

# مژویی بر حمله‌های انگشت‌نگاری تارنما

مریم طائبی<sup>۱</sup>, علی بهلوانی<sup>۲\*</sup> و مرجان کائیدی<sup>۳</sup>

<sup>۱</sup> کارشناسی ارشد مهندسی کامپیوتر، دانشگاه اصفهان

m.taebi@eng.ui.ac.ir

<sup>۲</sup> استادیار دانشکده مهندسی کامپیوتر، دانشگاه اصفهان

bohlooli@eng.ui.ac.ir

<sup>۳</sup> استادیار دانشکده مهندسی کامپیوتر، دانشگاه اصفهان

kaedi@eng.ui.ac.ir

## چکیده

در حملات انگشت‌نگاری تارنما، مقصود ارتباط کاربر بدون رمزگشایی محتواهای ترافیک، با استفاده از روش‌های تحلیل ترافیک شناسایی می‌شود. در این حملات، به طور معمول کاربران از یکی از فناوری‌های روز (شبکه‌های گمنامی، پراکسی‌ها یا VPN‌ها) برای پنهان کردن محتواهای ترافیک و مقصد واقعی خود استفاده می‌کنند. با استخراج مجموعه‌ای از وبگردی‌ها از دنباله ترافیک ورودی، حمله آغاز می‌شود؛ سپس داده‌ها پیش‌پردازش می‌شوند و در نهایت، از یک الگوریتم یادگیری ماشین برای شناسایی مقصود ترافیک کاربر استفاده می‌شود. پژوهش‌های متنوعی در زمینه شناسایی مقصود ترافیک با بهتر و واضح‌تر، تعیین صفحه وب مرور شده توسط کاربر با بهره‌گیری از روش‌های شناخته شده دسته‌بندی در حوزه یادگیری ماشین انجام گرفته است. در این مقاله، مژویی جامع بر روی روش‌های انگشت‌نگاری تارنما انجام می‌شود که در آن، پژوهش‌های بالا بر اساس وبگردی‌های مورد استفاده برای انگشت‌نگاری، دسته‌بندی با دیدگاهی تازه انجام می‌شود که بنابر دانش‌ما، تاکنون بر روی پژوهش‌های یادشده صورت نگرفته است.

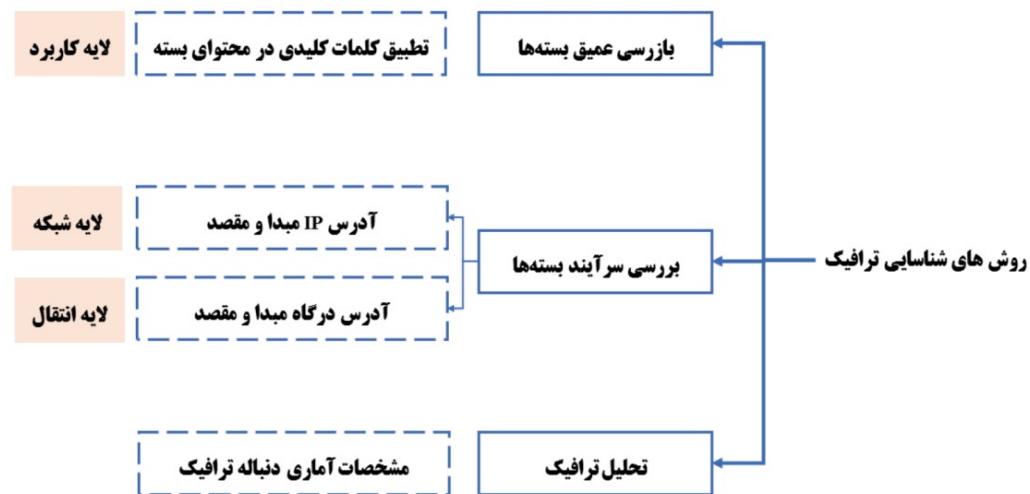
وازگان کلیدی: حمله انگشت‌نگاری تارنما، تحلیل ترافیک، یادگیری ماشین، دسته‌بندی، استخراج وبگردی

## ۱- مقدمه

مثال استفاده از پروتکل HTTPS (HTTP), مانع از دسترسی به محتواهای بسته‌ها و در نتیجه مانع استفاده از روش‌های بازرسی عمیق بسته برای شناسایی مقصود ارتباط می‌شود. روش دیگر برای کشف ارتباط بین فرستنده و گیرنده، استفاده از چهارتایی نشانی IP مبدأ، شماره درگاه مبدأ، نشانی IP مقصود، شماره درگاه مقصد است. معرفی پراکسی‌ها، روش‌های تولیدی ترافیک و شبکه‌های mix<sup>۱</sup> (که با هدف پنهان کردن مبدأ، مقصد و محتوا ارتباط کاربران مختلف به کار می‌رود) و استفاده روزافزون کاربران از آن، بهره‌گیری از نشانی‌های موجود را نیز در لایه شبکه و لایه انتقال برای تعیین مقصد ارتباط با محدودیت مواجه کرده است [۵]. در این شرایط، تشخیص صفحه وب با استفاده از روش‌های تحلیل ترافیک و به کارگیری یکی از روش‌های دسته‌بندی رایج در حوزه یادگیری ماشین انجام می‌شود.

شبکه‌های mix نمونه‌ای از شبکه‌های گمنامی هستند که در آن‌ها برقراری ارتباط بین دو نقطه از طریق زنجیره‌ای از مسیریاب‌ها در یک شبکه روى هم‌گذاري، بین مبدأ و مقصد ارتباط انجام می‌شود. مرور صفحات وب توسط یک کاربر، به تولید داده‌های متنوعی می‌انجامد. موجودیت‌های مختلفی در شبکه قادرند به جمع‌آوری این داده‌ها و استخراج اطلاعات از آن‌ها بپردازنند. این کار با اهداف گوناگونی مانند تحلیل رفتار کاربران برای مسائل اجتماعی و تعیین الگوی علاقه‌مندی کاربران برای تبلیغات انجام می‌شود [۲-۱]. یکی از اطلاعات مورد علاقه، تعیین مقصد ترافیک کاربر در حین مرور وب یا به عبارت دیگر، شناسایی صفحه وب مرور شده توسط کاربر است. روش‌های مختلفی برای دستیابی به این هدف ارائه شده‌اند (شکل ۱). یکی از این روش‌ها، بازرسی عمیق بسته برای کسب اطلاعات از محتواهای بسته‌ها (در لایه کاربرد) و در نتیجه مقصد نهایی ارتباط کاربر است [۳]. در این روش‌ها، بسته‌های جریان ترافیک، برای یافتن الگوها یا کلمات کلیدی خاص بررسی می‌شوند [۴]. این الگوها می‌توانند شامل URL یک صفحه وب یا کلمات کلیدی خاص موجود در URL باشند [۵]. با این حال، استفاده از ترافیک رمزشده در طول یک ارتباط (به عنوان

<sup>۱</sup> شبکه‌های mix نمونه‌ای از شبکه‌های گمنامی هستند که در آن‌ها برقراری ارتباط بین دو نقطه از طریق زنجیره‌ای از مسیریاب‌ها در یک شبکه روى هم‌گذاري، بین مبدأ و مقصد ارتباط انجام می‌شود.



(شکل-۱): روش‌های شناسایی مقصد یک دنباله ترافیک

پس زمینه را تشکیل می‌دهند [۹، ۱۰]. کلیه صفحات موجود در مجموعه تحت نظر را می‌توان در زبان یادگیری ماشین، طبقه مثبت و سایر صفحات را طبقه منفی نامید. در این تنظیمات، مهاجم باید با آموزش دسته‌بند برروی مجموعه صفحات تحت نظر را، تشخیص دهد آیا کاربر یکی از صفحات موجود را در مجموعه تحت نظر (کلاس مثبت) ملاقات کرده است یا صفحه مرور شده در مجموعه بدون نظر (طبقه منفی) قرار دارد [۸]. در یک حمله دقیق‌تر، مهاجم قادر است نوع صفحه ملاقات‌شده توسط کاربر را نیز در مجموعه تحت نظر تشخیص دهد [۹].

در این مقاله، مروری جامع بر روش‌های انگشت‌نگاری تارنما انجام می‌شود. در این مرور، پژوهش‌های بالا برای نخستین بار بر اساس ویژگی‌های مورداستفاده برای انگشت‌نگاری، دسته‌بندی می‌شوند؛ بنابراین مطالعه این پژوهش، به آشنایی با سیر تحول حملات انگشت‌نگاری تارنما در طول زمان، چالش‌های آن‌ها و شناخت مسیر آینده انگشت‌نگاری تارنما کمک می‌کند.

در ادامه این مقاله، در بخش ۲ فرایند مرور وب به اختصار توضیح داده می‌شود. در بخش ۳ حملات انگشت‌نگاری تارنما معرفی شده در پژوهش‌های پیشین در هفت زیربخش دسته‌بندی و بررسی می‌شود. همان‌طور که یاد شد، دسته‌بندی حملات بر اساس ویژگی‌های مورداستفاده برای شناسایی تارنما انجام می‌شود. درنهایت در بخش ۴ مقاله جمع‌بندی می‌شود.

<sup>۴</sup> Non-Monitored set

تحلیل ترافیک به معنای استنتاج اطلاعات از مشخصات آماری یک دنباله ترافیک و حمله انگشت‌نگاری تارنما یک حالت خاص از تحلیل ترافیک با هدف شناسایی مقصد ارتباط کاربر است.

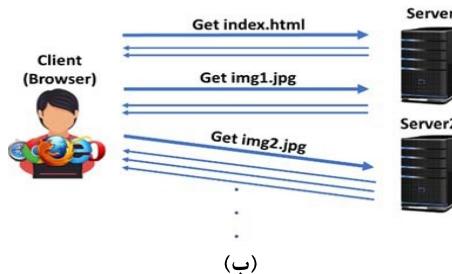
حمله انگشت‌نگاری تارنما را یک مهاجم محلی و منفعل انجام می‌دهد [۶]. منظور از مهاجم محلی و منفعل، گره‌ای است که در مسیر کاربر و پیش از پراکسی یا نخستین گره، در یک شبکه mix (مطابق شکل ۲) قرار می‌گیرد، فقط به جمع‌آوری داده‌های ترافیک می‌پردازد و دخل و تصرفی در دنباله ترافیک ایجاد نمی‌کند. این مسئله باعث می‌شود که مهاجم برای گره‌های موجود در مسیر قبل شناسایی نباشد.

برای تشخیص مقصد ترافیک کاربر، دو رویکرد قابل تصور است: در یک رویکرد، کاربر تنها محدود به ملاقات مجموعه‌ای از صفحات وب تحت عنوان «مجموعه تحت نظرات<sup>۱</sup>» مهاجم است. یک مهاجم، در صورتی قدرت‌مند تلقی می‌شود که با دریافت نمونه ورودی بتواند با دقت مناسب تشخیص دهد کاربر کدامیک از صفحات موجود در مجموعه تحت نظر را بازدید کرده است. این تنظیمات، تنظیمات جهان-بسته<sup>۲</sup> نامیده می‌شود [۷]. در ارزیابی این رویکرد، اساساً توانایی دسته‌بندی الگوریتم‌ها مدنظر است. در رویکرد دیگر (رویکرد جهان-باز<sup>۳</sup>، کاربر اجازه ملاقات کلیه صفحات وب را دارد [۸]. دنباله‌های ترافیکی که در مجموعه تحت نظر این مهاجم قرار نداشته باشند، مجموعه «بدون نظرات<sup>۴</sup>» یا ترافیک

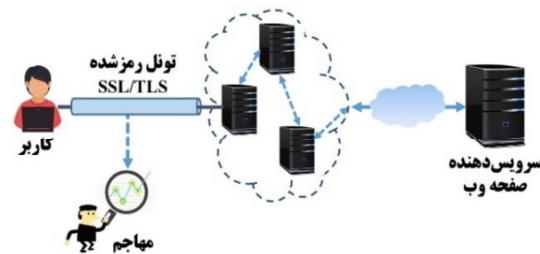
<sup>1</sup> Monitored set

<sup>2</sup> Closed-world

<sup>3</sup> Open-World



(شکل-۳): (الف) ساختار یک صفحه وب – (ب) فرآیند بارگذاری یک صفحه وب



(شکل-۲): سناریوی حمله انگشت‌نگاری تارنما

## ۲- مرور وب

یک صفحه وب، متشکل از یک سند HTML است که ساختار کلی صفحه را تعیین می‌کند و می‌تواند حاوی تعدادی شیء<sup>۱</sup> باشد (شکل-۳-الف). هر شیء می‌تواند یکی از انواع فایل جاوا، یک تصویر JPEG یا PNG، یک فایل ویدئویی، اسکریپت CSS یا انواع دیگر فایل باشد [۱۱]. زمانی که کاربر قصد مشاهده یک صفحه وب را داشته باشد، نشانی URL آن صفحه را در مرورگر خود وارد می‌کند. مرورگر یک اتصال TCP با سرویس‌دهنده مربوط برقرار کرده، سپس با ارسال پیام GET به سرویس‌دهنده موردنظر، نخستین شیء صفحه، یعنی سند HTML را دریافت می‌کند. مرورگر پس از پردازش صفحه، فهرستی از اشیای صفحه را استخراج می‌کند. در پروتکل HTTP، هر شیء معادل یک منبع<sup>۲</sup> با شناسه یکتای URI است. برای دریافت هر شیء، نخست یک اتصال به سرویس‌دهنده دارنده آن منبع برقرار می‌شود؛ سپس درخواست GET حاوی شناسه منبع به سرویس‌دهنده ارسال می‌شود، به عبارت دیگر، ممکن است منابع مختلف یک صفحه در سرویس‌دهنده‌های مختلفی قرار گرفته باشند و برای دریافت هر کدام لازم است یک اتصال جداگانه TCP به سرویس‌دهنده موردنظر برقرار شود [۱۲] (شکل-۳-ب).



(الف)

<sup>۳</sup> Stateless

<sup>۴</sup> بر اساس گزارش w3techs [۱۴] در حال حاضر ۸۶/۴ درصد از

کل وب سایتها از دنیا از پروتکل HTTP/1.1 استفاده می‌کنند.

<sup>۵</sup> Persistent

<sup>۶</sup> HTTP Pipelining

<sup>۱</sup> Object  
<sup>۲</sup> Resource

### ۳- حملات انگشت‌نگاری صفحات وب

[۱۷] برای صفحات وب گوناگون، نمایه‌ای شامل جفت اندازه کد HTML، اندازه شیء ایجاد و در یک پایگاه داده ذخیره می‌شود، سپس، با در نظر گرفتن سه صفحه وب پی‌درپی ملاقات‌شده توسط کاربر و رجوع به پایگاه داده، احتمال بازدید یک صفحه وب به کمک الگوریتم تحلیل لینک محاسبه می‌شود و صفحه با امتیاز بیشتر به عنوان صفحه ملاقات‌شده توسط کاربر اعلام می‌شود. در این الگوریتم، یک صفحه وب از پایگاه داده به طور تصادفی انتخاب می‌شود؛ سپس، برای نمونه ورودی جدید، احتمال این که صفحه مورد نظر، صفحه p باشد، مطابق رابطه (۱) محاسبه می‌شود و بالاترین امتیاز، مشخص کننده صفحه وب نمونه جدید است. در این رابطه،  $p^{-1}$  معادل احتمال بازدید صفحه p بلافاصله پس از بازدید صفحه  $p^{-1}$  و  $p^{+1}$  احتمال بازدید صفحه  $p^{+1}$  بی‌درنگ پس از بازدید p است (بنابراین این روش نیاز به پایگاه داده بزرگی از رفتارهای کاربر در هنگام بازدید صفحات وب دارد).

$$P(\text{page}) = P(p^{-1}) \cdot P(p^{+1}) \quad (1)$$

هینتر [۱۸] نشان داد که با در نظر گرفتن اندازه اشیای موجود در یک صفحه و تعداد دفعات تکرار این اندازه، برای هر صفحه یک نمایه یکتا می‌توان ایجاد کرد؛ سپس، با مقایسه تعداد تطبیق‌های موجود بین نمایه یک صفحه وب مشخص با نمایه نمونه جدید، می‌توان درباره نوع ترافیک نمونه جدید تضمیم‌گیری کرد. در این پژوهش، شناسایی با این فرض انجام شد که کاربران از پراکسی تک گام SafeWeb استفاده می‌کنند و ارزیابی روش پیشنهادی برای شناسایی پنج صفحه وب خبری مشهور نشان داد که حتی با وجود پراکسی و داده‌های رمزشده نیز امکان شناسایی صفحات وب وجود دارد؛ بطوطور مشابه، سان و همکاران [۱۹] با در نظر گرفتن تعداد و اندازه اشیای واکشی‌شده توسط مرورگر و انتخاب معیار مشابه ضریب جاکارد<sup>۳</sup>، شناسایی یک صفحه وب از میان مجموعه‌ای از صفحات هدف را بررسی کردند.

در پژوهش‌های یادشده، استفاده از ترافیک TCP ناپایدار<sup>۴</sup> برای تبادل داده بین مشتری و سرویس‌دهنده، امکان دسترسی به تعداد و سایز اشیا را فراهم می‌کرد. در حال حاضر، با فرآیند استفاده از پروتکل HTTP/1.1 دسترسی به اندازه شیء‌های موجود در صفحه امکان‌پذیر نیست.

در روش‌های انگشت‌نگاری تارنما، برای هر صفحه وب تحت نظرارت مهاجم براساس نمونه‌های آموزشی آن صفحه، به صورت صریح یا ضمنی یک نمایه<sup>۱</sup> جدید ایجاد می‌شود. برای شناسایی هر دنباله بسته جدید، این نمایه به همراه نمایه ایجادشده از نمونه جدید، به عنوان ورودی الگوریتم یادگیری ماشین یا یک روش آماری استفاده می‌شود.

در این بخش، حملات انگشت‌نگاری، به تفکیک ویژگی‌های مورد استفاده و نمایه‌های ایجادشده برای هر صفحه وب در هفت زیربخش، بررسی می‌شود؛ هم‌چنین ستاربیو، نحوه ارزیابی حمله ارائه شده در هر پژوهش و سایر جزئیات مربوط به آن، در صورت لزوم بیان می‌شود. ناگفته نماند که فرض نخستین تمامی این روش‌ها انتقال ترافیک کاربر به صورت رمزشده است.

در جدول‌های (۱ تا ۳) و جدول‌های (۶ و ۷) روش‌های معرفی شده در این بخش، مجموعه داده‌های مورد استفاده و نتایج حاصل از ارزیابی هر روش، بر حسب دقت<sup>۲</sup> گزارش شده در آن پژوهش، به اختصار آمده است. یادآوری می‌شود که پارامترهای مربوط به پیاده‌سازی هر روش، از جمله اندازه مجموعه‌های آموزش و آزمون و مجموعه داده استفاده شده در هر پژوهش، متفاوت است؛ هم‌چنین به دلیل نبود اطلاعات کافی درباره سرعت اجرای برخی از روش‌های معرفی شده در پژوهش‌های بالا، این شاخصه در جدول ذکر نشده است.

### ۱-۳- حملات مبتنی بر اندازه شیء

در نخستین حملات شناسایی ترافیک رمزشده، از اندازه اشیای موجود در هر صفحه برای شناسایی صفحه استفاده می‌شد [۱۹-۱۶] (جدول ۱).

با ظهور پروتکل SSL3.0، تلاش‌هایی برای بررسی میزان امنیت و میزان نشت اطلاعات در انتقال ترافیک با استفاده از این پروتکل انجام شد. در یکی از نخستین بررسی‌های انجام‌شده در تحلیل پروتکل SSL، بیان شد که شناسایی ترافیک یک صفحه وب مشاهده شده توسط کاربر با تحلیل طول درخواست GET رمزشده توسط پروتکل SSL امکان‌پذیر است [۱۶]. در روش استفاده شده چنگ و آنور

<sup>3</sup> Jaccard coefficient

<sup>4</sup> Non-persistent TCP

<sup>۱</sup> Profile

<sup>۲</sup> Accuracy

## مروری بر حمله‌های انگشت‌نگاری تارنما

(جدول-۱): حملات انگشت‌نگاری صفحات وب معرفی شده در بخش‌های ۱-۳-۳ - دقت ثبت شده در جدول، بر حسب درصد و مربوط به نتایج به دست آمده از هر پژوهش با در نظر گرفتن مجموعه داده و نوع ارزیابی گفته شده در ستون ارزیابی جدول است.

ردیف	عنوان	نويسنده	عنوان	روش دسته‌بندی	مجموعه ويژگی‌ها	مجموعه داده	عنوان
۱	چنگ و آونور [۱۷] (۱۹۹۸)	محاسبه احتمال ملاقات یک صفحه بر اساس صفحات قبلی و بعدی در یک تارنما	اندازه کد HTML، اندازه شیء	صفحات و ب سه تارنمای Unex <sup>۱</sup> ، Enough <sup>۲</sup> و Spectator <sup>۳</sup> بارگذاری شده با پروتکل HTTP			
۲	هینترز (۲۰۰۳) [۱۸]	مقایسه تعداد تطبیق در نمونه جدید و نمونه موجود در پایگاه داده	اندازه اشیای صفحه، تعداد دفاتر تکرار هر اندازه	صفحات وب پنج تارنمای خبری CNN <sup>۴</sup> ، BBC <sup>۵</sup> ، نیویورک تایمز <sup>۶</sup> ، اسلش دات <sup>۷</sup> و واشینگتن Safeweb <sup>۸</sup> پست <sup>۹</sup> بارگذاری شده با			
۳	سان و همکاران [۱۹] (۲۰۰۲)	ضریب جاکارد	تعداد و اندازه شیء‌های واکنش‌شده توسط مرورگر	صفحات بارگذاری شده از پایگاه داده DMOZ <sup>۱۰</sup>			
۴	شماتیکوف و وانگ (۲۰۰۶) [۲۰]	آزمون همبستگی	زمانی به طول W در دنباله زمانی بسته‌های پنجره‌های HTTP NLANR <sup>۱۱</sup> شامل دنباله‌های ترافیک	شبیه‌سازی ترافیک با استفاده از مجموعه داده			
۵	بیسیاس و همکاران (۲۰۰۵) [۲۳]	آزمون همبستگی	دبالة طول بسته، دنباله زمانی بین ورود	ترافیک HTTP تونل شده با OpenSSH [۲۴]			

باشد (طبق رابطه (۳)), دو دنباله مشابه یکدیگر تشخیص داده‌می‌شوند؛ (به عبارت دیگر، مقصد ترافیک هر دنباله یکسان در نظر گرفته‌می‌شود).

$$\chi(P_i, P_c) = \frac{\sum_j (P_{i,j} - \mu_{P_i})(P_{c,j} - \mu_{P_c})}{\sigma_{P_i}\sigma_{P_c}}, \quad (2)$$

$$(\sigma_Q) = \sqrt{\frac{1}{|Q|} \sum_{j=1}^{|Q|} (Q_j - \bar{Q})^2},$$

$$\mu_Q = \frac{\sum_{j=1}^{|Q|} Q_j}{|Q|}$$

$$\ell(P_i) = argmax_{c \in T} (\chi(P_i, P_c) > \tau) \quad (3)$$

### ۳-۳- حملات مبتنی بر زمان بین ورود و اندازه

#### بسته‌ها

بیسیاس و همکاران [۲۳] دنباله‌های رمزشده HTTP و به طور ویژه جریان‌های رمزشده با پروتکل IPSec/WEP/WPA یا تونل‌های SSH را (که در آن‌ها نشانی مقصد جریان داده به دلیل رمزشدن سرایند بسته‌های IP در دسترس نیست)، مدنظر قرار دادند. در این پژوهش، دنباله‌های صد صفحه وب در طول مدت دو ماه جمع‌آوری شد (این مجموعه با نام WebIdent در پایگاه داده شبکه دانشگاه ماساچوست آمرست قابل دسترسی است [۲۴]). برای هر دنباله، طول بسته‌ها و

### ۲-۳- حملات مبتنی بر تعداد بسته‌های دنباله

در پژوهش شماتیکوف و وانگ [۲۰] شبکه‌های mix (مانند شبکه‌های معرفی شده در پژوهش دینگلداين و همکاران [۲۱] و پژوهش فریدمن و موریس [۲۲]), به عنوان بستر تبادل اطلاعات کاربران به‌منظور پنهان کردن مبدأ و مقصد ارتباط در نظر گرفته شدند و روشی برای شناسایی صفحات وب مورورشده توسط کاربر ارائه شد. در این روش، مهاجم در بازه زمانی شصت ثانیه به مشاهده ترافیک می‌پردازد؛ سپس این بازه را به پنجره‌های زمانی با طول W تقسیم می‌کند. با شمارش تعداد بسته‌های موجود در هر پنجره، یک دنباله عددی برای هر ترافیک ایجاد می‌شود ( $P_i$ ). به‌منظور شناسایی ترافیک، همبستگی<sup>۱۱</sup> بین  $P_i$  و دنباله‌های  $P_c$  موجود در مجموعه آموزشی  $(P_i, P_c) \chi(P_i, P_c)$  مطابق با رابطه (۲) محاسبه شده و در صورتی که عدد به دست آمده از یک حد آستانه ( $\tau$ ) بیشتر

<sup>1</sup> www.enough.org

<sup>2</sup> http://www.unex.berkeley.edu:4243

<sup>3</sup> www.spectator.org

<sup>4</sup> www.cnn.com

<sup>5</sup> www.bbc.co.uk

<sup>6</sup> www.nytimes.com

<sup>7</sup> slashdot.org

<sup>8</sup> www.washingtonpost.com

<sup>9</sup> DMOZ Open Directory Project link database (DMOZ.org)

<sup>10</sup> National Laboratory for Applied Network Research (pma.nlanr.net)

<sup>11</sup> Cross-correlation

(مجموعه نمایه ایجادشده برای یک صفحه وب را  $X$  و مقادیر جمع‌آوری شده برای ترافیک ورودی را  $Y$  می‌نامیم).

$$\ell(P_i) = \operatorname{argmax}_{c \in T} S(X_c, Y) = \frac{\operatorname{argmax}_{c \in T} |X_c \cap Y|}{\operatorname{argmax}_{c \in T} |X_c \cup Y|} \quad (5)$$

در همین پژوهش [۲۶]، از دسته‌بند بیز ساده<sup>۱</sup> برای دسته‌بندی ترافیک جدید استفاده شد. در این روش هر اندازه یکتای بسته (با در نظر گرفتن جهت آن) یک ویژگی محسوب می‌شود و مقدار هر ویژگی برابر با تعداد تکرار اندازه بسته موردنظر است. مجموعه ویژگی به‌دست‌آمده به‌صورت  $P.S$  خواهد بود.

$P.S = \{(s_1, \text{cnt}_{s_1}), (s_2, \text{cnt}_{s_2}), \dots, (s_n, \text{cnt}_{s_n})\}$  برای شناسایی یک صفحه وب تازه، احتمال تعلق نمونه  $P_i$  به کلاس  $C$  به‌ازای کلیه صفحات وب تحت‌نظرارت محاسبه می‌شود (رابطه (۶)). واضح است که در این روش، دقت دسته‌بندی وابسته به تعداد دقیق دفعات تکرار طول بسته‌ها (مشخصه  $\text{cnt}_{s_i}$ ) است.

$$p(P_i \in C) = \frac{P(C)p(P.S|C)}{P(P.S)} \propto p(C) \prod_{j=1}^n p(\text{cnt}_{s_j}|C) \quad (6)$$

در پژوهش یادشده، ترافیک HTTP رمزشده در توپل‌های چندگام (مثل Tor و JAP)، توپل‌های SSH و IPSec و اتصالات رمزشده توسط پروتکل WPA گرفته‌است و در پیاده‌سازی از OpenSSH و پراکسی SOCKS استفاده شده است [۲۷].

به طور مشابه، در پژوهش هرمن و همکاران [۶]، شناسایی ترافیک صفحات وب برای شبکه‌های ناشناس Tor، JAP و STunnel با هم‌چنین بر روی OpenVPN، OpenSSH و استفاده از روش بیز ساده چندجمله‌ای پیاده شد. روش بیز چندجمله‌ای به‌طور معمول برای دسته‌بندی متن استفاده می‌شود. یک دنباله بسته را با همه اندازه‌های بسته مشاهده شده در آن می‌توان مشابه یک متن شامل تعدادی کلمه با تعداد تکرارهای گوناگون در نظر گرفت. در این رویکرد،  $P(S|C)$  در فرمول بیز ساده مطابق رابطه (۷) محاسبه می‌شود.

<sup>۱</sup> Naïve Bayes

زمان بین ورود آن‌ها به صورت  $\{t_1, t_2, \dots, t_n\}$  و  $I.T = \{s_1, s_2, \dots, s_n\}$  استخراج شد. به‌منظور ایجاد نمایه هر صفحه وب، برای هر دو دنباله زمان بین ورود و اندازه متوسط همه مقادیر  $x_i$  ( $i \in [1, n]$ ) محاسبه و دنباله‌های جدید  $\widehat{I.T}$  و  $\widehat{P.S}$  با این مقادیر ایجاد شد. به‌منظور شناسایی مقصد ترافیک ورودی جدید ( $P_i$ )، همبستگی بین دنباله جدید و نمایه ایجادشده برای هر صفحه وب به‌ازای هر دو دنباله اندازه و زمان بین ورود اندازه‌گیری می‌شود و حاصل ضرب دو مقدار محاسبه می‌شود (رابطه (۴)).

$$\ell(P_i) = \operatorname{argmax}_{c \in T} (\chi(P.S_i, \widehat{P.S}_c) \chi(I.T_i, \widehat{I.T}_c)) \quad (4)$$

عدد به‌دست‌آمده به‌عنوان امتیاز شباهت صفحه وب تازه و نمایه صفحات وب موجود در مجموعه آموزشی در نظر گرفته می‌شود. بالاترین امتیاز به‌دست‌آمده به‌عنوان پیش‌بینی مقصد ترافیک جدید انتخاب می‌شود.

### ۳-۴- حملات مبتنی بر اندازه و جهت بسته‌های

#### دنباله

نخستین روش شناسایی مقصد ترافیک بر اساس اندازه بسته، توسط میستری و رامان [۲۵] و بر روی چهار سایت و صفحات آن‌ها انجام شد و نشان داده شد که ترافیک SSL به‌تهاهای قابلیت حفظ محموله اطلاعات کاربر را ندارد. این کار با مقایسه طول بسته‌های دریافت شده از سرویس‌دهنده با طول بسته‌های یک نمونه ترافیک جدید انجام گرفت.

در روش ارائه شده توسط لیبراتور و لوین [۲۶] به‌ازای هر صفحه وب موجود در مجموعه تحت‌نظرارت مهاجم، مجموعه‌ای از دوتایی‌های جهت-اندازه تشکیل می‌شود. در صورتی که دوتایی جهت-اندازه با مقدار مشخص در بینشینه داده‌های آموزشی متعلق به یک صفحه، موجود باشد، این دوتایی به نمایه صفحه وب موردنظر مهاجم اضافه می‌شود؛ به عبارت دیگر، در این روش، بردار ویژگی یا نمایه هر طبقه (هر صفحه وب)، فهرستی از اندازه بسته‌های است. به‌منظور شناسایی مقصد ترافیک ورودی (صفحه وب بازدیدشده)، میزان شباهت ترافیک جدید با هر کدام از نمایه‌های از پیش جمع‌آوری شده با ضریب جاکارد (رابطه (۵)) محاسبه می‌شود. ترافیک جدید، مربوط به صفحه وب با بالاترین امتیاز شباهت خواهد بود.

(جدول-۲): حملات انگشت‌نگاری صفحات وب مبتنی بر بسته‌های دنباله – دقیق ثبت شده در جدول بر حسب درصد و مربوط به نتایج بدست آمده از هر پژوهش با در نظر گرفتن مجموعه داده و نوع ارزیابی گفته شده در ستون ارزیابی جدول است.

ردیف	نام	نوع	مجموعه داده	مجموعه ویژگی‌ها	روش دسته‌بندی	نویسنده	سال
۱	ناموجود	-	ترافیک HTTPS صفحات وب چهار تارنمای ISSAC <sup>۱</sup> , Wells Fargo <sup>۲</sup> , INDEX <sup>۳</sup> و Datek <sup>۴</sup>	طول بسته‌های ورودی	مقایسه نمونه جدید با نمونه‌های موجود در پایگاه داده	میستری و رامان (۱۹۹۸) [۲۵]	
۲	۸۶٪.	شبکه	ترافیک جمع‌آوری شده HTTP [۲۷] OpenSSH تونل شده با	مجموعه دوتایی‌های اندازه-جهت	ضریب جاکارد	لیبراتور و لوین (۲۰۰۶) [۲۶]	
۳	۸۳٪.	شبکه	ترافیک جمع‌آوری شده HTTP [۲۷] OpenSSH تونل شده با	(اندازه، جهت) بسته، تعداد تکرار هر (اندازه، جهت)	بیز ساده	لیبراتور و لوین (۲۰۰۶) [۲۶]	
۴	۹۶/۶۵٪. (OpenSSH) ۲/۹۶٪. (Tor)	شبکه	CiscoVPN ، STunnel ، OpenSSH و ترافیک شبکه OpenVPN چندگام Tor	همه اندازه-جهت‌های مشاهده شده در دنباله صفحات گوناگون	بیز چندجمله‌ای	هرمن و همکاران (۲۰۰۹) [۶]	

پژوهش فرض ناپایداری‌بودن اتصالات TCP در نظر گرفته شده است.

مشابه روش‌های پیشین، لو و همکاران [۲۸] برای شناسایی صفحه وب، ترافیک HTTP رمزشده را که توسط VPN یا SSH تونل شده است، انتخاب کردند و به این منظور، از دو مجموعه داده شامل دنباله‌های بسته بارگذاری صفحات توسط OpenVPN و OpenSSH استفاده کردند. در این روش از پروتکل HTTP پایدار برای بارگذاری صفحات استفاده شد. دنباله طول بسته‌ها (P) با در نظر گرفتن ترتیب آنها به دو دنباله شامل بسته‌های درخواست (P<sup>Request</sup>) و بسته‌های پاسخ (P<sup>Response</sup>) تقسیم شد. بسته‌هایی که در دنباله پاسخ، طولی برابر با حداقل اندازه قابل انتقال (MTU<sup>۵</sup>) داشتند، حذف شدند؛ همچنین، بسته‌هایی با طول کمتر از یک حد

$$P(P, S | C) \propto \prod_{j=1}^m p(s_j | C)^{cnt_{s_j}} \quad (7)$$

ارزیابی‌های این پژوهش نشان داد که روش ارائه شده برای شناسایی صفحات وب در سامانه‌های تک‌گام مؤثر است، اما برای شبکه‌های پراکسی چندگام Tor و JAP ناموفق عمل می‌کند. حملات معرفی شده در این بخش در جدول (۲) نمایش داده شده‌است.

### ۳-۵- حملات مبتنی بر ترتیب بسته‌های دنباله

در پژوهش‌های بیان شده در بخش‌های پیش، هر نمایه با استفاده از ویژگی‌های یادشده و صرفاً به صورت مجموعه‌ای از اعداد تشکیل می‌شد. هینتر [۱۸] به منظور بهبود حمله انگشت‌نگاری صفحات وب، ترتیب ارسال درخواست و دریافت اشیا را بررسی کرد و نشان داد که در مرورگرهای مختلف، این ترتیب متفاوت است و برای هر مرورگر ویژه، ترتیب بسته‌ها ثابت است. اگرچه، همان‌طور که پیشتر گفته شد در این

<sup>۱</sup> www.issac.cs.berkeley.edu

<sup>۲</sup> www.index.berkeley.edu

<sup>۳</sup> Banking.wellsfargo.com

<sup>۴</sup> Orders.datek.com

<sup>۵</sup> Maximum Transfer Unit

### ۶-۳- حملات مبتنی بر مجموعه ویژگی‌ها

از سال ۲۰۱۱ ویژگی‌های انتخابی برای شناسایی تارنما کامل‌تر شدند و جزئیات بیشتری از فرآیند بارگذاری صفحات در نظر گرفته شد. پژوهش پانچنکو و همکاران<sup>۸</sup> [۳۰] نخستین پژوهشی بود که در آن شناسایی ترافیک در بستر شبکه‌های گمناسی از جمله شبکه Tor و JAP بررسی و به آن بسیار توجه شد. در این اثر، همچنین مفهوم نشان‌گر اندازه<sup>۹</sup> (به معنای محل تغییر جهت بسته‌ها در یک دنباله)، برای نخستین بار معرفی و از این ویژگی برای دسته‌بندی استفاده شد؛ همچنین، با حذف بسته‌هایی با سایز ۵۲ بایت در دنباله به عنوان بسته‌های تصدیق دریافت (ACK)، دقت مطلوبی در شناسایی ترافیک در حضور شبکه Tor بدست آمد. ویژگی‌های مورداستفاده در این پژوهش مطابق جدول (۴) است.

در این پژوهش از ماشین بردار پشتیبان (SVM)<sup>۱۰</sup> به منظور دسته‌بندی و شناسایی ترافیک تولید شده توسط شبکه‌های Tor و JAP استفاده شد.

ایده اصلی SVM تبدیل نمونه‌ها به مجموعه‌ای از بردارهایست. با بارگذاری هر صفحه وب، داده‌های خام (دنباله بسته‌های ترافیک) به‌ازای هر صفحه به دست می‌آید و مجموعه ویژگی‌ها از هر دنباله استخراج می‌شود. دسته‌بند تلاش می‌کند تا بر اساس داده آموزشی، یک ابرصفحه جداکننده<sup>۱۱</sup> را به فضای برداری نگاشت کند، بهصورتی که فاصله نمونه‌های آموزشی موجود در دسته‌های گوناگون در راستای عمود بر این ابرصفحه بیشترین مقدار ممکن باشد. اگر حاشیه<sup>۱۲</sup> یک ابرصفحه بهصورت مجموع فواصل نزدیک‌ترین نقاط آموزشی هر کلاس به ابرصفحه (بردارهای پشتیبان هر کلاس) تعریف کنیم، ابرصفحه جداکننده یا مرز تصمیم‌گیری مناسب برای دسته‌بندی، ابرصفحه‌ای با بیشترین مقدار حاشیه خواهد بود [۳۱]. درصورتی که بردارها به صورت خطی قابل جداسازی نباشند، فضای برداری به فضایی با بعد بیشتر تبدیل می‌شود و باز دیگر یک ابرصفحه برای نگاشت جستجو می‌شود [۳۰].

دایر و همکاران<sup>۱۳</sup> [۳۲] تلاش کردند با در نظر گرفتن سه دسته از ویژگی‌های کلی ترافیک (صرف‌نظر از ویژگی‌هایی مانند طول بسته‌های منفرد موجود در دنباله که در

آستانه به عنوان بسته‌های کنترلی جربان در نظر گرفته شده و حذف شدند. به این ترتیب، برای هر صفحه وب موردنظر، یک نمایه شامل دو دنباله بالا ایجاد شد. برای شناسایی هر صفحه ورودی جدید، از فاصله ویرایش لونشتاین<sup>۱</sup> استفاده شد. فاصله لونشتاین تعداد عملیات درج<sup>۲</sup>، حذف<sup>۳</sup> و جایگذاری<sup>۴</sup> لازم را برای تبدیل یک دنباله به دنباله دیگر نشان می‌دهد. فاصله نمایه صفحات وب با نمونه جدید از رابطه (۸) تعیین می‌شود. کمترین فاصله، نشان‌دهنده صفحه وب موردنظر خواهد بود.

$$d(P_i, P_c) = \alpha \cdot d_{lev}(P_i^{\text{Request}}, P_c^{\text{Request}}) + (1 - \alpha) \cdot d_{lev}(P_i^{\text{Response}}, P_c^{\text{Response}}), \quad (8)$$

$$\alpha = 0.6$$

در پژوهش کای و همکاران [۲۹] و همچنین در پژوهش وانگ و گلدبیرگ [۱۱]، هر دنباله ترافیک بهصورت رشته‌ای از اعداد صحیح شامل طول بسته‌های دنباله (با حفظ ترتیب) در نظر گرفته شد و برای احتساب جهت هر بسته، علامت مثبت برای بسته‌های خروجی و علامت منفی برای بسته‌های ورودی تعیین شد؛ همچنین در هر دو روش، شناسایی صفحه وب با استفاده از دسته‌بند SVM انجام گرفت، با این تفاوت که برای محاسبه فاصله بین نقاط داده (دنباله‌ای ترافیک) از دو معیار جدید استفاده شد که بهطورعموم در مسائل متن‌کاوی و برای تطبیق کلمات به کار می‌رond. در روش کای و همکاران [۲۹]، فاصله بهینه تطبیق رشته (OSAD)<sup>۵</sup> (با افزودن عملیات انتقال<sup>۶</sup> به مجموعه عملیات لونشتاین) استفاده شد. هرچند به عملیات انتقال هزینه کمتری نسبت به عملیات درج و حذف اختصاص یافت. در روش وانگ و گلدبیرگ [۱۱] از فاصله دامرا-لونشتاین (DLD)<sup>۷</sup> برای محاسبه فاصله بین دنباله‌های ترافیک استفاده شد. در این پژوهش برای دستیابی به دقت مناسب، عملیات جایگذاری از مجموعه عملیات ممکن در روش لونشتاین حذف شد؛ همچنین، هزینه عملیات ویرایش برای بسته‌های خروجی و ورودی و برای ابتدا و انتهای دنباله، متفاوت در نظر گرفته شد. خلاصه چهار حمله بالا در جدول (۳) آمده است.

<sup>1</sup> Levenshtein Edit Distance

<sup>2</sup> Insertion

<sup>3</sup> Deletion

<sup>4</sup> Substitution

<sup>5</sup> Optimal String Alignment Distance

<sup>6</sup> Transposition

<sup>7</sup> Damerau-Levenshtein distance

(جدول-۳): حملات انگشت‌نگاری صفحات وب مبتنی بر ترتیب بسته‌های دنباله – دقت ثبت‌شده در جدول بر حسب درصد و مربوط به نتایج به دست آمده از هر پژوهش با در نظر گرفتن مجموعه داده و نوع ارزیابی گفته شده در ستون ارزیابی جدول است.

ردیف	عنوان	نوع	مجموعه داده	مجموعه ویژگی‌ها	روش دسته‌بندی	نویسنده	سال
۱	گزارش نشده	عکس	مشابه ردیف ۲ جدول	دنباله اندازه اشیاء و تعداد تکرار هر اندازه (با در نظر گرفتن ترتیب)	مقایسه تعداد تطبیق در نمونه جدید و نمونه موجود در پایگاه داده	هینترز(۲۰۰۳) [۱۸]	
۲	۸۱٪ (OpenSSH)	عکس	ترافیک HTTP توپل شده با OpenSSH [۲۷]	دنباله طول بسته‌های ورودی، دنباله طول بسته‌های خروجی	فاصله لونشتابی	لو و همکاران (۲۰۱۰) [۲۸]	
۳	۹۷٪ (OpenVPN)	عکس	ترافیک توپلید شده توسط مرورگر Tor [۳۸] و ترافیک توپل شده با OpenSSH	رشته مرتب شده از اعداد صحیح شامل طول بسته‌های دنباله	محاسبه فاصله بین نمونه‌ها به روش OSAD و دسته‌بند SVM	کای و همکاران (۲۰۱۲) [۲۹]	
۴	۹۱٪ (OpenSSH)	عکس	ترافیک صفحات وب تولید شده توسط مرورگر Tor [۳۸]	رشته مرتب شده از اعداد صحیح شامل طول بسته‌های دنباله	محاسبه فاصله بین نمونه‌ها به روش دامرا-لونشتابی و دسته‌بند SVM	وانگ و گلدبرگ (۲۰۱۳) [۱]	
	۸۳٪ (Tor)	عکس	ترافیک صفحات وب تولید شده توسط مرورگر Tor	رشته مرتب شده از اعداد صحیح شامل طول بسته‌های دنباله	محاسبه فاصله بین نمونه‌ها به روش دامرا-لونشتابی و دسته‌بند SVM	وانگ و گلدبرگ (۲۰۱۳) [۱]	
	۹۱٪ (closed world)	عکس	ترافیک صفحات وب تولید شده توسط مرورگر Tor	رشته مرتب شده از اعداد صحیح شامل طول بسته‌های دنباله	محاسبه فاصله بین نمونه‌ها به روش دامرا-لونشتابی و دسته‌بند SVM	وانگ و گلدبرگ (۲۰۱۳) [۱]	
	۹۰٪ (open world)	عکس					

صفحات وب به کار گرفتند که به طور تقریبی شامل ۴۰۰۰ ویژگی بود (جدول ۵). در این پژوهش جزئیات کامل دنباله ترافیک برای تعداد زیادی از بسته‌های ابتدایی جریان ترافیک استفاده شد که این امر اندازه مجموعه ویژگی‌ها را افزایش داده است. در این روش، دسته‌بندی با الگوریتم K-نزدیک‌ترین همسایه (KNN)<sup>۲</sup> انجام می‌شود و دسته‌بندی تنها زمانی نمونه جدید را به یک دسته منتسب می‌کند که هر K همسایه به آن دسته تعلق داشته باشد.

به منظور بهبود دقت شناسایی، روشی برای اختصاص وزن به مجموعه ویژگی‌ها ارائه شد که طی آن وزن هر ویژگی ( $W_i$ ) در یک الگوریتم تکرارشونده محاسبه می‌شود و سپس در محاسبه فاصله بین نمونه‌های آموزشی و نمونه جدید اعمال می‌شود. رابطه (۹)، فاصله وزن دار بین نمونه آموزشی  $P_i$  و نمونه آزمون  $P_h$  را برای  $n$  ویژگی با مقادیر  $p$  نشان می‌دهد. استفاده از روش تخصیص وزن ویژگی‌ها به انتخاب ویژگی‌های مؤثر در دسته‌بندی و بهبود دقت دسته‌بند کمک می‌کند.

<sup>2</sup> K-Nearest Neighbor

پژوهش‌های پیشین استفاده می‌شد؛ همچنین با کمک الگوریتم بیز ساده روشی با پیچیدگی کمتر ارائه دهنده.

به این منظور، هر کدام از سه ویژگی «زمان کل ارتباط»، «پهنه‌ای باند در هر طرف ارتباط» و «الگوی بسته‌های متوالی همجهت<sup>۱</sup>» در ترافیک به صورت N-Gram با طول N-Gram متغیر استفاده شدند. درواقع در این روش، یک عبارت است از مجموعه جهت‌اندازه کلیه بسته‌های متوالی همجهت که در دنباله موجودند. همچنین این پژوهش‌گران با ترکیب این سه ویژگی، یک دسته‌بند دیگر ارائه کردند که ساده‌تر از روش پانچنکو و همکاران [۳۰] بود، اما از لحاظ دقت نسبت به روش قبلی بهبود چشم‌گیری نداشت. در این پژوهش دسته‌بندی بر روی ترافیک HTTP رمزشده توسط TLS و IPSec که در پژوهش‌های قبلی جمع‌آوری شده بود، انجام گرفت.

وانگ و همکاران [۹] در مقایسه با پژوهش‌های پیشین، بزرگ‌ترین مجموعه ویژگی‌ها را برای شناسایی ترافیک

<sup>1</sup> Burst

دققت پایدارتری دارد (در این پژوهش، برای مقایسه تارنما و صفحه وب، ابتدا صفحه خانه تارنمای موردنظر و سپس صفحات گوناگونی از هر تارنما بارگذاری و ترافیک آنها جمع‌آوری شده است). آندری پانچنکو مجموعه داده جمع‌آوری شده توسط مرورگر تور را برای این پژوهش در صفحه شخصی خود در قالب دو فایل برای داده‌های تحت نظرنگار و بدون نظرنگار به اشتراک گذاشته است [33].

(جدول-۵): ویژگی‌های مورد استفاده در پژوهش وانگ و همکاران [۹]

ردیف	نام ویژگی	تعداد
۱	تعداد کل بسته‌ها	۱
۲	تعداد بسته‌های ورودی و خروجی	۲
۳	زمان کل	۱
۴	اندازه بسته‌های موجود در دنباله	۳۰۰ [-۱۵۰۰، ۱۵۰۰]
۵	مکان n بسته خروجی ابتدایی	n = ۳۰۰
۶	فاصله n بسته خروجی ابتدایی با بسته خروجی قبلی	n = ۳۰۰
۷	بیشینه تعداد بسته‌های خروجی در پنجره با اندازه W بسته	m = ۱۰۰ (w = ۳۰)
۸	حداکثر طول burst در دنباله	۱
۹	متots طول های burst در دنباله	۱
۱۰	تعداد burst های دنباله	۱
۱۱	تعداد burst های با طول بیشتر از ۱	۱ = {۵, ۱۰, ۱۵}
۱۲	طول b تا burst ابتدایی	b = ۵
۱۳	جهت حرکت d بسته اول	d = ۲۰

در پژوهش هیز و دنسیز [۳۴]، روش KFP<sup>۱</sup> معرفی شد. در KFP از جنگل تصمیم تصادفی<sup>۲</sup> برای تولید نمایه برای هر دنباله بسته استفاده می‌شود. در این روش، خروجی هر درخت یک مؤلفه از اثر انگشت یک نمونه ورودی را مشخص می‌کند و مجموعه این مؤلفه‌ها بردار اثر انگشت نمونه را می‌سازد؛ سپس این اثر انگشت‌ها به الگوریتم KNN داده می‌شود. با محاسبه فاصله همینگ بین دو اثر انگشت و رای‌گیری بین نزدیک‌ترین K نمونه آموزشی، می‌توان صفحه وب مرورشده توسط کاربر را شناسایی کرد.

<sup>۱</sup> K-fingerprinting

<sup>۲</sup> Random decision forest

(جدول-۴): ویژگی‌های مورد استفاده در پژوهش پانچنکو و همکاران [۳۰]

ردیف	نام ویژگی	تعداد
۱	تعداد بسته‌های بین دو نشان‌گر اندازه	β (وابسته به تعداد نشان‌گرها)
۲	مجموع طول بسته‌های موجود بین دو نشان‌گر (بایت)	β (وابسته به تعداد نشان‌گرها)
۳	اندازه سند HTML (تعداد و اندازه بسته‌های دریافتی بین اولین بسته خروجی از سمت کاربر و بسته‌های خروجی بعدی)	۲
۴	مجموع اندازه بسته‌های ورودی و خروجی (بایت)	۲
۵	تعداد بسته‌های ورودی و خروجی	۲
۶	اندازه بسته‌های ورودی و خروجی (با احتساب جهت)	A
۷	تعداد تکرار اندازه بسته‌های موجود در هر نمونه	a
۸	درصد بسته‌های ورودی و خروجی	۲

$$d(P_i, P_c) = \sum_{j=1}^n w_j |p_{i,j} - p_{c,j}| \quad (9)$$

در سال ۲۰۱۶، پانچنکو و همکاران [۱۰] برای استفاده از دنباله اندازه بسته‌ها، روش CUMUL را ارائه کردند. در این پژوهش به جای استفاده از طول بسته‌های دنباله به عنوان یک ویژگی مجزا و از پیش تعیین شده، از جمع تجمعی اندازه‌های بسته استفاده شده است که به صورت ضمی همه ویژگی‌های مرتبط با اندازه بسته، از جمله محل قرارگیری بسته‌های متوالی هم‌جهت را پشتیبانی می‌کند؛ سپس از نمایش تجمعی به دست آمده نمونه‌برداری و از نقاط حاصل از نمونه‌برداری به عنوان ویژگی‌های دیگر دنباله برای بهمود دقت دسته‌بند استفاده شده است. این پژوهش، دقت دسته‌بند SVM خود را برای سه سطح مختلف سلول (در دنباله‌های تولید شده توسط Tor، TLS و TCP) بررسی کرده است که تفاوت قابل توجهی نیز در دقت بدست آمده آن مشاهده نمی‌شود؛ هم‌چنین در این پژوهش، مقیاس‌بندیری روش شناسایی صفحه وب پیشنهاد شده با شناسایی تارنما مقایسه و نشان داده شد که شناسایی ترافیک تارنما با افزایش اندازه مجموعه بدون نظرنگار،

## مروری بر حمله‌های انگشت‌نگاری تارنما

(جدول-۶): حملات انگشت‌نگاری صفحات وب مبتنی بر مجموعه ویژگی‌ها – دقت ثبت شده در جدول بر حسب درصد و مربوط به نتایج بهدست آمده از هر پژوهش با در نظر گرفتن مجموعه داده و نوع ارزیابی گفته شده در ستون ارزیابی جدول است.

ردیف	عنوان	تاریخ	مجموعه داده	مجموعه ویژگی‌ها	روش دسته‌بندی	نویسنده	منبع
۱	۵۴/۶۱٪. (Tor closed world)	۲۰۱۱	صفحات وب پیشنهادی پژوهش هرمن و همکاران [۶] بارگزاری شده توسط Tor و JAP	مطابق جدول (۲)	دسته‌بند SVM	پانچنکو و همکاران [۳۰]	
۲	*۹۰/۶٪. (مجموعه داده هرمن و همکاران)	۲۰۱۲	مجموعه داده پژوهش هرمن و همکاران + مجموعه داده پژوهش لیبراتور و لوین [۲۷]	زمان کل ارتباط، پهنای باند در هر طرف ارتباط، الگوی burst ترافیک به صورت N- با طول متغیر Gram	بیز ساده	دایر و همکاران [۳۲]	
۳	۷۹٪.	۲۰۱۴	ترافیک صفحات وب بارگزاری شده توسط شبکه چندگام Tor [۳۸]	مطابق جدول (۳)	الگوریتم تعیین وزن WLLCC و دسته‌بند KNN	وانگ و همکاران [۹]	
۴	۹۶٪.	۲۰۱۶	ترافیک شبکه چندگام Tor [۳۳]	جمع تجمعی اندازه‌های بسه، نمونه‌برداری با تعداد متغیر از جمع تجمعی	دسته‌بند SVM	پانچنکو و همکاران (CUMUL) [۱۰]	

\* در این پژوهش، دقت روش پانچنکو و همکاران [۳۰] در شرایط آزمایش برابر با ۹۶/۴ گزارش شده است.

ترافیک، یک گام پیش‌پردازش داده به حمله پیشنهادی اضافه شد. در این گام، مجموعه بزرگ ویژگی‌های معرفی شده در پژوهش وانگ [۹] با استفاده از روش تحلیل مؤلفه‌های اساسی PCA<sup>۱</sup>) به مجموعه کوچکی با مقدار تقریبی ۲۳ ویژگی کاهش یافت که این امر باعث بهبود چشمگیر سرعت آموزش و آرمون دسته‌بند نیز شد. در پژوهش دیگری که توسط طائی و همکاران [۳۶] انجام شد، تأثیر گام پیش‌پردازش داده با استفاده از تحلیل مؤلفه‌های اساسی بر نرخ مثبت واقعی، نرخ مثبت کاذب، زمان آموزش و زمان آزمون دسته‌بند، با تغییر مشخصه‌های مؤثر در حمله برای دسته‌بند شبکه عصبی بررسی و نشان داده شد که استفاده از PCA، ضمن کاهش هفده درصدی نرخ مثبت واقعی در ارزیابی جهان‌باز، به افزایش بیش از پنجاه درصدی سرعت آموزش و آزمون می‌انجامد. در ارزیابی دو پژوهش بالا، از مجموعه داده مورداستفاده در پژوهش وانگ و همکاران [۹] استفاده شد. در زمان پژوهش، این مجموعه داده، به روزترین و یکی از بزرگ‌ترین مجموعه‌های موجود از دنباله‌های بارگذاری شده از صفحات آغازین صد تارنما و شامل هجده هزار دنباله ترافیک

در پژوهش النامی و همکاران [۲] با در نظر گرفتن دنباله‌های بسته‌های متوالی هم جهت مجاور که در دو جهت مخالف هستند و همچنین استفاده از اندازه و زمان آن‌ها، روشی برای شناسایی ارائه شد. برای دسته‌بندی صفحات وب در حالت جهان‌بسته از ماشین‌های بردار پشتیبان و برای حالت جهان‌باز از دسته‌بند KNN استفاده شد.

در این پژوهش به جای استفاده از الگوریتم تعیین وزن معروف شده در پژوهش وانگ و همکاران [۹]، از جنگل تصمیم تصادفی برای تعیین وزن ویژگی‌ها استفاده شده است. این روش زمان محاسبات را نسبت به روش وانگ و همکاران کاهش می‌دهد.

پژوهش طائی و همکاران [۳۵]، با در نظر گرفتن ماهیت پویای صفحات وب و لزوم به روزرسانی پیوسته مجموعه‌های آموزشی، روشنی را برای افزایش سرعت آموزش دسته‌بند در حملات انگشت‌نگاری تارنما ارائه کردند. در این پژوهش، از یک دسته‌بند KNN وزن دار برای شناسایی ترافیک ورودی با بهره‌گیری از ویژگی‌های ارائه شده در پژوهش وانگ [۹] استفاده شد.

به منظور کاهش ابعاد فضای ویژگی‌های نمونه‌های

روش‌ها نسبت به دقیق‌ترین روش‌های این حوزه بمبودی نداشت، اما دقت آنها در حد این روش‌هاست. علاوه بر این، هر کدام از شبکه‌های عمیق مورداستفاده در شرایط ویژه، از لحاظ دقت یا سرعت یا میزان پایداری نتایج، نتایجی نزدیک به روش‌های قبلی داشته‌اند.

است که در صفحه شخصی وانگ به همراه تعدادی از مجموعه‌های داده مربوط به پژوهش‌های پیشین بارگذاری شده است [۳۷]. جداول (۶ و ۷) به حملات معرفی شده در این بخش و بخش بعد اختصاص دارد.

### ۷-۳-حملات مبتنی بر دنباله‌های خام

در این مقاله، حمله انجشت‌نگاری صفحات وب به عنوان روشی برای کشف ماهیت ترافیک مرور وب کاربران معرفی شد و سیر تکامل پژوهش‌های انجام شده در این زمینه در طول زمان به شیوه‌ای نوین موردن بررسی قرار گرفت. به این منظور، پژوهش‌های پیشین انجشت‌نگاری تارنما بر اساس مجموعه ویژگی‌های استفاده شده برای شناسایی، به هفت دسته تقسیم و هر کدام از روش‌ها به اختصار توضیح داده شدند.

در یکی از آخرین پژوهش‌های منتشرشده در زمینه انجشت‌نگاری تارنما [۳۸]، به جای استفاده از یک تابع استخراج ویژگی برای انتخاب دقیق ویژگی‌ها، فرآیند استخراج ویژگی با به کارگیری شبکه‌های عصبی عمیق<sup>۱</sup> به صورت خودکار انجام می‌شود. در این پژوهش، عملکرد سه شبکه عصبی عمیق LSTM، CNN و SDAE در حوزه انجشت‌نگاری تارنما برای تنظیمات جهان‌بسته و جهان‌باز بررسی شد. نتایج ارزیابی‌ها نشان داد که به طور کلی، دقت شناسایی این

(جدول-۷): ادامه حملات انجشت‌نگاری صفحات وب مبتنی بر مجموعه ویژگی‌ها، دنباله‌های خام – دقت ثبت‌شده در جدول بر حسب درصد و مربوط به نتایج به دست آمده از هر پژوهش با در نظر گرفتن مجموعه داده و نوع ارزیابی گفته شده در ستون ارزیابی جدول است.

ردیف	عنوان	نوع	نوسنده	روش دسته‌بندی	مجموعه ویژگی‌ها	مجموعه داده	ردیف
۱	هیز و دنسیز (۲۰۱۶) [۳۴] (KFP)	ایجاد اثر انگشت با استفاده از جنگل تصمیم تصادفی و KNN دسته‌بندی با	مجموعه داده پژوهش وانگ + ترافیک صفحات وب بارگذاری شده [۳۹] و توسط Tor و HTTPS	مطابق جدول (۳)			۹۴٪
۲	النامی و همکاران (۲۰۱۶) [۲]	تعیین وزن ویژگی‌ها با جنگل تصمیم تصادفی و دسته‌بندی با KNN	اندازه بسته‌های ورودی و خروجی، اندازه زمان Burst (Tor) + مجموعه داده پژوهش (HTTPS) + مجموعه داده پژوهش وانگ [۳۷]				۹۲٪ (HTTPS)
۳	طائی و همکاران (۲۰۱۶) [۳۵]	دسته‌بند KNN	مؤلفه‌های اساسی برآمدی به دست آمده از مجموعه ویژگی‌های پژوهش وانگ [۳۷]	مجموعه داده پژوهش وانگ			۹۸٪ (Tor)
۴	طائی و همکاران (۲۰۱۶) [۳۶]	دسته‌بند شبکه عصبی	مؤلفه‌های اساسی برآمدی به دست آمده از مجموعه ویژگی‌های پژوهش وانگ [۳۷]	مجموعه داده پژوهش وانگ [۳۷]			۷۰٪
۵	ریمر و همکاران (۲۰۱۷) [۳۸]	شبکه‌های عصبی عمیق (LSTM, SDAE, CNN)	دنباله‌های ترافیک صفحات وب	ترافیک صفحات وب بارگذاری شده توسط Tor			۸۴٪ (شبکه SDAE)

<sup>۱</sup> Deep Neural Networks

- [10] Panchenko, Andriy., Lanze, F., Zinnen, A., Henze, M., Pennekamp, J., Wehrle, K. and Engel, T., "Website Fingerprinting at Internet Scale," in Proceedings of the 23rd Internet Society (ISOC) Network and Distributed System Security Symposium (NDSS 2016), 2016.
- [11] Kurose, James. F. and Ross, K. W., Computer Networking: A Top-Down Approach, 6 ed., Pearson, 2012.
- [12] Tanenbaum, Andrew S. and Wetherall, David J., Computer Networks, 5 ed., Prentice Hall, 2011.
- [13] Fielding, R. and Reschke, J., "Internet Engineering Task Force (IETF)," June 2014. [Online].
- [14] Available: <https://tools.ietf.org/html/rfc7230>. [Accessed 25 August 2017].
- [15] "Web Technology Surveys," [Online]. Available: <https://w3techs.com/technologies/details/ce-http2/all/all>. [Access-ed 25 August 2017].
- [16] Nielsen, Henrik Frystyk, Gettys, James, Baird-Smith, Anselm, Prud'hommeaux, Eric, Wium Lie, Håkon and Lilley, Chris, "Network performance effects of HTTP/1.1, CSS1, and PNG." In ACM SIGCOMM Computer Communication Review, 1997, vol. 27, no. 4, pp. 155-166.
- [17] Wagner, David and Schneier, Bruce, "Analysis of the SSL 3.0 protocol," in The Second USENIX Workshop on Electronic Commerce Proceedings, 1996, pp. 29-40.
- [18] Cheng, Heyning and Avnur, Ron, "Traffic Analysis of SSL Encrypted Web Browsing," 1998. [Online]. Available: [citeseer.ist.psu.edu/656522.html](http://citeseer.ist.psu.edu/656522.html). [Accessed 15 September 2016].
- [19] Hintz, Andrew, "Fingerprinting websites using traffic analysis," in International Workshop on Privacy Enhancing Technologies, Springer Berlin Heidelberg, 2002, pp. 171-178.
- [20] Sun, Qixiang, Simon, D. R., Wang, Y., Russell, W., Padmanabhan, V. N. and Qiu, Lili, "Statistical identification of encrypted web browsing traffic," In Proceedings of 2002 IEEE Symposium on Security and Privacy, 2002, pp. 19-30.
- [21] Shmatikov, Vitaly and Wang, M.-H., "Timing analysis in low-latency mix networks: Attacks and defenses," in European Symposium on Research in Computer Security, Springer Berlin Heidelberg, 2006.
- [22] Dingledine, Roger, Mathewson, Nick and Syverson, Paul, "Tor: The second-generation onion router," Naval Research Lab, Washington DC, 2004.
- [23] Freedman, Michael J. and Morris, Robert, "Tarzan: A peer-to-peer anonymizing network

بررسی سیر تغییرات روش‌های انگشت‌نگاری نشان می‌دهد که به مرور زمان، در پژوهش‌های گوناگون، مجموعه ویژگی‌های استفاده شده، جزئیات بیشتری از یک دنباله ترافیک را در بر گرفته‌اند که این امر موجب بزرگ‌ترشدن مجموعه ویژگی‌ها و صرف زمان بیشتر برای اجرای یک حمله می‌شود. با این حال، استفاده از ویژگی‌های دقیق‌تر، حملات را تشدید را برای موفقیت در شناسایی صفحات وب در شرایط مختلف تقویت می‌کند و دقت شناسایی را افزایش می‌دهد.

### - مراجع

- [1] Wang, Tao and Goldberg, Ian, "Improved website fingerprinting on tor," in 12th ACM Workshop on privacy in the electronic society, 2013, pp. 201-212.
- [2] Al-Naami, Khaled., Chandra, S., Mustafa, A., Khan, L., Lin, Z., Hamlen, K., Thuraisingham, B., "Adaptive encrypted traffic fingerprinting with bi-directional dependence," in Proceedings of the 32nd Annual Conference on Computer Security Applications, ACM, 2016, pp. 177-188.
- [3] Aceto, Giuseppe and Pescapé, Antonio, "Internet Censorship detection: A survey," Computer Networks, 2015, vol. 83, pp. 381-421.
- [4] Yanes, Adrian, "Privacy and Anonymity," arXiv preprint arXiv:1407.0423, 2014.
- [5] Dixon, Lucas, Ristenpart, Thomas and Shrimpton, Thomas, "Network Traffic Obscuration and Automated Internet Censorship," IEEE Security & Privacy, 2016, vol. 14, no. 6, pp. 43-53.
- [6] Herrmann, Dominik, Wendolsky, Rolf and Federrath, Hannes, "Website fingerprinting: attacking popular privacy enhancing technologies with the multinomial naïve-bayes classifier," in Proceedings of the 2009 ACM workshop on Cloud computing security, 2009, pp. 31-42.
- [7] Cai, Xiang, Nithyanand, Rishab, Wang, Tao, Johnson, Rob and Goldberg, Ian, "A systematic approach to developing and evaluating website fingerprinting defenses," in Proceedings of the 2014 ACM SIGSAC Conference on Computer and Communications Security, 2014, pp. 227-238.
- [8] Wang, Tao and Goldberg, Ian, "On realistically attacking Tor with website fingerprinting," in Proceedings on Privacy Enhancing Technologies, 2016, no. 4, pp. 21-36.
- [9] Wang, Tao, Cai, Xiang, Nithyanand, Rishab, Johnson, Rob and Goldberg, Ian, "Effective attacks and provable defenses for website fingerprinting," in 23rd USENIX Security Symposium (USENIX Security 14), 2014, pp. 143-157.

استفاده از تحلیل مولفه‌های اساسی", چهاردهمین دوره کنفرانس بین‌المللی انجمن رمز ایران، شیراز، شهریور ۱۳۹۶.

[37] طائبی، مریم، بهلوی، علی، کائیدی، مرجان، " مواد مرتبط با سرعت و دقت دسته‌بندی صفحات وب در انگشت‌انگاری صفحات وب "، نهمین دوره کنفرانس بین‌المللی فناوری اطلاعات و دانش (IKT2017)، تهران، مهر ۱۳۹۶.

[38] <https://www.cse.ust.hk/~taow/wf/data/>, [Accessed 1 February 2017].

[39] Rimmer, Vera, Preuveneers, Davy, Juarez, Marc, Goethem, Tom Van and Joosen, Wouter, "Automated Feature Extraction for Website Fingerprinting through Deep Learning," arXiv preprint arXiv:1708.06376, 2017.

[40] <http://www.homepages.ucl.ac.uk/~ucabaye/alex.tar.gz>, [Accessed 1 February 2017].

layer," in Proceedings of the 9th ACM conference on Computer and communications security, ACM, 2002, pp. 193-206.

[24] Bissias, George Dean, Liberatore, Marc, Jensen, D. and Levine, B. N., "Privacy vulnerabilities in encrypted HTTP streams," in International Workshop on Privacy Enhancing Technologies, Springer Berlin Heidelberg, 2005, pp. 1-11.

[25] WebIdent Traces, 2005, <http://traces.cs.umass.edu/index.php/Network/Network>, [Accessed 1 February 2017].

[26] Mistry, Shailesh and Raman, Bhaskaran, "Quantifying Traffic Analysis of Encrypted Web-Browsing," 1998.

[27] Liberatore, Marc and Levine, Brian Neil, "Inferring the source of encrypted HTTP connections," in Proceedings of the 13th ACM conference on Computer and communications security. ACM, 2006, pp. 255-263.

[28] WebIdent2 Traces, 2006, <http://traces.cs.umass.edu/index.php/Network/Network>, [Accessed 1 February 2017].

[29] Lu, Liming, Chang, Ee-Chien and Chan, Mun, "Website fingerprinting and identification using ordered feature sequences," in Computer Security—ESORICS, 2010, pp. 199-214.

[30] Cai, Xiang, Zhang, Xin Cheng, Joshi, Brijesh, Johnson, Rob, "Touching from a Distance: Web-site Fingerprinting Attacks and Defenses," in 19th ACM Conference on Computer and Communications Security, 2012, pp. 605-616.

[31] Panchenko, Andriy, Niessen, Lukas and Zinnen, Andreas, "Website fingerprinting in onion routing based anonymization networks," in Proceedings of the 10th annual ACM workshop on Privacy in the electronic society, Chicago, IL, USA, 2011, pp. 103-114.

[32] Aggarwal, Charu C., Data mining: the textbook, Springer, 2015.

[33] Dyer, Kevin P., Coull, Scott E. and Ristenpart, Thomas, "Peek-a-boo, I still see you: Why efficient traffic analysis countermeasures fail," in 2012 IEEE Symposium on Security and Privacy, San Francisco, CA, USA, 2012, pp. 332-246.

[34] <https://lorre.uni.lu/~andriy/zwiebelfreunde>, [Accessed 1 February 2017].

[35] Hayes, Jamie and Danezis, George, "k-fingerprinting: a Robust Scalable Website Fingerprinting Technique," in Usenix Security Symposium, 2016, 1187-1203.

[36] طائبی، مریم، بهلوی، علی، کائیدی، مرجان، "بهبود کارایی الگوریتم تشخیص حمله انگشت‌انگاری تارنما با



**مریم طائبی** تحصیلات خود را در مقاطع کارشناسی و کارشناسی ارشد مهندسی کامپیوتر به ترتیب در دانشگاه صنعتی اصفهان و دانشگاه اصفهان سپری کرده است. زمینه پژوهشی موردعالقه وی امنیت شبکه و یادگیری ماشین است.



**علی بهلوی** مقطع کارشناسی و کارشناسی ارشد خود را در دانشگاه صنعتی اصفهان سپری کرده و مدرک دکترای خود را از دانشگاه اصفهان گرفته است. وی از سال ۱۳۹۰ عضو هیئت علمی دانشکده مهندسی کامپیوتر دانشگاه اصفهان بوده و زمینه‌های پژوهشی وی شبکه و امنیت شبکه است.



**مرجان کائیدی** دارای کارشناسی مهندسی کامپیوتر از دانشگاه صنعتی اصفهان و کارشناسی ارشد و دکتری مهندسی کامپیوتر از دانشگاه اصفهان است. وی از سال ۱۳۹۱ عضو هیئت علمی دانشکده مهندسی کامپیوتر اطلاعات دانشگاه اصفهان است. زمینه‌های پژوهشی مورد علاقه وی، یادگیری ماشین، بهینه‌سازی و تجارت الکترونیک است.