

تشخیص و پیشگیری از حملات نرخ پایین منع سرویس توزیع شده پروتکل HTTP در شبکه های نرم افزار محور مبتنی بر سویچ های P4 با بکارگیری الگوریتم های یادگیری ماشین

رضا فلاحی کپورچالی^۱، رضا محمدی*^۲، محمد نصیری^۳

^۱ کارشناسی ارشد شبکه های کامپیوتری، دانشکده فنی مهندسی، دپارتمان کامپیوتر، دانشگاه بوعلی سینا، همدان

^۲ استادیار گروه مهندسی کامپیوتر، دانشکده فنی مهندسی، دپارتمان کامپیوتر، دانشگاه بوعلی سینا، همدان

^۳ دانشیار گروه مهندسی کامپیوتر، دانشکده فنی مهندسی، دپارتمان کامپیوتر، دانشگاه بوعلی سینا، همدان

چکیده

معماری SDN به دلیل فراهم کردن دید انتزاعی در شبکه، امروزه محبوبیت بسیاری یافته است. در معماری SDN، به دلیل وجود کنترلر مرکزی، بیشتر بار پردازشی بر عهده کنترلر شبکه است. این مرکزیت پردازش، کنترلر شبکه را به هدفی بسیار مناسب برای حملات DDoS تبدیل کرده است. در چند دهه اخیر، روش های مختلفی برای مقابله با این حملات ارائه شده است؛ اما با افزایش پیچیدگی حملات، میزان ترافیک شبکه و در نتیجه میزان بار پردازشی روی کنترلر شبکه، محققان درصدد بکارگیری ادوات صفحه داده در پردازش های لازم برآمدند. یکی از کارآمدترین روش های ارائه شده، معرفی فناوری P4 است. با روی کار آمدن P4، می توان از توان پردازشی ادوات صفحه داده در فرآیند تشخیص و پیشگیری حملات DDoS در شبکه های SDN استفاده نمود؛ که نتیجه حاصل از آن، کاهش میزان بار پردازشی روی کنترلر شبکه و افزایش انعطاف پذیری در ادوات صفحه داده است. در این مقاله، به معرفی یک مدل تشخیص و پیشگیری از حملات slow-rate DDoS با بکارگیری سویچ های P4 و استفاده از تکنیک های یادگیری ماشین پرداخته شده است. هدف اصلی ارائه این مدل، بکارگیری سویچ های قابل برنامه ریزی P4 در روند تشخیص حملات، به جهت کمینه سازی سربار پردازشی کنترلر است. در پیاده سازی این مدل از کنترلر ONOS استفاده شده است. فرآیند استخراج مقادیر ویژگی های مورد نیاز مدل های یادگیری ماشین، نیازمند تخصیص توان پردازشی بخصوصی است که با بکارگیری سویچ های قابل برنامه ریزی P4 و پردازش محلی بسته ها در سویچ، این سربار پردازشی کمینه خواهد شد. در این پژوهش، مدل ارائه شده از جهت زمان تشخیص حمله، مصرف پهنای باند و سربار پردازشی کنترلر مورد ارزیابی قرار گرفته است. بر اساس نتایج به دست آمده، مدل ارائه شده نسبت به حالت معمول SDN، حدود ۶۰ ثانیه بهبود در تشخیص حمله و حدود ۵۰٪ کاهش سربار پردازشی و مصرف پهنای باند را به همراه داشته است. نتایج حاصل، نشانگر آن است که استفاده از ادوات P4 و قابلیت برنامه ریزی ادوات صفحه داده، تاثیر بسزایی در تشخیص حملات slow-rate DDoS و بار پردازشی کنترلر در شبکه های SDN خواهد داشت.

کلمات کلیدی: پردازشگرهای مستقل از پروتکل و قابل برنامه ریزی پکت، حملات نرخ پایین منع سرویس توزیع شده، شبکه های نرم افزار محور،

یادگیری ماشین، اونوس، سرور وب

تاریخچه مقاله:

تاریخ ارسال: ۱۴۰۱/۱۰/۱۰

تاریخ اصلاحات: ۱۴۰۱/۱۱/۱۵

تاریخ پذیرش: ۱۴۰۱/۱۲/۲۵

تاریخ انتشار: ۱۴۰۱/۱۲/۲۹

Keywords:

P4
Slow-rate DDoS
Machine Learning
SDN
ONOS
Web server

* ایمیل نویسنده مسئول:

R.mohammadi@basu.ac.ir

Detection and prevention of slow-rate DDoS attacks on HTTP protocol in P4-based software defined networks using machine learning techniques

Reza Fallahi Kapourchaali¹, Reza Mohammadi^{*2}, Mohammad Nassiri³

¹ Master of Information Technology, Department of Computer Engineering, Faculty of Engineering, Bu-Ali Sina University, Hamedan, Iran.

² Assistant Professor, Department of Computer Engineering, Faculty of Engineering, Bu-Ali Sina University, Hamedan, Iran.

³ Associate Professor, Department of Computer Engineering, Faculty of Engineering, Bu-Ali Sina University, Hamedan, Iran.

Abstract

SDN architecture has become popular nowadays due to the abstract view that it provides. Due to the centralized network Controller in SDN, Most of the processing load is on the controller. This centralized controller has made this architecture a great target to DDoS attacks. Over the few past decades, many detection methods has been proposed; but with increased traffic and complexity of DDoS attacks, researchers aimed to utilize the data plane processing power. One of the most effective methods that has been proposed, is the P4 technology. With P4, we can utilize the processing power of the data plane devices in detection and prevention procedure of DDoS attacks on SDN; which will result the reduction of controller overhead and more flexibility data plane devices. In this research, we proposed a detection and prevention model that utilizes machine learning techniques along with implementation of P4 switches to detect slow-rate DDoS attacks on SDN. The ONOS controller has been used for implementation of this model. The goal of proposing this model, is to use programmable P4 switches in detection procedure, in order to minimize the controller overhead. The procedure of extracting feature values for machine learning models, will result processing overhead for the controller, but with implementing this procedure with P4 switches on data plane and local processing of packets in the switch, the controller overhead will be minimized. The proposed model has been analyzed in terms of detection time, bandwidth consumption and CPU utilization of the controller. In compare to the normal SDN, the results shows about 60 seconds improvement in detection time, about 50% less overhead on bandwidth consumption and CPU utilization in proposed method. The results show that implementation of P4 data plane, with programming the data plane devices, will have significant effects on detection of slow-rate DDoS attacks and processing load of the controller in SDN.

۱ - مقدمه

SDN یک معماری جدید از شبکه‌های اینترنتی است، که برای ساده سازی مدیریت شبکه معرفی شده است؛ این ساده سازی به وسیله جداسازی صفحه داده^۱ از صفحه کنترل^۲ به دست آمده، که مهم ترین ویژگی این معماری نیز به حساب می آید. هر یک از دو بخش اصلی صفحه داده و صفحه کنترل شامل زیربخش‌هایی هستند، که در معماری سنتی شبکه نیز وجود دارد، اما در این معماری به شکل ماژولار تغییر شکل داده و همین باعث انعطاف پذیری بالا در تولید و بکارگیری تجهیزات شبکه و در نهایت، مدیریت بهتر شبکه شده است.

در معماری سنتی شبکه، ادوات خاص منظوره همراه با توانایی پردازشی بخصوص و محدود، مورد استفاده قرار می گیرند که بخش صفحه کنترل و صفحه داده و به دنبال آن مفهوم کنترل و انتقال داده در شبکه، از یکدیگر جدایی ناپذیرند؛ اما با جدا شدن این دو بخش در معماری SDN، مفهوم کنترل و انتقال داده در شبکه دو مفهوم مجزا می باشند. در پی این جداسازی سطوح، ادوات معماری سنتی با ادواتی عام منظوره، ساده تر و البته ارزان قیمت تر جایگزین شده، که توان پردازشی خاصی ندارند؛ این ادوات تنها اجرا کننده سیاست‌هایی هستند که کنترلر شبکه برای آنها تعیین می کند، به همین دلیل از ادوات معماری SDN با عنوان "دستگاه‌های گنگ"^۳ یاد می شود.

در معماری SDN تمام موارد مدیریتی شبکه برعهده کنترلر شبکه است. کنترلر شبکه که در بخش صفحه کنترل قرار می گیرد، یک نرم افزار است که با بکارگیری تعداد خاصی از پروتکل‌ها با بخش صفحه داده ارتباط برقرار کرده و از این راه سیاست‌های اصلی شبکه را روی ادوات صفحه داده پیاده سازی می کند. نکته قابل توجه در این زمینه آن است که بار پردازشی زیادی در شبکه روی کنترلر بوده و ادوات تنها اجرا کننده نتایج این پردازش‌ها هستند؛ در واقع نقطه قوت و نقطه حساس این معماری هر دو در یک قسمت است؛ وجود کنترلر مرکزی شبکه.

مرکزیت کنترلر در این معماری باعث شده که در صورت بروز مشکل در کنترلر شبکه، تمام شبکه تحت تاثیر قرار گیرد؛ همین مورد شبکه‌های SDN را به یک هدف عالی برای انجام انواع حملات سایبری تبدیل کرده است، که حملات DDoS از جمله مهم ترین آن‌ها هستند.

حملات DDoS به گونه ای طراحی شده‌اند، که با ایجاد تعداد بالایی از درخواست‌ها توسط کاربران غیرواقعی، یک سیستم را طوری

درگیر پاسخگویی به خود کنند که سیستم ظرفیت پاسخگویی به کاربران واقعی را از دست داده و پس از مدتی به طور کامل مختل شود. کنترلر شبکه و معماری SDN در صورت رخداد چنین حملاتی بسیار آسیب پذیر خواهند بود که نتیجه آن، اختلال در کل شبکه مورد نظر است.

در راستای مقابله با این حملات پژوهشگران روش‌های مختلفی را ارائه کرده‌اند که در ادامه به آنها اشاره می شود، اما نکته قابل توجه آن است که در صورت پیاده سازی تمام اقدامات مقابله‌ای در کنترلر شبکه، سربرابر شدید پردازشی برای کنترلر به وجود خواهد آمد که در کیفیت کلی ارتباطات شبکه تاثیرگذار است. سربرابر پردازشی روی کنترلر، به دلیل وجود ادوات ساده و فاقد قدرت پردازشی به خصوص در معماری SDN، اجتناب ناپذیر است؛ این مساله موجب ارائه روش‌های مختلفی برای انتقال بخشی از پردازش شبکه از صفحه کنترل به صفحه داده شد، که یکی از این روش‌ها معرفی زبان P4 و ادوات مبتنی بر آن است.

فناوری P4 امکان تعیین روند پردازش بسته‌ها را در ادوات صفحه داده از طریق برنامه ریزی، فراهم می کند. ادوات مبتنی بر P4 دارای توان پردازشی مورد نیاز در بسیاری از کاربرد های شبکه، از جمله تشخیص و جلوگیری حملات، می باشند. با بکارگیری این ادوات می توان بخش زیادی از فرآیند تشخیص و جلوگیری از حملات را در صفحه داده پیاده سازی نمود و از این رو مشکل سربرابر پردازشی روی کنترلر شبکه تا حد بسیاری برطرف می شود. در ادامه به بررسی برخی پژوهش‌های صورت گرفته در زمینه تشخیص حملات DDoS در شبکه های SDN می پردازیم.

۲ - پیشینه پژوهش

۲-۱- حملات slow-rate DDoS: حملات انکار سرویس توزیع -

شده یا DDoS دسته‌ای از حملات مخرب هستند، که مبنای آن‌ها اشباع سازی منابع سیستم است. این حملات سیستم یا شبکه هدف خود را به طور دائم مشغول به خود می سازند، تا سیستم توانایی ارائه سرویس به کاربران واقعی خود را نداشته باشد؛ در ادامه، این حملات سیستم را وادار می سازند تا منابع خود را برای ارائه سرویس به مهاجم بکارگیرد و به طور دائم میزان تقاضا را افزایش داده تا در نهایت ظرفیت پاسخگویی سیستم، تکمیل شده و پس از مدتی سیستم به طور کامل مختل شود.

³ Dumb devices

¹ Data plane

² Control plane

رفتار و ماهیت این دسته حملات و همچنین دقت بالا و کاربرد

وسیع الگوریتم‌های حوزه یادگیری ماشین، در این پژوهش از الگوریتم‌های یاد شده در تشخیص حملات استفاده شده است [13]

۲-۲- شبکه‌های نرم‌افزار محور : شبکه‌های نرم‌افزار محور یا SDN عنوان یک معماری نسبتاً جدید است که شبکه را قادر می‌سازد تا کلیه اعمال کنترلی شبکه به وسیله یک کنترلر مرکزی (نه لزوماً یک کنترلر، بلکه به معنای مرکزیت کنترل در شبکه) مدیریت شود. تمرکز اصلی این معماری بر جداسازی صفحه کنترل از صفحه داده است. در پی این هدف، ادوات خاص منظوره موجود در معماری سنتی (سویچ، مسیریاب و ...) با ادوات عام منظوره فاقد قدرت پردازشی خاص جایگزین می‌شوند. این ادوات ساده‌تر، توسط یک کنترلر مرکزی مدیریت شده و تنها اجرا کننده قوانین تولید شده توسط آن هستند و از خود توان پردازشی به‌خصوصی ندارند.

معماری SDN، یک معماری سه لایه است که لایه‌های برنامه‌های کاربردی، کنترل و زیرساخت را شامل می‌شود. به این ترتیب سه سطح عملیاتی مدیریت، کنترل و داده در این لایه‌های یاد شده در نظر گرفته می‌شوند. همچنین بین لایه‌ها، دو رابط شمالی^۴ و جنوبی^۵ وجود داشته که ارتباط بین این لایه‌ها را فراهم می‌کنند؛ بر این اساس صفحه‌های کنترل و برنامه‌های کاربردی از طریق رابط شمالی و صفحه‌های کنترل و زیرساخت نیز از طریق رابط جنوبی به یکدیگر متصل شده‌اند. به دلیل وجود این سطوح مجزا و رابط‌های بین آن‌ها، قابلیت انعطاف-پذیری شبکه بالا بوده و همین امر جایگزینی پروتکل‌های ارتباطی و ادوات P4 با پروتکل‌های موجود و ادوات عام‌منظوره را ساده‌تر کرده است.

کنترلر شبکه یک محصول نرم‌افزاری است که نقش اصلی را در پیاده‌سازی قوانین تولید شده توسط برنامه‌های کاربردی بر روی ادوات شبکه، بر عهده دارد و به نوعی بازوی عملیاتی شبکه محسوب می‌شود. با توجه به جداسازی صفحه داده از صفحه کنترل و عدم وجود وابستگی، در انتخاب نوع کنترلر محدودیتی وجود نداشته و در این راستا شرکت‌ها و انجمن‌های مختلف، محصولات مختلفی را تولید و عرضه کرده‌اند. OpenDayLight، Ryu و ONOS برخی از کنترلرهای متن‌باز^۶ موجود هستند. ONOS یک پروژه متن‌باز بوده که هدف آن ایجاد یک سیستم عامل شبکه مبتنی بر SDN، برای ارائه دهندگان خدمات ارتباطی است. این کنترلر برای مقیاس‌پذیری، کارایی و دسترسی بالا طراحی شده است، مبتنی بر زبان Java بوده، دارای

حملات DDoS بسته به رفتاری که در شبکه دارند و سیستمی که مورد هدف قرار می‌دهند، در دسته‌بندی‌های مختلف قرار می‌گیرند. نوع خاصی از این حملات، slow-rate DDoS است که به شدت مخرب بوده و هدف آن بیشتر سرورهای HTTP هستند. در حملات DDoS به صورت پیش‌فرض، ماشین‌های مهاجم حجم بالایی از ترافیک را به شبکه تزریق می‌کنند. این حجم بالای ترافیک در بازه زمانی مشخص حین رصد شبکه، قابل تشخیص است. به بیان ساده‌تر از طریق تشخیص ناهنجاری در ترافیک شبکه می‌توان با حملات slow-rate DDoS با نرخ بالا مقابله نمود. اما در مقابل، slow-rate DDoS همانطور که از نام آن پیداست، حجم ترافیک بالایی را تولید نکرده و مکانیزم متفاوت و هوشمندانه‌تری در حمله دارد؛ در slow-rate DDoS با شناسایی نقطه ضعف‌های موجود در برخی پروتکل‌ها، مقادیر خاصی از سرآیند بسته‌ها در شبکه توسط ماشین‌های مهاجم دستخوش تغییر می‌شود. در واقع در این دسته حملات، با سوءاستفاده از ضعف‌های موجود در پروتکل‌ها، سرورها به صورت دائم مشغول پاسخگویی به ماشین‌های مهاجم شده و از پاسخگویی به کاربران واقعی بازمی‌مانند.

از جمله ابزارهای انجام این دسته از حملات می‌توان به Slowloris، SlowHTTPTest، R.U.D.Y، GoldenEye و H.U.L.K اشاره کرد. حملات slow-rate DDoS به سرورهای HTTP یکی از مهم‌ترین حملات در این دسته هستند که سرورهای thread-based بیشترین آسیب‌پذیری را در برابر آن‌ها خواهند داشت. پیام‌های درخواست و پاسخ در ارتباط بین ماشین درخواست دهنده و سرور HTTP، دارای قالب خاصی هستند و Slowloris یک نمونه از حمله‌هایی است که از قالب یاد شده سوءاستفاده کرده، و درخواست‌های ناقص و بخش‌بخش را با نرخ بسیار پایین و در تعداد بسیار بالا به سمت سرور ارسال می‌کند؛ با ادامه این روند، ظرفیت سرور بر اثر پردازش تعداد بالایی از درخواست‌های غیر واقعی اشباع شده و در نتیجه سرور از پاسخگویی باز خواهد ماند.

در تشخیص حملات DDoS اغلب روش‌های معرفی شده، بر پایه استفاده از تکنیک‌های آماری و یا با استفاده از الگوریتم‌های حوزه یادگیری ماشین ارائه شده‌اند. حجم ترافیک حملات با نرخ پایین از نظر ظاهری تقریباً مشابه کاربران واقعی بوده و شناسایی این دسته از حملات نسبت به حملات با نرخ بالا، به نسبت پیچیده‌تر است؛ در نتیجه برای هریک از دو روش تکنیک‌های آماری و الگوریتم‌های یادگیری ماشین، نیاز به تولید اطلاعات دقیق‌تر خواهد بود. با توجه به

⁶ Open source

⁴ Northbound API

⁵ Southbound API

رابط کاربری گرافیکی نیز می‌باشد. یکی از مهم‌ترین ویژگی‌های آن پشتیبانی مستقیم از ادوات P4 است. [14-16]

۲-۳- فناوری P4: همانطور که پیش تر اشاره شد، مرکزیت کنترل در شبکه‌های SDN باعث شده تا این معماری به هدفی عالی برای انجام حملات DDoS تبدیل شود. این حملات بخش‌های مختلف مرتبط با کنترلر شبکه را هدف قرار می‌دهند چراکه با از کار افتادن کنترلر شبکه، کل شبکه تحت تاثیر قرار خواهد گرفت. از سمتی دیگر، تشخیص و جلوگیری به موقع حملات، خود نیازمند اختصاص توان پردازشی به خصوصی است که در مقیاس یک شبکه می‌تواند بسیار بالا باشد. پیاده‌سازی روش‌های تشخیص و جلوگیری از حملات در کنترلر شبکه، به دلیل تحمیل سربار پردازشی به کنترلر، خود موجب کاهش کیفیت عملکرد آن می‌شود. این امر باعث ایجاد محدودیت‌هایی در ارائه روش‌های پیشنهادی در مقابله با حملات و یا پیچیدگی بیش از حد روش‌ها شده است. به همین دلیل محققان تصمیم گرفتند تا بخشی از پردازش‌های لازم را از کنترلر، به ادوات در سطح داده انتقال دهند. معرفی فناوری P4 و ادوات مبتنی بر آن، یکی از کارآمدترین روش‌های ارائه شده در این زمینه است.

محققان برای شبیه‌سازی شبکه‌های نرم افزار محور ابزارهای مختلفی استفاده می‌کنند که هر یک ویژگی‌های خاصی در اختیار کاربران خود قرار می‌دهند، اما به صورت عام، در اکثر محیط‌های آزمایشی و پژوهشی به دلیل انعطاف‌پذیری و سرعت بالا از شبیه‌ساز Mininet برای شبیه‌سازی شبکه‌های SDN استفاده شده است. Mininet یک شبیه‌ساز شبکه مبتنی بر خط فرمان^۷ است، که شبکه‌ای از میزبان‌های مجازی^۸، سوئیچ‌ها، کنترلرها و لینک‌های بین آن‌ها را ایجاد می‌کند. دلیل فراگیر بودن این شبیه‌ساز در امکاناتی است که در اختیار کاربر قرار می‌دهد. Mininet در پیاده‌سازی این پژوهش به دلیل پشتیبانی مستقیم این شبیه‌ساز از سوئیچ‌های P4 مورد استفاده قرار گرفته است. [17]

با معرفی زبان P4 و ادوات مبتنی بر آن این امکان فراهم شده است، تا بخشی از پردازش بسته‌ها در صفحه داده انجام شود. این قابلیت، محدودیت مطرح شده در حالت پیش فرض شبکه‌های SDN را برطرف می‌کند چراکه ادوات در این حالت، از توان پردازشی به-خصوصی برخوردار هستند. قابلیت پردازشی ادوات P4 از طریق برنامه-ریزی آن‌ها به وسیله زبان P4 و توسط متخصصان شبکه فراهم می‌شود. زبان P4، برخلاف زبان‌هایی مانند پایتون و C، یک زبان برنامه‌نویسی

خاص منظوره است که جهت تعیین روند پردازش بسته‌ها در ادوات SDN طراحی شده و با استفاده از قابلیت‌های آن می‌توان عملکرد ادوات را مطابق با نیازها در حوزه کاری مورد نظر تعیین نمود. بر این اساس می‌توان بسیاری از الگوریتم‌ها و روش‌های استخراج اطلاعات از شبکه را در یک سوئیچ P4 پیاده‌سازی و در تشخیص ناهنجاری از آن‌ها استفاده نمود؛ در این صورت کنترلر تنها دریافت کننده این اطلاعات است و سربار پردازشی مربوطه حذف خواهد شد. با توجه به جزئیات عنوان شده، از قابلیت‌های زبان و ادوات P4 می‌توان در کاربردهای مختلف مانند تشخیص حمله، تنظیم بار و رصد شبکه استفاده نمود، تا حجم بالایی از بار پردازشی کنترلر کاسته شود.

زبان P4 این قابلیت را دارد که قالب‌های سرآیند^۹ بسته‌ها را به صورت سفارشی^{۱۰} تعریف کرده و این سرآیندها را به صورت پویا از بسته تجزیه کند. P4 علاوه بر این، از جداول سفارشی‌سازی شده و سایر ساختارهای مرتبط با پردازش بسته مانند شمارنده‌ها، ثبات‌ها و تغییر سرآیند بسته‌ها نیز پشتیبانی می‌کند. این امر باعث شده زبان P4 کاملاً مستقل از پروتکل باشد؛ به این معنا که در صورت استقرار پروتکل جدید در شبکه، به راحتی می‌توان برنامه P4 را برای پشتیبانی از مقادیر سرآیند پروتکل جدید تغییر داد. بنابراین یکی دیگر از ویژگی‌های زبان P4 قابلیت پیکربندی مجدد است، به بیان ساده‌تر می‌توان در صورت نیاز بجای خرید سخت‌افزار جدید، برنامه جدید P4 را در سوئیچ آن پیاده‌سازی نمود.

هر برنامه P4 برای یک معماری خاص نوشته می‌شود که ماشین هدف (سوئیچ) نیز بر اساس همان معماری طراحی شده است؛ این یعنی برنامه نوشته شده به زبان P4 به معماری دستگاهی که توسط تولیدکنندگان ارائه می‌شود وابستگی دارد. برنامه P4 که برای یک معماری خاص نوشته شده است، تنها در ماشین‌های هدفی که از همان مدل معماری استفاده می‌کنند، قابل حمل و پیاده‌سازی است و عملکرد و قابلیت‌های هریک از این ماشین‌ها متفاوت هستند. در عمل روش‌های مختلفی برای پیاده‌سازی سوئیچ‌های P4 در شبکه وجود دارد، اما اکثراً در موارد پژوهشی از شبیه‌ساز Mininet همراه با سوئیچ‌های BMv2 که بر اساس معماری V1model است، استفاده شده است. [18,19]

۲-۴- پژوهش‌های پیشین: در ادامه به بررسی روش بکارگیری سوئیچ‌های P4 در این پژوهش جهت تشخیص و پیشگیری حمله، پرداخته خواهد شد.

⁹ Header
¹⁰ Custom-made

⁷ Command-line
⁸ Virtual hosts

SVM+GA+KPCA به طبقه‌بندی داده‌ها خواهد پرداخت و

در صورتی که داده‌های ترافیکی به عنوان حمله طبقه‌بندی شوند، سیستم وارد مرحله جلوگیری از حمله خواهد شد. بدیهیست بهبود کیفیت تشخیص الگوریتم‌های یادگیری ماشین، رابطه مستقیم با نتیجه نهایی و کیفیت تشخیص خواهد داشت اما چگونگی بهبود الگوریتم‌ها و از طرفی پیچیدگی و پردازش مورد نیاز آن‌ها در مسائل مختلف، متفاوت خواهد بود و امری غیرقطعی است.

Mohammadi و همکاران [4] در سال ۲۰۱۹ طی پژوهشی روشی را برای جلوگیری از حملات SYN flood در SDN معرفی کردند، که در قالب یک افزونه برای کنترلر عمل می‌کند. این نوع از حملات از قابلیت‌های موجود در پروتکل TCP که جهت اطمینان انتقال در شبکه طراحی شده است، سوءاستفاده کرده و هدف آنها اشباع‌سازی ظرفیت شبکه است. در این عنوان کنترلر شبکه، با استفاده از روش‌های آماری، نقش واسط را بین مبدا و مقصد بسته ایفا نموده و در صورت اطمینان از عدم وجود حمله، اقدام به نصب قانون در ادوات خواهد نمود. این روش، روشی مناسب برای جلوگیری از حمله و پیشگیری از وقوع خطا در تشخیص حمله، می‌باشد.

Musumeci و همکاران [5] در سال ۲۰۲۲ در پژوهشی سعی بر آن داشته‌اند تا با بکارگیری سویچ‌های مبتنی بر P4 و الگوریتم‌های یادگیری ماشین، جلوگیری از حملات DDoS را توسط خود سویچ‌ها انجام دهند. در این روش از چهار الگوریتم SVM، Random Forest، KNN و ANN استفاده شده است. هر یک از الگوریتم‌های یاد شده دارای تعدادی مولفه هستند، که در طول آزمایش‌های متعدد مورد ارزیابی قرار گرفته و بهترین مقادیر برای آن‌ها معرفی شده است. همانطور که اشاره شد، فرآیند استخراج مقادیر ویژگی برای کنترلر شبکه سربار پردازشی بالایی خواهد داشت، ویژگی اصلی در این پژوهش، استفاده از سویچ‌های P4 برای استخراج مقادیر ویژگی‌های مورد نیاز الگوریتم‌های یادگیری ماشین است. در کنار این پیاده‌سازی دو معماری متفاوت برای استخراج ویژگی نیز معرفی شده است، که بر اساس آن سویچ‌های مبتنی بر P4 مقادیر ویژگی‌های مورد نیاز الگوریتم‌های یادگیری ماشین را استخراج کرده و به کنترلر شبکه می‌فرستند. با استفاده از این روش، کنترلر شبکه تنها دریافت کننده مقادیر ویژگی‌ها بوده و مجبور به اختصاص توان پردازشی به این بخش نخواهد بود. این امر باعث کاهش سربار پردازشی روی کنترلر و بهبود کارایی کل شبکه در تشخیص حمله شده که در نتایج حاصل از این پژوهش قابل مشاهده است.

و همکاران [1] در سال ۲۰۱۹ در پژوهشی با توجه به اهمیت معماری SDN و وجود خطر حمله‌های جدید از نوع DDoS، سعی بر آن داشته‌اند تا چهار الگوریتم یادگیری ماشین شامل Random Forest، CART، SVM و MLP را در شرایط مختلف تحت آزمایش قرار داده تا میزان کارایی آن‌ها را در تشخیص حملات DDoS براساس مؤلفه‌های مختلف ارزیابی نمایند. بخشی از این پژوهش به بررسی مؤلفه‌ها و انتخاب ویژگی‌های مناسب برای حل این مسأله پرداخته شده که یکی از مراحل تأثیرگذار در نتیجه نهایی، در حل مسائل با استفاده از الگوریتم‌های یادگیری ماشین است. به عنوان نتیجه، تعدادی از ویژگی‌ها بر اساس میزان اهمیت آن‌ها در تشخیص حملات، به عنوان مؤثرترین ویژگی‌ها معرفی شده و بازدهی هر یک از چهار الگوریتم یاد شده، مورد ارزیابی قرار گرفته است. نکته قابل توجه در این پژوهش آن است، که در صورت پیاده‌سازی مرحله استخراج مقادیر ویژگی‌های الگوریتم یادگیری ماشین در کنترلر شبکه، سربار پردازشی بسیار زیادی به کنترلر شبکه تحمیل می‌شود. این خود یک گلوگاه برای کل شبکه است چراکه استخراج مقادیر ویژگی برای الگوریتم‌های یادگیری ماشین، نیازمند اندازه‌گیری دائمی مقادیر بوده و بخش قابل توجهی از توان پردازشی کنترلر را به خود اختصاص خواهد داد.

Diaz و همکاران [2] در سال ۲۰۲۰ یک چارچوب منعطف برای تشخیص حملات DDoS در شبکه‌های SDN با استفاده از الگوریتم‌های یادگیری ماشین ارائه کردند، که در آن تمرکز بر روی حملات DDoS با نرخ پایین بوده و در آن مدلی ماژولار را با بکارگیری کنترلر ONOS، جهت تشخیص و جلوگیری از این دسته حملات مورد استفاده قرار داده‌اند. مدل ارائه شده در این پژوهش بسیار کارآمد بوده چراکه بخش‌های مختلف آن فاقد وابستگی به یکدیگر است و از این رو شاهد انعطاف‌پذیری بسیاری در حین پیاده‌سازی خواهیم بود.

در سال ۲۰۲۰ Sahoo و همکاران [3] با استفاده از الگوریتم‌های یادگیری ماشین و روش‌های کاربردی حوزه هوش مصنوعی، روشی برای بهبود تشخیص ترافیک حملات DDoS در شبکه‌های نرم‌افزار محور ارائه کردند. در این پژوهش الگوریتم اصلی طبقه‌بندی SVM¹¹ بوده که جهت افزایش هرچه بیشتر دقت آن به صورت توأم با الگوریتم ژنتیک و KPCA بکارگرفته شده است. از الگوریتم ژنتیک جهت بهینه‌سازی مؤلفه‌های الگوریتم SVM و از KPCA جهت کاهش ابعاد بردار ویژگی‌ها و همچنین از N-RBF برای کاهش زمان آموزش الگوریتم استفاده شده است. در نهایت مدل آموزش داده شده

¹¹ Classification

می کنند که مبتنی بر gRPC/http2 عمل می کند و همچنین پروتکل ارتباطی ادوات مبتنی بر Openflow نیز TCP است؛ تمرکز این مدل نیز بر دو پروتکل یادشده می باشد. شناسایی ابعاد مختلف این مدل حمله، در طراحی سیستم تشخیص و جلوگیری از حملات slow-rate DDoS بسیار کاربردی خواهد بود.

در سال ۲۰۲۰ Dimolianis و همکاران [9] یک روش جلوگیری از حملات DDoS را با بکارگیری خاصیت برنامه پذیری صفحه داده که از طریق زبان P4 و ادوات مبتنی بر آن حاصل شده است، معرفی کردند. در این روش سویچ های مبتنی بر زبان P4 بکار گرفته شده اند که برای تشخیص ناهنجاری، اطلاعات خاصی از سرآیند بسته ها را استخراج و بررسی کرده و در مراحل بعد از این اطلاعات در تشخیص ناهنجاری استفاده می شود. این سویچ ها در نقاط حیاتی شبکه پیاده سازی شده و نتایج حاصل از رصدهای خود را به سیستم پیشگیری از حمله خارجی، در قالب هشدارهایی اعلام خواهند نمود.

با توجه به موارد عنوان شده، در بیشتر موارد، تشخیص و پیشگیری از حملات DDoS نیازمند پردازش به خصوصی در شبکه است. میزان این پردازش بسته به روش تشخیص و نوع دریافت اطلاعات از شبکه، متفاوت خواهد بود. برای ارائه یک روش تشخیص و جلوگیری کارآمد، نیاز است تا اطلاعات خاصی از نقاط حیاتی در شبکه دریافت شده و جلوگیری از حمله نیز در نقطه ای از شبکه انجام شود که مانع هدر رفت پهنای باند و سایر منابع شبکه شود. این امر نیازمند آن است که حملات در ابتدایی ترین نقاط شروع حمله و با کمترین سربار پردازشی ممکن برای کنترلر، تشخیص داده شوند.

Panda و Badotra [10] در سال ۲۰۱۹ در یک پژوهش با استفاده از سیستم تشخیص نفوذ Snort سعی بر آن داشته اند تا در سناریوهای مختلف و تحت حملات مختلف DDoS، میزان کارایی این سیستم تشخیص نفوذ را مورد ارزیابی قرار دهند. برای شبیه سازی، از شبیه ساز Mininet همراه با کنترلرهای ONOS و ODL استفاده شده است. طی آزمایشات انجام شده در این پژوهش، کنترلر ODL همراه با سیستم تشخیص نفوذ Snort، زمان کمتری را برای تشخیص حمله و همچنین زمان بیشتری را تا از کار افتادگی کامل کنترلر به همراه داشته است. شناسایی عملکرد کنترلرهای یاد شده همراه با ارزیابی عملکرد سیستم های تشخیص نفوذ، تاثیر بسزایی در شناخت بهتر مساله و ارائه راه حل های بهینه خواهد داشت.

در سال ۲۰۱۹ Febro و همکاران [6] در پژوهش خود سعی در شناخت و پیشگیری نوع خاصی از حملات DDoS با عنوان SIP-Invite DDoS را داشته اند. در این عنوان تمرکز بر تشخیص و پیشگیری حمله در نزدیکی مبدا حمله است و برای این امر از قابلیت های زبان P4 بهره گرفته شده است. تشخیص حمله در نزدیکی مبدا موجب پیشگیری از هدر رفت پهنای باند و خسارت در طول مسیر خواهد شد. در این پژوهش پیاده سازی رصد ترافیک^{۱۲} شبکه در نزدیکی مبدا و تشخیص ناهنجاری های موجود، با بکارگیری سویچ های مبتنی بر P4 حاصل شده است. روند کلی کار از سه قسمت اصلی حسگرها، بخش مدیریت سیاست ها و بخش تشخیص حمله تشکیل شده است. هر پورت در سویچ در واقع طوری برنامه ریزی شده است، که مانند یک حسگر عمل کرده و سرآیند بسته های ورودی را بررسی خواهد کرد. برای تشخیص و سیاست گذاری نیز کنترلر موظف است، تمام وظایف مربوط به مدیریت حسگرها و تشخیص حمله را انجام دهد. در این روش از ترکیب یک جدول (که بسته های SIP را نگهداری می کند) و یک شمارنده، تشخیص حمله انجام خواهد شد. کنترلر در صورت تشخیص حمله از طریق دستکاری در قوانین جدول سویچ، عمل انسداد ترافیک حمله از پورت مورد نظر را انجام می دهد.

Khooi و همکاران [7] در سال ۲۰۲۰، با توجه به شرایط خاصی که حملات DDoS برای ارائه دهندگان خدمات ارتباطی به وجود آورده اند، با بکارگیری ادوات مبتنی بر P4 یک معماری توزیع شده درون شبکه ای برای تشخیص و پیشگیری از حملات ارائه کردند. معماری ارائه شده یک معماری دفاعی کاملا اتوماتیک است که در آن تعداد درخواست ها و پاسخ ها در شبکه، رصد و نگهداری خواهند شد. نقاط انجام این رصدها در شبکه، بسیار مهم بوده و در نتیجه نهایی و میزان توان پردازشی لازم برای انجام آن، نقش بسزایی دارد. در معماری معرفی شده، تعداد پیام های درخواست در مسیر یاب های دسترسی^{۱۳} و تعداد پیام های پاسخ در مسیر یاب های مرزی^{۱۴} رصد می شوند. پس از آن بر اساس نتایج به دست آمده تشخیص و عملیات لازم برای جلوگیری از حمله صورت می گیرد.

Balarezo و همکاران [8] در سال ۲۰۲۰ یک مدل حمله slow-rate DDoS را معرفی کردند و جنبه های مختلف آن را مورد بررسی قرار دادند. تمرکز محققان بر پروتکل ارتباطی TCP و مکانیزم کنترل ازدحام این پروتکل بوده و بر این اساس در ادامه ارائه این مدل از پروتکل Openflow و همچنین فناوری P4 استفاده شده است. ادوات مبتنی بر P4 از طریق P4Runtime با صفحه کنترل ارتباط برقرار

¹⁴ Edge routers

¹² Traffic monitoring

¹³ Access routers

پیچیدگی الگوریتم‌های یادگیری ماشین و میزان تغییرات احتمالی آن‌ها با توجه به تغییرات حملات در آینده، نامشخص بوده و وجود یک ماژول تشخیص حمله خارجی و عدم وابستگی آن به کنترلر شبکه، انعطاف‌پذیری بیشتری را فراهم می‌آورد.

۳- مدل تشخیص حمله ارائه شده

حملات slow-rate DDoS، با سوءاستفاده از مدخل‌های امنیتی موجود در پروتکل‌های ارتباطی، سیستم قربانی را مورد هدف قرار می‌دهند. این دسته یکی از مخرب‌ترین حملات بر سرورهای HTTP هستند و سرورهای thread-based بیشترین آسیب‌پذیری را در برابر این حملات خواهند داشت. پیام‌های درخواست و پاسخ مبادله شده بین سرور و ماشین درخواست دهنده، دارای چرخه‌ای مشخص و قالبی خاص هستند، که ماشین مهاجم با ایجاد تغییر در روند معمول آن‌ها اقدام به حمله می‌کند. در پی این حملات، تعداد بالایی از درخواست‌ها با تغییر حالت معمول قالب پیام و یا چرخه یک پیام معمولی، به سمت سرور ارسال می‌شوند و منابع سرور بر اثر ناتوانی سرور در اتمام فرآیند پاسخگویی به درخواست‌ها، اشباع شده و سرور از پاسخگویی باز خواهد ماند. استفاده از تکنیک‌های یادگیری ماشین، روشی مناسب جهت تشخیص حملات یاد شده می‌باشد. در این پژوهش، با استفاده از قابلیت برنامه‌ریزی سویچ‌های P4 و تکنیک‌های یادگیری ماشین، مدلی منعطف جهت تشخیص این دسته از حملات ارائه شده است. مدل ارائه شده در این پژوهش، از سه بخش تشکیل شده است که در شکل ۱ قابل مشاهده است. مطابق شکل ۱، مؤلفه‌های کنترلر، ماژول تشخیص حمله خارجی و سویچ P4 به صورت هماهنگ با یکدیگر در تعامل هستند. راه ارتباطی بین ماژول تشخیص حمله و کنترلر ONOS، از طریق سوکت فراهم شده است؛ سویچ‌های P4 و کنترلر ONOS نیز از طریق پروتکل ارتباطی P4Runtime با یکدیگر در ارتباط هستند.

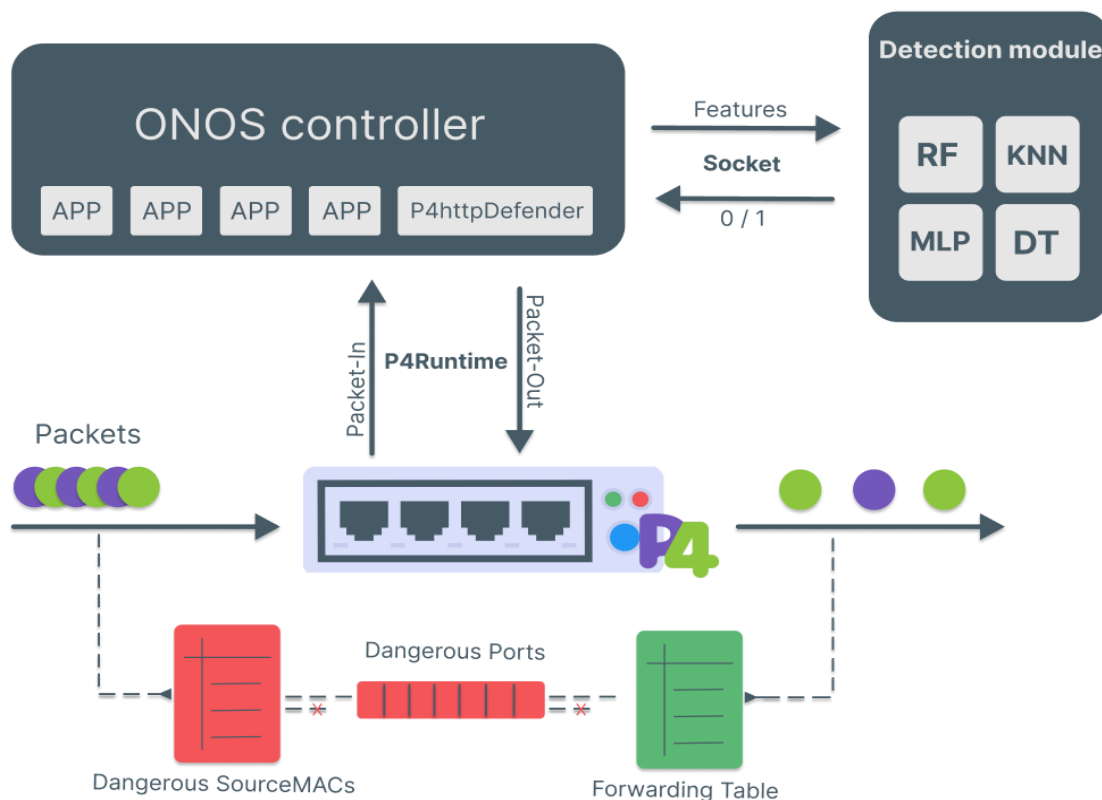
در پیاده‌سازی ماژول تشخیص حمله، از چهار الگوریتم CART، KNN، RF و MLP جهت طبقه‌بندی استفاده شده است که توسط کتابخانه Scikit-learn پیاده‌سازی شده است [20]. تشخیص توسط این الگوریتم‌ها، بر اساس مقادیر موجود در دو مرحله آموزش الگوریتم و ارائه ویژگی به آن‌ها انجام می‌شود. در مرحله آموزش، از یک مجموعه داده مناسب با تعداد ۱۶۶۵۳۰ نمونه و تعداد ۳۳ ویژگی استفاده شده است، که هریک از ویژگی‌ها متناسب با رفتار حملات slow-rate DDoS در شبکه انتخاب شده است [21]. جدول ۱ نشانگر مجموعه ویژگی‌های بکار رفته در فرآیند آموزش الگوریتم‌های یاد شده می‌باشد.

پس از آموزش الگوریتم‌های یادگیری ماشین با تنظیم مؤلفه‌های مناسب و مجموعه داده یاد شده، مدل‌های یادگیری ماشین حاصل در

Haqiq و Mahrach [11] در سال ۲۰۲۰ سعی در ارائه یک مکانیزم جلوگیری از حملات syn-flood در شبکه‌های نرم‌افزار محور از طریق بکارگیری بخش داده با استفاده از قابلیت‌های فناوری P4 را داشته‌اند. در مکانیزم ارائه شده به دلیلی محدودیت میزان حافظه موجود در بخش داده، از تکنیک syn cookie استفاده شده است، که بدون ذخیره حالت می‌باشد و به فضای ذخیره حالات ارتباط TCP نیاز ندارد.

Simsek و همکاران [12] در سال ۲۰۱۹ در پژوهشی سعی کردند تا با بکارگیری قابلیت‌های زبان P4 از بخش داده برای تشخیص حملات انکار سرویس استفاده کنند تا از این طریق میزان بار و حجم کاری روی پردازنده مرکزی را کاهش دهند. پیش فرض این پژوهش بر آن است که بیشتر حملاتی که بر روی کنترلر انجام می‌شوند از طریق جعل آدرس فیزیکی و IP هستند.

تمرکز این پژوهش بر روی تشخیص و جلوگیری از حملات slow-rate DDoS متمرکز بر سرورهای HTTP، در معماری شبکه‌های نرم‌افزار محور است؛ که برای این امر از کنترلر ONOS همراه با سویچ‌های مبتنی بر P4 و الگوریتم‌های یادگیری ماشین استفاده شده است. در این راستا سویچ‌های P4 اطلاعات شبکه را رصد کرده و مقادیر ویژگی‌های مورد نیاز مدل‌های یادگیری ماشین را استخراج می‌کنند. در صورت بروز شرایط مشکوک به حمله، ویژگی‌های حاصل از مرحله قبل همراه با اطلاعات ماشین‌های مشکوک به حمله، در قالب پیامی به سمت کنترلر شبکه ارسال می‌شوند. کنترلر شبکه در این حالت نقشی در استخراج ویژگی نداشته و از این جهت سربار پردازشی وجود نخواهد داشت. کنترلر پس از دریافت ویژگی‌ها، این مقادیر را به یک ماژول تشخیص حمله خارجی که از مدل‌های یادگیری ماشین تشکیل شده، ارسال می‌کند؛ بنابراین در تشخیص حمله و اجرای مدل‌های یادگیری ماشین نیز کنترلر سربار پردازشی را به همراه نخواهد داشت. ماژول تشخیص حمله با استفاده از مقادیر ویژگی‌های استخراج شده توسط سویچ‌های P4، تشخیص حمله را انجام داده و نتیجه را به کنترلر شبکه ارسال می‌کند. کنترلر شبکه بر اساس بازخوردی که از مرحله قبل به دست آمده، در صورت وجود حمله، قانونی را برای مسدودسازی پورت متصل به ماشین مهاجم، در سویچ مورد نظر، نصب می‌کند. به این صورت هرگونه ترافیک حاصل از پورت متصل به ماشین مهاجم، توسط سویچ P4 مسدود خواهد شد. لازم به ذکر است تأخیر ناشی از مبادله پیام بین ماژول تشخیص حمله و کنترلر بسیار ناچیز بوده و در مقابل سربار پردازشی حاصل از پیاده‌سازی الگوریتم‌های یادگیری ماشین در خود کنترلر، قابل چشم پوشی است؛ چراکه



(شکل ۱-): شمای کلی مدل تشخیص حمله ارائه شده

سوییچ شرایط مشکوک به حمله تلقی خواهد شد. در صورتی که سوییچ بر اساس بسته‌های مبادله شده HTTP، شرایط مشکوک را تشخیص دهد، به بسته برچسب مشکوک به حمله اختصاص خواهد داد، و بسته به همراه مقادیر ویژگی‌ها و مشخصات ماشین‌های مشکوک، جهت تشخیص حمله به کنترلر ONOS ارسال خواهد شد. در کنترلر ONOS، در صورتی که بسته برچسب مشکوک را به همراه داشته باشد، توسط برنامه تعبیه شده در کنترلر، فرآیندی آغاز می‌شود که در آن ویژگی‌های میزبان مشکوک، به ماژول تشخیص حمله ارسال خواهد شد. ماژول تشخیص حمله، از طریق مدل‌های یادگیری ماشین، اقدام به طبقه‌بندی ویژگی‌های ارائه شده خواهد نمود. نتیجه حاصل از بخش تشخیص حمله، یک خروجی دودویی است. در صورت پیشبینی حمله از سوی مدل‌های یادگیری ماشین، کنترلر ONOS اقدام به نصب قانونی مرتبط با فرآیند مسدودسازی پورت متصل به ماشین مهاجم خواهد نمود. در روند مسدودسازی، کنترلر ONOS با در اختیار داشتن نتیجه تشخیص و اطلاعاتی از ماشین‌های مهاجم، در جدول مخصوص مسدودسازی ترافیک حمله از سوییچ متصل به مبدا حمله، قانونی را نصب کرده تا مانع ارسال و دریافت اطلاعات از پورت متصل به ماشین

ماژول تشخیص حمله، آماده تشخیص حملات خواهند بود. بدین صورت تنها کافیست تا مقادیر ویژگی‌های مورد نظر به مدل‌های یادگیری ماشین تحویل داده شوند، تا عملیات تشخیص توسط آن‌ها صورت گیرد. با بکارگیری زبان P4، فرآیند استخراج مقادیر ویژگی‌ها در سوییچ پیاده‌سازی خواهد شد. بنابراین مقادیر ویژگی‌های مورد نیاز مدل‌های یادگیری ماشین، جهت تشخیص، به صورت مستقیم توسط سوییچ‌های P4 و در بخش داده استخراج می‌شوند. سوییچ‌های P4، مطابق روند پردازشی تعیین شده در برنامه P4، همزمان علاوه بر مسیریابی و هدایت بسته‌ها، به صورت مداوم در حال رصد بسته‌های HTTP موجود در شبکه می‌باشند. در فرآیند استخراج مقادیر ویژگی‌ها، سوییچ‌های P4، مقادیر ویژگی‌های مورد نیاز مدل‌های یادگیری ماشین جهت تشخیص حمله را استخراج می‌کنند. استخراج این مقادیر بر اساس مجموعه داده یادشده و بسته‌های مبادله شده مبتنی بر پروتکل HTTP می‌باشد. در مواقعی که شبکه تحت حمله باشد، سرور HTTP در اثر حمله، پس از بازه زمانی مشخص، از پاسخگویی به درخواست‌ها باز خواهد ماند. در چنین شرایطی، اختلاف بین درخواست‌های HTTP و پاسخ‌های بازگشته از سمت سرور، به صورت مدام افزایش خواهد یافت. سوییچ‌های P4 در این مدل طوری برنامه‌ریزی شده‌اند، که در صورت تجاوز این مقدار از بازه‌ای خاص، برای

(جدول ۱-): ویژگی‌های بکار گرفته شده در روند تشخیص حمله


شماره	ویژگی	شماره	ویژگی	شماره	ویژگی
۱	Flow Duration	۱۲	Fwd Packet Length Std	۲۳	Fwd IAT Min
۲	Total Fwd Packets	۱۳	Bwd Packet Length Std	۲۴	Fwd IAT Max
۳	Total Backward Packets	۱۴	Fwd Packets/s	۲۵	Bwd IAT Max
۴	Total Length of Fwd Packets	۱۵	Bwd Packets/s	۲۶	Fwd IAT Std
۵	Total Length of Bwd Packets	۱۶	Flow Bytes/s	۲۷	Bwd IAT Std
۶	Fwd Packet Length Mean	۱۷	Flow Packets/s	۲۸	Flow IAT Mean
۷	Bwd Packet Length Mean	۱۸	Fwd IAT Mean	۲۹	Packet Length Mean
۸	Bwd Packet Length Max	۱۹	Bwd IAT Mean	۳۰	Min Packet Length
۹	Bwd Packet Length Min	۲۰	Fwd IAT Total	۳۱	Max Packet Length
۱۰	Fwd Packet Length Max	۲۱	Bwd IAT Total	۳۲	Packet Length Variance
۱۱	Fwd Packet Length Min	۲۲	Bwd IAT Min	۳۳	Packet Length Std

۴- شبیه سازی شبکه و حمله

روش تشخیص حمله ارائه شده در این پژوهش، با استفاده از شبیه-ساز Mininet پیاده‌سازی شده است. جزئیات توپولوژی شبکه در شکل ۲ به تصویر کشیده شده است. در این شبیه‌سازی از چهار سویچ P4 استفاده شده است، که هر یک از نوع BMv2 و مبتنی بر معماری V1model می‌باشند. علاوه بر این، تعداد ۷ ماشین میزبان در شبکه پیاده سازی شده است، که یک ماشین میزبان در شبکه نقش سرور HTTP را ایفا کرده و سایر میزبان‌ها درخواست‌هایی را به سمت سرور ارسال می‌کنند. در این میان، سه ماشین میزبان اقدام به تولید ترافیک سالم نموده، و سه میزبان دیگر نیز با استفاده از ابزار slow-rate DDoS، اقدام به انجام حملات SlowHTTPTest خواهند نمود. در هر یک از سویچ‌های P4، دو جدول تعبیه شده است،

مهاجم شود. به این صورت تمام بسته‌های ورودی در سویچ، در صورت وجود تطابق اطلاعات بسته در جدول یادشده، مسدود خواهند شد و مابقی بسته‌ها طبق روند معمول به مسیر مناسب هدایت خواهند شد.

کنترلر در این مدل سربرار پردازشی بسیار کمتری را متحمل خواهد شد، چراکه تنها واسط ارتباطی بین سویچ‌های P4 و ماژول تشخیص حمله بوده و در روند تشخیص حمله با سربرار پردازشی کمتری مواجه خواهد بود. به دلیل عدم وجود وابستگی بین بخش تشخیص حمله و کنترلر ONOS، انعطاف‌پذیری در این مدل بالا است. در صورت نیاز به هرگونه تغییرات احتمالی در بخش تشخیص حمله، نیاز به هیچگونه تغییر در کنترلر نبوده؛ این ویژگی در پیاده‌سازی الگوریتم‌های بهینه‌تر، پیاده‌سازی روش‌های متفاوت برای تشخیص و در نتیجه بهبود کیفیت تشخیص حملات، بسیاری از محدودیت‌ها را برطرف خواهد نمود.



(شکل-۲): توپولوژی شبکه شبیه سازی شده

نظر گرفتن نتایج حاصل از پژوهش های پیشین و ارزیابی مقادیر مختلف بر روی مجموعه داده مورد استفاده در این پژوهش، انجام گرفته است.

جزئیات مقادیر مرتبط با زمان آموزش الگوریتم ها، در جدول ۳ موجود است. با توجه به مقادیر به دست آمده، در میان چهار مدل یادگیری ماشین مدل KNN به دلیل سازوکار متفاوت، فاقد زمان آموزش بوده و مقدار زمان بسیار پایینی را نشان خواهد داد، که تنها در آماده سازی مدل توسط سیستم سپری شده است.

(جدول-۲): پارامترهای تنظیم شده در آموزش مدل های یادگیری ماشین

مدل	پارامترهای تنظیم شده در مدل
MLP	hidden_layer_sizes = (2,10) , activation = relu
KNN	n_neighbors = 5 , weights = uniform
Random Forest	n_estimators = 10 , criterion = gini , max_features = None
Decision Tree (CART)	criterion = gini , splitter = best , max_depth = None

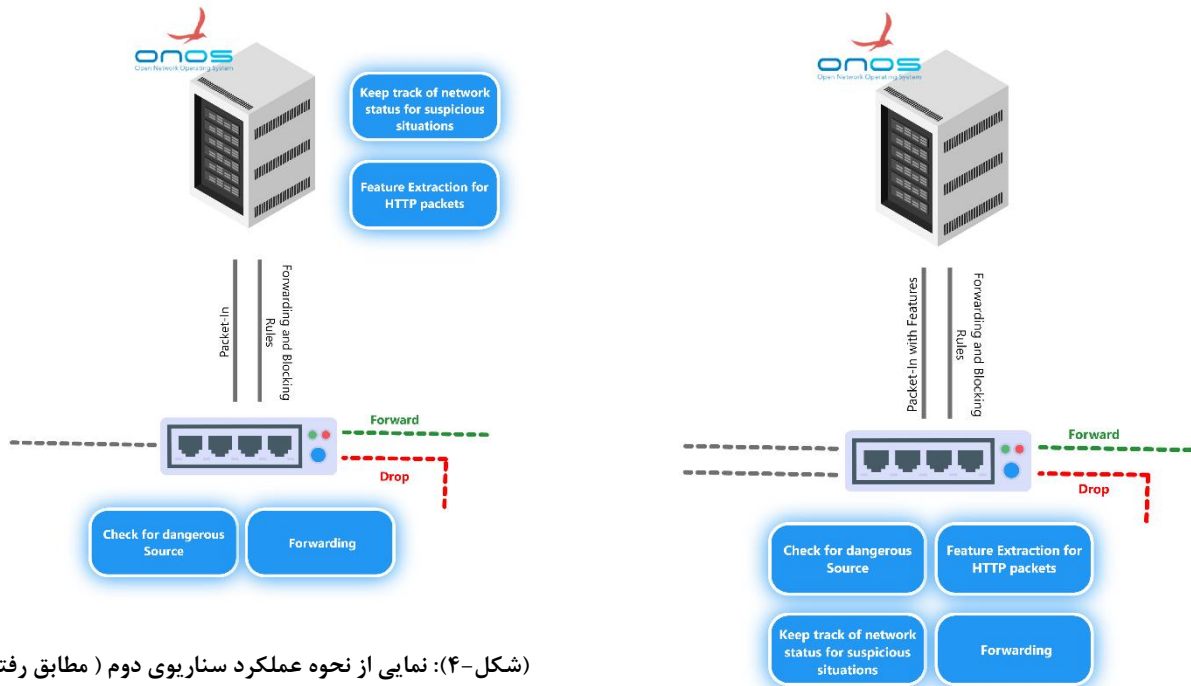
که یک مورد برای مسیریابی و دیگری برای مسدودسازی ترافیک حمله بکار گرفته می شود. در نهایت به جهت جلوگیری از تکنیک های جعل آدرس، با استفاده از یک ثبات، پورت های ورودی مخرب نیز مسدود خواهند شد. همانطور که اشاره شد، استخراج مقادیر ویژگی های مورد نیاز مدل های یادگیری ماشین توسط سویچ های P4، و براساس روند تعیین شده برای آن ها در فایل برنامه P4، انجام خواهد شد.

در این پژوهش به جهت مقایسه تاثیر استفاده از توان پردازشی ادوات برنامه ریزی شده P4، با حالت مبتنی بر استاندارد Openflow، دو سناریو پیاده سازی شده است، که در شکل ۳ و شکل ۴ قابل مشاهده است.

در سناریوی اول، سویچ های برنامه ریزی شده P4 وظیفه هدایت بسته ها، استخراج ویژگی، تشخیص شرایط مشکوک به حمله و جلوگیری از ترافیک حملات را بر عهده دارند. این در حالی است که در سناریوی دوم، سویچ تنها وظیفه هدایت بسته ها و جلوگیری از ترافیک حملات را بر عهده داشته، و تشخیص شرایط مشکوک به حمله و استخراج مقادیر ویژگی توسط کنترلر انجام خواهد گرفت.

۵- ارزیابی نتایج به دست آمده

۵-۱- ارزیابی عملکرد مدل های یادگیری ماشین: جدول ۲ نمایانگر مقادیر ویژگی ها و مولفه هایی است که مدل های یادگیری ماشین براساس آن آموزش داده شده اند. انتخاب مقادیر مولفه ها، با در



(شکل-۴): نمایی از نحوه عملکرد سناریوی دوم (مطابق رفتار (Openflow

(شکل-۳): نمایی از نحوه عملکرد سناریو اول (با برنامه‌ریزی سویچ‌های P4

نمونه‌های مثبتی که مدل یادگیری ماشین آن‌ها را به اشتباه، منفی تشخیص داده است نیز با عنوان FN^{۱۸} شناخته می‌شوند. بر اساس توضیحات پیشین، Precision کسری از نمونه‌های مثبت واقعی از میان کل نمونه‌هایی است که توسط مدل، مثبت تشخیص داده شده‌اند. پس از آن، Recall، کسری از نمونه‌های مثبت تشخیص داده شده توسط مدل یادگیری ماشین، از کل نمونه‌های مثبت واقعی می‌باشد. معیار Accuracy نشانگر تعداد نمونه‌هایی است که توسط مدل یادگیری ماشین به درستی طبقه‌بندی شده‌اند. معیار AUC-ROC score میزان کارایی و مؤثر بودن مدل را بر اساس نسبت FPR^{۱۹} به TPR^{۲۰} را نشان می‌دهد و یک معیار اندازه‌گیری از دقت کلی مدل یادگیری ماشین است. معیار F1-Score، بیانگر میانگین دو معیار Precision و Recall می‌باشد. این معیار اندازه‌گیری نشانگر آن است که مدل یادگیری ماشین بر اساس مجموعه داده موجود، چه تعداد نمونه را به درستی طبقه‌بندی کرده است. معیارهای یاد شده از طریق روابط ۱ تا ۶ قابل محاسبه هستند.

$$Precision = \frac{TP}{TP + FP}$$

(۱)

با صرف نظر از KNN، مدل Decision Tree (CART) کمترین زمان آموزش و مدل Random Forest با حدود ۱۶ ثانیه بیشترین زمان آموزش را به همراه داشته است. در این میان، می‌توان الگوریتم Decision Tree (CART) را متعادل‌ترین الگوریتم معرفی نمود، که زمان آموزش آن زیر ۳ ثانیه می‌باشد. همچنین در حالت کلی، بیشترین و کمترین زمان آموزش را نیز به ترتیب الگوریتم‌های Random Forest و KNN به همراه داشته‌اند.

در ارزیابی عملکرد و دقت مدل‌های یاد شده، از مقیاس‌های AUC-ROC score، Precision، Recall، Accuracy و F1-Score استفاده شده است. نحوه محاسبه هر یک از این مقادیر در روابط زیر شرح داده شده است. نمونه‌های مثبتی که مدل یادگیری ماشین آن‌ها را به درستی، مثبت تشخیص داده است با عنوان TP^{۱۵} شناخته می‌شوند. نمونه‌های منفی که مدل یادگیری ماشین آن‌ها را به درستی، منفی تشخیص داده است با عنوان TN^{۱۷} شناخته می‌شوند. و در نهایت

¹⁸ False Negatives

¹⁹ False Positive Rate

²⁰ True Positive Rate

¹⁵ True Positives

¹⁶ False Positives

¹⁷ True Negatives

(جدول-۴): میزان دقت مدل های یادگیری ماشین در تشخیص حملات

مدل یادگیری ماشین	AUC ROC	Recall	Precision	Accuracy	F1-Score
MLP	۰/۹۰	۰/۹۳	۰/۹۵	۰/۹۱	۰/۹۳
KNN	۰/۹۲	۰/۸۴	۰/۹۹	۰/۸۷	۰/۹۱
Random Forest	۰/۷۴	۰/۹۲	۰/۹۰	۰/۸۶	۰/۹۱
Decision Tree (CART)	۰/۷۶	۰/۹۷	۰/۹۰	۰/۹۰	۰/۹۴

در Random Forest و Tree (CART) قرار خواهند گرفت. در معیار Recall، به ترتیب دو مدل Decision Tree (CART) و MLP نمونه های مثبت بیشتری را در میان تشخیص های خود به همراه داشته اند. بر اساس معیار Precision به دست آمده، مدل های MLP و KNN تعداد نمونه های مثبت بیشتری را از کل نمونه های مثبت موجود تشخیص داده اند. با توجه به معیار Accuracy و F1-Score، دو مدل MLP و Decision Tree (CART) بهترین دقت را در بین چهار مدل یاد شده به همراه داشته اند. لازم به ذکر است، مدل KNN به دلیل سازوکار متفاوتی که داراست، در تشخیص حمله و به طور کلی کاربردهایی که حساس به زمان هستند، مناسب نمی باشد؛ چراکه برای هر نمونه در حین طبقه بندی، تمام نمونه های موجود در مجموعه داده را مورد بررسی قرار خواهد داد (به دلیل نداشتن مرحله آموزش) که این امر در حین اجرا، سربار زمانی ایجاد خواهد نمود. البته که در یافتن پاسخ و صرفه جویی در زمان تست و ارزیابی اولیه مسائل، یک نماینده مناسب از الگوریتم های حوزه یادگیری ماشین می باشد.

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

(۲)

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

(۳)

$$FPR = \frac{FP}{TN + FP}$$

(۴)

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

(۵)

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall}$$

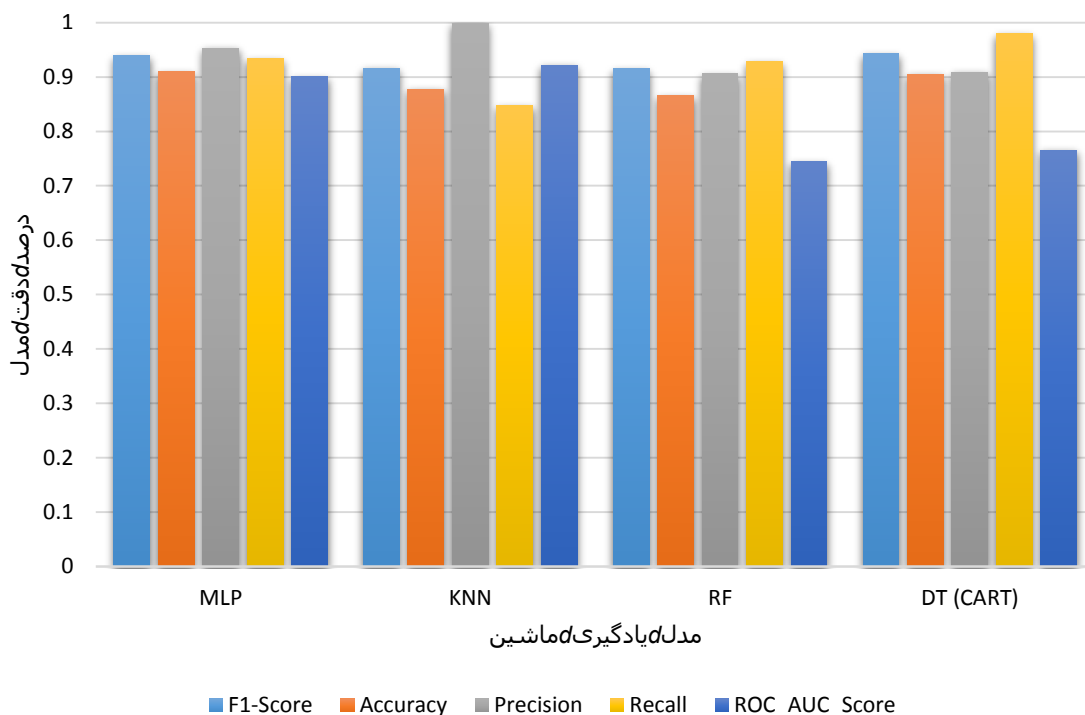
(۶)

(جدول-۳): زمان آموزش الگوریتم های یادگیری ماشین (میلی ثانیه)

مدل یادگیری ماشین	کمینه زمان آموزش	میانگین زمان آموزش	بیشینه زمان آموزش
MLP	۴۵۵۱	۸۵۷۵/۵	۱۰۳۷۰
KNN	۱۶	۱۷	۱۸
Random Forest	۱۵۴۲۴	۱۵۹۸۵/۳	۱۶۶۲۹
CART	۲۶۰۶	۲۷۳۹/۳	۲۸۸۳

در ادامه پس از آماده سازی ماژول تشخیص حمله، شبکه مطابق توضیحات پیشین، مورد حمله قرار گرفته و مدل های موجود با در اختیار داشتن ویژگی های استخراج شده توسط سویچ های P4، اقدام به طبقه بندی داده ها نموده اند. نتایج حاصل از ارزیابی مدل ها با معیار های یاد شده در جدول ۴ و نمودار شکل ۵ نمایش داده شده است.

بر اساس مقادیر حاصل، مدل KNN بهترین عملکرد را در معیار AUC ROC فراهم نموده و پس از آن به ترتیب MLP، Decision



(شکل-۵): نمودار ارزیابی عملکرد مدل‌های یادگیری ماشین موجود در ماژول تشخیص حمله

کندتر نیز مشاهده می‌شود؛ بیشینه مقدار زمان تشخیص آن حدود ۲۴ ثانیه بوده و این در حالی است، که بیشینه مقدار مدل Decision Tree (CART) نیز از بیشینه مقدار سایر مدل‌ها کمتر می‌باشد. پس از آن، مدل بهترین زمان تشخیص کلی را به همراه داشته، طوری که در سه بازه نرخ حمله نهایی مدت زمان تشخیص حمله آن حدود ۲۱ ثانیه بوده است و در بدترین حالت نیز با حدود ۲۶ ثانیه، عملکردی میانه، از نظر بیشینه زمان هر چهار مدل به همراه داشته است. پس از دو مدل یاد شده، در ارزیابی مدل KNN و RF می‌توان زمان تشخیص مدل RF را بهتر از KNN دانست، چراکه KNN بیشینه زمان تشخیص را در میان این چهار مدل به همراه داشته و نیز در نرخ حمله-های متفاوت RF زمان تشخیص کمتری را داشته است. این مورد به دلیل سازوکار مدل KNN است که پیش‌تر به آن اشاره شد و همانطور که انتظار می‌رفت، این سازوکار در زمان تشخیص حملات تأثیرگذار بوده است.

۵-۲- ارزیابی زمان تشخیص حمله: مطابق توضیحات پیشین،

جهت مقایسه عملکرد و تأثیر استفاده از قابلیت برنامه‌ریزی سویچ‌های P4، دو سناریو شبیه‌سازی شده است که سناریوی اول بر اساس برنامه‌ریزی سویچ‌های P4 و سناریوی دوم بر اساس رفتار Openflow می‌باشد. همانطور که اشاره شد، در هر یک از سناریوها، سه میزبان با استفاده از ابزار SlowHTTPTest اقدام به حمله به سرور HTTP خواهند نمود. نرخ ارسال حمله بر اساس *per follow-up data* second می‌باشد. بر این اساس چهار نرخ حمله در نظر گرفته شده است که مطابق جدول ۴ می‌باشد. میزبان‌های مهاجم بر اساس نرخ‌های گفته شده اقدام به انجام حملات *slow-rate DDoS* خواهند نمود و در هر یک از سناریوها، پس از تشخیص و پیشگیری از حملات، زمان تشخیص محاسبه خواهد شد. جزئیات مربوط به زمان تشخیص حمله در سناریوهای اول و دوم به ترتیب در جدول ۵ و جدول ۶ موجود است. نرخ حمله در این جدول بر اساس *per follow-up data* second می‌باشد.

بر اساس مقادیر زمان تشخیص در جدول ۵، مدل Decision Tree (CART) با حدود ۱۹ ثانیه، کمترین زمان تشخیص را در بین مدل‌ها به همراه داشته و این زمان تشخیص پایین، در نرخ حملات

(جدول-۶): زمان تشخیص حمله در سناریوی دوم بر حسب میلی ثانیه (مطابق رفتار Openflow)

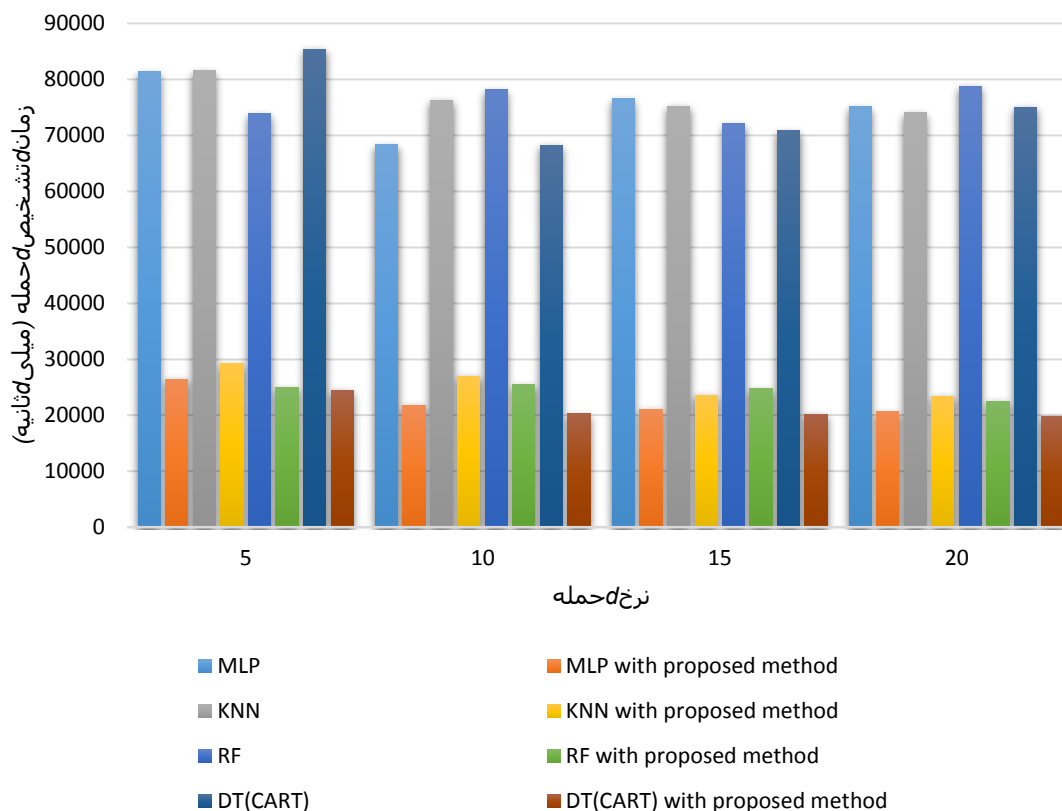
مدل	نرخ ۵	نرخ ۱۰	نرخ ۱۵	نرخ ۲۰
MLP	۸۱۴۳۰/۵	۶۸۳۵۰/۴	۷۶۵۳۳/۵۳	۷۵۰۶۵/۰۶
KNN	۸۱۵۸۷/۷۶	۷۶۳۱۱/۲۳	۷۵۱۸۷/۷۶	۷۴۰۹۶/۶۳
RF	۷۳۸۳۹/۳۳	۷۸۱۲۶/۷	۷۲۰۴۷/۰۶	۷۸۸۰۸/۹
CART	۸۵۴۱۸/۷۶	۶۸۳۰۹/۱	۷۰۷۹۳/۱۳	۷۵۰۴۵/۰۳

بر اساس نتایج به دست آمده از نمودار شکل ۶ می توان نتیجه گرفت که در سناریوی اول با افزایش نرخ، در حملات slow-rate DDoS، یا به بیان دیگر با افزایش فاصله زمانی بین درخواست ها از سرور HTTP، مدت زمان تشخیص حمله کاهش پیدا خواهد کرد. در مقایسه دو سناریوی اول و دوم، با اختلاف حدود ۶۰ ثانیه ای سناریوی اول در تمامی موارد عملکرد بهتری از خود نشان داده است. نتایج حاصل نشانگر میزان تاثیر بکارگیری فناوری P4 در تشخیص حملات موجود در شبکه های SDN می باشد. کاهش زمان تشخیص در سناریوی اول به دلیل انجام پردازش های اولیه و لازم در تشخیص حملات و استخراج مقادیر ویژگی های مورد نیاز مدل های یادگیری ماشین توسط سویچ های P4 است، که باعث شده بخش قابل توجهی از فرآیند تشخیص حمله بدون نیاز به پردازش های کنترلر انجام شود.

(جدول-۵): زمان تشخیص حمله در سناریوی اول بر حسب میلی ثانیه (با برنامه ریزی سویچ های P4)

مدل	نرخ ۵	نرخ ۱۰	نرخ ۱۵	نرخ ۲۰
MLP	۲۶۴۸۹/۸۳	۲۱۸۰۸/۱۶	۲۱۱۰۵/۲	۲۰۶۷۷/۲
KNN	۲۹۲۱۴/۲	۲۷۰۱۰/۴۶	۲۳۶۰۱/۴	۲۳۳۸۵/۹
RF	۲۵۰۲۶/۲۶	۲۵۴۳۷/۲	۲۴۷۷۳/۴۶	۲۲۵۱۷/۹۳
CART	۲۴۴۸۸/۰۳	۲۰۳۰۶/۹۳	۲۰۱۸۲/۳۳	۱۹۸۰۷/۶۶

اما در سناریوی دوم، مطابق جدول ۶، زمان تشخیص سیستم اختلاف بسیاری دارد که نشانگر تاثیر استفاده از سویچ های P4 و استفاده از توان پردازشی سویچ ها می باشد. مطابق جدول ۵، در سناریوی دوم کمینه مدت زمان تشخیص حمله، با اختلاف کمی توسط مدل Decision Tree (CART) انجام پذیرفته است. حال آنکه برخلاف سناریوی اول، بیشینه زمان تشخیص نیز متعلق به خود مدل Decision Tree (CART) بوده، هر چند که بیشینه زمان تشخیص سه مدل دیگر نیز با این مقدار اختلاف اندکی دارند. پس از Decision Tree (CART)، مجدداً می توان MLP را به عنوان مدل دوم با کمترین زمان تشخیص حمله در حالت کلی دانست؛ چراکه از جهت زمان تشخیص حمله در تمام نرخ های حمله، مشابه Decision Tree (CART) بوده و نتایج این دو مدل بسیار نزدیک به یکدیگر است و اختلاف کمی دارند. از میان دو مدل KNN و RF نیز با توجه به آن که بیشینه زمان تشخیص KNN با بیشینه زمان تشخیص RF اختلاف بیشتری داشته و در سایر قسمت ها نزدیک به یکدیگر بوده اند، می توان RF را دارای عملکرد بهتری، نسبت به KNN عنوان کرد. توضیحات عنوان شده در نمودار شکل ۶ به تصویر کشیده شده است.



شکل-۶: نمودار مقایسه زمان تشخیص حمله در سناریوی اول و دوم

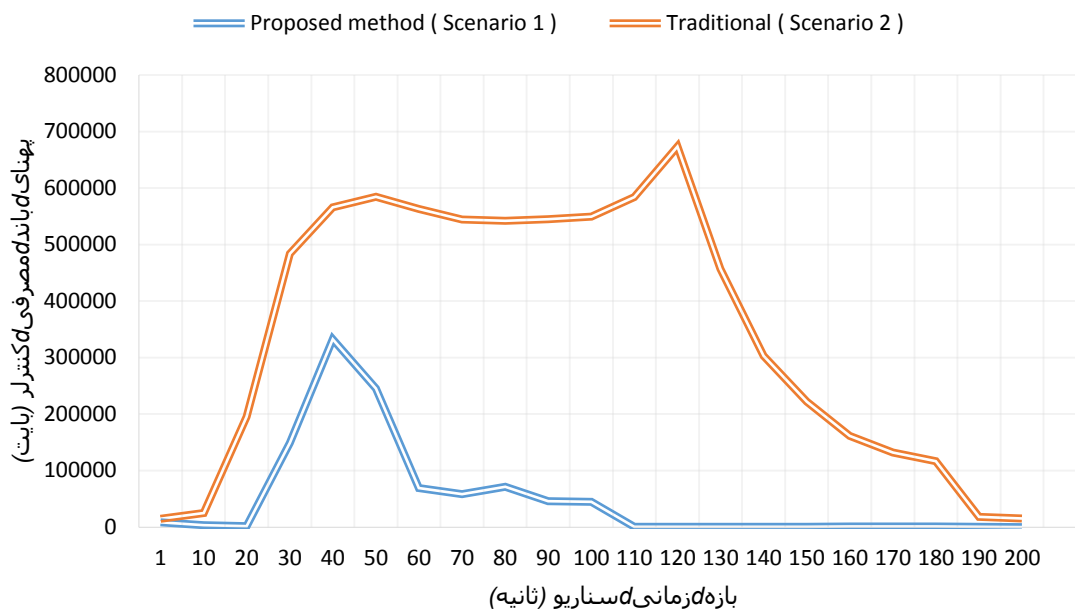
کلی نسبت به وضعیت شبکه و شرایط آن داشته باشد، تا در حین حمله بتواند ویژگی‌هایی که استخراج کرده است را جهت تشخیص حمله، تحویل مدل‌های یادگیری ماشین دهد. با توجه به نمودار موجود در شکل ۶، مصرف پهنای باند در سناریوی اول بسیار کمتر از سناریوی دوم بوده است. می‌توان دریافت که با توجه به بکارگیری توان پردازشی سویچ‌های P4 در سناریو اول، به دلیل کاهش مدت زمان تشخیص حمله و همچنین انجام برخی پردازش‌های لازم به صورت محلی توسط سویچ P4، میزان پهنای باند مصرفی بسیار کمتر از حالت موجود در سناریوی دوم می‌باشد. بر این اساس به دلیل انجام پردازش‌های ابتدایی به صورت محلی در سویچ، بسته‌ها با تاخیر زمانی بیشتری، نسبت به سناریوی دوم، به کنترلر ارسال شده‌اند که موجب کاهش مصرف پهنای باند کنترلر شده است. از طرفی با توجه به زمان تشخیص کوتاه‌تر در سناریوی اول، بیشینه مقدار پهنای باند مصرفی در این سناریو بسیار کمتر از سناریوی دوم بوده و پس از تشخیص حمله، ترافیک و پهنای باند اشغال شده توسط مهاجمان در مدت زمان سریع‌تری آزاد خواهد شد.

موارد عنوان شده، مزیت بکارگیری توان پردازشی سویچ‌های P4 و قابلیت برنامه‌ریزی این ادوات را نشان می‌دهد، که در نتیجه موجب

۳-۵- ارزیابی مصرف پهنای باند: در این بخش به بررسی پهنای باند مصرفی کنترلر پرداخته خواهد شد. همانطور که اشاره شد، تمرکز این پژوهش بر روی حملات slow-rate DDoS و از نوع slowloris است. و در این نوع حملات، ترافیک پروتکل TCP و HTTP بسیار بالا خواهد بود چراکه تعداد درخواست‌های بالا اما به صورت ناقص و بخش‌بخش توسط مهاجم از سرور درخواست خواهد شد.

در سناریوی اول که از سویچ‌های P4 جهت بررسی بسته‌ها و تشخیص شرایط مشکوک به حمله استفاده شده است، حجم بالایی از حملات در خود سویچ مسیریابی شده و به کنترلر فرستاده نخواهد شد، مگر آنکه شرایط حساس و مشکوک به حمله پدید آید. نمودار شکل ۶، میزان مصرف پهنای باند کنترلر ONOS را، طی حمله و فرآیند تشخیص حمله سناریوهای اول و دوم نشان می‌دهد.

در سناریوی دوم سویچ‌های P4، هیچ نقشی در روند تشخیص حمله و یا تشخیص شرایط مشکوک به حمله نداشته و به جهت نیاز فرآیند استخراج مقادیر ویژگی، تمامی بسته‌ها به کنترلر فرستاده شده تا مقادیر ویژگی‌های لازم استخراج شوند. همچنین کنترلر باید دید



(شکل-۷): نمودار مقایسه مصرف پهنای باند کنترلر ONOS در سناریوهای اول و دوم

فرآیند استخراج مقادیر ویژگی‌ها، به صورت محلی در خود سویچ P4، کنترلر شبکه را به میزان کمتری درگیر پردازش‌های لازم در تشخیص حملات کرده و به این جهت سربار پردازشی کنترلر شبکه بسیار کم بوده است. سناریوی اول در بازه حدود ۲۰ ثانیه بیشترین سربار پردازشی را با بیشینه مقدار حدود ۴۰۰ درصد فراهم آورده است، که این مقدار، به سرعت پس از تشخیص حمله کاسته شده است و منابع پردازشی به سرعت آزاد شده‌اند.

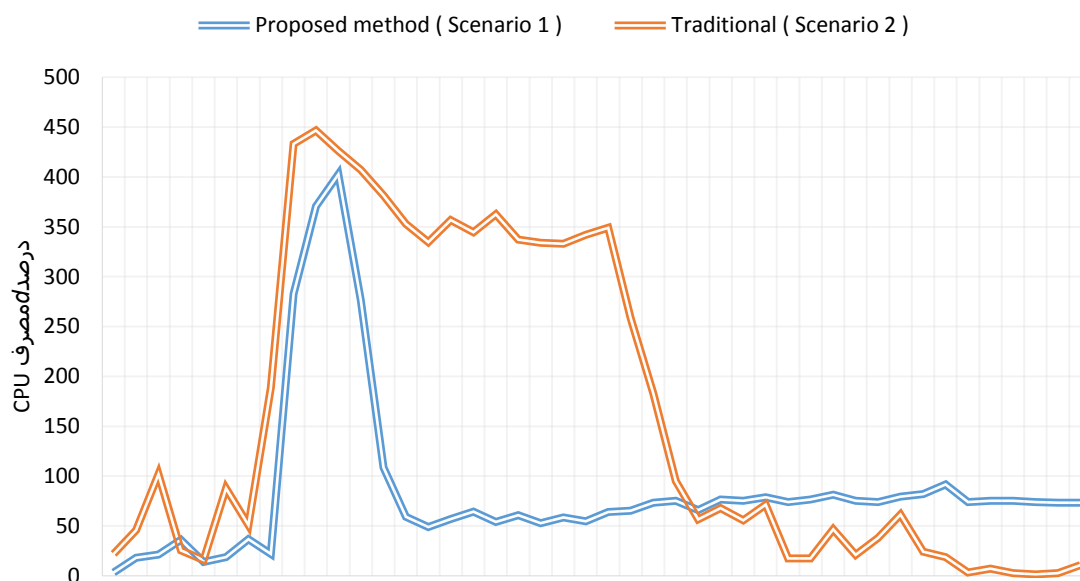
این در حالی است که در سناریوی دوم، کنترلر در حدود ۷۵ ثانیه سربار پردازشی بسیاری را با بیشینه مقدار حدود ۴۵۰ درصد، متحمل شده است و روند آزادسازی منابع نیز با اختلاف کمی، کندتر از سناریوی اول می‌باشد. در سناریوی دوم به دلیل زمان تشخیص بیشتر و درگیری کنترلر در تمام طول دوره حمله، که به سبب انجام فرآیند استخراج مقادیر ویژگی از شبکه موجب شده است، میزان سربار پردازشی بسیار بالا می‌باشد. فرآیند استخراج مقادیر ویژگی و دریافت اطلاعات از وضعیت شبکه، موجب شده سناریوی دوم در بیشینه میزان مصرف پردازنده نیز سربار پردازشی بیشتری را، در مقایسه با سناریوی اول، فراهم آورد.

با توجه به نتایج حاصل شده از این بخش می‌توان به اهمیت بکارگیری ادوات P4 و توان پردازشی آن‌ها که از طریق برنامه‌پذیری حاصل شده است، پی برد. همانطور که انتظار می‌رفت با استفاده از سویچ‌های P4 فرآیندهای پردازشی موجود در شبکه که موجب ایجاد

برتری مدل تشخیص حمله ارائه شده در این پژوهش نسبت به روش سنتی تشخیص حمله، که به طور کامل مبتنی بر کنترلر بوده، خواهد شد. همانطور که انتظار می‌رفت، مصرف پهنای باند کنترلر شبکه در مدل ارائه شده، در حین حملات slow-rate DDoS، بسیار پایین‌تر بوده است. بر این اساس، پهنای باند اشباع شده در کنترلر توسط سناریوی اول بسیار کمتر خواهد بود و همچنین پهنای باند اشغالی در مدت زمان کمتری آزاد خواهد شد.

۴-۵- ارزیابی سربار پردازشی کنترلر: با توجه به توضیحات پیشین، در سناریوی اول سویچ‌های P4، طوری برنامه‌ریزی شده‌اند، که بیشتر پردازش‌های محلی مورد نیاز را انجام داده و از این طریق، بسته‌های کمتری جهت پردازش بیشتر به کنترلر فرستاده می‌شوند. اما در سناریوی دوم به دلیل نیاز کنترلر به دید کلی از وضعیت شبکه، جهت استخراج مقادیر ویژگی، تمامی بسته‌ها به کنترلر ارسال شده و انتظار می‌رود کنترلر سربار پردازشی بیشتری را در مقایسه با سناریوی اول متحمل شود. نتایج حاصل از ارزیابی این دو سناریو در نمودار موجود در شکل ۷ به تصویر کشیده شده است، که نشان‌دهنده میزان سربار پردازشی بر روی کنترلر می‌باشد.

با توجه به نمودار شکل ۷، میزان سربار پردازشی موجود بر روی کنترلر، در مدل ارائه شده در این پژوهش، بسیار کمتر از حالت پیش فرض مبتنی بر Openflow بوده است. در زمان وقوع حمله، سناریوی اول به دلیل تشخیص سریع‌تر حمله و نیز پردازش بسته‌ها و انجام



(شکل-۸): نمودار مقایسه میزان مصرف بار پردازشی توسط پردازنده در سناریوی اول و سناریوی دوم

شده و در نتیجه کنترلر شبکه کمترین سربار پردازشی را در تشخیص حمله و جلوگیری از آن متحمل خواهد شد.

در مدل ارائه شده با بکارگیری توان پردازشی صفحه داده، بسیاری از محدودیت‌های موجود در روش‌های پیشین، برطرف شده و با توجه به نتایج به دست آمده، سیستم و مدل ارائه شده در تشخیص حملات slow-rate DDoS از دقت مناسبی برخوردار بوده است؛ که در کنار بهینگی، از جهت پیاده‌سازی نیز وابستگی میان نوع کنترلر و بخش تشخیص حمله وجود نداشته است. با توجه به برنامه‌ریزی سوییچ‌های P4، کیفیت ویژگی‌های استخراج شده بسیار مناسب بوده و به صورت غیرمستقیم در مراحل آموزش الگوریتم‌های یادگیری ماشين نیز تأثیرگذار می‌باشد. این امر که از طریق برنامه‌ریزی سوییچ‌های P4 انجام شده است، نشانگر میزان اهمیت ادوات P4 است که زمینه را برای استفاده از این فناوری در سایر موارد مدیریتی شبکه نیز فراهم می‌آورد.

سربار برای کنترلر شده بودند، برطرف خواهند شد و این مساله موجب رفع محدودیت‌های موجود، در پیاده‌سازی بسیاری از سازوکارهای موجود در تشخیص حملات و بسیاری از زمینه‌های عملیاتی موجود در شبکه‌های نرم‌افزار محور خواهد شد.

۶- نتیجه‌گیری و پژوهش‌های آتی

با توجه به روش‌های ارائه شده پیشین در زمینه تشخیص حملات slow-rate DDoS، فرآیند تشخیص حمله در سطح شبکه نیاز به توان پردازشی بخصوصی داشته که حاصل رصد و استخراج اطلاعات از شبکه است؛ پیاده‌سازی این فرآیند در کنترلر شبکه، در کیفیت عملکرد کنترلر و در نتیجه کل شبکه تحت اختیار آن، تأثیرگذار خواهد بود. به همین جهت فناوری P4 و ادوات مبتنی بر آن معرفی شدند تا با برنامه‌ریزی ادوات در صفحه داده، از توان پردازشی صفحه داده در معماری SDN استفاده شود.

در این مقاله، روشی برای جلوگیری از حملات slow-rate DDoS در سرورهای مبتنی بر پروتکل HTTP ارائه شد. این روش براساس یک مدل بسیار منعطف و با بکارگیری سوییچ‌های P4 و استفاده از کنترلر ONOS و الگوریتم‌های یادگیری ماشين، ارائه شده است. با بکارگیری توان پردازشی صفحه داده از طریق برنامه‌ریزی سوییچ‌های P4 و مدلی منعطف از چهار الگوریتم Decision Tree (CART)، Random Forest، MLP و KNN در تشخیص حمله، فرآیند استخراج اطلاعات و تشخیص حمله کاملاً خارج از کنترلر انجام

۶- مراجع

- [10] Badotra, S., Panda, S.N. , 2021, *SNORT based early DDoS detection system using Opendaylight and open networking operating system in software defined networking, cluster computing* , vol. 24, pp. 501-513.
- [11] Safaa MAHRACH, Abdelkrim HAQIQ, 2020, " *DDoS flooding attack mitigation in software defined networks*", (IJACSA) *International Journal of Advanced Computer Science and Applications*, Vol. 11, No. 1
- [12] Goksel Simsek, Hakan Bostan, Alper Kaan Sarica, Egemen Sarikaya, Alperen Keles, Pelin Angin, Hande Alemdar, Ertan Onur, 2020, *DroPPPP: A P4 Approach to Mitigating DoS Attacks in SDN*, *Information Security Applications. WISA 2019. Lecture Notes in Computer Science*, vol 11897, Springer, Cham.
- [13] Dhruva Kumar Bhattacharyya, Jugal Kumar Kalita , 2016, *DDoS Attacks : evolution, Detection, Prevention, Reaction, and Tolerance* , CRC Press
- [14] <https://opennetworking.org>
- [15] <https://opennetworking.org/onos/>
- [16] <https://wiki.onosproject.org>
- [17] <http://mininet.org>
- [18] <https://p4.org/p4-spec/docs>
- [19] github.com/p4lang/behavioral-model
- [20] <https://www.unb.ca/cic/dataset/dos-dataset.html>
- [21] <https://scikit-learn.org/>
- [1] Santos R, Souza D, Santo W, Ribeiro A, Moreno E, 2019, *Machine learning algorithms to detect DDoS attacks in SDN*, *Concurrency Computat Pract Exper.* 2019;e5402
- [2] J. A. Pérez-Díaz, I. A. Valdovinos, K. -K. R. Choo and D. Zhu, 2020, *A Flexible SDN-Based Architecture for Identifying and Mitigating Low-Rate DDoS Attacks Using Machine Learning*, *IEEE Access*, vol. 8, pp. 155859-155872.
- [3] K. S. Sahoo et al., "An Evolutionary SVM Model for DDOS Attack Detection in Software Defined Networks", *IEEE Access*, vol. 8, pp. 132502-132513, 2020
- [4] Mohammadi R, Conti M, Lal C, Kulhari SC, 2019 , *SYN-Guard: An effective counter for SYN flooding attack in software-defined networking*. *Int J Commun Syst.* 2019;e4061.
- [5] Musumeci, F., Fidanci, A.C., Paolucci, F. et al. , 2022, *Machine-Learning-Enabled DDoS Attacks Detection in P4 Programmable Networks*, *J Netw Syst Manage* 30, 21 (2022).
- [6] A. Febro, H. Xiao and J. Spring, 2019, "Distributed SIP DDoS Defense with P4," 2019 *IEEE Wireless Communications and Networking Conference (WCNC)*, pp. 1-8.
- [7] X. I. Khooi, L. Csikor, D. M. Divakaran and M. S. Kang, "DIDA: Distributed In-Network Defense Architecture Against Amplified Reflection DDoS Attacks," 2020 6th *IEEE Conference on Network Softwarization (NetSoft)*, 2020, pp. 277-281
- [8] J. F. Balarezo, S. Wang, K. G. Chavez, A. Al-Hourani, J. Fu and K. Sithamparanathan, "Low-rate TCP DDoS Attack Model in the Southbound Channel of Software Defined Networks," 2020 14th *International Conference on Signal Processing and Communication Systems (ICSPCS)*, 2020, pp. 1-10
- [9] M. Dimolianis, A. Pavlidis and V. Maglaris, "A Multi-Feature DDoS Detection Schema on P4 Network Hardware," 2020 23rd *Conference on Innovation in Clouds, Internet and Networks and Workshops (ICIN)*, 2020, pp. 1-6



محمد نصیری در حال حاضر با رتبه دانشیار در دانشگاه بوعلی سینا همدان فعالیت دارند. ایشان مدرک کارشناسی ارشد خود را از دانشگاه صنعتی شریف و مدرک دکتری خود را در سال ۱۳۸۷ از دانشگاه پلی‌تکنیک گرنوبل فرانسه دریافت کرده‌اند. ایشان در سال ۱۳۹۸ به عنوان محقق در دانشگاه گرنوبل آلپ (فرانسه) حضور داشته‌اند. زمینه‌های پژوهشی مورد علاقه ایشان عبارتند از: بهبود کارایی فناوری‌های مختلف بی‌سیم شامل شبکه‌های بی‌سیم محلی، شبکه‌های حسگر بی‌سیم، شبکه‌های زیر آب و فناوری‌های به هم پیوسته اینترنت اشیا.

نشانی رایانامه ایشان عبارت است از:

m.nassiri@basu.ac.ir

روش ارجاع به مقاله:

رفلاحي کپورچالي، ر.محمدي، م.نصيري، تشخيص و پيشگيري از حملات نرخ پايين منع سرويس توزيع شده پروتکل HTTP در شبکه‌های نرم‌افزار محور مبتنی بر سويچ‌های P4 با بکارگیری الگوریتم‌های یادگیری ماشین، دوفصلنامه محاسبات و سامانه‌های توزيع شده، سال پنجم، شماره ۲، شماره پیاپی ۱۰، صفحه ۲۳ تا ۴۲، سال ۱۴۰۱

How to cite: R.Fallahi Kapourchaali, R.Mohammadi, M.Nassiri- Detection and prevention of slow-rate DDoS attacks on HTTP protocol in P4-based software defined networks using machine learning techniques, Journal of Distributed Computing and Systems(JDCS), Vol 5, Issue 2, Page 23-42, 2023.



رضا فلاحي کپورچالي متولد ۱۳۷۶، مدرک کارشناسی ارشد خود را در رشته مهندسی کامپیوتر گرایش شبکه‌های کامپیوتری در سال ۱۴۰۱، از دانشگاه بوعلی سینا همدان دریافت کرده است. زمینه‌های پژوهشی مورد علاقه ایشان عبارتند از: امنیت شبکه، فناوری P4، شبکه‌های بی‌سیم، شبکه‌های نرم‌افزار محور و اینترنت اشیا صنعتی.

نشانی رایانامه ایشان عبارت است از:

rezfa.kap@gmail.com



رضا محمدي مدرک کارشناسی ارشد و دکتری خود را در رشته شبکه‌های کامپیوتری به ترتیب در سال‌های ۱۳۹۲ و ۱۳۹۶ از دانشگاه صنعتی شیراز دریافت کرده است. پایان‌نامه دکتری ایشان در رابطه با مهندسی ترافیک در شبکه‌های نرم‌افزار محور است. ایشان چندین مقاله در زمینه شبکه‌های حسگر بی‌سیم زیر آب و شبکه‌های نرم‌افزار محور، در کنفرانس‌ها و مجلات بین‌المللی مختلف داشته‌اند. ایشان از سال ۱۳۹۷ به عنوان استادیار در دپارتمان مهندسی کامپیوتر دانشگاه بوعلی سینا همدان فعالیت دارند. زمینه‌های پژوهشی مورد علاقه ایشان عبارتند از: شبکه‌های نرم‌افزار محور، الگوریتم‌های هیوریستیک، امنیت شبکه‌های نرم‌افزار محور، شبکه‌های حسگر بی-سیم زیر آب، شبکه‌های Ad-hoc، شبکه‌های حسگر بی‌سیم زیر زمین، اینترنت اشیا و اینترنت اشیا زیر آب.

نشانی رایانامه ایشان عبارت است از:

r.mohammadi@basu.ac.ir