

Time-Lagged Backpropagation Neural Network-Based Machine Learning for Loop Location Identification in Layer 2 Switch Network

Soradet Chaowinai¹, Nithzethe Mhuadthongon^{2,*}, and Apirada Jitjing³

^{1,2}Information and Communication Technology, School of Science and Technology,
Sukhothai Thammathirat Open University, Nonthaburi 11120 Thailand;
Email: ¹2629600095@stou.ac.th, ²nithizethe.mhu@stou.ac.th

³Aeronautical Engineering Division, Civil Aviation Training Center, Bangkok 10900, Thailand;
Email: ³japirada747@gmail.com

**Corresponding author: Nithzethe Mhuadthongon (nithizethe.mhu@stou.ac.th)*

Received: 8 June 2026; **Revised:** 14 August 2026; **Accepted:** 17 August 2026; **Published:** 28 August 2026

Abstract

This research aimed to study and analyze loop problems in Layer 2 switching networks and their impacts on system performance, to develop a machine learning model using a Time-Lagged Backpropagation Neural Network to identify the locations of network loop problems, and to evaluate and compare the performance of the developed model based on defined metrics. The research methodology consisted of eight main steps: 1) network simulation, 2) loop problem simulation, 3) traffic data collection, 4) data preparation and cleaning, 5) training and testing data splitting, 6) model development using various algorithms, 7) parameter tuning, and 8) model performance evaluation using a confusion matrix in conjunction with statistical metrics. The results indicated all five developed models successfully identified the locations of loop occurrences. Among these, the Time-Lagged Backpropagation Neural Network delivered the best performance, achieving an Accuracy of 91.46%, Precision of 95.27%, Recall of 91.46%, an F1-score of 93.11%, and an Area Under the Curve (AUC) of 0.986. These findings demonstrated that the proposed model possessed high efficiency in accurately detecting and locating network loop problems.

Keywords: Loop Problems in Layer 2 Switching Networks, Machine Learning Model, Time-Lagged Backpropagation Neural Network



Copyright © 2026 Journal of Computer and Creative Technology. This is an open-access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC-ND).

Citation:

Chaowinai, S., Mhuadthongon, N., & Jitjing, A. (2026). Time-Lagged Backpropagation Neural Network-Based Machine Learning for Loop Location Identification in Layer 2 Switch Network. *Journal of Computer and Creative Technology*, 4(2), e4181. <https://doi.org/10.65205/jcct.2026.e4181>

การเรียนรู้ของเครื่องโดยใช้โครงข่ายประสาทเทียมแบบกระจายย้อนกลับชนิดหนึ่งช่วงเวลาเพื่อ ระบุตำแหน่งปัญหาอุปในเครือข่ายสวิตช์เลเยอร์ 2

สรเดช เขาวินัย¹ นิติเศรษฐ์ หมวดทองอ่อน^{2*} และ อภิรดา จิตจริง³

^{1,2}แขนงวิชาเทคโนโลยีสารสนเทศและการสื่อสาร สาขาวิชาวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยสุโขทัยธรรมาธิราช
จังหวัดนนทบุรี 11120 ประเทศไทย; Email: ¹2629600095@stou.ac.th, ²nithizethe.mhu@stou.ac.th

³กองวิชาวิศวกรรมการบิน สถาบันการบินพลเรือน จังหวัดกรุงเทพมหานคร 10900 ประเทศไทย;
Email: ³japirada747@gmail.com

*ผู้ประพันธ์บทความ: นิติเศรษฐ์ หมวดทองอ่อน (nithizethe.mhu@stou.ac.th)

รับบทความ: 8 มิถุนายน 2569; แก้ไขบทความ: 14 สิงหาคม 2569; ตอรับบทความ: 17 สิงหาคม 2569;
เผยแพร่บทความ: 28 สิงหาคม 2569

บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อศึกษา และวิเคราะห์ปัญหาอุปในเครือข่ายสวิตช์เลเยอร์ 2 รวมถึงผลกระทบต่อประสิทธิภาพของระบบ เพื่อพัฒนาแบบจำลองการเรียนรู้ของเครื่องโดยใช้โครงข่ายประสาทเทียมแบบกระจายย้อนกลับชนิดหนึ่งช่วงเวลาในการระบุตำแหน่งปัญหาอุปในเครือข่าย และเพื่อประเมินพร้อมเปรียบเทียบประสิทธิภาพของแบบจำลองที่พัฒนาขึ้นภายใต้เกณฑ์วัดที่กำหนด การดำเนินงานวิจัยประกอบด้วย 8 ขั้นตอนหลัก ได้แก่ 1) การจำลองเครือข่าย 2) การจำลองการเกิดปัญหาอุป 3) การเก็บข้อมูลทราฟฟิก 4) การเตรียมและทำความสะอาดข้อมูล 5) การแบ่งชุดข้อมูลฝึกและทดสอบ 6) การพัฒนาแบบจำลองด้วยอัลกอริทึมที่หลากหลาย 7) การปรับแต่งพารามิเตอร์ และ 8) การประเมินประสิทธิภาพของแบบจำลองโดยใช้ตารางความสับสนร่วมกับตัวชี้วัดทางสถิติ ผลงานวิจัยพบว่าแบบจำลองที่พัฒนาขึ้นทั้ง 5 แบบจำลองสามารถระบุตำแหน่งการเกิดปัญหาอุปได้สำเร็จ ซึ่งแบบจำลองโครงข่ายประสาทเทียมแบบกระจายย้อนกลับชนิดหนึ่งเวลาให้ผลลัพธ์ที่ดีที่สุด โดยให้ค่าความถูกต้อง (Accuracy) ร้อยละ 91.46 ค่าความแม่นยำ (Precision) ร้อยละ 95.27 ค่าการเรียกคืน (Recall) ร้อยละ 91.46 ค่าประสิทธิภาพโดยรวม (F1-score) ร้อยละ 93.11 และพื้นที่ใต้กราฟ (AUC) เท่ากับ 0.986 แสดงให้เห็นว่าแบบจำลองดังกล่าวมีประสิทธิภาพสูงในการตรวจจับ และระบุตำแหน่งปัญหาอุปได้อย่างแม่นยำ

คำสำคัญ: ปัญหาอุปในเครือข่ายสวิตช์เลเยอร์ 2, แบบจำลองการเรียนรู้ของเครื่อง, โครงข่ายประสาทเทียมแบบกระจายย้อนกลับชนิดหนึ่งช่วงเวลา



Copyright © 2026 Journal of Computer and Creative Technology. This is an open-access article distributed under the terms of the Creative Commons Attribution License (CC-BY-NC-ND).

การอ้างอิง:

สรเดช เขาวินัย, นิติเศรษฐ์ หมวดทองอ่อน, และ อภิรดา จิตจริง. (2569). การเรียนรู้ของเครื่องโดยใช้โครงข่ายประสาทเทียมแบบกระจายย้อนกลับชนิดหนึ่งช่วงเวลาเพื่อระบุตำแหน่งปัญหาอุปในเครือข่ายสวิตช์เลเยอร์ 2. วารสารคอมพิวเตอร์และเทคโนโลยีสร้างสรรค์, 4(2), e4181. <https://doi.org/10.65205/jcct.2026.e4181>

1. บทนำ (Introduction)

ปัจจุบันมีการนำเครือข่ายคอมพิวเตอร์ มาประยุกต์ใช้ในองค์กรอย่างแพร่หลายเนื่องจากช่วยให้การแลกเปลี่ยนข้อมูลระหว่างเครื่องคอมพิวเตอร์เป็นไปได้อย่างมีประสิทธิภาพ ส่งผลให้เครือข่ายฯ เกิดการขยายตัวอย่างรวดเร็ว อย่างไรก็ตาม หากเกิดความขัดข้องขึ้นในเครือข่ายฯ ย่อมส่งผลกระทบต่อการทำงาน อย่างหลีกเลี่ยงไม่ได้ โดยเฉพาะปัญหาการเกิดลูป (Network Loop) ซึ่งสร้างความซ้ำซ้อนของเส้นทางในการส่งข้อมูลไปยังหมายเลขแมคแอดเดรส (MAC Address) ภายในเครือข่ายฯ ปริมาณข้อมูลที่เพิ่มขึ้นทวีคูณนี้จะก่อให้เกิดภาวะพายุบรอดคาสต์ (Broadcast Storm) จนเครือข่ายฯ ไม่สามารถให้บริการได้ แม้ว่าโดยทั่วไปอุปกรณ์สวิตช์เลเยอร์ 2 (Layer 2 Switch) ประเภทบริหารจัดการได้ (Managed Switch) ที่ใช้ในเครือข่ายฯ จะมีกลไกป้องกันปัญหานี้ผ่านโปรโตคอล STP (Spanning Tree Protocol) เพื่อปิดกั้นการวนซ้ำของข้อมูลแล้วก็ตาม (Institute of Electrical and Electronics Engineers, 2004) ทว่าในทางปฏิบัติ จากข้อจำกัดด้านงบประมาณเนื่องจากอุปกรณ์ประเภทดังกล่าวมีราคาสูง ประกอบกับความต้องการเชื่อมต่อ คอมพิวเตอร์เข้าสู่เครือข่ายฯ มีจำนวนเพิ่มขึ้น จึงมักมีการนำอุปกรณ์สวิตช์เลเยอร์ 2 ประเภทที่ไม่สามารถบริหารจัดการได้ (Unmanaged Switch) ซึ่งไม่รองรับโปรโตคอล STP มาใช้ในการขยายเครือข่ายฯ เพิ่มเติม ส่งผลให้เมื่อเกิดปัญหาลูปขึ้น ณ อุปกรณ์กลุ่มนี้เป็นเหตุให้ปริมาณการจราจรของข้อมูลจำนวนมหาศาลจะหมุนเวียน และแพร่กระจายไปทั่วทั้งเครือข่ายฯ อย่างไรก็ตามซึ่งส่งผลกระทบต่อประสิทธิภาพการทำงานของเครือข่ายฯ ในภาพรวมลดลงและหยุดชะงักลงในที่สุด

การแก้ไขปัญหาการเกิดลูปที่เกิดขึ้นภายในเครือข่ายฯ จำเป็นต้องสืบค้นอย่างเร่งด่วนเพื่อระบุตำแหน่งของอุปกรณ์ที่เกิดความผิดปกติจากนั้นจึงดำเนินการตัดวงจร และแก้ไขปัญหานั้นที่ต้นเหตุ อย่างไรก็ตาม กระบวนการตรวจสอบเพื่อระบุตำแหน่งดังกล่าวในปัจจุบันยังคงมีข้อจำกัด และอุปสรรคสำคัญเนื่องจากต้องอาศัยบุคลากรที่มีทักษะความเชี่ยวชาญขั้นสูงตลอดจนต้องใช้ระยะเวลาค่อนข้างนานในการตรวจค้นหา ยิ่งในเครือข่ายที่มีขนาดใหญ่และซับซ้อน หรือมีการผสมผสานอุปกรณ์ที่หลากหลายการตรวจเช็คทางกายภาพ และการวิเคราะห์การจราจรของข้อมูลยิ่งทวีความยากลำบากมากขึ้น ส่งผลให้ระยะเวลาในการกู้คืนระบบยาวนานขึ้นตามไปด้วย ด้วยเหตุนี้การพัฒนาหรือนำเทคโนโลยีที่ช่วยวิเคราะห์ และพยากรณ์ตำแหน่งการเกิดปัญหาลูปในระบบเครือข่ายฯ จึงถือเป็นแนวทางสำคัญในการเพิ่มประสิทธิภาพ และลดความเสียหายให้แก่องค์กร

ในการตรวจสอบตำแหน่งการเกิดปัญหาในเครือข่ายฯ มีงานวิจัย Detection of Broadcast Storms in Local Area Networks (Pešović et al., 2024) ใช้แนวทางตรวจจับปรากฏการณ์ Broadcast Storms ในเครือข่ายท้องถิ่น (LAN) โดยระบุออกมาเป็นหมายเลข MAC Address ที่เกิดปัญหา ข้อมูลที่ใช้สำหรับการป้อนเข้าได้จาก 1) MAC Address ของโหนดต้นทาง 2) จำนวนแพ็กเก็ต (TX Packets) ที่แต่ละโหนดส่งออกไป และ 3) ปริมาณข้อมูลในหน่วยไบต์ (TX Bytes) ที่แต่ละโหนดส่งออกไป ใช้การเรียนรู้ของเครื่องแบบ Agglomerative Hierarchical Clustering ในการจัดกลุ่มข้อมูลปกติ และข้อมูลที่ผิดปกติ ซึ่งการระบุตำแหน่งความผิดปกติในเครือข่ายฯ ยังไม่สามารถระบุถึงตำแหน่งพอร์ตของอุปกรณ์ที่เกิดปัญหาได้

งานวิจัยฉบับนี้ได้นำเสนอการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) โดยอาศัยสถาปัตยกรรมโครงข่ายประสาทเทียมแบบแพร่กระจายย้อนกลับชนิดหน่วงเวลา (Time-Lagged Backpropagation Neural Network: TLBPNN) เพื่อแก้ไขปัญหการเกิดลูปในระดับพอร์ตเชื่อมต่อ แนวทางดังกล่าวมีประโยชน์อย่างยิ่งในเชิงปฏิบัติสำหรับเจ้าหน้าที่ดูแลระบบเครือข่าย เนื่องจากช่วยลดระยะเวลาในการกู้คืนระบบ (Recovery Time) และเพิ่มความมั่นคงปลอดภัยให้แก่ระบบเครือข่ายขององค์กรที่มีข้อจำกัดด้านงบประมาณ

นอกจากนี้ งานวิจัยยังได้ทำการเปรียบเทียบประสิทธิภาพการทำนายกับแบบจำลองอีก 4 รูปแบบ ได้แก่ ต้นไม้ตัดสินใจ (Decision Tree: DT) โนอีฟเบย์ (Naïve Bayes: NB) ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) และโครงข่ายประสาทเทียมแบบป้อนไปข้างหน้าและแพร่กระจายย้อนกลับ (Feedforward Backpropagation Neural Network: FFBPNN) ทั้งนี้ การประเมินประสิทธิภาพของแบบจำลองถูกวิเคราะห์ผ่านเมตริกซ์ความสับสน (Confusion Matrix) โดยพิจารณาจากตัวชี้วัดเชิงสถิติ ประกอบด้วย ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความครอบคลุม (Recall) ค่าประสิทธิภาพโดยรวม (F1-Score) และค่าพื้นที่ใต้เส้นโค้ง ROC (AUC)

2. วัตถุประสงค์งานวิจัย (Research Objectives)

1. เพื่อศึกษาและวิเคราะห์ปรากฏการณ์ของการเกิดปัญหาในเครือข่ายคอมพิวเตอร์ เพื่อทำความเข้าใจถึงรูปแบบ และผลกระทบที่เกิดขึ้นต่อประสิทธิภาพของเครือข่ายคอมพิวเตอร์
2. เพื่อพัฒนาแบบจำลองการเรียนรู้ของเครื่องสำหรับใช้ในการระบุตำแหน่งการเกิดปัญหาในเครือข่ายคอมพิวเตอร์
3. เพื่อประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลองที่พัฒนาขึ้น

3. ทบทวนวรรณกรรมและทฤษฎีที่เกี่ยวข้อง (Literature Review)

3.1 ปัญหาและภัยคุกคามในเครือข่ายคอมพิวเตอร์

เครือข่ายคอมพิวเตอร์ถือเป็นโครงสร้างพื้นฐานที่มีความสำคัญต่อการขับเคลื่อนสารสนเทศในองค์กร แต่การขยายตัวของระบบที่มีขนาดใหญ่และเพิ่มความซับซ้อน ส่งผลให้การดำเนินงานรักษาประสิทธิภาพและการป้องกันการหยุดชะงักของการบริการ (Service Downtime) กลายเป็นประเด็นท้าทายสำคัญในการบริหารจัดการเทคโนโลยีสารสนเทศจากการประมวลผลรวมที่เกี่ยวเนื่อง สามารถจำแนกข้อบกพร่องและอุปสรรคที่เกิดขึ้นในระบบเครือข่ายออกเป็น 3 ประเด็นหลัก ได้แก่ ปัญหาด้านประสิทธิภาพการดำเนินงาน ปัญหาเชิงโครงสร้างสถาปัตยกรรม การกำหนดค่าอุปกรณ์เครือข่าย และปัญหาด้านภัยคุกคามความมั่นคงปลอดภัยทางไซเบอร์

1. ข้อบกพร่องพื้นฐานที่ส่งผลกระทบต่อเสถียรภาพของระบบเครือข่ายโดยตรงมักเกี่ยวเนื่องกับความเสื่อมถอยด้านสมรรถนะ (Performance Degradation) ซึ่งสามารถประเมินและตรวจวัดผ่านดัชนีชี้วัดคุณภาพบริการ (Quality of Service: QoS) ที่สำคัญ ได้แก่ ความหน่วงเวลา (Latency) ความผันผวนของความหน่วงเวลา (Jitter) อัตราการสูญหายของแพ็กเก็ตข้อมูล (Packet Loss) ความกว้างของช่องทางการสื่อสาร (Bandwidth Capacity) ตลอดจนปริมาณการใช้ทรัพยากรหน่วยประมวลผลกลางของอุปกรณ์เครือข่าย (CPU Utilization) ซึ่งตัวชี้วัดเหล่านี้สอดคล้องกับพฤติกรรมความผิดปกติของระบบในสภาวะวิกฤต

2. ความบกพร่องเชิงโครงสร้างในสถาปัตยกรรมเครือข่ายมักสร้างผลกระทบรุนแรง โดยเฉพาะปัญหาลูปในระดับเลเยอร์ 2 ซึ่งงานวิจัยของ Pešović et al. (2024) ชี้ให้เห็นว่าเกิดจากการมีเส้นทางเชื่อมต่อซ้ำซ้อนโดยปราศจากกลไกควบคุม ปัญหาดังกล่าวมักทวีความรุนแรงเมื่อมีการนำอุปกรณ์สวิตช์ที่ไม่สามารถบริหารจัดการได้ (Unmanaged Switch) ซึ่งไม่รองรับโพรโทคอล STP มาต่อพ่วงเพื่อขยายเครือข่าย เมื่อเกิดการเชื่อมต่อวนซ้ำที่อุปกรณ์ปลายทางเหล่านี้ข้อจำกัดของ Ethernet Frame ที่ไม่มีกลไกจำกัดอายุแพ็กเก็ต (TTL) จะส่งผลให้ข้อมูลถูกส่งวนซ้ำและทะลักกลับเข้าสู่เครือข่ายหลักอย่างควบคุมไม่ได้ จนลุกลามเป็นพายุบรอดคาสต์ (Broadcast Storms) สถานะนี้ทำให้ตาราง MAC Address ขาดความเสถียรและสิ้นเปลืองทรัพยากรการประมวลผลจนเครือข่ายล่มสลายทั้งระบบ การป้องกันจึงต้องอาศัยการกำหนดค่าโพรโทคอล เช่น STP, RSTP หรือ MSTP บนอุปกรณ์หลัก ควบคู่กับการสกัดกั้นผลกระทบจากอุปกรณ์ที่ไม่มีระบบจัดการด้วยการตั้งค่า BPDU Guard, Loopback Detection (LBD) และ Storm Control ที่พอร์ตปลายทาง นอกจากนี้ การประยุกต์ใช้โมเดลโครงข่ายประสาทเทียม (Neural Networks) เข้ามาช่วยวิเคราะห์และระบุตำแหน่งการเกิดลูป (Loop Localization) ยังเป็นการยกระดับการแก้ปัญหาเชิงรุกที่ช่วยจำกัดวงความเสียหายและลดระยะเวลาการหยุดชะงักของเครือข่ายได้อย่างแม่นยำ

3. นอกเหนือจากข้อบกพร่องทางเทคนิคแล้ว เครือข่ายฯ ในปัจจุบันยังตกเป็นเป้าหมายของภัยคุกคามทางไซเบอร์ที่มีความซับซ้อนเพิ่มขึ้นอย่างต่อเนื่อง เช่น การโจมตีเพื่อบริการให้ปฏิเสธการให้บริการ (Denial of Service: DoS และ Distributed DoS: DDoS) ซึ่งเป็นการจงใจส่งปริมาณข้อมูลขยะจำนวนมากเพื่อขับเคลื่อนให้เกิดภาวะทรัพยากรหรือความกว้างช่องทางการสื่อสารของระบบเป้าหมายหมดสิ้นไป จนไม่สามารถให้บริการแก่ผู้ใช้งานตามปกติได้ นอกจากนี้ ภัยคุกคามในรูปแบบอื่นยังครอบคลุมถึง การสแกนพอร์ต (Port Scans) เพื่อสำรวจหาช่องโหว่ของเครือข่าย การสุ่มเดารหัสผ่าน (Brute Force Attacks) การใช้มัลแวร์เพื่อเข้าควบคุมอุปกรณ์และจัดตั้งเป็นเครือข่ายบอตเน็ต (Botnet Attacks) การโจมตีช่องโหว่บนเว็บแอปพลิเคชัน (Web-based Attacks) เช่น การแทรกโค้ดคำสั่งแปลกปลอม (SQL Injection) และการแทรกซึมเข้าสู่ระบบเพื่อโจรกรรมข้อมูลสำคัญ (Infiltration and Heartbleed)

จากการวิเคราะห์ข้อมูลวรรณกรรมข้างต้น ชี้ให้เห็นว่าการบูรณาการความรู้เกี่ยวกับดัชนีชี้วัดสมรรถนะ (เช่น อัตราการใช้ทรัพยากรหน่วยประมวลผลกลางของอุปกรณ์) ร่วมกับลักษณะทางพฤติกรรมของข้อมูลในระบบ เช่น อัตราการเพิ่มขึ้นของ Broadcast Storms ตามเวลา ถือเป็นข้อมูลที่มีนัยสำคัญ ซึ่งไม่เพียงแต่ช่วยสะท้อนพฤติกรรมความผิดปกติของระบบเครือข่ายในแต่ละมิติเท่านั้น แต่ยังสามารถนำมาใช้พัฒนาเป็นตัวแบบหรือกลไกในการตรวจวัดและระบุตำแหน่งต้นตอของปัญหาในระบบเครือข่ายฯ ได้อย่างมีประสิทธิภาพ

3.2 การพยากรณ์ข้อมูลอนุกรมเวลา

การพยากรณ์ข้อมูลอนุกรมเวลาเป็นกระบวนการสำคัญที่มีการประยุกต์ใช้อย่างแพร่หลายในหลากหลายสาขาวิชา โดยขั้นตอนที่มีนัยสำคัญต่อประสิทธิภาพของแบบจำลองคือ การกำหนดจำนวนข้อมูลในอดีตที่เหมาะสม หรือค่าความหน่วงเวลา (Time-Lag) เพื่อใช้เป็นข้อมูลนำเข้า ทั้งนี้ หากกำหนดค่าความหน่วงเวลาน้อยเกินไป อาจส่งผลให้แบบจำลองมีข้อมูลไม่เพียงพอต่อการเรียนรู้แนวโน้มของข้อมูล แต่หากกำหนดค่าดังกล่าวมากเกินไป จะส่งผลให้แบบจำลองมีความซับซ้อนเกินความจำเป็น ประสิทธิภาพลดลง และใช้เวลาในการประมวลผลสูงขึ้น (Lim & Zohren, 2021)

โครงข่ายประสาทเทียมแบบหน่วงเวลา (Time-Lagged Neural Network) ถูกพัฒนาขึ้นเพื่อจัดการกับข้อมูลที่มีการเปลี่ยนแปลงตามเวลา โดยอาศัยหลักการนำข้อมูลในอดีตมาวิเคราะห์ร่วมกับข้อมูลปัจจุบันผ่านกลไกแถวคอยหน่วงเวลา (Tapped-Delay Line) (Hewamalage et al., 2021) สถาปัตยกรรมดังกล่าวได้รับการพัฒนาต่อยอดเป็นโครงข่ายประสาทเทียมแบบกระจายย้อนกลับชนิดหน่วงเวลา (Time-Lagged Backpropagation Neural Network) ซึ่งมีการบูรณาการหน่วยความจำแบบแกมมา (Gamma Memory) เข้าในแบบจำลอง โครงสร้างนี้ช่วยในการจัดเก็บประวัติการกระตุ้น (Activation History) ส่งผลให้แบบจำลองสามารถเรียนรู้ และตอบสนองต่อระบบที่มีความสัมพันธ์แบบไม่เป็นเชิงเส้น (Non-Linear) ของข้อมูลที่ซับซ้อนได้อย่างมีประสิทธิภาพ (Waqas et al., 2023)

การพัฒนาแบบจำลองโดยพิจารณาถึงความหน่วงเวลาหรือโครงข่ายประสาทเทียมแบบหน่วงเวลา ถือเป็นปัจจัยสำคัญที่ช่วยเพิ่มขีดความสามารถของระบบในการวิเคราะห์ข้อมูลที่มีรูปแบบของเวลาเข้ามาเกี่ยวข้อง การผสานสถาปัตยกรรมแบบ Tapped-Delay เข้ากับเทคนิคการหาค่าที่เหมาะสมที่สุด (Optimization) เพื่อคัดเลือกค่าความหน่วงเวลา จะเป็นส่วนสำคัญในการขับเคลื่อนให้การพยากรณ์มีความแม่นยำสูง และสามารถนำไปประยุกต์ใช้ในงานวิจัยเชิงลึกได้อย่างน่าเชื่อถือ (Surakhi et al., 2021)

3.3 การประเมินประสิทธิภาพในการทำนายผล

ในการพัฒนาระบบปัญญาประดิษฐ์ และการเรียนรู้ของเครื่อง (Machine Learning) การประเมินประสิทธิภาพของแบบจำลองถือเป็นขั้นตอนที่มีความสำคัญอย่างยิ่ง โดยเฉพาะในโมเดลประเภทการจัดหมวดหมู่ (Classification Models) เครื่องมือพื้นฐานที่ได้รับการยอมรับและนำมาใช้อย่างแพร่หลายคือ Confusion Matrix ควบคู่ไปกับการวิเคราะห์กราฟ ROC เนื่องจากสามารถให้ภาพรวมที่ครอบคลุมว่าแบบจำลองสามารถทำนายข้อมูลในแต่ละคลาสได้ดีเพียงใด และมีความเสถียรมากน้อยแค่ไหน (Luque et al., 2019)

องค์ประกอบของ Confusion Matrix สำหรับปัญหาการจำแนกประเภทแบบสองกลุ่ม (Binary Classification) จะทำการแจกแจงผลการทำนายออกเป็น 4 ส่วนหลัก ประกอบด้วย ผลลบจริง (True Negatives: TN) ผลบวกлож (False Positives: FP) ผลลบлож (False Negatives: FN) และผลบวกจริง (True Positives: TP) ซึ่งข้อมูลเชิงลึกจาก Confusion Matrix นี้ ไม่เพียงแต่แสดงความถูกต้องของการทำนายในแต่ละมิติเท่านั้น แต่ยังถูกนำไปใช้เป็นรากฐานสำคัญในการคำนวณมาตรวัดประสิทธิภาพ (Evaluation Metrics) อื่น ๆ ที่ช่วยประเมินโมเดลได้อย่างครอบคลุม ไม่ว่าจะเป็นค่า Accuracy, Precision, Recall และ F1-Score (Luque et al., 2019)

สำหรับปัญหาการจำแนกประเภทที่มีผลลัพธ์มากกว่า 2 กลุ่ม หรือการจัดหมวดหมู่แบบหลายคลาส (Multi-class Classification) โครงสร้างของ Confusion Matrix จะถูกขยายขนาดเป็นเมทริกซ์ขนาด $N \times N$ (โดย N คือจำนวนคลาสทั้งหมด) การคำนวณมาตรวัดประสิทธิภาพ เช่น Precision, Recall และ F1-Score สำหรับโมเดลลักษณะนี้ จะต้องอาศัยเทคนิคการหาค่าเฉลี่ย (Averaging Techniques) เพื่อสรุปผลรวมของทุกคลาสเข้าด้วยกัน เทคนิคที่นิยมใช้ ได้แก่ การหาค่าเฉลี่ยแบบมหภาค (Macro-Average) ซึ่งให้ความสำคัญกับทุกคลาสอย่างเท่าเทียมกันโดยไม่คำนึงถึงขนาดของคลาสมาพิจารณา และการหาค่าเฉลี่ยแบบจุลภาค (Micro-Average) ซึ่งจะนำจำนวนข้อมูลของแต่ละคลาสมาเป็นน้ำหนักในการ

คำนวณ ทำให้ได้ผลลัพธ์ที่สะท้อนความเป็นจริงได้ดีในกรณีที่ข้อมูลแต่ละคลาสมีความไม่สมดุล (Imbalanced Data) (Grandini et al., 2020)

การวิเคราะห์ประสิทธิภาพด้วยกราฟ ROC และพื้นที่ใต้โค้ง (AUC) นอกเหนือจากการพิจารณาค่าทางสถิติจาก Confusion Matrix แล้ว การประเมินความสามารถของอัลกอริทึมยังสามารถทำได้อย่างครอบคลุมมากขึ้นผ่านการวิเคราะห์กราฟ ROC ซึ่งเป็นกราฟที่แสดงความสัมพันธ์ระหว่างค่าอัตราผลบวกлож (False Positive Rate หรือ $1 - \text{Specificity}$) บน แกนนอน และค่าความไว (Sensitivity) บนแกนตั้ง โดยในกรณีของ โมเดลแบบหลายคลาส (Multi-class) จะมีการประยุกต์ใช้เทคนิคเชิงกลยุทธ์ เช่น One-vs-Rest (OvR) เพื่อพิจารณาและสร้างกราฟของทีละคลาสเทียบกับคลาสที่เหลือ การประเมินประสิทธิภาพจากกราฟ ROC จะพิจารณาจากขนาดของ “พื้นที่ใต้โค้ง” (Area Under the Curve: AUC) เป็นหลัก โดยหากค่าพื้นที่ใต้โค้งมีขนาดใหญ่ จะเป็นตัวบ่งชี้ที่ชัดเจนว่าอัลกอริทึมหรือโมเดลนั้นมีประสิทธิภาพโดยรวมที่ดีกว่า (Ahmad et al., 2021)

การประเมินประสิทธิภาพโดยใช้ Confusion Matrix เพื่อวิเคราะห์ความถูกต้องในระดับคลาส ร่วมกับการใช้กราฟ ROC และพิจารณาค่าพื้นที่ใต้โค้ง (AUC) เพื่อดูความเสถียรและความทนทานของโมเดล ถือเป็นแนวทางที่สมบูรณ์และเติมเต็มซึ่งกันและกัน เครื่องมือเหล่านี้ช่วยให้สามารถมองเห็นภาพรวมของความผิดพลาด ตัดสินใจเลือกอัลกอริทึมที่เหมาะสมที่สุด และนำไปสู่การพัฒนากระบวนการหรือระบบวิเคราะห์ข้อมูลที่มีความแม่นยำและน่าเชื่อถือสูงสุดสำหรับการใช้งานจริง (Kilincer et al., 2021)

4. กรอบแนวคิดงานวิจัย (Conceptual Framework)

กรอบแนวคิดและขั้นตอนการดำเนินงานวิจัยโดยรวมดัง Figure 1.




Figure 1. Overall Conceptual Framework for Conducting Research

จาก Figure 1. งานวิจัยนี้มุ่งเน้นการศึกษาปัญหาการเกิดปัญหาในเครือข่ายคอมพิวเตอร์ รวมทั้งพัฒนาแบบจำลองการเรียนรู้ของเครื่องเพื่อระบุตำแหน่งการเกิดปัญหาในเครือข่ายฯ อย่างเป็นระบบ กระบวนการเริ่มต้นจากการสร้างแบบจำลองสถานการณ์เครือข่าย (Network Simulation) เพื่อจัดเก็บและรวบรวมข้อมูลพฤติกรรมของข้อมูลในเครือข่ายฯ จากนั้นข้อมูลที่จัดเก็บได้จะถูกนำเข้าสู่กระบวนการเตรียมข้อมูล (Data Preprocessing) โดยการปรับช่วงข้อมูล

ให้เหมาะสมผ่านเทคนิคการแปลงข้อมูล Min-Max Normalization ร่วมกับการแปลงข้อมูลด้วยฟังก์ชันลอการิทึม (Log Transformation) เพื่อลดการกระจายตัวและความเอนเอียงของชุดข้อมูลก่อนนำไปประมวลผลร่วมกับแบบจำลอง

ในส่วนของการดำเนินงานหลัก ข้อมูลที่ผ่านการปรับสภาพแล้วจะถูกนำไปทดสอบกับแบบจำลองหลักที่นำเสนอ คือ TLBPNN พร้อมทั้งทำการเปรียบเทียบประสิทธิภาพกับแบบจำลองการเรียนรู้ของเครื่องอีก 4 ประเภท ได้แก่ DT, NB, SVM และ FFBPNN ทั้งนี้ เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือสูงสุดในการพยากรณ์ งานวิจัยนี้จึงได้ประเมินขีดความสามารถในการสรุปผลความรู้บนชุดข้อมูลที่ไม่เคยพบเห็น (Unseen Data) ควบคู่ไปกับการป้องกันปัญหาการเรียนรู้เกิน (Overfitting) และการเรียนรู้น้อยเกินไป (Underfitting) ด้วยเทคนิคการทวนสอบไขว้แบบเคโฟลด์ (K-Fold Cross-Validation) ร่วมกับการปรับแต่งค่าไฮเปอร์พารามิเตอร์ (Hyperparameter Tuning) ของแต่ละแบบจำลองให้มีความเหมาะสมที่สุด

สำหรับขั้นตอนสุดท้าย ประเมินประสิทธิภาพการจำแนกประเภทของแต่ละแบบจำลอง จะถูกวัดผลเปรียบเทียบผ่านดัชนีชี้วัด ได้แก่ Accuracy, Precision, Recall, F1-Score และ AUC

5. วิธีดำเนินงานวิจัย (Research Methodology)

งานวิจัยฉบับนี้เป็นงานวิจัยและพัฒนาที่มีวัตถุประสงค์เพื่อหาแนวทางลดระยะเวลาในการตรวจซ่อมและแก้ไขปัญหาอุปกรณ์เครือข่ายคอมพิวเตอร์ โครงสร้างเครือข่ายในปัจจุบันโดยทั่วไปอาศัยอุปกรณ์สวิตช์ระดับเลเยอร์ 2 แบบบริหารจัดการได้ ซึ่งรองรับโปรโตคอล STP ในการป้องกันปัญหา loops อย่างไรก็ตาม ในทางปฏิบัติมักมีการขยายเครือข่ายโดยใช้อุปกรณ์สวิตช์ระดับเลเยอร์ 2 แบบไม่สามารถบริหารจัดการได้ เนื่องจากมีต้นทุนที่ต่ำกว่า อุปกรณ์ประเภทนี้มีข้อจำกัดคือไม่รองรับโปรโตคอล STP ทำให้เมื่อเกิดปัญหาวนลูป ปริมาณข้อมูลมหาศาลจะแพร่กระจายและส่งผลกระทบต่อประสิทธิภาพของเครือข่ายโดยรวม จากปัญหาดังกล่าว งานวิจัยนี้จึงมุ่งเน้นการพัฒนาแบบจำลองการเรียนรู้ของเครื่อง ที่มีประสิทธิภาพสูง เพื่อนำมาประยุกต์ใช้ในการทำนายและระบุตำแหน่งการเกิดปัญหาลูปในเครือข่ายคอมพิวเตอร์ได้อย่างแม่นยำ

5.1 เครื่องมือที่ใช้ในงานวิจัย

เครื่องมือและอุปกรณ์ที่ใช้ในการดำเนินงานวิจัยแบ่งออกเป็น 2 ส่วนหลัก ๆ ตามวัตถุประสงค์ของการใช้งาน ดังนี้

1. อุปกรณ์สำหรับจำลองระบบเครือข่ายคอมพิวเตอร์

- 1) อุปกรณ์สวิตช์ระดับเลเยอร์ 2 ชนิดบริหารจัดการได้ ตราอักษร Cisco รุ่น Catalyst 2960 จำนวน 3 ชุด
- 2) อุปกรณ์สวิตช์ระดับเลเยอร์ 2 ชนิดไม่สามารถบริหารจัดการได้ ตราอักษร TP-Link จำนวน 1 ชุด

2. เครื่องมือสำหรับการจัดเก็บและประมวลผลข้อมูลเครือข่าย

1) อุปกรณ์คอมพิวเตอร์จัดเก็บข้อมูลสมรรถนะเครือข่ายและจัดการข้อมูล ได้แก่ เครื่องคอมพิวเตอร์พกพา (Laptop) ตราอักษร Lenovo รุ่น ThinkPad T480 ขนาดหน่วยความจำชั่วคราว (RAM) 16 GB ระบบปฏิบัติการ Windows 11 Pro ติดตั้งซอฟต์แวร์ PRTG Network Monitor สำหรับทำหน้าที่จัดเก็บข้อมูลพฤติกรรมและการทำงานของอุปกรณ์เครือข่าย ร่วมกับการใช้งานซอฟต์แวร์ Microsoft Excel สำหรับการบริหารจัดการ การจัดเตรียมและการปรับแต่งชุดข้อมูล จำนวน 1 เครื่อง

2) อุปกรณ์คอมพิวเตอร์จำลองการใช้งานในเครือข่าย ได้แก่ เครื่องคอมพิวเตอร์ตราอักษร HP รุ่น P3330 ขนาดหน่วยความจำชั่วคราว (RAM) 8 GB ระบบปฏิบัติการ Windows 10 Pro จำนวน 4 เครื่อง

5.2 ขั้นตอนดำเนินงานวิจัย

กระบวนการดำเนินงานวิจัยประกอบด้วย 8 ขั้นตอนหลัก ดังรายละเอียดต่อไปนี้

1. การจำลองเครือข่ายคอมพิวเตอร์ งานวิจัยนี้เลือกใช้วิธีการจำลองเครือข่ายคอมพิวเตอร์แทนการทดสอบในสภาพแวดล้อมจริง โดยทำการกำหนดค่าการทำงานของอุปกรณ์เครือข่ายด้วยการจัดสรรเครือข่ายท้องถิ่นเสมือน (VLAN) ออกเป็น 2 กลุ่ม ได้แก่ VLAN 200 สำหรับการติดต่อสื่อสารระหว่างเครื่องคอมพิวเตอร์ และ VLAN 100 สำหรับเป็นช่องสัญญาณในการจัดเก็บข้อมูลการทำงานของอุปกรณ์เครือข่าย ทั้งนี้ ในอุปกรณ์แต่ละตัวได้กำหนดให้พอร์ตหมายเลข 1 เป็นสมาชิกของ VLAN 100 กำหนดให้พอร์ตหมายเลข 2 ถึง 6 ในอุปกรณ์สวิตช์เลเยอร์ 2 ชนิดบริหารจัดการได้ ตัวที่ 1 เป็น

สมาชิกของ VLAN 200 และกำหนดให้พอร์ตหมายเลข 2 ถึง 5 ในอุปกรณ์สวิตช์เลเยอร์ 2 ชนิดบริหารจัดการได้ ตัวที่ 2 และ 3 เป็นสมาชิกของ VLAN 200 ดัง Figure 2.




Figure 2. Network Simulation

2. การจำลองสถานการณ์การเกิดปัญหา Loop (Loop Simulation) มีวัตถุประสงค์เพื่อสร้างข้อมูลจราจรบนเครือข่าย (Network Traffic) ที่สะท้อนพฤติกรรมการทำงานของอุปกรณ์เมื่อเกิดสภาวะ Loop โดยใช้ซอฟต์แวร์ PRTG Network Monitor เป็นเครื่องมือในการจัดเก็บและรวบรวมข้อมูลดังกล่าว ทั้งนี้ การทดสอบจำลองสถานการณ์ได้ดำเนินการครอบคลุมทุกพอร์ตที่ระบุให้เป็นสมาชิกของ VLAN 200 การเตรียมสภาพแวดล้อมการทดลองดำเนินการโดยเชื่อมต่อคอมพิวเตอร์เข้ากับอุปกรณ์สวิตช์เลเยอร์ 2 ทุกตัวในเครือข่ายจำลอง พร้อมกำหนดเส้นทางออกอินเทอร์เน็ตผ่านพอร์ตหมายเลข 6 ของสวิตช์บริหารจัดการได้ตัวที่ 1 แสดงใน Figure 2. สำหรับการจำลองปัญหา Loop (Loop Simulation) ผู้วิจัยดำเนินการโดยเชื่อมต่อสวิตช์เลเยอร์ 2 แบบไม่สามารถบริหารจัดการได้เข้ากับพอร์ตเป้าหมาย จากนั้นกระตุ้นการจราจรเครือข่ายผ่านการเข้าถึงเว็บไซต์ และบันทึกข้อมูลกราฟฟิกในสภาวะปกติ (Non-Loop Condition) ด้วยซอฟต์แวร์ PRTG Network Monitor ตามระยะเวลาที่กำหนด ลำดับถัดมา ผู้วิจัยได้สร้างสภาวะ Loop โดยเชื่อมต่อพอร์ต 3 และ 4 ของสวิตช์แบบไม่สามารถบริหารจัดการได้เข้าด้วยกัน เพื่อให้ Loop แพร่กระจายทั่วเครือข่าย และทำการบันทึกข้อมูลกราฟฟิกในสภาวะเกิด Loop (Loop Condition) ด้วยซอฟต์แวร์และกรอบเวลาเดิม กระบวนการทดสอบนี้จะถูกทำซ้ำโดยหมุนเวียนพอร์ตเป้าหมายจนครอบคลุมทุกพอร์ตที่เป็นสมาชิกของ VLAN 200 ทั้งนี้ หากพอร์ตเป้าหมายใดมีคอมพิวเตอร์เชื่อมต่ออยู่เดิม จะทำการย้ายอุปกรณ์ดังกล่าวไปยังพอร์ตว่างอื่นบนสวิตช์ตัวเดียวกันก่อนเริ่มการทดสอบเสมอ เพื่อควบคุมตัวแปรและรักษาความสมบูรณ์ของสถาปัตยกรรมเครือข่าย

3. การจัดเก็บและรวบรวมข้อมูลหลังการจำลองสถานการณ์ ผู้วิจัยได้รวบรวมสถิติปริมาณการจราจรเครือข่ายและอัตราการใช้ทรัพยากรหน่วยประมวลผลกลาง (CPU Utilization) ของสวิตช์เลเยอร์ 2 ทั้งในสภาวะปกติและสภาวะเกิด Loop แสดงใน Table 1. กระบวนการนี้ใช้ซอฟต์แวร์ PRTG Network Monitor ตรวจสอบสถานะของแต่ละพอร์ตด้วยความถี่ (Sampling Interval) ทุก 30 วินาที ข้อมูลเชิงปริมาณทั้งหมดที่รวบรวมได้จากทั้งสองสภาวะเครือข่ายจะถูกจัดเก็บและส่งออกในรูปแบบไฟล์ .CSV เพื่อใช้เป็นข้อมูลนำเข้าสำหรับการประมวลผลและวิเคราะห์ผลในขั้นตอนถัดไปอย่างเป็นระบบ

Table 1. Data Used for Analysis

Number	Data Name	Unit
1	Unicast Input	Bit/s
2	Unicast Output	Bit/s
3	Multicast Input	Bit/s
4	Multicast Output	Bit/s
5	Broadcast Input	Bit/s
6	Broadcast Output	Bit/s
7	CPU Utilization	Percent

4. การปรับแต่งข้อมูล เนื่องจากชุดข้อมูลที่จัดเก็บนั้นมีช่วงค่าที่ไม่เหมาะสมสำหรับป้อนเข้าสู่แบบจำลอง ซึ่งโดยทั่วไปแบบจำลองการเรียนรู้ของเครื่องจะตอบสนองได้ดีกับข้อมูลที่มีช่วงค่า $[0, 1]$ หรือ $[-1, 1]$ งานวิจัยนี้จึงเลือกใช้เทคนิค Min-Max Normalization ในการปรับช่วงข้อมูลให้อยู่ระหว่าง $[0, 1]$ ทว่าจากการตรวจสอบพบว่า ข้อมูลที่รวบรวมได้ส่วนใหญ่มีความหนาแน่นในสภาวะค่าต่ำ (เข้าใกล้ 0) มากกว่าสภาวะค่าสูง (เข้าใกล้ 1) ส่งผลให้ชุดข้อมูลเกิดความเอนเอียง (Skewed Data) ผู้วิจัยจึงได้ประยุกต์ใช้เทคนิค Log Transformation ร่วมด้วย เพื่อลดความเอนเอียงของชุดข้อมูล

ข้อมูลที่ผ่านการปรับช่วงข้อมูลให้อยู่ในช่วงระหว่าง $[0, 1]$ และแก้ไขการเอนเอียงข้อมูลเรียบร้อยแล้ว สามารถใช้ป้อนเข้าแบบจำลอง DT, NB, SVM, FFBNPNN ได้ แต่สำหรับแบบจำลอง TLBPNN นั้น ต้องทำการปรับแต่งเพิ่มเติมโดยใช้เทคนิคการหน่วงเวลาจากข้อมูลชุดเดียวกัน โดยกำหนดให้ข้อมูล ณ เวลาปัจจุบันเป็นคุณลักษณะที่ 1 (Feature 1) และข้อมูลที่ผ่านการหน่วงเวลาแล้วเป็นคุณลักษณะที่ 2 (Feature 2) ทั้งนี้ การปรับปรุงระยะเวลาในการหน่วง (Time-lag Adjustment) จะถูกดำเนินการเพื่อค้นหาค่าที่เหมาะสมที่สุดดัง Figure 3.




Figure 3. Prepare Data for Time-delay Model

X^t	X^{t^d}
t0	t-6
t1	t-5
t2	t-4
t3	t-3
t4	t-2
t5	t-1
t6	t0
t7	t1

Figure 4. Data for Time-Delay

กระบวนการเตรียมข้อมูลนำเข้าและการหน่วงเวลา (Time Lag) การเตรียมข้อมูลดำเนินการโดยป้อนข้อมูลปัจจุบันและข้อมูลที่ถูกหน่วงเวลาเข้าสู่แบบจำลองพร้อมกัน เพื่อเรียนรู้ความสัมพันธ์เชิงอนุกรมเวลาดังแสดงใน Figure 3. จากการทดสอบพบว่า การกำหนดค่าหน่วงเวลาที่ 6 ช่วงเวลา ให้ประสิทธิภาพการทำนายสูงสุด ส่งผลให้มิติข้อมูลนำเข้าเพิ่มขึ้นเป็นสองเท่าดังแสดงใน Figure 4. สำหรับปัญหาค่าสูญหายในช่วงเริ่มต้น ($t-1$ ถึง $t-6$) ได้รับการแก้ไขด้วยเทคนิคการแทนที่ข้อมูล (Data Imputation) ผ่านการสุ่มตัวอย่างเพื่อรักษาความสมบูรณ์ของชุดข้อมูลก่อนการประมวลผล

5. การแบ่งชุดข้อมูล (Data Partitioning) สำหรับฝึกสอนและทดสอบแบบจำลองใช้อัตราส่วน 80:20 จากข้อมูลรวม 350,000 ตัวอย่าง โดยแบ่งย่อยเป็น 5 ชุด ชุดละ 70,000 ตัวอย่าง ที่มีการควบคุมสัดส่วนคลาสละ 5,000 ตัวอย่างเท่ากันเพื่อแก้ปัญหาความไม่สมดุล (Data Imbalance) การจัดแบ่งนี้ดำเนินการโดยไม่สุ่มสลับลำดับข้อมูล (Without Data Shuffling) เพื่อรักษาสภาพความสัมพันธ์เชิงเวลา (Temporal Relationship) ซึ่งเป็นข้อกำหนดสำคัญในการประมวลผลชุดข้อมูลแบบหน่วงเวลา (Time-Delay Dataset)

6. การพัฒนาแบบจำลอง ผู้วิจัยเลือกใช้โปรแกรม Visual Studio Code เป็นเครื่องมือหลักในการพัฒนาแบบจำลอง โดยได้ดำเนินการสร้างแบบจำลองทั้งหมด 5 รูปแบบที่กล่าวมาแล้วด้วยภาษา Python

7. การปรับแต่งค่าไฮเปอร์พารามิเตอร์ กระบวนการปรับแต่งแบบจำลองดำเนินการผ่านการหาค่าไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุด (Hyperparameter Optimization) โดยประยุกต์ใช้เทคนิคการทวนสอบไขว้แบบ 5 ส่วน (5-Fold Cross-Validation) ในการแบ่งและสลับหมุนเวียนชุดข้อมูลทดสอบ กระบวนการนี้ช่วยประกันประสิทธิภาพสูงสุดในการทำนายของแบบจำลอง ลดความเอนเอียง และสร้างความน่าเชื่อถือที่เป็นกลางทางสถิติ

8. การประเมินประสิทธิภาพการทำนาย เมื่อแบบจำลองได้รับการพัฒนาและปรับปรุงสมรรถนะเสร็จสิ้น จะถูกนำมาทดสอบประสิทธิภาพในการจำแนกประเภท โดยผลลัพธ์การทำนายจากแบบจำลองจะแสดงผลออกมาในรูปแบบของตัวดัชนีชี้ (Index) เพื่อระบุตำแหน่งพอร์ตของอุปกรณ์สื่อสารที่เกิดปัญหาหรือไม่เกิดปัญหาลูปดัง Table 2.

Table 2. The Location of the Communication Device Port Experiencing the Loop Problem

Number	Index	Port Number
0	0	Port 2 Switch Number 1
1	1	Port 3 Switch Number 1
2	2	Port 4 Switch Number 1
3	3	Port 5 Switch Number 1
4	4	Port 6 Switch Number 1
5	5	Port 2 Switch Number 2
6	6	Port 3 Switch Number 2
7	7	Port 4 Switch Number 2
8	8	Port 5 Switch Number 2
9	9	Port 2 Switch Number 3
10	10	Port 3 Switch Number 3
11	11	Port 4 Switch Number 3
12	12	Port 5 Switch Number 3
13	13	No loop problem

6. ผลการวิจัย (Results)

6.1 ผลการศึกษาและวิเคราะห์ปรากฏการณ์ของการเกิดปัญหาลูปในเครือข่ายคอมพิวเตอร์

ปัญหาลูปในระบบเครือข่ายคอมพิวเตอร์ โดยเฉพาะอย่างยิ่งในเครือข่าย LAN ที่ทำงานบนสวิตช์เลเยอร์ 2 เกิดจากสถานะที่มีการเชื่อมต่ออุปกรณ์เครือข่ายเข้าด้วยกันในลักษณะที่เป็นวงแหวน (Ring Topology) ส่งผลให้ข้อมูลเกิดการไหลวนและทำซ้ำอย่างไม่มีที่สิ้นสุด นำไปสู่ภาวะเครือข่ายคับคั่งอย่างรุนแรง ซึ่งกลไกการเกิดปัญหาและผลกระทบมีดังนี้

1. จากการวิเคราะห์ปัญหาบนเครือข่ายสวิตช์เลเยอร์ 2 สามารถสรุปกลไกและผลกระทบของปัญหาได้ 5 ประการ ดังนี้

1) การขาดกลไกจำกัดอายุข้อมูล สวิตช์เลเยอร์ 2 ไม่มีกลไก Time-to-Live (TTL) สำหรับทำลายเฟรมข้อมูลเหมือนสวิตช์เลเยอร์ 3 ทำให้เฟรมที่อยู่ในลูปสามารถวิ่งวนในระบบได้อย่างไม่มีที่สิ้นสุด

2) การใช้อุปกรณ์ที่ไม่รองรับ STP การขยายเครือข่ายด้วยสวิตช์เลเยอร์ 2 แบบจัดการไม่ได้ ซึ่งไม่มีโปรโตคอล STP เพื่อป้องกันการวนซ้ำ เมื่อเกิดการเชื่อมต่อผิดพลาดจะทำให้ทราฟฟิกแพร่กระจายไปทั่วทั้งเครือข่าย

3) พายุบรอดแคสต์ (Broadcast Storm) การส่งข้อมูลแบบบรอดแคสต์ในลูปจะถูกส่งต่อวนซ้ำ ก่อให้เกิดปริมาณข้อมูลมหาศาลท่วมเครือข่ายและขัดขวางการสื่อสารปกติทั้งหมด

4) ความไม่เสถียรของตาราง MAC Address เฟรมที่วิ่งวนทำให้สวิตช์รับข้อมูลเดิมจากหลายพอร์ตสลับไปมา ตาราง MAC เกิดการอัปเดตซ้ำอย่างรวดเร็วจนสับสน ส่งผลให้การส่งข้อมูลแบบเจาะจง (Unicast) ล้มเหลว

5) การส่งเฟรมซ้ำซ้อน (Duplicate Frame) การคัดลอกและส่งข้อมูลวนซ้ำหลายครั้ง ทำให้สูญเสียแบนด์วิดท์และสิ้นเปลืองทรัพยากรการประมวลผลของสวิตช์และอุปกรณ์ปลายทางโดยเปล่าประโยชน์

2. ผลกระทบของปัญหาต่อประสิทธิภาพเครือข่าย (Impact on Network Performance) ปัญหาในเครือข่าย LAN ส่งผลกระทบรุนแรงและรวดเร็วต่อเสถียรภาพของระบบใน 4 ประการ ดังนี้

1) เครือข่ายล่มโดยสิ้นเชิง (Network Collapse) พายุบรอดแคสต์จะดึงทรัพยากรทั้งหมดไปใช้จนเต็มประสิทธิภาพ ทำให้การให้บริการหยุดชะงัก

2) ประสิทธิภาพลดลงอย่างรุนแรง (Poor Performance) ทราฟฟิกที่วนซ้ำจะแย่งชิงแบนด์วิดท์ ก่อให้เกิดความหน่วงสูง (High Latency) และลดความเร็วในการส่งข้อมูล

3) ภาระการประมวลผลเกินพิกัด (CPU Overload) สวิตช์ต้องประมวลผลเฟรมจำนวนมหาศาลและอัปเดตตารางเส้นทางตลอดเวลา ส่งผลให้ CPU Utilization พุ่งสูง เกิดความร้อนสะสม และบั่นทอนอายุการใช้งานฮาร์ดแวร์

4) ขาดความน่าเชื่อถือ (Unreliability) ระบบสูญเสียเสถียรภาพในการรับส่งข้อมูล ซึ่งกระทบต่อความต่อเนื่องของบริการไอทีและแอปพลิเคชันภายในองค์กรโดยตรง

6.2 ผลการพัฒนาแบบจำลองการเรียนรู้ของเครื่องสำหรับการระบุตำแหน่งการเกิดปัญหาในเครือข่ายคอมพิวเตอร์

การพัฒนาแบบจำลองระบุตำแหน่งลูปในเครือข่ายสวิตช์เลเยอร์ 2 ดำเนินการผ่านการเตรียมข้อมูลทราฟฟิกและปรับแต่งพารามิเตอร์ของ 5 แบบจำลอง เพื่อหาสถาปัตยกรรมที่เหมาะสมที่สุด มีรายละเอียดผลลัพธ์ดังนี้

1. การจัดเตรียมและปรับขนาดข้อมูลลดความแปรปรวนของข้อมูลดิบจากโปรแกรม PRTG ด้วยเทคนิค Log Transformation และปรับสเกลให้อยู่ในช่วง 0-1 ด้วยวิธี Min-Max Normalization จากนั้นแบ่งข้อมูลเป็นชุดฝึกสอนร้อยละ 80 และชุดทดสอบร้อยละ 20 ร่วมกับการใช้เทคนิคทวนสอบไขว้แบบ 5 ส่วน (5-Fold Cross-Validation) เพื่อลดความเอนเอียงและเพิ่มประสิทธิภาพในการสรุปผลของแบบจำลอง

2. โครงสร้างและการกำหนดพารามิเตอร์ของแบบจำลอง

1) แบบจำลอง DT ใช้ Gini Index โดยควบคุม Max Depth ที่ 20, Min Samples Split=2 และ Min Samples Leaf=1 เพื่อป้องกันภาวะ Overfitting

2) แบบจำลอง SVM ใช้ RBF Kernel สำหรับข้อมูลนอนลิเนียร์ กำหนด Gamma=Scale และ C=1

3) แบบจำลอง NB คำนวณความน่าจะเป็นตามการแจกแจงปกติจากข้อมูลโดยตรง ไม่ต้องกำหนดพารามิเตอร์เพิ่ม

4) แบบจำลอง FFBPNN ใช้ชั้นซ่อน 2 ชั้น (64 และ 32 โหนด) กำหนด 30 Epochs, Learning Rate=0.01 ด้วยฟังก์ชัน ReLU และ Softmax

5) แบบจำลอง TLBPNN สถาปัตยกรรมสำหรับข้อมูลทวนเวลา ใช้ชั้นซ่อน 2 ชั้น (128 และ 64 โหนด) กำหนด 60 Epochs, Learning Rate=0.001 โดยใช้ ReLU ในชั้นซ่อนร่วมกับ Softmax ในชั้นส่งออก

6.3 ผลการประเมินและเปรียบเทียบประสิทธิภาพแบบจำลองที่พัฒนาขึ้น

การระบุตำแหน่งการเกิดปัญหาหลูปในระบบเครือข่ายคอมพิวเตอร์ในงานวิจัยนี้ ดำเนินการผ่านการทดสอบแบบจำลองจำนวน 5 รูปแบบ โดยประสิทธิภาพของแต่ละแบบจำลองจะถูกประเมินด้วย Confusion Matrix เพื่อจำแนกผลการพยากรณ์ระหว่างข้อมูลที่ถูกต้องและข้อมูลที่คลาดเคลื่อน เนื่องจากชุดข้อมูลในงานวิจัยนี้ประกอบด้วยคลาสผลลัพธ์จำนวน 14 คลาส ผู้วิจัยจึงกำหนดให้ใช้การวิเคราะห์แบบ Confusion Matrix หลายกลุ่ม (Multi-class Confusion Matrix) เพื่อให้ครอบคลุมทุกมิติของการทำนาย ผลการทำนาย Confusion Matrix ของแบบจำลองทั้ง 5 แบบ แสดงใน Figure 5.




Figure 5. Confusion Matrix of Each Model

การประเมินประสิทธิภาพการทำนายของแบบจำลองทั้งหมด ดำเนินการโดยนำข้อมูลจากตาราง Confusion Matrix มาคำนวณหาค่าประสิทธิภาพ ซึ่งประกอบด้วย ค่า Precision, Recall, F1-Score, Accuracy ทั้งนี้ ผู้วิจัยได้ทำการคำนวณแยกตามแต่ละคลาส เพื่อให้เห็นถึงความสามารถของแบบจำลองในการจำแนกข้อมูลแต่ละคลาสได้อย่างชัดเจน โดยผล Accuracy และ Precision แสดงไว้ใน Table 3 และ ค่า Recall และ F1-Score แสดงไว้ใน Table 4.

Table 3. The Results of the Accuracy and Precision of Each Model

class	Accuracy					Precision				
	DT	NB	SVM	FFBPNN	TLBPNN	DT	NB	SVM	FFBPNN	TLBPNN
0	0.963	0.9474	0.6776	0.9843	0.9818	1	1	1	0.8699	1
1	0.9644	0.9488	0.6649	0.9785	0.9968	0.8241	1	1	1	0.999
2	0.8922	0.9505	0.6328	0.9769	0.9896	0.3661	1	0.9923	0.9682	0.8922
3	0.9358	0.9535	0.5662	0.9736	0.9927	0.5549	0.9855	0.9708	0.8809	0.9714
4	0.9423	0.9539	0.6702	0.9836	0.9973	0.6319	1	1	0.9896	0.9998
5	0.978	0.9484	0.6355	0.998	0.999	1	1	1	0.9767	1
6	0.9564	0.9433	0.6693	0.9904	0.9867	1	1	1	0.966	0.9809
7	0.9203	0.9472	0.6397	0.9843	0.9895	0.4507	1	0.9987	0.8549	0.9974
8	0.963	0.9508	0.6775	0.9319	0.9758	0.9967	0.9314	0.9144	0.5126	0.872
9	0.9671	0.9476	0.6858	0.9878	0.9932	1	1	0.9789	1	0.9748
10	0.951	0.9544	0.6772	0.9897	0.9974	0.6777	1	0.9555	0.9938	0.9737
11	0.8764	0.9525	0.684	0.9823	0.9958	0.3348	1	0.9861	0.9027	0.9952
12	0.973	0.9529	0.6854	0.9889	0.9974	1	1	0.9962	0.9787	0.9943
13	0.9129	0.3699	0.2285	0.9641	0.9406	0.45	0.1018	0.1296	0.6661	0.5464
Average	0.938	0.868	0.611	0.976	0.984	0.701	0.862	0.851	0.844	0.908

Table 4. The Results of the Recall and F1-Score of Each Model

class	Recall					F1-Score				
	DT	NB	SVM	FFBPNN	TLBPNN	DT	NB	SVM	FFBPNN	TLBPNN
0	0.482	0.263	0.512	0.9172	0.7446	0.65	0.417	0.678	0.8929	0.8536
1	0.637	0.284	0.498	0.6994	0.9568	0.719	0.442	0.665	0.8231	0.9774
2	0.696	0.307	0.464	0.6992	0.9718	0.48	0.47	0.633	0.812	0.9303
3	0.515	0.354	0.4	0.7294	0.9244	0.534	0.521	0.566	0.798	0.9473
4	0.461	0.354	0.504	0.7792	0.9622	0.533	0.523	0.67	0.8719	0.9806
5	0.692	0.278	0.466	0.9958	0.9858	0.818	0.435	0.636	0.9861	0.9928
6	0.39	0.206	0.503	0.8968	0.8306	0.561	0.342	0.669	0.93	0.8995
7	0.528	0.261	0.471	0.94	0.8558	0.486	0.414	0.64	0.8954	0.9212
8	0.484	0.337	0.538	0.9504	0.7756	0.652	0.494	0.678	0.666	0.821
9	0.54	0.266	0.528	0.829	0.9282	0.701	0.421	0.686	0.9065	0.9509
10	0.599	0.362	0.524	0.861	0.991	0.636	0.531	0.677	0.9226	0.9823
11	0.739	0.335	0.524	0.8426	0.9462	0.461	0.502	0.684	0.8716	0.9701
12	0.621	0.341	0.522	0.8638	0.9694	0.767	0.508	0.685	0.9176	0.9817
13	0.987	1	0.963	0.9962	0.994	0.618	0.185	0.229	0.7983	0.7051
Average	0.598	0.353	0.530	0.857	0.917	0.615	0.443	0.628	0.864	0.922

จากการประเมินพบว่า แบบจำลอง TLBPNN แสดงประสิทธิภาพสูงสุด (F1-Score 0.95-0.99) ในกลุ่มคลาสที่มีความซับซ้อนเชิงมิติ (คลาส 1, 4, 5, 9-12) และกลุ่มที่มีความผันแปรตามเวลาสูง (คลาส 2, 3, 7) เนื่องจากคุณสมบัติ Time-Lagged ช่วยให้เรียนรู้ความสัมพันธ์และลำดับเวลาได้ดีกว่าโมเดลอื่น ๆ (DT, NB, SVM) อย่างไรก็ตาม สำหรับความผิดปกติแบบฉับพลัน (คลาส 0, 6) แบบจำลอง BBPNN ตอบสนองได้ดีกว่าเล็กน้อย แต่กลับมีผลบวกสูงมากในคลาส 8

ซึ่ง TLBPNN สามารถจัดการได้ดีกว่า นอกจากนี้พบข้อสังเกตสำคัญในคลาส 13 ที่ทำหน้าที่เสมือนคลาสสำรอง (Fallback Class) เมื่อเผชิญข้อมูลที่มีพีเพอร์ทับซ้อนกันสูง แบบจำลองมักเอนเอียงการทำนายมาที่คลาสนี้ ส่งผลให้ค่า Recall สูงแต่ค่า Precision ต่ำมาก

ผลการประเมินประสิทธิภาพภาพรวม (Macro-Average) แบบจำลอง TLBPNN มีประสิทธิภาพสูงสุดและสมดุลที่สุด (Precision 0.9427, Recall 0.9169, F1-Score 0.9224, Accuracy 0.9881) ขณะที่ BBPNN อยู่ในเกณฑ์ดีแต่ขาดการประมวลผลมิติเวลา ส่วน NB และ SVM ขาดความครอบคลุมส่งผลให้ F1-Score ต่ำสุด สำหรับแบบจำลอง DT ขาดความยืดหยุ่น แม้ Accuracy จะสูงถึง 0.9426 แต่ F1-Score กลับต่ำเพียง 0.6154 ซึ่งให้เห็นว่าการพิจารณาด้วยค่า Accuracy เพียงอย่างเดียวไม่สามารถสะท้อนประสิทธิภาพที่แท้จริงของการทำนายในชุดข้อมูลนี้ได้ งานวิจัยนี้จึงประยุกต์ใช้เส้นโค้ง ROC และค่า AUC ที่มุ่งประเมินความสัมพันธ์ระหว่างอัตราผลบวกจริง (TPR) เทียบกับผลบวกлож (FPR) เพื่อความรัดกุมแทนความถูกต้องในภาพรวม โดยผลการประเมินประสิทธิภาพของแบบจำลองทั้ง 5 สถาปัตยกรรมได้แสดงไว้ในรูปแบบเส้นโค้ง ROC ดัง Figure 6.




Figure 6. ROC and AUC of Each Model

จากกราฟ ROC ชี้ให้เห็นว่าแบบจำลองโครงข่ายประสาทเทียม (TLBPNN, FFBPNN) มีความโค้งชันเข้าใกล้มุมซ้ายบนมากกว่า DT, NB และ SVM อย่างชัดเจน ซึ่งบ่งบอกถึงประสิทธิภาพในการแยกแยะข้อมูลที่สูงกว่า ทั้งนี้ผู้วิจัยได้คำนวณพื้นที่ใต้โค้ง (AUC) ทั้งแบบรายคลาสและค่าเฉลี่ยรวม ด้วยเทคนิค Macro-average เพื่อประเมินทุกคลาสอย่างเท่าเทียมกัน โดยผลการคำนวณค่า AUC ทั้งหมดได้สรุปผลไว้ใน Table 4.

Table 4. The Results of Area Under the Curve of Each Model

Class	DT	NB	SVM	FFBPNN	TLBPNN
0	0.963	0.812	0.835	1	0.96
1	0.619	0.865	0.804	0.98	1
2	0.663	0.84	0.747	0.98	1
3	0.582	0.84	0.73	0.91	0.98
4	0.709	0.875	0.828	0.98	1
5	0.64	0.883	0.815	1	1
6	0.693	0.74	0.761	0.99	0.96
7	0.738	0.84	0.765	0.99	0.96
8	0.763	0.899	0.869	0.97	0.99
9	0.772	0.839	0.813	1	0.98
10	0.768	0.858	0.855	1	1
11	0.628	0.84	0.806	0.99	1
12	0.613	0.88	0.807	0.99	1
13	0.567	0.675	0.876	0.99	0.98
Average	0.694	0.835	0.808	0.984	0.986

จาก Table 4. ผลการทดสอบชี้ชัดว่าแบบจำลองโครงข่ายประสาทเทียมมีประสิทธิภาพเหนือกว่าแบบจำลอง DT, NB และ SVM โดย TLBPNN เป็นสถาปัตยกรรมที่เหมาะสมที่สุด ให้ค่าเฉลี่ย AUC สูงสุดที่ 0.986 และจำแนกข้อมูลได้สมบูรณ์แบบ (AUC=1.0) ถึง 7 คลาส รองลงมาคือ FFBPNN (AUC=0.984) ซึ่งทำได้ดีกว่าเล็กน้อยในคลาส 0, 6 และ 7 ที่ลักษณะข้อมูลอาจไม่สอดคล้องกับกลไกเชิงเวลา ในกลุ่มแบบจำลอง DT มีประสิทธิภาพต่ำสุด (AUC=0.694) ไม่สามารถรองรับความซับซ้อนของข้อมูลได้ ขณะที่ NB และ SVM ยังมีความแปรปรวนสูงและขาดความเสถียร สรุปได้ว่า TLBPNN เป็นแนวทางที่เหมาะสมที่สุด มอบความแม่นยำและเสถียรภาพสูงสุดในการจำแนกข้อมูลได้อย่างครอบคลุม

7. สรุปผลการวิจัยและอภิปรายผลการวิจัย (Conclusion and Discussion)

งานวิจัยการเรียนรู้ของเครื่องที่ใช้โครงข่ายประสาทเทียมแบบกระจายย้อนกลับชนิดหนึ่งช่วงเวลา เพื่อระบุตำแหน่งปัญหาอุปในเครือข่ายสวิตช์เลเยอร์ 2 สามารถสรุปผล และอภิปรายผลการวิจัยโดยเปรียบเทียบกับงานวิจัยอื่นที่เกี่ยวข้องได้ดังนี้

1. สรุปประสิทธิภาพแบบจำลองการทำนายตำแหน่งอุป

จากการทดสอบพบว่าแบบจำลอง TLBPNN มีประสิทธิภาพสูงสุดและสมดุลในทุกมิติ (Precision 0.9427, Recall 0.9169, F1-Score 0.9224, Accuracy 0.9881, AUC 0.986) รองลงมาคือ BBPNN ขณะที่แบบจำลอง DT, NB และ SVM มีค่า Recall ต่ำและล้มเหลวในการตรวจจับหลายคลาส ซึ่งผลลัพธ์นี้สอดคล้องกับงานวิจัยของ Ferrag et al. (2020) ที่ระบุว่าอัลกอริทึมดั้งเดิมมีข้อจำกัดในการประมวลผลข้อมูลเครือข่ายที่มีความซับซ้อนและมีมิติสูง จึงมีประสิทธิภาพด้อยกว่าแบบจำลองโครงข่ายประสาทเทียมอย่างชัดเจน

2. ประสิทธิภาพการทำนายข้อมูลที่เปลี่ยนแปลงตามเวลา

แบบจำลอง TLBPNN โดดเด่นในการจำแนกข้อมูลที่มีความผันแปรตามเวลาสูง (คลาส 2, 3, 7) ด้วยคุณลักษณะช่วงเวลา แต่สำหรับความผิดปกติแบบฉับพลัน (คลาส 0, 6) BBPNN กลับให้ผลลัพธ์ที่ดีกว่า ซึ่งสอดคล้องกับ Le et al. (2019) ที่พบว่าโมเดลเชิงเวลาเหมาะกับการเปลี่ยนแปลงต่อเนื่อง ขณะที่ความผิดปกติแบบฉับพลัน (Point anomalies) เหมาะกับการใช้ FFBPNN ที่ไม่ใช้ข้อมูลย้อนหลังเพื่อลดความซับซ้อนและเพิ่มความเร็ว

3. ปัญหาการทับซ้อนของสัญญาณเครือข่าย (Feature Overlapping)

เมื่อเผชิญข้อมูลคลุมเครือ ทุกแบบจำลองมักเอนเอียงการทำนายไปที่คลาส 13 (Fallback Class) ทำให้ผลบวกสูงขึ้น โดยเฉพาะแบบจำลอง DT ที่ค่า AUC ลดเหลือเพียง 0.567 สะท้อนว่าแบบจำลอง DT ไม่สามารถรองรับความซับซ้อนนี้ได้ สอดคล้องกับ Berman et al. (2019) ที่พบว่าเมื่อข้อมูลมีการทับซ้อนสูง โมเดลเชิงเส้นและแบบจำลอง DT จะเกิดความลำเอียง (Bias) ไปยังคลาสทางออกหลักเพื่อลดข้อผิดพลาดรวม ส่งผลให้ประสิทธิภาพในคลาสนั้นลดลงอย่างรวดเร็ว

4. ความสำคัญของการประเมินด้วย ROC และ AUC

ในสภาวะข้อมูลเครือข่ายไม่สมดุล (Class Imbalance) ซึ่งปัญหาลุप्तมีส่วนการเกิดน้อยมาก การพิจารณาเพียงค่า Accuracy อาจทำให้ผลลัพธ์บิดเบือน งานวิจัยจึงใช้ค่า AUC ซึ่งพิสูจน์ว่าแบบจำลองโครงข่ายประสาทเทียมมีเสถียรภาพสูงในการแยกความผิดปกติ (True Positive) ออกจากสัญญาณหลอก (False Positive) โดยเฉพาะแบบจำลอง TLBPNN ที่ค่าคะแนน AUC ได้สมบูรณ์แบบ (1.0) ถึง 7 คลาส เป็นการยืนยันถึงประสิทธิภาพและเสถียรภาพสูงสุดในการนำไปประยุกต์ใช้งานจริง

5. ข้อจำกัดของการวิจัย (Limitations)

แม้แบบจำลอง TLBPNN จะมีความแม่นยำสูง แต่การใช้งานจริงยังมีข้อจำกัด เนื่องจากการศึกษานี้ดำเนินการบนเครือข่ายขนาดเล็กระดับห้องปฏิบัติการ ซึ่งอาจมีเงื่อนไขพฤติกรรมเฉพาะของผู้ผลิตอุปกรณ์ (Vendor-Specific) นอกจากนี้ การใช้แบบจำลองเชิงเวลายังมีความเสี่ยงเรื่องการรั่วไหลของข้อมูล (Temporal Leakage) และความหน่วงในการประมวลผลจริง (Deployment Latency) ซึ่งเป็นความท้าทายที่ต้องศึกษาและพัฒนาเพิ่มเติมในอนาคต

8. ข้อเสนอแนะงานวิจัย (Recommendation)

8.1 ข้อเสนอแนะในงานวิจัยครั้งต่อไป

1. การขยายขนาดและการทดสอบในสภาพแวดล้อมจริง

เนื่องจากการศึกษานี้จำกัดอยู่บนเครือข่ายจำลองขนาดเล็ก งานวิจัยในอนาคตจึงควรนำแบบจำลองไปทดสอบในเครือข่ายจริงที่มีขนาดใหญ่ ซับซ้อน และใช้อุปกรณ์หลากหลายผู้ผลิต เพื่อประเมินความเสถียรและความสามารถในการสรุปผลของแบบจำลองในการใช้งานจริง

2. การเปรียบเทียบกับแบบจำลอง Deep Learning

งานวิจัยในอนาคตควรนำสถาปัตยกรรมระดับลึก เช่น RNNs และ LSTM ที่มีจุดเด่นในการดักจับความสัมพันธ์เชิงเวลา มาประเมินเปรียบเทียบกับแบบจำลอง TLBPNN เพื่อยกระดับความแม่นยำและประสิทธิภาพในการตรวจจับปัญหาลุप्तให้สูงขึ้น

8.2 การประยุกต์ใช้ในงานวิจัย

1. การลดเวลาและทรัพยากรในการแก้ไขปัญหา

แบบจำลอง TLBPNN สามารถระบุตำแหน่งพอร์ตที่เกิดลูปได้แม่นยำถึงร้อยละ 91.46 ซึ่งสามารถนำไปใช้บนเครื่องมือสนับสนุนผู้ดูแลระบบเพื่อลดภาระและระยะเวลาในการลงพื้นที่ตรวจสอบทางกายภาพ ส่งผลให้องค์กรสามารถกู้คืนระบบเครือข่ายได้อย่างรวดเร็ว

2. การเสริมสร้างความปลอดภัยภายใต้ข้อจำกัดงบประมาณ

การนำแบบจำลองมาเฝ้าระวังทราฟฟิกตอบโจทยองค์กรที่ขยายเครือข่ายด้วย Unmanaged Switch ซึ่งไม่มีโปรโตคอล STP โดยช่วยลดความเสี่ยงจากการเกิดพายุบรอดแคสต์ (Broadcast Storm) และป้องกันการแพร่กระจายข้อมูลที่ส่งผลกระทบต่อประสิทธิภาพเครือข่ายโดยรวม

9. การเปิดเผยการใช้ปัญญาประดิษฐ์เชิงสร้างสรรค์ (Declaration of Generative AI)

งานวิจัยนี้ใช้ Gemini ในการปรับแก้ข้อความให้เป็นเชิงวิชาการอ่านเลื่องไหลแก้ไขคำผิด และใช้แปลข้อความจากภาษาไทยเป็นภาษาอังกฤษ ใช้ ChatGPT ในการปรับภาพ (Figure) ให้ชัดเจน หลังจากนั้นทำการตรวจสอบแก้ไขด้วยตนเองอีกครั้ง

10. การแสดงบทบาทผู้เขียน (CRediT Author Statement)

Soradet Chaowinai: Conceptualization, Methodology, Software, Validation, Investigation, Data Curation, Writing-Original Draft, Visualization

Nithizethe Mhuadthongon: Conceptualization, Methodology, Validation, Formal Analysis, Investigation, Resources, Writing-Review & Editing, Supervision, Project Administration

Apirada Jitjing: Conceptualization, Investigation, Resources, Data Curation, Writing-Review & Editing
All authors read and approved the final manuscript.

11. เอกสารอ้างอิง (References)

- Ahmad, Z., Khan, A. H., Shiang, C. W., Abdullah, J., & Ahmad, F. (2021). Network Intrusion Detection System: A Systematic Study of Machine Learning and Deep Learning Approaches. *Transactions on Emerging Telecommunications Technologies*, 32(1), e4150. <https://doi.org/10.1002/ett.4150>
- Berman, D. S., Buczak, A. L., Chavis, J. S., & Corbett, C. L. (2019). A Survey of Deep Learning Methods for Cyber Security. *Information*, 10(4), 122. <https://doi.org/10.3390/info10040122>
- Ferrag, M. A., Maglaras, L., Moschogiannis, S., & Janicke, H. (2020). Deep Learning for Cyber Security Intrusion Detection: Approaches, Datasets, and Comparative Study. *Journal of Information Security and Applications*, 50, 102419. <https://doi.org/10.1016/j.jisa.2019.102419>
- Grandini, M., Bagli, E., & Visani, G. (2020). *Metrics for Multi-Class Classification: An Overview*. arXiv. <https://doi.org/10.48550/arXiv.2008.05756>
- Hewamalage, H., Bergmeir, C., & Bandara, K. (2021). Recurrent Neural Networks for Time Series Forecasting: Current Status and Future Directions. *International Journal of Forecasting*, 37(1), 388–427. <https://doi.org/10.1016/j.ijforecast.2020.06.008>
- Institute of Electrical and Electronics Engineers. (2004). *802.1D-2004 - IEEE Standard for Local and Metropolitan Area Networks: Media Access Control (MAC) Bridges*. <https://doi.org/10.1109/IEEESTD.2004.94569>
- Kilincer, I. F., Ertam, F., & Sengur, A. (2021). Machine Learning Methods for Cyber Security Intrusion Detection: Datasets and Comparative Study. *Computer Networks*, 188, 107840. <https://doi.org/10.1016/j.comnet.2021.107840>
- Le, T.-T.-H., Kim, Y., & Kim, H. (2019). Network Intrusion Detection Based on Novel Feature Selection Model and Various Recurrent Neural Networks. *Applied Sciences*, 9(7), 1392. <https://doi.org/10.3390/app9071392>
- Lim, B., & Zohren, S. (2021). Time-Series Forecasting with Deep Learning: A Survey. *Philosophical transactions - Royal Society. Mathematical, Physical and Engineering Sciences*, 379(2194), 20200209. <https://doi.org/10.1098/rsta.2020.0209>
- Luque, A., Carrasco, A., Martín, A., & De Las Heras, A. (2019). The Impact of Class Imbalance in Classification Performance Metrics Based on the Binary Confusion Matrix. *Pattern Recognition*, 91, 216–231. <https://doi.org/10.1016/j.patcog.2019.02.023>

- Pešović, U., Pešović, S. Đ., Savić, B., & Marković, D. (2024, 20-22 September). Detection of Broadcast Storms in Local Area Networks. *10th International Scientific Conference Technics, Informatic, and Education*, 136–139. <https://doi.org/10.46793/TIE24.136P>
- Surakhi, O., Zaidan, M. A., Fung, P. L., Hossein Motlagh, N., Serhan, S., AlKhanafseh, M., Ghoniem, R. M., & Hussein, T. (2021). Time-Lag Selection for Time-Series Forecasting Using Neural Network and Heuristic Algorithm. *Electronics*, 10(20), 2518. <https://doi.org/10.3390/electronics10202518>
- Waqas, M., Humphries, U. W., Wangwongchai, A., Dechpichai, P., & Ahmad, S. (2023). Potential of Artificial Intelligence-Based Techniques for Rainfall Forecasting in Thailand: A Comprehensive Review. *Water*, 15(16), 2979. <https://doi.org/10.3390/w15162979>