

شناسایی باج‌افزارها و خانواده‌آنها با

بهره‌گیری از روش کاوش الگوهای متوالی در

تحلیل پویا

حمید دارابی^۱، ستار هاشمی^۲، سجاد همایون^۳ و کرم‌الله باقری‌فرد^{*۴}

^۱دانشکده مهندسی برق و کامپیوتر، دانشگاه شیراز، شیراز، ایران

^۲دانشکده مهندسی فناوری اطلاعات و کامپیوتر، دانشگاه صنعتی شیراز، شیراز، ایران

^۴گروه مهندسی کامپیوتر، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

^۵باشگاه پژوهشگران جوان و نخبگان، واحد یاسوج، دانشگاه آزاد اسلامی، یاسوج، ایران

چکیده

امروزه باج‌افزارهای رمزکننده تبدیل به یکی از مهم‌ترین تهدیدات حوزه سایبری شده است. یک باج‌افزار رمزکننده با رمزکردن داده‌های با ارزش قربانی، دسترسی به داده‌ها را از بین می‌برد و در ازای رمزگشایی آن‌ها درخواست پرداخت باج می‌کند. به‌علت نوظهور بودن باج‌افزارهای رمزکننده، پژوهش‌چندانی در جهت شناسایی آن‌ها انجام نشده است و بیش‌تر پژوهش‌های مرتبط روی سیستم فایل و نظارت بر رفتار فرآیندها روی فایل‌ها انجام شده است. از آنجایی که سرعت در تشخیص باج‌افزارها اهمیت فراوانی دارد، تمرکز این مقاله روی تشخیص دقیق و زودهنگام باج‌افزارها بر اساس تحلیل لاگ‌های رفتاری است. در این مقاله، ابتدا محیط آزمایشی مناسبی را ایجاد می‌کنیم تا بتوانیم رفتار ۵۷۲ نمونه باج‌افزار از خانواده TeslaCrypt، ۵۳۵ نمونه باج‌افزار از خانواده Cerber و ۵۱۷ نمونه باج‌افزار از خانواده Locky را ثبت کنیم که محیط مهیا شده قابلیت کاربرد در سایر پروژه‌ها و پژوهش‌های مشابه را دارد. برای دسته‌بندی و شناسایی نمونه‌های باج‌افزار، با بهره‌گیری از روش کاوش الگوهای متوالی، ویژگی‌هایی را به‌دست می‌آوریم تا قابل استفاده برای الگوریتم‌های دسته‌بندی‌کننده یادگیری ماشین باشد. دقت ۹۹٪ در تشخیص نمونه‌های باج‌افزار و همین‌طور دقت ۹۶٫۵٪ در شناسایی و دسته‌بندی خانواده آن‌ها روی الگوریتم‌های متداول یادگیری ماشین نشان از کیفیت بالای ویژگی‌های پیشنهادی دارد.

واژگان کلیدی: بدافزار، باج‌افزار، رمزکننده، شناسایی باج‌افزار، شناسایی خانواده باج‌افزار

Detecting Ransomware and Identifying their Families Using Sequence Mining in Dynamic Analysis

Hamid Darabian¹, Sattar Hashemi^{2*}, Sajad Homayoun³ & Karamollah Bagherifard^{*4,5}

^{1,2} Faculty of Computer Science and Engineering, Shiraz University, Shiraz, Iran

³ Faculty of Information Technology and Computer Engineering, Shiraz University of Technology, Shiraz, Iran

⁴ Department of Computer Engineering, Yasooj Branch, Islamic Azad University, Yasooj, Iran

⁵ Young Researchers and Elite Club, Yasooj Branch, Islamic Azad University, Yasooj, Iran

Abstract

Nowadays, crypto-ransomware is considered as one of the most threats in cybersecurity. Crypto ransomware removes data access by encrypting valuable data and requests a ransom payment to allow data decryption. The number of Crypto ransomware variants has increased rapidly every year, and ransomware needs to be distinguished from the goodware types and other types of ransomware to protect users' machines from ransomware-based attacks. Most published works considered System File and process behavior to identify ransomware which depend on how quickly and accurately system logs can be obtained and mined to detect abnormalities. Due to the severity of irreparable damage of ransomware attacks, timely detection of ransomware is of great importance. This paper focuses on the early detection of ransomware samples by analyzing behavioral logs of programs executing on the

* Corresponding author

* نویسنده عهده‌دار مکاتبات

سال ۱۴۰۰ شماره ۳ پیاپی ۴۹

تاریخ ارسال مقاله: ۱۳۹۸/۲/۸ • تاریخ پذیرش: ۱۳۹۹/۵/۲۸ • تاریخ انتشار: ۱۴۰۰/۱۰/۲۷ • نوع مطالعه: کاربردی



operating system before the malicious program destroy all the files. Sequential Pattern Mining is utilized to find Maximal Sequential Patterns of activities within different ransomware families as candidate features for classification. First, we prepare our test environment to execute and collect activity logs of 572 TeslaCrypt samples, 535 Cerber ransomware, and 517 Locky ransomware samples. Our testbed has the capability to be used in other projects where the automatic execution of malware samples is essential. Then, we extracted valuable features from the output of the Sequence Mining technique to train a classification algorithm for detecting ransomware samples. 99% accuracy in detecting ransomware instances from benign samples and 96.5% accuracy in detecting family of a given ransomware sample proves the usefulness and practicality of our proposed methods in detecting ransomware samples.

Keywords: malware, ransomware, crypto ransomware, ransomware detection, ransomware family detection.

۱- مقدمه

امروزه جرایم سایبری^۱، تهدیدات بسیار جدی‌ای را برای دولت‌ها، کسب‌وکارها و کاربران حقیقی و حقوقی به وجود آورده است. افراد بداندیش روزبه‌روز در حال توسعه ابزارهای خطرآفرین هستند و در طرف مقابل متخصصان امنیتی تلاش می‌کنند که از این فعالیت‌ها جلوگیری به‌عمل آورند [1]. حجم، حوزه و هزینه جرایم سایبری در سال‌های اخیر رشد قابل توجهی داشته است و نرم‌افزارهای بداندیش یا بدافزارها^۲ همیشه به‌عنوان یکی از مهمترین ابزارهای جرایم سایبری مطرح بوده‌اند [2]. بر اساس گزارش سیمنتک^۳ تعداد برنامه‌های مخرب از ۳۵۵ میلیون در سال ۲۰۱۵ به ۳۵۷ میلیون در سال ۲۰۱۶ افزایش داشته است [3]. توسعه پول‌های الکترونیکی مثل بیت‌کوین^۴ منجر به ظهور گونه‌ای از بدافزارها به نام باج‌افزار^۵ شده است [4]. باج‌افزار نوعی از بدافزار است که با بهره‌گیری از تکنیک‌های مخرب از دسترسی کاربران به سیستم‌هایشان یا داده‌هایشان جلوگیری می‌کند [5]. تاریخچه پیدایش باج‌افزارها به سال ۱۹۸۹ برمی‌گردد، زمانی که نخستین باج‌افزار تحت عنوان AIDS منتشر شد [6]. اما در آن زمان به‌علت عدم فراهم‌بودن زیرساخت‌های لازم جهت گمنام‌سازی^۶ موفقیت چندانی برای آن‌ها حاصل نشد؛ چون زیرساخت‌های گمنام‌سازی ارتباط در کنار پول‌های الکترونیکی گمنام از ملزومات و خواسته‌های حمله‌کننده است. باج‌افزارها از طریق روش‌های مختلفی انتشار پیدا می‌کنند و به‌صورت کلی فرایند انتشارشان شامل چند مرحله مختلف است که البته می‌توان با شناسایی آن‌ها و بلاک‌کردن آنها جلوی آلوده‌سازی را گرفت. برای مثال هنگامی که یک باج‌افزار از طریق رایانامه

منتشر می‌شود، ممکن است، صدها هزار رایانامه آلوده به باج‌افزار به‌وسیله سامانه‌های تشخیص هرزنامه^۷ بلاک شوند. بیشتر رایانامه‌های شامل باج‌افزار دارای یک داندلودکننده^۸ مخفی درون محتوای پیوست‌شده به رایانامه‌ها هستند که وظیفه داندلود نسخه اجرایی باج‌افزار را بر عهده دارد.

به‌طور کلی باج‌افزارها را می‌توان به دو دسته باج‌افزارهای قفل‌کننده^۹ سیستم و باج‌افزارهای رمزکننده^{۱۰} تقسیم کرد. دسته نخست رایانامه و سیستم قربانی را قفل می‌کنند و فایل‌های موجود در سیستم را دست‌کاری نمی‌کنند؛ درحالی‌که دسته دوم تمام یا قسمتی از داده‌ها را با استفاده از الگوریتم‌های رمزنگاری مثل AES رمز می‌کنند و سپس یک دستورالعمل پرداخت^{۱۱} به قربانی نمایش داده می‌شود [7]. باج‌افزارهای رمزکننده به‌طورمعمول محبوب‌تر از باج‌افزارهای قفل‌کننده هستند چرا که به‌طورمعمول مهندسان امنیت می‌توانند راهی را برای بازکردن قفل سیستم پیدا کند [8]؛ بنابراین تمرکز اصلی این مقاله بر روی باج‌افزارهای رمزکننده است.

در این مقاله تمامی نمونه‌ها از خانواده‌های مختلف باج‌افزارها در یک محیط شبیه‌سازی‌شده اجرا و دنباله فراخوانی‌های سیستمی آن‌ها ثبت می‌شود. با استفاده از روش کاوش الگوهای متوالی بهترین ویژگی‌ها برای جداسازی نمونه‌های باج‌افزار از نمونه‌های غیرمخرب، شناسایی می‌شود. از جمله مزایای روش پیشنهادی این است که باج‌افزارها می‌توانند با تعداد کمی ویژگی (شامل ۲۷ ویژگی) تشخیص داده شوند. دقت ۹۹ درصدی بعد از اعمال تعدادی از الگوریتم‌های یادگیری ماشین و در تشخیص روی ویژگی‌های یافت‌شده، نشان از کیفیت بالای این ویژگی‌ها دارد.

⁷ Spam Detection Systems (Anti-Spam Systems)

⁸ Downloader

⁹ Locker

¹⁰ Crypto

¹¹ Payment Instruction

¹ Cyber Criminals

² Malware

³ Symantec

⁴ Bitcoin

⁵ Ransomware

⁶ Anonymity

بخش ۲ این مقاله به بررسی پژوهش‌های انجام‌شده به‌وسیله سایر پژوهش‌گران می‌پردازد. بخش ۳ مراحل جمع‌آوری داده‌ها را به‌عنوان یک مرحله کلیدی شرح می‌دهد. فرآیند پیشنهادی جهت استخراج ویژگی‌ها با جزئیات در بخش ۴ شرح داده شده است. بخش ۵ متریک‌های مورد نظر جهت ارزیابی نتایج را معرفی و شرح می‌دهد و در بخش ۶ نتایج به‌دست‌آمده روی تفکیک باج‌افزارها از نرم‌افزارهای غیرمخرب مورد بحث قرار گرفته‌اند در حالی که بخش ۷ نتایج اجرای روش پیشنهادی برای تعیین خانواده باج‌افزارها را ارائه می‌دهد. درنهایت بخش ۸ به جمع‌بندی و نتیجه‌گیری می‌پردازد.

۲- پژوهش‌های پیشین

بسیاری از رویکردهای تشخیص باج‌افزارها وابسته هستند به سیستم فایل و تغییراتی که در کلیدهای رجیستری^۱ انجام می‌شود. *Kharaz* [9] و همکاران تعداد ۱۳۵۹ نمونه از باج‌افزارها را بررسی کردند و نشان دادند که بیش‌تر باج‌افزارها از توابع کتابخانه‌ای مشابهی استفاده می‌کنند و به‌طور کلی استراتژی‌های یکسانی را برای آلوده‌سازی و حمله به فایل‌های کاربران دنبال می‌کنند. *CryptoDrop* [10] به‌عنوان یک سیستم شناسایی فرآیندهای مخرب رمزکننده فایل‌های کاربر معرفی شده است. *CryptoDrop* با یک محدودیت کلیدی مواجه است که دست‌کم باید حدود ده فایل کاربر به‌وسیله باج‌افزار رمز شده باشند تا توانایی تعیین مخرب بودن آن مهیا شود که این خود منجر به ازدست‌رفتن داده‌های این فایل‌ها می‌شود که ممکن است در بردارنده داده‌های حساسی باشند. *ShieldFS* [11] روشی برای شناسایی باج‌افزارها براساس نحوه استفاده از توابع رمزنگاری و همچنین فایل‌های رمز شده است و درنهایت تصمیم می‌گیرد که یک نمونه فرآیند در حال اجرا مخرب است یا بی‌خطر است. *DAD* [12] با مقایسه آنتروپی^۲ فایل‌ها قبل و بعد از عملیات آلوده‌سازی (رمزگذاری فایل) قصد شناسایی یک باج‌افزار را دارد که بر اساس ارزیابی‌های انجام‌شده توسط پیشنهاددهندگان برای رسیدن به دقت ۹۹/۳۷ درصد شناسایی باج‌افزارها به‌طور تقریبی هفتاد مگابایت از داده‌های فایل‌ها را از دست داده است. روش *EldeRan* [13] از ترکیب آنالیز ایستا و پویا برای شناسایی باج‌افزارها بهره برده است. در این روش برای آنالیز ایستا از رشته‌های موجود در فایل‌های دودویی و برای آنالیز پویا از فعالیت‌های کلیدهای رجیستری،

عملیات روی فایل‌ها و دایرکتوری‌ها، عملیات ساخت فایل‌ها به‌وسیله فرآیندها در طول اجرای سی ثانیه استفاده می‌کند و درنهایت حضور یا عدم حضور هر رشته و فعالیت‌های پویا را به‌صورت ویژگی‌های باینری در نظر می‌گیرد که باعث می‌شود تعداد ویژگی‌ها به‌طور قابل ملاحظه‌ای افزایش پیدا کند. *Redemption* [14] به‌عنوان یک سیستم شناسایی باج‌افزارها سعی در استخراج ویژگی‌هایی مبتنی بر محتوا و مبتنی بر رفتار دارد که این ویژگی‌ها بیشتر روی سیستم فایل تمرکز دارند، ویژگی‌هایی نظیر آنتروپی، بازنویسی فایل‌ها و عملیات حذف فایل‌ها در نظر گرفته شده‌اند.

تشخیص به‌موقع باج‌افزار در زمان اجرا بسیار اهمیت دارد و سیستم‌هایی که در کمتر از ده ثانیه نتوانند بدافزارها را شناسایی کنند به‌صورت مؤثر در نظر گرفته نمی‌شوند [5]. همین‌طور این‌که شناسایی به‌موقع خانواده باج‌افزارها می‌تواند متخصصان را در ساختن عامل‌های هوشمند کاربردی یاری کند.

در این مقاله، ما از تکنیک کاوش الگوهای دنباله‌ای^۳ استفاده می‌کنیم تا بتوانیم ویژگی‌های^۴ قابل استفاده برای الگوریتم‌های دسته‌بندی‌کننده^۵ یادگیری ماشین^۶ را به‌دست بیاوریم که برای جداکردن نمونه‌های باج‌افزار از نمونه‌های غیرمخرب^۷ و همین‌طور شناسایی خانواده‌ی باج‌افزارها مناسب باشند. این تکنیک را بر روی الگوی فعالیت‌های رجیستری^۸، سیستم‌فایل^۹ و *DLL*^{۱۰} نمونه‌ها در زمان اجرا اعمال کردیم که مدت زمان اجرای نمونه‌ها کمتر از ده ثانیه بوده است. با انجام آزمایش بر روی ۵۱۷ عدد نمونه باج‌افزار از خانواده *Locky*، ۵۳۵ عدد باج‌افزار از خانواده *Cerber*، ۵۷۲ عدد از خانواده *TeslaCrypt* و ۲۲۰ عدد نمونه غیرمخرب ویندوزی، همین‌طور با بهره‌گیری از الگوریتم‌های دسته‌بندی‌کننده متداول یادگیری ماشین شامل *J48*، *Random Forest*، *Bagging* و *MLP*، کیفیت ویژگی‌های به‌دست‌آمده را مورد سنجش قرار می‌دهیم. دقت ۹۹ درصد در جداسازی بدافزارها از نمونه‌های غیر مخرب و دقت ۹۶/۵ درصد در شناسایی خانواده آن‌ها، نشان از مناسب بودن کیفیت ویژگی‌های به‌دست‌آمده دارد.

³ Mining Sequential Patterns

⁴ Feature

⁵ Classification

⁶ Machine Learning

⁷ Non-malicious

⁸ Registry Activities

⁹ System File

¹⁰ Dynamic Linked Library

¹ Registry Keys

² Entropy

در ابتدا به تعداد ۱۶۲۴ عدد نمونه باج افزار را از تارنمای virustotal.com دانلود کردیم که مخرب بودن این نمونه ها در تارنمای RansomwareTracker.abuse.ch در بازه زمانی فوریه ۲۰۱۶ تا مارس ۲۰۱۷ گزارش شده است. مجموعه باج افزارها شامل ۵۱۷ عدد نمونه باج افزار از خانواده Locky، ۵۳۵ عدد باج افزار از خانواده Cerber، ۵۷۲ عدد از خانواده TeslaCrypt که همگی فایل های اجرایی ویندوز هستند. همین طور تعداد ۲۲۰ عدد نرم افزار بی خطر از فهرست portableapps.com جمع آوری شده است که تمام این نرم افزارها، برنامه های قابل حمل^۱ exe هستند.

محیطی به طور کامل کنترل شده طراحی و پیاده سازی شده است تا بتوانیم رفتارهای نمونه های باج افزارها و نمونه های بی خطر را ثبت کنیم. معماری بستر آزمایش^۲ در شکل (۱) نمایش داده شده است. بستر آزمایش دارای دو قسمت اصلی کنترل کننده^۳ و عامل اجرا کننده^۴ است. وظایف عامل کنترل کننده شامل مشخص کردن مدت زمان اجرای آزمایش، ارسال نمونه به عامل اجرا کننده^۵ مستقر در ماشین مجازی^۶، بازگرداندن اسنپشات^۷ ماشین مجازی بعد از هر بار اجرای برنامه نمونه است. همین طور عامل اجرا کننده وظیفه دریافت نمونه را از مخزن موجود در FTP دارد تا با اجرای نمونه باج افزار، فعالیت های ناشی از نمونه مورد آزمایش در محیط سیستم عامل با استفاده از ابزار لاگ گیری ثبت شود. برای لاگ گیری از ابزار Process Monitor استفاده می کنیم که قابلیت ثبت فعالیت های یک فرایند روی فایل ها، کلیدهای رجیستری ویندوز، مانیتور کردن^۸ زیرفرایندها/زیر نخ ها^۹ و غیره را دارد. جدول (۱) نشان دهنده فهرستی از سه نوع اصلی از فعالیت های انجام شده به وسیله فرایندهای سیستم عامل از قبیل بارگذاری^{۱۰} DLL ها، رفتارهای مختلف روی فایل ها و فعالیت روی کلیدهای رجیستری است که قصد داریم با کمک ابزار Process Monitor به ثبت فعالیت های آنها بپردازیم. نکته اینکه فهرست موجود در جدول (۱) شامل

تمام رفتارهای منحصر به فرد انجام شده به وسیله نمونه های مورد آزمایش در این پروژه است و این یعنی رفتارهایی که هرگز دیده نشده اند در جدول (۱) آورده نشده اند؛ زیرا هیچ کمکی به صورت مسأله این مقاله نخواهند داشت. اجرای نمونه های باج افزارها با نمونه های بی خطر با یکدیگر تفاوت عمده ای دارد، چرا که نمونه های باج افزارها پس از اجرا و بدون نیاز به دخالت کاربر فعالیت های مخرب خود را انجام می دهد؛ در حالی که به طور معمول نمونه های غیر مخرب به علت وجود پنجره گرافیکی نیاز به تعامل کاربر وجود دارد تا بتوانیم فعالیت های برنامه را ثبت کنیم. به همین علت ابزاری به نام PyWinMonkey^{۱۱} طراحی و پیاده سازی کرده ایم که به صورت تصادفی^{۱۲} رفتار کاربر را در تعامل با پنجره گرافیکی برنامه بی خطر شبیه سازی می کند و این کار را تا زمانی انجام می دهد که یا مدت زمان آزمایش به پایان برسد یا خطاهای برنامه در اجرای صحیح نرم افزار یافته شود.

جهت اجرای بستر آزمایش از ویندوز ۱۰ با سریال تولید ۱۰۲۴۰ روی سیستم رایانه ای با پردازنده هشت هسته ای با قدرت ۴ گیگاهرتز و حافظه اصلی شانزده گیگابایت استفاده شده است. از نسخه ProcessMonitor V3.31 جهت لاگ برداری فعالیت های فرایندها استفاده شده است. از آنجا که رفتار کلی هر فرایند از طریق دنباله ای^{۱۳} از فعالیت های پشت سر هم تشکیل می شود؛ لذا در این مقاله از مفهوم دنباله جهت نمایش فعالیت های یک فرایند بهره گرفته می شود. گفتنی است که داده های اولیه (لاگ ها) استخراج شده از بستر آزمایش به صورت یک فایل به ازای هر آزمایش است که در مرحله نخست نیاز به ساخت دنباله فعالیت ها از فایل لاگ ها است و این یعنی پس از تبدیل به ازای هر فایل لاگ یک دنباله افقی نشان دهنده فعالیت های انجام گرفته به صورت ترتیبی موجود خواهد بود که در نهایت مجموعه این دنباله ها مجموعه دادگان $D = \{S_1, S_2, \dots, S_n\}$ را می سازند که S_i نشان دهنده دنباله ترتیبی مرتب شده در واحد زمان از فعالیت ها است.

هر دنباله S_i که به صورت عبارت ۱ است، نشان دهنده یک دنباله است که دارای m فعالیت است و m می تواند برای ک های مختلف متفاوت باشد که نشان دهنده تعداد فعالیت های انجام شده متفاوت به وسیله فرایندها است. $A_{i,j}(argA_j)$ نشان دهنده فعالیت j ام از دنباله i ام (S_i) است. هر فعالیت انجام شده روی یک مسیر

¹¹ <https://github.com/sajadhomayoun/PyWinMonkey>

¹² Random

¹³ Sequence

¹ Portable

² Test Bed

³ Controller

⁴ Launcher

⁵ Virtual Machine

⁶ Snapshot

⁷ Monitoring

⁸ Sub-process

⁹ Sub-thread

¹⁰ Load

بسترآزمایش است. D_{Cerber} نمایش‌گر دنباله‌های تولیدشده به وسیله باج‌افزارهای خانواده Cerber است. $D_{TeslaCrypt}$ دربرگیرنده دنباله‌های به‌دست‌آمده از اجرای نمونه‌های TeslaCrypt در بسترآزمایش است. درنهایت D_{Benign} نشان‌دهنده دنباله‌های تولیدشده از اجرای نرم‌افزارهای بی‌خطر است. جهت اینکه تخمینی واقع‌بینانه از مدل‌های پیش‌بینی ساخته‌شده در این بخش وجود داشته باشد و از عدم مشکل به‌وجودآمدن بیش‌برازش^۲ اطمینان حاصل کرد از مجموعه‌داده‌هایی استفاده می‌شود که شامل دنباله‌هایی باشند که به‌طورکامل برای مدل ساخته‌شده جدید باشند. از همین رو به‌ازای هر کدام از خانواده باج افزارها و برنامه‌های غیرمخرب از همان ابتدا به‌صورت تصادفی تعدادی از دنباله‌ها انتخاب و در دیتاستی جداگانه به نام D_{OP} قرار داده شدند.

(جدول-۱): فهرست فعالیت‌های استخراج‌شده از رفتار

نمونه‌های تحت آزمایش

(Table-1): List of activities can be captured by process monitor

ردیف	نوع فعالیت	لیست
۱	Registry Key	RegQueryKey, RegOpenKey, RegCloseKey, RegQueryValue, RegCreateKey, RegSetInfoKey, RegEnumKey, RegQueryKeySecurity, RegEnumValue, RegSetValue, RegDeleteValue, RegQueryMultipleValueKey, RegLoadKey, RegDeleteKey, RegFlushKey
۲	Filesystem	QueryNameInformationFile, ReadFile, CreateFile, QueryBasicInformationFile, CloseFile, QueryStandardInformationFile, CreateFileMapping, QuerySizeInformationVolume, FileSystemControl, QueryDirectory, WriteFile, QueryNetworkOpenInformationFile, QueryRemoteProtocolInformation, QuerySecurityFile, LockFile, UnlockFileSingle, DeviceIoControl, SetEndOfFileInformationFile, FlushBuffersFile, SetAllocationInformationFile, SetBasicInformationFile, QueryAttributeTagFile, QueryFileInternalInformationFile, QueryInformationVolume, QueryAttributeInformationVolume, SetRenameInformationFile, QueryNormalizeNameInformationFile, NotifyChangeDirectory, QueryFullSizeInformationVolume, SetSecurityFile, QueryStreamInformationFile, SetDispositionInformationFile,


² Overfit

در سیستم انجام می‌گیرد که با $argA_j$ نمایش داده شده و بیان‌کننده این است که فعالیت A_j روی مسیر $argA_j$ که تداعی‌کننده آرگمان^۱ ورودی به فعالیت است، انجام گرفته است.

$$S_i = \{A_{i,1}(argA_1), A_{i,2}(argA_2), \dots, A_{i,m}(argA_m)\} \quad (۱)$$

به‌عنوان مثال عبارت:

{LoadImage(system32\gdi32.dll), ReadFile(Windows\SysWOW64\wininet.dll)} نشان‌دهنده یک دنباله از دو فعالیت که نخستین فعالیت LoadImage است که فایل system32\gdi32.dll را در حافظه فرآیند فراخوانی‌کننده بارگذاری می‌کند و سپس فایل wininet.dll از مسیر Windows\SysWOW64\ خوانده شده است. اندازه هر دنباله وابسته به تعداد فعالیت‌هایی است که در طول اجرای برنامه انجام شده و بین برنامه‌های مختلف، متفاوت است.



(شکل-۱): بسترآزمایش طراحی شده جهت اجرای نمونه‌ها

(Figure-1): Designed test bed to execute samples

جدول (۲) نشان‌دهنده مجموعه‌داده نهایی و تعداد دنباله در هر مجموعه‌داده است. به‌صورتی که D_x به مجموعه‌داده x اشاره می‌کند که شامل دنباله‌های رفتاری توسط نمونه‌های از خانواده x تولید شده‌اند.

D_{Locky} نشان‌دهنده تمام دنباله‌های به‌دست‌آمده از اجرای نمونه‌های باج‌افزارهای از خانواده Locky در

¹ Argument

QueryEaInformationFile, QueryAllInformationFile, QueryIdInformation, SetPositionInformationFile, QueryPositionInformationFile, SetValidDataLengthInformationFile		
LoadImage	DLL	۳

حال که مجموعه دنباله‌های هر برنامه مخرب و غیر مخرب به دست آمد، روش معرفی شده در بخش بعدی به شرح نحوه استخراج ویژگی‌ها می‌پردازد.

(جدول-۲): مجموعه داده‌های ساخته شده

(Table-2): Created datasets

شماره ردیف	مجموعه داده	تعداد دنباله در هر مجموعه داد
۱	D_{Locky}	۴۵۰
۲	D_{Cerber}	۴۷۰
۳	$D_{TeslaCrypt}$	۵۰۷
۴	D_{Benign}	۲۰۰
۵	D_{Op}	۱۷۴

۴- استخراج ویژگی و بردارسازی

با بهره‌گیری از بستر آزمایش طراحی شده در قسمت پیش تمامی نمونه‌های بی‌خطر بارگیری شده و تمامی نمونه‌های باج‌افزارها و نرم‌افزارهای بی‌خطر اجرا شده و فعالیت‌های آن‌ها ثبت و ضبط شده است و تمامی فعالیت‌های هر نمونه تحت قالب یک دنباله نشان داده می‌شود. پس از اتمام فرآیند ساخت دنباله‌ها، از الگوریتم FindFPOF [15] جهت شناسایی و حذف دنباله‌های پرت استفاده شده است. تعداد کمی از الگوریتم‌های شناسایی نقاط پرت^۱ توانایی کار روی دنباله‌ها را دارند که $FindFPOF^2$ یکی از آن روش‌ها به شمار می‌آید و از روش کاهش دنباله‌ها بهره می‌گیرد [16]. FindFPOF از معیار $FFOF$ جهت شناسایی و حذف نقاط پرت استفاده می‌کند؛ بدین صورت که دنباله‌های با مقادیر FPOF پایین به عنوان نقاط پرت معرفی می‌کند.

جهت شناسایی بهترین ویژگی برای دسته‌بندی باج‌افزارها و نرم‌افزارهای بی‌خطر نیاز به استخراج ویژگی‌های فعالیت‌ها که قابل شناسایی در دنباله‌ها باشند، است؛

بنابراین از الگوریتم‌های کاوش الگوی متوالی برای به دست آوردن الگوهای متوالی بیشینه (MSP)^۴ بهره گرفته، سپس عملیات پیمایش دنباله‌ها در مجموعه داده‌ها انجام می‌شود و با توجه به MSPها عملیات بردارسازی و محاسبه ویژگی‌ها انجام می‌گیرد.

کاوش الگوهای متوالی، تمامی زیردنباله‌ها^۵ (الگوهای متوالی) موجود در یک مجموعه داده‌ها شامل داده‌های دنباله‌ای را طوری شناسایی می‌کند که تعداد تکرار آن‌ها در مجموعه داده‌ها بزرگتر مساوی کمینه مقدار آستانه^۶ تعیین شده از سوی کاربر است. یک دنباله α را که به صورت $\{a_1, a_2, \dots, a_{Len(\alpha)}\}$ است، در نظر بگیرید که a_i نمایشگر عنصر i ام باشد و $Len(\alpha)$ نمایشگر طول دنباله α است. α زیردنباله یک دنباله دیگر $\beta = \{b_1, b_2, \dots, b_{Len(\beta)}\}$ است؛ در صورتی که اعداد صحیحی به صورت $1 \leq j_1 < j_2 < \dots < j_{Len(\alpha)} \leq Len(\beta)$ وجود داشته باشند که $a_1 \leq b_{j_1}, a_2 \leq b_{j_2}, \dots, a_{Len(\alpha)} \leq b_{j_{Len(\alpha)}}$ باشد. اگر min_{sup} نشان‌دهنده کمینه تکرار مورد نظر جهت مشخص کردن یک الگوی مکرر باشد و شرط $sup_{\alpha} \geq min_{sup}$ برقرار باشد، می‌توان از α به عنوان یک الگوی متوالی مکرر (MSP) نام برد، جایی که sup_{α} نمایشگر تعداد رخداد α در مجموعه داده‌ها D است.

روش‌های مختلفی برای پیاده‌سازی روش کاوش الگوهای متوالی ارائه شده [17] مثل GSP، AprioriAll، SPADE و PrefixSpan که این روش‌ها اغلب به دلیل طولانی بودن زمان پردازش و مصرف حافظه زیاد ممکن است برای مجموعه داده‌های بزرگ ناکارآمد باشند [18]. در این مقاله برای تولید MSPها از راه‌کاری به نام MG-FSM استفاده شده است که یک راهکار پردازش موازی^۷ مبتنی بر Map-Reduce [19] ارائه می‌کند که به راحتی قابلیت پیاده‌سازی روی زیرساخت ابری را با هدف مقیاس‌پذیری در کاوش مجموعه داده‌ها بزرگ فراهم می‌آورد. مهم‌ترین ورودی این الگوریتم مجموعه داده‌ها و مقدار min_{sup} است [16]. در الگوریتم‌های کاوش الگوهای دنباله‌ای مقدار min_{sup} روی نتیجه نهایی تأثیر فراوانی دارد. مقادیر پایین برای min_{sup} ممکن است، مجموعه عظیمی از MSPها تولید کند (MC بزرگ) که این امر زمان اجرای الگوریتم بردارسازی^۸ پیشنهادی را افزایش

⁴ Maximum Sequential Pattern

⁵ Sub-sequence

⁶ Threshold

⁷ Parallel Processing

⁸ Vectorization

¹ Outlier

² Find Frequent Pattern Outlier Factor

³ Find Pattern Outlier Factor

(جدول-۳): فهرست انواع MSP

(Table-3): List of MSP types

نوع MSP	شرح
R	تمام فعالیت‌ها از نوع رجیستری باشد
F	تمام فعالیت‌ها از نوع سیستم فایل باشد
D	تمام فعالیت‌ها از نوع بارگذاری فایل‌های DLL باشد
RF	MSP دارای یک یا چند نوع انتقال بین فعالیت‌های انواع مختلف است در حالی که اولین انتقال رخ داده در آن انتقالی از فعالیت رجیستری به فعالیت سیستم فایل می‌باشد.
RD	MSP دارای یک یا چند نوع انتقال بین فعالیت‌های انواع مختلف است در حالی که اولین انتقال رخ داده در آن انتقالی از فعالیت رجیستری به فعالیت DLL می‌باشد.
FR	MSP دارای یک یا چند نوع انتقال بین فعالیت‌های انواع مختلف است در حالی که اولین انتقال رخ داده در آن انتقالی از فعالیت سیستم فایل به فعالیت رجیستری می‌باشد.
FD	MSP دارای یک یا چند نوع انتقال بین فعالیت‌های انواع مختلف است در حالی که اولین انتقال رخ داده در آن انتقالی از فعالیت سیستم فایل به فعالیت DLL می‌باشد.
DR	MSP دارای یک یا چند نوع انتقال بین فعالیت‌های انواع مختلف است در حالی که اولین انتقال رخ داده در آن انتقالی از فعالیت DLL به فعالیت رجیستری می‌باشد.
DF	MSP دارای یک یا چند نوع انتقال بین فعالیت‌های انواع مختلف است در حالی که اولین انتقال رخ داده در آن انتقالی از فعالیت DLL به فعالیت سیستم فایل می‌باشد.

با توجه به مطالب مطرح‌شده می‌توان تعداد کل ویژگی‌های موجود در بردار را با استفاده از فرمول (۳) به‌دست‌آورد. جایی که عدد ۳ نشان‌دهنده تعداد نوع فعالیت‌های در نظر گرفته شده است (R، F، D) و x بیان‌گر تعداد گذار مورد نظر در عملیات بردارسازی است. در توضیح این فرمول باید گفت که اگر $t = a, b, c$ یک MSP باشد و برای در نظر گرفتن انتقال‌های ۲ تایی a می‌تواند یکی از سه حالت ممکن (R، F، D) باشد و از آن جا که برای به‌وجود آمدن یک انتقال باید نوع فعالیت جدید با قبلی متفاوت باشد ($b \neq a$) یعنی دو نوع فعالیت مجاز برای b موجود است؛ درحالی‌که برای انتقال بعدی باید $c \neq b$ باشد و این یعنی دو نوع فعالیت ممکن برای c . در نتیجه بخش 3×2^i از فرمول (۳) تشکیل می‌شود. به‌عنوان مثال برای $x = 3$ که به معنای در نظر گرفتن تک انتقالی، دو انتقالی و سه انتقالی‌ها است براساس فرمول عبارت ۳ باید ۴۵ ویژگی در بردار باشد. بنابر مطالب گفته‌شده جهت جلوگیری از اسپارس شدن نمونه‌ها در این مقاله فقط انتقال‌های یگانه و دوتایی در استخراج ویژگی‌ها در نظر گرفته شده‌اند.

می‌دهد. از سوی دیگر مقادیر بالا برای min_{sup} ممکن است MSP‌های با ارزشی را حذف کند که می‌توانند در شناسایی و تفکیک باج‌افزارها مؤثر باشند. از همین رو در این مقاله min_{sup} به مقدار پنجاه درصد تنظیم شده است تا کارایی قابل قبولی در شناسایی MSP‌ها به‌دست آید.

به‌کاربردن جداگانه MG-FSM روی مجموعه‌دادگان D_{Locky} ، D_{Cerber} و $D_{TestaCrypt}$ موجب تولید $MC_{D_{Locky}}$ ، $MC_{D_{Cerber}}$ ، $MC_{D_{TestaCrypt}}$ می‌شود؛ به‌طوری‌که MC_D به شکل فرمال در فرمول (۲) قابل مشاهده است و P_x و P_y نشان‌دهنده یک زیر دنباله هستند.

$$MC_D = \left\{ \left(P_x, \sup_{P_x} \right) \left| \sup_{P_x} \geq min_{sup} \wedge \forall P_x (\neg P_y (P_x \subseteq P_y)) \right. \right\} \quad (2)$$

جهت تعریف انواع MSP‌ها در ابتدا سه نوع MSP اتمیک^۱ تعریف شده است و سپس شش نوع MSP تک‌انتقالی^۲ را در جدول (۳) تعریف می‌شود. MSP‌های اتمیک نشان‌دهنده فعالیت‌های از یک نوع به‌صورت پشت سر هم است؛ به عبارت دیگر یک MSP اتمیک است، اگر تمامی فعالیت‌های موجود در آن از یک نوع باشند. به‌عنوان مثال در جدول (۳) مشخص است که F نشان‌دهنده MSP‌هایی است که تمامی فعالیت‌هایشان از نوع کار با سیستم فایل‌ها باشد.

MSP‌های تک‌انتقالی نشان‌دهنده انتقال (گذار)^۳ از یک نوع فعالیت به نوع دیگری از فعالیت‌ها است. به‌عنوان مثال RD نشان می‌دهد که ابتدا دنباله از یک یا چند فعالیت رجیستری (R) رخ داده و سپس یک یا چند فعالیت DLL (D) انجام شده است. به‌عنوان مثالی از انتقال دوتایی FRD را در نظر بگیرید که نشان‌دهنده انتقال از F به R و سپس از R به D است. هر چند به‌طورعمومی تعداد ویژگی‌های بیشتر ساخت مدل پیش‌بینی‌کننده و تفکیک‌کننده نمونه‌ها ساده‌تر و امکان‌پذیرتر می‌کند؛ اما تعداد ویژگی‌های بیش از اندازه، داده‌های مجموعه‌داده را در فضای ابعاد اسپارس می‌کند و در نتیجه یافتن بهترین صفحه جداکننده نمونه‌ها امری دشوار می‌شود. این موضوع تحت عنوان مسأله نفرین ابعاد^۴ [20] مطرح می‌شود و بیان می‌کند که افزایش تعداد ابعاد موجب افزایش فضا شده به‌طوری‌که داده‌های موجود به‌سرعت در محیط نمودار پراکنده می‌شوند.

¹ Atomic

² One Step Transition

³ Transition

⁴ Curse of Dimensionality Problem

```

1. Procedure MSPTyping(MSP P)
2.   for all  $(E_x, E_y \in P) \wedge (x \leq i) \wedge (i, y \leq n)$ 
3.     if  $EventType(E_x) == EventType(E_y)$ 
4.       then
5.         if  $EventType(E_x) == R$  return R
6.         if  $EventType(E_x) == F$  return F
7.         if  $EventType(E_x) == D$  return D
8.       Else
9.         if  $EventType(E_x) == R$  &
10.           $EventType(E_x) == F$  return RF
11.        if  $EventType(E_x) == R$  &
12.           $EventType(E_x) == D$  return RD
13.        if  $EventType(E_x) == F$  &
14.           $EventType(E_x) == R$  return FR
15.        if  $EventType(E_x) == F$  &
16.           $EventType(E_x) == D$  return FD
17.        if  $EventType(E_x) == D$  &
18.           $EventType(E_x) == R$  return DR
19.        if  $EventType(E_x) == D$  &
20.           $EventType(E_x) == F$  return DF
21.      end if
22.    end for
23.  end procedure

```


(شکل-۲): الگوریتم MSPTType جهت تعیین نوع یک MSP
(Figure-2): MSPTType algorithm to determine a given MSP

```

1. Procedure CalculateSR(Sequence S, MSP Collection
   MC, MSPTypeSet)
2.    $SR_{p_{Total}} = 0$ 
3.   for all ( $P \in MC$ ) do
4.     if ( $P \subseteq S$ ) & ( $MSPType(P) == T$ ) then
5.        $SR_{p_{Total}} = SR_{p_{Total}} + \left(\frac{sup_P}{\gamma}\right)$ 
6.     end if
7.   end for
8.   return  $SR_{p_{Total}}$ 
9. end procedure

```

(شکل-۳): الگوریتم محاسبه SR برای دنباله S



(شکل-۴): شکل یک ابر بردار ساخته شده از سه MC مختلف
(Figure-4): A super vector made of three different MC

در شکل (۴)، $Vector(S)_{MC_i}$ نشان‌دهنده بردار به‌دست‌آمده از S با توجه به مجموعه MSP‌های موجود در MC_i است. از آن جا که در این پروژه سه خانواده باج‌افزار در نظر گرفته شده‌اند، بنابراین برای هر S سه بردار ساخته می‌شود: $Vector(S)_{MC_{Locky}}$ ، $Vector(S)_{MC_{Cerber}}$ و $Vector(S)_{MC_{TeslaCrypt}}$ که تشکیل یک آبربردار می‌دهند. با

$$TotalFeatures = 3 + \sum_{i=1}^x (3 \times 2^i) \quad (3)$$

با در نظر گرفتن $P = \{E_1, E_2, \dots, E_n\}$ به عنوان یک MSP اتمیک تعریف می شود اگر شرط

$$\forall E_{x_1}, E_{y_1} \in P \wedge E_{x_1} \neq E_{y_1} (EventType(E_{x_1}) = EventType(E_{y_1}))$$

برقرار باشد. همچنین P یک MSP تک انتقالی است؛ اگر

$$\exists E_{x_1}, E_{y_1} \in P \wedge E_{x_1} \neq E_{y_1} (EventType(E_{x_1}) \neq EventType(E_{y_1}))$$

شرط برقرار باشد. $EventType(x)$ نشان دهنده یک روال است که با دریافت یک فعالیت x نوع آن را با توجه به جدول (۳) مشخص می کند؛ به علاوه می توان مجموعه ای از انواع ممکن MSP در

$$MSPTypeset = \{F, R, D, FR, FD, RF, RD, DF, DR\}$$

مجموعه تعریف کرد که الگوریتم $MSPTypeset()$ در شکل (۲) به عنوان خروجی یکی از عناصر مجموعه $EventTypeset$ را باز می گرداند.

نرخ پشتیبانی^۱ (SR) برای یک MSP مقداری در بازه $[0,1]$ است که نشان‌دهنده احتمال رخداد آن MSP در مجموعه داده با افزایش آن است و از طریق تقسیم تعداد رخداد MSP (sup_{MSP}) بر تعداد کل (γ) دنباله‌های با افزایش آن مجموعه داده D به دست می‌آید. برای هر دنباله S یک بردار با ۹ ویژگی تعریف می‌شود که هر ویژگی مقدار SR برای آن نوع MSP و با توجه به مجموعه MSPها (MC) محاسبه می‌شود. قالب بردار ویژگی یادشده به صورت فرمول (۴) است.

$$Vector(S)_{MC} = \{SR_R, SR_F, SR_D, SR_{FR}, SR_{RF}, SR_{RD}, SR_{DF}, SR_{DR}\} \quad (4)$$

مقدار SR برای هر نوع MSP از یک دنباله با توجه به MC مورد نظر می‌تواند با استفاده از الگوریتم $CalculateSR()$ در شکل (۳) محاسبه می‌شود؛ پس از آن که یک بردار به‌ازای هر دنباله مجموعه‌داده محاسبه شد درنهایت مجموعه‌داده برداری $VD_{D,MC}$ را موجود خواهد داشت که $VD_{x,y}$ نشان‌دهنده نسخه‌برداری شده مجموعه‌داده x براساس مجموعه MSP‌های موجود در y است. همچنین این پروژه جهت شناسایی خانواده‌های باج‌افزارها مفهوم آبردار^۲ (SV) را مطرح می‌کند که از قرارگرفتن چند بردار در کنار یکدیگر بردار بزرگتری تشکیل می‌دهد. به عبارت دیگر اگر بردارسازی با توجه به MC‌های مختلف انجام گیرد می‌توان آن‌ها را کنار یکدیگر قرار داد و بردار بزرگتری ساخت که شکل (۴) نشان‌دهنده ساختار یک آبردار است.

¹ Support Ratio² Super Vector

توجه به اینکه هر بردار ۹ ویژگی دارد پس آبربردار نهایی دارای $27 = 3 \times 9$ ویژگی خواهد بود. پس از محاسبه آبربردارها برای S ‌های موجود در مجموعه داده D ، مجموعه داده ابربرداری شده SVD_D تشکیل خواهد شد.

۵- متریک‌های مورد استفاده جهت ارزیابی روش پیشنهادی

در این مقاله برای ارزیابی کارایی روش پیشنهادی از معیارهای شاخص کارایی دسته‌بندی‌کننده‌ها [21] شامل مثبت واقعی^۱، منفی واقعی^۲، مثبت کاذب^۳ و منفی کاذب^۴ هستند. معیار دقت^۵ که به‌عنوان نرخ آشکارسازی مثبت هم شناخته می‌شود، میزان حساسیت مدل یا مقدار نتایج مرتبط برگردانده شده را نشان می‌دهد و برابر است با تعداد باج‌افزارهای تشخیص داده شده به وسیله مدل تقسیم بر کل تعداد باج‌افزارهای عضو در مجموعه آزمایش که از طریق فرمول (۵) محاسبه می‌شود. معیار بازخوانی^۶ نشان‌دهنده نسبت داده‌های مثبتی (باج‌افزارهایی) که به درستی به وسیله مدل تشخیص داده شده‌اند می‌باشد که از رابطه (۶) محاسبه می‌شود. اندازه F-measure، میانگین هارمونیک معیارهای دقت و بازخوانی است و میزان کارایی دسته‌بندی‌کننده را نشان می‌دهد (فرمول ۷).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (6)$$

$$F\text{-measure} = 2 * \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

مشخصه عملیاتی گیرنده^۷ (ROC) یک معیار قوی برای مقایسه دسته‌بندی‌کننده‌ها به حساب می‌آید چرا که در برابر ناهم‌گونی طبقه‌های مجموعه داده ثابت و در این مقاله نیز گزارش شده است. در یک نمودار ROC نرخ مثبت واقعی بر اساس نرخ مثبت کاذب با آستانه‌ها مختلف کشیده می‌شود. سطح زیر نمودار ROC که به‌عنوان AUC شناخته می‌شود، پارامتر خوبی است که می‌تواند دو دسته‌بندی‌کننده را مقایسه کند. معیار AUC درواقع یک تک‌مقدار است که می‌توان گفت نمودار ROC را در یک عدد خلاصه کرده است. AUC مقداری بین صفر و یک دارد که مقدار یک بیان می‌کند که دسته‌بندی‌کننده عملکردی دقیق داشته است.

ضریب همبستگی متیوز^۸ (MCC) [22] پارامتر دیگری از میزان کیفیت است که برای مقایسه دسته‌بندی‌کننده‌های مختلف به کار می‌رود. این اندازه برای زمانی که طبقه‌های مجموعه داده متعادل نیستند بهتر از دیگر معیارها عمل می‌کنند [23]. به‌عنوان مثال معیار F-measure زمانی که مدل عملکرد تصادفی دارد مقدار آنها ممکن است بیشتر ۰/۵ و این مقدار به سمت طبقه با داده‌های بیشتر هم‌گرا می‌شود درحالی‌که این مقدار برای ضریب MCC دقیقاً صفر خواهد شد. مقدار این ضریب بین -۱ تا +۱ تغییر می‌کند. در این‌جا مقدار +۱ نشان‌دهنده این است که دسته‌بندی‌کننده به‌صورت کاملاً دقیق نمونه‌های آزمایش از هم تشخیص می‌دهد و مقدار -۱ بیان‌گر این است که دسته‌بندی‌کننده به‌صورت کاملاً برعکس جواب داده است. مقدار صفر نشان می‌دهد دسته‌بندی‌کننده مورد ارزیابی دارای عملکردی تصادفی است؛ بنابراین برای نشان دادن آن که دسته‌بندی‌کننده‌های آموزش دیده شده، عملکردی به دور از تصادفی بودن داشته‌اند، مقدار MCC از طریق فرمول (۸) گزارش داده می‌شود.

$$MCC = \frac{TP * TN - FP * FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (8)$$

۶- نتایج روش بردارسازی برای شناسایی باج‌افزارها

برای پیاده‌سازی قسمت پیش‌پردازش داده‌ها، بردارسازی و ساخت دسته‌بندی‌کننده‌ها از کتابخانه‌های موجود در Python 3.5 استفاده شده است. همین‌طور تمام ارزیابی‌های این مقاله به روش 10-Fold انجام شده است. در روش بردارسازی برای شناسایی بهترین ویژگی‌ها در تفکیک باج‌افزارها از نرم‌افزارهای بی‌خطر، مجموعه داده D_{Total} با ادغام D_{Benign} و $D_{Ransomware}$ ساخته می‌شود؛ سپس $MC_{Ransomware}$ را با به‌کارگیری MG-FSM روی $D_{Ransomware}$ به‌دست آورده تا مهبیای عملیات بردارسازی شود. اکنون با روش بردارسازی مطرح شده در بخش ۴ $VD_{D_{Total}, MC_{Ransomware}}$ ساخته شده و آماده الگوریتم‌های آموزش دسته‌بندی‌کننده می‌شود. جهت انتخاب بهترین ویژگی‌ها در تفکیک باج‌افزارها و نرم‌افزارهای بی‌خطر از روش جستجوی گام به گام حریصانه^۹ CfsSubsetEval [24] استفاده شده است. پس از اجرای CfsSubsetEval سه ویژگی SR_R ، SR_D و SR_{FD}

⁸ Matthews Correlation Coefficient

⁹ Greedy Stepwise Search

¹ True Positive

² True Negative

³ False Positive

⁴ False Negative

⁵ Precision

⁶ Recall


⁷ Receiver Operating Characteristic

کمتر از ۰/۰۴ بوده است (کمتر از ۰/۴). به علاوه شباهت‌های موجود بین نمودارهای ROC ترسیم‌شده برای هر کدام از الگوریتم‌ها در شکل (۶) اثبات می‌کند که تفاوت بسیاری بین کارایی دسته‌بندی‌کننده‌های مختلف آموزش داده‌شده وجود ندارد که این خود نشان‌دهنده کیفیت ویژگی‌های به‌دست‌آمده در عملیات بردارسازی است. به عبارت دیگر نتایج مشابه برای دسته‌بندی‌کننده‌های مختلف در مسأله حاضر اثبات می‌کند که ویژگی‌های با کیفیت در یک مسأله یادگیری ماشین از اهمیت ویژه‌ای برخوردار هستند و تکنیک بردارسازی ارایه شده توانایی استخراج این ویژگی‌ها را دارد. شکل (۷) مقادیر AUC تمام دسته‌بندی‌کننده‌های مورد مطالعه را نشان می‌دهد که همگی دسته‌بندی‌کننده‌های مورد مطالعه مقادیر بیش از ۰/۹۹ دارند و دسته‌بندی‌کننده ساخته‌شده به وسیله Bagging مقدار AUC برابر با ۰/۹۹۵ دارد.


(جدول ۴): عملکرد دسته‌بندی‌کننده‌ها روی مجموعه داده

$VD_{D_{Total}, MC_{Ransomware}}$
(Table-4): Performance classifiers on the $VD_{D_{Total}, MC_{Ransomware}}$ dataset

F-Measure	FPR	TPR	دسته‌بندی‌کننده
0.994	0.040	0.994	J48
0.993	0.040	0.993	Random Forest
0.997	0.039	0.994	Bagging
0.997	0.035	0.994	MLP



(شکل ۶): نمودارهای AUC برای دسته‌بندی‌کننده‌ها
(Figure-6): AUC diagrams of classifiers






(شکل ۷): مقادیر AUC برای دسته‌بندی‌کننده‌ها جهت

شناسایی باج‌افزارها

(Figure-7): AUC values of the classifiers for ransomware detection

به عنوان بهترین ویژگی‌ها انتخاب شدند که توانایی ایجاد بهترین جداسازی بین نمونه‌های مثبت (باج‌افزار) و نمونه‌های منفی (نرم افزارهای بی‌خطر) را داشته‌اند. شکل (۵) نشان‌دهنده هیستوگرام ویژگی R است که مشخص می‌کند باج‌افزارها تمایل بیشتری به استفاده از کلیدهای رجیستری در ده ثانیه نخست اجرایشان داشته‌اند. شکل (۵) نشان می‌دهد بیشتر نرم‌افزارهای بی‌خطر رفتار DLL مشابهی از خود نشان داده‌اند؛ در حالی که برای نمونه‌های باج‌افزار تغییرات بیشتری برای فعالیت‌های DLL مشاهده می‌شود؛ زیرا نمونه‌های بی‌خطر مقدار نرخ پشتیبانی (SR) کمتری نسبت به نمونه‌های باج‌افزار داشته‌اند. شکل (۵) بیان می‌کند که باج‌افزارها تمایل بیشتری در MSP‌های دارای انتقال از فعالیت‌های مرتبط با سیستم فایل به فعالیت‌های مرتبط با DLL‌ها دارند.



(شکل ۵): هیستوگرام‌های به‌دست‌آمده از ویژگی‌های

انتخاب‌شده به وسیله الگوریتم CfsSubsetEval

(SR: نرخ پشتیبانی)

(Figure-5): Obtained histograms from CfsSubsetEval algorithm (SR: Support Ratio)

جدول (۴) نشان‌دهنده مقایسه کارایی دسته‌بندی‌کننده دودویی به‌دست‌آمده روی مجموعه داده $VD_{D_{Total}, MC_{Ransomware}}$ است که فقط سه عدد ویژگی شامل R، D و FD دارد. تمامی الگوریتم‌ها به مقدار F-measure ۰/۹۹ درصد رسیده‌اند؛ درحالی‌که نرخ پیش‌بینی غلط نمونه‌های بی‌خطر برای همه الگوریتم‌ها

نمونه‌های بی‌خطر را به‌عنوان نمونه باج‌افزار شناسایی کرده که مقدار محسوسی در حوزه امنیت و دفاع است.


(جدول ۵): مقایسه بهترین نتیجه روش بردارسازی

با روش EldeRan

(Table-5): Comparison the best result of proposed method with EldeRan approach

F-Measure	FPR	TPR	دسته‌بندی‌کننده
0.997	0.035	0.994	روش پیشنهادی بردارسازی (MLP)
0.980	0.141	0.980	EldeRan

برای نشان دادن اینکه دسته‌بندی‌کننده‌های ساخته‌شده روی داده‌های آزمایش دچار مشکل بیش‌برازش نشده‌اند از دیتاست D_{OF} بهره گرفته شده است که شامل نمونه‌هایی از دنباله هاست که به‌طور کامل برای مدل پیش‌بینی ساخته‌شده جدید و تازه هستند و حتی در فرآیند تولید MSPها توسط الگوریتم MG-FSM نیز شرکت نداشته‌اند. جدول (۶) نشان‌دهنده دقت شناسایی باج‌افزارها روی $VD_{D_{OF}, MC_{Ransomware}}$ می‌باشد که نسخه بُرداری شده D_{OF} است. واضح است که همه دسته‌بندی‌کننده ۹۹/۴ درصد از باج‌افزارهای موجود در D_{OF} را شناسایی کرده‌اند.




(شکل ۹): هیستوگرام‌های ویژگی‌های به‌دست‌آمده از

$VD_{D_{TotalFamily}, MC_{Locky}}$ با الگوریتم

CfsSubsetEval (SR: نرخ پشتیبانی)

(Figure-9): Histograms of obtained features from $VD_{D_{TotalFamily}, MC_{Locky}}$ by using CfsSubsetEval algorithm (SR: Support Ratio)

مقدار MCC در شکل (۸) برای تمامی دسته‌بندی‌کننده‌ها بیشتر از ۰/۹۶ است و Random Forest و Bagging به مقداری نزدیک به ۱+ رسیده‌اند که حکایت از نزدیکی به حالت ایده‌آل پیش‌بینی دارد.



(شکل ۸): مقادیر MCC برای دسته‌بندی‌کننده‌ها جهت

شناسایی باج‌افزارها

(Figure-8): MCC values of the classifiers for ransomware detection

جهت نمایش کارایی روش پیشنهادی با سایر پژوهش‌های انجام‌شده در حوزه شناسایی باج‌افزارها به مقایسه نتایج به‌دست‌آمده از دسته‌بندی‌کننده‌های ساخته‌شده در روش بردارسازی با روش EldeRan پرداخته می‌شود که در سال ۲۰۱۶ پیشنهاد شده است. بر اساس جدول (۴)، جدول (۵) روش MLP بهترین نتایج دسته‌بندی‌کننده دودویی روی ویژگی‌های استخراج‌شده به‌وسیله روش بردارسازی را تولید کرده است که نتایج MLP به‌عنوان بهترین نتیجه در جدول (۴) جهت مقایسه با نتایج به‌دست‌آمده در جدول (۵) درج شده است. نتایج به‌دست‌آمده از اجرای روش EldeRan نیز در جدول (۵) نشان داده شده است.

روش پیشنهادی بردارسازی قصد شناسایی باج‌افزارها در ۱۰ ثانیه نخست اجرای آن‌ها را دارد؛ درحالی‌که روش EldeRan شناسایی را در ۳۰ ثانیه نخست انجام می‌دهد. برای اینکه مقایسه صحیحی بین روش پیشنهادی و روش EldeRan قابل انجام باشد، روش EldeRan روی ۱۰ ثانیه نخست اجرای برنامه‌ها اعمال شده و نتایج به‌دست‌آمده در جدول (۵) نشان داده شده است. همان‌طور که مشخص است روش پیشنهادی بردارسازی مقدار F-Measure بالاتری نسبت به روش EldeRan به‌دست آورده است. هر چند مقادیر F-Measure به‌دست‌آمده نزدیک به یکدیگر هستند؛ اما با بررسی مقادیر FPR مشخص می‌شود که روش EldeRan در صورتی که روی ده ثانیه نخست اعمال شود مقدار FPR بسیار بالاتری نسبت به روش بردارسازی تولید کرده که این به معنای آن است که به‌خوبی توانایی تفکیک نمونه‌های بی‌خطر را ندارد و حدود ۱۴/۱ درصد از

(Table-6): Obtained results of trained classifiers on the unseen dataset

دسته بندی کننده	J48	Random Forest	Bagging	MLP
TPR	0.994	0.994	0.994	0.994


۷- شناسایی خانواده باج افزارها

درواقع شناسایی خانواده باج افزارها دارای اهمیت است؛ زیرا یکی از فعالیت های هوشمندی تهدید به شمار می آید که در آن در کنار شناسایی باج افزار بودن یک برنامه مخرب، هدف کسب اطلاعات بیشتر از جزئیات کارکردی از جمله اینکه باج افزار کشف شده متعلق به چه نوع از خانواده های درقبل ثبت شده است که بتوان از روش های درقبل طراحی شده برای مقابله و بازیابی از حمله استفاده کرد. ممکن است باج افزار از یک خانواده جدید باشد که این امر می تواند نشان دهنده ظهور یک نسل جدید و اعلام هشدارهای جدی جهت آمادگی مقابله را در پی داشته باشد.

برای ارزیابی کارایی دسته بندی کننده ها در شناسایی خانواده باج افزارها ابتدا $D_{TotalFamily}$ ساخته شده که ترکیبی از D_{Locky} ، D_{Cerber} ، $D_{TeslaCrypt}$ و D_{Benign} است و برچسب های نمونه ها به ترتیب D_{Locky} ، D_{Cerber} ، $D_{TeslaCrypt}$ و D_{Benign} تنظیم شده اند.

$VD_{D_{TotalFamily}, MC_{Cerber}}$ ، $VD_{D_{TotalFamily}, MC_{Locky}}$ و $VD_{D_{TotalFamily}, MC_{TeslaCrypt}}$ مجموعه داده های برداری هستند که به صورت جداگانه به الگوریتم انتخاب ویژگی CfsSubsetEval تحویل داده شده اند و در کل ۱۳ ویژگی به عنوان بهترین ویژگی ها در شناسایی و جداسازی خانواده های مختلف باج افزارها و نرم افزارهای بی خطر انتخاب شده اند. شکل های (۸، ۹ و ۱۰) به ترتیب هیستوگرام های ویژگی های انتخابی برای $VD_{D_{TotalFamily}, MC_{Cerber}}$ ، $VD_{D_{TotalFamily}, MC_{Locky}}$ و $VD_{D_{TotalFamily}, MC_{TeslaCrypt}}$ را به تصویر کشیده اند.

با مقایسه شکل ها می توان دریافت که MSP های اتمیک رجیستری (R) از اهمیت ویژه ای در تفکیک باج افزارهای خانواده های مختلف برخوردار است؛ زیرا در هر سه مورد D_{Locky} ، D_{Cerber} و $D_{TeslaCrypt}$ به عنوان یک ویژگی تأثیرگذار وجود دارد. فعالیت های انتقالی از سیستم فایل به DLL (FD) نیز در هر سه شکل به عنوان ویژگی مهم نشان داده شده است.



(شکل-۱۰): هیستوگرام های ویژگی های به دست آمده از

CfsSubsetEval الگوریتم با $VD_{D_{TotalFamily}, MC_{Cerber}}$

(SR: نرخ پشتیبانی)

(Figure-10): Histograms of obtained features from $VD_{D_{TotalFamily}, MC_{Cerber}}$ by using CfsSubsetEval algorithm (SR: Support Ratio)

از آن جا که شناسایی خانواده باج افزارها یک عملیات دسته بندی کننده با چند رده^۱ است هر کدام از نمونه ها دارای یکی از برچسب های D_{Locky} ، D_{Cerber} ، $D_{TeslaCrypt}$ یا D_{Benign} هستند. در انتها J48، Random Forest، Bagging و MLP با استفاده از $SVD_{D_{TotalFamily}}$ و با ۱۳ ویژگی انتخاب شده نهایی آموزش داده شده اند که جدول (۷) نشان دهنده کارایی دسته بندی کننده های مورد نظر در شناسایی خانواده های باج افزارها بر اساس ارزیابی 10-Fold است. F-measure به دست آمده ۰/۹۸۳ با FPR کوچکتر مساوی ۰/۰۰۶ حکایت از مناسب بودن ویژگی های محاسبه شده در شناسایی نمونه های سه نوع خانواده مورد بررسی است. مقادیر MCC بیشتر از ۰/۹۵ به دست آمده برای دسته بندی کننده های مختلف نشان از کیفیت بالای بردارهای ویژگی به دست آمده دارد.

(جدول-۷): نتیجه دسته بندی کننده ها روی دیتاست

 $SVD_{D_{TotalFamily}}$ (Table-7): Results of classifiers on $SVD_{D_{TotalFamily}}$

دسته بندی کننده	TPR	FPR	F-Measure	MCC
J48	0.981	0.006	0.981	0.974
Random Forest	0.983	0.006	0.983	0.978
Bagging	0.980	0.007	0.980	0.974
MLP	0.980	0.007	0.980	0.973

¹ Multi-class Classification


پیشنهاد ادامه کار می‌توان به کاربرد روش‌های خوشه‌بندی در شناسایی و دسته‌بندی خانواده‌های مختلف باج‌افزارها اشاره کرد. باج‌افزارهای قفل‌کننده سیستم نیز می‌تواند مورد مطالعه قرار گیرند هرچند روند رشد و توسعه آن‌ها مانند باج‌افزارهای رمزکننده نیست. روش‌های پیشنهادی این مقاله می‌تواند روی باج‌افزارهای تلفن‌های هوشمند نیز مورد مطالعه قرار گیرند. همچنین با توجه به پیش‌بینی‌ها رشد و تهدید حوزه باج‌افزارها ادامه خواهد داشت و در سال‌های آینده قطعاً به‌عنوان تهدیدی برای دنیای اینترنت اشیا^۲ محسوب خواهد شد که نحوه برخورد با باج‌افزارها جذابیت زیادی برای پژوهش‌گران حوزه امنیت سایبری خواهد داشت. همین‌طور شرکت‌های تولیدکننده ضد بدافزار و حتی پژوهش‌گرانی که قصد مقابله با نسل‌های جدید باج‌افزارها و بدافزارها را دارند، می‌توانند از روش‌های پیشنهادی و نتایج این مقاله بهره ببرند.

9- References

۹- مراجع

- [1] M. Hopkins and A. Dehghantanha, "Exploit Kits: The production line of the Cybercrime economy?," in *2015 2nd International Conference on Information Security and Cyber Forensics*, InfoSec 2015, 2016, pp. 23–27.
- [2] Hosseini F, Mirzarezaee M, Sharifi A, "Malware Detection using Classification of Variable-Length Sequences," *JSDP*, vol. 16 (2), pp.137-146, 2019
- [۲] حسینی فاطمه، میرزازایی میترا، شریفی آر.ش. آشکارسازی بدافزارها با استفاده از دسته‌بندی دنباله‌های با طول متغیر. پردازش علائم و داده‌ها. ۱۳۷-۱۴۶؛ ۱۶(۲)؛ ۱۳۹۸
- [3] Symantec, "Internet Security Threat Report (ISTR)," no. April. p. 10, 2017.
- [4] D. Palmer, "How Bitcoin helped fuel an explosion in ransomware attacks," 2016. [Online]. Available: <http://www.zdnet.com/article/how-bitcoin-helped-fuel-an-explosion-in-ransomware-attacks/>.
- [5] A. Azmoodeh, A. Dehghantanha, M. Conti, and K.-K. R. Choo, "Detecting crypto-ransomware in IoT networks based on energy consumption footprint," *J. Ambient Intell. Humaniz. Comput.*, Aug. 2017.
- [6] R. Richardson and M. M. North, "Ransomware : Evolution , Mitigation and Prevention," *Int. Manag. Rev.*, vol. 13, no. 1, pp. 10–21, Jan. 2017.

² Inter of Things



(شکل-۱۱): هیستوگرام‌های ویژگی‌های به‌دست آمده از

$VDD_{TotalFamily.MCTeslaCrypt}$ با الگوریتم $CfsSubsetEval$

(SR: نرخ پشتیبانی)

(Figure-11): Histograms of obtained features from $VDD_{TotalFamily.MCTeslaCrypt}$ by using $CfsSubsetEval$ algorithm (SR: Support Ratio)

۸- نتیجه‌گیری

این مقاله به‌طور خاص روی شناسایی زود هنگام باج‌افزارها تمرکز داشته است و سعی بر این است تا عملیات شناسایی در بازه زمان تنظیم^۱ باج‌افزارها که به‌طور معمول در ابتدای شروع فعالیت انجام می‌گیرد انجام شود. نکته مهم دیگری که در این مقاله مطرح شده شناسایی خانواده باج‌افزارها با توجه به فعالیت‌های انجام‌شده است که اجرای نمونه‌ها (شامل باج‌افزارها و نمونه‌های بی‌خطر) در فضای بستر آزمایش پیاده‌سازی انجام می‌شود و این بستر توانایی اجرای خودکار برنامه‌ها در محیطی امن را دارد. این امر می‌تواند به خبرگان فضای امنیت سایبری در تحلیل رفتار بدافزارها کمک بسیار زیادی کند که تحت عنوان عملیات هوشمندی تهدید مطرح است. روش بردارسازی پیشنهادشده با ملاحظه دسته‌های فعالیت‌ها از قبیل عملیات سیستم فایل، رجیستری و کار با DLL سعی در پیشنهاد ویژگی‌هایی با کیفیت بالا در دسته‌بندی باج‌افزارها دارد. به دلیل نوظهور بودن بدافزارهای باج‌گیر طبیعتاً جای کار و نوآوری هنوز هم وجود دارد. به‌عنوان

¹ Setup Time

- [19] "What is Apache MapReduce? | IBM." [Online]. Available: <https://www.ibm.com/analytics/hadoop/mapreduce>. [Accessed: 30-May-2019].
- [20] J. A. K. Suykens, "Introduction to Machine Learning," 2014, pp. 765–773.
- [21] M. Sohrabi, M. M. Javidi, and S. Hashemi, "Detecting intrusion transactions in database systems: A novel approach," *J. Intell. Inf. Syst.*, vol. 42, no. 3, pp. 619–644, Jun. 2014.
- [22] S. Boughorbel, F. Jarray, and M. El-Anbari, "Optimal classifier for imbalanced data using Matthews Correlation Coefficient metric," *PLoS One*, vol. 12, no. 6, pp. e0177678, Jun. 2017.
- [23] D. M. W. Powers, "Evaluation: From precision, recall and fmeasure to roc, informedness, markedness and correlation," *J. Mach. Learn. Technol.*, vol. 2, no. 1, pp. 37–63, 2007.
- [24] A. Hall, Mark, "Correlation-based feature selection for machine learning ۱۹۹۹",.
- [7] K. Savage, P. Coogan, and H. Lau, "The Evolution of Ransomware," *Res. Manag.*, vol. 54, no. 5, pp. 59–63, 2015.
- [8] Monika, P. Zavarsky, and D. Lindskog, "Experimental Analysis of Ransomware on Windows and Android Platforms: Evolution and Characterization," in *Procedia Computer Science*, 2016, vol. 94, pp. 465–472.
- [9] E. Kirda, "UNVEIL: A large-scale, automated approach to detecting ransomware (keynote)," in *usenix.org*, 2017, pp. 1–1.
- [10] N. Scaife, H. Carter, P. Traynor, and K. R. B. Butler, "CryptoLock (and Drop It): Stopping Ransomware Attacks on User Data," in *Proceedings - International Conference on Distributed Computing Systems*, 2016, vol. Aug2016, pp. 303–312.
- [11] A. Continella et al., "ShieldFS," in *Proceedings of the 32nd Annual Conference on Computer Security Applications - ACSAC 16*, 2016, pp. 336–347.
- [12] A. Palisse, A. Durand, H. Le Boudier, C. Le Guernic, and J. L. Lanet, "Data aware defense (DaD): Towards a generic and practical ransomware countermeasure," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2017, vol. 10674 LNCS, pp. 192–208.
- [13] D. Sgandurra, L. Muñoz-González, R. Mohsen, and E. C. Lupu, "Automated Dynamic Analysis of Ransomware: Benefits, Limitations and use for Detection," undefined, 2016.
- [14] A. Kharraz and E. Kirda, "Redemption: Real-Time Protection Against Ransomware at End-Hosts," in *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 2017, vol. 10453 LNCS, pp. 98–119.
- [15] Z. He, X. Xu, J. Z. Huang, and S. Deng, "A Frequent Pattern Discovery Method for Outlier Detection," Springer, Berlin, Heidelberg, 2010, pp. 726–732.
- [16] R. Agrawal and R. Srikant, "Mining Sequential Patterns," in *Proceedings of the Eleventh International Conference on Data Engineering*, 1995, pp. 3–14.
- [17] C. H. Mooney and J. F. Roddick, "Sequential pattern mining -- approaches and algorithms," *ACM Comput. Surv.*, vol. 45, no. 2, pp. 1–39, Feb. 2013.
- [18] Andrej Karpathy, "The Unreasonable Effectiveness of Recurrent Neural Networks," 2015. [Online]. Available: <http://karpathy.github.io/2015/05/21/rnn-effectiveness/>. [Accessed: 30-May-2019].



حمید دارابی، در سال ۱۳۹۳ مدرک

کارشناسی در رشته مهندسی مهندسی

فناوری اطلاعات از دانشگاه صنعتی

شیراز و در سال ۱۳۹۷ مدرک

کارشناسی ارشد خود را در رشته

مهندسی فناوری اطلاعات-امنیت اطلاعات از دانشگاه

شیراز دریافت کرد. زمینه‌های پژوهشی مورد علاقه ایشان

امنیت فضای سایبری، رمزنگاری، کاربرد یادگیری ماشین

و یادگیری عمیق در امنیت سیستم‌ها و شبکه‌های

کامپیوتری است.

نشانی رایانامه ایشان عبارت است از:

h.darabian@cse.shirazu.ac.ir



ستار هاشمی، در سال ۱۳۷۷ مدرک

کارشناسی در رشته مهندسی کامپیوتر-

سخت‌افزار از دانشگاه صنعتی اصفهان و

در سال ۱۳۸۰ مدرک کارشناسی ارشد

خود را در رشته مهندسی کامپیوتر-

هوش مصنوعی از دانشگاه علم و صنعت ایران و همچنین

مدرک دکترای خود را در رشته مهندسی کامپیوتر-هوش

مصنوعی از دانشگاه علم و صنعت و موناخ استرالیا

دریافت کرد. وی هم‌اکنون عضو هیئت علمی و دانشیار

دانشگاه شیراز و زمینه‌های پژوهشی مورد علاقه ایشان

یادگیری ماشین، داده‌کاوی، نظریه بازی‌ها و امنیت سایبری است.

نشانی رایانامه ایشان عبارت است از:

s_hashemi@shirazu.ac.ir



سجاد همایون، در سال ۱۳۹۶ از

پایان‌نامه خود روی موضوع شناسایی باج

افزارها با بهره‌گیری از تکنیک‌های مبتنی

بر یادگیری ماشین و یادگیری عمیق در

دانشگاه صنعتی شیراز دفاع کرده است.

از ایشان تاکنون مقالات متعددی در مجلات و همایش‌های

معتبر داخلی و خارجی را به چاپ رسیده است. زمینه‌های

پژوهشی ایشان امنیت فضای سایبری و کاربرد یادگیری

ماشین و یادگیری عمیق در امنیت سیستم‌ها و شبکه‌های

کامپیوتری است.

نشانی رایانامه ایشان عبارت است از:

s.homayoun@sutech.ac.ir



کرم الله باقری فرد، در سال ۱۳۸۴

مدرک کارشناسی در رشته مهندسی

کامپیوتر از دانشگاه اصفهان و در سال

۱۳۸۷ مدرک کارشناسی ارشد خود را در

رشته مهندسی کامپیوتر- نرم افزار را دریافت کرد. ایشان

مدرک دکترای خود را در سال ۱۳۹۶ در گرایش نرم افزار

در دانشگاه اراک به اتمام رساند. زمینه‌های پژوهشی مورد

علاقه ایشان یادگیری ماشین، داده‌کاوی و سیستم‌های

پیشنهاددهنده است.

نشانی رایانامه ایشان عبارت است از:

k.bagheri@iauyasooj.ac.ir

