Conv(۱۴)	---
۱۴-دقت	---	---	---	---	Conv(۱۶)	---
۱۵-دقت	---	---	---	---	Dense(۱۰۰)	---
۱۶-دقت	---	---	---	---	Dropout	---
۱۷-دقت	---	---	---	---	Dense(۲*۶)	---
۱۸-دقت	---	---	---	---	Dropout	---
۱۹-دقت	---	---	---	---	Dense(۲*۶)	---
۲۰-دقت	---	---	---	---	Dropout	---
۲۱-دقت	---	---	---	---	FC	---
۲۲-دقت	---	---	---	---	FC	---

۴-۴-۱ ارزیابی ۷ مدل در مجموعه داده KDD ۹۹

جدول ۴: مقایسه عملکرد راهکار پیشنهادی و ۶ مدل شبکه عصبی دیگر در مجموعه

داده KDD ۹۹

معیارها	مدل اول	مدل دوم	مدل سوم	مدل چهارم	مدل پنجم	مدل ششم	مدل پیشنهادی
صحت	۵۳/۹۶	۹۸/۹۳	۵۰/۸۷	۶۱/۱۰	۹۸/۹۰	۸۸/۲۲	۹۹/۰۲
دقت	۸۳/۷۹	۸۸/۶۷	۷۸/۵۴	۹۸/۲۷	۸۸/۳۸	۶۳/۱۷	۹۹/۱۴
فراخوانی	۷۶/۱۹	۸۶/۳۴	۷۹/۰۰	۴۱/۲۴	۸۵/۹۴	۵۸/۷۷	۹۸/۹۳
معیار F	۷۸/۷۸	۸۷/۴۹	۷۸/۷۴	۵۸/۰۸	۸۷/۱۴	۶۰/۰۰	۹۹/۰۴
تابع زیان	۰/۰۴۵۹	۰/۰۳۰۴	۰/۰۵۴۴	۰/۰۴۱۶	۰/۰۲۰۶	۰/۰۷۷۳	۰/۰۱۶۷

با ملاحظه مقادیر معیارهای ارزیابی به دست آمده در جدول (۴)، کاملا واضح است که راهکار پیشنهادی در ۴ معیار صحت، دقت، فراخوانی و معیار F بیشترین مقدار را داشته است که این بهبود، نشان از چیدمان درست لایه ها و کنترل خوب بیش برزش می باشد. با این حال تابع زیان مدل پیشنهادی برای این مجموعه داده از مدل دوم بیشتر است، یعنی مدل دوم با مقدار ۰/۰۳۰۴ به عنوان کمترین تابع زیان مطرح می باشد. در حالت کلی، درست است مدل پیشنهادی کمترین تابع زیان به نسبت دیگر مدل ها را ندارد، اما با مقایسه تابع اعتبارسنجی مناسبی که مدل پیشنهادی ارائه کرده و با مشاهده مقادیر بالای معیارهای ارزیابی دیگر، می توان عملکرد بسیار خوب مدل پیشنهادی در این مجموعه داده را اثبات نمود.

۴-۴-۲ ارزیابی ۷ مدل در مجموعه داده NSL-KDD

جدول ۵: مقایسه عملکرد راهکار پیشنهادی و ۶ مدل شبکه عصبی دیگر در مجموعه


داده NSL-KDD

معیارها	مدل اول	مدل دوم	مدل سوم	مدل چهارم	مدل پنجم	مدل ششم	مدل پیشنهادی
صحت	۷۱/۷۵	۹۵/۹۵	۹۶/۵۳	۶۷/۰۸	۹۵/۹۵	۶۱/۳۲	۹۹/۳۹
دقت	۸۳/۵۱	۵۳/۳۶	۹۳/۲۵	۹۱/۱۷	۵۳/۴۸	۸۰/۳۳	۹۹/۴۹
فراخوانی	۶۹/۷۹	۵۳/۳۳	۷۰/۲۳	۷۸/۴۰	۵۳/۴۴	۸۴/۱۱	۹۹/۳۳
معیار F	۷۵/۶۳	۵۳/۳۴	۷۹/۹۸	۸۳/۸۹	۵۳/۴۶	۸۱/۷۴	۹۹/۴۱
تابع زیان	۰/۰۶۸۳	۰/۰۸۷۶	۰/۰۸۴۱	۰/۰۹۳۵	۰/۰۸۷۸	۰/۰۷۶۳	۰/۰۲۲۴

با توجه به جدول (۵) برای مجموعه داده NSL-KDD با ۲۳ کلاس، کاملا واضح است که راهکار پیشنهادی در همه معیارهای ارزیابی، حتی در تابع زیان نیز از دیگر مدل ها با اختلاف بسیار خوبی بهتر عمل کرده است. به عبارت دیگر، بالاتر از ۹۹ درصد بودن مقادیر معیارهای ارزیابی در مدل پیشنهادی و کاهش بسیار خوب تابع زیان روی آن، نشان از عملکرد بسیار عالی راهکار پیشنهادی و طراحی چیدمان مناسب لایه های شبکه عصبی در آن، نسبت به مدل های دیگر می باشد.


۴-۵ مقایسه مقادیر معیارهای ارزیابی راهکار پیشنهادی با مقاله پایه (وینیاکومار ۲۰۱۹)

همانطور که پیش‌تر نیز ذکر شد، مقاله وینیاکومار [۱۹] ۲۰۱۹، از بهترین، به روزترین و جسورانه‌ترین مقالاتی است، که با استفاده از شبکه‌های عصبی عمیق (DNN)، مقادیر معیارهای ارزیابی بسیار خوبی را روی ۶ مجموعه داده این حوزه که از شبکه‌های نرم افزار محور جمع آوری شده اند، کسب کرده و اکثر چالش‌های تشخیص نفوذ را تحت پوشش قرار داده است. لازم به ذکر است که تکنیک استفاده شده در مقاله وینیاکومار نیز، DNN بوده و وجه تمایز راهکار پیشنهادی ما و مقاله وینیاکومار در چیدمان، تعداد، ترکیب و توالی لایه‌های مختلفی است که در مدل شبکه عصبی عمیق خود به کار برده ایم. در ادامه سعی شده راهکار پیشنهادی پژوهش با نتایج این مقاله نیز مقایسه و بررسی گردد.



شکل ۱: مقایسه راهکار پیشنهادی با مقاله وینیاکومار در مجموعه داده KDD ۹۹

همانطور که در شکل (۱) ملاحظه می‌کنید، با توجه به اینکه مجموعه داده KDD ۹۹ مد نظر می‌باشد، مدل و راهکار پیشنهادی در همه مقادیر معیارهای ارزیابی از جمله: صحت، دقت، فراخوانی و معیار F، توانسته از مقاله وینیاکومار بهتر عمل کند و در واقع مقادیر معیارهای ارزیابی این مقاله بسیار خوب را بهبود دهد.



شکل ۲: مقایسه راهکار پیشنهادی با مقاله وینیاکومار در مجموعه داده NSL-KDD

همچنین با ملاحظه شکل (۲) و مقایسه مقادیر معیارهای ارزیابی مدل و راهکار پیشنهادی با مقاله وینیاکومار [۱۹] ۲۰۱۹ روی مجموعه داده NSL-KDD، واضح است که در این مجموعه داده حتی اختلاف مقادیر معیارها روی مدل پیشنهادی با مقاله وینیاکومار، نسبت به مقادیر کسب شده روی مجموعه داده KDD ۹۹، بیشتر هم شده است و تقریباً همه معیارها به نزدیک صد در صد رسیده‌اند و اختلاف تقریباً ۲۰ درصدی معیارهای صحت، دقت، فراخوانی و معیار F مشهود می‌باشد.

۵ نتیجه گیری و راهکارهای آتی

در این پژوهش سعی کردیم در جهت ارتقای سطح امنیت و جلوگیری از حملات مختلف به شبکه‌ها، گامی برداشته و نیازی از جامعه را حل کنیم. راهکار پیشنهادی این پژوهش، سیستم تشخیص نفوذی است، که بر پایه یک شبکه عصبی عمیق منحصراً به فرد ۱۲ لایه بوده و روی دو مجموعه داده جمع آوری شده از شبکه‌های نرم افزار محور (SDN) به نام های NSL-KDD و KDD ۹۹ اعمال شده است. در واقع ترکیب و چیدمان این ۱۲ لایه به این صورت می‌باشد: لایه Dense، لایه Dense، لایه فعال ساز، لایه حذف تصادفی، لایه Dense، لایه حذف تصادفی، لایه Dense، لایه فعال ساز، لایه حذف تصادفی، لایه Dense، لایه فعال ساز، لایه حذف تصادفی، لایه Dense، لایه فعال ساز یا همان لایه کاملاً

متصل (Fully Connected-FC) که بر حسب تعداد خروجی کلاس‌ها از توابع سافت مکس (Softmax) یا تانژانت هیپربولیک (Tanh) برای انتخاب کلاس متناسب، مورد استفاده قرار گرفته است. لازم به ذکر است، که معماری و چیدمان لایه‌ای مدل DNN پیشنهادی برای هر دو مجموعه داده، ۱۲ لایه بوده و تعداد و چیدمان لایه‌ها تغییر نکرده، که این از نقاط قوت مدل و راهکار پیشنهادی به شمار می‌رود.

اما راهکار پیشنهادی روی هر کدام از این مجموعه داده‌ها، در جداول جداگانه‌ای با ۶ مدل شبکه عصبی دیگر مورد مقایسه و بررسی قرار گرفت، که نتایج به دست آمده برای مجموعه داده NSL-KDD با ۲۳ کلاس، مشخص کرد که راهکار پیشنهادی در همه معیارهای ارزیابی، حتی در تابع زیان، از دیگر مدل‌ها با اختلاف زیادی بهتر عمل کرده است، که این بالاتر از ۹۹ درصد بودن مقادیر معیارهای ارزیابی مدل پیشنهادی و کاهش بسیار خوب تابع زیان روی آن، نشان از عملکرد بسیار خوب راهکار پیشنهادی نسبت به مدل‌های دیگر می‌باشد. همچنین نتایج عملکرد راهکار پیشنهادی برای مجموعه داده KDD ۹۹ نیز، مشخص کرد که راهکار پیشنهادی در چهار معیار مذکور، بیشترین مقادیر معیارهای ارزیابی را به دست آورده، در عین اینکه تنها تابع زیان مدل پیشنهادی برای این مجموعه داده، از مدل دوم بیشتر بود، که با توجه به اینکه راهکار پیشنهادی بسیار خوب توانسته، بیش‌برازش را با چیدمان درست لایه‌ها کنترل نماید، این خطای ناچیز قابل اغماض می‌باشد. در نهایت نیز، مدل پیشنهادی روی دو مجموعه داده مشترک با مقاله وینیاکومار [۱۹] ۲۰۱۹، که از بهترین مقالات انجام شده در این حوزه بوده، مورد مقایسه قرار گرفت. به این ترتیب که با در نظر گرفتن مجموعه داده KDD ۹۹، مشخص شد که راهکار پیشنهادی در همه معیارهای مذکور بهتر از مقاله وینیاکومار ۲۰۱۹ عمل کرد و توانست همه معیارهای ارزیابی مذکور را به میزان بسیار خوبی نسبت به مقاله پایه بهبود بخشد. همچنین با در نظر گرفتن مجموعه داده NSL-KDD، حتی اختلاف مقادیر معیارها روی مدل پیشنهادی با مقاله وینیاکومار، نسبت به مقادیر کسب شده روی مجموعه داده KDD ۹۹، بیشتر هم شد و تقریباً همه معیارها به نزدیک صد در صد رسیدند و اختلاف تقریباً ۲۰ درصدی معیارهای صحت، دقت، فراخوانی و معیار F روی این مجموعه داده کاملاً مشهود بود. در نهایت، با توجه به مقادیر معیارهای ارزیابی کسب شده، می‌توان نتیجه گرفت که مدل پیشنهادی عملکردی بسیار مناسب برای تشخیص نفوذ روی دو مجموعه داده مختلف معرفی شده از شبکه‌های نرم افزار محور داشته و توانسته نتایج بهترین مقاله این حوزه را به میزان بسیار خوبی بهبود بخشد.

در انتها، برای پژوهشگرانی که علاقه مند هستند در این حوزه فعالیت کنند، می‌توان تحقیق و بررسی روی راهکارهای زیر را پیشنهاد داد:

مجموعه داده‌های جمع آوری شده روی شبکه‌های نرم افزار محور، بیشتر از ۲۰ مورد هستند، که در این پژوهش دو مجموعه داده پرکاربرد از این حوزه به نام های KDD ۹۹ و NSL-KDD استفاده شدند. اما می‌توان مجموعه داده‌های دیگر را نیز مورد بررسی قرار داد و نتایج حاصل را تحلیل نمود.

در پژوهش جاری، از معماری‌های مختلف معرفی شده در شبکه‌های کانولوشن مانند AlexNet، MobileNet، LeNet و یا دیگر معماری‌های موجود استفاده نشده است و می‌توان در کارهای آینده این معماری‌ها را نیز تست کرد و بهبود یا عدم بهبود را بعد از انجام آزمایشات مشاهده نمود. همچنین می‌توان از ترکیب راهکار پیشنهادی با معماری‌های عمیق دیگر استفاده نمود، یا از الگوریتم‌های فرا ابتکاری مانند الگوریتم بهینه سازی ازدحام ذرات (PSO) و موارد دیگر بهره گرفت و عملکرد مدل و راهکار پیشنهادی را به همراه استفاده از چنین الگوریتم‌ها و معماری‌هایی مورد تحلیل و بررسی قرار داد.

مراجع:

- [۱] Heady, R., Luger, G., Maccabe, A., & Servilla, M. (۱۹۹۰). *The architecture of a network level intrusion detection system* (No. LA-SUB-۹۳-۲۱۹). Los Alamos National Lab., NM (United States); New Mexico Univ., Albuquerque, NM (United States). Dept. of Computer Science.
- [۲] Panda, M., Abraham, A., & Patra, M. R. (۲۰۱۲). A hybrid intelligent approach for network intrusion detection. *Procedia Engineering*, ۳۰, ۱-۹.

- [14] Roy, S.S., Mallik, A., Gulati, R., Obaidat, M.S., Krishna, P.V. (2017, January). A deep learning based artificial neural network approach for intrusion detection. In International Conference on Mathematics and Computing (pp. 11-13). Springer, Singapore.
- [15] Li, Z., Qin, Z., Huang, K., Yang, X., & Ye, S. (2017, November). Intrusion detection using convolutional neural networks for representation learning. In International Conference on Neural Information Processing (pp. 108-116). Springer, Cham.
- [16] Liu, Y., Liu, S., Zhao, X. (2017). Intrusion detection algorithm based on convolutional neural network. DEStech Transactions on Engineering and Technology Research, (iceta).
- [17] Niyaz, Q. (2017). Design and Implementation of a Deep Learning based Intrusion Detection System in Software-Defined Networking Environment (Doctoral dissertation, University of Toledo).
- [18] Marir, N., Wang, H., Feng, G., Li, B., & Jia, M. (2018). Distributed abnormal behavior detection approach based on deep belief network and ensemble svm using spark. IEEE Access, 6, 91607-91611.
- [19] Shone, N., Ngoc, T. N., Phai, V. D., & Shi, Q. (2018). A deep learning approach to network intrusion detection. IEEE Transactions on Emerging Topics in Computational Intelligence, 3(1), 1-10.
- [20] Jiang, F., Fu, Y., Gupta, B. B., Lou, F., Rho, S., Meng, F., & Tian, Z. (2018). Deep learning based multi-channel intelligent attack detection for data security. IEEE transactions on Sustainable Computing.
- [21] Tang, T.A., Mhamdi, L., McLernon, D., Zaidi, S.A.R., Ghogho, M. (2018, June). Deep recurrent neural network for intrusion detection in sdn-based networks. In 2018 IEEE Conference on Network Softwareization and Workshops (NetSoft) (pp. 1-6). IEEE.
- [22] Ponkarthika, M., & Saraswathy, V. R. (2018). Network intrusion detection using deep neural networks. Asian J Appl Sci Technol, 3(1), 110-113.
- [23] Parvat, A., Dev, S., Kadam, S., & Chavan, J. (2018, August). Network Intrusion Detection System Using Ensemble of Binary Deep Learning Classifiers. In International Conference on Smart Trends for Information Technology and Computer Communications (pp. 1-10). Springer, Singapore.
- [24] Potluri, S., Ahmed, S., & Diedrich, C. (2018, December). Convolutional Neural Networks for Multiclass Intrusion Detection System. In International Conference on Mining Intelligence and Knowledge Exploration (pp. 12-18). Springer, Cham.
- [25] Farahnakian, F., Heikkonen, J. (2018, February). A deep auto-encoder based approach for intrusion detection system. In 2018 21st International Conference on Advanced Communication Technology (ICACT) (pp. 117-122). IEEE.
- [26] Nguyen, S. N., Nguyen, V. Q., Choi, J., & Kim, K. (2018, February). Design and implementation of intrusion detection system using convolutional neural network for dos detection. In Proceedings of the 17th International Conference on Machine Learning and Soft Computing (pp. 11-18). ACM.
- [27] Papamartzivanos, D., Mármol, F. G., Kambourakis, G. (2019). Introducing deep learning self-adaptive misuse network intrusion detection systems. IEEE Access, 7, 11000-11007.
- [28] Abusitta, A., Bellaiche, M., Dagenais, M., & Halabi, T. (2019). A deep learning approach for proactive multi-cloud cooperative intrusion detection system. Future Generation Computer Systems, 98, 108-118.
- [29] Vinayakumar, R., Soman, K. P., & Poornachandran, P. (2019). A Comparative Analysis of Deep Learning Approaches for Network Intrusion Detection Systems (N-IDSs): Deep Learning for N-IDSs. International Journal of Digital Crime and Forensics (IJDCF), 11(2), 108-119.
- [30] Khan, M. A., Karim, M., & Kim, Y. (2019). A Scalable and Hybrid Intrusion Detection System Based on the Convolutional-LSTM Network. Symmetry, 11(1), 1-12.
- [31] Chawla, A., Lee, B., Fallon, S., Jacob, P. (2019, September). Host based intrusion detection system with combined CNN/RNN model. In Joint European Conference on Machine Learning and Knowledge Discovery in Databases (pp. 111-128). Springer, Cham.
- [32] Chockwanich, N., Visoottiviseth, V. (2019, February). Intrusion Detection by Deep Learning with TensorFlow. In 2019 11st International Conference on Advanced Communication Technology (ICACT) (pp. 100-105). IEEE.
- [33] Ustebay, S., Turgut, Z., Aydin, M.A. (2019, June). Cyber Attack Detection by Using Neural Network Approaches: Shallow Neural Network, Deep Neural Network and AutoEncoder. In International Conference on Computer Networks (pp. 111-118). Springer, Cham.
- [34] Vigneswaran, K. R., Vinayakumar, R., Soman, K. P., & Poornachandran, P. (2018, July). Evaluating shallow and deep neural
- [35] Sheikhan, M., & Bostani, H. (2016). A hybrid intrusion detection architecture for internet of things. In 2016 14th International Symposium on Telecommunications (IST) (pp. 1-6). IEEE.
- [36] Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., ... & Kudlur, M. (2016). Tensorflow: A system for large-scale machine learning. In 12th USENIX Symposium on Operating Systems Design and Implementation (OSDI 16) (pp. 280-283).
- [37] He, D., Chen, X., Zou, D., Pei, L., & Jiang, L. (2018, May). An Improved Kernel Clustering Algorithm Used in Computer Network Intrusion Detection. In Circuits and Systems (ISCAS), 2018 IEEE International Symposium on (pp. 1-6). IEEE.
- [38] Song, J., Takakura, H., Okabe, Y., & Kwon, Y. (2019). Unsupervised anomaly detection based on clustering and multiple one-class SVM. IEICE transactions on communications, 92(7), 1981-1990.
- [39] Revathi, S., & Malathi, A. (2013). A detailed analysis on NSL-KDD dataset using various machine learning techniques for intrusion detection. International Journal of Engineering Research & Technology (IJERT), 2(12), 1818-1823.
- [40] Powers, D. M. (2011). Evaluation: from precision, recall and F-measure to ROC, informedness, markedness and correlation.
- [41] Chiba, Z., Abghour, N., Moussaid, K., El Omri, A., & Rida, M. (2019, March). Smart Approach to Build A Deep Neural Network Based IDS for Cloud Environment Using an Optimized Genetic Algorithm. In Proceedings of the 17th International Conference on Networking, Information Systems & Security (p. 1). ACM.
- [42] Wang, G., Hao, J., Ma, J., & Huang, L. (2010). A new approach to intrusion detection using Artificial Neural Networks and fuzzy clustering. Expert systems with applications, 37(9), 1220-1232.
- [43] Lin, S. W., Ying, K. C., Lee, C. Y., & Lee, Z. J. (2012). An intelligent algorithm with feature selection and decision rules applied to anomaly intrusion detection. Applied Soft Computing, 12(10), 3280-3290.
- [44] Aburomman, A. A., & Reaz, M. B. I. (2016). A novel SVM-kNN-PSO ensemble method for intrusion detection system. Applied Soft Computing, 38, 330-342.
- [45] Yin, C., Zhu, Y., Fei, J., & He, X. (2017). A deep learning approach for intrusion detection using recurrent neural networks. Ieee Access, 5, 21902-21911.
- [46] Baek, S., Kwon, D., Kim, J., Suh, S. C., Kim, H., & Kim, I. (2017, June). Unsupervised labeling for supervised anomaly detection in enterprise and cloud networks. In 2017 IEEE 17th International Conference on Cyber Security and Cloud Computing (CSCloud) (pp. 100-101). IEEE.
- [47] Wang, H., Gu, J., & Wang, S. (2017). An effective intrusion detection framework based on SVM with feature augmentation. Knowledge-Based Systems, 136, 130-139.
- [48] Zhu, M., Ye, K., & Xu, C. Z. (2018, June). Network anomaly detection and identification based on deep learning methods. In International Conference on Cloud Computing (pp. 111-124). Springer, Cham.
- [49] Hsu, C.M., Hsieh, H.Y., Prakosa, S.W., Azhari, M.Z., Leu, J.S. (2018, October). Using Long-Short-Term Memory Based Convolutional Neural Networks for Network Intrusion Detection. In International Wireless Internet Conference (pp. 16-24). Springer, Cham.
- [50] Aljawarneh, S., Aldwairi, M., & Yassein, M. B. (2018). Anomaly-based intrusion detection system through feature selection analysis and building hybrid efficient model. Journal of Computational Science, 10, 102-110.
- [51] Vinayakumar, R., Alazab, M., Soman, K. P., Poornachandran, P., Al-Nemrat, A., & Venkatraman, S. (2019). Deep Learning Approach for Intelligent Intrusion Detection System. IEEE Access, 7, 10200-10207.
- [52] Tang, T. A., Mhamdi, L., McLernon, D., Zaidi, S. A. R., & Ghogho, M. (2017, October). Deep learning approach for network intrusion detection in software defined networking. In 2017 International Conference on Wireless Networks and Mobile Communications (WINCOM) (pp. 108-113). IEEE.
- [53] Wang, W., Sheng, Y., Wang, J., Zeng, X., Ye, X., Huang, Y., & Zhu, M. (2017). HAST-IDS: Learning hierarchical spatial-temporal features using deep neural networks to improve intrusion detection. IEEE Access, 5, 11922-11931.
- [54] Vinayakumar, R., Soman, K. P., & Poornachandran, P. (2017, September). Applying convolutional neural network for network intrusion detection. In 2017 International Conference on Advances in Computing, Communications and Informatics (ICACCI) (pp. 1122-1128). IEEE.
- [55] Mohammadi, S., & Namadchian, A. (2017). A New Deep Learning Approach for Anomaly Base IDS using Memetic Classifier. International Journal of Computers, Communications & Control, 12(2).

networks for network intrusion detection systems in cyber security. In 2018 9th International Conference on Computing, Communication and Networking Technologies (ICCCNT) (pp. 1-6). IEEE.

[40] Pham, N. T., Foo, E., Suriadi, S., Jeffrey, H., Lahza, H. F. M. (2018, January). Improving performance of intrusion detection system using ensemble methods and feature selection. In Proceedings of the Australasian Computer Science Week Multiconference (p. 5). ACM.

[41] Sharma, J., Giri, C., Granmo, O. C., & Goodwin, M. (2019). Multi-layer intrusion detection system with ExtraTrees feature selection, extreme learning machine ensemble, and softmax aggregation. *EURASIP Journal on Information Security*, 2019(1), 10.

[42] Ludwig, S. A. (2019). Intrusion detection of multiple attack classes using a deep neural net ensemble. In 2019 IEEE Symposium Series on Computational Intelligence (SSCI) (pp. 1-5). IEEE.

[43] Faker, O., & Dogdu, E. (2019, April). Intrusion Detection Using Big Data and Deep Learning Techniques. In Proceedings of the 2019 ACM Southeast Conference (pp. 16-19). ACM.

[44] Ma, T., Wang, F., Cheng, J., Yu, Y., & Chen, X. (2016). A hybrid spectral clustering and deep neural network ensemble algorithm for intrusion detection in sensor networks. *Sensors*, 16(10), 1701.

[45] Barushka, A., Hájek, P. (2018, May). Spam filtering in social networks using regularized deep neural networks with ensemble learning. In IFIP International Conference on Artificial Intelligence Applications and Innovations (pp. 38-49). Springer, Cham.

[46] Rawat, S., & Srinivasan, A. (2019). Intrusion detection systems using classical machine learning techniques versus integrated unsupervised feature learning and deep neural network. arXiv preprint arXiv:1910.01114.

¹ Intrusion Detection System

² Deep Learning

³ Software Defined Network

⁴ <https://www.unb.ca/cic/datasets/nsl.html>

⁵ Deep Neural Network

⁶ Loss Function

⁷ Accuracy

⁸ Precision

⁹ Recall

¹⁰ F-measure

¹¹ True Positive

¹² True Negative

¹³ False Positive

¹⁴ False Negative

¹⁵ <https://colab.research.google.com>