

การตรวจจับการบุกรุกระบบเครือข่ายด้วยวิธีการเรียนรู้แบบไม่มีผู้สอน

NETWORK INTRUSION DETECTION USING AN UNSUPERVISED
LEARNING APPROACH



การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและการวิเคราะห์
ศูนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง
คณะวิทยาศาสตร์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ. 2566

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้ในเพื่อการศึกษาเท่านั้น มิอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

NETWORK INTRUSION DETECTION USING AN UNSUPERVISED
LEARNING APPROACH



AN INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE
IN DATA SCIENCE AND ANALYTICS
KMITL DIGITAL ANALYTICS AND INTELLIGENCE CENTER SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2023

KMITL-2023-SC-M-017-026

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2023

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การตรวจจัดการบุงรุกรบบเครือข่ายด้วยวิธีการเรียนรู้แบบไม่มีผู้สอน
ชื่อนักศึกษา	นายวิทยา ทศพิทักษ์กุล
รหัสประจำตัว	64605102
ปริญญา	วิทยาศาสตรมหาบัณฑิต (วิทยาการข้อมูลและการวิเคราะห์)
พ.ศ.	ศุนย์วิเคราะห์ข้อมูลดิจิทัลอัจฉริยะพระจอมเกล้าลาดกระบัง 2566
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	รองศาสตราจารย์ ดร.ละออ บุญเกษม

บทคัดย่อ

การค้นคว้าอิสระนี้มีวัตถุประสงค์เพื่อศึกษาวิธีการจำแนกการบุงรุกรบบเครือข่ายโดยการใช้การเรียนรู้แบบไม่มีผู้สอน ซึ่งในการศึกษานี้จะใช้วิธีการรู้เชิงลึกประเภทตัวเข้ารหัสอัตโนมัติมาประยุกต์ใช้ในการจำแนกผ่านการใช้ค่าการสูญเสียการสร้างใหม่ โดยที่ชุดข้อมูลที่ใช้ในการศึกษาเป็นชุดข้อมูลที่ได้จากฐานข้อมูล UNSW-NB15 ซึ่งเป็นฐานข้อมูลที่มีความนิยมจากผู้ศึกษาด้านระบบตรวจจัดการบุงรุกร และสุดท้ายจะนำตัวแบบที่ได้มาวัดประสิทธิภาพโดยใช้ ความแม่นยำ ความเที่ยง ค่าเรียกคืน และคะแนนเอฟ

จากการทดลองพบว่าตัวเข้ารหัสอัตโนมัติมีความสามารถในการจำแนกข้อมูลการบุงรุกรจากฐานข้อมูล UNSW-NB15 ได้ โดยได้ค่าความแม่นยำสูงถึง 82% และจะได้ค่าความแม่นยำสูงขึ้นไปถึง 92% สำหรับชุดข้อมูลที่ไม่มีการบุงรุกรประเภท Fuzzers Reconnaissance และ Shellcode ถึงแม้ว่าในการทดสอบจะพบว่าตัวแบบจะมีความสามารถในการจำแนกตกลงถ้าชุดข้อมูลที่ใช้สำหรับฝึกสอนมีอัตราส่วนของข้อมูลประเภทการบุงรุกรมากขึ้น แต่เนื่องจากในระบบจริง อัตราส่วนข้อมูลปกติจะมีมากกว่าข้อมูลบุงรุกร ทำให้การเรียนรู้แบบไม่มีผู้สอนสามารถทำให้ต้นทุนในการสร้างตัวแบบสำหรับตรวจจัดการบุงรุกรระบบเครือข่ายลดลง และมีโอกาสถูกนำไปใช้ในระบบต่าง ๆ มากขึ้น

คำสำคัญ : การตรวจจัดการบุงรุกรบบเครือข่าย การเรียนรู้แบบไม่มีผู้สอน ชุดข้อมูล UNSW-NB15 ตัวเข้ารหัสอัตโนมัติ

Independent Study Title	Network Intrusion Detection Using an Unsupervised Learning Approach
Student Name	Mr. Witaya Tospitakkul
Student ID	64605102
Degree	Master of Science (Data Science and Analytics) KMITL-Digital Analytics and Intelligence Center
Year	2023
Independent Study Advisor	Assoc.Prof.Dr. Laor Boongasame

Abstract

The purpose of this independent study is to study the methodology of network intrusion detection using an unsupervised learning approach. In this study, a deep learning approach called autoencoder will be applied for intrusion detection by utilizing reconstruction error values. The dataset used in this study was obtained from the UNSW-NB15 database, which is popular among researchers in the field of intrusion detection systems. Finally, the performance of the model will be evaluated using accuracy, precision, recall, and F1-score metrics.

From the experiments, the findings of the study indicate that the autoencoder model can classify intrusion data from the UNSW-NB15 database with a high accuracy up to 82% and up to 92% for datasets without intrusions of Fuzzers, Reconnaissance, and Shellcode types. However, it also revealed that model's classification performance decreases when the training dataset contains a higher proportion of intrusion data, Nevertheless, in the real-world systems, the proportion of normal data is typically higher than that of intrusion data. This allows unsupervised learning to significantly reduce the cost of building intrusion detection models and increases their potential for deployment in various systems.

Keywords : Network Intrusion Detection, Unsupervised Learning, UNSW-NB15 Dataset, Autoencoder

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กิตติกรรมประกาศ

การค้นคว้าอิสระฉบับนี้สำเร็จลงได้ด้วยความช่วยเหลือ ความกรุณาของรศ.ดร.ละออ บุญเกษม อาจารย์ที่
ปรึกษาการค้นคว้าอิสระ ผู้ซึ่งกรุณาให้ความรู้ คำแนะนำ และคำปรึกษา ตลอดจนถึงช่วยตรวจทาน
แก้ไขปรับปรุงข้อบกพร่องต่าง ๆ จนการศึกษาครั้งนี้สำเร็จเสร็จสิ้นลุล่วงด้วยดี ผู้เขียนขอขอบพระคุณ
เป็นอย่างสูงไว้ ณ โอกาสนี้

ขอขอบพระคุณหัวหน้างานและเพื่อนร่วมงานทุกท่าน ที่คอยให้ความช่วยเหลือ ความสะดวก
และให้กำลังใจด้วยดีเสมอมา รวมไปถึงอาจารย์และเพื่อน ๆ สาขาวิทยาการข้อมูลและการวิเคราะห์
ทุกท่านที่ให้ความรู้และคอยช่วยเหลืออยู่เสมอ และสุดท้ายขอกราบขอบพระคุณมารดาของผู้เขียนที่
เข้าใจและคอยให้กำลังใจในการศึกษาอยู่เสมอ

ท้ายสุดนี้หากมีข้อผิดพลาดประการใด ผู้เขียนต้องขออภัยเป็นอย่างสูงในความผิดพลาดและ
ผู้เขียนหวังว่าการค้นคว้าอิสระฉบับนี้ จะมีประโยชน์สำหรับผู้สนใจเพื่อใช้เป็นแนวทางในการศึกษา
การตรวจจัดการบุกรุกระบบเครือข่ายในวิธีและแนวทางอื่น ๆ ต่อไป

นายวิทยา ทศพิทักษ์กุล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ก
บทคัดย่อภาษาอังกฤษ	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ฉ
สารบัญรูป	ช
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย	2
1.3 ขอบเขตของงานวิจัย	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ	2
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	3
2.1 ระบบตรวจจับการบุกรุกเครือข่าย (Network Intrusion Detection System)	3
2.1.1 ประเภทของการตรวจจับการบุกรุก	3
2.1.2 การทำงานของระบบตรวจจับการบุกรุก	4
2.2 การวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis หรือ PCA)	7
2.3 โครงข่ายประสาทเทียม (Artificial Neural Network)	8
2.3.1 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feed-Forward Neural Network)	8
2.3.2 ฟังก์ชันกระตุ้น (Activation Function)	9
2.3.3 ฟังก์ชันต้นทุน (Cost Function หรือ Loss Function)	10
2.3.4 การหาค่าที่เหมาะสมที่สุด (Optimization)	11
2.3.5 การแพร่กระจายย้อนกลับ (Backpropagation)	13
2.4 ตัวเข้ารหัสอัตโนมัติ (Autoencoder)	15
2.5 งานวิจัยที่เกี่ยวข้อง	17
2.5.1 การนำเอาการเรียนรู้แบบไม่มีผู้สอนมาใช้งานในงานด้านการตรวจจับความผิดปกติ	18
2.5.2 การปรับปรุงประสิทธิภาพของการทำการจำแนก	19
บทที่ 3 วิธีการดำเนินงานวิจัย	23
3.1 ชุดข้อมูล (Dataset)	23

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.2 การเตรียมข้อมูล (Data Preparation and Preprocessing)	27
3.2.1 การเข้ารหัสข้อมูลเชิงกลุ่ม (Categorical Data Encoding)	27
3.2.2 การทำให้ค่าเป็นมาตรฐาน (Standardization)	28
3.2.3 การลดมิติข้อมูล (Dimensionality Reduction)	28
3.3 การสร้างตัวแบบ (Modeling)	28
3.3.1 การออกแบบขั้นตอนการฝึกสอนตัวแบบ	29
3.3.2 หาโครงสร้างของตัวเข้ารหัสอัตโนมัติที่เหมาะสม	29
3.3.3 หาค่า Hyperparameters ที่เหมาะสม	33
3.4 การวัดประสิทธิภาพของตัวแบบ (Performance Evaluation)	33
บทที่ 4 ผลการวิจัยและการอภิปรายผล	34
4.1 การกำหนดโครงสร้างของตัวเข้ารหัสอัตโนมัติที่ใช้ในการทดสอบ	34
4.1.1 การหาโครงสร้างของตัวเข้ารหัสอัตโนมัติ	34
4.1.2 การหาค่า Hyperparameters ที่เหมาะสม	37
4.2 ผลการศึกษาและวัดประสิทธิภาพ	39
4.2.1 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%	39
4.2.2 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%	41
4.2.3 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%	42
4.2.4 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%	44
4.3 ปัญหาที่พบจากการศึกษา	47
4.3.1 ตัวแบบไม่สามารถตรวจจับการบุกรุกบางประเภทได้	47
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	50
5.1 สรุปผลการวิจัย	50
5.2 ข้อจำกัด	51
5.3 ข้อเสนอแนะและงานในอนาคต	51
เอกสารอ้างอิง	52
ประวัติผู้เขียน	53

สารบัญตาราง

ตารางที่	หน้า
2.1 แสดงงานวิจัยที่เกี่ยวข้องกับการนำเอาการเรียนรู้แบบไม่มีผู้สอนมาใช้งานในงานด้านการตรวจจับความผิดปกติ	17
2.2 แสดงงานวิจัยที่เกี่ยวข้องกับการปรับปรุงประสิทธิภาพของการทำการจำแนก	17
2.3 แสดงค่า AUC ของวิธีการทั้ง 4 แบบกับชุดข้อมูล Lorenz, Sat-A และ Sat-B	18
2.4 แสดงค่าความแม่นยำของวิธีการจัดกลุ่ม	19
2.5 แสดงประสิทธิภาพของ SAE-DNN เมื่อเทียบกับวิธีอื่น ๆ บนชุดข้อมูล KDDCup99	20
2.6 แสดงประสิทธิภาพของ SAE-DNN เมื่อเทียบกับวิธีอื่น ๆ บนชุดข้อมูล NSL-KDD	21
2.7 แสดงประสิทธิภาพของ SAE-DNN เมื่อเทียบกับวิธีอื่น ๆ บนชุดข้อมูล UNSW-NB15	21
3.1 แสดงข้อมูลคุณลักษณะของชุดข้อมูล UNSW-NB15	24
3.2 แสดงการแจกแจงของข้อมูลที่มีในฐานข้อมูล UNSW-NB15	26
3.3 แสดงตัวอย่างผลลัพธ์ของการเข้ารหัสด้วยวิธีการสร้างตัวแปรหุ่นของคุณลักษณะ state ที่มีค่า CON	27
3.4 แสดงตัวอย่างผลลัพธ์ของการทำให้ค่าเป็นมาตรฐาน	28
3.5 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 1 ชั้น	30
3.6 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 3 ชั้น	30
3.7 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 5 ชั้น	30
3.8 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้น	31
3.9 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 9 ชั้น	32
3.10 แสดงค่า Hyperparameters ที่ใช้ในการหาโครงสร้างของตัวแบบ	33
4.1 แสดงตารางเปรียบเทียบประสิทธิภาพของตัวแบบที่มีชั้นซ่อน 1-7 ชั้น	37
4.2 แสดงค่า Hyperparameters ที่ใช้ในตัวแบบสำหรับการทดลอง	39
4.3 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%	41
4.4 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%	41
4.5 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%	42
4.6 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%	42
4.7 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%	44
4.8 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%	44
4.9 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%	45
4.10 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%	45

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.11	แสดงผลการจำแนกโดยการจัดกลุ่มตามประเภทการบุกรุก	47
4.12	คำอธิบายของการบุกรุกแต่ละประเภท	47
4.13	แสดงเมทริกซ์ความสัมพันธ์ของตัวแบบที่ฝึกสอนจากชุดข้อมูลที่ไม่มีการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode	49
4.14	แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลที่ไม่มีการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode	49
5.1	แสดงค่าประสิทธิภาพของการจำแนกข้อมูลปกติจากการทดลอง	50
5.2	แสดงค่าประสิทธิภาพของการจำแนกข้อมูลผิดปกติจากการทดลอง	50



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
2.1 แสดงสถาปัตยกรรมของระบบที่มีการใช้งานระบบตรวจจับการบุกรุกเครือข่าย	3
2.2 แสดงขั้นตอนการทำงานของระบบตรวจจับการบุกรุก	5
2.3 แสดงโครงสร้างของโครงข่ายประสาทเทียม	9
2.4 แสดงโครงสร้างของโครงข่ายประสาทเทียมชนิดตัวเข้ารหัสอัตโนมัติ	16
2.5 แสดงตัวอย่างลำดับการทำงานและผลลัพธ์ของตัวเข้ารหัสอัตโนมัติ	16
2.6 แสดงการเปรียบเทียบความแม่นยำของวิธีที่งานวิจัยนำเสนอ[9]	20
3.1 ขั้นตอนในการดำเนินงานวิจัย	23
3.2 ตัวอย่างชุดข้อมูล UNSW-NB15	27
3.3 แสดงขั้นตอนการเตรียมข้อมูล	27
3.4 แสดงขั้นตอนการสร้างตัวแบบ	29
4.1 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 1 ชั้น	34
4.2 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 3 ชั้น	35
4.3 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 5 ชั้น	35
4.4 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้น	36
4.5 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 9 ชั้น	36
4.6 แสดงค่าการสูญเสียของการฝึกสอน 0 – 1000 รอบ	37
4.7 แสดงค่าการสูญเสียของการฝึกสอนระหว่าง Batch size 128 (รูปซ้าย) และ 256 (รูปขวา)	38
4.8 แสดงค่าการสูญเสียของการฝึกสอนระหว่าง MSE (รูปซ้าย) และ MAE (รูปขวา)	38
4.9 แสดงค่าการสูญเสียของการฝึกสอนระหว่าง Learning rate 0.01 (รูปซ้าย) และ 0.001 (รูปขวา)	39
4.10 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%	40
4.11 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%	40
4.12 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%	41
4.13 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%	42
4.14 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%	43
4.15 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%	43
4.16 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%	44
4.17 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%	45
4.18 แสดงแผนภาพเปรียบเทียบค่าประสิทธิภาพของการจำแนกข้อมูลปกติจากการทดลอง	46

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- 4.19 แสดงแผนภาพเปรียบเทียบค่าประสิทธิภาพของการจำแนกข้อมูลผิดปกติจากการทดลอง 46
- 4.20 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลที่ไม่มีการบุกรุกประเภท Fuzzers
Reconnaissance และ Shellcode 49



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในปีพ.ศ. 2564 ที่ผ่านมามีจำนวนคนที่ใช้งานอินเทอร์เน็ตที่มีจำนวนที่เพิ่มขึ้นมาจากข้อมูลที่ได้เก็บโดย DataReportal ซึ่งได้เก็บข้อมูลการใช้งานอินเทอร์เน็ตของโลก แสดงให้เห็นว่ามีคนใช้งานอินเทอร์เน็ตเพิ่มขึ้น 1 ล้านคนในทุก ๆ วัน ทำให้ในปีพ.ศ. 2565 มีผู้ใช้งานอินเทอร์เน็ตรวมกันมากถึง 4,950 ล้านคน ยิ่งจำนวนผู้ใช้งานอินเทอร์เน็ตมีมากขึ้น ยิ่งทำให้เกิดการบุกรุกระบบคอมพิวเตอร์เป็นจำนวนมากขึ้นและความซับซ้อนมากยิ่งขึ้นตามไปด้วย ซึ่งในปีที่ผ่านมา มีมูลค่าความเสียหายที่เกิดจากอาชญากรรมไซเบอร์รวมทั้งหมดมากถึง 6.9 พันล้านดอลลาร์สหรัฐ ทำให้เทคโนโลยีหลาย ๆ อย่างเช่นไฟร์วอลล์ การเข้ารหัส และการยืนยันตัวตนได้ถูกนำมาใช้งานเพื่อป้องกันระบบเครือข่ายคอมพิวเตอร์

อย่างไรก็ตาม เทคโนโลยีเหล่านั้นมีความสามารถไม่เพียงพอและบางครั้งไม่สามารถป้องกันการโจมตีระบบเครือข่ายคอมพิวเตอร์ได้ ดังนั้นระบบตรวจจับการบุกรุก (Intrusion Detection System) ที่มีประสิทธิภาพได้ถูกนำเสนอโดยนักวิจัยมากมาย ซึ่งวิธีการตรวจจับได้ถูกแบ่งเป็นสองประเภทคือ 1. ใช้พื้นฐานของลักษณะเฉพาะ (Signature Based) และ 2. การตรวจจับความผิดปกติ (Anomaly Detection) สำหรับการตรวจจับวิธีแรกใช้พื้นฐานลักษณะเฉพาะจะมีความสามารถในการตรวจจับรูปแบบการโจมตีที่รู้จักซึ่งข้อมูลจะถูกเก็บไว้ในฐานข้อมูลดังนั้นจึงจำเป็นที่จะต้องปรับปรุงฐานข้อมูลให้มีรูปแบบที่ทันสมัยอยู่ตลอดเวลาเพื่อป้องกันการโจมตีรูปแบบใหม่ ๆ แต่สำหรับวิธีการตรวจจับวิธีที่สอง การตรวจจับความผิดปกตินั้นจะมีความสามารถในการตรวจจับรูปแบบการโจมตีที่ไม่เคยพบมาก่อนโดยใช้พื้นฐานทางสถิติ ทำให้มีการศึกษาวิธีการทางการเรียนรู้ของเครื่อง (Machine learning) สำหรับการตรวจจับการบุกรุกมากกว่า 20 ปี แต่การศึกษาที่ผ่านมาจำนวนมาก ทำการศึกษาโดยใช้การเรียนรู้แบบมีผู้สอน (Supervised learning) และใช้ชุดข้อมูลตัวอย่างที่มีคำตอบ (Label) ในการศึกษา อย่างไรก็ตามวิธีการดังกล่าว ก่อให้เกิดข้อจำกัดมากในการนำวิธีการเรียนรู้ของเครื่องไปใช้งานจริง เนื่องจากชุดข้อมูลของจริงนั้นมีจำนวนมหาศาลและไม่มีคุณลักษณะ (Feature) ที่เป็นคำตอบมาให้ ซึ่งเป็นเรื่องยากที่จะทำการระบุคำตอบด้วยตัวเองเพื่อที่จะนำไปใช้ในการเรียนรู้ของวิธีการเรียนรู้แบบมีผู้สอน เพราะฉะนั้นจึงเริ่มมีการศึกษาการใช้การเรียนรู้ของเครื่องแบบไม่มีผู้สอน (Unsupervised learning) มาประยุกต์ใช้ในระบบตรวจจับการบุกรุก

ในการค้นคว้าอิสระนี้ได้ศึกษาและนำเสนอวิธีการตรวจจับการบุกรุกระบบเครือข่ายโดยใช้การเรียนรู้เชิงลึกประเภทตัวเข้ารหัสอัตโนมัติ ซึ่งเป็นการเรียนรู้แบบไม่มีผู้สอนมาใช้เพื่อจำแนกข้อมูล โดยที่ชุดข้อมูลที่ใช้ในการทดลองจะเป็นข้อมูลจากฐาน UNSW-NB15 ซึ่งเป็นชุดข้อมูลที่มีความนิยมใน

การนำมาศึกษาทางด้านการตรวจจับการบุกรุก

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.2 วัตถุประสงค์ของงานวิจัย

- 1) ศึกษาวิธีการลดคุณลักษณะข้อมูลเพื่อเตรียมไปใช้จำแนก
- 2) ศึกษาการจำแนกพฤติกรรมการบุกรุกด้วยวิธีการเรียนรู้แบบไม่มีผู้สอน
- 3) เพื่อหาประสิทธิภาพของวิธีการตรวจจับการบุกรุกระบบเครือข่ายที่น่าเสนอ

1.3 ขอบเขตของงานวิจัย

- 1) ชุดข้อมูลที่ใช้ในการทดลองมาจากฐานข้อมูล UNSW-NB15 ซึ่งจัดทำโดยองค์กร Cyber Range Lab of UNSW Canberra
- 2) ศึกษาเฉพาะวิธีการสร้างขั้นตอนวิธี (Algorithm) โดยที่ไม่มีการสร้างโปรแกรมประยุกต์ (Application)
- 3) สร้างต้นแบบของตัวแบบโดยใช้ภาษา Python โดยจะไม่มีส่วนติดต่อกับผู้ใช้ (User Interface)
- 4) ใช้เทคนิคการเรียนรู้แบบไม่มีผู้สอนในการสร้างตัวแบบสำหรับการจำแนก (Classification)

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ได้วิธีการตรวจจับการบุกรุกระบบเครือข่ายแบบใหม่ที่สามารถเรียนรู้จากชุดข้อมูลที่ไม่มีคำตอบได้
- 2) เพื่อเป็นแนวทางสำหรับการพัฒนาวิธีการตรวจจับการบุกรุกระบบเครือข่ายได้หลายรูปแบบมากขึ้น
- 3) ได้ทราบประสิทธิภาพของการนำการเรียนรู้แบบไม่มีผู้สอนมาใช้ในการจำแนกข้อมูล


บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีและงานวิจัยที่เกี่ยวข้อง ซึ่งจะประกอบไปด้วยพื้นฐานของระบบตรวจจับการบุกรุกระบบเครือข่าย การลดมิติของข้อมูลด้วยวิธีการวิเคราะห์องค์ประกอบหลัก โครงข่ายประสาทเทียม ตัวเข้ารหัสอัตโนมัติ และส่วนสุดท้ายคืองานวิจัยที่เกี่ยวกับระบบตรวจจับการบุกรุกเครือข่าย

2.1 ระบบตรวจจับการบุกรุกเครือข่าย (Network Intrusion Detection System)

ระบบตรวจจับการบุกรุก คือ ระบบตรวจจับสัญญาณของความผิดปกติต่าง ๆ ที่เกิดขึ้นในระบบที่อยู่ในขอบเขตที่ระบบนี้มีหน้าที่ตรวจสอบ โดยตัวโปรแกรมจะมีความสามารถในการตรวจจับสัญญาณของความผิดปกติที่เกิดขึ้นในระบบไม่ว่าจะเป็นภายในระบบคอมพิวเตอร์ ระบบปฏิบัติการ โปรแกรมที่รันอยู่ในเครื่อง การทำงานกับฐานข้อมูล หรือแม้แต่ข้อมูลที่วิ่งผ่านไปมาในเครือข่าย ซึ่งจะมีสถาปัตยกรรมดังรูปที่ 2.1



รูปที่ 2.1 แสดงสถาปัตยกรรมของระบบที่มีการใช้งานระบบตรวจจับการบุกรุกเครือข่าย

ระบบการตรวจจับการบุกรุกนี้ได้รับการศึกษาและปรับปรุงพัฒนาในหลายด้านอย่างต่อเนื่อง ตัวอย่างเช่น การพัฒนาวิธีการสำหรับใช้ในการตรวจจับการบุกรุกหรือการ ออกแบบสถาปัตยกรรมของระบบการตรวจจับการบุกรุกเพื่อรองรับและป้องกันระบบเครือข่ายคอมพิวเตอร์จากการโจมตีในรูปแบบต่าง ๆ ที่มีอยู่ในปัจจุบัน

2.1.1 ประเภทของการตรวจจับการบุกรุก

ระบบตรวจจับการบุกรุกแบ่งออกเป็น 2 รูปแบบ [1] ดังนี้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. ระบบที่ตรวจหาการทำงานที่ผิดไปจากการทำงานปกติของระบบ (Anomaly Detection) คือ การหาเซตของการทำงานที่เป็นปกติย่อย ๆ ขึ้นมาแล้วนำมารวมกันเพื่อให้ระบบตรวจจับการบุกรุกทราบข้อมูลของเซตการทำงานที่เป็นปกติทั้งหมดในระบบ หลังจากนั้นเมื่อระบบตรวจจับการบุกรุกทำงาน ถ้าเกิดกรณีที่ระบบตรวจจับการบุกรุกตรวจจับการทำงานที่ไม่ได้อยู่ในเซตของการทำงานที่เป็นปกติ ระบบตรวจจับการบุกรุกจะแจ้งเตือนต่อผู้ดูแลระบบทันที สำหรับการสร้างขอบเขตของระบบนั้น อาจสร้างได้โดยการหาข้อมูลการทำงานที่เป็นปกติในระบบขึ้นมา โดยเอาข้อมูลการทำงานของผู้ใช้งานแต่ละคน เวลาที่มีการใช้งาน ทรัพยากรที่ผู้ใช้งานคนนั้น ๆ มักจะใช้บ่อย ๆ หรือแม้กระทั่งข้อมูลในระบบ หรือในเครือข่ายก็สามารถนำมาสร้างเป็นเซตของระบบได้เช่นกัน ในการหาเซตของการทำงานที่เป็นปกติทั้งหมดอาจเกิดการผิดพลาดขึ้นทำให้เกิดผลลัพธ์ที่เป็นค่าบวกเท็จหรือค่าลบเท็จขึ้นมาได้เช่นกัน

2. ระบบที่ตรวจหาการทำงานที่ไม่ควรเกิดขึ้นในระบบ (Misuse Detection หรือ Signature based) ซึ่งเป็นแนวความคิดที่ตรงข้ามกับระบบที่ตรวจหาการทำงานที่ผิดไปจากการทำงานปกติของระบบ (Anomaly Detection) คือ รูปแบบนี้จะใช้ข้อมูลของการทำงานที่ผิดปกติต่าง ๆ ที่เคยเกิดขึ้นมาแล้ว สร้างเป็นฐานข้อมูลของการทำงานที่ผิดปกติให้ระบบตรวจจับการบุกรุกจดจำไว้ และในการทำงานของตรวจจับการบุกรุกประเภทนี้จะนำข้อมูลที่อยู่ในระบบมาค้นหาในฐานข้อมูลว่ามีอยู่หรือไม่ ถ้าระบบตรวจจับการบุกรุกมีข้อมูลของการทำงานรูปแบบนั้น ๆ อยู่ ก็แสดงว่าเกิดความผิดปกติขึ้น แต่ในการรวบรวมข้อมูลนี้อาจรวมเอาการทำงานที่เป็นปกติเข้าไปด้วย ทำให้เกิดผลลัพธ์ที่เป็นค่าบวกเท็จหรือในบางกรณีที่ไม่ได้เก็บข้อมูลความผิดปกติเอาไว้ก็ทำให้เกิดกรณีผลลัพธ์ที่เป็นค่าลบเท็จได้เช่นกัน ซึ่งในการทำงานประเภทนี้จะมีข้อเสียคือจะไม่สามารถตรวจจับการบุกรุกชนิดใหม่ๆ ได้ เนื่องจากต้องมีข้อมูลของการบุกรุกอยู่ก่อนจึงจะตรวจจับได้

2.1.2 การทำงานของระบบตรวจจับการบุกรุก

ระบบตรวจจับการบุกรุกแต่ละแบบมีหน้าที่การทำงานที่แตกต่างกันออกไป บางตัวจะตรวจจับความผิดปกติในระบบเครือข่าย บางตัวจะตรวจจับความผิดปกติในระบบฐานข้อมูล แต่โดยการทำงานทั้งหมดจะสามารถแบ่งการทำงานของระบบตรวจจับการบุกรุกได้เป็น 4 ขั้นตอนดังรูปที่ 2.2



รูปที่ 2.2 แสดงขั้นตอนการทำงานของระบบตรวจจับการบุกรุก

ขั้นตอนที่ 1. การเก็บข้อมูลในระบบ

การเก็บข้อมูลในระบบที่ต้องการตรวจสอบสามารถแบ่งการเก็บข้อมูลออกเป็นกลุ่มต่างๆ ได้ 4 กลุ่มคือ 1. การเก็บข้อมูลในชั้นแอปพลิเคชันเพื่อนำมาตรวจสอบการทำงานของแอปพลิเคชันต่าง ๆ 2. การเก็บข้อมูลของการทำงานของเครื่องเพื่อนำมาตรวจสอบการทำงานของระบบของเครื่องที่ใช้งานอยู่ 3. การเก็บข้อมูลการเปลี่ยนแปลงข้อมูลในระบบเพื่อนำมาตรวจสอบว่าข้อมูลมีการเปลี่ยนแปลงอย่างไร และ 4. การเก็บข้อมูลเครือข่ายเพื่อนำมาตรวจสอบว่ามีการบุกรุกทางระบบเครือข่ายหรือไม่

ขั้นตอนที่ 2. การวิเคราะห์ข้อมูลระบบ

การวิเคราะห์ข้อมูลระบบสามารถแบ่งการทำงานตามรูปแบบการวิเคราะห์ข้อมูลได้ 2 รูปแบบคือ

1. การวิเคราะห์ในขณะที่เก็บข้อมูลทันที

ในการวิเคราะห์ข้อมูลที่ได้ในขณะที่เก็บข้อมูลนั้น ระบบจะจัดเก็บข้อมูลวิเคราะห์ข้อมูลและรายงานผลการวิเคราะห์ในช่วงเวลาเดียวกัน เมื่อเกิดข้อผิดพลาดขึ้นจะสามารถตอบสนองได้ทันที แต่ก็ขึ้นอยู่กับความเร็วในการวิเคราะห์ข้อมูลด้วย ถ้าข้อมูลมีความซับซ้อนมากก็จะใช้เวลามากตาม ซึ่งการทำงานที่รวดเร็วดังกล่าวก็ต้องแลกกับการใช้หน่วยความจำปริมาณมาก อีกทั้งการตอบสนองต่อการบุกรุกโดยอัตโนมัติอาจจะทำให้เกิดความเสียหายกับระบบมากกว่าเดิม เพราะในบางครั้งการทำงานที่เร็วเกินไปของระบบ ทำให้เกิดความผิดพลาดในการวิเคราะห์ข้อมูลจนประมวลผลการทำงานปกติกลายเป็นการทำงานที่ผิดปกติ ระบบตรวจจับการบุกรุกที่ทำงานแบบนี้จึงเหมาะกับระบบที่มีข้อมูลที่ต้องพิจารณาน้อย ต้องการการรายงานอย่างรวดเร็วเมื่อผิดปกติ และข้อมูลที่น่าวิเคราะห์นั้นต้องไม่ซับซ้อนมาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. การวิเคราะห์ข้อมูลภายหลังจากที่เก็บข้อมูล

การทำงานในลักษณะนี้เหมาะกับงานที่ไม่จำเป็นต้องตอบสนองทันทีเมื่อเกิดความผิดปกติขึ้น แต่ให้มีการบันทึกและรายงานว่าเกิดความผิดปกติขึ้น การทำงานจะใช้หน่วยความจำและการประมวลผลน้อยกว่าแบบแรก แต่จะใช้เวลาในการเก็บข้อมูลมากกว่าแบบแรก ข้อเสียของการทำงานแบบนี้คือ มักแก้ปัญหาที่เกิดขึ้นไม่ทัน เพราะกว่าจะทราบว่าจะเกิดปัญหาขึ้น ปัญหานั้นก็เกิดขึ้นนานมากแล้ว

ไม่ว่าจะเป็นการวิเคราะห์ในขณะที่เก็บข้อมูลหรือการวิเคราะห์ข้อมูลภายหลังจากที่เก็บข้อมูล ก็จะมีวิธีการวิเคราะห์ระบบที่เหมือนกันคือ ระบบที่ตรวจหาการทำงานที่ผิดไปจากการทำงานปกติของระบบ (Anomaly Detection) ส่วนในอีกรูปแบบหนึ่ง คือ ระบบที่ตรวจหาการทำงานที่ไม่ควรเกิดขึ้นในระบบ (Misuse Detection)

ขั้นตอนที่ 3. การตอบสนอง

เมื่อมีการตรวจพบว่าการบุกรุกเกิดขึ้นในระบบ สำหรับระบบตรวจจับที่ทำงานแบบทันทีจะมีการตอบสนองต่อการบุกรุกเพื่อไม่ให้เกิดความเสียหายหรือบรรเทาความเสียหายที่เกิดขึ้น แต่สำหรับระบบที่ทำงานเป็นแบบกลุ่มการตอบสนองอาจจะทำได้ไม่มากนัก เพราะการบุกรุกนั้นเกิดขึ้นไปแล้วและความเสียหายก็เกิดขึ้นไปแล้ว การตอบสนองอาจจะอยู่ในรูปแบบการบรรเทาไม่ให้เกิดความเสียหายมากขึ้นเท่านั้น ซึ่งการตอบสนองต่อการบุกรุกนั้นจะแบ่งออกได้ 3 รูปแบบดังนี้

1. การเปลี่ยนแปลงสภาพของระบบ

การตอบสนองโดยการเปลี่ยนแปลงสภาพของระบบก็เพื่อแก้ปัญหาหรือลดความเสียหายที่จะเกิดขึ้น เช่น ตัดการเชื่อมต่อระหว่างระบบกับการบุกรุกออกจากกัน การตั้งค่าอุปกรณ์เครือข่ายหรือไฟร์วอลล์ไม่ให้มีการติดต่อกับระบบของการบุกรุก

2. การแก้ไขความผิดพลาดให้ถูก

เป็นการตอบสนองต่อปัญหาที่เกิดขึ้นแล้วในระบบ โดยปกติแล้วการบุกรุกมักเปลี่ยนแปลงค่าต่าง ๆ ในระบบ โดยเฉพาะเข้ามาทำการเปลี่ยนแปลงข้อมูลในระบบตรวจจับการบุกรุกเพื่อไม่ให้อาจสามารถตรวจจับการบุกรุกได้ การแก้ไขระบบก็เพื่อให้ระบบดังกล่าวสามารถทำงานได้อย่างปกติ

3. การแจ้งเตือนผู้ดูแลระบบ

สุดท้ายเป็นการแจ้งเตือนผู้ดูแลระบบ โดยปกติมักแจ้งเตือนผู้ดูแลระบบทันทีเมื่อทำการวิเคราะห์ได้ว่ามีความผิดปกติเกิดขึ้น เพื่อให้ผู้ดูแลระบบรับรู้และสามารถแก้ไขระบบได้ทันที

ขั้นตอนที่ 4. การรายงานผลการทำงาน

เมื่อระบบตรวจจับการบุกรุกทำการวิเคราะห์ระบบและตรวจพบความผิดปกติในระบบ อาจจะมีการตอบสนองต่อความผิดปกตินั้นถ้าทำได้ จากนั้นระบบจะต้องมีการรายงานผลให้กับผู้ดูแลระบบทราบในรูปแบบต่าง ๆ โดยรายละเอียดของการรายงานผลนั้น จะบอกถึงช่องโหว่ในระบบ การแก้ไขปัญหาคือว่า ๆ บางครั้งอาจจะมีรายละเอียดของความรู้พื้นฐานบางอย่างของระบบที่ทำให้เกิดการบุกรุกลักษณะนั้น ๆ ได้ การรายงานผลการทำงานนอกจากจะเป็นการรายงานต่อผู้ดูแลระบบ เพื่อให้ทราบการทำงานหรือจุดอ่อนนั้นแล้ว ยังเป็นประโยชน์ต่อการวิเคราะห์สถานะของระบบและการวิเคราะห์ความปลอดภัยในระบบอีกด้วย

2.2 การวิเคราะห์องค์ประกอบหลัก (Principle Component Analysis หรือ PCA)

การวิเคราะห์องค์ประกอบหลัก [3] เป็นวิธีการที่ถูกนำมาใช้มากสำหรับการลดรูปมิติในการเรียนรู้ของเครื่อง ซึ่งจะนิยมใช้ในขั้นตอนการเตรียมข้อมูล ซึ่งการวิเคราะห์องค์ประกอบหลักจะลดรูปข้อมูลจากมิติที่สูงมามีมิติที่ต่ำกว่าโดยการใช้การฉายภาพเชิงเส้น (Linear Projection) เพื่อที่จะลดมิติของตัวแปรในขณะที่ยังคงความแปรปรวนของข้อมูลไว้ให้ได้มากที่สุด ซึ่งการทำงานจะแบ่งเป็น 4 ขั้นตอนดังนี้

1. ทำให้ชุดข้อมูลเป็นมาตรฐานดังสมการที่ 2.1

$$Z_{ij} = \frac{x_{ij} - \bar{x}_j}{s_j}, \quad i = 1, 2, \dots, m; j = 1, 2, \dots, n \quad (2.1)$$

เมื่อ m คือ จำนวนของชุดข้อมูล

n คือ จำนวนของตัวแปรในชุดข้อมูล

x_{ij} คือ ค่าของข้อมูลของชุดข้อมูลที่ i และตัวแปรที่ j

\bar{x}_j คือ ค่าเฉลี่ยของข้อมูลของข้อมูลตัวแปรที่ j

s_j คือ ค่าส่วนเบี่ยงเบนมาตรฐานของข้อมูลตัวแปรที่ j

Z_{ij} คือ ค่าของข้อมูลของชุดข้อมูลที่ i และตัวแปรที่ j ที่ถูกทำให้เป็นมาตรฐาน

2. หาเมทริกซ์สัมประสิทธิ์สหสัมพันธ์ ดังสมการที่ 2.2

$$R = \frac{Z^T Z}{m - 1} \quad (2.2)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อ Z คือ เมทริกซ์ที่ถูกทำให้เป็นค่ามาตรฐาน
 Z^T คือ เมทริกซ์สลับเปลี่ยนที่ถูกทำให้เป็นค่ามาตรฐาน
 m คือ จำนวนของชุดข้อมูล

3. หาค่าเฉพาะ (eigenvalue) และเวกเตอร์เฉพาะ (eigenvector) ที่สอดคล้อง ดังสมการที่ 2.3

$$a_1 = \begin{Bmatrix} \alpha_{11} \\ \alpha_{21} \\ \vdots \\ \alpha_{m1} \end{Bmatrix}, a_2 = \begin{Bmatrix} \alpha_{12} \\ \alpha_{22} \\ \vdots \\ \alpha_{m2} \end{Bmatrix}, \dots, a_n = \begin{Bmatrix} \alpha_{1n} \\ \alpha_{2n} \\ \vdots \\ \alpha_{mn} \end{Bmatrix} \quad (2.3)$$

เมื่อ a_n คือ เวกเตอร์เฉพาะที่สอดคล้องกับองค์ประกอบหลักที่ n
 α_{mn} คือ ค่าของค่าเฉพาะที่ m ในเวกเตอร์เฉพาะขององค์ประกอบหลักที่ n

4. คำนวณหาองค์ประกอบหลัก ดังสมการที่ 2.4

$$t_i = \alpha_{1i}Z_1 + \alpha_{2i}Z_2 + \dots + \alpha_{ni}Z_n, \quad i = 1, \dots, n' \quad (2.4)$$

เมื่อ n' คือ จำนวนขององค์ประกอบหลัก


2.3 โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียม [4] คือตัวแบบทางคณิตศาสตร์ที่เป็นการจำลองการทำงานของสมองมนุษย์ด้วยวัตถุประสงค์ที่จะสร้างเครื่องมือซึ่งมีความสามารถในการเรียนรู้การจดจำรูปแบบและการอุปมาความรู้แบบเดียวกับสมองมนุษย์ โดยสามารถเรียนรู้ข้อมูลจากชุดข้อมูลที่มีอยู่แล้วในชุดข้อมูลฝึกสอน เพื่อใช้ทำนายข้อมูลในลักษณะเดียวกันในชุดข้อมูลทดสอบ โดยมีรายละเอียดในส่วนต่าง ๆ [5] ดังนี้

2.3.1 โครงข่ายประสาทเทียมแบบป้อนไปข้างหน้า (Feed-Forward Neural Network)

โครงข่ายประสาทเทียมประเภทนี้ จะมีลำดับในการคำนวณและส่งต่อข้อมูลไปในทิศทางเดียว โดยโครงสร้างจะแบ่งออกเป็นลำดับชั้น โดยในแต่ละชั้นจะมีเพอร์เซ็ปตรอนจำนวนหนึ่งซึ่งไม่มีเส้นเชื่อมถึงกันภายในชั้นเดียวกัน แต่จะมีเส้นเชื่อมถึงเพอร์เซ็ปตรอนตัวอื่น ๆ ที่อยู่ลำดับชั้นที่

ติดกันทั้งหมด โดยข้อมูลส่งออกของเพอร์เซ็ปตรอนในชั้นก่อนหน้า จะเป็นข้อมูลรับเข้าของเพอร์เซ็ปตรอนในชั้นปัจจุบัน ดังแสดงโครงสร้างได้ในรูปที่ 2.3



รูปที่ 2.3 แสดงโครงสร้างของโครงข่ายประสาทเทียม

และสามารถคำนวณหาค่าของผลลัพธ์ในชั้นถัดไปได้จากสมการดังต่อไปนี้

$$z_j^l = \sum_{k=1}^n w_{jk}^l a_k^{l-1} + b_j^l \quad (2.5)$$

$$a_j^l = g(z_j^l) \quad (2.6)$$

เมื่อ a_k^{l-1} คือ ผลลัพธ์ของเพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้น $l - 1$

w_{jk}^l คือ น้ำหนักสำหรับเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l ที่มีเส้นเชื่อมมาจากเพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้นก่อนหน้า

b_j^l คือ ค่าไบแอสสำหรับเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l

g คือ ฟังก์ชันกระตุ้น

2.3.2 ฟังก์ชันกระตุ้น (Activation Function)

สำหรับข้อมูลส่งออกของแต่ละเพอร์เซ็ปตรอน จะมีการใช้ฟังก์ชันกระตุ้น $g(z)$ ที่มีลักษณะแบบไม่ใช่ฟังก์ชันเชิงเส้น (Non-linear) เพื่อให้โครงข่ายประสาทเทียมมีความซับซ้อนและสามารถแก้ปัญหาได้หลากหลายมากยิ่งขึ้น โดยฟังก์ชันกระตุ้นที่นิยมใช้กัน มีดังต่อไปนี้

1. ฟังก์ชันซิกมอยด์ (Sigmoid Function) เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง

0 ถึง 1 ฟังก์ชันซิกมอยด์สามารถเขียนแทนด้วย σ ซึ่งคำนวณได้จากสมการต่อไปนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\sigma(z) = \frac{1}{1 + e^{-z}} \quad (2.7)$$

2. ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent Function) เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง -1 ถึง 1 ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์สามารถเขียนแทนด้วย \tanh ซึ่งคำนวณได้จากสมการต่อไปนี้

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (2.8)$$

3. ฟังก์ชันเรกทิไฟด์เชิงเส้น (Rectified Linear Unit Function) เป็นฟังก์ชันที่เปลี่ยนค่าติดลบที่เข้ามาให้เป็น 0 ส่วนค่าอื่น ๆ คงเดิม ซึ่งคำนวณได้จากสมการต่อไปนี้

$$f(z) = \begin{cases} 0, & \text{if } z \leq 0 \\ z, & \text{if } z > 0 \end{cases} \quad (2.9)$$

4. ฟังก์ชันซอฟต์แมกซ์ (Softmax Function) เป็นฟังก์ชันที่ให้ค่าผลลัพธ์ออกมาอยู่ในช่วง 0 ถึง 1 ซึ่งเป็นค่าที่แสดงความน่าจะเป็นของค่าที่นำเข้ามาแต่ละตัว โดยผลรวมของความน่าจะเป็นที่ได้จะมีค่าเป็น 1 ซึ่งคำนวณได้จากสมการต่อไปนี้

$$f(z_i) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (2.10)$$

2.3.3 ฟังก์ชันต้นทุน (Cost Function หรือ Loss Function)

เป็นฟังก์ชันที่แสดงถึงต้นทุนของโครงข่ายประสาทเทียม โดยในกระบวนการเรียนรู้ของโครงข่ายประสาทเทียมนั้น จะทำการปรับค่าน้ำหนักเพื่อที่จะลดค่าของฟังก์ชันต้นทุนเพื่อให้เข้าใกล้กับค่า 0 มากที่สุด ฟังก์ชันต้นทุนที่เป็นที่นิยมมีดังต่อไปนี้

1. ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error)

$$J = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - y_i)^2 \quad (2.11)$$

เมื่อ y_i คือ ค่าตอบจริง ณ ข้อมูลที่ i

\hat{y}_i คือ ผลลัพธ์ที่ทำนายได้จากข้อมูลที่ i

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. ค่าเฉลี่ยครอสเอนโทรปีแบบทวิภาค (Binary Cross-entropy)

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) + (1 - y_i) \log(1 - \hat{y}_i) \quad (2.12)$$

เมื่อ y_i คือ ค่าตอบจริงของข้อมูลที่ i

\hat{y}_i คือ ผลลัพธ์ที่ทำนายได้จากข้อมูลที่ i

3. ค่าติดลบลอการิทึมภาวะน่าจะเป็น (Negative Log Likelihood)

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (2.13)$$

เมื่อ y_i คือ ค่าตอบจริง ณ ข้อมูลที่ i

\hat{y}_i คือ ผลลัพธ์ที่ทำนายได้จากข้อมูลที่ i

2.3.4 การหาค่าที่เหมาะสมที่สุด (Optimization)

เป็นวิธีการปรับปรุงอัตราการเรียนรู้ เพื่อให้สามารถลดค่าจากฟังก์ชันต้นทุนได้มากที่สุด ในแต่ละรอบ เพื่อเพิ่มโอกาสไปยังจุดต่ำสุดทั้งหมด โดยใช้วิธีการปรับปรุงน้ำหนักของเส้นเชื่อมในโครงข่ายประสาทเทียม วิธีการปรับปรุงน้ำหนักที่ได้รับความนิยมมีดังต่อไปนี้

1. สโตแคสติกเกรเดียนต์เดสเซนท์ (Stochastic Gradient Descent)

เมื่อกำหนดให้ w แทนค่าพารามิเตอร์ ซึ่งเป็นน้ำหนักที่ต้องการจะปรับค่า α คือ อัตราการเรียนรู้ และ $\frac{\partial J}{\partial w}$ คือ เกรเดียนต์ฟังก์ชันของต้นทุนเทียบกับ w โดยจะทำการปรับค่าด้วยสมการดังต่อไปนี้

$$w_t = w_{t-1} - \alpha \frac{\partial J}{\partial w_{t-1}} \quad (2.14)$$

เมื่อ α คือ อัตราการเรียนรู้

J คือ ฟังก์ชันต้นทุน

w_{t-1} คือ ค่าน้ำหนัก ณ จุด $t-1$

w_t คือ ค่าน้ำหนักใหม่ที่ได้อ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แต่ปัญหาที่อาจจะเจอในระหว่างการเรียนรู้คือ การติดอยู่ในโลคอลออปติมา (Local Optima) ดังนั้นจึงมีการนำโมเมนตัม (Momentum) มาใช้โดยมีจุดประสงค์เพื่อทำให้การเรียนรู้มีการลู่ออกเข้าที่ดีขึ้นและหลีกเลี่ยงการติดอยู่ในโลคอลออปติมา โดยกำหนดให้ v แทนค่าความเร็ว ซึ่งมีการปรับค่าพร้อมกับ w และ γ แทนค่าสัมประสิทธิ์ของโมเมนตัม สามารถแสดงการเรียนรู้ได้เป็นสมการดังนี้

$$v_t = \gamma v_{t-1} + \alpha \frac{\partial J}{\partial w_{t-1}} \quad (2.15)$$

$$w_t = w_{t-1} - v_t \quad (2.16)$$

เมื่อ α	คือ อัตราการเรียนรู้
J	คือ ฟังก์ชันต้นทุน
w_{t-1}	คือ ค่าน้ำหนัก ณ จุด t-1
v_{t-1}	คือ ค่าของความเร็ว ณ จุด t-1
γ	คือ สัมประสิทธิ์ของโมเมนตัม
v_t	คือ ค่าของความเร็ว ณ จุด t
w_t	คือ ค่าน้ำหนักใหม่ที่ได้

2. วิธีเกรเดียนที่ปรับตัวได้ (Adaptive Gradient Method)

เป็นวิธีที่จะมีการปรับอัตราการเรียนรู้ได้ด้วยตัวเองจากค่าเริ่มต้นที่กำหนด โดยการปรับค่าของอัตราการเรียนรู้จะมีการนำค่าเกรเดียนในอดีตมาใช้ กำหนดให้ g_t แทนเกรเดียนที่เวลา t ซึ่งสามารถแสดงการเรียนรู้ได้เป็นสมการดังนี้

$$g_t = \frac{\partial J}{\partial w_{t-1}} \quad (2.17)$$

$$w_t = w_{t-1} - \frac{\alpha}{\sqrt{\sum_{k=1}^t g_i^2}} g_t \quad (2.18)$$

เมื่อ J	คือ ฟังก์ชันต้นทุน
w_{t-1}	คือ ค่าน้ำหนัก ณ จุด t-1
g_t	คือ เกรเดียนของฟังก์ชันต้นทุน เทียบกับค่าน้ำหนัก ณ จุด t-1
g_i	คือ เกรเดียนของฟังก์ชันต้นทุน เทียบกับค่าน้ำหนัก ณ จุด i-1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

α คือ อัตราการเรียนรู้
 w_t คือ ค่าน้ำหนักใหม่ที่ได้

3. อาร์เอ็มเอสพรอป (RMSProp)

เป็นวิธีที่มีการเก็บค่าเกรเดียนของครั้งก่อนหน้าไว้เพื่อที่จะนำมาใช้ในรอบการเรียนรู้ปัจจุบัน โดยนำไปปรับปรุงอัตราส่วนของอัตราการการเรียนรู้ โดยนอกเหนือจากการใช้ g_t แล้ว ยังมีการใช้ $MeanSquare_t$ สำหรับเก็บค่าเฉลี่ยของเกรเดียน และให้ v แทนอัตราการใช้เกรเดียนของอดีตในการเรียนรู้ สามารถแสดงการเรียนรู้ได้เป็นสมการต่อไปนี้

$$g_t = \frac{\partial J}{\partial w_{t-1}} \quad (2.19)$$

$$MeanSquare_t = \gamma MeanSquare_{t-1} + (1 - \gamma) g_t^2 \quad (2.20)$$

$$w_t = w_{t-1} - \frac{\alpha}{\sqrt{MeanSquare_t}} g_t \quad (2.21)$$

เมื่อ J คือ ฟังก์ชันต้นทุน

w_{t-1} คือ ค่าน้ำหนัก ณ จุด t-1

g_t คือ เกรเดียนของฟังก์ชันต้นทุน เทียบกับค่าน้ำหนัก ณ จุด t-1

γ คือ สัมประสิทธิ์ของโมเมนตัม

$MeanSquare_{t-1}$ คือ ค่าเฉลี่ยกำลังสองของเกรเดียน ณ จุด t-1

$MeanSquare_t$ คือ ค่าเฉลี่ยกำลังสองของเกรเดียน ณ จุด t

α คือ อัตราการเรียนรู้

w_t คือ ค่าน้ำหนักใหม่ที่ได้

2.3.5 การแพร่กระจายย้อนกลับ (Backpropagation)

เนื่องจากเกรเดียนที่ได้จากการหาค่าความผิดพลาดสุดท้ายจากฟังก์ชันต้นทุนนั้นมีไว้ให้ลำดับชั้นสุดท้ายในโครงข่ายประสาทเทียมเท่านั้น ดังนั้น หากต้องการจะทำการหาค่าเกรเดียนสำหรับปรับค่าของ w ของเพอร์เซ็ปตรอนในลำดับชั้นก่อนหน้า จะต้องใช้วิธีการแพร่กระจายย้อนกลับ โดยจะสามารถเขียนเป็นสมการได้ดังนี้

$$\delta_j^l = \frac{\partial J}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} \frac{\partial a_j^l}{\partial z_j^l} = \frac{\partial J}{\partial a_j^l} = g'(z_j^l) \quad (2.22)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น มิอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อ δ_j^l คือ ค่าความผิดพลาดของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l

J คือ ฟังก์ชันต้นทุน

z_j^l คือ ค่าที่คำนวณได้ก่อนผ่านฟังก์ชันกระตุ้น g ของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l

a_j^l คือ ผลลัพธ์ของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้น l

g' คือ ฟังก์ชันกระตุ้น

สำหรับการหาค่า $\frac{\partial J}{\partial a_j^l}$ นั้น ในลำดับชั้นสุดท้ายสามารถคำนวณหาได้โดยตรงจากฟังก์ชันต้นทุนที่เลือกใช้ ส่วนในลำดับชั้นก่อนหน้าจะต้องหาโดยวิธีการแพร่กระจายย้อนกลับ โดยจะคล้ายกับการป้อนไปข้างหน้า เพียงแต่เป็นการกลับทิศทางการคำนวณเท่านั้น กำหนด m คือ จำนวนเพอร์เซ็ปตรอนในลำดับชั้นที่ $l + 1$ สามารถคำนวณได้จากสมการดังนี้

$$\frac{\partial J}{\partial a_j^l} = \sum_{k=1}^m \frac{\partial J}{\partial z_j^{l+1}} \frac{\partial z_j^{l+1}}{\partial a_j^l} = \sum_{k=1}^m \delta_k^{l+1} w_{kj}^{l+1} \quad (2.23)$$

เมื่อ J คือ ฟังก์ชันต้นทุน

a_j^l คือ ผลลัพธ์ของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้น l

z_j^{l+1} คือ ค่าที่คำนวณได้ก่อนผ่านฟังก์ชันกระตุ้น g ของเพอร์เซ็ปตรอนตัวที่ j_1 ในลำดับชั้นที่ $l + 1$

δ_j^{l+1} คือ ค่าความผิดพลาดของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ $l + 1$

m คือ จำนวนเพอร์เซ็ปตรอนในลำดับชั้นที่ $l + 1$

w_{kj}^{l+1} คือ ค่าน้ำหนักสำหรับเพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้นที่ $l + 1$ ที่มีเส้นเชื่อมมาจากเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นก่อนหน้า

จากนั้น เมื่อคำนวณค่าความผิดพลาดของแต่ละลำดับชั้นได้ ก็สามารถหาค่าความผิดพลาดเทียบกับน้ำหนักและค่าไบแอส ได้จากสมการดังนี้

$$\frac{\partial J}{\partial w_{jk}^l} = \frac{\partial J}{\partial z_j^l} \frac{\partial z_j^l}{\partial w_{jk}^l} = \delta_j^l a_k^{l-1} \quad (2.24)$$

เมื่อ J คือ ฟังก์ชันต้นทุน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

w_{jk}^l คือ ค่าน้ำหนักสำหรับเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l ที่มีเส้นเชื่อมมาจากเพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้นก่อนหน้า

z_j^l คือ ค่าที่คำนวณได้ก่อนผ่านฟังก์ชันกระตุ้น g ของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l

δ_j^{l+1} คือ ค่าความผิดพลาดของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ $l + 1$

α_k^{l-1} คือ ผลลัพธ์ของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้น $l - 1$

ในกรณีที่ใช้สโตแคสติกเกรเดียนต์เดสเซนท์ การปรับปรุงค่าน้ำหนักจะทำโดย

$$w_{jk,t}^l = w_{jk,t-1}^l - \alpha a_{k,t}^{l-1} \delta_{j,t}^l \quad (2.25)$$

เมื่อ $w_{jk,t}^l$ คือ ค่าน้ำหนักสำหรับเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l ที่มีเส้นเชื่อมมาจากเพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้นก่อนหน้า ณ จุด t

$w_{jk,t-1}^l$ คือ ค่าน้ำหนักสำหรับเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l ที่มีเส้นเชื่อมมาจากเพอร์เซ็ปตรอนตัวที่ k ในลำดับชั้นก่อนหน้า ณ จุด $t - 1$

α คือ อัตราการเรียนรู้

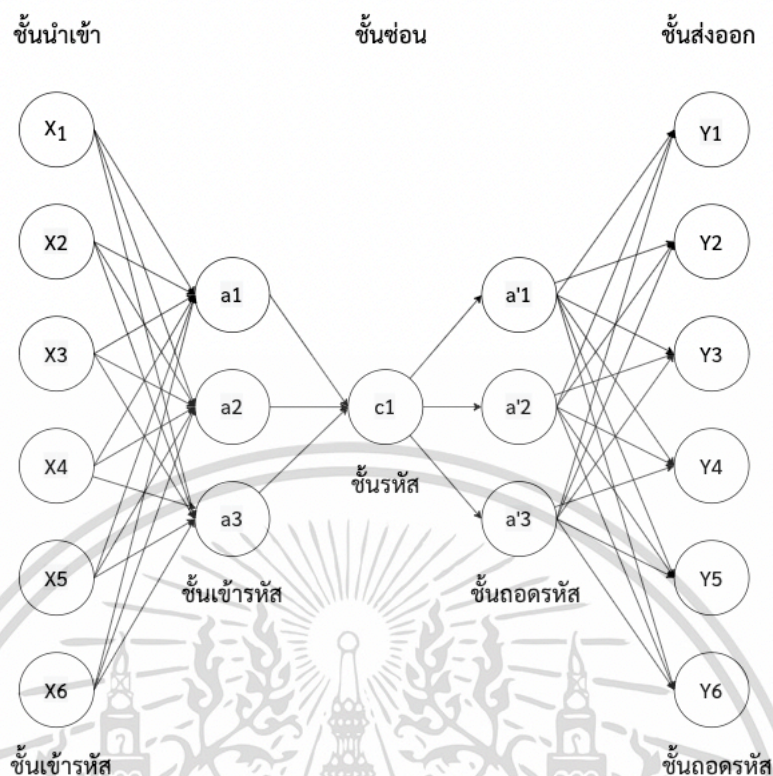
$a_{k,t}^{l-1}$ คือ ผลลัพธ์ของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้น $l - 1$ ณ จุด t

$\delta_{j,t}^l$ คือ ค่าความผิดพลาดของเพอร์เซ็ปตรอนตัวที่ j ในลำดับชั้นที่ l ณ จุด t

2.4 ตัวเข้ารหัสอัตโนมัติ (Autoencoder)

ตัวเข้ารหัสอัตโนมัติ [6] คือ ขั้นตอนวิธีพื้นฐานสำหรับนำไปประกอบเพื่อสร้างโครงข่ายประสาทเทียมชนิดหนึ่ง โดยการใช้งานตัวเข้ารหัสอัตโนมัติจะมีลักษณะคล้ายคลึงกับโครงข่ายประสาทเทียมทั่วไปที่มีชั้นนำเข้า ชั้นซ่อน และชั้นส่งออก โดยที่แตกต่างไปคือโครงข่ายประสาทเทียมจะเป็นการเรียนรู้แบบมีผู้สอน แต่ตัวเข้ารหัสอัตโนมัติจะเป็นการเรียนรู้แบบไม่มีผู้สอน กล่าวคือ เป็นเพียงการเรียนรู้ที่ต้องการให้ข้อมูลส่งออกมีลักษณะใกล้เคียงกับข้อมูลนำเข้า จึงเหมือนกับเป็นการฝึกข้อมูลนำเข้า x ให้เข้ารหัสเพื่อให้ได้ชั้นซ่อน $a = f(x)$ และสามารถถอดรหัสออกมาได้เป็น $y = g(a)$ ดังรูปที่


2.4



รูปที่ 2.4 แสดงโครงสร้างของโครงข่ายประสาทเทียมชนิดตัวเข้ารหัสอัตโนมัติ

ดังนั้นตัวแบบจะพยายามเรียนรู้ความสัมพันธ์ของชุดข้อมูลเพื่อที่จะสามารถบีบอัดหรือเข้ารหัสข้อมูลได้อย่างมีประสิทธิภาพ และยังเรียนรู้ที่จะถอดรหัสข้อมูลกลับออกมาจากชุดข้อมูลที่ถูกบีบอัดแล้วให้มีความใกล้เคียงกับต้นฉบับมากที่สุด ซึ่งการเรียนรู้ของตัวแบบจะทำการแพร่กลับเพื่อที่จะลดค่าการสูญเสียการสร้างใหม่ให้ได้น้อยที่สุด (Reconstruction Loss)

โครงสร้างของตัวเข้ารหัสอัตโนมัติประกอบไปด้วย 3 ส่วนหลักดังรูปที่ 2.5



รูปที่ 2.5 แสดงตัวอย่างลำดับการทำงานและผลลัพธ์ของตัวเข้ารหัสอัตโนมัติ

โดยในแต่ละส่วนมีความหมายดังนี้

1. ตัวเข้ารหัส (Encoder) เป็นชั้นที่จะเรียนรู้การลดขนาดมิติและบีบอัดข้อมูลต้นฉบับไปยังชั้นรหัส
2. ชั้นรหัส (Code) เป็นชั้นที่จะประกอบไปด้วยข้อมูลที่ถูกระบุบีบอัดแล้ว ซึ่งจะมีมิติที่น้อยที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- ตัวถอดรหัส (Decoder) เป็นชั้นที่จะเรียนรู้การสร้างข้อมูลกลับมาจากข้อมูลที่ถูกบีบอัดแล้วให้ใกล้เคียงต้นฉบับมากที่สุด ซึ่งสามารถวัดความใกล้เคียงได้จากค่าการสูญเสียการสร้างใหม่ระหว่างข้อมูลที่สร้างกลับมาและข้อมูลต้นฉบับ

2.5 งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับการศึกษานี้ทั้ง 6 ชิ้นจะสามารถถูกแบ่งงานวิจัยเป็น 2 ประเภทดังนี้ 1. การนำเอาการเรียนรู้แบบไม่มีผู้สอนมาใช้งานในงานด้านการตรวจจับความผิดปกติ 2. การปรับปรุงประสิทธิภาพของการทำการจำแนก ดังที่แสดงในตารางที่ 2.1 และตารางที่ 2.2 ตามลำดับ

ตารางที่ 2.1 แสดงงานวิจัยที่เกี่ยวข้องกับการนำเอาการเรียนรู้แบบไม่มีผู้สอนมาใช้งานในงานด้านการตรวจจับความผิดปกติ

ชื่องานวิจัย	วิธีที่นำเสนอ
Anomaly Detection Using Autoencoders with Nonlinear Dimensionality Reduction [7]	นำตัวเข้ารหัสอัตโนมัติมาประยุกต์ใช้ในงานตรวจจับความผิดปกติ
Unsupervised Learning Approach for Network Intrusion Detection System Using Autoencoders [8]	นำตัวเข้ารหัสอัตโนมัติมาประยุกต์ใช้ในงานระบบตรวจจับการบุกรุก
Unsupervised Clustering Approach for Network Anomaly Detection [11]	นำการเรียนรู้แบบไม่มีผู้สอนมาประยุกต์ใช้ในงานระบบตรวจจับการบุกรุก

ตารางที่ 2.2 แสดงงานวิจัยที่เกี่ยวข้องกับการปรับปรุงประสิทธิภาพของการทำการจำแนก

ชื่องานวิจัย	วิธีที่นำเสนอ
Dimensionality Reduction and Visualization of Network Intrusion Detection Data [9]	เปรียบเทียบประสิทธิภาพของ PCA และ ตัวเข้ารหัสอัตโนมัติในการลดมิติของข้อมูลก่อนที่จะนำไปฝึกสอนตัวแบบ
A hybrid Intrusion Detection System based on Sparse autoencoder and Deep Neural Network [10]	ประยุกต์ใช้วิธีผสมเทคนิคการทำวิศวกรรมข้อมูลและโครงข่ายประสาทเทียมเชิงลึกมาปรับปรุงประสิทธิภาพของการจำแนก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.2 แสดงงานวิจัยที่เกี่ยวข้องกับการปรับปรุงประสิทธิภาพของการทำการจำแนก (ต่อ)

ชื่องานวิจัย	วิธีที่นำเสนอ
An Intrusion Detection Model Based on Feature Reduction and Convolutional Neural Networks [3]	ประยุกต์ใช้วิธีลดจำนวนมิติข้อมูลเพื่อปรับปรุงประสิทธิภาพของการจำแนก

โดยรายละเอียดของงานวิจัยแต่ละกลุ่มตามตารางข้างต้นมีรายละเอียดอย่างย่อ ดังนี้

2.5.1 การนำเอาการเรียนรู้แบบไม่มีผู้สอนมาใช้งานในงานด้านการตรวจจับความผิดปกติ

1. งานวิจัยของ M. Sakurada และ T. Yairi [7] ได้นำเสนอการใช้ตัวเข้ารหัสอัตโนมัติเข้ามาประยุกต์ใช้ในการตรวจจับความผิดปกติข้อมูลการทำงานของยานอวกาศซึ่งมีจำนวนมิติของข้อมูลที่สูง โดยการใช้การลดมิติของข้อมูล ซึ่งได้มีการเปรียบเทียบกับวิธีวิเคราะห์องค์ประกอบหลัก (Linear PCA) และ วิธีวิเคราะห์องค์ประกอบหลักแบบใช้เคอร์เนล (Kernel PCA) ผลการทดลองปรากฏว่า ตัวเข้ารหัสอัตโนมัติมีประสิทธิภาพสูงสามารถแยกข้อมูลที่ผิดปกติได้ดีและใช้เวลาในการคำนวณต่ำกว่าเมื่อเปรียบเทียบกับวิธีการวิเคราะห์องค์ประกอบหลัก ซึ่งการวัดประสิทธิภาพจะใช้ค่า AUC เป็นตัวเปรียบเทียบโดยใช้ชุดข้อมูล Sat-A, Sat-B ได้ผลลัพธ์ดังตารางที่ 2.3

ตารางที่ 2.3 แสดงค่า AUC ของวิธีการทั้ง 4 แบบกับชุดข้อมูล Lorenz, Sat-A และ Sat-B

	LPCA	AE	dAE	KPCA
Lorenz	0.5104	0.6473	0.7011	0.7045
Sat-A	0.8852	0.8847	0.9354	0.8862
Sat-B	0.9764	0.9763	0.8355	0.7689

2. งานวิจัยของ H. Choi และคณะ [8] ได้นำเสนอระบบตรวจจับการบุกรุกระบบเครือข่ายโดยการใช้ตัวเข้ารหัสอัตโนมัติทั้ง 4 รูปแบบคือ ตัวเข้ารหัสอัตโนมัติแบบพื้นฐาน (Basic Autoencoder), ตัวเข้ารหัสอัตโนมัติประเภทลดสัญญาณรบกวน (Denoising Autoencoder), ตัวเข้ารหัสอัตโนมัติแบบซ้อน (Stacked Autoencoder) และ ตัวเข้ารหัสอัตโนมัติแบบแปรผัน (Variational Autoencoder) โดยผลการทดลองปรากฏว่าประสิทธิภาพที่ได้จากตัวเข้ารหัสอัตโนมัติทุกรูปแบบมีประสิทธิภาพสูงโดยมีความแม่นยำสูงสุดถึง 91.70% เมื่อเทียบกับวิธีการเรียนรู้แบบไม่มี

ผู้สอนแบบการจัดกลุ่มที่มีความแม่นยำ 80% และงานวิจัยนี้ยังแสดงให้เห็นอีกว่าตัวเข้ารหัสอัตโนมัติสามารถจัดการกับชุดข้อมูลที่มีจำนวนข้อมูลในคลาสที่แตกต่างกันมาก

3. งานวิจัยของ I. Syarif และคณะ [11] ได้อธิบายประโยชน์ของการใช้การเรียนรู้แบบไม่มีผู้สอนในการตรวจจับการบุกรุกระบบเครือข่ายจากการเปรียบเทียบประสิทธิภาพของวิธีการจัดกลุ่มเมื่อถูกนำมาใช้กับการตรวจจับความผิดปกติ จากการทดลองโดยใช้ชุดข้อมูลที่มีการบุกรุกที่ไม่รู้จักปรากฏว่า วิธีการตรวจจับแบบใช้กฎมีความแม่นยำที่ 63.97% แต่วิธีการจัดกลุ่มที่ได้ถูกนำมาเปรียบเทียบมีความแม่นยำสูงมากที่สุดที่ 80.15% ดังตารางที่ 2.4 แต่วิธีการจัดกลุ่มยังมีอัตราผลบวกเท็จที่สูง จึงต้องมีการศึกษาเพิ่มเติมเกี่ยวกับการปรับปรุงประสิทธิภาพของตัวแบบ

ตารางที่ 2.4 แสดงค่าความแม่นยำของวิธีการจัดกลุ่ม

	ความแม่นยำ	อัตราผลบวกเท็จ
k-Means	57.81%	22.95%
Improved k-Means	65.40%	21.52%
k-Medoids	76.71%	21.83%
EM Clustering	78.06%	20.74%
Distance-based outlier	80.15%	21.14%


งานวิจัยในกลุ่มนี้แสดงให้เห็นถึงความสามารถในการนำตัวเข้ารหัสอัตโนมัติซึ่งเป็นการเรียนรู้แบบไม่มีผู้สอนเข้ามาใช้งานในการจำแนกข้อมูลที่มีความผิดปกติในขอบเขตระบบตรวจจับการบุกรุกระบบเครือข่ายอีกทั้งยังสามารถจัดการกับชุดข้อมูลที่มีจำนวนข้อมูลในคลาสที่แตกต่างกันมากได้ดี แต่งานวิจัยทั้งสามชิ้นเป็นเพียงแค่การประยุกต์ใช้ตัวเข้ารหัสอัตโนมัติเพียงอย่างเดียวโดยที่ไม่ได้มีการใช้เทคนิคอื่น ๆ เพิ่มเติมจึงอาจจะยังไม่ได้ผลลัพธ์ที่ดีที่สุด

2.5.2 การปรับปรุงประสิทธิภาพของการทำการจำแนก

1. งานวิจัยของ Y. Chow และ W. Susilo [9] ได้นำเสนอถึงการเปรียบเทียบประสิทธิภาพของเทคนิคการลดมิติของข้อมูลเมื่อนำชุดข้อมูลที่ลดมิติแล้วไปใช้ทำการจำแนกต่อ 2 วิธีคือ 1. การวิเคราะห์องค์ประกอบหลัก และ 2. ตัวเข้ารหัสอัตโนมัติ โดยการทดลองจะใช้ชุดข้อมูลของระบบตรวจจับการบุกรุกระบบเครือข่าย 2 ฐานข้อมูลคือ NSL KDD และ UNSW-NB15 โดยขั้นตอน

การเปรียบเทียบประสิทธิภาพจะทำการลดมิติของข้อมูลแล้วจึงนำชุดข้อมูลที่ได้ไปจำแนก โดยผลการเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ทดลองปรากฏว่า ชุดข้อมูลที่ถูกลดมิติของข้อมูลด้วยตัวเข้ารหัสอัตโนมัติมีความสามารถในการสร้างตัวแบบที่มีประสิทธิภาพที่ดีกว่าการใช้ชุดข้อมูลที่ลดมิติข้อมูลด้วยการวิเคราะห์องค์ประกอบหลักดังรูปที่ 2.6



รูปที่ 2.6 แสดงการเปรียบเทียบความแม่นยำของวิธีที่งานวิจัยนำเสนอ[9]

2. งานวิจัยของ K. Narayana Rao และคณะ [10] ได้นำเสนอวิธีการแบบผสม 2 ขั้นตอนสำหรับการตรวจจับการบุกรุก โดยในขั้นตอนแรกนั้นจะนำตัวเข้ารหัสอัตโนมัติมาใช้สำหรับการทำวิศวกรรมคุณลักษณะ และขั้นตอนที่สองคือการนำโครงข่ายประสาทเทียมเชิงลึกมาใช้ทำนายและจำแนก โดยผลการทดลองปรากฏว่า SAE-DNN มีความแม่นยำสูงสุดเมื่อเทียบกับวิธีอื่น ๆ บนชุดข้อมูล KDDCup99 NSL-KDD และ UNSW-NB15 ดังที่แสดงในตารางที่ 2.5 – 2.7

ตารางที่ 2.5 แสดงประสิทธิภาพของ SAE-DNN เมื่อเทียบกับวิธีอื่น ๆ บนชุดข้อมูล KDDCup99

วิธีการ	ความแม่นยำ	อัตราตรวจจับ	F1	FPR
LSTM-RNN	96.93	98.88	NA	10.04
RBM-DBN	97.16	NA	NA	0.48
CNN-GRU	98.1	97.6	98.8	NA
Multi-scale CNN	94.11	93.21	NA	2.18
CFA	91.98	91.00	NA	3.917
AE+DBN	92.10	92.20	NA	NA
SAE-DNN	99.03	99.48	99.14	1.55

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.6 แสดงประสิทธิภาพของ SAE-DNN เมื่อเทียบกับวิธีอื่น ๆ บนชุดข้อมูล NSL-KDD

วิธีการ	ความแม่นยำ	อัตราตรวจจับ	F1	FPR
SAE-SVM	80.48	NA	NA	NA
S-NDAE	85.42	85.42	87.37	14.58
ID-CVAE	80.10	80.10	79.08	8.18
SAVER-DNN	89.36	95.98	90.08	4.70
SSAE-SVM	99.35	99.01	NA	0.13
SAE-DNN	99.71	99.72	99.74	0.30

ตารางที่ 2.7 แสดงประสิทธิภาพของ SAE-DNN เมื่อเทียบกับวิธีอื่น ๆ บนชุดข้อมูล UNSW-NB15

วิธีการ	ความแม่นยำ	อัตราตรวจจับ	F1	FPR
TSDL	89.13	NA	NA	0.749
Random tree + NB Tree	89.24	83.90	NA	NA
CASCADE-ANN	86.40	86.74	NA	13.1
SAVAER-DNN	93.01	91.94	93.54	5.67
SAE-DNN	99.98	99.99	99.98	0.17

3. งานวิจัยของ Y. Xiao และคณะ [11] ได้นำเสนอวิธีการนำการลดมิติข้อมูลและโครงข่ายประสาทเทียมแบบคอนโวลูชันมาใช้เพื่อปรับปรุงประสิทธิภาพของตัวแบบสำหรับระบบตรวจจับการบุกรุกระบบเครือข่าย โดยวิธีการลดมิติข้อมูลได้นำเอาวิธีการสองแบบมาทดสอบได้แก่ตัวเข้ารหัสอัตโนมัติและ PCA ผลการทดลองปรากฏว่าตัวแบบที่งานวิจัยนำเสนอมีความแม่นยำมากขึ้นและใช้เวลาการทำงานลดลงเมื่อเปรียบเทียบกับวิธีในอดีต

งานวิจัยในกลุ่มนี้แสดงให้เห็นว่าการทำวิศวกรรมคุณลักษณะ (Feature Engineering) เช่น การลดมิติของข้อมูลก่อนที่จะนำไปฝึกสอนตัวแบบ ทำให้ประสิทธิภาพของตัวแบบมีความแม่นยำเพิ่มมากขึ้น โดยที่งานวิจัยของ K. Narayana Rao และคณะ ยังแสดงให้เห็นเพิ่มเติมว่าเมื่อนำเทคนิคการทำวิศวกรรมคุณลักษณะเข้ามาผสมกับการใช้โครงข่ายประสาทเทียมแบบลึก สามารถทำให้เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประสิทธิภาพของโครงข่ายประสาทเทียมแบบลึกดีขึ้น แต่การทดลองทุกงานนั้น ในส่วนของการ
จำแนกยังคงใช้ตัวแบบประเภทการเรียนรู้แบบมีผู้สอน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3

วิธีการดำเนินงานวิจัย

ในบทนี้จะกล่าวถึงวิธีการดำเนินงานซึ่งเป็นขั้นตอนการปฏิบัติงานทั้งหมดในการศึกษานี้ โดยที่การศึกษานี้คือการศึกษากการประยุกต์นำเอาการเรียนรู้เชิงลึกประเภทตัวเข้ารหัสอัตโนมัติซึ่งเป็นการเรียนรู้แบบที่ไม่มีผู้สอน มาใช้จำแนกหาข้อมูลที่บ่งชี้ถึงการบุกรุกในชุดข้อมูลการจราจรของระบบเครือข่าย UNSW-NB15 โดยที่ขั้นตอนดำเนินงานวิจัยแบ่งออกเป็น 4 ขั้นตอนหลัก ได้แก่ การเก็บข้อมูล การเตรียมข้อมูล การสร้างตัวแบบ และการวัดประสิทธิภาพของตัวแบบดังรูปที่ 3.1



3.1 ชุดข้อมูล (Dataset)

ชุดข้อมูลที่ผู้วิจัยใช้คือชุดข้อมูล UNSW-NB15 [2] เป็นชุดข้อมูลที่ถูกพัฒนาโดย Australian Centre for Cyber Security โดยการผสมผสานระหว่างข้อมูลปกติของจริงและข้อมูลการโจมตีที่ถูกสังเคราะห์ขึ้นมา โดยที่ชุดข้อมูลนี้จะประกอบไปด้วยการโจมตี 9 ประเภทได้แก่ DoS, Analysis, Generic, Fuzzers, Back-doors, Exploits, Shellcode, Reconnaissance และ Worms ซึ่งจะประกอบไปด้วยตัวอย่างข้อมูลเรียนรู้ทั้งหมด 175,341 ตัวอย่างและตัวอย่างข้อมูลทดสอบทั้งหมด 82,332 ตัวอย่าง ซึ่งแต่ละชุดข้อมูลจะมีคุณลักษณะทั้งหมด 49 ตัวดังที่แสดงในตารางที่ 3.1 และจะมีฉลากคำตอบที่จะใช้ระบุว่าการจราจรของระบบเครือข่ายนี้เป็นแบบปกติหรือแบบไม่ปกติ โดยที่การแจกแจงของตัวอย่างจะมีค่าดังตารางที่ 3.2 การศึกษาครั้งนี้ผู้วิจัยจะรวมชุดข้อมูลทั้งชุดข้อมูลสำหรับการเรียนรู้และชุดข้อมูลสำหรับการทดสอบมาเป็นชุดข้อมูลเดียวกัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 แสดงข้อมูลคุณลักษณะของชุดข้อมูล UNSW-NB15

หลักที่	ชื่อ	ชนิด	รายละเอียด
1	srcip	Nominal	ไอพีเครื่องต้นทาง
2	sport	Integer	พอร์ตเครื่องต้นทาง
3	dstip	Nominal	ไอพีเครื่องปลายทาง
4	dsport	Integer	พอร์ตเครื่องปลายทาง
5	proto	Nominal	โปรโตคอลการทำธุรกรรม
6	state	Nominal	สถานะของโปรโตคอล เช่น ACC, CON, ECO
7	dur	Float	ระยะเวลารวมทั้งหมด
8	sbytes	Integer	ไบต์ธุรกรรมจากต้นทางถึงปลายทาง
9	dbytes	Integer	ไบต์ธุรกรรมจากปลายทางถึงต้นทาง
10	sctl	Integer	ค่าที่ที่แอสของต้นทางถึงปลายทาง
11	dctl	Integer	ค่าที่ที่แอสของปลายทางถึงต้นทาง
12	sloss	Integer	แพ็คเก็ตต้นทางที่สูญหาย
13	dloss	Integer	แพ็คเก็ตปลายทางที่สูญหาย
14	service	Nominal	บริการ เช่น http, ftp, smtp
15	Sload	Float	ค่าบิตต่อวินาทีของต้นทาง
16	Dload	Float	ค่าบิตต่อวินาทีของปลายทาง
17	Spkts	Integer	จำนวนแพ็คเก็ตต้นทางถึงปลายทาง
18	Dpkts	Integer	จำนวนแพ็คเก็ตปลายทางถึงต้นทาง
19	swin	Integer	ค่าขนาดช่องทางที่ซีพีทีที่โฆษณาต้นทาง
20	dwin	Integer	ค่าขนาดช่องทางที่ซีพีทีที่โฆษณาปลายทาง
21	stcpb	Integer	ค่าลำดับพื้นฐานของทีซีพีต้นทาง
22	dtcpb	Integer	ค่าลำดับพื้นฐานของทีซีพีปลายทาง
23	smeansz	Integer	ค่าเฉลี่ยขนาดของแพ็คเก็ตที่ถูกส่งโดยต้นทาง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 แสดงข้อมูลคุณลักษณะของชุดข้อมูล UNSW-NB15 (ต่อ)

หลักที่	ชื่อ	ชนิด	รายละเอียด
24	dmeansz	Integer	ค่าเฉลี่ยขนาดของแพ็คเก็ตที่ถูกส่งโดยปลายทาง
25	trans_depth	Integer	ความลึกของท่อของการเชื่อมต่อของเอชทีทีพี
26	res_bdy_len	Integer	ขนาดของข้อมูลก่อนบีบอัดที่ถูกส่งจากตัวบริการ
27	Sjit	Float	ความช้าในการรับแพ็คเก็ตต้นทาง
28	Djit	Float	ความช้าในการรับแพ็คเก็ตปลายทาง
29	Stime	Timestamp	เวลาเริ่มการบันทึก
30	Ltime	Timestamp	เวลาสิ้นสุดการบันทึก
31	Sintpkt	Float	ระยะเวลามาถึงของอินเตอร์แพ็คเก็ตต้นทาง
32	Dintpkt	Float	ระยะเวลามาถึงของอินเตอร์แพ็คเก็ตปลายทาง
33	tcprrt	Float	เวลาครบรอบของการเชื่อมต่อที่ซีพี
34	synack	Float	ระยะเวลาระหว่างแพ็คเก็ต SYN และ SYN_ACK
35	ackdat	Float	ระยะเวลาระหว่างแพ็คเก็ต SYN_ACK และ SYN
36	is_sm_ips_ports	Binary	มีค่า 1 ถ้าไอพีและพอร์ตของต้นทางและปลายทางเหมือนกัน
37	ct_state_ttl	Integer	จำนวนของ state ตามช่วงของค่าที่ที่แอล
38	ct_flw_http_mthd	Integer	จำนวนของกระแสที่เป็นกระบวนการเอชทีทีพี
39	is_ftp_login	Binary	มีค่า 1 ถ้าเอชทีทีพีถูกใช้งานผ่านรหัสผ่าน
40	ct_ftp_cmd	Integer	จำนวนของคำสั่งที่ใช้ผ่านเอชทีทีพี
41	ct_srv_src	Integer	จำนวนของการเชื่อมต่อที่ใช้บริการและที่อยู่ต้นทางเดียวกันจาก 100 การเชื่อมต่อล่าสุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 แสดงข้อมูลคุณลักษณะของชุดข้อมูล UNSW-NB15 (ต่อ)

หลักที่	ชื่อ	ชนิด	รายละเอียด
42	ct_srv_dst	Integer	จำนวนของการเชื่อมต่อที่ใช้บริการและที่อยู่ปลายทางเดียวกันจาก 100 การเชื่อมต่อล่าสุด
43	ct_dst_ltm	Integer	จำนวนของการเชื่อมต่อที่มีที่อยู่ปลายทางเดียวกันจาก 100 การเชื่อมต่อล่าสุด
44	ct_src_ltm	Integer	จำนวนของการเชื่อมต่อที่มีที่อยู่ต้นทางเดียวกันจาก 100 การเชื่อมต่อล่าสุด
45	ct_src_dport_ltm	Integer	จำนวนของการเชื่อมต่อที่มีที่อยู่ต้นทางและพอร์ตปลายทางเดียวกันจาก 100 การเชื่อมต่อล่าสุด
46	ct_dst_sport_ltm	Integer	จำนวนของการเชื่อมต่อที่มีที่อยู่ปลายทางและพอร์ตต้นทางเดียวกันจาก 100 การเชื่อมต่อล่าสุด
47	ct_dst_src_ltm	Integer	จำนวนของการเชื่อมต่อที่มีที่อยู่ต้นทางและที่อยู่ปลายทางเดียวกันจาก 100 การเชื่อมต่อล่าสุด
48	attack_cat	Nominal	ชื่อกลุ่มการโจมตี
49	label	Binary	จะมีค่า 0 ถ้าเป็นปกติ และมีค่า 1 ถ้าเป็นการโจมตี

ตารางที่ 3.2 แสดงการแจกแจงของข้อมูลที่มีในฐานข้อมูล UNSW-NB15

ประเภท	ชุดข้อมูลฝึกสอน	ชุดข้อมูลทดสอบ
ปกติ	56,000	37,000
โจมตี	119,341	45,332
รวม	175,341	82,332

โดยที่ชุดข้อมูลนี้จะมีรูปแบบข้อมูลเป็นแบบค่าที่ถูกแบ่งด้วยจุลภาค (CSV) ดังรูปที่ 3.2 เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.3 แสดงตัวอย่างผลลัพธ์ของการเข้ารหัสด้วยวิธีการสร้างตัวแปรหุ่นของคุณลักษณะ state ที่มีค่า CON (ต่อ)

Feature ที่สร้างขึ้นใหม่	ค่าของข้อมูล
state_RST	0
state_URN	0
state_no	0

3.2.2 การทำให้ค่าเป็นมาตรฐาน (Standardization)

ช่วงขอบเขตของข้อมูลในชุดข้อมูลมีความแตกต่างกันอย่างมาก ทำให้มีความจำเป็นในการปรับช่วงขอบเขตของข้อมูลแต่ละคุณลักษณะให้อยู่ในช่วงเดียวกัน เพื่อให้เหมาะสมกับการนำไปประมวลผลต่อ ในการศึกษาเลือกวิธีการทำให้เป็นมาตรฐานแซด (Z-Score Normalization) มาใช้ปรับขอบเขตของข้อมูล โดยตัวอย่างของการทำให้ค่าเป็นมาตรฐานได้แสดงตามตารางที่ 3.4

ตารางที่ 3.4 แสดงตัวอย่างผลลัพธ์ของการทำให้ค่าเป็นมาตรฐาน

ชื่อคุณลักษณะ	ค่าต้นฉบับ	ค่าหลังจากทำให้เป็นมาตรฐานแล้ว
dur	0.121478	-0.188346
spkts	6	-0.101342
dpkts	4	-0.129612
sbytes	258	-0.047849
dbytes	172	-0.097232
rate	74.08749	-0.56865

3.2.3 การลดมิติข้อมูล (Dimensionality Reduction)

ชุดข้อมูลมีจำนวนคุณลักษณะเป็นจำนวนมาก ซึ่งบางคุณลักษณะอาจจะไม่มีข้อมูลที่ เป็นประโยชน์ในการวิเคราะห์และจะส่งผลกระทบต่อความถูกต้องของการประมวลผล นอกจากนี้ยัง ทำให้สิ้นเปลืองทรัพยากรในการประมวลผล ขั้นตอนการลดมิติข้อมูลจึงมีความสำคัญในการเตรียม ข้อมูล ในการศึกษาเลือกวิธีการการวิเคราะห์องค์ประกอบหลักมาใช้ลดมิติของชุดข้อมูล และ กำหนดให้ลดจำนวนมิติของข้อมูลให้เหลือเพียง 128 ตัว


3.3 การสร้างตัวแบบ (Modeling)

ในการศึกษานี้จะสร้างตัวแบบสำหรับการจำแนกโดยใช้การเรียนรู้แบบไม่มีผู้สอนซึ่งเป็น ขั้นตอนวิธีการเรียนรู้แบบที่ไม่ต้องระบุผลตอบในชุดข้อมูล โดยที่การศึกษานี้จะเลือกใช้การ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยามให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เรียนรู้เชิงลึกประเภทตัวเข้ารหัสอัตโนมัติมาใช้ เนื่องจากชุดข้อมูลการจราจรของระบบเครือข่ายโดยปกติจะมีอัตราส่วนของข้อมูลการบุกรุกที่น้อยมากเมื่อเทียบกับข้อมูลการใช้ระบบเครือข่ายแบบปกติ แต่ชุดข้อมูลประเภทนี้จะมีจำนวนข้อมูลเป็นจำนวนมาก ทำให้ถ้าต้องมาระบุคำตอบสำหรับทุกข้อมูลที่ผู้ใช้ฝึกสอนจะสิ้นเปลืองทรัพยากรมาก ผู้วิจัยจึงมีแนวคิดว่าการประยุกต์นำตัวเข้ารหัสอัตโนมัติมาฝึกสอนด้วยชุดข้อมูลประเภทนี้ จะสามารถเข้าช่วยแก้ปัญหาชุดข้อมูลที่ไม่มีฉลากคำตอบมาให้ได้

3.3.1 การออกแบบขั้นตอนการฝึกสอนตัวแบบ

ขั้นตอนการฝึกสอนตัวแบบจะถูกแบ่งออกเป็น 3 ขั้นตอนหลักดังรูปที่ 3.4



รูปที่ 3.4 แสดงขั้นตอนการสร้างตัวแบบ

โดยที่ในแต่ละขั้นตอนจะมีการทำงานดังนี้

1. การแบ่งชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบ
เป็นขั้นตอนที่จะแบ่งชุดข้อมูลเป็น 2 ชุดคือ ชุดข้อมูลฝึกฝน 70% และ ชุดข้อมูลทดสอบ 30% การแยกชุดข้อมูลเป็น 2 ชุดจะทำให้วัดประสิทธิภาพของตัวแบบได้ถูกต้องมากขึ้น
2. การฝึกสอนตัวแบบประเภทตัวเข้ารหัสอัตโนมัติ
จากการฝึกสอนตัวแบบด้วยชุดข้อมูลที่เป็นปกติ จะทำให้ตัวแบบรู้จักถึงความสัมพันธ์ของลักษณะข้อมูล ส่งผลให้ตัวแบบมีความสามารถในการถอดรหัสข้อมูลที่เป็นปกติกลับมาโดยที่มีค่าการสูญเสียการสร้างใหม่ที่ต่ำ
3. การจำแนกชุดข้อมูลโดยการใช้ค่าการสูญเสียการสร้างใหม่
ในขั้นตอนการจำแนกจะต้องระบุค่าเกณฑ์ (Threshold) ขึ้นมา เพื่อที่จะนำไปเปรียบเทียบกับค่าการสูญเสียการสร้างใหม่ที่ได้จากการถอดรหัส ถ้าค่าการสูญเสียการสร้างใหม่มีค่าสูงกว่าค่าเกณฑ์ให้ระบุว่าข้อมูลนั้นเป็นประเภทผิดปกติ ซึ่งในการศึกษานี้ผู้วิจัยจะใช้วิธีการดูแผนภาพฮิสโทแกรมของค่าการสูญเสียเพื่อหาค่าเกณฑ์ที่เหมาะสม

3.3.2 หาโครงสร้างของตัวเข้ารหัสอัตโนมัติที่เหมาะสม

จากการศึกษาโครงสร้างของตัวเข้ารหัสอัตโนมัติ แนวคิดของตัวเข้ารหัสอัตโนมัติคือการบังคับให้ตัวแบบบีบอัดชุดข้อมูลนำเข้าเพื่อให้ได้ข้อมูลรหัสออกมา จากนั้นตัวแบบจะถอดรหัสจากข้อมูลรหัสให้ออกมาคล้ายข้อมูลนำเข้าให้มากที่สุด ซึ่งโครงสร้างโดยทั่วไปของของตัวเข้ารหัสอัตโนมัติเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จะประกอบไปด้วย 3 ส่วนคือ ตัวเข้ารหัส ชั้นรหัส และตัวถอดรหัส โดยที่จำนวนชั้นของตัวเข้ารหัสนั้นจะต้องเท่ากับจำนวนชั้นของตัวถอดรหัส และในส่วนของจำนวนนิวรอนของชั้นซ่อนไม่ได้ถูกระบุไว้ว่าควรจะมีค่าเท่าไร แต่จะมีจำนวนน้อยกว่าจำนวนนิวรอนของชั้นนำเข้าและชั้นส่งออกซึ่งจะมีลักษณะของโครงสร้างคล้ายกับการถูกบีบเป็นนาฬิกาทรายขวางดังรูปที่ 2.4 ดังนั้นการทดลองนี้จึงได้ถูกแบ่งออกตามจำนวนชั้นซ่อนของตัวเข้ารหัสอัตโนมัติได้ 5 แบบดังตารางที่ 3.5 – 3.9

ตารางที่ 3.5 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 1 ชั้น

ลำดับ	ประเภทชั้น	ชนิด	จำนวนนิวรอน	ชนิดฟังก์ชันกระตุ้น
1	Input layer (encoder)	-	128	-
2	Hidden layer (code)	Fully Connected	64	ReLU
3	Output layer (decoder)	Fully Connected	128	ReLU

ตารางที่ 3.6 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 3 ชั้น

ลำดับ	ประเภทชั้น	ชนิด	จำนวนนิวรอน	ชนิดฟังก์ชันกระตุ้น
1	Input layer (encoder)	-	128	-
2	Hidden layer (encoder)	Fully Connected	64	ReLU
3	Hidden layer (code)	Fully Connected	32	ReLU
4	Hidden layer (decoder)	Fully Connected	64	ReLU
5	Output layer (decoder)	Fully Connected	128	Linear

ตารางที่ 3.7 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 5 ชั้น

ลำดับ	ประเภทชั้น	ชนิด	จำนวนนิวรอน	ชนิดฟังก์ชันกระตุ้น
1	Input layer (encoder)	-	128	-

เอกสารนี้เป็นเอกสารสงวนลิขสิทธิ์การใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้拿去ใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.7 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 5 ชั้น (ต่อ)

ลำดับ	ประเภทชั้น	ชนิด	จำนวนนิวรอน	ชนิดฟังก์ชันกระตุ้น
2	Hidden layer (encoder)	Fully Connected	64	ReLU
3	Hidden layer (encoder)	Fully Connected	32	ReLU
4	Hidden layer (code)	Fully Connected	16	ReLU
5	Hidden layer (decoder)	Fully Connected	32	ReLU
6	Hidden layer (decoder)	Fully Connected	64	ReLU
7	Output layer (decoder)	Fully Connected	128	Linear

ตารางที่ 3.8 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้น

ลำดับ	ประเภทชั้น	ชนิด	จำนวนนิวรอน	ชนิดฟังก์ชันกระตุ้น
1	Input layer (encoder)	-	128	-
2	Hidden layer (encoder)	Fully Connected	64	ReLU
3	Hidden layer (encoder)	Fully Connected	32	ReLU
4	Hidden layer (encoder)	Fully Connected	16	ReLU
5	Hidden layer (code)	Fully Connected	8	ReLU
6	Hidden layer (decoder)	Fully Connected	16	ReLU
7	Hidden layer (decoder)	Fully Connected	32	ReLU

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.8 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้น (ต่อ)

ลำดับ	ประเภทชั้น	ชนิด	จำนวนนิวรอน	ชนิดฟังก์ชันกระตุ้น
8	Hidden layer (decoder)	Fully Connected	64	ReLU
9	Output layer (decoder)	Fully Connected	128	Linear

ตารางที่ 3.9 แสดงโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 9 ชั้น

ลำดับ	ประเภทชั้น	ชนิด	จำนวนนิวรอน	ชนิดฟังก์ชันกระตุ้น
1	Input layer (encoder)	-	128	-
2	Hidden layer (encoder)	Fully Connected	64	ReLU
3	Hidden layer (encoder)	Fully Connected	32	ReLU
4	Hidden layer (encoder)	Fully Connected	16	ReLU
5	Hidden layer (encoder)	Fully Connected	8	ReLU
6	Hidden layer (code)	Fully Connected	4	ReLU
7	Hidden layer (decoder)	Fully Connected	8	ReLU
8	Hidden layer (decoder)	Fully Connected	16	ReLU
9	Hidden layer (decoder)	Fully Connected	32	ReLU
10	Hidden layer (decoder)	Fully Connected	64	ReLU
11	Output layer (decoder)	Fully Connected	128	Linear

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยจะกำหนด Hyperparameters ที่ใช้สำหรับการเปรียบเทียบโครงสร้างของตัวแบบดัง ตารางที่ 3.10 ซึ่งค่าของ Hyperparameter แต่ละประเภทที่ถูกเลือกมานั้นมีประสิทธิภาพเพียงพอที่จะทำให้เปรียบเทียบประสิทธิภาพของตัวแบบได้

ตารางที่ 3.10 แสดงค่า Hyperparameters ที่ใช้ในการหาโครงสร้างของตัวแบบ

ชื่อ	ค่าที่กำหนด
Epoch	100
Batch size	256
Optimizer	Adam
Loss function	MAE
Learning rate	0.001

3.3.3 หาค่า Hyperparameters ที่เหมาะสม

Hyperparameters ที่ต้องทดลองหาค่าที่เหมาะสมและเกี่ยวข้องกับการฝึกสอนตัวแบบ มีดังต่อไปนี้

1. Epoch เป็นจำนวนรอบของการฝึกสอน
2. Batch size เป็นจำนวนชุดข้อมูลที่จะให้ Optimizer คำนวณใน 1 ครั้ง
3. Loss function เป็นฟังก์ชันสำหรับคำนวณค่าการสูญเสีย
4. Learning rate เป็นค่าที่ใช้กำหนดว่าการปรับค่าน้ำหนักในแต่ละรอบการฝึกสอนจะมากหรือน้อยเท่าใด

3.4 การวัดประสิทธิภาพของตัวแบบ (Performance Evaluation)

ในการศึกษาชุดข้อมูลสำหรับฝึกสอนได้ถูกแบ่งอัตราส่วนระหว่างข้อมูลปกติและข้อมูลผิดปกติเป็น 4 ประเภทเพื่อจำลองสถานการณ์ของชุดข้อมูลจริงที่อาจจะเป็นไปได้ดังนี้

1. ข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%
2. ข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%
3. ข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%
4. ข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%

ซึ่งการวัดประสิทธิภาพของตัวแบบจะใช้ค่าความแม่นยำ ค่าความเที่ยง ค่าเรียกคืน และค่าคะแนนเอฟ ถ้ามีค่าสูงแสดงว่าตัวแบบมีประสิทธิภาพในการตรวจจับสูง โดยจะพิจารณาเปรียบเทียบระหว่างชุดข้อมูลเรียนรู้ทั้ง 4 แบบข้างต้น

บทที่ 4

ผลการวิจัยและการอภิปรายผล

ในบทนี้จะกล่าวถึงการกำหนดโครงสร้างของตัวเข้ารหัสอัตโนมัติที่ใช้ในการทดสอบ ผลการศึกษาและทดสอบประสิทธิภาพของการนำเอาการเรียนรู้แบบไม่มีผู้สอนประเภทตัวเข้ารหัสอัตโนมัติมาฝึกสอนเพื่อใช้สร้างตัวแบบสำหรับตรวจจับการบุกรุกระบบเครือข่าย และปัญหาที่พบจากการศึกษา

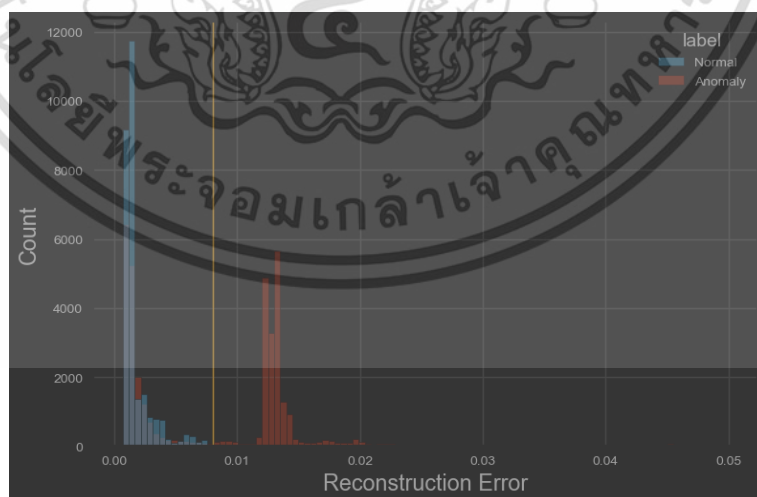
4.1 การกำหนดโครงสร้างของตัวเข้ารหัสอัตโนมัติที่ใช้ในการทดสอบ

จากการทดลองปรับค่าและดูประสิทธิภาพของตัวแบบที่สร้างจากชุดข้อมูลปกติ 100% เพื่อที่จะเลือกโครงสร้างที่มีประสิทธิภาพกับการใช้จำแนกข้อมูล การทดลองถูกแบ่งเป็นสองส่วนคือ

1. การหาโครงสร้างของตัวเข้ารหัสอัตโนมัติ และ
2. การหาค่า Hyperparameters ที่เหมาะสม


4.1.1 การหาโครงสร้างของตัวเข้ารหัสอัตโนมัติ

จากทดลองพบว่าตัวแบบที่มีโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้นมีความสามารถในการแยกแยะชุดข้อมูลที่ผิดปกติออกจากชุดข้อมูลที่ปกติได้ดีที่สุด โดยการเปรียบเทียบแผนภาพฮิสโทแกรมของค่าการสูญเสียระหว่างข้อมูลที่เป็นปกติ (สีฟ้า) และข้อมูลที่ผิดปกติ (สีแดง) ดังรูปที่ 4.1 – 4.5




รูปที่ 4.1 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 1 ชั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.2 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 3 ชั้น




รูปที่ 4.3 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 5 ชั้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.4 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้น



รูปที่ 4.5 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 9 ชั้น

และเมื่อเปรียบนำค่าประสิทธิภาพของตัวแบบมาเปรียบเทียบกับตารางที่ 4.1 จะพบว่าตัวแบบที่มีโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้นมีประสิทธิภาพดีที่สุด ซึ่งสอดคล้องไปกับผลลัพธ์ที่แสดงจากฮิสโทแกรม ดังนั้นผู้วิจัยจึงเลือกโครงสร้างของตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้น ไปใช้หาค่า Hyperparameter ต่อไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.1 แสดงตารางเปรียบเทียบประสิทธิภาพของตัวแบบที่มีชั้นซ่อน 1-7 ชั้น

	จำนวนชั้นซ่อน				
	1	3	5	7	9
Accuracy	0.77	0.80	0.80	0.81	0.76
Precision	0.80	0.79	0.79	0.81	0.73
Recall	0.82	0.81	0.80	0.83	0.74
F1-Score	0.77	0.79	0.79	0.80	0.74

4.1.2 การหาค่า Hyperparameters ที่เหมาะสม

จากการทดลองโดยการกำหนดค่า Hyperparameters บนโครงสร้างตัวเข้ารหัสอัตโนมัติที่มีชั้นซ่อน 7 ชั้น ได้ผลได้ดังนี้

1. Epoch

จากการทดลองพบว่า ตัวแบบสามารถฝึกสอนได้ถึง 1000 รอบโดยที่ค่าการสูญเสียได้น้อยลงตามจำนวนรอบที่ฝึกสอนดังรูปที่ 4.6 และยังไม่ก่อให้เกิดการท่องจำ (Overfitting) อีกทั้งยังใช้เวลาในการฝึกสอนไม่มากเกินไป ผู้วิจัยจึงเลือกค่า 1000 รอบมาใช้งาน



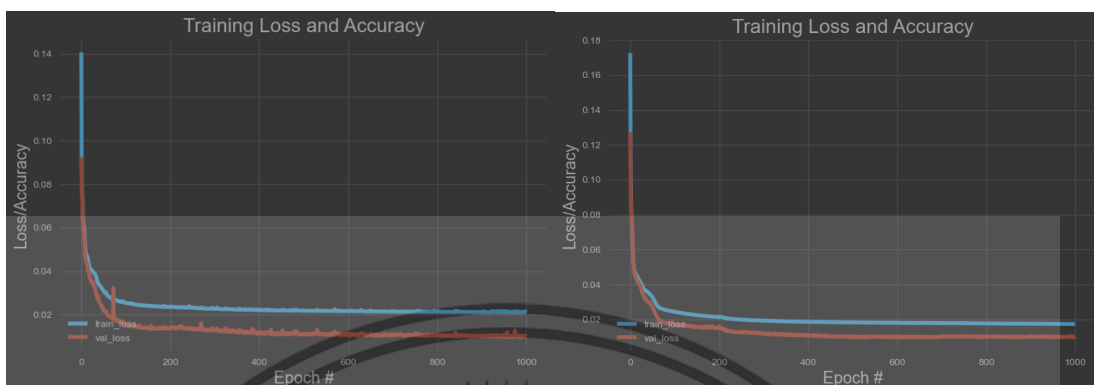
รูปที่ 4.6 แสดงค่าการสูญเสียของการฝึกสอน 0 – 1000 รอบ

2. Batch size

จากการทดลองพบว่า ค่านี้ไม่ได้ส่งผลถึงประสิทธิภาพของการฝึกสอนอย่างมีนัยยะสำคัญ ดังรูปที่ 4.7 แต่จะช่วยให้การฝึกสอนชุดข้อมูลจำนวนมากเป็นไปได้ในเครื่องที่มี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


หน่วยความจำน้อย แลกกับระยะเวลาในการฝึกสอนที่มากขึ้นเนื่องจาก Optimizer ต้องคำนวณจำนวนรอบที่มากขึ้น ดังนั้นผู้วิจัยจึงเลือกค่า 256 มาใช้งาน



รูปที่ 4.7 แสดงค่าการสูญเสียของการฝึกสอนระหว่าง Batch size 128 (รูปซ้าย) และ 256 (รูปขวา)

3. Loss function

จากการทดลองพบว่า MSE มีความแปรปรวนมากเมื่อเปรียบเทียบกับ MAE ดังรูปที่ 4.8 ดังนั้นผู้วิจัยจึงเลือกค่า MAE มาใช้งาน

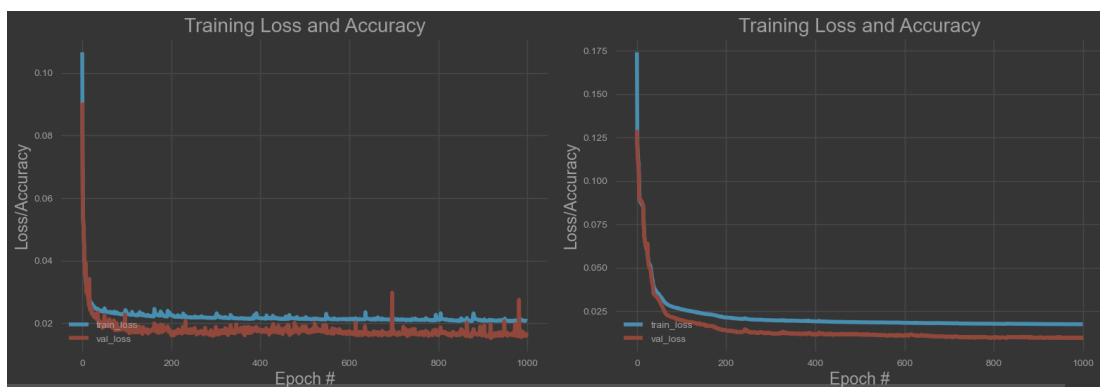


รูปที่ 4.8 แสดงค่าการสูญเสียของการฝึกสอนระหว่าง MSE (รูปซ้าย) และ MAE (รูปขวา)

4. Learning rate

จากการทดลองพบว่าเมื่อระบุค่าเป็น 0.01 ค่าการสูญเสียของตัวแบบมีความแปรปรวนมากเมื่อเปรียบเทียบกับค่า 0.001 ดังรูปที่ 4.9 ส่วนเมื่อระบุค่าเป็น 0.0001 ตัวแบบไม่สามารถฝึกสอนได้จนจบได้บนเครื่องที่ใช้ทดสอบ ดังนั้นผู้วิจัยจึงเลือกค่า 0.001 มาใช้งาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.9 แสดงค่าการสูญเสียของการฝึกสอนระหว่าง Learning rate 0.01 (รูปซ้าย) และ 0.001 (รูปขวา)

จากข้อมูลข้างต้นจึงสามารถสรุปค่า Hyperparameters ที่จะนำมาใช้ในการทดลองได้ดังตารางที่ 4.2

ตารางที่ 4.2 แสดงค่า Hyperparameters ที่ใช้ในตัวอย่างสำหรับการทดลอง

ชื่อ	ค่าที่กำหนด
Epoch	1,000
Batch size	256
Optimizer	Adam
Loss function	MAE
Learning rate	0.001

4.2 ผลการศึกษาและวัดประสิทธิภาพ

ผลการศึกษาและทดสอบประสิทธิภาพได้ถูกแบ่งตามอัตราส่วนของข้อมูลฝึกฝนดังนี้

1. ข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%
2. ข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%
3. ข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%
4. ข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%


4.2.1 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%

จากการทดลองพบว่าตัวแบบสามารถเรียนรู้ชุดข้อมูลนี้ได้ดังรูปที่ 4.10 และสามารถแยกแยะข้อมูลที่ผิดปกติได้ดีจากค่าการสูญเสียดังรูปที่ 4.11

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.10 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%



รูปที่ 4.11 แสดงแผนภาพฮิสโตแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%

โดยที่เมื่อกำหนดค่าเกณฑ์ที่ 0.018 และนำผลลัพธ์มาสร้างเป็นเมทริกซ์ความสับสนและคำนวณประสิทธิภาพของตัวแบบดังตารางที่ 4.3 และ 4.4 จะพบว่าตัวแบบมีประสิทธิภาพในการตรวจจับข้อมูลผิดปกติที่ ความแม่นยำ (Accuracy) 82% ความเที่ยง (Precision) 96% ค่าเรียกคืน (Recall) 76% และคะแนนเอฟ (F1-Score) 84%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.3 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%

		ค่าทำนาย	
		ข้อมูลปกติ	ข้อมูลบุกรุก
ค่าจริง	ข้อมูลปกติ	26,187	1,754
	ข้อมูลบุกรุก	12,015	37,346

ตารางที่ 4.4 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 100% ข้อมูลผิดปกติ 0%

	Accuracy	Precision	Recall	F1-score	Support
ข้อมูลปกติ	0.82	0.69	0.94	0.79	27,941
ข้อมูลบุกรุก		0.96	0.76	0.84	49,361


4.2.2 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%

เมื่อมีการเพิ่มข้อมูลที่ผิดปกติเข้าไป 1% พบว่าตัวแบบมีค่าการสูญเสียที่เพิ่มมากขึ้นในการเรียนรู้ดังรูปที่ 4.12 และเมื่อดูฮิสโทแกรมรูปที่ 4.13 จะพบว่าการกระจายตัวของค่าการสูญเสียของข้อมูลผิดปกติเริ่มเข้าใกล้ค่าการสูญเสียของข้อมูลปกติมากขึ้น



รูปที่ 4.12 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.13 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%

โดยที่เมื่อกำหนดค่าเกณฑ์ที่ 0.008 และนำผลลัพธ์มาสร้างเป็นเมทริกซ์ความสับสนและคำนวณประสิทธิภาพของตัวแบบดังตารางที่ 4.5 และ 4.6 จะพบว่าตัวแบบมีประสิทธิภาพในการตรวจจับข้อมูลผิดปกติที่ ความแม่นยำ (Accuracy) 81% ความเที่ยง (Precision) 88% ค่าเรียกคืน (Recall) 81% และคะแนนเอฟ (F1-Score) 84%

ตารางที่ 4.5 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%

		ค่าทำนาย	
		ข้อมูลปกติ	ข้อมูลบกรุก
ค่าจริง	ข้อมูลปกติ	22,303	5,638
	ข้อมูลบกรุก	9,159	40,202

ตารางที่ 4.6 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 99% ข้อมูลผิดปกติ 1%

	Accuracy	Precision	Recall	F1-score	Support
ข้อมูลปกติ	0.81	0.71	0.80	0.75	27,941
ข้อมูลบกรุก		0.88	0.81	0.84	49,361

4.2.3 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%


เมื่อมีการเพิ่มข้อมูลที่ผิดปกติเข้าไป 3% พบว่าตัวแบบมีค่าการสูญเสียที่เพิ่มมากขึ้นในการเรียนรู้ดังรูปที่ 4.14 และเมื่อดูฮิสโทแกรมรูปที่ 4.15 จะพบว่าการกระจายตัวของค่าการสูญเสีย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ของข้อมูลผิดปกติมีแนวโน้มเริ่มซ้อนทับค่าการสูญเสียของข้อมูลปกติ ทำให้ตั้งข้อสังเกตได้ว่า จำนวนของข้อมูลผิดปกติที่นำไปฝึกสอนตัวแบบน่าจะมีผลต่อประสิทธิภาพในการจำแนกของตัวแบบ



รูปที่ 4.14 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%



รูปที่ 4.15 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%

โดยที่เมื่อกำหนดค่าเกณฑ์ที่ 0.032 และนำผลลัพธ์มาสร้างเป็นเมทริกซ์ความสับสนและคำนวณประสิทธิภาพของตัวแบบดังตารางที่ 4.7 และ 4.8 จะพบว่าตัวแบบมีประสิทธิภาพในการตรวจจับข้อมูลผิดปกติที่ ความแม่นยำ (Accuracy) 76% ความเที่ยง (Precision) 82% ค่าเรียกคืน (Recall) 80% และคะแนนเอฟ (F1-Score) 81%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.7 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%


		ค่าทำนาย	
		ข้อมูลปกติ	ข้อมูลบกพร่อง
ค่าจริง	ข้อมูลปกติ	19,239	8,702
	ข้อมูลบกพร่อง	9,874	39,487

ตารางที่ 4.8 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 97% ข้อมูลผิดปกติ 3%

	Accuracy	Precision	Recall	F1-score	Support
ข้อมูลปกติ	0.76	0.66	0.69	0.67	27,941
ข้อมูลบกพร่อง		0.82	0.80	0.81	49,361

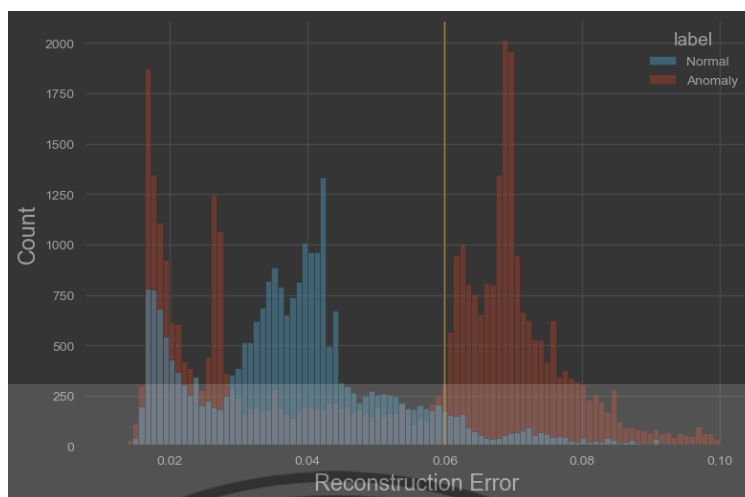
4.2.4 อัตราส่วนข้อมูลฝึกฝน ข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%

เมื่อมีการเพิ่มข้อมูลที่ผิดปกติเข้าไป 5% จะพบว่าตัวแบบมีค่าการสูญเสียที่เพิ่มมากขึ้น และมีแนวโน้มสูงขึ้นต่อเนื่องจากการฝึกสอนหลังจากรอบที่ 200 ดังรูปที่ 4.16 และเมื่อดูฮิสโทแกรมรูปที่ 4.17 จะพบว่าข้อมูลผิดปกติจำนวนหนึ่งมีค่าการสูญเสียที่ต่ำ ส่งผลให้การจำแนกมีความผิดพลาดมากขึ้น จากข้อมูลข้างต้นจะสรุปได้ว่า จำนวนของข้อมูลผิดปกติที่นำไปฝึกสอนตัวแบบมีผลต่อประสิทธิภาพในการจำแนกของตัวแบบอย่างเห็นได้ชัด



รูปที่ 4.16 แสดงค่าการสูญเสียของการฝึกสอนของชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.17 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%

โดยที่เมื่อกำหนดค่าเกณฑ์ที่ 0.06 และนำผลลัพธ์มาสร้างเป็นเมทริกซ์ความสับสนและคำนวณประสิทธิภาพของตัวแบบดังตารางที่ 4.9 และ 4.10 จะพบว่าตัวแบบมีประสิทธิภาพในการตรวจจับข้อมูลผิดปกติที่ ความแม่นยำ (Accuracy) 70% ความเที่ยง (Precision) 87% ค่าเรียกคืน (Recall) 63% และคะแนนเอฟ (F1-Score) 73%

ตารางที่ 4.9 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%


		ค่าทำนาย	
		ข้อมูลปกติ	ข้อมูลบุงรุก
ค่าจริง	ข้อมูลปกติ	23,120	4,821
	ข้อมูลบุงรุก	18,137	31,224

ตารางที่ 4.10 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลปกติ 95% ข้อมูลผิดปกติ 5%


	Accuracy	Precision	Recall	F1-score	Support
ข้อมูลปกติ	0.70	0.56	0.83	0.67	27,941
ข้อมูลบุงรุก		0.87	0.63	0.73	49,361

เมื่อนำข้อมูลที่ได้จากการทดลองทั้ง 4 ชุดมาเขียนแผนภาพเพื่อเปรียบเทียบประสิทธิภาพดังรูปที่ 4.18 และ 4.19 จะเห็นได้ว่าประสิทธิภาพของการจำแนกทั้งสองกลุ่มนั้นเป็นไปในทิศทางเดียวกัน โดยที่ประสิทธิภาพที่ได้จะขึ้นอยู่กับจำนวนของอัตราส่วนข้อมูลปกติที่ใช้ในการฝึกสอนตัวแบบ ถ้าเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อัตราส่วนของข้อมูลปกติมาก จะทำให้ตัวแบบมีประสิทธิภาพในการจำแนกสูง และประสิทธิภาพจะค่อย ๆ ลดลงเมื่อเพิ่มอัตราส่วนของข้อมูลผิดปกติให้มากขึ้น



รูปที่ 4.18 แสดงแผนภาพเปรียบเทียบค่าประสิทธิภาพของการจำแนกข้อมูลปกติจากการทดลอง



รูปที่ 4.19 แสดงแผนภาพเปรียบเทียบค่าประสิทธิภาพของการจำแนกข้อมูลผิดปกติจากการทดลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.3 ปัญหาที่พบจากการศึกษา

4.3.1 ตัวแบบไม่สามารถตรวจจัดการบุกรุกบางประเภทได้

จากผลการศึกษาของตัวแบบที่เรียนรู้จากข้อมูลปกติ 100% ข้อมูลผิดปกติ 0% เมื่อนำผลการจำแนกจากชุดข้อมูลทดสอบมาวิเคราะห์หาค่าประสิทธิภาพ โดยการนำผลการจำแนกมาจัดกลุ่มตามประเภทการบุกรุกดังตารางที่ 4.11 โดยที่การบุกรุกแต่ละประเภทจะมีคำอธิบายดังตารางที่ 4.12

ตารางที่ 4.11 แสดงผลการจำแนกโดยการจัดกลุ่มตามประเภทการบุกรุก

ประเภทการบุกรุก	ผลการจำแนก	จำนวนข้อมูล	อัตราส่วน
Analysis	ผิด	114	14%
	ถูก	675	86%
Backdoor	ผิด	60	8%
	ถูก	646	92%
DoS	ผิด	445	8%
	ถูก	4,489	92%
Exploits	ผิด	1,857	11%
	ถูก	11,643	89%
Fuzzers	ผิด	4,599	59%
	ถูก	2,609	41%
Generic	ผิด	117	1%
	ถูก	17,351	99%
Reconnaissance	ผิด	2,744	62%
	ถูก	1,493	38%
Shellcode	ผิด	432	88%
	ถูก	40	12%
Worms	ผิด	1	2%
	ถูก	46	98%

ตารางที่ 4.12 คำอธิบายของการบุกรุกแต่ละประเภท

ประเภทการบุกรุก	คำอธิบาย
Analysis	เป็นการโจมตีโปรแกรมประยุกต์บนเว็บโดยมีพื้นฐานจากพอร์ต

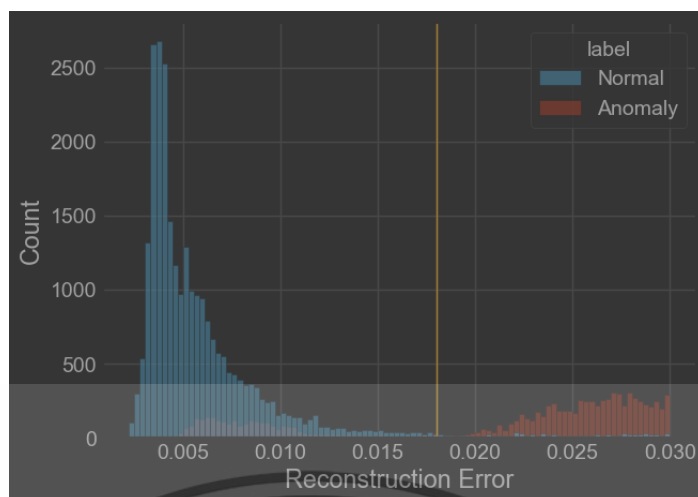
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.12 คำอธิบายของการบุกรุกแต่ละประเภท (ต่อ)

ประเภทการบุกรุก	คำอธิบาย
Backdoor	เป็นวิธีการในการเข้าถึงระบบโดยที่ไม่ได้รับอนุญาต
DoS	เป็นการโจมตีที่จะทำให้ระบบปฏิเสธการเข้าถึงทรัพยากรต่าง ๆ ของระบบที่จำเป็นสำหรับการประมวลผล
Exploits	เป็นการโจมตีโดยใช้ประโยชน์ของช่องโหว่ของระบบที่เกิดจากความบกพร่องในระบบปฏิบัติการหรือซอฟต์แวร์
Fuzzers	เป็นการโจมตีที่ทำให้ระบบค้างโดยการป้อนข้อมูลสุ่มเป็นจำนวนมาก
Generic	เป็นเทคนิคการทำลายการเข้ารหัสโดยที่ไม่ต้องคำนึงถึงโครงสร้างของการเข้ารหัส
Reconnaissance	เป็นการโจมตีที่จะเข้าถึงข้อมูลเกี่ยวกับระบบซึ่งอาจจะทำให้รู้ถึงความบกพร่องของระบบได้
Shellcode	เป็นการโจมตีโดยใช้ชุดคำสั่งขนาดเล็กเพื่อทำให้ระบบมีช่องโหว่
Worms	เป็นการโจมตีระบบโดยใช้โปรแกรมที่มีความสามารถในการทำซ้ำตัวเองและแพร่กระจายไปยังระบบอื่น ๆ ผ่านทางช่องทางต่าง ๆ

พบว่าการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode ไม่สามารถถูกจำแนกได้อย่างมีประสิทธิภาพ เนื่องจากการโจมตีทั้งสามแบบนี้จะต้องมีการวิเคราะห์ถึงข้อมูลที่ถูกส่งมากับกลุ่มข้อมูล (Packet) ในระบบเครือข่ายด้วย ซึ่งชุดข้อมูลที่ใช้ในการศึกษานี้ไม่ได้มีคุณลักษณะดังกล่าว จึงเป็นข้อจำกัดที่ทำให้ไม่สามารถจำแนกการบุกรุกประเภทนี้ได้

ดังนั้นจึงได้มีการนำตัวแบบและชุดข้อมูลนี้มาทำการทดสอบอีกครั้ง โดยครั้งนี้การทดลองจะลบข้อมูลที่เป็นการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode ออกไปเพื่อดูประสิทธิภาพของตัวแบบในกรณีที่ไม่มีการบุกรุกประเภทดังกล่าว ซึ่งหลังจากทดลองพบว่า ตัวแบบมีความสามารถในการแยกแยะข้อมูลที่ผิดปกติได้ดีขึ้นดังรูปที่ 4.20



รูปที่ 4.20 แสดงแผนภาพฮิสโทแกรมของค่าการสูญเสียของชุดข้อมูลที่ไม่มีการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode

โดยที่เมื่อกำหนดค่าเกณฑ์ที่ 0.018 และนำผลลัพธ์มาสร้างเป็นเมทริกซ์ความสับสนและคำนวณประสิทธิภาพของตัวแบบดังตารางที่ 4.13 และ 4.14 จะพบว่าตัวแบบมีประสิทธิภาพในการตรวจจับข้อมูลผิดปกติที่ ความแม่นยำ (Accuracy) 92% ความเที่ยง (Precision) 94% ค่าเรียกคืน (Recall) 92% และคะแนนเอฟ (F1-Score) 93%

ตารางที่ 4.13 แสดงเมทริกซ์ความสับสนของตัวแบบที่ฝึกสอนจากชุดข้อมูลที่ไม่มีการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode

		ค่าทำนาย	
		ข้อมูลปกติ	ข้อมูลบุกรุก
ค่าจริง	ข้อมูลปกติ	25,829	2,185
	ข้อมูลบุกรุก	2,828	34,537

ตารางที่ 4.14 แสดงค่าประสิทธิภาพของตัวแบบที่ฝึกสอนจากชุดข้อมูลที่ไม่มีการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode

	Accuracy	Precision	Recall	F1-score	Support
ข้อมูลปกติ	0.92	0.90	0.92	0.91	28,014
ข้อมูลบุกรุก		0.94	0.92	0.93	37,365

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การศึกษานี้มีวัตถุประสงค์เพื่อศึกษาประสิทธิภาพของการตรวจจับการบุกรุกระบบเครือข่ายโดยใช้วิธีการเรียนรู้แบบไม่มีผู้สอน โดยการสร้างตัวแบบสำหรับจำแนกข้อมูลจากโครงข่ายประสาทเทียมประเภทตัวเข้ารหัสอัตโนมัติ และใช้ชุดข้อมูล UNSW-NB15 สำหรับฝึกสอนตัวแบบ ซึ่งมีจำนวนข้อมูลทั้งหมด 257,673 ตัวอย่าง โดยที่ชุดข้อมูลจะถูกนำมาลดมิติโดยใช้การวิเคราะห์องค์ประกอบหลักให้เหลือคุณลักษณะ 128 ตัว แล้วจึงนำมาฝึกสอนตัวแบบโครงข่ายประสาทเทียมประเภทตัวเข้ารหัสอัตโนมัติ

การศึกษานี้ได้ออกแบบการทดลองเป็น 4 ชุดตามจำนวนอัตราส่วนข้อมูลฝึกฝนระหว่างข้อมูลประเภทปกติและประเภติดัดปกติ โดยที่แต่ละการทดลองได้ผลลัพธ์ดังตารางที่ 5.1 และ 5.2

ตารางที่ 5.1 แสดงค่าประสิทธิภาพของการจำแนกข้อมูลปกติจากการทดลอง

อัตราส่วนข้อมูล	Accuracy	Precision	Recall	F1-score
ข้อมูลปกติ 100%	0.82	0.69	0.94	0.79
ข้อมูลปกติ 99%	0.81	0.71	0.80	0.75
ข้อมูลปกติ 97%	0.76	0.66	0.69	0.67
ข้อมูลปกติ 95%	0.70	0.56	0.83	0.67

ตารางที่ 5.2 แสดงค่าประสิทธิภาพของการจำแนกข้อมูลผิดปกติจากการทดลอง

อัตราส่วนข้อมูล	Accuracy	Precision	Recall	F1-score
ข้อมูลปกติ 100%	0.82	0.96	0.76	0.84
ข้อมูลปกติ 99%	0.81	0.88	0.81	0.84
ข้อมูลปกติ 97%	0.76	0.82	0.80	0.81
ข้อมูลปกติ 95%	0.70	0.87	0.63	0.73

ดังนั้นจากผลการทดลองที่ได้มาจะสรุปได้ว่า โครงข่ายประสาทเทียมประเภทตัวเข้ารหัสอัตโนมัติมีความสามารถในการจำแนกข้อมูลที่ผิดปกติได้ โดยที่เมื่อฝึกสอนตัวแบบด้วยชุดข้อมูลฝึกฝนที่มีจำนวนข้อมูลปกติมาก ตัวแบบที่ได้ก็จะมีประสิทธิภาพในการจำแนกสูง แต่เมื่อฝึกสอนด้วยชุดข้อมูลฝึกฝนที่มีจำนวนข้อมูลผิดปกติเพิ่มมากขึ้น ตัวแบบที่ได้จะมีประสิทธิภาพลดลง นอกจากนี้เมื่อเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

วิเคราะห์ผลเพิ่มเติมจะพบว่าการบุกรุกประเภท Fuzzers Reconnaissance และ Shellcode ยังไม่สามารถถูกจำแนกได้อย่างมีประสิทธิภาพเพราะเป็นการบุกรุกที่มีอัตราการจำแนกถูกต้องต่ำกว่า 50% เนื่องจากการโจมตีทั้งสามแบบนี้จะต้องมีการวิเคราะห์ถึงข้อมูลที่ถูกส่งมาที่กลุ่มข้อมูลในระบบเครือข่ายเพิ่มเติม

5.2 ข้อจำกัด

ในการศึกษาในครั้งนี้ผู้วิจัยได้พบข้อจำกัดในการศึกษาดังนี้

1. คุณลักษณะที่ได้มาจากชุดข้อมูล UNSW-NB15 ประกอบไปด้วยข้อมูลการเชื่อมต่อเบื้องต้น แต่ไม่ได้รวมถึงข้อมูลที่แท้จริงที่ส่งมาพร้อมกับกลุ่มข้อมูล (Data Packet) ของการเชื่อมต่ออื่น ๆ ทำให้วิธีการที่นำเสนอยังไม่สามารถตรวจจับการบุกรุกบางประเภทได้อย่างมีประสิทธิภาพ
2. เนื่องจากข้อจำกัดทางด้านเวลาในการศึกษาทำให้ยังต้องมีการกำหนดค่าเกณฑ์สำหรับการระบุผลการจำแนกด้วยตัวเอง

5.3 ข้อเสนอแนะและงานในอนาคต

1. การลดมิติชุดข้อมูลแบบไม่เป็นเส้นตรง (Nonlinear) อาจเพิ่มประสิทธิภาพของการจำแนกได้
2. นำวิธีการที่นำเสนอไปทดลองใช้กับชุดข้อมูลสำหรับทดสอบระบบตรวจจับการบุกรุกระบบเครือข่ายอื่น ๆ เพื่อดูประสิทธิภาพของตัวแบบเมื่อต้องทำงานกับชุดข้อมูลอื่น
3. ปรับแต่ง Hyperparameters ของตัวแบบแบบละเอียดอาจทำให้ประสิทธิภาพของการจำแนกดีขึ้น
4. ศึกษาหาขั้นตอนวิธีที่ทำให้ได้ค่าเกณฑ์สำหรับการระบุผลการจำแนกแบบอัตโนมัติ และไม่ต้องพึ่งพาลากค่าตอบในการกำหนดค่าเกณฑ์
5. ควรนำผลที่ได้ไปเปรียบเทียบประสิทธิภาพกับวิธีการจำแนกในงานวิจัยอื่น ๆ เพื่อหาข้อบกพร่องและพัฒนาวิธีการเพิ่มเติม

เอกสารอ้างอิง

- [1] Denning, D.E. 1987. "An Intrusion-Detection Model." *IEEE Transactions on Software Engineering*. 13(2) : 222 – 232.
- [2] Moustafa, N. and Slay, J. 2015. "UNSW-NB15: a comprehensive data set for network intrusion detection systems (UNSW-NB15 network data set)." 1-6. in **Military Communications and Information Systems Conference (MilCIS)**. Canberra : IEEE
- [3] Xiao, Y. Xing, C. Zhang, T. and Zhao, Z. 2019. "An Intrusion Detection Model Based on Feature Reduction and Convolutional Neural Networks." *IEEE Access*. 7(1) : 42210 – 42219.
- [4] Anderson, D. and McHeill, G. 1992. "Artificial Neural Network Technology." New York : Kaman Sciences Corporation
- [5] Ciaburro, G. and Venkateswaran, B. 2017. **Neural Networks with R**. Birmingham : Packt Publishing
- [6] Goodfellow, I. Bengio, Y. and Courville, A. 2016. **Deep Learning**. [Online]. Available : <https://www.deeplearningbook.org/contents/autoencoders.html>
- [7] Sakurada, M. and Yairi, T. 2014. "Anomaly Detection Using Autoencoders with Nonlinear Dimensionality Reduction." 4-11. In Rahman, A. and Deng, J. and Li, J. **Proceedings of the MLSDA 2014 2nd Workshop on Machine Learning for Sensory Data Analysis**. New York : Association for Computing Machinery
- [8] Choi, H. Kim, M. Lee, G. and Kim, W. 2019. "Unsupervised Learning Approach for Network Intrusion Detection System Using Autoencoders." *The Journal of Supercomputing*. 75(9) : 5597 – 5621.
- [9] Zong, W. Chow, Y. and Susilo, W. 2019. "Dimensionality Reduction and Visualization of Network Intrusion Detection Data." 441-455 in Jang-Jaccard, J. and Guo, F. **Information Security and Privacy**. Christchurch : Springer Cham
- [10] Narayana Rao, K. Venkata Rao, K. and P.V.G.D., P.R. 2021. "A Hybrid Intrusion Detection System Based on Sparse Autoencoder and Deep Neural Network." *Computer Communications*. 180(C) : 77 – 88.
- [11] Syarif, I. Prugel-Bennett, A. Wills, G.. 2012. "Unsupervised Clustering Approach for Network Anomaly Detection." 135-145. In Benlamri, R. **Networked Digital Technologies, 2012, Volume 293**. Berlin, Heidelberg : Springer

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ	นายวิทยา ทศพิทักษ์กุล
วัน เดือน ปีเกิด	18 กุมภาพันธ์ พ.ศ. 2534
ที่อยู่ปัจจุบัน	กรุงเทพมหานคร
ประวัติการศึกษา	(2556) วิทยาศาสตรบัณฑิต สาขาวิทยาการคอมพิวเตอร์ เกรดเฉลี่ย 3.76 มหาวิทยาลัยเกษตรศาสตร์
ทุนการศึกษาที่ได้รับ	ไม่มี
ผลงานทางวิชาการ	ไม่มี



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้