

## تشخیص شبکه بات با رویکرد تحلیل رفتاری جریان شبکه و بهره‌گیری از الگوریتم‌های داده‌کاوی

سعید پارسا<sup>۱\*</sup>، حامد مرتاضی<sup>۲</sup>

۱- دانشیار، دانشگاه علم و صنعت ایران ۲- کارشناس ارشد کامپیوتر، دانشگاه آزاد اسلامی شبستر

(دریافت: ۹۵/۰۵/۰۴، پذیرش: ۹۵/۱۱/۲۵)

### چکیده

«شبکه بات» شبکه‌ای از رایانه‌های آلوده متصل به اینترنت است که تحت مدیریت سرور فرماندهی و کنترل قرار دارد و برای حملات انکار سرویس، فرستادن هرزنامه و عملیات مخرب دیگر مورد استفاده قرار می‌گیرد. با وجود ویژگی‌های خاص هر شبکه بات، بات‌ها در داخل شبکه رفتاری همسانی از خود نشان می‌دهند و این می‌تواند نقطه آغاز شناسایی یک بات در داخل شبکه باشد و با شناسایی این رفتار همگون می‌توان ترافیک تولیدی بات‌ها را از ترافیک عادی شبکه تفکیک کرد و از مشکلاتی مانند یافتن الگوریتم‌های رمزگشایی کانال‌های ارتباطی رمزنگاری شده در امان بود. رفتار همسان بات‌ها در داخل شبکه بات می‌تواند منجر به تولید ویژگی‌ها و خصیصه‌هایی شود که بتوان با تحلیل این ویژگی‌ها، جریان بدخواه را از جریان سالم تشخیص داد. منطق اصلی روش استفاده‌شده در این پژوهش بر این پایه استوار است که شبکه‌های بات، الگوهای ترافیکی قابل تشخیصی از خود به‌جای می‌گذارند که به کمک روش‌های یادگیری ماشین قابل شناسایی بوده و می‌توان ترافیک تولیدی توسط آن‌ها را از ترافیک عادی شبکه جدا کرد. در این مقاله، ویژگی‌ها و رفتار شبکه‌های بات مشهور همچون Weasel در جهت تولید خصیصه‌ها مطالعه شد. سپس، بعد از تهیه مجموعه داده‌های واقعی که ترکیبی از ترافیک سالم و ترافیک تولیدی توسط چندین شبکه بات مشهور است، جریان بسته‌ها در پنجره‌های زمانی ۳۰۰ ثانیه‌ای تحلیل شده و با توجه به الگوهای ترافیکی قابل تشخیص، خصیصه‌های مختلفی استخراج (تولید) شد. این خصیصه‌ها در ابزار وکا و به کمک الگوریتم‌های یادگیری ماشین داده‌کاوی شده و نتایج طبقه‌بندی به‌عنوان خروجی ارائه می‌شود. نتایج خروجی‌ها نشان‌دهنده نرخ تشخیص بالاتر در مقایسه با کارهای مشابه و در حدود ۹۹٪ می‌باشد. درنهایت نیز روشی برای شناسایی بلادرنگ شبکه‌های بات ارائه خواهد شد.

**واژه‌های کلیدی:** شبکه بات، تشخیص شبکه بات، سرور فرماندهی و کنترل، پنجره زمانی، یادگیری ماشین

### ۱- مقدمه

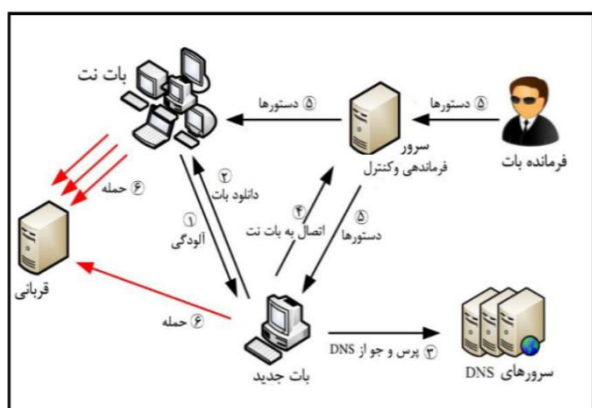
بات به‌ویژه در مقابله با حملات ارسال هرزنامه و حملات انکار سرویس انجام شده است را می‌توان به دو گروه واکنشی و جلوگیری تقسیم نمود [۱].

روش‌های واکنشی رایج‌ترین روش‌ها هستند. راهبرد مورد استفاده در این روش‌ها آن است که ابتدا فعالیت‌های مخرب تشخیص داده شوند و سپس اقدام مناسب برای کاهش ترافیک مخرب به مقداری قابل قبول، انجام گیرد. این روش‌ها دارای دو عیب عمده می‌باشند: (۱) نیاز به ساخت یک زیربنای کامل با قدرت پردازشی قابل توجه و هم‌چنین فضای ذخیره‌سازی داده برای تحلیل حجم عظیمی از اطلاعات جمع‌آوری شده. (۲) با توجه به این که حمله در زمان تشخیص هم‌چنان در حال اجرا است، کاربران عادی حداقل از بخشی از تأثیرات منفی آن تا انجام واکنش مناسب، رنج خواهند برد. روش‌های جلوگیری، روش‌هایی هستند که سعی می‌کنند احتمال انجام فعالیت‌های مخرب را تا حد ممکن کاهش دهند. این

واژه بات از روبات برگرفته شده و در حقیقت یک کد دودویی بدخواه است که بر روی میزبان‌های آسیب‌پذیر اجرا شده و به مهاجم یا مدیر بات امکان می‌دهد تا از راه دور آن میزبان‌ها را با فرامین خود هدایت نماید. شبکه بات نیز به معنی شبکه‌ای از میزبان‌های آلوده به بات می‌باشد. زمانی که یک رایانه به بات آلوده می‌شود، دیگر قادر نخواهد بود در برابر دستورات مدیر بات مقاومت کرده یا از اجرای آن‌ها سرباز زند. درنتیجه، مهاجم می‌تواند از توان پردازشی میزبان‌های به تصرف درآمده، به‌صورت توزیع شده به نفع خود بهره‌برداری کرده و انواع مختلفی از حملات را به صورت هماهنگ و با قدرت تخریبی بسیار بالا بر روی قربانی سازمان‌دهی کند. این در حالی است که معمولاً هویت وی مخفی می‌ماند. اقداماتی که تا به امروز برای مقابله با فعالیت‌های مخرب شبکه‌های

شده‌اند تا برخی از توابع از قبل تعریف شده را به صورت خودکار انجام دهند. به عبارت دیگر، بات‌های منفرد برنامه‌های نرم‌افزاری هستند که روی رایانه میزبان اجرا می‌شوند و موجب می‌شوند مهاجم فعالیت‌های میزبان را از راه دور کنترل کند [۴]. برخی اوقات به جای کلمه بات، اصطلاح زامبی<sup>۲</sup> به کار برده می‌شود.

**شبکه بات:** شبکه بات، شبکه‌ای از رایانه‌های آلوده به نام بات‌ها است که تحت کنترل مهاجم قرار دارند و برای حملات انکار سرویس توزیع شده، کلاهبرداری، تقلب کلیک و انتشار بدافزارها مورد استفاده قرار می‌گیرند. شبکه بات را ارتش زامبی‌ها نیز می‌گویند [۲ و ۵].



شکل (۱): شمای کلی یک شبکه بات و مفاهیم مرتبط با آن بر مبنای [۶] IRC

**سرور فرماندهی و کنترل:** بات دستورات خود را از سرور فرماندهی و کنترل که توسط مهاجم هدایت می‌شود، دریافت می‌نماید. استفاده از این سرور موجب گمنامی مهاجم می‌شود تا به راحتی قابل ردیابی نباشد.

**فرمانده بات یا مهاجم<sup>۳</sup>:** مهاجم به فردی گفته می‌شود که تمامی کارهای یک شبکه بات - از ایجاد تا کنترل - را به دست دارد؛ بدین ترتیب که بات را پیکربندی و پیاده‌سازی می‌نماید، سپس بات را بر روی رایانه قربانی نصب کرده و در نهایت، بات‌ها را از طریق کانال کنترلی هدایت و رهبری کرده و دستورهای حمله را صادر می‌نماید.

### ۳- طبقه‌بندی روش‌های تشخیص شبکه بات

شکل (۲)، طبقه‌بندی روش‌های مختلف تشخیص شبکه بات براساس نوع پیاده‌سازی آن‌ها را نمایش می‌دهد. در ادامه، این روش‌ها به صورت اجمالی توضیح داده شده است.

راه‌کارها می‌توانند شامل افزایش منابع کاربران و یا ایجاد تغییر در زیربنای شبکه به گونه‌ای باشد که کاربران را وادار به احراز هویت کند. هرچند که در مقابله با این راه‌کارها، مهاجمان نیز می‌توانند منابع و ابزارهای خود را بهبود بخشند. در این مقاله رویکرد ارائه شده، بر مبنای روش واکنشی بوده و بدخواه بودن یا سالم بودن بسته‌های آزمایشی بدین صورت تشخیص داده می‌شود که پس از تحلیل جریان بسته‌ها و استخراج و تولید خصیصه‌های وابسته به جریان، این خصیصه‌ها در جهت شناسایی الگوهای رفتاری مشابه، داده‌کاوی شده و در نهایت، الگوی بسته‌های سالم از بسته‌های مخرب متمایز می‌شود.

در بخش‌های دوم و سوم این مقاله به تشریح ویژگی‌های شبکه‌های بات و انواع روش‌های تشخیص آن‌ها پرداخته می‌شود. در بخش چهارم، نمونه کارهای مشابه در جهت تشخیص شبکه‌های بات مطالعه می‌شود. در بخش پنجم، روش پیشنهادی تشخیص شبکه‌های بات توضیح داده می‌شود. در بخش ششم، شرایط و نحوه انجام آزمایش‌ها بیان شده و در نهایت در بخش هفتم، نتایج ارزیابی به همراه مقایسه آن با کارهای مشابه ارائه خواهد شد.

### ۲- شبکه‌های بات

«شبکه بات» شبکه‌ای از رایانه‌های آلوده متصل به اینترنت است که تحت مدیریت سرور فرماندهی و کنترل قرار دارد و برای حملات انکار سرویس، فرستادن برنامه مخرب دیگر مورد استفاده قرار می‌گیرد. ممکن است شبکه‌های بات دارای کارکردهای قانونی نیز باشند، ولی در اغلب موارد با فعالیت‌های مجرمانه برای انتشار برنامه، بدافزار یا حملات سرقت هویت در ارتباط هستند [۲]. اندازه یک شبکه بات، به پیچیدگی و تعداد رایانه‌های استفاده شده در آن بستگی دارد. معمولاً کاربران کامپیوترها از این موضوع که دستگاه‌هایشان از راه دور کنترل شده و مورد سوءاستفاده قرار می‌گیرند اطلاعی ندارند. در مقایسه شبکه بات با بدافزارهای موجود مانند کرم و ویروس، وجود کانال‌های فرماندهی و کنترل، تفاوت کلیدی است؛ چون بات‌ها تحت کنترل مهاجم، دستور را دریافت و رفتارهای مخرب انجام می‌دهند [۳]. برخلاف سایر بدافزارها، شبکه‌های بات چرخه حیات شفاف‌تری دارند که می‌تواند به سه مرحله اصلی شکل‌گیری، فرمان و کنترل، و حمله تقسیم شود. شکل (۱) شمای کلی یک شبکه بات و مفاهیم مرتبط با آن را نمایش می‌دهد.

**بات<sup>۱</sup>:** کلمه بات از کلمه روبات مشتق شده است. بات‌ها طراحی

2- Zombie  
3- Botmaster

1- Bot

## ۳-۱- تله عسل

سایت استفاده می‌شود. روش‌های مبتنی بر تشخیص نفوذ به دو بخش مبتنی بر امضاء<sup>۳</sup> و مبتنی بر ناهنجاری<sup>۴</sup> تقسیم می‌شود که در ادامه توضیح داده خواهد شد.

## ۳-۲-۱- روش‌های مبتنی بر امضاء

در این روش، سیستم تشخیص نفوذ شامل امضاءها و الگوهای شبکه‌های باتی مشهور است تا با مقایسه جریان‌های عبوری از یک ایستگاه با این امضاءها، بات‌بودن یا نبودن آن ایستگاه را گزارش دهد. عمده‌ترین عیب این روش، نیاز به به‌روزرسانی دوره‌ای مخزن امضاءها برای تشخیص شبکه‌های باتی جدید می‌باشد و چون سرعت به‌روزرسانی امضاءها همیشه کندتر از شبکه‌های باتی جدید است، لذا سیستم‌هایی که از این روش برای تشخیص شبکه‌های بات استفاده می‌کنند، معمولاً یک‌قدم از بات‌های جدید عقب هستند. نمونه بارز این نوع سیستم‌ها SNORT<sup>۵</sup> می‌باشد. SNORT یک برنامه‌ی متن‌باز است که به سه روش قابل تنظیم است: سیستم تشخیص نفوذ، Sniffer و Packet Logger.

## ۳-۲-۲- روش‌های مبتنی بر ناهنجاری

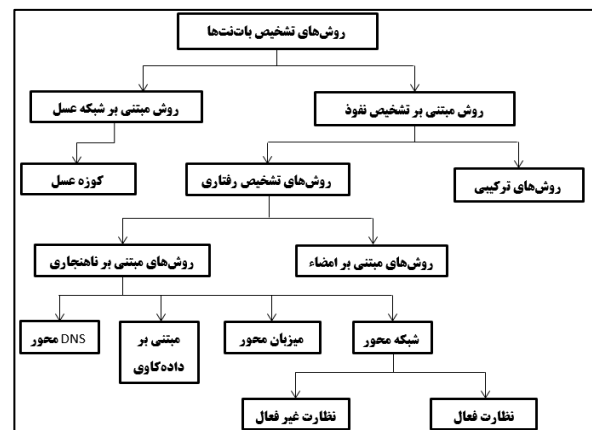
ایده اصلی این روش بر این پایه استوار است که کل ترافیک غیرعادی عبوری از شبکه مانند ترافیک عبوری از درگاه‌های غیرمعمول، تأخیر بالا، بار ترافیکی غیرعادی و ... تحلیل و در جهت شناسایی ترافیک بدخواه از ترافیک سالم استفاده شود [۹]. به عبارت دیگر، رفتارهای معمول و عادی شبکه مطالعه و براساس آن ترافیک غیرعادی شبکه از ترافیک عادی جداسازی می‌شود. این روش خود به چهار بخش تقسیم می‌شود [۱۰]:

(۱) **روش میزبان محور**: در این روش، تک‌تک ایستگاه‌های موجود در شبکه در جهت کشف فعالیت‌های بدخواهانه نظارت می‌شوند. به دلیل این که در این روش باید تمام ایستگاه‌های موجود در شبکه به ابزارهای پیشرفته مانیتورینگ مانند آنتی‌ویروس‌ها مجهز شوند، مقیاس‌پذیری و به تبع آن کارایی این روش پایین می‌آید.

(۲) **روش شبکه محور**: در این روش، برخلاف روش میزبان محور، جریان عبوری از کل شبکه مورد نظارت قرار می‌گیرد. این روش به دو شکل انجام می‌شود؛ نظارت فعال و نظارت غیرفعال. در نظارت فعال، بسته‌های آزمایشی در جهت سنجش کارایی و مقاومت شبکه، بدون تأثیر در کارایی آن به داخل شبکه تزریق شده و مکان‌های

یک تله عسل<sup>۱</sup> یا یک شبکه عسل برای جمع‌آوری اطلاعات بات‌ها به منظور انجام تحلیل‌های مختلف به کار گرفته می‌شود. تله‌های عسل در جامعه امنیتی تحت عنوان دستگاه‌های کامپیوتری آسیب‌پذیر شناخته می‌شوند که در مکان خاصی از شبکه قرار می‌گیرند و حمله‌کنندگان را تحریک به حمله می‌کنند. بعد از حمله، کارکنان امنیتی سیستم با استفاده از مهندسی معکوس اقدام به بررسی بار مفید<sup>۲</sup> بات و نحوه رفتار آن می‌کنند [۷]. تله‌های عسل هیچ‌گونه محصول تولیدی ندارند. بنابراین، هرگونه ارتباط میان آن‌ها و دیگر اعضای شبکه، ترافیک مشکوکی است که باید به‌دقت بررسی شود. این روش، نقاط ضعفی دارد که نمی‌توان از آن به‌عنوان یک روش مستقل برای تشخیص شبکه‌های بات استفاده کرد. از جمله این ضعف‌ها می‌توان به موارد زیر اشاره کرد [۸]:

- مقیاس‌پذیری محدود به علت نیاز به تجهیزات سخت‌افزاری قدرتمند مانند مسیریاب‌ها و دستگاه‌های کامپیوتری پیچیده.
- عدم توانایی پیدا کردن حملات اینترنتی به علت ایزوله‌بودن.
- چالش کشف تله‌های عسل آلوده که به‌عنوان دام قرار داده شده‌اند.
- احتمال آسیب به تله‌های عسل برای تخریب سایر بخش‌های شبکه وجود دارد.



شکل (۲). طبقه‌بندی روش‌های مختلف تشخیص شبکه بات

## ۳-۲-۳- روش‌های مبتنی بر تشخیص نفوذ

یک سیستم تشخیص نفوذ، یک نرم‌افزار کاربردی یا یک ماشین سخت‌افزاری است که برای نظارت بر سرویس‌های سیستم به منظور کشف فعالیت‌های بدخواهانه، نقض امنیت و گزارش آن به مدیر

3- Signature-Based  
4- Anomaly-Based  
5- (www.snort.org)  
6- Host-Base  
7- Network-Base

1- HoneyNet (HoneyPot)  
2- Payload

از بات‌ها در زمان یکسان شروع به فعالیت کرده و حتی می‌توانند سرور فرماندهی و کنترل خود را نیز تغییر دهند؛ این کار باعث تولید ترافیک DNS می‌شود که یک رفتار گروهی بوده و می‌توان از آن برای پیدا کردن ترافیک‌های DNS مرتبط با شبکه بات استفاده کرد. با توجه به این‌که در این مقاله جریان بسته‌های عبوری از شبکه تحلیل شده است، لذا از روش نظارت غیرفعال به کمک داده‌کاوی برای تشخیص شبکه‌های بات استفاده می‌شود.

#### ۴- نمونه کارهای انجام شده

با مطالعه انواع روش‌های شناسایی شبکه‌های بات، این نتیجه حاصل شد که باید برای مقایسه و تعیین نقاط ضعف و قوت روش‌های مختلف، شاخص‌هایی تعیین شده و براساس آن نتیجه‌گیری نمود. برای مقایسه کارهای گذشته در تشخیص شبکه‌های بات از پنج شاخص موجود در جدول (۱)، استفاده شده است.

جدول (۱): شاخص‌های تشخیص شبکه‌های بات

توضیحات	شاخص
نشان‌دهنده قابلیت تشخیص شبکه‌های باتی جدید و حملات ناشناخته می‌باشد.	تشخیص شبکه بات ناشناخته
نشان‌دهنده قابلیت تشخیص ترافیک فرماندهی و کنترل در صورتی که حتی مدیر بات نوع پروتکل و ساختار سرور فرماندهی و کنترل را تغییر دهد، می‌باشد.	مستقل از ساختار و پروتکل
نشان‌دهنده تشخیص ترافیک شبکه بات به صورت غلط و غیر شبکه بات می‌باشد که خطرناک است.	مقدار False Positive
نشان‌دهنده میزان دقت تشخیص شبکه بات در روش مورد نظر می‌باشد.	مقدار نرخ تشخیص
نشان‌دهنده امکان تشخیص شبکه‌های باتی با ارتباطات فرماندهی و کنترل رمزنگاری شده می‌باشد.	تشخیص بات‌های رمزنگاری شده
نشان‌دهنده نوع تشخیص روش پیشنهادی می‌باشد که می‌تواند بلادرنگ بوده یا از نظارت غیرفعال استفاده شود.	تشخیص بلادرنگ (نظارت فعال) / غیربلادرنگ (نظارت غیرفعال)

این می‌تواند نقطه آغاز شناسایی یک شبکه بات در داخل شبکه باشد. با شناسایی این رفتار همگون، می‌توان ترافیک تولیدی شبکه‌های بات را از ترافیک عادی شبکه تفکیک کرد و از مشکلاتی مانند یافتن الگوریتم‌های رمزگشایی کانال‌های ارتباطی رمزنگاری شده در امان بود. رفتار همسان بات‌ها در داخل شبکه‌های بات می‌تواند منجر به تولید ویژگی‌ها<sup>۱</sup> و خصیصه‌هایی<sup>۲</sup> شود که بتوان با تحلیل این ویژگی‌ها، جریان بدخواه را از جریان سالم تشخیص داد. همچنین، می‌توان روشی ارائه کرد که با توجه به گروه‌بندی بسته‌های با تعداد مناسب (و بسیار کم) در جریان‌ها، بتوان پیش‌زمینه طراحی یک سیستم بلادرنگ برای تشخیص شبکه‌های بات را فراهم کرد. تمامی این نتایج به‌علت تولید خصیصه‌ها و ویژگی‌های مناسب و تحلیل این ویژگی‌ها به‌دست آمده است.

آسیب‌پذیر شبکه شناسایی می‌شود. در نظارت غیرفعال، کل جریان عبوری از شبکه به سمت یک درگاه سخت‌افزاری خاص هدایت شده و کلیه بسته‌های این جریان برای تشخیص فعالیت‌های بدخواهانه مورد واریسی قرار می‌گیرند.

۳) روش مبتنی بر داده‌کاوی: یکی از روش‌هایی که بر مبنای نظارت غیرفعال بر ترافیک شبکه کار می‌کند بحث داده‌کاوی است. در این روش، ابتدا الگوهای ارتباطی مشابه دسته‌بندی می‌شوند و سپس بررسی برای میزبان‌هایی که براساس این الگوها فعالیت می‌کنند؛ آغاز می‌شود. این روش مستقل از پروتکل‌ها و ساختارهای شبکه‌های بات کار می‌کند.

۴) روش DNS محور: یکی از مکانیسم‌های برقراری ارتباط با سرور فرماندهی و کنترل و ارسال پیام فعال‌بودن، استفاده از DNS است. در شبکه‌های باتی که از این روش استفاده می‌کنند، تعداد مشخصی

جدول (۲) نمونه‌هایی از کارهای انجام شده در راستای تشخیص شبکه‌های بات را با توجه به شاخص‌های تعیین شده، طبقه‌بندی می‌کند. با توجه به مقدار شاخص‌های تشخیص مربوط به این روش‌ها، روش ارائه شده در این مقاله نرخ تشخیص بالاتر و مثبت کاذب کمتری داشته و قادر به تشخیص بلادرنگ بات‌ها نیز می‌باشد.

#### ۵- روش پیشنهادی تشخیص شبکه‌های بات

در این مقاله برای تشخیص شبکه‌های بات از روش تحلیل جریان<sup>۱</sup> استفاده شده است. با وجود ویژگی‌های خاص هر شبکه بات، بات‌ها در داخل شبکه‌های بات، رفتارهای همسانی از خود نشان می‌دهند و

2- Attributes

3- Features

1- Flow Analysis

### ۵-۱- مفروضات

قبل از تشریح روش ارائه‌شده در این مقاله، تعاریف اولیه‌ای که در این تحقیق مورد استفاده قرار خواهد گرفت، بیان می‌شود:

**جریان (Flow):** مجموعه بسته‌های رد و بدل شده مابین دو آدرس IP منحصربه‌فرد در پنجره زمانی T (یا شامل تعداد محدود و مشخص از بسته‌ها) و با استفاده از یک جفت درگاه و پروتکل لایه انتقال<sup>۱</sup> UDP یا TCP است [۱۱].

**پنجره زمانی:** جریان بسته‌های رد و بدل شده مابین دو آدرس IP، در پنجره‌های زمانی مشخصی مورد واریسی قرار می‌گیرند زیرا ممکن است این ارتباط از چند ثانیه تا چندین روز به طول انجامد. هنگام انتخاب مقدار عددی این پنجره زمانی نیز باید به این نکته توجه شود که اگر مقدار بسیار کوچکی انتخاب شود ممکن است به‌دست‌آوردن ویژگی‌های منحصربه‌فرد ترافیک که تنها در طی یک

دوره طولانی‌تر از زمان آشکار می‌شود، امکان‌پذیر نباشد. در صورتی که پنجره زمانی مقدار بزرگی انتخاب شود، تا حصول این فاصله زمانی هیچ ویژگی استخراج نخواهد شد و در نتیجه، عملیات تشخیص شبکه بات به طول خواهد انجامید. در این تحقیق، مقدار مناسب برای پنجره زمانی با توجه به تجربه و مطالعه کارهای مشابه مانند [۳۶ و ۳۹]، ۳۰۰ ثانیه انتخاب شده است.

### ۵-۲- خصیصه‌ها و ویژگی‌های مبتنی بر جریان

یک ویژگی یا یک خصیصه به مشخصه‌ای از یک جریان بسته در پنجره زمانی T اطلاق می‌شود که می‌تواند یک مقدار عددی<sup>۲</sup> یا غیر عددی<sup>۳</sup> داشته باشد. اگرچه تعداد زیادی از خصیصه‌های مبتنی بر جریان در جهت تشخیص انواع مختلف شبکه‌های بات پیشنهاد شده است، اما هنوز به‌طور قطعی نمی‌توان در مورد ارزش واقعی و تعداد مناسب این خصیصه‌ها نتیجه‌گیری کرد.

جدول (۲): نمونه کارهای انجام‌شده در راستای تشخیص شبکه‌های بات

شاخص تشخیص						نوع روش تشخیص				نویسنده/نام طرح پیشنهادی
تشخیص بلادرنگ	تشخیص بات‌های رمزنگاری‌شده	مقدار رخ تشخیص	مقدار False Positive	مستقل از ساختار و پروتکل	تشخیص شبکه بات ناشناخته	مبتنی بر داده‌کاوی	مبتنی بر DNS	مبتنی بر ناهنجاری	مبتنی بر امضاء	
x	x	ضعیف	بالا	x	x				✓	Snort (2006) [14]
x	x	ضعیف	بالا	x	x				✓	Wang و همکاران [15] (2009)
x	x	متوسط	پایین	x	x				✓	Botzilla (2010) [16]
x	x	٪ ۸۰	پایین	x	✓			✓		BotSwat (2007) [17]
x	x	ضعیف	بالا	✓	✓			✓		BotHunter (2007) [18]
x	✓	متوسط	پایین	x	✓			✓		BotSniffer (2008) [19]
✓	✓	خوب	پایین	✓	✓	✓		✓		BotMiner (2008) [20]
x	x	٪ ۷۰	بالا	x	✓	✓		✓		Strayer و همکاران [21] (2008)
x	x	٪ ۷۵	بالا	x	x			✓		BotProbe (2009) [22]
✓	x	ضعیف	بالا	x	✓		✓			BotGAD (2009) [23]
x	x	ضعیف	بالا	✓	✓		✓			Shahrestani و همکاران [24] (2009)
x	✓	٪ ۹۸	پایین	✓	✓	✓		✓		Masud و همکاران [25] (2008)
✓	✓	٪ ۹۷	پایین	✓	✓	✓		✓		Saad و همکاران [13] (2011)
x	✓	٪ ۷۰	پایین	✓	✓	✓		✓		Bilge و همکاران [26] (2012)
x	✓	٪ ۹۸	متوسط	✓	✓	✓		✓		Zhao و همکاران [12] (2013)
x	x	٪ ۹۰	متوسط	✓	✓	✓		✓		عزمی و همکاران (۱۳۹۴) [27]
x	✓	٪ ۹۸	متوسط	✓	✓	✓		✓		فتحیان و همکاران (۱۳۹۵) [28]

1- Transport Layer  
2- Numeric  
3- Nominal

تعداد زیادی بسته را در یک بازه زمانی ارسال می‌کنند. این ویژگی کمک شایانی برای شناسایی این الگوی ترافیکی می‌کند.

#### ۵-۲-۵- تعداد بسته‌ها با بار مفید به طول صفر

با توجه به توضیح ارائه شده در مورد خصیصه قبلی، بات‌ها برای زنده نگه داشتن ارتباط خود با کانال‌های فرماندهی و کنترل، تعداد زیادی بسته را در یک بازه زمانی ارسال می‌کنند که این بسته‌ها معمولاً دارای بار مفید با طول صفر می‌باشند. برای شناسایی این رفتار، از خصیصه تعداد بسته‌ها با بار مفید به طول صفر استفاده شده است.

#### ۵-۲-۶- تعداد بسته‌ها با بار مفید با طول کوچک/درصد

##### تعداد بسته‌های با بار مفید با طول کوچک

با توجه به این‌که شبکه‌های بات سعی در مخفی نگه داشتن ارتباطات خود دارند، به همین دلیل، ترافیک رد و بدل شده بین اجزای شبکه‌های بات دارای بار مفید با طول بسیار کم می‌باشد. این در حالی است که ارتباطات عادی شبکه از این قاعده پیروی نمی‌کند. لذا برای شناسایی این الگوی ترافیکی از این خصیصه‌ها استفاده شده است.

#### ۵-۲-۷- نرخ تعداد بسته‌های ورودی به تعداد بسته‌های

##### خروجی

به علت وجود الگوهای ترافیکی خاص در شبکه‌های بات، تعداد بسته‌های ورودی و خروجی در یک جریان و در یک بازه زمانی مشخص، از نظم خاصی برخوردار است ولی در مورد ترافیک عادی شبکه نرخ مابین تعداد بسته‌های ورودی به تعداد بسته‌های خروجی دارای رفتار مشخص و قابل پیش‌بینی نیست. لذا از این خصیصه به منظور تشخیص رفتارهای شبکه‌های بات در مورد ارسال و دریافت بسته‌ها استفاده شده است.

#### ۵-۲-۸- تعداد بسته‌های ورودی و تعداد بسته‌های خروجی

در برخی شبکه‌های بات مانند Weasel، ارتباط داخل شبکه بات برای یافتن بات‌های نظیر به نظیر، به شکلی انجام می‌شود که برخی جریان‌ها دارای تعداد بسته‌های ورودی و یا خروجی صفر می‌باشند. در این حالت، عملاً خصیصه نرخ تعداد بسته‌های ورودی به تعداد بسته‌های خروجی بدون استفاده خواهد بود. برای حل این مشکل، از این دو خصیصه به صورت مجزا استفاده شد.

#### ۵-۲-۹- مدت زمان جریان

یکی از خصیصه‌های مهم و پرکاربرد در زمینه شناسایی شبکه‌های بات -به کمک تحلیل رفتاری ترافیک شبکه- ویژگی مدت زمان جریان می‌باشد. شبکه باتی مانند Weasel در ارتباطات خود، بین مدیر بات و بات‌ها، بسیار کند عمل می‌کند و بسته‌های ارسالی با فاصله‌های زمانی کوتاه و پراکنده ارسال می‌شود تا سیستم‌های

در این مقاله سعی شده است تا با مطالعه رفتارهای مختلف شبکه‌های باتی مشهور مانند Storm، Waledac، Nugache و ...، ویژگی‌ها و خصیصه‌های متفاوتی از بسته‌های نمونه، تولید و استخراج شده و به عنوان بردار ورودی روش‌های یادگیری ماشین در جهت شناسایی شبکه‌های بات به کار رود. منطق اصلی روش استفاده شده در این پژوهش، بر این پایه استوار است که شبکه‌های بات الگوهای ترافیکی قابل تشخیصی از خود به جای می‌گذارند که به کمک روش‌های یادگیری ماشین قابل شناسایی بوده و می‌توان ترافیک تولیدی توسط شبکه‌های بات را از ترافیک عادی شبکه جدا کرد. در ادامه، منطق تولید خصیصه‌ها از بسته‌های نمونه توضیح داده شده است.

#### ۵-۲-۱- آدرس‌های آی‌پی فرستنده و گیرنده جریان

آدرس آی‌پی فرستنده و گیرنده جریان به صورت گسترده در دستگاه‌های تشخیص نفوذ استفاده می‌شود. این خصیصه به عنوان تعیین کننده تعداد ارتباطات مجزا استفاده شده و نیز در محاسبات سایر خصیصه‌ها کاربرد دارد. این ویژگی جزء بردار خصیصه‌ها در ورودی الگوریتم‌های یادگیری ماشین به کار برده نمی‌شود. در این پژوهش، از یک لیست سیاه شامل آدرس آی‌پی‌های مربوط به شبکه‌های باتی مشهور و یک لیست سفید شامل آدرس آی‌پی‌های ترافیک عادی شبکه برای برچسب‌گذاری مجموعه داده آزمایشی استفاده شده است.

#### ۵-۲-۲- درگاه‌های مربوط به فرستنده و گیرنده جریان

در حالت کلی، این ویژگی برای گروه‌بندی مناسب بسته‌ها در جریان‌ها به کار گرفته می‌شود. این ویژگی، خصیصه مناسبی برای استفاده به عنوان بردار ورودی الگوریتم یادگیری ماشین نیست زیرا به عنوان مثال، شبکه باتی مانند Nugache به صورت دوره‌ای درگاه خود را عوض می‌کند و شناسایی این شبکه بات به کمک ویژگی درگاه، عملاً امکان‌پذیر نخواهد بود.

#### ۵-۲-۳- پروتکل

همانند ویژگی درگاه، پروتکل نیز برای گروه‌بندی ترافیک‌های هم‌شکل به کار گرفته می‌شود. همچنین مهم‌ترین استفاده از این خصیصه، جداسازی ترافیک (جریان) مرتبط و غیرمرتبط می‌باشد. به عنوان مثال، اکثر شبکه‌های بات از پروتکل‌های TCP و UDP به عنوان پروتکل‌های لایه ارتباطی استفاده می‌کنند و از ویژگی پروتکل در جهت جداسازی این ترافیک‌ها استفاده می‌شود.

#### ۵-۲-۴- تعداد بسته‌های ردوبدل شده در هر جریان

بات‌ها سعی می‌کنند تا ارتباطشان با سرور فرماندهی و کنترل و نیز مدیر بات همیشه در حالت برخط و زنده باقی بماند، لذا معمولاً

در این مقاله روشی برای شناسایی بلادرنگ و برخط شبکه‌های بات ارائه شده است. بدین ترتیب که با توجه به استخراج مناسب خصیصه‌ها از مجموعه داده آزمایشی، به‌جای گروه‌بندی بسته‌ها در پنجره‌های زمانی ۳۰۰ ثانیه‌ای، تعداد مناسب (و البته بسیار کم) از بسته‌ها در هر جریان گروه‌بندی شده و به کمک روش‌های یادگیری ماشین، طبقه‌بندی می‌شود. بر این اساس و با تغییر در تعداد بسته‌ها در هر جریان می‌توان سامانه‌ای طراحی کرد که در فاصله‌های زمانی کوتاه، جریان‌هایی از بسته‌ها با تعداد کم بسته را مورد واریسی قرار داده و بدخواه‌بودن یا سالم‌بودن ترافیک عبوری را به‌صورت آبی تشخیص دهد.

#### ۵-۴- معرفی مجموعه داده‌های نمونه

یکی از نقاط کلیدی این مقاله که در بسیاری از کارهای مشابه توجه زیادی به آن نشده است، استفاده از مجموعه داده‌های دنیای واقعی برای رسیدن به بهترین کارایی، می‌باشد. در این مقاله از مجموعه داده‌های iscx که در دانشگاه unb کانادا جمع‌آوری شده است، استفاده شد<sup>۳</sup> که حدود ۵ میلیون بسته برچسب‌گذاری شده را در بر می‌گیرد. این مجموعه داده‌ها هم ترافیک بدخواه و هم ترافیک سالم شبکه را شامل می‌شود و دارای نمونه بسته‌های واقعی از شبکه‌های باتی معروف مانند Zeus، Weasel، RBot و... می‌باشد. فایل مورد نظر با پسوند pcap است که استاندارد شرکت وایرشارک<sup>۴</sup> است. وایرشارک نرم‌افزار گزارش‌گیری، تحلیل و بررسی اطلاعات در حال تبادل شبکه و یا اینترنت است. این نرم‌افزار با استفاده از توابع آماري، امکان تولید گزارش‌ها و تحلیل نحوه عملکرد و اطلاعات در حال تبادل شبکه را فراهم می‌سازد. در این پروژه ابتدا قبل از بهره‌برداری از بسته‌های موجود در فایل نمونه، از نرم‌افزار وایرشارک برای بررسی این بسته‌ها و درک ویژگی‌های اولیه آن‌ها، استفاده شد.

#### ۶- شرایط و نحوه انجام آزمایش‌ها

در این فصل فرآیند انجام آزمایش بر روی ترافیک نمونه و نحوه واکنشی ویژگی‌ها از بسته‌های نمونه، تشریح شده است.

#### ۶-۱- فرآیند تولید ترافیک از فایل نمونه

در این مرحله، نرم‌افزارهای مختلفی مانند Wireshark، Winpcap و Ethereal برای تحلیل، مقایسه و شبیه‌سازی ترافیک موجود در فایل مذکور آزمایش شد و در نهایت برای عملیات دریافت و فیلترسازی بسته‌ها، از تحلیلگر نحوی مربوط به شرکت مایکروسافت به نام Microsoft Network Monitor در پلتفرم دات‌نت و زبان برنامه‌نویسی C# استفاده شد. Microsoft Network Monitor ابزاری

کشف شبکه بات قادر به شناسایی آن نباشند. این درحالی است که ترافیک سالم شبکه از این نظم تبعیت نمی‌کند و لذا از خصیصه مدت‌زمان جریان می‌توان برای شناسایی الگوهای زمانی شبکه‌های بات استفاده کرد.

#### ۵-۲-۱۰- طول اولین بسته جریان

بسیاری از شبکه‌های بات اطلاعات خاصی مانند اطلاعات پروتکل و یا اطلاعات مربوط به کانال‌های ارتباطی خود را در اولین بسته از جریان قرار می‌دهند و استفاده از این ویژگی می‌تواند کمک به‌سزایی در تشخیص انواع مختلف شبکه‌های بات داشته باشد.

#### ۵-۲-۱۱- ویژگی‌های مبتنی بر اندازه جریان / ویژگی‌های

##### مبتنی بر طول زمان

با توجه به این که ترافیک تولیدی توسط شبکه‌های بات از الگوهای ارتباطی مشابهی برخوردار بوده و یکنواختی بیشتری نسبت به ترافیک کاربران عادی شبکه دارد، ویژگی‌های مبتنی بر اندازه و طول زمان جریان برای طبقه‌بندی ترافیک و نیز شناسایی ترافیک بدخواه از ترافیک سالم مورد استفاده قرار می‌گیرد.

جدول (۳) نشان‌دهنده فهرستی از ویژگی‌های استخراج‌شده برای عملیات داده‌کاوی می‌باشد. برخی از ویژگی‌ها مانند آدرس آی‌پی مبدأ و مقصد و شماره درگاه فرستنده و گیرنده جریان می‌تواند به‌طور مستقیم از طریق بررسی سرآیند<sup>۱</sup> TCP/UDP به دست آید. اما برخی دیگر از ویژگی‌ها مانند متوسط طول بار مفید بسته، نیاز به پردازش و محاسبات بیشتری دارند.

#### ۵-۳- مدل طبقه‌بندی

روش‌های یادگیری ماشین به‌دلیل استفاده از توابع خودکار برای انجام عملیات پیش‌بینی، می‌توانند ابزار مناسبی به‌جای تولید دستی قوانین و الگوها باشند. به کمک الگوریتم‌های یادگیری ماشین، می‌توان ترافیک شبکه را به دو بخش بدخواه و سالم طبقه‌بندی کرد. برای این منظور ابتدا باید داده‌های ورودی اولیه آموزش دیده<sup>۲</sup> و سپس داده‌های آزمایشی به کمک الگوریتم یادگیر، آزمایش شود. برای نیل به این هدف، ابتدا بردار ویژگی شامل خصیصه‌های تولیدشده در بخش قبل را به‌عنوان ورودی، به الگوریتم یادگیر داده و نتایج به‌دست می‌آید. بردار ورودی در الگوریتم‌های مختلف آزمایش شده و نتایج ارائه می‌شود. در این مقاله از الگوریتم‌های معروف یادگیری ماشین شامل: Bayesian Network (BNNet)، Decision Tree (j48)، Naive Bayesian (NB) و Random Forest (RF) استفاده شده است. این الگوریتم‌ها، الگوریتم‌های بهینه و پرکاربرد در زمینه یادگیری ماشین و داده‌کاوی می‌باشند.

3- <https://www.cs.unb.ca/downloads/iscx/>

4- Wireshark

1- Header

2- Train

امنیت فراهم سازد. این تحلیلگر نحوی دارای توابع از پیش آماده است تا بسته‌های موجود در فایل‌های با پسوند .cap و .pcap را تحلیل کند. برای انجام این هدف برنامه‌ای در پلتفرم دات نت و زبان برنامه‌نویسی C# نوشته شد تا بسته‌های موجود در مجموعه داده‌های نمونه را با توجه به ویژگی‌های هر بسته مانند آدرس آی‌پی مبدأ و مقصد، شماره درگاه، اندازه بار مفید و... گرفته و برای انجام عملیات بعدی در داخل پایگاه داده ذخیره کند.

جهت دریافت، نمایش و تحلیل داده‌های شبکه و بازگشایی پروتکل‌های آن می‌باشد. این ابزار دارای فیلترینگ کامل و هوشمند بوده و می‌تواند ابزار مفیدی برای مدیریت شبکه باشد. این نرم‌افزار توانایی نمایش فریم به فریم کلیه بسته‌ها را در لایه دو شبکه دارد. تحلیلگر نحوی این نرم‌افزار نیز به صورت متن‌باز برای استفاده در محیط VisualStudio در دسترس عموم قرار گرفته است تا ابزاری قدرتمند برای توسعه‌دهندگان نرم‌افزار در جهت افزایش

جدول (۳): ویژگی‌های استخراجی از جریان بسته‌ها

ویژگی	توضیحات انگلیسی	توضیحات فارسی
SrcIP	Flow source IP address	آدرس آی‌پی مربوط به ارسال‌کننده جریان
DestIP	Flow destination IP address	آدرس آی‌پی مربوط به دریافت‌کننده جریان
SrcPort	Flow source port address	آدرس درگاه مربوط به ارسال‌کننده جریان
DestPort	Flow destination port address	آدرس درگاه مربوط به دریافت‌کننده جریان
Protocol	Transport layer protocol	پروتکل لایه انتقال (TCP یا UDP)
APL	Average payload packet length for time interval	متوسط اندازه بار مفید بسته در پنجره زمانی
PV	Variance of payload packet length for time interval	واریانس اندازه بار مفید بسته در پنجره زمانی
PX	Number of packets exchanged for time interval	تعداد بسته‌های رد و بدل شده در بازه زمانی مشخص
NNP	Number of null packets exchanged	تعداد بسته‌های رد و بدل شده با بار مفید خالی (بسته‌های با طول بار مفید صفر)
NSP	Number of small packets exchanged	تعداد بسته‌های رد و بدل شده با بار مفید کوچک (بسته‌های با طول بار مفید، ۶۳ الی ۴۰۰ بایت)
PSP	Percentage of small packets exchanged	درصد بسته‌های رد و بدل شده با بار مفید کوچک
Duration	Flow duration	فاصله زمانی شروع تا پایان جریان (در این تحقیق این بازه مابین ۰ تا ۳۰۰ ثانیه متغیر خواهد بود)
PPS	Number of packets exchanged per second in time interval T	نرخ رد و بدل شدن بسته‌ها در هر ثانیه در پنجره زمانی
FPS	The size of the first packet in the flow	اندازه اولین بسته رد و بدل شده در جریان
IOPR	Ratio between the number of incoming packets over the number of outgoing packets	نرخ مابین تعداد بسته‌های ورودی بر تعداد بسته‌های خروجی در هر جریان
InPktCount	number of incoming packets	تعداد بسته‌های ورودی در هر جریان
OutPktCount	number of outgoing packets	تعداد بسته‌های خروجی در هر جریان
TBT	Total number of bytes	کل بایت‌های رد و بدل شده در جریان
DPL	Total number of packets with the same length over the total number of packets	نسبت تعداد کل بسته‌ها با طول یکسان به تعداد کل بسته‌ها
BS	Average bits-per-second	متوسط تعداد بیت بر ثانیه

سپس می‌توان به کمک این جریان‌ها، ویژگی‌های موردنظر استخراج شوند. در بخش‌های بعدی این مراحل نیز توضیح داده خواهد شد. در این مرحله بسته‌های خام پس از واکنشی از فایل‌های شکسته شده، در جدولی در پایگاه داده SQL Server ذخیره شدند.

الگوریتم (۱)، شبه‌کد این برنامه را نشان می‌دهد. برای این‌که ویژگی‌های معرفی شده در فصل ۶، از بسته‌ها استخراج شوند، ابتدا این بسته‌ها در یک پایگاه داده ذخیره شده و به کمک امکانات پرس‌وجوها، در جریانی از بسته‌ها گروه‌بندی می‌شوند.



شد، نوبت به واکنشی خصیصه‌های انتخابی از لیست جریان‌ها می‌رسد. این خصیصه‌ها براساس ویژگی‌های ارائه‌شده در بخش ۶-۲ تولید می‌شوند. حال بعد از استخراج ویژگی‌های جریان‌ها، حدود ۲۵۰۰۰ داده ورودی برای انجام عملیات داده‌کاوی تهیه شد و در مرحله بعدی به کمک این داده‌ها عملیات یادگیری انجام خواهد پذیرفت.

#### ۴-۶- فرآیند ارزیابی خصیصه‌ها

در این مرحله از یک ابزار قدرتمند در زمینه داده‌کاوی به نام وکا<sup>۲</sup> استفاده شده است. ابزار وکا نرم‌افزاری است متن‌باز که توسط دانشگاه Waikato در کشور نیوزلند ارائه شده است [۲۹]. از ویژگی‌های بارز این نرم‌افزار می‌توان به پوشش تقریباً کامل الگوریتم‌های داده‌کاوی در آن اشاره کرد. این نرم‌افزار همان‌طور که گفته شد به صورت متن‌باز و با زبان جاوا از سال ۱۹۹۹ به جامعه علمی در دنیا عرضه شده است که می‌توان از این ویژگی جهت توسعه و یا حتی سفارشی‌سازی آن برای کاربردهای خاص استفاده نمود. این ابزار برخلاف دیگر نرم‌افزارهایی که در حوزه داده‌کاوی فعالیت دارند -مانند متلب<sup>۳</sup>- رایگان می‌باشد. وکا دارای محیطی کاملاً گرافیکی و کاربرپسند بوده و از لحاظ کاربری، نرم‌افزاری بسیار ساده و روان می‌باشد [۳۰]. به‌طور خلاصه، وکا مجموعه تقریباً کاملی از جدیدترین الگوریتم‌های یادگیری ماشین و پیش‌پردازش داده را برای داده‌کاوی فراهم کرده است. امکانات این ابزار در تمام گام‌های داده‌کاوی از قبیل آماده‌سازی داده‌های ورودی، اعمال روش‌های یادگیری و ارزیابی نتایج، بصری‌سازی داده‌ها و بصری‌سازی نتایج خروجی بدون نیاز به کدنویسی در دسترس می‌باشد.

در این مرحله خصیصه‌های به‌دست‌آمده در مرحله قبل در یک فایل با پسوند CSV ذخیره شده و به‌عنوان ورودی ابزار وکا مورد استفاده قرار می‌گیرد. مدل طبقه‌بندی در وکا به کمک اعتبارسنجی متقابل<sup>۴</sup> و به روش k-fold که در آن  $k=10$  می‌باشد انجام می‌گیرد. در این حالت، مجموعه ورودی به ۱۰ زیرمجموعه تقسیم و برای هر زیرمجموعه، ۹ قسمت از داده‌ها به‌عنوان یادگیر و قسمت باقی‌مانده به‌عنوان داده آزمایش استفاده می‌شود. این مراحل ۱۰ بار تکرار شده و بهترین کارایی حاصل می‌شود و رفتار شبکه‌های باتی ناشناخته به کمک این روش به دست می‌آید. البته به‌علت این که خصیصه‌هایی مانند آدرس آی‌پی و شماره درگاه مربوط به جریان‌های ورودی و خروجی، نمی‌تواند خصیصه‌های مناسبی برای داده‌کاوی باشد و فقط

الگوریتم (۱): شبه‌کد فرآید تولید ترافیک از فایل نمونه

```

1: procedure Parser(filePath)
2:   ArrayList <Packet> p;
3:   ArrayList <Packet> Parser;
4:   ArrayList <Packet> packetlist;
5:   Pcap pcap1 ← Pcap.openOffline(path, errbuf);
6:   if pcap1 := NULL then errbuf.toString();
7:   end if
8:   packetlist ← new ArrayList < Packet >;
9:   for Packet p : packets do
10:    if packet has IP then
11:      packet.getHeader(ip);
12:      if packet has TCP then
13:        packet.getHeader(tcp);
14:        p ← Packet(tcp.srcport, tcp.dstport, ip.src,
ip.dst,
15:                    pkt.hdr.length, pkt.length,
16:                    pkt.timestamp);
17:        packetlist.add(p);
18:      else
19:        packet.getHeader(udp);
20:        p ← Packet(udp.srcport, udp.dstport,
ip.src, ip.dst,
21:                    pkt.hdr.length, pkt.length,
22:                    pkt.timestamp);
23:        packetlist.add(p);
24:      end if
25:    end if
26:  end for
27:  pcap1.loop;
28:  return packetlist;
29: end procedure

```

#### ۶-۲- فرآیند گروه‌بندی بسته‌ها در جریان‌ها<sup>۱</sup>

همان‌طور که در تعریف جریان آمده است، جریان عبارت از مجموعه‌ای از بسته‌های رد و بدل شده مابین دو آدرس آی‌پی منحصر به فرد در پنجره زمانی T (یا شامل تعداد محدود و مشخص از بسته‌ها) و با استفاده از یک جفت درگاه و پروتکل لایه انتقال UDP یا TCP است. نحوه گروه‌بندی بسته‌ها بدون در نظر گرفتن پنجره زمانی، ساده اما غیر کاربردی می‌باشد زیرا ممکن است یک جریان مابین ۱ ثانیه تا چندین روز به طول انجامد. پس قبل از هر چیز باید ترافیک بسته‌ها در پنجره زمانی 300، گروه‌بندی شوند. برای این کار از یک پرس‌وجوی SQL ای استفاده شده است. در این پرس‌وجو، بسته‌هایی که دارای جفت آدرس آی‌پی و درگاه مبدأ / مقصد یکسان هستند در یک گروه به صورتی گروه‌بندی می‌شوند که فاصله زمانی شروع تا پایان کمتر از ۳۰۰ ثانیه باشد. به عبارت دیگر، پنجره زمانی ۳۰۰ ثانیه انتخاب شد.

#### ۶-۳- فرآیند استخراج خصیصه‌ها

پس از این که جریان بسته‌ها در پنجره زمانی ۳۰۰ ثانیه گروه‌بندی

2- Weka  
3- Matlab  
4- Cross Validation

## ۷- نتایج ارزیابی و مقایسه نتایج

بعد از بارگذاری فایل csv. به‌عنوان ورودی وکا، نوبت به طبقه‌بندی و اعمال الگوریتم‌های یادگیر می‌رسد که از زیرمنوی Classify قابل دسترس می‌باشند. جدول (۴) نشان‌دهنده درصد معیارهای ارزیابی مورد نظر برای ترافیک بدخواه و ترافیک سالم که از ۴ الگوریتم یادگیری انتخابی به‌دست آمده است، می‌باشد. این نتایج از طبقه‌بندی جریان‌های دارای پنجره زمانی ۳۰۰ ثانیه و به‌صورت 10-Fold محاسبه شده است. این جدول نشان می‌دهد که الگوریتم RandomForest با دقت بیشتری نسبت به سه الگوریتم دیگر، سالم‌بودن یا مخرب‌بودن بسته‌ها را تشخیص می‌دهد.

قبل از ادامه این بخش، به بررسی مناسب‌ترین پنجره زمانی T برای گروه‌بندی بسته‌ها در جریان‌ها می‌پردازیم. با گروه‌بندی بسته‌ها در پنجره‌های زمانی مختلف و مقایسه TP و FP مربوط به ترافیک بدخواه، این نتیجه حاصل شد که پنجره زمانی حدود ۳۰۰ ثانیه بهترین کارایی را حاصل می‌کند. اشکال (۳-۴) نشان‌دهنده تأثیر اندازه پنجره زمانی بر نرخ مثبت صحیح و مثبت کاذب الگوریتم RandomForest می‌باشد. شکل (۵)، مقایسه الگوریتم‌های مختلف برای طبقه‌بندی جریان‌ها را نشان می‌دهد. این شکل نشان می‌دهد که الگوریتم Random Forest دقت بیشتر داشته و معیارهای ارزیابی دارای کمترین تفاوت نسبت به همدیگر می‌باشند. همچنین شکل (۶)، نشان‌دهنده مقایسه زمان‌های تولید مدل در هر الگوریتم می‌باشد.

در این مقاله روشی برای شناسایی بلادرنگ و برخط شبکه‌های بات ارائه شده است. بدین ترتیب که تعداد مناسب (و البته بسیار کم) از بسته‌ها در هر جریان گروه‌بندی شده و به کمک روش‌های یادگیری ماشین، طبقه‌بندی می‌شود. می‌توان نتیجه گرفت که به کمک این روش، بتوان سیستمی طراحی کرد که در فاصله‌های زمانی کوتاه، جریان‌هایی از بسته‌ها با تعداد کم بسته را مورد واریسی قرار داده و بدخواه‌بودن یا سالم‌بودن ترافیک عبوری را به‌صورت آنی تشخیص داد. برای این منظور، الگوریتم گروه‌بندی بسته‌ها تغییر کرده و به‌جای گروه‌بندی بسته‌ها در پنجره‌های زمانی ۳۰۰ ثانیه‌ای، در هر جریان تعداد محدود بسته قرار می‌گیرد. این تعداد به ترتیب ۱۰، ۵۰، ۱۰۰ و ۱۰۰۰ بسته در هر جریان را شامل می‌شود. سپس نتایج گروه‌بندی بسته‌ها به‌عنوان ورودی به الگوریتم تولید خصیصه‌ها ارسال و نتایج به‌صورت فایل csv. به نرم‌افزار وکا داده

برای انجام عملیات محاسباتی مورد استفاده قرار گرفتند، از فایل ورودی حذف و فقط تعداد ۱۶ خصیصه به‌عنوان بردار ورودی نرم‌افزار وکا انتخاب شد. نکته بسیار مهم دیگر مشکلی است که در این مرحله رخ داد و پس از بارگذاری فایل ورودی در نرم‌افزار وکا و قبل از شروع عملیات طبقه‌بندی، نرم‌افزار وکا با خطای کمبود حافظه مواجه گردید. برای حل این مشکل، فایل RunWeka.ini موجود در مسیر نصب وکا را در محیط نوت‌پد باز کرده و مقدار maxheap افزایش یافته و به ۱۲۸۰۰ تغییر می‌یابد و به این ترتیب مشکل حل خواهد شد.

قبل از انجام عملیات داده‌کاوی در وکا، معیارهای ارزیابی که توسط الگوریتم‌های یادگیری ماشین ایجاد و مقایسه خواهد شد، معرفی می‌شود. ابزار وکا، معیارهایی که در ادامه معرفی می‌شوند را به‌صورت خودکار بعد از تولید مدل، به‌عنوان خروجی نمایش می‌دهد.

$$\text{Precision (PRC)} = \frac{TP}{TP+FP} \quad (1)$$

$$\text{Recall (RCL)} = \frac{TP}{TP+FN} \quad (2)$$

$$F - \text{measure (FM)} = 2 * \frac{RCL * PRC}{RCL + PRC} \quad (3)$$

که در آن، TP، FP، FN به ترتیب مثبت واقعی<sup>۱</sup>، مثبت کاذب<sup>۲</sup>، منفی کاذب<sup>۳</sup> می‌باشند. دو پارامتر Precision و Recall از اهمیت یکسانی برخوردار نیستند. Precision نشان‌دهنده این است که چند درصد از ترافیک‌های باتی که الگوریتم به‌عنوان ترافیک بات شناسایی کرده است، واقعاً بات هستند. پارامتر Recall نیز مشخص می‌کند که الگوریتم توانسته است چند درصد ترافیک‌های بات را شناسایی کند. پارامتر Recall از پارامتر Precision مهم‌تر است زیرا: اگر Recall کم باشد، یعنی الگوریتم توانسته است درصد کمی از ترافیک‌های بات را شناسایی کند. به‌عبارت‌دیگر، تعداد زیادی از ترافیک‌های بات به‌عنوان ترافیک نرمال شناسایی شده‌اند. این برای امنیت، سیستم بسیار خطرناک است، زیرا الگوریتم نتوانسته است چنین ترافیک‌های باتی را تشخیص دهد. اگر Precision کم باشد، یعنی الگوریتم تعداد زیادی ترافیک نرمال را به‌عنوان ترافیک بات شناسایی کرده است. این برای امنیت سیستم خطر چندانی ایجاد نمی‌کند، فقط ممکن است موجب ناراحتی کاربر شود، زیرا ترافیک‌های نرمال به‌عنوان ترافیک بات شناسایی شده‌اند و ممکن است یک برنامه عادی، غیرفعال شود.

- 
- 1- True Positive
  - 2- False Positive
  - 3- False Negative


• با مطالعه ویژگی‌های شبکه‌های باتی مشهور مانند Weasel و ...، خصیصه‌هایی برای شناسایی الگوهای مشابه شبکه‌های بات تولید و استخراج شد که منجر به دستیابی به بالاترین دقت و کمترین مثبت کاذب نسبت به نتایج پژوهش‌های مذکور شد. به‌عنوان مثال، Saad و همکاران، به کمک روش SVM به نرخ تشخیص حدود ۹۷٪ و Bilge و همکاران به کمک روش Random Forest به نرخ تشخیص ۷۰٪ دست پیدا کرده‌اند. این در حالی است که پس از تحلیل جریان بسته‌ها و استخراج و تولید خصیصه‌های وابسته به جریان، این خصیصه‌ها در جهت شناسایی الگوهای رفتاری مشابه، داده‌کاوی شده و در نهایت الگوی بسته‌های سالم از بسته‌های مخرب متمایز شد و نرخ تشخیص در حدود ۹۹٪ به دست آمد. این افزایش دقت به علت تولید خصیصه‌های مناسب و در نتیجه جداسازی رفتار شبکه‌های بات از جریان عادی شبکه می‌باشد.

می‌شود. با توجه به این‌که الگوریتم Random Forest از نتیجه قابل قبول‌تر و با انحراف کمتر برخوردار است، نتایج این گروه‌بندی توسط این الگوریتم طبقه‌بندی شده و نتیجه در جدول (۵) نمایش داده شده است. اطلاعات به‌دست‌آمده نشان می‌دهد که با گروه‌بندی تعداد کم بسته‌ها در یک جریان (بین ۵۰ تا ۱۰۰ بسته) و با در نظر گرفتن این‌که شبکه‌های باتی مانند weasel در ارتباطات خود بسیار کند عمل کرده و تعداد بسته‌های کمی بین مدیر بات و بات‌ها رد و بدل می‌شود، بتوان سیستمی طراحی کرد که ترافیک عبوری را به‌صورت بلادرنگ و با نرخ تشخیص بالا در دو گروه بدخواه و سالم طبقه‌بندی کند.


پروژه‌های انجام‌شده توسط [۲۵] Masud، [۱۳] Saad، [۲۶] Bilge و [۱۲] Zhao مشابه با مقاله حاضر می‌باشند. با مطالعه نتایج به‌دست‌آمده از این مقالات و مقایسه با پژوهش حاضر، نتایج زیر حاصل می‌شود:

جدول (۴): درصد معیارهای ارزیابی برای تشخیص شبکه بات براساس خصیصه‌های استخراجی (T=300s)

Random Forest			Naive Bayesian			Decision Tree			Bayesian Network			الگوریتم یادگیری
FM	RCL	PRC	FM	RCL	PRC	FM	RCL	PRC	FM	RCL	PRC	پارامتر ارزیابی
۹۸	۹۹/۳	۹۷/۷	۲۲/۷	۱۳/۵	۷۳/۲	۹۷/۸	۹۷/۸	۹۷/۷	۹۲/۸	۸۹/۵	۹۶/۴	ترافیک بدخواه
۹۶/۳	۹۵/۵	۹۶/۸	۵۱/۷	۹۰/۸	۳۶/۱	۹۵/۸	۹۵/۸	۹۵/۹	۸۷/۹	۹۳/۸	۸۲/۸	ترافیک سالم



شکل (۳): تأثیر اندازه پنجره زمانی بر نرخ مثبت صحیح ترافیک بدخواه

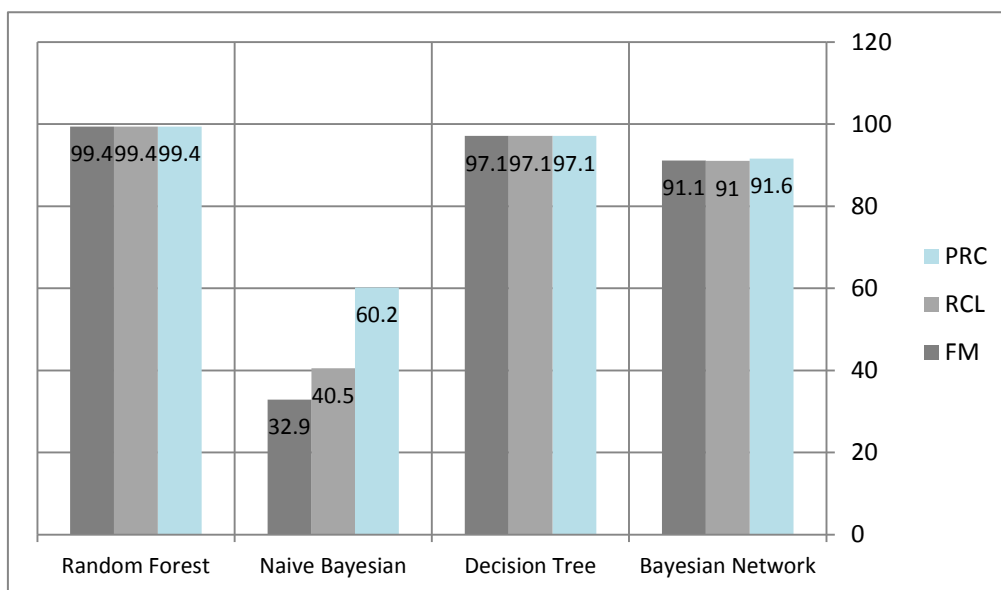


شکل (۴): تأثیر اندازه پنجره زمانی بر نرخ مثبت کاذب ترافیک بدخواه

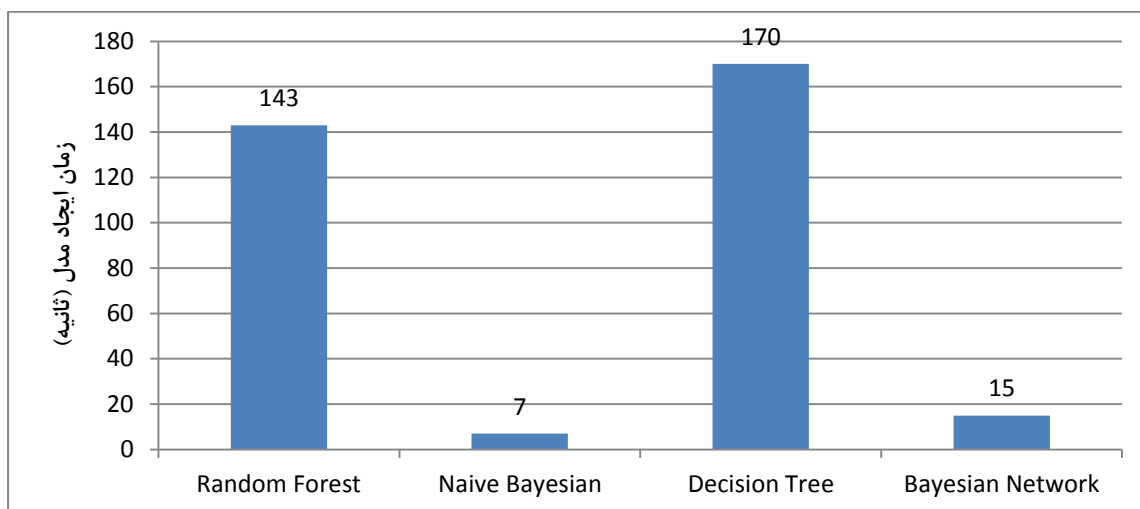
با استخراج خصیصه‌های مناسب، زمان تولید مدل نسبت به کارهای مشابه در وضعیت مناسب‌تری قرار دارد.

روش پیشنهادی برای کشف بلادرنگ شبکه‌های بات در این مقاله، در هیچ‌یک از کارهای مشابه مدنظر قرار داده نشده است و از این لحاظ می‌توان این پژوهش را پیش‌زمینه‌ای برای تولید یک سیستم برخط برای شناسایی بلادرنگ شبکه‌های بات دانست.

الگوریتم پیشنهادی در مقاله برای تولید ترافیک از فایل نمونه با توجه به استفاده از یک تحلیل‌گر نحوی قابل اطمینان و قدرتمند مانند Microsoft Network Monitor Parser از سرعت بسیاری نسبت به کارهای مشابه مانند روش‌های تحت وب و فیتون دارد. با توجه به این که مجموعه داده‌های مورد استفاده در مقالات مذکور تا حدودی از لحاظ ساختاری شبیه به مجموعه بسته‌های استفاده‌شده در این مقاله می‌باشد،



شکل (۵): مقایسه الگوریتم‌های مختلف برای طبقه‌بندی جریان‌ها در پنجره زمانی ۳۰۰ ثانیه



شکل (۶): مقایسه زمان‌های تولید مدل در هر الگوریتم

گروه‌بندی مناسب بسته‌های نمونه در جریان‌ها با توجه به پنجره زمانی متناسب.

مطالعه ویژگی‌های شبکه‌های باتی مشهور مانند Weasel و ...، در جهت تولید خصیصه‌هایی برای شناسایی الگوهای مشابه شبکه‌های بات.

دست‌یابی به بالاترین دقت و کمترین مثبت کاذب نسبت به نتایج پژوهش‌های مذکور به دلیل استخراج ویژگی‌های مناسب از جریان‌های ترافیکی برچسب‌دار.

انتخاب الگوریتم‌های یادگیری ماشین با کارایی مناسب در ابزار وکا.

ارائه روشی برای کشف بلادرنگ شبکه‌های بات در جهت تولید یک سیستم برخط برای شناسایی بلادرنگ شبکه‌های بات.

در این پروژه با مطالعه مقالات مختلف در زمینه تشخیص شبکه‌های بات، یک راه‌حل عملی برای شناسایی میزبان‌های آلوده ارائه شده و از کلی‌گویی پرهیز شد. در اکثر کارهای مشابه، فرآیند تولید ترافیک به صورت نظری توضیح داده شده است و ترافیک تولیدی نیز کمتر شامل شبکه‌های بات مشهور بوده و تعداد بسته‌های موجود برای عملیات داده‌کاوی نیز کافی نیست؛ درحالی‌که در این پروژه برای بالابردن کارایی، از مجموعه داده‌های کامل استفاده شده است. همچنین، با آزمایش تعداد مختلف بسته در هر جریان سعی شد تا بهترین کارایی حاصل شده و پیش‌زمینه برای کارهای آینده در جهت تولید یک سیستم شناسایی برخط شبکه‌های بات فراهم شود.

جدول (۵): مقایسه معیارهای ارزیابی در گروه‌بندی تعداد مختلف بسته

در هر جریان				
۱۰۰۰ بسته در هر جریان	۱۰۰ بسته در هر جریان	۵۰ بسته در هر جریان	۱۰ بسته در هر جریان	
۹۷/۸	۹۷/۸	۹۵/۶	۹۱/۵	Precision
۹۸	۹۷/۸	۹۵/۶	۹۱/۱	Recall
۹۷/۹	۹۷/۸	۹۵/۶	۹۱/۱	F-measure

## ۸- نتیجه‌گیری

در این مقاله سعی شده است تا یک روندکاری مناسب در جهت تشخیص کامپیوترهای آلوده به شبکه بات اتخاذ شود تا به کمک روش‌های یادگیری ماشین و نیز با استفاده از داده‌های برچسب‌گذاری‌شده، خصیصه‌های تولیدی از جریان بسته‌ها به کمک ابزار متن‌باز وکا طبقه‌بندی شود. منطق اصلی روش استفاده‌شده در این پژوهش بر این پایه استوار است که شبکه‌های بات الگوهای ترافیکی قابل تشخیصی از خود به‌جای می‌گذارند که به کمک روش‌های یادگیری ماشین قابل شناسایی بوده و می‌توان ترافیک تولیدی توسط شبکه‌های بات را از ترافیک عادی شبکه جدا کرد. در این مسیر نکات زیر را می‌توان به‌عنوان عامل اصلی موفقیت این مقاله قلمداد کرد:

استفاده از "مجموعه داده‌های نمونه جهان واقعی"<sup>۱۱</sup> از بسته‌های شبکه شامل شبکه‌های باتی معروف و نیز بسته‌های سالم برچسب‌گذاری‌شده.

## ۹- پژوهش‌های آینده

در پژوهش‌های مختلف، روش‌های تشخیص شبکه بات، ساختار خود را با جزئیات تشریح می‌کنند. بنابراین، این خطر همواره وجود دارد که فن‌های گریز مختلفی برای آن‌ها، از طرف مهاجمین ارائه شود. در سوی دیگر، شبکه‌های باتی نسل آینده به احتمال بسیار زیاد از فن‌های مختلفی برای گریز از تشخیص بهره می‌گیرند. از این‌رو، مقاوم‌سازی هرچه بیشتر روش‌های پیشنهادی در برابر فن‌های مختلف گریز یکی از مهم‌ترین چالش‌های موجود برای تشخیص شبکه‌های بات خواهد بود. هرچند شبکه‌های بات و بات‌ها روزبه‌روز در حال پیشرفت بوده و پیچیده‌تر می‌شوند، اما بررسی‌های انجام‌شده در رابطه با تشخیص شبکه‌های بات هنوز در مسیر ابتدایی قرار دارد و می‌توان با ترکیب چند روش به نتایج بهتری دست یافت. یکی دیگر از مباحثی که جای مطالعه و تحقیق بسیاری دارد، مطالعه بر روی روش‌های تشخیص برخط شبکه‌های بات می‌باشد. اکثر روش‌های ارائه‌شده برای شناسایی شبکه‌های بات، به‌صورت غیربرخط و بر مبنای پروتکل کانال فرماندهی و کنترل بنا نهاده شده و بسیار کند می‌باشند. این روش‌ها اکثراً بر اساس اطلاعات جمع‌آوری‌شده در گذشته عمل می‌کنند و همیشه یک‌قدم عقب‌تر از مهاجم قرار دارند. لذا ارائه یک روش برخط برای تشخیص شبکه‌های بات می‌تواند گام بسیار بزرگی در جهت مقابله با حملات سایبری باشد.

در نهایت، با افزایش روزافزون استفاده از تبلت‌ها و گوشی‌های هوشمند، شبکه‌های باتی مختلف این حوزه نیز روزبه‌روز در حال گسترش می‌باشد و به‌خصوص شبکه‌های اجتماعی مانند تلگرام و فیس‌بوک، بیش از گذشته در معرض حملات و سوءاستفاده توسط شبکه‌های بات قرار دارند. لذا لزوم مطالعه و تحقیق بر روی انواع روش‌های کشف و شناسایی شبکه‌های بات در حوزه گوشی‌های هوشمند و سیستم‌عامل‌های اندروید و IOS بیش از پیش حس می‌شود.

## ۱۰- مراجع

- [5] M. Feily, A. Shahrestani, and S. Ramadass, "A Survey of Botnet and Botnet Detection, IEEE 3rd Int. Conf. On Emerging Security Information, Systems and Technologies, 2009.
- [6] J. Park, "Acquiring Digital Evidence from Botnet Attacks: Procedures and Methods," M. Sc Thesis, 2011.
- [7] F. C. Freiling, T. Holz, and G. Wicherski, "Botnet tracking: exploring a root-cause methodology to prevent distributed denial-of-service attacks," Springer Berlin Heidelberg, 2005.
- [8] C. C. Zou and R. Cunningham, "Honeypot-aware advanced botnet construction and maintenance," IEEE Int. Conf. on Dependable Systems and Networks, 2006.
- [9] J. R. Binkley and S. Singh, "An Algorithm for Anomalybased botnet detection. Proc. USENIX Steps to Reducing Unwanted Traffic on the Internet Workshop, 2006.
- [10] S. S. C. Silva, R. M. P. Silva, R. C. G. Pinto, and M. Ronaldo Salles, "Botnets: A survey, Computer Networks," The International Journal of Computer and Telecommunications Networking, 2013.
- [11] A. Sperotto, G. Schaffrath, R. Sadre, C. Morariu, A. Pras, and B. Stiller, "An Overview of IP Flow-based Intrusion Detection," IEEE Communications Surveys & Tutorial, 2010.
- [12] D. Zhao, I. Traore, A. Ghorbani, B. Sayed, S. Saad, and W. Lu, "Peer to Peer Botnet Detection Based on Flow Intervals, Part of the IFIP Advances in Information and Communication Technology Book Series, 2012.
- [13] S. Saad, I. Traore, A. Ghorbani, B. Sayed, D. Zhao, W. Lu, J. Felix, and P. Hakimian, "Detecting p2p Botnets Through Network Behavior Analysis and Machine Learning," In Privacy, Security and Trust (PST), 2011 Ninth Annual International Conference on, July 2011.
- [14] Snort IDS [Online] Retrieved on January 2013 from <http://www.snort.org>
- [15] W. Wei, F. Binxing, et al., "A Novel Approach to Detect IRC-Based Botnet," International Conference on Networks Security, Wireless Communications and Trusted Computing (NSWCTC), 2009.
- [16] R. Konrad, S. Guido, et al., "Botzilla: Detecting the "Phoning Home" Of Malicious Software," Proceedings of the Symposium on Applied Computing, Sierre, Switzerland, ACM, 2010.
- [17] E. Stinson and J. C. Mitchell, "Characterizing bots remote control behavior," In: Detection of Intrusions and Malware, and Vulnerability Assessment, Springer, 2007.
- [18] G. Gu, P. Porras, V. Yegneswaran, et al., "Bothunter: Detecting Malware Infection Through IDS-driven Dialog Correlation," Proc. 16th USENIX Security Symp., pp. 167-182, 2007.
- [19] G. Gu, J. Zhang, and W. Lee, "A BotSniffer: detecting Botnet Command and Control Channels in Network Traffic," Proc. 15th Annual Network and Distributed System Security Symp., pp. 2-19, 2008a.
- [20] G. Gu, R. Perdisci, J. Zhang, et al., "BotMiner: Clustering Analysis of Network Traffic for Protocol and Structure-Independent Botnet Detection," USENIX Security Symp., pp. 139-154, 2008b.
- [21] W. T. Strayer, R. Walsh, C. Livadas, et al., "Detecting botnets with tight command and control," Proc. 31st IEEE Conf. on Local Computer Networks, pp. 195-202, 2006.

- [1] Available <https://en.wikipedia.org/wiki/Botnet>
- [2] J. Liu, et al., "Botnet: Classification, Attacks, Detection, Tracing and Preventive Measures," Journal on Wireless Communications and Networking, 2009.
- [3] L. Heng-Feng and H. Ru-Xin, "A Survey of botnet Detection," Computers & Security, 2010.
- [4] M. Feily, A. Shahrestani, and S. Ramadass, "A Survey of Botnet and Botnet Detection," 09 Proceedings of the 2009 Third International Conference on Emerging Security Information, Systems and Technologies, 2009.

- [22] A. G. Tokhtabayev and V. A. Skormin, "Non-stationary Markov models and anomaly propagation analysis in IDS," IEEE 3rd Int. Symp. on Information Assurance and Security, pp. 203-208, 2007. [doi:10.1109/IAS.2007.72]
- [23] H. Choi, H. Lee, and H. Kim, "BotGAD: detecting botnets by Capturing Group Activities in Network Traffic," Proc. 4th Int. ICST Conf. on Communication System Software and Middleware, pp. 1-8, 2009. [doi:10.1145/1621890.1621893]
- [24] A. Shahrestani, M. Feily, R. Ahmad, et al., "Architecture for applying data mining and visualization on network flow for botnet traffic detection," IEEE Int. Conf. on Computer Technology and Development, pp. 33-37, 2009.
- [25] M. Masud, T. Al-khateeb, L. Khan, B. Thuraisingham, and K. Hamlen, "Flow-based Identification of Botnet Traffic by Mining Multiple log Files," In Distributed Framework and Applications, DFmA 2008, First International Conference on, pp. 200–206, Oct. 2008.
- [26] L. Bilge, D. Balzarotti, W. Robertson, E. Kirda, and C. Kruegel, "Disclosure: detecting botnet command and control servers through large-scale netflow analysis," In Proceedings of the 28th Annual Computer Security Applications Conference, ser. ACSAC '12, New York, NY, USA: ACM, pp. 129–138, 2012.
- [27] R. Azmi, M. Gholinezhad, and M. Saberi, "Botnet Detection for Peer to Peer Networks," Journal of Electronical & Cyber Defence, vol. 3, n o. 4, Serial No.12, 2016. (In Persian)
- [28] M. Fathian, M. Abdollahi Azgomi, and H. Dehghani, "Modeling Browsing Behavior Analysis for Malicious Robot Detection in Distributed Denial of Service Attacks," Journal of Electronical & Cyber Defence, vol. 4, no. 2, 2016, Serial no. 14 (In Persian)
- [29] I. H. Witten and E. Frank, "Data Mining, 3th ed, SanFrancisco: Morgan Kafman, pp. 403-468, 2011.
- [30] J. Han and M. Kamber, "Data Mining Concepts and Techniques," SanFrancisco :Morgan Kafman, pp. 18-21, 2011.

---

## Botnet Detection with Flow Behavior Analysis Approach

S. Parsa\*, H. Mortazi

\*Iran University of Science and Technology

(Received: 25/07/2016, Accepted: 13/02/2017)

### ABSTRACT

*Botnet* is a network of infected computers connected to the Internet that is under management of the command and control server and is used for denial of service attacks, for sending spams and other malicious operations. The size of a botnet depends on the complexity and number of computers employed. Users usually do not know that their systems are remotely controlled and abused. Botnets are attractive for cyber criminals, because they are capable of being reset for various offenses, moved to new hosting services, or they are reprogrammed in response to new developments in security. Despite the specific characteristics of each botnet, bots in a botnet exhibit homogeneous behaviors and this can be the starting point for identifying a botnet within a network. Discoverable behavior of bots in a botnet can lead to production of features and attributes. Analyzing of these features, we can classify traffic to malicious and non-malicious traffic. This approach uses network flow analysis and machine learning methods to detect peer to peer botnets. Furthermore, this approach is flow-based and analyzes features extracted from flows based on the behavior of well-known botnets such as Weasel, etc and determines that the new traffic is an attack or not.

**Keywords:** Botnet, Bot, Peer to Peer Botnet, Network Flow Analysis, Machine Learning.