BỘ GIÁO DỤC
VÀ ĐÀO TẠO

VIỆN HÀN LÂM KHOA HỌC
VÀ CÔNG NGHỆ VIỆT NAM

HỌC VIỆN KHOA HỌC VÀ CÔNG NGHỆ

Tống Anh Tuấn

NGHIÊN CỨU CẢI TIẾN MỘT SỐ MÔ HÌNH HỌC MÁY VÀ HỌC SÂU ÁP DỤNG CHO BÀI TOÁN PHÂN LOẠI DGA BOTNET

LUẬN ÁN TIẾN SĨ NGÀNH MÁY TÍNH

Hà Nội, năm 2023

BỘ GIÁO DỤC
VÀ ĐÀO TẠO

VIỆN HÀN LÂM KHOA HỌC
VÀ CÔNG NGHỆ VIỆT NAM

HỌC VIỆN KHOA HỌC VÀ CÔNG NGHỆ

Tống Anh Tuấn

NGHIÊN CỨU CẢI TIẾN MỘT SỐ MÔ HÌNH HỌC MÁY VÀ HỌC SÂU ÁP DỤNG CHO BÀI TOÁN PHÂN LOẠI DGA BOTNET

LUẬN ÁN TIẾN SĨ NGÀNH MÁY TÍNH
Mã số: 9 48 01 04

Xác nhận của Học viện Khoa học và Công nghệ	Người hướng dẫn 1 *(Ký, ghi rõ họ tên)*	Người hướng dẫn 2 *(Ký, ghi rõ họ tên)*

Hà Nội, năm 2023

LỜI CAM ĐOAN

Tôi xin cam đoan đề tài nghiên cứu trong luận án này là công trình nghiên cứu của tôi dựa trên những tài liệu, số liệu do chính tôi tự tìm hiểu và nghiên cứu. Chính vì vậy, các kết quả nghiên cứu đảm bảo trung thực và khách quan nhất. Đồng thời, kết quả này chưa từng xuất hiện trong bất cứ một nghiên cứu nào. Các số liệu, kết quả nêu trong luận án là trung thực, nếu sai tôi hoàn toàn chịu trách nhiệm trước pháp luật.

TÁC GIẢ LUẬN ÁN

Tống Anh Tuấn

LỜI CÁM ƠN

Để hoàn thành luận án tiến sĩ này, tôi đã nhận được rất nhiều sự chỉ dạy, giúp đỡ từ tập thể người hướng dẫn, đồng nghiệp và các nhà khoa học.

Trước tiên, tôi xin được gửi lời cám ơn chân thành tới thầy PGS. TS. Hoàng Việt Long - người hướng dẫn thứ nhất và là trưởng đơn vị, người đã định hướng, giúp đỡ tôi về mặt chuyên môn cũng như tạo điều kiện cho tôi trong công tác. Tôi xin gửi lời cám ơn chân thành tới thầy PGS. TS. Nguyễn Việt Anh - người hướng dẫn thứ hai, đã luôn quan tâm, hướng dẫn chuyên môn và ủng hộ tôi trong suốt quá trình học tập tại học viện.

Tôi xin gửi lời cám ơn tới thầy PGS. TS. Lê Hoàng Sơn, PGS. TS. Nguyễn Long Giang và các thầy cô, nhà khoa học của Viện Công nghệ thông tin, Học viện Khoa học và Công nghệ đã giảng dạy, truyền đạt kiến thức, kỹ năng nghiên cứu; tạo điều kiện cho tôi tham gia các hoạt động khoa học, các nhóm nghiên cứu chuyên sâu; góp ý, hướng dẫn tôi hoàn thiện các bài báo khoa học và luận án trong suốt quá trình học tập.

Tôi xin gửi lời cám ơn chân thành tới Ban Lãnh đạo, Phòng Đào tạo, các phòng chức năng của Học viện Khoa học và Công nghệ, Viện Hàn lâm Khoa học và Công nghệ Việt Nam đã luôn quan tâm, hướng dẫn, tạo điều kiện thuận lợi cho tôi trong quá trình học tập.

Tôi cũng xin gửi lời cám ơn tới Ban Giám hiệu, tập thể Khoa Công nghệ thông tin và các đơn vị chức năng của Trường Đại học Kỹ thuật - Hậu cần CAND đã tạo điều kiện cho tôi học tập; luôn quan tâm, động viên và giúp đỡ tôi về cả chuyên môn và công tác.

Tôi xin gửi lời cám ơn tới Quỹ Đổi mới sáng tạo VinGroup (VinIF) đã tài trợ học bổng Hỗ trợ đào tạo thạc sĩ/tiến sĩ trong nước cho tôi và Đề tài khoa học công nghệ mã số ĐTĐL.CN-105/21-C đã hỗ trợ đào tạo.

Cuối cùng, tôi xin bày tỏ niềm vui với vợ Lê Thị Oanh, dì Hoa và gia đình đã động viên, giúp đỡ tôi chăm sóc con nhỏ để tôi có thời gian yên tâm học tập và hoàn thành luận án này.

MỤC LỤC

DANH MỤC CÁC KÝ HIỆU

STT	Ký hiệu	Ý nghĩa
1.	C	Tập các phụ âm
2.	V	Tập các nguyên âm
3.	N	Tập các chữ số
4.	S	Tập các ký tự đặc biệt
5.	T	Tập các ký tự thỏa mãn một điều kiện nhất định
6.	dom	Một tên miền
7.	TF	Tần suất xuất hiện của văn bản
8.	IDF	Nghịch đảo tần suất xuất hiện của văn bản
9.	$LCS(T, dom)$	Thuật toán tìm độ dài của chuỗi dài nhất
10.	$ACS(T, dom)$	Thuật toán tìm độ dài trung bình của các chuỗi
11.	$DCS(T, dom)$	Thuật toán tìm độ chênh lệch giữa chuỗi ký tự dài nhất và ngắn nhất
12.	$NoC(T, dom)$	Thuật toán tìm số lượng ký tự xuất hiện trong tên miền
13.	$RoC(T, dom)$	Thuật toán tìm tỉ lệ xuất hiện của ký tự trong tên miền
14.	i, j, k	Ký tự thể hiện số đếm trong vòng lặp
15.	TP	Số lượng mẫu tên miền nhãn 1 được phân loại là 1
16.	TN	Số lượng mẫu tên miền nhãn 0 được phân loại là 0
17.	FP	Số lượng mẫu tên miền nhãn 0 được phân loại là 1
18.	FN	Số lượng mẫu tên miền nhãn 1 được phân loại là 0
19.	Acc	Giá trị Accuracy
20.	Pre	Giá trị Precision
21.	Re	Giá trị Recall
22.	F_1	Giá trị F_1-score
23.	Sup	Giá trị Support

DANH MỤC CÁC CHỮ VIẾT TẮT

STT	Viết tắt	Viết đầy đủ tiếng nước ngoài	Viết đầy đủ Tiếng Việt
1.	AB	Adaptive Boosting	Tăng cường thích ứng
2.	APT	Advanced Persistent Threat	Tấn công có chủ đích
3.	CCTV	Closed Circuit Televison	Hệ thống giám sát truyền hình mạch đóng
4.	CNN	Convolutional Neural Network	Mạng neural tích chập
5.	C&C	Command and Control	Điều khiển và kiểm soát
6.	DDoS	Distributed Denial of Service	Tấn công từ chối dịch vụ phân tán
7.	DGA	Domain Generation Algorithm	Thuật toán sinh tên miền tự động
8.	DNS	Domain Name Service	Dịch vụ phân giải tên miền
9.	DoS	Denial of Service	Tấn công từ chối dịch vụ
10.	DT	Decision Trees	Cây quyết định
11.	HEA	Hard Ensemble Algorithm	Thuật toán học cộng đồng cố định
12.	HTTP	Hyper Text Transfer Protocol	Giao thức truyền tải siêu văn bản
13.	HTTPS	Hypertext Transfer Protocol Security	Giao thức bảo mật truyền tải siêu văn bản
14.	IDS	Intrusion Detection System	Hệ thống phát hiện xâm nhập
15.	IoT	Internet of Things	Internet vạn vật
16.	IRC	Internet Relay Chat	Trò chuyện qua Internet Relay
17.	kNN	k-Nearest Neighbour	k láng giềng gần nhất
18.	LR	Logistic Regression	Hồi quy logic
19.	LSTM	Long Short-Term Memory	Bộ nhớ dài ngắn hạn (LSTM)
20.	NB	Naive Bayes	Thuật toán Naive Bayes
21.	NCM	Neutrosophic C-Means	Thuật toán phân cụm mờ trên tập Neutrosophic Set
22.	NCS	PhD Student	Nghiên cứu sinh
23.	NN	Neural Networks	Mạng neuron
24.	N/A	Not Available	Không có sẵn
25.	RF	Random Forests	Rừng ngẫu nhiên
26.	RNN	Recurrent Neural Network	Mạng neuron hồi quy

27.	SVM	Support Vector Machines	Máy vector hỗ trợ
28.	TF-IDF	Term-Frequency – Inverse Document Frequency	Tần suất thuật ngữ - Tần suất nghịch đảo văn bản
29.	URL	Uniform Resource Locator	Địa chỉ tài nguyên đồng nhất
30.	VEA	Voting Ensemble Algorithm	Thuật toán học cộng đồng dựa trên bình chọn

DANH MỤC CÁC BẢNG

Trang

DANH MỤC CÁC HÌNH VẼ, ĐỒ THỊ

Trang

MỞ ĐẦU

1. Đặt vấn đề

- *Mạng Botnet*

Botnet là tập hợp các máy tính bị mã độc xâm nhập, được điều khiển từ xa bởi người khởi tạo ra nó (BotMaster) và được quản trị thông qua các máy chủ điều khiển - Commond-and-Control Server (C&C Server) [1]. Chúng cung cấp một nền tảng cho các hoạt động mạng bất hợp pháp như phát động các cuộc tấn công từ chối dịch vụ phân tán, phân phối phần mềm độc hại, phát tán thư rác hay lừa đảo. Đối với các hệ thống thông tin nhạy cảm, Botnet còn có thể đóng vai trò là gián điệp mạng và phục vụ cho các cuộc tấn công có chủ đích (APT - Advanced Persistent Threat). Ngoài ra, Botnet cũng có xu hướng phát triển lây nhiễm trên các thiết bị IoT có kết nối Internet. Điều này giúp chúng đạt được quy mô mạnh mẽ hơn so với việc chỉ lây nhiễm trên máy tính cá nhân truyền thống. Một loại Botnet đặc trưng của dạng này là Mirai [2], đây cũng có thể coi là đại diện cho thế hệ Botnet mới nhất.

Một số nghiên cứu đã chỉ rõ ảnh hưởng của Botnet đối với mạng máy tính. Ghafir và cộng sự tính toán được rằng khoảng từ 16% đến 25% các máy tính kết nối Internet là thành viên của một mạng Botnet nào đó [3]. Một thống kê khác cho thấy khoảng 80% lưu lượng thư điện tử trên Internet là thư rác và hầu hết được gửi bởi Botnet như Botnet Grum, Cutwail và Rustock [4], đã gây lãng phí tài nguyên băng thông mạng. Các cuộc tấn công từ chối dịch vụ phân tán bởi Botnet cũng gây thiệt hại ngày càng lớn. Tiêu biểu là cuộc tấn công vào tập đoàn dịch vụ hosting OVH của Pháp với mức băng thông bị chiếm dụng đạt mức kỷ lục, lên đến 1,5Tbps [5], khiến hệ thống bị tê liệt hoàn toàn.

Các minh chứng trên cho thấy, Botnet là một mối đe dọa lớn và thường trực trên Internet, các hoạt động của chúng có thể gây ra những thiệt hại về tài chính, danh tiếng đối với các nhà cung cấp dịch vụ, công ty tư nhân, chính quyền và cả người dùng cá nhân. Từ đó, các giải pháp phát hiện Botnet để kịp thời ngăn chặn là câu hỏi được các nhà khoa học đặt ra và tập trung nghiên cứu. Điều này đặc biệt có ý nghĩa trong thời đại công nghệ thông tin và truyền thông được ứng dụng rộng rãi trong đời sống như hiện nay.

- *Kỹ thuật phát hiện Botnet*

Nhận xét rằng, các của Botnet về cơ bản tương tự như con người, nhưng với năng lực lớn hơn rất nhiều. Botnet thực hiện các thao tác lặp đi lặp lại với tốc độ cao, tần suất lớn, chúng gây ảnh hưởng đến khả năng đáp ứng của hệ thống thông tin, tạo nên tình trạng quá tải và mất khả năng cung cấp dịch vụ. Việc nắm rõ các cơ chế hoạt động của Botnet cung cấp cho các nhà khoa học giải pháp để phát hiện chúng.

Có hai hướng tiếp cận chính được sử dụng để phát hiện Botnet, bao gồm [6]:

- (1) Hướng tiếp cận dựa trên Honeynet (mạng bẫy tin tặc).

- (2) Hướng tiếp cận dựa trên hệ thống phát hiện xâm nhập (Intrusion Detection System - IDS), bao gồm các kỹ thuật:

+ Kỹ thuật phát hiện Botnet dựa trên sự bất thường.

+ Kỹ thuật phát hiện Botnet dựa trên chữ ký.

+ Kỹ thuật phát hiện Botnet dựa trên tên miền.

Các kỹ thuật theo hướng tiếp cận (1) thường xây dựng các mạng Honeynet để thu thập thông tin Botnet, sau đó phân tích các đặc điểm và hành vi của chúng. Các hệ thống Honeynet có ưu điểm là dễ xây dựng và đòi hỏi ít tài nguyên. Chúng cung cấp những thông tin về Botnet để có thể bổ sung vào cơ sở dữ liệu chữ ký nhận dạng của Botnet. Tuy nhiên, mạng Honeynet có hạn chế về khả năng mở rộng và khả năng tương tác với các hành vi độc hại. Cách tiếp cận này chủ yếu dựa trên kinh nghiệm thực tế và sự hỗ trợ của các giải pháp, thiết bị mạng.

Các kỹ thuật theo hướng tiếp cận (2) dựa trên các kỹ thuật IDS. IDS là một ứng dụng phần mềm hoặc một thiết bị phần cứng có khả năng giám sát các dịch vụ hệ thống để phát hiện các hành vi độc hại, hoặc các vi phạm chính sách an ninh và thông báo cho người quản trị. Các IDS thường được cài đặt để giám sát các gói tin truyền qua cổng mạng, các sự kiện xảy ra, sau đó tiến hành phân tích để tìm các dấu hiệu xuất hiện Botnet.

Mỗi kỹ thuật trong IDS đều có ưu nhược điểm riêng. Đối với kỹ thuật phát hiện Botnet dựa trên sự bất thường, tỉ lệ đưa ra các cảnh báo giả là cao bởi hệ thống dễ bị nhầm lẫn sự bất thường được gây ra bởi các tác nhân gây hại khác mà không chỉ riêng Botnet. Kỹ thuật phát hiện Botnet dựa trên chữ ký thiếu hiệu quả với các

dạng Botnet mới chưa được nhận dạng chữ ký trong cơ sở dữ liệu. Kỹ thuật phát hiện Botnet dựa trên tên miền áp dụng trong phạm vi DGA Botnet có thể khắc phục được hạn chế của hai kỹ thuật trước đó. Đây cũng là vấn đề được NCS lựa chọn nghiên cứu, phân tích và luận giải.

- *Phát hiện và phân loại DGA Botnet*

Trong phạm vi của luận án, NCS tập trung vào một dạng Botnet phổ biến đó là DGA Botnet. Dạng Botnet này sử dụng phương thức truy vấn tên miền tự động để kết nối đến C&C Server nhằm trao đổi thông tin và nhận nhiệm vụ. Việc phát hiện DGA Botnet được thực hiện khi chúng có các hành vi truy vấn tên miền này. Bằng cách ngăn chặn các kết nối này, ta có thể vô hiệu hóa DGA Botnet kể cả khi chúng đã lây nhiễm vào máy tính. Một số đánh giá trước đó cho thấy hướng tiếp cận này hiệu quả và tiết kiệm chi phí tính toán hơn.

Một số kết quả nghiên cứu chuyên sâu về bài toán DGA Botnet đã được công bố, cụ thể như sau:

- Alieyan và cộng sự [7] trình bày các kỹ thuật để phát hiện mạng Botnet thông qua phân tích lưu lượng DNS. Kwon và cộng sự giới thiệu giải pháp PsyBoG [8], dùng để phát hiện hành vi độc hại của Botnet đạt độ chính xác 95%. Giải pháp Wang và cộng sự đề xuất giải pháp DBod để phát hiện Botnet dựa trên phân tích tên miền [9] với độ chính xác trên 99% nhưng các đánh giá đang thực hiện trên phạm vi nhỏ. Bisio và cộng sự [10] đề xuất thuật toán phát hiện DGA Botnet dựa trên một Single Network Monitoring với ba bước, đạt độ chính xác từ 88,85% đến 92,67% trong các kịch bản thử nghiệm. Giải pháp của Wang và cộng sự bổ sung một cải tiến đó là phát hiện các máy bị nhiễm. Trung và cộng sự [11] phát triển các nghiên cứu với dạng IoT Botnet. Giải pháp đồ thị PSI (PGS-Graph) nhóm tác giả đề xuất đạt được độ chính xác 98,7%.

- Trên nền tảng học máy, Hiếu và cộng sự sử dụng học có giám sát để phát hiện DGA Botnet [12]. Nổi bật là SVM và LSTM với độ chính xác từ 99,55% trở lên tuy nhiên khả năng phân loại còn hạn chế. Khan và cộng sự [13] phát hiện các mạng Botnet ngang hàng và đạt độ chính xác trung bình là 98,7% trên CTU-13 và ISOT Dataset. Giải pháp của Xuân và cộng sự [14] sử dụng học máy có tỉ cảnh báo sai dưới 3,02% và điểm F_1-score đạt 97,03%.

- Trên nền tảng học sâu, Đức và cộng sự [15] đề xuất giải pháp LSTM.MI, đạt F_1-score là 98,49% trong phát hiện DGA Botnet nhưng hạn chế trong phân loại họ DGA Botnet. Curtin và cộng sự đã sử dụng mạng RNN để phát hiện và phân loại DGA Botnet [16] và đạt các kết quả tương tự. Giải pháp của Vinayakumar và cộng sự [17] là CNN-LSTM để phát hiện tên miền độc hại được sinh bởi Botnet hay thư điện tử, URL độc hại có F_1-score đạt 96,3%.

Zago và cộng sự công bố một bộ dữ liệu mới về DGA Botnet là UMUDGA Dataset [18]. Bộ dữ liệu này được xem là đầy đủ nhất tính đến thời điểm công bố với 50 họ DGA Botnet khác nhau. Nhóm tác giả cũng đưa ra các thử nghiệm của mình trên bộ dữ liệu này.

Các kết quả nghiên cứu trên cho thấy: Trong các hướng tiếp cận được đề cập, hướng tiếp cận phân tích lưu lượng, sử dụng học máy, học sâu nói chung hay mạng LSTM nói riêng cho kết quả cao từ 96,3% trở lên trong bài toán phát hiện DGA Botnet. Tuy nhiên, các kết quả này hoàn toàn có thể được cải tiến thêm và đánh giá toàn diện hơn trên các bộ dữ liệu mới đầy đủ hơn. Một vấn đề khác đặt ra là các nghiên cứu về phân loại hay nhận diện họ DGA Botnet còn hạn chế, ít được đề cập hoặc độ chính xác đạt được chưa cao (LSTM đạt 53%, LSTM.MI đạt 49%), một số họ DGA Botnet khả năng nhận diện kém. Cuối cùng, việc đánh giá trên các bộ dữ liệu chính thức còn hạn chế.

Từ các vấn đề trên, NCS đặt ra các câu hỏi nghiên cứu cho luận án như sau:

Câu hỏi 1: Đối với bài toán phát hiện DGA Botnet, các hướng tiếp cận mới bao gồm sử dụng thuật toán phân cụm trên tập mờ, sử dụng mô hình học máy kết hợp có hiệu quả hay không?

Câu hỏi 2: Mạng LSTM có thể được cải tiến để nâng cao hiệu quả của việc phát hiện và phân loại DGA Botnet không và giải pháp cụ thể là gì? Trong đó trọng tâm là giải pháp để phân loại DGA Botnet.

Câu hỏi 3: Các bộ dữ liệu về DGA Botnet hiện nay có những đặc điểm gì gây hạn chế cho việc thử nghiệm thuật toán, đối sánh các kết quả nghiên cứu hay tính cập nhật. Có thể xây dựng bộ dữ liệu mới để giải quyết các hạn chế trên hay không?

2. Mục tiêu nghiên cứu

Đề tài đặt ra mục tiêu chung là nghiên cứu, cải tiến các mô hình học máy, học sâu để nâng cao độ chính xác của giải pháp phân loại DGA Botnet, với các mục tiêu cụ thể như sau:

- Nghiên cứu về đặc điểm của DGA Botnet. Trình bày nền tảng lý thuyết, các kỹ thuật, nghiên cứu liên quan, là cơ sở để phát triển các thuật toán phát hiện và phân loại DGA Botnet.

- Nghiên cứu, đánh giá hiệu quả của hai hướng tiếp cận là thuật toán phân cụm trên tập mờ, kỹ thuật học máy kết hợp để giải quyết bài toán phát hiện DGA Botnet.

- Đề xuất mô hình học sâu mới trên nền tảng kế thừa mạng LSTM để phát hiện và phân loại DGA Botnet. Trong đó, trọng tâm chính là bài toán phân loại DGA Botnet với mục tiêu nâng cao đáng kể độ chính xác so với các giải pháp trước đó.

3. Đối tượng và phạm vi nghiên cứu

Nghiên cứu tập trung vào các đối tượng như sau:

- Đặc điểm, cơ chế, hành vi của DGA Botnet; kỹ thuật phát hiện, phân loại DGA Botnet dựa trên phân tích tên miền và học máy, học sâu.

- Hai bài toán chính trong DGA Botnet bao gồm: Bài toán phân lớp nhị phân và phân lớp đa lớp, tương ứng với phát hiện và phân loại DGA Botnet.

- Các bộ dữ liệu công khai, tin cậy và mới cập nhật về DGA Botnet và phương pháp xây dựng bộ dữ liệu mới.

Phạm vi nghiên cứu của luận án tập trung vào bài toán phân loại DGA Botnet và các vấn đề liên quan, bao gồm kỹ thuật phát hiện DGA Botnet trước khi phân loại, và bộ dữ liệu mới chuyên dùng cho đánh giá bài toán DGA Botnet.

4. Nội dung và phương pháp nghiên cứu

a. Nôi dung nghiên cứu

Để giải quyết các câu hỏi nghiên cứu đặt ra, NCS nghiên cứu tổng quan các kỹ thuật phát hiện DGA Botnet và các nghiên cứu liên quan. Đề xuất giải pháp để nâng cao độ chính xác của thuật toán phát hiện và phân loại DGA Botnet. Bên cạnh các hướng tiếp cận truyền thống, NCS cũng thực hiện các hướng tiếp cận mới như sử

dụng thuật toán phân cụm trên tập mờ, sử dụng kỹ thuật học kết hợp. NCS cũng xây dựng một bộ dữ liệu mới về DGA Botnet với những cải tiến, cập nhật mới.

Một số nội dung chi tiết mà NCS sẽ tập trung nghiên cứu như sau:

- Nghiên cứu đặc điểm, các kỹ thuật phát hiện và phân loại DGA Botnet;

- Nghiên cứu, thuật toán phân cụm trên tập Neutrosophic Set, học máy và các mô hình học kết hợp để áp dụng cho phát hiện DGA Botnet.

- Nghiên cứu mạng LSTM và các biến thể, trên cơ sở đó cải tiến, đề xuất giải pháp phát hiện, phân loại DGA Botnet. Trọng tâm là bài toán phân loại DGA Botnet.

- Nghiên cứu các bộ dữ liệu chuyên dùng về DGA Botnet, bao gồm: Botnet DGA Dataset [19], Andrey Abakumov [20], UMUDGA Dataset [21] [18], DGArchive [22], OSINT DGA feed [23], 360NetLab Dataset [24], Johannes Bader [25] và xây dựng bộ dữ liệu mới.

b. Phương pháp nghiên cứu

NCS sử dụng các phương pháp nghiên cứu bao gồm:

- Thu thập, tổng hợp tài liệu:

+ Thu thập, tổng hợp và đánh giá các kết quả nghiên cứu trước đó về đặc điểm, chữ ký, hành vi và kỹ thuật phát hiện DGA Botnet, tài liệu thuật toán NCM, các mô hình học máy, học sâu tiên tiến.

+ Các tư liệu và thông tin được thu thập, tổng hợp được từ các nguồn như: Các bài báo trên tạp chí khoa học chuyên ngành uy tín thuộc danh mục ISI/Scopus, kỷ yếu hội thảo khoa học chuyên ngành, giáo trình, tài liệu của các nhà trường, viện nghiên cứu.

- Tham khảo ý kiến chuyên gia:

+ Tham khảo, xin ý kiến của tập thể giáo viên hướng dẫn, các thầy cô, nhà khoa học tại Viện Công nghệ thông tin và Học viện Khoa học và Công nghệ, Viện Hàn lâm Khoa học và công nghệ Việt Nam.

+ Trao đổi, chia sẻ và tham khảo ý kiến các nhà khoa học, đồng nghiệp, chuyên gia, các đơn vị chuyên về an toàn thông tin tại Trường Đại học Kỹ thuật - Hậu cần CAND, Học viện Kỹ thuật mật mã, Cục Công nghệ thông tin - Bộ Công an.

+ Trao đổi, thảo luận với các NCS, nhóm nghiên cứu gần lĩnh vực nghiên cứu, tham gia các hội thảo khoa học chuyên ngành để báo cáo, học hỏi kinh nghiệm nghiên cứu, kỹ năng trình bày.

- Nghiên cứu thực nghiệm, đánh giá: Đánh giá các giải pháp phát hiện và phân loại DGA Botnet đề xuất. Thực hiện trên các bộ dữ liệu chuyên dùng về DGA Botnet như: Andrey Abakumov's DGA Repository, OSINT DGA feed, UMUDGA Dataset, 360NetLab Dataset và bộ dữ liệu UTL_DGA22 đề xuất. So sánh, đánh giá với các nghiên cứu liên quan.

5. Các đóng góp của luận án

Các đóng góp của luận án đạt được qua quá trình nghiên cứu như sau:

Đóng góp 1: Đề xuất ba giải pháp phát hiện và phân loại DGA Botnet, bao gồm NCM, LA_Bin07, LA_Mul07 nhằm nâng cao độ chính xác so với các giải pháp trước đó.

Đóng góp 2: Đề xuất một bộ dữ liệu mới UTL_DGA22 chuyên dụng cho bài toán DGA Botnet phục vụ cho các nghiên cứu cùng hướng trong tương lai.

6. Bố cục của luận án

Luận án thể hiện các kết quả đạt được của NCS trong quá trình học tập, nội dung được cấu trúc thành 04 chương, cụ thể như sau:

- *Chương 1: Cơ sở lý thuyết về DGA Botnet*. Trình bày cơ sở lý thuyết về DGA Botnet, các kỹ thuật phát hiện, phân loại và các nghiên cứu liên quan.

- *Chương 2: Đánh giá giải pháp phát hiện DGA Botnet sử dụng lý thuyết tập mờ và học máy*. Trình bày các đánh giá về việc áp dụng lý thuyết tập mờ, học máy để giải quyết bài toán phát hiện DGA Botnet, là cơ sở để cải tiến các mô hình học sâu trong Chương 3.

- *Chương 3:Giải pháp phát hiện và phân loại DGA Botnet sử dụng kỹ thuật học sâu*. Trình bày đề xuất về hai mô hình mới gồm LA_Bin07 và LA_Mul07 phát triển trên cơ sở mạng LSTM, giải quyết bài toán phát hiện và phân loại DGA Botnet với độ chính xác cao, đặc biệt là bài toán phân loại DGA Botnet.

- *Chương 4: Bộ dữ liệu mới UTL_DGA22 chuyên dùng cho đánh giá bài toán DGA Botnet*. Công bố một bộ dữ liệu mới UTL_DGA22 chuyên dùng cho DGA Botnet. Bộ dữ liệu mới này đảm bảo tính cập nhật, chính xác, dễ tiếp cận, hướng tới là nền tảng chung được sử dụng rộng rãi trong thời gian tới.

Các kết quả nghiên cứu của luận án được công bố tại 04 bài báo trên tạp chí khoa học chuyên ngành quốc tế uy tín thuộc danh mục ISI/Scopus và 02 báo cáo tại hội thảo khoa học chuyên ngành quốc gia, quốc tế uy tín, được thể hiện trong phần "Danh mục công trình của tác giả" ở cuối của luận án này.

Chương 1. CƠ SỞ LÝ THUYẾT VỀ DGA BOTNET

Chương 1 trình bày cơ sở kiến thức về Botnet nói chung và DGA Botnet nói riêng. NCS cũng trình bày hai bài toán trong DGA Botnet là phân lớp nhị phân và phân lớp đa lớp, tương ứng với phát hiện và phân loại DGA Botnet. Đây cũng là vấn đề được NCS tập trung nghiên cứu, giải quyết và trình bày kết quả trong các chương tiếp theo của luận án này.

1.1. Tổng quan chung về Botnet

1.1.1. Khái niệm Botnet

Khái niệm Bot: Là một đoạn mã máy tính thực hiện một công việc hay nhiệm vụ nào đó một cách tự động. Bot có thể hoạt động trên máy tính cục bộ hoặc trên môi trường mạng. Các con bot thường được lập trình để thực hiện các nhiệm vụ đơn giản nhưng lặp đi lặp lại với tốc độ cao.

Bot được phát triển lần đầu tiên trong hệ thống mạng Internet Relay Chat - IRC [26]. Giao thức IRC là một dạng truyền dữ liệu thời gian thực trên Internet, cho phép một nhóm người có thể trò chuyện với nhau thông qua một kênh truyền chung. IRC cũng hỗ trợ các cuộc trò chuyện riêng tư giữa hai máy khách và truyền tải trực tiếp dữ liệu. Mạng IRC nhanh chóng được người dùng Internet yêu thích và trở nên phổ biến. Các Bot đầu tiên đã được phát triển và sử dụng như một phương tiện để bảo vệ kênh IRC chống lại các hình thức tấn công từ chối dịch vụ DDOS.

Khái niệm Botnet: Theo Provos & Holz [27], Botnet là một "mạng gồm rất nhiều máy tính bị xâm nhập và có thể bị kẻ tấn công điều khiển từ xa". Máy tính bị xâm nhập là máy tính đã bị lây nhiễm mã độc hay phần mềm độc hại và chịu sự điều khiển bí mật của kẻ tấn công. Botnet là một tập hợp các máy tính đã bị xâm nhập ở trên, chúng tiếp nhận và thực thi lệnh từ một máy chủ điều khiển C&C Server. Máy chủ này đóng vai trò là trung gian, gửi các lệnh từ kẻ tấn công hay người điều khiển tới mạng Botnet. Người này được gọi là BotMaster. Để tránh bị phát hiện bởi các giải pháp an ninh, các BotMaster có thể tùy chọn sử dụng một số máy chủ Proxy, đặt ở giữa các C&C Server và người điều khiển.

Hình 1.1 thể hiện một mạng Botnet với BotMaster, C&C Server và các con Bot. Các bước hoạt động của mạng Botnet này được mô tả như sau:

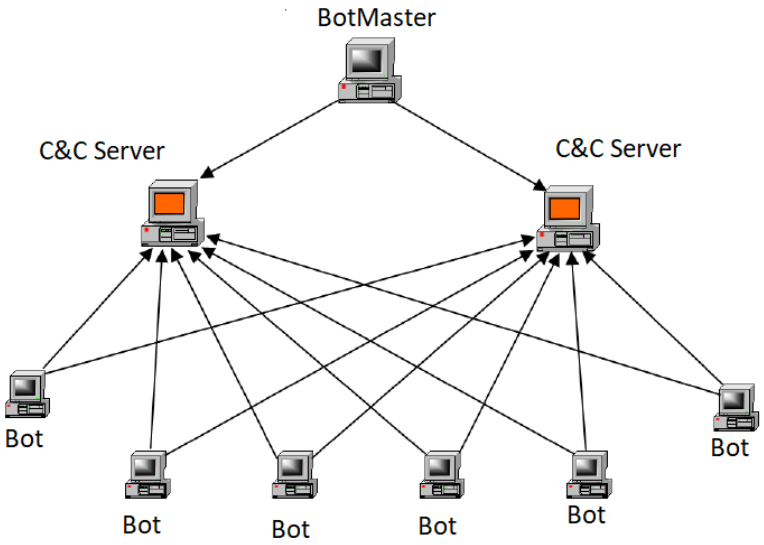

Hình 1.1. Mô hình mạng Botnet với các C&C Server

- Bước 1: Khi một Bot mới được tạo ra bằng cách lây nhiễm vào máy tính nào đó, nhiệm vụ đầu tiên của nó là tìm kiếm và báo cáo thông tin trở lại máy chủ C&C.

- Bước 2: Trong thời gian lây nhiễm, con Bot sẽ ẩn mình để hạn chế tối đa khả năng phát hiện của các giải pháp bảo mật, chúng có thể trao đổi với C&C Server để báo cáo thông tin, cập nhật mã nguồn hoặc các hoạt động khác.

- Bước 3: Khi BotMaster gửi lệnh, các C&C Server sẽ chuyển tiếp và gửi chúng tới Bot để lên lịch cho hoạt động được yêu cầu.

- Bước 4: Vào thời điểm đã định, tất cả các Bot đã được lựa chọn sẽ bắt đầu thực hiện các hành vi độc hại đến mục tiêu. Các hành vi này có thể bao gồm: Gửi lưu lượng mạng độc hại, gửi tin nhắn/email rác.

- Bước 5: Bot báo cáo lại kết quả cho máy chủ C&C, chẳng hạn như đã hoàn thành nhiệm vụ và sẵn sàng cho các lệnh mới. Chúng cũng có thể bị ngắt kết nối để kết thúc vòng đời của mình hoặc bị phát hiện, bóc gỡ bởi các giải pháp bảo mật.

Trong mô hình này, tin tặc có thể khá yên tâm rằng máy tính thực hiện các hành động tấn công không phải là máy tính của họ C&C Server cũng không có nằm trên máy của họ, từ đó có thể hạn chế khả năng bị lộ danh tính. Để ngăn chặn Botnet, các chuyên gia, nhà quản trị mạng phải theo dõi ngược từ máy khách đến máy chủ C&C Server. Để tăng cường thêm cơ chế ẩn mình, tin tặc có thể thêm một lớp trung gian khác bằng cách gửi tất cả các lệnh thông qua một proxy gây nhiễu, hoặc thông qua một loạt nhiều bước nhảy bằng cách sử dụng công cụ Tor. Thêm vào đó, một số

mã Botnet còn bao gồm cả các lệnh xóa bằng chứng, lệnh mã hóa lưu lượng và các kỹ thuật ẩn mình đa hình.

Mục tiêu cuối cùng của một mạng Botnet là để thực hiện các hoạt động độc hại với quy mô lớn, tốc độ cao như phát tán tin nhắn rác, mã độc, thư rác… hoặc tấn công từ chối dịch vụ. Trước đây, các con Bot được thiết kế để lây nhiễm trên các máy tính cá nhân và mạng Botnet cũng được hình thành từ những thiết bị này. Tuy nhiên hiện nay, với sự phát triển của các thiết bị Internet of Things - IoT, khái niệm Botnet đã mở rộng hơn. Các con Bot không chỉ dừng lại ở việc lây nhiễm vào máy tính cá nhân, mà chúng còn có thể lây nhiễm vào các loại thiết bị IoT như tivi thông minh, tủ lạnh thông minh, camera an ninh, các cảm biến không dây. Từ đó, quy mô và sức ảnh hưởng của mạng Botnet hiện đại cũng tăng lên hơn nhiều lần so với mạng Botnet truyền thống.

1.1.2. Các bước phát triển về công nghệ Botnet

Các con Bot ban đầu được thiết kế như một công cụ hữu ích để hỗ trợ cho con người. Chúng được phát triển dưới dạng một cá nhân ảo có thể đứng trên kênh IRC và làm việc cho chủ sở hữu của nó. Trải qua thời gian, các con Bot liên tục được phát triển, cải tiến về công nghệ, cụ thể như sau:

- Năm 1989: Greg Lindahl tạo ra GM, được xem là con Bot đầu tiên [28]. GM có thể chơi trò “Hunt the Wumpus” với người dùng giao thức IRC.

- Năm 1999: Pretty Park được phát triển [28], chúng được xem là loại virus đầu tiên sử dụng hệ thống máy chủ IRC như một hệ thống điều khiển từ xa.

- Năm 1999: Phát hiện Subseven Trojan/Bot [28], là một trojan điều khiển từ xa có thêm quyền kiểm soát thông qua IRC.

- Năm 2000: GTBot, dựa trên mIRC để chạy các tập lệnh phản hồi sự kiện máy chủ IRC [29]. Con Bot này hỗ trợ cả giao thức TCP và UDP.

- Năm 2002: SDBot [30] được viết bằng C, dùng để khai thác dữ liệu cho cộng đồng tin tặc.

- Năm 2002: AgoBot lần đầu tiên được thiết kế dưới dạng module [28]. Gồm các module như tải xuống, ẩn mình và tấn công.

- Năm 2003: SpyBot [31] xuất hiện với khả năng tương tự các phần mềm gián điệp.

- Năm 2003: Rbot được phát triển [31], chúng có thể vượt qua mật khẩu yếu, dễ dàng sửa đổi, sử dụng phần mềm đóng gói.

- Năm 2004: PolyBot là một biến thể của AgoBot với khả năng đa hình [28]. Chúng có thể thay đổi mã của nó trong mỗi lần lây nhiễm.

- Năm 2005: MYTOB My Doom [32], là loại sâu có khả năng gửi số lượng lớn các email rác.

- Năm 2016: Xuất hiện Botnet Mirai [33] có khả năng lây nhiễm trên các thiết bị IoT, được xem là IoT Botnet đầu tiên.

1.1.3. Một số đặc điểm của Botnet

Mạng Botnet là sự kết hợp của nhiều thành phần, thường bao gồm một vài máy máy chủ C&C và nhiều BotClient. Mạng Botnet với hàng trăm hoặc vài nghìn BotClient được coi là quy mô nhỏ. Các mạng Botnet quy mô lớn hơn có thể bao gồm vài chục hoặc vài trăm nghìn con Bot.

Botnet có những đặc điểm đặc trưng về vòng đời, phương thức lây nhiễm và các hành vi độc hại, cụ thể như sau:

1.1.3.1. Vòng đời hoạt động

Vòng đời của một mạng Botnet thường trải qua các giai đoạn như Hình 1.2:

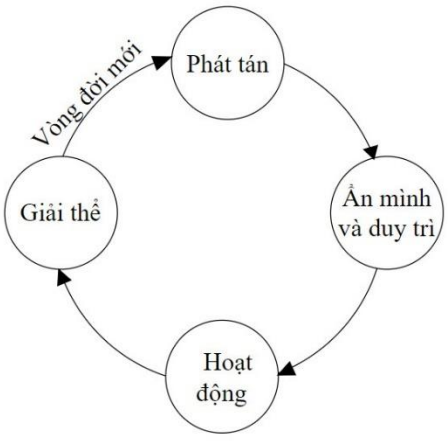

Hình 1.2. Các giai đoạn trong vòng đời của Botnet

- Phát tán: Các con Bot được phát tán thông qua mã độc hay phần mềm độc hại. Chúng cũng có thể lây nhiễm qua các kênh như tin nhắn, email, tệp tin tải từ Internet hay kênh USB...

- Ẩn mình và duy trì: Khi đã lây nhiễm vào máy tính, các con Bot sẽ bí mật kết nối trở lại C&C Server để báo cáo. Chúng duy trì sự hiện diện bí mật của mình trên thiết bị của nạn nhân và cố gắng không tạo ra những dấu hiệu khác lạ nào. Trong giai đoạn này, chúng cũng có thể liên tục cập nhật mã nguồn mới hoặc gửi về các dữ liệu mà chúng thu thập được.

- Hoạt động: Các con Bot sẽ đồng loạt hoạt động vào một thời điểm và điều kiện được chỉ định bởi BotMaster thông qua C&C Server. Chúng có thể phát động một cuộc tấn công từ chối dịch vụ, phát tán tin nhắn rác hoặc thực hiện các hành vi gian lận. Trong giai đoạn này, người dùng có thể phần nào nhận ra được sự hoạt động của các con Bot trên thiết bị của mình.

- Giải thể: Thông thường, các con Bot có thể dễ bị phát hiện khi chúng đã tiến hành hoạt động cho một mục đích nào đó. Trong giai đoạn cuối cùng của vòng đời, các con Bot sẽ tự hủy hoạt động của nó, xóa các dấu vết trên thiết bị nạn nhân, cũng như lịch sử kết nối tới C&C Server. Điều này giúp kẻ tấn công có thể phòng ngừa việc bị lần ra dấu vết. Đồng thời cũng để giải phóng một mạng Botnet đã bị lộ. Một mạng Botnet mới sẽ được hình thành và sẽ lặp lại theo vòng đời ở trên.

1.1.3.2. Phương thức lây nhiễm

Botnet có thể sử dụng các phương thức khác nhau để lây nhiễm lên các máy tính. Đồng thời, chúng cũng có khả năng sao chép chính mình từ thiết bị này sang thiết bị khác. Jose Nazario đã liệt kê một số đặc trưng về phương thức lây nhiễm của Botnet, cụ thể như sau [34]:

- Thông qua email: Các email được gửi đính kèm các tệp tin chứa mã độc hại. Nếu người dùng mở những email này và thực thi các mã đó thì máy tính của họ sẽ bị lây nhiễm mã độc. Trước đây, hình thức này tương đối dễ bị phát hiện bởi những dấu hiệu như email đến từ địa chỉ không tin cậy, tệp tin đính kèm có nhận dạng là độc hại. Hiện nay, kỹ thuật phát tán ngày càng trở nên tinh vi hơn khi các email được giả mạo được gửi từ các công ty hay tổ chức uy tín. Đồng thời, khi một máy bị nhiễm thì danh

sách địa chỉ liên hệ của người dùng trên máy đó sẽ bị đọc và các email độc hại này lại tiếp tục được gửi đến những địa chỉ liên hệ đó.

- URL độc hại: Là những URL điều hướng người sử dụng đến các trang web chứa mã độc hại. Tin tặc có thể gửi liên kết này thông qua email, mạng xã hội, tin nhắn và sử dụng các kỹ nghệ xã hội để cố gắng thuyết phục người dùng rằng nó đáng tin cậy.

- Website giả mạo: Các trang web này thường được thiết lập để giả mạo các website nổi tiếng như Facebook, YouTube hoặc một trang web đáng tin cậy nào đó bị tấn công và chèn vào các mã độc. Có hai kiểu tấn công chính là tấn công phía Client và khai thác tải về:

+ Trong hình thức tấn công phía Client, khi người dùng truy cập vào trang web, các mã độc hại sẽ được khởi động và cố gắng lợi dụng các lỗ hổng bảo mật trên trình duyệt để có thể truy cập vào máy tính. Nếu lỗ hổng này được lợi dụng thành công, máy tính của người dùng sẽ bị lây nhiễm và trở thành một con bot. Trang web sẽ sử dụng đồng thời một vài lỗ hổng bởi vì sự thành công sẽ phụ thuộc vào trạng thái cập nhật của phần mềm cũng như plugin của bên thứ ba.

+ Dạng tấn công dựa trên khai thác tải về là khi truy cập vào một website, người dùng sẽ được nhắc nhở để tải về một tập tin. Nếu người dùng chấp nhận tải về và thực thi chúng, máy tính sẽ có khả năng bị lây nhiễm mã độc hại được đính kèm trong tập tin này.

1.1.3.3. Các hành vi độc hại

Một số hành vi độc hại của các con Bot bao gồm:

- Gửi tin nhắn hoặc thư rác: Các mạng Botnet có thể gửi một lượng lớn các tin nhắn hoặc thư rác, gây tiêu tốn băng thông mạng, phiền toái và các nguy cơ lừa đảo, đánh cắp thông tin người dùng.

- Tấn công từ chối dịch vụ phân tán: Các mạng Botnet lớn thường được sử dụng để phát động một cuộc tấn công từ chối dịch vụ phân tán. Đây là một đặc điểm phổ biến của Botnet giúp phân biệt chúng với các phần mềm mã độc khác.

Một số vụ tấn công nổi bật như: Cuộc tấn công vào Amazon Web Services năm 2022 [35]; Tấn công nhắm vào Brian Krebs và OVH năm 2016 với tốc độ 620

Gbps [36]. Lúc đó, đây là cuộc tấn công DDoS lớn nhất từng được ghi nhận. Từ tháng 7/2012 tới tháng 09/2016, trang blog của Krebs đã hứng chịu 269 cuộc tấn công DDoS nhưng đây là cuộc tấn công lớn nhất, lớn gấp 3 lần so với kỷ lục lúc bấy giờ. Cuộc tấn công của Mirai Botnet vào OVH, được thực hiện bởi khoảng 145.000 con Bot và tạo ra lưu lượng chiếm dụng trái phép có lúc lên tới 1,1 Tbps và kéo dài trong thời gian 7 ngày.

- Do thám người dùng: Các Bot khi nhiễm vào máy tính có thể bí mật thu thập thông tin của người dùng, như là lịch sử gõ phím hoặc các tệp tin lưu trữ trên đó.

- Gian lận Click: Bot có thể đóng vai trò giả mạo con người để truy cập vào những quảng cáo hoặc tương tự. Trong những trường hợp này, việc thực hiện tự động trên giúp kẻ tấn công thu được lợi nhuận bất chính.

- Đánh cắp bản quyền: Một số họ Botnet có khả năng thu thập và đánh cắp bản quyền phần mềm trên máy tính mà nó lây nhiễm.

- Phát tán mã độc: Các con Bot tự bản thân nó cũng có thể tiếp tục phát tán mã nguồn để lây nhiễm tới nhiều máy hơn, từ đó có thể mở rộng mạng lưới của chúng.

Một số giải pháp để phòng ngừa và ngăn chặn Botnet bao gồm: Phòng ngừa sự lây nhiễm của Botnet vào máy tính cá nhân và thiết bị IoT, cài đặt các phần mềm chống virus cho máy tính cá nhân, có phương án dự phòng về máy chủ, băng thông cho các hệ thống thông tin, ứng dụng các giải pháp phòng chống và điều tra tấn công DDOS từ các nhà cung cấp dịch vụ.

1.1.4. Phân loại Botnet

Botnet có thể được phân loại theo các tiêu chí như: Giao thức, thiết bị lây nhiễm hoặc kiến trúc.

1.1.4.1. Phân loại Botnet theo giao thức

Giao thức là phương thức gửi nhận giữa Bot và C&C Server. Botnet thường sử dụng hai giao thức phổ biến là giao thức truyền tải siêu văn bản HTTP (HyperText Transfer Protocol), HTTPS (Hypertext Transfer Protocol Security) và giao thức trò chuyện qua Internet là IRC.

- IRC Botnet: Đây là loại Botnet hoạt động trên giao thức IRC, là một giao thức mạng phổ biến trên Internet. Hầu hết mọi IRC Server đều cho phép truy cập

miễn phí, không kể đối tượng sử dụng. Các IRC Botnet sử dụng kênh IRC để liên lạc, phát tán và thực hiện hành vi độc hại.

- HTTP Botnet: Botnet sử dụng giao thức HTTP cũng hoạt động theo mô hình Client-Server. Tuy nhiên, thay vì nhận lệnh thông qua kênh chat thì HTTP Botnet sẽ sử dụng giao thức HTTP để gửi các yêu cầu và nhận lệnh từ Bot Master. HTTP Botnet thường không nhận lệnh theo thời gian thực mà chúng sẽ gửi yêu cầu liên tục hoặc qua một khoảng thời gian nào đó để cập nhật các dữ liệu mới. Hiện nay, các loại Botnet hiện đại hơn sử dụng giao thức HTTPS để tăng cường khả năng che dấu vết của mình.

1.1.4.2. Phân loại Botnet theo thiết bị lây nhiễm

Thiết bị lây nhiễm là mục tiêu mà Bot có khả năng hoặc được thiết kế để lây nhiễm. Các thiết bị này có điểm chung là có hệ điều hành, có kết nối Internet và tồn tại các lỗ hổng có thể bị khai thác bởi mã độc.

- Botnet truyền thống: Đây là các con Bot được thiết kế để lây nhiễm trên máy tính cá nhân của người dùng, thông thường là chạy các hệ điều hành họ Windows.

- Mobile Botnet: Là dạng Botnet được thiết kế để lây nhiễm trên các thiết bị di động thông minh như điện thoại thông minh, máy tính bảng thông qua Internet. Các con Bot này thường đi kèm với các ứng dụng độc hại được vô tình cài lên thiết bị, thông thường là sử dụng hệ điều hành Android hoặc iOS.

- IoT Botnet: Đây là dạng Botnet mới nhất, hoạt động trên các thiết bị IoT, như các cảm biến, thiết bị gia đình thông minh, camera an ninh. Sự bùng nổ về số lượng của các thiết bị IoT cùng với năng lực xử lý ngày càng cao, thậm chí tiệm cận đến năng lực xử lý của máy tính cá nhân, cho phép các mạng IoT Botnet có thể phát triển với quy mô lớn hơn rất nhiều so với các mạng Botnet truyền thống, đồng nghĩa với việc tạo ra các cuộc tấn công có sức ảnh hưởng lớn hơn.

1.1.4.3. Phân loại theo kiến trúc

Có bốn loại kiến trúc của Botnet: Kiến trúc Agent-Handler, kiến trúc IRC-based, kiến trúc Peer-to-Peer, và các kiến trúc lai tiên tiến [37].

- Kiến trúc Agent-Handler (Hình 1.3): Trong đó, Agent là các con Bot còn Handler là hệ thống chỉ huy và kiểm soát hay là C&C Server. Lớp Handler đóng vai trò trung gian giữa Bot và BotMaster.

Kẻ tấn công giao tiếp với các C&C Server để thiết lập các cài đặt và kiểm soát hệ thống. Đây thường là một máy chủ mạnh mẽ với rất nhiều tài nguyên (băng thông, bộ nhớ và sức mạnh xử lý). Ngoài việc nhận lệnh từ kẻ tấn công, C&C Server còn có trách nhiệm theo dõi các Bot và gửi lệnh bao gồm cấu hình, cập nhật mới tới con Bot.

Chủ sở hữu của hệ thống máy tính bị xâm nhập thường không có biết rằng các phần mềm độc hại đã được cài đặt trong máy tính của họ hay họ là một phần của Botnet. Những kẻ tấn công sử dụng các con Bot như một bàn đạp để khởi động các cuộc tấn công chống lại các mục tiêu.

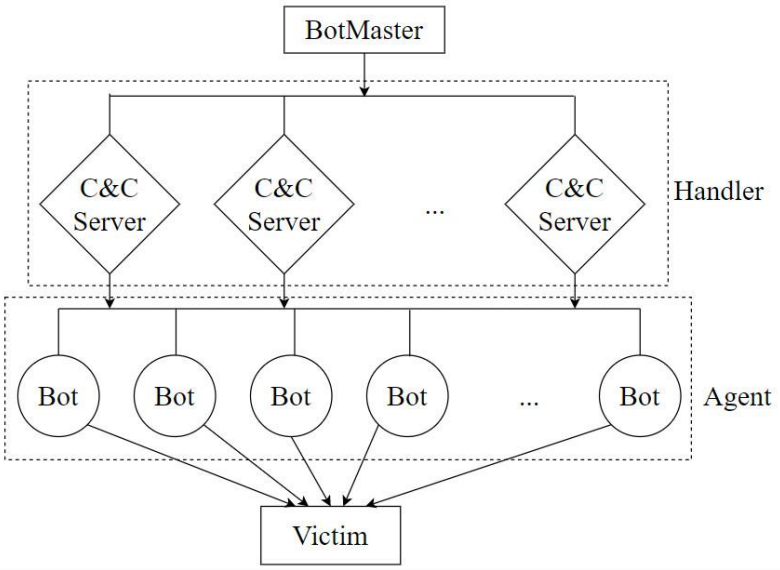

Hình 1.3. Kiến trúc Agent-Handler của Botnet

Kiến trúc Agent-Handler có một hạn chế lớn là kẻ tấn công phải có khả năng giao tiếp với các C&C Server cũng như C&C Server phải có khả năng liên lạc với các Bot. Nếu các kết nối trên bị gián đoạn thì kẻ tấn công có thể mất kiểm soát với một C&C Server, cũng như một C&C Server sẽ không kiểm soát được các Bot mà nó phụ trách. Điều này có thể dẫn đến việc không thể thiết lập cho các Bot để tấn công một mục tiêu mới.

- Kiến trúc IRC-Based (Hình 1.4): Kiến trúc Botnet Internet Relay Chat giải quyết các giới hạn trong kiến trúc Agent-Handler. Botnet IRC-Based thay thế các Handlers bằng các Public IRC Server.

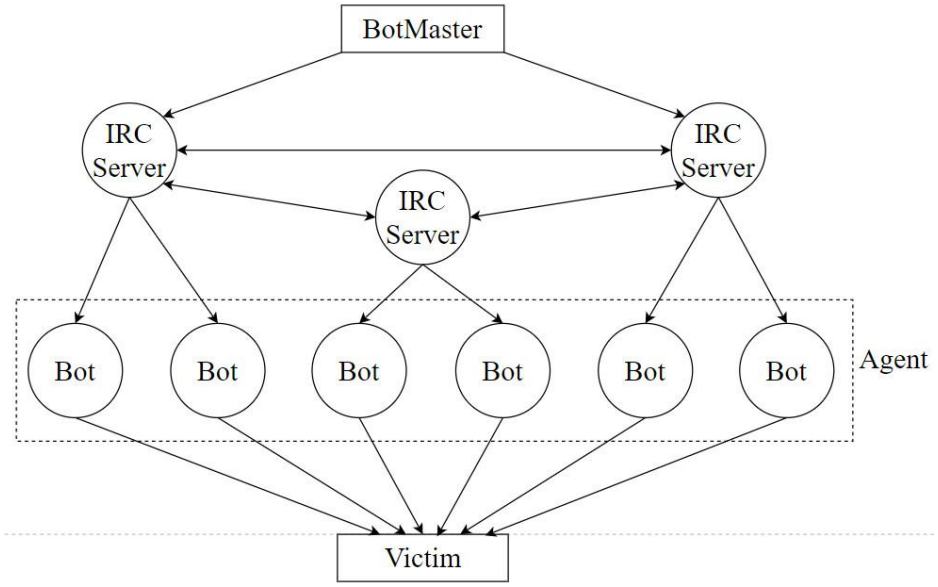

Hình 1.4. Kiến trúc IRC-Based của Botnet

Khi các Bot đã được triển khai, mỗi Bot sẽ kết nối đến một máy chủ IRC và chờ lệnh. Kẻ tấn công ra lệnh cho các Bot thông qua các kênh IRC sử dụng giao thức IRC. Nó cho phép mỗi Bot khởi đầu một hoặc cả hai hình thức tấn công. Nó cũng tạo nên một lớp phức tạp để che giấu các dấu vết của BotMaster. Thông tin liên lạc giữa BotMaster và các máy chủ IRC có thể được mã hóa. Khác biệt chính giữa các kiến trúc dựa trên IRC và kiến trúc Agent-Handler là cấu trúc điều khiển và thông tin liên lạc. Trong kiến trúc dựa trên IRC, mỗi Bot kết nối với một máy chủ IRC trong khi ở Agent-Handler, mỗi Bot có thể kết nối với nhiều hơn một C&C Server.

- Kiến trúc Peer-to-Peer (Hình 1.5): Không giống như kiến trúc Agent-Handler và IRC-based, cấu trúc Peer-to-Peer không có C&C Server riêng biệt. Lệnh được gửi đến các Bot bằng giao thức P2P. Mỗi Bot không chỉ chịu trách nhiệm cho việc chuyển tiếp lệnh tấn công mà còn là một phần của cơ cấu chỉ huy và kiểm soát để quản lý các Bot khác. Như vậy, kiến trúc P2P Botnet khó để đánh sập vì sự phân bố tự nhiên rất cao của nó.

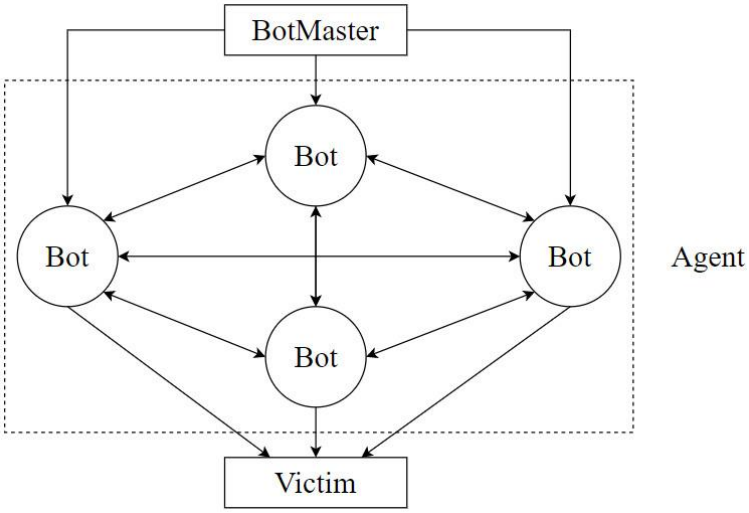

Hình 1.5. Kiến trúc Peer-to-Peer của Botnet

Ngoài việc phân phối lệnh, các kênh truyền thông P2P cũng được sử dụng để phân phối các phiên bản mới của phần mềm Bot, tải về công cụ tấn công mới hoặc một danh sách các mục tiêu mới. Việc phát hiện các thông tin liên lạc này là khó hơn nhiều vì sự phán tán của chúng, đồng thời dữ liệu cũng được mã hóa.

- Kiến trúc lai Peer-to-Peer tiên tiến: Kiến trúc Botnet lai Peer-to-Peer hoạt động với vai trò như cả máy khách và máy chủ trong một hệ thống chia sẻ tệp tin P2P truyền thống. Kẻ tấn công có thể chèn câu lệnh của mình vào bất kỳ máy chủ nào của các Botnet này. Mỗi máy chủ định kỳ sẽ kết nối với các Bot để cập nhật thông tin mới. Khi một lệnh mới xuất hiện, máy chủ sẽ chuyển lệnh này cho tất cả các Bot gần đó. Kiến trúc như vậy có các ưu điểm là một Bot chỉ biết một danh sách hạn chế của các bot xung quanh. Do đó, ngay cả khi bot này được phát hiện, những người điều tra cuộc tấn công cũng chỉ có thể có được danh sách hạn chế của các Bots, mà không phải là danh sách đầy đủ của toàn bộ mạng lưới. Mô hình này cũng giúp kẻ tấn công dễ dàng quản lý hoặc huy động toàn bộ mạng Botnet của mình bằng cách phát một lệnh duy nhất.

1.2. Kỹ thuật phát hiện Botnet

Hiện nay, có kỹ thuật chính được sử dụng để phát hiện Botnet [6]:

- (1) Các kỹ thuật dựa trên honeynet (mạng bẫy tin tặc).

- (2) Các kỹ thuật dựa trên hệ thống phát hiện xâm nhập (Intrusion Detection System - IDS), bao gồm:

+ Phát hiện Botnet dựa trên sự bất thường.

+ Phát hiện Botnet dựa trên chữ ký.

+ Phát hiện Botnet dựa trên tên miền.

Khái quát các kỹ thuật trên được trình bày tại Hình 1.6:

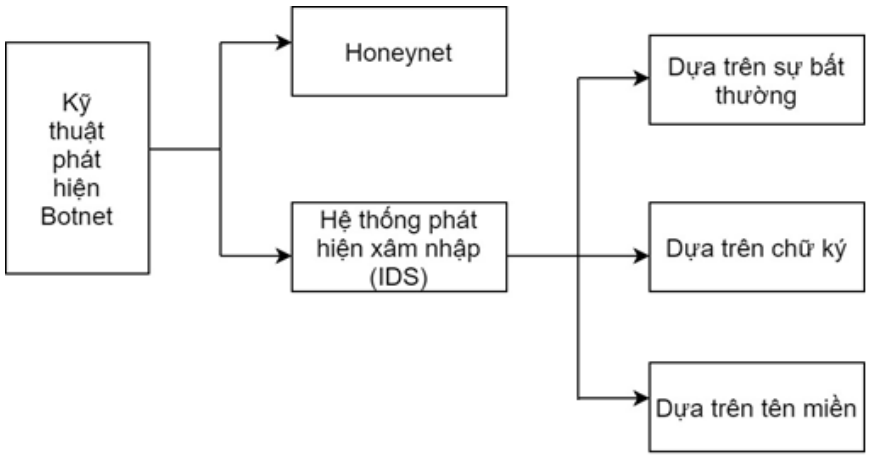

Hình 1.6. Khái quát về các kỹ thuật phát hiện Botnet

1.2.1. Kỹ thuật phát hiện Botnet sử dụng HoneyNet

1.2.1.1. Khái niệm HoneyNet

Honeynet là một hệ thống thông tin được xây dựng với mục đích giả dạng đánh lừa những tin tặc và các hành vi xâm nhập không hợp pháp. Honeynet thu hút sự chú ý và bí mật truy tìm thông tin của mục tiêu, đồng thời ngăn không cho chúng tiếp xúc với hệ thống thật.

Honeynet có thể giả dạng bất cứ loại máy chủ tài nguyên nào như là Mail Server, Domain Name Server, Web Server… Honeypot là một điểm trong HoneyNet sẽ trực tiếp tương tác với tin tặc và tìm cách khai thác thông tin về chúng như hình thức tấn công, công cụ tấn công hay cách thức tiến hành cuộc tấn công đó.

Honeynet gồm hai loại chính là tương tác thấp và tương tác cao:

- Tương tác thấp (Low Interaction): Mô phỏng giả lập các dịch vụ, ứng dụng và hệ điều hành. Mức độ rủi ro thấp, dễ triển khai và bảo dưỡng nhưng bị giới hạn về dịch vụ.

- Tương tác cao (High Interaction): Là các dịch vụ, ứng dụng và hệ điều hành thực. Mức độ thông tin thu thập được cao. Nhưng rủi ro cũng cao tương ứng và tốn nhiều thời gian để vận hành, bảo dưỡng.

1.2.1.2. Mô hình phát hiện Botnet dựa trên Honeynet

Từ ý tưởng đánh lừa kẻ tấn công ở trên, mạng Honeynet phát hiện Botnet được xây dựng để thu thập thông tin chi tiết về Botnet, như nguồn gốc của máy chủ C&C, các thành viên trong mạng hay các hành vi tấn công của chúng.

Mô hình xây dựng hệ thống Honeynet để phát hiện Botnet bao gồm Honeywall và Windows Honeypot, được minh họa tại Hình 1.7:

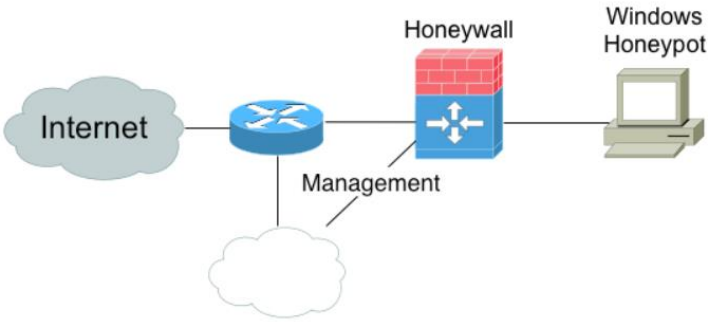

Hình 1.7. Mô hình mạng HoneyNet để phát hiện Botnet

Trong đó:

- Windows Honeypot: Là một hoặc nhiều máy tính cá nhân, được cài đặt các phiên bản hệ điều hành cũ hoặc chưa được vá lỗi kịp thời, nhằm tạo cơ hội cho Botnet lây nhiễm. Đây là sẽ mục tiêu ưu thích của các mạng Botnet.

- Honeywall: Đóng vai trò tương tự như tường lửa, nhưng thay vì mục đích ngăn chặn các cuộc tấn công của Botnet, thiết bị này được cấu hình để cho phép các Botnet đi qua và lây nhiễm theo như các chức năng mà chúng được thiết kế. Trong quá trình đó, Honeywall sẽ theo dõi và phân tích các hành vi, đặc trưng và chữ ký của Botnet, từ đó thu nhận được tri thức về Botnet để cập nhật cho Firewall trên các hệ thống thật sự.

1.2.2. Kỹ thuật phát hiện Botnet sử dụng hệ thống phát hiện xâm nhập

1.2.2.1. Phát hiện Botnet dựa trên sự bất thường

Kỹ thuật này thông qua việc phân tích lưu lượng mạng và hoạt động của máy tính để phát hiện sự cố bất thường như sự gia tăng đột ngột lưu lượng truy cập, lưu lượng đến cổng dịch vụ, độ trễ mạng cao, máy tính chịu tải cao và những dấu hiệu tương tự khác. Những bất thường này được sử dụng để so sánh với trạng thái bình

thường của hệ thống, từ đó phát hiện ra những mối đe dọa đã làm thay đổi hiện trạng hệ thống.

Một số hoạt động bất thường bao gồm:

- Phân tích các luồng dữ liệu mạng để phát hiện các hoạt động không đúng như: Các kết nối đến các cổng không thường xuyên hoặc kích thước gói tin lớn hơn mức bình thường.

- Trạng thái máy tính: Việc phát hiện botnet cũng có thể được thực hiện bằng cách theo dõi trạng thái của các máy tính trong mạng, bao gồm tình trạng tài nguyên của máy tính như sử dụng bộ nhớ, bộ vi xử lý và tốc độ đọc/ghi đĩa.

- Hành vi người dùng: Nếu có một số lượng lớn các truy cập vào cùng một tài khoản trong một khoảng thời gian ngắn, thì có thể đây là một tấn công giả mạo được thực hiện bởi các con Bot.

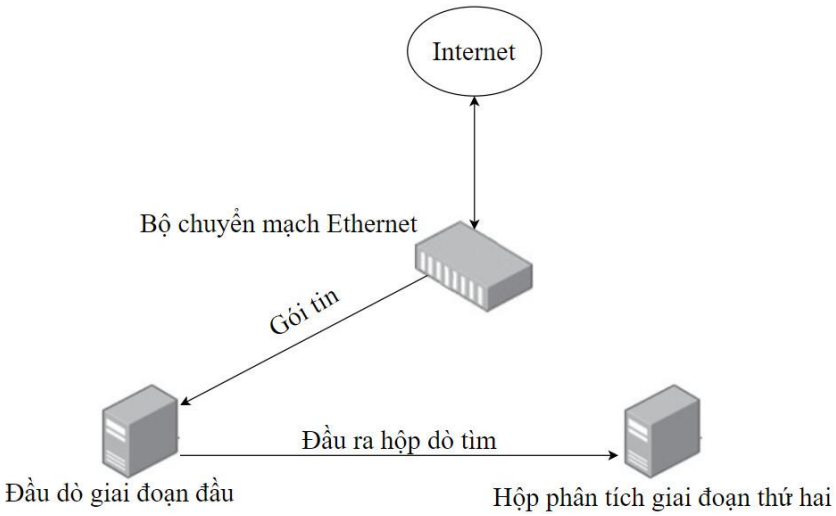

Hình 1.8. Minh họa cơ sở hạ tầng giám sát mạng

Hình 1.8 minh họa một mô hình khái quát nhất cho các trình theo dõi sự bất thường. Với lưu lượng Internet đi vào, quản trị viên có thể gắn đầu dò giai đoạn đầu vào bộ chuyển mạch Ethernet để dò gói tin. Đầu ra của hộp dò tìm được đưa tới Hộp phân tích giai đoạn thứ hai để thực hiện các chức năng như: Ghi nhật ký dữ liệu, phân tích và mô hình hóa lưu lượng. Bằng cách so sánh các thông số hiện tại với thông số bình thường, hệ thống có thể nhận biết các bất thường và xác định các nguy cơ tương ứng. Một số công cụ giám sát mạng thường được sử dụng khi áp dụng kỹ thuật này như SNMP hay Netflow.

Hạn chế của kỹ thuật phát hiện Botnet dựa trên sự bất thường đó là nó có thể tạo ra nhiều các cảnh báo giả. Hơn nữa, nó cũng không phát hiện được những botnet có hoạt động rất giống như hoạt động bình thường của các hệ thống mạng.

1.2.2.2. Phát hiện Botnet dựa trên chữ ký

Phát hiện Botnet dựa trên chữ ký là một cách tiếp cận truyền thống của phát hiện xâm nhập, có thể được áp dụng không chỉ với Botnet mà còn các loại virus, mã độc hay các phần mềm độc hại khác. Kỹ thuật này dựa trên cơ sở người quản trị đã có những tri thức về Botnet, họ thu thập và tổng hợp được một cơ sở dữ liệu các thông tin về Botnet và tạo nên khái niệm gọi là chữ ký của chúng, hay nói cách khác là những đặc trưng đã biết của Botnet. Chữ ký của Botnet có thể được thể hiện dưới nhiều dạng khác nhau. Chúng có thể đơn giản chỉ là một địa chỉ IP hay một chuỗi văn bản là giá trị băm, hoặc cũng có thể phức tạp hơn như là số lượng byte NULL xuất hiện sau một chuỗi xác định khi sử dụng một giao thức nào đó.

Khi áp dụng trong thực tế, kỹ thuật này tiến hành đối sánh các mẫu thu thập được với các mẫu đã biết để từ đó quyết định xem mẫu thu thập được có phải là một dạng Botnet đã biết hay không.

Các cơ sở dữ liệu chữ ký có thể chứa các chữ ký về Botnet, hay là chữ ký của các phần mềm, công cụ lành tính. Nói chung, mục tiêu của phương pháp này là nhận dạng nguy cơ dựa trên những tri thức đã biết. Hạn chế của nó là kém hiệu quả để phát hiện được các mối đe dọa mới, bởi vì cơ sở dữ liệu chữ ký luôn phải theo sau sự xuất hiện của các loại Botnet mới.

1.2.2.3. Phát hiện Botnet dựa trên tên miền

Nhiều họ Botnet khi lây nhiễm thành công vào máy tính của nạn nhân thì kết nối trở lại máy chủ thông qua những tên miền được sinh tự động, được gọi là DGA Botnet Những tên miền này có đặc điểm tương tự nhau và tuân theo cùng một thuật toán sinh đối với từng họ Botnet. Kỹ thuật phát hiện Botnet dựa trên tên miền vận dụng cơ chế trên để, nhà quản trị sẽ thu thập, giám sát lưu lượng DNS, từ đó có khả năng phát hiện ra các họ DGA Botnet đã bị lây nhiễm ở trong mạng, đồng thời gián tiếp tìm được địa chỉ của C&C Server.

Đầu vào của các thuật phát hiện DGA Botnet là các tên miền, bao gồm nhãn độc hại và nhãn lành tính. Nhãn lành tính là các tên miền thông thường, còn nhãn độc hại là các tên miền được sinh ra bởi DGA Botnet. Về cảm quan, có sự khác nhau cho phép phân biệt được giữa hai nhóm tên miền này. Trong một số trường hợp, các nhãn độc hại tiếp tục được phân loại nhỏ hơn để nhận diện từng họ Botnet nói riêng.

Một số kỹ thuật có thể được sử dụng để phát hiện DGA Botnet như sau:

- Kỹ thuật đối sánh tên miền: Kỹ thuật này đơn giản nhất và tương tự như việc phát hiện Botnet dựa trên chữ ký.

- Sử dụng các mô hình học máy, các thuật toán phân cụm dựa trên lý thuyết tập mờ, các kỹ thuật dựa trên xử lý văn bản… Thực tế cho thấy các mô hình này có độ chính xác khá tốt.

- Sử dụng học sâu: Sự phát triển trong năng lực của vi xử lý giúp cho các mô hình học sâu có thể chạy nhanh hơn, hiệu quả hơn, đưa công nghệ này trở nên khả thi hơn trong nhiều lĩnh vực, trong đó có phát hiện DGA Botnet.

1.3. Bài toán DGA Botnet

DGA - Domain Generation Algorithm là thuật toán sinh tên miền tự động. DGA Botnet là những Botnet sử dụng phương thức truy vấn tên miền được sinh tự động theo thuật toán để tìm địa chỉ IP của máy chủ điều khiển. Hai bài toán thường được nghiên cứu trong phát hiện DGA Botnet là bài toán phân lớp nhị phân và bài toán phân lớp đa lớp [38].

1.3.1. Khái quát về DGA Botnet

1.3.1.1. Vấn đề truy vấn C&C Server

Trong vòng đời Botnet, hoạt động truyền thông giữa con Bot với C&C Server đóng vai trò rất quan trọng. Hoạt động này giúp con Bot gửi các báo cáo, cập nhật mã nguồn hoặc nhận lệnh từ máy chủ C&C. Các Bot cần có địa chỉ IP để kết nối với máy chủ C&C. Dễ thấy rằng, việc thiết lập cố định một địa chỉ IP cố định cho C&C Server trong mã nguồn của con Bot là không thực tế. Bởi vì nhà quản trị có thể dễ dàng phát hiện và ngăn chặn chúng thông qua các giải pháp bảo mật như tường lửa, hệ thống phát hiện và ngăn chặn xâm nhập. Đồng thời, máy chủ C&C cũng dễ dàng bị lộ và có nguy cơ bị điều tra.

Để giải quyết vấn đề trên, các Bot sử dụng truy vấn tên miền như là một giải pháp hiệu quả để tìm đến địa chỉ máy của C&C. Ở những phiên bản Bot đầu tiên, có hai kỹ thuật đơn giản thường được sử dụng là Domain Name và Multihoming [39]:

- Kỹ thuật Domain Name sử dụng một vài tên miền để cùng trỏ đến một địa chỉ IP đích. Ví dụ:

```
domain01.com pointing to 192.168.1.1
domain02.com pointing to 192.168.1.2
domain03.com pointing to 192.168.1.2
domain04.net pointing to 192.168.1.2
domain05.net pointing to 192.168.1.3
domain06.net pointing to 192.168.1.3
```

Ta thấy rằng, địa chỉ IP là 192.168.1.2 được trỏ đến bởi ba tên miền khác nhau, bao gồm domain02.com, domain04.com và domain04.net.

- Kỹ thuật Multihoming cho phép nhiều tên miền cùng trỏ đến một địa chỉ IP đích. Khi đó, nếu một trong các địa chỉ IP không còn khả dụng, tên miền vẫn tìm được địa chỉ IP khác đang hoạt động để kết nối. Đối với Botnet, các địa chỉ IP này là các C&C Server.

```
domain01.com pointing to 192.168.1.1
domain01.com pointing to 192.168.1.2
domain01.com pointing to 192.168.1.3
domain01.com pointing to 192.168.1.4
domain01.com pointing to 192.168.1.5
domain01.com pointing to 192.168.1.6
```

Trong ví dụ trên, ta thấy rằng tên miền domain01.com trỏ đến các địa chỉ IP gồm 192.168.1.1 đến 192.168.1.6. Giả sử kết nối đến C&C Server đặt tại địa chỉ 192.168.1.1 bị chặn, các con Bot vẫn có thể sử dụng tên miền trên để truy cập đến các địa chỉ IP khác như 192.168.1.2, 192.168.1.3..., nơi có các C&C Server khác được dự phòng.

Nhìn chung, tuy có ưu điểm nhưng đây cũng chưa phải là một giải pháp hiệu quả trong thực tế bởi tính đơn giản và dễ bị nhận biết của nó.

1.3.1.2. Giải pháp truy vấn sử dụng DGA

Dịch vụ phân giải tên miền (DNS – Domain Name Service) là một dịch vụ phổ biến trên mạng Internet, cho phép phân giải tên máy, hoặc tên miền sang địa chỉ IP và ngược lại. Dịch vụ DNS được các con Bot sử dụng để qua mặt các hệ thống bảo vệ với kỹ thuật sinh tên miền tự động.

Để cải tiến hai phương pháp ở trên, giải pháp truy vấn địa chỉ IP thông qua thuật toán sinh tên miền sinh tự động gọi là Domain Generation Algorithm – DGA được áp dụng. Trong mô hình này, các máy chủ C&C và Bots sẽ cùng nhau thống nhất một thuật toán sinh tên miền. Vào mỗi thời điểm, các tên miền được sinh ra sẽ trỏ đến một IP được quy định bởi BotMaster. Các con Bot và C&C Server sẽ tuân theo thuật toán này để thay đổi IP tương ứng, giúp chúng vẫn tìm thấy địa chỉ của nhau nhưng có thể qua mặt được các hệ thống kiểm soát. Giải pháp này cải tiến hơn nhiều so với các giải pháp trước đó, cho phép các con Bot có thể truy vấn tới máy chủ với tỉ lệ bị phát hiện thấp hơn. Đồng thời, C&C Server cũng có thể dễ dàng ẩn mình hoặc thay đổi địa chỉ IP theo thời gian mà vẫn cho phép các con Bot tìm thấy được chúng.

1.3.1.3. Khái niệm DGA Botnet

DGA Botnet là khái niệm chỉ một dạng Botnet được triển khai theo mô hình Client-Server. Trong đó, các Bot đóng vai trò là Client sẽ liên kết trở lại máy chủ C&C - đóng vai trò là Server - thông qua các tên miền DNS được sinh một cách tự động và được thống nhất trước đó. Các tên miền này được sinh dựa trên quy tắc mà BotMaster quy định, và khác với các tên miền lành tính. Việc phát hiện các tên miền này là khó hơn nhiều và đây là phương pháp được phần lớn các con Bot sử dụng.

Các DGA Botnet sử dụng kỹ thuật DGA để sinh và đăng ký nhiều tên miền ngẫu nhiên khác nhau cho máy chủ C&C và điều khiển chúng nhằm chống lại việc bị kiểm soát và đưa vào danh sách đen. Các thuật toán sinh tên miền được thiết kế để cố gắng sinh ra các tên miền có thể qua mặt được các hệ thống bảo mật. Thuật toán DGA có thể sử dụng các toán tử kết hợp với các biến luôn thay đổi chẳng hạn như năm, tháng, ngày, giờ, phút để sinh tên miền ngẫu nhiên. Ví dụ, một dạng của thuật toán DGA được thực hiện bởi một hàm có chứa 16 vòng lặp, mỗi vòng lặp sinh ngẫu nhiên một ký tự trong tên miền như sau:

```
year = ((year ^ 8 * year) >> 11) ^ ((year & 0xFFFFFFF0) << 17)
month = ((month ^ 4 * month) >> 25) ^ 16 * (month & 0xFFFFFFF8)
day = ((day ^ (day << 13)) >> 19) ^ ((day & 0xFFFFFFFE) << 12)
domain += chr(((year ^ month ^ day) % 25) + 97)
```

Trong đó:

- Toán tử '^': Phép mũ.

- Toán tử '*': Phép nhân.

- Toán tử '%': Phép chia lấy phần dư.

- Toán tử '>>': Phép dịch bit sang phải.

- Toán tử '<<': Phép dịch bit sang trái.

- Toán tử '&': Phép AND.

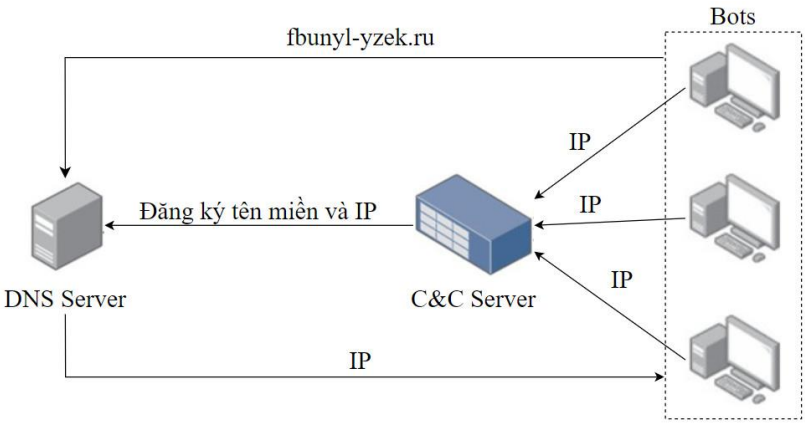

Hình 1.9. DGA Botnet sử dụng thuật toán sinh để tự động sinh và đăng ký các tên miền cho máy chủ C&C

Hình 1.9 biểu diễn cơ chế Botnet sử dụng thuật toán sinh DGA để tự động sinh và đăng ký các tên miền cho máy chủ C&C. Theo đó, máy chủ C&C và các bot sử dụng cùng một thuật toán DGA với cùng một nhân nên chúng có thể sinh ra cùng một tập các tên miền. DGA Botnet thường sử dụng ngày giờ như là nhân để khởi tạo thuật toán sinh tên miền và do đó, có một sự thống nhất giữa C&C Server và các con Bot.

Để khởi tạo kết nối đến máy chủ C&C, một Bot trước hết cần thực thi thuật toán DGA để sinh một tên miền và tên miền này cũng có thể được sinh tự động bởi máy chủ C&C và chung một nhân thời gian. Sau khi tạo được tên miền, Bot sử dụng hệ thống DNS để phân giải tên miền thành địa chỉ IP của máy chủ C&C. Nếu quá trình phân giải tên miền không thành công, Bot sử dụng DGA để sinh một tên miền

mới và lặp lại yêu cầu phân giải địa chỉ. Nếu quá trình phân giải tên miền thành công, Bot sử dụng địa chỉ IP để kết nối đến máy chủ C&C để nhận các lệnh và điều khiển từ BotMaster.

Việc giám sát và phân tích dữ liệu truy vấn DNS, đặc biệt là các tên miền và kết quả truy vấn có thể tiết lộ sự tồn tại của các hành vi độc hại trong hệ thống mạng do Botnet tạo ra. Do đó, nếu có thể phát hiện và ngăn chặn các truy vấn tên miền này, ta có thể gián tiếp xác định được địa chỉ IP của C&C Server, cô lập và hạn chế các hoạt động của con Bot khi chúng đã lây nhiễm vào máy tính.

1.3.2. Bài toán phân lớp nhị phân trong DGA Botnet

Bài toán phân lớp nhị phân: Là bài toán với mục tiêu phát hiện các tên miền được sinh ra bởi DGA Botnet trong số tất cả các tên miền được truy vấn trong luồng mạng. Bài toán phân lớp nhị phân được thực hiện trên bộ dữ liệu gồm có hai nhãn là 0 và 1. Trong đó, một tên miền lành tính sẽ được gán nhãn 0 và tên miền của Botnet sẽ được gán nhãn 1.

Minh họa về tên miền và nhãn tương ứng trong bài toán phân lớp nhị phân được trình bày tại Bảng 1.1:

Bảng 1.1. Minh họa dữ liệu và nhãn của bài toán phân lớp nhị phân

Tên miền	**Nhãn**	**Giải thích**
google.com.vn	0	google.com.vn là một tên miền lành tính
facebook.com	0	facebook.com là một tên miền lành tính
ofdhiydrrttpblp.com	1	ofdhiydrrttpblp.com là một tên miền độc hại được sinh ra bởi DGA Botnet
eimgukowkqeckykg.org	1	eimgukowkqeckykg.org là một tên miền độc hại được sinh ra bởi DGA Botnet

1.3.3. Bài toán phân lớp đa lớp trong DGA Botnet

Bài toán phân lớp đa lớp: Là bài toán nhằm mục tiêu phát hiện họ/chủng loại của DGA Botnet. Bài toán này có đầu vào là các tên miền đã được gán nhãn là DGA Botnet. Công việc phân lớp đa lớp được thực hiện trên bộ dữ liệu gồm có n nhãn, tương ứng với n họ DGA Botnet được xem xét. Các nhãn được đánh số i có giá trị từ 1 đến n, với i tương ứng là họ của DGA Botnet.

Bảng 1.2 minh họa về tên miền và nhãn tương ứng của DGA Botnet trong bài toán phân lớp đa lớp, với 03 nhãn được thể hiện.

Bảng 1.2. Minh họa dữ liệu và nhãn trong bài toán phân lớp đa lớp với 03 nhãn

Tên miền	**Nhãn**	**Họ DGA Botnet**	**Giải thích**
qkdchxxxzn.com meojytusps.com	1	alureon	Đây là tên miền DGA Botnet thuộc về họ alureon
ofdhiydrrttpblp.com aaifkidvjspwc.biz	2	cryptolocker	Đây là tên miền DGA Botnet thuộc về họ cryptolocker
eimgukowkqeckykg.org uowgugsysycoqeqs.org	3	ramdo	Đây là tên miền DGA Botnet thuộc về họ ramdo

1.3.4. Phân biệt với bài toán phát hiện URL giả mạo

Bài toán phát hiện DGA Botnet có những nét tương đồng với bài toán phát hiện các Uniform Resource Locator - URL giả mạo. Tuy nhiên chúng lại có những đặc điểm khác nhau trong cả dữ liệu vào và phương thức tiếp cận.

Trong nghiên cứu [40], Corona và cộng sự đã đề xuất một giải pháp là DeltaPhish để phát hiện các trang web giả mạo. Họ đánh giá rằng, các trang web giả mạo được tin tặc tạo ra để đánh cắp thông tin cá nhân, lừa đảo, quảng cáo hoặc kiếm tiền. Việc bấm vào các URL độc hại sẽ đưa người dùng chuyển hướng tới các trang web giả mạo, nơi mà họ có thể đối mặt với các nguy hiểm đến từ tội phạm mạng. Giải pháp của họ là thông qua việc phân tích sự khác biệt giữa các trang đã truy cập và trang tham chiếu được xác định từ trước, để đưa ra kết luận là trang web này có giả mạo hay không. Họ dựa trên mã nguồn HTML và sự xuất hiện trực quan của mỗi trang web để trích xuất các thuộc tính từ đó. Các thuộc tính này được đưa qua bộ phân loại Fussion để cho ra nhãn Phishing hoặc Legitimate. Bộ dữ liệu đánh giá gồm 5.6GB chứa cả URL và HTML code của một số webpage giả mạo. Độ chính xác đạt được cho phát hiện Website giả mạo là 99%.

Marchal và cộng sự cũng phát triển giải pháp là PhishStorm nhằm phát hiện các website giả mạo [41]. Khác với DeltaPhish khi xem xét cả mã nguồn HTML, giải pháp PhishStorm đánh giá một một trang web có giả mạo hay không chủ yếu dựa trên phân tích URL của nó. Họ sử dụng một số mô hình học máy để phân loại URL là giả mạo hay lành tính. Độ chính xác đạt được là 94.91%.

Nhìn chung, mặc dù có một số nét khá tương đồng, nhưng bài toán phát hiện trang web giả mạo và phát hiện DGA botnet có những đặc điểm khác nhau. NCS tóm tắt ở Bảng 1.3, bao gồm các điểm khác nhau chính như sau:

Bảng 1.3. So sánh bài toán phát hiện Website giả mạo và bài toán DGA botnet

	Đầu vào	**Mục tiêu**	**Nhãn phân lớp nhị phân**	**Nhãn phân lớp đa lớp**	**Thuật toán DGA**
Phát hiện Website giả mạo	URLs / HTML Code	Trang Web giả mạo	0: Website lành tính 1: Website giả mạo	NULL	Không
Phát hiện và phân loại DGA Botnet	Tên miền	Địa chỉ IP của C&C Server	0: Tên miền lành tính 1: Tên miền độc hại	n nhãn tương ứng với n họ DGA Botnet	Có

- Đầu tiên, dữ liệu đầu vào của bài toán DGA Botnet chỉ là tên miền, trong khi đó đối với bài toán phát hiện URL giả mạo thì đó là các URL và HTML Code. Cần lưu ý rằng, khái niệm URL khác với khái niệm tên miền.

- Thứ hai, trong bài toán phát hiện DGA Botnet, các tên miền được trỏ đến địa chỉ IP của C&C Server. Ngược lại, các URL độc hại đưa người dùng đến các webpage với nội dung giả mạo, độc hại.

- Thứ ba, vấn đề DGA Botnet gồm hai bài toán phân lớp nhị phân và phân lớp đa lớp. Trong khi đó, các URL chỉ được đánh giá với hai nhãn là giả mạo hoặc lành tính mà không có nhãn cho bài toán phân lớp đa lớp.

- Cuối cùng, các thuật toán sinh tên miền xuất hiện trong bài toán DGA Botnet, mà không xuất hiện trong bài toán Website giả mạo.

1.3.5. Bộ dữ liệu đánh giá cho bài toán DGA Botnet

Một số bộ dữ liệu chuyên dùng cho đánh giá bài toán DGA Botnet đã được công bố. NCS lựa chọn 04 bộ dữ liệu được xem là phù hợp nhất cho các đánh giá thuật toán được trình bày ở các chương sau, bao gồm: Andrey Abakumov's DGA Repository [20], OSINT DGA feed [23], UMUDGA Dataset [18] và 360NetLab Dataset [24]:

- Andrey Abakymov’s DGA Repository (AADR): Đây là kho lưu trữ được tạo vào năm 2016 bởi Andrey Abakumov, bao gồm mã nguồn các thuật toán tạo tên miền tự động và các tên miền DGA độc hại. Top 1.000.000 tên miền phổ biến của Alexa cũng được sử dụng và gán nhãn là lành tính. Bộ dữ liệu này đã được nhiều nghiên cứu trước đó sử dụng để đánh giá giải pháp của họ. Dữ liệu được công bố công khai trên GitHub.

- OSINT DGA feed (OSINT): Là một bộ dữ liệu đáng tin cậy, được tạo bởi Bambenek, với một khối lượng lớn các tên miền độc hại được thu thập và tổng hợp. Dữ liệu này được chia sẻ miễn phí cho cộng đồng khoa học và không được cho phép sử dụng vào các mục đích thương mại.

- UMUDGA Dataset (UMUDGA): Bộ dữ liệu được tổng hợp, xây dựng bởi Zago và cộng sự thuộc trường đại học University of Murcia. Đây là bộ dữ liệu có thể xem là đầy đủ nhất hiện nay, khi tổng hợp được 50 họ DGA Botnet. Mỗi họ có từ 10.000 đến 500.000 mẫu tên miền. Các dữ liệu được bố trí một cách khoa học, dưới các dạng ARFF, CSV và TXT, phù hợp với các công cụ và ngôn ngữ lập trình khác nhau. Toàn bộ dữ liệu có thể dễ dàng tiếp cận trên Mendeley Data, đảm bảo tính tin cậy và công bố rộng rãi.

- 360NetLab Dataset (360NetLab): Là bộ dữ liệu gồm các tên miền độc hại thu thập từ thế giới thực, được xây dựng bởi nhóm nghiên cứu 360NetLab, Qihoo 360 Technology Co.,Ltd. Máy tìm kiếm sẽ liên tục tìm và phát hiện các mẫu DGA Botnet mới nhất để cập nhật vào cơ sở dữ liệu. Tuy nhiên, hạn chế của bộ dữ liệu này là thiếu tính ổn định khi liên tục thay đổi theo thời gian thực.

Chi tiết về số lượng tên miền và tính chất của các bộ dữ liệu cho bởi Bảng 1.4:

Bảng 1.4. Mô tả về 04 bộ dữ liệu được sử dụng trong các đánh giá

Bộ dữ liệu	**Phân lớp nhị phân**	**Phân lớp đa lớp**	**Số mẫu lành tính**	**Số mẫu DGA Botnet**	**Số họ DGA Botnet**
AADR	X	X	1.000.000	801.667	08
OSINT	X		1.000.000	495.186	
UMUDGA	X	X	1.000.000	500.000	50
360NetLab	X		1.000.000	1.513.524	

1.3.6. Thông số đánh giá thuật toán

1.3.6.1. Tham số đánh giá cho bài toán phân lớp nhị phân

Đối với bài toán phân lớp nhị phân, với nhãn 0 là tên miền lành tính, nhãn 1 là tên miền DGA Botnet, ta định nghĩa:

- TP: Số lượng mẫu tên miền độc hại được phân loại đúng là độc hại.

- TN: Số lượng mẫu tên miền là lành tính được phân loại đúng là lành tính.

- FP: Số lượng mẫu tên miền lành tính được phân loại sai thành độc hại.

- FN: Số lượng mẫu tên miền độc hại được phân loại sai thành lành tính.

NCS đánh giá hiệu quả của giải pháp phân lớp nhị phân thông qua các tham số gồm Accuracy, Precision, Recall và F_1-score, lần lượt được tính bằng các công thức dưới đây:

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1.1)$$

Accuracy giúp đánh giá độ chính xác chung của mô hình, bao gồm việc phát hiện đúng tên miền là lành tính hoặc tên miền là độc hại.

$$Precision = \frac{TP}{TP + FP} \quad (1.2)$$

$$Recall = \frac{TP}{TP + FN} \quad (1.3)$$

Precision và Recall đánh giá riêng về khả năng phát hiện đúng một tên miền lành tính hay một tên miền độc hại trên tổng số lượng mẫu của tên miền đó. Nhìn chung, việc phát hiện nhầm một tên miền lành tính thành độc hại sẽ ít gây nguy hiểm hơn là việc chấp nhận nhầm một tên miền độc hại là lành tính.

$$F_1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (1.4)$$

$F_1 - score$ là đại lượng dùng chung để đánh giá một cách tổng thể giữa Precison và Recall trong mô hình.

1.3.6.2. Tham số đánh giá trung bình cho nhiều lớp

Đối với các bài toán phân lớp có nhiều lớp, NCS sử dụng phương pháp tính Weighted Averrage để đánh giá hiệu quả phân loại trung bình cho tất cả các lớp với các giá trị tương ứng là $Avg\ Accuracy$, $Avg\ Precision$, ($Avg\ Recall$ và $Avg\ F_1 - score$. Các thông số trung bình này được đánh giá dựa trên Accurcy, Precision, Recall và F_1-Score của từng lớp và số lượng mẫu phân loại tương ứng, lần lượt được tính bởi các công thức (1.5), (1.6), (1.7) và (1.8) như sau:

$$Avg\ Accuracy = \frac{\sum_{i=1}^{n}(Support_i \times Accuracy_i)}{\sum_{i=1}^{n} Support_i} \quad (1.5)$$

$$Avg\ Precision = \frac{\sum_{i=1}^{n}(Support_i \times Precision_i)}{\sum_{i=1}^{n} Support_i} \quad (1.6)$$

$$Avg\ Recall = \frac{\sum_{i=1}^{n}(Support_i \times Recall_i)}{\sum_{i=1}^{n} Support_i} \quad (1.7)$$

$$Avg\ F_1 - score = \frac{\sum_{i=1}^{n}(Support_i \times F_1 - score_i)}{\sum_{i=1}^{n} Support_i} \quad (1.8)$$

Trong đó, $Support_i$ là số lượng được phân loại có nhãn i với $1 \leq i \leq n$.

Dựa trên yêu cầu của bài toán, NCS linh hoạt sử dụng các tham số phù hợp cho việc đánh giá kết quả phân loại. Đối với từng lớp, NCS sử dụng các giá trị Accuracy, Precision, Recall và F_1-score được tính bằng công thức (1.1), (1.2), (1.3) và (1.4). Trong trường hợp đánh giá tổng thể từng bộ phân loại, NCS sử dụng các giá trị Avg Accuracy, Avg Precision, Avg Recall và Avg F_1-score được tính bằng công thức (1.5), (1.6), (1.7) và (1.8) và linh hoạt trong ký hiệu có hoặc không có tiền tố Avg để thuận tiện cho việc trình bày sơ đồ, bảng biểu.

1.3.7. Ý nghĩa của bài toán DGA Botnet

Botnet ngày càng phát triển, các con Bot được thiết kế không chỉ để lây nhiễm trên các thiết bị truyền thống như máy tính cá nhân, laptop, mà còn có khả năng lây nhiễm trên các thiết bị IoT như CCTV, tivi thông minh, tủ lạnh thông minh… Quy mô của mạng Botnet hiện đại có thể mở rộng hơn rất nhiều so với các mạng Botnet truyền thống, từ đó cho phép chúng có khả năng tấn công với quy mô, cường độ mạnh hơn, gây ra những thiệt hại lớn và lâu dài hơn cho nạn nhân.

Botnet có nhiều phương thức để lây nhiễm vào thiết bị, chúng cũng liên tục cải tiến mã nguồn để có thể lây nhiễm và ẩn mình hiệu quả hơn. Có một số phương án được đưa ra, gồm các giai đoạn như: Phòng chống lây nhiễm, rà quét mã độc và ngăn chặn các cuộc tấn công khi nó đang diễn ra. Mỗi phương án đều có những ưu điểm và hạn chế riêng.

Vận dụng cơ chế hoạt động của thuật toán sinh tên miền có thể mang lại một giải pháp hiệu quả và mang lại nhiều ưu điểm để phát hiện và ngăn chặn DGA Botnet. Các thuật toán để giải quyết bài toán DGA Botnet có đối tượng đầu vào là lưu lượng DNS, không đòi hỏi quá nhiều năng lực thu thập và xử lý của hệ thống. Việc phát hiện hoạt động của DGA Botnet diễn kể ra khi bằng cách nào đó chúng đã lây nhiễm vào máy tính, gián tiếp cho phép tìm kiếm địa chỉ của C&C Server. Đồng thời, chúng cũng bị vô hiệu hóa một cách hiệu quả nếu hệ thống phát hiện và ngăn chặn kết nối của chúng ra bên ngoài. Một ưu điểm nữa là thuật toán cho bài toán DGA Botnet hoàn toàn có thể áp dụng cho việc phát hiện những phần mềm, mã độc có hành vi truy vấn DNS tương tự. Đặc biệt là các phần mềm, mã độc có hành vi nghe lén, tình báo vì chúng có xu hướng cần kết nối ra bên ngoài.

Các thuật toán, giải pháp đề xuất để giải quyết bài toán phân lớp nhị phân và phân lớp đa lớp trong DGA Botnet có thể được áp dụng vào các giải pháp bảo mật như tường lửa, hệ thống phát hiện và ngăn chặn xâm nhập, mudule phát hiện mã độc trong thiết bị UTM hay các giải pháp đảm bảo an ninh tương tự.

1.4. Một số nghiên cứu giải quyết bài toán DGA Botnet

Một số hướng tiếp cận đã được đề xuất để phát hiện Botnet nói chung và DGA Botnet nói riêng, bao gồm các phương pháp như: Các kỹ thuật phân tích DNS; các thuật toán học máy và học sâu.

1.4.1. Hướng tiếp cận sử dụng các kỹ thuật phân tích DNS

Trong [7], Alieyan và cộng sự trình bày các kỹ thuật để khám phá mạng Botnet khác nhau thông qua phân tích lưu lượng DNS. Đây cũng là cuộc khảo sát để thảo luận các kỹ thuật phát hiện Botnet dựa trên DNS. Trong đó đưa ra và làm rõ các vấn đề, giải pháp hiện tại và hướng nghiên cứu trong lĩnh vực phát hiện Botnet dựa trên phân tích lưu lượng DNS trong tương lai.

Trong nghiên cứu [8], tác giả Kwon và cộng sự đã lập luận rằng, có thể trích xuất được nhiều thông tin bảo mật quan trọng dựa trên lưu lượng DNS. Tuy nhiên, trong trường hợp lưu lượng các truy vấn DNS có mức độ lớn thì việc phân tích gặp nhiều khó khăn. Các nghiên cứu cũng bị hạn chế tiêu cực bởi số lượng lớn các truy vấn và tên miền. Nhóm tác giả giới thiệu một hướng tiếp cận nhanh, được gọi là PsyBoG, dùng để phát hiện hành vi độc hại dựa trên phân tích một lượng lớn lưu lượng DNS. Giải pháp đề xuất sử dụng kỹ thuật xử lý tín hiệu, phân tích mật độ phổ năng lượng PSD để phát hiện các truy vấn DNS định kỳ của Botnet. Giải pháp PsyBoG có các ưu điểm bao gồm: (1) Phát hiện các mạng Botnet có khả năng ẩn mình tinh vi; (2) Cho phép xử lý các truy vấn DNS trên quy mô lớn và (3) Có khả năng phát hiện các nhóm máy chủ có hành vi độc hại.

Giải pháp đề xuất được đánh giá dựa trên 755 DNS Traces thu thập trong một mạng thực, đã bao gồm các lưu lượng độc hại. Kết hợp với 756 lưu lượng truy cập máy chủ DNS thực. Kết quả thử nghiệm cho thấy PsyBoG có khả năng phát hiện chính xác với tỉ lệ 95%, đồng thời chứng minh tính hiệu quả và khả năng ứng dụng trong thực tế khi có thể hoạt động với lưu lượng DNS lớn. Trong các lưu lượng DNS trên, nhóm nghiên cứu cũng phát hiện được 23 họ Botnet chưa biết, 26 họ Botnet đã biết với tỉ lệ dương tính giả chỉ 0,1%.

Wang và cộng sự phát hiện Botnet dựa trên phân tích tên miền [9]. Họ đề xuất một sơ đồ phát hiện Botnet dựa trên DGA, gọi là DBod. Giải pháp này dựa trên phân tích hành vi truy vấn DNS. Thử nghiệm thực tế trên các máy chủ và nhận thấy rằng hầu hết các truy vấn độc hại đều bị chặn bắt. Tính khả thi của giải pháp được thể hiện thông qua việc đánh giá trên bộ dữ liệu mạng thu được trong môi trường giáo dục trong thời gian 26 tháng, với quy mô khoảng 10.000 người dùng. Kết quả cho thấy giải pháp đề xuất có khả năng phát hiện Botnet với độ chính xác trên 99%. Tuy nhiên, hạn chế của nghiên cứu đó là số mẫu trong bộ dữ liệu đánh giá còn nhỏ, chỉ gồm 04 họ DGA Botnet được xem xét tới gồm Kraken, Conficker, Cycbot và Murofet, cũng như chưa có sự nghiên cứu rộng rãi trên các bộ dữ liệu tiêu chuẩn khác.

Chowdhury và cộng sự nhận xét rằng, Botnet ngày càng trở nên tinh vi và có khả năng tấn công gây thiệt hại to lớn hơn [42]. Hầu hết các phương pháp phát hiện Botnet dựa trên luật hay lưu lượng mạng tỏ ra không thật sự hoàn hảo. Do đó, việc xây dựng một phương pháp có khả năng phát hiện nhanh và mạnh mẽ có ý nghĩa quan

trọng. Trong nghiên cứu của mình, nhóm tác giả đề xuất một phương pháp phát hiện Botnet mới dựa trên đặc điểm cấu trúc liên kết của các nút trong đồ thị, bao gồm: Bậc, bán bậc ra, bán bậc vào, trọng số của bán bậc ra và bán bậc vào, hệ số phân cụm... Phương pháp phân cụm dựa trên bản đồ tự tổ chức được áp dụng để thiết lập các cụm nút trong mạng. Phương pháp đề xuất có khả năng cô lập Bot trong các cụm có kích thước nhỏ, trong khi cũng chứa phần lớn các nút bình thường trong cùng một cụm lớn. Khi đó, các con Bot có thể được phát hiện bằng cách tìm kiếm một số lượng hạn chế các node. Bên cạnh đó, một quy trình lọc cũng được đề xuất để nâng cao tính chính xác của thuật toán. Nghiên cứu được đánh giá trên bộ dữ liệu CTU-13 [43]. Kết quả cho thấy phương pháp đề xuất có thể phát hiện các con Bot một cách hiệu quả, dù cho các hành vi của chúng là khác nhau.

Trong nghiên cứu [10], Bisio và cộng sự đã trình bày báo cáo về thuật toán phát hiện DGA Botnet dựa trên một Single Network Monitoring. Các giai đoạn của giải pháp đề xuất bao gồm: (1) Phát hiện một Bot đang tìm kiếm máy chủ C&C và các tên miền được sinh ra tự động có liên quan; (2) Phân tích các yêu cầu DNS đã được giải quyết trong cùng một khoảng thời gian. Sau đó, các đặc điểm về ngôn ngữ và ngữ nghĩa được phân lớp chúng vào một họ DGA cụ thể. Cuối cùng (3), các cụm được phân tích để giảm thiểu hiện tượng dương tính giả. Giải pháp đề xuất được đánh giá trên hai môi trường, bao gồm một môi trường mạng đặc biệt được xây dựng, với các họ DGA Botnet đã được gán nhãn. Môi trường thứ hai là mạng nội bộ LAN của một công ty. Trong thí nghiệm đầu tiên, tất cả các họ DGA Botnet đều được phát hiện. Với thí nghiệm thứ hai, thuật toán đã phát hiện ra một máy chủ bị nhiễm mã độc trong một quá trình đánh giá kéo dài 15 ngày. Bộ dữ liệu thử nghiệm bao gồm 40 họ DGA Botnet khác nhau, với khả năng phát hiện hầu hết các họ DGA Botnet với độ chính xác cao từ 92,67% trở lên, duy nhất một trường hợp đạt 88,85%.

Wang và cộng sự giới thiệu một cách tiếp cận bao gồm: (1) Phát hiện sự hiện diện của Botnet và (2) Xác định các nút bị lây nhiễm [44]. Trong giai đoạn đầu tiên, các bất thường sẽ được phát hiện bằng cách tính toán sự chênh lệch giữa trạng thái hiện tại và các trạng thái trước đó, gọi là phân phối theo kinh nghiệm. Ở giai đoạn thứ hai, các con Bot được phát hiện dựa trên ý tưởng xây dựng cộng đồng mạng xã hội trong một biểu đồ, ghi lại mối tương quan và tương tác giữa các nút theo thời gian. Việc phát hiện cộng đồng được thực hiện bằng cách tối đa hóa thước đo module

trong biểu đồ này. Nhóm nghiên cứu đánh giá phương pháp đề xuất bằng lưu lượng truy cập Botnet trong thế giới thực và so sánh với các nghiên cứu khác. Tuy nhiên, các kết quả đánh giá chưa được thảo luận một cách kỹ lưỡng.

Trung và cộng sự [11] trình bày các nghiên cứu mở rộng của Botnet trên các thiết bị IoT. Chúng có các khả năng tương tự với Botnet truyền thống, có khả năng tạo nên những cuộc tấn công từ chối dịch vụ quy mô lớn. Mối đe dọa này càng tăng khi mà các cơ chế bảo mật cho thiết bị IoT chưa thực sự đầy đủ. Các thiết bị IoT có những đặc điểm hạn chế riêng về hệ điều hành, khả năng xử lý cũng như nguồn năng lượng. Hầu hết các nghiên cứu trước đó chưa giải quyết vấn đề đa kiến trúc và cần tiết kiệm tài nguyên xử lý trên các thiết bị IoT. Đòi hỏi một giải pháp cần ít tài nguyên xử lý hơn.

Trong nghiên cứu của mình, nhóm tác giả đề xuất một phương pháp phát hiện IoT Botnet, dựa trên việc trích xuất các thuộc tính từ đồ thị PSI (PGS-Graph). Giải pháp này có thể khắc phục được vấn đề đa kiến trúc trong thiết bị IoT, đồng thời giảm thiểu sự phức tạp tính toán. Kết quả thử nghiệm cho thấy, giải pháp đề xuất đạt độ chính xác 98,7%. Bộ dữ liệu thử nghiệm gồm 11.200 tệp ELF chứa 7.199 mẫu Botnet IoT và 4.001 mẫu lành tính. Dữ liệu được thu thập từ IoTPOT Team [45] và VirusShare [46]. So sánh với một số nghiên cứu khác cho thấy mô hình đề xuất cho kết quả tốt hơn. Mã nguồn của giải pháp cũng được công bố trên GitHub.

1.4.2. Hướng tiếp cận dựa trên học máy

Trong một nghiên cứu tiếp cận theo hướng sử dụng học máy, Hiếu và cộng sự đã đánh giá độ hiệu quả các các thuật toán học máy có giám sát trong việc phát hiện DGA Botnet [12]. Với dữ liệu đầu vào là các tiên miền, nhóm nghiên cứu xây dựng các mô hình bao gồm: Hidden Markov, C4.5 Decision Tree, Extreme Learing Machine. Đồng thời cũng thí nghiệm trên các mô hình SVM, Recurrent SVM, CNN kết hợp LSTM và Bidirectional LSTM. Các đánh giá được thực hiện trên bộ dữ liệu gồm 1.000.000 tên miền lành tính của Alexa được gán nhãn non-DGA [47], và 37 họ DGA Botnet được gán nhãn DGA. Các họ DGA Botnet này được tổng hợp từ OSINT DGA feed from Bambenek Consulting, với 81.490 tên miền. Kết quả thử nghiệm cho thấy, trong bài toán phân lớp nhị phân, các mô hình dựa trên SVM và LSTM cho kết quả với độ chính xác từ 99,55% trở lên, cao hơn đáng kể so với các mô hình học máy

truyền thống. Đối với bài toán phân loại đa lớp, các kết quả thu được chưa thực sự khả quan, đặc biệt là có 08 họ DGA Botnet không phát hiện được bởi các mô hình học máy có giám sát.

Trong một nghiên cứu khác, Khan và cộng sự xem xét tới việc phát hiện các mạng Botnet ngang hàng (Peer-to-Peer) [13]. Họ lập luận rằng việc phát hiện các mô hình Botnet dạng này đặt ra các thách thức nhiều hơn so với Botnet sử dụng giao thức Internet Relay Chat - IRC hay giao thức truyền tải siêu văn bản HTTP. Để giải quyết vấn đề trên, nhóm nghiên cứu đề xuất một phương pháp phân loại lưu lượng đa lớp bằng cách áp dụng các mô hình học máy. Đầu tiên, các thuộc tính phù hợp sẽ được lựa chọn, đồng nghĩa với việc loại bỏ những thuộc tính dư thừa dựa trên thuật toán cây quyết định. Các gói tin không phải là P2P cũng được loại bỏ để giảm thiểu lưu lượng qua các cổng mạng. Tiếp theo, lớp thứ hai thực hiện phân lớp lưu lượng thành hai nhóm là P2P và không phải P2P. Ở lớp cuối cùng, nhóm nghiên cứu đề xuất sử dụng bộ phân loại cây quyết định để phát hiện mạng P2P Botnet. Độ chính xác trung bình đạt được là 98,7%. Các thí nghiệm được thực hiện trên bộ dữ liệu CTU-13 và ISOT Dataset.

Zago và cộng sự [18] trình bày một nghiên cứu về bộ dữ liệu mới cho phát hiện DGA Botnet. Nhóm nghiên cứu tổng hợp và xây dựng thành bộ dữ liệu mới với tên gọi là UMUDGA Dataset. Bộ dữ liệu này bao gồm 1.000.000 tên miền lành tính kết hợp với 50 họ DGA Botnet khác nhau, mỗi họ DGA Botnet chứa mã nguồn tự động sinh tên miền, các tên miền mẫu với số lượng từ 10.000 đến 500.000 đối với mỗi họ. Các đánh giá ban đầu của nhóm tác giả cho thấy, thuật toán SVM cho F^{+}-Score cao nhất trong các mô hình học máy truyền thống, đạt 98,9% cho bài toán phân lớp nhị phân [21]. Đối với bài toán phân lớp đa lớp, các thuật toán này tỏ ra chưa hiệu quả khi F_1-Score đều ở dưới mức 80%.

Trong một công bố gần đây, Xuân và cộng sự [14] đã đề xuất những cải tiến cho mô hình học máy. Họ đề xuất sử dụng các thuộc tính mới và áp dụng trên thuật toán rừng ngẫu nhiên. Kết quả cho thấy thuật toán mới giúp giảm tỉ lệ cảnh báo nhầm cũng như tăng tỉ lệ phát hiện tên miền của DGA Botnet. Cụ thể, mô hình có thể lệ cảnh báo sai dưới 3,02% và điểm F_1-score đạt 97,03% trong các đánh giá.

Suryotrisongko và cộng sự [48] giới thiệu một hướng tiếp cận mới sử dụng các mô hình học máy lượng tử lai để phát hiện DGA Botnet. Họ phân tích hiệu suất của mô hình lai so với mô hình truyền thống để nghiên cứu hiệu quả của mạch lượng tử như một lớp trong một mô hình học sâu. Nhóm nghiên cứu sử dụng bốn đặc trưng được trích xuất từ DGA Botnet bao gồm MinREBotnets, CharLength, TreeNewFeature và nGramReputation_Alexa. Mạch lượng tử của mô hình hybrid là sự kết hợp của các kỹ thuật nhúng và mạch lớp. Kỹ thuật gây nhiễu cũng được áp dụng để đánh giá khả năng thích ứng của mô hình đối với nhiễu. Kết quả thực nghiệm cho thấy, trong một số trường hợp, mô hình lai đạt hiệu suất cao (độ chính xác tối đa lên đến 94,7% với n=100 và đạt 93,9% với n=1.000). Cách tiếp cận trên mang lại độ chính xác cao, vượt trội hơn so với mô hình học sâu truyền thống trong các thử nghiệm với n=100. Tuy nhiên, hiệu suất tổng thể vẫn kém hơn trong các trường hợp còn lại. Mô hình này gợi ý một hướng nghiên cứu tiềm năng trong tương lai để phát hiện DGA Botnet.

Zhao và cộng sự [49] đề xuất phương pháp DOmain Linguistic PHonIcs detectioN (DOLPHIN) để phát hiện DGA Botnet. Dựa trên các mẫu DOLPHIN, một phương pháp so khớp mới được sử dụng để tái tạo tên miền với các thành phần của nguyên âm và phụ âm có độ dài biến đổi. Từ những tên miền đó, DOLPHIN trích xuất các đặc trưng dựa trên ngữ âm. Kết quả thực nghiệm cho thấy, so với FANCI và RF, DOLPHIN có thể đạt được độ chính xác phát hiện cao hơn 0,0265 với tỷ lệ dương tính sai và tỷ lệ phủ sóng sai thấp hơn mà không đòi hỏi quá nhiều chi phí tính toán DOLPHIN cũng có khả năng tổng quát hóa cho các nguồn dữ liệu khác trong thế giới thực. Do đó, giải pháp này có thể phù hợp với hầu hết các đặc trưng ngôn ngữ và mang lại cải thiện về hiệu suất so với các phương pháp dựa trên đặc trưng ngôn ngữ hiện có.

Các lưu lượng mạng của Botnet luôn cố gắng ẩn mình trước các lưu lượng thông thường của người dùng, đặc biệt là các mạng Botnet được triển khai theo mô hình P2P. Trong một nghiên cứu của mình [50], Alauthman và cộng sự đề xuất một cơ chế giúp giảm thiểu các lưu lượng phức tạp, tích hợp với một kỹ thuật học tăng cường. Lưu lượng mạng được rút gọn giúp giảm khối lượng tính toán của thuật toán đề xuất. Kết quả thử nghiệm cho thấy phương pháp mới đạt tỉ lệ phát hiện đúng là 98,3%, tỉ lệ dương tính giả thấp với 0,012%. Nghiên cứu được đánh giá trên sự tổng

hợp của ba bộ dữ liệu gồm ISOT Dataset [51], P2P Botnet [52] và Information Security Centre of Excellence Dataset [53].

1.4.3. Hướng tiếp cận dựa trên học sâu

Trong hướng tiếp cận dựa trên học sâu, Đức và cộng sự [15] đã sử dụng mạng bộ nhớ ngắn hạn dài Long Short-Term Memory Network để giải quyết cả hai bài toán DGA Botnet. Nhóm nghiên cứu đề xuất một thuật toán mới với tên gọi là LSTM.MI, kết hợp cả hai mô hình phân loại, kế thừa ưu điểm của LSTM truyền thống và các cải tiến để tăng cường độ chính xác, giảm thiểu tối đa nhiễu. Về dữ liệu thử nghiệm, các tên miền được nhóm tác giả thu thập từ thực tế, với 100.000 tên miền lành tính phổ biến nhất từ Alexa và 37 họ DGA Botnet được tổng hợp. Kết quả thử nghiệm cho thấy thuật toán đề xuất giúp nâng cao ít nhất 7% độ chính xác so với mô hình LSTM truyền thống. Nó cũng đạt độ chính xác cao trong bài toán phân lớp nhị phân với F_1-score đạt 98,49%, đồng thời có khả năng nhận ra 05 họ Botnet bổ sung. Hạn chế của nghiên cứu là bộ dữ liệu chưa thực sự đầy đủ và một số họ DGA Botnet gần như không thể phát hiện được.

Curtin và cộng sự đã sử dụng mạng RNN để phát hiện và phân loại DGA Botnet [16]. Họ nhận ra rằng các tên miền được xây dựng dựa trên một không gian từ vừng, có các nét đặc trưng khá giống với các tên miền lành tính, từ đó giúp tăng khả năng ẩn mình của các tên miền được sinh ra. Nhóm nghiên cứu đã đề xuất một khái niệm mới, gọi là thang điểm Smashword. Đây là thang đo lường mức độ giống nhau giữa tên miền của Botnet và các tên miền lành tính. Nhóm nghiên cứu áp dụng mô hình mạng Recurrent Neural Network và Side Information để áp dụng tiêu chuẩn đo lường trên. Bộ dữ liệu thử nghiệm với 1.000.000 tên miền Alexa, kết hợp với 41 họ DGA Botnet được nhóm nghiên cứu tổng hợp, với tổng cộng 2.300.000 tên miền cho cả hai nhãn. Thực nghiệm cho thấy mô hình mới có tiềm năng ứng dụng cao cải tiến được độ chính xác hơn so với các mô hình trước đó. Một số họ DGA Botnet phức tạp như matsnu, suppobiox hay rovnix cũng được phát hiện bởi giải pháp trên.

Vinayakumar và nhóm cộng sự nghiên cứu bài toán phát hiện tên miền độc hại được sinh bởi Botnet hay thư điện tử, URL độc hại [17]. Một số kỹ thuật biểu diễn đặc trưng dựa trên n-gram đã được sử dụng để mô hình hóa bài toán. Bộ dữ liệu để đánh giá bao gồm các tên miền lành tính và độc hại được thu thập từ OpenDNS, Alexa

và OSINT Feeds. Kết quả so sánh thấy mô hình CNN-LSTM là hiệu quả nhất với F_1-score đạt 96,3% cho bài toán phân lớp nhị phân.

Liu và cộng sự [54] lập luận rằng biểu diễn đặc trưng bằng các giá trị vô hướng có thể dẫn đến mất mát thông tin. Nhóm tác giả đề xuất một Capsule Network tuần tự (mạng học sâu được cải tiến từ CNN) dựa trên thuật toán định tuyến k-means, gọi là LSTM-CapsNet. Mô hình sử dụng một đơn vị LSTM hai chiều để trích xuất các thuộc tính cơ bản và sử dụng thuật toán k-mean để phân cụm thành hai nhãn độc hại và lành tính. Đánh giá được thực hiện trên hai bộ dữ liệu, bao gồm bộ dữ liệu tên miền DGA từ mạng thực tế và tên miền DGA thu được thông qua thuật toán tạo tên miền tự động. Kết quả thực nghiệm cho thấy mô hình đề xuất đạt độ chính xác lần lượt là 99,17% và 97,75% trên hai bộ dữ liệu. Mô hình này không chỉ cải thiện khả năng nhận dạng tên miền DGA và nhận dạng họ tên miền DGA trên lý thuyết mà còn thể hiện hiệu quả trong bộ dữ liệu thực tế.

1.5. Kết luận Chương 1

Trong Chương 1, NCS trình bày tổng quan chung về Botnet nói chung, bài toán DGA Botnet nói riêng và các nghiên cứu liên quan. Trong đó, xác phạm vi nghiên cứu của luận án là bài toán DGA Botnet, tập trung vào bài toán phân loại . Chương 1 cũng trình bày sự khác nhau giữa bài toán phát hiện DGA Botnet với bài toán phát hiện URL độc hại và ý nghĩa của bài toán này.

Trong các chương tiếp theo, NCS trình bày các kết quả nghiên cứu, đánh giá và đề xuất giải pháp dựa trên học sâu để giải quyết hai bài toán gồm phân lớp nhị phân và phân lớp đa lớp, với ý nghĩa phát hiện và phân loại DGA Botnet.

Một phần kết quả nghiên cứu được trình bày tại Chương 1 được công bố tại [CT2] [CT6] trong danh mục công trình của tác giả.

Chương 2. ĐÁNH GIÁ GIẢI PHÁP PHÁT HIỆN DGA BOTNET SỬ DỤNG LÝ THUYẾT TẬP MỜ VÀ HỌC MÁY

Trong chương 2, NCS tiếp cận để giải quyết bài toán phân lớp nhị phân - phát hiện DGA Botnet sử dụng lý thuyết tập mờ và học máy. NCS cũng đề xuất hai mô hình học máy kết hợp là VEA và HEA để nâng cao độ chính xác so với các mô hình đơn. Mục tiêu của chương này là đánh giá hiệu quả của hai hướng tiếp cận gồm dựa trên lý thuyết tập mờ và học máy trong bài toán phân lớp nhị phân.

2.1. Phát hiện DGA Botnet dựa trên lý thuyết tập mờ

2.1.1. Cơ sở thuật toán phân cụm mờ

Việc phân cụm dữ liệu có nhiều ứng dụng quan trọng trong khai phá dữ liệu, nhận dạng mẫu, truy hồi thông tin và học máy. Trong thực tế, để các dữ liệu thường phức tạp, thiếu hụt hoặc có tính chất mơ hồ, không chắc chắn. Để giải quyết vấn đề này, lý thuyết tập mờ đã được Zadeh đề xuất. Trong đó thông tin không chắc chắn được mô hình hóa dưới dạng độ thuộc của phần tử vào một tập. Thuật toán phân cụm trên tập mờ của Zadeh là Fuzzy C-Means - FCM đưa ra bởi Bezdek và cho đến nay đã được ứng dụng trong nhiều lĩnh vực khác nhau với những kết quả tiềm năng. Một vấn đề cơ bản trong các nghiên cứu liên quan đến tập mờ truyền thống của Zadeh là khả năng biểu diễn các thông tin liên quan đến tính "không thuộc" và tính "do dự".

2.1.1.1. Khái niệm tập mờ trung lập

Tập mờ trung lập – Neutrosophic Set được Smarandache đề xuất [55], là một cải tiến của tập mờ truyền thống. Trên không gian X, một tập mờ trung lập A được định nghĩa như sau:

$$A = \{x, \big(T_A(x), I_A(x), F_A(x)\big) : x \in X\}$$

Trong đó, hàm $T_A(x), I_A(x), F_A(x)$ lần lượt thể hiện độ thuộc của phần tử x thuộc về, trung lập và không thuộc về một tập xác định nào đó. Các giá trị $T_A(x), I_A(x), F_A(x) \in [0, 1]$ và thỏa mãn điều kiện:

$$0 \leq T_A(x) + I_A(x) + F_A(x) \leq 3$$

Lý thuyết tập mờ trung lập cung cấp một công cụ mạnh mẽ để giải quyết tính bất định và ứng dụng trong nhiều lĩnh vực. Trong bài toán DGA Botnet, việc áp dụng lý thuyết tập mờ để giải quyết bài toán là một hướng đi tiềm năng, với các nghiên cứu

của Sahin [56] hay Gou [57]. Trong phần này, NCS sử dụng thuật toán phân cụm NCM trên tập mờ trung lập để giải quyết bài toán phân lớp nhị phân

2.1.1.2. Thuật toán phân cụm NCM

Neutrosophic C-Means - NCM là thuật toán phân cụm mờ trên tập mờ trung lập, được phát biểu như sau: Cho X là một tập khác rỗng, với một phần tử của X ký hiệu là $x \in$ X, tập mờ trung lập A xác định trên không gian X được đặc trưng bởi ba hàm số:

- Hàm T_A(x) đo độ thuộc chỉ ra rằng sự kiện x sẽ xảy ra;

- Hàm I_A(x) đo độ trung lập, tức là không có ý kiến gì về việc sự kiện x có xảy ra hay là x thuộc vào vùng ranh giới.

- Hàm F_A(x) đo độ không thuộc hoặc độ nhiễu, tin rằng sự kiện x sẽ không xảy ra hoặc chưa thể xác định được.

Trong bài toán DGA Botnet, hàm T_A(x) thể hiện độ thuộc của một tên miền x vào một cụm, hàm F_A(x) thể hiện độ nhiễu và hàm I_A(x) thể hiện độ trung lập, tức là mức độ mà tên miền x không thuộc cả một trong hai cụm. Khác với các phương pháp phân cụm truyền thống như K-means hay Fuzzy C-Means, phương pháp phân cụm NCM có thể xác định được các dữ liệu nhiễu, ngoại lệ, hay trung tính giữa các cụm.

Hàm mục tiêu được cho bởi công thức (2.1) như sau:

$$J_{NCM}(T, I, F, C) = \sum_{i=1}^{N}\sum_{j=1}^{C}(\omega_1 T_{ij})^m \left\|x_i - c_j\right\|^2 + \sum_{i=1}^{N}(\omega_2 I_i)^m \left\|x_i - \bar{c}_{i_{max}}\right\|^2 + \delta^2 \sum_{i=1}^{N}(\omega_3 F_i)^m \quad (2.1)$$

Với T_{ij} là độ thuộc của phần tử i đối với cụm j; I_i và F_i thể hiện độ trung lập và độ nhiễu của phần tử i. Giá trị w_1, w_2, w_3 là các trọng số tương ứng thỏa mãn điều kiện $0 < w_1, w_2, w_3 < 1$ và $(w_1 + w_2 + w_3 = 1)$. Các hệ số mờ m và δ được lựa chọn cố định.

Ta có $1 \leq i \leq N$ với N là số phần tử, $1 \leq j \leq C$ với C là số cụm. Các tâm cụm được ký hiệu là c_j.

Điều kiện $0 < T_{ij}, I_i, F_i < 1$, với T_{ij}, I_i, F_i thỏa mãn:

$$\sum_{j=1}^{C} T_{ij} + F_i + I_i = 1$$

Với mỗi điểm i, giá trị của $\bar{c}_{i_{max}}$ được xác định bằng giá trị của trung tâm cụm với giá trị lớn nhất và lớn thứ nhì của T_{ij} theo các công thức:

$$\bar{c}_{i_{max}} = \frac{c_{p_i} + c_{q_i}}{2} \tag{2.2}$$

$$p_i = argmax(T_{ij}) \; với \; j = 1, 2, \dots C \tag{2.3}$$

$$q_i = argmax(T_{ij}) \; với \; j \neq p_i \cap j = 1, 2, \dots C \tag{2.4}$$

Với m là hằng số, p_i và q_i là giá trị T_{ij} có giá trị lớn nhất và lớn thứ nhì của mỗi cụm. Khi p_i và q_i được tính, giá trị $\bar{c}_{i_{max}}$ được tính và sẽ không đổi cho mỗi điểm dữ liệu i.

Với giá trị K:

$$K = \left[\frac{1}{\omega_3} \sum_{j=1}^{C} (x_i - c_j)^{-\frac{2}{m-1}} + \frac{1}{\omega_2} (x_i - \bar{c}_{i_{max}})^{-\frac{2}{m-1}} + \frac{1}{\omega_3} \delta^{-\frac{2}{m-1}} \right]^{-1} \tag{2.5}$$

Các giá trị T_{ij}, I_i, F_i lần lượt được tính bởi công thức sau:

$$T_{ij} = \frac{K}{\omega_1} (x_i - c_i)^{-\frac{2}{m-1}} \tag{2.6}$$

$$I_i = \frac{K}{\omega_2} (x_i - \bar{c}_{imax})^{-\frac{2}{m-1}} \tag{2.7}$$

$$F_i = \frac{K}{\omega_3} \delta^{-\frac{2}{m-1}} \tag{2.8}$$

Cập nhật lại tâm cụm như sau:

$$c_i = \frac{\sum_{i=1}^{N}(\omega_1 T_{ij})^m x_i}{\sum_{i=1}^{N}(\omega_1 T_{ij})^m} \quad (2.9)$$

Việc phân cụm được thực hiện lặp lại kết hợp việc tối ưu hóa hàm mục tiêu. Các giá trị của độ thuộc, độ trung lập và độ không thuộc sẽ được cập nhật theo các biểu thức trên trong mỗi lần lặp.

Giá trị $\bar{c}_{i_{max}}$ cũng được cập nhật trong mỗi lần lặp. Thuật toán dừng khi ta có $\left|T_{ij}^{(k+1)} - T_{ij}^{(k)}\right| < \varepsilon$. Trong đó $0 < \varepsilon < 1$ là ngưỡng thay đổi để thuật toán được coi là hội tụ, k là số lần lặp.

Thuật toán NCM được tóm tắt như sau:

Thuật toán: $NCM(X, \varepsilon)$

Dữ liệu vào X, ε

Dữ liệu ra k

Khởi tạo $T^{(0)}, I^{(0)}, F^{(0)}$

Khởi tạo $C, m, \varepsilon, \delta,\ \omega_1,\ \omega_2,\ \omega_3$

Lặp:

Tính $c_i^{(k)}$

Tính $\bar{c}_{i_{max}}$

Cập nhật $T^{(k+1)}$

Cập nhật $I^{(k+1)}$

Cập nhật $F^{(k+1)}$

Điều kiện lặp $\left|T_{ij}^{(k+1)} - T_{ij}^{(k)}\right| > \varepsilon$

$TM = [T, I, F]$ $với$ $x_i \epsilon\ k^{th}$

$k = argmax(TM_{ij})$ $với$ $j = 1, 2, \ldots, C+2$

Trả về k

Khi đó, nếu $k = C + 1$ thì phần tử thuộc vào lớp trung tính; nếu $k = C + 2$ thì phần tử thuộc vào lớp không thuộc. Biểu diễn k^{th} là vòng lặp thứ k.

So với thuật toán NCM gốc, NCS đưa vào một số điều chỉnh để phù hợp với bài toán phát hiện DGA Botnet như sau:

- Sử dụng kỹ thuật vector hóa để điều chỉnh các đặc trưng phù hợp với đầu vào thuật toán NCM.

- Điều chỉnh lựa chọn sử dụng hai nhãn 0 và 1 để làm kết quả bài toán, thay vì ba nhãn như thuật toán gốc.

Do số lượng cụm đặc trưng của thuật toán phân cụm NCM gốc, giải pháp này chưa phù hợp cho bài toán phân lớp đa lớp trong DGA Botnet.

2.1.2. Thuật toán phát hiện DGA Botnet với NCM

2.1.2.1. Mô hình thuật toán NCM để phát hiện DGA Botnet

Mô hình thuật toán NCM để phát hiện DGA Botnet được thể hiện tại Hình 2.1, bao gồm ba giai đoạn như sau:

(1) Tính toán các đặc trưng: Mỗi tên miền sẽ được trích xuất các đặc trưng liên quan, tạo ra cơ sở dữ liệu đặc trưng cho bước lựa chọn tiếp theo. Các phương pháp tính toán đặc trưng được trình bày ở phần tiếp theo của nội dung này.

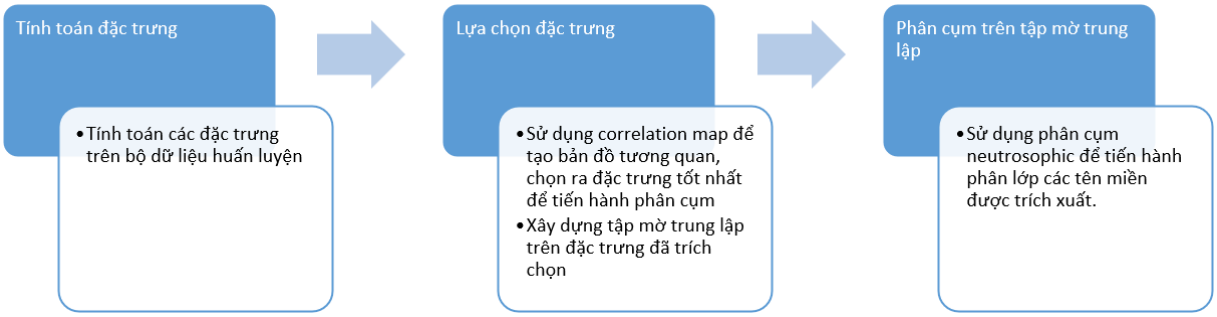

Hình 2.1. Mô hình áp dụng thuật toán NCM để phát hiện DGA Botnet

(2) Lựa chọn đặc trưng: NCS sử dụng bản đồ tương quan để chọn ra các đặc trưng có ảnh hưởng nhất trong các đặc trưng đã được trích chọn. Việc này giúp thuật toán giảm bớt nhiễu và khối lượng tính toán. Từ những đặc trưng đã trích chọn, xây dựng thuật toán phân cụm dựa trên tập mờ trung lập. Các đặc trưng được thể hiện dưới dạng vector đầu vào cho thuật toán phân cụm NCM.

(3) Phân cụm Neutrosophic: Sử dụng thuật toán phân cụm trên tập Neutrosophic Set để tiến hành phân cụm. Tìm ra các tên miền bình thường, tên miền của DGA Botnet và tên miền trung lập và nhiễu.

Bộ tham số được lựa chọn cho thuật toán NCM cụ thể như sau:$C = 2; w_1 = 0{,}8;\ w_2 = 0{,}1; w_3 = 0{,}1; m = 2, \delta = 1{,}4; \varepsilon = 10^{-5}$.

2.1.2.2. Đề xuất đặc trưng

Đối với phân cụm trên tập Nneutrosophic Set, việc lựa chọn các đặc trưng rất quan trọng. NCS đề xuất các đặc trưng dựa trên tên miền gồm ba nhóm như sau:

- Nhóm các đặc trưng về cấu trúc;

- Nhóm các đặc trưng về ngữ pháp;

- Nhóm các đặc trưng về thống kê.

Bảng 2.1 liệt kê các đặc trưng thuộc nhóm các đặc trưng về cấu trúc của tên miền.

Bảng 2.1. Các đặc trưng về cấu trúc của tên miền và ví dụ

STT	**Đặc trưng**	**Ý nghĩa**	**vnexpress.net**	**tccyyuytiymh.pw**
1	DNL	Độ dài của tên miền	13	15
2	NoS	Số lượng tên miền con	1	1
3	SLM	Độ dài của tên miền phụ	9	12
4	HwP	Tên miền có chứa “www” hay không? 1: Có 0: Không	0	0
5	HVTLD	Chứa tên miền root hợp lệ hay không? *(Căn cứ www.iana.org)* 1: Có 0: Không	1	1
6	CTS	Có tên miền phụ nằm trong Root-zone database hay không? 1: Có 0: Không	0	0
7	UR	Tỉ lệ ký tự “_” trong tên miền.	0,0	0,0
8	CIPA	Tên miền chứa địa chỉ IP hay không?	0	0

		1: Có 0: Không		

Trong đó, giá trị UR được xác định bởi công thức sau:

$$UR_{dom} = \frac{count("\_",\ dom)}{length(dom)} \quad (2.10)$$

Với: $count("\_", dom)$ là số lượng ký tự "_" trong tên miền dom; $length(dom)$ là độ dài của tên miền dom.

Bảng 2.2 liệt kê các thuộc tính thuộc nhóm các đặc trưng về ngữ pháp của một tên miền.

Bảng 2.2. Các đặc trưng về ngữ pháp của tên miền và ví dụ

STT	Đặc trưng	Ý nghĩa	vnexpress.net	tccyyuytiymh.pw
1	CD	Có chứa chữ số hay không? 1: Có 0: Không	0	0
2	VR	Tỉ lệ nguyên âm trên độ dài tên miền	0,222	0,167
3	NR	Tỉ lệ chữ số trên độ dài tên miền	0	0

Trong đó:

- VR: Giá trị này được xác định bởi công thức sau:

$$VR_{dom} = \frac{count(V, dom)}{length(dom)} \quad (2.11)$$

Với $V = \{'a','e','i','o','u'\}$.

- NR: Giá trị này được xác định bởi công thức sau:

$$NR_{dom} = \frac{count(N, dom)}{length(dom)} \quad (2.12)$$

Với $N = \{'0','1','2','3','4','5','6','7','8','9'\}$.

Bảng 2.3 trình bày nhóm các đặc trưng về thống kê:

Bảng 2.3. Các đặc trưng về các thống kê dựa trên ngữ nghĩa và ví dụ

STT	Đặc trưng	Ý nghĩa	vnexpress.net	tccyyuytiymh.pw
1	RRC	Giá trị lặp lại của một ký tự trong tên miền con	0,285714	0,428571
2	RCC	Tỉ lệ phụ âm liên tiếp trong tên miền	0,555556	0,583333
3	RCN	Tỉ lệ chữ số liên tiếp trong tên miền	0,0	0,0
4	Entropy	Giá trị entropy của tên miền con	2,725481	2,584963

Trong đó:

- RRC của một tên miền ký hiệu là RRC_{dom} được xác định bởi công thức sau:

$$RRC_{dom} = \frac{\sum_{c \in D} count(repeated_{dom})}{length(dom)} \quad (2.13)$$

Với $repeated_{dom}$ là số lần ký tự được lặp lại trong dom.

- RCC của một tên miền ký hiệu là RCC_{dom} được xác định bởi công thức sau:

$$RCC_{dom} = \frac{\sum_{c \in C} count(CC_{dom})}{length(dom)} \quad (2.14)$$

Với CC_{dom} là số lần phụ âm được được lặp lại liên tiếp trong dom.

- RCN của một tên miền ký hiệu là RCN_{dom} được xác định bởi công thức sau:

$$RCN_{dom} = \frac{\sum_{c \in N} count(CN_{dom})}{length(dom)} \quad (2.15)$$

Với CN_{dom} là số lần chữ số được được lặp lại liên tiếp trong dom.

- Entropy của một tên miền ký hiệu là $Entropy_{dom}$ được xác định bởi công thức sau:

$$Entropy_{dom} = -\sum_{c \in D} \frac{count(c, dom)}{length(dom)} \times \log\left(\frac{count(c, dom)}{length(dom)}\right) \quad (2.16)$$

Với c là một ký tự trong dom, D là tập các ký tự có trong dom, V là tập các nguyên âm, C là tập các phụ âm và N là tập các chữ số.

2.1.2.3. Lựa chọn đặc trưng

NCS sử dụng ma trận tương quan để tiến hành lựa chọn ra các đặc trưng ảnh hưởng nhất. Có ba phương pháp xây dựng ma trận tương quan thường được sử dụng bao gồm: Phương pháp Pearson, phương pháp Spearman và phương pháp Kendall. Trong thống kê, hệ số tương quan có ý nghĩa quan trọng. Hệ số này có thể góp phần giải thích sự ảnh hưởng của biến độc lập so với biến phụ thuộc, dự báo thông qua các mô hình hồi quy tuyến tính hay ước lượng độ tin cậy và hợp lý.

Trong thuật toán phân cụm NCM đề xuất, các thuộc tính đề xuất trên một tên miền là nhiều, việc sử dụng toàn bộ thuộc tính sẽ cần một năng lực tính toán lớn. Hơn nữa, một số thuộc tính có thể không có nhiều ảnh hưởng tới nhãn của tên miền. Do đó, ma trận tương quan Pearson được sử dụng, lựa chọn các thuộc tính có ảnh hưởng nhất để đưa vào phân cụm.

NCS sử dụng hệ số tương quan Pearson để lựa chọn các đặc trưng ảnh hưởng nhất. Giá trị tương quan của thuộc tính x và y là r_{xy} được tính như sau:

$$r_{xy} = \frac{\sum_{i=1}^{n}(x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^{n}(x_i - \bar{x})^2}\sqrt{\sum_{i=1}^{n}(y_i - \bar{y})^2}} \quad (2.17)$$

Trong đó:

- n là số lượng giá trị mẫu;

- x_i, y_i: Là giá trị mẫu thứ i của x và y;

- $\bar{x}$: Giá trị trung bình các mẫu của x được xác định bởi:

$$\bar{x} = \frac{1}{n}\sum_{i=1}^{n} x_i \quad (2.18)$$

- $\bar{y}$: Giá trị trung bình các mẫu của y được xác định bởi:

$$\bar{y} = \frac{1}{n}\sum_{i=1}^{n} y_i \quad (2.19)$$

Hệ số tương quan có giá trị từ [-1, 1], với giá trị -1 hoặc 1 thể hiện mối liên quan tuyệt đối giữa hai biến số; ngược lại giá trị 0 thể hiện rằng không có bất kỳ mối quan hệ nào giữa hai biến.

Tính toán ma trận tương quan của các đặc trưng từ các bộ dữ liệu AADR, 360NetLab, UMUDGA và OSINT, cho kết quả được thể hiện tại Hình 2.2:

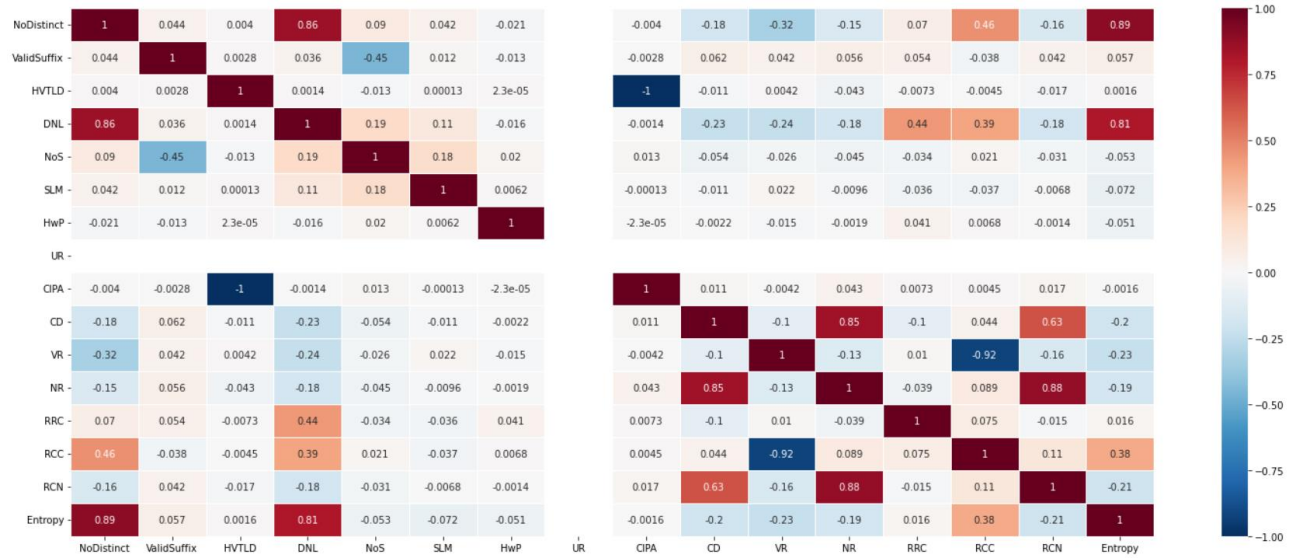

Hình 2.2. Ma trận tương quan các thuộc tính trên tập AADR

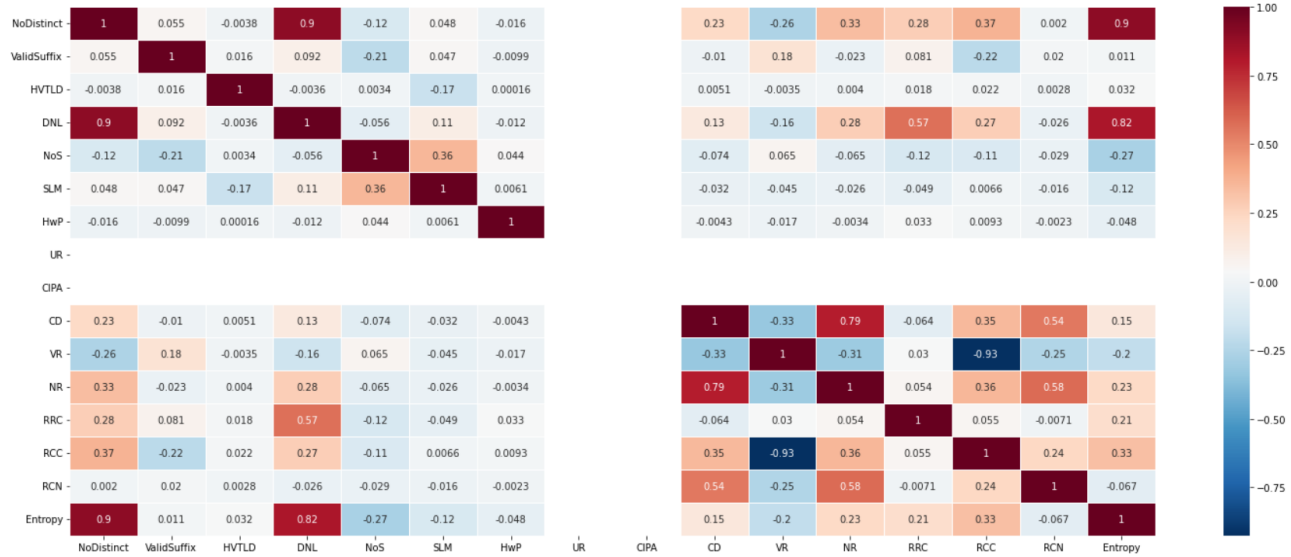

Hình 2.3. Ma trận tương quan các thuộc tính trên tập 360NetLab

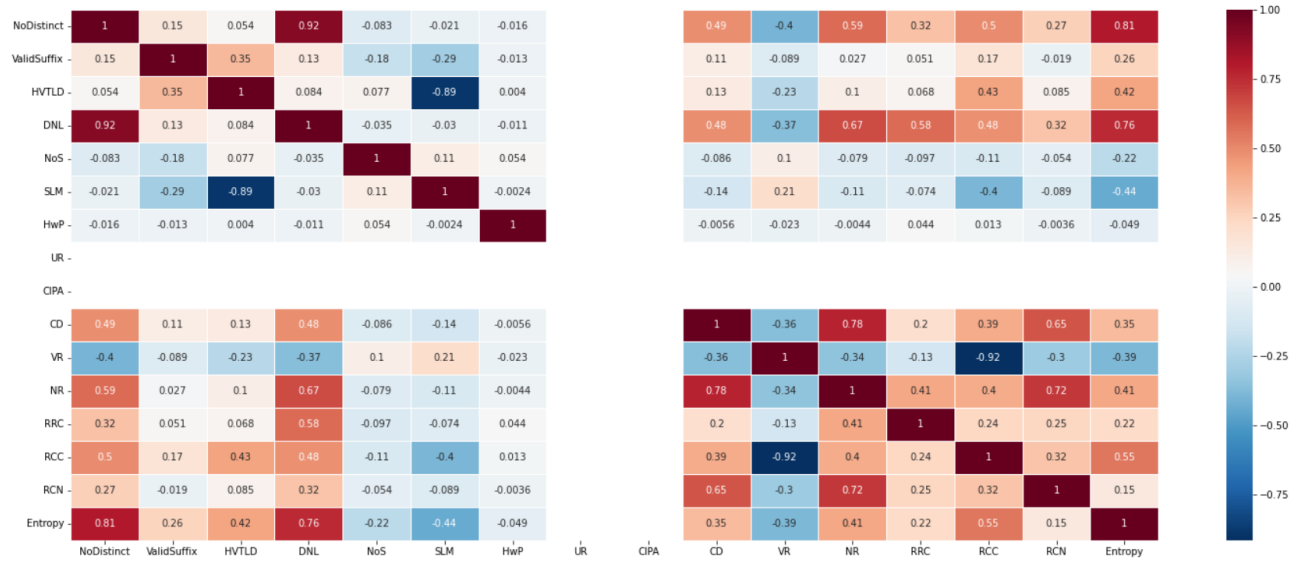

Hình 2.4. Ma trận tương quan trên tập OSINT

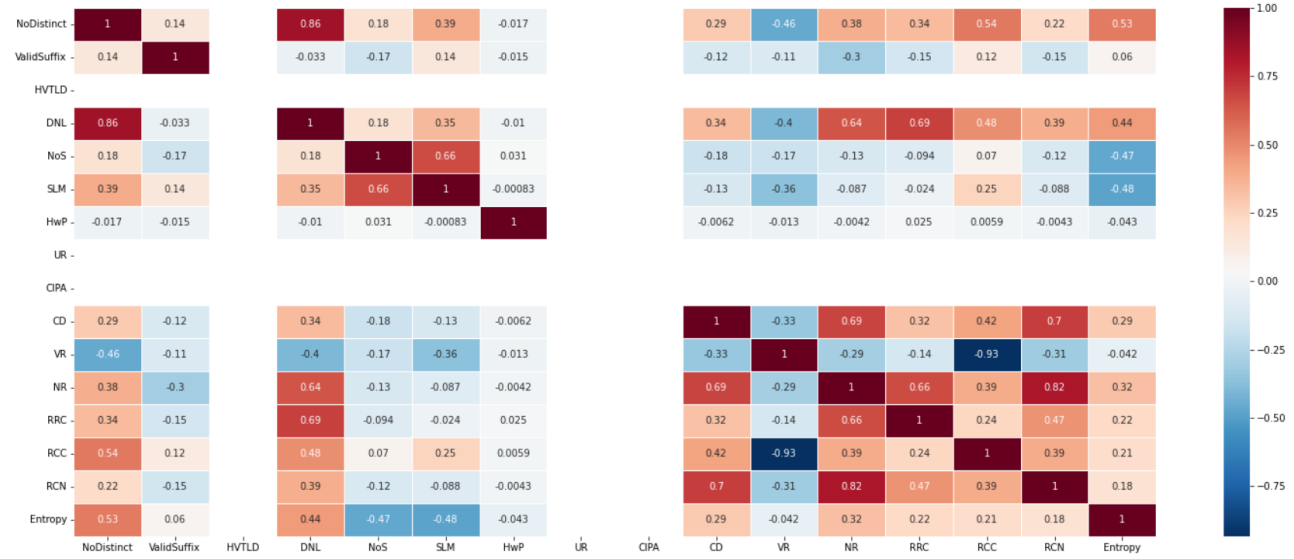

Hình 2.5. Ma trận tương quan trên tập UMUDGA

Thực hiện lựa chọn các đặc trưng có ảnh hưởng nhất để phân lớp, với đặc trưng Type để gán nhãn, phục vụ cho đánh giá kết quả phân cụm. Các đặc trưng được lựa chọn là khác nhau đối với từng bộ dữ liệu, kết quả trích chọn đặc trưng được cho tại Bảng 2.4:

Bảng 2.4. Các đặc trưng có ảnh hưởng cao nhất trong các bộ dữ liệu

STT	AADR	360NetLab	OSINT	UMUDGA
1	CIPA	RCC	DNL	RCC
2	HVTLD	VR	NoDistinct	VR
3	VR	Entropy	VR	Entropy
4	RCC	NoDistinct	RCC	NoDistinct

5	NoDistinct	DNL	Entropy	DNL
6	Entropy	NR	NR	NR
7	RCN	CD	CD	CD

2.1.3. Đánh giá và thảo luận

2.1.3.1. Công cụ đánh giá

Trong phần này, NCS cài đặt và đánh giá mô hình NCM với mô hình Sahin sử dụng phân cụm phân cấp trên tập mờ trung lập (Sahin) [56], mô hình sử dụng các thuật toán K-means, Fuzzy Cmeans (FCM) [58], Support Vector Machine (SVM) [59], Twin Support Vector Machine (TSVM) [60] và Fuzzy Support Vector Machine (FSVM) [61].

Sử dụng độ đo khoảng cách Manhattan để tính toán mức độ tương đồng giữa hai phần tử X và Y là $Sim(X,Y)$ như sau:

$$Sim(X,Y) = \sum_{i=1}^{m} |x_i - y_i| \quad (2.20)$$

Trong đó x_i, y_i lần lượt là các phần tử của X, Y với $i = 1, 2, \dots, m$;

Thuật toán được thể hiện bằng ngôn ngữ lập trình Python, sử dụng nền tảng Google CoLab Pro, sử dụng CPU và 12GB RAM cho việc đánh giá thuật toán NCM để giải quyết bài toán phân lớp nhị phân. Hiệu quả của thuật toán được đánh giá thông qua các tham số Precision, Recall và F_1-Score.

2.1.3.2. Kết quả thực nghiệm và thảo luận

Lần lượt đánh giá trên các bộ dữ liệu AADR, 360NetLab, OSINT và UMUDGA. Kết quả được thể hiện tại Bảng 2.5:

Bảng 2.5. Kết quả phân lớp nhị phân của thuật toán NCM trên 04 bộ dữ liệu

	Avg Precision*	**Avg Recall***	**Avg F_1-Score***
AADR	0,87	0,76	0,79
360NetLab	0,87	0,81	0,84
OSINT	0,77	0,61	0,54
UMUDGA	0,87	0,81	0,84

**: Giá trị trung bình dựa trên trọng số của 02 nhãn*

Về tổng thể, thuật toán NCM có thông số chung đại diện cho Precision và Recall là F_1-score trong khoảng từ 0,54 đến 0,84 trong 04 bộ dữ liệu đánh giá. Thuật toán hoạt động tốt nhất trên bộ dữ liệu 360NetLab và UMUDGA với F_1-score đều là 0,84; và kém hiệu quả nhất trên bộ dữ liệu OSINT với F_1-score đạt 0,54. Trong cả 04 trường hợp, chỉ số Precision thường cao hơn so với Recall. Điều này có ý nghĩa là giải pháp NCM có khả năng phát hiện đúng các tên miền độc hại hiệu quả hơn.

Các ma trận nhầm lẫn trên 04 bộ dữ liệu được cho tại Hình 2.6. Trong đó, nhãn 0 và 1 tương ứng là lành tính hoặc độc hại đối với từng bộ dữ liệu. Nhãn 2 tương ứng với nhiễu và nhãn 3 là không phân loại.

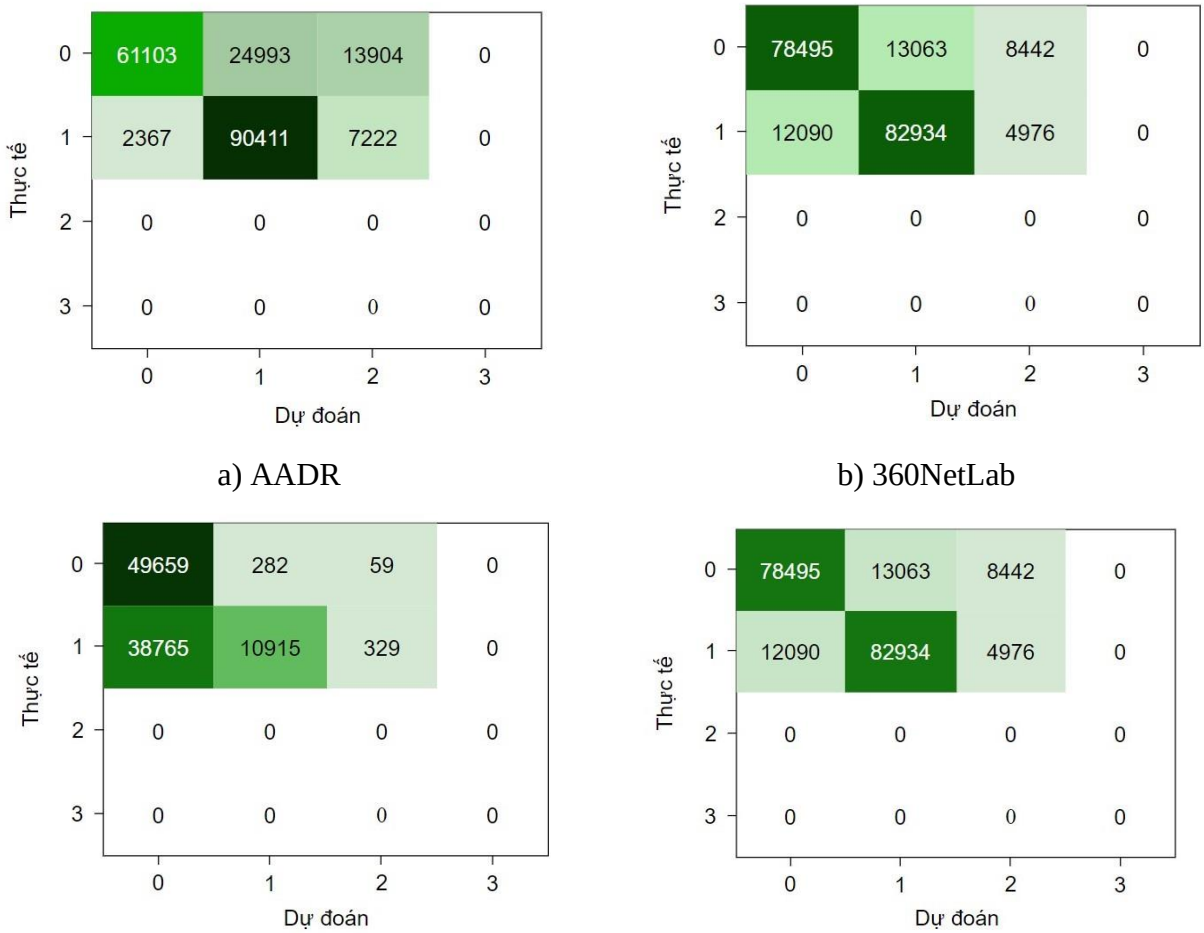

a) AADR b) 360NetLab

c) OSINT d) UMUDGA

Hình 2.6. Ma trận nhầm lẫn khi đánh giá thuật toán NCM trên 04 bộ dữ liệu

Hình 2.6 cho thấy, thuật toán NCM có khả năng phân loại chưa được tốt giữa tên miền lành tính và tên miền độc hại. Khả năng phát hiện đúng các tên miền độc hại là tốt hơn so với khả năng xác định đúng các tên miền lành tính. Tuy nhiên, nó cũng chưa thể phân loại một số lượng đáng kể các tên miền, chúng được xếp vào

dạng nhiễu hoặc trung tính, nghĩa là chưa đủ căn cứ để xếp vào một lớp cụ thể. Mức độ nhiễu thể hiện rõ nhất trên bộ dữ liệu AADR và thấp nhất trên bộ dữ liệu OSINT, được thể hiện bằng số lượng tên miền được phân loại là nhãn 2 và nhãn 3 trong ma trận. Ngoài ra, thuật toán NCM cũng hoạt động không ổn định, khi có sự chênh lệch lớn khi đánh giá trên các bộ dữ liệu khác nhau, dao động trong khoảng 0,54 đến 0,84. Đây cũng là một hạn chế của NCM so với các thuật toán khác.

2.1.3.3. So sánh với các thuật toán dựa trên lý thuyết mờ

Thực hiện so sánh thuật toán NCM đề xuất với các thuật toán khác dựa trên lý thuyết mờ của Sahin, K-means, FCM, SVM, TSVM và FSVM, ta thu được các kết quả được thể hiện tại Bảng 2.6:

Bảng 2.6. So sánh NCM với một số thuật toán tương tự

	*NCM**	Sahin	K-means	FCM	SVM	TSVM	FSVM
Precision	*0,85*	0,48	0,74	0,76	0,82	0,80	0,83
Recall	*0,75*	0,80	0,86	0,83	0,72	0,81	0,73
F_1-score	*0,75*	0,60	0,79	0,79	0,77	0,81	0,78

** Giá trị trung bình cộng khi đánh giá trên 04 bộ dữ liệu*

Kết quả trên cho thấy, nhìn chung thuật toán NCM cho hiệu quả tổng thể tốt hơn Sahin, nhưng thấp hơn phần lớn các thuật toán còn lại dựa trên F_1-Score. Tuy nhiên, Precision của NCM cho kết quả cao nhất trong các thuật toán được đối sánh. Điều này thể hiện rằng, trong các trường hợp cần ưu tiên Precision thì thuật toán NCM là có ưu điểm hơn .

Xem xét về thời gian chạy giữa các thuật toán. Hình 2.7 cho thấy, thuật toán K-means có thời gian chạy nhanh nhất, với 12,4 giây và FSVM có thời gian chạy dài nhất là 715,7 giây. Tuy nhiên, nếu xem xét thêm về độ chính xác, NCM là hiệu quả hơn bởi thời gian chạy 42,4 giây, nhanh hơn rất nhiều so với TSVM (606,0 giây) hay FSVM (715,7 giây) nhưng đều đạt độ chính xác tương đương. Có thể thấy, mô hình sử dụng thuật toán NCM có sự cân bằng tốt giữa thời gian chạy và độ chính xác tổng thể đạt được.

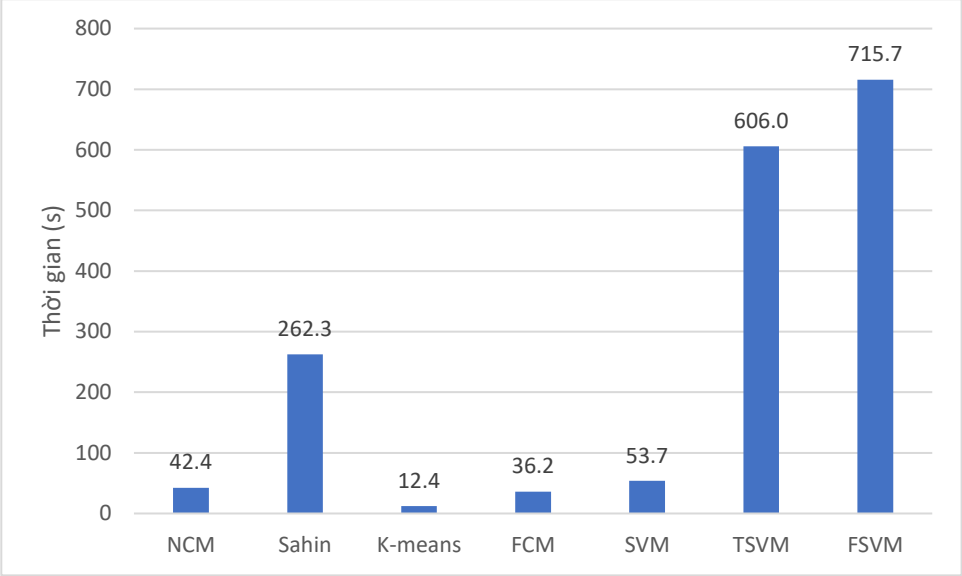

Hình 2.7. Thời gian thực hiện của NCM với các thuật toán dựa trên lý thuyết mờ

2.2. Phát hiện DGA Botnet dựa trên học máy

Các mô hình học máy đã được sử dụng rộng rãi trong giải quyết các bài toán về an ninh mạng, trong đó có bài toán phát hiện DGA Botnet. Trong phần này, NCS trình bày các đánh giá về việc sử dụng học máy để phát hiện DGA Botnet, hay chính là bài toán phân lớp nhị phân. Đồng thời, đề xuất hai mô hình lai mới trên nền tảng học máy để nâng cao độ chính xác của thuật toán so với các mô hình cơ bản.

2.2.1. Mô hình đánh giá các thuật toán học máy

2.2.1.1. Mô hình chung

Các giai đoạn trong quá trình đánh giá thuật toán học máy đối với bài toán phân lớp nhị phân được thể hiện ở Hình 2.8.

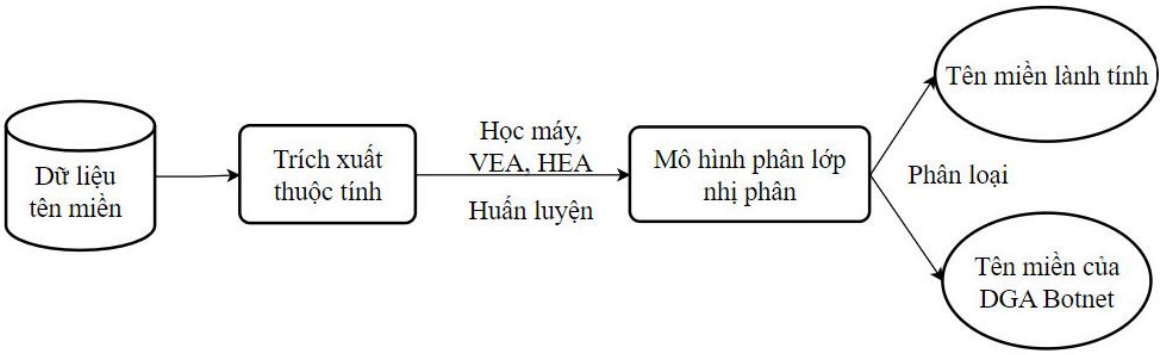

Hình 2.8. Sơ đồ mô hình huấn luyện, đánh giá

Theo đó, với dữ liệu đầu vào là các tên miền, bao gồm cả lành tính và độc hại đã được gán nhãn, sử dụng n-gram để tách các tên miền và kỹ thuật TF-IDF để biểu

diễn các đặc trưng. Tiếp theo, các thuật toán học máy được sử dụng để huấn luyện, bao gồm: Support Vector Machines, Logistic Regression, Naive Bayes, Neural Networks, Decision Trees, Random Forests, k-Nearest Neighbour, Adaptive Boosting. NCS cũng đồng thời đề xuất hai mô hình kết hợp khác là VEA và HEA. Mô hình sau khi huấn luyện được dùng để giải quyết bài toán phân lớp nhị phân, với hai nhãn là độc hại và lành tính.

2.2.1.2. Các thuật toán học máy

NCS tiến hành thực nghiệm với các thuật toán học máy bao gồm:

- Support Vector Machines (SVM): Đây là một trong những phương pháp học có giám sát phổ biến nhất cho bài toán phân loại, đồng thời cũng hiệu quả với các bài toán phân loại nhị phân. Các tên miền được biểu diễn như là các điểm trên không gian đa chiều. Kết quả hướng tới là tìm ra một siêu mặt phẳng để phân loại các điểm thuộc về hai lớp khác nhau nằm về hai phía của siêu mặt phẳng đó.

- Logistic Regression (LR): Cũng là một mô hình phân loại phổ biến dựa trên tính toán xác suất có điều kiện cho một vectơ đặc trưng. Giải thuật LR rất phù hợp cho các bài toán phân lớp nhị phân.

- Naive Bayes (NB): Là một mô hình tổng quát để phân loại, mô hình này giả định rằng tất cả các đặc trưng của x là độc lập với nhau và giải quyết bài toán dựa trên lý thuyết Bayes.

- Neural Networks (NN): Mô hình này bao gồm nhiều lớp khác nhau, trong đó có một lớp đầu vào, một lớp đầu ra và các lớp ẩn. Một số lượng phù hợp các lớp ẩn được đặt giữa lớp đầu vào và đầu ra. Dữ liệu đầu vào lần lượt đi qua các lớp ẩn để cho kết quả phân loại tại đầu ra. Thuật toán lan truyền ngược cũng được áp dụng để cập nhật tham số phù hợp cho từng lớp.

- Decision Trees (DT): Là một trong những phương pháp phổ biến để suy luận quy nạp. Thuật toán này có ưu điểm chính là có khả năng diễn giải cao và khả năng đọc hiểu tốt. Thuật toán giúp đưa ra quyết định dựa trên các thông tin đầu vào và các luật đã được cài đặt.

- Random Forests (RF): Một thành viên trong họ thuật toán Decision Tree, là phương pháp học tập tổng hợp để phân loại, hồi quy và các tác vụ khác hoạt động

bằng cách xây dựng nhiều cây quyết định dựa trên kết quả của nhiều bộ phân loại Decision Tree.

- k-Nearest Neighbour (kNN): kNN là giải thuật phân loại các đối tượng dựa vào khoảng cách gần nhất giữa đối tượng cần phân lớp với tất cả các đối tượng trong tập huấn luyện. Ý tưởng của phương pháp này là khi cần phân loại một điểm mới, thuật toán sẽ tính toán khoảng cách của tất cả các điểm trong tập huấn luyện đến điểm cần phân loại này để tìm ra tập k láng giềng gần nhất, từ đó xác định tập mà điểm này thuộc về.

- Adaptive Boosting (AB): Đây một trong những thuật toán học cộng đồng. Theo đó, boosting là một kỹ thuật nhằm tạo ra một bộ phân lớp mạnh từ một số các bộ phân lớp yếu hơn. Ý tưởng cơ bản của boosting là học từng mô hình yếu theo các bước lặp và tập trung vào việc cải thiện những điểm dữ liệu bị lỗi. Adaptive Boosting là một thuật toán ứng dụng boosting, được giới thiệu bởi Yoav Freund và Robert Schapire [62]. Thuật toán xây dựng một mô hình từ dữ liệu huấn luyện, sau đó các mô hình tiếp theo được tạo ra và cố gắng sửa các lỗi từ mô hình đầu tiên. Các mô hình được thêm vào cho đến khi tập huấn luyện được dự đoán tốt nhất hoặc số lượng mô hình đạt ngưỡng cực đại. Các đánh giá của tác giả cho thấy thuật toán này phù hợp với các bài toán phân lớp.

2.2.1.3. Trích chọn đặc trưng

Thông thường, mỗi tên miền sẽ có các đặc trưng được rút trích như độ dài tên miền; cấp độ của tên miền; tỉ lệ nguyên âm, phụ âm trên tổng số âm tiết… Cụ thể:

TF-IDF (Term-Frequency – Inverse Document Frequency) [63] là một kỹ thuật được sử dụng trong xử lý ngôn ngữ tự nhiên. Kỹ thuật này tính toán tần suất xuất hiện của một ký tự hoặc nhóm ký tự trong văn bản, thường là một từ nếu đặt trong ngữ cảnh là một câu văn. Kỹ thuật này được sử dụng để hỗ trợ đánh giá tầm quan trọng của một từ trong một câu văn hoặc một đoạn văn bản.

Trong đó:

- TF: Tần suất xuất hiện: Là tần suất xuất hiện của một từ trong văn bản, được tính tỉ lệ theo số lần xuất hiện của từ có số lần xuất hiện nhiều nhất trong văn bản d. Giá trị này cho biết một từ xuất hiện nhiều hay ít, được tính bằng công thức sau:

$$TF(t,d) = \frac{f(t,d)}{max\{f(w,d): w \in d\}} \quad (2.21)$$

Trong đó:

- $TF(t,d)$ là tần suất xuất hiện của từ t trong văn bản d;
- $f(t,d)$ là số lần xuất hiện của từ t trong văn bản d;
- $\max\{f(w,d): w \in d\}$ là số lần xuất hiện của từ có số lần xuất hiện nhiều nhất trong văn bản d.

- IDF Nghịch đảo tần suất của văn bản: Khái niệm này cũng để chỉ tần suất xuất hiện của một từ nhưng được dành cho những từ không mang nhiều ý nghĩa. Giá trị này giúp giảm bớt sự ảnh hưởng của những từ xuất hiện nhiều nhưng không mang nhiều ý nghĩa vào kết quả đánh giá chung.

Giá trị IDF được tính bằng công thức sau:

$$IDF(t,D) = log\frac{|D|}{|\{d \in D: t \in d\}|} \quad (2.22)$$

Trong đó:

- $IDF(t,D)$ là giá trị IDF của từ t trong tập văn bản D;
- $|D|$ là tổng số văn bản trong tập D;
- $|\{d \in D: t \in d\}|$ là số văn bản trong tập D có chứa từ t.

Cơ số logarit trong trường hợp này không nhằm thay đổi giá trị IDF mà nhằm mục đích giới hạn giá trị nhận được trong một khoảng xác định. Ngoài ra, ta có mối quan hệ giữa TF và IDF như công thức :

$$TF - IDF(t,d,D) = TF(t,d) \times IDF(t,D) \quad (2.23)$$

Đầu tiên, sử dụng đặc trưng n-gram để tách tên miền thành các nhóm ký tự, gồm 2-gram và 3-gram, 4-gram và 5-gram. Tiếp đến, sử dụng kỹ thuật TF-IDF để biểu diễn các đặc trưng rút trích thành các vector biểu diễn tần suất của các n-gam đại diện cho tên miền. Các vector đặc trưng n-gram này được sử dụng làm đầu vào cho các mô hình học máy.

2.2.1.4. Bộ dữ liệu đánh giá

Đánh giá được thực hiện trên bộ dữ liệu UMUDGA Dataset [18]. Bộ dữ liệu này được công bố năm 2020 bởi Zago và các cộng sự, bao gồm 1.000.000 tên miền nhãn lành tính và 50 họ DGA Botnet, mỗi họ có từ 10.000 cho đến 1.000.000 mẫu tên miền.

NCS trích xuất 1.000.000 tên miền lành tính làm nhãn 0 và 20.000 mẫu tên miền của từng họ DGA Botnet lãm nhãn 1. Tỉ lệ số lượng mẫu giữa hai nhãn 0 và 1 là 50%-50%, đảm bảo sự cân bằng dữ liệu. Chi tiết về số lượng mẫu dùng trong huấn luyện và đánh giá được cho ở Bảng 2.7:

Bảng 2.7. Số lượng mẫu dành cho đánh giá phân lớp nhị phân sử dụng học máy

	Nhãn 0 (Lành tính)	**Nhãn 1 (DGA Botnet)**
Số lượng mẫu cho mỗi họ tên miền	1.000.000	20.000
Số lượng họ tên miền	1	50
Tổng số lượng mẫu	1.000.000	1.000.000
Tỉ lệ của nhãn trong toàn bộ tập dữ liệu	50%	50%

Sử dụng phương pháp đánh giá k-fold với k = 10. Với bộ dữ liệu được chia thành 90%:10% tương ứng với tập huấn luyện và tập đánh giá. Phương pháp này giúp cho các mô hình được đánh giá một cách toàn diện nhất trong cả 10 trường hợp tập huấn luyện khác nhau.

2.2.2. Kết quả đánh giá và thảo luận

Bảng 2.8 thể hiện kết quả các độ đo Precision, Recall và F_1-score khi sử dụng các thuật toán học máy cho bài toán phân lớp nhị phân.

Bảng 2.8. Kết quả phát hiện DGA Botnet sử dụng học máy trên bộ dữ liệu UMUDGA

Mô hình học máy	**Precision***	**Recall***	**F_1-score***
LR	0,97	0,97	0,97
NB	0,93	0,89	0,91
DT	0,93	0,95	0,94
NN	0,97	0,97	0,97

SVM	0,97	0,96	0,97
RF	0,74	0,82	0,77
k-NN	0,97	0,66	0,78
AB	0,83	0,85	0,84

**: Giá trị trung bình có trọng số của tất cả các nhãn*

Kết quả trên cho thấy, hầu hết các thuật toán học máy đạt được độ chính xác cao trong bài toán phân lớp nhị phân, bao gồm LG, NN và SVM, với F_1-score đạt từ 0,97 trở lên. Mô hình NN cho kết quả tổng thể cao nhất, với Precision, Recall và F_1-score đều đạt 0,97. Mô hình có kết quả thấp nhất là RF với Precision, Recall và F_1-score lần lượt đạt 0,74, 0,82 và 0,77.

Các mô hình LG, NN, SVM, AB và DT có sự cân bằng giữa Precision và Recall. Tuy nhiên, các mô hình như NB, RF và k-NN lại có sự chênh lệch đáng kể. Trong đó, NB và k-NN có Precision đạt lần lượt là 0,98 và 0,97, thì Recall lại chỉ đạt lần lượt là 0,84 và 0,66. Điều này chứng tỏ hai mô hình có khả năng phát hiện chính xác các tên miền độc hại, nhưng tỉ lệ phân loại nhầm các tên miền lành tính thành độc hại cũng cao. Mô hình RF ngược lại với Precision thấp hơn nhiều so với Recall, lần lượt đạt 0,74 và 0,82.

Một nhận xét nữa đó là mô hình AB và RF cho độ chính xác thấp hơn so với DT, mặc dù chúng cùng dựa trên cơ chế học cộng đồng với bộ phân loại yếu là DT. Điều này được lý giải bởi việc sử dụng tham số mặc định của mô hình. NCS cũng nhận xét rằng, không phải các mô hình được xây dựng dựa trên học cộng đồng đều chắc chắn cho kết quả tốt hơn các mô hình đơn.

2.2.3. Mô hình học máy kết hợp

2.2.3.1. Mô hình VEA và HEA

Kết quả phân loại ở trên cho thấy, các mô hình học máy đơn có độ chính xác tốt nhưng vẫn có thể nâng cao hơn. Đồng thời, với một số mô hình thì nếu muốn Precision cao hơn thì phải chấp nhận Recall giảm xuống hoặc ngược lại. Điều này thể hiện rõ nhất ở mô hình NB, K-NN và RF như đã phân tích.

Gọi các mô hình đơn lẻ là các bộ phân loại yếu - Weak Classifier, ta có thể cải thiện hơn nữa độ chính xác của mô hình này bằng việc kết hợp các kết quả phân loại

đúng của chúng. NCS đề xuất hai mô hình gọi là VEA và HEA, là các bộ phân loại mạnh hơn - Stronger Classification, dựa trên cơ chế Ensemble Learning. Mục tiêu của bộ phân loại mới là dựa trên kết quả phân loại của mô hình đơn để bình chọn và tạo nên một mô hình mới có độ chính xác cao hơn.

Mô hình VEA và HEA sử dụng phương thức Bagging & Pasting, được thể hiện tại Hình 2.9:

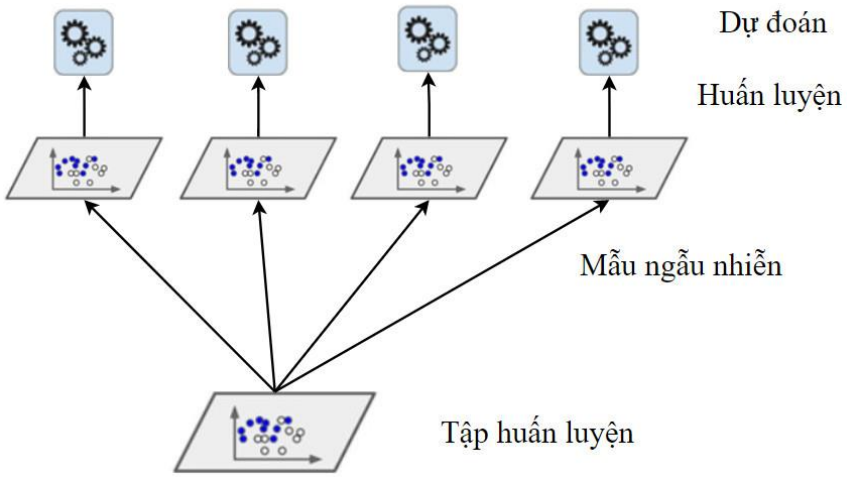

Hình 2.9. Phương thức Bagging & Pasting trong mô hình VEA và HEA

Trong phương thức này, dữ liệu từ tập huấn luyện sẽ được chia ngẫu nhiên thành các mẫu ngẫu nhiên (hay các tập huấn luyện con) bằng kỹ thuật Bootstrap. Các mẫu ngẫu nhiên này có phân phối các nhãn tương tự như tập huấn luyện gốc, được sử dụng cho việc huấn luyện các mô hình đơn. Dưới dạng toán học, l mẫu Bootstrap tương ứng với l mẫu ngẫu nhiên có kích thước b.

Ta có biểu diễn:

$$\{z_1^1, z_2^1, \dots, z_b^1\}, \{z_1^2, z_2^2, \dots, z_b^2\}, \dots, \{z_1^l, z_2^l, \dots, z_b^l\}$$

với z_i^j là phần tử thứ i của mẫu Bootstrap thứ j với $(1 \le i \le b; 1 \le j \le l)$

Tương ứng với l mẫu Bootstrap ta có l model đơn lẻ (hay model yếu). Quá trình huấn luyện các mô hình này được thực hiện song song.

$$m_1(.), m_2(.), \dots, m_l(.)$$

Trong các bài toán phân lớp, với l mô hình đơn, ta nhận được l kết quả phân loại tương ứng là nhãn của dữ liệu đầu vào. Ta có n nhãn từ $1 - n$. Kết quả cuối cùng được lựa chọn dựa trên kỹ thuật Voting như sau:

- Voting Ensemble Algorithm (VEA): Đưa ra kết quả cuối cùng dựa trên việc kết hợp các xác suất dự đoán của các bộ phân lớp đơn. Sau khi tính trung bình xác suất lựa chọn theo từng lớp của các nhãn, nhãn được lựa chọn là nhãn t có tổng thể xác xuất cao nhất, thỏa mãn:

$$\sum_{i=1}^{l} v_i^t \geq \sum_{i=1}^{l} v_i^k \ với i \ \forall k \in (1,n) \tag{2.24}$$

Trong đó, v_i^k là xác suất phần tử thuộc về lớp k theo kết quả phân loại của mô hình m_i. Với $1 \leq k \leq n$. Trong đó, mô hình VEA bao gồm các bộ phân loại sau:

$$VEA \begin{cases} w_1 : LG \\ w_2 : NN \\ w_3 : SVM \end{cases}$$

- Hard Ensemble Algorithm (HEA): Tương tự như VEA, nhưng mô hình HEA sẽ lựa chọn nhãn dựa trên tổng số lượng bầu lớn nhất. Nhãn cuối cùng t sẽ được chọn khi đó là nhãn mà được dự đoán bởi nhiều bộ phân lớp đơn nhất. Khi đó, nhãn t cần thỏa mãn điều kiện sau:

$$\sum_{i=1}^{l} h_i^t \geq \sum_{i=1}^{l} h_i^k \ với i \ \forall k \in (1,n) \tag{2.25}$$

Trong đó: h_i^t có giá trị là 1 nếu mô hình m_i dự đoán t là nhãn điểm cần phân lớp, và có giá trị là 0 trong trường hợp ngược lại. Mô hình HEA gồm các bộ phân loại đơn sau:

$$HEA \begin{cases} w_1 : LG \\ w_2 : NN \\ w_3 : AB \end{cases}$$

2.2.3.2. Kết quả đánh giá và thảo luận

Trong phần này, NCS tiến hành đánh giá hai mô hình học kết hợp đề xuất với các mô hình đơn cho bài toán phát hiện DGA Botnet – Phân lớp nhị phân. NCS cũng bổ sung các nội dung về kết quả đánh giá trung bình của các mô hình học máy đơn, mô hình mạnh nhất là NN và mô hình yếu nhất là RF. Kết quả đánh giá được tổng hợp và thể hiện tại Bảng 2.9.

Bảng 2.9. Kết quả phát hiện DGA Botnet của mô hình VEA và HEA trên bộ dữ liệu UMUDGA

Thuật toán	**Precision**	**Recall**	**F_1-score**
Trung bình các mô hình đơn	*0,92*	*0,88*	*0,89*
Neural Network (mạnh nhất)	0,97	0,97	0,97
Random Forrest (yếu nhất)	0,74	0,82	0,77
VEA	0,98	0,99	0,98
HEA	0,97	0,97	0,97

Bảng 2.9 cho thấy, cả hai mô hình VEA và HEA đều có độ chính xác cao hơn so với giá trị trung bình của các mô hình đơn, với F_1-score lần lượt là 0,98 và 0,97, coa hơn so với trung bình là 0,89.

So sánh với mô hình đơn yếu nhất là RF có F_1-score là 0,77, ta thấy rằng VEA và HEA hiệu quả hơn rõ rệt về độ chính xác của mô hình. Đối với mô hình mạnh nhất là NN có F_1-score là 0,97, mô hình VEA cải thiện độ chính xác tăng thêm 0,01, với F_1-score tăng từ 0,97 lên 0,98. Điều này được giải thích bởi VEA được kết hợp của cả ba mô hình đơn đã cho kết quả tốt là LG, NN và SVM. Trong trường hợp ngược lại, HEA tuy cải thiện rõ rệt độ chính xác so với mức trung bình, nhưng không có cải thiện so với mô hình đơn tốt nhất là NN. Điều này giải thích bởi việc ta đã đưa vào một bộ phân loại yếu là AB và cơ chế bình chọn không dựa trên trọng số của HEA.

Các kết quả trên cũng cho thấy rằng, cơ chế học cộng đồng hiệu quả trong việc kết hợp ưu điểm của các mô hình yếu, tạo nên một mô hình mạnh hơn. Đồng thời, cả hai mô hình VEA và HEA đều có một sự cân bằng trong Precision và Recall, thể hiện rằng khả năng phát hiện không bị thiên vị về một phía nào.

2.2.3.3. Thời gian huấn luyện và đánh giá

Thời gian huấn luyện và đánh giá của các mô hình cũng là vấn đề được quan tâm. Hình 2.10 thể hiện thời gian dành cho việc huấn luyện và đánh giá của các mô hình học máy đơn và hai mô hình học kết hợp VEA, HEA.

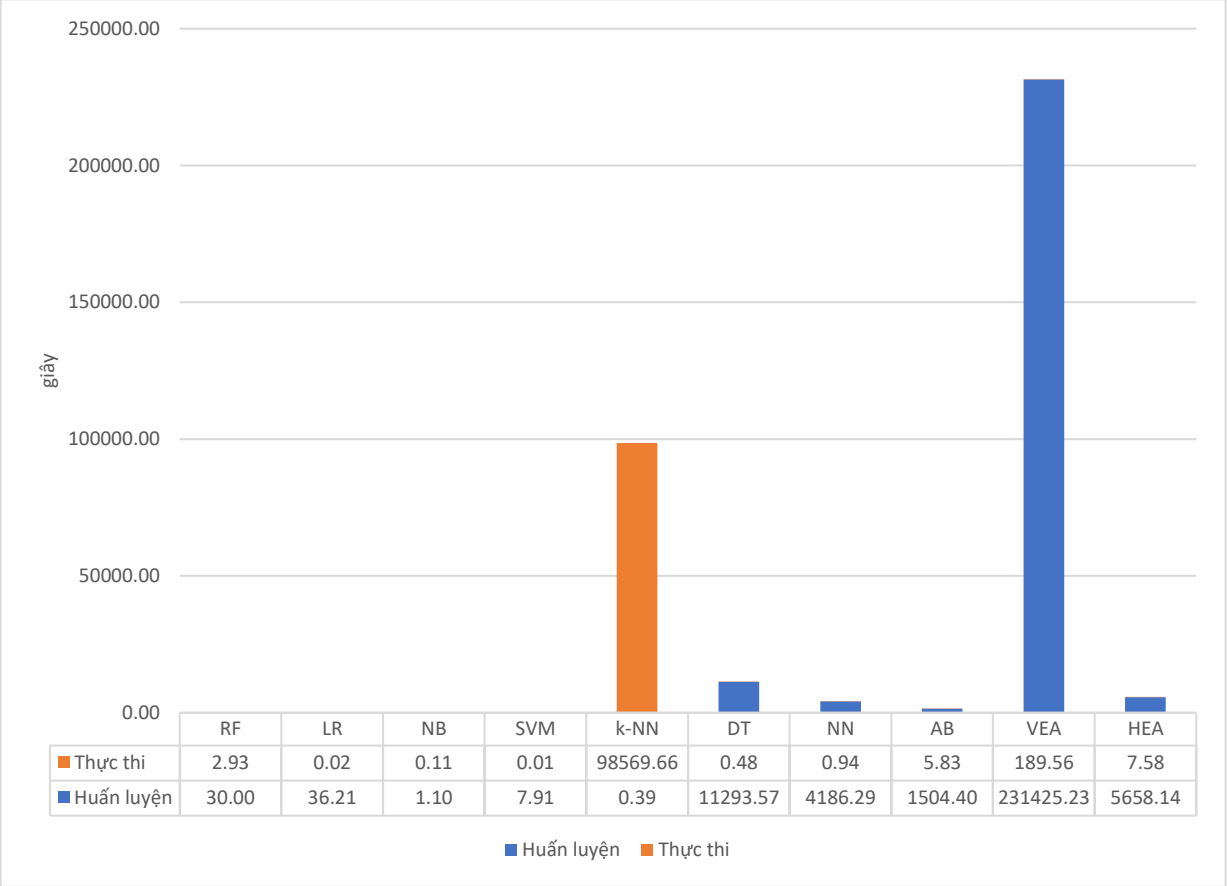

	RF	LR	NB	SVM	k-NN	DT	NN	AB	VEA	HEA
Thực thi	2.93	0.02	0.11	0.01	98569.66	0.48	0.94	5.83	189.56	7.58
Huấn luyện	30.00	36.21	1.10	7.91	0.39	11293.57	4186.29	1504.40	231425.23	5658.14

Hình 2.10. Thời gian huấn luyện và thực thi của VEA, HEA so với các thuật toán học máy trên bộ dữ liệu UMUDGA

Về thời gian huấn luyện, các mô hình DT, RF, AB và NN, VEA và HEA có thời gian huấn luyện khá lâu, đều từ 1.504,40 giây trở lên. Đặc biệt, mô hình VEA có thời gian huấn luyện đặc biệt lâu là 231.425,23 giây. Ở chiều ngược lại, các mô hình như NB, SVM, RF, LR lại có thời gian nhanh hơn rất nhiều với lần lượt 1,10, 7,91, 30,00 và 36,21 giây mà vẫn đảm bảo độ chính xác ở mức cao như đã phân tích ở trên. Cần lưu ý rằng, thông thường các thuật toán học máy sẽ được thực thi trên CPU với tốc độ và khả năng tính toán song song là hạn chế. Điều này có thể được cải thiện bởi các mô hình học sâu có thể chạy trên GPU giúp tiết kiệm nhiều thời gian cho giai đoạn huấn luyện.

Về thời gian thực thi, ngoại trừ k-NN, các mô hình còn lại đều có thời gian thực thi chiếm một tỉ lệ thấp so với thời gian huấn luyện, với các giá trị từ 0,02 giây của LR đến cao nhất là 189,56 giây của VEA. Một điều khá đặc biệt cần lưu ý là mô hình k-NN tuy có thời gian huấn luyện rất nhanh với 0,39 giây, nhưng thời gian đánh giá lại cao hơn rất nhiều với 98.569,66 giây.

2.3. Kết luận Chương 2

Trong chương 2, NCS trình bày các kết quả nghiên cứu và đánh giá cách tiếp cận sử dụng lý thuyết tập mờ và học máy cho bài toán phát hiện DGA Botnet.

- Với hướng tiếp cận sử dụng lý thuyết tập mờ, NCS đã đề xuất ứng dụng thuật toán phân cụm trên tập Neutrosophic Set - NCM để phát hiện DGA Botnet. NCS đã đưa vào các điều chỉnh từ thuật toán gốc để phù hợp với bài toán DGA Botnet. Đánh giá trên 04 bộ dữ liệu tiêu chuẩn cho thấy, thuật toán NCM có độ chính xác tương tự các giải pháp cùng hướng tiếp cận sử dụng lý thuyết mờ. Đồng thời, có ưu điểm là cải thiện đáng kể về Precision so với các bộ phân loại này. Thời gian tính toán của mô hình cũng có sự cân bằng giữa thời gian tiêu hoa và độ chính xác đạt được. Mô hình NCM cũng phát hiện các phần tử nhiễu hay trung tính để từ đó đưa ra các đề nghị kiểm tra bổ sung. Mặc dù có tốc độ thực thi nhanh, hạn chế của NCM là độ chính xác thấp hơn đáng kể so với các thuật toán học máy.

- Với hướng tiếp cận sử dụng học máy, các đánh giá trên 04 bộ dữ liệu tiêu chuẩn cho thấy, các mô hình học máy mang lại độ chính xác cao hơn rất đáng kể, với cao nhất là thuật toán Neural Network với F_1-score đạt 0,97. Độ chính xác này được cải thiện khi sử dụng các mô hình kết hợp dựa trên cơ chế vote là VEA và HEA mà NCS đề xuất.

Cả hai hướng tiếp cận trên đều có những ưu điểm và hạn chế về mặt thời gian hoặc độ chính xác. Đồng thời, việc áp dụng vào bài toán phân lớp đa lớp là còn hạn chế. Cả hai yếu tố này vẫn có thể được giải quyết bằng các mô hình học sâu. Nội dung này được NCS đề xuất và trình bày ở Chương 3 của luận án.

Một phần kết quả nghiên cứu được trình bày tại Chương 2 được công bố tại [CT1] [CT3] trong danh mục công trình của tác giả.

Chương 3. GIẢI PHÁP PHÁT HIỆN VÀ PHÂN LOẠI DGA BOTNET SỬ DỤNG KỸ THUẬT HỌC SÂU

Dựa trên các nghiên cứu và đánh giá trước đó, NCS đề xuất một giải pháp dựa trên kỹ thuật học sâu để nâng cao độ chính xác của bài toán phát hiện và phân loại DGA Botnet. NCS đề xuất hai mô hình học sâu mới là LA_Bin07 và LA_Mul07 trên cơ sở cải tiến so với mạng LSTM truyền thống. Các đánh giá cho thấy, mô hình đề xuất có độ chính xác được cải thiện đáng kể so với các nghiên cứu trước đó, đặc biệt là trong bài toán phân loại DGA Botnet.

3.1. Nền tảng kỹ thuật học sâu

Trong bài toán phát hiện và phân loại Botnet, dữ liệu DNS trong thực tế có tính chất tuần tự, liên tục. Nếu có hoạt động của các con Bot, chúng liên tục gửi các truy vấn DNS được lặp lại sau một khoảng thời gian. Các tên miền này có tính chất giống nhau bởi cùng được sinh ra từ một thuật toán sinh, và nếu mô hình có thể phát hiện được mối quan hệ giữa một tên miền ở thời điểm hiện tại, với các tên miền ghi nhận được trong quãng thời gian trước đó, chúng có cơ sở để phát hiện và phân loại chính xác những tên miền này. Cần lưu ý rằng, mối quan hệ chuỗi này dựa trên tính chất cùng sinh ra bởi một thuật toán sinh và phụ thuộc theo nhân thời gian.

3.1.1. Mạng Recurrent Neural Network

Recurrent Neural Network - RNN hay mạng nơ-ron hồi quy, được thiết kế để huấn luyện với các dữ liệu đầu vào có dạng chuỗi (sequence/ time-series). Mạng RNN có cấu trúc như sau:

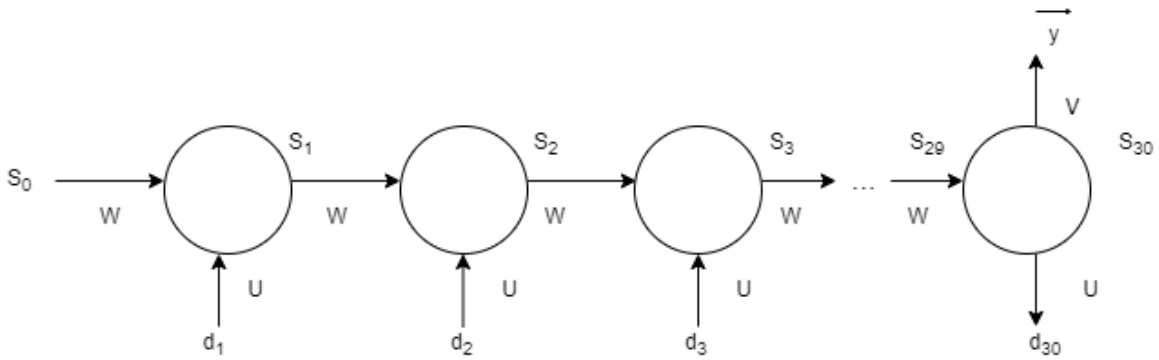

Hình 3.1. Cấu trúc mạng RNN trong bài toán DGA Botnet

Cấu trúc RNN trong Hình 3.1 bao gồm:

- $D = \{d_0, d_1, \dots, d_n\}$: Là các tên miền được sử dụng làm đầu vào. Trong trường hợp này, ta có n tên miền tương ứng với n đầu vào tuần tự.

- Mỗi hình tròn là một $State$, mỗi $State$ bao gồm: Input, Output và Activation Function. Với $State_i$ ta có:

+ Input: d_i và s_{i-1}, với s_{i-1} là Output của $State$ trước đó. Riêng trong $State$ đầu tiên thì s_0 được sử dụng để kích hoạt chuỗi.

+ Output: s_i được tính bằng công thức sau:

$$s_i = f(U \times d_i + W \times s_{i-1}) \tag{3.1}$$

Trong đó, W là ma trận trọng số của mô hình, U là ma trận để biến đổi dữ liệu đầu vào.

+ Acctivation: Hàm f là hàm kích hoạt, thường sử dụng là hàm $Tanh$ hoặc hàm $ReLU$ cho bởi công thức sau:

$$Tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \tag{3.2}$$

$$ReLU(x) = \max(0, x) \tag{3.3}$$

Đồ thị hàm $Tanh$ và hàm $ReLU$ lần lượt được cho tại Hình 3.2 và Hình 3.3. Nhìn vào đồ thị ta thấy, cả hai hàm kích hoạt đều có sự phân hóa rõ ràng ở hai phía của điểm $x = 0$. Tính chất này giúp nó được sử dụng để kích hoạt tìm nhãn cho các mô hình phân lớp.

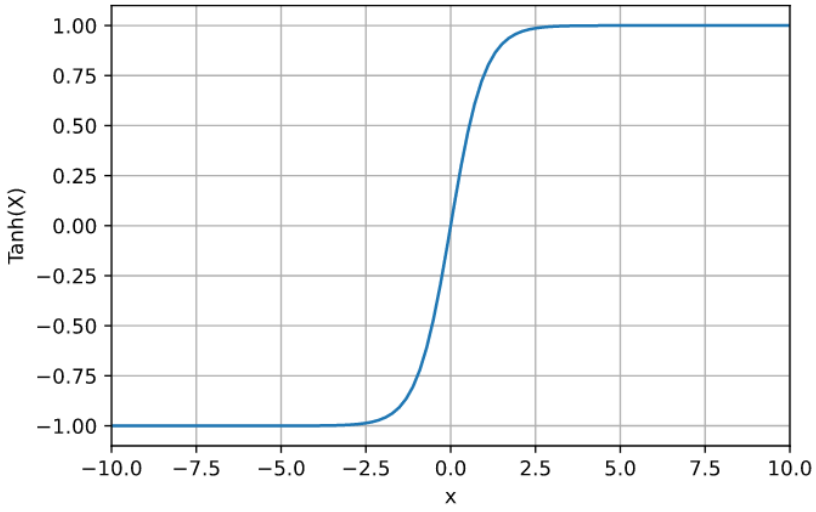

Hình 3.2. Đồ thị hàm $Tanh$

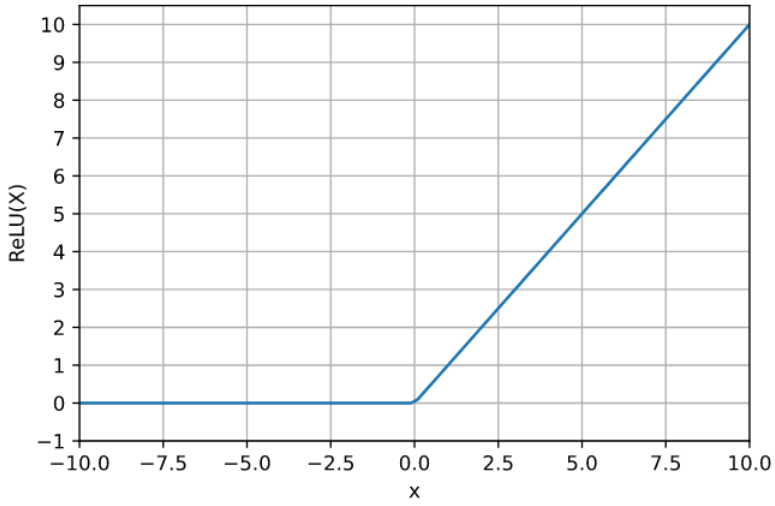

Hình 3.3. Đồ thị hàm $ReLU$

Cấu trúc RNN trong Hình 3.1 cho thấy, s_i được tính toán dựa trên thông tin từ s_{i-1}, và s_{i-1} lại mang thông tin từ s_{i-2}. Điều này có nghĩa là $State$ sau được tính toán một phần dựa vào $State$ trước đó, ta gọi khả năng này là "nhớ" các đặc điểm trước đó của chuỗi. Lưu ý rằng, s_{i-1} và s_{i-2} được tính toán dựa trên d_{i-1} và d_{i-2}. Như vậy, khả năng "nhớ" này về cơ bản chính là các giá trị trước đó của chuỗi dữ liệu đầu vào.

Giá trị s_0 được xem là kích hoạt, biểu thị rằng ban đầu trạng thái bộ nhớ rỗng. Giá trị nhãn sẽ được tính toán sau $State$ cuối cùng ($State_n$). Ở trạng thái này, mô hình đã học được hết các dữ liệu tên miền đầu vào. Giá trị dự đoán $\hat{y}$ được tính bằng công thức sau:

$$\hat{y} = g(V \times s_n) \tag{3.4}$$

Trong đó, g là một hàm kích hoạt phù hợp với bài toán.

3.1.2. Mạng Long-Short Term Memory

Mạng RNN tuy có khả năng nhớ các trạng thái trước đó, nhưng khả năng nhớ này chưa thực sự tốt bởi vấn đề biến mất đạo hàm. Trong mạng RNN, đạo hàm của hàm mất mát phải được tính theo chuỗi các trạng thái trước đó thông qua quá trình lan truyền ngược. Tuy nhiên, khi chuỗi dữ liệu dài, gradient (vector thể hiện hướng tăng/giảm cực đại của hàm số tại mỗi điểm) có thể giảm dần qua mỗi bước thời gian. Và khi đi ngược lại trạng thái trước đó, gradient có thể sẽ suy giảm rất nhanh và tiến gần đến 0. Điều này dẫn đến việc mô hình không thể học các phụ thuộc xa trong quá

khứ và dẫn đến khả năng nhớ của mạng RNN bị hạn chế. Nghĩa là, các $State$ hiện tại có xu hướng nhớ các $State$ gần nó nhiều hơn là các $State$ xa. Điều này khiến cho mô hình bị phụ thuộc nhiều vào các $State$ ở cuối. Đồng thời, hiện tượng biến mất đạo hàm khiến cho quá trình suy giảm độ dốc trở nên kém hiệu quả và sự hội tụ trở nên chậm chạp.

Mạng LSTM được phát triển từ mạng RNN, với khả năng học được các phụ thuộc xa hơn so với RNN. LSTM lần đầu tiên được đề xuất vào năm 1996 bởi Hochreiter [64] và liên tục được cải tiến sau đó. Thuật toán này hoạt động hiệu quả trên nhiều bài toán khác nhau, đặc biệt là các bài toán mà dữ liệu có dạng chuỗi.

Cấu trúc của mạng LSTM cũng dựa trên kiến trúc của RNN, nhưng mỗi $State$ trong chuỗi được cải tiến. Thay vì chỉ có một tầng mạng Neural như RNN, LSTM có 04 tầng trong mỗi $State$ và chúng có thể tương tác với nhau.

Kiến của của một $State$ trong LSTM được thể hiện tại Hình 3.4.

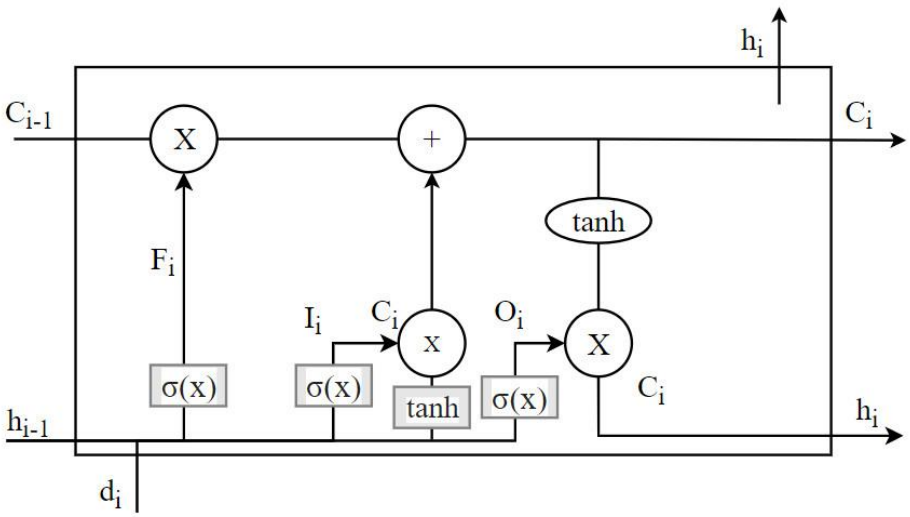

Hình 3.4. Kiến trúc 04 tầng của một $State$ trong LSTM

Trong đó, tại $State_i$ ta có:

- Các mũi tên chỉ đường đi của các giá trị trong $State_i$, thể hiện tuần tự các bước thực hiện.

- Output: Gồm c_i và h_i, trong đó c_i là trạng thái của $State$ hiện tại, h_i là trạng thái ẩn của $State$ hiện tại.

- Input: Gồm c_{i-1}, h_{i-1} và d_i, trong đó c_{i-1} và h_{i-1} là giá trị của $State$ trước đó $State_{i-1}$, được dùng để tính toán cho $State$ hiện tại, đảm bảo khả năng "có nhớ" của mạng LSTM; d_i là giá trị tên miền đầu vào.

Trong một $State$ của LSTM, ta sử dụng thêm một hàm kích hoạt là $Sigmoid$, được tính bằng công thức sau:

$$\sigma(x) = \frac{1}{1 + e^{-x}} \tag{3.5}$$

Hình 3.5 thể hiện đồ thị của hàm $Sigmoid$.

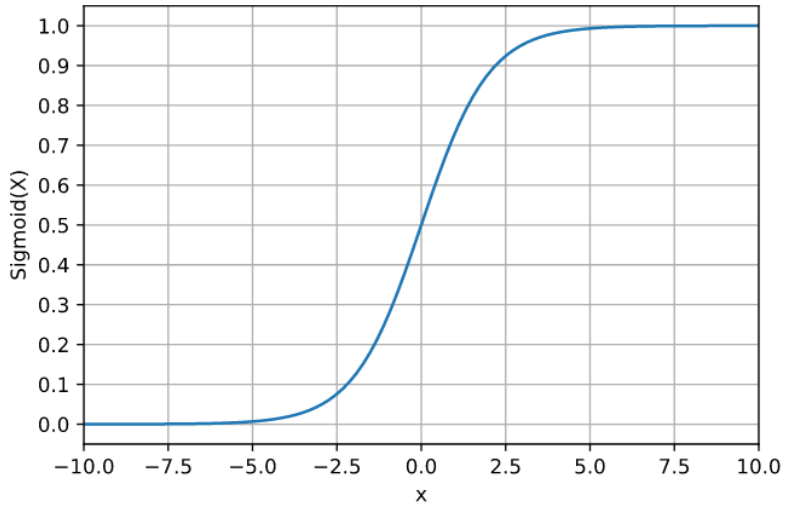

Hình 3.5. Đồ thị hàm $Sigmoid$

Bên trong một $State$ của LSTM, được thiết kế ba cổng gồm cổng Forget Gate F, Input Gate I và Output Gate O. Ở $State_i$, ta có:

$$F_i = \sigma(U_F * d_i + W_F * h_{i-1} + b_F) \tag{3.6}$$

$$I_i = \sigma(U_I * d_i + W_I * h_{i-1} + b_I) \tag{3.7}$$

$$O_i = \sigma(U_O * d_i + W_O * h_{i-1} + b_O) \tag{3.8}$$

Ta có $0 < F_i, I_i, O_i < 1$ vì là kết quả của hàm $Sigmoid$; b_F, b_I và b_O là các sai số để điều chỉnh. Phép $*$ là phép nhân Element-Wise;

Xem xét kỹ hơn tới các Gate, ta có:

- Input Gate I: Cổng này có chức năng lựa chọn bao nhiêu lượng thông tin đầu vào sẽ được dùng cho $State$ mới. Kết quả của I là giá trị của hàm $Sigmoid$, nằm

trong khoảng [0,1]. Một vector khi đi qua hàm này có thể từ không giữ lại được thông tin nào (khi $\sigma = 0$) cho tới được giữ lại thông tin hoàn toàn (khi $\sigma = 1$).

- Forget Gate F: Cổng này sẽ thực hiện việc chọn bao nhiêu thông tin để loại bỏ. Việc thực hiện cũng thông qua hàm $Sigmoid$ tương tự cổng I.

- Output Gate O: Cổng này có chức năng điều chỉnh lượng thông tin có thể ra ngoài, cũng như lượng thông tin truyền tới $State$ tiếp theo.

Cuối cùng, các giá trị đầu ra của $State_i$ được tính bằng công thức sau:

$$\tilde{c}_i = \tanh\left(U_c * d_i + W_c * h_{i-1} + b_c\right) \tag{3.9}$$

$$c_i = F_i * c_{i-1} + I_i * \tilde{c}_i \tag{3.10}$$

$$h_i = O_i * \tanh\left(c_i\right) \tag{3.11}$$

Với sự có mặt của c_i, mô hình LSTM cải tiến hơn so với RNN, giúp lựa chọn và đưa thông tin đi xa hơn trong chuỗi, được minh họa tại Hình 3.6.

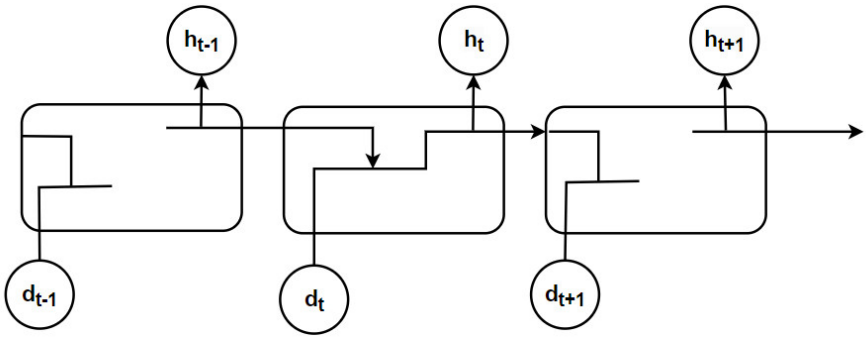

Hình 3.6. Minh họa chuỗi các lớp LSTM

3.1.3. Cơ chế Attention

Mạng LSTM đã khắc phục được hạn chế của RNN về vấn đề nhớ các phụ thuộc ở xa. Tuy nhiên, một vấn đề khác cần quan tâm đó là trọng số của các thuộc tính. Về cơ bản thì mỗi thuộc tính thường có một vai trò khác nhau ảnh hưởng đến nhãn của lớp, có thuộc tính chiếm tỉ trọng nhiều và ngược lại. Cơ chế Attention có thể hỗ trợ để giải quyết vấn đề trên.

Attention là một thành phần gồm ba nhân tố: Query, Key và Value. Chúng được đề xuất để giúp mô hình huấn luyện tập trung hơn vào một đặc điểm nào đó của

dữ liệu, hay nói cách khác là tập trung hơn và các thông tin quan trọng. Các thành phần của Attention được thể hiện tại Hình 3.7:

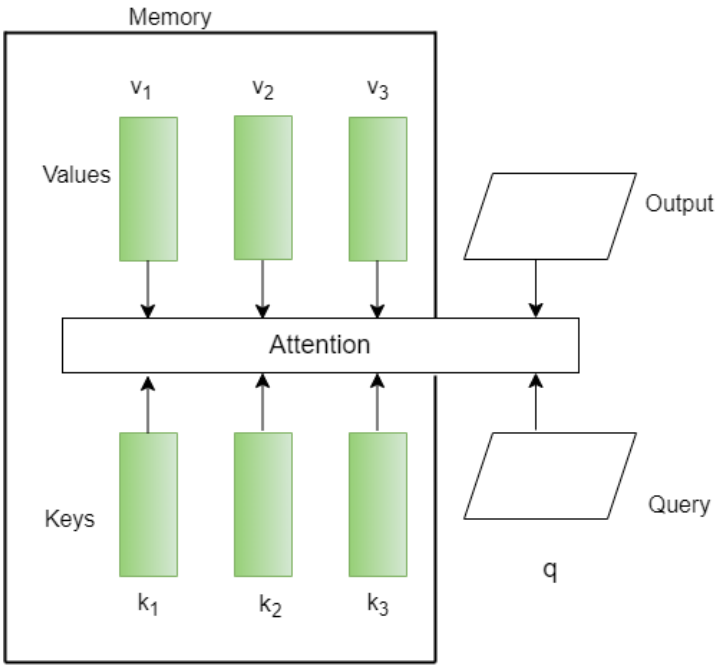

Hình 3.7. Kiến trúc của một lớp Attention

Theo đó, Query q sẽ lấy thông tin tiếp theo cần xử lý. Chúng được chia thành hai phần tương ứng là Key và Value, thông tin thứ i ký hiệu là k_i và v_i

Với mỗi q đầu vào, a_i được gọi là mức độ ảnh hưởng của thông tin thứ i lên q, được tính theo công thức:

$$a_i = \alpha(q, k_i) \tag{3.12}$$

Các giá trị a_i sau đó được chuẩn hóa để có được b_i. Hàm chuẩn hóa thường được sử dụng là $softmax$ [65] như sau:

$$b_i = \frac{exp(a_i)}{\sum_j exp(a_j)}, b = [b_1, b_2, \ldots, b_n]^T \tag{3.13}$$

Các giá trị v_i được tính lại dựa trên b_i. Việc chuẩn hóa giúp cho dữ liệu không bị thay đổi kích cỡ so với mô hình đang huấn luyện. Cuối cùng, đầu ra o là tổng trọng số của các giá trị:

$$o = \sum_{i=1}^{n} b_i v_i \tag{3.14}$$

Cơ chế Attention giúp tăng cường chú ý vào các đặc điểm quan trọng của dữ liệu, có thể áp dụng mở rộng với nhiều bài toán khác.

RNN và cải tiến của nó là LSTM đã thể hiện hiệu quả của mình với khả năng ghi nhận được sự phụ thuộc thời gian của các từ trong câu hay các elements trong tên miền đối với bài toán DGA Botnet. Tuy nhiên, các nghiên cứu mới đã chỉ ra rằng với với cơ chế Attention (mà không cần sử dụng RNN) ta có thể cải thiện được kết quả của các tác vụ học. Kết quả đánh giá với mô hình BERT của Devlin và cộng sự cũng đã minh chứng thêm điều này [66].

3.2. Hai mô hình học sâu mới để phát hiện và phân loại DGA Botnet

Dựa trên tính chất dạng chuỗi, tuần tự của dữ liệu vào, mô hình RNN và cải tiến của nó là LSTM đã chứng minh sự hiệu quả trong các nghiên cứu trước đó. Trong phần này, NCS đề xuất hai mô hình học sâu mới, kết hợp giữa Attention và mạng LSTM cho bài toán phân lớp nhị phân và phân lớp đa lớp. Trong đó, mô hình phân lớp nhị phân đặt tên là LA_Bin07 dành cho việc phân loại tên miền là lành tính hay là của DGA Botnet. Tiếp theo, mô hình phân lớp đa lớp đặt tên là LA_Mul07 sẽ xác định họ của DGA Botnet đã phát hiện ở giai đoạn trước đó.

Giải pháp tổng thể sử dụng hai mô hình LA_Bin07 và LA_Mul07 được mô tả tại Hình 3.8:

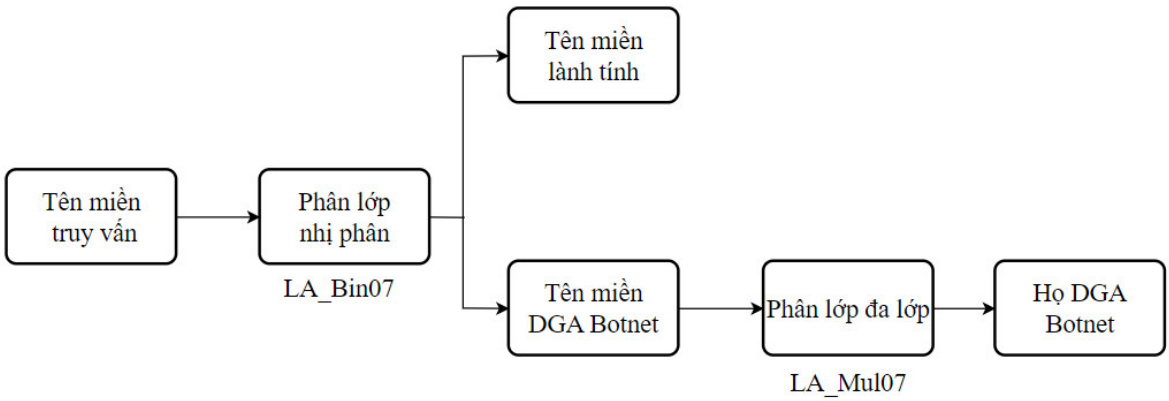

Hình 3.8. Giải pháp phát hiện và phân loại DGA Botnet với hai mô hình học sâu mới LA_Bin07 và LA_Mul07

Đầu tiên, các tên miền truy vấn sẽ được đưa vào mô hình LA_Bin07, mô hình sẽ thực hiện việc gán nhãn đây là tên miền độc hại hay lành tính.

- Đối với các tên miền lành tính, việc truy cập được cho phép diễn ra bình thường trong thực tế.

- Đối với các tên miền độc hại, chúng tiếp tục được đi qua bộ phân loại LA_Mul07 để xác định họ của tên miền DGA Botnet đó.

3.2.1. Mô hình LA_Bin07 cho phát hiện DGA Botnet

Mô hình LA_Bin07 được thiết kế theo dạng Sequence-to-Sequence, với cấu trúc được cho ở Hình 3.9.

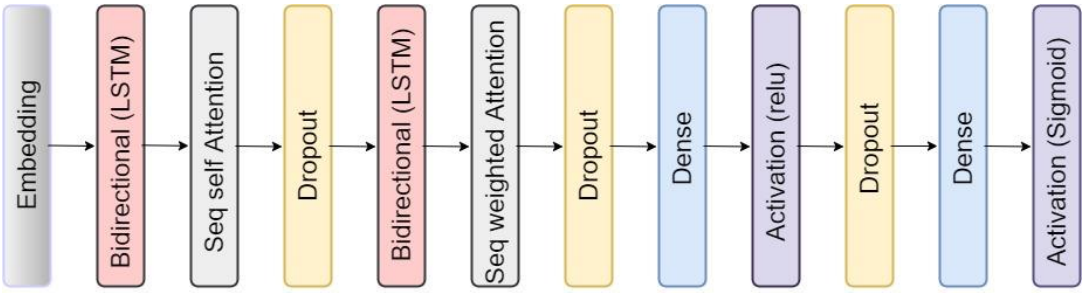

Hình 3.9. Kiến trúc của mô hình LA_Bin07

Trong mô hình LA_Bin07, lớp đầu tiên là Embedding, có chức năng khởi tạo các trọng số ngẫu nhiên cho mô hình và nhúng chúng vào tập huấn luyện. Tiếp theo, dữ liệu được huấn luyện với hai vòng gồm lớp LSTM kết hợp với lớp Attention, theo sau mỗi vòng là lớp Dropout với xác suất $p = 0{,}5$, có chức năng giảm số lượng tham số được sinh ra sau mỗi vòng LSTM và Attention, được áp dụng như sau:

$$h' = \begin{cases} 0 \\ \dfrac{h}{1-p} \end{cases} \tag{3.15}$$

Theo đó, $h' = 0$ xảy ra với xác suất là p. Đầu ra của hàm kích hoạt trung gian h được thay thế bởi một biến ngẫu nhiên h' có cùng kỳ vọng.

Mô hình được tiếp đến với lớp Dense, giúp kết nối dữ liệu trước đó duỗi dữ liệu ra phù hợp với số nhãn cần phân loại. Hàm ReLU được sử dụng cho kích hoạt những giá trị này. Một lớp Droput kế tiếp để giảm tiếp trọng số. Lớp Dense cuối cùng để kết nối các dữ liệu trước khi được kích hoạt bằng hàm Sigmoid để xác định nhãn.

Thiết kế trên giúp mô hình LA_Bin07 vừa đảm bảo được độ chính xác cần thiết, vừa giúp giảm bớt khối lượng tính toán. Chi tiết về mô hình được thể hiện ở Bảng 3.1.

Bảng 3.1. Chi tiết về kích thước đầu và số lượng tham số của mô hình LA_Bin07

STT	Lớp	Kích thước đầu ra	Số tham số
1	Embedding	(None, 100, 128)	640.000
2	Bidirectional LSTM	(None, 100, 256)	263.168
3	Seq Self Attention	(None, None, 256)	16.449
4	Dropout	(None, None, 256)	0
5	Bidirectional LSTM	(None, None, 256)	394.240
6	Seq Weighted Attetion	(None, 256)	257
7	Dropout	(None, 256)	0
8	Dense	(None, 64)	16.448
9	Activation (ReLU)	(None, 64)	0
10	Dropout	(None, 64)	0
11	Dense	(None, 1)	65
12	Activation (Sigmoid)	(None, 1)	0
Tổng số tham số			1.330.627

Về chi tiết, kiến trúc mô hình LA_Bin07 được mô tả bao gồm các lớp theo thứ tự như sau:

1. Lớp nhúng (Embedding): Lớp này chuyển đổi đầu vào thành một không gian nhúng có kích thước (None, 100, 128). Tổng số tham số của lớp nhúng là 640.000.

2. Lớp Bidirectional LSTM: Lớp này sử dụng mạng LSTM có kết nối hai chiều, giúp mô hình có khả năng học từ cả hai phía của dữ liệu chuỗi. Kích thước đầu ra của lớp này là (None, 100, 256) và số tham số là 263.168.

3. Lớp Seq Self Attention: Lớp này áp dụng cơ chế Attention để tạo ra một ma trận trọng số Attention dựa trên đầu ra của lớp trước đó. Kích thước đầu ra của lớp này là (None, None, 256) và số tham số là 16.449.

3. Lớp Dropout: Lớp này áp dụng kỹ thuật Dropout để ngẫu nhiên loại bỏ một số lượng các đơn vị trong quá trình huấn luyện, nhằm tránh hiện tượng quá khớp. Kích thước đầu ra và số tham số của lớp này giống với lớp Seq Self Attention.

4. Lớp Bidirectional LSTM: Tương tự như lớp thứ 2, lớp này sử dụng mạng LSTM hai chiều với kích thước đầu ra là (None, None, 256) và số tham số là 394.240.

5. Lớp Seq Weighted Attention: Lớp này áp dụng cơ chế Attention dựa trên trọng số cho chuỗi đầu vào, tạo ra một đầu ra có kích thước (None, 256). Số tham số của lớp này là 257.

6. Lớp Dropout: Lớp này có kích thước đầu ra là (None, 256) và số tham số là 0, tương tự như các lớp Dropout trước đó.

7. Lớp Dense: Lớp này áp dụng phép biến đổi tuyến tính và có kích thước đầu ra là (None, 64). Số tham số của lớp này là 16.448.

8. Lớp Activation (ReLU): Lớp này áp dụng hàm kích hoạt ReLU lên đầu ra của lớp trước đó.

9. Lớp Dropout: Tương tự như các lớp Dropout trước đó.

10. Lớp Dense: Lớp này có kích thước đầu ra là (None, 1), nhằm thực hiện phân loại nhị phân. Số tham số của lớp này là 65.

11. Lớp Activation (Sigmoid): Lớp này áp dụng hàm kích hoạt Sigmoid lên đầu ra của lớp trước đó, để đưa ra dự đoán cuối cùng về xác suất tên miền là độc hại hay không.

Tổng cộng, mô hình này có tổng số tham số là 1.330.627. Các lớp nhúng và các lớp LSTM đóng vai trò quan trọng trong việc xử lý dữ liệu chuỗi và trích xuất các đặc trưng. Các lớp Dropout giúp kiểm soát hiện tượng quá khớp và tăng tính tổng quát của mô hình. Các lớp Dense và Activation cuối cùng đóng vai trò trong quá trình phân loại tên miền độc hại.

3.2.2. Mô hình LA_Mul07 cho phân loại DGA Botnet

Đối với bài toán phân lớp đa lớp, mô hình LA_Mul07 được thiết kế tinh giản hơn cho phù hợp với yêu cầu xác định nhiều nhãn dữ liệu. Một số lớp Dense và Dropout được loại bỏ, hàm kích hoạt được sử dụng là $Softmax$.

Kiến trúc các lớp trong mô hình LA_Mul07 được thể hiện ở Hình 3.10.

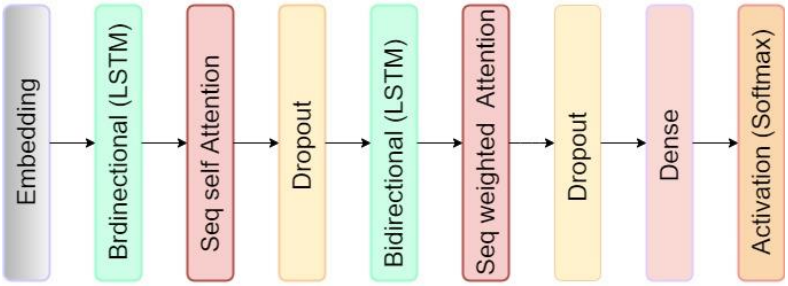

Hình 3.10. Cấu trúc đề xuất của mô hình LA_Mul07

Trong mô hình LA_Mul07, lớp đầu tiên là Embedding để khởi tạo các trọng số và đưa dữ liệu vào. Hai bộ kết hợp LSTM + Attention + Dropout được thực hiện liên tiếp để huấn luyện tương tự LA_Bin07. Lớp Dense giúp duỗi các giá trị tương ứng và mô hình sẽ xác định nhãn thông qua hàm kích hoạt $Softmax$ ở lớp cuối cùng.

Trong bài toán phân lớp đa lớp, số nhãn đưa vào thường khá nhiều (ví dụ 50 nhãn đối với bộ dữ liệu UMUDGA), số tham số cần tính toán có thể tăng nhanh nên một mô hình không quá phức tạp sẽ giảm bớt khối lượng tính toán. Chi tiết về mô hình LA_Mul07 được cho ở Bảng 3.2:

Bảng 3.2. Chi tiết về kích thước đầu và số lượng tham số của mô hình LA_Mul07

STT	**Lớp**	**Kích thước đầu ra**	**Số tham số**
1	Embedding	(None, 100, 128)	640.000
2	Bidirectional LSTM	(None, 100, 256)	263.168
3	Seq Self Attention	(None, None, 256)	16.449
4	Dropout	(None, None, 256)	0
5	Bidirectional LSTM	(None, None, 256)	394.240
6	Seq Weighted Attetion	(None, 256)	257
7	Dropout	(None, 256)	0
8	Dense	(None, n)	P_n
9	Activation (Softmax)	(None, n)	0
Tổng số tham số			1.314.114+P_n

Trong đó, P_n là số lớp cần phân loại, giá trị này càng tăng khi mà số lượng lớp càng nhiều.

Về chi tiết, kiến trúc mô hình LA_Mul07 được mô tả bao gồm các lớp theo thứ tự như sau:

1. Lớp nhúng (Embedding): Lớp này chuyển đổi đầu vào thành một không gian nhúng có kích thước (None, 100, 128). Tổng số tham số của lớp nhúng là 640.000.

2. Lớp Bidirectional LSTM: Lớp này sử dụng mạng LSTM hai chiều, giúp mô hình có khả năng học từ cả hai phía của dữ liệu chuỗi. Kích thước đầu ra của lớp này là (None, 100, 256). Số tham số của lớp này là 263.168.

3. Lớp Seq Self Attention: Lớp này áp dụng cơ chế Attention để tạo ra một ma trận trọng số attention dựa trên đầu ra của lớp trước đó. Kích thước đầu ra của lớp này là (None, None, 256). Số tham số của lớp này là 16.449.

4. Lớp Dropout: Lớp này áp dụng kỹ thuật Dropout để ngẫu nhiên loại bỏ một số lượng các đơn vị trong quá trình huấn luyện, nhằm tránh hiện tượng quá khớp. Kích thước đầu ra và số tham số của lớp này giống với lớp Seq Self Attention.

5. Lớp Bidirectional LSTM: Tương tự như lớp thứ 2, lớp này sử dụng mạng LSTM hai chiều với kích thước đầu ra là (None, None, 256) và số tham số là 394.240.

6. Lớp Seq Weighted Attention: Lớp này áp dụng cơ chế Attention dựa trên trọng số cho chuỗi đầu vào, tạo ra một đầu ra có kích thước (None, 256). Số tham số của lớp này là 257.

7. Lớp Dropout: Lớp này có kích thước đầu ra là (None, 256) và số tham số là 0, tương tự như các lớp Dropout trước đó.

8. Lớp Dense: Lớp này có kích thước đầu ra là (None, n), với n là số lượng lớp đầu ra mong muốn. Số tham số của lớp này là P_n.

9. Lớp Activation (Softmax): Lớp này áp dụng hàm kích hoạt Softmax lên đầu ra của lớp Dense. Softmax chuyển đổi giá trị đầu ra thành một phân phối xác suất, trong đó tổng các xác suất bằng 1. Kích thước đầu ra của lớp này là (None, n), tương ứng với số lượng lớp đầu ra mong muốn.

Tổng cộng, mô hình này có tổng số tham số là 1.314.114 + P_n.

3.2.3. Cải tiến so với LSTM truyền thống

Hai mô hình LA_Bin07 và LA_Mul07 được thiết kế theo dạng seq2seq. Đây là mô hình chuỗi, gồm các lớp kế tiếp nhau và có thứ tự về thời gian. Điều này có

nghĩa là, các dữ liệu từ ở đầu vào sẽ có mối liên hệ lớn hơn đối với các dữ liệu từ ở đầu ra trong cùng vị trí. Một ví dụ của dạng thiết kế này là mô hình Transformer [67].

Trong hai mô hình mạng mới này, NCS có sự cải tiến so với LSTM truyền thống, đó là sự kết hợp với Attention và kích thước, thứ tự các lớp trong mạng. Lớp Attention trong hai mô hình đề xuất đóng vai trò giúp thuật toán điều chỉnh sự tập trung lớn hơn ở các cặp dữ liệu từ ở đầu vào trước khi chúng được đưa vào huấn luyện trong LSTM.

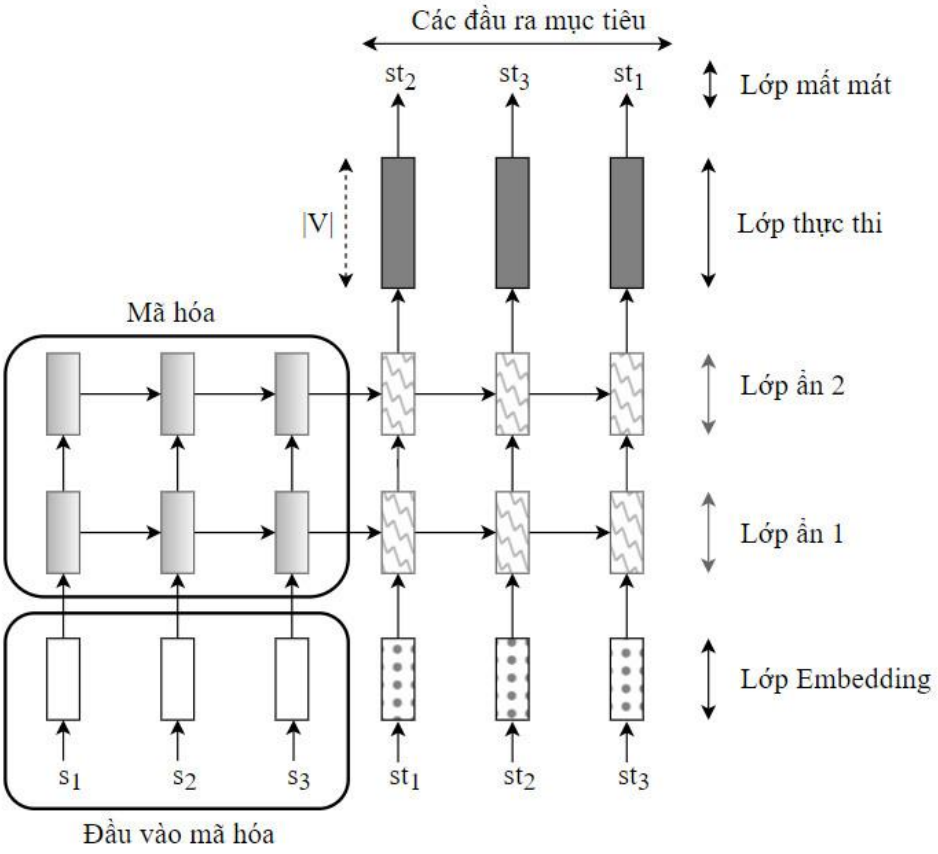

Hình 3.11. Mô hình LSTM truyền thống không có Attention

Ở Hình 3.11, mô hình LSTM truyền thống không có Attention, dữ liệu đầu vào s_1, s_2, s_3 sau khi qua bộ mã hóa sẽ được đưa tới các Lớp ẩn 1, Lớp ẩn 2 của mô hình học sâu để huấn luyện. Tại các lớp này, vai trò của s_1, s_2, s_3 được mô hình coi là như nhau.

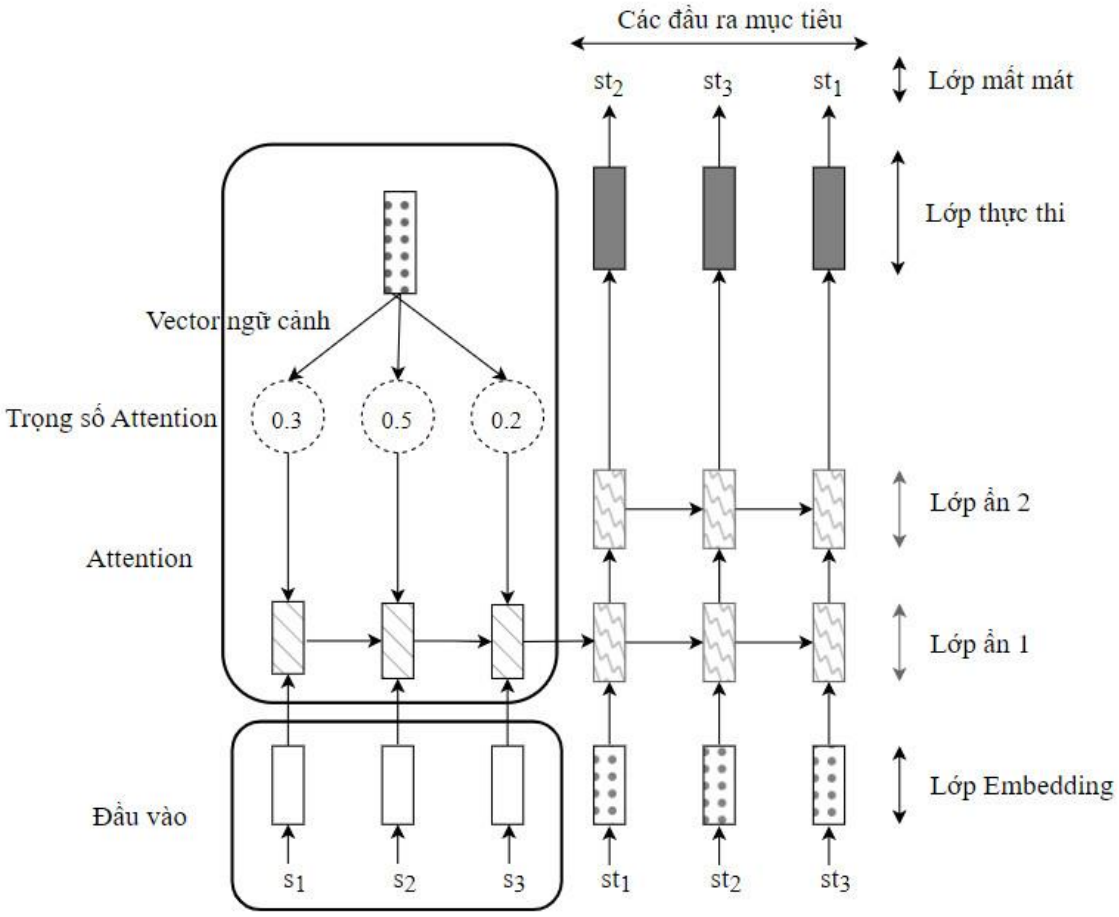

Hình 3.12. Mô hình LSTM cải tiến với Attention

Hình 3.12 mô tả vai trò của Attention trong mạng LSTM mới. Sự có mặt của Attention giúp tính toán trọng số cho từng phần tử đầu vào là s_1, s_2, s_3 được gán với bộ trọng số tương ứng $(0{,}3, 0{,}5, 0{,}2)$. Trọng số này giúp các Lớp ẩn 1, Lớp ẩn 2 trong mô hình học sâu biết những nội dung nào quan trọng hơn để tập trung hơn. Đây là sự phát triển của mô hình đề xuất so với mô hình LSTM truyền thống.

Nhìn tổng thể, mạng LSTM kết hợp Attention trong mô hình LA_Bin07 và LA_Mul07 có các cải tiến so với mạng LSTM truyền thống. Mạng mới giúp tăng cường truyền thông tin chính xác giữa các lớp ẩn nhờ việc có thêm trọng số cho các thành phần đầu vào. Các trọng số được quyết định với lớp Self Attention dựa trên các lớp ẩn, trạng thái từng $Stage$ trong LSTM và bước thời gian hiện tại. Các thông tin chính xác hơn giúp cho mô hình học sâu huấn luyện được hiệu quả hơn.

Một cải tiến khác của mô hình LA_Bin07 và LA_Mul07 so với các mô hình truyền thống là kiến trúc, kỹ thuật lựa chọn, sắp xếp và cấu hình trọng số các lớp. Các

tính toán công phu và chi tiết của NCS cho thấy hai mô hình trên đạt được hiệu quả tối ưu trong cả hai bài toán của DGA Botnet.

3.3. Đánh giá hai mô hình học sâu đề xuất

3.3.1. Bộ dữ liệu và môi trường đánh giá

Trong đánh giá của mình, NCS sử dụng cả 04 bộ dữ liệu tiêu chuẩn cho bài toán phân lớp nhị phân và sử dụng 02 bộ dữ liệu trong số đó gồm Andrey Abakymov's DGA Repository và UMUDGA Dataset cho bài toán phân lớp đa lớp. Các bộ dữ liệu được chia theo tỉ lệ 80%-20% tương ứng với tập huấn luyện và tập đánh giá. Chi tiết về các bộ dữ liệu đã được trình bày tại mục 1.3.5 của luận án này.

Mô hình được huấn luyện và đánh giá trên công cụ Google Colab Pro, môi trường Linux, sử dụng GPU Tesla K80, thư viện hỗ trợ Keras, batch_size = 64.

3.3.2. Đánh giá mô hình LA_Bin07 cho bài toán phát hiện DGA Botnet

Đối với bài toán phân lớp nhị phân, kết quả đánh giá mô hình LA_Bin07 qua các tham số Accuracy, Precision, Recall và F_1-Score được cho ở Hình 3.13:

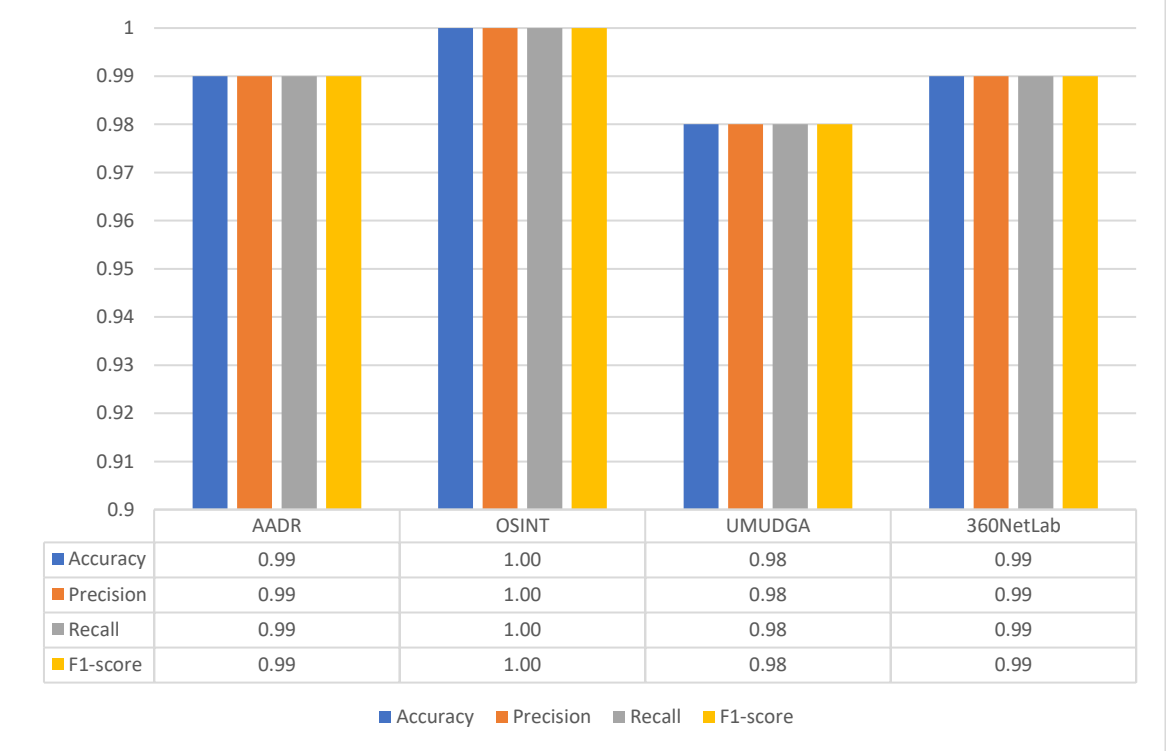

	AADR	OSINT	UMUDGA	360NetLab
Accuracy	0.99	1.00	0.98	0.99
Precision	0.99	1.00	0.98	0.99
Recall	0.99	1.00	0.98	0.99
F1-score	0.99	1.00	0.98	0.99

Hình 3.13. Kết quả đánh giá của mô hình LA_Bin07 cho bài toán phân lớp nhị phân trên 04 bộ dữ liệu tiêu chuẩn

Biểu đồ ROC Curve và AUC tương ứng đối với 04 bộ dữ liệu AADR, OSINT, UMUDGA và 360NetLab được cho tại Hình 3.14:

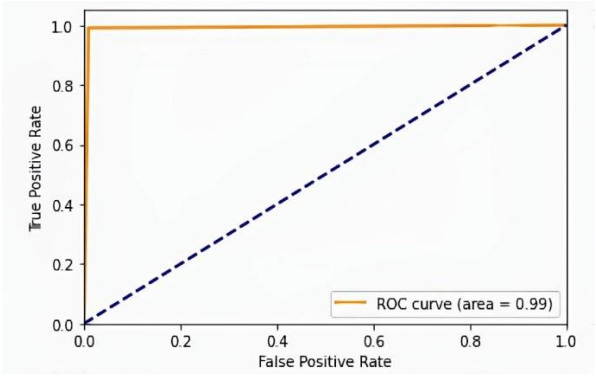

a) AADR

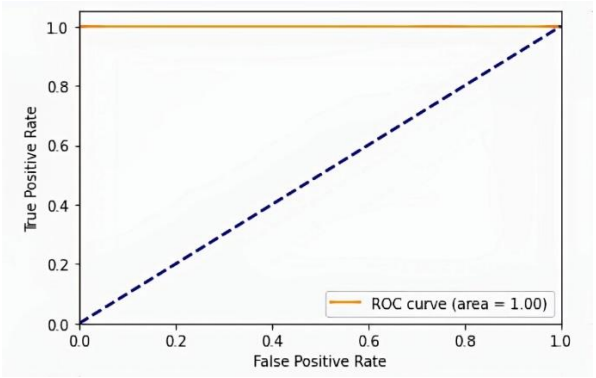

b) OSINT

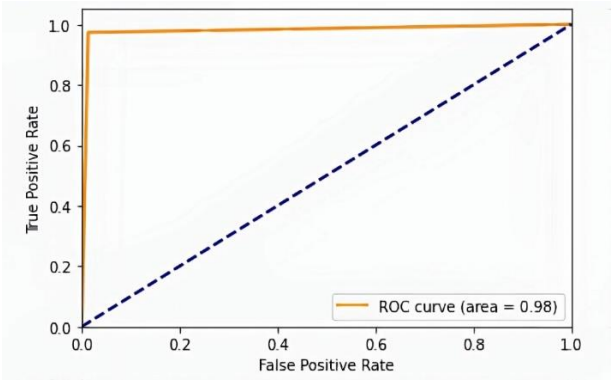

c) UMUDGAt

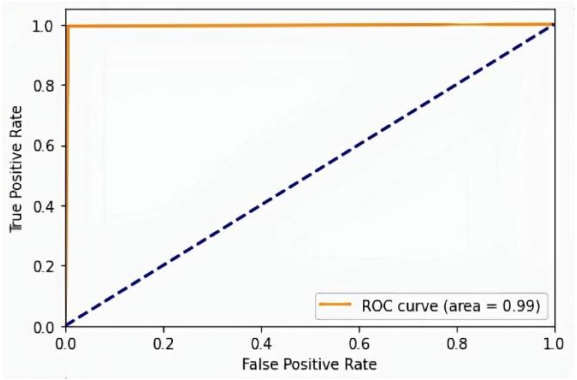

d) 360NetLab

Hình 3.14. ROC Curve và AUC của LA_Bin07 khi đánh giá trên 04 bộ dữ liệu tiêu chuẩn

Các kết quả trình bày ở trên cho thấy mô hình LA_Bin07 có độ chính xác rất cao trong việc phân loại các tên miền lành tính và độc hại, với Accuracy đều đạt từ 0,98 trở lên trên cả 04 bộ dữ liệu tiêu chuẩn được đánh giá. Điều này cũng thể hiện thông qua ROC Curve và AUC, với ROC Curve đạt trạng thái gần tối ưu và AUC cũng đạt từ 0,98 trở lên.

Đặc biệt, mô hình LA_Bin07 dự đoán chính xác với tỉ lệ là 1,00 trên bộ dữ liệu OSINT. Đây là bộ dữ liệu về DGA Botnet chứa các tên miền được phát hiện và ghi nhận trên Internet. Kết quả thử nghiệm trên bộ dữ liệu UMUDGA thấp hơn một chút ở mức 0,98 có thể được giải thích bởi số lượng mẫu DGA Botnet nhiều hơn và đa dạng hơn, trong đó có một số họ tên miền khá giống với tên miền lành tính về cả độ dài, không gian ký tự, từ khóa và ngữ nghĩa.

Chi tiết hơn về khả năng phân loại nhị phân của mô hình LA_Bin07 được thể hiện bởi ma trận nhầm lẫn và ma trận nhầm lẫn chuẩn hóa. Các ma trận này được thể hiện ở Hình 3.15, là kết quả thử nghiệm của mô hình LA_Bin07 trên các bộ dữ liệu AADR, OSINT, UMUDGA và 360NetLab.

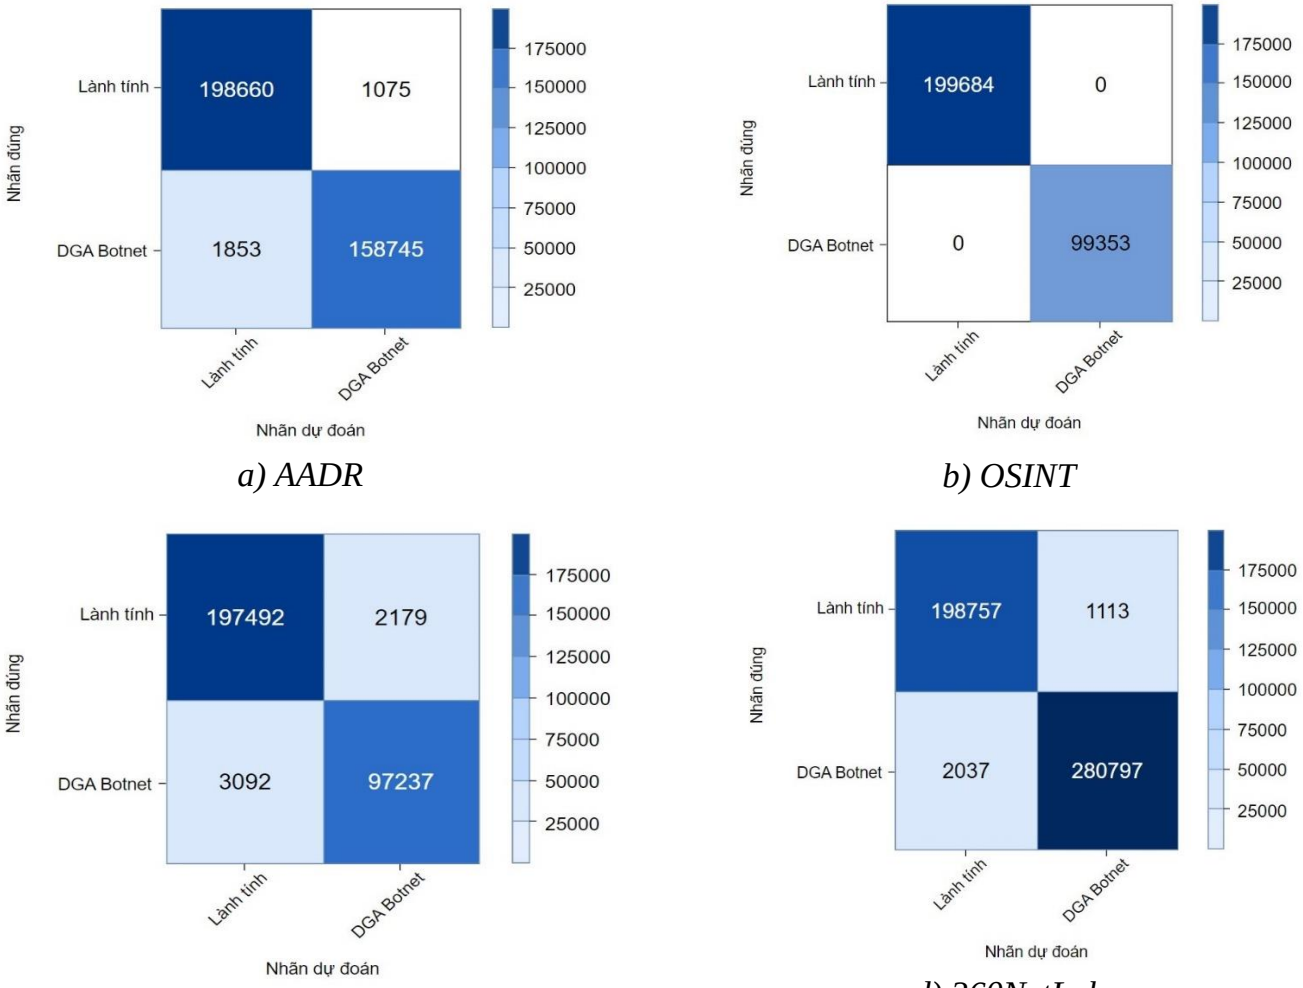

a) AADR *b) OSINT*

c) UMUDGA *d) 360NetLab*

Hình 3.15. Ma trận nhầm lẫn của mô hình LA_Bin07 khi đánh giá trên 04 bộ dữ liệu tiêu chuẩn

Hình trên cho thấy, mô hình LA_Bin07 có kết quả tốt nhất trên bộ dữ liệu OSINT, với số lượng mẫu chấp nhận nhầm và phát hiện nhầm là 0 (tỉ lệ 0,00). Ở hướng ngược lại, mô hình LA_Bin07 có số lượng mẫu chấp nhận nhầm và phát hiện nhầm lần lượt là 3.092 và 2.179 mẫu, tỉ lệ là 0,03 trên bộ dữ liệu UMUDGA. Điều này có thể giải thích bởi bộ UMUDGA có cập nhật thêm một số họ DGA Botnet mới với các đặc trưng giống tên miền lành tính đã phân tích ở trên. Một số mẫu đặc trưng dạng này như gozi_gpl, gozi_lutherm gozi_nase và gozi_rfc4343.

Trong vấn đề phòng chống DGA Botnet, việc phát hiện nhầm một tên miền lành tính thành độc hại có thể được xem là ít nguy hiểm hơn so với việc bỏ sót một tên miền độc hại được gán nhãn thành lành tính. Các ma trận nhầm lẫn ở Hình 3.15 cho thấy mô hình đề xuất có tỉ lệ bỏ sót các tên miền của DGA Botnet là rất thấp, đều dưới 0,03.

Hình 3.16 thể hiện thời gian huấn luyện và đánh giá của mô hình LA_Bin07 trên 04 bộ dữ liệu tiêu chuẩn.

Hình 3.16. Thời gian huấn luyện và đánh giá của mô hình LA_Bin07 trên 04 bộ dữ liệu tiêu chuẩn

Có thể thấy, mô hình LA_Bin07 có thời gian luyện dao động từ 3.106 giây đến 6.883 giây cho mỗi bộ dữ liệu. Thời gian huấn luyện này tăng dần theo thứ tự OSINT, UMUDGA, AADR và 360NetLab với lần lượt là 3.106 giây, 4.424 giây, 5.083 giây và 6.883 giây. Nguyên nhân là do số lượng mẫu tên miền của các bộ dữ liệu trên cũng tăng theo thứ tự trên.

Trong cả bốn trường hợp, mô hình được huấn luyện với epoch = 10. Các ghi nhận thực tế cho thấy rằng mô hình bắt đầu hội tụ từ epoch = 6 trở đi. Hơn nữa, việc tăng số lượng epoch huấn luyện có thể cải thiện một chút độ chính xác, nhưng lại tốn kém nhiều hơn về mặt thời gian.

Cuối cùng, có thể thấy rằng thời gian để huấn luyện và đánh giá ổn định và tận dụng được năng lực tính toán của GPU. Các mô hình học máy có thời gian huấn luyện

nhanh hơn như LR, SVM lại không đạt được độ chính xác tương đương. Do đó, mô hình đề xuất hoàn toàn có thể đáp ứng được yêu cầu xử lý trong thực tế. Cần lưu ý rằng, việc huấn luyện mô hình trên CPU cho tốc độ chậm hơn rất nhiều so với huấn luyện trên GPU.

3.3.3. Đánh giá mô hình LA_Mul07 cho bài toán phân loại DGA Botnet

Mô hình LA_Mul07 áp dụng cho bài toán phân loại DGA Botnet được đánh giá lần lượt trên hai bộ dữ liệu là AADR và UMUDGA, bởi các bộ dữ liệu này đã được gán nhãn các họ DGA Botnet cho từng tên miền.

3.3.3.1. Đánh giá trên bộ dữ liệu AADR

Kết quả đánh giá mô hình LA_Mul07 trên bộ AADR bao gồm các tham số đánh giá, ma trận nhầm lẫn và ROC Curve lần lượt được thể hiện tại Bảng 3.3, Hình 3.17 và Hình 3.18 như sau:

Bảng 3.3. Kết quả đánh giá mô hình LA_Mul07 trên bộ dữ liệu AADR

STT	**DGA Botnet**	**Precision**	**Recall**	**F_1-Score**
1	cryptolocker	1,00	0,98	0,99
2	zeus	1,00	1,00	1,00
3	pushdo	1,00	1,00	1,00
4	rovnix	1,00	1,00	1,00
5	tinba	0,98	1,00	0,99
6	conficker	1,00	1,00	1,00
7	matsnu	1,00	1,00	1,00
8	ramdo	1,00	1,00	1,00
Avg Accuracy		***1,00***		

Mô hình LA_Mul07 có độ chính xác phân loại rất cao trên bộ dữ liệu AADR, tiệm cận đến mức chính xác hoàn toàn với Avg Accuracy đạt 1,00. Trong 08 họ DGA Botnet được xem xét tới thì có 06 họ DGA Botnet bao gồm: cryptolocker, zeus, pushdo, rovnix, conficker, matsnu và ramdo được phát hiện gần như chính xác hoàn toàn với Precision, Recall, F_1-Score đều đạt 1,00.

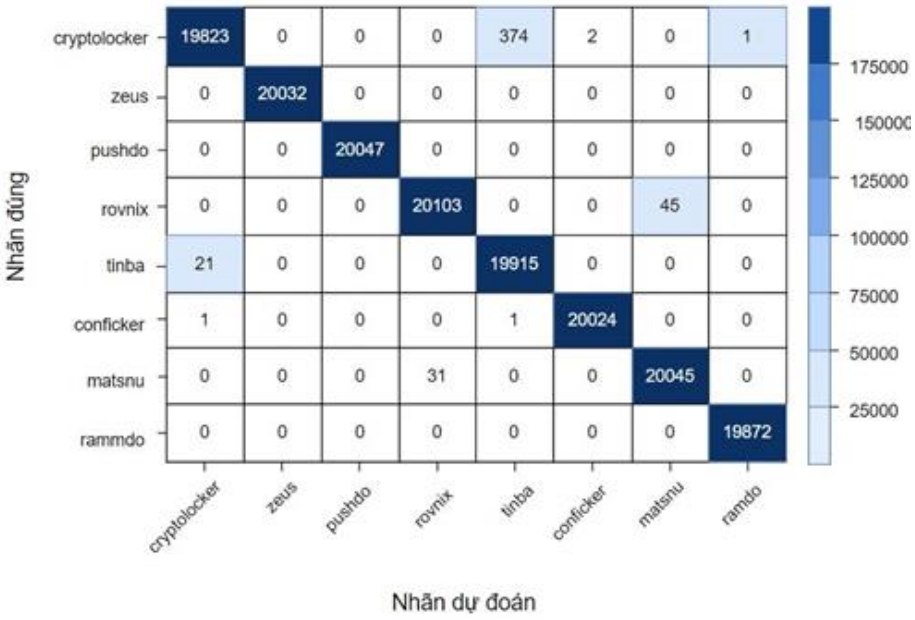

a) Ma trận nhầm lẫn

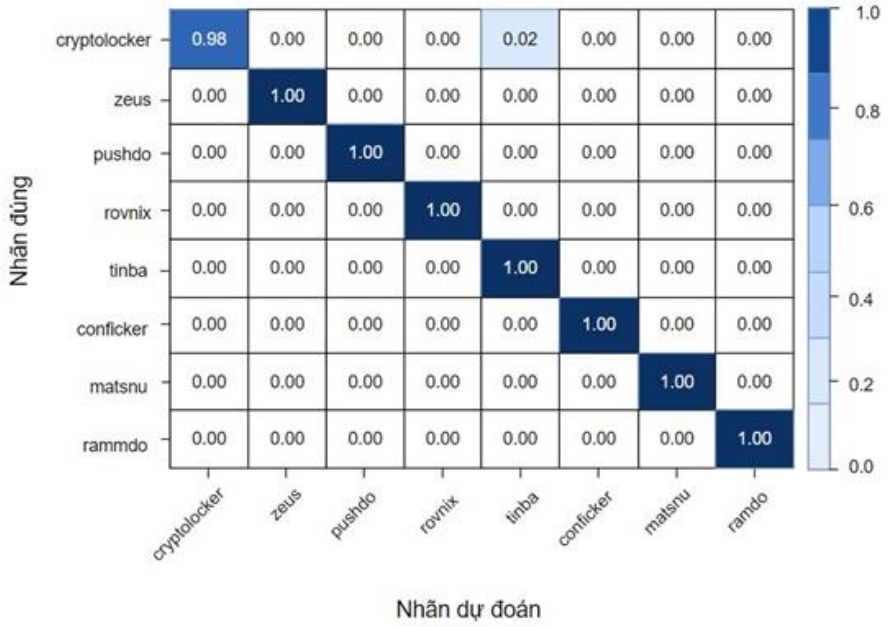

b) Ma trận nhầm lẫn chuẩn hóa

Hình 3.17. Ma trận nhầm lẫn và ma trận nhầm lẫn chuẩn hóa của mô hình LA_Mul07 khi phân loại 08 họ DGA Botnet trên bộ dữ liệu AADR

Ma trận nhầm lẫn ở Hình 3.17 cho thấy các tên miền lành tính và độc hại được phân loại một cách gần như chính xác. Trong ma trận nhầm lẫn chuẩn hóa, điều này thể hiện bằng giá trị 1,00 ở các ô nằm trên đường chéo chính của ma trận. Riêng họ cryptolocker có tỉ lệ 0,02 các mẫu bị phân loại sai thành họ tinba.

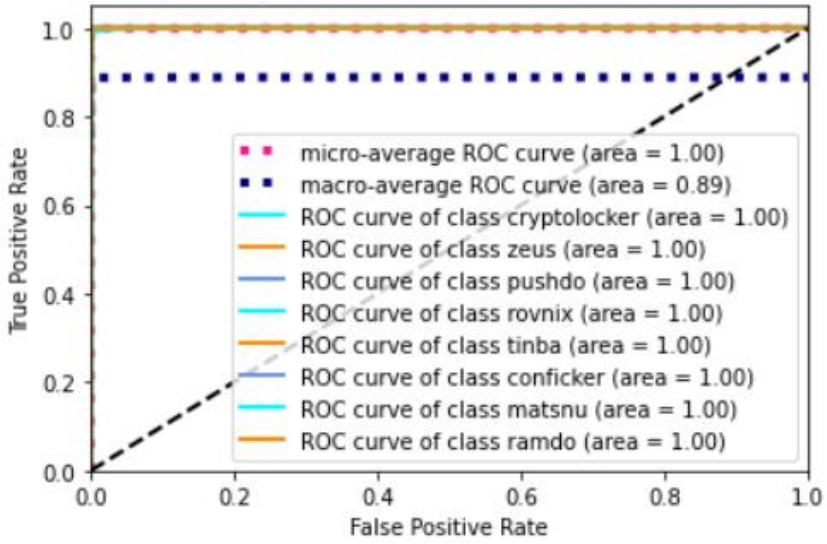

Hình 3.18. Biểu diễn ROC Curve và AUC của LA_Mul07 trên bộ dữ liệu AADR

Hình 3.18 cho thấy rõ hơn hiệu quả của mô hình LA_Mul07, với các đường ROC Curve và Area, giá trị đạt gần như tuyệt đối.

3.3.3.2. Đánh giá trên bộ dữ liệu UMUDGA

Kết quả đánh giá mô hình LA_Mul07 trên bộ dữ liệu UMUDGA gồm các thông số và ma trận nhầm lẫn lần lượt được cho tại Bảng 3.4 và Hình 3.19.

Bảng 3.4. Kết quả đánh giá mô hình LA_Mul07 trên bộ dữ liệu UMUDGA

STT	DGA Botnet	Pre	Re	F_1	STT	DGA Botnet	Pre	Re	F_1
1	alureon	0,45	0,92	0,60	26	pizd	0,97	0,86	0,91
2	banjori	0,99	1,00	1,00	27	proslikefan	0,82	0,65	0,73
3	bedep	0,96	0,47	0,63	28	pushdo	0,99	0,99	0,99
4	ccleaner	1,00	1,00	1,00	29	pykspa	0,39	0,57	0,47
5	china	1,00	0,99	1,00	30	pykspa_noise	0,35	0,16	0,22
6	corebot	1,00	1,00	1,00	31	qadars	0,99	0,99	0,99
7	cryptoloker	0,70	0,66	0,68	32	qakbot	0,84	0,55	0,67
8	dircrypt	0,52	0,42	0,47	33	ramdo	1,00	1,00	1,00
9	dyre	1,00	1,00	1,00	34	ramnit	0,44	0,66	0,52
10	fobber_v1	0,88	1,00	0,93	35	ranbyus_v1	0,76	0,98	0,86
11	fobber_v2	0,48	0,08	0,14	36	ranbyus_v2	0,76	0,88	0,82
12	gozi_gpl	0,96	0,99	0,98	37	rovnix	0,97	0,94	0,95
13	gozi_luther	0,97	0,95	0,96	38	shiotob	1,00	0,90	0,95
14	gozi_nase	0,89	0,97	0,93	39	simda	1,00	1,00	1,00

15	gozi_rfc4343	0,91	0,98	0,90	40	aaron	1,00	1,00	1,00
16	kraken_v1	0,72	0,96	0,83	41	suppobox_1	0,87	0,97	0,92
17	kraken_v2	0,82	0,41	0,55	42	suppobox_2	0,98	1,00	0,99
18	locky	0,84	0,62	0,71	43	suppobox_3	0,99	1,00	1,00
19	matsnu	0,98	0,94	0,96	44	symmi	1,00	1,00	1,00
20	murofet_v1	0,99	1,00	1,00	45	tempedreve	0,58	0,86	0,69
21	murofet_v2	0,94	0,96	0,95	46	tinba	0,77	0,97	0,86
22	murofet_v3	1,00	1,00	1,00	47	vawtrak_v1	1,00	1,00	1,00
23	necurs	0,99	0,80	0,89	48	vawtrak_v2	0,99	1,00	1,00
24	maim	0,95	0,94	0,95	49	vawtrak_v3	1,00	1,00	1,00
25	padcrypt	1,00	1,00	1,00	50	zeus_newgoz	1,00	1,00	1,00
Avg Accuracy		***0,86***							

Bộ dữ liệu UMUDGA bao gồm 50 họ DGA Botnet tương ứng với 50 lớp. Bảng 3.4 cho thấy, mô hình LA_Mul07 có độ chính xác đạt cao trong phân lớp các họ DGA Botnet, kể cả trong trường hợp số lượng họ DGA Botnet cần phân lớp là nhiều như ở bộ dữ liệu UMUDGA, với Avg Accuracy đạt 0,86. Hầu hết các họ DGA Botnet đều được phân loại có độ chính xác cao từ 0,90 trở lên, trừ một số họ có tỉ lệ khá thấp như alureon, pikspa, pikspa_noise với độ chính xác lần lượt là 0,60, 0,47, 0,22. Nhìn chung, với nhiệm vụ phân loại cùng lớp 50 lớp của bộ dữ liệu UMUDGA thì mô hình LA_Mul07 cho kết quả cao hơn so với các nghiên cứu trước đó.

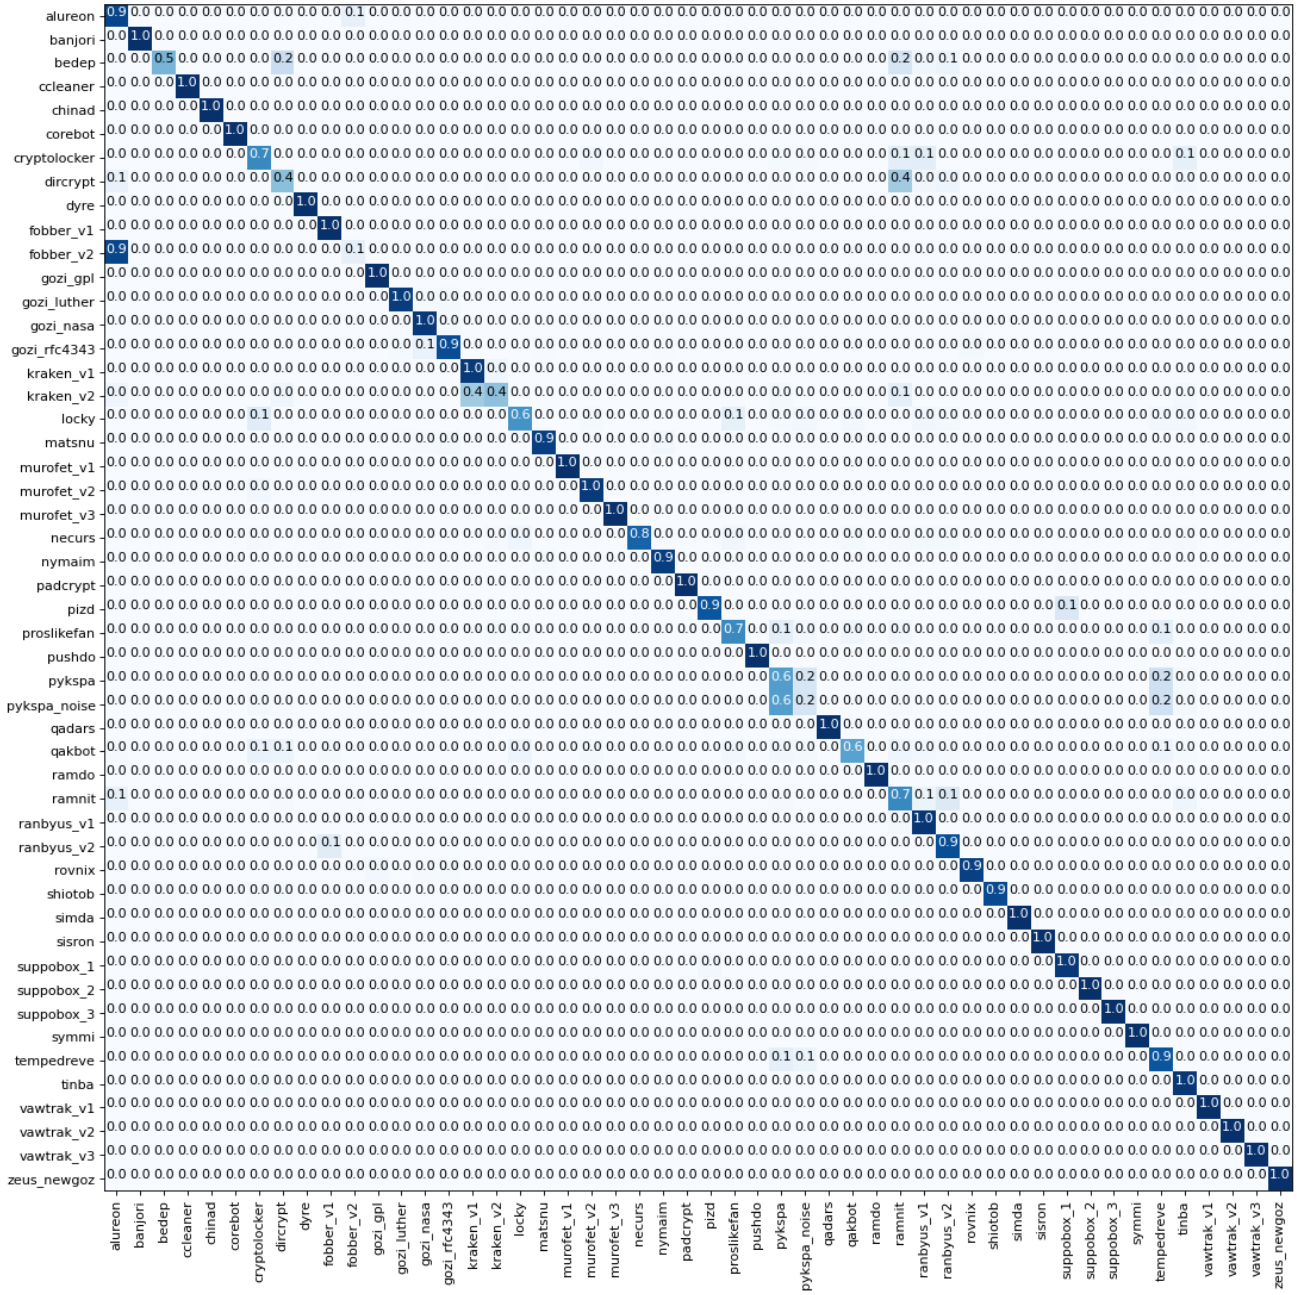

Hình 3.19. Ma trận nhầm lẫn chuẩn hóa khi phân lớp đa lớp trên bộ UMUDGA

Hình 3.19 cho ta thấy ma trận nhầm lẫn của mô hình LA_Mul07 có đường chéo chính đậm nét, thể hiện rằng phần lớn các lớp được phân loại đúng. Các vấn đề còn tồn tại bao gồm: Họ fobber_v2 bị phân loại nhầm thành alureon với tỉ lệ 0,90; họ kraken_v2 bị phân loại nhầm thành kreken_v1 với tỉ lệ 0,40; Tỉ lệ gần 0,60 họ pykspa_noise bị phân loại nhầm thành pykspa. Điều này có thể giải thích bởi 2/3 họ này là các biến thể của nhau, có những đặc trưng khá giống nhau, nên có thể gây nhầm lẫn cho bộ phân lớp. Đánh giá trên những họ DGA Botnet còn lại, bộ phân lớp LA_Mul07 cho độ chính xác cao từ 0,90 trở lên.

Do số lượng mẫu được đánh giá là lớn, NCS thể hiện ma trận nhầm lẫn chuẩn hóa thay vì ma trận nhầm lẫn. Mỗi ô có giá trị trong đoạn [0, 1] được chuẩn hóa bởi tỉ lệ so với số lượng mẫu.

3.3.3.3. Thời gian huấn luyện và đánh giá

Hình 3.22 thể hiện thời gian huấn luyện và đánh giá của mô hình LA_Mul07 đối với bài toán phân lớp đa lớp, trên bộ dữ liệu AADR và UMUDGA.

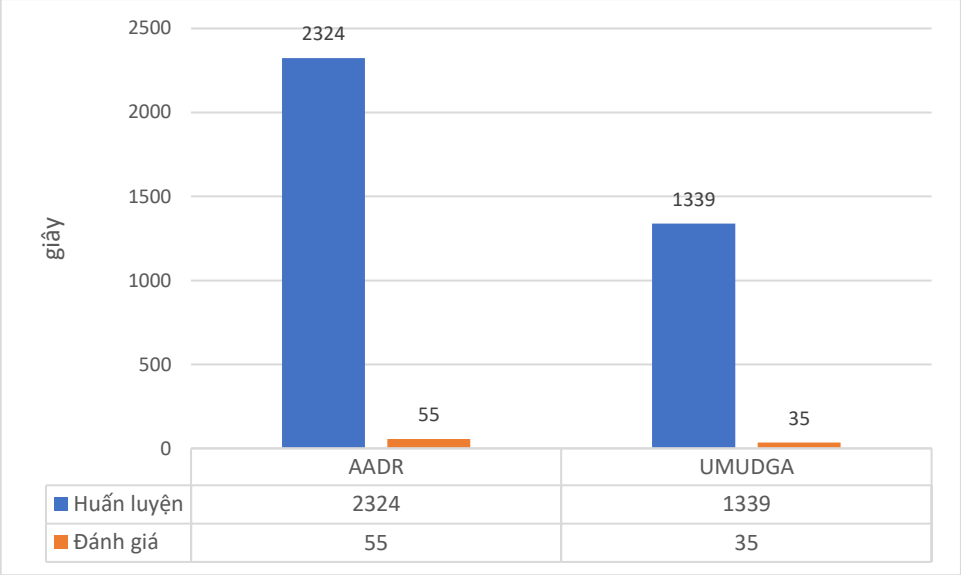

Hình 3.20. Thời gian huấn luyện và đánh giá của mô hình LA_Mul07 cho bài toán phân lớp đa lớp trên hai bộ dữ liệu AADR và UMUDGA

Kết quả cho thấy, mô hình LA_Mul07 có thời gian huấn luyện nhanh, với khoảng 2.324 giây trên bộ dữ liệu AADR và 1.339 giây trên bộ dữ liệu UMUDGA. Thời gian đánh giá lần lượt là 55 giây và 35 giây theo thứ tự trên. Nhận xét rằng, thời gian đánh giá chiếm từ 2.3% đến 2.6% thời gian huấn luyện mô hình.

3.4. Đánh giá với các nghiên cứu liên quan

3.4.1. Đánh giá trên chung bộ dữ liệu UMUDGA

Trong công bố về bộ dữ liệu UMUDGA, Zago và cộng sự [21] sử dụng các mô hình học máy bao gồm Adaptive Boosting (AB), Neural Network (NN), Random Forest (RF), Support Vector Machines (SVM), Decision Tree (DT) và k-Nearest Neighbours (kNN) để áp dụng cho bài toán phân lớp nhị phân và phân lớp đa lớp. NCS tiến hành so sánh, đánh giá mô hình LA_Bin07 và LA_Mul07 với các mô hình

đã đề cập trong nghiên cứu ở trên. Môi trường thử nghiệm và số lượng mẫu cho mỗi đánh giá được thiết lập ở mức tương tự là 10.000 mẫu cho mỗi họ DGA Botnet.

3.4.1.1. So sánh với mô hình LA_Bin07

Đối với bài toán phân lớp nhị phân, kết quả so sánh giữa LA_Bin07 và các kết quả của Zago được thể hiện tại Hình 3.21.

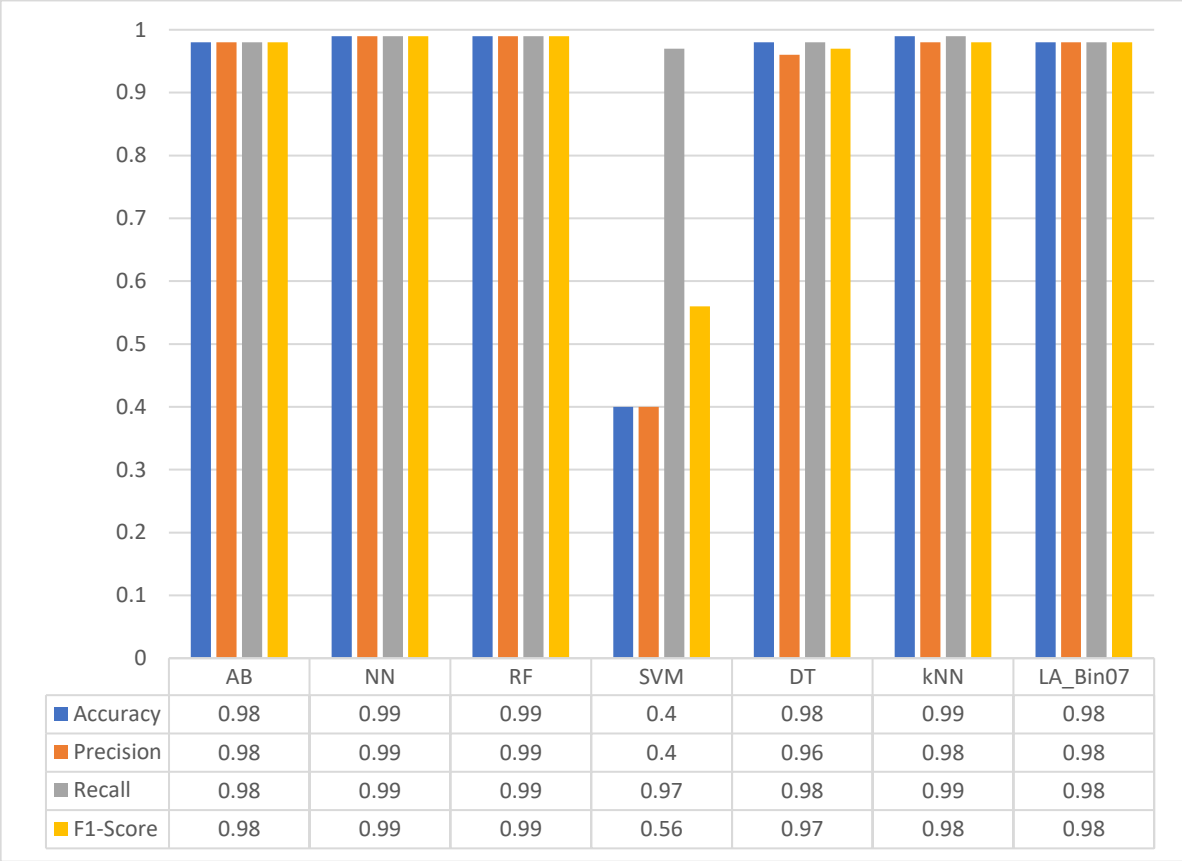

	AB	NN	RF	SVM	DT	kNN	LA_Bin07
Accuracy	0.98	0.99	0.99	0.4	0.98	0.99	0.98
Precision	0.98	0.99	0.99	0.4	0.96	0.98	0.98
Recall	0.98	0.99	0.99	0.97	0.98	0.99	0.98
F1-Score	0.98	0.99	0.99	0.56	0.97	0.98	0.98

Hình 3.21. So sánh bộ phân loại LA_Bin07 với các thuật toán học máy trên bộ dữ liệu UMUDGA

Hình 3.21 cho thấy, mô hình LA_Bin07 có độ chính xác tốt hơn rất nhiều so với mô hình SVM. Đồng thời, cho kết quả gần như tương đương với các mô hình AB, DT và thấp hơn 0,01 so với NN, RF và kNN, với Accuray đạt từ 0,98 đến 0,99. Ta cũng thấy rằng, SVM có độ chính xác hơn hẳn so với các thuật toán được đối sánh. Điều này được giải thích bởi việc thuật toán SVM nhạy cảm với nhiễu, trong khi các họ DGA Botnet khác nhau tuy có đặc điểm khác nhau nhưng được đặt chung nhãn độc hại nên ảnh hưởng đến khả năng phân loại của SVM. Ngoài ra, việc trích xuất nhiều thuộc tính từ tên miễn cũng khiến cho việc tìm kiếm một mặt siêu phẳng phân tách hai lớp của SVM trở nên kém khả thi hơn. Thuật toán k-NN tỏ ra hiệu quả trong trường hợp này nhưng lại hạn chế của k-NN là rất tốn kém thời gian đánh giá. Việc

chênh lệch độ chính xác giữa k-NN và LA_Bin07 trong thực tế là không đáng kể. Lưu ý rằng, mô hình LA_Bin07 có ưu điểm hơn ở việc không cần sử dụng các đặc trưng đã được trích chọn từ trước như những mô hình còn lại. Điều này giúp giảm bớt thời gian cho quá trình trích chọn đặc trưng.

3.4.1.2. So sánh mô hình LA_Mul07

Đối với nhiệm vụ phân lớp đa lớp, kết quả so sánh của mô hình LA_Mul07 với các kết quả của Zalo được tổng hợp và thể hiện tại Hình 3.22.

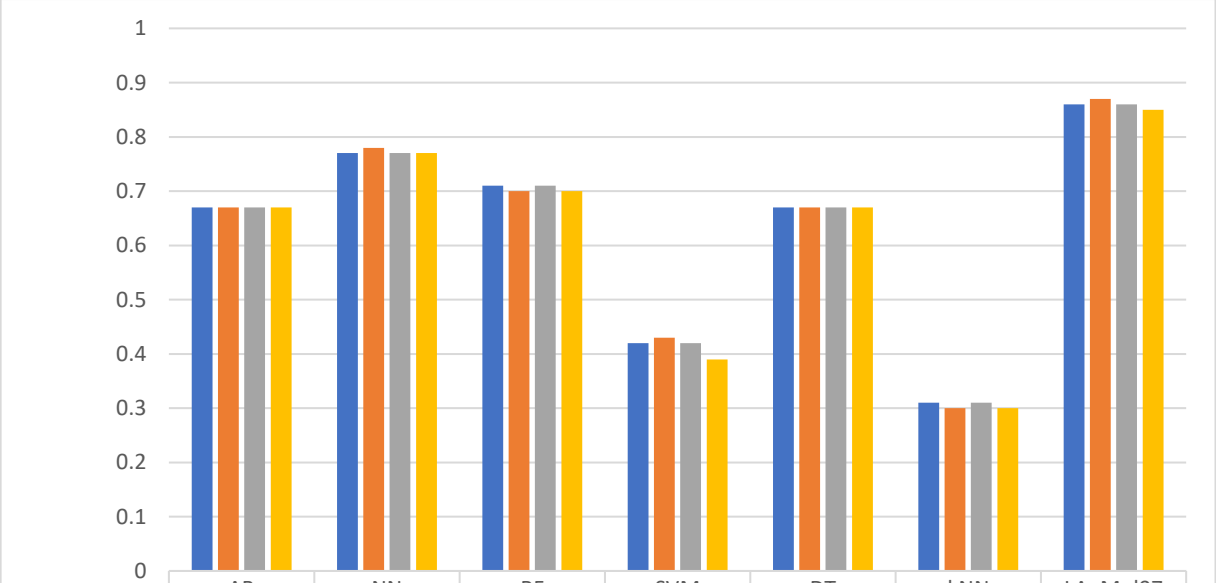

	AB	NN	RF	SVM	DT	kNN	LA_Mul07
Accuracy	0.67	0.77	0.71	0.42	0.67	0.31	0.86
Precision	0.67	0.78	0.7	0.43	0.67	0.3	0.87
Recall	0.67	0.77	0.71	0.42	0.67	0.31	0.86
F1-Score	0.67	0.77	0.7	0.39	0.67	0.3	0.85

Hình 3.22. So sánh bộ phân loại LA_Mul07 với các thuật toán học máy trên bộ dữ liệu UMUDGA

Đối với bài toán phân lớp đa lớp, mô hình LA_Mul07 cho Accuracy cao hơn rõ rệt so với các mô hình học máy còn lại. Với Accuracy, Precision, Recall và F_1-score lần lượt đạt 0,86, 0,87, 0,86 và 0,85. Trong khi đó, mô hình tốt thứ hai là NN chỉ đạt lần lượt là 0,77, 0,78, 0,77 và 0,77. Ở chiều ngược lại, mặc dù đạt độ chính xác rất cao trong bài toán phân lớp nhị phân, mô hình kNN lại tỏ ra rất thiếu chính xác trong bài toán phân lớp đa lớp khi chỉ đạt lần lượt là 0,31, 0,30, 0,31 và 0,30. Có thể kết luận rằng, mô hình LA_Mul07 cho kết quả phân lớp đa lớp chính xác và toàn diện hơn nhiều so với các mô hình còn lại.

3.4.2. Đánh giá với một số mô hình học sâu khác

NCS cũng đồng thời đánh giá với một số kiến trúc học sâu khác mà NCS xây dựng trên cơ sở CNN và LSTM bao gồm: Basic CNN, Basic LSTM, Bi-LSTM và CNN-LSTM, được mô tả chi tiết tại Bảng 3.5:

Bảng 3.5. Một số kiến trúc học sâu khác cho bài toán DGA Botnet

STT	Basic CNN	Basic LSTM	Bi-LSTM	CNN LSTM
1	Embedding	Embedding	Embedding	Embedding
2	Dropout(0,2)	LSTM(128)	Bidirectional (LSTM(128))	Dropout(0,25)
3	Conv1D	Dropout(0,5)	Dropout(0,5)	Convo1D
4	MaxPooling1D	Dense(class_num)	Dense(class_num)	MaxPooling1D
5	Dense(250)	Activation (sigmoid)	Activation (sigmoid)	LSTM(128)
6	Dropout(0,2)			Dense(class_num)
7	Activation(relu)			Activation (sigmoid)
8	Dense(class_num)			
9	Activation (sigmoid)			

Kết quả của các mô hình trên khi thử nghiệm trên bộ dữ liệu UMUDGA và so sánh với LA_Bin07/LA_Mul07 được thể hiện tại Hình 3.23:

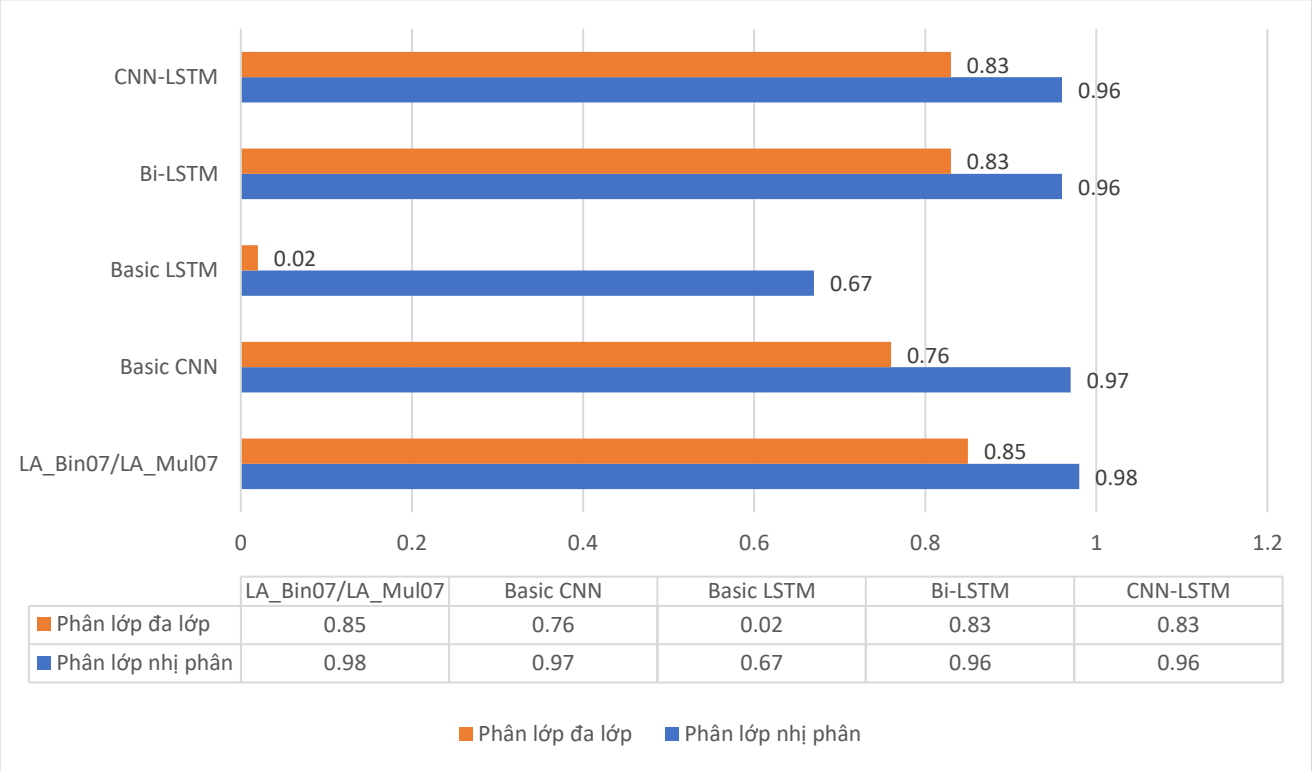

	LA_Bin07/LA_Mul07	Basic CNN	Basic LSTM	Bi-LSTM	CNN-LSTM
Phân lớp đa lớp	0.85	0.76	0.02	0.83	0.83
Phân lớp nhị phân	0.98	0.97	0.67	0.96	0.96

Hình 3.23. Thử nghiệm mô hình LA_Bin07 và LA_Mul07 với một số kiến trúc học sâu dựa trên CNN và LSTM trên bộ dữ liệu UMUDGA

Kết quả trên cho thấy, mô hình LA_Bin07 và LA_Mul07 đạt được độ chính xác cao nhất trong lần lượt hai bài toán phân lớp nhị phân và phân lớp đa lớp. Mô hình Basic CNN và Basic LSTM cho kết quả lần lượt là 0,76 và 0,02, thể hiện rằng các mô hình truyền thống này không đạt hiệu quả trong phân loại. Ngược lại, việc cải tiến các mô hình truyền thống này thể hiện qua Bi-LSTM hoặcCNN-LSTM cải thiện độ chính xác hơn rất nhiều và gần đạt được độ chính xác tốt nhất, với lần lượt là 0,86 cho phân lớp nhị phân và 0,83 cho phân lớp đa lớp, nhưng vẫn thấp hơn so với mô hình LA_Bin07 và LA_Mul07. Cuối cùng, việc kết hợp LSTM và Attention như mô hình LA_Bin07 và LA_Mul07 đề xuất cho kết quả tốt nhất.

3.4.3. Đánh giá với một số nghiên cứu khác trong bài toán phân lớp đa lớp

Bài toán phân lớp nhị phân đã được một số nghiên cứu trước đó xem xét tới, với Accuracy đạt được cao nhất từ 0,98 đến 0,99, tiệm cận mức chính xác hoàn toàn. Trong phần này, NCS xem xét chi tiết hơn về vấn đề giải quyết bài toán phân lớp đa lớp, với một số kết quả chính bao gồm: Mô hình LSTM.MI [15] của Đức và cộng sự, mô hình Hidden Markow Model (HMM) [68], Decision Tree (DT) [69] và LSTM nguyên bản (LSTM) [70]. Những nghiên cứu này được lựa chọn để đối sánh bởi sự

tương đồng trong môi trường và bộ dữ liệu thử nghiệm. Các nghiên cứu khác đánh giá trên các bộ dữ liệu thực tế hoặc do nhóm nghiên cứu tự tổng hợp, nên không phù hợp cho đánh giá khách quan.

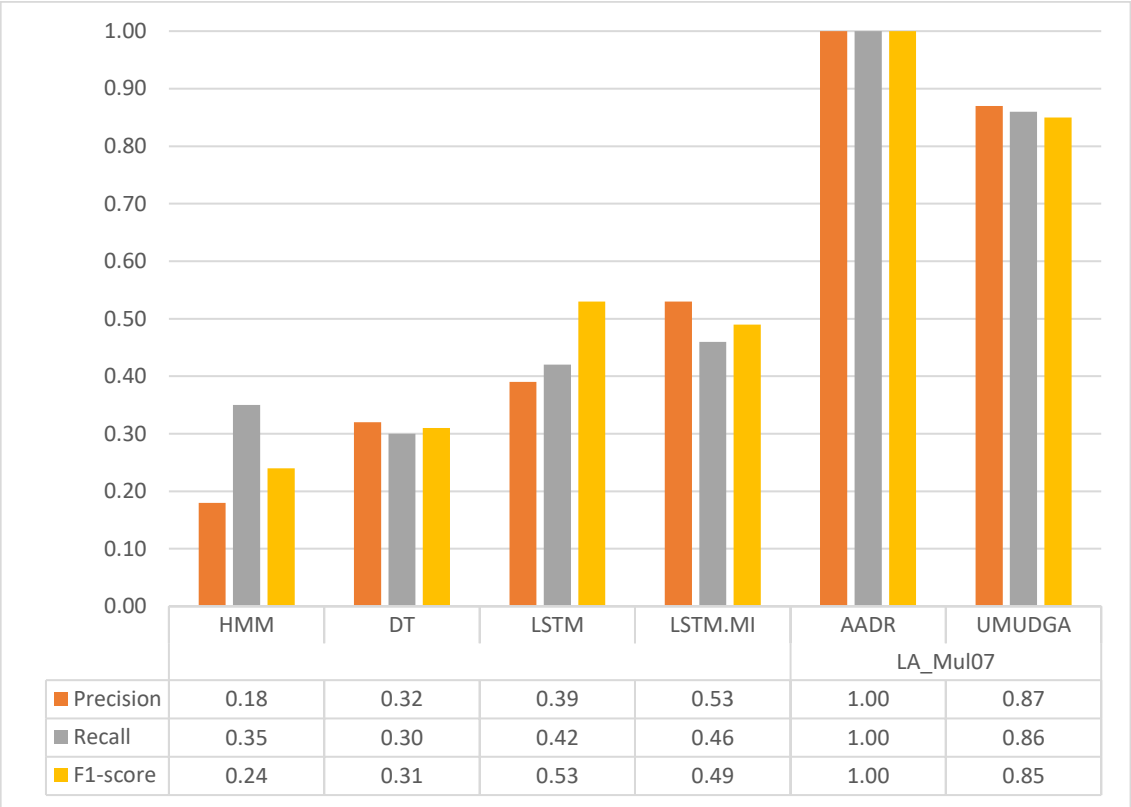

	HMM	DT	LSTM	LSTM.MI	AADR	UMUDGA
					LA_Mul07	
Precision	0.18	0.32	0.39	0.53	1.00	0.87
Recall	0.35	0.30	0.42	0.46	1.00	0.86
F1-score	0.24	0.31	0.53	0.49	1.00	0.85

Hình 3.24. Kết quả so sánh mô hình LA_Mul07 với các mô hình khác trong bài toán phân lớp đa lớp

Kết quả so sánh giữa các mô hình được trình bày ở Hình 3.24. Có thể thấy rằng, mô hình LA_Mul07 được đề xuất có Precision, Recall và F_1-Score cao hơn nhiều so với các mô hình HMM, DT, LSTM hay LSTM.MI trên cả hai bộ dữ liệu AADR và UMUDGA. Điểm số F_1-Score thể hiện đánh giá chung là 1,00 và 0,85 lần lượt trên bộ dữ liệu AADR và UMUDGA. Trong khi đó, mô hình tốt thứ hai là LSTM có F_1-score chỉ đạt 0,53. Mô hình kém nhất là HMM khi F_1-Score chỉ đạt 0,24, được xem là gần như không thể phân loại được.

Mô hình mới đã cải tiến được nhiều về Accuracy so với mô hình LSTM truyền thống hay LSTM.MI đã được đề xuất trước đó. Cần lưu ý rằng, mô hình LA_Mul07 được đánh giá trên bộ dữ liệu UMUDGA gồm 50 họ DGA Botnet, có độ phức tạp cao hơn do số lượng nhãn cần phân lớp là lớn hơn so với bộ dữ liệu của mô hình LSTM.MI trước đó (đánh giá trên 37 họ DGA Botnet). Đối với bộ dữ liệu AADR, mô hình LA_Mul07 cho kết quả phân lớp gần như chính xác hoàn toàn.

Do hạn chế thiếu các đánh giá trên cùng một bộ dữ liệu nên NCS trích dẫn kết quả độ chính xác (Hình 3.24) mà tác giả công bố khi đánh giá trên bộ dữ liệu của họ. Các hạn chế trên được NCS giải quyết ở Chương 4 với việc đề xuất một bộ dữ liệu mới về DGA Botnet làm cơ sở chung cho các đánh giá sau này.

3.5. Kết luận Chương 3

Trong Chương 3, NCS đã trình bày các kết quả nghiên cứu về cải tiến mô hình học sâu để giải quyết bài toán DGA Botnet. NCS đề xuất hai mô hình học sâu mới là LA_Bin07 và LA_Mul07 lần lượt giải quyết bài toán phát hiện và phân loại DGA Botnet. Mô hình mới được cải tiến trên cơ sở mạng LSTM truyền thống. Hai mô hình được đánh giá một cách đầy đủ trên 04 bộ dữ liệu bao gồm: Andrey Abakumov's DGA Repository, OSINT DGA feed, UMUDGA Dataset và 360NetLab Dataset.

Các đánh giá cho thấy, mô hình LA_Bin07 có độ chính xác rất cao, đạt từ 0,98 trên bộ UMUDGA và cho đến 1,00 trên bộ dữ liệu OSINT. Mô hình LA_Mul07 cho khả năng phân loại các họ DGA Botnet cao, cải thiện đáng kể so với các mô hình trước đó, với Accuracy lần lượt đạt 1,00 và 0,86 trên hai bộ dữ liệu là AADR và UMUDGA.

Việc giải quyết bài toán DGA Botnet mang lại nhiều ý nghĩa trong vấn đề đảm bảo an ninh mạng, đặc biệt là bài toán phân loại DGA Botnet. Thứ nhất, hướng tiếp cận này có thể nhanh chóng đưa ra các cảnh báo phát hiện và phân loại về DGA Botnet khi được tích hợp trên các thiết bị Firewall/IDS. Thứ hai, giải pháp này đòi hỏi ít tài nguyên tính toán hơn so với các giải pháp phân tích gói tin truyền thống và tận dụng được năng lực tính toán của GPU. Thứ ba, giải pháp có thể mở rộng áp dụng cho mã độc, phần mềm độc hại, phần mềm gián điệp có cơ chế truy vấn tên miền tương tự. Cuối cùng, module phát hiện tên miền độc hại hoàn toàn có thể được tích hợp trên các giải pháp bảo mật tiên tiến, hiện đại như tường lửa thế hệ mới, giải pháp an ninh hợp nhất.

Một phần kết quả nghiên cứu được trình bày tại Chương 3 được công bố tại [CT4] trong danh mục công trình của tác giả.

Chương 4. BỘ DỮ LIỆU MỚI UTL_DGA22 CHUYÊN DÙNG CHO BÀI TOÁN DGA BOTNET

Trong chương 4, NCS đề xuất một bộ dữ liệu mới chuyên dùng cho bài toán DGA Botnet là UTL_DGA22. Bộ dữ liệu này kế thừa kết quả của những bộ dữ liệu trước đó, đồng thời có thêm các điểm mới, cải tiến bao gồm: Bổ sung các họ DGA Botnet mới, chuẩn hóa dữ liệu và gán nhãn, đề xuất và trích chọn sẵn các thuộc tính mới, tài liệu mô tả chi tiết. NCS cũng đánh giá các giải pháp đề xuất ở Chương 2 và Chương 3 bao gồm NCM, VEA, HEA, LA_Mul07 và LA_Bin07 trên bộ dữ liệu mới cho kết quả tốt. Bộ dữ liệu UTL_DGA22 được kỳ vọng sẽ là một cơ sở tin cậy, công khai, khách quan, đầy đủ cho các nhà khoa học thử nghiệm, so sánh, đánh giá các giải pháp của họ trong thời gian tới.

4.1. Đặt vấn đề bộ dữ liệu DGA Botnet

4.1.1. Khái quát vấn đề

Một số nghiên cứu được công bố trước đó đề xuất các thuật toán hoặc mô hình mới để phát hiện DGA Botnet. Điểm tương đồng giữa các nghiên cứu này đó là việc chúng đều giải quyết ít nhất một trong hai bài toán phân lớp nhị phân và phân lớp đa lớp. Một số thuật toán có độ chính xác rất cao. Tuy nhiên, việc thực hiện các đối sánh giữa những nghiên cứu đó là chưa thuận lợi, bởi các bộ dữ liệu trong đánh giá phần lớn được tổng hợp bởi nhóm nghiên cứu hoặc thu thập trực tuyến trên Internet. Đồng thời, việc công bố và mô tả chi tiết bộ dữ liệu, số lượng mẫu trong từng bộ dữ liệu cũng còn hạn chế.

Bảng 4.1 mô tả chi tiết về đặc điểm của một số bộ dữ liệu được sử dụng cho đánh giá bởi các nghiên cứu trước đó về DGA Botnet.

Bảng 4.1. Một số bộ dữ liệu để đánh giá giải pháp cho bài toán DGA Botnet

STT	Tác giả/Nhóm nghiên cứu	Năm công bố	Thuật toán đề xuất	Mô tả bộ dữ liệu
1	Antonakakis và cộng sự [68]	2012	Cây quyết định, mô hình Makov ẩn	Bộ dữ liệu được thu thập trong 15 tháng từ 11/2010 đến 01/2012
2	Zhou và cộng sự [71]	2013	DNS NXDomain Traffic	Bộ dữ liệu Alexa top 1.000.000 Domain và NXDomain Traffic Capture.

3	Bilge và cộng sự [72]	2014	EXPOSURE	Được thu thập sử dụng SIE DNS feeds theo thời gian thực trong 2,5 tháng, bao gồm 100 tỉ truy vấn DNS
4	Nguyen và cộng sự [73]	2015	Lọc cộng tác và phân cụm	Được thu thập từ những bản ghi DNS từ 18.000 người dùng từ 01/04/2015 đến 15/04/2015
5	Sharifnya và cộng sự [74]	2015	DFBotKiller	Dữ liệu thu thập từ lưu lượng DNS thực tế
6	Bottazzi và cộng sự [75]	2015	Fast Mining	Dữ liệu được thu thập từ mạng của một công ty trong tháng 06/2014, với gồm hơn 60.000 máy trạm và 100.000 người dùng ở Italia
7	Kwon và cộng sự [8]	2016	PsyBoG	Dữ liệu thu thập từ lưu lượng DNS thực tế, bao gồm cả lưu lượng của mã độc và lưu lượng từ máy chủ DNS
8	Erquiaga và cộng sự [76]	2016	Markov Models	Dữ liệu thu thập từ lưu lượng truy cập của máy tính cá nhân, mạng quy mô nhỏ và mạng trong khuôn viên trường đại học. Bộ dữ liệu được công khai là một phần của Malware Capture Facility Project [77]
9	Mạc và cộng sự [12]	2017	Học máy	Dữ liệu thu thập từ thực tế, bao gồm 168.900 mẫu DNS của 38 họ DGA Botnet.
10	Wang và cộng sự [9]	2017	DBoD	Dữ liệu DNS được thu thập từ một mạng dành cho giáo dục, trong thời gian 26 tháng
11	Bisio và cộng sự [10]	2017	Phân cụm	Đánh giá trên 2 bộ dữ liệu: - Dataset 01: Gồm 40 họ DGA Botnet Dataset 02: Thu thập từ mạng LAN của một công ty trong vòng 15 ngày
12	Trần và cộng sự [15]	2018	LSTM	Dữ liệu lấy từ Alexa top 1.000.000 sites và 37 họ DGA Botnet từ OSINT DGA feed.

13	Curtin và cộng sự [16]	2019	RNN và Side Information	Bộ dữ liệu gồm 41 họ DGA Botnet và những tên miền lành tính, bao gồm 2,3 triệu tên miền, trong đó có 1,01 tên miền lành tính và 1,28 triệu tên miền của DGA Botnet.
14	Ashiq và cộng sự [78]	2019	Feedforward NN	Dữ liệu được mô tả tại tài liệu [79]
15	Alieyan và cộng sự [80]	2019	DNS rule-based schema	Dữ liệu DNS được lọc từ bộ dữ liệu ISOT Dataset [51]
16	Căn và cộng sự [81]	2020	NCM	Sử dụng dữ liệu DNS từ Alexa Top 1.000.000 Domain, Bambenek Consulting feed và 360 NetLab
17	Yun và cộng sự [82]	2020	Khaos	Tên miền lành tính: LD1 và LD2 lần lượt được tổng hợp từ Reverse DNS và Alexa Top 1M Domains. Tên miền độc hại được thu thập từ Research DGAs [83][79] và dữ liệu tổng hợp thực tế
18	Vinayakumar và cộng sự [17]	2020	Học sâu	Bộ dữ liệu DS1 và DS2 (AmritaDGA), là một phần trích ra từ DMD 2018 Dataset [84]
19	Zago [18] [21]	2020	Học máy	Sử dụng bộ dữ liệu UMUDGA Dataset được nhóm nghiên cứu xây dựng và công bố
20	Pei và cộng sự [85]	2020	Capsule Networks và Sliced RNN	Gồm: Alexa Top 1M Domains, OSINT, 360NetLab, và Andrey Abakumov’s repository.

Nhận xét chung, các giải pháp đề xuất thường được đánh giá trên những bộ dữ liệu do nhóm nghiên cứu thu thập vào những thời điểm khác nhau, số lượng mẫu không đồng đều, tính công bố rộng rãi không cao và thường không thuận tiện cho việc đối sánh.

4.1.2. Bộ dữ liệu về Botnet nói chung

Trong phần này, NCS đề cập một cách khái quát đến các bộ dữ liệu về Botnet nói chung, để làm căn cứ phân biệt với các bộ dữ liệu về DGA Botnet.

- CTU-13 [86] là một bộ dữ liệu ghi lại lưu lượng mạng của Botnet. Bộ dữ liệu này bao gồm các lưu lượng mạng được thu thập tại CTU University, Czech Republic vào năm 2011. Nhóm tác giả đã xây dựng 13 kịch bản của các loại Botnet khác nhau. Mỗi kịch bản được ghi lại với đầy đủ lưu lượng mạng Botnet, các lưu lượng bình thường và các lưu lượng nền. Dung lượng dữ liệu của mỗi kịch bản trên từ 5,2 GB cho đến 123 GB. Một bộ dữ liệu nhỏ hơn được trích xuất chỉ gồm các lưu lượng của Botnet có dung lượng là 1,9 GB. Các trường thuộc tính trong mỗi mẫu dữ liệu này bao gồm: Địa chỉ IP và cổng của nguồn và đích, giao thức, dung lượng gói tin, các cờ của gói tin. Bộ dữ liệu đã gán nhãn lưu lượng của một số loại Botnet như Neris, Rbot, Virut, Menti, Sogou, Murlo hay NSIS.ay. Bộ dữ liệu CTU-13 tương thích với các giải pháp dựa trên việc phân tích gói tin.

- UGR16 là bộ dữ liệu về phát hiện xâm nhập mạng được tạo ra bởi Maciá-Fernández và cộng sự [87]. Bộ dữ liệu này cũng thu thập lại tất cả các lưu lượng trong một mạng thực tế. Họ xây dựng một mạng và đặt các cảm biến tại nút mạng để thu thập dữ liệu. Những dữ liệu này chứa trong đó các lưu lượng của một cuộc tấn công Low-rate DoS, Port Scanning hay Bot Traffic. Tác giả đã gán nhãn của các cuộc tấn công, bao gồm Signitue-based Labeling và Anomoly-based Labelling. Các tài liệu mô tả về bộ dữ liệu cũng được nhóm tác giả công bố đầy đủ. Cần lưu ý rằng, bộ dữ liệu UGR16 không chỉ tập trung vào việc phát hiện Botnet, mà bao gồm cả những kỹ thuật tấn công khác như DoS hay Port Scanning.

- DreLAB là bộ dữ liệu được công bố bởi Andrea Venturi và cộng sự [88]. Mục tiêu của bộ dữ liệu này là hướng tới việc đánh giá sự hiệu quả của các thuật toán trong Botnet nói chung. Họ sử dụng kỹ thuật học sâu tăng cường để tạo ra các mẫu dữ liệu. Họ cũng tạo các mẫu Botnet đối nghịch giúp tăng cường khả năng trốn tránh sự phát hiện. Toàn bộ dữ liệu mạng được thu thập dưới dạng tệp tin *pcap, sau đó chuyển thành *CSV để công bố. Bộ dữ liệu cung cấp những hiểu biết sâu hơn về hoạt động của Botnet nói chung và đánh giá khả năng phát hiện của các thuật toán học máy nói riêng.

UNSW-NB15 cũng là một bộ dữ liệu mạng về Botnet, được tạo ra bởi The IXIA PerfectStorm Tool tại the Cyber Range Lab of UNSW Canberra [89]. Họ sử dụng công cụ TCPDump đặt tại một nút mạng để thu thập lưu lượng của các truy cập mạng. Họ ghi lại được 100 GB lưu lượng truy cập dưới dạng pcap. Trong số này,

ngoài các lưu lượng mạng thông thường, còn bao gồm 09 dạng tấn công mạng khác nhau, gồm Fuzzers, Analysis, Backdoors, DoS, Exploits, Generic, Reconnaissance, Shellcode và Worms. Tiếp theo, họ sử dụng công cụ Argus, Bro-IDS để trích xuất 49 thuộc tính và gán nhãn tương ứng. Các thuộc tính và nhãn được cung cấp dưới dạng tệp tin CSV. Nhìn chung, tương tự như UGR16, bộ dữ liệu UNSW-NB15 không phải là bộ dữ liệu chuyên tập trung vào Botnet mà còn cả những dạng tấn công khác.

Bộ dữ liệu ISCX-Bot-2014 được xây dựng bởi Viện An ninh mạng Canada, bao gồm 16 loại Botnet khác nhau, bao gồm: Neris, Rbot, Menti, Sogou, Murlo, Virut, NSIS, Zeus, SMTP Spam, UDP Storm, Tbot, Zero Access, Weasel, Smoke Bot, Zeus Control và ISCX IRC Bot [40]. Bộ dữ liệu được chia thành hai nhóm gồm TrainSet có khối lượng 5,3 GB và TestSet có dung lượng 8,5 GB. Chúng là sự tổng hợp của 03 bộ dữ liệu thành phần, bao gồm: ISOT Dataset [90], ISCX 2012 IDS Dataset [53] và Malware Capture Facility Project [91]. Mỗi bộ đều bao gồm các lưu lượng mạng độc hại và lưu lượng mạng bình thường. Đối với các thuật toán học máy, học sâu thì việc phân chia dữ liệu có ý nghĩa phần TrainSet được dùng cho quá trình huấn luyện, còn tập TestSet được dùng cho đánh giá. Tương tự, bộ dữ liệu ISCX-Bot-2014 phù hợp để đánh giá các thuật toán phát hiện Botnet nói chung.

Bảng 4.2 trình bày tóm tắt tính chất của các bộ dữ liệu về Botnet đã trình bày ở trên, cụ thể như sau:

Bảng 4.2. Đặc điểm của các bộ dữ liệu về chung về Botnet

STT	**Bộ dữ liệu**	**Ký hiệu**	**Lưu lượng mạng**	**Nhãn**	**Lưu lượng độc hại khác**	**Định dạng**	**Năm công bố**
1	CTU-13 [86]	CTU	Thực tế	Botnet	Không	PCAP & Flow	2014
2	UGR16 [87]	UGR	Thực tế	Low-rate DoS, Port Scanning, Botnet	Có	Flow & CSV	2018
3	DreLAB [88]	DLAB	Phòng thí nghiệm	Botnet	Không	CSV	2021

4	UNSW-NB15 [89]	UNSW	Phòng thí nghiệm	Botnet và Network Attack	Có	CSV	2015
5	ISCX-Bot-2014 [40]	ISCX	Phòng thí nghiệm	Botnet và mã độc	Có	PCAP & CSV	2014

Nhận xét rằng, các bộ dữ liệu trên đều được thu thập từ lưu lượng mạng bằng các công cụ thu thập gói tin như TCPDump hay Wireshark dưới dạng PCAP. Một số được trích xuất ra dạng CSV để giảm bớt dung lượng và trích chọn thuộc tính. Ngoài hai bộ dữ liệu CTU-13 và DreLab chỉ tập trung vào bài toán Botnet, thì ba bộ dữ liệu còn lại được mở rộng cho việc phát hiện mã độc và các dạng tấn công mạng khác. Cuối cùng, cả 05 bộ dữ liệu ở trên đều không được thiết kế để đánh giá chuyên sâu cho bài toán DGA Botnet bởi chúng thiếu tên miền của các họ DGA Botnet và nhãn tương ứng. Đây là cơ sở quan trọng để phát triển các bộ dữ liệu chuyên dùng cho bài toán DGA Botnet.

4.1.3. Bộ dữ liệu chuyên dùng về DGA Botnet

Một số nghiên cứu trước đó đã có đề cập đến các bộ dữ liệu chuyên dùng cho đánh giá bài toán DGA Botnet, cụ thể như sau:

Trong nghiên cứu [19], Suryotrisongko và cộng sự chia sẻ bộ dữ liệu "Botnet DGA Dataset" đi kèm với các kết quả nghiên cứu của họ. Bộ dữ liệu này có dung lượng 205 MB, được lưu trữ dưới dạng tệp tin *csv, bao gồm 1.000.000 tên miền từ Alexa Top 1 Milion Domains [47] được gán nhãn lành tính và 10 họ DGA Botnet với 1.803.333 tên miền được gán nhãn độc hại. Mỗi mẫu dữ liệu có 07 trường thuộc tính đã được trích xuất từ tên miền gốc bao gồm: CharLength, TreeNewFeature, nGramReputation_Alexa, REAlexa, MinREBotnets, Entropy và InformationRadius. Thuộc tính thứ 08 là Class bao gồm hai giá trị là 0 và 1, tương ứng với nhãn của tên miền. Bộ dữ liệu Botnet DGA Dataset được công bố công khai trên IEEE Dataport [92]. Hạn chế của bộ dữ liệu này là không chứa các tên miền gốc và số lượng mẫu của các họ DGA Botnet còn ít.

Andrey Abakumov công bố một bộ dữ liệu về DGA Botnet trên kho lưu trữ GibHub tại địa chỉ [20]. Bộ dữ liệu này bao gồm 1.000.000 tên miền lành tính từ Alexa, kết hợp với tên miền của 08 họ DGA Botnet bao gồm: cryptolocker, zeus,

pushdo, rovnix, tinba, conficker, matsnu và ramdo. Các tên miền được cung cấp dưới dạng tệp tin *txt và chưa được rút trích đặc trưng. Nhãn 0 được gán cho tên miền lành tính và 08 họ DGA Botnet lần lượt được gán nhãn từ 1 đến 8. Bộ dữ liệu này cho phép thực hiện đánh giá cả bài toán phân lớp nhị phân và phân lớp đa lớp. Bên cạnh đó, họ cũng cung cấp mã nguồn sinh tên miền tự động cho các họ DGA Botnet được đề cập.

Nhóm nghiên cứu của Zago và cộng sự từ University of Murcia đã xây dựng một bộ dữ liệu được xem là đầy đủ và chi tiết nhất về DGA Botnet tính đến thời điểm công bố, gọi là UMUDGA Dataset vào năm 2020 [21] [18]. Bộ dữ liệu này bao gồm 1.000.000 tên miền lành tính và 50 họ DGA Botnet. Trong đó, mỗi họ DGA Botnet có từ 10.000 đến 1.000.000 mẫu tên miền được lưu dưới dạng *ARFF, *CSV và *TXT. Mã nguồn sinh tên miền cũng được nhóm tác giả kèm theo bộ dữ liệu này và chia sẻ công khai trên IEEE Dataport.

Ngoài việc cung cấp tên miền nguyên gốc, Zago và các cộng sự cũng đã đề xuất một số đặc trưng của tên miền, gồm các đặc trưng cơ bản, các đặc trưng n-gram và đặc trưng dựa trên xử lý ngôn ngữ tự nhiên. Kết quả thử nghiệm cho thấy các đặc trưng này là phù hợp để làm đầu vào các mô hình học máy. Bộ dữ liệu cho phép đánh giá với cả hai bài toán DGA Botnet.

DGArchive là một dịch vụ được cung cấp bởi Fraunhofer FKIE và được quản trị bởi Daniel Plohmann. Dịch vụ này tổng hợp và cung cấp dữ liệu về DGA Botnet với 86 họ DGA Botnet khác nhau [22]. Bộ dữ liệu DGArchive bao gồm các họ tên miền của DGA Botnet được thể hiện dưới dạng rõ. Mặc dù số lượng họ DGA Botnet được tổng hợp là rất nhiều, nhưng số lượng tên miền trong mỗi họ DGA Botnet là không đồng đều, có một số họ rất ít dữ liệu trong khi một số họ khác lại nhiều hơn rất đáng kể. Bộ dữ liệu này được cung cấp dưới dạng tệp tin *CSV và không được phép sử dụng cho các mục đích thương mại. Daniel Plohmann và các cộng sự cũng đã trình bày những đánh giá của họ về DGA Botnet trên bộ dữ liệu này và được công bố tại [93].

Alexa công bố 1.000.000 tên miền được xếp hạng dựa trên độ phổ biến của chúng đối với người dùng Internet từ hơn 70 quốc gia [47]. Những tên miền này được các nhóm nghiên cứu gán nhãn là lành tính trong các bài đánh giá của họ. Chúng ta

dễ dàng tìm thấy những tên miền phổ biến được xếp hạng cao như google.com. facebook.com, youtube.com. Những tên miền được xếp hạng thấp hơn thì ít phổ biến hơn và trong một số trường hợp, nó trông khá giống những tên miền được sinh ra bởi DGA Botnet.

OSINT DGA feed [23] là một bộ dữ liệu đáng tin cậy về DGA Botnet, được tạo bởi Bambenek, bao gồm một khối lượng lớn các tên miền độc hại được thu thập và tổng hợp. Dữ liệu này được tác giả chia sẻ miễn phí cho cộng đồng khoa học và không được phép sử dụng vào mục đích thương mại. Cần lưu ý rằng dữ liệu này không phải luôn sẵn sàng để tải về mà người sử dụng cần gửi thư điện tử tới chủ sở hữu để xin cấp quyền. Hạn chế của bộ dữ liệu này là không gán nhãn cho các họ DGA Botnet, do đó chỉ có thể sử dụng được cho bài toán phân lớp nhị phân.

360NetLab Dataset [24] là bộ dữ liệu về DNS được thu thập theo thời gian thực, bao gồm các tên miền độc hại đang truy vấn trên thế giới, được xây dựng và duy trì bởi nhóm nghiên cứu 360NetLab, Qihoo 360 Technology Co., Ltd. Website của nhóm cung cấp một công cụ cho phép dò quét và tổng hợp các tên miền độc hại theo thời gian thực, sau đó bổ sung vào cơ sở dữ liệu đang có. Hạn chế của việc này là dữ liệu tên miền Botnet liên tục thay đổi do có sự cập nhật thường xuyên, khiến cho việc khó tạo thành một tiêu chuẩn chung cho đánh giá. Hơn nữa, số lượng họ DGA Botnet tại một thời điểm được lưu trữ trong bộ dữ liệu là không phong phú và ổn định như các bộ dữ liệu khác.

Johannes Bader công bố một bộ dữ liệu về DGA Botnets trên Github, với 48 họ DGA Botnets được chia sẻ [25]. Bộ dữ liệu này được công bố bắt đầu từ năm 2018, và liên tục được cập nhật các họ DGA Botnets mới. Mặc dù có một số họ DGA Botnets trùng lặp với những bộ dữ liệu trước đó, bộ dữ liệu của Bader cũng bao gồm một số họ DGA Botnet đặc trưng mà các bộ dữ liệu khác không có. Mỗi họ DGA Botnet thường bao gồm mã nguồn sinh tên miền tự động và các mẫu tên miền của họ đó. Tác giả công bố bộ dữ liệu với giấy phép GPL-2.0 License [94]. Một điểm rất đáng chú ý là tác giả cũng cung cấp các phân tích chi tiết về các họ DGA Botnets trên blog cá nhân của mình [95], giúp các nhà nghiên cứu có thể tìm hiểu rõ hơn về từng họ DGA Botnet cụ thể.

Bên cạnh Alexa top 1M domain, một bộ dữ liệu khác về các tên miền lành tính là The Majestic Million [96], được cung cấp bởi Majestic và công bố trên Website của họ. Bên cạnh việc cung cấp 1.000.000 tên miền lành tính, bộ dữ liệu này còn sắp xếp chúng theo thứ tự mức độ phổ biến trong thực tế. Danh sách các tên miền và mức độ phổ biến của chúng cũng được cập nhật liên tục từ hệ thống máy quét tự động. Do đó, mang lại sự yên tâm cho các nhà nghiên cứu khi dữ liệu luôn được cập nhật mới. Các tệp tin được cho phép tải về dưới dạng *CSV và sử dụng dưới giấy phép Creative Commons Attribution 3.0 Unported License [97].

Bảng 4.3 tóm tắt các đặc điểm chính của các bộ dữ liệu phổ biến về DGA Botnet đã nêu ở trên.

Bảng 4.3. Đặc điểm chính của các bộ dữ liệu phổ biến hiện nay về DGA Botnet

STT	**Bộ dữ liệu**	**Viết tắt**	**Số lượng tên miền lành tính**	**Số lượng tên miền của DGA Botnet**	**Sọ họ DGA Botnet**	**Định dạng**	**Năm công bố**
1	Andrey Abakumov's DGA Repository [20]	AADR	1.000.000	801.667	08	txt	2016
2	Johannes Bader's Domain Generation Algorithms Repository [25]	JBR	Null	N/A	48	txt	2018
3	Alexa Top 1 milion domains [47]	AT1D	1.000.000	0	0	csv	2019
4	Botnet DGA Dataset [92]	BDD	1.000.000	1.803.333	10	csv	2020
5	UMUDGA Dataset [18]	UMU	1.000.000	Trên 30.000.000	50	arff, csv, txt	2020
6	DGArchive by Fraunhofer FKIE [22]	DFF	Null	N/A	86	csv	2020
7	OSINT DGA feed [23]	OSINT	1.000.000	495.186	0	txt	2021
8	360NetLab Dataset [24]	360NL	0	Không cố định	Không cố định	txt	2021

9	The Majestic Million [96]	TMM	1.000.000	0	0	csv	2021

4.1.4. Đặt vấn đề nghiên cứu

Nhìn chung, có sự khác nhau về cấu trúc và mục đích giữa các bộ dữ liệu cho Botnet nói chung và bộ dữ liệu cho DGA Botnet nói riêng. NCS phân nhóm và thể hiện chi tiết tại Bảng 4.4:

Bảng 4.4. Đánh giá về đặc điểm các nhóm bộ dữ liệu cho Botnet

Bộ dữ liệu	**Nhóm**	**Phát hiện Botnet**	**Phát hiện DGA Botnet**	**Phát hiện tấn công lưu**	**Lưu lượng mạng**	**Định dạng**		
						PCAP	**SCV**	**TXT**
CTU	Botnet	✓	×	×	✓	✓	✓	×
UGR	Botnet/IDS	✓	×	✓	✓	✓	✓	×
DLAB	Botnet	✓	×	×	✓	✓	✓	×
UNSW	Botnet/IDS	✓	×	✓	✓	✓	✓	×
ISCX	Botnet/IDS	✓	×	✓	✓	✓	✓	×
AADR	DGA Botnet	✓	✓	×	×	×	✓	✓
JBR	DGA Botnet	✓	✓	×	×	×	✓	✓
AT1D	DGA Botnet	✓	✓	×	×	×	✓	✓
BDD	DGA Botnet	✓	✓	×	×	×	✓	✓
UMU	DGA Botnet	✓	✓	×	×	×	✓	✓
DFF	DGA Botnet	✓	✓	×	×	×	✓	✓
OSINT	DGA Botnet	✓	✓	×	×	×	✓	✓
360NL	DGA Botnet	✓	✓	×	×	×	✓	✓
TMM	DGA Botnet	✓	✓	×	×	×	✓	✓

Bảng 4.4 thể hiện sự khác nhau giữa hai nhóm bộ dữ liệu Botnet/IDS với DGA Botnet. Nhìn chung, các bộ dữ liệu CTU, UGR, DLAB, UNSW và ISCX thuộc nhóm

Botnet/IDS, chứa các gói tin là lưu lượng mạng, thường được lưu dưới dạng PCAP hoặc trích xuất ra CSV. Ngược lại, các bộ dữ liệu thuộc nhóm DGA Botnet như AADR, JBR, AT1D, BDD, UMU, DFF, OSINT, 360NL và TMM chỉ chứa các tên miền được lưu dưới dạng TXT hoặc CSV.

Các bộ dữ liệu Botnet/IDS có thể dùng cho đánh giá các kỹ thuật tấn công mạng khác nhưng không phù hợp để đánh giá cho các giải pháp DGA Botnet bởi chúng không được đánh nhãn tương ứng và số lượng mẫu tên miền cũng rất hạn chế. Trong khi bộ dữ liệu DGA Botnet chỉ dành cho đánh giá các giải pháp phát hiện DGA Botnet và được đánh nhãn tương ứng. Các bộ dữ liệu về Botnet chung bao gồm cả các lưu lượng mạng thô, nên có dung lượng lớn hơn rất nhiều (tính bằng GB) so với các bộ dữ liệu dành cho DGA Botnet đã được trích xuất các thông tin cần thiết (tính bằng MB). Cuối cùng, số lượng mẫu tên miền và số họ DGA Botnet trong các bộ dữ liệu chung về Botnet là rất ít so với các bộ dữ liệu về DGA Botnet chuyên dụng. Điều này tạo nên các hạn chế cho các đánh giá thuật toán, đặc biệt là các thuật toán học máy, học sâu cần một số lượng đủ dữ liệu để huấn luyện. Các vấn đề trên cho thấy sự cần thiết của một số dữ liệu về DGA Botnet chuyên dụng.

Bảng 4.5 khái quát các ưu điểm và hạn chế của những bộ dữ liệu về DGA Botnet chuyên dụng trình bày ở trên. Trong bảng này, NCS bổ sung riêng hàng cuối là bộ dữ liệu UTL_DGA22 (ký hiệu *UTL*), để làm rõ mục tiêu, ưu điểm của bộ dữ liệu mới đề xuất được trình bày bên dưới so với các bộ dữ liệu đã có.

Bảng 4.5. Khái quát ưu điểm và hạn chế của các bộ dữ liệu DGA Botnet hiện có và bộ dữ liệu UTL_DGA22 đề xuất

Bộ dữ liệu	**Phân lớp nhị phân**	**Phân lớp đa lớp**	**Tên miền gốc**	**Trích xuất thuộc tính**	**Công khai**	**Tài liệu**
AADR	✓	✓	✓	×	✓	N/A
JBR	✓	✓	✓	×	✓	✓ [95]
AT1D	✓	×	✓	×	✓	N/A
BDD	✓	×	×	✓	✓	✓ [92]
UMU	✓	✓	✓	✓	✓	✓[21] [18]
DFF	✓	✓	✓	×	✓	✓ [22]
OSINT	✓	×	✓	×	✓*	N/A

360NL	✓	✓	✓	×	✓	N/A
TMM	✓	×	✓	×	✓	N/A
UTL	✓	✓	✓	✓	✓	✓[38]

**: Người dùng phải liên hệ với chủ sở hữu qua email để xin cấp phép truy cập*

Trong đó:

- Phân lớp nhị phân: Bộ dữ liệu có thể được dùng cho bài toán phân lớp nhị phân hay không.

- Phân lớp đa lớp: Bộ dữ liệu có thể được dùng cho bài toán phân lớp đa lớp hay không.

- Tên miền gốc: Bộ dữ liệu có chứa các tên miền gốc hay không.

- Trích xuất thuộc tính: Bộ dữ liệu có chứa các thuộc tính đã được trích xuất từ tên miền gốc hay không.

- Công khai: Bộ dữ liệu có được công khai rộng rãi hay không.

- Tài liệu: Bộ dữ liệu có được mô tả một cách chi tiết trong các tài liệu được công bố hay không.

Bảng 4.5 cho thấy rằng, hầu hết các bộ dữ liệu về DGA Botnets hiện nay đều có thể áp dụng cho bài toán phân lớp nhị phân, nhưng chỉ một số trong đó có thể áp dụng cho bài toán phân lớp đa lớp (như BDD, AT1D, OSINT hay TMM). Điều này là do bộ dữ liệu chỉ bao gồm các tên miền lành tính, hoặc có chứa các tên miền độc hại nhưng không được phân loại rõ ràng thuộc họ DGA Botnet nào. Hầu hết các bộ dữ liệu được lưu dưới dạng tên miền gốc mà chưa được trích xuất sẵn các thuộc tính, trừ bộ dữ liệu BDD chứa các thuộc tính đã được trích xuất. Bộ dữ liệu UMUDGA Dataset được công bố năm 2020, là một bộ dữ liệu mới với 50 họ DGA Botnets, chứa cả dữ liệu gốc và dữ liệu thuộc tính đã trích xuất, có thể xem là khá toàn diện. Cuối cùng, đa phần các bộ dữ liệu trên đều được công bố trên Internet. Tuy nhiên, việc công bố tài liệu cho từng bộ dữ liệu cũng chưa hoàn toàn đầy đủ

Mục tiêu của bộ dữ liệu đề xuất là kế thừa các kết quả của tất cả các bộ dữ liệu trên và bổ sung các điểm mới, cải tiến mới để đáp ứng tất cả các tiêu chí đã đặt ra ở trong bảng.

4.2. Bộ dữ liệu UTL_DGA22 đề xuất

Trong phần này, NCS giới thiệu một bộ dữ liệu mới về DGA Botnet là UTL_DGA22 [38]. Bộ dữ liệu này kế thừa các kết quả trước đó, đồng thời cập nhật, bổ sung và cải tiến để phù hợp với các tiêu chí đã đặt ra cho một bộ dữ liệu về DGA Botnets. UTL_DGA22 chỉ được sử dụng cho học tập, nghiên cứu, không được sử dụng cho các mục đích thương mại.

4.2.1. Xây dựng bộ dữ liệu

Bộ dữ liệu UTL_DGA22 được xây dựng trải qua các bước như sau:

- Tổng hợp dữ liệu tên miền lành tính và tên miền DGA Botnet từ các nguồn đáng tin cậy. Trong đó bao gồm: UMUDGA Dataset [21] [18], DGArchive by Fraunhofer FKIE [22], Andrey Abakumov's GitHub Repository [20], The OSINT DGA feed [23], 360NetLab Dataset [24] và Johannes Bader's GitHub Repository [25]. Dữ liệu tên miền được thể hiện dưới dạng tên miền gốc và lưu trữ trong tệp tin định dạng *txt.

- Tổng hợp và đánh giá, xác định các họ DGA Botnet độc lập, loại bỏ các trường hợp cùng một họ DGA Botnet nhưng khác tên gọi, đảm bảo sự khác nhau giữa các họ DGA Botnet trong bộ dữ liệu. Kết quả có 76 họ DGA Botnets thỏa mãn các tiêu chí đặt ra.

- Tiến hành làm giàu cơ sở dữ liệu tên miền bằng cách xây dựng, kế thừa các thuật toán sinh tên miền tương ứng với từng họ tên miền. NCS cũng tổng hợp thêm từ các nguồn đáng tin cậy để đạt số lượng cần thiết. Kết quả, mỗi họ DGA Botnet có 20.000 tên miền, đảm bảo các tính chất: Sự cân bằng dữ liệu, không có trùng lặp giữa các tên miền trong cùng một họ DGA Botnet, không có sự xung đột giữa các tên miền thuộc hai họ DGA Botnet khác nhau, và cuối cùng là các tên miền trong cùng một họ thỏa mã các tính chất đặc trưng, được sinh ra từ chính thuật toán sinh mã của họ DGA Botnet đó.

- NCS đề xuất 02 nhóm thuộc tính mới, bao gồm nhóm Base-Features và TF-IDF Features, chứa các đặc trưng được rút trích từ tên miền và từ họ tên miền. Những thuộc tính đề xuất được đánh giá thử nghiệm với các thuật toán học máy cơ bản và đạt được độ chính xác khả quan. Điều này chứng tỏ các thuộc tính này hoàn toàn phù

hợp và có thể ứng dụng trong giai đoạn Feature Selection và Feature Extraction ở giải pháp đề xuất mới sau này.

- Cuối cùng, bộ dữ liệu tên miền được lưu trữ dưới dạng tệp tin *TXT. Các thuộc tính đề xuất được trích xuất giá trị bằng hệ thống máy tính có hiệu năng cao, kết quả được lưu dưới định dạng *ARFF và *CSV. Các định dạng này phù hợp để làm đầu vào cho các hệ thống như Weka, các thuật toán chạy trên Google CoLab hay Jupyter Notebook.

4.2.2. Các thuộc tính đề xuất

NCS đề xuất 02 nhóm thuộc tính, tương ứng với nhóm thuộc tính dựa trên tên miền (Base-Features) và nhóm thuộc tính dựa trên họ tên miền (TF-IDF-Features), cụ thể như sau:

4.2.2.1. Nhóm thuộc tính trên tên miền

Nhóm các thuộc tính dựa trên tên miền bao gồm 36 thuộc tính, mỗi thuộc tính được trích xuất từ một tên miền gốc. Chi tiết các thuộc tính đề xuất và ký hiệu của chúng được trình bày tại Bảng 4.6:

Bảng 4.6. Các thuộc tính đề xuất dựa trên tên miền

STT	Ký hiệu	Diễn giải	Công thức
1	dom_{TLD}	Top Level Domain	
2	dom_{SLD}	Second Level Domain	
3	L_{dom}	Độ dài của tên miền	$L_{dom} = length(dom)$
4	L_{TLD}	Độ dài của Top Level Domain	$L_{TLD} = length(dom_{TLD})$
5	L_{SLD}	Độ dài của Second Level Domain	$L_{TLD} = length(dom_{SLD})$
6	L_{OLD}	Độ dài của Other Level Domain	$L_{OLD} = L_{dom} - (L_{TLD} + L_{SLD} + 2)$
7	D_{dom}	Bậc của tên miền (tên miền cấu tạo gồm bao nhiêu phần)	$D_{dom} = \|parts(dom)\|$
8	HwP	Tên miền có bao gồm www hay không?	$HwP = \begin{cases} 1: Yes \\ 0: No \end{cases}$
9	HIP	Tên miền có bao gồm địa chỉ IP hay không	$HIP = \begin{cases} 1: Yes \\ 0: No \end{cases}$

10	LC_c	Độ dài của chuỗi phụ âm dài nhất	$LC_c = LCS(C, dom)$
11	LC_v	Độ dài của chuỗi nguyên âm dài nhất	$LC_v = LCS(V, dom)$
12	LC_l	Độ dài của chuỗi ký tự dài nhất	$LC_v = LCS(C \cup V, dom)$
13	LC_n	Độ dài của chuỗi số dài nhất	$LC_n = LCS(N, dom)$
14	AC_c	Độ dài trung bình của các chuỗi phụ âm	$AC_c = ACS(C, dom)$
15	AC_v	Độ dài trung bình của các chuỗi nguyên âm	$AC_v = ACS(V, dom)$
16	AC_l	Độ dài trung bình của các chuỗi ký tự	$AC_l = ACS(C \cup V, dom)$
17	AC_n	Độ dài trung bình của các chuỗi chữ số	$AC_n = ACS(N, dom)$
18	DC_c	Chênh lệch giữa chuỗi phụ âm dài nhất và ngắn nhất	$DC_c = DCS(C, dom)$
19	DC_v	Chênh lệch giữa chuỗi nguyên âm dài nhất và ngắn nhất	$DC_v = DCS(V, dom)$
20	DC_l	Chênh lệch giữa chuỗi ký tự dài nhất và ngắn nhất	$DC_l = DCS(C \cup V, dom)$
21	DC_n	Chênh lệch giữa chuỗi chữ số dài nhất và ngắn nhất	$DC_n = DCS(N, dom)$
22	NC_c	Số lượng các phụ âm khác nhau trong tên miền	$NC_c = NoC(C, dom)$
23	NC_v	Số lượng các nguyên âm khác nhau trong tên miền	$NC_v = NoC(V, dom)$
24	NC_l	Số lượng các chữ cái khác nhau trong tên miền	$NC_l = NC_c + NC_v$
25	NC_n	Số lượng các chữ số khác nhau trong tên miền	$NC_n = NoC(N, dom)$
26	NC_s	Số lượng các ký tự đặc biệt khác nhau trong tên miền	$NC_n = NoC(S, dom)$
27	RA_c	Tỉ lệ các ký tự phụ âm xuất hiện trong tên miền	$RA_c = \frac{NC_c}{21}$
28	RA_v	Tỉ lệ các ký tự nguyên âm xuất hiện trong tên miền	$RA_v = \frac{NC_v}{5}$

29	RA_l	Tỉ lệ các ký tự chữ cái xuất hiện trong tên miền	$RA_l = \frac{NC_l}{26}$
30	RA_n	Tỉ lệ các ký tự chữ số xuất hiện trong tên miền	$RA_n = \frac{NC_n}{10}$
31	RA_s	Tỉ lệ các ký tự đặc biệt xuất hiện trong tên miền	$RA_s = \frac{NC_s}{2}$
32	R_c	Tỉ lệ ký tự phụ âm trong tên miền	$R_c = RoC(C, dom)$
33	R_v	Tỉ lệ ký tự nguyên âm trong tên miền	$R_c = RoC(V, dom)$
34	R_l	Tỉ lệ ký tự chữ cái trong tên miền	$R_l = RoC(C \cup V, dom)$
35	R_n	Tỉ lệ ký tự chữ số trong tên miền	$R_n = RoC(N, dom)$
36	R_s	Tỉ lệ ký tự đặc biệt trong tên miền	$R_s = RoC(S, dom)$

Trong đó:

- C là tập các phụ âm:

$$C = \{b, c, d, f, g, h, j, k, l, m, n, p, q, r, s, t, v, w, x, y, z\}$$

- V là tập các nguyên âm:

$$V = \{a, e, i, o, u\}$$

- N là tập các ký tự chữ số:

$$N = \{0, 1, 2, 3, 4, 5, 6, 7, 8, 9\}$$

- S là tập các ký tự đặc biệt:

$$S = \{".", "-"\}$$

- $LCS(T, dom)$: Là thuật toán tìm độ dài của chuỗi dài nhất chứa các ký tự thuộc tập T trong tên miền dom (Thuật toán 1).

Thuật toán 1: $LCS(T, dom)$
Input $T \neq \emptyset;\ \|dom\| > 0; T, dom_j \in C \cup V \cup N \cup S$
Output $l = LCS(T, dom)$
$temp = 0$

$l = 0$

for j in $range(length(dom))$:

    if $dom_j \in T$:

        $temp = temp + 1$

    else:

        $l = \max(l, temp)$

        $temp = 0$

$l = \max(l, temp)$

return l

- $ACS(T, dom)$: Là thuật toán tìm độ dài trung bình của các chuỗi được tạo bởi các ký tự thuộc tập T trong tên miền dom (Thuật toán 2).

Thuật toán 2: $ACS(T, dom)$

Input $T \neq \emptyset; |dom| > 0; T, dom_j \in C \cup V \cup N \cup S$

Output $a = ACS(T, dom)$

$c = 0$

$st = 0$

$mark = true$

for j in $range(length(dom))$:

    if $dom_j \in T$:

        $c = c + 1$

        if $mark = true$:

        then:

            $st = st + 1$

            $mark = false$

    else $mark = true$

$a = c/st$

return a

- $DCS(T, dom)$: Là thuật toán tìm độ chênh lệch giữa chuỗi ký tự dài nhất và chuỗi ký tự ngắn nhất, các chuỗi được tạo bởi các ký tự thuộc tập T trong tên miền dom (Thuật toán 3).

Thuật toán 3: $DCS(T, dom)$

Input $T \neq \emptyset; |dom| > 0; T, dom_j \in C \cup V \cup N \cup S$

Output $d = DCS(T, dom)$

$temp = 0$
$minlength = +\infty$
$maxlength = -\infty$
for j in $range(length(dom))$:
    if $dom_j \in T$:
        $temp = temp + 1$
    else:
        $minlength = \min(minlength, temp)$
        $maxlength = \max(maxlength, temp)$
        $temp = 0$
$minlength = \min(minlength, temp)$
$maxlength = \max(maxlength, temp)$
$d = maxlength - minlength$
return d

- $NoC(T, dom)$: Là thuật toán tìm số lượng ký tự thuộc tập T xuất hiện ít nhất một lần trong tên miền dom (Thuật toán 4).

Thuật toán 4: $NoC(T, dom)$

Input $T \neq \emptyset;\ |dom| > 0; T, dom_j \in C \cup V \cup N \cup S$

Output $n = NoC(T, dom)$

$E = \emptyset$
$n = 0$
for j in $range(length(dom))$:
    if $dom_j \in T$ and $dom_j \notin E$
        $n = n + 1$
        $E = E \cup \{dom_j\}$
return n

- $RoC(T, dom)$: Là thuật toán tìm tỉ lệ ký tự thuộc tập T trên số lượng ký tự của tên miền dom (Thuật toán 5).

Thuật toán 5: $RoC(T, dom)$

Input $T \neq \emptyset;\ |dom| > 0; T, dom_j \in C \cup V \cup N \cup S$

Output $c = RoC(T, dom)$

$count = 0$

for j in $range(length(dom))$:

if $dom_j \in T$: $count = count + 1$

$c = count/length(dom)$

return c

Các thuộc tính đề xuất thể hiện vai trò, tính chất riêng của chúng trong từng tên miền hoặc họ tên miền. Điều này giúp chúng có ý nghĩa phân biệt trong việc phân loại. Vai trò của các thuộc tính được diễn giải tại Bảng 4.7:

Bảng 4.7. Vai trò của các thuộc tính đề xuất

STT	Ký hiệu	Vai trò trong phân loại DGA Botnet	
1	dom_{TLD}	Top Level Domain: TLD của mỗi tên miền trong cùng một họ DGA Botnet thường là giống nhau. Mỗi họ DGA Botnet khác nhau có TLD đặc trưng riêng.	
2	dom_{SLD}	Second Level Domain: SLD của mỗi tên miền trong cùng một họ DGA Botnet thường là giống nhau. Mỗi họ DGA Botnet khác nhau có thể có SLD đặc trưng riêng.	
3	L_{dom}	Độ dài của tên miền: Phần lớn các tên miền trong cùng một họ DGA Botnet có độ dài cố định. Độ dài cố định này thường là khác nhau giữa các họ DGA Botnet khác nhau.	
4	L_{TLD}	Độ dài của Top Level Domain: Phân biệt độ dài TLD của tên miền giữa các họ DGA Botnet, thường có các giá trị là 2, 3 hoặc 4.	
5	L_{SLD}	Độ dài của Second Level Domain: Phân biệt độ dài SLD của tên miền giữa các họ DGA Bonet.	
6	L_{OLD}	Độ dài của Other Level Domain: Phân biệt độ dài OLD của tên miền giữa các họ DGA Botnet. Độ dài này thường khác nhau rõ ràng giữa các họ DGA Botnet.	
7	D_{dom}	Bậc của tên miền: Mỗi họ DGA Botnet có số bậc đặc trưng riêng.	
8	HwP	Tên miền có bao gồm www hay không: Phân biệt giữa các họ DGA Botnet có chứa và không chứa www trong tên miền	
9	HIP	Tên miền có bô gồm địa chỉ IP hay không: Phân biệt giữa các họ DGA Botnet có chứa và không chứa địa chỉ IP trong tên miền	
10	LC_c	Độ dài của chuỗi phụ âm dài nhất	Tỉ lệ các nguyên âm, phụ âm, chữ số trong bộ từ khóa, ký tự riêng của tên miền và thuật toán sinh tên miền có
11	LC_v	Độ dài của chuỗi nguyên âm dài nhất	

12	LC_l	Độ dài của chuỗi ký tự dài nhất	liên hệ mật thiết đến độ dài dài nhất của chuỗi các loại ký tự, góp phần tạo nên đặc trưng của họ DGA Botnet đó
13	LC_n	Độ dài của chuỗi số dài nhất	
14	AC_c	Độ dài trung bình của các chuỗi phụ âm	Tỉ lệ các nguyên âm, phụ âm, chữ số trong bộ từ khóa, ký tự riêng của tên miền và thuật toán sinh tên miền có liên hệ mật thiết đến độ dài trung bình của chuỗi các loại ký tự, góp phần tạo nên đặc trưng của họ DGA Botnet đó
15	AC_v	Độ dài trung bình của các chuỗi nguyên âm	
16	AC_l	Độ dài trung bình của các chuỗi ký tự	
17	AC_n	Độ dài trung bình của các chuỗi chữ số	
18	DC_c	Chênh lệch giữa chuỗi phụ âm dài nhất và ngắn nhất	Tỉ lệ các nguyên âm, phụ âm, chữ số trong bộ từ khóa, ký tự riêng của tên miền và thuật toán sinh tên miền có liên hệ mật thiết đến độ dài của chuỗi các loại ký tự. Sự chênh lệch giữa chuỗi dài nhất và chuỗi ngắn nhất cũng là một đặc trưng riêng của họ DGA Botnet.
19	DC_v	Chênh lệch giữa chuỗi nguyên âm dài nhất và ngắn nhất	
20	DC_l	Chênh lệch giữa chuỗi ký tự dài nhất và ngắn nhất	
21	DC_n	Chênh lệch giữa chuỗi chữ số dài nhất và ngắn nhất	
22	NC_c	Số lượng các phụ âm khác nhau trong tên miền	Do tỉ lệ các nguyên âm, phụ âm, chữ số trong bộ từ khóa, ký tự riêng của tên miền và thuật toán sinh tên miền là khác nhau giữa các họ DGA Botnet. Nên sự phân bố số lượng của từng loại ký tự trong tên miền cũng có đặc trưng riêng cho từng họ.
23	NC_v	Số lượng các nguyên âm khác nhau trong tên miền	
24	NC_l	Số lượng các chữ cái khác nhau trong tên miền	
25	NC_n	Số lượng các chữ số khác nhau trong tên miền	
26	NC_s	Số lượng các ký tự đặc biệt khác nhau trong tên miền	
27	RA_c	Tỉ lệ các ký tự phụ âm xuất hiện trong tên miền	Do tỉ lệ các nguyên âm, phụ âm, chữ số trong bộ từ khóa, ký tự riêng của tên miền và thuật toán sinh tên miền là khác nhau giữa các họ DGA Botnet. Nên tỉ lệ xuất hiện của từng loại ký tự trong tên miền cũng có đặc trưng riêng cho từng họ.
28	RA_v	Tỉ lệ các ký tự nguyên âm xuất hiện trong tên miền	
29	RA_l	Tỉ lệ các ký tự chữ cái xuất hiện trong tên miền	
30	RA_n	Tỉ lệ các ký tự chữ số xuất hiện trong tên miền	

31	RA_s	Tỉ lệ các ký tự đặc biệt xuất hiện trong tên miền	
32	R_c	Tỉ lệ ký tự phụ âm trong tên miền	Do tỉ lệ các nguyên âm, phụ âm, chữ số trong bộ từ khóa, ký tự riêng của tên miền. Nên sự tỉ lệ xuất hiện của từng loại ký tự trong tên miền cũng có đặc trưng riêng cho từng họ. Trong tỉ lệ này, các ký tự trùng nhau được tính duy nhất một lần.
33	R_v	Tỉ lệ ký tự nguyên âm trong tên miền	
34	R_l	Tỉ lệ ký tự chữ cái trong tên miền	
35	R_n	Tỉ lệ ký tự chữ số trong tên miền	
36	R_s	Tỉ lệ ký tự đặc biệt trong tên miền	

Bảng 4.8 minh họa ví dụ giá trị của các thuộc tính đề xuất thuộc nhóm Base Features, được áp dụng trên một tên miền lành tính và một tên miền của DGA Botnet.

- Tên miền lành tính - Nhãn 0: google.com.vn.

- Tên miền DGA Botnet - Nhãn 1: ojhpiwdmmyxneo88.com.

Bảng 4.8. Minh họa giá trị của thuộc tính thuộc nhóm Base-Features

STT	**Thuộc tính**	***Nhãn 0***	***Nhãn 1***	**STT**	**Thuộc tính**	***Nhãn 0***	***Nhãn 1***
1	dom_{TLD}	vn	com	19	DC_v	1	1
2	dom_{SLD}	com	ojhpiwdmmyxneo88	20	DC_l	4	11
3	L_{dom}	13	20	21	DC_n	0	2
4	L_{TLD}	2	3	22	NC_c	6	10
5	L_{SLD}	3	0	23	NC_v	2	3
6	L_{OLD}	6	16	24	NC_l	8	13
7	D_{dom}	3	2	25	NC_n	0	1
8	HwP	0	0	26	NC_s	1	1
9	HIP	0	0	27	RA_c	0,29	0,48
10	LC_c	2	7	28	RA_v	0,40	0,60
11	LC_v	2	2	29	RA_l	0,31	0,50
12	LC_l	6	14	30	RA_n	0,00	0,10
13	LC_n	0	2	31	RA_s	0,50	0,50

14	AC_c	1,4	3,5	32	R_c	0,54	0,60
15	AC_v	1,33	1,25	33	R_v	0,31	0,25
16	AC_l	3,66	8,5	34	R_l	0,85	0,85
17	AC_n	0	2	35	R_n	0,00	0,10
18	DC_c	1	6	36	R_s	0,15	0,.05

4.2.2.2. Nhóm thuộc tính trên họ tên miền

Nhận xét rằng, mỗi họ tên miền có các đặc trưng khác nhau về không gian ký tự, bộ từ khóa, thứ tự các từ khóa trong cấu tạo tên miền và sự phụ thuộc vào nhân sinh tên miền. Các đặc trưng TF-IDF có khả năng thể hiện được những đặc trưng trên đối với mỗi họ tên miền, khi mà số lượng mẫu tên miền trong một họ là đủ lớn. NCS đề xuất sử dụng các thuộc tính này và gọi là nhóm thuộc tính TI-IDF Features.

Khái niệm về TF-IDF được trình bày tại Mục 2.2.1.3. Để tính toán đặc trưng TF-IDF, NCS trích xuất các n-gram với giá trị từ 2-gram đến 5-gram và được lưu trữ như một thành phần của bộ dữ liệu.

4.2.3. Cấu trúc lưu trữ của bộ dữ liệu

Bộ dữ liệu DGA_UTL22 được cấu trúc gồm hai phần tương ứng với hai thư mục, gồm DGA_Botnets_Domains và DGA_Botnets_Features_Extraction.

- Thư mục DGA_Botnets_Domains bao gồm 76 tệp tin TXT, mỗi tệp tin chứa 10.000 tên miền gốc của họ DGA Botnets tương ứng. Thư mục cũng bao gồm tệp tin AT1M.txt lưu trữ 1.000.000 tên miền lành tính được cung cấp bởi Alexa. Danh sách các họ DGA Botnets có trong bộ dữ liệu được trình bày tại Mục 4.3.

- Thư mục DGA_Botnets_Features_Extraction, chứa dữ liệu được trích xuất từ 10.000 tên miền cho mỗi họ DGA Botnet và nhóm các tên miền lành tính, gồm hai thư mục con như sau:

+ Thư mục Base_Features: Chứa 77 tệp tin CSV và 77 tệp tin ARFF, lưu trữ các thuộc tính được trích xuất cho 76 họ DGA Botnet và 01 họ tên miền lành tính.

+ Thư mục TF-IDF_Features: Chứa 308 tệp tin thuộc tính được trích xuất từ 76 họ DGA Botnet và một họ các tên miền lành tính. Mỗi họ gồm 4 tệp tin như sau: Tệp tin thuộc tính 2-gram, 3-gram tương ứng được lưu dưới dạng CSV hoặc

Pickle. Tệp tin còn lại là ALLS.pickle chứa thuộc tính được trích xuất trên toàn bộ các tên miền.

4.3. Các họ DGA Botnet trong bộ dữ liệu UTL_DGA22

Bộ dữ liệu UTL_DGA22 bao gồm 76 họ DGA Botnet riêng biệt. Danh sách các họ DGA Botnet này được liệt kê ở Bảng 4.9:

Bảng 4.9. Danh sách các họ DGA Botnet trong bộ dữ liệu UTL_DGA22

STT	**Tên (*Tên gọi khác*)**	**STT**	**Tên (*Tên gọi khác*)**
1	banjori (*MultiBanker 2 / BankPatch / BackPatcher*)	39	qsnatch
2	bazarbackdoor (*BazarLoader / Team9Backdoor*)	40	ramnit
3	bazarbackdoor_v2 (*BazarLoader / Team9Backdoor*)	41	ranbyus_v1
4	bazarbackdoor_v3 (*BazarLoader / Team9Backdoor*)	42	ranbyus_v2
5	chinad	43	reconyc
6	corebot	44	shiotob (*Urlzone / Bebloh*)
7	dircrypt	45	simda (*Shiz*)
8	dnschanger (*Alureon*)	46	sisron (*Tomb / win32_agent.wrq / trojan.scar*)
9	fobber_v1 (*Tinba_v3*)	47	suppobox_1
10	fobber_v2 (*Tinba_v3*)	48	suppobox_2
11	gozi_rfc4343	49	suppobox_3
12	gozi_nasa	50	symmi
13	gozi_luther	51	tempedreve
14	gozi_gpl	52	tinba [98] (*Tinybanker*)
15	kraken_v1 (*Oderoor / Bobax*)	53	vawtrak_v1
16	kraken_v2 (*Oderoor / Bobax*)	54	vawtrak_v2
17	locky	55	vawtrak_v3
18	monerodownloader	56	zloader
19	murofet_v1	57	cryptolocker
20	murofet_v2	58	rovnix

21	murofet_v3	59	matsnu
22	mydoom (*Novarg / Mimail.r / Shimgapi*)	60	ramdo
23	necurs	61	bigviktor
24	newgoz (*Gameover Zeus / Peer-to-Peer Zeus*)	62	ccleaner
25	nymaim	63	enviserv
26	nymaim2	64	vidro
27	padcrypt	65	dyre
28	pitou	66	beautiful baby
29	pizza	67	bamital
30	proslikefan	68	emotet
31	pushdo	69	infy
32	pykspa_improved_useful	70	murofetweekly
33	pykspa_improved_noise	71	oderoor
34	pykspa_precursor	72	pandabanker
35	qadars	73	sphinx
36	qakbot	74	szribi
37	virus	75	tinynuke
38	wd	76	torpig

4.4. Đánh giá bộ thuộc tính đề xuất

NCS sử dụng các thuộc tính đề xuất làm đầu vào của các mô hình học máy cơ bản cho bài toán phân lớp nhị phân và phân lớp đa lớp. Các thuật toán được sử dụng bao gồm: RF, LR, NB, SVM, k-NN, DT, NN và AB. Các mô hình được cài đặt thông số mặc định. Bộ dữ liệu đánh giá được lấy từ bộ DGA_UTL22, cụ thể:

- Tên miền lành tính: Gồm 1.000.000 tên miền lành tính của Alexa.

- Tên miền độc hại: Gồm 76 họ DGA Botnet, mỗi họ gồm 10.000 tên miền. Tổng số lượng tên miền độc hại là 760.000 tên miền.

Phương pháp đánh giá k-fold với k=5. Các tham số đánh giá bao gồm: Accuray, Precision, Recall và F_1-Score. Giá trị các tham số cài đặt cho các mô hình học máy được cho tại Bảng 4.10.

Bảng 4.10. Giá trị các tham số cài đặt cho các mô hình học máy khi đánh giá trên bộ dữ liệu UTL_DGA22

STT	Mô hình	Thư viện	Cấu hình tham số
1	Logistic Regression	Logistic Regression (sklearn.linear_model)	penalty='l2', *, dual=False, tol=0.0001, C=1.0, fit_intercept=True, intercept_scaling=1, class_weight=None, random_state=42, solver='lbfgs', max_iter=100, multi_class='auto', verbose=0, warm_start=False, n_jobs=None, l1_ratio=None
2	Naive Bayes	BernoulliNB (sklearn.naive_bayes)	*, alpha=1.0, binarize=0.0, fit_prior=True, class_prior=None
3	Decision Tree	DecisionTree Classifier (sklearn.tree)	*, criterion='gini', splitter='best', max_depth=None, min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_features=None, random_state=42, max_leaf_nodes=None, min_impurity_decrease=0.0, class_weight=None, ccp_alpha=0.0)
4	Neural Network	MLPClassifier (sklearn.neural_network)	hidden_layer_sizes=(100,), activation='relu', *, solver='lbfgs', alpha=0.00001, batch_size='auto', learning_rate='constant', learning_rate_init=0.001, power_t=0.5, max_iter=200, shuffle=True, random_state=42, tol=0.0001, verbose=False, warm_start=False, momentum=0.9, nesterovs_momentum=True, early_stopping=False, validation_fraction=0.1, beta_1=0.9, beta_2=0.999, epsilon=1e-08, n_iter_no_change=10, max_fun=15000
5	Support Vector Machine	LinearSVC (sklearn.svm)	penalty='l2', loss='squared_hinge', *, dual=True, tol=0.0001, C=0.05, multi_class='ovr', fit_intercept=True, intercept_scaling=1, class_weight=None, verbose=0, random_state=None, max_iter=1000
6	Random Forrest	RandomForestClassifier (sklearn.ensemble)	n_estimators=10, *, criterion='gini', max_depth=None, min_samples_split=2, min_samples_leaf=1, min_weight_fraction_leaf=0.0, max_features='sqrt', max_leaf_nodes=None, min_impurity_decrease=0.0, bootstrap=True, oob_score=False, n_jobs=None, random_state=42, verbose=0, warm_start=False, class_weight=None, ccp_alpha=0.0, max_samples=None
7	K-Nearest Neighbor	Kneighbors Classifier (sklearn.neighbors)	n_neighbors=3, *, weights='uniform', algorithm='auto', leaf_size=30, p=2, metric='minkowski', metric_params=None, n_jobs=None

8	Adaptive Boosting	AdaBoost Classifier (sklearn. ensemble)	base_estimator=None, *, n_estimators=100, learning_rate=1.0, algorithm='SAMME.R', random_state=42

4.4.1. Thử nghiệm đối với bài toán phân lớp nhị phân

Hình 4.1 thể hiện kết quả phân lớp nhị phân khi sử dụng các thuộc tính Base-Features làm đầu vào:

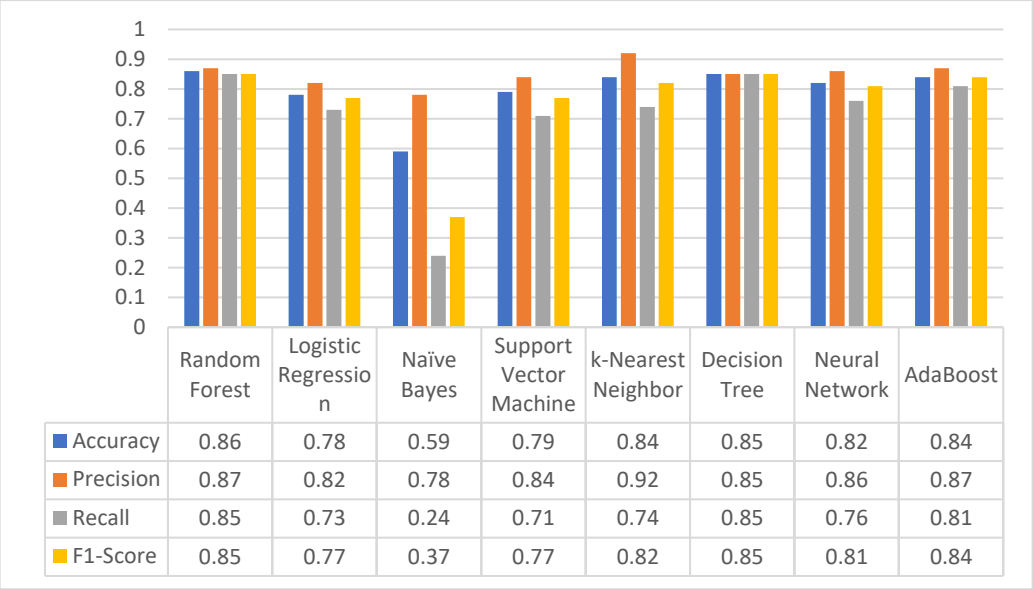

	Random Forest	Logistic Regression	Naïve Bayes	Support Vector Machine	k-Nearest Neighbor	Decision Tree	Neural Network	AdaBoost
Accuracy	0.86	0.78	0.59	0.79	0.84	0.85	0.82	0.84
Precision	0.87	0.82	0.78	0.84	0.92	0.85	0.86	0.87
Recall	0.85	0.73	0.24	0.71	0.74	0.85	0.76	0.81
F1-Score	0.85	0.77	0.37	0.77	0.82	0.85	0.81	0.84

Hình 4.1. Kết quả phân lớp nhị phân sử dụng Base Features làm đầu vào trên bộ dữ liệu UTL_DGA22

Hình 4.2 thể hiện kết quả phân lớp nhị phân khi sử dụng các thuộc tính TF-IDF-Features làm đầu vào:

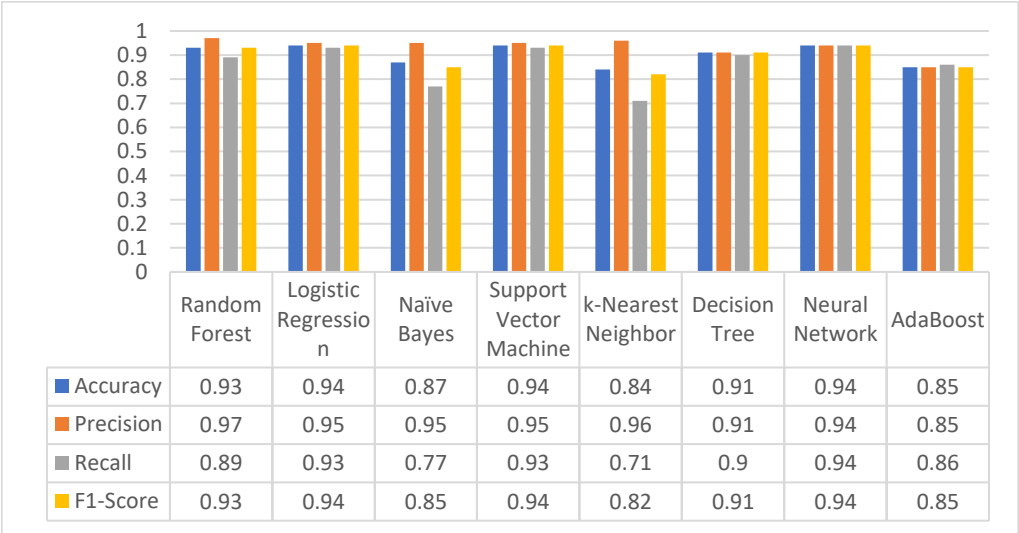

	Random Forest	Logistic Regression	Naïve Bayes	Support Vector Machine	k-Nearest Neighbor	Decision Tree	Neural Network	AdaBoost
Accuracy	0.93	0.94	0.87	0.94	0.84	0.91	0.94	0.85
Precision	0.97	0.95	0.95	0.95	0.96	0.91	0.94	0.85
Recall	0.89	0.93	0.77	0.93	0.71	0.9	0.94	0.86
F1-Score	0.93	0.94	0.85	0.94	0.82	0.91	0.94	0.85

Hình 4.2. Kết quả phân lớp nhị phân sử dụng TF-IDF Features làm đầu vào trên bộ dữ liệu UTL_DGA22

Nhận xét rằng, trong bài toán phân lớp nhị phân, cả hai bộ thuộc tính Base và TF-IDF đều chứng tỏ sự phù hợp khi làm đầu vào cho các thuật toán học máy. Điều này được thể hiện ở việc phần lớn các mô hình đều có Accuracy, Precision, Recall và F_1-Score đạt được giá trị cao, trong khoảng 0,82 đến 0,94 đối với F_1-score. Ví dụ, mô hình RF có Accuracy đạt 0,86 khi sử dụng các thuộc tính Base. Hay mô hình LR, NN cho Accuracy đạt 0,94 khi sử dụng các thuộc tính TF-IDF. Các mô hình còn lại cũng cho kết quả tốt, chứng tỏ rằng các nhóm thuộc tính đề xuất là hoàn toàn phù hợp, mang những đặc trưng riêng của từng họ tên miền, từ đó giúp cho các mô hình phân loại hoạt động hiệu quả.

Từ Hình 4.1 và Hình 4.2 cũng có thể thấy rằng, các thuật toán học máy có hiệu quả tốt hơn khi sử dụng nhóm các thuộc tính TF-IDF làm đầu vào so với nhóm các thuộc tính Base. Điều này có thể được giải thích bởi vì mỗi họ DGA Botnet sử dụng một không gian ký tự riêng, dẫn tới sự phân bố tần suất các ký tự cũng mang những đặc trưng riêng và khác nhau giữa các họ DGA Botnet. Thuộc tính TF-IDF xem xét đặc điểm của tên miền dựa trên tần suất xuất hiện của các ký tự trong tên miền. Tần suất này có thể mang đặc trưng cho một họ DGA Botnet khi kích thước mẫu đủ lớn. Điều này khác với các tên miền lành tính, khi nó sử dụng các ký tự trong bảng chữ cái tiếng anh, các chữ số từ ‘0’ đến ‘9’ và thường không tuân theo một sự phân bố tần suất cụ thể. Sự khác biệt này cho phép các thuật toán học máy phân biệt tốt hơn khi phân lớp giữa tên miền độc hại và tên miền lành tính. Các giải pháp đề xuất trong tương lai cũng có thể kết hợp hai bộ thuộc tính TF-IDF và thuộc tính Base để đạt được độ chính xác tối đa.

4.4.2. Thử nghiệm đối với bài toán phân lớp đa lớp

Trong trường hợp sử dụng các bộ thuộc tính Base và TF-IDF cho bài toán phân lớp đa lớp, ta có các kết quả lần lượt được cho ở Hình 4.3 và Hình 4.4.

Hình 4.3 cho thấy, có 6/8 thuật toán học máy cho kết quả phân loại ở mức trên 0,52. Trong đó, thuật toán RF đạt Accuracy, Precision, Recall và F_1-Score mức khoảng 0,65; thuật toán DT đạt Accuracy, Precision, Recall và F_1-Score lần lượt là 0,66, 0,64, 0,66 và 0,65. Chỉ hai thuật toán đạt kết quả thấp là NB và AB trong thử nghiệm này với F_1-score lần lượt là 0,09 và 0,05.

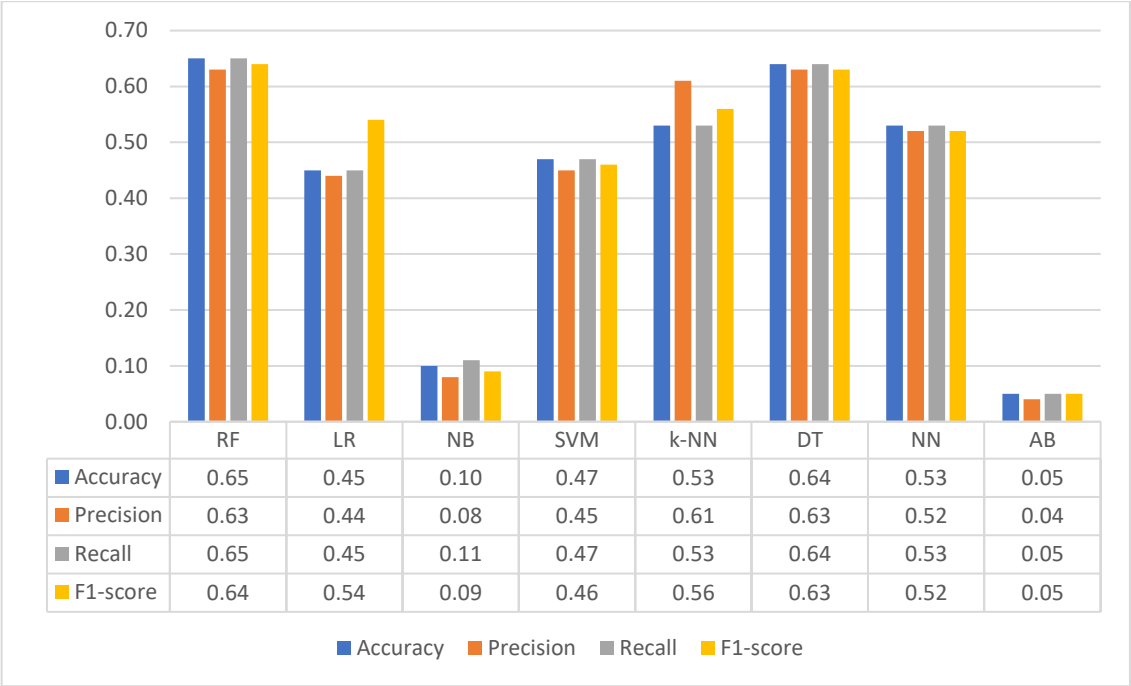

	RF	LR	NB	SVM	k-NN	DT	NN	AB
Accuracy	0.65	0.45	0.10	0.47	0.53	0.64	0.53	0.05
Precision	0.63	0.44	0.08	0.45	0.61	0.63	0.52	0.04
Recall	0.65	0.45	0.11	0.47	0.53	0.64	0.53	0.05
F1-score	0.64	0.54	0.09	0.46	0.56	0.63	0.52	0.05

Hình 4.3. Kết quả phân lớp đa lớp của các mô hình học máy sử dụng Base Features trên bộ dữ liệu UTL_DGA22

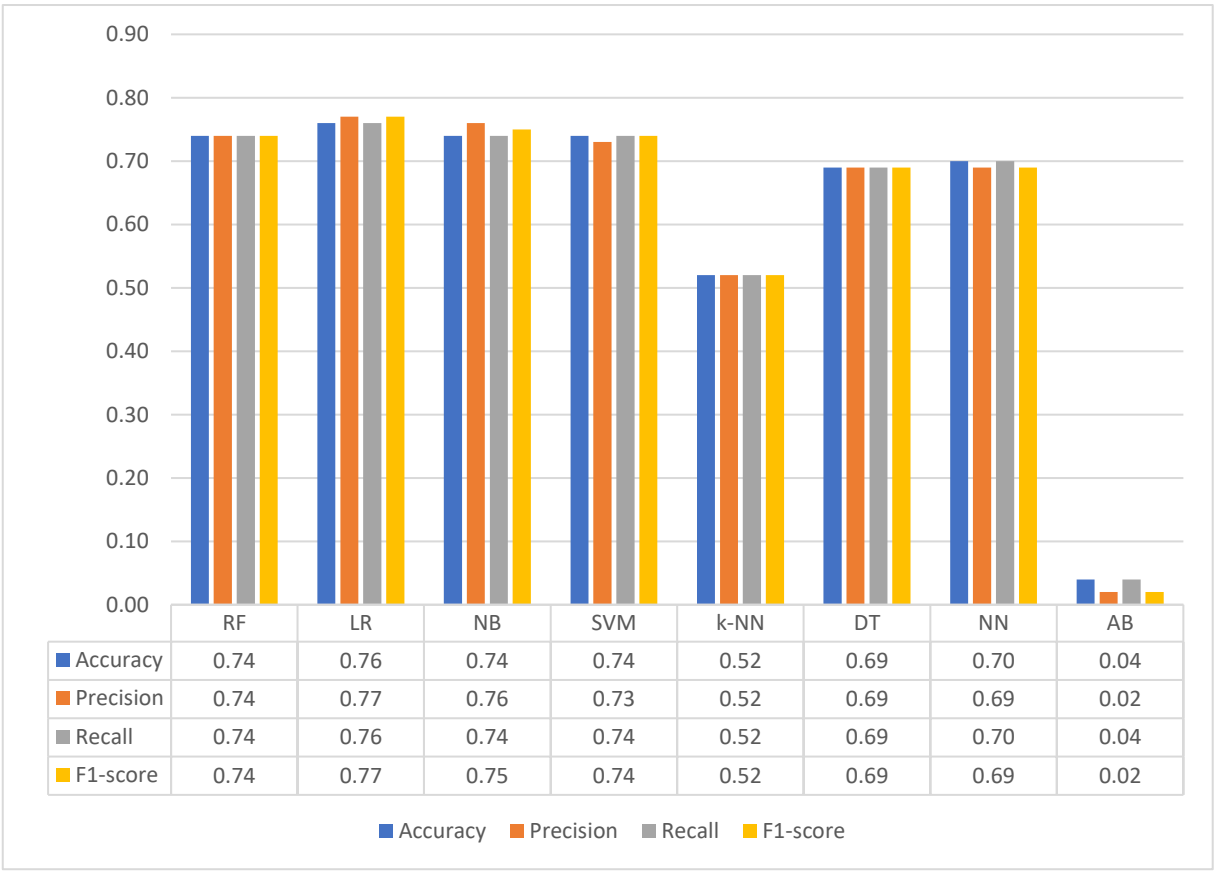

	RF	LR	NB	SVM	k-NN	DT	NN	AB
Accuracy	0.74	0.76	0.74	0.74	0.52	0.69	0.70	0.04
Precision	0.74	0.77	0.76	0.73	0.52	0.69	0.69	0.02
Recall	0.74	0.76	0.74	0.74	0.52	0.69	0.70	0.04
F1-score	0.74	0.77	0.75	0.74	0.52	0.69	0.69	0.02

Hình 4.4. Kết quả phân lớp đa lớp của các mô hình học máy sử dụng TF-IDF Featues trên bộ dữ liệu UTL_DGA22

Hình 4.4 cho thấy, khi sử dụng các thuộc tính TF-IDF làm đầu vào, các thuật toán học máy cho hiệu năng tốt với Accuracy hầu hết đạt từ 0,70 trở lên (RF, LR, SVM, NN. Mô hình AB và k-NN hoạt động kém hiệu quả trong trường hợp này với F_1-socre lần lượt đạt 0,02 và 0,52.

Tổng kết lại, kết quả thực nghiệm trên cho thấy các tập thuộc tính được đề xuất là hoàn toàn phù hợp làm đầu vào cho các bộ phân loại, thể hiện bằng việc chúng đạt độ chính xác tốt khi chỉ áp dụng các mô hình học máy cơ bản. Việc lựa chọn các thuộc tính phụ thuộc vào từng phương pháp đề xuất mới để tối ưu hóa độ chính xác và thời gian huấn luyện. Sự kết hợp của nhóm thuộc tính Base và thuộc tính TF-IDF được khuyến nghị để có thể đạt được độ chính xác tối ưu.

4.5. Đánh giá các giải pháp đề xuất trên bộ dữ liệu UTL_DGA22

Trong phần này, NCS tiến hành đánh giá các giải pháp đề xuất ở Chương 2, Chương 3 trên bộ dữ liệu mới UTL_DGA22, bao gồm: Thuật toán NCM, mô hình VEA và HEA, hai mô hình học sâu LA_Bin07 và LA_Mul07.

4.5.1. Đánh giá với thuật toán phân cụm NCM

Thuật toán phân cụm NCM áp dụng cho bài toán phân lớp nhị phân, được đề xuất và mô tả các bước tại Mục 2.1 của luận án này.

Trong đánh giá này, NCS sử dụng 100.000 tên miền lành tính và 100.000 tên miền của DGA Botnet được lựa chọn ngẫu nhiên và phân phối đều cho 76 họ DGA Bonet trong bộ dữ liệu UTL_DGA22. Thuật toán chạy trên Google Colab sử dụng CPU, RAM 12GB. Kết quả được cho tại Bảng 4.11:

Bảng 4.11. Kết quả đánh giá thuật toán NCM trên bộ dữ liệu UTL_DGA22

Nhãn	**Precision**	**Recall**	**F_1-Score**
0	0,66	0,93	0,77
1	0,91	0,48	0,62
Avg*	***0,79***	***0,70***	***0,70***

Ma trận nhầm lẫn thể hiện phân phối các nhãn và số lượng các mẫu được cho tại Hình 4.5:

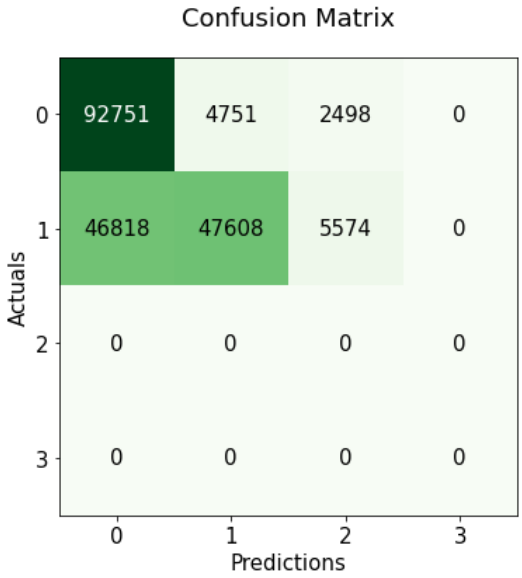

Hình 4.5. Ma trận nhầm lẫn của thuật toán NCM trên bộ dữ liệu UTL_DGA22

Nhận xét rằng, thuật toán NCM có khả năng phân loại chưa tốt trên bộ dữ liệu UTL_DGA22, với Precision, Recall và F_1-score lần lượt đạt 0,79, 0,70 và 0,70. So sánh với kết quả trên 04 bộ dữ liệu AADR, 360NetLab, OSINT và UMUDGA (tại Bảng 2.5), ta thấy rằng ngoại trừ bộ dữ liệu OSINT, thì kết quả đánh giá của NCM trên UTL_DGA22 thấp hơn so với 03 bộ dữ liệu còn lại, tương ứng F_1-score là 0,70 so với lần lượt 0,79, 0,84 và 0,84. Điều này thể hiện rằng, bộ dữ liệu UTL_DGA22 là khó để phân loại hơn so với các bộ dữ liệu trước đó. Điều này có thể được cải thiện bởi các mô hình học máy và học sâu.

4.5.2. Đánh giá với các thuật toán học máy

Các mô hình học máy và VEA, HEA áp dụng cho bài toán phân lớp nhị phân, được đề xuất và mô tả tại Mục 2.2 của luận án này.

NCS sử dụng 1.000.000 tên miền lành tính và 76.000 tên miền của DGA Botnet tương ứng với 76 họ DGA Bonet trong bộ dữ liệu UTL_DGA22, mỗi họ có chứa đúng 10.000 tên miền. Thuật toán chạy trên Google Colab sử dụng CPU, RAM 12GB, đánh giá k-fold với k=10. Kết quả đánh giá được thể hiện ở Bảng 4.12:

Bảng 4.12. Kết quả đánh giá các thuật toán học máy đề xuất trên bộ dữ liệu UTL_DGA22

Mô hình	**Acc.**	**Pre.**	**Re.**	**F_1.**	**Thời gian huấn luyện (s)**	**Thời gian đánh giá (s)**
Logistic Regression	0,96	0,97	0,95	0,96	75,59	0,04

Naive Bayes	0,90	0,91	0,86	0,89	1,34	0,14
Decision Tree	0,90	0,90	0,88	0,89	16.004,87	0,71
Neural Network	0,97	0,97	0,96	0,96	4.777,21	0,96
Support Vector Machine	0,96	0,97	0,94	0,96	11,04	0,03
Random Forrest	0,60	1,00	0,07	0,14	62,57	4,06
K-Nearest Neighbor	0,80	0,97	0,56	0,71	0,47	19.462,80
Adaptive Boosting	0,84	0,84	0,79	0,81	2.917,49	12,22
VEA	0,97	0,97	0,96	0,96	16.803,67	18,45
HEA	0,97	0,97	0,95	0,96	7.425,03	10,10

Kết quả trên cho thấy, các thuật toán học máy có kết quả tốt trên bộ dữ liệu mới nhưng thấp hơn so với kết quả đánh giá trên bộ dữ liệu UMUDGA, trong đó mô hình đạt kết quả thấp nhất là RF với F_1-score là 0,14, mô hình đạt kết quả cao nhất là NN, VEA và HEA với F_1-score đạt 0,96. Hầu hết các mô hình đều có sự cân bằng giữ Accuracy, Precision và Recall, trừ hai mô hình RF và k-NN cho sự khác biệt khác lớn giữa Precision và Recall.

Xem xét về thời gian, hầu hết các mô hình đều có thời gian huấn luyện chiếm tỉ trọng lớn trong toàn bộ thời gian thử nghiệm, ngoại trừ k-NN. Mô hình NB cho tổng thời gian huấn luyện và đánh giá nhanh nhất với 1,48 giây, và chậm nhất là mô hình k-NN với 19.463,27 giây cho việc đánh giá. Lưu ý rằng, việc huấn luyện trên CPU đòi hỏi rất nhiều thời gian và không tận dụng được năng lực của GPU, đây cũng là một hạn chế so với các mô hình học sâu.

4.5.3. Đánh giá với hai mô hình học sâu LA_Bin07 và LA_Mul07

Hai mô hình học sâu LA_Bin07 và LA_Mul07 lần lượt được áp dụng cho bài toán phân lớp nhị phân và phân lớp đa lớp, được đề xuất và trình bày tại Chương 3 của luận án này.

NCS sử dụng 1.000.000 tên miền lành tính và 76.000 tên miền của DGA Botnet tương ứng với 76 họ DGA Bonet, mỗi họ có 10.000 tên miền. Thuật toán chạy trên Google Colab Pro sử dụng GPU, RAM Premium, epochs = 10.

4.5.3.1. Đánh giá mô hình LA_Bin07 trên bộ dữ liệu UTL_DGA22

Kết quả đánh giá độ chính xác của mô hình LA_Bin07 trên bộ dữ liệu UTL_DGA22 cho bài toán phân lớp nhị phân được thể hiện tại Bảng 4.13:

Bảng 4.13. Kết quả đánh giá mô hình LA_Bin07 trên bộ dữ liệu UTL_DGA22

Nhãn	**Precision**	**Recall**	**F_1-Score**
Lành tính	0,98	0,98	0,98
DGA Botnet	0,98	0,97	0,97
Accuracy	***0,98***		

Bảng trên cho thấy, mô hình LA_Bin07 có Accuracy cao đạt 0,98. Khả năng xác định các nhãn cũng đồng đều, không bị lệch về phía nào. Độ chính xác này cũng cao hơn so với hai giải pháp trước đó là NCM và học máy, chứng tỏ mô hình LA_Bin07 vẫn đảm bảo tính hiệu quả và cải tiến độ chính xác như các đánh giá ở Chương 3.

Ma trận nhầm lẫn và ROC Curve của mô hình LA_Bin07 lần lượt được thể hiện tại Hình 4.6 và Hình 4.7, cung cấp thêm các thông tin về khả năng phân loại của mô hình đề xuất.

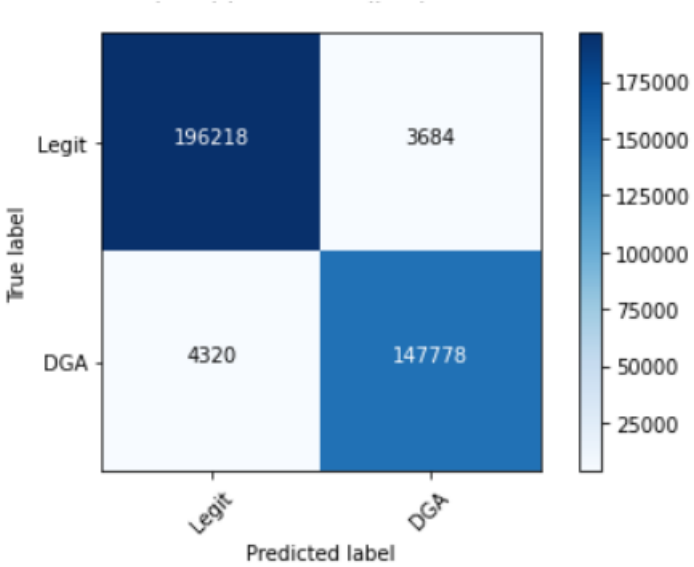

Hình 4.6. Ma trận nhầm lẫn của mô hình LA_Bin07 khi đánh giá trên bộ dữ liệu UTL_DGA22

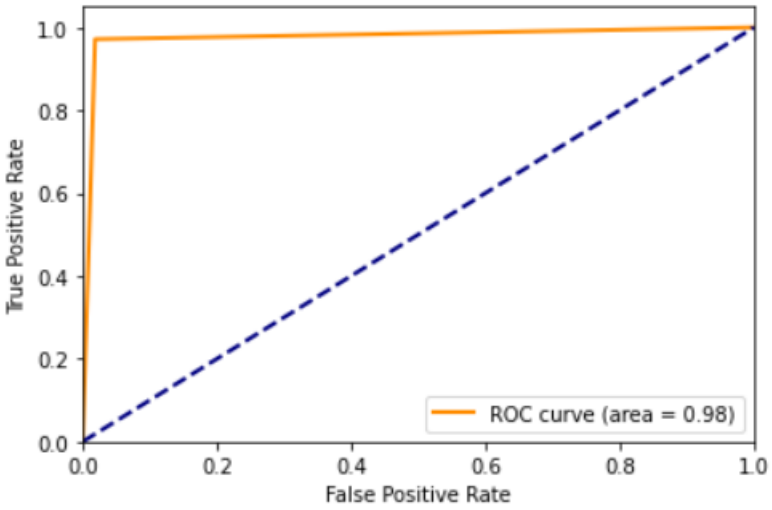

Hình 4.7. ROC Curve của mô hình LA_Bin07 khi đánh giá trên bộ dữ liệu UTL_DGA22

4.5.3.2. Đánh giá mô hình LA_Mul07 trên bộ dữ liệu UTL_DGA22

Kết quả đánh giá độ chính xác của mô hình LA_Mul07 trên bộ dữ liệu UTL_DGA22 trong bài toán phân lớp đa lớp được thể hiện tại Bảng 4.13:

Bảng 4.14. Kết quả đánh giá mô hình LA_Mul07 trên bộ dữ liệu UTL_DGA22

STT	DGA Botnet	Pre.	Re.	F_1.	STT	DGA Botnet	Pre.	Re.	F_1.
1	bamital	1,00	1,00	1,00	39	padcrypt	1,00	1,00	1,00
2	banjori	1,00	1,00	1,00	40	pandabanker	1,00	1,00	1,00
3	bazarbackdoor	1,00	1,00	1,00	41	pitou	1,00	1,00	1,00
4	bazarbackdoor_v2	1,00	1,00	1,00	42	pizd	0,92	0,97	0,95
5	bazarbackdoor_v3	1,00	1,00	1,00	43	proslikefan	0,79	0,62	0,70
6	bedep	0,71	0,67	0,69	44	pushdo	1,00	0,99	1,00
7	bigviktor	0,97	0,96	0,97	45	pykspa_ improved_noise	0,44	0,19	0,26
8	ccleaner	1,00	1,00	1,00	46	pykspa_ improved_useful	0,36	0,37	0,37
9	chinad	1,00	1,00	1,00	47	pykspa_precursor	0,99	0,99	0,99
10	corebot	1,00	1,00	1,00	48	qadars	1,00	0,99	1,00
11	cryptolocker	0,69	0,65	0,67	49	qakbot	0,83	0,48	0,61
12	dircrypt	0,50	0,13	0,20	50	qsnatch	1,00	1,00	1,00
13	dnschanger	0,41	0,84	0,55	51	ramdo	1,00	1,00	1,00
14	dyre	1,00	1,00	1,00	52	ramnit	0,37	0,56	0,44

15	emotet	1.00	1.00	1.00	53	ranbyus_v1	0,75	0,98	0,85
16	enviserv	1,00	1,00	1,00	54	ranbyus_v2	0,83	0,87	0,85
17	fobber_v1	0,88	1,00	0,94	55	reconyc	1,00	1,00	1,00
18	fobber_v2	0,44	0,17	0,25	56	rovnix	0,98	0,95	0,96
19	gozi_gpl	0,97	0,99	0,98	57	shiotob	1,00	0,91	0,95
20	gozi_luther	0,98	0,97	0,97	58	simda	1,00	1,00	1,00
21	gozi_nasa	0,94	0,97	0,95	59	sisron	1,00	1,00	1,00
22	gozi_rfc4343	0,93	0,95	0,94	60	sphinx	0,82	0,96	0,89
23	infy	1,00	1,00	1,00	61	suppobox_1	0,97	0,92	0,94
24	kraken_v1	0,90	0,44	0,59	62	suppobox_2	0,99	1,00	0,99
25	kraken_v2	0,58	0,66	0,62	63	suppobox_3	1,00	1,00	1,00
26	locky	0,85	0,63	0,72	64	symmi	1,00	1,00	1,00
27	matsnu	0,96	0,98	0,97	65	szribi	0,99	1,00	0,99
28	monerodownloader	1,00	1,00	1,00	66	tempedreve	0,59	0,75	0,66
29	murofetweekly	0,50	0,70	0,59	67	tinba	0,73	0,98	0,84
30	murofet_v1	0,95	0,96	0,95	68	tinynuke	1,00	1,00	1,00
31	murofet_v2	0,74	0,84	0,79	69	torpig	0,98	1,00	0,99
32	murofet_v3	0,48	0,29	0,36	70	vawtrak_v1	1,00	1,00	1,00
33	mydoom	1,00	1,00	1,00	71	vawtrak_v2	1,00	1,00	1,00
34	necurs	0,99	0,80	0,89	72	vawtrak_v3	1,00	1,00	1,00
35	newgoz	1,00	1,00	1,00	73	vidro	0,33	0,48	0,39
36	nymaim	0,50	0,84	0,63	74	virut	0,90	1,00	0,95
37	nymaim2	0,99	0,94	0,96	75	wd	1,00	1,00	1,00
38	oderoor	0,43	0,17	0,24	76	zloader	0,95	1,00	0,97
Avg Accuracy		***0,86***							

Kết quả trên cho thấy, mô hình LA_Mul07 có Avg Accuracy đạt 0,86 khi đánh giá trên bộ dữ liệu mới UTL_DGA22. Có 32 họ DGA Botnet được xác định nhãn đúng gần như tuyệt đối với F_1-score đạt 1,00. Một số họ DGA Botnet có khả năng phát hiện kém với F_1-score thấp như dircrypt (0,20), fobber_v2 (0,25), murofet_v3 (0,36), oderoor (0,24), pykspa_improved_noise (0,26), pykspa_improved_useful (0,37), ramnit (0,44), vidro (0,39). Các họ DGA Botnet còn lại nhìn chung cho kết quả phân loại khá tốt.

NCS không thể hiện ma trận nhầm lẫn và ROC Curve của đánh giá trên bằng đồ thị vì không đủ kích thước. Giá trị Support được tóm tắt tại Bảng 4.15:

Bảng 4.15. Giá trị support của các nhãn khi đánh giá mô hình LA_Mul07 trên bộ dữ liệu UTL_DGA22

STT	DGA Botnet	Sup	STT	DGA Botnet	Sup	STT	DGA Botnet	Sup
1	bamital	2.037	27	matsnu	2.021	52	ramnit	1.986
2	banjori	2.048	28	monerodownloader	1.914	53	ranbyus_v1	1.985
3	bazarbackdoor	2.070	29	murofetweekly	2.040	54	ranbyus_v2	2.044
4	bazarbackdoor_v2	1.964	30	murofet_v1	1.955	55	reconyc	1.987
5	bazarbackdoor_v3	2.020	31	murofet_v2	1.955	56	rovnix	2.023
6	bedep	2.068	32	murofet_v3	1.977	57	shiotob	1.993
7	bigviktor	2.029	33	mydoom	1.986	58	simda	2.010
8	ccleaner	2.005	34	necurs	1.992	59	sisron	1.971
9	chinad	2.040	35	newgoz	1.977	60	sphinx	1.976
10	corebot	1.940	36	nymaim	1.974	61	suppobox_1	2.063
11	cryptolocker	1.981	37	nymaim2	1.967	62	suppobox_2	2.006
12	dircrypt	2.024	38	oderoor	2.236	63	suppobox_3	1.981
13	dnschanger	1.927	39	padcrypt	2.019	64	symmi	1.951
14	dyre	2.036	40	pandabanker	2.062	65	szribi	2.007
15	emotet	2.085	41	pitou	2.082	66	tempedreve	2.032
16	enviserv	1.967	42	pizd	1.971	67	tinba	1.966
17	fobber_v1	2.001	43	proslikefan	2.028	68	tinynuke	1.980
18	fobber_v2	2.016	44	pushdo	1.989	69	torpig	1.968
19	gozi_gpl	2.014	45	pykspa_ improved_noise	2.040	70	vawtrak_v1	1.954
20	gozi_luther	2.043	46	pykspa_ improved_useful	1.952	71	vawtrak_v2	2.002
21	gozi_nasa	2.001	47	pykspa_precursor	1.974	72	vawtrak_v3	1.998
22	gozi_rfc4343	2.068	48	qadars	1.968	73	vidro	1.983
23	infy	2.042	49	qakbot	1.990	74	virut	1.981
24	kraken_v1	1.918	50	qsnatch	2.077	75	wd	1.947
25	kraken_v2	1.801	51	ramdo	2.043	76	zloader	1.907
26	locky	1.965						

4.6. Kết luận Chương 4

Trong Chương 4, NCS trình bày kết quả nghiên cứu về các bộ dữ liệu cho phân lớp nhị phân và phân lớp đa lớp trong bài toán DGA Botnet. Trong đó, trình bày chi tiết các điểm hạn chế cần cải tiến của các bộ dữ liệu hiện có, sau đó đề xuất một bộ dữ liệu mới UTL_DGA22, được xây dựng dựa trên cơ sở kế thừa các thành quả trước đó, bổ sung những cải tiến, dữ liệu và thuộc tính mới.

Các đóng góp chính bao gồm:

- Đề xuất một bộ dữ liệu DGA_UTL22, bao gồm 76 họ DGA Botnet phổ biến hiện nay, mỗi họ gồm 20.000 mẫu tên miền. Các tên miền thể hiện dưới dạng nguyên bản, lưu trữ dưới dạng tệp tin CSV, ARFF và TXT.

- Đề xuất 02 nhóm các thuộc tính, bao gồm 36 thuộc tính thuộc nhóm Base-Features cho tên miền và các thuộc tính TF-IDF cho họ tên miền DGA Botnet. Các thuộc tính này được trích xuất và lưu trữ dưới dạng *CSV, *ARFF và được chia sẻ đi kèm với bộ dữ liệu. Các đánh giá thử nghiệm sử dụng bộ thuộc tính này với các thuật toán học máy cho kết quả tích cực. Điều này thể hiện rằng các thuộc tính đề xuất hoàn toàn phù hợp để làm đầu vào cho các giải pháp mới trong tương lai.

NCS cũng tiến hành các đánh giá trên bộ dữ liệu mới UTL_DGA22 với các thuật toán đề xuất trong luận án, bao gồm: NCM, học máy, VEA, HEA, LA_Bin07 và LA_Mul07. Kết quả cho thấy các thuật toán đề xuất đều phù hợp và có độ chính xác tương đồng như đánh giá trên các bộ dữ liệu trước đó.

NCS kỳ vọng UTL_DGA22 là cơ sở chung đáng tin cậy, được sử dụng rộng rãi cho phép các nhà khoa học đánh giá hiệu năng giữa các giải pháp đề xuất mới một cách thuận lợi, khách quan và dễ dàng đối sánh, tham chiếu.

Một phần kết quả nghiên cứu được trình bày tại Chương 4 được công bố tại [CT5] trong danh mục công trình của tác giả.

KẾT LUẬN VÀ KIẾN NGHỊ

Sau thời gian học tập và nghiên cứu tại Học viện Khoa học và Công nghệ, Viện Hàn lâm Khoa học và Công nghệ Việt Nam, NCS đã hoàn thành luận án "*Nghiên cứu cải tiến một số mô hình học máy và học sâu áp dụng cho bài toán phân loại DGA Botnet*", đạt được các kết quả chính như sau:

- Trình bày một cơ sở lý thuyết về DGA Botnet; bài toán phát hiện và phân loại DGA Botnet, khái quát các kỹ thuật, giải pháp và nghiên cứu liên quan. Đánh giá hiệu quả của hai hướng tiếp cận sử dụng thuật toán phân cụm mờ NCM, học máy với hai mô hình học kết hợp là VEA và HEA trong phát hiện DGA Botnet.

- Đề xuất hai mô hình học sâu mới là LA_Bin07 và LA_Mul07 áp dụng cho phát hiện và phân loại DGA Botnet. Các đánh giá cho thấy, hai mô hình mới đạt được độ chính xác cao trong phân lớp, đặc biệt là trong bài toán phân loại họ DGA Botnet.

- Đề xuất bộ dữ liệu UTL_DGA22 chuyên dùng cho đánh giá bài toán DGA Botnet. Đây là có thể coi là bộ dữ liệu mới, đầy đủ mã nguồn và tài liệu nhất về DGA Botnet tính đến thời điểm hiện tại.

Các kết quả nghiên cứu trên đã trả lời các câu hỏi nghiên cứu đặt ra, mang lại ý nghĩa thiết thực trong bài toán phát hiện và phân loại DGA Botnet.

- *Đối với câu hỏi 1*: Trong bài toán phát hiện DGA Botnet, các đánh giá cho thấy việc áp dụng thuật toán phân cụm mờ NCM để phát hiện DGA Botnet tuy có tốc độ nhanh hơn nhưng độ chính xác thấp hơn các mô hình học máy. Ở chiều ngược lại, các mô hình học máy có độ chính xác cao, với Precision cao nhất đạt 0,97 nhưng hạn chế là tốn kém nhiều thời gian huấn luyện mô hình. Mô hình học sâu LA_Bin07 được đề xuất đã nâng cao độ chính xác phân loại, đạt từ 0,98 đến 1,00 khi đánh giá trên từng bộ dữ liệu khác nhau.

- *Đối với câu hỏi 2*: Mạng LSTM truyền thống có thể được cải tiến để nâng cao hiệu quả phát hiện và phân loại DGA Botnet. NCS đã đề xuất hai mô hình học sâu mới là LA_Bin07 và LA_Mul07 giải quyết được vấn đề trên. Trong đó trọng tâm là mô hình LA_Mul07 đã giải quyết bài toán phân loại DGA Botnet với độ chính xác được cải thiện rất đáng kể so với các giải pháp trước đó. Mô hình đạt độ chính xác thấp nhất là 0,86 và cao nhất là 1,00 khi đánh giá trên 03 bộ dữ liệu chuyên dụng.

Giải pháp học sâu cũng có ưu điểm là thời gian huấn luyện nhanh hơn rất nhiều so với học máy, bởi tận dụng được năng lực tính toán của GPU.

- *Đối với câu hỏi 3*: Các bộ dữ liệu về DGA Botnet trước đó có những hạn chế về khả năng áp dụng cho từng bài toán, độ chính xác, số lượng và sự cân bằng mẫu, chưa có các họ DGA Botnet mới, thiếu tài liệu, thuộc tính đề xuất. NCS đã đề xuất bộ dữ liệu mới UTL_DGA22 chuyên dùng cho đánh giá bài toán DGA Botnet, được kế thừa đầy đủ các ưu điểm của những bộ dữ liệu trước đó, đồng thời bổ sung các mẫu dữ liệu, thuộc tính và mô tả đầy đủ. Tính từ thời điểm công bố bài báo vào đầu năm 2023, NCS đã nhận được 06 đề nghị truy cập để phục vụ nghiên cứu từ các nhà khoa học ở ngoài nước. NCS kỳ vọng UTL_DGA22 sẽ trở thành một bộ dữ liệu tiêu chuẩn được sử dụng rộng rãi bởi các nhà khoa học, chuyên gia an ninh mạng trong thời gian tới cho công tác đánh giá của họ.

Các kết quả nghiên cứu của NCS được công bố tại 04 bài báo trên tạp chí khoa học chuyên ngành uy tín thuộc danh mục ISI/Scopus, 02 báo cáo tại hội thảo khoa học chuyên ngành quốc gia, quốc tế uy tín, được thể hiện tại "Danh mục công trình của tác giả" và "Phụ lục" đính kèm.

Bên cạnh những kết quả đạt được, NCS đặt ra một số hướng phát triển trong thời gian tới để tiếp tục cải tiến mô hình. Cụ thể, cải tiến mô hình LA_Mul07 để nâng cao độ chính xác so với mức 0,86 hiện tại trên các bộ dữ liệu có nhiều hơn 50 nhãn. Xây dựng cơ chế phát hiện riêng cho các họ DGA Botnet có sự tương đồng cao hoặc là các phiên bản kế thừa của nhau. Về hướng ứng dụng, NCS dự kiến kế thừa mô hình LA_Bin07 và LA_Mul07, tích hợp thành một module để phát hiện và phân loại DGA Botnet dựa trên tên miền. Module này có thể được tích hợp vào các giải pháp bảo vệ an ninh mạng tiên tiến, hiện đại như Tường lửa thế hệ mới hoặc Giải pháp an ninh hợp nhất.

DANH MỤC CÁC CÔNG TRÌNH CỦA TÁC GIẢ

[CT1] Can, N.V., Tu, D. N., **Tuan, T. A.**, Long, H. V., Son, L. H., & Son, N. T. K. (2020). A new method to classify malicious domain name using Neutrosophic sets in DGA Botnet detection. *Journal of Intelligent & Fuzzy Systems*, *38*(4), 4223-4236. ***(ISI Q2, IF = 1.737)***

[CT2] **Tuan, T. A.**, Long, H. V., Son, L. H., Kumar, R., Priyadarshini, I., & Son, N. T. K. (2020). Performance evaluation of Botnet DDoS attack detection using machine learning. *Evolutionary Intelligence*, *13*(2), 283-294. ***(SCOPUS, ESCI Q2)***

[CT3] **Tuan, T. A.**, Anh, N. V., & Long, H. V. (2021, December). Assessment of Machine Learning Models in Detecting DGA Botnet in Characteristics by TF-IDF. In *2021 IEEE International Conference on Machine Learning and Applied Network Technologies (ICMLANT)* (pp. 1-5). IEEE. ***(SCOPUS)***

[CT4] **Tuan, T. A.**, Long, H. V., & Taniar, D. (2022). On Detecting and Classifying DGA Botnets and their Families. *Computers & Security*, *113*, 102549. ***(ISI Q1, IF = 5.105)***

[CT5] **Tuan, T. A.,** Anh, N. V., Luong, T. T., & Long, H. V. (2023). UTL_DGA22-a dataset for DGA botnet detection and classification. *Computer Networks*, 221, 109508. ***(ISI Q1, IF = 5.493)***

[CT6] **Tống Anh Tuấn**, Nguyễn Ngọc Cương, Nguyễn Việt Anh, Hoàng Việt Long. (2022). Đề xuất ứng dụng giải pháp phân lớp nhị phân trong bài toán DGA Botnet cho phát hiện địa chỉ IP độc hại. Hội thảo Quốc gia lần thứ XXV *"Một số vấn đề chọn lọc của Công nghệ thông tin và Truyền thông*" (VNICT 2022), trang 55-60.

TÀI LIỆU THAM KHẢO

[1] X. Li, C., Jiang, W., & Zou, "Botnet: Survey and case study. In innovative computing, information and control (icicic)," pp. 1187–1187, 2009.

[2] C. Kolias, G. Kambourakis, A. Stavrou, and J. Voas, "DDoS in the IoT: Mirai and other botnets," *Computer (Long. Beach. Calif).*, vol. 50, no. 7, pp. 80–84, 2017, doi: 10.1109/MC.2017.201.

[3] I. Ghafir, M. Hammoudeh, and V. Prenosil, "Botnet Command and Control Traffic Detection Challenges A Correlation based Solution," pp. 1–5, 2016, doi: 10.15224/978-1-63248-113-9-01.

[4] R. Kishore Kumar, G. Poonkuzhali, and P. Sudhakar, "Comparative study on email spam classifier using data mining techniques," *Lect. Notes Eng. Comput. Sci.*, vol. 2195, pp. 539–544, 2012.

[5] M. Roopak, G. Y. Tian, and J. Chambers, "Multi-objective-based feature selection for DDoS attack detection in IoT networks," *IET Networks*, vol. 9, no. 3, pp. 120–127, 2020, doi: 10.1049/iet-net.2018.5206.

[6] A. Karim, R. Bin Salleh, M. Shiraz, S. A. A. Shah, I. Awan, and N. B. Anuar, "Botnet detection techniques: review, future trends, and issues," *J. Zhejiang Univ. Sci. C*, vol. 15, no. 11, pp. 943–983, 2014, doi: 10.1631/jzus.C1300242.

[7] K. Alieyan, A. Almomani, A. Manasrah, and M. M. Kadhum, "A survey of botnet detection based on DNS," *Neural Comput. Appl.*, vol. 28, no. 7, pp. 1541–1558, 2017, doi: 10.1007/s00521-015-2128-0.

[8] J. Kwon, J. Lee, H. Lee, and A. Perrig, "PsyBoG: A scalable botnet detection method for large-scale DNS traffic," *Comput. Networks*, vol. 97, pp. 48–73, 2016, doi: 10.1016/j.comnet.2015.12.008.

[9] T. S. Wang, H. T. Lin, W. T. Cheng, and C. Y. Chen, "DBod: Clustering and detecting DGA-based botnets using DNS traffic analysis," *Comput. Secur.*, vol. 64, pp. 1–15, 2017, doi: 10.1016/j.cose.2016.10.001.

[10] F. Bisio, S. Saeli, P. Lombardo, D. Bernardi, A. Perotti, and D. Massa, "Real-time behavioral DGA detection through machine learning," *Proc. - Int. Carnahan Conf. Secur. Technol.*, vol. 2017-Octob, pp. 1–6, 2017, doi: 10.1109/CCST.2017.8167790.

[11] H. T. Nguyen, Q. D. Ngo, and V. H. Le, "A novel graph-based approach for IoT botnet detection," *Int. J. Inf. Secur.*, vol. 19, no. 5, pp. 567–577, 2020, doi: 10.1007/s10207-019-00475-6.

[12] H. Mac, D. Tran, V. Tong, L. G. Nguyen, and H. A. Tran, "DGA botnet detection using supervised learning methods," *ACM Int. Conf. Proceeding Ser.*, vol. 2017-Decem, pp. 211–218, 2017, doi: 10.1145/3155133.3155166.

[13] R. U. Khan, X. Zhang, R. Kumar, A. Sharif, N. A. Golilarz, and M. Alazab, "An adaptive multi-layer botnet detection technique using machine learning classifiers," *Appl. Sci.*, vol. 9, no. 11, 2019, doi: 10.3390/app9112375.

[14] X. D. Hoang and X. H. Vu, "An improved model for detecting DGA botnets using random forest algorithm," *Inf. Secur. J.*, vol. 31, no. 4, pp. 441–450, 2022, doi: 10.1080/19393555.2021.1934198.

[15] D. Tran, H. Mac, V. Tong, H. A. Tran, and L. G. Nguyen, "A LSTM based framework for handling multiclass imbalance in DGA botnet detection," *Neurocomputing*, vol. 275, pp. 2401–2413, 2018, doi: 10.1016/j.neucom.2017.11.018.

[16] R. R. Curtin, A. B. Gardner, S. Grzonkowski, A. Kleymenov, and A. Mosquera, "Detecting DGA domains with recurrent neural networks and side information," *ACM Int. Conf. Proceeding Ser.*, 2019, doi: 10.1145/3339252.3339258.

[17] R. Vinayakumar, M. Alazab, S. Srinivasan, Q. V. Pham, S. K. Padannayil, and K. Simran, "A Visualized Botnet Detection System Based Deep Learning for the Internet of Things Networks of Smart Cities," *IEEE Trans. Ind. Appl.*, vol. 56, no. 4, pp. 4436–4456, 2020, doi: 10.1109/TIA.2020.2971952.

[18] M. Zago, M. Gil Pérez, and G. Martínez Pérez, "UMUDGA: A dataset for profiling algorithmically generated domain names in botnet detection," *Data Br.*, vol. 30, p. 105400, 2020, doi: 10.1016/j.dib.2020.105400.

[19] H. Suryotrisongko, "Computable CTI: Sharing AI Model for the Next Level of Actionable Cyber Threat Intelligence. Case Study of Botnet Detection," *IEEE Open Access J.*, 2020.

[20] A. Abakumov, "DGA Repository," *GitHub*, 2016. https://github.com/andrewaeva/DGA (accessed Jun. 08, 2021).

[21] M. Zago, M. Gil Pérez, and G. Martínez Pérez, "UMUDGA: A dataset for profiling DGA-based botnet," *Comput. Secur.*, vol. 92, 2020, doi: 10.1016/j.cose.2020.101719.

[22] F. FKIE, "DGArchive - Fraunhofer FKIE," 2020. https://dgarchive.caad.fkie.fraunhofer.de/welcome/ (accessed Jun. 08, 2021).

[23] OSINT, "Feeds from Bambenek Consulting," 2021. https://osint.bambenekconsulting.com/feeds/ (accessed Mar. 15, 2021).

[24] 360NetLab, "DGA - Netlab OpenData Project," *Qihoo 360 Technology*, 2022. https://data.netlab.360.com/dga/ (accessed Mar. 09, 2021).

[25] J. Bader, "Domain_Generation_Algorithms Repository," *GitHub*, 2018. https://github.com/baderj/domain_generation_algorithms (accessed Aug. 16, 2021).

[26] T. Holz, "A short visit to the bot zoo [malicious bots software]," *IEEE Secur. Priv.*, vol. 3, no. 3, pp. 76–79, 2005.

[27] N. Provos and T. Holz, "Virtual honeypots: from botnet tracking to intrusion detection," p. 440, 2007, [Online]. Available: http://books.google.com/books?id=QuHnPgAACAAJ&pgis=1

[28] A. Kurniawan and A. Fitriansyah, "A Literature Review of Historical and Detection Analysis of Botnets Forensics," *Int. J. Comput. Commun. Eng.*, vol. 7, no. 4, pp. 128–135, 2018, doi: 10.17706/ijcce.2018.7.4.128-135.

[29] A. C. Atluri and V. Tran, "Botnets threat analysis and detection," *Inf. Secur. Pract. Emerg. Threat. Perspect.*, pp. 7–28, 2017, doi: 10.1007/978-3-319-48947-6_2.

[30] C. Li, W. Jiang, and X. Zou, "Botnet: Survey and case study," *2009 4th Int. Conf. Innov. Comput. Inf. Control. ICICIC 2009*, pp. 1184–1187, 2009, doi: 10.1109/ICICIC.2009.127.

[31] N. Manzoor, M. Saleem, and M. Aslam, "Role of Machine Learning Techniques in Digital Forensic Investigation of Botnet Attacks," *Int. J. Manag.*, 2021.

[32] C. A. Schiller *et al.*, "Botnets: The Killer Web Applications," *Botnets Kill. Web Appl.*, pp. 1–464, 2007, doi: 10.1016/B978-1-59749-135-8.X5000-8.

[33] K. Vengatesan, A. Kumar, M. Parthibhan, A. Singhal, and R. Rajesh, "Analysis of Mirai Botnet Malware Issues and Its Prediction Methods in Internet of Things," *Lect. Notes Data Eng. Commun. Technol.*, vol. 31, pp. 120–126, 2020, doi: 10.1007/978-

3-030-24643-3_13.

[34] J. Nazario, “Bot and Botnet Taxonomy,” *Comput. Secur. Institute. Comput. Secur. Inst. Secur. Exch.*, p. 52, 2008, [Online]. Available: https://www.monkey.org/~jose/presentations/csisx2008.d/CSI SX 2008 Nazario Botnet Taxonomy.pdf

[35] N. V. Patil, C. Rama Krishna, and K. Kumar, “Distributed frameworks for detecting distributed denial of service attacks: A comprehensive review, challenges and future directions,” *Concurr. Comput.* , 2021, doi: 10.1002/cpe.6197.

[36] L. Barry, D., & Bol, “Who’s Hacking Who?,” 2016.

[37] D. S. & S. S. A. B. Tickle, E. Ahmed, S. M. Bhaskar, G. Mohay, S. Panichprecha, S. V. Raghavan, B. Ravindran, “Chapter 2: Background,” in *An Investigation into the Detection and Mitigation of Denial of Service (DoS) Attacks*, 2011. doi: 10.1007/978-81-322-0277-6.

[38] T. A. Tuan, N. V. Anh, T. T. Luong, and H. V. Long, “UTL_DGA22 - a dataset for DGA botnet detection and classification,” *Comput. Networks*, vol. 221, 2023, doi: 10.1016/j.comnet.2022.109508.

[39] C. Schiller *et al.*, “Botnets: The Killer Web Applications,” *Syngress Publ.*, pp. 29–75, 2007.

[40] E. B. Beigi, H. H. Jazi, N. Stakhanova, and A. A. Ghorbani, “Towards effective feature selection in machine learning-based botnet detection approaches,” *2014 IEEE Conf. Commun. Netw. Secur. CNS 2014*, pp. 247–255, 2014, doi: 10.1109/CNS.2014.6997492.

[41] S. Marchal, J. Francois, R. State, and T. Engel, “Phish storm: Detecting phishing with streaming analytics,” *IEEE Trans. Netw. Serv. Manag.*, vol. 11, no. 4, pp. 458–471, 2014, doi: 10.1109/TNSM.2014.2377295.

[42] S. Chowdhury *et al.*, “Botnet detection using graph-based feature clustering,” *J. Big Data*, vol. 4, no. 1, 2017, doi: 10.1186/s40537-017-0074-7.

[43] O. Yavanoglu and M. Aydos, “A review on cyber security datasets for machine learning algorithms,” *Proc. - 2017 IEEE Int. Conf. Big Data, Big Data 2017*, vol. 2018-Janua, pp. 2186–2193, 2017, doi: 10.1109/BigData.2017.8258167.

[44] J. Wang and I. C. Paschalidis, “Botnet Detection Based on Anomaly and Community Detection,” *IEEE Trans. Control Netw. Syst.*, vol. 4, no. 2, pp. 392–404, 2017, doi: 10.1109/TCNS.2016.2532804.

[45] Y. M. P. Pa, S. Suzuki, K. Yoshioka, T. Matsumoto, T. Kasama, and C. Rossow, “IoTPOT: A novel honeypot for revealing current IoT threats,” *J. Inf. Process.*, vol. 24, no. 3, pp. 522–533, 2016, doi: 10.2197/ipsjjip.24.522.

[46] “VirusShare.com - Because Sharing is Caring.” https://virusshare.com/ (accessed Mar. 15, 2021).

[47] Alexa Internet Inc., “Alexa top 1 million sites,” *Kaggle Datasets*, 2019. http://s3.amazonaws.com/alexa-static/top-1m.csv.zip (accessed Mar. 10, 2021).

[48] H. Suryotrisongko and Y. Musashi, “Evaluating hybrid quantum-classical deep learning for cybersecurity botnet DGA detection,” *Procedia Comput. Sci.*, vol. 197, pp. 223–229, 2021, doi: 10.1016/j.procs.2021.12.135.

[49] D. Zhao, H. Li, X. Sun, and Y. Tang, “Detecting DGA-based botnets through effective phonics-based features,” *Futur. Gener. Comput. Syst.*, vol. 143, pp. 105–117, 2023,

doi: 10.1016/j.future.2023.01.027.

[50] M. Alauthman, N. Aslam, M. Al-kasassbeh, S. Khan, A. Al-Qerem, and K. K. Raymond Choo, "An efficient reinforcement learning-based Botnet detection approach," *J. Netw. Comput. Appl.*, vol. 150, p. 102479, 2020, doi: 10.1016/j.jnca.2019.102479.

[51] S. Saad *et al.*, "Detecting P2P botnets through network behavior analysis and machine learning," *2011 9th Annu. Int. Conf. Privacy, Secur. Trust. PST 2011*, pp. 174–180, 2011, doi: 10.1109/PST.2011.5971980.

[52] B. Rahbarinia, R. Perdisci, A. Lanzi, and K. Li, "PeerRush: Mining for unwanted P2P traffic," *Lect. Notes Comput. Sci. (including Subser. Lect. Notes Artif. Intell. Lect. Notes Bioinformatics)*, vol. 7967 LNCS, pp. 62–82, 2013, doi: 10.1007/978-3-642-39235-1_4.

[53] A. Shiravi, H. Shiravi, M. Tavallaee, and A. A. Ghorbani, "Toward developing a systematic approach to generate benchmark datasets for intrusion detection," *Comput. Secur.*, vol. 31, no. 3, pp. 357–374, 2012, doi: 10.1016/j.cose.2011.12.012.

[54] X. Liu and J. Liu, "DGA botnet detection method based on capsule network and k-means routing," *Neural Comput. Appl.*, vol. 34, no. 11, pp. 8803–8821, 2022, doi: 10.1007/s00521-022-06904-3.

[55] S. Broumi *et al.*, "Neutrosophic Sets: An Overview," *New Trends Neutrosophic Theory Appl.*, vol. II, p. 32, 2018, [Online]. Available: http://fs.gallup.unm.edu/nss.

[56] R. Şahin, "Neutrosophic hierarchical clustering algoritms," *Neutrosophic Sets Syst.*, vol. 2, no. June, pp. 18–24, 2014.

[57] Y. Guo and A. Sengur, "NCM: Neutrosophic c-means clustering algorithm," *Pattern Recognit.*, vol. 48, no. 8, pp. 2710–2724, 2015, doi: 10.1016/j.patcog.2015.02.018.

[58] J. C. Bezdek, R. Ehrlich, and W. Full, "FCM: The fuzzy c-means clustering algorithm," *Comput. Geosci.*, vol. 10, no. 2–3, pp. 191–203, 1984, doi: 10.1016/0098-3004(84)90020-7.

[59] N. Davuth and S. R. Kim, "Classification of malicious domain names using support vector machine and bi-gram method," *Int. J. Secur. its Appl.*, vol. 7, no. 1, pp. 51–58, 2013.

[60] Jayadeva, R. Khemchandani, and S. Chandra, "Twin support vector machines for pattern classification," *IEEE Trans. Pattern Anal. Mach. Intell.*, vol. 29, no. 5, pp. 905–910, 2007, doi: 10.1109/TPAMI.2007.1068.

[61] C. F. Lin and S. De Wang, "Fuzzy support vector machines," *IEEE Trans. Neural Networks*, vol. 13, no. 2, pp. 464–471, 2002, doi: 10.1109/72.991432.

[62] Y. Freund and R. E. Schapire, "Experiments with a New Boosting Algorithm," *Proc. 13th Int. Conf. Mach. Learn.*, pp. 148–156, 1996, doi: 10.1.1.133.1040.

[63] K. N. S. S. V Prasad, S. K. Saritha, and D. Saxena, "A Survey Paper on Concept Mining in Text Documents," *Int. J. Comput. Appl.*, vol. 166, no. 11, pp. 7–10, 2017, doi: 10.5120/ijca2017914143.

[64] S. Hochreiter, "Lstm Can Solve Hard Long Time Lag Problems," *Adv. Neural Inf. Process. Syst.*, 1996.

[65] B. Gao and L. Pavel, "On the properties of the softmax function with application in game theory and reinforcement learning," *arXiv*, 2017.

[66] J. Devlin, M. W. Chang, K. Lee, and K. Toutanova, "BERT: Pre-training of deep

bidirectional transformers for language understanding," *arXiv*, 2018.

[67] A. Vaswani *et al.*, "Attention is all you need," *Adv. Neural Inf. Process. Syst.*, vol. 2017-Decem, pp. 5999–6009, 2017.

[68] M. Antonakakis *et al.*, "From throw-away traffic to bots: Detecting the rise of DGA-based malware," *Proc. 21st USENIX Secur. Symp.*, pp. 491–506, 2012.

[69] J. R. Quinlan, "Data mining tools See 5 and C5. 0.," 2004.

[70] J. Woodbridge, H. S. Anderson, A. Ahuja, and D. Grant, "Predicting Domain Generation Algorithms with Long Short-Term Memory Networks," 2016, [Online]. Available: http://arxiv.org/abs/1611.00791

[71] Y.-L. Zhou, Q.-S. Li, Q. Miao, and K. Yim, "DGA-Based Botnet Detection Using DNS Traffic," *J. Internet Serv. Inf. ...*, vol. 3, no. 11, pp. 116–123, 2013, [Online]. Available: http://isyou.info/jisis/vol3/no34/jisis-2013-vol3-no34-11.pdf

[72] L. Bilge, S. Sen, D. Balzarotti, E. Kirda, and C. Kruegel, "EXPOSURE: A passive DNS analysis service to detect and report malicious domains," *ACM Trans. Inf. Syst. Secur.*, vol. 16, no. 4, 2014, doi: 10.1145/2584679.

[73] T. D. Nguyen, T. D. Cao, and L. G. Nguyen, "DGA botnet detection using collaborative filtering and density-based clustering," *ACM Int. Conf. Proceeding Ser.*, vol. 03-04-Dece, pp. 203–209, 2015, doi: 10.1145/2833258.2833310.

[74] R. Sharifnya and M. Abadi, "DFBotKiller: Domain-flux botnet detection based on the history of group activities and failures in DNS traffic," *Digit. Investig.*, vol. 12, pp. 15–26, 2015, doi: 10.1016/j.diin.2014.11.001.

[75] G. Bottazzi and G. F. Italiano, "Fast mining of large-scale logs for Botnet detection: A field study," *Proc. - 15th IEEE Int. Conf. Comput. Inf. Technol. CIT 2015, 14th IEEE Int. Conf. Ubiquitous Comput. Commun. IUCC 2015, 13th IEEE Int. Conf. Dependable, Auton. Se*, pp. 1989–1996, 2015, doi: 10.1109/CIT/IUCC/DASC/PICOM.2015.295.

[76] M. J. Erquiaga, C. Catania, and S. García, "Detecting DGA malware traffic through behavioral models," *2016 IEEE Bienn. Congr. Argentina, ARGENCON 2016*, 2016, doi: 10.1109/ARGENCON.2016.7585238.

[77] S. Garcia, "Stratoshpere Project," *Https://Stratosphereips.Org*, 2015. https://stratosphereips.org

[78] M. I. Ashiq, P. Bhowmick, M. S. Hossain, and H. S. Narman, "Domain Flux-based DGA Botnet Detection Using Feedforward Neural Network," *Proc. - IEEE Mil. Commun. Conf. MILCOM*, vol. 2019-Novem, pp. 1–6, 2019, doi: 10.1109/MILCOM47813.2019.9020730.

[79] Y. Fu *et al.*, "Stealthy Domain Generation Algorithms," *IEEE Trans. Inf. Forensics Secur.*, vol. 12, no. 6, pp. 1430–1443, 2017, doi: 10.1109/TIFS.2017.2668361.

[80] K. Alieyan, A. Almomani, M. Anbar, M. Alauthman, R. Abdullah, and B. B. Gupta, "DNS rule-based schema to botnet detection," *Enterp. Inf. Syst.*, vol. 00, no. 00, pp. 1–20, 2019, doi: 10.1080/17517575.2019.1644673.

[81] N. Van Can, D. N. Tu, T. A. Tuan, H. V. Long, L. H. Son, and N. T. K. Son, "A new method to classify malicious domain name using neutrosophic sets in DGA botnet detection," *J. Intell. Fuzzy Syst.*, vol. 38, no. 4, pp. 4223–4236, 2020, doi: 10.3233/jifs-190681.

[82] X. Yun, J. Huang, Y. Wang, T. Zang, Y. Zhou, and Y. Zhang, "Khaos: An Adversarial

Neural Network DGA with High Anti-Detection Ability," *IEEE Trans. Inf. Forensics Secur.*, vol. 15, no. c, pp. 2225–2240, 2020, doi: 10.1109/TIFS.2019.2960647.

[83] H. S. Anderson, J. Woodbridge, and B. Filar, "DeepDGA: Adversarially-tuned domain generation and detection," *AISec 2016 - Proc. 2016 ACM Work. Artif. Intell. Secur. co-located with CCS 2016*, pp. 13–21, 2016, doi: 10.1145/2996758.2996767.

[84] R. Rajalakshmi, S. Ramraj, and R. Ramesh Kannan, "Transfer learning approach for identification of malicious domain names," *Commun. Comput. Inf. Sci.*, vol. 969, pp. 656–666, 2019, doi: 10.1007/978-981-13-5826-5_51.

[85] X. Pei, S. Tian, L. Yu, H. Wang, and Y. Peng, "A Two-Stream Network Based on Capsule Networks and Sliced Recurrent Neural Networks for DGA Botnet Detection," *J. Netw. Syst. Manag.*, vol. 28, no. 4, pp. 1694–1721, 2020, doi: 10.1007/s10922-020-09554-9.

[86] S. García, M. Grill, J. Stiborek, and A. Zunino, "An empirical comparison of botnet detection methods," *Comput. Secur.*, vol. 45, pp. 100–123, 2014, doi: 10.1016/j.cose.2014.05.011.

[87] G. Maciá-Fernández, J. Camacho, R. Magán-Carrión, P. García-Teodoro, and R. Therón, "UGR'16: A new dataset for the evaluation of cyclostationarity-based network IDSs," *Comput. Secur.*, vol. 73, pp. 411–424, 2018, doi: 10.1016/j.cose.2017.11.004.

[88] A. Venturi, G. Apruzzese, M. Andreolini, M. Colajanni, and M. Marchetti, "DReLAB - Deep REinforcement Learning Adversarial Botnet: A benchmark dataset for adversarial attacks against botnet Intrusion Detection Systems," *Data Br.*, vol. 34, 2021, doi: 10.1016/j.dib.2020.106631.

[89] N. Moustafa and J. Slay, "UNSW-NB15: A comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set)," *2015 Mil. Commun. Inf. Syst. Conf. MilCIS 2015 - Proc.*, 2015, doi: 10.1109/MilCIS.2015.7348942.

[90] D. Zhao *et al.*, "Botnet detection based on traffic behavior analysis and flow intervals," *Comput. Secur.*, vol. 39, no. PARTA, pp. 2–16, 2013, doi: 10.1016/j.cose.2013.04.007.

[91] S. Garcia, "Malware Capture Facility Project," 2013. https://mcfp.felk.cvut.cz/ (accessed Jul. 25, 2022).

[92] H. Suryotrisongko, "Botnet DGA Dataset," *IEEE Dataport*, 2020. https://ieee-dataport.org/open-access/botnet-dga-dataset (accessed Jun. 08, 2021).

[93] J. Spooren, D. Preuveneers, L. Desmet, P. Janssen, and W. Joosen, "Detection of algorithmically generated domain names used by botnets: A dual arms race," *Proc. ACM Symp. Appl. Comput.*, vol. Part F1477, pp. 1916–1923, 2019, doi: 10.1145/3297280.3297467.

[94] N. Brown, "GNU GPL 2.0 and 3.0: obligations to include license text, and provide source code," *Int. Free Open Source Softw. Law Rev.*, vol. 2, no. 1, 2010, doi: 10.5033/ifosslr.v2i1.31.

[95] J. Bader, "Johannes Bader's Blog." https://johannesbader.ch/blog/ (accessed Aug. 16, 2021).

[96] Majestic, "Majestic Million - Majestic," *Majestic Website*, 2019. https://majestic.com/reports/majestic-million

[97] L. Lessig, "Creative Commons - attribution 3.0 unported license," 2001.

[98] "Tinba's DGA Adds Other Top Level Domains," *Johannes Bader's Blog*, 2015. https://bin.re/blog/new-top-level-domains-for-tinbas-dga/ (accessed Oct. 11, 2021).