

## Analysis of Failed DNS Responses Using Neural Network in Botnet Detection

V. Mohammadi<sup>\*1</sup>, M. Shirmohammadi<sup>2</sup>

<sup>1</sup> Department of Information Technology Management, Hamedan Branch, Islamic Azad University, Hamedan, Iran

<sup>2</sup> Department of Computer Engineering, Hamedan Branch, Islamic Azad University, Hamedan, Iran

### ABSTRACT

### RESEARCH PAPER

Received: 2 April 2024  
Accepted: 24 June 2024

### KEYWORDS:

Botnet,  
Command and Control Server,  
DNS Traffic,  
Nxdomain,  
Neural Network

With the increasing development of technology and the expansion of the use of the Internet, botnets are considered as one of the most important security threats in the digital space. Botnets are networks of infected devices controlled by attackers and used for various purposes such as sending spam, DDoS attacks, and stealing sensitive information. Considering the increasing trend of using botnets, it is very important to detect and prevent their activity. The spread of communication, resource sharing, curiosity, earning money, gathering information and gaining resource capacity are motivations for creating botnets. In addition to these, political, economic and military motives should also be added. Our method has the ability to detect known and unknown botnets that use this method. Our goal in this paper is to present an innovative method to detect botnets using failed response analysis and neural network. In this method, botnets are detected based on failed responses or NXDomain in each host. This feature increases the accuracy of detection in small and medium networks. This method has been tested in networks infected with Konfiker and Kraken botnets and the information obtained from it has been analyzed using neural networks. The evaluation results show the good performance of this method in botnet detection.

<sup>1</sup> Corresponding author:



[Vahid.mohammadi1364@gmail.com](mailto:Vahid.mohammadi1364@gmail.com)

نشریه تخصصی آرمان پردازش، دوره ۵، شماره ۲، تابستان ۱۴۰۳



## فصلنامه تخصصی آرمان پردازش (APJ)

Homepage: [www.armanprocessjournal.ir](http://www.armanprocessjournal.ir)

## آنالیز پاسخهای ناموفق DNS با استفاده از شبکه عصبی در تشخیص بات نت

وحید محمدی<sup>۱\*</sup>، محمد مهدی شیرمحمدی<sup>۲</sup><sup>۱</sup> گروه مدیریت فناوری اطلاعات، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران<sup>۲</sup> گروه مهندسی کامپیوتر، واحد همدان، دانشگاه آزاد اسلامی، همدان، ایران

### چکیده

### مقاله پژوهشی

با پیشرفت روزافزون فناوری و گسترش استفاده از اینترنت، بات نت ها به عنوان یکی از تهدیدات امنیتی مهم در فضای دیجیتال به شمار می روند. بات نت ها، شبکه هایی از دستگاه های آلوده اند که توسط مهاجمان کنترل می شوند و برای اهداف مختلفی مانند ارسال اسپم، حملات DDoS و سرقت اطلاعات حساس استفاده می شوند. با توجه به روند رو به افزایش استفاده از بات نت ها، تشخیص و جلوگیری از فعالیت آن ها از اهمیت بسیاری برخوردار است. گستردگی ارتباطات، به اشتراک گذاری منابع، حس کنجکاوی، کسب پول، جمع آوری اطلاعات و به دست آوردن ظرفیت منابع، انگیزه هایی برای ایجاد بات نت است. علاوه بر اینها باید انگیزه های سیاسی، اقتصادی و نظامی را نیز اضافه نمود. روش ما قابلیت تشخیص بات نت های شناخته شده و همچنین نا شناخته ای که از این روش استفاده می کنند را دارا هست. هدف ما در این مقاله، ارائه روشی نوآورانه برای تشخیص بات نت ها با استفاده از تحلیل پاسخهای ناموفق و شبکه عصبی است. در این روش تشخیص بات نت ها بر اساس پاسخهای ناموفق یا NXDomain در هر میزبان صورت می گیرد. این ویژگی باعث می شود که دقت تشخیص در شبکه های کوچک و متوسط افزایش یابد. این روش در شبکه های آلوده به بات نت های کانفیکر و کراکن آزمایش و اطلاعات به دست آمده از آن با استفاده از شبکه های عصبی مورد تجزیه و تحلیل قرار گرفته است. نتایج ارزیابی نشان دهنده کارایی خوب این روش در تشخیص بات نت است.

### واژگان کلیدی:

بات نت،

سرور فرماندهی و کنترل،

ترافیک سرویس نام دامنه،


پاسخهای ناموفق،

شبکه عصبی،

## مقدمه

به اندازه کافی مورد توجه قرار نگرفته است. بدافزارها بر بسیاری از ابزارهای محاسباتی در عصر دیجیتال تأثیر گذاشته اند. نرم افزارهای بدخواه یا بدافزار با هدف دستیابی به اهداف منفی یک مهاجم مخرب ایجاد می شود. بدافزارها می توانند به شبکه ها حمله کنند، به زیرساخت های حیاتی آسیب بزنند، رایانه ها و دستگاه های هوشمند را در معرض خطر قرار دهند و داده های حساس را به سرقت ببرند. آمار توسعه بدافزار در سیستم عامل ویندوز و لینوکس که توسط بخش تحقیقاتی موسسه ای-وی تست (AV-Test) انجام شده و در شکل ۲ و ۳ قابل مشاهده است مهر تاییدی بر این موضوع را دارد [۱].

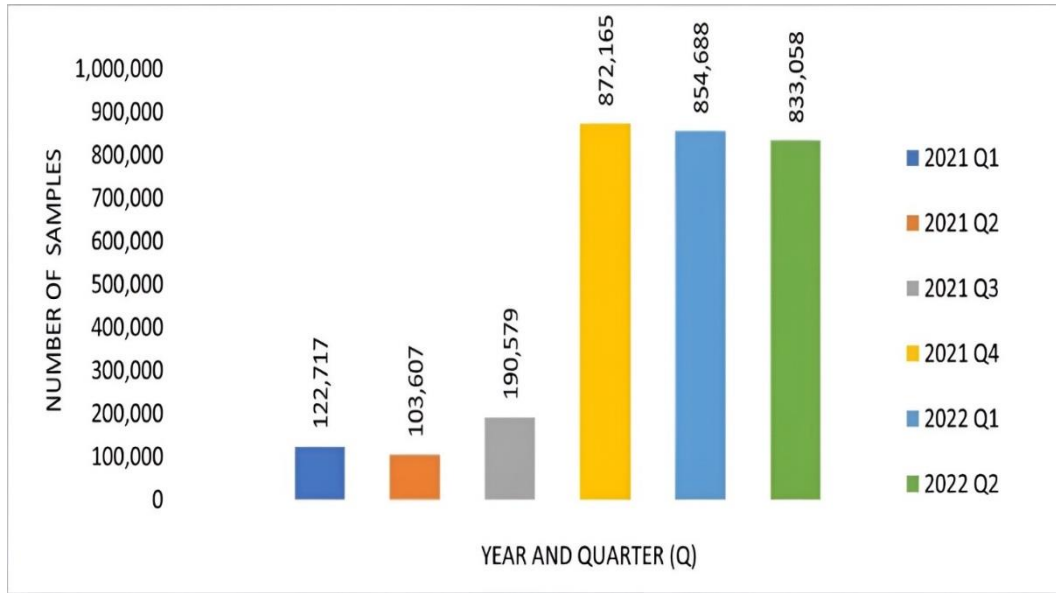
بدافزارها یکی از رایج ترین و شدیدترین حملات سایبری امروزی هستند. بدافزار میلیون ها دستگاه را آلوده می کند و می تواند چندین فعالیت مخرب از جمله استخراج داده های حساس، رمزگذاری داده ها، فلج کردن عملکرد سیستم و بسیاری موارد دیگر را انجام دهد. از این رو، تشخیص بدافزار برای محافظت از رایانه ها و دستگاه های تلفن همراه ما در برابر حملات بدافزار بسیار مهم است. ترافیک بدافزار همیشه نامتقارن است در مقایسه با ترافیک خوش خیم که همیشه متقارن است. خوشبختانه تکنیک های هوش مصنوعی زیادی وجود دارد که می توان برای شناسایی بدافزارها و تمایز آن ها از فعالیت های عادی استفاده کرد. با این حال، مشکل برخورد با داده های بزرگ و با ابعاد بالا



شکل ۱: توسعه بدافزار در (الف) ویندوز از 2013-Feb 2022 AV-TEST (2022)

حساسی برای بسیاری از اشخاص و شرکت ها تبدیل شده است. بسیاری از حملات و فعالیت های جعلی در اینترنت از طریق نرم افزارهای مخرب انجام می شود، این نرم افزارها شامل ویروس ها، اسب های تروجان و کرم ها است که در چند سال اخیر بات نت ها نیز به این مجموعه اضافه شده است. بات نت ها به یک منبع اساسی برای بسیاری از حملات خطرناک از قبیل پویش، جلوگیری از سرویس توزیع شده، هرزنامه، فعالیت های جعلی و غیره تبدیل شده اند [۲۱-۲۲].

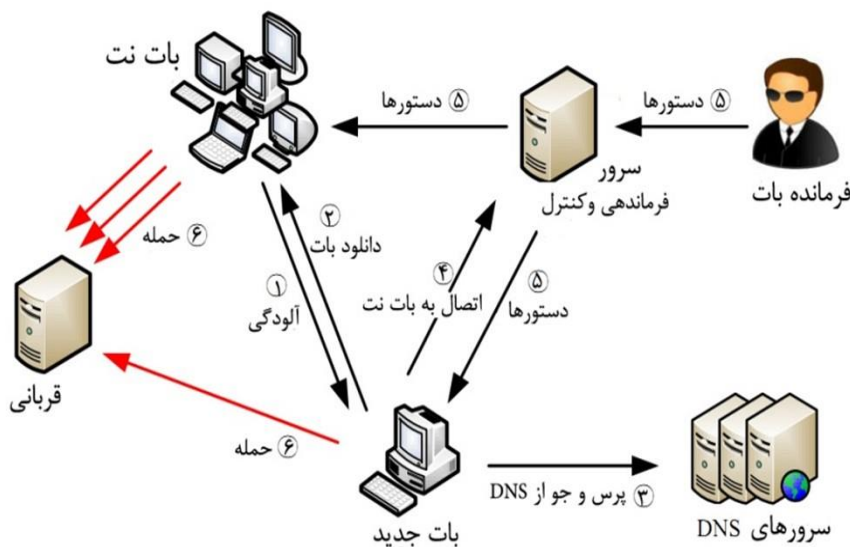
با افزایش حملات اینترنتی، به دلایلی همچون مسائل سیاسی، اقتصادی، اجتماعی، نظامی و غیره و همچنین شیوع استفاده از بات نت ها، آن ها ابزاری خطرناک که دارای قدرت تخریبی بسیار بالایی هستند تبدیل شده اند. همچنین پیشرفت بات نت ها و انتقال آن ها از معماری قدیم (HTTP, IRC) به معماری جدید (P2P) تشخیص آن ها را سخت نموده است [۲۰]. در چند دهه اخیر شاهد افزایش استفاده از اینترنت و برنامه های کاربردی آن هستیم، به صورتی که استفاده از اینترنت به بخش مهمی در زندگی روزمره ما تبدیل شده است. اگرچه اینترنت تسهیلات زیادی را به ما ارائه می دهد، اما با افزایش استفاده از اینترنت چالش های امنیتی بزرگی ظاهر شده است و این امر به مسئله مهم و



شکل ۲: رشد خانواده بدافزار لینوکس از (2022) 2021 Q1-2022 Q2، data from C.

مجاز به دسترسی به آن اطلاعات نیستند، نتوانند محتویات فرستاده شده را تشخیص دهند. جامعیت تضمین می‌کند که اطلاعات سیستم با تلاش‌های غیرمادی و یا عمدی و بدخواهانه بدون تغییر باقی بماند و دسترس‌پذیری نیز بدان معناست که اطلاعات و منابع سیستم در هر زمان، در هر جا و به هر شکل که کاربران نیاز دارند، در دسترس آن‌ها قرار گیرد. به عبارت دیگر سیستم باید عملیاتی باشد و سرویس‌ها را به درستی ارائه دهد و ارائه هیچ‌یک از سرویس‌ها را انکار ننماید. یکی از تهدیدات روزافزون در اینترنت و شبکه‌های کامپیوتری که اصل دسترس‌پذیری را نقض می‌کند Botnet است که به عنوان مهم‌ترین تهدیدکننده امنیتی در چند سال اخیر شناخته شده است.

دو عامل مهم در افزایش سوءاستفاده حمله‌کنندگان مؤثر است (۱) کاربران ناآگاه و (۲) وجود آسیب‌پذیری‌های متعدد در نرم‌افزارها. با وجود این دو عامل، نفوذگران کامپیوتری صرف‌نظر از محل جغرافیایی خود و یا کاربر می‌توانند به دستگاه‌های مختلف حمله کنند و از آن‌ها سوءاستفاده نمایند. در چنین شرایطی امنیت به عنوان مسئله‌ای مهم پدیدار می‌شود. واژه امنیت عبارت است از به حداقل رساندن آسیب‌پذیری منابع و سرمایه‌ها. اگر بخواهیم تعریف دقیق‌تر و رسمی‌تری از امنیت بیان نماییم باید بگوییم که امنیت مبتنی بر تحقق سه ویژگی محرمانگی، جامعیت و دسترس‌پذیری در یک سیستم است. محرمانگی این اطمینان را به فرستنده می‌دهد؛ که تنها گیرنده‌ی موردنظر وی توانایی درک داده‌ها را داشته باشد و سایر عوامل موجود در سیستم که



شکل ۳: چرخه زندگی و ساختار یک بات‌نت بر پایه IRC برگرفته از [۲۳]

غیرمعمول از نقاط قوت این روش می باشد. پیچیدگی در پیاده سازی و آموزش RNN هاو همچنین نیاز به داده های برجسب گذاری شده برای آموزش مدل ها از نقاط ضعف این روش می باشد.

Wang و همکاران [۲۸] از چندین تکنیک ماشین لرنینگ شامل شبکه های عصبی استفاده کرده و نشان می دهد که این تکنیک ها در تشخیص بات نت ها دقت بالایی دارند. استفاده از چندین تکنیک، استفاده از داده های واقعی، دقت بالا از نقاط قوت این روش می باشد. عدم تمرکز بر پاسخ های ناموفق DNS، پیچیدگی بیشتر از نقاط ضعف این روش می باشد. Lu و همکاران [۲۷] از شبکه های عصبی LSTM برای تحلیل ترافیک DNS استفاده کرده و نشان می دهد که LSTM می تواند الگوهای پیچیده را شناسایی کند. استفاده از LSTM برای شناسایی الگوهای پیچیده، تحلیل ترافیک DNS، دقت بالا از نقاط قوت این روش می باشد. پیچیدگی مدل، عدم تمرکز خاص بر پاسخ های ناموفق DNS، نقاط ضعف این روش می باشد.

Patel و همکاران [۲۶] از این مقاله از ترکیب چندین تکنیک ماشین لرنینگ برای تشخیص بات نت ها استفاده کرده و نشان می دهد که این ترکیب می تواند دقت تشخیص را بهبود بخشد. استفاده از ترکیب چندین تکنیک، استفاده از داده های واقعی و متنوع، چارچوب کارآمد از نقاط قوت این روش می باشد. پیچیدگی بیشتر، عدم تمرکز خاص بر پاسخ های ناموفق DNS، نقاط ضعف این روش می باشد.

Choi و همکاران [۱۳]، [۱۴] و [۱۵] یک روش تشخیص بات نت مبتنی بر ناهنجاری ارائه کرده اند که با نظارت بر فعالیت های گروهی در ترافیک DNS، بات نت ها را در مراحل مختلف از چرخه حیات آن ها تشخیص می دهد. این فعالیت گروهی بر اساس پرس و جوهای DNS ارسال شده به صورت همزمان توسط بات های توزیع شده شکل می گیرد. در این روش، از ویژگی های متمایز کننده بین پرس و جوهای DNS بات نت برای تشخیص استفاده می شود. اگر بات های عضو یک بات نت تنها در مرحله شکل گیری از پرس و جوهای DNS استفاده کرده و یا از آدرس های IP به جای نام های دامنه استفاده کنند، روش فوق قادر به تشخیص آن بات نت خواهد بود.

GU و همکاران [۱۶]، [۱۷] یک روش مبتنی بر خوشه بندی برای تشخیص بات نت ها در مرحله حمله ارائه کرده اند. در این روش، ابتدا ترافیک ارتباطی مشابه و ترافیک بدخواهانه مشابه خوشه بندی شده و سپس یک همبستگی بین خوشه ای انجام می شود تا میزبان های دارای هر دو الگوی ارتباطی مشابه و الگوی فعالیت بدخواهانه مشابه شناسایی شوند. روش فوق به صورت غیر برخط عمل می کند که در سیستم های تشخیص بات نت یک ضعف عمده است. همچنین جدول زیر شامل برخی از مهم ترین کارهای مرتبط با تشخیص بات نت (Botnet) است که از روش های مختلف تحلیل پاسخ های ناموفق شبکه و استفاده از شبکه های عصبی استفاده کرده اند.

شکل ۳ چرخه زندگی و ساختار یک بات نت را نشان می دهد: در دنیای امروز، با توجه به پیشرفت روزافزون فناوری و افزایش وابستگی به اینترنت، امنیت شبکه به یکی از مهم ترین چالش های حوزه فناوری اطلاعات تبدیل شده است. یکی از بزرگترین تهدیدات امنیتی در این زمینه، بات نت ها هستند. یکی از روش های موثر برای تشخیص بات نت ها، تحلیل پاسخ های ناموفق یا NXDomain در شبکه است. بات نت ها غالباً با ارسال حجم زیادی از درخواست های شبکه که منجر به پاسخ های ناموفق می شود، قابل شناسایی هستند. این رفتارهای غیرعادی می تواند به عنوان نشانه ای از وجود بات نت ها در شبکه مورد استفاده قرار گیرد. با پیشرفت در حوزه تکنولوژی های هوش مصنوعی و یادگیری ماشین، استفاده از شبکه های عصبی برای تحلیل و تشخیص الگوهای پیچیده در داده های شبکه به یک رویکرد موثر تبدیل شده است. شبکه های عصبی با توانایی بالای خود در یادگیری و تشخیص الگوهای غیرخطی، می توانند برای شناسایی رفتارهای غیرعادی ناشی از بات نت ها بسیار کارآمد باشند [۱۸].

### تجزیه و تحلیل کارهای مرتبط:

برای تشخیص بات نت ها روش های مختلفی پیشنهاد شده است که در ادامه به برخی از آن ها اشاره می شود. YU و همکاران [۳۰] یک روش مبتنی بر استفاده از شبکه های عصبی عمیق (DNN) برای تحلیل ترافیک DNS و تشخیص بات نت ها ارائه کرده اند. دقت بالا در تشخیص بات نت ها به دلیل توانایی شبکه های عصبی در شناسایی الگوهای پیچیده و نامنظم ترافیک شبکه و همچنین قابلیت یادگیری خودکار ویژگی ها بدون نیاز به استخراج دستی از نقاط قوت این روش می باشد. نیاز به حجم بالایی از داده های آموزشی برای آموزش شبکه های عصبی و همچنین زمان و منابع محاسباتی زیاد برای آموزش و اجرای مدل ها از نقاط ضعف این روش می باشد.

Bilge و همکاران [۳۱] یک روش مبتنی بر استفاده از الگوریتم های ماشین یادگیری سنتی مانند جنگل تصادفی (Random Forest) و ماشین بردار پشتیبانی (SVM) برای تحلیل ترافیک DNS و تشخیص بات نت ها ارائه کرده اند. پیاده سازی و آموزش ساده تر الگوریتم های ماشین یادگیری سنتی و همچنین نیاز به داده های کمتر نسبت به شبکه های عصبی از نقاط قوت این روش می باشد. دقت پایین تر نسبت به شبکه های عصبی در تشخیص بات نت ها و همچنین قابلیت یادگیری محدودتر و نیاز به استخراج دستی ویژگی ها از نقاط ضعف این روش می باشد.

Antonkakis و همکاران [۲۹] یک روش مبتنی بر استفاده از شبکه های عصبی بازگشتی (RNN) برای تحلیل توالی های زمانی درخواست های DNS و شناسایی الگوهای غیرمعمول برای تشخیص بات نت ها ارائه کرده اند. دقت بالا در شناسایی الگوهای زمانی پیچیده و همچنین قابلیت مدل سازی توالی های زمانی و شناسایی رفتارهای

[Wei Wang, Hui و Nazanin]Zargari, Morteza Saebi و [۱۰] Zeng, Dan Li [۱۱] روش‌های موثر برای تشخیص بات‌نت‌ها با استفاده از تحلیل ترافیک شبکه و تکنیک‌های هوش ارائه می‌دهند. از تحلیل‌های آماری و یادگیری ماشین برای شناسایی الگوهای غیرعادی در ترافیک شبکه استفاده کرده‌اند که می‌تواند نشان‌دهنده فعالیت بات‌نت باشد.

Arjun Singh, و [۲] Deepak Kumar, Suresh Reddy و [۳] Preeti Sharma و [۴] Mirco Anil Kumar, Praveen Kumar, و [۵] Sashank Gupta, و [۶] Marchetti, Michele Colajanni و [۷] Harshal A. Patel, Kavita و [۸] Bharat Bhargava و [۹] Sandeep Yadav, Ashwin L. Ganesh و [۸] Sharma

جدول ۱ روش‌های تشخیص بات‌نت‌ها با استفاده از تحلیل ترافیک شبکه و تکنیک‌های هوش

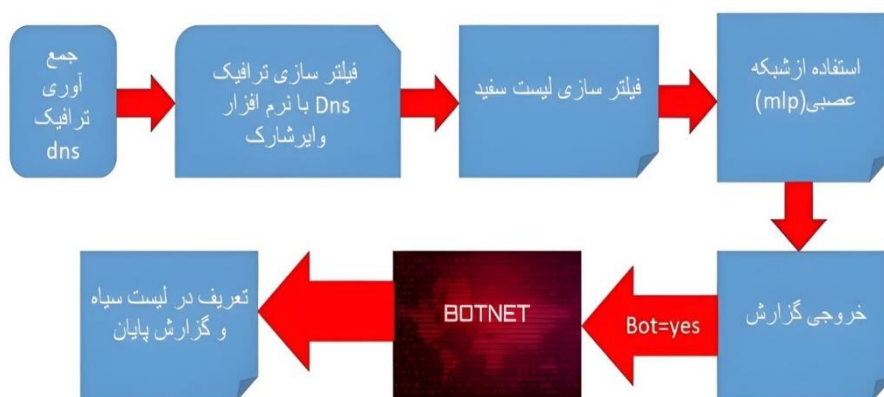
شماره	عنوان مقاله	نویسندگان	سال	روش پیشنهادی	نتایج کلیدی
۱	Effective Botnet Detection with Network Traffic Analysis and AI Techniques	Deepak Kumar, Suresh Reddy	2023	تحلیل ترافیک شبکه و تکنیک‌های هوش مصنوعی	تکنیک‌های هوش مصنوعی در کنار تحلیل ترافیک شبکه به بهبود دقت و سرعت تشخیص بات‌نت‌ها منجر شده است
۲	Hybrid Approach for Botnet Detection Using Machine Learning and Statistical Analysis	Arjun Singh, Preeti Sharma	2022	یادگیری ماشین و تحلیل آماری	ترکیب روش‌های آماری و یادگیری ماشین برای تشخیص بات‌نت‌ها نتایج مثبتی به همراه داشته است
۳	Anomaly-Based Botnet Detection Using Machine Learning and Flow Analysis	orge Luis Reyes Ortiz, Daniel Roggen	2021	تحلیل جریان شبکه و یادگیری ماشین	استفاده از تحلیل جریان شبکه و الگوریتم‌های یادگیری ماشین به تشخیص بات‌نت‌ها کمک می‌کند
۴	Automated Botnet Detection with Deep Learning Techniques	Anil Kumar, Praveen Kumar	2020	شبکه‌های عصبی عمیق	شبکه‌های عصبی عمیق توانسته‌اند به طور موثری بات‌نت‌ها را با دقت بالا تشخیص دهند
۵	Botnet Detection Using DNS Traffic Analysis and Machine Learning	Mirco Marchetti, Michele Colajanni	2019	تحلیل ترافیک DNS و یادگیری ماشین	استفاده از تحلیل ترافیک DNS و تکنیک‌های یادگیری ماشین باعث افزایش دقت تشخیص بات‌نت شد
۶	Detecting Botnets Using a Combined Approach of Network Traffic Analysis and Machine Learning	Shashank Gupta, Bharat Bhargava	2018	تحلیل ترافیک شبکه و ترکیب با یادگیری ماشین	ترکیب دو روش تحلیل ترافیک و یادگیری ماشین منجر به بهبود دقت و کاهش نرخ مثبت کاذب شد
۷	Real-Time Botnet Detection Using Machine Learning Techniques	Harshal A. Patel, Kavita Sharma	2017	تحلیل ترافیک شبکه و یادگیری ماشین در زمان واقعی	تشخیص بات‌نت در زمان واقعی با استفاده از مدل‌های یادگیری ماشین موثر و کارآمد است

مدل‌های یادگیری ماشین کارایی بالایی در تشخیص بات نت در شبکه‌های بزرگ دارند	یادگیری ماشین و تحلیل رفتار شبکه	2015	Sandeep Yadav, Ashwin L. Ganesh	A Machine Learning Approach for Botnet Detection in Large-Scale Networks	۸
ترکیب تحلیل ترافیک و الگوریتم‌های یادگیری ماشین منجر به افزایش دقت تشخیص بات نت شد	تحلیل ترافیک شبکه و یادگیری ماشین	2013	Nazanin Zargari, Morteza Saebi	Detecting Botnets Using Network Traffic Behavior Analysis and Machine Learning Techniques	۹
افزایش دقت تشخیص بات نت به کمک تحلیل رفتار ترافیک شبکه و مدل‌های شبکه عصبی	تحلیل رفتار ترافیک و شبکه‌های عصبی مصنوعی	۲۰۱۰	Wei Wang, Hui Zeng, Dan Li	Botnet Detection Based on Traffic Behavior Analysis and Artificial Neural Networks	۱۰

مبتنی بر از تحلیل پاسخ‌های ناموفق شبکه (NXDomain) ترافیک DNS و استفاده از شبکه عصبی پرسپترون چند لایه (MLP) را نشان می‌دهد. در شکل ۴، معماری سیستم پیشنهادی ارائه شده است. روش پیشنهادی شامل شش مؤلفه اصلی هست که عبارت‌اند از جمع‌آوری ترافیک DNS فیلترسازی ترافیک NXDOMAIN، فیلترسازی فهرست سفید، استفاده از شبکه عصبی، تحلیل معیارهای سنجش و گزارش تشخیص بات نت.

### روش پیشنهادی برای تشخیص بات نت

تشخیص بات نت یک چالش پیچیده و مهم در حوزه امنیت سایبری است. بات‌ها مجموعه‌ای از دستگاه‌های متصل به اینترنت هستند که توسط مهاجمین کنترل می‌شوند و می‌توانند برای حملات سایبری مختلفی مانند DDoS، ارسال هرزنامه و سرقت اطلاعات استفاده شوند. برای مقابله با این تهدیدات، شکل ۴ الگوی تشخیص بات نت پیشنهادی



شکل ۴: الگوی تشخیص بات نت پیشنهادی مبتنی بر از تحلیل پاسخ‌های ناموفق شبکه (NXDomain) ترافیک DNS و استفاده از شبکه عصبی

فعالیت‌های زیادی در شبکه‌ها ضروری است. به همین دلیل DNS برای مانیتورینگ، تشخیص و کاهش فعالیت بات‌ها بسیار مناسب است. در تشخیص مبتنی بر تحلیل ترافیک DNS به کل ترافیک شبکه نیاز نیست و فقط اطلاعات ترافیک DNS مورد نیاز است و این باعث افزایش کارایی روشمان می‌گردد. ترافیک DNS حدود ۶ درصد از کل ترافیک شبکه است [۴].

### جمع‌آوری ترافیک DNS:

سیستم پیشنهادی در سرویس‌دهنده DNS یا در لبه شبکه قرار می‌گیرد تا درخواست‌های DNS ماشین‌های داخل شبکه و پاسخ‌های دریافتی را ثبت و نظارت نماید. واضح است فقط ترافیک DNS مدنظر است که درصد کمی از ترافیک کل شبکه هست. با توجه به فعالیت روزانه بات‌نت‌های مبتنی بر الگوریتم نام دامنه، فرض بر این است که این نوع بات‌ها حداقل روزی یک‌بار اجرا می‌شوند؛ بنابراین حداکثر دوره زمانی برای جمع‌آوری ترافیک ۲۴ ساعت خواهد بود. با توجه به اینکه DNS یکی از رایج‌ترین پروتکل‌ها در شبکه است و برای کارکرد صحیح

دلیل شروع به فرستادن درخواست‌های رکورد A به سیستم DNS می‌نمایند. سیستم DNS نیز در پاسخ به این درخواست‌ها، با شرط وجود رکورد A مربوطه را برمی‌گرداند و در غیراینصورت پاسخ ناموفق دریافت می‌شود. بدین ترتیب، برای تحلیل و استخراج اطلاعات، تنها ترافیک مربوط به سؤال/پاسخ رکوردهای A در ترافیک DNS بررسی می‌گردند. در فیلترسازی ترافیک NXDomain، فقط درخواست‌هایی از رکورد A باقی خواهند ماند که دارای پاسخ‌های ناموفق یا NXDomain باشند و مابقی ترافیک DNS حذف خواهد شد؛ بنابراین بازهم حجم ترافیک ورودی به سیستم تشخیص کاهش خواهد یافت. همان‌طوری که اشاره گردید، یکی از ویژگی‌های کلیدی بات‌نت‌های مبتنی بر الگوریتم تولید نام دامنه، تولید روزانه نگاشت‌های ناموفق یا NXDomainها برای نام‌های دامنه‌ای است که وجود ندارند؛ بنابراین در میزبانی که به بات آلوده است تعداد NXDomainها نسبت به میزبان‌های عادی به‌طور قابل توجهی بیشتر است NXDomainها. غالباً به‌صورت گروهی تولید می‌شوند؛ بنابراین در ترافیک شبکه‌ای که آلوده به بات‌های موردنظر ما هستند، افزایش تعداد درخواست‌های رکورد A و در پی آن افزایش پاسخ‌های ناموفق یا NXDomain و در نهایت افزایش حجم ترافیک DNS نسبت به ترافیک کل شبکه اتفاق می‌افتد. در شکل ۳ درخواست‌های رکورد A و پاسخ‌های ناموفق در ترافیک DNS بات‌نت کراکن مشاهده می‌شود. این ترافیک از طریق اجرای کد بات کراکن بر روی یک میزبان متصل به اینترنت به‌دست‌آمده است.

## فیلترسازی فهرست سفید (Whitelist Filtering)

### برای تشخیص بات‌نت:

فیلترسازی فهرست سفید (Whitelist Filtering) یکی از موثرترین روش‌ها برای کاهش ترافیک مخرب و تشخیص فعالیت‌های غیرمجاز مانند بات‌نت‌ها در شبکه است. در این روش، تنها درخواست‌های DNS به دامنه‌های معتبر و شناخته‌شده که در فهرست سفید قرار دارند، مجاز به عبور از شبکه هستند. این رویکرد به طور قابل توجهی می‌تواند تعداد درخواست‌های DNS مشکوک و مخرب را کاهش دهد [۱۸]. در فیلترسازی فهرست سفید، فهرستی از نام‌های دامنه قابل اعتماد مثل google.com نگهداری می‌شود و درخواست و پاسخ‌های DNS مربوط به آن‌ها فیلتر می‌شود. بدین منظور، ابتدا ترافیک شبکه ضبط می‌شود. سپس بسته‌ها به/از سمت میزبان‌های موجود در فهرست سفید از این ترافیک حذف‌شده و سایر بسته‌های باقیمانده به‌عنوان ترافیک ورودی به مؤلفه بعدی داده می‌شوند. فیلتر سفید حجم ترافیک و در نتیجه حجم پردازش و نرخ خطای سیستم تشخیص را کاهش می‌دهد. برای ایجاد فهرست سفید، یک میلیون وب‌سایت برتر از Alex مورد استفاده قرار می‌گیرد. بدین دلیل که صد سایت پربازدید در اینترنت به احتمال زیاد به بات آلوده نیستند [۱۹].

### فیلترسازی ترافیک NXDomain :

در شبکه‌های بات، اعضای شبکه سعی در برقراری ارتباط با سرور فرماندهی و کنترل دارند تا دستورات حمله را دریافت نمایند، به همین

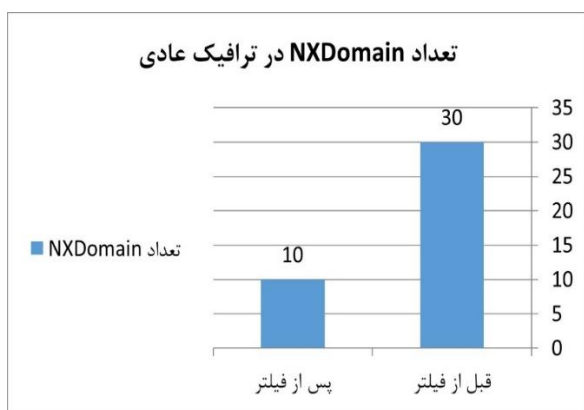
No.	Time	Source	Destination	Protocol	Length	Info
6696	3111.05426	192.168.121.129	192.168.121.255	NBNS	92	Name query NB L\MYNOX.NET<00>
6697	3111.83053	192.168.121.129	192.168.121.2	DNS	78	Standard query 0x6238 A gfooaqf.dyndns.org
6698	3112.15882	192.168.121.2	192.168.121.129	DNS	129	Standard query response 0x6238 No such name
6699	3112.15921	192.168.121.129	192.168.121.2	DNS	90	Standard query 0xe3d0 A gfooaqf.dyndns.org.localdomain
6700	3112.50793	192.168.121.2	192.168.121.129	DNS	90	Standard query response 0xe3d0 No such name
6701	3112.63076	192.168.121.129	192.168.121.2	DNS	75	Standard query 0xd6c9 A egmbdedy.yi.org
6702	3112.85547	192.168.121.2	192.168.121.129	DNS	141	Standard query response 0xd6c9 No such name
6703	3112.85567	192.168.121.129	192.168.121.2	DNS	87	Standard query 0x956e A egmbdedy.yi.org.localdomain
6704	3112.89982	192.168.121.2	192.168.121.129	DNS	87	Standard query response 0x956e No such name

شکل ۵: فعالیت بات‌نت کراکن و پاسخ‌های NXDomain

رکورد A و معیار گروه‌بندی. با بررسی میزان تحقق این معیارها، می‌توان درباره آلودگی به بات یا پاک بودن یک میزبان تصمیم گرفت. در ادامه به تشریح معیارها می‌پردازیم.

انجام محاسبات و تحلیل معیارهای سنجش: از اطلاعات دریافتی از مؤلفه‌های قبلی و با انجام محاسباتی بر روی جدول نام دامنه برای هر IP یا میزبان معین، می‌تواند سه معیار تعریف نمود. معیارها عبارتند از تعداد پاسخ‌های ناموفق یا NXDomainها، تراکم درخواست‌های

مذکور در هنگام فعالیت و به دفعات جمع آوری شد. ترافیک زمینه یا ترافیک بی خطر، با استفاده از نرم افزار وایرشارک و در محل سرور DNS شبکه دانشگاه، جمع آوری شد. همچنین در موارد متعدد و در ساعات مختلف، ترافیک میزبان های بی خطر متصل به اینترنت، به دست آمده و ذخیره شدند. در کلیه موارد فوق، ترافیک ها به صورت خام و بدون هیچ گونه پردازشی در بسته های pcap ذخیره شدند. تعداد کل NXDomain ها را با n نشان می دهیم. محدوده زمانی نظارت بر ترافیک را با T نشان داده و مقدار آن را یک ساعت در نظر می گیریم. قبل و بعد از اعمال فیلترهای NXDomain و فهرست سفید در ترافیک عادی، تعداد NXDomain ها به دفعات برای یک میزبان متصل به اینترنت اندازه گیری شد و حداکثر آن در دوره زمانی T محاسبه شد. قبل از فیلتر n=30 و پس از فیلتر n=10 به دست آمد. این موضوع در نمودار شکل ۶ مشاهده می شود.



شکل ۶: تعداد NXDomain ترافیک عادی قبل و بعد از فیلترها

مواردی که فیلتر شده اند عبارتند از درخواست های تکراری، درخواست های غیر از رکورد A یا درخواست های موجود در فهرست سفید بوده است. در جدول ۲ مواردی از ترافیک DNS نشان داده شده است، این درخواست ها، غیر از رکورد A بوده اند و به همین دلیل فیلتر شده اند.

جدول ۲: پاسخ های NXDomain - فیلتر شده

Source	Destination	Protocol	Length	Info
192.168.1.2	192.168.1.1	DNS	84	Standard query 0x66be PTR 1.1.168.192.in-addr.arpa
192.168.1.1	192.168.1.2	DNS	133	Standard query response 0x66be No such name
192.168.1.2	192.168.1.1	DNS	92	Standard query 0x5d05 SRV _ldap._tcp.dc._msdcs.domain.name
192.168.1.1	192.168.1.2	DNS	155	Standard query response 0x5d05 No such name

شکل ۷، تعداد NXDomain - ها در میزبان های آلوده بسیار بیشتر از میزبان های عادی است.

## انجام محاسبات و تحلیل معیارهای سنجش:

الف- تعداد پاسخ های ناموفق: از جدول دامنه مربوط به هر IP یا میزبان معین، می توانیم تعداد کل NXDomain ها را در دوره زمانی T محاسبه نماییم. این تعداد را با n نشان می دهیم. دوره زمانی T با توجه به فعالیت روزانه بات نت های مبتنی بر تولید نام دامنه حداکثر برابر ۲۴ ساعت خواهد بود. در میزبانی که به بات آلوده است تعداد NXDomain ها نسبت به میزبان های عادی به طور قابل توجهی بیشتر است. اگر n بیش از یک حد آستانه باشد یکی از معیارهای آلودگی میزبان تحقق می یابد. حد آستانه در ادامه تعیین خواهد شد.

T: دوره زمانی برای ثبت و بررسی ترافیک (حداکثر ۲۴ ساعت)  
n: تعداد کل NXDomain های محاسبه شده در دوره زمانی T  
ب- تراکم درخواست های رکورد A: در ترافیک شبکه آلوده به بات های مورد نظر، تعداد درخواست های رکورد A نسبت به ترافیک یک شبکه بی خطر بسیار بیشتر است. با توجه به اینکه زمان درخواست های رکورد A مربوط به هر دامنه در جدول دامنه مربوط به IP معین ثبت شده است، زمان درخواست هر رکورد برای نام دامنه i را با t<sub>i</sub> نشان می دهیم. از t<sub>i</sub> می توان متوسط فاصله زمانی مابین درخواست های رکورد A را طبق رابطه زیر به دست آورد:

$$p = \sum_{i=1}^{n-1} (t_{i+1} - t_i) / n - 1$$

از p برای سنجش تراکم تعداد درخواست های رکورد A در دوره زمانی T استفاده می شود. تراکم بیش از یک حد آستانه می تواند نشان دهنده وجود بات باشد. از اطلاعات و روابط فوق می توان درباره آلوده بودن یا عادی بودن نام های دامنه یک میزبان معین در دوره زمانی T تصمیم گرفت. بدین ترتیب که اگر معیارهای فوق در یک میزبان محقق شود آنگاه آن میزبان آلوده به بات تشخیص داده خواهد شد.

## نتایج آزمایش:

فایل های اجرایی کانفیگر و کراکن، که از نوع بات نت های مبتنی بر نام دامنه هستند از اینترنت دانلود و روی چند سیستم مجازی اجرا گردیدند. با استفاده از نرم افزار وایرشارک [۲۵]، ترافیک بات نت های

در دوره یک ساعته T و پس از اعمال فیلترها، فعالیت بات نت کانفیگر، کراکن و ترافیک عادی با یکدیگر مقایسه شده است. مطابق نمودار


جدول ۳: متوسط فاصله زمانی بین درخواست‌های رکورد A در انواع ترافیک

نوع ترافیک	$\gamma$
کانفیگر	۸
کراکن	۳
عادی	>۱۰

مقدار  $\gamma = 10$  را انتخاب می‌نماییم، به این معنی که متوسط فاصله زمانی مابین درخواست‌های رکورد A در مواردی که کمتر از ۱۰ باشد ممکن است نشانه‌ای از آلودگی به بات باشد.

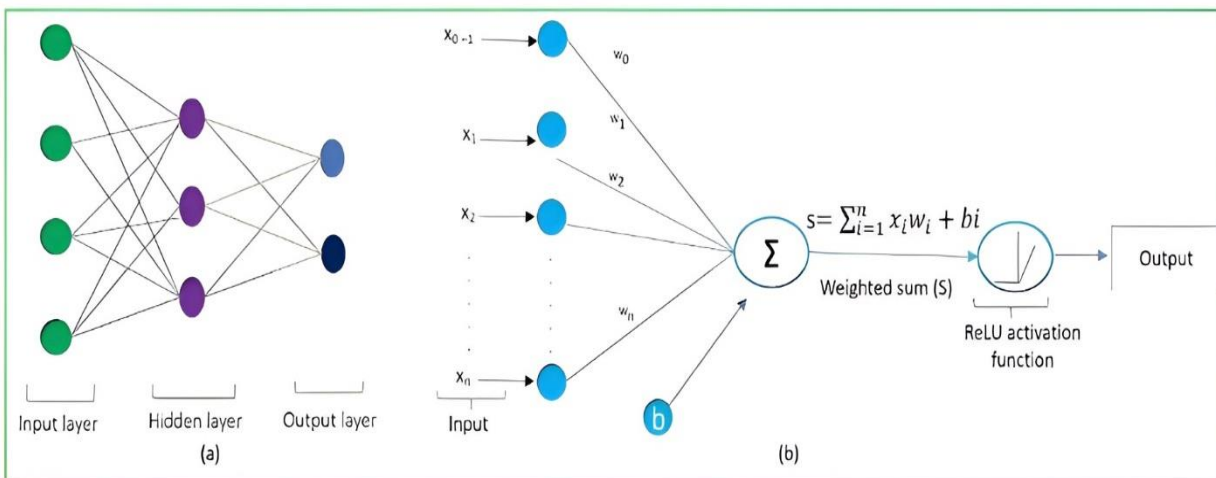
**پیاده سازی شبکه عصبی پرسپترون چند لایه (MLP):**

ایده ما در حل تشخیص بات نت توسط شبکه عصبی پرسپترون چندلایه این است که متلب این ورودی‌ها را از فایل متنی خروجی وایرشارک گرفته و تحلیل می‌نماید که آیا شبکه مشکوک به بات است یا خیر؟ ما ابتدا باید با استفاده از ورودی‌ها و خروجی‌های به دست آمده از مراحل قبل که مطابق جدول و در یک فایل اکسل ذخیره هست این آموزش را به متلب می‌دهیم. آموزشات لازم توسط ورودی‌ها و هدف‌هایی که مورد نظر ما هست انجام می‌گردد. ما در اینجا ۵ داده را به عنوان زمان درخواست در نظر گرفتیم برای هر شبکه‌ای که ترافیکش را گرفته‌ایم و متوسط زمان درخواست‌ها را با فرمول گفته شده در بالا به دست آوردیم که متلب این ورودی و خروجی‌ها را به طور خودکار از فایل اکسل دریافت و وزن‌های هر یال و بایاس‌های هر نرون را به دست می‌آورد. شکل ۸ نمونه ای از (a) معماری ساده یک شبکه عصبی مصنوعی و همچنین (b) تصویری از عملیات فعال سازی در شبکه عصبی مصنوعی با استفاده از تابع فعال سازی ReLU را نشان می‌دهد.



شکل ۷: نمودار تعداد NXDomain

حد آستانه‌ای به نام  $\alpha$  تعریف نموده و میزبان‌هایی که بیش از حد آستانه NXDomain دارند، در مرحله بعد گروه‌بندی می‌شوند و از بررسی سایر میزبان‌ها صرف نظر می‌شود. با استفاده از نتایج این بخش  $\alpha = 10$  خواهد بود. یعنی اگر پس از اعمال فیلتر NXDomain و فیلتر فهرست سفید، تعداد NXDomain های موجود در ترافیک، در محدوده زمانی یک ساعت، بیش از ۱۰ عدد باشد در مرحله بعد گروه‌بندی خواهند شد. در غیراینصورت از ادامه سایر مراحل صرف نظر نموده و آن میزبان در محدوده زمانی T غیر آلوده تشخیص داده می‌شود.




شکل ۸ نمونه ای از (الف) معماری و عملیات فعال سازی در شبکه عصبی [1]

جدول ۴: ورودی و خروجی‌های شبکه عصبی پرسپترون چندلایه

	A	B	C	D	E	F	G
		RT1	RT2	RT3	RT4	RT5	Avg(RTi)
1	D1	1	9	23	54	98	24
2	D2	6	20	34	76	90	21
3	D3	2	30	80	90	120	24
4	D4	3	10	15	25	66	13
5	Conficker	4	12	22	30	36	9
6	Craker	1	4	5	8	13	3
7	D7	1	20	33	44	57	14
8	D8	10	15	57	90	112	25
9	D9	8	20	46	87	99	23
10	D10	1	14	29	39	59	15
11	D11	1	20	33	55	55	14
12	D12	10	15	57	90	99	22
13	D13	8	20	46	87	99	20
14	D14	1	14	29	39	59	15
15	D15	1	9	23	54	88	22
16	D16	6	20	34	76	90	21
17	D17	2	20	80	90	120	30
18	D18	3	10	15	25	45	11
19	D19	8	20	46	87	99	23
20	D20	1	14	29	39	59	15
21	D21	1	9	23	54	88	22
22	D22	6	20	34	76	90	21

انتشار نیز به معنای این است که خطاها به سمت عقب در شبکه تغذیه می‌شوند تا وزن‌ها را اصلاح کنند و پس از آن، مجدداً ورودی مسیر پیش‌سوی خود تا خروجی را تکرار کند. روش پس انتشار خطا از روش‌های با سرپرست است به این مفهوم که نمونه‌های ورودی برچسب خورده اند و خروجی مورد انتظار هر یک از آن‌ها از پیش دانسته است. لذا خروجی شبکه با این خروجی‌های ایده آل مقایسه شده و خطای شبکه محاسبه می‌گردد. در این الگوریتم ابتدا فرض بر این است که وزن‌های شبکه به‌طور تصادفی انتخاب شده‌اند. در هر گام خروجی شبکه محاسبه شده و برحسب میزان اختلاف آن با خروجی مطلوب، وزن‌ها تصحیح می‌گردند تا در نهایت این خطا، مینیمم شود.

شکل‌های ۹ و ۱۰ نشان‌دهنده پیاده‌سازی مراحل شبکه عصبی ما هست. همان‌طور که مشاهده می‌کنید شبکه طراحی شده عصبی پرسپترون چندلایه ما شامل ۳ لایه ورودی، پنهان و خروجی هست؛ که هر لایه پنهان ما که در همان جعبه سیاه می‌باشند شامل ۱۴ نرون هست. ما از الگوریتم پس انتشار خطا در اینجا استفاده نمودیم این الگوریتم که در سال 1986 توسط روملهارت و مک کلیلاند پیشنهاد گردید، در شبکه‌های عصبی پیش‌سوی مورد استفاده قرار می‌گیرد. پیش‌سوی بودن به این معناست که نرون‌های مصنوعی در لایه‌های متوالی قرار گرفته‌اند و خروجی سیگنال خود را روبرو جلو می‌فرستند. واژه پس



شکل ۹: مدل ریاضی ساده شده شبکه عصبی برای تشخیص بات نت


```

>> testInput=[2 15 24 35 48]';
>> nntools
??? Undefined function or variable 'nntools'.

>> nntool
>> nntool
>> nntool
(1:
a(6
2 1
Ne
MLP
>>
%% Test MLP Network for Bot
>> Result=sim(MLP_Bot,TestInput)

Result =

    15.04
  
```




شکل ۱۰: شبکه عصبی پرسپترون چندلایه بات نت

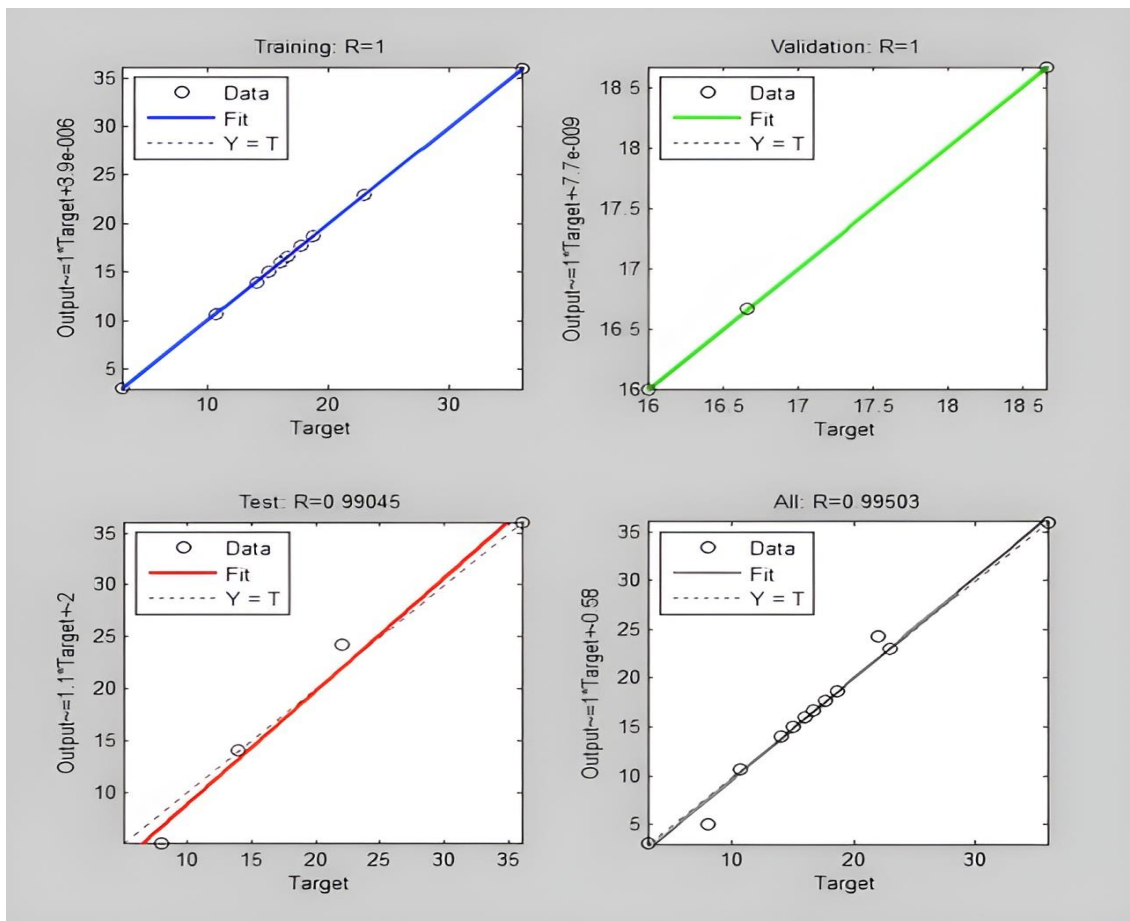
شکل ۱۱: مثالی از آزمون شبکه عصبی طراحی شده

نمودار عملکرد که شامل نمودارهای آموزشی، آزمون و اعتبار سنجی هست در شکل های ۱۲، ۱۳ و ۱۴ نمایش داده شده است. که با توجه به اینکه در مرحله آموزش و اعتبار سنجی  $r=1$  هست یعنی به طور کامل متلب آموزشات و اعتبار سنجی های لازم را در خصوص تشخیص بات نت دیده است. مرحله آزمون نیز  $r=0.99503$  هست که این هم در حد ایده آل هست.

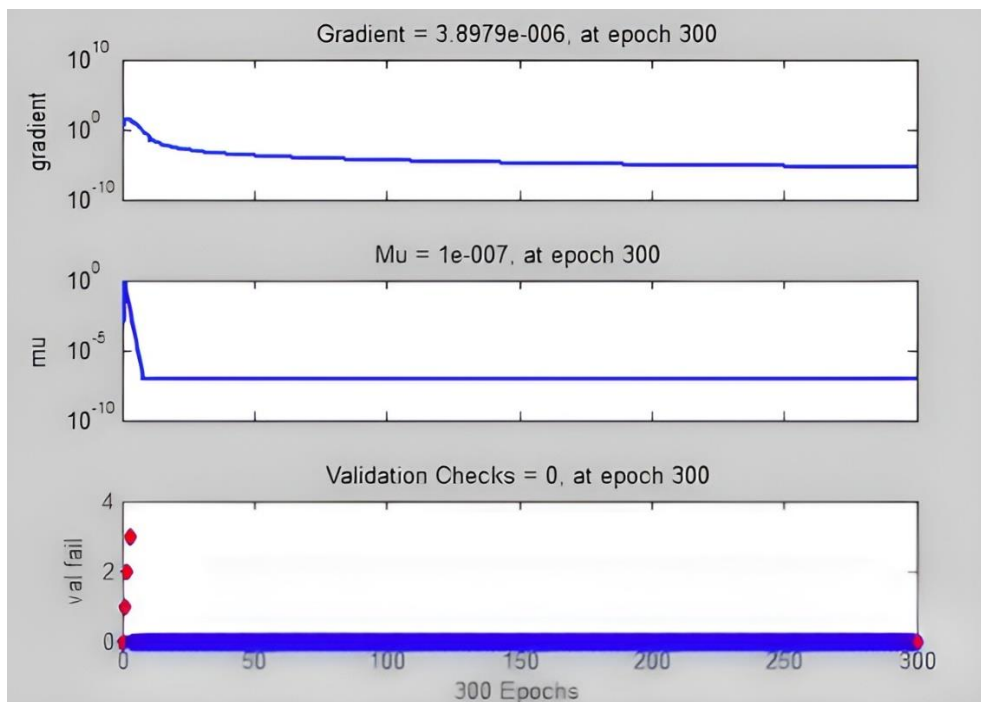
پس از اینکه توسط متلب اعتبارسنجی های لازم انجام شد. می توانیم مطابق شکل ۱۱ آزمون هایمان را انجام بدهیم و به نتایج مورد نظر که همان تشخیص بات نت هست به سادگی و بدون هیچ گونه تحلیلی برسیم.



شکل ۱۲: تابع عملکرد و کار آیی شبکه عصبی طراحی شده



شکل ۱۳: تابع REGRESSION شبکه عصبی طراحی شده



شکل ۱۴: تابع TRAINING STATE شبکه عصبی طراحی شده

## نتیجه گیری:

روش پیشنهادی ما ابتدا رفتارهای غیرعادی و پاسخهای ناموفق شبکه که ممکن است ناشی از فعالیت باتنتها باشد را شناسایی می کند. سپس، با بهره گیری از شبکه های عصبی عمیق، الگوهای پنهان و پیچیده در این داده ها تحلیل می شوند. شبکه های عصبی با توانایی بالا در یادگیری الگوهای غیرخطی، ابزار قدرتمندی برای تشخیص دقیق و کارآمد باتنتها ارائه می دهند. روش ما قابلیت تشخیص باتنتهای شناخته شده و همچنین ناشناخته ای که از این روش استفاده می کنند را دارا هست. هدف ما در این مقاله، ارائه روشی نوآورانه برای تشخیص باتنتها با استفاده از تحلیل پاسخهای ناموفق و شبکه عصبی است. در این روش تشخیص باتنتها براساس پاسخهای ناموفق یا NXDomain در هر میزبان صورت می گیرد. این ویژگی باعث می شود که دقت تشخیص در شبکه های کوچک و متوسط افزایش یابد. نتایج آزمایشها نشان دهنده دقت بالا و نرخ پایین مثبت کاذب مدل پیشنهادی در تشخیص باتنتها است. این روش نه تنها قابلیت شناسایی سریع و موثر باتنتها را دارد، بلکه می تواند به عنوان یک ابزار پیشگیرانه برای بهبود امنیت شبکه های کامپیوتری مورد استفاده قرار گیرد. این مطالعه نشان می دهد که تحلیل پاسخهای ناموفق شبکه با استفاده از شبکه های عصبی می تواند رویکردی مؤثر و عملی برای مقابله با تهدیدات امنیتی ناشی از باتنتها باشد. استفاده از شبکه های عصبی برای آنالیز پاسخهای ناموفق DNS در تشخیص باتنتها یک راهکار مؤثر و کارآمد است. این روش می تواند دقت تشخیص را افزایش دهد، الگوهای ناشناخته را شناسایی کند و قابلیت اطمینان سیستم های امنیتی را بهبود بخشد. با توجه به پیشرفت های اخیر در زمینه یادگیری عمیق و شبکه های عصبی، انتظار می رود که این روشها در آینده نقش مهم تری در مقابله با تهدیدات امنیت سایبری ایفا کنند. پیاده سازی صحیح و رعایت امنیت و حریم خصوصی، کلید موفقیت این رویکرد در کاربردهای عملی است. ارائه رویکرد ترکیبی شبکه های عصبی مختلف مانند LSTM، RNN و LSTM و پیاده سازی رویکرد در محیط کاربردی اینترنت برای تشخیص باتنت از رویکردهای آتی پژوهش حاضر می باشد.

## تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان بیان نشده است.

## منابع:

- [3] Singh A, Sharma P. Hybrid Approach for Botnet Detection Using Machine Learning and Statistical Analysis. J Cybersecurity. 2022.
- [4] Reyes Ortiz JL, Roggen D. Anomaly-Based Botnet Detection Using Machine Learning and Flow Analysis. Comput Commun. 2021.
- [5] Kumar A, Kumar P. Automated Botnet Detection with Deep Learning Techniques. J Inf Secur Appl. 2020.
- [6] Wang W, Zeng H, Li D. Botnet Detection Based on Traffic Behavior Analysis and Artificial Neural Networks. IEEE Commun Mag. 2010.
- [7] Zargari N, Saebi M. Detecting Botnets Using Network Traffic Behavior Analysis and Machine Learning Techniques. J Netw Comput Appl. 2013.
- [8] Yadav S, Ganesh AL. A Machine Learning Approach for Botnet Detection in Large-Scale Networks. IEEE Trans Netw Serv Manag. 2015.
- [9] Patel HA, Sharma K. Real-Time Botnet Detection Using Machine Learning Techniques. Comput Netw. 2017.
- [10] Gupta S, Bhargava B. Detecting Botnets Using a Combined Approach of Network Traffic Analysis and Machine Learning. J Comput Secur. 2018.
- [11] Marchetti M, Colajanni M. Botnet Detection Using DNS Traffic Analysis and Machine Learning. IEEE Trans Inf Forensics Secur. 2019.
- [12] LeCun Y, Bengio Y, Hinton G. Deep learning. Nature. 2015;521(7553):436-444.
- [13] Choi H, Lee H. Identifying botnets by capturing group activities in DNS traffic. 2011.
- [14] Choi H, Lee H. Identifying botnets by capturing group activities in DNS traffic. Comput Netw. 2012;56:20-33.
- [15] Choi H, et al. BotGAD: detecting botnets by capturing group activities in network traffic. In: Proceedings of the Fourth International ICST Conference on COMMunication System softWARE and middlewaRE; 2009; Dublin, Ireland.
- [16] Gu G, et al. BotHunter: Detecting malware infection through ids-driven dialog correlation. In: Proceedings of 16th USENIX Security Symposium on USENIX Security Symposium; 2007; Boston, MA.
- [17] Gu G, et al. Botminer: Clustering analysis of network traffic for protocol and structure independent Botnet detection. In: Proceedings of the 17th conference on Security symposium; 2008; San Jose, CA.
- [18] Rahbarinia B, et al. Segugio: Efficient Behavior-Based Tracking of Malware-Control Domains in Large ISP Networks. In: NDSS Symposium; 2015.
- [19] Alexa Top Global Sites. Available: <http://www.alexacom/topsites>.
- [20] Schoof R, Koning R. Detecting peer-to-peer botnets. University of Amsterdam, Technical report; 2007.
- [21] Skoudis E, et al. Top Ten Cyber Security Menaces for 2008. SANS Institute; 2008.

- [1] Maniriho P, Mahmood AN, Chowdhury MJM. Deep Learning Models for Detecting Malware Attacks. 2024.
- [2] Kumar D, Reddy S. Effective Botnet Detection with Network Traffic Analysis and AI Techniques. J Netw Comput Appl. 2023.

[28]Wang, W., Xu, M., Huang, R., & Sun, Z. Botnet Detection Using Machine Learning Techniques; 2018.

[29] Antonakakis M, Perdisci R, Lee W, Vasiloglou N, Dagon D. Detecting Malware Domains at the Upper DNS Hierarchy. USENIX Security Symposium; 2010.

[30]Yu J, Li Z, Yan Q, Han J, Guan X. Network traffic characteristics analysis and anomaly detection on DNS. Comput Netw. 2017;117:87-99.

[31]Bilge L, Kirda E, Kruegel C, Balduzzi M. Exposure: Finding Malicious Domains Using Passive DNS Analysis. NDSS; 2011.

[22] Cooke E, et al. The zombie roundup: understanding, detecting, and disrupting botnets; 2005.

[23]Park J. Acquiring Digital Evidence from Botnet Attacks: Procedures and Methods; 2011.

[24] Sharifnya R, Abadi M. A novel reputation system to detect DGA-based botnets. In: Computer and Knowledge Engineering (ICCKE), 2013 3th International eConference on; 2013. p. 417-423.

[25]Wireshark. Available: <http://www.wireshark.org>.

[26]Patel, P., & Modi, C. An Efficient Botnet Detection Framework Using Machine Learning Techniques; 2020.

[27]Lu, Y., Li, Z., & Zhang, C. DNS-based botnet detection using Long Short-Term Memory (LSTM) networks; 2019.

---

#### COPYRIGHTS

©2024 by the authors. Published by the Islamic Azad University, Khodabandeh Branch, Zanjan. This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution 4.0 International (CC BY 4.0) <https://creativecommons.org/licenses/by/4.0>

---

