مجله علمی - پژوهشی "پدافند الکترونیکی و سایبری"
سال چهارم، شماره ۲، تابستان ۱۳۹۵، ص ۱۳- ۱

ارائه یک مدل تحلیل رفتار مرورگری برای تشخیص روبات‌های وب مخرب در حملات منع خدمت توزیعی

محمد فتحیان*[۱]، محمد عبدالهی ازگمی[۲]، حسن دهقانی[۳]

۱- استاد، دانشکده مهندسی صنایع، دانشگاه علم و صنعت ایران، ۲- دانشیار، دانشکده مهندسی کامپیوتر، دانشگاه علم و صنعت ایران
۳- دانشجوی کارشناسی ارشد، دانشکده مهندسی صنایع، دانشگاه علم و صنعت ایران

(دریافت: ۹۴/۰۲/۱۷، پذیرش: ۹۵/۰۲/۱۴)

چکیده

حملات منع خدمت توزیعی، یکی از مهم‌ترین تهدیدات دنیای تجارت الکترونیکی بوده و هدف اصلی آن جلوگیری از دسترسی کاربران به سایت‌ها و منابع اینترنتی از طریق مصرف بیش از حد منابع است. در این حملات، مؤلفه امنیتی دسترس‌پذیری، هدف تهاجم قرار می‌گیرد. یکی از روش‌های نیل به این هدف، به‌کارگیری روبات‌های وب است که حمله‌گران با استفاده از این روبات‌های مخرب، حملات منع خدمت در لایه کاربرد را طراحی و اجرا می‌نمایند. برای تشخیص این‌گونه روبات‌های مخرب از سایر روبات‌های غیرمخرب، از روش‌های گوناگونی استفاده شده است. یکی از روش‌هایی که در سال‌های اخیر مورد توجه قرار گرفته، یادگیری ماشین و داده‌کاوی است. محور اصلی این روش‌ها، استخراج و انتخاب خصیصه‌های مناسب جلسات وب از داده‌های ثبت رویداد و به‌کارگیری الگوریتم‌های داده‌کاوی است. این تحقیق سعی دارد تا با توجه به پویایی و سفارشی بودن طراحی و اجرای حملات منع خدمت توزیعی برای هر سایت، یک ساز وکار دفاعی پویا با قابلیت سفارشی‌سازی برای تشخیص روبات‌های وب مخرب مشارکت‌کننده در حملات، با استفاده از تحلیل رفتار مرورگری آن‌ها ارائه دهد. در این مطالعه، ضمن بهینه‌سازی روش‌های قبلی تعیین جلسات وب، استخراج مجموعه خصیصه‌ها براساس ویژگی‌های حملات دی‌داس انجام گرفت. همچنین پالایش خصیصه‌های استخراجی و انتخاب مجموعه خصیصه‌های کارا، باعث کاهش زمان ساخت مدل گردید و در نتیجه، دو درصد افزایش کارایی در مقایسه با بهترین تحقیق مشابه به‌دست آمد.

واژه‌های کلیدی: حمله منع خدمت توزیعی، امنیت تجارت الکترونیکی، تشخیص روبات‌های وب مخرب، داده‌کاوی

۱- مقدمه

حملات منع خدمت توزیعی یا دی‌داس[۱] یکی از این انواع حملات امنیتی است که هدف اصلی آن از بین بردن قابلیت دسترس‌پذیری[۲] برنامه‌ها و خدمات تحت اینترنت برای کاربران است. در این نوع حمله، حجم زیادی پیام و داده به ماشین یا سایت مقصد با هدف ایجاد تداخل در عملیات آن ارسال می‌شود که نتیجه آن معلق‌کردن ماشین یا سایت مقصد به‌دلیل استفاده بیش از حد از منابع آن مثل پردازنده، حافظه، پهنای‌باند و غیره است. این امر قطع کامل یا کاهش شدید سرعت ارائه خدمات را به همراه خواهد داشت. در عمل حملات منع خدمت انجام شده از یک محل، به راحتی با شناسایی محل و مسدودسازی ترافیک ارسالی مخرب از سوی آن قابل دفع می‌باشد ولی موقعی که حملات توزیعی باشد و از صدها تا ده‌ها هزار منبع تحت تسلط[۳] نشأت بگیرد، با چالش پیچیده‌تری مواجه خواهیم بود؛ چرا که برخلاف سناریوی حمله منع خدمت از یک منبع، در اینجا مسئله تشخیص[۴] محل منابع مخرب به دلیل تعداد بیشمار منابع شرکت‌کننده در حمله، بسیار سخت می‌شود. در این حالت حجم بسیار سنگینی از ترافیک ایجاد شده توسط تعداد انبوه منابع، به سمت سیستم قربانی[۵] گسیل می‌گردد که نتیجه آن ضرر مالی قابل ملاحظه برای کسب و کار و تجارت الکترونیکی تحت حمله به‌دلیل مسدودشدن ارائه خدمات می‌باشد. بر طبق گزارش سال ۲۰۰۸ وزارت دفاع آمریکا، حملات سایبری طراحی و اجرا شده از سوی افراد و کشورها به سازمان‌های اقتصادی، سیاسی و نظامی در آینده افزایش یافته و مخارج چند میلیارد دلاری در پی خواهد داشت [۱].

* رایانامه نویسنده مسئول: fathian@iust.ac.ir

1 -Distributed Denial of Service (DDoS)
2- Availability
3 -Compromised Zombie
4- Detection
5 -Victim

در سال‌های اخیر، حملات لایه ۷ مورد توجه حمله‌گران قرار گرفته است و به‌دلیل شباهت خیلی زیاد رفتار حمله‌گر با رفتار کاربران عادی در این لایه، عملاً تفکیک و تشخیص حمله بسیار سخت می‌باشد و به همین دلیل روش‌های داده‌کاوی[1] مورد توجه قرار گرفته است. یکی از انواع مهم این‌گونه حملات، حملات مبتنی بر روبات وب[2] مانند یک خزشگر وب[3] است که حجم زیادی ترافیک غیرواقعی از طریق عملیات پیمایش روی سایت‌های وب ایجاد نموده و باعث اختلال در عملکرد سایت و به هدر دادن منابع قربانی می‌گردد. موضوع این مقاله، ارائه مدلی برای تحلیل رفتار مرورگری[4] به‌منظور تشخیص روبات‌های وب مخرب[5] مشارکت‌کننده در حملات منع خدمت توزیعی می‌باشد.

در بخش دوم این مقاله به مرور ادبیات مشتمل بر معرفی و دسته‌بندی انواع روش‌های تشخیص روبات‌های وب خوش‌رفتار[6] و بدرفتار[7] (مخرب) مخرب پرداخته می‌شود. در بخش سوم مدل پیشنهادی برای تشخیص روبات‌های مخرب مشارکت‌کننده در حملات منع خدمت توضیح داده می‌شود. بخش چهارم به تشریح آزمایشات و نتایج حاصله با استفاده از داده‌های آزمایشی و ارزیابی مدل می‌پردازد. در بخش پنجم پس از بحث و بررسی، جمع‌بندی و نتیجه‌گیری ارائه می‌گردد.

۲- مرور ادبیات

مطالعات پیشین در حوزه تشخیص روبات وب و تفکیک آن از مرورگران انسانی، روش‌های تشخیص را به چهار دسته تحلیل نحوی ثبت رویداد[8]، تحلیل الگوی ترافیکی[9]، روش‌های یادگیری تحلیلی[10] و سیستم‌های تست تورینگ[11] تقسیم کرده‌اند [۲]. سه دسته اول به روش‌های حل مسئله تشخیص غیربرخط[12] و دسته چهارم به روش‌های حل مسئله بی‌درنگ[13] می‌پردازند. در روش تحلیل نحوی داده‌های ثبت رویداد سعی می‌شود روبات‌ها از طریق پردازش داده‌های ثبت رویداد دسترسی به سایت، مورد شناسایی قرار گیرند. کیب و میازاکی [۳] در مطالعه خود، بر اساس توصیف فیلد عامل کاربری[14] توانستند کاربران را به دسته‌های مختلف مرورگر[15]، تقسیم کنند. هانتینگتون و همکارانش[۴]، یک روش تحلیل رویداد چندمرحله‌ای پیشنهاد دادند که در مرحله اول کلیه آدرس‌های اینترنتی درخواست‌کننده فایل متنی روباتز[16] روبات شناسایی می‌شدند. در مرحله بعد از طریق جستجوی معکوس کارگزار نام دامنه، جستجو بر روی کلیه آدرس‌های آی‌پی، انجام شده و نام‌های محتوی کلمات روبات[17]، بات[18]، سرچ[19]، اسپایدر[20] و کراولر[21] با نظارت خبرگان انسانی و به‌صورت دستی به‌عنوان روبات وب دسته‌بندی می‌شدند.

روش تحلیل الگوی ترافیکی به دنبال آن دسته از ویژگی‌های معمول ترافیکی روبات وب می‌گردد که در تقابل با خصیصه‌های ترافیک عامل انسانی قرار دارد. گینز و همکارانش [۵]. یک روش تشخیص روبات پیشنهاد دادند که تحلیل نحوی را با تحلیل الگوی ترافیکی ترکیب می‌کرد. آن‌ها در تحقیقات خود به این نتیجه رسیدند که استفاده از هر یک از روش‌های درخواست فایل متنی روباتز، مقایسه آدرس‌های آی‌پی با لیست آدرس‌های روبات‌های شناخته شده و مقایسه فیلد عامل کاربری در برابر پایگاه داده‌ای از عبارات شناخته شده، به تنهایی برای تشخیص روبات کافی نبوده و قابل‌اعتماد نیست. به همین دلیل از سه الگوی ساده در ترافیک، برای بالابردن درصد تشخیص روبات‌ها استفاده نمودند. این الگوها عبارت بودند از تعیین تعداد درخواست هد[22] که بیشتر مورداستفاده روبات‌ها می‌باشد، فیلد ارجاع[23] که معمولاً در مراجعه روبات‌ها تخصیص نیافته[24] (خالی) است و میزان فایل‌های تصویری که بیشتر درخواست این‌گونه فایل‌ها توسط عامل انسانی و مرورگر است. گیو و همکارانش [۶] از این فرض استفاده کردند که روبات‌های وب، هنگام پیمایش یک سایت فقط منابع خاصی را درخواست می‌کنند. با این فرض آن‌ها سعی در تشخیص روبات براساس الگوهای درخواست منبع نمودند. بر این پایه، آن‌ها دو الگوریتم جدید تشخیص ارائه دادند. در تحقیق آن‌ها منابع به هشت نوع صفحه وب، سند[25]، اسکریپت، تصویر، موزیک، ویدئو، فایل و سایر تقسیم‌بندی شده بودند. اولین الگوریتم براساس حجم و میزان منابع درخواستی و دومی بر پایه نرخ درخواست‌ها به تشخیص روبات می‌پرداخت.

داسکین و همکارانش [۷] از طریق تحلیل نرخ درخواست

1- Data Mining
2- Web Robot
3- Web Crawler
4- Browsing Behavior
5- Malicious
6- Well-Behaved
7- Ill-Behaved
8- Syntactical Log Analysis
9- Traffic Pattern Analysis
10- Analytical Learning Technique
11- Turing Test System
12- Off-Line
13- Real Time
14- User-Agent
15- Browser
16- Robots.txt
17- Robot
18- Bot
19- Search
20- Spider
21- Crawler
22- Head
23- Referrer
24- Unassigned
25- Document

پرس‌وجوهای[1] ارسالی در داده‌های ثبت رویداد موتور جستجوی وب، روشی برای تفکیک روبات از انسان ارائه دادند. پیشنهاد آن‌ها این بود که الگوی فعالیت کاربران جستجوگر با استفاده از چندین معیار مورد مطالعه قرار گیرد. این معیارها عبارت بودند از: نرخ ارسال درخواست پرس‌وجو، فاصله زمانی بین پرس‌وجوها، نرخ تایپ کردن کاربران، طول جلسه فعالیت‌های مداوم، همبستگی[2] با زمان در روز، و نظم و قاعده پرس‌وجوهای ارسالی. لین و همکارانش [۸]، طرحی را معرفی کردند که ترافیک وب را به سه دسته عوامل انسانی، روبات‌های وب و سایر پروتکل‌های اینترنتی مثل اشتراک فایل نظیر به نظیر[3] تقسیم می‌کرد. آن‌ها از سه معیار برای تعیین سه دسته ترافیک پیشنهای خود استفاده کردند. اولین معیار به نام تشابه انسانی[4] برای تخمین میزان تشابه هر جلسه خاص با جلسات انسانی در انواع فایل‌های درخواستی و نتایج درخواست تعریف گردید. معیار دیگری به نام ضریب تنوع[5] تعریف شد که به میزان تنوع انواع منابع درخواستی در هر جلسه توجه داشت. معیار سوم آن‌ها به نام وابستگی به صفحات وب[6] (اچ‌تی‌ام‌ال[7])، انعکاس دهنده این فرض است که جلسات انسانی حاوی ترکیبی از انواع منابع بوده و در مقابل در جلسات روباتی درخواست‌های فایل‌های محتوی پیوند به منابع تفوق دارد. پژوهشگران با ترکیب این معیارها، یک رده‌بند[8] خودکار برای تشخیص ترافیک روبات وب ایجاد نمودند.

روش‌های یادگیری تحلیلی به مشاهده و بررسی ویژگی‌های جلسات ثبت شده پرداخته و احتمال این‌که هر جلسه توسط یک روبات ایجاد شده باشد را تخمین می‌زنند. برای این منظور از روش‌های یادگیری ماشین و مدل‌های مبتنی بر تئوری احتمالات استفاده می‌شود. یکی از اولین و مهم‌ترین مطالعات بر روی رده‌بندی[9] روبات‌های وب با استفاده از الگوریتم‌های داده‌کاوی توسط تن و کومار[۹] در سال ۲۰۰۲ انجام گرفت. در اولین مرحله، پژوهشگران یک رویکرد جدید برای استخراج جلسات وب از داده‌های ثبت رویداد پیشنهاد دادند. در مرحله بعد، ۲۶ خصیصه مختلف را برای هر جلسه وب استخراج نمودند. از میان آن‌ها، سه خصیصه انتخاب شد که بیشتر احتمال تعلق جلسه به روبات را می‌داد و از این سه خصیصه برای برچسب‌دهی استفاده شد. آن‌ها عبارت بودند: ۱- کنترل دسترسی به فایل متنی روباتز (فایلی که معمولاً روبات‌ها را برای صفحات قابل دسترسی هدایت می‌کند)؛ ۲- درصد صفحات درخواستی از طریق دستور هد، ۳- درصد درخواست‌های با فیلد ارجاع خالی، در برچسب‌دهی اولیه، جلسات کاربری به چهار گروه روبات‌های شناخته شده، مرورگرهای شناخته شده، روبات‌های محتمل، و مرورگرهای محتمل تقسیم‌بندی گردیدند. در نهایت با به کارگیری الگوریتم سی۴/۵[10] که یک الگوریتم داده‌کاوی درخت تصمیم[11] است، مدل رده‌بندی[12] ساخته شد. پس از اعمال این مدل بر روی مجموعه داده‌ها، روبات‌ها با صحت بیش از ۹۰ درصد و بعد از تنها چهار درخواست، تشخیص داده شدند. فراخوان و دقت روش آن‌ها بعد از بیش از سه درخواست ۰/۸۲ و ۰/۹۵ بود.

بومهارت و همکارانش [۱۰] برای تشخیص روبات‌های وب از شبکه عصبی استفاده کرده و به مقایسه نتایج حاصل با روش درخت تصمیم (شبیه تحقیق تن و کومار) پرداختند. استاسوپولو و دیکایاکوس [۱۱] یک رویکرد مبتنی بر بیزین[13] برای تشخیص خزشگرها ارائه دادند. لو و یو [۱۲] از مدل مخفی مارکوو[14] برای تشخیص کاربران انسانی از روبات براساس الگوهای ورودی استفاده کردند. بنابه ادعای آن‌ها یک کاربر انسانی مراجعه‌کننده به یک صفحه وب را می‌توان از طریق ارسال درخواست‌های پی‌درپی اچ‌تی‌تی‌پی توسط مرورگر برای منابع داخل صفحه و سپس طی مدت زمانی برای بازدید صفحه، توصیف نمود. در مقابل یک روبات درخواست برای منابع را در نرخ آهسته‌تر و در دوره زمانی یکنواخت‌تری بین درخواست‌ها، ارسال می‌کند. بر این اساس پژوهشگران زمان را در فواصل مجزایی با طول یکسان تقسیم نمودند و یک یا چند درخواست وارد شده توسط یک کاربر در همان فاصله زمانی را یک دسته ورودی[15] نامیدند. هر فاصله زمانی با یک دسته ورودی به‌صورت یک مشاهده برای مدل مخفی مارکوو در نظر گرفته شد. پژوهشگران از دنباله روبات‌های قبلاً مشاهده شده برای آموزش مدل خود استفاده کردند. این مجموعه آموزشی از طریق آزمایش فیلد عامل کاربری و استخراج عامل درخواست‌هایی که به‌طور واضح از ناحیه روبات بودند، انتخاب شد.

تنها مطالعه‌ای که با توجه به نقش مشارکت خزشگرهای وب مخرب در اجرای حملات منع خدمت توزیعی، بر روی تشخیص روبات وب مخرب از روبات وب خوش‌رفتار تمرکز داشت، تحقیقات استوانوویچ و همکارانش [۱۳] بود. آن‌ها به مطالعه

1- Query
2- Correlation
3- Peer-to-Peer (P2P)
4- Human Similarity (HS)
5- Diversity Factor (DF)
6- Html Affinity (HA)
7- HyperText Markup Language (HTML)
8- Classifier
9- Classification
10- C4.5
11- Decision Tree
12- Classification Model
13- Bayesian
14- Hidden Markov Model (HMM)
15- Batch Arrival

تشخیص رفتار کاربران و روبات‌های عادی از روبات‌های مخرب با استفاده از الگوریتم‌های داده‌کاوی موجود پرداختند. در این راستا از هفت الگوریتم مطرح رده‌بند (سی۴/۵، ریپر[1]، نزدیک‌ترین همسایه، نایو بیزین، شبکه بیزین، ماشین بردار پشتیبان[2] و شبکه عصبی[3]) برای رده‌بندی جلسات وب روبات‌ها از کاربران انسانی و سپس تعیین جلسات روبات‌های مخرب شرکت‌کننده در حمله از میان آن‌ها استفاده گردید. همچنین دو خصیصه جدید به هفت خصیصه از مطالعات قبلی برای رده‌بندی جلسات روبات‌های وب، اضافه شد و ظرفیت آن‌ها درخصوص بهبود صحت رده‌بندهای داده‌کاوی در تعیین جلسات روبات‌های وب مخرب مورد ارزیابی قرار گرفت. بهره‌گیری از دو خصیصه جدید مقدار کمی بر صحت رده‌بندی افزود. همین تیم[۱۴] در ادامه تحقیقات خود در این حوزه، برای افزایش کارایی تشخیص از دو الگوریتم نظارت نشده یادگیری شبکه عصبی برای تحلیل داده‌های ثبت رویداد استفاده نمودند.

مسئله تشخیص روبات در سیستم‌های تست تورینگ سعی در تعیین روبات یا انسان بودن منشأ تولید جلسات دارد. یک مثال متداول از سیستم تست تورینگ، تست کپچا می‌باشد که توسط آن و همکارانش [۱۵] ارائه گردید و در واقع یک تست چالش/ پاسخ قرار گرفته در داخل یک صفحه وب است. در این حالت کارگزار وب یک تست ساده استخراج می‌کند که کاربر باید جهت دسترسی به برخی منابع، در آن موفق عمل نماید. تست‌های کپچا که کاربر باید در آن قبول شود می‌تواند کپی متن از یک تصویر یا تایپ یک کلمه یا عبارت از یک فایل صوتی باشد. استخراج کاراکترها از تصویر یا تحلیل فایل صوتی برای تعیین کلمه یا عبارت مربوطه، توسط روبات قابل تشخیص نمی‌باشد. پارک و همکارانش [۱۶] روشی را ارائه دادند که در آن براساس رفتار مرورگری انسان، از تست تورینگ به‌صورت ضمنی[4] برای تفکیک ترافیک انسان از روبات استفاده می‌شود. در این مطالعه، فعالیت‌های کاربر انسانی از طریق ظهور برخی رویدادهای خاص توسط یک مرورگر وب تشخیص داده می‌شود. یک اسکریپت جاوای[5] قرار گرفته در صفحه وب که محتوی یک هندلر رویداد[6] برای حرکت ماوس یا فشردن یک کلید است، می‌تواند تعیین کند که جلسه متعلق به یک انسان است یا یک روبات. جدول (۱) مهمترین کارهای انجام شده در حوزه تشخیص روبات در سنوات اخیر را نشان می‌دهد.

جدول (۱). اهم کارهای انجام شده در حوزه تشخیص روبات وب

مطالعه	روش تشخیص	تشخیص روبات از انسان	تشخیص روبات مخرب	استخراج خصیصه	ساخت مدل تشخیص
[۳-۴]	تحلیل نحوی ثبت رویداد	✓			
[۵-۸]	تحلیل الگوی ترافیکی	✓		✓	
[۹-۱۲]	روش‌های یادگیری تحلیلی	✓		✓	✓
[۱۳-۱۴] و [۱۷]	روش‌های یادگیری تحلیلی	✓	✓	✓	✓
[۱۵-۱۶]	سیستم‌های تست تورینگ	✓			

۳- روش تحقیق

هدف این تحقیق، تشخیص روبات‌های وب مخرب حمله‌گر از طریق ساخت یک مدل رده‌بندی (کلاس‌بندی) است که توانایی تفکیک خودکار روبات‌های وب مخرب از سایر مراجعه‌کنندگان به سایت اعم از مرورگران عادی و روبات‌های خوش‌رفتار را براساس ویژگی‌های رفتار مرورگری مراجعه‌کننده داشته باشد. برای این منظور از داده‌های ثبت رویداد (لاگ) هر سایت وب به‌عنوان منبعی ارزشمند استفاده می‌شود. اطلاعات مرتبط با ترافیک ورودی به هر سایت، در فایل‌های ثبت رویداد کارگزار (سرور) وب ذخیره می‌گردد. هر فایل ثبت رویداد محتوی هزاران رکورد است که در یک قالب[7] مشخص و استاندارد ذخیره می‌شوند. طبیعت پروتکل اچ‌تی‌تی‌پی طوری است که رکوردها هیچ‌گونه وابستگی به یکدیگر ندارند. بنابراین داده‌های ثبت رویداد محتوی هیچ اطلاعاتی نیستند که بتواند درخواست‌های صادره در طول یک مراجعه را به هم مرتبط نماید. به‌همین دلیل برای استخراج خصیصه‌های رفتاری مراجعات به سایت مدنظر، قبل از هر اقدامی نیاز است تا داده‌های ثبت رویداد، مورد پردازش قرار گرفته و جلسات وب از آن‌ها استخراج گردد. درصورت برچسب‌دهی مناسب به جلسات، امکان استفاده از الگوریتم‌های داده‌کاوی برای ساخت مدل رده‌بندی با کارایی بالا فراهم می‌گردد.

شکل (۱) چارچوب کلی روش تحقیق را نشان می‌دهد. در این تحقیق برای انجام مراحل پیش‌پردازش و آماده‌سازی داده‌های ثبت رویداد و نیز تعیین جلسات، استخراج و انتخاب بهترین خصیصه‌ها (مناسب برای حملات منع خدمت توزیعی) و

1- RIPPER
2- Support Vector Machine (SVM)
3- Neural Network
4- Implicit
5- Javascript
6- Event Handler
7- Format

برچسب‌دهی به جلسات، یک تحلیلگر داده‌های ثبت رویداد[1] طراحی شد. برای رتبه‌بندی خصیصه‌ها و انتخاب زیرمجموعه مناسبی از آنها و نیز ساخت مدل رده‌بندی و ارزیابی آن از نرم‌افزار داده‌کاوی وکا[2] استفاده گردید.

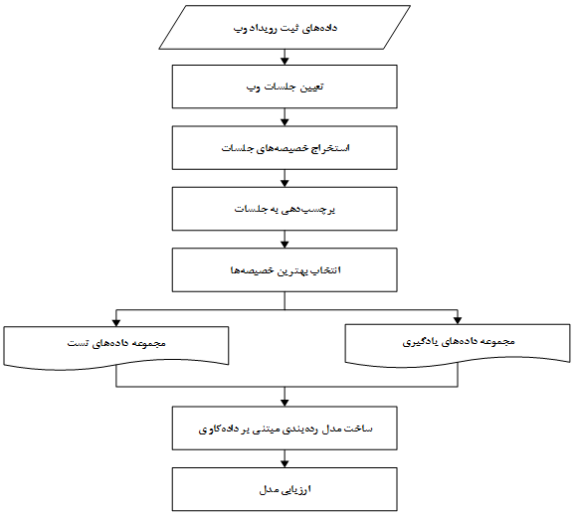

شکل (۱). چارچوب کلی روش تحقیق

۳-۱- تعیین جلسه

یک جلسه وب عبارت است از کلیه فعالیت‌هایی که یک کاربر از لحظه ورود به یک سایت تا لحظه ترک آن انجام می‌دهد[۱۸]. به‌عبارت دیگر یک جلسه وب دنباله‌ای از درخواست‌های اچ‌تی‌تی‌پی است که از یک مبدأ نشأت گرفته و در یک بازه زمانی مشخص و محدود، به کارگزار وب وارد گردند. تعیین جلسه عبارت از فرایند تبدیل رکوردهای ثبت رویداد هر کاربر به جلسات وب مربوطه می‌باشد. هر رکورد، متناظر با یک درخواست اچ‌تی‌تی‌پی است. به‌طورکلی تعیین جلسه به این صورت انجام می‌گیرد: ۱- درصورت امکان استفاده از روش‌های ابتکاری برای استخراج شناسه یکتا، ۲- گروه‌بندی درخواست‌های اچ‌تی‌تی‌پی براساس آدرس آی‌پی و فیلد عامل کاربری، ۳- شکستن گروه‌ها به زیرگروه‌هایی با فاصله زمانی بیش از یک آستانه از قبل تعریف شده.

چالش کلیدی این روش، تعیین صحیح مقدار آستانه با توجه به رفتارهای مرورگری مختلف کاربران وب است. در اکثر تحقیقات مرتبط، این مقدار معادل ۳۰ دقیقه به‌عنوان حداکثر طول زمانی یک جلسه مدنظر قرار گرفته است [۱۳].

به هرحال این رویکرد، ممکن است به دو دلیل روش کاملی نباشد. اول آن‌که، این امکان وجود دارد که هر جفت فیلد آدرس آی‌پی/ عامل کاربری، محتوی بیش از یک جلسه باشد؛ به‌عنوان مثال این حالت می‌تواند در جلساتی رخ دهد که کاربران وب از طریق یک کارگزار نماینده[3] مشترک و با یک نوع مرورگر وب، آن‌ها را ایجاد کرده باشند. دلیل دوم، احتمال وجود چندگانه آدرس آی‌پی یا عامل کاربری در یک جلسه است که باعث تقسیم یک جلسه به چند جلسه مجزا می‌شود [۹]. اگر فاصله زمانی بین دو درخواست متوالی در یک جلسه، بیشتر از ۳۰ دقیقه باشد، درخواست جدید آغازگر جلسه جدیدی است. شکل (۲) فرایند استخراج و تعیین جلسات وب از رکوردهای ثبت رویداد را نشان می‌دهد. همچنین ما جلسات با تعداد کمتر از پنج درخواست را حذف می‌نماییم، چرا که عملاً امکان بررسی و ارزیابی این قبیل جلسات برای تخصیص برچسب حتی توسط عامل انسانی و به‌صورت دستی وجود ندارد.

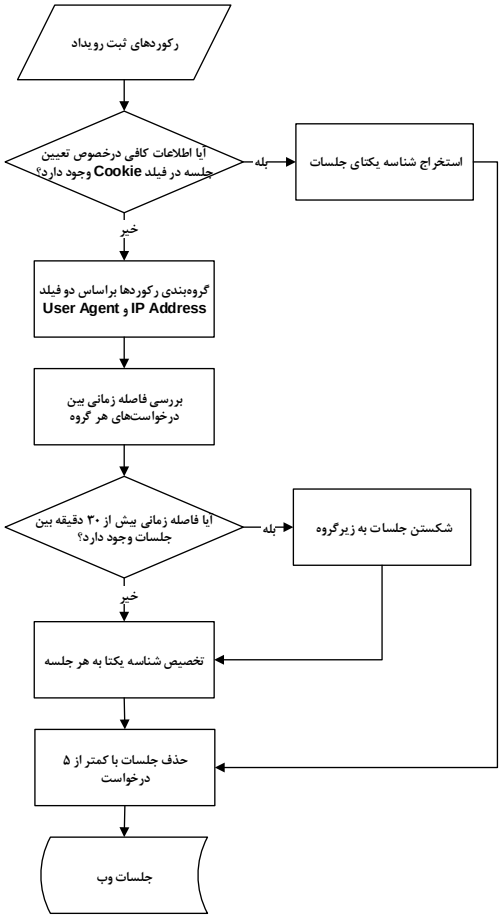

شکل (۲). فرایند تعیین جلسات وب

۳-۲- استخراج خصیصه

مرحله بعد از تعیین جلسات وب، استخراج خصیصه‌های هر

1- Log Analyzer
2-Waikato Environment for Knowledge Analysis (WEKA)
3- Proxy Server

جلسه در رابطه با تفکیک الگوهای مرورگری کاربران انسانی و روبات‌های وب است. با تعمیم این خصیصه‌ها و با توجه به ویژگی‌های روبات‌های وب مشارکت‌کننده در حملات منع خدمت، می‌توان به دسته‌ای از خصیصه‌ها رسید که از طریق آن‌ها می‌توان روبات‌های مخرب را از سایر گروه‌های کاربری اعم از کاربران انسانی و روبات‌های خوش‌رفتار تشخیص داد. رکوردهای ثبت رویداد، محتوی اطلاعاتی از قبیل آدرس آی‌پی، نام میزبان مراجعه‌کننده به سایت، آدرس صفحه درخواستی، تاریخ و ساعت درخواست، اندازه داده‌های درخواستی، روش درخواست و غیره است. علاوه بر این در هر رکورد ثبت رویداد، فیلد رشته حرفی عامل کاربری قرار دارد که در واقع توصیف‌کننده سخت‌افزار و نرم‌افزار کاربر مراجعه کننده به سایت می‌باشد. همچنین فیلد ارجاع که مشخص‌کننده صفحه‌ای است که کاربر از طریق آن به صفحه جاری ارجاع داده شده است، از دیگر فیلدهای موجود در رکورد ثبت رویداد است. از این فیلدها می‌توان برای توصیف خصیصه‌های خاص یک جلسه وب کاربر استفاده کرد.

هدف این تحقیق صرفاً تشخیص روبات‌های وب در دو گروه خوش‌رفتار و مخرب نبوده و بلکه در یک نوآوری، این مطالعه بنا دارد مدلی برای تشخیص روبات‌های وب مخرب مشارکت‌کننده در حملات منع خدمت توزیعی از سایر مرورگران اعم از کاربران انسانی عادی و روبات‌های وب خوش‌رفتار ارائه نماید. برای این منظور قبل از هر چیز باید ویژگی‌های یک حمله منع خدمت توزیعی را شناخت تا بتوان براساس آن، خصیصه‌های مناسب برای تشخیص این‌گونه روبات‌های وب مخرب حمله‌گر را تعریف نمود. به‌طورکلی ویژگی‌های خاص یک حمله منع خدمت توزیعی در لایه کاربرد به این شرح است:

- از تعداد زیادی منبع (روبات وب) برای حمله و ارسال درخواست به سایت قربانی استفاده می‌شود.
- حجم داده‌های مبادله شده بین منابع و قربانی نسبتاً زیاد است تا پهنای باند سایت قربانی پر شود.
- نوع و نرخ درخواست‌های ارسالی طوری است که سایت قربانی را به شدت درگیر پاسخ‌گویی می‌کند.
- از آدرس‌های آی‌پی مبدأ متناوب و احتمالاً جعلی برای درخواست‌ها استفاده می‌شود.
- قواعد متداول بین روبات‌های خوش‌رفتار مثل ضوابط مندرج در فایل روباتز رعایت نمی‌شود.
- از فیلد عامل کاربری ناشناخته و احیاناً جعلی استفاده می‌گردد.
- شبیه روبات‌های خوش‌رفتار معمولاً فیلد ارجاع (آدرس صفحه قبلی) خالی است.
- رفتار آن‌ها بسیار شبیه روبات‌های معمولی به‌ویژه خزشگرهای جستجوی وب می‌باشد.
- نرخ درخواست‌های آن‌ها متناوب و احتمالاً ضربانی است.
- درخواست‌های آن‌ها از ساختار خاصی تبعیت نمی‌کند.

با مدنظر قرار دادن ویژگی‌های حملات منع خدمت توزیعی و نیز بررسی رفتار مرورگری روبات‌های مخرب، می‌توان به مجموعه‌ای از بهترین خصیصه‌ها برای جداسازی روبات‌های وب مخرب حمله‌گر از سایر مرورگران انسانی و روباتی دست یافت. در این مطالعه، ملاک عمل ابتدا بررسی خصیصه‌های مطالعات قبلی درخصوص جلسات روبات‌های وب مخرب بوده است و سپس براساس نتایج بررسی، مجموعه مناسب‌تری که هم‌راستا با ویژگی‌های حملات منع خدمت باشد، با توجه به گزاره‌های زیر استخراج شده است:

- عمده مرورگرهای انسانی و روبات‌های خوش‌رفتار وب مثل خزشگرهای جستجو، به دنبال صفحات با محبوبیت بیشتر هستند، اما کارکرد اصلی روبات‌های وب مخرب حمله‌گر، صرفاً ارسال حجم زیادی درخواست بدون هدف صفحه، برای ایجاد ترافیک مزاحم می‌باشد.
- روبات‌های مخرب وب برای رسیدن به هدف اصلی خود که همانا مصرف بی‌رویه منابع قربانی از جمله پهنای باند است، زمان زیادی را برای حضور در سایت صرف می‌کنند و به همین دلیل جلسات وب طولانی‌تری را سپری می‌نمایند.
- اندازه و حجم داده‌های مبادله شده در جلسات روبات‌های وب مخرب زیادتر از جلسات معمولی است که دلیل آن درگیر بودن کارگزار وب در پاسخ‌گویی به درخواست‌های پیمایشی روبات حمله‌گر است.

متناظر با نتایج فوق چهار خصیصه به شرح زیر انتخاب گردید:

- شاخص محبوبیت صفحه: این شاخص میزان محبوبیت یک صفحه وب را نشان می‌دهد. مقدار این شاخص برای روبات‌های مخرب کمتر از سایر مراجعه‌کنندگان (روبات‌های خوش‌رفتار و مرورگران انسانی) است.
- نرخ ترافیک: عبارت از نسبت حجم داده‌های مبادله شده در یک جلسه به زمان آن جلسه است. این مقدار برای روبات‌های مخرب بیشتر از سایرین است.
- نرخ درخواست: عبارت از نسبت تعداد درخواست‌ها در یک جلسه به زمان آن جلسه است. این فرکانس برای روبات‌های مخرب بیشتر از سایرین است.
- زمان پردازش: عبارت از مدت زمانی است که در یک جلسه صرف پردازش درخواست‌ها می‌گردد. این زمان برای روبات‌های مخرب طولانی‌تر از سایرین است.

ما در این کار، خصیصه‌ها را به دو دسته تقسیم می‌کنیم: دسته اول خصیصه‌هایی که برای تشخیص هر نوع روباتی قابل استفاده هستند و دسته دوم خصیصه‌هایی که کارایی بالاتری را در تشخیص روبات‌های دی‌داس در لایه کاربرد ارائه می‌دهند. جدول (۲) لیست خصیصه‌های استخراج شده برای این تحقیق را نشان می‌دهد.

جدول (۲). خصیصه‌های استخراج‌شده برای تحقیق

ردیف	نام خصیصه	شرح	نوع روبات
۱	Request Number	تعداد درخواست اچ‌تی‌تی‌پی	خاص دی‌داس
۲	Click Number	تعداد درخواست صفحه وب	عمومی
۳	HTML-to-Image Ratio	نسبت درخواست صفحه وب به درخواست فایل تصویری	عمومی
۴	%PDF/PS	درصد درخواست فایل پی‌دی‌اف/پی‌اس	عمومی
۵	%4xx Error	درصد پاسخ خطا با کد ۴xx	عمومی
۶	%Head	درصد درخواست نوع هد	عمومی
۷	%Unassigned Referrer	درصد درخواست با فیلد ارجاع خالی یا تخصیص نیافته	عمومی
۸	Robots.txt	مشخص‌کننده دسترسی به فایل روباتز	عمومی
۹	Client Size	حجم داده ارسالی از سوی کاربر به سمت کارگزار	خاص دی‌داس
۱۰	Server Size	حجم داده ارسالی از سوی کارگزار به سمت کاربر	خاص دی‌داس
۱۱	Total Size	مجموع داده‌های تبادل شده	خاص دی‌داس
۱۲	Time Taken	کل زمان صرف شده برای پردازش درخواست‌ها	خاص دی‌داس
۱۳	Duration	کل زمان سپری شده در یک جلسه	خاص دی‌داس
۱۴	Page Popularity Index	شاخص محبوبیت یک صفحه	عمومی
۱۵	Request Rate	نرخ درخواست‌های ارسالی	خاص دی‌داس
۱۶	Traffic Rate	نرخ ترافیک مبادله شده	خاص دی‌داس

۳-۳- برچسب‌دهی

پس از استخراج مجموعه داده آموزش، نیاز است به هر بردار خصیصه متناظر با یک جلسه وب، یک برچسب تخصیص یابد تا بتوان عملیات رده‌بندی و ساخت مدل را انجام داد. برچسب‌دهی به هر جلسه وب عبارت است از عمل تخصیص یک جلسه به یک روبات مخرب یا سایر مرورگران. پس از استخراج جلسات وب متشکل از بردار خصیصه‌ها، باید به هر بردار یک برچسب توسط برنامه تحلیلگر داده‌های ثبت رویداد داده شود. به‌طور کلی هر بردار خصیصه متعلق به یکی از چهار گروه مرورگران انسانی، روبات‌های وب خوش‌رفتار، روبات‌های وب مخرب و مراجعه‌کنندگان ناشناس می‌باشد. ما جلسات وب را به دو گروه ۱) روبات‌های وب مخرب و ۲) مرورگران غیرمخرب شامل کاربران انسانی و روبات‌های خوش‌رفتار تقسیم می‌کنیم. برای انجام فرایند برچسب‌دهی، برنامه تحلیلگر ما یک جدول از فیلدهای عامل کاربری انواع مرورگران و روبات‌های وب شناخته شده را در خود نگهداری می‌کند. این اطلاعات از طریق سه سایت [۲۱-۱۹] به‌دست می‌آید. شکل (۳) فرایند برچسب‌دهی به جلسات وب را به شرح زیر نشان می‌دهد:

- همه بردارهای خصیصه دارای ویژگی‌های خاص به‌عنوان روبات وب خوش‌رفتار برچسب می‌گیرند (برچسب صفر).
- همه بردارهای خصیصه با فیلد عامل کاربری با رشته حرفی مربوط به یک مرورگر شناخته‌شده، به‌عنوان یک مراجعه‌کننده انسانی برچسب می‌گیرند (برچسب صفر).
- همه بردارهای خصیصه با فیلد عامل کاربری با رشته حرفی مربوط به یک روبات وب ناشناخته، به‌عنوان یک روبات وب مخرب برچسب می‌گیرند (برچسب یک).
- سایر بردارهای خصیصه به‌عنوان مراجعه‌کنندگان ناشناس برچسب می‌گیرند (برچسب یک).

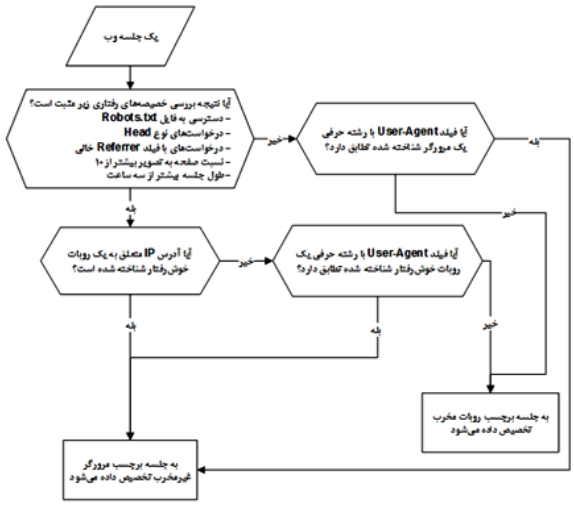

شکل (۳). فرایند برچسب‌دهی به جلسات وب

۴-۳- انتخاب خصیصه‌ها

مرحله انتخاب خصیصه یکی از مهمترین مراحل پیش‌پردازش در داده‌کاوی است که با استفاده از الگوریتم‌های مربوطه، به جستجوی بهترین ترکیب ممکن از خصیصه‌هایی

پرداخته می‌شود که باعث صرفه‌جویی در مصرف حافظه و کاهش زمان پردازش گردد. این عمل با کاهش تعداد خصیصه‌ها و حذف خصیصه‌های نامرتبط[1] و افزونه[2] انجام می‌پذیرد. افزایش خصیصه‌ها از یک طرف مشکلاتی از قبیل اشغال حجم بیشتر حافظه مصرفی و افزایش زمان پردازش را در رابطه با محاسبات در پی دارد و از طرف دیگر تعداد زیاد خصیصه‌ها فاکتورهای همبستگی خاصی را سبب می‌شود که نتیجه آن تکرار و به هدر دادن اطلاعات است. به همین دلیل نیاز به استفاده از معیارهایی برای کاهش ابعاد خصیصه‌ها بدون کاهش اثر تشخیص است که به مسئله انتخاب بهینه خصیصه‌ها[3] معروف می‌باشد [۲۲]. چگونگی ارزیابی خوب بودن خصیصه‌ها برای رده‌بندی، مسئله مهمی است. به‌طورکلی، هر خصیصه‌ای که مرتبط به مفهوم کلاس بوده و نسبت به خصیصه‌های دیگر دارای افزونگی نباشد، به‌عنوان خصیصه خوب[4] ارزیابی می‌گردد. اگر همبستگی بین دو متغیر[5] به‌عنوان معیار خوب بودن مدنظر قرار گیرد، تعریف بالا به این صورت در می‌آید که یک خصیصه درصورتی خوب است که به‌طور شدیدی همبسته با کلاس بوده، اما با هیچ خصیصه دیگری همبستگی زیاد نداشته باشد. بنابراین مسئله انتخاب خصیصه تبدیل به جستجو برای یافتن معیاری مناسب برای اندازه‌گیری میزان همبستگی بین خصیصه‌ها می‌شود [۲۳].

در این تحقیق، ما از قابلیت‌های وکا، برای انتخاب خصیصه استفاده می‌کنیم. ابزار نرم‌افزار وکا برای انتخاب خصیصه از دو بخش تشکیل شده است. ارزیابی‌کننده خصیصه[6] روشی را برای ارزیابی زیرمجموعه‌ای از خصیصه‌ها ارائه می‌دهد و روش جستجو[7] روشی ساخت یافته را بیان می‌کند که به‌وسیله آن فضای جستجوی زیرمجموعه‌های خصیصه‌ها، براساس نوع ارزیابی‌کننده تحت پیمایش قرار می‌گیرد. برخی از ارزیابی‌کننده‌های خصیصه‌ها و روش‌های جستجو در نرم‌افزار وکا که در این تحقیق مورد استفاده قرار گرفته به شرح زیر است [۲۴].

- ارزیابی‌کننده‌های خصیصه: CfsSubsetEval، GainRatioAttributeEval، ChiSquaredAttributeEval، InfoGainAttributeEval
- روش‌های جستجو: BestFirst، GeneticSearch، Ranker، GreedyStepwise

1- Irrelevant
2- Redundant
3- Feature Optimum Selection
4- Good
5- Variable
6- Attribute Evaluator
7- Search Method

۳-۵- رده‌بندی

بعد از تعیین جلسات وب، استخراج و انتخاب خصیصه‌ها و برچسب‌دهی به جلسات، ساختن مدل‌های رده‌بندی (کلاس‌بندی) براساس الگوریتم‌های داده‌کاوی شروع می‌گردد. در این تحقیق، الگوریتم‌های مختلف با هدف تشخیص روبات‌های مخرب از سایر مرورگران غیرمخرب با کارایی و صحت بالا مورد آزمایش و ارزیابی قرار می‌گیرند. الگوریتم‌های مدنظر در این تحقیق که با استفاده از نرم‌افزار وکا مورد ارزیابی قرار می‌گیرند، به شرح زیر می‌باشند [۲۵]:

- J48: یادگیرنده مبتنی بر درخت تصمیم، پیاده‌سازی شده براساس الگوریتم C4.5
- NaiveBayes: رده‌بند مبتنی بر مدل احتمالات نایو بیزین
- IBK[8]: رده‌بند مبتنی بر الگوریتم نزدیکترین همسایه
- SMO[9]: الگوریتم حداقل بهینه‌سازی ترتیبی برای رده‌بندی بردار پشتیبان
- MLP[10]: مدل مبتنی بر شبکه عصبی انتشار به عقب[11] (پس انتشار)

برای ارزیابی کارایی یک رده‌بند از معیارهای بخصوصی استفاده می‌گردد. دو معیار مهم برای ارزیابی کارایی رده‌بندها، معیارهای فراخوان و دقت است که در روابط (۲ و ۱) آمده است [۲۶ و ۹]:

$$Recall, r = \frac{Number\ of\ robot\ sessions\ found\ correctly}{Total\ number\ of\ actual\ robot\ sessions} \quad (۱)$$

$$Precision, p = \frac{Number\ of\ robot\ sessions\ found\ correctly}{Total\ number\ of\ predicted\ robot\ sessions} \quad (۲)$$

در رابطه (۱) فراخوان نسبت تعداد جلسات حمله رده‌بندی شده به‌صورت صحیح به تعداد کل جلسات واقعی حمله است. در واقع، فراخوان معیاری برای تحلیل سبک و سنگین نمودن بین خطاهای مثبت درست (ترو پوزتیو)[12] و منفی غلط (فالس نگاتیو)[13] است. در رابطه (۲) دقت نسبت تعداد جلسات حمله رده‌بندی شده به‌صورت صحیح به تعداد کل جلسات پیش‌بینی شده به‌عنوان حمله است. در حقیقت، دقت معیاری برای تحلیل سبک و سنگین نمودن بین خطاهای مثبت درست (ترو پوزتیو) و مثبت غلط (فالس پوزتیو)[14] است. این دو معیار می‌توانند در قالب

8- Instance based K-Nearest Neighbors (KNN)
9- Sequential Minimal Optimization
10- Multilayer Perceptron
11- Backpropagation Neural Network
12- True Positive
13- False Negative
14- False Positive

یک معیار به نام معیار اف‌یک[1] مطابق رابطه (۳) خلاصه گردند:

$$F_1 = \frac{2 * Recall * Precision}{Recall + Precision} \quad (۳)$$

۴- آزمایشات و ارزیابی

آزمایشات ما در این تحقیق بر روی داده‌های ثبت رویداد کارگزار وب یکی از سازمان‌های دولتی در طول شش ماه اول سال ۲۰۱۴ انجام گرفت. در یک کارگزار (سرور) وب، داده‌های ثبت رویداد در قالب فایل‌های متنی و معمولاً به‌صورت روزانه سازماندهی می‌شود. منبع داده ما، متشکل از ۱۶۹ فایل ثبت رویداد وب است که در یک بازه شش ماهه تولید شده است. با توجه به حجم بالای داده‌ها و نیاز به تجمیع و یکپارچه نمودن آن‌ها، می‌بایست داده‌ها را به یک پایگاه داده قوی مثل اس‌کیوال سرور منتقل نمود. خوشبختانه نرم‌افزار لاگ‌پارزر شرکت مایکروسافت این عملیات تبدیل و انتقال داده را به خوبی انجام می‌دهد. این نرم‌افزار از زبان اس‌کیوال بر روی فایل‌های داده‌های ثبت رویداد پشتیبانی کرده و به راحتی می‌توان پرس‌وجوهای مختلف را بر روی داده‌ها انجام داد. پس از انجام اقدامات لازم، منبع داده انتخابی ما با تعداد ۱۱۴۳۶۵۶۷ رکورد بر روی پایگاه داده، ایجاد گردید. سپس تفکیک فایل‌ها و منابع (صفحات وب، تصاویر، پی‌دی‌اف و فایل متنی روباتز) انجام شده و منبع داده برای ادامه کار براساس اطلاعات آماری جدول (۳) آماده بهره‌برداری گردید. پس از استخراج خصیصه‌های جلسات، کار تخصیص برچسب کلاس به هر بردار خصیصه متناظر با جلسه وب مربوطه انجام پذیرفت. جدول (۴) توزیع برچسب کلاس در مجموعه داده و آمار فراوانی جلسات را در دو برچسب کلاس صفر (۰) و یک (۱) نمایش می‌دهد.

جدول (۳). توزیع آماری رکوردهای منبع داده

نوع درخواست	تعداد
کل درخواست‌ها	۱۱۴۳۶۵۶۷
صفحات وب	۶۶۲۲۴۸
تصویر	۴۲۹۲۳۰۷
فایل پی‌دی‌اف	۰
فایل متنی روباتز (robots.txt)	۲۰۸۵۳

جدول (۴). توزیع برچسب کلاس در مجموعه داده

جلسات وب	تعداد
کل جلسات	۱۲۸۸۰۵
جلسات با برچسب کلاس ۰ (مرورگر انسانی + روبات وب خوش‌رفتار)	۱۲۵۷۶۷
جلسات با برچسب کلاس ۱ (روبات وب مخرب + مراجعه‌کنندگان ناشناس)	۳۰۳۸

در این تحقیق از نرم‌افزار وکا که یک ابزار یادگیری ماشین است برای ساخت مدل، ارزیابی آن و تحلیل مقایسه‌ای استفاده گردید و ابتدا با ترکیب روش‌های مختلف انتخاب خصیصه، مجموعه‌ای از بهترین خصیصه‌ها انتخاب شده و سپس با اجرای چند الگوریتم داده‌کاوی روی داده‌های آموزش، کارایی آن‌ها مورد ارزیابی و مقایسه قرار گرفت. عملیات انتخاب خصیصه، از طریق سازوکارهای انتخاب خصیصه در نرم‌افزار وکا انجام شده و نتایج در جدول (۵) منعکس گردیده است. در ستون اول این جدول، روش انتخاب خصیصه آورده شده و در ستون دوم تعداد خصیصه‌های انتخاب شده از بین ۱۶ خصیصه جدول (۲)، توسط روش مربوطه بیان شده است. ستون سوم اشاره به شماره خصیصه‌های انتخابی دارد. به‌منظور انتخاب بهترین زیرمجموعه از خصیصه‌ها، کارایی آن‌ها با استفاده از چندین رده‌بند مبتنی بر الگوریتم‌های داده‌کاوی مورد ارزیابی قرار گرفت. برای انجام آزمایشات در نرم‌افزار وکا، ۷۰ درصد مجموعه داده برای آموزش مدل و ۳۰ درصد باقیمانده جهت تست مدل تخصیص داده شد.

جدول (۵). خصیصه‌های انتخابی توسط روش‌های مختلف انتخاب خصیصه

شماره	روش انتخاب خصیصه	تعداد	شماره خصیصه‌های انتخابی
۱	BestFirst+CfsSubsetEval	۶	۱،۹،۱۳،۱۴،۱۵،۱۶
۲	GeneticSearch+CfsSubsetEval	۴	۷،۹،۱۴،۱۵
۳	GreedyStepwise+CfsSubsetEval	۷	۱،۱۱،۱۲،۱۳،۱۴،۱۵،۱۶
۴	Ranker+InfoGainAttributeEval	۱۱	۷،۹،۱۵،۱۶،۱،۱۴،۱۳،۱۰،۱۱،۲،۱۲
۵	Ranker+GainRatioAttributeEval	۱۱	۷،۱۵،۹،۸،۱۶،۱۴،۱۳،۱،۲،۱۰،۱۱
۶	Ranker+ChiSquaredAttributeEval	۹	۹،۱۵،۱۶،۷،۱۳،۱۰،۱۱،۱۴،۱

جدول (۵) نتایج آزمایشات را نشان می‌دهد. با استفاده از الگوریتم‌های رده‌بندی اشاره شده در ستون دوم جدول، مدل‌های مختلف برای مجموعه خصیصه‌های مختلف ساخته شده است. در این بخش پس از انجام آزمایشات مربوطه، از دو الگوریتم ماشین بردار پشتیبان و شبکه عصبی به دلیل پایین بودن کارایی آن‌ها در تشخیص حملات صرف‌نظر گردید. برای ارزیابی مدل‌ها و مقایسه آن‌ها نسبت به هم از معیارهای دقت، فراخوان و اف‌یک

1- F1-Measure

استفاده شده است. همچنین با توجه به اهمیت زمان ساخت هر مدل در ارزیابی و انتخاب آن، اطلاعات مدت زمان ساخت هر مدل، در ستون آخر آورده شده است.

جدول (۶). مقایسه ترکیب‌های مختلف رده‌بند و روش‌های انتخاب خصیصه

ردیف	رده‌بند (Classifier)	شماره روش انتخاب خصیصه	دقت (Precision)	فراخوان (Recall)	معیار اف‌یک (F1_Measure)	زمان ساخت مدل (ثانیه)
۱	J48	۱	۰/۹۹۰	۰/۹۹۰	۰/۹۹۰	۱۹۵/۱۱
۲	J48	۲	۰/۹۸۲	۰/۹۸۳	۰/۹۸۳	۱۱۱/۳۴
۳	J48	۳	۰/۹۸۵	۰/۹۸۶	۰/۹۸۵	۴۱۳/۸۴
۴	J48	۴	۰/۹۸۸	۰/۹۸۹	۰/۹۸۹	۶۴۱/۷۳
۵	J48	۵	۰/۹۸۹	۰/۹۹۰	۰/۹۸۹	۶۰۴/۴۲
۶	J48	۶	۰/۹۹۰	./۹۹۰	۰/۹۹۰	۲۵۷/۱۱
۷	NaiveBayes	۱	۰/۹۷۴	۰/۸۸۴	۰/۹۲۱	۶۸/۱۳
۸	NaiveBayes	۲	۰/۹۸۰	۰/۹۱۰	۰/۹۳۷	۴۶/۹۳
۹	NaiveBayes	۳	./۹۹۵	۰/۹۶۴	۰/۹۵۹	۷۹/۶۲
۱۰	NaiveBayes	۴	۰/۹۷۵	۰/۹۲۸	۰/۹۴۷	۱۲۸/۵۴
۱۱	NaiveBayes	۵	۰/۹۸۱	۰/۹۱۲	۰/۹۳۸	۱۲۰/۵۹
۱۲	NaiveBayes	۶	۰/۹۸۰	۰/۹۰۳	۰/۹۳۳	۱۱۰/۹۲
۱۳	IBK	۱	۰/۹۷۰	۰/۹۵۳	۰/۹۶۰	۰/۰۵
۱۴	IBK	۲	۰/۹۷۲	۰/۹۶۱	۰/۹۶۶	۰/۰۵
۱۵	IBK	۳	۰/۹۷۲	۰/۹۵۶	۰/۹۶۳	۰/۰۵
۱۶	IBK	۴	۰/۹۷۵	۰/۹۶۳	./۹۶۸	۰/۰۶
۱۷	IBK	۵	۰/۹۸۰	۰/۹۷۹	۰/۹۷۹	۰/۰۵
۱۸	IBK	۶	۰/۹۷۵	۰/۹۶۴	۰/۹۶۹	۰/۰۵

شکل‌های (۴ و ۵) نمودار نمایشی گویاتری جهت مقایسه بهتر بین رده‌بندها و مجموعه خصیصه‌های انتخابی هر مدل، ارائه می‌دهند. براساس نمودار شکل(۴)، رده‌بند جی۴۸ (درخت تصمیم) نسبت به دو رده‌بند نایو بیزین و آی‌بی‌کی (نزدیکترین همسایه)، بهترین دقت، فراخوان و اف‌یک را ارائه می‌دهد. کارایی و صحت رده‌بند درخت تصمیم بیش از ۹۸ درصد است. در این آزمایش، الگوریتم درخت تصمیم با شش دسته مجموعه خصیصه انتخابی مورد بررسی قرار گرفته است (ردیف‌های ۱ تا ۶ جدول (۶)). همان‌طور که مشاهده می‌گردد، نتیجه ارزیابی هر شش آزمایش، کارایی بالاتر از ۹۸ درصد را برای این الگوریتم نشان می‌دهد. نقطه ضعف این الگوریتم نسبت به سایر الگوریتم‌ها، براساس نمودار شکل (۵) زمانبر بودن زیاد آن است. الگوریتم نزدیکترین همسایه (ردیف‌های ۱۳ تا ۱۸ جدول (۶))، کارایی کمتری نسبت به درخت تصمیم ارائه می‌دهد ولی در مقابل زمان ساخت مدل در آن بسیار کوتاه است. این نکته حائز اهمیت است که اگرچه زمان ساخت مدل در آن بسیار کوتاه است ولی آزمایشات نشان داد که زمان تست مدل بسیار طولانی می‌باشد. در مجموع، با توجه به مدنظر قرار دادن دو عامل میزان کارایی و زمانبری ساخت و تست مدل، می‌توان ردیف ۱ جدول (۶) را با الگوریتم درخت تصمیم و خصیصه‌های شماره ۱، ۹، ۱۳، ۱۴، ۱۵ و ۱۶ به‌عنوان بهترین گزینه با صحت (کارایی) ۹۹ درصد برای ساخت مدل ارزیابی انتخاب نمود.

به‌منظور مقایسه نتایج آزمایش این تحقیق با مطالعه استوانوویچ و همکارانش [۱۳]، آزمایش آن‌ها بر روی مجموعه داده ما و با اجرای الگوریتم درخت تصمیم بر روی مجموعه خصیصه‌های انتخابی توسط آن‌ها انجام پذیرفت. مقایسه کارایی دو آزمایش در جدول (۷) ارائه شده است. همان‌طور که مشاهده می‌شود، در مجموع مقایسه دو عامل کارایی و زمان نشان می‌دهد که چارچوب ارائه شده در تحقیق جاری برای تشخیص روبات‌های وب مخرب (روبات‌های مشارکت‌کننده در حملات منع خدمت توزیعی)، با ۲ درصد افزایش در کارایی و ۲۷ درصد کاهش در زمان ساخت مدل موفق‌تر می‌باشد.

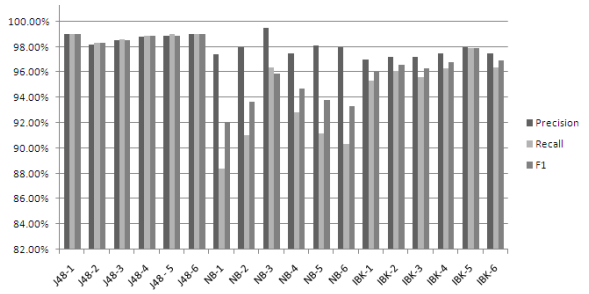

شکل (۴). نمودار مقایسه کارایی ترکیب‌های مختلف رده‌بند و مجموعه خصیصه

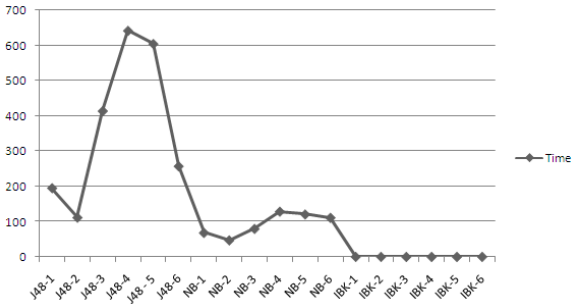

شکل (۵). نمودار مقایسه زمان ساخت مدل با ترکیب‌های مختلف رده‌بند و مجموعه خصیصه

جدول (۷). مقایسه دو مدل در تحقیق استوانوویچ و تحقیق جاری

تحقیق	رده‌بند	مجموعه خصیصه‌های انتخابی	زمان ساخت مدل (ثانیه)	درصد صحت (کارایی)
استوانوویچ	درخت تصمیم (J48)	Click Number HTML-to-Image Ratio %PDF/PS %4xx Error %Head %Unassigned Referrer Robots.txt	۲۶۶/۲۵	۹۷
جاری	درخت تصمیم (J48)	Request Number Client Size Duration Page Popularity Index Request Rate Traffic Rate	۱۹۵/۱۱	۹۹

۵- نتیجه‌گیری

هدف این تحقیق طراحی یک سازوکار دفاعی پویا با قابلیت سفارشی‌سازی برای تشخیص این نوع روبات‌های مخرب از طریق تحلیل رفتار آنها و به‌کارگیری الگوریتم‌های داده‌کاوی می‌باشد. در این روش، استفاده از بردارهای خصیصه‌های جلسات وب که از منبع داده‌های ثبت رویداد یک کارگزار وب استخراج می‌شود، در الگوریتم‌های مختلف داده‌کاوی مدنظر قرار می‌گیرد. در این تحقیق سعی شد تا با بهینه‌سازی روش‌های قبلی تعیین جلسات که در کارهای قبلی ارائه شده بود، بهترین روش تعیین جلسه معرفی گردد. ما برای انجام مراحل پیش‌پردازش و آماده‌سازی داده‌های ثبت رویداد، یک تحلیلگر داده‌های ثبت رویداد طراحی کردیم و برای تعیین جلسات، استخراج و انتخاب بهترین زیرمجموعه از خصیصه‌ها و برچسب‌دهی به جلسات، از آن استفاده شد. برای ساخت مدل‌های رده‌بندی و ارزیابی آنها، نرم‌افزار داده‌کاوی وکا مورد استفاده قرار گرفت.

در این مطالعه، صرفاً تشخیص روبات‌های وب از سایر مراجعه‌کنندگان مدنظر نبوده و بلکه در یک نوآوری، مدلی برای تشخیص روبات‌های وب مخرب که مشارکت‌کننده در حملات دی‌داس هستند از سایر مرورگران اعم از کاربران انسانی عادی و روبات‌های وب خوش‌رفتار ارائه گردید. برای این منظور قبل از هر چیز براساس ویژگی‌های یک حمله دی‌داس، خصیصه‌های مناسب برای تشخیص این‌گونه روبات‌های وب مخرب حمله‌گر تعریف شد. از طریق توجه به ویژگی‌های حملات دی‌داس و نیز بررسی رفتار مرورگری روبات‌های مخرب، می‌توان به مجموعه‌ای از بهترین خصیصه‌ها برای جداسازی روبات‌های وب مخرب حمله‌گر از سایر مرورگران انسانی و روباتی دست یافت. به همین دلیل ما خصیصه‌ها را به دو دسته تقسیم کردیم: دسته اول خصیصه‌هایی که برای تشخیص هر نوع روباتی قابل استفاده هستند و دسته دوم خصیصه‌هایی که در تشخیص روبات‌های دی‌داس در لایه کاربرد کارایی بهتری را ارائه می‌دهند. براساس این مطالعه، به‌طور کلی هر بردار خصیصه متعلق به یکی از چهار گروه مرورگران انسانی، روبات‌های وب خوش‌رفتار، روبات‌های وب مخرب و مراجعه‌کنندگان ناشناس می‌باشد.

به‌دلیل حجم بالای داده‌های ثبت رویداد، ساخت مدل تشخیص روبات‌های وب مخرب بسیار پیچیده و نیازمند زمان زیادی برای پردازش است. کاهش تعداد خصیصه‌ها یعنی انتخاب چند خصیصه از میان خصیصه‌های استخراج شده، می‌تواند باعث کاهش زمان پردازش و جلوگیری از پیچیدگی مدل گردد. ما از قابلیت‌های وکا برای انتخاب مجموعه‌ای کارامد از خصیصه‌ها، استفاده نمودیم. این کار باعث حذف خصیصه‌های نامرتبط و افزونه شده و نتیجه آن ساخت یک مدل یادگیری اثربخش و کارامد خواهد بود. در واقع از طریق این بخش از چارچوب پیشنهادی، برای هر سایتی می‌توان براساس ویژگی‌های آن، مجموعه مناسبی از خصیصه‌ها جهت بکارگیری در الگوریتم‌های داده‌کاوی، سفارشی‌سازی نمود. در اینجا، ۶ زیرمجموعه خصیصه مختلف به کمک وکا و توسط الگوریتم‌های گوناگون استخراج گردید.

پس از آماده شدن مجموعه داده متشکل از بردارهای خصیصه جلسات وب که به هرکدام برچسب تخصیص داده شده است، کار ساخت مدل‌های مختلف رده‌بندی انجام پذیرفت. در این مرحله، از نرم‌افزار وکا استفاده شده و ۵ رده‌بند روی ۶ مجموعه خصیصه مورد آزمایش قرار گرفت. سپس آزمایشات از لحاظ کارایی و زمان مورد ارزیابی واقع شده و بهترین نتیجه مربوط به الگوریتم درخت تصمیم با مجموعه خصیصه‌های ویژه حملات دی‌داس و صحت ۹۹ درصد بود. برای مقایسه نتیجه این تحقیق با کارهای قبلی، مجموعه خصیصه‌های انتخابی یکی از مهمترین مطالعات در این حوزه، بر روی مجموعه داده موردنظر

آزمایش گردید که نتیجه آن صحت ۹۷ درصد بود و این حکایت از برتری مدل پیشنهادی این تحقیق است.

۶- مراجع

[1] C. Wilson, "Botnets, cyber crime, and cyber terrorism: Vulnerabilities and policy issues for congress," Washington, DC, 2008.

[2] D. Doran and S. S. Gokhale, "Web robot detection techniques: overview and limitations," Data Min. Knowl. Disc., vol. 22, no. 1-2, pp. 183-210, 2011.

[3] T. Kabe and M. Miyazaki, "Determining WWW user-agents from server access log," in Proceedings of seventh international conference on parallel and distributed systems, 2000.

[4] P. Huntington, D. Nicholas, and H. R. Jamali, "Web robot detection in the scholarly information environment," Journal of Information Science, vol. 34, no. 5, pp. 726-741, 2008.

[5] N. Geens, J. Huysmans, and J. Vanthienen, "Evaluation of Web robot discovery techniques: a benchmarking study," Lecture notes in computer science, vol. 4065, no. 1, pp. 121-130, 2006.

[6] W. Guo, S. Ju, and Y. Gu, "Web robot detection techniques based on statistics of their requested URL resources," in Proceedings of ninth international conference on computer supported cooperative work in design, 2005.

[7] O. M. Duskin and D. G. Feitelson, "Distinguishing humans from robots in web search logs: preliminary results using query rates and intervals," in Proceedings of 2009 workshop on Web Search Click Data, 2009.

[8] X. Lin, L. Quan, and H. Wu, "An Automatic Scheme to Categorize User Sessions in Modern HTTP Traffic," in Proceedings of IEEE global telecommunications conference, 2008.

[9] P. N. Tan and V. Kumar, "Discovery of Web Robot Sessions Based on their Navigational Patterns," Data Mining and Knowledge Discovery, vol. 6, no. 1, pp. 9-35, 2002.

[10] C. Bomhardt, W. Gaul, and L. Schmidt-Thieme, "Web Robot Detection - Preprocessing Web Log Files for Robot Detection," New Developments in Classification and Data Analysis, vol. 1, no. 1, pp. 113-124, 2006.

[11] A. Stassopoulou and M. D. Dikaiakos, "Web robot detection - A probabilistic reasoning approach," Computer Networks, vol. 53, no. 3, pp. 265-278, 2009.

[12] W.-Z. Lu and S.-Z. Yu, "Web Robot Detection Based on Hidden Markov Model," in Proceedings of international conference on communications, circuits and systems, 2006.

[13] D. Stevanovic, A. An, and N. Vlajic, "Feature evaluation for web crawler detection with data mining techniques," Expert Systems with Applications, vol. 39, no. 10, pp. 8707-8717, 2012.

[14] D. Stevanovic, N. Vlajic, and A. An, "Detection of malicious and non-malicious website visitors using unsupervised neural network learning," Applied Soft Computing, vol. 13, no. 1, pp. 698–708, 2013.

[15] L. V. Ahn and et al., "CAPTCHA: Using Hard AIP Problems for Security," in Proceedings of Eurocrypt, 2003.

[16] K. Park and et al., "Securing Web Service by Automatic Robot Detection," in Proceedings of the annual conference on USENIX '06 annual technical conference, 2006.

[17] D. Stevanovic and N. Vlajic, "An Integrated Approach to Defence Against Degrading Application-Layer DDoS Attacks," Toronto, Canada, 2013.

[18] H. Liu and V. Keselj, "Combined mining of Web server logs and web contents or classifying user navigation patterns and predicting users' future requests," Data & Knowledge Engineering, vol. 61, no. 2, pp. 304–330, 2007.

[19] 2015. [Online]. Available: http://www.botsvsbrowsers.com/.

[20] 2015. [Online]. Available: http://www.user-agents.org/.

[21] 2015. [Online]. Available: http://www.useragentstring.com/.

[22] K. Selvakuberan, M. Indradevi, and R. Rajaram, "Combined Feature Selection and classification – A novel approach for the categorization of web pages," Journal of Information and Computing Science, vol. 3, no. 2, pp. 83-89, 2008.

[23] L. Yu and H. Liu, "Feature Selection for High-Dimensional Data: A Fast Correlation-Based Filter Solution," in Proceedings of the Twentieth International Conference on Machine Learning (ICML), Washington DC, 2003.

[24] M. Aggarwal and Amrita, "Performance Analysis of Different Feature Selection Methods In Intrusion Detection," International Journal of Scientific & Technology Research, vol. 2, no. 6, pp. 255-231, June 2013.

[25] I. H. Witten, E. Frank, and M. A. Hall, "Data Mining: Practical Machine Learning Tools and Techniques," Burlington: Morgan Kaufmann - Elsevier, 2011.

[26] P. N. Tan, M. Steinbach, and V. Kumar, "Introduction to Data Mining," Pearson Education, Inc., 2006.

[27] "Denial of Service Attacks," [Online]. Available: http://www.cert.org/tech_tips/denial_of_service.html.

[28] C. M. Patel, "Survey On Taxonomy of DDoS Attacks With Impact And Mitigation Techniques," International Journal of Engineering Research & Technology (IJERT), vol. 2, no. 9, pp. 1-8, 2012.

[29] C. Douligeris and A. Mitrokotsa, "DDoS attacks and defense mechanisms: classification and state-of-the-art," Computer Networks, vol. 44, pp. 643-666, 2004.

[30] "Trends in Denial of Service Technology," [Online]. Available: http://www.cert.org/archive/pdf/DoS_trends.pdf.

[31] H.-V. Nguyen and Y. Choi, "Proactive Detection of DDoS Attacks Utilizing k-NN Classifier in an Anti-DDoS Framework," International Journal of Electrical and Electronics Engineering, vol. 4, no. 4, pp. 247-252, 2010.

[32] K. Lee and et al., "DDoS Attack Detection Method Using Cluster Analysis," Expert Systems with Applications, vol. 34, no. 3, pp. 1659-1665, 2008.

[33] J. Mirkovic and P. Reiher, "A Taxonomy of DDoS Attack and DDoS Defense Mechanisms," ACM SIGCOMM Computer Communication Review, vol. 34, no. 2, pp. 39-53, 2004.

[34] P. Zaroo, "A Survey of DDoS attacks and some DDoS defense mechanisms," Advanced Information Assurance (CS 626), 2002.

[35] C. Wilson, "Botnets, cybercrime, and cyberterrorism: Vulnerabilities and policy issues for congress," Washington, DC, 2008.

[36] J. Mirkovic, J. Martin, and P. Reiher, "A Taxonomy of DDoS Attacks and DDoS Defense Mechanisms," Los Angeles, 2002.

[37] T. Peng, L. Christopher, and K. Ramamohanarao, "Survey of network-based defense mechanisms countering the DoS and DDoS problems," ACM Computing Survey, vol. 39, no. 1, pp. 1-42, 2007.

[38] K. Arora, K. Kumar, and M. Sachdeva, "Impact Analysis of Recent DDoS Attacks," International Journal on Computer Science and Engineering (IJCSE), vol. 3, no. 2, pp. 877-884, 2011.

[39] M. H. Bhuyan and et al., "Detecting Distributed Denial of Service Attacks: Methods, Tools and Future Directions," The Computer Journal, 2012.

[40] S. Noel, D. Wijesekera, and C. Youman, "Modern Intrusion Detection, Data Mining, and Degrees of Attack Guilt," in Applications of Data Mining in Computer Security, George Mason, Kluwer Academic Publishers, pp. 1-31, 2003.

[41] P. M. HallamBaker and B. Behlendorf, 2015. [Online]. Available: http://www.w3.org/TR/WDlogfile.html.

[42] J. Lee and et al., "Classification of web robots: An empirical study based on over one billion requests," computers & security, vol. 28, pp. 795–802, 2009.

[43] Z. Chen and W. Feng, "Detecting Impolite Crawler by using Time Series Analysis," in IEEE 25th International Conference on Tools with Artificial Intelligence (ICTAI), pp. 123-126, 2013.

[44] X. Sun and et al., "Feature selection using dynamic weights for classification," Knowledge-Based Systems, vol. 37, no.1, pp. 541–549, 2013.

Journal Of Electronical & Cyber Defence
Vol. 4, No. 2, 2016, Serial No.14

Modeling Browsing Behavior Analysis for Malicious Robot Detection in Distributed Denial of Service Attacks

M. Fathian*, M. Abdollahi Azgomi, H. Dehghani

*Iran University of Science and Technology

(Received: 07/05/2015, Accepted: 03/05/2016)

ABSTRACT

Distributed denial of service (DDoS) attacks are one of the most important threats for E-commerce. Their main goal is to prevent the users from accessing to web sites and internet resources through excessive use of the resources. In these attacks, availability which is one of the elements of security is targeted. One of the ways to achieve this goal is to apply web robots by which the attackers design and carry out the DDoS attacks at application layer. Various methods have been used to distinguish between malicious and non-malicious web robots. One of the most popular methods in the recent years is data mining and machine learning. This method is based on extracting and selecting those features which are fit for web sessions via web server access log files and applying data mining algorithms. Considering the fact that the DDoS attacks are dynamic and customizable, in this research, an attempt is made to present a customizable dynamic defensive mechanism for detecting malicious web robots through the analysis of behaviors of their browsing. At the present study, features extraction was carried out based on the characteristics of DDoS attacks together with optimization of the previous methods to determine web sessions. Furthermore refining the extracted features and selecting a set of efficient features reduced the time required for building a model. As a consequence, the efficiency enhanced by two percent compared to the best similar study.

Keywords: DDoS Attack, E-Commerce Security, Malicious Web Robot Detection, Data Mining

* Corresponding Author Email: fathian@iust.ac.ir