فصلنامه علمی - پژوهشی فرماندهی و کنترل، سال ششم، شماره دو، تابستان 1401

بهبود افزایش امنیت و تشخیص بدافزار با استفاده از الگوریتم‌های تجمیعی

زهره بوشهری[1]، پروانه اصغری[1]*

تاریخ دریافت: 1401/05/02 **تاریخ پذیرش:** 1401/07/23

چکیده

یکی از راه های امنیت، تشخیص بدافزار در سامانه های کامپیوتری توسط روش های شناسایی بدافزار می باشد. از آنجایی که این امر هزینه مالی، زمانی و انسانی زیادی به همراه دارد، تحقیق پیش رو درصدد بوده تا با تکیه بر استخراج اطلاعات مفید داده ها از روی دیتاست بدافزار مایکروسافت با نام BIG 2015 یک کلاسه کننده که هم در زمینه ی استخراج ویژگی و هم در زمینه ی ساز و کار طبقه بند که بسیار ساده و پیچیدگی محاسباتی کمی دارد هزینه های ذکر شده را کاهش دهد. در این راستا جهت دستیابی به پیش بینی های بهتر و دقت بالاتر از الگوریتم های Xgboost و Lgb ، مجموعه ویژگی های مبتنی بر محتوا و تکنیک‌های Feature selection ، Feature Importance و permutation Importance استفاده شده است. از میان 1804 ویژگی استخراج شده ویژگی section_name_headre با وزن 0/2160 نقش مهم تر و پر رنگ تری در کلاسه بندی ایفا کرده است . که میزان دقت کلاسه کننده 99/81 و خطای پیش بینی کننده به میزان 0/00774 بدست آمده است. لذا با بهره گیری از یافته های این تحقیق در سامانه های IDS و IPS می توان دقت تشخیص بدافزار را افزایش و میزان خطای تشخیص را کاهش داد.

کلید واژه : یادگیری ماشین ،بدافزار، انتخاب ویژگی ، permutation Importance ، Xgboost

[1] گروه مهندسی کامپیوتر، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران.z.boushehri9699@gmail.com

[1] گروه مهندسی کامپیوتر، واحد تهران مرکزی، دانشگاه آزاد اسلامی، تهران، ایران.p_asghari@iauctb.ac.ir

[Downloaded from ic4i-journal.ir on 2026-10-14]

۱. مقدمه

با فراگیرشدن استفاده از شبکه‌های کامپیوتری و افزایش ارتباطات در حوزه علوم کامپیوتری، یکی از مسائلی که توجه کارشناسان امر را به خود مشغول داشته است، امنیت سیستم‌های کامپیوتری است. از حوزه‌های مهم این علم می‌توان به شناسایی و کشف نرم‌افزارهای مخرب اشاره کرد ،نرم‌افزارهای مخرب را بدافزار می نامند. بدافزار یک تکه کد است که رفتار سیستم عامل یا برخی از برنامه های حساس امنیتی را بدون رضایت کاربر تغییر می دهد. شناسایی این تغییرات با استفاده از ویژگی ثبت اعمال سیستم عامل یا هر برنامه ی دیگری ممکن نیست. با پیشرفت سریع و توسعه وب ، امروزه یکی از مهمترین خطرات دیجیتالی بشمار می‌آیند که در سیستم‌های کامپیوتری پخش شده و رفتار عادی سیستم را دچار اختلال می‌کنند [1]. از زمان پیدایش اولین کد مخرب کامپیوتری در سال 1986هر ساله تعداد قابل توجهی از کدهای مخرب جدیدی ظهور پیدا می‌کنند. این رشد سریع کدهای مخرب، تلاش‌های متخصصین امنیتی برای ارائه راه‌حل‌هایی به منظور تشخیص و حذف آن‌ها از سیستم کاربران را بالا برده‌است [2] [3]. این نرم‌افزارها طیف وسیعی از خطرات و تهدیدها را در بر می‌گیرند و براساس نحوه آسیب رسانی به سیستم قربانی به دسته‌های مختلفی از جمله ویروس‌ها، کرم‌ها، اسب‌های تروآ، جاسوس‌افزارها، آگهی‌افزارها، روت‌کیت‌ها و هرزنامه‌ها تقسیم می شوند [4]. روش‌های شناسایی بدافزار از دیدگاه‌های مختلفی طبقه‌بندی شده‌اند که دراین مقاله روش‌های شناسایی بدافزار به سه گروه مبتنی بر ناهنجاری، ویژگی و امضا تقسیم می‌شودکه در ادامه توضیح داده می‌شوند [3].

روش مبتنی بر ناهنجاری: از دانش گذشته‌ی خود در مورد آنچه آن را رفتار عادی می‌داند جهت تشخیص بدافزار مورد بررسی استفاده می‌نماید. نوع خاصی از روش مبتنی بر ناهنجاری با نام روش مبتنی بر ویژگی شناخته می‌شود. این روش از یک سری ویژگی‌ها یا قوانینی از رفتار درست به عنوان ابزاری جهت تشخیص بدافزار بودن فایل استفاده می‌کنند. برنامه‌ای که دارای آن ویژگی‌ها نباشد مشکوک و یا بدافزار تلقی می‌شوند. روش مبتنی بر ناهنجاری معمولا در دو مرحله انجام می‌شود. یک مرحله آموزش و یک مرحله تشخیص در طول مرحله آموزش تشخیص- گر سعی در رفتار عادی دارد. یکی از مزیت‌های اصلی روش مبتنی بر ناهنجاری توانایی آن در تشخیص حملات روز نخست است.

تشخیص مبتنی بر ویژگی: نوعی از تشخیص مبتنی بر ناهنجاری است که سعی دارد هشدار اشتباه بالای روش‌های مبتنی بر ناهنجاری را بهبود ببخشد. در روش مبتنی بر ویژگی در فاز یادگیری مجموعه‌ای از قواعد ایجاد می‌گردد که این قواعد مشخص کننده تمامی رفتارهای درستی است که هر برنامه‌ای در سیستم در حال بررسی می‌تواند از خود بروز دهد. بزرگترین

[Downloaded from ic4i-journal.ir on 2026-10-14]

مزیت روش مبتنی بر ویژگی آن است که مشخص نمودن درست و دقیق مجموعه رفتارهایی که برنامه می تواند از خود بروز دهد [5,6].

روش مبتنی بر امضا: از امضای خاصی که به هر فایل تعلق دارد جهت تشخیص بدافزار بودن فایل های مشابه استفاده می نماید. بصورت ایده‌آل یک امضا باید بتواند هر بدافزاری را که رفتاری شبیه آنچه در امضا مشخص شده از خود بروز دهد را شناسایی نماید. این امضاها نیازمند مخزنی جهت ذخیره سازی هستند. این مخزن تمامی دانشی است که روش مبتنی بر امضا دارا است. هنگامی که روش مبتنی بر امضا سعی در کشف یک بدافزار درون فایل دارند این مخزن جستجو می شود. در حال حاضر امضاهایی که نشان دهنده بدافزار هستند عمدتاً توسط عوامل انسانی خبره توسعه داده می شوند. هنگامی که امضای جدیدی تشخیص داده می شود به مخزن دانش اضافه می گردد. یکی از اشکالات عمده روش مبتنی بر امضا عدم تشخیص حملات روز نخست است زیرا هیچ امضایی از این نوع در مخزن وجود ندارد (اسکندری و هاشمی 2012 ، سانتوز و دیگران 2013 ، ایگل و دیگران 2007).

هر روش تشخیصی می‌تواند بر یکی از سه روش ایستا، پویا یا ترکیبی باشد (روبیا و دیگران ،2009). روش ایستا از ویژگی هایی مانند کد برنامه جهت تشخیص بدافزار بودن آن استفاده می کنند در حالی که روش های پویا از اطلاعات اجرایی مانند پشته برنامه در حال اجرا بهره می برد. به صورت کلی روش ایستا قبل از اجرای برنامه بدافزار بودن آن را تشخیص می دهد ولی روش پویا سعی در تشخیص بدافزار در حین اجرا یا پس از اجرای آن دارد. روش‌های ترکیبی نیز وجود دارند (رابک و دیگران ،2003) که در آن ها اطلاعات ایستا و پویا جهت تشخیص بدافزار بودن استفاده می‌گردد. برای شناسایی بدافزارها، روش‌های متعددی پیشنهاد شده است. یکی از روش هایی که اخیرا در این حوزه مطرح شده است، استفاده از الگوریتم های تجمیعی برای شناسایی خانواده بدافزارها می‌باشد. استفاده از این روش‌ها به دلیل ماهیت عملکرد بالا، می‌تواند موثر واقع شود.

در این مقاله، از مجموعه داده‌های Big Data تشخیص بدافزار سایت kaggle استفاده می‌شود و از دقت و خطا به عنوان دو معیار جهت ارزیابی و آزمون کارایی روش پیشنهادی استفاده می‌شود. برای دست‌یابی به این دو معیار در این مقاله برای انتخاب ویژگی در بخش کلاس‌بندی از الگوریتم LGB و الگوریتم Xgboost که هر دو الگوریتم زیر مجموعه‌ی جنگل تصادفی و از الگوریتم‌های تجمیعی هستند، استفاده شده است. در انتخاب ویژگی‌های مناسب از تکنیک‌های Feature Importance و permutation Importance استفاده می‌شود که اساس و پایه ی این پژوهش جهت نوآوری تکنیک های جدید انتخاب ویژگی می باشد. در این تحیق با استفاده از روش‌های انتخاب ویژگی

فصلنامهٔ علمی - پژوهشی فرماندهی و کنترل، سال ششم ، شمارهٔ دو، تابستان 1401

[Downloaded from ic4i-journal.ir on 2026-10-14]

برای دستیابی به بهترین زیرمجموعه ویژگی‌ها و همچنین دستیابی به پیش بینی‌های بهتر و رسیدن به بالاترین دقت بر اساس این زیرمجموعه کمینه از ویژگی‌ها از مدلسازی پیش‌بینانه استفاده شده‌است. در روش پیشنهادی انواع مختلف تکنیک‌های داده‌کاوی که می‌توانند در زمینه ترکیب طبقه‌بندها مورد استفاده قرار گیرد، مورد بحث و بررسی قرار می‌گیرد. همچنین مفاهیم پایه امنیت و راه‌های تشخیص بدافزار مورد بحث و بررسی قرار می‌گیرد تا ساختارهای مورد استفاده برای ترکیب تشریح گردد.

ساختار این مقاله به این شرح است: در بخش 2، به بیان پیشینه این تحقیق می‌پردازیم. در بخش 3، روش پیشنهادی به تفصیل توضیح داده می‌شود. در بخش 4، نتایج ارزیابی روش پیشنهادی در مقایسه با سایر روش‌ها ارائه می‌شود و در بخش 5 به نتیجه-گیری و کارهای آتی اشاره خواهد شد.

2. پیشینه تحقیق

یکی از مقوله های امنیت فناوری اطلاعات امن بودن فضای تبادل اطلاعات است. بدون شک بدافزارها یکی از مهمترین تهدیدهای امنیتی برای فنآوری اطلاعات بوده و هستند. پیشرفت در توسعه‌ی بدافزارها از یک سو همچنین اهمیت امنیت سیستم‌های کامپیوتری از سوی دیگر، مقابله با این تهدید بزرگ به یکی از مباحث به روز در حوزه‌ی امنیت سیستم‌های کامپیوتری تبدیل شده است.

ریچا شارما و همکارانش در سال2020 یک تکنیک جدید در شناسایی بد افزار Trojan با استفاده از کلاس طبقه بندی شده XGBoost ارائه نمودند. تکنیک‌های موجود در تشخیص بد-افزار تروجان قادر به تشخیص Trojan ها به طور دقیق نیستند، تعادل کلاس را به طور کارآمد کنترل نمی‌کنند، از اهمیت ویژگی درختکاری استفاده نمی‌شود و دارای نرخ مثبت و منفی زیادی هستند، بنابراین برای غلبه بر این مشکلات، این مقاله یک تکنیک جدید تشخیص وزن مبتنی بر Extreme Gradient Boosting (CWXGB) را ارائه می‌دهد، که Trojanها را با استفاده از بهترین مجموعه مقادیر ترکیبی و پی در پی SCOAP و HT را از netlist سطح گیت تشخیص می‌دهد. یک طرح توزین در مدل CW-XGB برای حل مشکل عدم تعادل کلاس با اختصاص وزنه های بالاتر به اقلیت وارد شده در تروجان ارائه شده است. علاوه بر این، یک روش انتخاب ویژگی جدید است که بهترین مجموعه ویژگی‌ها را با استفاده از importance Permutation انتخاب می‌کند و همچنین از تکرار مدل جلوگیری می‌کند. نتایج ارزیابی نشان می‌دهد که روش پیشنهادی به طور متوسط، دقت و یادآوری 04: 99٪ ، 86: 98٪ ، و سرانجام، دقت کل مدل را 73: 98٪ ارائه می‌دهد که اندازه گیری بالایی از قابلیت تفکیک را نشان می‌دهد.

[Downloaded from ic4i-journal.ir on 2026-10-14]

دیمین ماریون و همکارانش در سال 2021 در مقاله [7] رویکردی با استفاده از تابش الکترومغناطیسی برای آشکارساختن مبهمات بدافزارها جهت شناسایی انواع تهدیدات و طبقه‌بندی آن ها که دستگاه‌های اینترنت اشیا را مورد هدف قرار می‌دهند، ارائه نمودند. آنها با گرفتن 100000 نمونه اندازه‌گیری از یک سیستم اینترنت اشیا آلوده به نمونه های مختلف بدافزار دست پیدا نمودند که دقت پیش بینی آزمایش آنها عدد 99.89 درصد را نشان می-دهد. علاوه بر این، نتایج تحقیق آنها نشان می‌دهد نمونه‌های بدافزار تغییریافته را با تکنیک‌های مبهم‌سازی در مرحله آموزش طبقه‌بندی و تعیین کردند که چه نوع مبهم‌هایی وجود دارد که برای تجزیه و تحلیل بدافزارها برای تحلیل گران مفید واقع شود.

در مقاله [8]، بوراک طهتاچی و همکارش در سال 2020 در کنفرانس نوآوری در سیستم های هوشمند و برنامه های کاربردی روشی برای تشخیص بدافزار در دستگاه‌های تلفن هوشمند اندرویدی با استفاده از الگوریتم‌های یادگیری ماشین ارائه نمودند. در این مطالعه فایل‌های smali که بسته‌های اندروید دیکامپایل شده هستند را با استفاده از ویژگی های n-gram که از مدل‌های یادگیری ماشین می‌باشد را استخراج کردند و همچنین ترکیب استخراج ویژگی و انتخاب ویژگی را از مدل های آموزش دیده انجام داده اند.

در مقاله [9]، سونیتا چوداری و همکارش در سال 2020 الگوی رفتاری مطالعه خود را با استفاده از تکنیک‌ها و الگوریتم‌های یادگیری ماشین که از طریق تجزیه و تحلیل استاتیک یا دینامیکی بوده است را برای تشخیص و طبقه بندی بدافزارها بدست آورند، در این تحقیق، روش‌های تشخیص مبتنی بر رفتار [10] را برای استفاده از الگوریتم‌های یادگیری ماشین مورد بحث قرار دادند تا مدل شناسایی و طبقه‌بندی بدافزار مبتنی بر رفتار خود را چارچوب‌بندی کنند. نتایج ارزیابی آزمایش‌های این تحقیق جهت تشخیص بدافزار که با استفاده از برنامه ی J48 بدست آمده است دقت 96.8 درصد را نشان می دهد.

روهیت سریواستا و همکارانش در 5 دسامبر 2020 در مقاله [11] به مطالعه بر روی تشخیص حملات بدافزارها در دستگاه‌های تلفن همراه که از سیستم عامل اندروید استفاده می‌شود پرداختند. روش ارائه شده توسط این گروه محقق ایجاد یک تشخیص‌گر و تحلیل-گر بدافزار می‌باشد در این پژوهش همچنین بینش‌هایی را درباره حملات بدافزار COVID-19 در دستگاه‌های تلفن همراه پیوند می‌دهد. برای دستیابی به این اهداف، مدلی پیاده سازی شده است که ویژگی های ذاتی فایل برنامه اندروید را استخراج کرده و آن‌ها را برای تجزیه و تحلیل سریع و دقیق تجزیه و تحلیل می کند که 400 برنامه را به طور کامل از بازار رسمی اندروید گوگل پلی-

[Downloaded from ic4i-journal.ir on 2026-10-14]

استور جمع آوری کرده اند و با استفاده از الگوریتم K-means که مبتنی بر ویژگی‌های ترکیبی هستند به دقت 96.12٪ رسیدند.

الخاندرو مارتینا و همکارانش در سال ۲۰۱۹ در مقاله [12] یک روش شناسایی بدافزار را بر اساس تلفیق ویژگی های استاتیک و پویا از طریق ترکیب طبقه بندی کننده های گروه برای سیستم‌های اندرویدی ارائه نمودند. در این تحقیق مکانیسم‌های تشخیص، از یادگیری ماشین برای ساخت طبقه بندی چارچوب AndroPyToolو مجموعه داده OmniDroid در تشخیص نرم افزارهای مخرب یا خوش خیم که در تشخیص موثر است استفاده کردند. برای این منظور از ۲۲۰۰۰ نمونه بدافزارهای واقعی نرم افزاری را با هدف کمک به سازندگان و محققان ابزارهای ضد بدافزار هنگام بهبود یا توسعه مکانیسم ها و ابزارهای جدید برای شناسایی بدافزارهای اندرویدی ارائه نمودند.

سلیمان یریما و همکارش در سال ۲۰۱۸ در مقاله [13]، یک رویکرد ترکیبی طبقه‌بندی جدید مبتنی بر یک معماری چندسطحی را ارائه نمودند. که این رویکرد، ترکیبی موثر از الگوریتم‌های یادگیری ماشین برای بالا بردن بهبود دقت می‌باشد. این چارچوب که معرف به DroidFusion است مدلی را ایجاد می‌کند که با آموزش طبقه بندی کننده های پایه در یک سطح پایین، مجموعه‌ای از الگوریتم های مبتنی بر رتبه‌بندی را بر روی دقت‌های پیش بینی کننده آنها در سطح بالاتر به منظور به دست آوردن یک طبقه‌بندی نهایی اعمال می‌کند. مدل DroidFusion چند سطحی می‌تواند بعنوان یک پیش بینی‌کننده دقت بهبود یافته برای تشخیص بدافزار اندرویدی مورد استفاده قرار گیرد.

نظرول هوک و همکارانش در سال ۲۰۱۸ در مقاله [14]، یک روش انتخاب ویژگی مجموعه برای طبقه بندی مجموعه داده‌ها از روش‌های انتخاب ویژگی با نام Ensemble Feature Selection با استفاده از اطلاعات متقابل (EFS-MI) معرفی نمودند که ترکیبی از زیر مجموعه‌های ویژگی‌های انتخاب شده توسط فیلترهای مختلف مانند InfoGain، GainRatio ، ReliefF، Chi-square و عدم قطعیت متقارن و زیر مجموعه‌ای بهینه از ویژگی ها را به همراه دارد است. برای ارزیابی عملکرد این روش، آنها از داده‌های NSL-KDD و TUIDS برای تایید صحت طبقه بندی روش خود با استفاده از طبقه‌بندی کننده‌های مختلف، مانند درختان تصمیم‌گیری، جنگل‌های تصادفی، KNN و SVM در مجموعه داده‌های استفاده کردند و به دقت ۹۸/۹۲ درصد رسیدند. آنها در این مقاله از تکنیک جستجوی حریص در زیر مجموعه داده های بهینه استفاده کردند و معتقد بودند که برنامه های مخرب به سرعت در حال توسعه و گسترش هستند. بنابراین ضروری است که دقت تشخیص بدافزارها را در برنامه‌های سیستم اندرویدی همانند برنامه‌های سیستم ویندوزی باید بهبود بخشید.

[Downloaded from ic4i-journal.ir on 2026-10-14]

در مقاله [15]، جی فانگ و همکارانش در سال ۲۰۱۹، یک روش تشخیص ترکیبی برای بدافزارهای سیستم‌های اندروید ارائه نمودند که تشخیص پویا را بر روی برنامه های مشکوک به دست آمده از تشخیص استاتیک انجام می‌دهد. نتایج آزمایشات این مقاله نشان می‌دهد که این روش از دقت بالایی برخوردار است و پیچیدگی زمان کم دارد و الگوریتم xgboost با عملکرد بهینه دقت تشخیص این روش را بالاتر از تشخیص استاتیک وتشخیص پویا با نرخ ۹٤.٦% انجام می‌دهد.

در گذشته بسیاری از پژوهشگران روی نوع خاصی از مسائل تمرکز می‌کردند و تعداد بسیار کمی از آن ها روی چندین بهبود برخی هدف ها به صورت همزمان کار می‌کنند. در [16]، سیستم-های یادگیری مبتنی بر دقت DTGA ارائه شده‌است که هدف آن بهبود دقت پیش گویی با توجه به مسائل مربوط به دامنه، اندازه، ابعاد مجموعه داده و توزیع شدگی کلاس‌ها می‌باشد. دقت و قابلیت تفسیر به صورت همزمان مورد توجه قرار گرفته است و در این مقاله تلاش شده تا علاوه بر دقت، قابلیت درک مسئله نیز افزایش یابد و هرچه تعداد قانون کمتر باشد، آن قانون قابل تفسیرتر می‌باشد .

دیوید دونالد و همکارش در سال ۲۰۱۷ در مقاله [17]، برای بهبود شناسایی بدافزار در فضای اینترنت از روش گروه انتخابی برای طبقه‌بندی ترافیک اینترنت استفاده نمودند، طبقه‌بندی ترافیک اینترنت برای فعالیت‌های مختلف شبکه مانند شناسایی بدافزار یک رویکرد کارآمد و بسیار حیاتی محسوب می‌شود. در این پژوهش از تکنیک هرس چند مرحله ای برای هرس طبقه‌بندی کننده های گروه بزرگ و همچنین از اسکریپت نویسیGroovy استفاده شده‌است. که این تکنیک ابزاری قدرتمند است که باعث کاهش چشمگیر زمان کدگذاری می شود. استفاده از اسکریپت نویسی می‌تواند یکی از روش‌های مناسب در طبقه‌بندی داده‌های بزرگ باشد. برای تجزیه و تحلیل این تحقیق از نرم افزار داده‌کاوی و بدافزار n-gram به عنوان مجموعه داده از مخازن داده و همچنین در آزمایشات آنها از SimpleCLI در WEKA برای تولید و اجرای همه طبقه‌بندی‌ها در طول آزمایش استفاده شده‌است. معیارهای عملکرد در این مقاله تضمین می‌کند که مدل هرس ساخته شده قوی است تا بدافزارها را به طور موثر تشخیص دهد. از متریال سطح زیر منحنی، برای ارزیابی اثربخشی طبقه بندی استفاده شده است.

3. روش پیشنهادی

انتخاب ویژگی یکی از روش های موثر در کاهش ابعاد داده و در نتیجه، محدود کردن فضای مسأله برای الگوریتم‌های یادگیری ماشین است. هدف انتخاب ویژگی که از آن به عنوان انتخاب زیرمجموعه ویژگی‌ها هم یاد می‌شود، حذف ویژگی‌های بی ربط و زائد است. اخیرا روش های مبتنی بر الگوریتم های XGBM

[Downloaded from ic4i-journal.ir on 2026-10-14]

و LIGHTGBM (که به اختصار xgb و lgb نامیده می شوند) به عنوان روش‌هایی کارآمد برای انتخاب ویژگی، پذیرفته شده‌اند. از این رو در این مقاله از feature importance این الگوریتم‌ها برای انتخاب بهترین زیرمجموعه ویژگی‌ها بر اساس سطوح مختلف اهمیت استفاده می‌شود. مایکروسافت تقریبا نیمی از اطلاعات مربوط به 21741 نمونه بدافزار را منتشر کرده‌است که 10868 نمونه از آن برای آموزش مدل کار پیش رو استفاده شده است. شناسه هر نمونه بدافزار یک کد هش 20 کارکتری است. این فایل ها از 9 خانواده مخرب به نام های kelihos_ver1، Tracur(T)، Simda(S)، Vundo(V)، kelihos_ver3(K3)، Lollipop(L)، Ramnit(R)، Gatak(G)، Obfuscator.ACY(O)، (K1) تشکیل شده‌اند [18]. برچسب کلاس ها یک عدد صحیح از 1 تا 9 می باشد، اگر"1" باشد اولین خانواده ی مخرب در لیست فوق را نشان می‌دهد و اگر 9 باشد آخرین خانواده را نشان می‌دهد. دو فایل برای هر نمونه مخرب وجود دارد، یکی حاوی کد هگز و دیگری حاوی کد دیس اسمبل شده است. مایکروسافت هدر PE را برای اطمینان از عدم فاش شدن هویت بدافزار ها از بین برده است. در شکل 1 توزیع داده ها در 9 خانواده ابر CoLab نشان داده‌شده است. در فاز اول این پروژه، از مجموعه داده دسته‌بندی بدافزار مایکروسافت، 1804 ویژگی برای 9 دسته از بدافزارها استخراج شد. در مجموعه داده حاصل، 10868 رکورد متعلق به آموزش و 10873 رکورد متعلق به مجموعه داده آزمایش هستند. در تعداد رکوردهای متعلق به هر گروه از بدافزار نشان داده شده است که طبق آن، کلاس 3 دارای بیشترین و کلاس 5 دارای کمترین تعداد رکوردها در مجموعه داده آموزش است.

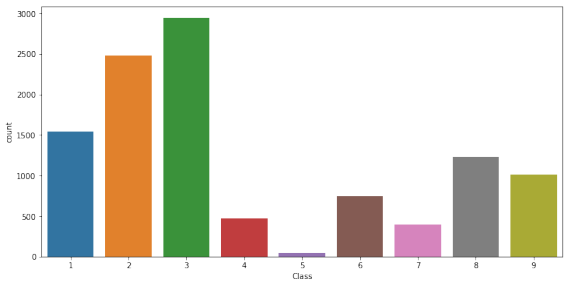

شکل 1. گروه های مختلف بدافزار

[Downloaded from ic4i-journal.ir on 2026-10-14]

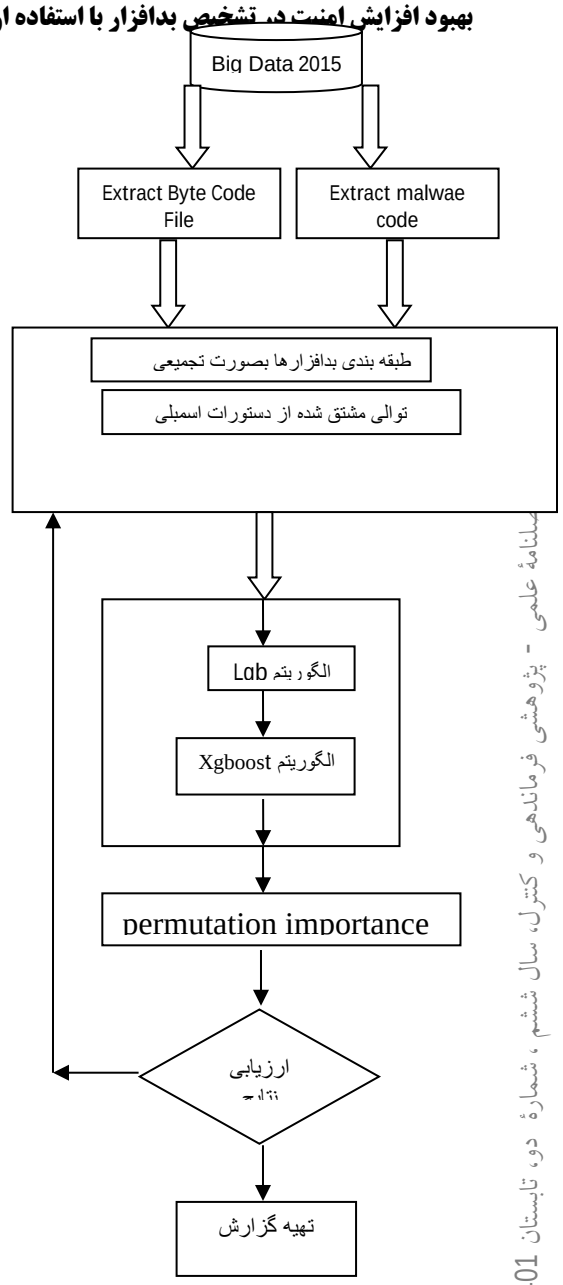

شکل 2. فرآیند روش پیشهادی

در واقع، در روش پیشنهادی داده کاوی بر روی بدافزارها و استخراج ویژگی هاست که بشترین تاثیر را در تشخیص دسته بندی بدافزارها خواهد داشت. لذا در ایین راهکار استخراج ویژگی های عمومی بدافزارها به منظور طبقه بندی آن ها با توجه به فضای مساله صورت گرفته است که این ویژگی ها در تمامی بدافزارها به صورت مشترک مورد استفاده قرار گرفته است. که شامل توالی مشتق شده از دستورات اسمبلی و فراخوانی توابع سیستمی توسط بدافزارها می باشند. در نهایت این ویژگی ها بصورت تجمیعی برای طبقه بندی بدافزارها مورد استفاده قرار می گیرد. بدست آوردن ویژگی های متعدد و موثر از دیتاست تا زمانی که کلاسه کننده بتواند بهترین شکل کارخود را انجام دهد، ادامه خواهد داشت. لذا در روش فوق از چندین الگوریتم برای استخراج ویژگی ها استفاده شده است. در واقع ابتدا مدل سازی 90 درصد از داده های آموزش (10درصد از داده به عنوان داده اعتبارسنجی در ارزیابی stratified kfold cross validation)، با الگوریتم های xgb و lgb انجام شده و بر اساس feature importance هر یک از این دو الگوریتم، چند زیر مجموعه از لیست ویژگی‌های مجموعه داده آموزش انتخاب می‌شود. سپس مدل سازی و پیش‌بینی جدید بر اساس مجموعه ویژگی‌های کاهش یافته صورت گرفته و سرانجام، میزان دقت پیش بینی آنها بر اساس معیار logloss با هم مقایسه می‌شود.

علاوه بر این، با استفاده از permutation importance هم به انتخاب زیرمجموعه ویژگی‌ها پرداخته شده است. در این روش، برای هر مجموعه داده به تعداد ویژگی‌های آن مدل سازی و ارزیابی انجام می‌گیرد. بدین صورت که در هر مرحله از این روش، مقادیر یک ویژگی، در هم سازی شده و سپس مدل سازی می‌گردد و بر اساس میزان تفاوت خروجی مدل بین دو حالت اولیه و در هم‌سازی شده و مهم‌ترین ویژگی‌ها استخراج شد. روش‌های فوق، روش‌های کاهنده ابعاد داده‌ها هستند. زیرا از بخشی از ویژگی های موجود که بیشترین تأثیر را در پیش‌بینی دارند، انتخاب می‌کنند. هدف این مقاله، استفاده از روش‌های انتخاب ویژگی برای بهترین زیرمجموعه ویژگی‌ها و دستیابی به پیش بینی‌های بهتر بر اساس این زیرمجموعه کمینه از ویژگی-هاست. در مقابل، روش های افزایش ابعاد داده ها، نظیر استخراج

[Downloaded from ic4i-journal.ir on 2026-10-14]

ویژگی می‌توان استفاده کرد که ویژگی‌های جدیدی را به مجموعه ویژگی‌های موجود می‌افزایند. در این مقاله، با استفاده از استخراج ویژگی‌ها، چهار ویژگی جدید به ویژگی‌های داده‌ها افزوده شد.

3-1. بررسی و پیش پردازش داده‌ها

3-1-1. بررسی همبستگی ویژگی‌ها

میزان همبستگی ویژگی‌ها با ویژگی هدف محاسبه و نمایش داده می‌شود. همانگونه که در جدول1 مشاهده می‌شود، ویژگی‌های setusermaterr_، _p_fmode و HeapCreate دارای بیشترین همبستگی با ویژگی هدف هستند. ماتریس همبستگی نشان می‌دهد که بسیاری از ویژگی‌ها مانند "TB-f0 و "img161 و "TB-89 و "img321 دارای همبستگی بالایی با یکدیگر هستند. این موضوع می‌تواند منجر به multicollinearity شود.

جدول 1. ویژگی های دارای بیشترین همبستگی با ویژگی class

Class	1.000000
__setusermatherr	0.545989
__p__fmode	0.533037
HeapCreate	0.509319
DispatchMessageA	0.471076
FreeEnvironmentStringsA	0.457317
db3_NdNt	0.433308
Img107	0.407566
TB_89	0.404929
TB_f0	0.397401
FreeEnvironmentStringsW	0.396155
Img32.1	0.395749
TlsAlloc	0.395407
_acmdln	0.390966
Img16.1	0.389151

با به دست آوردن میزان همبستگی ویژگی‌ها نسبت به ویژگی‌ها، ویژگی کلاس آن دسته از ویژگی‌ها که null بوده‌اند با میانگین جایگزین شده‌اند. لازم به ذکر است که در ماتریس همبستگی آن دسته از ویژگی‌ها مقداری نزدیک به صفر داشته‌اند نقش کمرنگی در دسته‌بندی دارند و هرچه عدد ویژگی در این ماتریس به 1 و 1- نزدیک تر باشد نقش موثرتری در دسته بندی دارد. بعنوان مثال : BYTES با CLASS نسبت معکوس قوی دارد و در دسته بندی بسیار موثر است. نظر به خروجی می‌توان دریافت که رسم یک جعبه برای هر ترکیب سطرها و ستون ها، در اصل کاری است که نقشه حرارتی انجام می‌دهد. رنگ جعبه، به مقدار آن خانه بستگی دارد. مثلاً در شکل 3، چنانچه همبستگی بالایی میان دو ویژگی وجود داشته باشد، خانه یا جعبه متناظر، زرد است، از طرف دیگر، چنانچه همبستگی وجود نداشته باشد، خانه متناظر، بنفش باقی می‌ماند. این طیف رنگی از کمترین مقدار تا بیشترین مقدار تمام خانه‌های ماتریس تغییر می‌کند که در سمت راست جدول قابل مشاهده است. مقادیر همبستگی را نیز، از طریق ارسال True برای پارامتر annot در نقشه حرارتی می‌توان مشاهده نمود.

[Downloaded from ic4i-journal.ir on 2026-10-14]

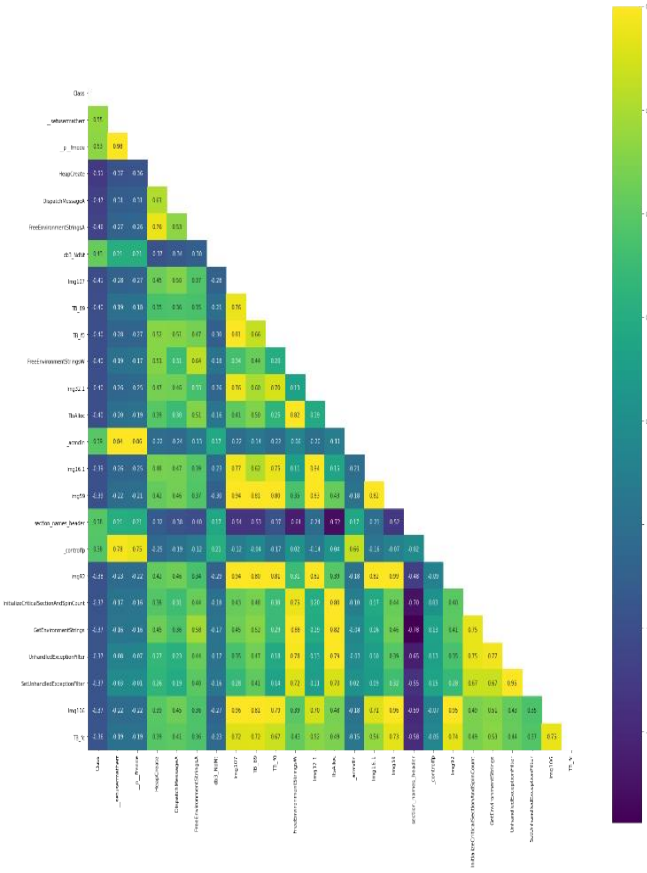

شکل 3. ویژگی های دارای بیشترین همبستگی با ویژگی class

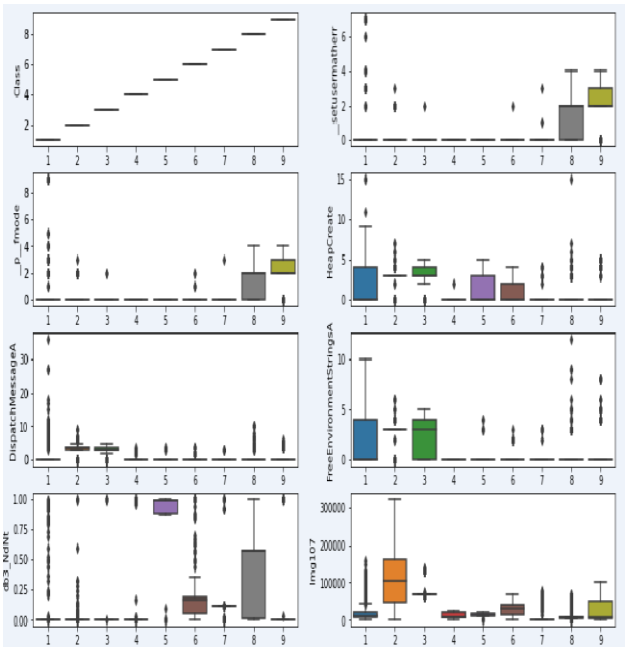

شکل 4-الف. نمودار جعبه ای ویژگی های دارای بیشترین همبستگی با ویژگی class

3-1-2. بررسی پرت بودن داده بر اساس نمودار جعبه ای

در این بخش با استفاده از نمودارهای جعبه‌ای شکل‌های 4-الف و4-ب، میزان پرت بودن مقادیر بخشی از ویژگی هایی که دارای بیشترین میزان همبستگی با متغیر هدف هستند مورد بررسی قرار گرفته است. کاملا مشخص است که تعدادی از مقادیر اکثر ویژگی‌ها، پرت هستند.

[Downloaded from ic4i-journal.ir on 2026-10-14]

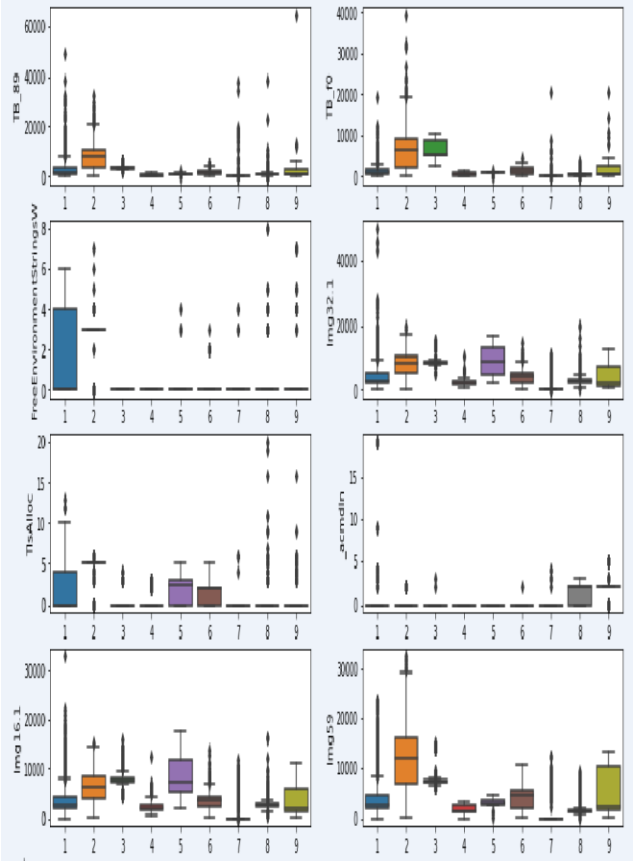

شکل4-ب . نمودار جعبه ای ویژگی های دارای بیشترین همبستگی با ویژگی class

3-1-3. بررسی وضعیت نرمال بودن داده‌ها

بسیاری از الگوریتم‌های یادگیری ماشین براساس مجموعه‌ای از فرضیات و قواعد آماری عمل می‌کنند. و این فرضیات و قواعد برای داده‌هایی طراحی شده اند که توزیع آنها نرمال است. هر چند در صورتی که مجموعه داده بزرگ باشد، توزیع داده‌ها، نرمال فرض می‌شود، ولی در این صورت هم بهتر است نرمال بودن داده‌ها بررسی شده و تا حد ممکن با تبدیلات داده‌ای لازم، توزیع داده‌ها به توزیع نرمال نزدیک شود. در این بخش میزان نرمال بودن بخشی از متغیرهای دارای بیشترین میزان همبستگی با متغیر هدف بررسی شد. این موضوع درشکل‌های 5-الف و 5-ب نشان داده شده‌است که بر اساس آن، اکثر متغیرها دارای توزیع غیر نرمال هستند. محاسبه میزان چولگی مقادیر ویژگی‌ها نیز این موضوع را تأیید می‌کند.

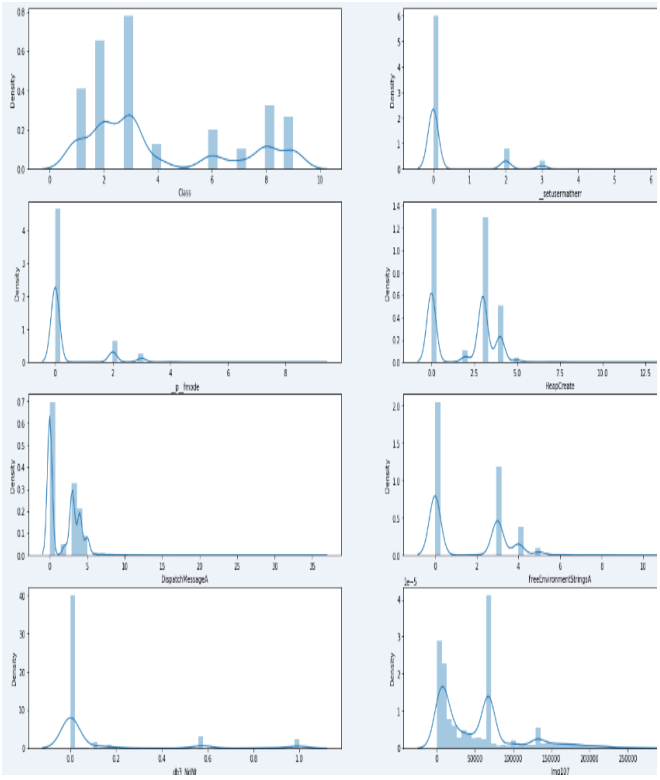

شکل 5-الف. نمودار توزیع ویژگی های دارای بیشترین همبستگی با ویژگی class

[Downloaded from ic4i-journal.ir on 2026-10-14]

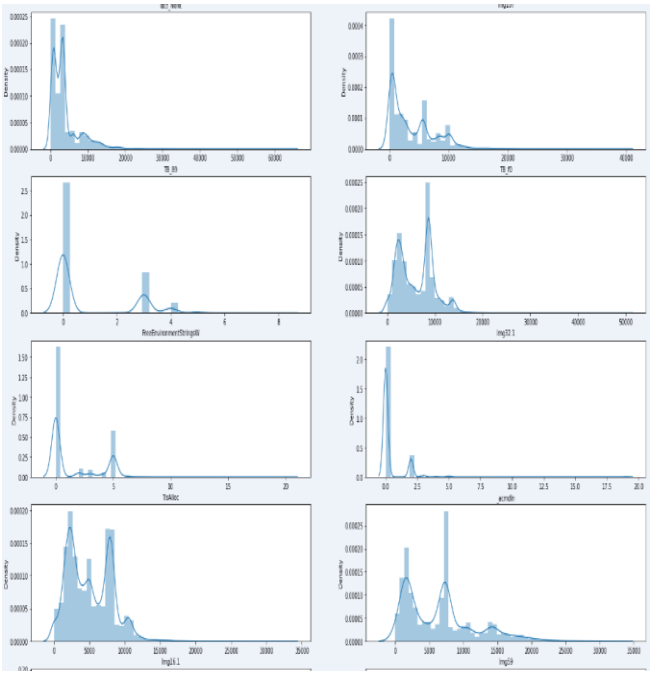

شکل 5-ب. نمودار توزیع ویژگی های دارای بیشترین همبستگی با ویژگی class

3-1-4. تبدیل داده به منظور رفع چولگی داده‌ها:

معمولا برای رفع چولگی غیر نرمال داده‌ها، مجموعه‌ای از تبدیلات داده‌ای روی داده‌ها انجام می‌شود. در این مقاله، از روش شکل 6 برای کاهش چولگی مقادیر ویژگی‌ها استفاده شده است:

۱- توزیع ویژگی هایی که چولگی آن ها بین 0.5- و 0.5 است، نرمال فرض می‌شود.

۲- مقادیر غیر صفر ویژگی‌هایی که چولگی آنها بیش از 0.5 است، به لگاریتم مقادیر همان ویژگی تبدیل می‌شوند.

۳- مقادیر ویژگی هایی که چولگی آنها کمتر از 0.5- است، به مجذور مقادیر همان ویژگی تبدیل می‌شوند.

```
skews= pd.Series(index= df_x.columns)
for col in df_x.columns:
  skews[col] = df_x[col].skew()


index_list= list(skews.index)
for x, i in enumerate(index_list):
  if x_train[i].skew() < -0.5:
    for j in range(len(x_train)):
      x_train.iloc[j, x] = np.square(x_train.iloc[j, x])
  if x_train[i].skew() > 0.5:
    for j in range(len(x_train)):
      if x_train.iloc[j, x] != 0:
        x_train.iloc[j, x] = np.log(np.abs(x_train.iloc[j, x]))

return x_train
```

شکل 6. روش کاهش چولگی مقادیر ویژگی‌ها

بررسی چولگی اولیه داده ها در شکل 7 نمایش داده شده‌است.

```
MethCallEngine              104.249700
__vbaErase                  104.249700
__vbaVarZero                104.249700
__vbaInStrVar               104.249700
__vbaAryVar                 104.249700
                                ...
ent_p_19                     -4.767019
ent_q_diff_diffs_median      -7.770609
ent_q_diff_diffs_min        -11.153566
ent_q_diff_diffs_0_max      -11.537138
ent_q_diffs_max             -13.403123
```

شکل7. بررسی چولگی اولیه داده ها

[Downloaded from ic4i-journal.ir on 2026-10-14]

بررسی چولگی داده‌های نرمال شده در شکل 8 نمایش داده شده است.

```
x_train_sk_handled.skew().sort_values(
```

```
__vbaStrI2                104.249700
__vbaVarZero              104.249700
__vbaErase                104.249700
__vbaAryConstruct2        104.249700
__vbaInStrVar             104.249700
                              ...
ent_q_diff_diffs_min       -5.124846
tls_por                    -5.602426
ent_q_diff_block_2_20      -5.699199
dd5_NdNt                   -8.298382
db3_idata                 -48.985028
Length: 1804, dtype: float64
```

شکل 8. بررسی چولگی داده های نرمال شده

3-1-4-1 آموزش و ارزیابی با مقادیر تبدیل یافته (تبدیلات کاهش چولگی داده‌ها)

ضرورت و نحوه تبدیل داده‌ها به منظور کاهش چولگی داده ها در بخش سوم این مقاله مورد بحث قرار گرفت. در ادامه ی این بخش و در این مرحله، مدلسازی و ارزیابی هر یک از الگوریتم های lgb و xgb با استفاده مجموعه مقادیر اولیه و مجموعه مقادیر تبدیل یافته داده ها انجام گرفته است و نتایج ارزیابی ها مطابق جدول 2 نشان می دهد که این تبدیلات موجب کاهش عملکرد مثبت مدل می شوند.

جدول 2. مقایسه نتایج مقادیر اولیه و مجموعه مقادیر تبدیل یافته داده ها

logloss_xgb_raw_data	0.01194
logloss_xgb_sk_handled_data	0.01576
logloss_lgb_raw_data	0.0082
logloss_lgb_sk_handled_data	0.01225

3-2 استخراج ویژگی

استخراج ویژگی از ویژگی های موجود، از تکنیک های موثر در بهبود یادگیری الگوریتم‌هاست. بدین منظور در این مقاله، چهار ویژگی به شرح زیر به مجموعه ویژگی ها، اضافه شد:

```
x_train_feature_added= x_train.copy()
x_train_feature_added['sumImg']= x_train_feature_added['Img107']
for i in range(107):
  feat_name= 'Img{0}'.format(i)
  x_train_feature_added['sumImg']= x_train_feature_added['sumImg'] + x_train_feature_added[feat_name]
  x_train_feature_added['sumImport']= x_train_feature_added['Import'] + x_train_feature_added['Imports']
  x_train_feature_added['loc_by_mean']= x_train_feature_added['loc']/x_train_feature_added['loc'].mean()
  x_train_feature_added['var_by_mean']= x_train_feature_added['var']/x_train_feature_added['var'].mean()
  x_train_feature_added['Forwarder_by_mean']= x_train_feature_added['Forwarder']/x_train_feature_added['Forwarder'].mean()
x_train_feature_added.head()
```

در جدول 3 تأثیر اضافه شدن چهار ویژگی جدید به مجموعه ویژگی‌ها نشان داده شده است. نتایج نشان می دهد که افزودن این ویژگی‌ها باعث بهبود عملکرد در هر یک از مدل های lgb و xgb شده است.

[Downloaded from ic4i-journal.ir on 2026-10-14]

جدول 3. مقایسه نتایج آموزش مدل ها با ویژگی‌های اولیه و همه ویژگی‌ها

logloss_xgb_raw_data	0.01194
logloss_xgb_allfeat	0.01148
logloss_lgb_raw_data	0.0082
logloss_lgb_allfeat	0.00744

3-2-1 استخراج اهمیت ویژگی‌ها

ویژگی‌های مختلف از اهمیت برابری برای شرکت در تعیین نتایج الگوریتم‌های یادگیری ماشین برخوردار نیستند. یکی از روش‌های استخراج میزان اهمیت ویژگی‌ها، استفاده از feature importance الگوریتم های lgb و xgb است. در این مرحله ابتدا هر یک از این الگوریتم‌ها با همه ویژگی‌ها، آموزش دیده و در نتیجه آن، میزان اهمیت ویژگی ها استخراج شده‌است. در شکل 9 و 10 ، 20 مورد از مهم ترین ویژگی‌های مجموعه داده به همراه میزان اهمیت آنها، نشان داده می‌شود.

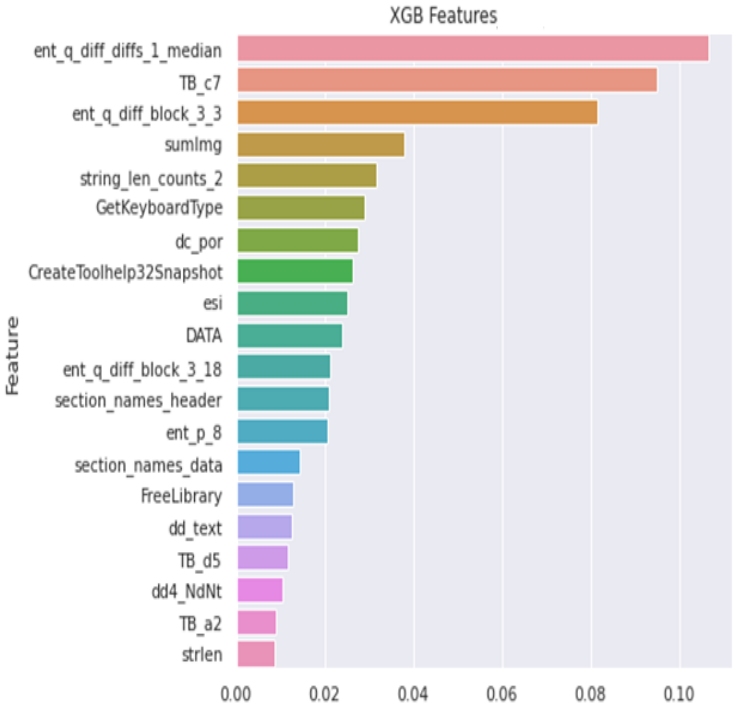

شکل 9. 20 ویژگی مهم حاصل از xgb

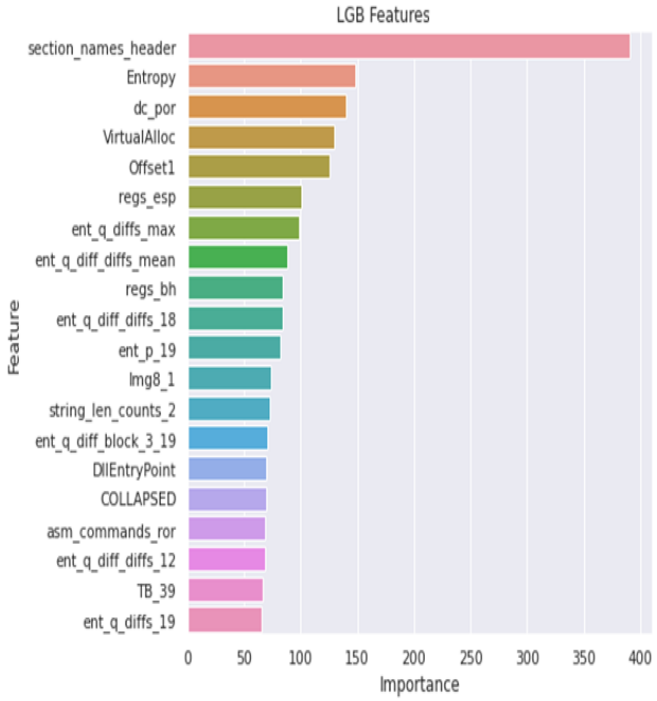

شکل 10. 20 ویژگی مهم حاصل از lgb

[Downloaded from ic4i-journal.ir on 2026-10-14]

3-3 آموزش و ارزیابی با زیرمجموعه ویژگی ها

3-3-1 آموزش و ارزیابی با زیرمجموعه ویژگی ها (با سطوح مختلف feature importance)

در این مرحله، ابتدا الگوریتم های xgb و lgb با استفاده از همه ویژگی‌ها (ویژگی های اولیه و ویژگی‌های افزوده شده) آموزش دیدند. سپس با استفاده از feature importance هر یک از آنها، مجموعه‌های 50، 100،150 و 250تایی از بهترین ویژگی‌ها استخراج شد و در مرحله پایانی، مدل سازی و ارزیابی با استفاده از هر یک از این مجموعه ویژگی ها انجام گرفت. نتایج و ارزیابی های بدست امده هر یک از این مدل ها مطابق جدول 4 نشان می‌دهد که دقت الگوریتم xgb با 50 ویژگی مهم از مجموعه ویژگی‌ها تفاوت فاحشی با دقت آن با استفاده کل مجموعه ویژگی های این مسأله ندارد.

این موضوع در مورد استفاده از 100، 150 و 250 ویژگی مهم هم صدق می‌کند ولی دقت الگوریتم lgb با زیرمجموعه‌ای از ویژگی‌ها (زیرمجموعه ای از بهترین ویژگی‌های حاصل از feature importance الگوریتم lgb) به مراتب بدتر از دقت آن با استفاده کل ویژگی‌هاست. این تفاوت به تفاوت سیاست ساخت درخت این دو الگوریتم برمی‌گردد.

جدول 4. مقایسه نتایج آموزش با کل ویژگی‌ها و زیرمجموعه ویژگی‌ها حاصل از feature importance

logloss_xgb_raw_data	0.01194
logloss_xgb_best_features_50	0.01194
logloss_xgb_best_features_100	0.01194
logloss_xgb_best_features_150	0.01194
logloss_xgb_best_features_250	0.01194
logloss_lgb_raw_data	0.0082
logloss_lgb_best_features_50	5.21675
logloss_lgb_best_features_100	4.86224
logloss_lgb_best_features_150	5.21675
logloss_lgb_best_features_250	4.43379

3-3-2 آموزش و ارزیابی با زیرمجموعه ویژگی‌ها (با سطوح مختلف permutation Importance)

در روش permutation Importance برای هر مجموعه داده به تعداد ویژگی‌های آن مدل سازی و ارزیابی انجام می‌گیرد. بدین‌صورت که در هر مرحله از این روش، مقادیر یک ویژگی، در هم‌سازی شده و سپس مدل سازی می‌گردد و بر اساس میزان تفاوت خروجی مدل بین دو حالت اولیه و در هم‌سازی شده (حالت اول: بدون در هم سازی هیچ یک از ویژگی‌ها و حالت دوم: با در هم سازی یک ویژگی)، مهم ترین ویژگی‌ها استخراج می‌شود. الگوریتم permutation Importance ، الگوریتمی بسیار سنگین است و پردازش آن نیاز به منابع پردازشی زیادی دارد. به همین دلیل در این پروژه، به منظور اجرای الگوریتم permutation Importance با استفاده از هر یک از الگوریتم‌های xgb و lgb، تنها 300 مورد از بهترین ویژگی‌های آنها (300 ویژگی برتر حاصل از feature importance هر یک از این الگوریتم‌ها) انتخاب شده و بر اساس آنها، permutation Importance انجام گرفت. در مرحله آخر

[Downloaded from ic4i-journal.ir on 2026-10-14]

200 ویژگی از بهترین ویژگی‌های حاصل از permutation Importance انتخاب شده و با استفاده از آنها، آموزش هر یک از الگوریتم های xgb و lgb صورت گرفت. در شکل 11 و12 مهم ترین ویژگی‌های استخراج شده از این روش، به ترتیب اهمیت نشان داده شده‌اند.

ویژگی section_names_header در هر دو مدل، بیشترین امتیاز را در مقایسه با سایر ویژگی‌ها کسب نموده است.

Weight	Feature
0.2160 ± 0.0000	section_names_header
0.0012 ± 0.0000	regs_esp
0.0007 ± 0.0000	Entropy
0.0006 ± 0.0000	Offset1
0.0005 ± 0.0000	VirtualAlloc
0.0004 ± 0.0000	ent_q_diffs_max
0.0004 ± 0.0000	asm_commands_ror
0.0001 ± 0.0000	Unknown_Sections_lines_por
0 ± 0.0000	ent_q_diff_diffs_0_min
0 ± 0.0000	section_names_text
0 ± 0.0000	GetStartupInfoA
0 ± 0.0000	ent_q_diffs_11
0 ± 0.0000	regs_dl
0 ± 0.0000	ent_q_diff_diffs_median
0 ± 0.0000	ent_q_diff_diffs_1_var
0 ± 0.0000	int1
0 ± 0.0000	Plus
0 ± 0.0000	TB_a4
0 ± 0.0000	regs_ebx
0 ± 0.0000	ent_q_diff_diffs_0_var
... 280 more ...	

شکل 11. مهم ترین ویژگی های حاصل از

permutation importance(lgb)

Weight	Feature
0.1336 ± 0.0026	section_names_header
0.0004 ± 0.0001	Entropy
0.0004 ± 0.0001	Unknown_Sections_lines_por
0.0003 ± 0.0001	asm_commands_std
0.0002 ± 0.0002	ent_q_diff_diffs_1_median
0.0001 ± 0.0001	sumImg
0.0001 ± 0.0000	regs_esp
0.0001 ± 0.0001	Offset1
0.0001 ± 0.0000	ent_q_diffs_max
0.0001 ± 0.0001	section_names_rsrc
0.0001 ± 0.0001	VirtualAlloc
0.0001 ± 0.0002	dc_por
0 ± 0.0000	SetStdHandle
0 ± 0.0000	TB_40
0 ± 0.0000	TB_b3
0 ± 0.0000	edx
0 ± 0.0000	Img2_1
0 ± 0.0000	ImageList_Destroy
0 ± 0.0000	WriteProcessMemory
0 ± 0.0000	ent_q_diff_diffs_median
... 280 more ...	

شکل 12. مهم ترین ویژگی های حاصل از

permutation importance (xgb)

نتایج ارزیابی های صورت گرفته مطابق جدول 5 از مقایسه نتیجه آموزش با همه ویژگی‌ها و زیرمجموعه ویژگی ها حاصل از permutation importance نشان می دهد که استفاده از چنین زیرمجموعه‌ای از ویژگی‌ها تأثیر چشمگیری بر عملکرد مدل ندارد و نتایج این دو حالت بسیار نزدیک به هم خواهد بود.

[Downloaded from ic4i-journal.ir on 2026-10-14]

جدول 5. مقایسه نتیجه آموزش با همه ویژگی‌ها و زیرمجموعه ویژگی ها حاصل از permutation importance

logloss_xgb_allfeat	0.01148
logloss_xgb_best_features_perm	0.01209
logloss_lgb_allfeat	0.00744
logloss_lgb_best_features_perm	0.009968

4. ارزیابی روش پیشنهادی در مقایسه با مدل های منفرد و stacking

در مرحله آخر، روش پیشنهادی با استفاده از مدل‌های نهایی مرحله قبل و GaussianNB ، پشته‌ای از مدل‌ها پیاده‌سازی شد. بدین صورت که در لایه اول، مدل های lgb و xgb آموزش دیده با 200 ویژگی مهم حاصل از permutation importance و در لایه دو GaussianNB به عنوان کلاسه‌کننده نهایی مورد استفاده قرار گرفت. نتایج و ارزیابی های صورت گرفته مطابق جدول 6 نشان می‌دهد که عملکرد هر یک از مدل های lgb و xgb به تنهایی، بهتر از عملکرد چنین پشته‌ای است. در جدول 7 نتایج دقت همه مدل‌ها ذکر شده است و مطابق این جدول ویژگی های اولیه با استفاده از الگوریتم lgb بیشترین دقت را به خود اختصاص داده اند . نتایج و ارزیابی های صورت گرفته مطابق با جدول 8 میزان خطای پیش بینی الگوریتم lgb از همه ی مدل ها ، کمتر بوده در نتیجه بهترین عملکرد و دقت را داشته است. جدول 9. نتایج confusion matrix و accuracyscore را نشان می دهد و در پایان با استفاده از خروجی های دو الگوریتم xgb و lgb نتایج جدول 9 حاصل گردیده است.همانطور که در جدول 9 نمایش داده شده است، میزان خطای پیش بینی و دقت در روش ارائه شده به مراتب بهتر از روش احمدی و همکاران می باشد.

جدول 6. مقایسه نتیجه مدل سازی با مدل‌های منفرد و stacking

logloss_xgb_allfeat	0.01148
logloss_xgb_best_features_perm	0.01209
logloss_sclf_xgb_best_features_perm	0.190646
logloss_lgb_allfeat	0.00744
logloss_lgb_best_features_perm	0.009968
logloss_sclf_lgb_best_features_perm	0.190646

جدول 7. نتایج دقت همه مدل‌ها

acc__xgb_raw_data	0.9972401103955841
acc__xgb_allfeat	0.9981600735970562
acc_xgb_best_features_50	0.9972401103955841
acc__xgb_best_features_100	0.9954001839926403
acc__xgb_best_features_150	0.9972401103955841
acc__xgb_best_features_250	0.9981600735970562
acc_xgb_sk_handled_data	0.9972401103955841
acc_lgb_raw_data	0.9990800367985281
acc_lgb_allfeat	0.9981600735970562
acc_lgb_best_features_50	0.0229990800367985
acc_lgb_best_features_100	0.1665133394664213
acc_lgb_best_features_150	0.0229990800367985
acc_lgb_best_features_250	0.2483900643974241
acc_lgb_sk_handled_data	0.9981600735970562
acc_xgb_best_features_perm	0.9972401103955841
acc_lgb_best_features_perm	0.9963201471941122
acc_sclf_xgb_best_features_perm	0.9963201471941122
acc_sclf_lgb_best_features_perm	0.9944802207911684

[Downloaded from ic4i-journal.ir on 2026-10-14]

جدول 8. نتایج همه مدل‌ها

logloss_xgb_raw_data	0.01194
logloss_xgb_sk_handled_data	0.01576
logloss_xgb_best_features_50	0.01194
logloss_xgb_best_features_100	0.01194
logloss_xgb_best_features_150	0.01194
logloss_xgb_best_features_250	0.01194
logloss_xgb_allfeat	0.01148
logloss_lgb_allfeat	0.00744
logloss_lgb_raw_data	0.0082
logloss_lgb_sk_handled_data	0.01225
logloss_lgb_best_features_50	5.21675
logloss_lgb_best_features_100	4.86224
logloss_lgb_best_features_150	5.21675
logloss_lgb_best_features_250	4.43379
logloss_lgb_best_features_perm	0.00997
logloss_xgb_best_features_perm	0.01209
logloss_sclf_xgb_best_features_perm	0.19065
logloss_sclf_lgb_best_features_perm	0.19065

جدول 9. نتایج confusion matrix و accuracyscore

```
logloss_xgb_allfeat: 0.010852646612050954
acc__xgb_allfeat: 0.9981600735970562
cm__xgb_allfeat:
 [[163   0   0   0   0   0   0   0   0]
 [  0 266   0   0   0   0   0   0   0]
 [  0   0 296   0   0   0   0   0   0]
 [  0   0   0  49   0   0   0   0   0]
 [  0   0   0   0   2   0   0   0   0]
 [  0   0   0   0   0  73   0   0   0]
 [  0   0   0   0   0   0  50   0   0]
 [  0   0   0   0   0   0   0 100   1]
 [  0   0   0   0   0   0   0   1  86]]
```

```
logloss_xgb_sk_handled_data: 0.01537082264501708
acc_xgb_sk_handled_data: 0.9972401103955841
cm_xgb_sk_handled_data:
 [[163   0   0   0   0   0   0   0   0]
 [  0 266   0   0   0   0   0   0   0]
 [  0   0 296   0   0   0   0   0   0]
 [  0   0   0  49   0   0   0   0   0]
 [  0   0   0   0   2   0   0   0   0]
 [  0   0   0   0   0  73   0   0   0]
 [  0   0   0   0   0   0  50   0   0]
 [  1   0   0   0   0   0   0  99   1]
 [  0   0   0   0   0   0   0   1  86]]
```

```
logloss_lgb_allfeat: 0.007443924578695638 5
acc_lgb_allfeat: 0.9981600735970562
cm_lgb_allfeat:
 [[163   0   0   0   0   0   0   0   0]
 [  0 266   0   0   0   0   0   0   0]
 [  0   0 296   0   0   0   0   0   0]
 [  0   0   0  49   0   0   0   0   0]
 [  0   0   0   0   2   0   0   0   0]
 [  0   0   0   0   0  73   0   0   0]
 [  0   0   0   0   0   0  50   0   0]
 [  0   0   0   0   0   0   0 100   1]
 [  0   0   0   0   0   0   0   1  86]]
```

```
logloss_lgb_sk_handled_data: 0.010453178169007513
acc_lgb_sk_handled_data: 0.9981600735970562
cm_lgb_sk_handled_data:
 [[163   0   0   0   0   0   0   0   0]
 [  0 266   0   0   0   0   0   0   0]
 [  0   0 296   0   0   0   0   0   0]
 [  0   0   0  49   0   0   0   0   0]
 [  0   0   0   0   2   0   0   0   0]
 [  0   0   0   0   0  73   0   0   0]
 [  0   0   0   0   0   0  50   0   0]
 [  1   0   0   0   0   0   0 100   0]
 [  0   0   0   0   0   0   0   1  86]]
```

```
logloss_lgb_best_features_perm: 0.0099680370820131 47
acc_lgb_best_features_perm: 0.9963201471941122
cm_lgb_best_features_perm:
 [[163   0   0   0   0   0   0   0   0]
 [  0 266   0   0   0   0   0   0   0]
 [  0   0 296   0   0   0   0   0   0]
 [  0   0   0  49   0   0   0   0   0]
 [  0   0   0   0   2   0   0   0   0]
 [  0   0   1   0   0  72   0   0   0]
 [  0   0   0   0   0   0  50   0   0]
 [  0   0   0   0   0   0   0  99   2]
 [  0   0   0   0   0   0   0   1  86]]
```

```
logloss_lgb_best_features_perm: 0.0
acc_lgb_best_features_perm: 0.99632
cm_lgb_best_features_perm:
 [[163   0   0   0   0   0   0   0
 [  0 266   0   0   0   0   0   0
 [  0   0 296   0   0   0   0   0
 [  0   0   0  49   0   0   0   0
 [  0   0   0   0   2   0   0   0
 [  0   0   1   0   0  72   0   0
 [  0   0   0   0   0   0  50   0
 [  0   0   0   0   0   0   0  99
 [  0   0   0   0   0   0   0   1
```

```
logloss_sclf_xgb_best_features_perm: 0.12709761322875074
acc_sclf_xgb_best_features_perm: 0.9963201471941122
cm_sclf_xgb_best_features_perm:
 [[161   0   0   0   2   0   0   0   0]
 [  0 266   0   0   0   0   0   0   0]
 [  0   0 296   0   0   0   0   0   0]
 [  0   0   0  49   0   0   0   0   0]
 [  0   0   0   0   2   0   0   0   0]
 [  0   0   0   0   1  72   0   0   0]
 [  0   0   0   0   0   0  50   0   0]
 [  0   0   0   0   0   0   0 101   0]
 [  0   0   0   0   0   0   0   1  86]]
```

```
logloss_sclf_lgb_best_features_perm:
acc_sclf_lgb_best_features_perm: 0.9
cm_sclf_lgb_best_features_perm:
 [[161   0   0   0   2   0   0   0
 [  0 266   0   0   0   0   0   0
 [  0   0 296   0   0   0   0   0
 [  0   0   0  49   0   0   0   0
 [  0   0   0   0   2   0   0   0
 [  0   0   0   0   1  72   0   0
 [  0   0   0   0   0   0  50   0
 [  0   0   0   0   0   0   0  99
 [  0   0   0   0   0   0   0   1  8
```

جدول 9. نتایج مقایسه کارهای انجام شده

محققین	Log loss	Accuracy
احمدی و همکارانش	0/009656	99/77
مهدوی	0/007604	99/81
کار انجام شده	0/00774	99/81

۵. نتیجه گیری

برای مقابله با بدافزارها ابتدا باید راهکارهایی برای شناسایی و تجزیه تحلیل آن ها داشته باشیم. یکی از مشکلات در تشخیص بدافزارها، پیچده تر شدن بدافزارها توسط تکنیک های مبهم سازی است که در این صورت مقابله با بدافزارها نیازمند تشخیص و تمایز میان بدافزارها و نرم فزارهای قانونی است. در این مقاله، روشی جهت بهبود افزایش امنیت و تشخیص بدافزار با استفاده از الگوریتم تجمیعی ارائه شد. همچنین با استفاده از روش‌های

[Downloaded from ic4i-journal.ir on 2026-10-14]

انتخاب ویژگی جهت دستیابی به پیش‌بینی‌های بهتر و دقت بالاتر از دو الگوریتم xgboost و lgb استفاده شد. در روش پیشنهادی، یک کلاسه کننده طراحی شد که هم در زمینه استخراج ویژگی و هم در زمینه ساز و کار کلاسه‌کننده بسیار ساده و پیچیدگی محاسباتی کمی دارد. چهار ویژگی جدید پیشنهاد شد و نتایج نشان می‌دهد که افزودن این ویژگی‌ها باعث بهبود عملکرد در هر یک از مدل‌های lgb و xgb و همچنین دقیق‌تر شدن کلاسه‌کننده و بهبود دقت آن نسبت به تحقیقات پیشین شده‌است. استخراج ویژگی‌های ساختاری جدید در مقایسه با ویژگی‌های مبتنی بر محتوا، آسان‌تر بوده و طبقه‌بندی پوشه‌های مخرب و بسته‌بندی-شده به آسانی صورت می‌پذیرد و این امر سبب پایین آمدن هزینه محاسباتی و زمانی شده‌است. پیاده‌سازی‌ها و روش‌های گوناگونی برای هوش مصنوعی و یادگیری ماشین به منظور حل مسائل جهان واقعی وجود دارد و یادگیری نظارت شده (Supervised Learning)یکی از پرکاربردترین رویکردها است. یادگیری با نظارت یکی از زیرمجموعه‌های یادگیری ماشینی است. در این روش مدل با دریافت اطلاعات برچسب زده شده آموزش می‌بیند و سعی می‌کند الگوی بین داده‌ها و برچسب‌هایشان را به صورت یک تابع یاد گرفته و برچسب داده‌های جدید و دیده نشده را پیش بینی کند. از این روش هم در مسائل طبقه‌بندی و هم در مسائل رگرسیون استفاده می‌شود.

در این تحقیق تنها به 9 مدل بدافزار و نحوه ی تفکیک آن ها از یکدیگر اکتفا شده است اما می توان با توسعه ی این روش، به روشی کارآمد برای شناسایی طیف وسیعی از بدافزارها، بدون توجه به دسته بندی آن ها اقدام کرد و همچنین در کارهای آینده‌ی هم‌راستا با این تحقیق، می‌توان علاوه بر ابزارهای استفاده شده، سایر روش‌های ترکیبی را مورداستفاده قرارداده و برای اطمینان از عملکرد صحیح آنها، علاوه بر مجموعه داده‌های استفاده شده، می‌توان از مجموعه داده‌های مشابه نیز استفاده کرده و روش پیشنهادی را در زمینه‌های جدیدی بکار گرفت. هچنین، استفاده از یک مجموعه‌ی کاهش‌یافته به گونه‌ای که تنها شامل مهمترین ویژگی‌ها باشد می‌تواند باعث کاهش زمان و دقت بالاتر کلاسه کننده شود و از بیش برازش جلوگیری نماید و کار را برای تحلیلگران سهل کند. تمرکز روی مبحث استخراج ویژگی‌های ساختاری جدید از ویژگی‌های مبتنی بر محتوا در عین کم هزینه بودن از نظر محاسباتی نیز سریع می‌باشد و همین امر می‌تواند دلیلی بر گرایش محققان به سمت اینگونه روش‌ها جهت تحقیقات آتی باشد.

مراجع

[Downloaded from ic4i-journal.ir on 2026-10-14]

[۱] Alazab M, Layton R, Venkataraman S, Watters P. (2010) , “Malware detection based on structural and behavioural features of api calls”, IEEE International, Conference.

[۲] Aycock.J (2006) , “Computer Viruses and Malware”. Springer, Heidelberg.

[3] F. Mira. (2021) , “ A Systematic Literature Review on Malware Analysis”. IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS).

[۴] RK .Shahzad, SI .Haidar, N .Lavesson. (2010) , ‘‘ Detection of spyware by mining executable files’’, 2010 International Conference on Availability, Reliability and Security; IEEE.

[۵] J. Z. Kolter and M. A. Maloof . (2006) , “Learning to Detect and Classify Malicious Executables in the Wild”, J. Mach. Learn. Res., vol. 7, pp.2721–2744, Dec.

[۶] M. Gheorghescu. (2005) , “An automated virus classification system ”, in Virus Bulletin Conference, pp. 294–300.

[۷] D. Marion, D. Phuc Pham, A. Heuser . (2021) , “ Obfuscation Revealed - Using Electromagnetic Emanation to Identify and Classify Malware,” IEEE European Symposium on Security and Privacy (EuroS&P) Vienna, Austria.

[۸] B. Tahtaci, B. canbay. (2020) , “Android Malware Detection Using Machine Learning,” Innovations in Intelligent Systems and Applications Conference (ASYU), Istanbul, Turkey.

[۹] S. Choudhary, A. Sharma. (2020) , “Malware Detection & Classification using Machine Learning,” International Conference on Emerging Trends in Communication, Control and Computing (ICONC3) Mody University of Science and Technology, Lakshmangarh.

[۱۰] H. S. Galal, Y. B. Mahdy, M. A. Atiea. (2016) , ‘‘ Behavior-based features model for Malware detection,’’ JCVHT, vol. 12, pp. 59-67.

[۱۱] S. srivastavai, R.P Mishra, V. Kumar, H. Kumar Shukla, N. Goyal, C. Singh. (2020) , “Android Malware Detection Amid COVID-19,” International Conference on System Modeling & Advancement in Research Trends, Faculty of Engineering & Computing Sciences, Teerthanker Mahaveer University, Moradabad, India

[۱۲] Alejandro Martın, R.Lara-Cabrera, D.Camacho. (2019) , ‘‘Android malware detection through hybrid features fusion and ensemble classifiers: the AndroPyTool framework and the OmniDroid dataset’’IEEE.

[۱۳] Suleiman Yerima , Y. Member, and Sakir Sezer. (2018) , ‘‘ DroidFusion: A Novel Multilevel Classifier Fusion Approach for Android Malware Detection,’’IEEE .

[۱۴] Nazrul Hoque , Mihir Singh, K.Dhruba Bhattacharyya. (2018) , ‘‘ EFS-MI: an ensemble feature selection method for classification An ensemble feature selection method,’’ IEEE.

[۱۵] Qi Fang , X.Yang , C.Ji . (2019) , ‘‘A Hybrid Detection Method For Android Malware,’’ IEEE.

[۱۶] B.K Sarkar, S. Sana. (2011) , ‘‘A Genetic Algorithm-Based Rule Extraction System,’’ Journal of Applied Soft Computing, vol. ۱۲, pp. ۲۳۸-۲۵۴.

[۱۷] A. David Donald , G. Murali. (2017) , ‘‘ Selective Ensemble of Internet Traffic Classifiers for Improving Malware Detection,’’ IEEE.

[۱۸] G. Serazzi, & S.Zanero. (2004) , ‘‘Computer Virus Propagation Models’’, Computer Science , 2965 , 26-50. Computer Virus Propagation Models. Computer Science , 2965 , 26-50.

[19] M. Ahmadi, D. Ulyanov, S .Semenov, M .Trofimov, G .Giacinto. (2016) ‘‘Novel featur extraction, selection and fusion for effective malware family classification’’, Proceeding of the sixth ACM conference on data and application security and privacy;: ACM.

[19] مهدوی، راحله (۱۳۹۷)،تشخیص بدافزار با استفاده از شبکه های عصبی عمیق و الگوریتم xgboost ، تهران

[Downloaded from ic4i-journal.ir on 2026-10-14]