



Malware Classification Based On Visualizing Binary Content of Samples

E. Khazai, M. R. Hassanzadeh* 

Assistant professor, Babol Noshirvani University of Technology *

(Received: 2024 /06/18, Revised: 2024/09/04, Accepted: 2024/10/14, Published: 2024/10/22)

DOR: DOR: <https://dor.isc.ac/dor/20.1001.1.23224347.1403.12.3.5.7>

Abstract

Malware is one of the constant challenges of the modern world, which has particular importance due to the harm it causes to users. In the last decade, there has been a great increase in malware number and complexity that caused the current security tools and methods not able to defend against. Visualizing binary content of malware and searching for malicious elements among suspicious image patterns is one of the new methods that have achieved high progress and efficiency in the last decade thanks to deep learning algorithms. In this research, by combining various ideas that exist in the field of malware image analysis, a suitable algorithm has been presented for classifying malware into their corresponding families. Visualizing the binary content of the malware executable file, applying the GIST descriptor and classifying the extracted features using the SVM classifier forms the proposed algorithm of this research, which can achieve the same results as previous researches by using traditional machine learning methods and obtain average classification accuracy of 99.72 and 99.16% on Malimg and Microsoft datasets.

Keywords: Malware Family, Static Analysis, Visualization, Image Classification

This article is an open-access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license.

Publisher: Imam Hussein University

 Authors



*Corresponding Author Email: m.hasanzadeh@nit.ac.ir

علمی - پژوهشی

دسته‌بندی بدافزارها بر اساس بصری‌سازی محتوای دودویی نمونه‌ها

اسماعیل خزائی^۱، محمدرضا حسن‌زاده^{۲*}

۱- کارشناسی ارشد، ۲- استادیار، دانشگاه صنعتی نوش یروانی بابل، بابل، ایران

(دریافت: ۱۴۰۳/۰۳/۲۹، بازنگری: ۱۴۰۳/۰۶/۱۴، پذیرش: ۱۴۰۳/۰۷/۲۳، انتشار: ۱۴۰۳/۰۸/۰۱)

DOR: <https://dor.isc.ac/dor/20.1001.1.23224347.1403.12.3.5.7>

* این مقاله یک مقاله با دسترسی آزاد است که تحت شرایط و ضوابط مجوز (CC BY) Creative Commons توزیع شده است.



ناشر: دانشگاه جامع امام حسین (ع) نویسندگان

چکیده

بدافزارها از چالش‌های همیشگی دنیای مدرن محسوب می‌شوند که به علت آزار کاربران و خساراتی که به وجود می‌آورند، از اهمیت ویژه‌ای برخوردارند. در دهه اخیر، رشد سریع و پیچیده‌تر شدن سازوکار مخرب بدافزارها سبب شده است، ابزارها و روش‌های امنیتی فعلی نتوانند با این اندازه از وسعت و تنوع تهدیدها مقابله کنند. بصری‌سازی ساختن محتوای دودویی بدافزار و جستجوی عناصر مخرب از بین الگوهای تصویری مشکوک، از روش‌های نوین محسوب می‌شود که در دهه گذشته، به لطف الگوریتم‌های پردازش تصویر به پیشرفت و کارایی بالایی دست پیدا کرده است. در این پژوهش با ترکیب ایده‌های متنوعی که در زمینه تحلیل تصویری بدافزارها وجود دارد، یک روش مناسب برای دسته‌بندی بدافزارها به خانواده‌های متناظرشان ارائه شده است. بصری‌سازی محتوای دودویی فایل اجرایی بدافزار، اعمال توصیفگر $GIST^1$ و دسته‌بندی ویژگی‌های استخراج شده با استفاده از طبقه‌بند SVM ، روش پیشنهادی این پژوهش را تشکیل می‌دهد که می‌تواند تنها با به‌کارگیری روش‌های سنتی یادگیری ماشین، به نتایجی برابر با پژوهش‌های پیشین دست پیدا کند و در مجموعه داده‌های Malimg و میکروسافت، به میانگین دقت طبقه‌بندی $99/72\%$ و $99/16\%$ درصد برسد.

کلیدواژه‌ها: خانواده بدافزار، تحلیل ایستا، بصری‌سازی، دسته‌بندی تصاویر

۱- مقدمه

به‌طور کلی هرگونه نرم‌افزاری که عامدانه برای آسیب‌زدن به یک رایانه یا شبکه رایانه‌ای طراحی شده باشد، بدافزار^۲ گفته می‌شود [۱]. بدافزارها از جمله چالش‌های جدی عصر حاضر هستند که انگیزه توسعه آن‌ها از یک مزاحمت ساده به دزدی، جاسوسی و خرابکاری گسترش یافته است و هم‌اکنون طیف وسیعی از افراد، کسب‌وکارها و حتی دولت‌ها را تهدید می‌کند. در گذشته به کلیه نرم‌افزارهای مخرب ویروس گفته می‌شد. ویروس‌های رایانه‌ای عمده تهدیداتی بوده‌اند که به شیوه ویروس‌های عادی در دنیای واقعی، با آلوده کردن حافظه‌های قابل حمل شیوع می‌یافتند. امروزه با پیشرفت فناوری‌های ارتباطی، سازوکار بدافزارها نیز متنوع‌تر و پیچیده‌تر شده است، به‌طوری‌که رفتار ویروس گونه بدافزار، تنها یک راهبرد از میان طیف وسیع تهدیدات محسوب می‌شود [۲].

طبق آمار ارائه شده از مؤسسه تحقیقاتی AV-Test، تعداد

بدافزارهای کشف شده از ابتدای سال ۱۹۸۴ میلادی تاکنون در حدود $1/4$ میلیارد برآورد شده است که نیمی از آن‌ها در ۵ سال اخیر تولید شده‌اند. شکل (۱) نمودار تجمعی بدافزارهای کشف شده تا به امروز را نشان می‌دهد که رشدی نمایی را دنبال می‌کند [۳]. البته آمار واقعی بدافزارها از این میزان بیشتر بوده و نمونه‌های بسیاری وجود دارند تاکنون کشف نشده‌اند. در این شرایط روش‌های دستی تحلیل بدافزار، از لحاظ تعداد نیروی متخصص و زمان مورد نیاز برای یافتن راه‌حل، برای مقابله با رشد روزافزون تهدیدها کافی نیستند. از این‌رو امروزه اکثر فرایندهای تحلیل بدافزار به‌صورت خودکار پیگیری می‌شود و فقط در صورتی که تهدید مورد نظر بسیار مهم باشد یا ابزارهای تحلیل خودکار توانایی مقابله با آن را نداشته باشند، متخصصان وارد عمل می‌شوند. انگیزه این پژوهش نیز ارائه الگوریتمی است که بتواند در خودکارسازی فرایند تحلیل بدافزار به متخصصان کمک کند.

* رایانامه نویسنده مسئول: m.hasanzadeh@nit.ac.ir

¹ Global Image Structure Tensor² Malware

می‌شوند [۵]. در کنار تحلیل ایستا، راهبردهای «تحلیل پویا» و «تحلیل پیشرفته» نیز وجود دارند که به ترتیب با نظارت بر اجرای بدافزار یا مهندسی معکوس الگوریتم آن به اطلاعات مهم دست پیدا می‌کنند. اما این تحلیل‌ها از لحاظ زمانی نسبت به تحلیل ایستا طولانی‌تر بوده و نیاز به اجرای بدافزار در یک محیط قرنطینه یا تجربه کافی برای بررسی کد زبان ماشین دارند.

۱-۳- تحلیل اکتشافی^۱


تحلیل اکتشافی فرایند استخراج ویژگی‌های ایستا و پویا به‌منظور شناسایی و دسته‌بندی بدافزارها است. برخلاف تحلیل‌های قبلی، این ویژگی‌ها به مؤلفه‌های مخرب خاصی اشاره ندارند و وجود آن‌ها در یک نمونه مشکوک به معنای مخرب بودن قطعی آن نیست. ویژگی‌های استخراج‌شده تنها داده‌هایی خام هستند که متخصصان آن‌ها را از طیف وسیعی از نرم‌افزارهای مخرب و غیرمخرب استخراج کرده و طبقه‌بندی را بر اساس آن آموزش می‌دهند. هدف طبقه‌بندی یادگیری الگوهایی است که به کشف بدافزارها و تشخیص نوع آن‌ها کمک کند. اگر این الگوها در نمونه غریبه‌ای یافت شود، آن نمونه به‌احتمال زیاد مخرب است و به خانواده‌ای تعلق دارد که بیشترین اشتراک را با آن داشته باشد. امروزه که با رشد سریع و پیچیده‌تر شدن بدافزارها، روش‌های پایه‌ای تحلیل به چالش کشیده شده‌اند، تحلیل اکتشافی می‌تواند با ارائه یک الگوریتم خودکار و یادگیرنده به این چالش‌ها پایان دهد.

۱-۴- تحلیل تصویری بدافزار

تحلیل تصویری بدافزار یک روش ایستای اکتشافی است که در آن نمونه‌ها به کمک تصاویرشان، شناسایی و دسته‌بندی می‌شوند. تصاویر بدافزارها از بصری‌سازی مستقیم محتوای فایل موردنظر به دست می‌آید به‌طوری‌که هر پیکسل تصویر، نماینده بخشی از داده‌های دودویی موجود در فایل است. از این طریق الگوریتم‌های اکتشافی می‌توانند الگوهای مخرب دودویی را از روی تصویر بیاموزند و متخصصان را در ریشه‌کن کردن بدافزارها یاری دهند. البته بصری‌سازی محتوای دودویی منحصربه‌فرد نیست و متخصصان می‌توانند بسته به اهداف مدنظرشان، روش‌های متعددی را بکار گیرند. اینکه تصاویر تولیدشده برای ناظر انسانی قابل‌درک یا برای استخراج ویژگی غنی باشد، می‌تواند از جمله اهداف این تحلیل باشد.

۱-۵- پژوهش فعلی

نوآوری‌های این پژوهش را می‌توان در ارتقا روش‌های تحلیل تصویری موجود و ترکیب آن‌ها با روش‌های جدیدتر و کارآمدتر دانست. استفاده از بردار بیتی برای ساخت بردارهای هیستوگرام و آنترپی، استفاده چینش هیلبرت، ماتریس نقطه‌ای و ماتریس



شکل (۱). نمودار تجمعی بدافزارهای کشف‌شده در سه دهه اخیر [۳]

۱-۱- دسته‌بندی بدافزارها

برای مقابله با طیف وسیع بدافزارها، متخصصان آن‌ها را به روش‌های متعدد دسته‌بندی می‌کنند. این امر به متخصص کمک می‌کند که هر نمونه جدید بر اساس انواع مشابه قبلی، قابل‌بررسی باشد. نوع رفتار، سکوی اجرا و خانواده بدافزار، معیارهای رایجی هستند که به دسته‌بندی بدافزارها کمک می‌کنند و همانند شکل (۲) چهارچوب دقیقی برای اشاره به هر بدافزار می‌سازند. کاربردی‌ترین معیار دسته‌بندی بدافزارها که در این پژوهش به آن پرداخته شده است، تفکیک نمونه‌ها به خانواده‌های مختلف است. هر خانواده به گروهی از بدافزارها اطلاق می‌شود که وجوه مشترک بسیاری در سازوکار مخرب خود داشته و اهداف یکسانی را دنبال می‌کنند. مستقل از اینکه هر بدافزار چه طیفی از رفتارها و سکوهایی اجرایی داشته باشد، این معیار منحصربه‌فرد است و تنها به جامعه کوچکی از نمونه‌ها اشاره دارد. بدین ترتیب متخصصان می‌توانند تمرکز خود را بر روی نمونه‌های کاملاً مرتبط معطوف کرده و برداشت دقیق‌تری از سازوکارهای مخرب داشته باشند.

Type:	Platform/	Family	.Variant	ISuffixes
Trojan, Worm, etc.	Windows, MacOS, etc.	Ramnit, Conficker, etc.		

Backdoor:Win32/Caphaw.D lnk

شکل (۲). چهارچوب نام‌گذاری بدافزارها، مورد استفاده در محصولات امنیتی شرکت مایکروسافت [۴]

۱-۲- تحلیل بدافزار

برای دسته‌بندی و مقایسه بدافزارها، نمونه‌های مربوطه مورد تحلیل قرار می‌گیرند. تحلیل بدافزار فرایندی است که در آن به روش‌ها و ابزارهای متعدد، حداکثر اطلاعات ممکن از یک نمونه مشکوک استخراج شود. اگر این فرایند بدون اجرای بدافزار و تنها بر اساس ویژگی‌های فایل آن انجام شود، آن را به اصطلاح «تحلیل ایستا» می‌نامند. مشخصات ظاهری فایل بدافزار اعم از نام و حجم نمونه موردنظر، مشخصات محتوایی و رشته‌های دودویی موجود در آن از جمله اطلاعاتی هستند که در این تحلیل بکار گرفته

¹ Heuristic

در دهه گذشته، با موفقیت شبکه‌های عصبی عمیق در پردازش تصویر، استخراج ویژگی به عهده ماشین گذاشته شد تا خود بتواند طی یادگیری‌های متعدد بهترین راه‌حل را بیابد و محدود به یک الگوریتم خاص برای حل مسئله نباشد. همسو با این روند، در پژوهش‌های تحلیل تصویری بدافزار نیز توصیفگر GIST با روش‌های مبتنی بر شبکه‌های عصبی عمیق جایگزین شد، تا از یک‌طرف دیگر نیازی به ویژگی‌های دست‌ساخته و غیر بهینه نباشد و از طرف دیگر سازندگان بدافزار نتوانند با دور زدن محاسبات ریاضی این ویژگی‌ها، بدافزارهای خود را بی‌خطر جلوه دهند [۷-۱۱]. پژوهش [۷] از جمله موارد مهم در این زمینه محسوب می‌شود که در آن با همکاری مشترک شرکت‌های فناوری مایکروسافت و اینتل در سال ۲۰۲۰ میلادی، مجموعه‌ای متشکل از ۲ میلیون بدافزار به‌صورت بصری و با استفاده از شبکه عصبی Resnet موردبررسی قرار گرفته‌اند.

هم‌زمان با پژوهش‌های ذکرشده، برخی دیگر از محققان بر روی نحوه ساخت تصاویر متمرکز شده و سعی در غنی‌تر کردن ویژگی‌های بصری آن داشته‌اند. از جمله تلاش‌های انجام‌شده در این زمینه می‌توان به آنتروپی اشاره کرد که از آن برای اندازه‌گیری میزان فشردگی بخش‌های مختلف فایل مشکوک استفاده شده است و می‌تواند برای تشخیص گد و نوع داده‌ها و میزان فشردگی آن‌ها مورد استفاده قرار گیرد [۱۲، ۱۳]. هم‌اکنون این معیار در پژوهش‌های [۱۴، ۱۵] نه تنها به‌عنوان یک ویژگی تک‌بعدی بلکه به‌عنوان یک روش بصری‌سازی یا کانال رنگی برای نمایش بدافزارها استفاده شده است. منحنی فضا گیر هیلبرت^۲ از دیگر ابزارهای مورد استفاده در خصوص بهبود بصری‌سازی است که به دلیل خاصیت آن در حفظ خصوصیات محلی برای نگاشت داده‌های یک‌بعدی به ابعاد بالاتر بکار گرفته می‌شود. در پژوهش [۱۶] نشان داده شد که چینش هیلبرت می‌تواند نسبت به چینش سطری به نتایج بهتری برای تشخیص/دسته‌بندی بدافزارها بیانجامد.

از آخرین پژوهش‌های انجام‌شده در این زمینه می‌توان به پژوهش [۱۷] اشاره کرد که در آن تصویر بدافزار و آنتروپی آن به‌عنوان ورودی‌های یک شبکه عصبی پیچشی برای دسته‌بندی بدافزارها را به کار گرفته شده‌اند. یا در پژوهش [۱۸] محتوای دودویی فایل بدافزار، به تصاویر رنگی تبدیل شده و با استفاده روش‌های مختلف یادگیری عمیق موردبررسی قرار گرفته‌اند.


۳- روش پژوهش

الگوریتم پیشنهادی این پژوهش متشکل از چهار فرایند اصلی است. ابتدا در مرحله پیش‌پردازش، سه بردار از فایل نمونه به دست می‌آید. سپس هریک از این بردارها به روش‌های متعدد

هیستوگرام برای نمایش فایل بدافزارها، بررسی عملکرد یکایک بصری‌سازی‌ها، استخراج محتوای دودویی بدافزارها از مجموعه Maling، ترکیب مجموعه‌ها برای ساخت یک فضای نمونه بزرگ‌تر (۲۰ هزار بدافزار) و بالاتر این موارد، ساخت الگوریتمی که بتواند با استفاده از روش‌های رایج یادگیری ماشین با پژوهش‌های مبتنی بر یادگیری عمیق (CNN)^۱ - که از لحاظ محاسبات به مراتب سنگین‌تر هستند - برابری کند، به نوبه خود قدمی روبه‌جلو محسوب می‌شود.

۲- پیشینه پژوهش

تحلیل تصویری بدافزار مطابق آنچه امروز می‌شناسیم از پژوهش [۶] آغاز شد. در این پژوهش محتوای دودویی فایل بدافزار که به‌مثابه برداری از بایت‌های متوالی است، به برداری از پیکسل‌های خاکستری نگاشت داده می‌شود، به‌طوری‌که روشنایی هر پیکسل بر اساس عدد بایت متناظرش تعیین می‌شود. به عبارت دقیق‌تر، بایت صفر متناظر با پیکسل مشکی، بایت ۲۵۵ متناظر با پیکسل سفید و مقادیر بایتی بین این دو، ۲۵۵ درجه روشنایی را تعیین می‌کند. سپس با چینش سطر به سطر پیکسل‌ها، تصاویر دوبعدی از فایل موردنظر تهیه می‌گردد که می‌توان آن را به روش‌های متعدد موردبررسی قرارداد. این پژوهش نشان داد که بدافزارهای هم‌خانواده به دلیل استفاده از داده‌ها و کدهای مخرب مشابه، الگوهای تصویری نزدیکی دارند، همچنین تفاوت بین الگوهای تصویری خانواده‌های مختلف به حدی است که همانند شکل (۳) حتی با چشم غیر مجهز از یکدیگر قابل تشخیص‌اند. برای آنکه این ادعا به‌صورت علمی نیز تأیید شود، با استخراج ویژگی GIST از تصاویر و به‌کارگیری طبقه‌بند k-NN، نشان داده شد که می‌توان خانواده‌های مختلف بدافزارها را با دقت ۹۸ درصد دسته‌بندی کرد. بدین ترتیب روش‌های مبتنی بر پردازش تصویر به‌عنوان راهکاری نوین در زمینه تحلیل ایستای بدافزارها مطرح شدند.



شکل (۳). بصری‌سازی خانواده‌های مختلف بدافزارها [۶]

² Hilbert Space Filling Curve

¹ Convolutional Neural Network

...	$b_n \dots b_{n+255}$	$b_{n+256} \dots b_{n+511}$	...
↓			
...	$H(b_n) \dots H(b_{n+255})$	$b_{n+256} \dots b_{n+511}$	...
↓			
...	$H(b_n) \dots H(b_{n+255})$	$H(b_{n+256}) \dots H(b_{n+511})$	...

شکل (۶). نحوه ساخت بردار هیستوگرام از روی بردار بایتی

۳-۲-۳- بصری سازی فایل ها

پس از آنکه بردارهای سه گانه از فایل موردنظر تهیه شد، درایه های بردارها تغییر مقیاس داده شده و به ماتریس های دوبعدی نگاشت داده می شوند تا تصاویر مطلوب را بسازند. به طور کلی ۵ نوع بصری سازی مختلف برای هر بردار در نظر گرفته شده است.

۳-۲-۱- نمایش مستقیم

در نمایش مستقیم یک بردار، هر درایه پیکسل متناظری در تصویر دارد. به طوری که می توان هر بافت یا الگوی تصویر را در بخش متناظری از بردار جستجو کرد. مراحل نمایش مستقیم هر بردار دلخواه به شرح زیر است:

۱. درایه های بردار به بازه ۰ الی ۱ تغییر مقیاس داده می شوند.
۲. بردار موردنظر به روش درونیابی خطی بسط داده می شود تا اندازه بردار به توانی از چهار برسد. پیچیدگی زمانی این الگوریتم در بدترین حالت $O(n)$ است که n تعداد بایت های بردار بایتی است.
۳. درایه های بردار بر مبنای چینش هیلبرت در یک ماتریس مربعی جانمایی می شوند. (بسط دادن بردار در مرحله پیشین کمک می کند تا در این مقطع ماتریس مربعی کاملی ساخته شود)
۴. ماتریس به دست آمده می تواند به عنوان یک تصویر خاکستری مورد استفاده قرار گیرد که در آن موقعیت و روشنایی هر پیکسل بر اساس جانمایی و عدد درایه متناظرش تعیین می شود.

۳-۲-۲- نمایش غیرمستقیم

در نمایش غیرمستقیم، ماتریس های ویژگی با تغییر مقیاس به بازه ۰ الی ۱ به صورت یک تصویر خاکستری مورد استفاده قرار می گیرند. وجه مشترک این ماتریس ها، استفاده از مشخصات آماری مرتبه دو و اطلاعات همسایگی درایه ها برای ساخت آن ها است. البته در بعضی موارد تغییر مقیاس می تواند جزئیات مربوط به درایه های کوچک تر را از بین برده و تصویر را کاملاً تیره کند. این موضوع معمولاً زمانی رخ می دهد که تعدادی درایه بسیار بزرگ که جزو نمونه های پرت به شمار می آیند، در ماتریس وجود داشته باشند. برای عبور از این مشکل، پیش از تغییر مقیاس، مقدار بیشینه خاصی برای درایه های ماتریس در نظر گرفته می شود و درایه های بالاتر از این محدوده با مقدار بیشینه

بصری سازی شده و ویژگی های تصویری مطلوب از آن استخراج می شود. در نهایت با استفاده از طبقه بند SVM، هر نمونه به خانواده متناظرش دسته بندی شده و الگوریتم ارزیابی می شود.



شکل (۴). روند الگوریتم پیشنهادی

۳-۱- پیش پردازش فایل ها

در مرحله پیش پردازش از هر فایل سه بردار استخراج می شود: بردار بایتی، بردار آنتروپی و بردار هیستوگرام. بردار بایتی مستقیماً از محتوای دودویی فایل موردنظر به دست می آید. دو بردار دیگر نیز از روی بایتی محاسبه می شوند.

برای ساخت بردارهای آنتروپی و هیستوگرام، پنجره های به اندازه ۲۵۶ بایت و با گام های ۲۵۶ بایت در طول بردار بایتی حرکت کرده و مقدار هر بایت را با آنتروپی آن پنجره یا تعداد دفعات تکرار بایت ها در آن پنجره جایگزین می کند. بدین ترتیب بردارهایی هم اندازه با بردار بایتی به دست خواهد آمد که می توانند نرخ تغییرات آنتروپی و تکرار بایت ها به موازات یکدیگر نشان دهند. نحوه ساخت این دو بردار در شکل های (۵) و (۶) نمایش داده است. در این اشکال b_n به معنای بایت n -ام و B_n بلوکی است که از بایت n -ام آغاز می شود. همچنین $E(B_n)$ آنتروپی بلوک B_n و $H(b_n)$ تعداد دفعات تکرار بایت n -ام در پنجره موردنظر است.

آنتروپی متغیر تصادفی X از رابطه (۱) به دست می آید که در آن p_i احتمال پیشامد i -ام از فضای پیشامد X است. از آنجاکه هر بایت ۲۵۶ مقدار متفاوت (۰ الی ۲۵۵) می تواند داشته باشد، آنتروپی بایت ها مقداری حقیقی بین ۰ الی ۸ خواهد داشت.

$$H(X) = -\sum_{i=1}^n p_i \log_2 p_i \quad (1)$$

اگر n تعداد بایت های بردار بایتی باشد، پیچیدگی زمانی محاسبه بردار هیستوگرام $O(n)$ خواهد بود. همچنین از آنجاکه می توان از این اطلاعات این بردار می توان برای محاسبه بردار آنتروپی استفاده کرد، در پیاده سازی الگوریتم این پژوهش پیچیدگی زمانی محاسبه بردار آنتروپی نیز برابر $O(n)$ است.

...	$b_n \dots b_{n+255}$	$b_{n+256} \dots b_{n+511}$	...
↓			
...	$E(B_n) \dots E(B_n)$	$b_{n+256} \dots b_{n+511}$	...
↓			
...	$E(B_n) \dots E(B_n)$	$E(B_{n+256}) \dots E(B_{n+256})$	...

شکل (۵). نحوه ساخت بردار آنتروپی از روی بردار بایتی

می‌شود. به‌عنوان مثال برای دو بردار x و y ، اگر بلوک b_m^x از بردار اول با بلوک b_n^y از بردار دوم، d درایه مشترک داشته باشند، درایه (m,n) از ماتریس نقطه‌ای برابر d خواهد بود که این فرایند در شکل (۸) نشان داده شده است. پیچیدگی زمانی و مرتبه حافظه این الگوریتم $O(n_x \cdot n_y)$ است؛ اما با تغییر نحوه محاسبه آن می‌توان مرتبه حافظه مورد نیاز را به $O(b_x \cdot b_y)$ رساند.

در این پژوهش از ماتریس نقطه‌ای برای مقایسه هر بردار با خودش استفاده شود. برای آنکه از هر بردار، ماتریس نقطه هم‌اندازه‌ای به دست آید، ابتدا درایه‌ها به بازه ۰ الی ۲۵۵ تغییر مقیاس داده شده و به پایین گرد می‌شوند تا مقادیر صحیحی داشته باشند. سپس بردار به ۲۵۶ بلوک هم‌اندازه تفکیک شده و با خودش مقایسه می‌شود. در این حالت ماتریس نقطه‌ای به دست آمده همواره ابعاد ۲۵۶×۲۵۶ خواهد داشت.

بردار y						
		b_{n-1}^y	b_n^y	b_{n+1}^y		
...						
بردار x	...	...	...	...	...	...
	b_{m-1}^x	...	$d_{m-1,n-1}$	$d_{m-1,n}$	$d_{m-1,n+1}$	...
	b_m^x	...	$d_{m,n-1}$	d_{mn}	$d_{m,n+1}$	...
	b_{m+1}^x	...	$d_{m+1,n-1}$	$d_{m+1,n}$	$d_{m+1,n+1}$	...
	...	...	...	...	...	...

شکل (۸). نحوه ساخت ماتریس نقطه‌ای از دو بردار دلخواه X و Y

۳-۲-۴- ماتریس‌های هیستوگرام

برای الگوریتم این پژوهش دو نوع ماتریس هیستوگرام تعریف شده است؛ «ماتریس هیستوگرام بلوکی» و «ماتریس هیستوگرام کامل». برای آنکه این دو روش برای هر بردار با هر اندازه‌ای قابل استفاده باشد، ابتدا بردارهای ورودی به بازه ۰ الی ۲۵۵ تغییر مقیاس داده شده و به پایین گرد می‌شوند تا درایه‌ها مقادیر صحیحی داشته باشند. از این طریق بردارهای هیستوگرام محاسبه شده همواره ۲۵۶×۲۵۶ درایه‌ای خواهند بود.

برای ساخت ماتریس هیستوگرام بلوکی، بردار پس از تغییر مقیاس، به ۲۵۶ بلوک هم‌اندازه تفکیک شده و هیستوگرام هریک محاسبه می‌شود. با چیدن سطر به سطر بردارهای به دست آمده، یک ماتریس ۲۵۶×۲۵۶ به دست خواهد آمد که ساختار آن در شکل (۹) نشان داده شده است. در این شکل B_n بیانگر بلوک n -ام و $F_n(m)$ بیانگر تعداد تکرار عدد m در بلوک n -ام است.

فرایند ذکر شده برای ساخت ماتریس هیستوگرام کامل یکسان است، با این تفاوت که در آن تنها هیستوگرام کل بردار محاسبه می‌شود. بردار هیستوگرام به دست آمده را می‌توان آن در

جایگزین می‌شوند. در این پژوهش، حد بیشینه دو برابر میانگین درایه‌ها در نظر گرفته شده است، تا تضاد بین روشنایی و تاریکی تصاویر متعادل باشد.

۳-۲-۱- ماتریس هم رخداد^۱

ماتریس هم رخداد از جمله روش‌های تحلیل بردارها و تصاویر محسوب می‌شود که در آن تعداد دفعات رخ دادن زوج درایه‌ها به صورت یک ماتریس هیستوگرام دو بُعدی به نمایش درمی‌آید. در این پژوهش برای آنکه از هر بردار دلخواه، ماتریس هم رخداد یکسانی تهیه شود، ابتدا درایه‌های بردار به بازه ۱ الی ۲۵۶ تغییر مقیاس داده شده و به پایین گرد می‌شوند تا مقدار صحیحی داشته باشند. سپس پنجره‌ای به اندازه دو درایه و با گام یک درایه، در طول بردار به حرکت درآمده و همانند شکل (۷) درایه‌ها را به صورت دوتایی از آن استخراج می‌کند. مقادیر هر جفت درایه به مختصات سطر و ستون متناظری از ماتریس هم رخداد اشاره دارد. از آنجاکه بازه مقادیر درایه‌ها، اعداد صحیح بین ۱ الی ۲۵۶ هستند، ماتریس هم رخداد مطلوب نیز ابعاد ۲۵۶×۲۵۶ خواهد داشت. در نهایت تعداد دفعات تکرار هر جفت درایه منحصربه‌فرد در ماتریس هم رخداد ذکر می‌شود. پیچیدگی زمانی این الگوریتم $O(n)$ است که n تعداد بایت‌های بردار بایتی است.

نحوه حرکت پنجره در طول بردار						
جفت درایه‌ها		b_n	b_{n+1}	b_{n+2}	b_{n+3}	...
...		...				
(b_n, b_{n+1})		...	b_n	b_{n+1}	b_{n+2}	b_{n+3}
(b_{n+1}, b_{n+2})		...	b_n	b_{n+1}	b_{n+2}	b_{n+3}
(b_{n+2}, b_{n+3})		...	b_n	b_{n+1}	b_{n+2}	b_{n+3}


شکل (۷). نحوه استخراج جفت درایه‌های یک بردار

۳-۲-۳- ماتریس نقطه‌ای

ماتریس نقطه‌ای از جمله روش‌های مقایسه دو بردار محسوب می‌شود که در آن شباهت‌ها و تفاوت‌های یکایک درایه‌ها، به صورت ماتریسی از صفرها و یک‌ها نمایش داده می‌شود. به‌عنوان مثال برای دو بردار x و y اگر درایه x_m از بردار اول با درایه y_n از بردار دوم برابر باشد، درایه (m,n) از ماتریس نقطه‌ای برابر یک و در غیر این صورت برابر صفر خواهد بود. البته از آنجاکه مرتبه حافظه برای این الگوریتم $O(n_x \cdot n_y)$ است، این موضوع سبب می‌شود برای دو بردار یک مگابایتی، ماتریسی در حدود یک ترابایت تولید شود. از این رو برای کاهش حافظه مورد نیاز، هر بردار به بلوک‌های هم‌اندازه تفکیک شده و بلوک به بلوک مقایسه

¹ Co-Occurrence Matrix

تصاویر استفاده می‌شود. فیلترها در یک جهت و در ۸ مقیاس مختلف به تصویر اعمال می‌شوند. سپس تصاویر فیلتر شده به ۱۶ بلوک هم‌اندازه تفکیک شده و میانگین هریک محاسبه می‌شود. بدین ترتیب برداری حاوی ۱۲۸ ویژگی از هر تصویر به دست می‌آید. شکل (۱۱) روند کلی استخراج بردار ویژگی از تصویر یک بدافزار را نشان می‌دهد که مشابه آن در پژوهش [۱۸] استفاده شده است.



شکل (۱۱). روند استخراج ویژگی‌های GIST از تصویر بدافزار [۱۸]

۴- ارزیابی پژوهش

الگوریتم پیشنهادی این پایان‌نامه بر اساس سه معیار دقت^۱، پوشش^۲ و صحت^۳ مورد ارزیابی قرار می‌گیرد. منظور از معیار دقت، نسبت تعداد پاسخ‌های صحیح به کل مجموعه است که عملکرد الگوریتم را در دسته‌بندی انواع بدافزارها مشخص می‌کند. معیار پوشش، دقت الگوریتم را در یادآوری نمونه‌های مخصوص به هر دسته می‌سنجد. معیار صحت نیز میزان درستی پیش‌بینی الگوریتم در معرفی اعضای هر دسته را نشان می‌دهد. تعاریف ریاضی این معیارها به ترتیب در روابط (۲) الی (۴) آورده شده است. برای ارائه دقیق‌تر نتایج، معیارهای موردنظر به همراه جدول سردرگمی^۴ آورده می‌شوند تا قوت و ضعف الگوریتم در تفکیک انواع مختلف خانواده‌ها مشخص شود.

البته فارغ از اینکه نقاط ضعف و قوت الگوریتم مربوط کدام نوع بدافزارها باشد، دقت دسته‌بندی به‌عنوان معیار اصلی این پژوهش همواره اولویت دارد. دلیل اهمیت معیار دقت آن است که الگوریتم این پژوهش و پژوهش‌های مرتبط، برای خودکارسازی فرایند تحلیل بدافزار به‌خصوص دسته‌بندی آن‌ها طراحی شده است. دسته‌بندی اشتباه یک بدافزار به نوبه خود عواقبی ندارد و تنها زمان تحلیل را برای فرد متخصص طولانی می‌کند. اما اگر دقت دسته‌بندی الگوریتم برای تعداد بسیاری از نمونه‌ها کافی نباشد، به همان اندازه بهره‌وری تحلیل‌گران نیز کاهش پیدا خواهد کرد. البته می‌توان استدلال کرد که تشخیص بعضی

ماتریسی مربعی به ابعاد ۱۶×۱۶ جایگذاری کرد که نحوه چینش آن در شکل (۱۰) نشان داده شده است. در این شکل $F(m)$ بیانگر تعداد تکرار عدد m در بردار موردنظر است.

ماتریس هیستوگرام بلوکی

B_1	$F_1(0)$	$F_1(1)$	$F_1(2)$	...	$F_1(255)$
B_2	$F_2(0)$	$F_2(1)$	$F_2(2)$	...	$F_2(255)$
B_3	$F_3(0)$	$F_3(1)$	$F_3(2)$	...	$F_3(255)$
...	...	...	...	...	...
B_{256}	$F_{256}(0)$	$F_{256}(1)$	$F_{256}(2)$	...	$F_{256}(255)$

شکل (۹). چینش درایه‌ها در ماتریس هیستوگرام بلوکی یک بردار

ماتریس هیستوگرام کامل یک بردار دلخواه

$F(0)$	$F(1)$	$F(2)$	...	$F(15)$
$F(16)$	$F(17)$	$F(18)$	...	$F(31)$
$F(32)$	$F(33)$	$F(34)$	...	$F(47)$
...	...	...	...	...
$F(240)$	$F(241)$	$F(242)$	...	$F(255)$

شکل (۱۰). چینش درایه‌ها در ماتریس هیستوگرام

۳-۳- استخراج ویژگی

پس از آنکه فایل بدافزار به روش‌های مختلف بصری‌سازی شد، برای تحلیل تصاویر به‌دست‌آمده از توصیفگر GIST استفاده می‌شود. این توصیفگر نخستین‌بار در پژوهش [۱۹] معرفی شده است که می‌تواند بدون نیاز به تشخیص اشیاء، ویژگی‌های کافی برای تشخیص محیط را فراهم کند. در این الگوریتم بانکی از فیلترهای گابور در مقیاس‌ها و چرخش‌های مختلف به تصویر موردنظر اعمال می‌شوند. تصاویر به‌دست‌آمده هم‌اندازه با تصویر ورودی خواهند بود که در آن‌ها مطابق با فیلتر اعمال شده، برخی الگوهای تصویر برجسته شده است. در ادامه هریک از این تصاویر به بلوک‌های هم‌اندازه تفکیک شده و میانگین هر بلوک محاسبه می‌شود. مجموعه میانگین‌های به‌دست‌آمده، برداری از ویژگی‌ها را تشکیل می‌دهد که به آن توصیف GIST از تصویر موردنظر گفته می‌شود. البته باید به این نکته اشاره کرد که تعداد جهت‌ها و مقیاس‌ها در هر کاربرد متغیر است و انتخاب دقیق آن می‌تواند تأثیر زیادی در نتایج داشته باشد. با این حال روش نظام‌مندی برای انتخاب تعداد جهت‌ها و مقیاس‌ها وجود ندارد و بهترین تنظیمات با انجام آزمون‌های متعدد به دست می‌آید.

در این پژوهش از توصیفگر GIST برای استخراج ویژگی

¹ Accuracy

² Recall

³ Precision

⁴ Confusion Matrix

جدول (۱). توزیع بدافزارها در مجموعه Malimg

تعداد	بدافزار	تعداد	بدافزار
۱۸۴	Lolyda.AA2	۱۲۲	Adialer.C
۱۲۳	Lolyda.AA3	۱۱۶	Agent.FYI
۱۵۹	Lolyda.AT	۲۹۴۹	Allapple.A
۱۳۶	Malex.gen! J	۱۵۹۱	Allapple.L
۱۴۲	Obfuscator.AD	۱۹۸	Alureon.gen! J
۱۵۸	Rbot! gen	۱۰۶	Autorun.K
۸۰	Skintrim.N	۲۰۰	C2LOP.gen! g
۱۲۸	Swizzor.gen! E	۱۴۶	C2LOP.P
۱۳۲	Swizzor.gen! I	۱۷۷	Dialplatform.B
۴۰۸	VB.AT	۱۶۲	Dontovo.A
۹۷	Wintrim.BX	۳۸۱	Fakerean
۸۰۰	Yuner.A	۴۳۱	Instantaccess
۹۳۳۹	تعداد کل	۲۱۳	Lolyda.AA1

جدول (۲). توزیع بدافزارهای آموزش در مجموعه مایکروسافت

تعداد	بدافزار
۱۵۴۱	Ramnit
۲۴۷۸	Lollipop
۲۹۴۲	Kelihos_ver3
۴۷۵	Vundo
۴۲	Simda
۷۵۱	Tracur
۳۹۸	Kelihos_ver1
۱۲۲۸	Obfuscator.ACY
۱۰۱۳	Gatak
۱۰۸۶۸	تعداد کل

۵- یافته‌های پژوهش

پارامترهای تنظیم‌شده برای ارزیابی روش پیشنهادی این پژوهش به شرح زیر است.

۱. **پیش‌پردازش:** از نمونه بدافزارهای موردنظر، سه بردار بایتی، آنتروپی و هیستوگرام تهیه می‌شود.
۲. **بصری‌سازی:** بردارهای سه‌گانه هر بدافزار به روش‌های مختلف بصری‌سازی شده و ۱۵ تصویر مختلف از آن‌ها به دست آورده می‌شود. سپس همه تصاویر به‌دست‌آمده به روش درونیابی دوخطی به ابعاد ۲۵۶×۲۵۶ تغییر سایز داده می‌شوند.

۳. **استخراج ویژگی:** به‌وسیله توصیفگر GIST از هریک از

خانواده‌های بدافزار به دلیل خطرناک‌تر بودن اولویت دارد، اما از آنجاکه در مجموعه‌داده‌های فعلی به میزان اهمیت و خطرناک بودن آن‌ها اشاره نشده است، به همه آن‌ها با یک اولویت نگاه می‌شود.

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (2)$$

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

$$Precision = \frac{TP}{TP + FP} \quad (4)$$

۴-۱- مجموعه‌داده

در این پژوهش از دو مجموعه‌داده Malimg و مایکروسافت برای ارزیابی الگوریتم پیشنهادی استفاده‌شده است.

مجموعه‌داده Malimg دربردارنده ۹۳۳۹ بدافزار از ۲۵ خانواده مختلف است که در پژوهش [۶] ارائه‌شده است و یکی از پراستفاده‌ترین مجموعه‌ها در حوزه تحلیل تصویری بدافزار به شمار می‌آید. نمونه‌های مخرب با استفاده از روش بصری‌سازی مربوط به آن پژوهش به قالب تصویری png درآمده‌اند. البته از آنجاکه هیچ دخل و تصرفی در محتوای آن‌ها داده نشده است، محتوای دودویی بدافزارها از تصویرشان قابل استخراج است. نکته دیگر در خصوص این مجموعه آن است که در ابتدا، تعداد نمونه‌های این مجموعه ۹۳۴۲ عدد بوده است که ۳ نمونه اضافه‌تر از خانواده Adialer.C داشته است. باین حال به دلیل از دسترس خارج شدن لینک دریافت از دانشگاه کالیفرنیا، مجموعه‌داده موردنظر از تارنمای شخصی گروه مربوطه دریافت شده است که این سه نمونه بدافزار را ندارد [۲۰]. در حال حاضر پژوهش‌هایی که با مجموعه‌داده Malimg کار می‌کنند، همین شرایط را داشته و نبود این سه نمونه را نادیده می‌گیرند. جدول (۱) توزیع بدافزارها در این مجموعه را نشان می‌دهد.

مجموعه‌داده شرکت مایکروسافت دربردارنده بیش از ۲۰ هزار بدافزار از ۹ خانواده مختلف است که طی برگزاری یک رقابت در سال ۲۰۱۵ میلادی به شرکت‌کنندگان ارائه‌شده است [۲۱]. در این مجموعه ۱۰۸۶۸ نمونه برای آموزش و ۱۰۸۷۳ نمونه برای ارزیابی در نظر گرفته‌شده است. البته بنا به دلایل نامعلوم هیچ‌گاه برچسب نمونه‌های ارزیابی به‌صورت عمومی اعلام نشد به همین دلیل در پژوهش‌های مختلف تنها از نمونه‌های آموزش این مجموعه برای ارزیابی الگوریتم‌ها استفاده می‌شود. از برتری‌های این مجموعه که آن را به یک انتخاب ایدئال تبدیل می‌کند، آن است که به همراه فایل دودویی بدافزار، محتوای اسمبلی معکوس آن نیز قرار داده‌شده است. از این‌رو برای محققانی که بر روی تحلیل پیشرفته بدافزارها کار می‌کنند، بسیار مناسب است. جدول (۲) توزیع بدافزارها در این مجموعه را نشان می‌دهد.

نوع خانواده یک بدافزار باید اولویت بیشتری نسبت به تشخیص نسل آن داشته باشد و عواقب انتخاب اشتباه آن نباید در الگوریتم یکسان در نظر گرفته شود. به همین دلیل در ارزیابی دیگری که از مجموعه Malimg انجام شده است بدافزارهای هم خانواده در یک دسته بندی تجمیع شده اند. در این حالت میزان دقت الگوریتم پیشنهادی به ۹۹/۸۶ درصد می رسد که مطابق شکل (۱۳) عموم اشتباهات الگوریتم در شناسایی نسل های خانواده Swizzor و Lolyda برطرف شده است.

شکل (۱۴) جدول سردرگمی الگوریتم برای مجموعه بدافزارهای میکروسافت را نشان می دهد. در این ارزیابی، دقت الگوریتم ۹۹/۱۶ درصد به دست آمده است که مطابق جدول (۶) از پژوهش های مشابه تحلیل تصویری بدافزار جلوتر است.

جدول (۳). «دقت» دسته بندی الگوریتم (به درصد)

برای مجموعه بدافزارهای Malimg

بصری سازی	بردار	بایتی	آنتروپی	هیستوگرام
مستقیم	۹۹/۱۰	۹۸/۸۸	۹۹/۳۵	
هم رخدادی	۹۰/۵۸	۹۳/۵۰	۹۵/۶۲	
نقطه ای	۹۸/۸۹	۹۹/۳۳	۹۸/۸۴	
هیستوگرام بلوکی	۹۹/۱۹	۹۹/۶۰	۹۹/۲۱	
هیستوگرام کامل	۸۰/۸۸	۹۳/۲۵	۹۵/۱۴	

جدول (۴). «دقت» دسته بندی الگوریتم (به درصد)

برای مجموعه بدافزارهای میکروسافت

بصری سازی	بردار	بایتی	آنتروپی	هیستوگرام
مستقیم	۹۷/۳۱	۹۷/۳۷	۹۷/۹۷	
هم رخدادی	۹۶/۶۷	۹۸/۱۸	۹۷/۲۵	
نقطه ای	۹۷/۱۲	۹۷/۳۱	۹۶/۷۳	
هیستوگرام بلوکی	۹۶/۶۳	۹۸/۲۷	۹۷/۲۳	
هیستوگرام کامل	۹۶/۶۶	۹۸/۱۱	۹۷/۱۵	

تصاویر به دست آمده، ۱۲۸ ویژگی استخراج می شود که با کنار هم قرار دادن آن ها، برداری به طول ۱۹۲۰ ویژگی به دست خواهد آمد.

۴. طبقه بندی: پس از به دست آوردن بردار ویژگی برای همه نمونه ها، ستون های مربوط به هر ویژگی نرمال سازی می شود. در نهایت طبقه بندی SVM بر اساس اعتبارسنجی متقابل ۱۰ لایه مورد آموزش و ارزیابی قرار می گیرد.


۵-۱- بررسی جداگانه بردارهای ویژگی

در این پژوهش برای آنکه خصوصیات بصری سازی های مختلف سنجیده شود، بردارهای ویژگی هر بصری سازی، جداگانه به طبقه بند ارائه شده و بر اساس معیار دقت مورد ارزیابی قرار می گیرند. جدول (۳) و (۴) دقت دسته بندی الگوریتم به ازای بصری سازی های مختلف را نشان می دهد. با مقایسه این دو جدول که مربوط به مجموعه بدافزارهای متفاوتی است، می توان مشاهده کرد که لزوماً بصری سازی برتر و کامل تری بین آن ها وجود ندارد. هر کدام از آن ها به سهم خود می تواند تا حد قابل قبولی (معمولاً ۹۰ درصد) بدافزارها را به خانواده های متناظرشان دسته بندی کنند.


۵-۲- ترکیب بردارهای ویژگی

هریک از بصری سازی های معرفی شده در این پژوهش، در تشخیص بدافزارهای به خصوصی موفق اند که انتظار می رود ترکیب بردارهای ویژگی آن ها بتواند نتایج بهتری را فراهم کند. ترکیب ویژگی های ۱۵ بصری سازی مختلف، برداری شامل ۱۹۲۰ ویژگی می سازد (۱۲۸×۱۵) که می توان آن را مستقیماً به طبقه بند ارائه داده و مورد بررسی قرارداد. آزمون های متعدد نشان داده است که تنها با استفاده از بردار ویژگی ۱۹۲۰ بُعدی، می توان بهترین نتیجه را به دست آورد.


شکل (۱۲) جدول سردرگمی الگوریتم برای مجموعه داده Malimg را نشان می دهد. در این دسته بندی، دقت الگوریتم ۹۹/۷۲ درصد به دست آمده است که مطابق جدول (۵) به جز در پژوهش [۲۲] از تمام پژوهش های مربوطه جلوتر است. البته همان پژوهش نتوانسته است در ارزیابی مجموعه میکروسافت با نتایج این پایان نامه رقابت کند؛ بنابراین می توان استدلال کرد که الگوریتم پیشنهادی این پایان نامه درک کامل تری از بدافزارها دارد که سبب می شود در هردو مجموعه آزمون بسیار موفق باشد. نکته نادیده گرفته شده در مجموعه داده Malimg آن است که در این مجموعه علاوه بر خانواده های مختلف بدافزارها، نسل آن ها نیز به صورت جداگانه آورده شده است. با این حال تشخیص صحیح



شکل (۱۲). جدول سردرگمی الگوریتم برای مجموعه بدافزارهای Malimg



شکل (۱۳). جدول سردرگمی الگوریتم برای مجموعه بدافزارهای Malimg (بدون در نظر گرفتن نسل بدافزارها)



شکل (۱۴). جدول سردرگمی الگوریتم برای مجموعه بدافزارهای Microsoft

پژوهش‌های مرتبط	دقت الگوریتم
Narayanan BN et al. 2016 [29]	۹۶/۶۰
Gibert D et al. 2019 [25]	۹۸/۴۰
Wang C et al. 2021 [28]	۹۷/۳۰
Guo H et al. 2020 [22]	۹۷/۸۸
Santacroce ML et al. 2020 [30]	۹۸/۷۴
روش پیشنهادی	۹۹/۱۶

۵-۳- ترکیب مجموعه‌ها


ترکیب مجموعه‌ها برای ساخت فضای نمونه گسترده‌تر، آخرین مرحله ارزیابی این پژوهش محسوب می‌شود که تاکنون در هیچ پژوهش دیگری انجام نشده است. از یک طرف به دلیل نبود مجموعه داده‌های متنوع، پژوهش‌های سالیان گذشته تنها به دو مجموعه Malimg و Microsoft محدود بوده و از طرف دیگر مجموعه Malimg به دلیل بصری‌سازی پیش فرض خود، هیچ‌گاه

جدول (۵). دقت الگوریتم‌های مختلف بر اساس مجموعه Malimg

پژوهش‌های مرتبط	دقت الگوریتم
Nataraj L et al. 2011 [6]	۹۸/۰۸
Rezende E et al. 2017 [23]	۹۸/۶۲
Yue S. 2017 [24]	۹۸/۶۳
Cui Z et al. 2018 [10]	۹۴/۵۰
Gibert D et al. 2019 [25]	۹۸/۴۰
Naeem H et al. 2019 [26]	۹۸/۴۰
Vasan D et al. 2020 [27]	۹۸/۸۲
Wang C et al. 2021 [28]	۹۸/۵۰
Vasan D et al. 2020 [8]	۹۹/۵۰
Guo H et al. 2020 [22]	۹۹/۸۳
روش پیشنهادی	۹۹/۷۲


جدول (۶). دقت الگوریتم‌های مختلف بر اساس مجموعه مایکروسافت

می‌شود. شکل (۱۵) جدول سردرگمی الگوریتم برای مجموعه ترکیبی جدید را نشان می‌دهد. این مجموعه ۲۰۱۹۹ نمونه از ۲۸ خانواده متفاوت دارد که دقت دسته‌بندی الگوریتم برای آن ۹۹/۳۷ درصد ارزیابی شده است. با مقایسه شکل (۱۵) با شکل‌های (۱۲، ۱۳ و ۱۴) می‌توان مشاهده کرد که مشخصه «پوشش» نمونه‌ها بدون تغییر مانده است و الگوریتم با بزرگ‌تر شدن فضای نمونه‌ای، یادگیری قبلی خود را از دست نداده است.



شکل (۱۵). جدول سردرگمی الگوریتم از ترکیب مجموعه بدافزارهای Malimg و Microsoft

نشان می‌دهد که الگوریتم‌های تحلیل تصویری بدافزار، برخلاف ادعاهای مطرح‌شده در پژوهش‌های پیشین، الگوهای مخرب را جستجو نمی‌کنند، بلکه الگوهای انسانی را دنبال می‌کنند که سازندگان بدافزار از روی عادت مرتکب می‌شوند. الگوها و اشتباهات انسانی که می‌تواند به دلیل استفاده از ابزارهای برنامه‌نویسی یکسان یا رونوشت کدهای مخربی باشد که خود فرد آن را توسعه داده و به‌عنوان امضای کاری خود بکار می‌گیرد.



شکل (۱۶). مراحل استخراج ویژگی از تصویربرداری بیتی یک بدافزار

استفاده از روش یادگیری عمیق که امروز در کانون توجهات قرار دارد، سبب شده که پژوهشگران از تحلیل جزئیات مسئله بازمانند و با سپردن استخراج ویژگی به این جعبه سیاه، تحلیل‌هایی را به آن نسبت دهند که لزوماً با واقعیات مسئله تطابق نداشته باشد. البته این موضوع، موفقیت شبکه‌های عصبی

قابل ترکیب با مجموعه مایکروسافت نبوده است. با این حال در این پژوهش نشان داده شد که می‌توان در مجموعه Malimg، محتوای دودویی نمونه‌ها را از تصاویرشان قابل استخراج کرد که این موضوع کمک می‌کند آن‌ها را در کنار مجموعه مایکروسافت با هر بصری سازی دلخواه مورد استفاده قرار داد. بدین ترتیب نه تنها توانایی الگوریتم در طیف وسیع‌تری از بدافزارها مورد آزمایش قرار می‌گیرد؛ بلکه مسیر جدیدی برای پژوهش‌های بعدی فراهم

۴-۵- اعتبار و مزایای روش پیشنهادی

روش پیشنهادی این پژوهش با اینکه فرایند آموزش و ارزیابی ساده‌تری نسبت به پژوهش‌های مشابه دارد؛ اما در هنگام ارزیابی می‌تواند هم‌تراز آن‌ها عمل کند. اکثر پژوهش‌های مشابه از روش‌های یادگیری عمیق استفاده کرده‌اند که به‌مراتب پیچیدگی زمانی بیشتری نسبت به روش این پژوهش دارند و از لحاظ عملکرد در بسیاری از زمینه‌های علمی نیز پیش‌تاز هستند. با این تفاسیل اگر بتوان تشخیص داد که چه ویژگی‌هایی در تشخیص بدافزارها مؤثرند می‌توان تاحدامکان، روش‌های ساده‌تر و بهینه‌تری را برای دسته‌بندی بدافزارها به کار گرفت.

شکل (۱۶) نمونه‌ای از فرایند استخراج ویژگی از تصویر یک بدافزار دلخواه را نشان می‌دهد. مطابق شکل، تصویر بدافزار بعد از اعمال فیلتر به ۱۶ بلوک تفکیک‌شده و از هریک میانگین گرفته می‌شود تا برداری متشکل از ۱۶ ویژگی بسازد. در این فرایند ویژگی‌های استخراج‌شده به دستورات به‌کاررفته در فایل اشاره ندارند بلکه ساختار فایل اعم از نوع داده‌های به‌کاررفته و نحوه قرارگیری آن‌ها برای الگوریتم قابل تشخیص می‌شود. این موضوع

است. به لطف بار پردازشی کمی که توصیفگر GIST به همراه داشته است، این فرصت فراهم شد که تمرکز پژوهش بر روی ساخت انواع بصری سازی ها قرار گیرد. بصری سازی های مختلف طی آزمون و خطاهای بسیار مورد بررسی قرار گرفتند تا به آنچه اکنون در اختیار است، برسند البته در ابتدای امر تمام تلاش ها به این منظور صورت گرفته است که با کشف یک بصری سازی مناسب، الگوریتم نهایی از توصیفگر GIST به یک شبکه عصبی پیچشی مهاجرت داده شود؛ اما به مرور زمان مشخص شد که حتی اگر بهترین طبقه بندی ها بکار گرفته شود، یک بصری سازی تنها نمی تواند راه حلی برای همه مشکلات باشد؛ بنابراین رویکرد این پژوهش ناخواسته به سمت ترکیب ویژگی ها سوق داده شد که توانست به نتایج بسیار بهتری ختم شود.

الگوریتم فعلی این پژوهش این استعداد را دارد که با جایگزینی استخراج گر GIST و طبقه بند SVM با شبکه های عصبی عمیق، بهبود یابد. اکنون با در اختیار داشتن مجموعه ای از ۲۰ هزار بدافزار، این فرصت فراهم است که بدون نگرانی از بابت نامتوازن بودن مجموعه ها، با آزادی عمل بیشتری به آموزش الگوریتم های یادگیری عمیق پرداخته شود. البته مطالعه مقالات مختلف نیز نشان می دهد که طراحی یک شبکه عصبی پیچشی از پایه، لزوماً راهبرد سریعی نیست. روش های یادگیری عمیق همه روزه در حال به روز رسانی هستند و متخصصان بسیاری از سراسر دنیا در توسعه آن نقش دارند. استفاده از شبکه های عصبی پیچشی که به صورت انتقالی آموزش می بینند نه تنها فرایند آموزش آن سرعت می بخشد بلکه اجازه می دهد که تمرکز پژوهش بر روی بهبود بصری سازی ها و روش های بصری سازی بهتر معطوف شود. بدین ترتیب با معرفی هر شبکه جدیدتر و تواناتر، الگوریتم مربوطه می تواند به ساختارهای جدید مهاجرت کند.

۷- مراجع

- [1] R. Moir, "Defining Malware: FAQ," 2009. [Online]. Available: <https://technet.microsoft.com/en-us/library/dd632948.aspx>
- [2] C. C. Elisan, *Advanced malware analysis*. McGraw Hill Professional, 2015.
- [3] AV-TEST - The Independent IT-Security Institute, "Malware Statistics & Trends Report," 2022. [Online]. Available: <https://www.av-test.org/en/statistics/malware/>
- [4] D. Simpson, "Malware names." [Online]. Available: <https://docs.microsoft.com/en-us/microsoft-365/security/intelligence/malware-naming>
- [5] D. Gibert, C. Mateu, and J. Planes, "The rise of machine learning for detection and classification of malware: Research developments, trends and challenges," *J. Netw. Comput. Appl.*, vol. 153, p. 102526, 2020, doi: 10.1016/j.jnca.2019.102526.

عمیق را انکار نمی کند و چه بسا در مجموعه داده های وسیع تر نیاز به یک استخراج گر ویژگی عمومی تر مثل مثل شبکه های عصبی عمیق احساس شود. در هر صورت تا بدین جای کار، نتایج این پژوهش نشان می دهد که حتی برای مجموعه ای به وسعت ۲۰ هزار بدافزار می توان با بهبود بصری سازی بدافزارها به نتیجه یکسان دست یافت. نکته نگران کننده در این باره آن است که الگوریتم این پایان نامه و پژوهش های پیشین توانسته است بدافزارها را نه بر اساس الگوهای مخرب، بلکه بر اساس اشتباهات انسانی شناسایی کند. از آنجاکه سازندگان بدافزار همچون محققان در زمینه کاری خود بسیار پیگیر هستند، در صورتی که از این نتایج مطلع شوند، روش های پیشگیرانه ای را برای محافظت از بدافزارهای خود ترتیب خواهند داد که این موضوع سبب می شود، در آینده، استفاده از بصری سازی های این پژوهش و توصیفگر ساده ای همچون GIST برای جستجوی الگوها کافی نباشد.

۶- نتیجه گیری

دقت دسته بندی بالا و سبک بودن محاسبات الگوریتم، از نقاط قوت روش پیشنهادی محسوب می شود که آن را هم تراز با روش های مشابه خود قرار می دهد. ارزیابی روش این پژوهش با مجموعه بدافزارهای Malimg و Microsoft نشان می دهد که نه تنها از لحاظ دقت، توانایی روش فعلی با روش یادگیری عمیق برابری می کند؛ بلکه حتی با ترکیب این مجموعه بدافزارها نیز توانایی آن همچنان قابل قبول است، بدون آنکه نیاز به بازنگری پارامترها یا آموزش های طولانی مجدد باشد. در کنار مزایای ذکر شده، سادگی استفاده از توصیفگر GIST و طبقه بند SVM نیز باعث شده است که نگاه دقیق تری به سازوکار داخلی آن شود و اعتبار تحلیل تصویری بدافزار بیش از پیش مورد بررسی قرار گیرد.

تحلیل تصویری بدافزار با وجود گذشت یک دهه، همچنان در ابتدای راه خود به سر می برد. علی رغم طیف وسیع خلاقیت ها و ابتکاراتی که می توان در این مسیر بکار برد، همچنان پژوهش های کمی وجود دارند که به طور اساسی به این مقوله پرداخته باشند. در اغلب موارد، چالش مربوطه بدون تحلیل دقیق تر و تنها با به کارگیری یک طبقه بند پیشرفته پشت سر گذاشته شده است. این موضوع سبب شد که در ابتدای مسیر این پژوهش، به یافته های پژوهش های قبلی با دیده شک و تردید نگاه شود. چراکه اکثر آن ها همان پژوهش قبلی اما با یک الگوریتم بهبود یافته تر بوده اند بدون آنکه تفسیری از سازوکار آن داشته باشد. استفاده از توصیفگر GIST به عنوان استخراج گر ویژگی این پژوهش، در نتیجه تلاش هایی بوده است که در ابتدا برای تولید نتایج پژوهش های قبلی انجام گرفته است؛ اما در نهایت به دلیل کاربردی بودن آن، به عنوان الگوریتم اصلی پژوهش حفظ شده

- [19] A. Oliva and A. Torralba, "Modeling the shape of the scene: A holistic representation of the spatial envelope," *Int. J. Comput. Vis.*, vol. 42, no. 3, pp. 145–175, 2001, doi: 10.1023/A:1011139631724.
- [20] SARVAM Team, "Supervised Classification with k-fold Cross Validation on a Multi Family Malware Dataset." [Online]. Available: <https://sarvamblog.blogspot.com/2014/08/supervised-classification-with-k-fold.html>
- [21] R. Ronen, M. Radu, C. Feuerstein, E. Yom-Tov, and M. Ahmadi, "Microsoft malware classification challenge," *arXiv Prepr. arXiv1802.10135*, 2018.
- [22] H. Guo, S. Huang, C. Huang, Z. Pan, M. Zhang, and F. Shi, "File entropy signal analysis combined with wavelet decomposition for malware classification," *IEEE Access*, vol. 8, pp. 158961–158971, 2020, doi: 10.1109/ACCESS.2020.3020330.
- [23] E. Rezende, G. Ruppert, T. Carvalho, F. Ramos, and P. De Geus, "Malicious software classification using transfer learning of resnet-50 deep neural network," in *2017 16th IEEE International Conference on Machine Learning and Applications (ICMLA)*, 2017, pp. 1011–1014. doi: 10.1109/ICMLA.2017.00-19.
- [24] S. Yue, "Imbalanced malware images classification: a CNN based approach," *arXiv Prepr. arXiv1708.08042*, 2017.
- [25] D. Gibert, C. Mateu, J. Planes, and R. Vicens, "Using convolutional neural networks for classification of malware represented as images," *J. Comput. Virol. Hacking Tech.*, vol. 15, no. 1, pp. 15–28, 2019, doi: 10.1007/s11416-018-0323-0.
- [26] H. Naeem, B. Guo, M. R. Naeem, F. Ullah, H. Aldabbas, and M. S. Javed, "Identification of malicious code variants based on image visualization," *Comput. & Electr. Eng.*, vol. 76, pp. 225–237, 2019, doi: 10.1016/j.compeleceng.2019.03.015.
- [27] D. Vasan, M. Alazab, S. Wassan, H. Naeem, B. Safaei, and Q. Zheng, "IMCFN: Image-based malware classification using fine-tuned convolutional neural network architecture," *Comput. Networks*, vol. 171, p. 107138, 2020, doi: 10.1016/j.comnet.2020.107138.
- [28] C. Wang, Z. Zhao, F. Wang, and Q. Li, "A novel malware detection and family classification scheme for IoT based on DEAM and DenseNet," *Secur. Commun. Networks*, vol. 2021, 2021, doi: 10.1155/2021/6658842.
- [29] B. N. Narayanan, O. Djaneye-Boundjou, and T. M. Kebede, "Performance analysis of machine learning and pattern recognition algorithms for malware classification," in *2016 IEEE National Aerospace and Electronics Conference (NAECON) and Ohio Innovation Summit (OIS)*, 2016, pp. 338–342. doi: 10.1109/NAECON.2016.7856826.
- [30] M. L. Santacrose, D. Koranek, and R. Jha, "Detecting malware code as video with compressed, time-distributed neural networks," *IEEE Access*, vol. 8, pp. 132748–132760, 2020, doi: 10.1109/ACCESS.2020.3010706.
- [6] L. Nataraj, S. Karthikeyan, G. Jacob, and B. S. Manjunath, "Malware images: visualization and automatic classification," in *Proceedings of the 8th international symposium on visualization for cyber security*, 2011, pp. 1–7. doi: 10.1145/2016904.2016908.
- [7] L. Chen, R. Sahita, J. Parikh, and M. Marino, "STAMINA: Scalable Deep Learning Approach for Malware Classification," 2020. [Online]. Available: <https://www.intel.com/content/dam/www/public/us/en/ai/documents/stamina-scalable-deep-learning-whitepaper.pdf>
- [8] D. Vasan, M. Alazab, S. Wassan, B. Safaei, and Q. Zheng, "Image-Based malware classification using ensemble of CNN architectures (IMCEC)," *Comput. & Secur.*, vol. 92, p. 101748, 2020, doi: 10.1016/j.cose.2020.101748.
- [9] L. Chen, "Deep transfer learning for static malware classification," *arXiv Prepr. arXiv1812.07606*, 2018.
- [10] Z. Cui, F. Xue, X. Cai, Y. Cao, G. Wang, and J. Chen, "Detection of malicious code variants based on deep learning," *IEEE Trans. Ind. Informatics*, vol. 14, no. 7, pp. 3187–3196, 2018, doi: 10.1109/TII.2018.2822680.
- [11] E. Bastami, P. Keshavarzi, M. Rahmanianesh, and H. Soltanizadeh, "A Malware Classification Method Using visualization and Word Embedding Features," *Electron. Cyber Def.*, 2023, <https://dor.isc.ac/dor/20.1001.1.23224347.1402.11.1.1.2>
- [12] R. Lyda and J. Hamrock, "Using entropy analysis to find encrypted and packed malware," *IEEE Secur. & Priv.*, vol. 5, no. 2, pp. 40–45, 2007, doi: 10.1109/MSP.2007.48.
- [13] X. Ugarte-Pedrero, I. Santos, B. Sanz, C. Laorden, and P. G. Bringas, "Countering entropy measure attacks on packed software detection," in *2012 IEEE Consumer Communications and Networking Conference (CCNC)*, 2012, pp. 164–168. doi: 10.1109/CCNC.2012.6181079.
- [14] D.-L. Vu, T.-K. Nguyen, T. V. Nguyen, T. N. Nguyen, F. Massacci, and P. H. Phung, "HIT4Mal: Hybrid image transformation for malware classification," *Trans. Emerg. Telecommun. Technol.*, vol. 31, no. 11, p. e3789, 2020, doi: 10.1002/ett.3789.
- [15] J. Fu, J. Xue, Y. Wang, Z. Liu, and C. Shan, "Malware visualization for fine-grained classification," *IEEE Access*, vol. 6, pp. 14510–14523, 2018, doi: 10.1109/ACCESS.2018.2805301.
- [16] Z. Ren, G. Chen, and W. Lu, "Malware visualization methods based on deep convolution neural networks," *Multimed. Tools Appl.*, vol. 79, no. 15, pp. 10975–10993, 2020.
- [17] J. Kim, J.-Y. Paik, and E.-S. Cho, "Attention-Based Cross-Modal CNN Using Non-Disassembled Files for Malware Classification," *IEEE Access*, vol. 11, pp. 22889–22903, 2023, doi: 10.1109/ACCESS.2023.3253770.
- [18] K. Shaukat, S. Luo, and V. Varadharajan, "A novel deep learning-based approach for malware detection," *Eng. Appl. Artif. Intell.*, vol. 122, p. 106030, 2023, doi: 10.1016/j.engappai.2023.106030.