



Analiza efektywności wybranych metod grafowego uczenia maszynowego do detekcji złośliwego oprogramowania

Opiekun pracy: dr hab. inż. Zbigniew Tarapata, prof. WAT
Autor: mgr inż. Jan Romańczuk



Przegląd

- Wykonanie przeglądu metod *GML*
- Wykonanie przeglądu metod *GML* do detekcji złośliwego oprogramowania
- Zdefiniowanie miar oceny klasyfikatorów złośliwego oprogramowania

Klasyfikacja

- Wybór innowacyjnych i interesujących metod grafowego uczenia maszynowego do detekcji złośliwego oprogramowania z uzasadnieniem

Implementacja

- Zaproponowanie i teoretyczny opis usprawnień wybranej metody *GML* do detekcji złośliwego oprogramowania
- Implementacja wybranych metod *GML* do tego celu

Opracowanie

- Badanie własności zaimplementowanych metod z wykorzystaniem zdefiniowanych miar oceny na zbiorze danych testowych

Cele nadrzędne

Rozbudowanie programu badawczego z przestudiowanego

artykułu (A. Oliveira i R. J. Sassi, „Behavioral Malware Detection Using Deep Graph Convolutional Neural Networks,” *International Journal of Computer Applications* 174/29, 2021)

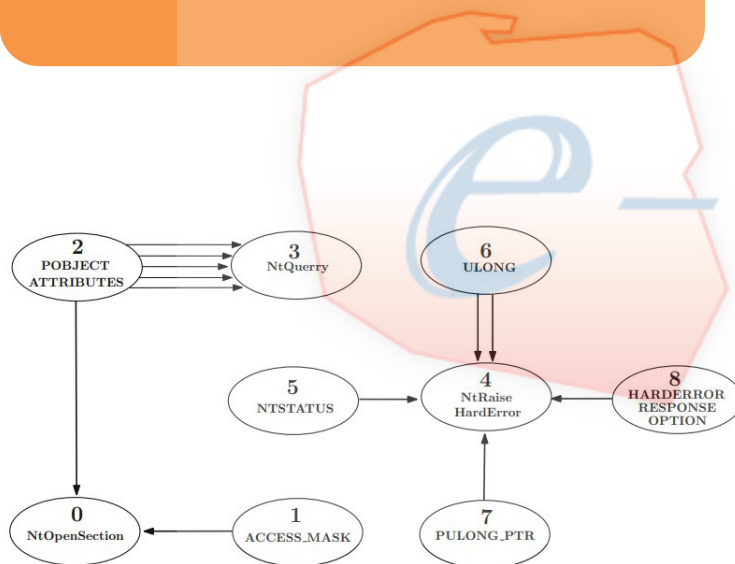
Implementacja nowych modeli realizujących zaproponowane usprawnienia na podstawie pierwotnego programu

Analiza porównawcza zaimplementowanych modeli

Przeszukiwanie bazy danych zaklasyfikowanych już próbek w postaci diagramów *CFG* (ang. *Control Flow Graph* – graf przepływu sterowania)



Porównywanie próbek zaklasyfikowanych z próbką badaną następuje poprzez wyznaczenie odległości edycji grafu (*Graph Edit Distance*).

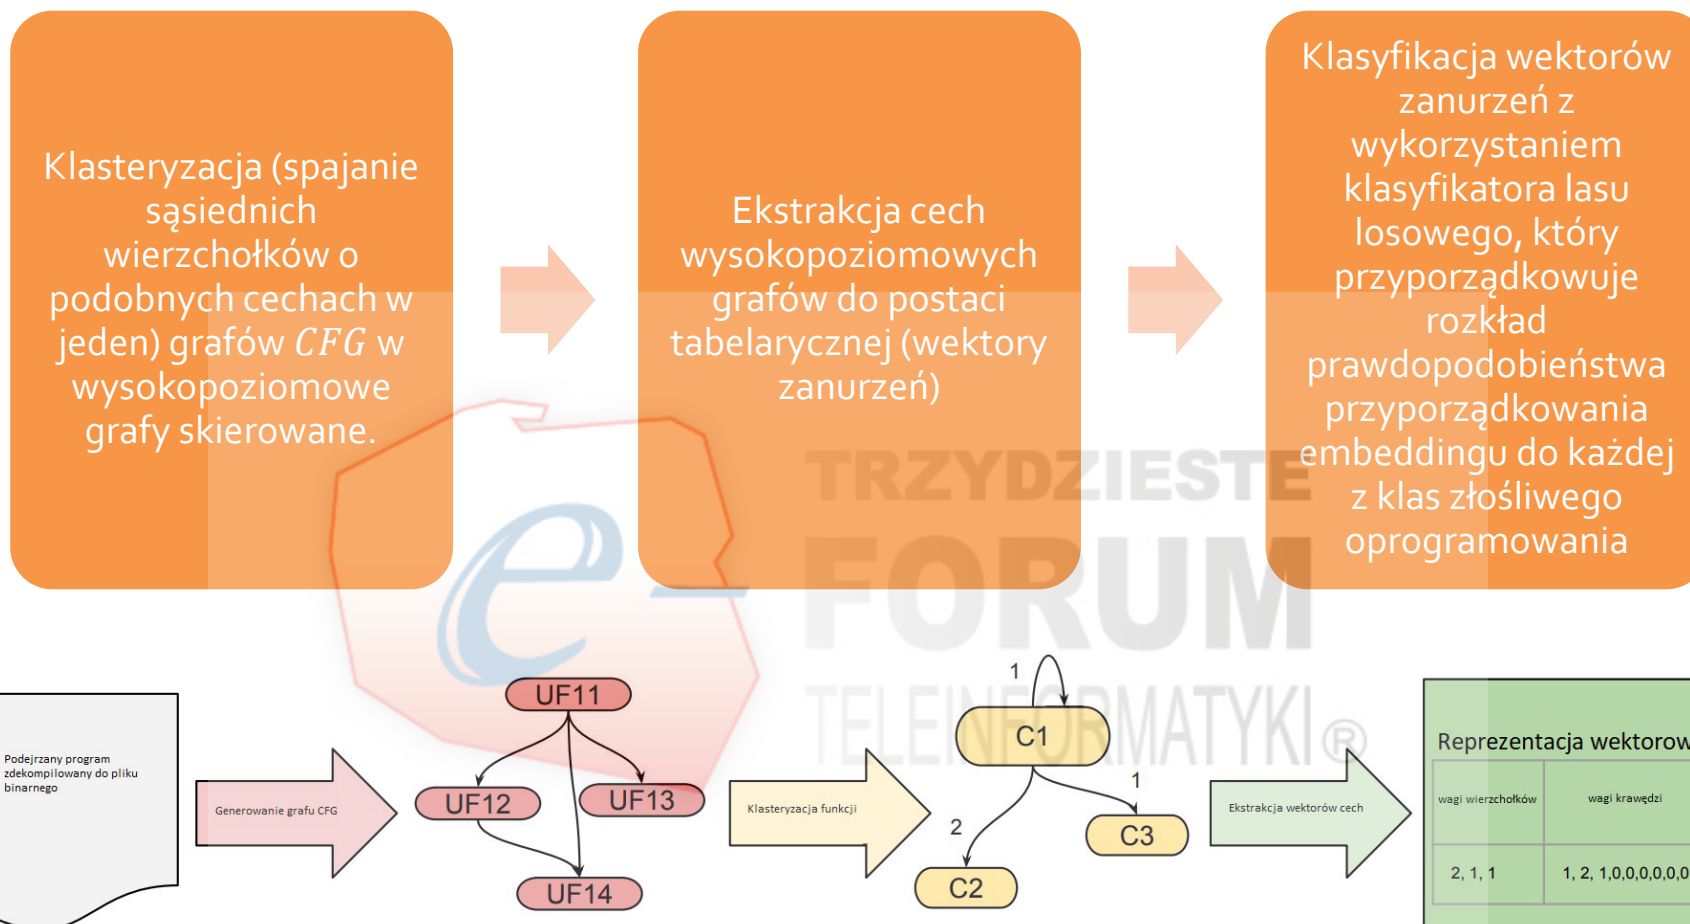


Przykładowy graf wywołań funkcji systemowych podejrzanego programu. Może być określony jako wysokopoziomowy *CFG*

Źródło:

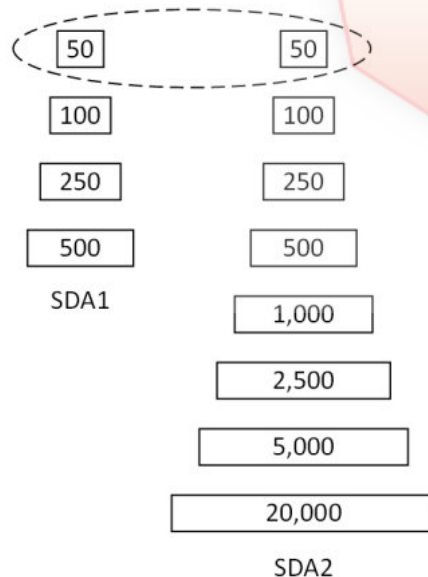

„Nikolopoulos S., Polenakis I., “A graph-based model for malware detection and classification using system-call groups”, Journal of Computer Virology and Hacking Techniques, Volume 13, pages 29–46, (2017).”

Źródło rysunku: „Hu X., Chiueh T., Shin K., „Large-Scale Malware Indexing Using Function-Call Graphs” Proceedings of the 16th ACM conference on Computer and communications security, pp. 611–620, (2009).”

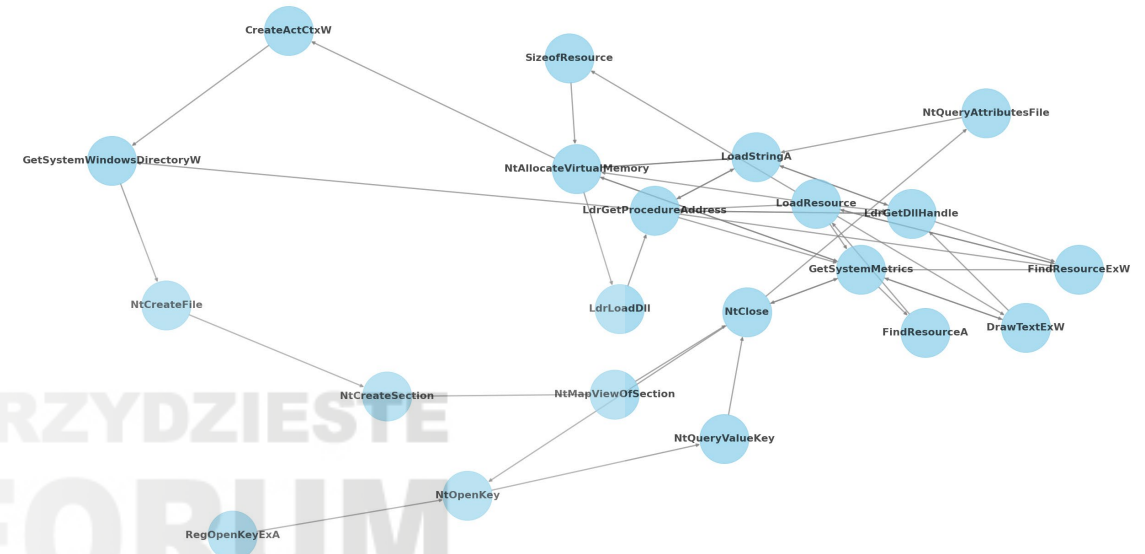
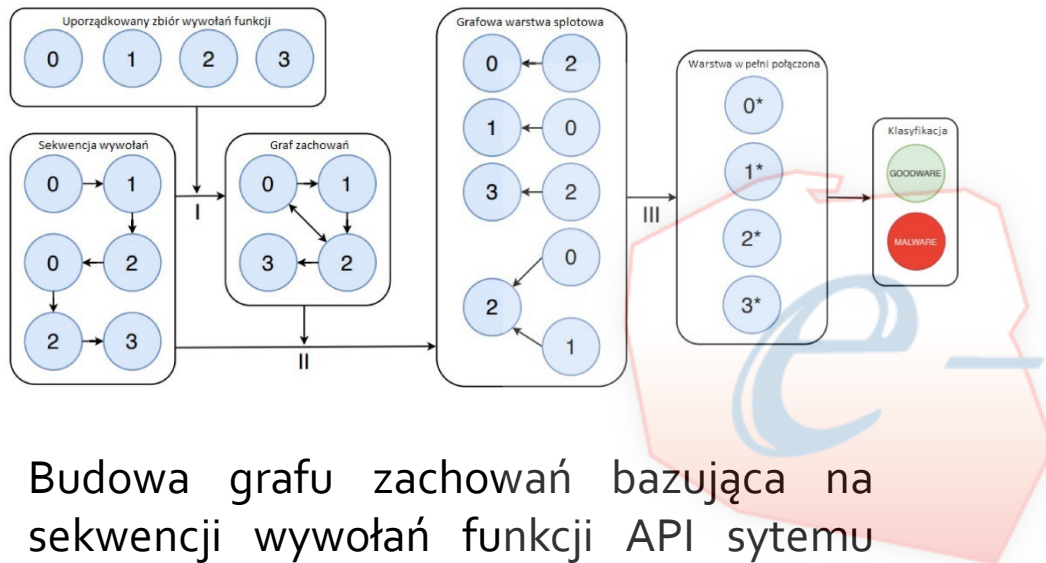


Ciąg przetwarzania cech funkcji wywoływanych przez podejrzanę oprogramowanie

Źródło: „Hassen M., Chan P., „Scalable Function Call Graph-based Malware Classification”, Proceedings of the 7th ACM Conference on Data and Application Security and Privacy, pp. 239-248, (2017).”



Podwójna architektura autoenkoderów SDA. SDA1 przyjmuje na wejście znormalizowaną poprzez *node2vec* reprezentację grafu CFG wywołań API, SDA2 natomiast na wejściu przyjmuje rzadki wektor zastosowań odpowiednich metod z API Windowsa w podejrzanym programie.



Budowa grafu zachowań bazująca na sekwencji wywołań funkcji API systemu operacyjnego

Przykładowy graf zachowań wirusa na system Windows zbudowany na podstawie danych uczących rozbudowywanego programu badawczego

Źródło: A. Oliveira i R. J. Sassi, „Behavioral Malware Detection Using Deep Graph Convolutional Neural Networks,” International Journal of Computer Applications 174/29, 2021.

Źródło: Opracowanie własne

Wykorzystanie lepszej normalizacji macierzy sąsiedztwa

$$S = D^{-\frac{1}{2}} \hat{A} D^{-\frac{1}{2}}$$

zamiast

$$S = D^{-1} A$$


Gdzie:

$D^{-\frac{1}{2}}$: Macierz stopni wierzchołków D podniesiona macierzowo do potęgi $-\frac{1}{2}$

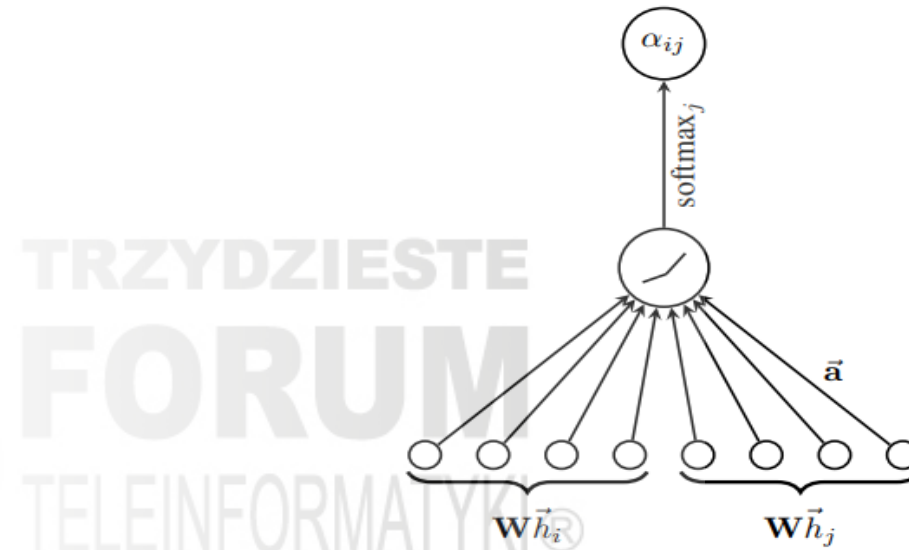
A : Macierz sąsiedztwa

\hat{A} : Macierz sąsiedztwa A z pętlami

Zastosowanie mechanizmu uwagi (Graph Attention Network)



Przykładowy skierowany graf zachowań wykorzystywany w warstwie splotowej *GCN*. Prawdopodobieństwa transmisji pakietów obliczane są z wykorzystaniem uczenia perceptrona jednowarstwowego. Zapewnia to lepsze przypisanie struktury danych do analizowanego problemu.




Perceptron jednowarstwowy stosowany do wyznaczania wag uwagi każdego z wierzchołków grafu wejściowego sieci *GCN*.

Wykorzystanie architektury równoległych sieci *GCN* z lepszą normalizacją macierzy sąsiedztwa


A

| | 0 | 1 | 2 | 3 |
|---|---|---|---|---|
| 0 | | 1 | 1 | |
| 1 | | | 1 | |
| 2 | 1 | | | 1 |
| 3 | | | | |



A^T

| | 0 | 1 | 2 | 3 |
|---|---|---|---|---|
| 0 | | | 1 | |
| 1 | 1 | | | |
| 2 | 1 | 1 | | |
| 3 | | | 1 | |



Przykładowe grafy zachowań wykorzystywane w warstwie spłotowej *GCN* z ulepszoną normalizacją macierzy sąsiedztwa A . Graf po prawej stronie ma przeciwnie skierowane łuki względem grafu po lewej. Zbudowanie bliźniaczych sieci neuronowych *GCN* w oparciu o obie reprezentacje jednocześnie zapewnia jeszcze lepsze odwzorowanie rzeczywistych danych w strukturę grafu. Sieć wykorzystująca graf oparty na A normalizuje macierz stopniami wyjścia wierzchołków, sieć A^T natomiast – normalizuje macierz sąsiedztwa stopniami wejścia wierzchołków. Wyniki uczenia obu sieci są agregowane w warstwie w pełni połączonej.

| | dokładność | precyzja | czułość | wskaźnik F1 | ROC AUC |
|---|------------|----------|---------|-------------|---------|
| GCN | 0,9275 | 0,9348 | 0,9205 | 0,9276 | 0,9275 |
| GCN z lepszą normalizacją | 0,9367 | 0,9414 | 0,9327 | 0,9370 | 0,9368 |
| GCN z lepszą normalizacją, 2 warstwowa | 0,9213 | 0,9110 | 0,9310 | 0,9209 | 0,9214 |
| GCN z lepszą normalizacją, 3 warstwowa | 0,9228 | 0,9113 | 0,9342 | 0,9226 | 0,9230 |
| GCN z lepszą normalizacją, 4 warstwowa | 0,9398 | 0,9321 | 0,9467 | 0,9393 | 0,9399 |
| GCN z lepszą normalizacją, 5 warstwowa | 0,9151 | 0,9681 | 0,8558 | 0,9085 | 0,9142 |
| GCN z lepszą normalizacją, 6 warstwowa | 0,9336 | 0,9510 | 0,9122 | 0,9312 | 0,9333 |
| GCN z lepszą normalizacją, 7 warstwowa | 0,9090 | 0,9140 | 0,8997 | 0,9068 | 0,9088 |
| GCN z lepszą normalizacją, 8 warstwowa | 0,8796 | 0,8453 | 0,9248 | 0,8832 | 0,8803 |
| GCN z lepszą normalizacją, 9 warstwowa | 0,8843 | 0,8526 | 0,9248 | 0,8872 | 0,8849 |
| GCN z lepszą normalizacją, 10 warstwowa | 0,8904 | 0,8804 | 0,8997 | 0,8899 | 0,8906 |
| GAT | 0,9059 | 0,9057 | 0,9028 | 0,9042 | 0,9058 |
| GAT, 2 wymiarowa | 0,8318 | 0,7793 | 0,9185 | 0,8432 | 0,8331 |
| GCN równoległa | 0,9306 | 0,9281 | 0,9310 | 0,9296 | 0,9306 |

Tabela przedstawia wartości zdefiniowanych miar jakości klasyfikatorów binarnych dla każdego ze zbudowanych modeli. W pierwszym wierszu tabeli zaprezentowane są wyniki reprodukcji oryginalnego algorytmu autorów badanego artykułu (autorzy w publikacji podają, że ich model uzyskał jeszcze lepsze wartości parametrów, jednakże zdecydowano, że punktem odniesienia w tym badaniu będą najwyższe zreprodukowane wyniki, jakie udało się uzyskać lokalnie autorowi pracy).

W powyższym zestawieniu czterowarstwowa sieć splotowa GCN uzyskała najwyższe wartości niemalże wszystkich parametrów – model ten uznano za najskuteczniejszy z zaimplementowanych.

Źródło: opracowanie własne

Perspektywy rozwoju

Rozbudowanie zbioru danych uczących o wektory cech

Zastosowanie struktur grafowych dla innych zastosowań cyberbezpieczeństwa

Wykorzystanie potencjału sieci równoległych