Prosiding
ANNUAL RESEARCH SEMINAR 2016
6 Desember 2016, Vol 2 No. 1

ISBN : 979-587-626-0 | UNSRI http://ars.ilkom.unsri.ac.id

Klasifikasi Malware Trojan Ransomware Dengan Algoritma Support Vector Machine (SVM)

Erick Lamdompak S
Sistem Komputer, Fakultas Ilmu Komputer
Universitas Sriwijaya
Palembang, Indonesia
ericklamdompak@gmail.com

Abstrak— Identifikasi dari file malware itu sendiri merupakan proses yang kompleks, yang melibatkan ektraksi ciri khas dari satu sampel dataset malware. Dataset normal file dan dataset malware Trojan ransomware diperiksa menggunakan pola opcode n-gram yang diekstrak dari file setelah pembongkaran. Opcode pola n-gram digunakan sebagai fitur untuk proses klasifikasi. Penellitian yang dilakukan dalam makalah ini adalah melakukan training untuk normal file sebagai pembanding dengan file Trojan ransomware yang di deteksi menggunakan fitur ekstraksi N-grams. Hasil dari analisis sementara proses training dan deteksi malware harus di dukung dengan metode klasifikasi yang akurat dan efisien. Hasil dari penelituan ini menunjukkan bahwa Support vector Machine (SVM) adalah metode yang kuat dan akurat untuk penyelesaian klasifikasi malware Trojan Ransomware dan normal file.

Kata kunci— Trojan Ransomware, klasifikasi malware, N-grams, Supprot Vector Machine.

I. PENDAHULUAN

Trojan Ransomware merupakan salah satu jenis *malware* yang paling berbahaya dan paling dibenci olah para pengguna komputer, dikarenakan Trojan Ransomware ini menggunakan kode berbahaya untuk menggangu sistem sebelum pengguna menyadarinya, dapat mengenkripsi file penting seseorang dan meminta nya untuk membayar ke pada si penyerang agar file itu bisa di gunakan lagi oleh penggunanya hingga merusak seluruh *hard drive* pengguna tersebut[1]. Terdapat sepuluh malware yang paling terpopuler di tahun 2015 adalah *Trojan Ransomware, Exploit kits, Banking Trojans, worms, PoS (Point-of-Sale) Malware, Social Engineering Attacks, Fake Tech Support Services, Rogue Antivirus Software, Potentially Unwanted Programs,* dan *Adware*[5].

Teknik analisis dalam pendeteksian malware umumnya diklasifikasikan menjadi pendekatan dinamis dan statis. Dalam analisis dinamis dikenal sebagai analisis perilaku sedangkan dalam analisis statis, informasi mengenai program atau perilaku yang yang diharapkan dalam kode biner [2]. *Support Vector Machine* adalah suatu teknik untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi dalam analisis dinamis maupun statis[3]. SVM memiliki prinsip dasar *linier classifier* yaitu kasus klasifikasi yang secara linier dapat dipisahkan, namun SVM telah dikembangkan agar dapat bekerja pada problem non-linier dengan memasukkan konsep kernel pada ruang kerja berdimensi tinggi[4]

Tujuan dari penelitian ini adalah menggunakan *Support Vector Machine* untuk klasifikasi malware dan normal file sebagai pembanding yang di dapat dari dataset *malware* dan dataset file normal. Dilakukannya pengklasifikasian setiap sampel data kedalam salah satu dari dua kategori yaitu kelas positif yang dilambangkan dengan 1 sebagai data normal dan kelas negatif dilambangkan dengan -1 sebagai data berbahaya (*malware*) yang dipisahkan dengan garis *hyperlane. Malware* dapat dideteksi dengan menggunakan fitur N-grams pola sequensial yang digunakan setelah melakukan pembongkaran file *malware* dalam dataset.

II. GAMBARAN KERJA

Pada penelitian [6] membahas bagaimana banyak nya data yang sangat beragam (*heterogeneous data*) yang dianggap sebagai data ancaman dari internet. Penelitian ini menggunakan *Support Vector Machine* untuk klasifikasi *heterogeneous data* atau data yang beragam dengan mengklasifikasikan setiap sampel data ke dalam salah satu dari dua kategori: kelas positif dilambangkan dengan "1" (data normal) dan kelas negatif dilambangkan dengan "-1" (data berbahaya).

ISBN : 979-587-626-0 | UNSRI http://ars.ilkom.unsri.ac.id

Pada penelitian lain [7] membahas bagaimana SVM digunakan dalam melakukan identifikasi *malware* yang dapat di deteksi dengan menggunakan *Support Vector Machine* (SVM) dan kode operasional yang terdapat pada *malware* (opcodes), yang menunjukan bahwa (`ja, adc, sub, inc, add, mov and rep`) adalah indikator kuat *malware* yang memberikan dasar untuk peningkatan teknik mendeteksi *malware* di beberapa negara. Dan pada penelitian ini juga membahas bagaimana tahap identifikasi penyaringan menggunakan fitur penyaringan *vector eigen* atau (*eigen vector'prefilter*).

Pada penelitian lainnya [8] membahas bagaimana proses pencegahan identifikasi karakteristik unik dari program *malware* seperti enkripsi dan pola kebingungan. Pada penelitian ini menggunakan N-grams sebagai fitur sequential setelah proses dataset *malware* di bongkar untuk mendapatkan pola dari keluarga *malware*. Teknik klasifikasi yang di gunakan ada 3 yaitu: Decision tree (C4.5), ANN dan SVM untuk menentukan metode manakah yang memiliki tingkat akurasi yang paling tinggi.

III. METODOLOGI

Penelitian ini berfokus pada klasifikasi *malware* dengan beberapa fitur pilihan yang digunakan untuk mewakili setiap sampel malware dalam pengklasifikasian. Perancanngan sistem penelitian ini terdapat pada gambar 1 berikut:

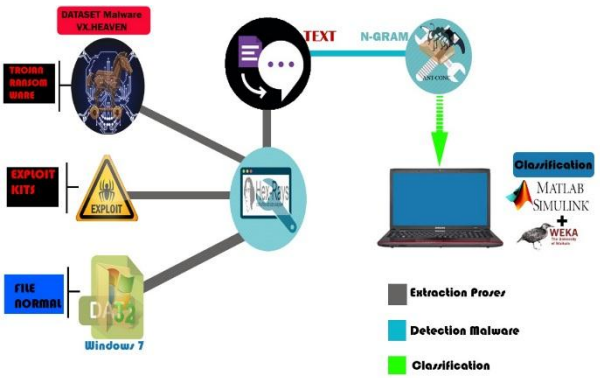

Gambar 1. Perancangan sistem penelitian

Penelitian ini hanya menggunakan 1 perangkat fisik yang difungksikan untuk pengolahan data menggunakan matlab+weka sebagai media klasifikasi dan IDA pro[18] dan N-grams menggunakan knfgram[19] dan Ant conc [20] sebagai diassemble file dan ektraski.

A. *Diassemble File*

Interactive Disassembler (IDA) Pro adalah diassembler untuk software komputer yang menghasilkan kode operasional bahasa *assembly* dari kode mesin *executable* atau biasanya kita sebut .exe [28].

Berikut hasil dari *Diassemble file* pada dataset *malware Trojan* Ransomware dan normal file:

1. Normal set Representation

```
.rdata:0040B940  20 54 68 69 73 20 61 70  70 6C 69 63 61 74
69 6F
.rdata:0040B950  6E 20 63 61 6E 6E 6F 74  20 72 75 6E 20 75
        73 69
.rdata:0040B960  6E 67 20 74 68 65 20 61  63 74 69 76 65 20
        76 65
.rdata:0040B970  72 73 69 6F 6E 20 6F 66  20 74 68 65 20 4D
        69 63
.rdata:0040B980  72 6F 73 6F 66 74 20 2E  4E 45 54 20 52 75
        6E 74
.rdata:0040B990  69 6D 65 0A 50 6C 65 61  73 65 20 63 6F 6E
        74 61
```

Gambar 2. Tampilan Hexa normal file

```
mov     edi, edi
push    ebp
mov     ebp, esp
sub     esp, 14h
push    esi
push    edi
xor     edi, edi
mov     [ebp+dwRegister], edi
mov     [ebp+var_14], edi
mov     [ebp+dwMilliseconds], 0BB8h
mov     esi, offset unk_1014458
push    esi
call    sub_10030A7
```

Gambar 3. Tampilan *assembly* normal file

Dari gambar 3 dapat dijelaskan bahwa hasil dari training file normal menghasilkan kode operasional yang sangat berbeda dengan hasil dari malware Trojan Ransomware yang telah dibongkar. Perbedaannya sangat signifikan dilihat dari kode operasional yang berbeda pada hasil assembly di file normal.

2. Malware Representation

```
HEADER:00400040  BA 10 00 0E 1F B4 09 CD  21 B8 01
        4C CD 21 90 90
HEADER:00400050  54 68 69 73 20 70 72 6F  67 72 61
        6D 20 6D 75 73
```

Prosiding
ANNUAL RESEARCH SEMINAR 2016
6 Desember 2016, Vol 2 No. 1

ISBN : 979-587-626-0 | UNSRI http://ars.ilkom.unsri.ac.id

```
HEADER:00400060  74 20 62 65 20 72 75 6E  20 75 6E
        64 65 72 20 57
HEADER:00400070  69 6E 33 32 0D 0A 24 37  00 00 00
        00 00 00 00 00
```

Gambar 4. Tampilan *hexa malware Trojan ransomware*

```
push    ebx
mov     eax, [ebp+nCmdShow]
push    esi
mov     dword_40C04C, eax
push    edi
xor     edi, edi
mov     [ebp+var_2], di
cmp     [ebp+arg_4], edi
jnz     short loc_401090
mov     [ebp+var_54.cbClsExtra], edi
mov     esi, [ebp+hInstance]
push    offset IconName ; "SC"
push    esi             ; hInstance
mov     [ebp+var_54.hInstance], esi
mov     [ebp+var_54.cbSize], 30h
mov     [ebp+var_54.lpfnWndProc], offset sub_40175F
mov     [ebp+var_54.cbWndExtra], 1Eh
mov     ecx,0A6Bh
mov     [ebp+var_54.lpszClassName], offset AppName ;
       "SciCalc"
lea     eax, [ebp+var_54]
push    eax             ; WNDCLASSEXA *
call    ds:RegisterClassExA
test    ax, ax
jnz     short loc_401093
jmp     loc_401372
```

Gambar 5. Tampilan *Assembly malware Trojan*

Dari gambar 5 diatas dapat dijelaskan bagaimana perbedaan konten dalam malware dan normal file yang hanya di jumpai dalam file *malware* saja, sebagai berikut:

1. Pada gambar di atas kode xor yang di gunakan adalah (`xor edi, edi`) yang merupakan bagian dari proses *decrypt virus malware Trojan* yang sudah di deklarasikan pada bagian awal *script.*
2. kode operasional pada *Trojan Ransomware* di gambar 5 yaitu: `cmp [ebp+arg_4], edi`, kode operasional tersebut membandingkan kode ebp dengan edi dan akan memverifikasi kode manakah yang akan diteruskan untuk ke sesi berikutnya pada proses malware dijalankan.
3. `Kode mov ecx,0A6Bh` kode operasional ini merupakan panjang dari bagian badan atau *body script* enkripsi dan fungsi dari kode tersebut merupakan bagian dari proses enckripsi file yang akan diserang oleh malware Trojan Ransomware.
4. Pada kode operasional Trojan ransomware di gambar 5 letak kode jnz dan jmp setelah kode operasional `test ax,ax`. `jnz short loc 401093, jmp loc 401372` kode ini dapat diartikan bahwa jika lokasi tujuan tidak sesuai, kode berikut nya akan pindah ke lokasi yang akan di set sebagai breakpoint dan akan meneruskan ke kode berikutnya.

B. *Feature Extraction*

1. *N-gram Extraction*

Setelah file di ekstrak ke dalam sebuah string panjang *hexadecimal* dan *assembly* menggunakan IDA pro, kemudian string diolah menjadi satu set tumpang tindih dengan N-grams. Manfaat dari menggunakan n-gram adalah bahwa hal itu dapat menangkap frekuensi kata-kata yang memiliki panjang n-gram [21]. Banyak penelitian ke dalam fitur n-gram telah menyarankan 4-gram untuk menjadi yang terbaik[8].

Dalam penelitian ini digunakan fitur n-gram dengan *range* n = 1, n = 2, n = 3 dan n = 4. Dan hasil dari fitur N-gram ini dapat di lihat pada tabel berikut:

No	Freq	N-grams =1	No	Freq	N-grams = 2
1	24	Ebp	1	15	Ebp var
2	19	Mov	2	11	Mov ebp
3	17	Var	3	5	Eax ebp
4	15	eax	4	4	Call sub
5	11	push	5	4	Dword ptr
6	8	ptr	6	4	Mov eax
7	8	sub	7	3	Eax mov
8	7	edi	8	3	Edi mov
9	6	esp	9	3	Push eax
10	6	pop	10	3	Var push

Tabel 1. Hasil N-gram Extraction

Setelah file berhasil dibongkar dan di ekstraksi dan menghasilkan kode operasional (*opcodes*), N-grams digunakan untuk mengurutkan hasil ekstraksi kode opersional yang muncul dalam file Trojan Ransomware dan File Normal dengan mengabaikan lokasi, memory, dan register. Contoh:

ISBN : 979-587-626-0 | UNSRI http://ars.ilkom.unsri.ac.id

`mov dword 40C04C, eax` akan di normalisasikan dengan mengurutkan kode operasional mov saja berdasarkan frekuensi banyaknya mov muncul di file *Trojan Ransomware* dan File normal , tetapi pengabaian lokasi, memeory dan register ini hanya berlaku jika N-gram menggunakan range n=1.

C. Classification

Klasifikasi adalah proses dimana klasifier (user yang melakukan pengklasifikasian) belajar dari data sampel yang telah di beri label, data tersebut digunakan untuk pengujian sampel data. Setiap contoh malware di dalam dataset nilai satu target dan beberapa atribut, proses keseluruhan dari klasifikasi ini melibatkan penggunaan metode mesin belajar (*machine learning*) untuk hasil klasfikasi file yang tidak diketahui, apakah jinak atau berbahaya.

Metode atau teknik dalam pengklassifikasian adalah *Support Vector Machine*, SVM merupakan teknik pembelajaran yang cocok untuk memecahkan masalah klasifikasi dengan ruang fitur dimensi tinggi, SVM adalah teknik yang digunakan untuk data klasifikasi dan dikategorikan sebagai metode kernel.

1. Support Vector Machine

Dalam penelitian ini menggunakan implementasi LIBSVM dengan fungsi kernel polinomial untuk melatih SVM walaupun tetap menggunakan teknik dasar digunakan untuk klasifikasi biner. selama fase pelatihan, algoritma memperoleh pengetahuan tentang kelas dengan memeriksa training set yang menggambarkan dataset tersebut. Selama fase pengujian, mekanisme klasifikasi meneliti data set dan sekumpulan angggota nya untuk kelas yang tersedia. Target dari algoritma ini adalah estimasi batas antara kelas.

Dataset *Trojan ransomware* terdiri dari 149 *opcodes* yang berbeda, dan masing-masing memiliki karakteristik distribusi yang unik, karena itu SVM adalah pilihan yang tepat untuk melakukan klasifikasi

IV. DATASET

A. Dataset Malware VX Heavens Virus Collection

Dataset yang digunakan dalam penelitian ini adalah *VX Heavens Virus Collection database* [27] yang memiliki bermacam-macam jenis *malware dan virus* yang telah di kelompokkan dalam tabel berikut:

Malware Class	***Malware Type***
Trojan	*Banker, Clicker, DDoS, Downloader, Dropper, GameThief, IM, Mailfinder, Notifier, PSW, Proxy, Ransomware, SMS, Spy, Win32.*
Exploit	*Exploit.DOS, Exploit.HTA.Behind, IRC, HTML, Exploit.IIS.Beavuh, JS,Java,Linux, MSPPoint, MSWord, Exploit.Mac.Small, Exploit.Multi.Qtp, Exploit.MySQL.Privilege, PHP, Perl, Python, SWF, Shell, SunOS, Unix, VBS, Win16, Win32*
Flooder	*Flooder. DOS.Code, IRC, Java, Linux, Flooder.PHP.MailSpam, Flooder.Unix.MailSpam, Win16,Win32, Email-Flooder.BAT.Prob, Email-Flooder.DOS.Bombing, Email-Flooder.JS.Viv, Perl, IM-Flooder, SMS-Flooder*
Constructor	*BAT, MSIL, HTML, DoS, Perl, MSWord, Script, VBS, Win16, Win32*
Backdoor	*ASP, BAT, IRC, Java, Linux, MSIL, PHP, Perl, Python, SunOS, Unix, VBS, Win16, Win32*
Virus	*ABAP, ALS, ALS, Acad, AmiPro, BAS, BAT, Boot-DOS, Boot, CSC, DOS, DOS32, Ferite, HTML, JS, Java, Linux, Lua, MSAccess, MSExcel, MSH, MSIL, MSOffice, MSPPoint, MSProject, MSVisio, MSWord, Mac, Matlab, Menuet, Multi, OS2, PHP, Perl, Python, QNX, Ruby, SGold, Script, StarOffice, TSQL, Unix, VBS, WBS, Win16, Win32, Win64, Win9x, WinHLP, WinINF, WinREG*
Worm	*FreeBSD, Email-Worm, IM-Worm, IRC-Worm, Net-Worm, P2P-Worm*

Tabel 2. *Malware Class pada VX Heaven Virus Collection Dataset*

B. Dataset Opcodes (Operational Codes)

Kode operasional (*Opcodes*) adalah instruksi bahasa mesin yang melakukan operasi CPU pada operan seperti aritmatika, manipulasi memori / data, operasi logis dan Program *flow control* [7].

Opcode Class	**Opcodes Type**
Arithmetic operations	*add, adc (add* dengan tambahan

ISBN : 979-587-626-0 | UNSRI http://ars.ilkom.unsri.ac.id

	flag), inc, sub,cmp ,dec, div, idiv, imul
Memory manipulation	*lea (load effective address), mov, pop, push,(* memasukan nilai dari *Operand* ke dalam *Stack)*
Logical operations	*xor (exclusive or), and, or*
Program flow control	*call (jump to a function), ret (re-turn from function) cmp (compare data), ja, je, jmp (jump if a condition is met)*

Tabel 3. Opcodes (kode Operasional di dalam malware

C. Registers

Sebelum mengetahui tentang kode operasional *assembly* yang paling dasar, terlebih dahulu harus akrab dengan register IA-32 bit. Pada umumnya dalam IA-32 bit ada 8 register umum[29] yaitu: `EAX`, `EBX`, `ECX`, `EDX`, `ESI`, `EDI`, `EBP`, dan `ESP`. Diluar register umum tersebut, arsitektur juga mendukung *floating point register* dan *register* lainnya diluar 8 register tersebut yang melayani tingkat kebutuhan dari sistem yang digunakan.

V. HASIL SEMENTARA

A. Trace Dataset

Berikut hasil trace pada file Trojan Ransomware dalam file zakk.a dan normal file mcbuilder.exe:

Gambar 6. Hasil *trace Trojan Ransomware* pada *thread*

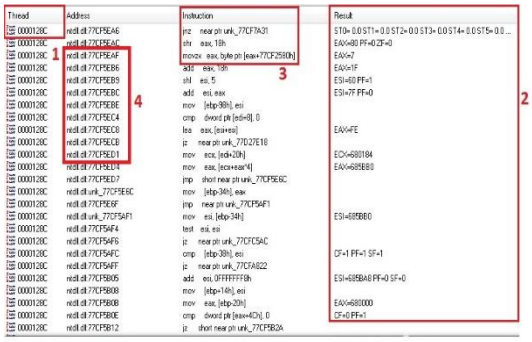

0000128C

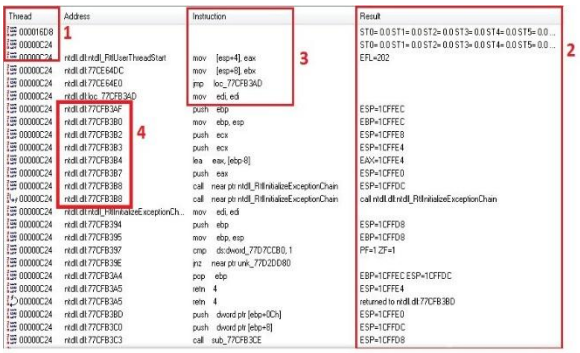

Gambar 7. Hasil *trace* pada normal file pada 2 *thread*

Hasil dari trace dataset malware dan normal file dilakukan perbandingan dalam bentuk grafik sebagai berikut:

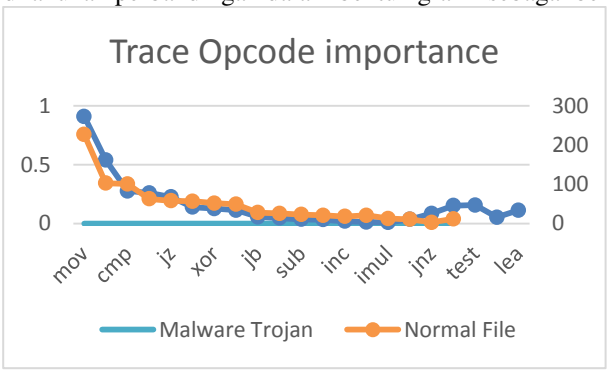

Gambar 7. Perbandingan kode operasional pada *trace file*

Grafik diatas merupakan hasil dari kode operasional (opcodes) yang di peroleh dari proses trace yang dilakukan pada normal file dan Trojan malware. Dapat kita liat letak perbedaan yang signifikan dari jumlah kode operasional yang berada di file Trojan dan normal. Mov, Push dan cmp merupakan kode operasional yang paling sering muncul di antara kedua file, tetapi yang paling membedakan adalah pada kode operasioanl test dan lea yang tidak tedapat pada file normal.

B. Pengujian Data menggunakaan Support Vector Machine

Pengujian data yang diperoleh dari hasil N-gram Extraction dan terlihat perbedaan dari segi frekuensi nya yang dapat di tampilkan pada hasil klasifikasi berikut:

ISBN : 979-587-626-0 | UNSRI http://ars.ilkom.unsri.ac.id

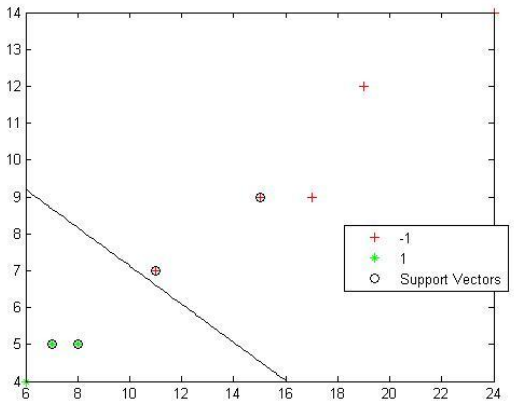

Gambar 8. Hasil klasifikasi dengan SVM

Dari hasil klasifikasi di atas terlihat bahwa malware dan normal file terpisah bersadarkan garis hyperlane yang berada di tengah, dan malware dilambangkan dengan -1 yang berwarnah merah sedangkan normal file dengan 1 yang berwarnah hijau.

VI. KESIMPULAN SEMENTARA

Adapun kesimpulan sementara yang didapatkan dari penelitian ini adalah sebagai berikut:

1. N-grams dapat mendeteksi malware yang di ektraks berdasarkan kode operasional yang sering muncul.
2. Algoritma Support Vector Machine menghasilkan klasifikasi antara Malware dengan Normal file yang di pisahkan berdasarkan garis Hyperlane.
   Malware dan normal file di klasfikasikan berdasarkan kelas -1 untuk malware dan 1 untuk normal file.

REFERENSI

[1] X. Luo and Q. Liao, “Ransomware : a new cyber hijacking threat to enterprises,” in Handbook of Research on Information Security and Assurance, IGI Global, 2009.

[2] Rieck, K., Holz, T., Willems, C., Düssel, P., & Laskov, P. (2008). Learning and classification of malware behavior. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, *5137 LNCS*, 108–125. https://doi.org/10.1007/978-3-540-70542-0_6

[3] Octaviani, P. A., Yuciana Wilandari, & Ispriyanti, D. (2014). Penerapan Metode Klasifikasi Support Vector Machine (SVM) pada Data Akreditasi Sekolah Dasar (SD) di Kabupaten Magelang. *Jurnal Gaussian - Issn: 2339-2541*, *3*(8), 811–820. Retrieved from http://ejournal-s1.undip.ac.id/index.php/gaussian

[4] Noorniawati, V. Y. (2007). Metode Support Vector Machine untuk Klasifikasi pada Sistem Temu Kembali Citra, 64103034–64103034.

[5] CFOC.ORG. (2016). Top 10 Malware Attacks Retrieved from http://cfoc.org/top-10-malware-attacks-of-2015/

[6] Kruczkowski, M., & Szynkiewicz, E. N. (2014). Support Vector Machine for Malware Analysis and Classification. *2014 IEEE/WIC/ACM International Joint Conferences on Web Intelligence (WI) and Intelligent Agent Technologies (IAT)*, 415–420. http://doi.org/10.1109/WI-IAT.2014.127

[7] O’Kane, P., Sezer, S., McLaughlin, K., & Im, E. G. (2013). SVM Training phase reduction using dataset feature filtering for malware detection. *IEEE Transactions on Information Forensics and Security*, *8*(3), 500–509. https://doi.org/10.1109/TIFS.2013.2242890

[8] Liangboonprakong, C., & Sornil, O. (2013). Classification of malware families based on N-grams sequential pattern features. *Proceedings of the 2013 IEEE 8th Conference on Industrial Electronics and Applications, ICIEA 2013*, 777–782. http://doi.org/10.1109/ICIEA.2013.6566472

[18] IDA Support: Download Center. (n.d.). Retrieved from https://www.hex-rays.com/products/ida/support/download.shtml

[19] Knfgram. (n.d.). Retrieved from http://www.kwicfinder.com/kfNgram/kfNgramHelp.html

[20] Ant Conc. (n.d.). Retrieved from http://www.laurenceanthony.net/software/antconc/

[21] Jain, S., & Meena, Y. K. (2011). Computer Networks and Intelligent Computing: 5th International Conference on Information Processing, ICIP 2011, Bangalore, India, August 5-7, 2011. Proceedings. *Computer Networks and Intelligent Computing*, 51–59. http://doi.org/10.1007/978-3-642-22786-8_6

[27] Heaven, V. (n.d.). Computer Virus Collection. Retrieved from http://vxheaven.org/vl.php

[29] M. Christodorescu, S. Jha, S. Seshia, D. Song, and R. Bryant. Semantics-aware malware detection. In Security and Privacy, 2005 IEEE Symposium on, pages 32–46, May 2005.