

تشخیص ناهنجاری در ترافیک شبکه با استفاده از سامانه توزیع شده مبتنی بر سیستم‌های چندعامله خودسازمانده

نیلوفر شکبیا^۱، دانشجوی کارشناسی ارشد، اکرم بیگی^۲، استادیار

۱- دانشکده مهندسی کامپیوتر - دانشگاه تربیت دبیر شهید رجایی - تهران - ایران - n_shakiba@vatanmail.ir

۲- دانشکده مهندسی کامپیوتر - دانشگاه تربیت دبیر شهید رجایی - تهران - ایران - akrambeigi@sru.ac.ir

چکیده: امروزه چالش‌های حوزه امنیت اطلاعات و ارتباطات بسیار مورد توجه محققین است. گسترش مرزهای شبکه، افزایش و پیچیدگی حملات امنیتی شبکه، نیاز به وجود سامانه‌های هوشمند، خودکار و بی‌درنگ کشف ناهنجاری و تهدیدات شبکه را دوچندان نموده است. برای کشف ناهنجاری، لازم است ترافیک شبکه به صورت بی‌درنگ مورد پایش قرار گیرد. ناهنجاری شامل تغییرات قابل توجه و غیرمعمول رفتار ترافیک شبکه در مقایسه با الگوهای رفتار نرمال آن است. در این مقاله به منظور کشف ناهنجاری، یک سامانه مبتنی بر سیستم‌های چندعامله خودسازمانده ارائه شده است. سیستم‌های چندعامله از عامل‌هایی که با یکدیگر برای رسیدن به هدف مشخصی تعامل دارند تشکیل شده‌اند. از این سیستم‌ها برای حل مسائلی استفاده می‌شود که حل آن برای یک عامل و یا به صورت یکپارچه مشکل است. معماری سامانه پیشنهادی مقیاس پذیر است و می‌تواند خود را با تغییرهای شبکه‌های امروزی وفق دهد. ارزیابی و تحلیل انجام شده روی سامانه پیشنهادی در مجموعه داده NSL-KDD، نشان می‌دهد نرخ کشف ناهنجاری در ترافیک شبکه در مقایسه با روش‌های مطرح اخیر بهبود یافته است. همچنین با پیشنهاد الگوریتم‌هایی برای بهینه کردن انتخاب عامل‌ها و تعیین وزن تصمیم به طور هوشمند برای عامل‌ها، علاوه بر افزایش نرخ تشخیص ناهنجاری، زمان تحلیل رخدادها نیز کاهش داده شده است.

واژه‌های کلیدی: امنیت شبکه، تشخیص ناهنجاری، تشخیص نفوذ، سیستم‌های چندعامله، سامانه‌های مقیاس‌پذیر.

Anomaly Detection in Network Traffic using Distributed Self-Organizing Multi Agent Systems

Niloofer Shakiba, MSc¹, Akram Beigi, Assistant Professor²

1- Computer Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran, Email: n_shakiba@vatanmail.ir

2- Computer Engineering, Shahid Rajaee Teacher Training University, Tehran, Iran, Email: akrambeigi@sru.ac.ir

Abstract: Challenges in the field of information and communication security are of great interest to researchers. The expansion of network boundaries, the intensification and complexity increase of network security attacks, has amplified the need for intelligent, automated and real-time systems to detect network anomalies and threats. To detect anomalies, network traffic needs to be monitored immediately. The anomaly involves significant and unusual changes in network traffic behavior compared to its normal behavior patterns. In this paper, in order to detect anomalies, a system based on self-organizing multi agent systems is presented. Multi agent systems are made up of agents that interact with each other to achieve a specific goal. These systems are used to solve problems that are difficult for a single agent to solve or integrate. The proposed system architecture is scalable and can adapt to changes in today's networks. The evaluation and analysis of the proposed system in the NSL-KDD dataset shows that the rate of anomalies detection has improved compared to the recently proposed methods. Also, by proposing an algorithm to optimize the agents' choices and another one for intelligent agents' decision weighting, the rate of anomaly detection is increased and the time of event analysis is reduced.


Keywords: Network security, Anomaly detection, Intrusion detection, Multi agent systems, Saleable systems.

نام نویسنده مسئول: اکرم بیگی

نشانی نویسنده مسئول: ایران - تهران - لویزان - دانشگاه تربیت دبیر شهید رجایی - دانشکده مهندسی کامپیوتر

۱- مقدمه

نشان داده شده است [۶]، کشف و پاسخ بی‌درنگ به عملیات نفوذ به شبکه، نیاز به فرآیندهای خودکار و هوشمندانه دارد.



شکل ۱: نرخ وقوع آلودگی با بدافزار (میلیون بار) [۷]

گسترش استفاده از شبکه و همچنین افزایش نیاز به اشتراک‌گذاری داده‌های مهم در انواع کسب‌وکارها باعث شده است که سیستم‌های سنتی کشف نفوذ که تا حد زیادی به فرد خبیره وابسته هستند قادر به پاسخگویی به نیازهای امنیت نباشند. همچنین افزایش استفاده از موبایل و فناوری‌های بی‌سیم مرزهای شبکه را به وسیله معرفی تجهیزات پویا که در آن کاربران و ابزارها مدام در حال پیوستن به شبکه و جدا شدن از آنها هستند به شدت تغییر و گسترش داده است. برای سازگاری با این تغییرات، لازم است IDSها قابلیت مقیاس‌پذیری داشته باشند. عموماً IDSهای سنتی از یک واحد پردازش مرکزی به منظور تحلیل ترافیک شبکه استفاده می‌کنند که این امر احتمال خطای نقطه شکست مرکزی^۱ را افزایش می‌دهد. به منظور استقرار امنیت در شبکه‌های امروزی نیاز است تا از سیستم‌های تشخیص نفوذ بی‌درنگ، نامتمرکز، خودکار و مقیاس‌پذیر استفاده نمود. در این مقاله یک سامانه توزیع‌شده مبتنی بر سیستم‌های چندعامله خودسازمانده به منظور کشف ناهنجاری‌های ترافیک شبکه ارائه شده است. این سامانه از تعدادی عامل هوشمند تشکیل شده است که بنا بر ماهیت توزیع‌شدگی سامانه، هر عامل به‌تنهایی قادر به تحلیل و جمع‌آوری اطلاعات شبکه است. همچنین عامل‌های این سیستم می‌توانند به صورت هوشمند به شبکه اضافه و یا از آن کم شوند تا بتوانند با کمترین پیچیدگی و سربر، خود را با تغییرات موردنیاز شبکه وفق دهند. علاوه بر این، تعداد عامل‌های درگیر در تحلیل شبکه بنا بر میزان اهمیت یک رخداد و گستردگی آن تعیین می‌شود. عامل‌های سیستم پیشنهادی قادرند ناهنجاری‌های ترافیک شبکه را یافته و از این طریق حمله‌های ناشناخته و یا پیچیده امنیتی را تشخیص دهند.

۲- مروری بر ادبیات موضوع

بررسی تحقیقات انجام‌شده در تشخیص ناهنجاری شبکه، مشخص‌کننده این است که بسیاری از روش‌های پیشنهادی در این حوزه از الگوریتم‌های خوشه‌بندی^{۱۱}، طبقه‌بندی^{۱۲}، تکاملی، تحلیل آماری و یا ترکیب چند الگوریتم مختلف استفاده کرده‌اند که عمده این روش‌ها ماهیت متمرکز دارند [۱]. در این حوزه رویکردهای دیگری نیز

امنیت اطلاعات یکی از مسائل حائز اهمیت در دنیای امروز است. امنیت اطلاعات را می‌توان به حفاظت و صیانت از داده‌ها و جلوگیری از هرگونه فعالیت غیرمجاز تعبیر کرد. فعالیت غیرمجاز هرگونه فعالیتی است که یکی از سه مؤلفه امنیت اطلاعات یعنی یکپارچگی^۱، محرمانگی^۲ و دسترس‌پذیری را مختل نماید. به منظور استقرار امنیت در شبکه‌های کامپیوتری، راه‌حل‌های متعددی وجود دارد که در این بین، سامانه‌های تشخیص نفوذ^۳ (IDS) بیشترین کاربرد را دارند. این سامانه‌ها یک راه حل خودکار دفاعی و یک سیستم امنیتی برای نظارت، پایش، تحلیل و کشف رفتارهای خصمانه و ناهنجار در شبکه هستند که می‌توانند مبتنی بر میزبان^۴ و یا مبتنی بر شبکه باشند [۱]. سامانه‌های تشخیص نفوذ با توجه به روش تشخیص نفوذ می‌توانند به سه دسته مبتنی بر امضا^۵، مبتنی بر ناهنجاری^۶ و یا ترکیبی طبقه‌بندی شوند [۲]. IDSهای مبتنی بر امضا به یک پایگاه داده از اطلاعات انواع حملات نیاز دارند. نگهداری و به‌روزرسانی این پایگاه داده یکی از موضوعات چالش‌برانگیز در این نوع سامانه‌هاست. همچنین آنها نمی‌توانند حملات روز صفر^۷ که ناشناخته هستند و در پایگاه داده برای آن الگویی وجود ندارد را تشخیص دهند. با این وجود این سیستم‌ها به علت دارا بودن نرخ پایین مثبت کاذب^۸ (تعداد رخدادهایی که از نظر امنیتی عادی و بی‌خطر هستند اما سامانه آنها را مخرب تشخیص داده و هشدار تولید نموده است)، هنوز هم در صنعت استفاده می‌شوند. در IDSهای مبتنی بر ناهنجاری، الگوهای رفتار هنجار تشخیص داده می‌شوند و سیستم تشخیص نفوذ به منظور پیدا کردن مغایرت با این الگوها ترافیک شبکه را پایش می‌کند [۳]. در واقع با تحلیل ترافیک شبکه و ساخت نمایه^۹ از رفتار شبکه می‌تواند هرگونه تغییر در رفتار معمول شبکه را تشخیص دهند.

اولین گام در تشخیص ناهنجاری، تعریف مسئله و مدل‌سازی درست آن است [۴]. بنابراین تعریف و تعیین رفتار هنجار یا نرمال شبکه مهم‌ترین گام برای تشخیص ناهنجاری است. به این منظور تعاریف و مصادیق مختلفی ارائه شده است. ناهنجاری در شبکه می‌تواند با قصد ایجاد تخریب و نفوذ صورت گرفته باشد و یا صرفاً یک رفتار غیرمعمول ولی بدون قصد تخریب باشد. از کار انداختن سرورهای توسط مهاجمین و تلاش برای دسترسی به اطلاعات محرمانه شبکه مثال‌هایی از ناهنجاری مخرب هستند. رخدادهایی مثل انتقال یک فایل حجیم نیز مثالی از ناهنجاری در شبکه است که با وجود اینکه ماهیت خصمانه ندارد می‌تواند برای شبکه تهدید محسوب شود و سرویس‌دهی آن را مختل کند. از سویی دیگر، می‌توان مشاهداتی که با سایر داده‌های یک مجموعه همخوانی ندارد را ناهنجاری دانست [۵]. در حالت کلی، می‌توان الگوهایی از رفتار شبکه را که با رفتار هنجار تعریف شده تطابق ندارند را ناهنجاری به شمار آورد [۶]. با توجه به افزایش سریع حملات در شبکه و رشد صعودی آن در سالیان اخیر، همان‌طور که در شکل ۱

داده جمع‌آوری کنند و دسته دیگر آنها را تحلیل نمایند ممکن است دسترس‌پذیری را مختل کرده و گلوگاه کارایی ایجاد نماید.

در [۱۱] یک محیط برای جمع‌آوری شواهد قانونی^{۱۵} معرفی شده است. در این محیط از سه نوع عامل برای جمع‌آوری داده، تحلیل داده و تولید هشدار استفاده شده است. نویسنده این مقاله عنوان کرده است که الگوی سیستم‌های چندعامله برای جمع‌آوری داده‌های قانونی بسیار مناسب هستند. زیرا می‌توانند در فضای شبکه پخش شوند و به جمع‌آوری شواهد بپردازند. بسیاری از IDSها فاقد این ویژگی هستند و تنها ارتباطات شبکه‌ای قابل مشاهده را نظارت می‌کنند.

در [۱۲] یک سیستم جمع‌آوری شواهد قانونی توزیع شده با روش سلسله‌مراتبی و حسگرهای قابل بیکربندی چندگانه توسعه داده شده است. این سیستم از انواع حسگرها برای جمع‌آوری و تجمیع داده‌ها به منظور استخراج طبیعت رخدادهای امنیتی استفاده می‌نماید. این سیستم نوع حمله را بر اساس اینکه کدام قسمت شواهد در طول جستجو وجود ندارد تشخیص می‌دهد. در محیط‌های سایبری پیچیده این راه‌حل مناسب است زیرا نبود اطلاعات لزوماً به معنای اینکه حمله‌ای وجود ندارد، نیست.

در [۱۳] کاربردهای رایج در زیرساخت‌های حیاتی شامل سیستم‌های تشخیص نفوذ مرور شده است. انعطاف‌پذیری سیستم به عنوان یک فاکتور مهم در سیستم چندعامله مورد تأکید قرار گرفته است. مهاجمین می‌توانند عامل‌ها را از طریق حمله منع سرویس از دسترس خارج نمایند. عامل‌ها باید قادر باشند که خود را با تغییرات شبکه وفق دهند چراکه ممکن است تعدادی از عامل‌ها قادر به ارتباط با سایر عامل‌ها نباشند. مدل‌های سلسله‌مراتبی اگر مسیر ارتباطی آنها سالم نباشد درست عمل نخواهند کرد.

در [۱۴] با استفاده از سیستم‌های چندعامله، روشی برای تشخیص حمله منع سرویس توزیع شده ارائه شده است که در آن عامل‌ها از روش بهینه‌سازی هوش جمعی برای برقراری ارتباط و تصمیم‌گیری دقیق استفاده می‌کنند. چندین نوع عامل تعریف شده‌اند که هر کدام وظایف خاصی دارند. به طور مثال عامل‌های تشخیص با استفاده از روش‌های تحلیل بی‌نظمی^{۱۶} و کوواریانس، حملات را تشخیص می‌دهند و عامل‌های هماهنگ‌کننده ارتباط بین عامل‌ها و تصمیم‌گیری را برقرار می‌نمایند. همچنین عامل‌های ناظر در صورت مشاهده هرگونه رخداد غیرمعمول، عامل‌های تشخیص را فعال می‌نمایند.

در [۱۵] از سیستم‌های چندعامله به منظور کشف حملات مانای پیشرفته^{۱۷} استفاده شده است. در این سیستم تشخیص نفوذ با به کارگیری معماری چندعامله و با استفاده از منابع داده خارجی، منشأ اتصالات مشکوک را جستجو می‌کند. در این محیط سه نوع عامل تعریف شده است: (۱) عامل مشاور به منظور پیدا کردن مکان آدرس‌های IP (۲) عامل تحلیل‌کننده به منظور مقایسه اتصالات مشکوک با الگوی ترافیک مشاهده شده (۳) عامل تمایزدهنده بین اتصالات ایجاد شده توسط انسان و ربات.

در دسته مدل‌سازی با سیستم‌های چندعامله و همچنین الگوریتم‌های هوش جمعی^{۱۸} مشاهده می‌شوند. با توجه به ویژگی‌های شبکه‌های امروزی، استفاده از سیستم‌های چندعامله به دلیل قابلیت توزیع شدن راه‌حل مناسبی به نظر می‌رسد.

طبق تعریف، عامل موجودیتی است که بتواند از طریق حسگر از محیط ادراک داشته و توسط عملکرد محیط تأثیر بگذارد. عامل‌ها باید خودمختار بوده و دارای قدرت تصمیم‌گیری در رابطه با اینکه چه کاری باید انجام دهند تا به اهداف تعیین شده برسند داشته باشند و نیز بتوانند با دیگر عامل‌ها تعامل داشته باشند. سیستم‌های چندعامله از چندین عامل تشکیل شده‌اند که با یکدیگر برای رسیدن به هدف مشخص تعامل دارند. از سیستم‌های چندعامله در مسائلی استفاده می‌شود که حل آنها برای یک سیستم تک‌عامله و یا یکپارچه مشکل باشد [۸]. به صورت ایده‌آل انتظار می‌رود سیستم‌های مبتنی بر عامل مزیت‌های مقیاس‌پذیری و سهولت استقرارپذیری که معماری مبتنی بر عامل ارائه می‌دهد را دارا باشند. همچنین مشکلات رایجی مثل وجود خطای شکست مرکزی، سخت‌افزار گران برای فراهم نمودن مقیاس‌پذیری و ساختار عملیاتی نامنظم را نداشته باشند. در این بخش تعدادی از پژوهش‌هایی که از سیستم‌های مبتنی بر عامل به منظور تحلیل امنیت شبکه استفاده نموده‌اند مرور خواهد شد.

در [۹] یک سیستم تشخیص نفوذ مبتنی بر عامل که در آن از چندین منبع اطلاعاتی استفاده می‌شود، پیشنهاد شده است. عامل‌ها از اطلاعاتی که از منابع نظامی به منظور استخراج فاکتورهایی مثل مکان جغرافیایی، چشم‌انداز سیاسی و انگیزه‌های ممکن حمله استخراج شده است، استفاده می‌نمایند. مزیت مهم این سیستم این است که از منابع اطلاعاتی باکیفیت بالا به منظور نتیجه‌گیری در رابطه با حمله استفاده می‌نماید. این سیستم داده‌ها را به دو دسته حقیقت و پیش‌فرض (به عنوان حقیقت تأیید نشده) رده‌بندی می‌نماید. معماری پیشنهادی این مقاله به عدم وجود یک داده و یا اشتباه بودن آن حساس است. همچنین، عامل‌ها داده‌ها را به صورت زنده جمع‌آوری می‌کنند تا بتوانند به روزترین اطلاعات در دسترس را به منظور جلوگیری از افت کیفیت داده^{۱۹}، که عموماً در مخازن اطلاعات مرکزی رخ می‌دهد، فراهم نمایند. در [۱۰] از یک سیستم چندعامله سلسله‌مراتبی برای نظارت و گزارش نقض سیاست‌ها در یک شبکه امنیتی استفاده شده است. این سیستم از چندین نوع عامل تشکیل شده است که هر کدام کار بخصوصی را انجام می‌دهند (مانند نظارت بر رخدادها، تولید هشدار و ساخت گزارش). مدیر شبکه سیاست‌هایی را برای عامل‌ها تعریف می‌کند تا مدل سلسله‌مراتبی آنها پیاده‌سازی شود. این مدل ذاتاً به طور مرکزی اداره می‌شود و معایب IDSهای مرکزی که قبلاً ذکر شده است، در آن وجود دارد. عامل‌های بالاترین لایه، رخدادهای امنیتی را از طریق داده‌هایی که توسط عامل‌های لایه پایین‌تر جمع‌آوری شده است را رده‌بندی می‌نمایند. استفاده از ساختار لایه‌ای به این گونه که یک دسته از عامل‌ها

$$(f, v) \text{ where } f \in F, v \in V \quad (1)$$

در رابطه (۱)، F را به عنوان مجموعه تمام ویژگی‌های قابل استخراج از شبکه بوده در نظر می‌گیریم (f ها اعضای این مجموعه هستند) و به طور کلی V محدوده ممکن مقادیر متناظر با این ویژگی‌ها در نظر گرفته می‌شوند. v ها مقادیر ممکن مربوط به هر ویژگی هستند و لازم به ذکر است که مقادیر مجاز و ممکن هر ویژگی دارای محدوده خاص خود است و V به ازای هر ویژگی محدوده متفاوتی را تعریف می‌کند و به منظور تسهیل در درک عبارت به این شکل نشان داده شده است.

- تعریف ۳: سامانه تشخیص نفوذ مبتنی بر سیستم‌های چندعامله از تعدادی عامل تشکیل شده است که در دامنه‌های مختلف شبکه پخش شده‌اند. این سامانه طبق رابطه (۲) نمایش داده می‌شود:

$$\text{System} = \{G_1, G_2, \dots, G_n\} \quad (2)$$

G_i ها نماد عامل‌ها هستند. تعداد آنها برحسب نیاز تعیین می‌شود. هر عامل یک مجموعه ورودی و یک مجموعه خروجی دارد. مجموعه ورودی، شرایط شروع به فعالیت عامل را نشان می‌دهد. تولید خروجی توسط عامل می‌تواند شرایط سایر عامل‌ها را جهت شروع به فعالیت برقرار سازد. به طور مثال یک عامل می‌تواند با تحقق رخداد پوشش در گاه فعال شده و پس از جمع‌آوری اطلاعات و تحلیل آنها، یک خروجی مبنی بر مشکوک بودن IP منبع تولید نماید. در ادامه عامل دیگری که شرایط فعالیت آن با رخداد فعالیت IP مشکوک محقق می‌شود شروع به فعالیت خواهد نمود. نحوه شروع فعالیت عامل i در رابطه (۳) آمده است. C_i مجموعه ورودی یا شرایط عامل i را نشان می‌دهد. I نیز کلیه رخدادهای محقق شده را نشان می‌دهد:

$$\forall (f_j, v_j) \in C_i, (f_j, v_j) \in I \quad (3)$$

با توجه به رابطه (۳) بدیهی است که برای شروع فعالیت عامل باید تمام مجموعه شرایط محقق شوند.

- تعریف ۴: تابع همبستگی در هر عامل، رخداد امنیتی را دریافت کرده و با توجه به رخدادهای امنیتی قبلی که در حافظه عامل وجود دارد میزان همبستگی را محاسبه می‌نماید. تابع همبستگی با رابطه (۴) تعریف می‌شود:

$$\text{corr}(e_{id})[0, 1] \& e_{id} \{e_0, e_1, \dots, e_n\} \quad (4)$$

در رابطه (۴)، corr تابع محاسبه همبستگی در هر عامل را نشان می‌دهد. e_{id} نیز رخدادی با شناسه id است $\{e_0, e_1, \dots, e_n\}$ رخدادهای ثبت شده قبل از e_{id} هستند.

- تعریف ۵: تابع تصمیم‌گیری در هر عامل، میزان مخرب بودن یک رخداد را محاسبه می‌نماید. رابطه (۵) این تابع را نشان می‌دهد:

$$p(c, \text{coll}, \text{corr}(e_{id})) [0, 1] \quad (5)$$

p تابع تصمیم‌گیری است که میزان همبستگی محاسبه شده توسط واحد همبستگی را به همراه اطلاعات جمع‌آوری شده و شرایط محقق شده را به عنوان ورودی دریافت می‌کند و احتمال مخرب بودن رخداد

در [۱۶] سیستم تشخیص نفوذی با سه لایه پیشنهاد شده است. در این سیستم از هر دو روش مبتنی بر امضا و مبتنی بر ناهنجاری استفاده شده است. لایه اول با استفاده از قوانین ابتکاری برخی نفوذها را که بسیار شبیه نمونه‌های هنجار هستند تشخیص می‌دهد. لایه دوم با استفاده از خوشه‌بندی، نمونه ورودی که به مرکز خوشه ناهنجار نزدیک‌تر از مرکز خوشه هنجار هستند را نفوذ تشخیص می‌دهد. مرکز خوشه توسط الگوریتم ژنتیک محاسبه می‌شود. لایه سوم نیز با استفاده از یک رده‌بند جنگل تصادفی، نفوذها را تشخیص می‌دهد.

در [۴] یک سیستم چندعامله خودسازمانده به منظور جمع‌آوری شواهد حقوقی در سطح شبکه پیشنهاد شده است. این سیستم با هدف سازگاری با شبکه‌های امروزی از بعد مقیاس‌پذیری ارائه شده است. در این سیستم عامل‌ها خودمختارند و نقش‌های مختلفی در محیط امنیت شبکه می‌پذیرند. ایجاد و به‌کارگیری خودکار عامل‌ها که در سیستم‌های تشخیص نفوذ سنتی توسط کارشناس صورت می‌گیرد یکی از وجوه تمایز برجسته این سیستم است.

سامانه پیشنهادی این مقاله ترافیک شبکه را به منظور کشف انواع ناهنجاری پایش می‌نماید. معماری این سامانه توزیع شده و مبتنی بر سیستم‌های چندعامله است. این سامانه با به‌کارگیری عامل‌های خودمختار و هوشمند می‌تواند خود را با تغییرات شبکه سازگار نماید. وجود قابلیت تشخیص ناهنجاری می‌تواند ضمن کشف انواع نفوذها و حملات، هرگونه نقض سیاست‌های شبکه را نیز گزارش دهد.

۳- سامانه تشخیص نفوذ مبتنی بر سیستم‌های چندعامله

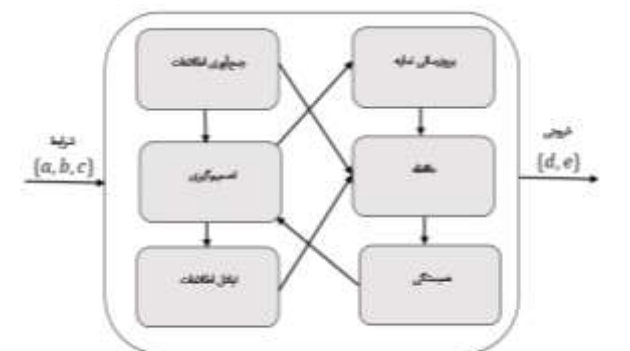
در این پژوهش یک سامانه مبتنی بر سیستم‌های چندعامله با ساختار توزیع شده و خودسازمانده به منظور کشف ناهنجاری ارائه شده است. الگوریتم‌های توسعه یافته در این سامانه، با استفاده از ویژگی و قابلیت عامل‌ها، ترافیک شبکه را پایش می‌نمایند. الگوریتم انتخاب هوشمند گروه که در این سامانه توسعه داده شده است، با بهینه نمودن عامل‌های مشارکت‌کننده در پایش یک رخداد، سبب افزایش نرخ تشخیص ناهنجاری و همچنین کاهش زمان موردنیاز برای تحلیل رخداد موردنظر می‌شوند. الگوریتم تصمیم‌گیری وزن‌دار هوشمند نیز با هوشمند نمودن وزن‌دهی تصمیم‌عامل‌ها سعی در بهبود نرخ تشخیص ناهنجاری و زمان تحلیل دارد. در ادامه به توصیف سامانه پیشنهادی می‌پردازیم.

۳-۱- تعاریف

- تعریف ۱: یک رخداد را هر نوع اتفاق قابل تشخیص در شبکه در نظر می‌گیریم که از نظر امنیتی نیاز به توجه دارد. مثلاً یک رخدادنما از نوع پروتکل Syslog با درجه سخت‌گیری 1^8 می‌تواند یک رخداد نیازمند به توجه باشد (درجه سخت‌گیری میزان اهمیت رخدادنما را نشان می‌دهد که می‌تواند عددی بین ۰ تا ۷ باشد. هرچه قدر این عدد کمتر باشد رخدادنما نیاز به توجه بیشتری دارد).
- تعریف ۲: اطلاعات جمع‌آوری شده از ترافیک شبکه به صورت زوج مرتب (f, v) از ویژگی و مقدار مطابق رابطه (۱) است:

هر عامل دارای یک حافظه کوچک است که در آن امتیاز عملکرد خود و تعدادی از آخرین گزارش‌های دریافتی را نگهداری می‌کند. تعداد گزارش‌های نگهداری شده به صورت ایستا در مرحله تنظیمات قبل از شبیه‌سازی تعیین می‌گردد. گزارش‌های نگهداری شده در روند محاسبه همبستگی استفاده می‌شود. با گذشت زمان مشخصی، اعتبار این گزارش‌ها از بین می‌رود. زمان عدم اعتبار این گزارش‌ها می‌تواند به صورت ایستا و یا پویا در نظر گرفته شود که در آزمایش‌های انجام شده به صورت ایستا تعیین شده است.

- همبستگی: این واحد، همبستگی بین رخدادها را محاسبه و تحلیل می‌نماید و می‌تواند زمینه تشخیص حملات چندگامی را فراهم کند.
- جمع‌آوری اطلاعات: اطلاعات مورد نیاز عامل از دامنه فعالیت آن را جمع‌آوری می‌کند.
- تصمیم‌گیری: در این واحد می‌توان از کلیه روش‌هایی که برای تشخیص ناهنجاری وجود دارد استفاده نمود.
- تبادل اطلاعات: این واحد وظیفه تبادل اطلاعات بین عامل‌ها را بر عهده دارد. عامل‌ها اطلاعات محلی جمع‌آوری شده را در قالب گزارش محلی با یکدیگر تبادل می‌نمایند. همچنین عامل‌ها نتیجه گزارش‌های نهایی را نیز به اطلاع یکدیگر می‌رسانند تا بتوانند امتیاز عملکرد خود و نیز نمایه دامنه فعالیت را به‌روزرسانی کنند. شکل ۲ نمای کلی معماری عامل‌ها را نشان می‌دهد. در این شکل a, b, c, d, e اطلاعات جمع‌آوری شده از شبکه هستند و یک نمونه از گزارش محلی تولید شده نیز نشان داده شده است.



$$R_{local} = \{e_{ts}, ts, g_{id}, coll = \{d, e\}, p(c = \{a, b, c\}, coll = \{d, e\}, corr(e_{ts})) = 0.8\}$$

شکل ۲: معماری عامل‌های سامانه

۳-۳- سامانه توزیع شده خودسازمانده

برای مدل‌سازی شبکه‌های پیشرفته امروزی می‌توان از مفهومی به نام دامنه استفاده کرد. با تعریف دامنه‌های مختلف می‌توان پیچیدگی‌های شبکه‌های امروزی را پیاده‌سازی نمود. با استقرار عامل‌ها در دامنه‌های شبکه می‌توان آن را پایش کرد. عامل‌های این سامانه وظیفه جمع‌آوری اطلاعات و تحلیل آنها را بر عهده دارند. هر کدام از عامل‌ها قادرند با در اختیار داشتن یک گزارش سراسری، در مورد ناهنجار بودن و یا نبودن

مشکوک را محاسبه می‌کند. c مجموعه شرایط عامل و $coll$ اطلاعات جمع‌آوری شده است. هر عاملی که شرایط آن محقق شود به جمع‌آوری اطلاعات از شبکه خواهد پرداخت.

- تعریف ۶: وضعیت دامنه فعالیت و گزارش محلی که در نهایت توسط عامل تولید می‌شود عبارت است از:

$$R_{local} = \{e_{id}, ts, g_{id}, coll, p(c, coll, corr(e_{id}))\} \quad (6)$$

در رابطه (۶) متغیر ts زمان وقوع رخداد را نشان می‌دهد، g_{id} عامل تولیدکننده گزارش است و $coll$ خروجی و حد جمع‌آوری‌کننده اطلاعات است که شامل اطلاعات تکمیلی در مورد رخداد مورد نظر است و ممکن است شرایط عامل‌های دیگری را محقق نموده و آنها را در فرآیند پایش مشارکت دهد. تابع p نیز میزان همبستگی محاسبه شده توسط واحد همبستگی را به همراه اطلاعات جمع‌آوری شده و شرایط محقق شده به عنوان ورودی دریافت می‌کند و احتمال مخرب بودن رخداد امنیتی را محاسبه می‌کند. برای تصمیم‌گیری نهایی در رابطه با مخرب بودن و یا نبودن یک رخداد، گزارش نهایی تولید می‌شود.

- تعریف ۷: گزارش نهایی شامل n گزارش محلی است. n تعداد عامل‌هایی است که در رابطه با یک رخداد امنیتی فعال شده‌اند و گزارش محلی تولید نموده‌اند. گزارش نهایی R_{global} طبق رابطه (۷) تعریف می‌شود:

$$R_{global} = \{R_{local 1}, R_{local 2}, \dots, R_{local n}\} \quad (7)$$

- تعریف ۸: برای محاسبه میزان کفایت شواهد جمع‌آوری شده از رابطه (۸) استفاده می‌گردد. بطوریکه مجموع قدرمطلق اختلاف میزان ناهنجاری محاسبه شده توسط هر عامل با مقدار 0.5 ، میزان قطعیت شواهد را نشان می‌دهد. به‌طور کلی هر چقدر میزان احتمال ناهنجاری با مقدار 0.5 تفاوت داشته باشد به معنای تصمیم دقیق‌تر است.

$$certainty = \sum_{R_{local i=1}}^{i=n} w_i |p_i - 0.5| \quad (8)$$

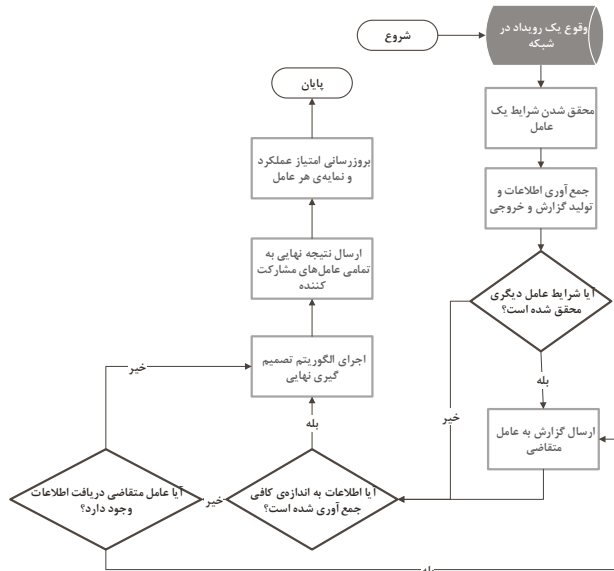
در رابطه (۸) P_i خروجی تابع تصمیم‌گیری عامل i است. این متغیر احتمال ناهنجار بودن رخداد را از دید عامل i نشان می‌دهد. w_i نیز وزن تصمیم عامل i را نشان می‌دهد. به‌طور پیش‌فرض برابر ۱ است.

۳-۲- معماری عامل‌ها

هر عامل دارای واحدهای^{۱۹} مختلفی به شرح زیر است:

- به‌روزرسانی نمایه: یکی از روش‌های تشخیص رفتار ناهنجار مدل‌سازی رفتار هنجار شبکه است. شناخت دامنه‌های مختلف شبکه و ساخت نمایه برای آنها می‌تواند نرخ هشدارهای کاذب را نیز کاهش دهد. در این راستا واحد نمایه برای دامنه فعالیت عامل یک نمایه می‌سازد و به صورت پویا آن را به‌روزرسانی می‌کند.
- حافظه:

شکل ۳ یک نمونه از نحوه پایش رخداد در سامانه را نشان می‌دهد که در آن مثالی از جمع‌آوری اطلاعات در مورد یک رخداد و تولید گزارش نهایی و در انتها تصمیم‌گیری در مورد آن ارائه شده است. سیاست در پیش گرفته شده در این روش این است که شواهد موجود در رابطه با رخداد مورد نظر به اندازه کفایت جمع‌آوری شود. در فرآیند اجرای الگوریتم نهایی و نحوه جمع‌آوری اطلاعات توسط عامل‌ها می‌توان از روش‌های مختلفی استفاده کرد. در ادامه الگوریتم‌های پیشنهادی که به این منظور توسعه داده شده‌اند آمده است.



شکل ۳: مثالی از نحوه تولید گزارش نهایی

۳-۴- الگوریتم‌های توسعه داده شده

مطابق با معماری سیستم پیشنهادی برای تعامل عامل‌ها با هم می‌توان از سیاست‌های متفاوتی استفاده کرد. همچنین به منظور تصمیم‌گیری نهایی در رابطه با ناهنجار بودن و یا نبودن یک رخداد نیز می‌توان از الگوریتم‌های مختلفی استفاده نمود. در ادامه الگوریتم‌هایی که برای این منظور توسعه داده شده‌اند معرفی می‌گردد.

۳-۴-۱- الگوریتم طبقه‌بندی پایه

الگوریتم پایه صرفاً به منظور مقایسه عملکرد الگوریتم‌های پیشنهادی و اندازه‌گیری میزان بهبود آنها ارائه شده است (شکل ۴). در این الگوریتم وقتی شرایط یک عامل محقق می‌گردد عامل مورد نظر شروع به فعالیت نموده و خروجی تولید می‌نماید. الگوریتم پایه گزارش محلی تولید شده توسط یک عامل را به صورت تصادفی به یکی از عامل‌های متقاضی در یافت گزارش ارسال می‌نماید. هر گزارش نهایی مجموعه‌ای از گزارش‌های محلی است که توسط عامل‌ها تولید می‌شود. الگوریتم تصمیم‌گیری نهایی به ازای هر R_{global} و به روش اکثریت آرا به کار گرفته می‌شود و رخداد مورد نظر در کلاس مخرب یا معمولی طبقه‌بندی می‌شود (خط ۷ تا ۱۰ شکل ۴). شایان ذکر است الگوریتم تصمیم‌گیری نهایی در هر یک از عامل‌ها می‌تواند اجرا شود و تنها شرط اجرای آن

یک رخداد تصمیم‌گیری نمایند. در سامانه‌های متمرکز تصمیم‌گیری در واحد پردازش مرکزی انجام می‌شود که در این صورت امکان بروز خطای شکست مرکزی وجود دارد. اما در سامانه توزیع شده پیشنهادی تمام عامل‌ها قابلیت تصمیم‌گیری نهایی دارند و امکان خطای شکست مرکزی از بین می‌رود. در این سامانه حتی اگر تعدادی از عامل‌ها از کار بیافتند با وجود احتمال افت عملکرد، همچنان شبکه پایش می‌شود.

به محض اینکه رخدادی در شبکه باعث تحقق شرایط یک عامل شود آن عامل شروع به جمع‌آوری اطلاعات، گزارش محلی و خروجی توسط نمایند. در روند جمع‌آوری اطلاعات، گزارش محلی و خروجی توسط عامل تولید می‌شود که در حقیقت جزئیات رخداد را از دید آن عامل نشان می‌دهد. خروجی تولید شده توسط عامل ممکن است شرایط سایر عامل‌ها را برقرار کرده و آنها را در فرآیند پایش مشارکت دهد. در ابتدای تحلیل یک رخداد اطلاعات کمی از جزئیات آن وجود دارد. با وارد عمل شدن عامل‌ها و افزایش مشارکت آنها اطلاعات بیشتری در مورد رخداد مورد نظر جمع‌آوری می‌گردد. برای تصمیم‌گیری نهایی برای برچسب رخداد پس از جمع‌آوری شواهد موجود به حدکفایت (طبق رابطه ۸)، برای آن یک گزارش نهایی تولید می‌شود.

برای بررسی ناهنجاری رخداد توسط هر عامل می‌توان از کلیه روش‌های موجودی که در ادبیات ارائه شده است استفاده کرد. بعد از تولید گزارش نهایی و تعیین برچسب نهایی رخداد، نتیجه این گزارش به اطلاع تمام عامل‌هایی که در فرآیند بررسی آن رخداد شرکت داشته‌اند خواهد رسید. در گام بعدی عامل‌ها عملکرد خود را با نتیجه نهایی مقایسه کرده و امتیاز خود را که g_{score} نام دارد به روزرسانی می‌کنند. این متغیر به ازای هر تصمیم‌گیری مقدار احتمال صحیح محاسبه شده توسط عامل مذکور را به صورت جمع تجمعی نگهداری می‌کند. نگهداری تجمعی امتیاز عامل می‌تواند دید خوبی از عملکرد عامل در تحلیل رخدادها پیشین ارائه دهد. هرچقدر این امتیاز بیشتر باشد به معنای عملکرد بهتر عامل است. عامل‌هایی که عملکرد ضعیفی دارند به مرور از فرآیند پایش دامنه حذف خواهند شد. حذف و اضافه شدن خودکار عامل‌ها به فرآیند تشخیص ناهنجاری باعث سازگار شدن سامانه با تغییرات شبکه خواهد شد.

عامل‌ها پس از دریافت نتیجه گزارش نهایی، نمایه دامنه‌فعالیت خود را نیز به روزرسانی می‌نمایند. عدم ناهنجار بودن یک رخداد در دامنه خاص باعث می‌شود تا این مورد روی تصمیم‌گیری‌های آینده در رابطه با رخداد مشابه تأثیرگذار باشد. زیرا ممکن است رخدادی که در وهله اول از دید عامل‌ها ناهنجار است یک رخداد معمول در شبکه مورد پایش باشد. عامل‌ها با به روزرسانی نمایه دامنه مورد فعالیت خود می‌توانند ویژگی‌های آن را نگهداری کنند. همچنین اگر رخدادی ناهنجار باشد می‌تواند ویژگی‌های ثبت شده در نمایه دامنه را تحت تأثیر قرار دهد و در صورت تکرار ممکن است تعدادی ویژگی را از نمایه حذف نماید. به عبارت دیگر خصوصیات ثبت شده در نمایه دامنه می‌توانند حذف یا اضافه گردند.

عملکرد عامل‌ها، سه عامل با بالاترین امتیاز را انتخاب کرده (اولویت با عامل‌هایی است که در دامنه مشترک با رخداد جاری هستند) و گزارش را به آنها ارسال می‌کند (سطر ۲ و ۳ شکل ۵). این کار باعث می‌شود فقط عامل‌هایی که کارا هستند انتخاب شوند تا فرآیند تشخیص ناهنجاری دقیق‌تر و در زمان کمتری صورت گیرد. نحوه به‌روزرسانی امتیاز عامل‌ها مشابه الگوریتم پایه است. با گذشت زمان، امتیاز عامل‌ها با شیب کم کاهش می‌یابد. بنابراین اگر عاملی برای مدت طولانی در فرآیند پایش شرکت نکرده باشد امتیاز عملکرد پایینی خواهد داشت. از سوی دیگر، امتیاز عملکرد پایین شانس انتخاب شدن عامل در فرآیند پایش را کاهش می‌دهد. زمانی که عامل برای مدت طولانی در فرآیندهای پایش شرکت ننماید در عمل حذف شده است.

Algorithm: Self-selected group Algorithm

Inputs

$R_{global} = \{R_{local}, \dots, R_{local}\}$ // a set of local reports
 $R_{local} = \{e_{id}, ts, g_{id}, (f, v), p\}$
 $g_{req} \subseteq G$ // agents whose conditions are satisfied and requested R_{global}
 $g_{sel} \subseteq G$ // selected agents to receive R_{global}
 $a \in (0,1)$ // a threshold for marking event as malicious
 $Num_{malicious} = 0$
 $Num_{innocuous} = 0$

1: Procedure: Agent Selection
 2: For $g \in g_{req}$ do
 3: Return threeHighest $((g, g_{score}) \in g_{req})$ as g_{se}

4: Procedure: Final decision
 5: For R_{local} in R_{global} do
 6: if $p \geq a$ then //the event is malicious in local report
 7: $Num_{malicious}++$
 8: else
 9: $Num_{innocuous}++$
 10: if $Num_{malicious} \geq Num_{innocuous}$ then
 11: Return $\langle e_{id}, decision = malicious \rangle$
 12: else
 13: Return $\langle e_{id}, decision = innocuous \rangle$
 14: For agent in g_{se} do
 15: If decision =malicious:
 16: $g_{score} = g_{score} + p$
 17: update(profile)
 18: else
 19: $g_{score} = g_{score} + (1-p)$
 20: update(profile)

شکل ۵: الگوریتم انتخاب هوشمند گروه

در این سامانه برای ضعیف قلمداد کردن یک عامل با توجه به امتیاز آن نیازی به تعریف حد آستانه نیست. زیرا امتیاز عملکرد برای مشارکت در فرآیند پایش صرفاً با مقایسه امتیاز عامل‌ها مورد استفاده قرار می‌گیرد. عملکرد ضعیف عامل‌ها ممکن است به دلایل مختلفی مانند نامناسب بودن روش تشخیص ناهنجاری، تنظیم نادرست پارامترهای عامل و دچار نقص شدن آن باشد. برچسب نهایی یک رخداد با روش اکثریت آراء بین سه عامل انتخاب شده صورت می‌گیرد. روش دیگر این است که شرط تصمیم‌گیری نهایی، مشابه الگوریتم پایه،

جمع‌آوری شواهد در حد قابل قبول است که این مقدار می‌تواند به‌وسیله تعریف یک حد آستانه پویا و یا ایستا مشخص شود. عدم تصمیم‌گیری نهایی در یک واحد پردازش مرکزی باعث می‌شود که سامانه مذکور به شکل توزیع شده عمل کند و وابسته به پردازشگر مرکزی نباشد و دچار خطای شکست مرکزی نیز نشود. همچنین اگر به هر دلیلی عاملی که در حال اجرای الگوریتم تصمیم‌گیری نهایی است از کار بیافتد عاملی که بلافاصله قبل از آن مشغول فعالیت بوده به پایش شبکه ادامه خواهد داد. هر عامل بعد از ارسال گزارش به عامل دیگر، مدت‌زمان مشخصی منتظر دریافت پاسخ (سیگنال) از عامل دریافت‌کننده گزارش خواهد ماند. دریافت این سیگنال به این معنی است که الگوریتم تصمیم‌گیری نهایی اجرا شده و یا گزارش به عامل دیگری ارسال شده است.

بعد از طبقه‌بندی رخداد، برچسب آن به اطلاع عامل‌هایی که در فرآیند جمع‌آوری اطلاعات و تحلیل رخداد مشارکت داشته‌اند خواهد رسید. سپس عامل‌ها عملکرد خود را با نتیجه نهایی مقایسه کرده و امتیاز خود را (g_{score}) به‌روزرسانی می‌کنند (سطر ۱۱ تا ۱۷ شکل ۴).

Algorithm: Baseline Algorithm

Inputs

R_{global} // a global report
 $R_{local} = \{e_{id}, ts, g_{id}, (f, v), p\}$
 g_p // participant agents
 $a \in (0,1)$ // a threshold for marking event as malicious
 $Num_{malicious} = 0$
 $Num_{innocuous} = 0$

1: Procedure: Final decision
 2: For $R_{global} = \{R_{local}, \dots, R_{local}\}$ do
 3: For $R_{local} = \{e_{id}, ts, g_{id}, (f, v), p\} \in R_{global}$ do
 4: if $p \geq a$ then //the event is malicious in local report
 5: $Num_{malicious}++$
 6: else
 7: $Num_{innocuous}++$
 8: if $Num_{malicious} \geq Num_{innocuous}$ then
 9: Return $\langle e_{id}, decision = malicious \rangle$
 10: else
 11: Return $\langle e_{id}, decision = innocuous \rangle$
 12: For agent in G_p do
 13: If decision =malicious:
 14: $g_{score} = g_{score} + p$
 15: update(profile)
 16: else
 17: $g_{score} = g_{score} + (1-p)$
 18: update(profile)

شکل ۴: الگوریتم طبقه‌بندی پایه

۳-۴-۲- الگوریتم انتخاب هوشمند گروه

برای اینکه عامل‌ها بتوانند خود را با بهتر و سریع‌تر با تغییرات شبکه وفق دهند و زمان تحلیل رخدادها نیز کاهش یابد، الگوریتم انتخاب هوشمند گروه ارائه شده است (شکل ۵). عملکرد این الگوریتم به این صورت است که وقتی یک گزارش محلی توسط یک عامل تولید شد، تعدادی عامل که شرایط آنها محقق شده است، درخواست دریافت این گزارش را خواهند داد. الگوریتم انتخاب هوشمند گروه با توجه به امتیاز

شود وزن تصمیم به مقدار پیش فرض ۱ تنظیم می‌گردد (سطر ۱۱ و ۱۴ شکل ۶).

```

Algorithm: Smart Series-weighting algorithm
Inputs
Rglobal //a global report
a ∈ (0,1) //a threshold for marking event as
malicious
w =1 //initial weight
Nummalicious = 0
Numinnocuous = 0
Domain =0 //domain of agent

1: Procedure: Final decision
2: For Rglobal = {Rlocal, ..., Rlocal} do
3:   For Rlocal = <eid, ts, gid, (f, v), p) ∈ Rglobal do
4:     if p ≥ a then //the event is malicious in
       local eport
5:       if gid. domain == Domain then
6:         Nummalicious + w
7:         W = w+1
8:         Domain = gid. domain
9:       else
10:        Nummalicious++
11:        W = 1 //the series is broken
12:        Domain = gid. domain
13:       else //the event is innocuous in local reports
14:        W = 1 //the series is broken
15:        Domain = 0
16:        Numinnocuous ++
17:       if Nummalicious ≥ Numinnocuous then
18:         Return <eid, decision =malicious>
19:       else
20:         Return <eid, decision =innocuous>
21:   For agent in gse do
22:     If decision =malicious:
23:       gsore = gsore +p
24:       update(profile)
25:     else
26:       gsore = gsore +(1-p)
27:       update(profile)
    
```

شکل ۶: الگوریتم انتخاب هوشمند گروه

در این الگوریتم هرچه تعداد عامل‌های همسایه که نظر بر مخرب بودن یک رخداد دارند بیشتر شود وزن تصمیم آنها و در نتیجه اثرگذاری آنها بر نتیجه نهایی بیشتر خواهد شد. علت صعودی بودن وزن دهی به این علت است که عامل‌های جدیدتر سری با استفاده از اطلاعات بیشتری تصمیم‌گیری نموده‌اند و احتمال اینکه تصمیم آنها دقیق‌تر باشد بیشتر است. شایان ذکر است در حالت عادی تصمیم هر عامل وزن ۱ دارد. همچنین کمترین مقدار وزن تأثیر تصمیم برابر ۱ است.

به عنوان مثال ۷ عامل را در نظر بگیرید که به منظور پایش ترافیک شبکه در ۳ دامنه پخش شده‌اند (شکل ۷). همانطور که در شکل مشاهده می‌شود، با تحقق رخداد CI عامل A1 فعال شده و پس از جمع‌آوری اطلاعات و تولید خروجی عامل A4 فعال شده و وارد فرآیند پایش می‌شود. به همین ترتیب در ادامه عامل A7 و A6 نیز وارد فرآیند پایش می‌شوند. در نهایت پس از جمع‌آوری اطلاعات به حد کفایت تولید گزارش نهایی، الگوریتم تصمیم‌گیری نهایی اجرا شده و هنجار بودن و یا نبودن ترافیک مشخص می‌گردد.

جمع‌آوری شواهد به‌اندازه کافی با شد. همچنین اگر دامنه‌ای از شبکه مورد تهاجم‌های پی‌درپی قرار گیرد عامل‌های بیشتری به تحلیل آن رخداد خواهند پرداخت و یا اگر دامنه‌ای از شبکه حذف شود با کاهش امتیاز عملکرد عامل‌های آن با توجه به تعریف یک حد آستانه، به‌مرور حذف خواهند شد و منابع زیر ساخت آزاد خواهند گردید. نهایتاً بعد از این که طبقه رخداد مشخص گردید، نتیجه به اطلاع تمام عامل‌های مشارکت‌کننده در فرآیند خواهد رسید تا عامل‌ها امتیاز خود را به‌روزرسانی نمایند (سطر ۱۰ تا ۲۰ شکل ۵). همچنین عامل نمایه دامنه خود را به‌روزرسانی می‌نماید تا در مراحل بعدی فرآیند بررسی ناهنجاری لحاظ گردد. یعنی وقتی عاملی با احتمال بالا رخدادی را ناهنجار تشخیص می‌دهد اما این رخداد توسط سامانه هنجار تشخیص داده می‌شود رخداد مذکور از دید عامل غیرمعمول بوده است.

با به‌روزرسانی نمایه توسط عامل در دفعات بعدی مواجهه با این رخداد، عامل تجربیات گذشته (این تجربیات در نمایه ذخیره می‌گردد) را در تصمیم‌گیری دخالت می‌دهد. این فرآیند باعث کاهش نرخ هشدارهای کاذب می‌گردد. همچنین اگر رخدادی توسط عامل هنجار تشخیص داده شود اما برچسب‌نهایی این رخداد ناهنجار باشد، عامل نمایه را به‌روزرسانی می‌نماید تا با تغییر در سیاست‌های شبکه و غیره سازگار گردد.

الگوریتم انتخاب هوشمند گروه همچنین این امکان را فراهم می‌کند که عامل‌ها در گروهی که بهترین عملکرد را دارند فعالیت نمایند. این امر سبب افزایش کارایی عامل‌ها می‌شود چراکه آنها از دامنه فعالیت خود اطلاعات دقیق‌تری خواهند داشت که در نتیجه آن، ناهنجاری‌ها دقیق‌تر تشخیص داده خواهد شد. در این صورت تابع همبستگی نیز مقدار دقیق‌تری را محاسبه خواهد کرد زیرا گزارش‌های تبادل شده بین عامل‌ها عموماً در یک دامنه اتفاق افتاده‌اند.

۳-۴-۳ الگوریتم تصمیم‌گیری وزن دار هوشمند

حمله‌ها و نفوذهای در شبکه عموماً در دامنه خاصی از شبکه رخ می‌دهند. براین اساس، در مواجهه با یک رخداد مخرب ممکن است عموم عامل‌هایی که در سایر دامنه‌ها قرار دارند رأی بر هنجار بودن آن بدهند. به‌منظور پیشگیری از این مشکل و کاهش نرخ منفی کاذب الگوریتم تصمیم‌گیری وزن دار هوشمند ارائه شده است (شکل ۶). عامل‌هایی که در یک دامنه قرار دارند و دقیقاً پشت سر هم وارد فرآیند پایش می‌شوند و گزارش محلی تولید می‌کنند را همسایه در نظر می‌گیریم.

این الگوریتم می‌تواند تعدادی عامل که در یک دامنه و در همسایگی یکدیگر هستند و تمام آنها رأی بر مخرب بودن یک رخداد دارند (به آنها سری متوالی می‌گوییم) را در گزارش نهایی تشخیص دهد (سطر ۴ و ۵ شکل ۶). در الگوریتم‌های پیشین نتیجه تصمیم هر عامل با وزن ۱ روی تصمیم نهایی تأثیرگذار بوده است. در این الگوریتم هرچه قدر طول سری متوالی عامل‌ها بیشتر شود ۱ واحد به وزن تصمیم عامل اضافه می‌گردد (سطر ۷ شکل ۶). به‌محض اینکه سری شکسته

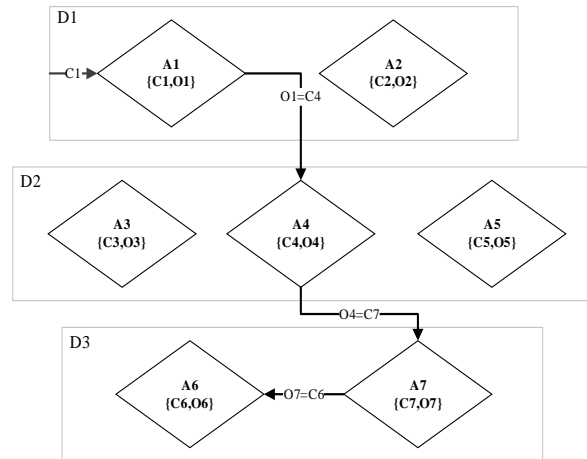
ناهنجار در یک قالب از مجموعه داده KDDTrain+ مدل سازی شده‌اند. قالب رخدادها به شکل $\langle e_{id}, type, detectability, validity \rangle$ هستند که در آن، e_{id} شناسه رخداد است که به صورت تصادفی و یکتا تولید می‌شود. رکوردهای مجموعه داده با توجه به برجسب آنها (هنجار و یا ناهنجار) و نیز نوع ناهنجاری و میزان سختی تشخیص به ۲۴۷ خوشه تقسیم شده‌اند. متغیر $type$ نشان می‌دهد که هر رخداد عضو کدام خوشه است. متغیر $detectability$ با توجه به فاصله هر رخداد از مرکز خوشه متناظر و نیز برجسب میزان سختی تشخیص آن محاسبه شده است. مرکز خوشه‌ها میانگین مقادیر ویژگی‌های اعضای خوشه‌ها هستند. هرچه مقدار متغیر $detectability$ کمتر باشد به معنی وجود حمله‌ای است که تشخیص آن دشوار است. حملات روز صفر را می‌توان نوعی از این حملات دانست که به علت ناشناخته بودن به سختی قابل تشخیص هستند. متغیر $validity$ میزان ناهنجاری یک رخداد را نشان می‌دهد. به منظور مدل سازی دقیق تر رخدادها و به تبع آن تحلیل بهتر آنها به جای نگاه دودویی به هنجار بودن و یا نبودن، از رویکرد فازی برای محاسبه میزان ناهنجاری استفاده شده است و میزان ناهنجاری یک رخداد در بازه $[0, 1]$ تعیین شده است (۱ برای ناهنجاری و ۰ برای نرمال). این متغیر با توجه به برجسب رکورد و نیز فاصله رکورد از مرکز خوشه‌ای که به آن تعلق دارد، محاسبه شده است.

تابع تصمیم‌گیری در عامل با توجه به دو متغیر $detectability$ و $validity$ میزان هنجار بودن رخداد را مشخص می‌کند. در گام اول ابتدا دو عدد تصادفی با توزیع نرمال و با میانگین مقادیر $detectability$ و $validity$ تولید می‌گردد. واریانس این دو توزیع با هم برابر است و به صورت ایستا تعیین می‌گردد. سپس عدد خروجی تابع تصمیم‌گیری بر اساس میانگین این دو عدد محاسبه می‌شود.

با تغییر واریانس توزیع‌های نرمال می‌توان انواع روش‌های تشخیص ناهنجاری را نیز مدل سازی نمود. به طور مثال هر چه واریانس توزیع کمتر باشد به این معناست که از روش تشخیص دقیق تری در عامل‌ها استفاده شده است. مزیت مدل سازی ارائه شده این است که اولاً نمای کلی رخدادهای مدل سازی شده واقعی است و تفسیر دقیق تری نسبت به رخدادهای صرفاً تصادفی و انتزاعی ارائه می‌دهد. ثانیاً این امکان را فراهم می‌کند تا سنجش سامانه مستقل از روش تشخیص ناهنجاری به کار گرفته شده در عامل باشد. در نتیجه می‌توان بر توسعه الگوریتم‌هایی که هوشمندی ارتباط عامل‌ها و کارایی آنها را افزایش می‌دهد که هدف اصلی این پژوهش است تمرکز کرد.

۴-۲- پیاده‌سازی

سامانه پیشنهادی با زبان پایتون، سیستمی با پردازنده corei5-CPU و حافظه RAM 8G پیاده‌سازی شده است. این سامانه از چهار کلاس اصلی مدل ساز داده‌ها، نوع داده ناهنجاری، عامل و شبیه‌ساز تشکیل شده است. جدول ۲ متغیرهای مربوط به کلاس عامل را نشان می‌دهد که به منظور تنظیم عملکرد عامل و به صورت ایستا تعیین می‌گردند.



شکل ۷: مثالی از روند پایش شبکه توسط ۷ عامل در ۳ دامنه

۴- پیاده‌سازی و تحلیل نتایج

همان‌طور که گفته شد در این پژوهش یک سامانه توزیع شده خود سازمانده می‌تواند بر سیستم‌های چندعامله ارائه شده است. برای آزمودن این سامانه ابتدا شبیه‌ساز این سامانه پیاده‌سازی شده است. شبیه‌ساز پیاده‌سازی شده از طریق [۱۷] قابل دسترس است. از این شبیه‌ساز برای مدل سازی داده‌ها، پیاده‌سازی کلاس‌های عامل، الگوریتم‌های پیشنهادی و نوع داده‌های مختص این پژوهش مثل ناهنجاری استفاده شده است.

۴-۱- مدل سازی داده‌ها و شبیه‌سازی

برای بررسی و تحلیل عملکرد سامانه پیشنهادی مجموعه داده آموزشی NSL_KDD به کار گرفته شده است. به گزارش [۱۸] که مرجعی معتبر برای انواع مجموعه داده‌ها برای سامانه‌های تشخیص نفوذ است، این مجموعه از معیارهای مؤثر ارزیابی در این حوزه است. برای سنجش سامانه داده‌های KDDTrain+ که دارای ۱۲۵۹۷۴ رکورد شامل ۶۷۳۴۳ داده نرمال و ۵۸۶۳۱ داده حمله است، استفاده شده‌اند. در گام اول با استفاده از نرم‌افزار وکا [۱۹] تعداد ۶ عدد از مؤثرترین ویژگی‌های مجموعه داده انتخاب و به مقادیر عددی تبدیل شدند (جدول ۱).

جدول ۱: ویژگی‌های منتخب مجموعه داده KDDTrain+

ردیف	شماره ویژگی	نام ویژگی
۱	۴	flag
۲	۵	Src_bytes
۳	۶	Dst_bytes
۴	۱۲	Logged_in
۵	۲۶	Srv_error_rate
۶	۳۰	Diff_srv_rate

همان‌طور که پیش‌تر ذکر شد عامل‌های این سامانه می‌توانند از روش‌های مختلفی برای رده‌بندی رخدادهای شبکه استفاده نمایند. از این رو به منظور سهولت در بررسی عملکرد عامل‌های سامانه و مقایسه الگوریتم‌های مختلفی که در این محیط توسعه داده می‌شوند رخدادهای

۳-۴- نتایج

هدف اصلی این پژوهش فراهم نمودن ویژگی مقیاس پذیری برای سیستم‌های تشخیص نفوذ مبتنی بر ناهنجاری است. به منظور تحلیل عملکرد الگوریتم‌های پیشنهادی، ناهنجاری‌های مدل‌سازی شده از مجموعه داده KDDTrain+ به سامانه تزریق شده است. برای هر رخداد ممکن است یکی از چهار حالت زیر رخ دهد:

- مثبت صحیح (TP): رخداد‌های ناهنجار که سامانه آنها را به درستی تشخیص می‌دهد.
 - منفی صحیح (TN): رخداد‌های نرمال که سامانه آنها را به درستی تشخیص می‌دهد.
 - مثبت کاذب (FP): رخداد‌های نرمال که سامانه آنها را به اشتباه ناهنجاری تشخیص می‌دهد.
 - منفی کاذب (FN): رخداد‌های ناهنجار که سامانه آنها را به اشتباه نرمال تشخیص می‌دهد.
- برای ارزیابی الگوریتم‌ها از معیارهای نرخ تشخیص ناهنجاری (DR)، نرخ مثبت کاذب (FRR) و دقت کل (AC) که به ترتیب با رابطه‌های (۹)، (۱۰) و (۱۱) محاسبه می‌شوند، استفاده شده است. دقت کل برابر است با نرخ نمونه‌هایی که به درستی برچسب‌گذاری شده اند.

$$DR = \frac{TP}{TP + FN} \quad (9)$$

$$FPR = \frac{FP}{FP + TN} \quad (10)$$

$$AC = \frac{TP + TN}{TP + TN + FP + FN} \quad (11)$$

همچنین برای ارزیابی زمان تصمیم‌گیری در رابطه با برچسب یک رخداد، تعداد تصمیم‌های محلی اتخاذ شده سنجیده شده است. جدول ۴ ماتریس ابهام حاصل از شبیه‌سازی انجام شده را نشان می‌دهد.

جدول ۴: ماتریس ابهام شبیه‌سازی

FN	FP	TN	TP	الگوریتم
۱۷۰۰۳	۷۴۰۷	۵۹۹۳۶	۴۱۶۲۸	پایه
۵۲۷۷	۱۱۴۴۲	۵۵۹۰۱	۵۳۳۵۴	تصمیم‌گیری وزن‌دار هوشمند
۸۲۰۹	۸۷۵۴	۵۸۵۸۹	۵۰۴۲۲	انتخاب هوشمند گروه

جدول ۵ مقدار معیارهای ارزیابی نرخ تشخیص، نرخ مثبت کاذب و دقت کل را برای سه الگوریتم پایه، انتخاب هوشمند گروه و تصمیم‌گیری وزن‌دار هوشمند نشان می‌دهد. در الگوریتم تصمیم‌گیری وزن‌دار هوشمند در واقع با مدنظر قرار دادن محل فعالیت عامل و در نظر گرفتن وزن بیشتر برای رأی عامل‌هایی که در دامنه رخداد مشکوک هستند نرخ تشخیص ناهنجاری در این الگوریتم در مقایسه با الگوریتم پایه افزایش یافته است. در الگوریتم هوشمند گروه نیز با توجه به اینکه تعداد محدودی از عامل‌هایی که بهترین عملکرد را در دامنه رخداد مشکوک داشته‌اند انتخاب شده است نرخ تشخیص افزایش یافته است. ستون سوم در جدول ۵، مقدار پارامتر نرخ مثبت کاذب را برای سه الگوریتم پایه،

جدول ۲: متغیرهای تنظیم عامل

مقدار	توضیح	متغیر
۲۰	مشخص‌کننده تعداد رخدادهایی که در حافظه عامل نگهداری می‌شوند	buffer_size
۰/۶	حد آستانه مربوط به ناهنجار قلمداد کردن یک رخداد	threshold_analysis
۱۰	مقدار اختلاف زمانی تأثیرگذار بر میزان همبستگی رخدادها	threshold_ts
۰/۲	واریانس توزیع‌های نرمال مورد استفاده در تابع تصمیم‌گیری را مشخص می‌نماید	variance
۲۰	مقدار اطلاعات ذخیره‌شده در نمایه را نشان می‌دهد	profile_size

جدول ۳ متغیرهای مربوط به کلاس شبیه‌سازی را نشان می‌دهد. این متغیرها نحوه شبیه‌سازی و مدل‌سازی شبکه را نشان می‌دهند. در جدول ۳ متغیر num_of_domain تعداد دامنه‌های موجود در شبکه را نشان می‌دهد. هرچه قدر تعداد دامنه در شبکه بیشتر باشد به معنای پیچیده‌تر شدن شبکه و حضور فناوری‌های مختلف در آن است.

جدول ۳: متغیرهای تنظیم شبیه‌ساز

مقدار	توضیح	متغیر
۱۰۰۰	تعداد شبیه‌سازی‌های انجام شده	Num_of_itation
[۵۰، ۱۰۰]	تعداد عامل‌های مستقر در شبکه	num_of_agents
{۱، ۲، ۳}	تعداد اعضای مجموعه شرایط هر عامل	num_of_condition
{۱، ۲، ۳}	تعداد اعضای مجموعه خروجی هر عامل	num_of_effect
[۲۰، ۵۰]	تعداد دامنه‌های موجود در شبکه	num_of_domain
[۲۰، ۵۰]	محدوده IP های عامل‌ها	agent_domain_range
(۰، ۱۰۰)	محدوده زمان	time_stamp_range
۱۰	حد آستانه کفایت شواهد برای تصمیم‌گیری نهایی	global_decision_threshold
[۰، ۱]	میزان ارتباط بین دامنه‌ها	domain_association_factor
۱	مقدار پیش‌فرض وزن تصمیم‌عامل‌ها	def_w

متغیر domain_association_factor میزان ارتباط منطقی بین دامنه‌ها را کنترل می‌نماید. در این متغیر مقدار صفر به معنی این است که تمام دامنه‌ها مستقل‌اند. در این حالت عامل‌ها فقط با عامل‌های هم دامنه خود ارتباط دارند. افزایش مقدار این متغیر به معنای وجود ارتباط بین دامنه‌های مختلف شبکه است. با این متغیر می‌توان پیچیدگی‌های مختلف شبکه و نیز تغییرات آن را مدل‌سازی نمود.

$$T = T_c + T_D + T_U \quad (12)$$

وقتی رخدادی در شبکه اتفاق می افتد عامل‌ها شروع به تحلیل آن و جمع‌آوری اطلاعات می‌نمایند که زمان این تحلیل و جمع‌آوری اطلاعات T_c نامیده می‌شود. بعد از جمع‌آوری اطلاعات به حدکفایت، باید الگوریتم تصمیم‌گیری نهایی اجرا شود که T_D این زمان را نشان می‌دهد. بعد از اجرای الگوریتم تصمیم‌گیری نهایی باید نتیجه به اطلاع عامل‌های مشارکت‌کننده برسد تا آن‌ها بتوانند خود را به‌روزرسانی نمایند که T_U نشانگر این زمان است. پیچیدگی هر کدام از این زمان‌ها با رابطه‌های (۱۳) تا (۱۵) نشان داده شده است:

$$T_c = O(n d_1) \quad (13)$$


$$T_D = O(n d_2) \quad (14)$$

$$T_U = O(n d_3) \quad (15)$$

در رابطه‌های فوق، n تعداد عامل‌های مشارکت‌کننده در فرآیند پایش رخداد است. d_1 متوسط زمان جمع‌آوری اطلاعات و تحلیل آن توسط هر عامل، d_2 متوسط زمان بررسی هر گزارش محلی در الگوریتم تصمیم‌گیری نهایی و d_3 متوسط زمان به‌روزرسانی هر عامل است. همان‌طور که از پیچیدگی‌های زمانی مشخص است مدت زمان تحلیل رویدادها به تعداد عامل‌های مشارکت‌کننده و یا همان تعداد تصمیم‌های محلی اتخاذ شده بستگی دارد. واضح است که:

$$d_1 > d_3 > d_2 \quad (16)$$

نمودار شکل ۸ مقدار پارامتر نرخ تعداد تصمیم‌های محلی که متناسب با زمان اجرا است را برای الگوریتم پایه، الگوریتم انتخاب هوشمند گروه و الگوریتم تصمیم‌گیری وزن‌دار هوشمند نشان می‌دهد. تعداد تصمیم‌های محلی اتخاذ شده توسط عامل‌ها رابطه مستقیمی با مدت زمان اجرای برنامه دارد. تعداد عامل‌های مشارکت‌کننده در فرآیند پایش بر اساس رابطه (۸) تعیین می‌گردد.



شکل ۸: مقایسه نرخ تعداد تصمیم‌های محلی

الگوریتم انتخاب هوشمند گروه با انتخاب عامل‌های کارا سعی در بهبود متغیر p_i دارد. هرچقدر این متغیر که خروجی تابع تصمیم‌گیری است قطعی‌تر باشد (به این معنا که به صفر یا یک نزدیک‌تر باشد) مقدار $certainty$ زودتر به حدکفایت از پیش تعیین شده خواهد رسید. الگوریتم تصمیم‌گیری وزن‌دار هوشمند نیز با افزایش مقدار w_i سعی دارد متغیر $certainty$ را زودتر به حدکفایت برساند. همان‌طور که در شکل ۸ مشخص است نرخ تعداد تصمیم‌های محلی در الگوریتم‌های

انتخاب هوشمند گروه و تصمیم‌گیری وزن‌دار هوشمند نشان می‌دهد. در الگوریتم‌های انتخاب هوشمند گروه و تصمیم‌گیری وزن‌دار هوشمند نرخ مثبت کاذب در مقایسه با الگوریتم پایه اندکی افزایش یافته است. بنابر [۲۷] به‌طور کلی به علت نیاز به حفظ زیرساخت شبکه از حملات و تهدیدات مختلف، پارامتر نرخ تشخیص از اهمیت بیشتری در مقایسه با نرخ هشدارهای کاذب برخوردار است.

جدول ۵: نتایج الگوریتم‌های توسعه داده شده

الگوریتم	DR	FP	AC%
پایه	۰/۷۱	۰/۱۱	۸۱
تصمیم‌گیری وزن‌دار هوشمند	۰/۹۱	۰/۱۷	۸۸
انتخاب هوشمند گروه	۰/۸۶	۰/۱۳	۸۶

در جدول ۶ نتایج حاصل از شبیه‌سازی تعدادی از سامانه‌های تشخیص نفوذ مطرح اخیر آورده شده است. نتایج حاصل از آزمایش‌های انجام شده توسط این سامانه‌ها روی مجموعه داده KDDTrain+ در جدول گزارش شده است. مشخص است که میزان دقت کل در سامانه توزیع شده چندعامله پیشنهادی این مقاله با در نظر گرفتن الگوریتم تصمیم‌گیری وزن‌دار هوشمند در مقایسه با این سامانه‌ها بهبود یافته است. همچنین با در نظر گرفتن الگوریتم انتخاب هوشمند گروه، میزان دقت کل در مقایسه با سامانه‌های عنوان شده بهبود یافته است. لازم به ذکر است که اکثر سامانه‌های مبتنی بر سیستم‌های چندعامله که در مرور ادبیات بررسی شده‌اند، از پایگاه داده‌های رایج برای ارزیابی کار خود استفاده نکرده‌اند. بنابراین روش پیشنهادی با به‌روزترین تحقیقات اخیر مقایسه شده است.

جدول ۶: میزان دقت کل برای روش‌های مطرح اخیر

روش	سال	AC%
روش پیشنهادی	۲۰۲۰	۸۸/۰۰
مبتنی بر یادگیری عمیق [۲۰]	۲۰۱۷	۸۳/۲۸
مبتنی بر یادگیری نیمه‌نظارتی فازی [۲۱]	۲۰۱۷	۸۴/۱۲
مدل حافظه کوتاه مدت - بلندمدت دوطرفه [۲۲]	۲۰۲۰	۸۴/۲۵
مبتنی بر یادگیری نیمه‌نظارتی فازی [۲۳]	۲۰۱۸	۸۴/۵۴
مبتنی بر یادگیری عمیق [۲۴]	۲۰۱۸	۸۵/۰۰
انتخاب ویژگی و الگوریتم‌های هوش جمعی [۲۵]	۲۰۱۹	۸۵/۸۰
مبتنی بر درخت تصمیم‌گیری [۲۶]	۲۰۱۹	۸۵/۸۱
سیستم تشخیص نفوذ سه لایه [۱۶]	۲۰۱۹	۸۶/۷۵

۴-۴- پیچیدگی زمانی

از بین مقالات مقایسه شده با تحقیق حاضر پژوهش‌های [۲۰]، [۲۴]، [۲۵] و [۲۶] زمانی برای آموزش مدل و تحقیق [۲۱] زمان آزمایش داده‌ها را ارائه داده‌اند. لازم به ذکر است که زمان‌های گزارش شده با استفاده از پردازنده‌های متفاوتی بدست آمده‌اند و امکان مقایسه بین آنها از این طریق ممکن نیست. در ادامه به تحلیل پیچیدگی زمانی سامانه پیشنهادی می‌پردازیم. زمان تحلیل رخدادها در این سامانه از سه قسمت به‌صورت رابطه (۱۲) تشکیل شده است:

تصمیم‌گیری نهایی هنجار بودن و یا نبودن رخداد مشخص می‌شود. همچنین عامل‌ها از محیط مورد پایش خود یک نمایه می‌سازند که این نمایه به ماژول تصمیم‌گیری در اخذ تصمیم دقیق‌تر کمک می‌نماید. بدیهی است که استفاده از چند عامل و به تبع آن استفاده از داده‌های بیشتر که در نهایت نوع رخداد را بوسیله الگوریتم رای اکثریت بین نظرات عامل‌ها مشخص می‌کند کارا تر از یک روش متمرکز است؛ هرچند این امر هزینه زمانی بیشتری را می‌طلبد. البته سعی ما بر این بوده است که با گروه‌بندی هوشمند و وزن‌دهی هوشمند به تصمیم‌ها، زمان را حتی الامکان کاهش دهیم.

با توجه به این توضیحات می‌توان ادعا کرد که معماری پیشنهادی این مقاله نسبت به روش‌های موجود بهبود داشته است و نتایج پیاده‌سازی نیز گواه این موضوع است.

۵-۵- نتیجه و کارهای آینده

سامانه پیشنهادی ارائه‌شده قادر است ضمن فراهم کردن ویژگی مقیاس‌پذیری، از روش‌های موجود تشخیص ناهنجاری بهره برده و عملکرد آنها را بهبود دهد. در سامانه مذکور عامل‌ها می‌توانند بدون پیش شرط وارد سامانه شده و شروع به فعالیت نمایند و با سایر عامل‌ها به تعامل بپردازند. قابلیت اضافه و حذف شدن هوشمند عامل‌ها ویژگی مقیاس‌پذیری را در سامانه فراهم نموده است. با این روش سامانه تشخیص نفوذ قادر است خود را با تغییرات شبکه سازگار نماید. در عموم سامانه‌های تشخیص نفوذ از یک پردازشگر مرکزی استفاده می‌شود که عامل‌ها عموماً وظیفه جمع‌آوری اطلاعات و ارسال آن به پردازشگر را دارند. در سامانه پیشنهادی این مقاله عامل‌ها می‌توانند ضمن جمع‌آوری اطلاعات به تحلیل آنها نیز بپردازند. وجود ویژگی توزیع‌شدگی از بروز نقطه شکست مرکزی جلوگیری می‌نماید. وجود فاکتور امتیاز عملکرد در عامل‌ها باعث می‌شود که هر عامل در دامنه فعالیت خود تخصصی‌تر عمل نماید. همچنین عامل‌هایی که امتیاز عملکرد پایین دارند به‌مرور از سامانه حذف‌شده و منابع تحت اختیار مثل حافظه و CPU را عملاً آزاد می‌نمایند. وجود چنین قابلیت‌هایی باعث می‌شود که این سامانه، خود سازمانده باشد.

به‌منظور بررسی رخداد‌های ترافیک شبکه، در این سامانه تعدادی الگوریتم برای تصمیم‌گیری نهایی پیشنهاد شده است. این الگوریتم‌ها برچسب نهایی یک رخداد را با توجه به گزارش محلی تولیدشده توسط هر عامل تعیین می‌نمایند. ارزیابی صورت گرفته روی این الگوریتم‌ها نشان داده است که میزان نرخ تشخیص در مقایسه با سامانه تشخیص نفوذ سه‌لایه ارائه‌شده اخیر بهبود یافته است. نرخ مثبت کاذب اندکی افزایش یافته است که در مجموع میزان قابل قبولی دارد. شایان ذکر است که در صنعت، نرخ تشخیص از اهمیت بیشتری برخوردار است. همچنین ارزیابی صورت گرفته بر مقدار تحلیل مورد نیاز برای تعیین برچسب یک رخداد روی الگوریتم‌های پیشنهادی نشان داده است که

تصمیم‌گیری وزن دار هوشمند و انتخاب هوشمندگروه در مقایسه با الگوریتم پایه کاهش یافته است. به‌عبارت‌دیگر زمان تحلیل رخدادها در این دو الگوریتم کاهش یافته است. این امر به‌این دلیل است که الگوریتم انتخاب هوشمندگروه از عامل‌های کارا تر استفاده می‌نماید و در زمان کمتری شواهد کافی جمع‌آوری می‌کند. در الگوریتم تصمیم‌گیری وزن دار هوشمند نیز به علت وزن بیشتر تصمیم‌های عامل‌های همسایه نیز شواهد جمع‌آوری شده زودتر به حدکفایت می‌رسد.

۴-۵- تحلیل کارایی

سامانه ارائه‌شده در این مقاله علاوه بر هدف بهبود نرخ تشخیص ناهنجاری در ترافیک شبکه سعی دارد ویژگی مقیاس‌پذیری و همچنین جلوگیری از بروز خطای نقطه‌شکست مرکزی را نیز فراهم کند. همانطور که پیش‌تر اشاره شد از یک سو، وجود قابلیت حذف و اضافه شدن هوشمند عامل‌ها به فرآیند پایش ترافیک شبکه، که بنا بر تغییرات و نیازهای شبکه رخ می‌دهد، ویژگی مقیاس‌پذیری را فراهم آورده است و این سامانه بدون نیاز به یک فرد خبره می‌تواند خود را با تغییرات شبکه سازگار نماید. از سوی دیگر نحوه ارتباط عامل‌ها و فعال شدن آنها نیز قابلیت مقیاس‌پذیری را پشتیبانی می‌کنند. علی‌رغم اهمیت مقیاس‌پذیری سامانه‌های تشخیص نفوذ، در کارهای انجام شده در این حوزه توجه کمی به این ویژگی معطوف بوده است (مقالات عنوان شده در جدول ۶ به این موضوع نپرداخته‌اند).

در سامانه توزیع شده پیشنهادی، عامل‌ها ساختار مشابه داشته و هر یک قابلیت جمع‌آوری داده، تحلیل داده‌ها و تصمیم‌گیری نهایی دارند و اگر یکی از عامل‌ها به هر دلیلی از کار بیافتد، عامل‌های دیگر می‌توانند به فرآیند پایش ادامه دهند. وجود این ویژگی از بروز خطای نقطه‌شکست مرکزی می‌کاهد. با توجه به اینکه پایش یک امر 7×24 است جلوگیری از وقوع خطای نقطه‌شکست مرکزی با کمترین هزینه نیازمند توجه است. که این موضوع نیز کمتر در مقالات مورد بررسی قرار گرفته است (مقالات مورد مقایسه به این موضوع نپرداخته‌اند).

بدیهی است که هدف اصلی این سامانه بهبود نرخ تشخیص است. در مقالات مختلف سعی شده است که با بهره‌گیری از روش‌های متنوعی مانند روش‌های یادگیری ماشین و یا روش‌های هیوربستیک و غیره مدلی ساخته شود و با داده‌های آموزشی، آموزش داده شود تا در نهایت بتواند نرخ تشخیص را بهبود دهد. ماهیت معماری پیشنهادی این مقاله و همچنین ساختار عامل‌های به‌کارگرفته‌شده در آن به‌این صورت است که می‌تواند از روش‌های مختلفی برای تشخیص ناهنجاری در ترافیک شبکه در ماژول تصمیم‌گیری عامل‌ها استفاده نمود. به عبارت دیگر عامل‌های به‌کارگرفته‌شده در این سامانه می‌توانند هر نوع روش تشخیص ناهنجاری را با استفاده از رویکرد بررسی داده‌های بیشتر و به کارگیری عامل‌های بیشتر در تحلیل بهبود دهند. عامل‌ها فراخور نیاز با یکدیگر همکاری می‌کنند و هر یک از زاویه دید خود و نیز با استفاده از اطلاعات محلی خود، رخداد را پایش کرده و نظر خود را با استفاده از ماژول تصمیم‌گیری اعلام کرده و نهایتاً پس از اجرای الگوریتم

- [12] K. Shanmugasundaram, N. Memon, A. Savant and H. Bronnimann, "ForNet: A distributed forensics network" International Workshop on Mathematical Methods, Models, and Architectures for Computer Network Security, Springer, 2003.
- [13] Z.A. Baig, "Multi-agent systems for protecting critical infrastructures: A survey", Journal of Network and Computer Applications, vol. 35, no. 3, pp. 1151-1161, 2012.
- [14] R. Kesavamoorthy and K.R. Soundar, "Swarm intelligence based autonomous DDoS attack detection and defense using multi agent system", Cluster Computing, vol. 22, no. 4, pp. 9469-9476, 2019.
- [15] W. Mees, "Multi-agent anomaly-based APT detection", Proceedings of Information Systems Technology Panel Symposium, 2012.
- [۱۶] آمرهای، بیگی، «یک سیستم تشخیص نفوذ چندلایه با رویکرد ترکیبی»، پانزدهمین کنفرانس بین‌المللی انجمن رمز ایران، تهران، انجمن رمز ایران، ۱۳۹۷.
- [17] *Distributed Self-organizing Multi-agent System*, July 2020, https://gitlab.com/N_shakiba/dsms/
- [18] *NSL-KDD dataset*, June 2020, <https://www.unb.ca/cic/datasets/nsl.html>.
- [19] M. Hall, E. Frank, G. Holmes, B. Pfahringer, P. Reutemann and I.H. Witten, "The WEKA data mining software: an update", ACM SIGKDD explorations newsletter, vol. 11, no. 1, pp. 10-18, 2009.
- [20] C. Yin, Y. Zhu, J. Fei and X. He, "A deep learning approach for intrusion detection using recurrent neural networks" IEEE Access, vol. 5, pp. 21954-21961, 2017.
- [21] R.A.R. Ashfaq, X.Z. Wang, J.Z. Huang, H. Abbas and Y.L. He, "Fuzziness based semi-supervised learning approach for intrusion detection system", Information Sciences, vol. 378, pp. 484-497, 2017.
- [22] T. Su, H. Sun, J. Zhu, S. Wang and Y. Li, "BAT: Deep learning methods on network intrusion detection using NSL-KDD dataset". IEEE Access, vol. 8, pp. 29575-29585, 2020
- [23] Y. Gao, Y. Liu, Y. Jin, J. Chen, and H. Wu, "A novel semi-supervised learning approach for network intrusion detection on cloud-based robotic system", IEEE Access, vol. 6, pp. 50927-50938, 2018.
- [24] S. Naseer, Y. Saleem, S. Khalid, M.K. Bashir, J. Han, M.M. Iqbal and K. Han, "Enhanced network anomaly detection based on deep neural networks". IEEE Access. Vol 6, pp. 48231- 48246, 2018.
- [25] B.A. Tama, M. Comuzzi and K.H. Rhee, "TSE-IDS: A two-stage classifier ensemble for intelligent anomaly-based intrusion detection system". IEEE Access, vol. 7, pp. 94497-507, 2019.
- [26] P. Illy, G. Kaddoum, C.M. Moreira, K. Kaur and S. Garg, "Securing fog-to-things environment using intrusion detection system based on ensemble learning". IEEE Wireless Communications and Networking Conference (WCNC), pp. 1-7, 2019.
- [27] K. Alsubhi, N. Bouabdallah and R. Boutaba, "Performance analysis in intrusion detection and prevention systems", IFIP/IEEE International Symposium on Integrated Network Management (IM 2011) and Workshops, 2011.
- دو الگوریتم انتخاب هو شمندگروه و تصمیم‌گیری وزن‌دار هو شمند در مقایسه با الگوریتم پایه عملکرد بهتری دارند.
- در آینده به منظور بهبود نرخ هشدارهای کاذب بر توسعه الگوریتمی در سیستم چندعامله توزیع شده خودسازمانده تمرکز خواهد شد. این امر می‌تواند با تغییر در معماری عامل‌ها و یا الگوریتم‌های تصمیم‌گیری نهایی صورت گیرد. در این پژوهش تابع تشخیص ناهنجاری در عامل‌ها به صورت آماری مدل‌سازی شده‌است که در آینده می‌توان به کارگیری انواع روش‌های تشخیص ناهنجاری در عامل‌ها را مورد ارزیابی قرار داد.

مراجع

- [1] G. Fernandes, J.J. Rodrigues, L.F. Carvalho, J.F. Al-Muhtadi and M.L. Proença, "A comprehensive survey on network anomaly detection", Telecommunication Systems, vol. 70, no. 3, pp. 447-489, 2019.
- [2] A. Nisioti, A. Mylonas, P.D. Yoo and V. Katos, "From intrusion detection to attacker attribution: A comprehensive survey of unsupervised methods", IEEE Communications Surveys & Tutorials, vol. 20, no. 4, pp. 3369-3388, 2018.
- [3] M.H. Bhuyan, D.K. Bhattacharyya and J.K. Kalita, "Network anomaly detection: methods, systems and tools", IEEE communications surveys & tutorials, vol. 16, no. 1, pp. 303-336, 2013.
- [4] P. Kendrick, N. Criado, A. Hussain and M. Randles, "A self-organising multi-agent system for decentralised forensic investigations", Expert Systems with Applications, vol. 102, pp. 12-26, 2018.
- [5] V. Rothamsted, T. Lewis and V. Barnett, *Outliers in statistical data*, John Wiley & Sons, 1996.
- [6] N. Hoque, M.H. Bhuyan, R.C. Baishya, D.K. Bhattacharyya and J.K. Kalita, "Network attacks: Taxonomy, tools and systems", Journal of Network and Computer Applications, vol. 40, pp. 307-324, 2014.
- [7] *2020 Cyber Security Statistics The Ultimate List Of Stats, Data & Trends*, June 2020, <https://purplesec.us/resources/cyber-security-statistics>.
- [8] M. Wooldridge, *An Introduction to MultiAgent Systems*. Second ed., John Wiley & sons, 2009.
- [9] P. Shakarian, G.I. Simari, G. Moores and S. Parsons, "Cyber attribution: An argumentation-based approach", Cyber Warfare, Springer, pp. 151-171, 2015.
- [10] A.D. McKinnon, S.R. Thompson, R.A. Doroshchuk, G.A. Fink and E.W. Fulp, "Bio-inspired cyber security for smart grid deployments", IEEE PES Innovative Smart Grid Technologies Conference (ISGT), pp. 1-6, 2013.
- [11] A. Jahanbin, A. Ghafarian, S.A. Hosseini Seno and S. Nikookar, "A computer forensics approach based on autonomous intelligent multi-agent system", International Journal of Database Theory and Application, vol. 6, no.5, pp. 1-12, 2013.

زیر نویس‌ها

- ¹¹ Clustering
- ¹² Classification
- ¹³ Swarm intelligence
- ¹⁴ Degradation
- ¹⁵ Forensic
- ¹⁶ Entropy
- ¹⁷ Advanced persistent threat
- ¹⁸ Severity level
- ¹⁹ Module

- ¹ Integrity
- ² Confidentiality
- ³ Intrusion detection system
- ⁴ Host based
- ⁵ Signature based
- ⁶ Anomaly based
- ⁷ Zero day attacks
- ⁸ False positive
- ⁹ Profile
- ¹⁰ Single point of failure