



วารสารวิศวกรรมศาสตร์และนวัตกรรม Journal of Engineering and Innovation

บทความวิจัย

การพัฒนาโมเดลปัญญาประดิษฐ์เพื่อจำแนกเหตุการณ์การหยุดชะงักของเครื่องจักร ในระยะเวลาสั้น: กรณีศึกษาโรงงานผลิตเครื่องดื่ม

Development of an artificial intelligence model for classifying short-duration machine stoppages: A case study of a beverage manufacturing plant

กัญยารัตน์ วรชาติไพศาล* นพคุณ แสงเขียว

ภาควิชาวิศวกรรมอุตสาหการและการจัดการ คณะวิศวกรรมศาสตร์และเทคโนโลยีอุตสาหกรรม มหาวิทยาลัยศิลปากร 73000

Kanyarat Worachatphaisan* Noppakun Sangkhiew

Department of Industrial Engineering and Management, Faculty of Engineering and Industrial Technology, Silpakorn University 73000

* Corresponding author.

E-mail: Worachatphaisan_K@su.ac.th; Telephone: 0961681610

วันที่รับบทความ 17 ธันวาคม 2568; วันที่แก้ไขบทความ ครั้งที่ 1 12 กุมภาพันธ์ 2569; วันที่ตอบรับบทความ 2 มีนาคม 2569

บทคัดย่อ

ในอุตสาหกรรมการบรรจุเครื่องดื่ม การหยุดชะงักของเครื่องจักรในระยะเวลาสั้นสามารถส่งผลกระทบต่อประสิทธิภาพการผลิตโดยรวมอย่างมีนัยสำคัญ งานวิจัยนี้พัฒนาโมเดลปัญญาประดิษฐ์โดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Perceptron: MLP) เพื่อจำแนกเหตุการณ์การหยุดชะงักระยะสั้น (Minor Stoppage) บนสายการบรรจุกระป๋องออกเป็น 2 ระดับ ได้แก่ General-Minor Stoppage (GM) และ Major-Minor Stoppage (Mi) และประเมินประสิทธิภาพด้วยการตรวจสอบความถูกต้องแบบไขว้สำหรับข้อมูลอนุกรมเวลาแบบเดินหน้า (Walk-Forward Time-Series Cross-Validation) 5 รอบ ผลการทดลองพบว่าโมเดลมีค่าเฉลี่ย Macro-F1 เท่ากับร้อยละ 92.00 ($\sigma = 8.40$) และค่าเฉลี่ย Mi-F1 เท่ากับร้อยละ 84.48 ($\sigma = 15.97$) สะท้อนถึงความสามารถในการจำแนกคลาสได้อย่างสมดุล แม้ข้อมูลมีความไม่สมดุลระหว่างกลุ่มเหตุการณ์ โดยเหตุการณ์ส่วนใหญ่จัดอยู่ในกลุ่ม GM ร้อยละ 62.83 ขณะที่กลุ่ม Mi มีร้อยละ 6.67 แต่เป็นสาเหตุหลักของการสูญเสียเชิงประสิทธิภาพ ผลลัพธ์แสดงให้เห็นว่าโมเดลที่พัฒนาขึ้นสามารถก้าวข้ามข้อจำกัดของวิธีการติดตามแบบดั้งเดิม โดยทำหน้าที่เป็นเครื่องมืออัจฉริยะสำหรับติดตาม วิเคราะห์ และแจ้งเตือนเหตุหยุดเครื่องจักรได้อย่างเป็นระบบ ระบบสามารถตรวจจับสัญญาณความผิดปกติในระยะเริ่มต้น เพื่อให้พนักงานตอบสนองได้ก่อนเกิดความเสียหายรุนแรง ซึ่งช่วยสนับสนุนการวางแผนบำรุงรักษาเชิงรุกลดระยะเวลาหยุดเครื่องจักรที่ไม่ได้วางแผนไว้ ยกระดับค่า OEE อย่างเป็นรูปธรรม และเพิ่มขีดความสามารถในการแข่งขันระยะยาวของโรงงานผลิตเครื่องดื่ม

คำสำคัญ

การหยุดชะงักระยะสั้น โครงข่ายประสาทเทียม การตรวจสอบความถูกต้องแบบไขว้สำหรับข้อมูลอนุกรมเวลาแบบเดินหน้า การจำแนกประเภท

Abstract

In the beverage packaging industry, even short-duration machine interruptions can significantly affect overall production performance (Overall Equipment Effectiveness: OEE). This study presents the development of an artificial intelligence model using a Multilayer Perceptron (MLP) Artificial Neural Network to classify short-duration machine stoppage (Minor Stoppage) events on a can-filling line. The model was evaluated using 5-fold walk-forward time-series

cross-validation to ensure robust performance under sequential data conditions. The evaluation results indicate that the proposed ANN model achieved a high overall performance, with a mean macro-F1 score of 92.00% ($\sigma = 8.40\%$) and a mean Mi-F1 score of 84.48% ($\sigma = 15.97\%$). The model was also able to systematically categorize stoppage events, revealing that most cases were classified as short, non-repetitive interruptions (General-Minor Stoppage: GM), accounting for 62.83% of all events. Meanwhile, severe short stoppages (Major-Minor Stoppage: Mi) comprised only 6.67% but were identified as a major source of production efficiency losses. Traditional monitoring methods could not clearly distinguish between routine and severe short-duration stoppages. These findings demonstrate that the developed ANN model has strong potential to serve as an intelligent tool for automatic monitoring and analysis of machine stoppage events. It can detect early signs of abnormality and alert operators to take corrective action before serious failures occur. Consequently, the system enables proactive maintenance planning, reduces unplanned downtime, and enhances OEE in a tangible way, and ultimately improves the long-term efficiency and competitiveness of beverage manufacturing plants.

Keywords

minor stoppage; artificial neural network; time-series cross-validation; classification

1. บทนำ

ในอุตสาหกรรมการผลิตเครื่องดื่ม สายการบรรจุแบบต่อเนื่อง (Beverage Filling Line) มีบทบาทสำคัญอย่างยิ่งต่อความสามารถในการแข่งขันขององค์กร โดยเฉพาะอย่างยิ่งการรักษาค่าประสิทธิภาพโดยรวมของเครื่องจักร (Overall Equipment Effectiveness: OEE) ให้อยู่ในระดับสูง ซึ่งเป็นดัชนีชี้วัดสำคัญที่สะท้อนถึงขีดความสามารถในการควบคุมต้นทุนการผลิตและความพร้อมในการส่งมอบสินค้าได้ตามกำหนดเวลา ทั้งนี้ อุตสาหกรรมเครื่องดื่มทั่วโลกยังคงมีแนวโน้มเติบโตอย่างต่อเนื่อง โดยคาดการณ์อัตราการเติบโตเฉลี่ยต่อปี ประมาณร้อยละ 4.16 ในช่วงปี ค.ศ. 2025 – ค.ศ. 2030 [1] ส่งผลให้ผู้ประกอบการต้องให้ความสำคัญกับการเพิ่มประสิทธิภาพในกระบวนการผลิตเพื่อรักษาความได้เปรียบในตลาดโลก

หนึ่งในปัญหาสำคัญที่ขัดขวางการบรรลุเป้าหมายประสิทธิภาพสูงสุดในระบบการผลิตคือ การหยุดชะงักของเครื่องจักรในระยะเวลาด้าน (Minor Stoppage: MS) ซึ่งหมายถึงเหตุการณ์ที่เครื่องจักรหยุดทำงานชั่วคราวในช่วงเวลาสั้น ๆ โดยทั่วไปมักน้อยกว่า 5 นาที แต่เกิดขึ้นด้วยความถี่ที่สูงตลอดการปฏิบัติงาน [2]–[4] แม้เหตุการณ์แต่ละครั้งจะดูไม่รุนแรงและมักไม่ถูกบันทึกเป็นเวลาขัดข้องหลัก (Major Breakdown) แต่เมื่อเกิดการสะสมจะก่อให้เกิดเวลาสูญเสีย (Loss Time) มหาศาล ซึ่งจัดเป็นความสูญเสียสะสมเรื้อรัง (Chronic Losses) ที่บั่นทอนกำลังการผลิตและเพิ่มต้นทุนแฝงอย่างมีนัยสำคัญ [5]–[7] นอกจากนี้ การหยุดชะงักระยะสั้นยัง

ส่งผลกระทบต่อมิติอื่น ๆ เช่น ความเสี่ยงด้านคุณภาพจากการแปรปรวนของกระบวนการในช่วงเริ่มต้นใหม่ (Startup) ภาระงานที่เพิ่มขึ้นของพนักงาน และการใช้พลังงานที่ไม่เกิดประโยชน์ [5], [6], [8]

ตามกรอบแนวคิดการบำรุงรักษาที่ทุกคนมีส่วนร่วม (Total Productive Maintenance: TPM) การหยุดชะงักระยะสั้นถูกจัดให้เป็นหนึ่งใน Six Big Lossesภายใต้หมวดหมู่ Idling and Minor Stoppages [2], [5] แม้จะมีแนวทางเชิงทฤษฎีในการจัดการปัญหา เช่น หลักการ TPM หรือการผลิตแบบลีน (Lean Manufacturing) ที่มุ่งเน้นการกำจัดความสูญเสียดังกล่าว [3], [5], [7] แต่ในภาคปฏิบัติ โรงงานจำนวนมากยังเผชิญความท้าทายในการวิเคราะห์ข้อมูล Minor Stoppage อย่างเป็นระบบ เนื่องจากข้อมูลมีปริมาณมหาศาล กระจาย และมีความไม่สมดุลของคลาสข้อมูล (Class Imbalance) ซึ่งจำกัดความสามารถในการระบุสาเหตุรากเหง้า (Root Cause Analysis) และทำให้การตอบสนองเชิงรุกเป็นไปได้ยาก

จากปัญหาดังกล่าว งานวิจัยนี้จึงมุ่งเน้นการพัฒนาโมเดลปัญญาประดิษฐ์โดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Perceptron: MLP) เพื่อจำแนกประเภทเหตุการณ์หยุดชะงักระยะสั้นตามระดับความรุนแรง โดยเน้นการประมวลผลข้อมูลผสม (Hybrid Data) ระหว่างข้อความอาการเสียและบริบทการดำเนินงาน และประเมินผลด้วยวิธี Walk-Forward Time-Series Cross-Validation 5 Folds เพื่อให้สะท้อนประสิทธิภาพโมเดลในสภาวะการใช้งานจริง

ตามลำดับเวลา นอกจากนี้ งานวิจัยยังให้ความสำคัญกับการปรับเทียบความน่าเชื่อถือของโมเดล (Probability Calibration) เพื่อให้ผลการทำนายมีระดับความเชื่อมั่นที่แม่นยำแม้ในสถานะข้อมูลไม่สมดุล [4], [6], [8], [9], [17]

จากการทบทวนวรรณกรรมพบว่า งานวิจัยก่อนหน้าส่วนใหญ่เน้นการตรวจจับความผิดปกติหรือทำนายการหยุดเครื่องจักรโดยรวม แต่ยังขาดแนวทางการจำแนกความรุนแรงของ Minor Stoppage อย่างเป็นระบบ โดยเฉพาะในบริบทข้อมูลอนุกรมเวลา (Time-series context) ที่สะท้อนพฤติกรรมการเกิดซ้ำในสายการผลิต งานวิจัยนี้จึงมุ่งเติมเต็มช่องว่างดังกล่าวด้วยการพัฒนาโมเดลที่สามารถแยกแยะระหว่างเหตุการณ์ทั่วไป (General-Minor Stoppage: GM) และเหตุการณ์รุนแรงหรือเรื้อรัง (Major-Minor Stoppage: Mi) ได้อย่างมีประสิทธิภาพ ภายใต้เงื่อนไขข้อมูลที่คลาสสำคัญมีสัดส่วนน้อย (Long-tailed recognition) [18] เพื่อสนับสนุนการตัดสินใจบำรุงรักษาเชิงรุกและยกระดับประสิทธิภาพ OEE ในอุตสาหกรรมการบรรจุเครื่องดื่มอย่างยั่งยืน

2. ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

บทนี้สรุปกรอบแนวคิดและงานวิจัยที่เกี่ยวข้องกับการหยุดชะงักระยะสั้นในสายการผลิตแบบต่อเนื่อง โดยครอบคลุมแนวคิดด้าน OEE และ TPM แนวคิดความสูญเสียสะสมเรื้อรัง (Chronic Losses: CL) ผลกระทบเชิงมิติประสิทธิภาพและต้นทุนแฝง ตลอดจนการเปรียบเทียบแนวทางปรับปรุงแบบดั้งเดิมกับการประยุกต์ใช้ MLP และเทคนิคการปรับเทียบความน่าเชื่อถือของโมเดล เพื่อสนับสนุนการติดตามและวิเคราะห์เหตุการณ์เชิงรุกภายใต้สถานะข้อมูลที่มีความไม่สมดุลในบริบทอุตสาหกรรมการผลิต

2.1 OEE และการจัดการความสูญเสียในระบบ TPM

ประสิทธิผลโดยรวมของเครื่องจักรเป็นดัชนีชี้วัดหลักที่สะท้อนสมรรถนะของระบบการผลิตผ่านมิติความพร้อมใช้งาน (Availability) ประสิทธิภาพการเดินเครื่อง (Performance) และคุณภาพของผลิตภัณฑ์ (Quality) ซึ่งถูกใช้เพื่อระบุตำแหน่งของความสูญเสียและติดตามผลการปรับปรุงอย่างต่อเนื่อง [5] ภายใต้แนวคิด TPM ความสูญเสียหลักถูกแบ่ง

ออกเป็น Six Big Losses ที่ส่งผลกระทบต่อประสิทธิภาพการเดินเครื่องและค่า OEE ในภาพรวม [2]

2.2 ความสูญเสียเรื้อรัง (Chronic Losses) และการหยุดชะงักในระยะสั้น

การหยุดชะงักของเครื่องจักรในระยะเวลายาว มักมีลักษณะเป็นเหตุการณ์หยุดที่สั้นกว่า 5 นาที แต่เกิดขึ้นด้วยความถี่ที่สูงและซ้ำซาก ทำให้เวลาสูญเสียสะสมมีมูลค่ามหาศาล [10], [11] ซึ่งมักไม่ถูกตรวจพบจากการซ่อมบำรุงตามปกติ และต้องอาศัยการจำแนกสาเหตุและการติดตามที่แม่นยำเพื่อไม่ให้ความสูญเสียคงอยู่ต่อเนื่องในระบบการผลิต [3]

2.3 ผลกระทบเชิงมิติและต้นทุนแฝง (Hidden Losses)

งานวิจัยชี้ให้เห็นว่าการหยุดชะงักในระยะสั้นสร้าง ต้นทุนแฝง (Hidden Losses) ที่ไม่ปรากฏในรายงานระดับบริหาร เช่น เวลาปฏิบัติงานที่หายไปโดยไม่มีกรบันทึก และช่องว่างประสิทธิภาพจากการรอคอย [6] นอกจากนี้ยังก่อให้เกิดผลกระทบแบบระลอกคลื่น (Ripple Effects) ต่อสายการผลิต เช่น ความไม่สม่ำเสมอของการไหลของผลิตภัณฑ์ในระบบ และความเสี่ยงด้านคุณภาพจากการแปรปรวนของกระบวนการในช่วงเริ่มต้นใหม่ [11]

2.4 ข้อจำกัดของแนวทางปรับปรุงแบบดั้งเดิม

แม้แนวทาง TPM, การผลิตแบบลีน และ Lean Six Sigma จะถูกนำมาใช้เพื่อลดความสูญเสียอย่างแพร่หลาย [3], [7], [12] แต่ในสถานะการผลิตจริงยังคงเผชิญข้อจำกัดด้านความสมบูรณ์และมาตรฐานของข้อมูล การจัดกลุ่มเหตุการณ์ที่กว้างเกินไปส่งผลให้การวิเคราะห์สาเหตุรากเหง้า (Root Cause Analysis: RCA) ทำได้ไม่ชัดเจน และจำกัดความสามารถในการจัดลำดับความสำคัญของปัญหาเพื่อการตอบสนองเชิงรุก [6]

2.5 การประยุกต์ใช้โครงข่ายประสาทเทียมในการวิเคราะห์ข้อมูลการผลิต

เทคนิคปัญญาประดิษฐ์ถูกนำมาใช้เพื่อสนับสนุนการวิเคราะห์ข้อมูลและการตัดสินใจในภาคอุตสาหกรรม แทนการพึ่งพาการประเมินจากประสบการณ์ของผู้ปฏิบัติงานเพียงอย่างเดียว [13], [14] โดยเฉพาะโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ในรูปแบบโครงข่ายประสาทเทียม

แบบหลายชั้น (Multilayer Perceptron: MLP) ซึ่งมีความสามารถในการเรียนรู้ความสัมพันธ์แบบไม่เชิงเส้นและรูปแบบข้อมูลที่ซับซ้อนจากข้อมูลเชิงประจักษ์ [4]

ในบริบทของการผลิตแบบต่อเนื่อง MLP สามารถเรียนรู้รูปแบบการเกิดเหตุการณ์หยุดชะงักระยะสั้นที่มีความถี่สูงและมีลักษณะซ้ำซ้อน ซึ่งยากต่อการวิเคราะห์ด้วยวิธีเชิงสถิติแบบดั้งเดิม การเรียนรู้แบบอาศัยข้อมูล (Data-driven approach) ยังช่วยเพิ่มความสามารถในการตรวจจับความผิดปกติในระยะเริ่มต้น และสนับสนุนการปรับปรุงกระบวนการผลิตอย่างเป็นระบบและยั่งยืน [8], [9], [15]

2.6 การประเมินความแม่นยำของโมเดลในบริบทข้อมูลไม่สมดุล

ในการพัฒนาโมเดลสำหรับการจำแนกเหตุการณ์ในภาคอุตสาหกรรม ข้อมูลมักมีลักษณะไม่สมดุล (Imbalanced Data) กล่าวคือ บางคลาสมีจำนวนตัวอย่างมาก ขณะที่บางคลาสมีความถี่ต่ำแต่มีผลกระทบสูงต่อระบบการผลิต การใช้ตัวชี้วัดเพียงค่า Accuracy อาจทำให้การประเมินประสิทธิภาพของโมเดลคลาดเคลื่อน เนื่องจากโมเดลสามารถทำนายคลาสที่มีจำนวนมากได้ถูกต้องเป็นส่วนใหญ่ แม้จะจำแนกคลาสสำคัญที่มีความถี่ต่ำได้ไม่ดี

ด้วยเหตุนี้ งานวิจัยด้านการจำแนกข้อมูลไม่สมดุลจึงนิยมใช้ตัวชี้วัดที่พิจารณาทั้งความแม่นยำและความสามารถในการตรวจจับ ได้แก่ Precision, Recall และ F1-score สำหรับคลาสที่ i นิยามของตัวชี้วัด ดังสมการที่ 1 และ สมการที่ 2 ดังนี้

$$Precision_i = \frac{TP_i}{TP_i + FP_i} \quad (1)$$

$$Recall_i = \frac{TP_i}{TP_i + FN_i} \quad (2)$$

โดยที่

TP_i คือ จำนวนตัวอย่างที่โมเดลทำนายถูกต้องในคลาส i

FP_i คือ จำนวนตัวอย่างที่โมเดลทำนายว่าเป็นคลาส i แต่ไม่ใช่จริง

FN_i คือ จำนวนตัวอย่างที่เป็นคลาส i จริง แต่โมเดลทำนายผิด

ค่า F1-score ซึ่งเป็นค่าเฉลี่ยฮาร์โมนิกของ Precision และ Recall คำนวณได้ ดังสมการที่ 3 และ สมการที่ 4 ดังนี้

$$F1_i = \frac{2 \times Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (3)$$

ในการประเมินโมเดลหลายคลาส นิยมใช้ค่า Macro-F1 ซึ่งเป็นค่าเฉลี่ยของ F1-score ในแต่ละคลาสโดยให้น้ำหนักเท่ากันทุกคลาส ดังสมการที่ 4

$$Macro-F1 = \frac{1}{C} \sum_{i=1}^C F1_i \quad (4)$$

โดยที่ C คือ จำนวนคลาสทั้งหมด

ซึ่ง Macro-F1 มีความเหมาะสมในกรณีที่แต่ละคลาสมีความสำคัญเชิงปฏิบัติการแตกต่างกัน โดยเฉพาะเหตุการณ์ที่มีความถี่ต่ำแต่ส่งผลกระทบสูง (Low-frequency, High-impact Events) เนื่องจากตัวชี้วัดดังกล่าวไม่ให้น้ำหนักตามสัดส่วนจำนวนข้อมูล จึงสะท้อนความสามารถของโมเดลในการจำแนกทุกคลาสได้อย่างรอบด้าน

ดังนั้น ในบริบทการวิเคราะห์ข้อมูลการผลิตที่มีความไม่สมดุลของคลาส การใช้ Macro-F1 ร่วมกับการพิจารณาค่า Recall รายคลาสจึงเป็นแนวทางที่เหมาะสมในการประเมินประสิทธิภาพของโมเดลอย่างเป็นระบบ นอกเหนือจากการประเมินผลที่รัดกุมแล้ว งานวิจัยนี้ยังเน้นการแก้ปัญหาคลาสไม่สมดุล (Imbalanced Data) ในขั้นตอนการทำนายด้วยวิธี Temperature Scaling และ Threshold Adjustment ซึ่งงานวิจัยก่อนหน้านักใช้ค่า Softmax ปกติ ทำให้โมเดลในงานวิจัยนี้มีความน่าเชื่อถือ ลดอัตราการแจ้งเตือนผิดพลาด และสามารถนำไปประยุกต์ใช้ในบริบทอุตสาหกรรมได้จริงมากกว่า

3. วิธีการวิจัย

3.1 ข้อมูลที่ต้องใช้ในงานวิจัย

ข้อมูลทุติยภูมิจากระบบฐานข้อมูลของโรงงานกรณีศึกษาครอบคลุมเหตุการณ์หยุดเครื่องจักรบนสายการบรรจุกระป๋อง

ระหว่างปี พ.ศ. 2565 – พ.ศ. 2567 รวม 2,443 ครั้ง คิดเป็น เวลาสูญเสียสะสม 4,777 นาที

3.2 การนิยามเหตุการณ์และการเตรียมข้อมูล (Data Preparation)

เพื่อให้ข้อมูลเหตุการณ์ของเครื่องจักรสามารถนำไปใช้ พัฒนาโมเดลได้อย่างมีประสิทธิภาพ จำเป็นต้องนิยามหน่วย ของเหตุการณ์ (Event) ให้ชัดเจนและจัดเตรียมข้อมูลให้อยู่ใน รูปแบบที่สะอาดและไม่ซ้ำซ้อนก่อนขั้นตอนการสกัด คุณลักษณะและการฝึกสอนโมเดล ในการดำเนินการทำความสะอาดข้อมูล โดยทำการตัดข้อมูลซ้ำ (Deduplication) และ นิยามเหตุการณ์หลักโดยใช้คีย์ Line_Name, Machine และ Symptom_norm โดยระเบียบวิธีที่มีช่วงเวลาเกิดเหตุทับซ้อน กันจะถูกจัดรวมให้เป็นเหตุการณ์เดียว จากนั้นกำหนดให้การ เกิดซ้ำของเหตุการณ์เดียวกันภายใน 60 นาที นับเป็นครั้งย่อย เพื่อนำไปใช้คำนวณตัวแปร RepeatCount60m สำหรับเป็น คุณลักษณะเชิงบริบทในขั้นตอนการสร้างโมเดล

3.3 การกำหนดฉลากเป้าหมาย (Target Label Definition)

ฉลากเป้าหมายถูกกำหนดตามเกณฑ์ด้านระยะเวลาและ ความถี่ของการเกิดซ้ำ ซึ่งตัวแปรในสมการประกอบด้วย

d คือ ระยะเวลาการหยุด (นาที)

R คือ จำนวนครั้งการเกิดซ้ำของเหตุการณ์เดียวกัน ภายใน 60 นาที (RepeatCount60m)

θ คือ ค่าเกณฑ์จำนวนครั้งการเกิดซ้ำ (Threshold) สำหรับการเรียกช่างซ่อมบำรุง โดยกำหนดค่าอยู่ระหว่าง 1–10 ครั้ง ตามลักษณะของเครื่องจักรและประเภทอาการเสีย ดังสมการที่ 5

$$Label(d, R) = \begin{cases} X, & d < 1 \\ GM, & 1 \leq d \leq 5 \wedge R < \theta \\ Mi, & d > 5 \vee R \geq \theta \end{cases} \quad (5)$$

โดยที่

X คือ Non-Minor Stoppage หมายถึงเหตุการณ์ที่มี ระยะเวลาสั้นมาก หรือไม่จัดเป็นเหตุการณ์ Downtime ที่มี นัยสำคัญ

GM คือ General Minor Stoppage หมายถึงเหตุการณ์ หยุดทำงานระยะสั้น (1–5 นาที) และไม่เกิดซ้ำเกินเกณฑ์

Mi คือ Major Minor Stoppage หมายถึงเหตุการณ์ หยุดระยะสั้นที่มีความรุนแรงสูง โดยมีระยะเวลาเกิน 5 นาที หรือเกิดซ้ำถี่เกินเกณฑ์

3.4 การสกัดคุณลักษณะ (Feature Extraction)

งานวิจัยนี้ได้พัฒนากระบวนการแปลงข้อมูล (Data Transformation Pipeline) เพื่อสร้างเวกเตอร์ตัวแทนสำหรับ โมเดลโครงข่ายประสาทเทียมแบบหลายชั้น (MLP) โดย แบ่งเป็น 2 ส่วนหลัก ดังนี้

3.4.1 การสกัดคุณลักษณะเชิงข้อความ (Textual Feature Extraction)

ดำเนินการแปลงข้อความอาการเสียด้วยวิธี TF-IDF โดยใช้ เทคนิค Hybrid N-grams ที่ประกอบด้วย Word N-grams ($N = 1, 2$) เพื่อจับใจความสำคัญ และ Character N-grams ($N = 3-5$) เพื่อลดผลกระทบจากการสะกดผิดและเพิ่มความทนทาน ต่อข้อมูลนำเข้าที่มีความแปรปรวน จากนั้นลดมิติของข้อมูล (Dimensionality Reduction) ด้วยเทคนิค Truncated SVD ให้เหลือ 256 องค์ประกอบ (Components) เพื่อป้องกัน ภาวะการเรียนรู้มากเกินไป (Overfitting) และเพิ่ม ประสิทธิภาพในการคำนวณ

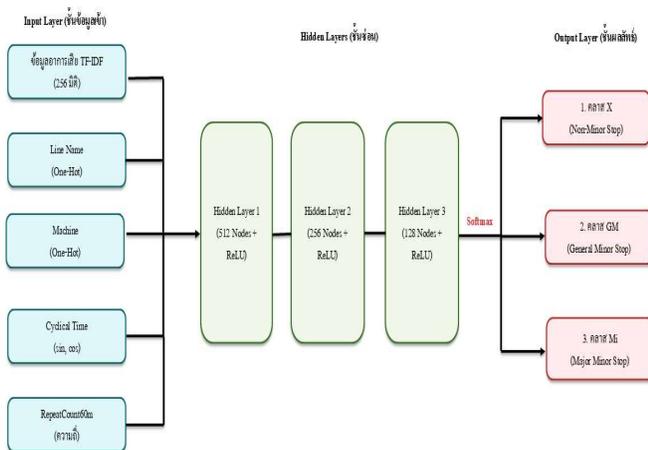
3.4.2 การสกัดคุณลักษณะเชิงบริบท (Contextual Feature Extraction)

ดำเนินการวิศวกรรมคุณลักษณะ (Feature Engineering) บนข้อมูลโครงสร้างเพื่อให้โมเดลรับรู้ถึงบริบทขณะเกิดเหตุ ดังนี้

1. ข้อมูลหมวดหมู่ (Categorical Data) หมายถึง ใช้ One-Hot Encoding แปลงข้อมูลระบุตำแหน่ง ได้แก่ Line Name และ Machine
2. ข้อมูลเวลาเชิงวัฏจักร (Cyclical Time) หมายถึง แปลงข้อมูลเวลาให้อยู่ในรูปแบบฟังก์ชันตรีโกณมิติ ($time_sin, time_cos$) ตามรอบ 24 ชั่วโมง เพื่อ รักษาความสัมพันธ์ของช่วงเวลาที่เกี่ยวข้องกัน
3. ความถี่ของเหตุการณ์ (Event Frequency) หมายถึง สร้างตัวแปร RepeatCount60m โดยนับ ความถี่การหยุดของเครื่องจักรเดิมด้วยอาการเดิม ย้อนหลัง 60 นาที เพื่อใช้เป็นดัชนีชี้วัดหลักในการ จำแนกปัญหาเรื้อรัง (Chronic Issues)

3.5 รูปแบบโมเดลและการฝึกสอน (Model & Training)

ในงานวิจัยนี้ เลือกใช้โมเดลโครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Perceptron: MLP) สำหรับจำแนกเหตุการณ์การหยุดชะงักของเครื่องจักร เนื่องจากสามารถรองรับข้อมูลคุณลักษณะผสมทั้งเชิงข้อความและเชิงบริบทได้ดี และมีความยืดหยุ่นในการปรับโครงสร้างชั้นซ่อนให้เหมาะสมกับลักษณะของปัญหา โครงสร้างของโมเดลประกอบด้วยชั้นซ่อน (Hidden Layers) จำนวน 3 ชั้น ใช้ร่วมกับเทคนิค Batch Normalization และ Dropout เพื่อช่วยเพิ่มเสถียรภาพในการฝึกสอนและลดปัญหาการเรียนรู้อกเกินไป (Overfitting) ส่วนชั้นเอาต์พุตใช้ฟังก์ชัน Softmax สำหรับ 3 คลาส ได้แก่ $P(X)$, $P(GM)$ และ $P(Mi)$ พร้อมทั้งมีการถ่วงน้ำหนักคลาส (Class Weighting) เพื่อบรรเทาปัญหาข้อมูลไม่สมดุลดังแสดงใน รูปที่ 1



รูปที่ 1 โมเดลโครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer Perceptron: MLP)

โครงข่ายประสาทเทียมที่พัฒนาในงานวิจัยนี้เป็นแบบ Multilayer Perceptron (MLP) ประกอบด้วย 3 ชั้นซ่อน (Hidden Layers) โดยกำหนดจำนวนหน่วยประสาท (Neurons) เท่ากับ 512, 256 และ 128 ตามลำดับ เพื่อรองรับมิติของข้อมูล TF-IDF ที่มีความซับซ้อนสูง ฟังก์ชันกระตุ้น (Activation Function) ของแต่ละชั้นซ่อนใช้ Rectified Linear Unit (ReLU) เพื่อลดปัญหา Vanishing Gradient และเพิ่มประสิทธิภาพการเรียนรู้ในข้อมูลมิติสูง ส่วนชั้นผลลัพธ์ (Output Layer) ใช้ Softmax Function สำหรับการจำแนกหลายคลาส (Multi-class Classification)

กระบวนการเรียนรู้ใช้ตัวปรับเหมาะ (Optimizer) แบบ Adam ด้วยค่า Learning Rate เริ่มต้นเท่ากับ 0.001 และใช้ค่า Batch Size เท่ากับ 32 ตัวอย่างต่อรอบการอัปเดตน้ำหนัก กำหนดจำนวนรอบการฝึกสูงสุด (Epochs) เท่ากับ 100 รอบ เพื่อป้องกันปัญหา Overfitting ได้ใช้เทคนิค Early Stopping โดยหยุดการฝึกเมื่อค่า Validation Loss ไม่ลดลงติดต่อกัน 6 รอบ (Patience = 6) และเลือกโมเดลที่ให้ค่า Validation Performance ดีที่สุด

3.6 การปรับเทียบความน่าจะเป็นและการกำหนดค่าขีดแบ่ง

ภายหลังจากโมเดลโครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Perceptron: MLP) ทำการทำนายความน่าจะเป็นของแต่ละคลาสผ่านฟังก์ชัน Softmax แล้วให้ P_i คือการแทนค่าความน่าจะเป็นของคลาสที่ i จาก Softmax เดิม ดังสมการที่ 6

$$p_m = P(y = mx) \quad (6)$$

โดยที่ m คือ $1, 2, \dots, M$ และ M คือ จำนวนคลาสทั้งหมด

แม้ Softmax จะให้ค่าความน่าจะเป็น แต่โมเดล Deep Learning มักมีปัญหา Overconfidence ซึ่งอาจทำให้ค่าความน่าจะเป็นสูงเกินจริงในบางคลาส โดยเฉพาะในกรณีข้อมูลไม่สมดุล (Class Imbalance)

ดังนั้น งานวิจัยนี้จึงใช้วิธี Power-based Temperature Scaling ซึ่งเป็นการปรับค่าความน่าจะเป็นโดยตรงในระดับ probability (ไม่ใช่ logits) ตามสมการ 7

$$q_m = \frac{P_m^{\frac{1}{T}}}{\sum_{k=1}^M P_k^{\frac{1}{T}}} \quad (7)$$

โดยที่

- q_m คือ ความน่าจะเป็นหลังการปรับเทียบ
- $T > 0$ คือ ค่า temperature
- M คือ จำนวนคลาสทั้งหมด

พฤติกรรมของค่า T คือ

- a. เมื่อ $T > 1$ คือ การกระจายความน่าจะเป็นจะแบนลง (ลดความมั่นใจเกินจริง)

b. เมื่อ $T < 1$ คือ การกระจายจะคมขึ้น (เพิ่มความมั่นใจ)

c. เมื่อ $T = 1$ คือ ไม่มีการปรับค่า

ค่า T ถูกปรับจาก Validation Set โดยเลือกค่าที่ให้ค่า Macro-F1 สูงสุด เพื่อให้สมดุลระหว่าง Precision และ Recall ของทุกคลาส โดยเฉพาะคลาสที่มีข้อมูลน้อย

การกำหนดค่าขีดแบ่งรายคลาส

เพื่อเพิ่มความน่าเชื่อถือของการจำแนกในบริบทอุตสาหกรรมจริง งานวิจัยนี้กำหนดค่าขีดแบ่ง (Threshold) สำหรับแต่ละคลาส ให้ q_m เป็นค่าความน่าจะเป็นหลังการปรับเทียบของคลาสที่ m การตัดสินใจจำแนกกำหนดดังสมการที่ 8 และ สมการที่ 9 ดังนี้

$$\hat{y} = m \quad \text{If } q_m \geq \tau_m \quad (8)$$

$$\hat{y} = GM \quad \text{If } q_m < \tau_m \quad \text{For all } m \neq GM \quad (9)$$

โดยที่

\hat{y} คือ ผลลัพธ์คลาสที่โมเดลตัดสินใจทำนาย (Predicted Class)

q_m คือ ความน่าจะเป็นของคลาสที่ m หลังผ่านการปรับเทียบ (Calibrated Probability)

τ_m คือ ค่าขีดแบ่ง (Threshold) ของคลาสที่ m

GM คือ General-Minor Stoppage ซึ่งถูกกำหนดให้เป็นคลาสพื้นฐาน (Default Class) ในกรณีที่ค่าความน่าจะเป็นของคลาสอื่น ๆ ไม่ผ่านเกณฑ์ขีดแบ่งที่ตั้งไว้ (เพื่อป้องกันการแจ้งเตือนผิดพลาดในคลาสที่มีความเสี่ยงสูง เช่น Mi)

ในงานวิจัยนี้ให้ความสำคัญกับคลาสที่เกี่ยวข้องกับ Chronic Loss เป็นพิเศษ ดังนั้นค่า τ_{Mi} สำหรับคลาส Minor Stoppage สำคัญถูกปรับจาก Validation Set เพื่อเพิ่มค่า Recall และลดความเสี่ยงของ False Negative

เหตุผลเชิงอุตสาหกรรม

ในบริบทโรงงานผลิตเครื่องตี การจำแนก Minor Stoppage ผิดพลาดอาจทำให้การวิเคราะห์สาเหตุรากเหง้าล่าช้า และกระทบต่อ OEE ในระยะยาวการใช้ Probability

Calibration ร่วมกับ Threshold รายคลาสจึงช่วยให้โมเดลลดการทำนายผิดพลาดในคลาสที่มีลักษณะใกล้เคียงเพิ่มความสามารถในการตรวจจับเหตุการณ์ Chronic Loss ลดผลกระทบจากความไม่สมดุลของข้อมูลสะท้อนพฤติกรรมการใช้งานจริงมากกว่าการใช้ argmax เพียงอย่างเดียว

แนวทางดังกล่าวทำให้ค่าประสิทธิภาพมีเสถียรภาพมากขึ้นในทุก Fold ของ Walk-Forward Validation และเพิ่มความเชื่อมั่นในการนำโมเดลไปใช้งานจริงในระดับโรงงานอุตสาหกรรม

3.7 ระเบียบวิธีประเมินผล (Evaluation Protocol)

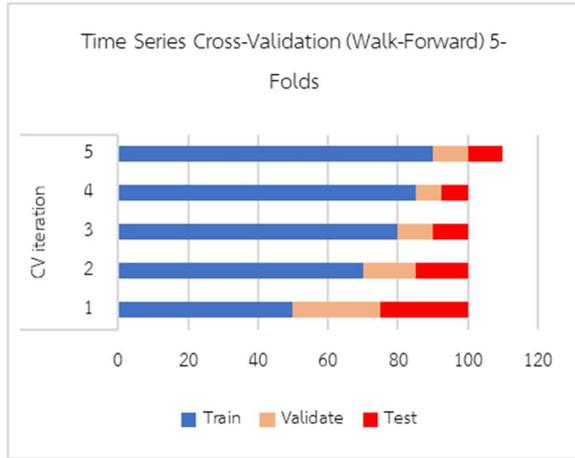
งานวิจัยนี้ใช้ระเบียบวิธีการตรวจสอบความถูกต้องแบบไขว้สำหรับข้อมูลอนุกรมเวลาแบบเดินหน้า (Walk-Forward Time-Series Cross-Validation) จำนวน 5 รอบ (5 Folds) เพื่อให้ผลการประเมินสะท้อนการใช้งานจริงในภาคอุตสาหกรรม ซึ่งโมเดลต้องเรียนรู้จากข้อมูลในอดีตและทำนายเหตุการณ์ที่จะเกิดขึ้นในอนาคต โดยกระบวนการทั้งหมดจะไม่มีการสุ่มลำดับข้อมูล (No Random Shuffling) เพื่อรักษาลำดับเหตุการณ์ตามเวลาจริงและลดความเสี่ยงของการรั่วไหลของข้อมูล (Data Leakage) ที่อาจทำให้ผลการประเมินคลาดเคลื่อนจากความเป็นจริง

3.7.1 การแบ่งชุดข้อมูลตามลำดับเวลา (Time-based Data Splitting)

จากข้อมูลทั้งหมดจำนวน 2,443 เหตุการณ์ ได้มีการจัดเรียงตามตัวแปรเวลาเริ่มต้นเหตุการณ์ (StartTime) ก่อนจะถูกแบ่งออกเป็น 3 ส่วนตามลำดับเวลา (Chronological Split) ในแต่ละรอบการทดสอบ (Fold) ตามที่ปรากฏในรูปที่ 2 โดยมีสัดส่วนดังนี้

1. ชุดข้อมูลฝึก (Training Set) ร้อยละ 70 ใช้สำหรับการฝึกสอนโมเดลเพื่อให้เรียนรู้รูปแบบความสัมพันธ์ของข้อมูลในอดีต
2. ชุดข้อมูลตรวจสอบ (Validation Set) ร้อยละ 15 ใช้สำหรับการปรับจูนค่าพารามิเตอร์สำคัญ ได้แก่ ค่าพารามิเตอร์อุณหภูมิในกระบวนการ Temperature Scaling และการค้นหาค่าขีดแบ่ง (τ_m) ที่เหมาะสมที่สุด เพื่อเพิ่มความน่าเชื่อถือผ่านการปรับเทียบความน่าจะเป็น

3. ชุดข้อมูลทดสอบ (Test Set) ร้อยละ 15 เป็นข้อมูลส่วนท้ายสุดในแต่ละรอบที่โมเดลไม่เคยเห็นมาก่อน ใช้สำหรับประเมินประสิทธิภาพขั้นสุดท้ายเพื่อให้มั่นใจว่าโมเดลสามารถทำงานได้จริงภายใต้สภาวะข้อมูลในอนาคต



รูปที่ 2 การตรวจสอบความถูกต้องแบบไขว้สำหรับข้อมูลอนุกรมเวลาแบบเดินหน้า (Walk-Forward Time-Series Cross-Validation)

ซึ่งในแต่ละ Fold ชุดข้อมูลฝึกจะเพิ่มขึ้นตามลำดับเวลา ขณะที่ชุดทดสอบจะเลื่อนไปยังช่วงเวลาที่ถัดไป เพื่อจำลองสถานการณ์การใช้งานจริงของระบบทำนายในโรงงาน

3.8 ตัวชี้วัดการประเมินผล (Evaluation Metrics)

เพื่อหลีกเลี่ยงอคติจากข้อมูลไม่สมดุล การประเมินควรวัดตัวชี้วัดที่ให้ความสำคัญเท่าเทียมทุกคลาสและสะท้อน precision-recall trade-off ได้ชัดเจน Precision / Recall / F1 (รายคลาส) ดังสมการ ดังนี้

$$Precision = \frac{TP}{TP + FP} \quad (10)$$

โดยที่

TP คือ จำนวนครั้งที่ทำนายถูกต้องว่าเป็นคลาสนั้น (True Positive)

FP คือ จำนวนครั้งที่ทำนายผิดพลาดว่าเป็นคลาสนั้น (False Positive)

$$Recall = \frac{TP}{TP + FN} \quad (11)$$

โดยที่

TP คือ จำนวนที่ทำนายถูกว่าเป็นคลาสนั้น (True Positive)

FN คือ จำนวนที่พลาดทำนายเป็นคลาสนั้นที่จริงเป็น คลาสนั้น (False Negative)

$$F1 = \frac{2PR}{P + R} \quad (12)$$

โดยที่

P = ค่าความแม่นยำ (Precision)

R = ค่าอัตราการระลึก (Recall)

$$Macro-F1 = \frac{1}{C} \sum_{c=1}^C F1_c \quad (13)$$

โดยที่ c คือ จำนวนคลาสนั้นทั้งหมดในที่นี้คือ 3

นอกจากนี้มีการคำนวณค่าพื้นที่ใต้เส้นโค้งความแม่นยำและการระลึก (Area Under the Precision-Recall Curve :PR-AUC) ดังสมการที่ 14

$$PR-AUC = \int_0^1 P(R) dR \approx \sum_k P_k \Delta R_k \quad (14)$$

โดยที่

$P(R)$ คือ ค่าความแม่นยำ (Precision) ที่ระดับ Recall R

R คือ ค่าอัตราการระลึก (Recall)

P_k คือ ค่าความแม่นยำในช่วงย่อยที่ k

ΔR_k คือ ผลต่างของค่า Recall ในช่วง k และ $k+1$

4. ผลการวิจัย

4.1 ผลการประเมินโมเดล (Model Performance)

ผลการประเมินโมเดลโครงข่ายประสาทเทียมแบบ หลายชั้น (Multilayer Perceptron: MLP) โดยใช้วิธี Walk-

Forward Time-Series Cross-Validation 5-Folds ดังแสดงในตารางที่ 1 ซึ่งรายงานค่าเฉลี่ย (Mean) และส่วนเบี่ยงเบนมาตรฐาน (Standard Deviation) ของตัวชี้วัดหลัก ได้แก่ Accuracy, Macro-F1, Precision, Recall และ F1 แยกตามคลาส GM (General-Minor Stoppage) และ Mi (Major-Minor Stoppage)

ตารางที่ 1 ผลการประเมินโมเดลโครงข่ายประสาทเทียมใช้ วิธี Walk-Forward Time Series Cross-Validation - 5 Folds

Metric	Mean	Std
Accuracy	0.9556	0.0360
Macro-F1	0.9200	0.0840
GM-Precision	0.9479	0.0417
GM-Recall	0.9856	0.0187
GM-F1	0.9661	0.0267
Mi-Precision	0.9304	0.0971
Mi-Recall	0.7934	0.2214
Mi-F1	0.8448	0.1597

จากตารางที่ 1 พบว่าโมเดล MLP ที่พัฒนาขึ้นให้ผลลัพธ์โดยรวมที่ดีมาก โดยมีค่า Accuracy เฉลี่ย 0.9556 (คิดเป็นร้อยละ 95.56) และค่า Macro-F1 เฉลี่ย 0.9200 (คิดเป็นร้อยละ 92.00) สะท้อนว่าโมเดลสามารถจำแนกเหตุการณ์การ

ตารางที่ 2 ผลการประเมินรายรอบ (Per-fold Results)

Fold	Acc	Macro- F1	GM-Precision	GM-F1	Mi-Precision	Mi-F1
1	0.934	0.922	0.907	0.947	1.000	0.903
2	0.904	0.778	0.907	0.930	0.800	0.571
3	0.967	0.937	0.949	0.974	1.000	0.850
4	0.989	0.970	1.000	0.991	0.852	0.920
5	0.984	0.993	0.977	0.988	1.000	0.980

จากตารางที่ 2 พบว่าโมเดลมีค่าความถูกต้อง (Accuracy) อยู่ในช่วง 0.904–0.989 โดยมีค่าเฉลี่ยสูงถึงร้อยละ 95.56 สะท้อนว่าประสิทธิภาพของโมเดลมีความเสถียรในหลายช่วงเวลา แม้ว่าข้อมูลจะมีความไม่สมดุลระหว่างคลาสก็ตาม ทั้งนี้ ในรอบการทดสอบที่ 5 (Fold 5) โมเดลสามารถทำ

หยุดชะงักของเครื่องจักรในระยะเวลาสั้นได้อย่างแม่นยำในทุกคลาส

ขณะที่คลาส Mi (Major-Minor Stoppage) ซึ่งเป็นคลาสกลุ่มน้อย (Minority Class) พบว่ามีค่า Mi-F1 เฉลี่ย 0.8448 (คิดเป็นร้อยละ 84.48) โดยมี Precision สูงกว่า Recall (Mi-Precision = 0.9304, Mi-Recall = 0.7934) สะท้อนให้เห็นว่าโมเดลถูกปรับให้ลดการแจ้งเตือนผิดพลาด (False Positive) เพื่อรักษาความน่าเชื่อถือของการแจ้งเตือนจริง ซึ่งเหมาะสมกับการประยุกต์ใช้ในเชิงปฏิบัติสำหรับระบบแจ้งเตือนความเสี่ยงในโรงงานจริง

นอกจากนี้ ส่วนเบี่ยงเบนมาตรฐานที่สูงที่สุดใน Mi-Recall (0.2214) สะท้อนผลกระทบจากความไม่สมดุลของข้อมูล (Imbalanced Data) เนื่องจากคลาส Mi มีจำนวนตัวอย่งน้อยกว่าคลาสอื่นอย่างมาก อย่างไรก็ตาม วิธี Walk-Forward 5-Folds ช่วยลดอคติจากการแบ่งข้อมูลแบบสุ่ม (Random Split) และทำให้ผลการประเมินสะท้อนพฤติกรรมของโมเดลในสภาพการทำงานตามลำดับเวลาได้ใกล้เคียงสภาพจริงมากขึ้น

4.1.2 ผลการประเมินรายรอบ (Per-fold Results)

เพื่อพิจารณาเสถียรภาพของโมเดลในแต่ละช่วงเวลา แสดงผลการประเมินโมเดลรายรอบ (Per-Fold Results) ของ MLP classifier ดังแสดงในตารางที่ 2 ดังนี้

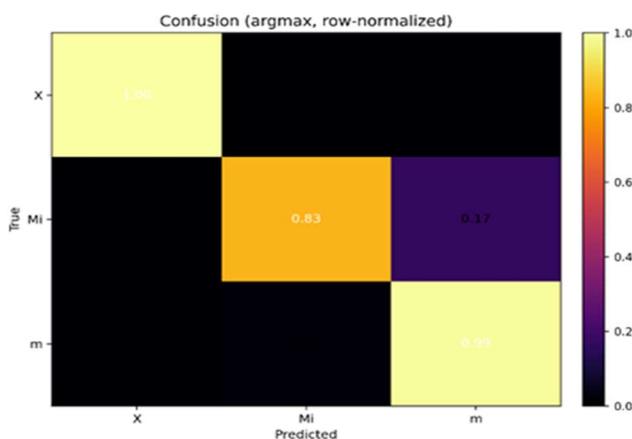
ประสิทธิภาพได้สูงสุด โดยมีค่า Macro-F1 ถึง 0.993 และค่า Mi-F1 ถึง 0.980 ซึ่งแสดงให้เห็นถึงศักยภาพในการจำแนกคลาสวิกฤต (Mi) ได้อย่างแม่นยำสมบูรณ์แบบ ในขณะที่รอบที่ 2 (Fold 2) มีค่า Mi-F1 ต่ำที่สุดที่ 0.571 (แม้ว่าค่า Mi-Precision จะทำได้ถึง 0.800 ก็ตาม) ซึ่งอาจเกิดจากช่วงเวลา

ดังกล่าวมีรูปแบบเหตุการณ์ M_i ที่แตกต่างจากช่วงอื่น หรือมีจำนวนตัวอย่างที่น้อยมาก ส่งผลให้โมเดลไม่สามารถเรียนรู้รูปแบบเฉพาะได้ครบถ้วน อย่างไรก็ตาม เมื่อพิจารณาค่าเฉลี่ยรวมทุก Fold พบว่าโมเดลยังคงรักษาประสิทธิภาพโดยรวมในระดับสูง แสดงถึงความทนทานต่อความแปรปรวนของข้อมูลตามลำดับเวลา

โดยสรุป โมเดลที่พัฒนามีเสถียรภาพสูงต่อการเปลี่ยนแปลงของข้อมูลในแต่ละรอบการทดสอบและเหมาะสมสำหรับการนำไปใช้งานจริงในการจำแนกเหตุการณ์การหยุดชะงักของเครื่องจักรในระยะเวลาสั้นภายในสายการผลิตอุตสาหกรรมเครื่องตัด

4.1.3 ความน่าเชื่อถือของโมเดล (Model Reliability)

ในการประเมินประสิทธิภาพเชิงลึกของโมเดล ปัญญาประดิษฐ์โครงข่ายประสาทเทียมได้ใช้การวิเคราะห์ผ่านตารางความสับสนแบบปรับมาตรฐานตามแถว (Row-normalized Confusion Matrix) เพื่อตรวจสอบค่าความไว (Recall) หรือความสามารถของโมเดลในการระบุประเภทของเหตุการณ์ในแต่ละคลาส (Class-wise Performance) ได้แก่ คลาส X (Non-Minor Stoppage), คลาส GM (General-Minor Stoppage) และคลาส M_i (Major - Minor Stoppage) ดังแสดงในรูปที่ 3



รูปที่ 3 การประเมินประสิทธิภาพเชิงลึกของโมเดล โดยใช้การวิเคราะห์ผ่าน Confusion Matrix

จากรูปที่ 3 จากการพิจารณาค่าความน่าจะเป็นในแนวทแยงมุม (Diagonal Elements) ของเมทริกซ์ ซึ่งสะท้อนถึงความถูกต้องในการทำนายเทียบกับข้อมูลจริง สามารถอธิบายผลการจำแนกได้ดังนี้

1. การจำแนกคลาสเหตุการณ์ที่ไม่ใช่ช่วงเวลาหยุดเครื่องจักร (Non-Minor Stoppage: X) โมเดลมีประสิทธิภาพในการจำแนกสูงสุด โดยมีค่า Recall เท่ากับ 1.00 หมายความว่าโมเดลสามารถคัดแยกเหตุการณ์ที่หยุดสั้นมากหรือเหตุการณ์ที่ไม่ใช่ Downtime ออกจากระบบได้อย่างสมบูรณ์ (ร้อยละ 100) โดยไม่มีความผิดพลาดซึ่งแสดงถึงขีดความสามารถในการกรองสัญญาณรบกวน (Noise Filtering) ช่วยลดภาระในการจัดการข้อมูลที่ไม่จำเป็น

2. การจำแนกคลาสสำหรับเหตุการณ์ทั่วไป (General-Minor Stoppage: GM) สำหรับเหตุการณ์ทั่วไปที่ไม่เกิดถี่ซ้ำพบว่าโมเดลสามารถทำนายได้ถูกต้องแม่นยำที่ค่า Recall เท่ากับ 1.00 (ร้อยละ 100) เช่นเดียวกัน โดยไม่มีความสับสนปะปนกับคลาสอื่น ผลลัพธ์นี้ชี้ให้เห็นว่าคุณลักษณะ (Features) ของการหยุดทำงานแบบทั่วไปมีความชัดเจนเพียงพอที่โมเดลจะเรียนรู้และจำแนกได้อย่างถูกต้อง

3. การจำแนกคลาสเหตุการณ์หยุดชะงักระดับรุนแรง (Major-Minor Stoppage: M_i) ในส่วนนี้ของเหตุการณ์หยุดชะงักระดับรุนแรงหรือมีการเกิดซ้ำถี่ (Severe/Chronic Stops) โมเดลมีค่าความถูกต้องในการทำนายอยู่ที่ 0.83 (83%) โดยพบความคลาดเคลื่อนในการจำแนกผิดเป็นคลาส GM อยู่ที่สัดส่วน 0.17 (17%) ผลการวิเคราะห์บ่งชี้ว่ามีเหตุการณ์รุนแรงประมาณร้อยละ 17 ที่โมเดลประเมินความสำคัญต่ำกว่าความเป็นจริง (Underestimation) โดยระบุว่าเป็นเพียงการหยุดทั่วไป สาเหตุคาดว่าเกิดจากความกำกวมของรูปแบบข้อมูล (Data Ambiguity) บริเวณรอยต่อของเงื่อนไขความถี่และเวลา ทำให้โมเดลตัดสินใจจัดประเภทเหตุการณ์ที่กึ่งกลางระหว่างความรุนแรง (Borderline Cases) ให้เป็นเหตุการณ์ปกติ ความน่าเชื่อถือในภาพรวมโมเดลมีความน่าเชื่อถือสูงมากในการจำแนกและคัดกรองเหตุการณ์ส่วนใหญ่ โดยเฉพาะการแยกแยะเหตุการณ์ปกติ (GM) และเหตุการณ์ที่ไม่สำคัญ (X) ได้อย่างเด็ดขาด อย่างไรก็ตาม ข้อสังเกตสำคัญคือการจำแนกเหตุการณ์รุนแรง (M_i) ซึ่งโมเดลมีแนวโน้มที่จะระมัดระวัง (Conservative) โดยอาจจัดให้เหตุการณ์รุนแรง

บางส่วนเป็นเหตุการณ์ทั่วไป ซึ่งเป็นประเด็นที่สามารถนำไปปรับปรุงต่อยอด (Further Improvement) เพื่อเพิ่มความไวในการตรวจจับปัญหาเรื้อรังในอนาคต

4.2 ผลการจำแนกเหตุการณ์การหยุดชะงักของเครื่องจักรในระยะเวลาสั้น

จากการจำแนกข้อมูล 2,443 ครั้ง โดยใช้โมเดลที่ได้รับการพัฒนาเหตุการณ์การหยุดชะงักของเครื่องจักรในระยะเวลาสั้นสามารถจำแนกได้ดังแสดงในตารางที่ 3 ดังนี้

ตารางที่ 3 ผลการจำแนกเหตุการณ์การหยุดชะงักของเครื่องจักรในระยะเวลาสั้น

ลำดับที่	เหตุการณ์	จำนวนครั้ง	ร้อยละ (%)	การวิเคราะห์
1	General-Minor Stoppage (GM)	1,535	62.83	กลุ่มเหตุการณ์ที่เกิดขึ้นบ่อยที่สุด ส่วนใหญ่เป็นการหยุดชะงักระยะสั้นแบบทั่วไป ซึ่งโดยปกติไม่ก่อให้เกิดผลกระทบเชิงปฏิบัติการที่รุนแรง
2	Non-Minor Stoppage (X)	745	30.50	กลุ่มนี้ประกอบด้วยเหตุการณ์หยุดที่มีระยะเวลาสั้นมาก หรือข้อมูลรบกวน (Noise) ซึ่งถูกคัดแยกออกจากเหตุการณ์หยุดเครื่องจักรที่มีนัยสำคัญต่อการผลิต
3	Major-Minor Stoppage (Mi)	163	6.67	แม้มีความถี่ต่ำกว่า แต่เป็นกลุ่มเหตุการณ์ที่มีระดับความรุนแรงสูง และสามารถส่งผลกระทบต่อประสิทธิภาพการผลิตโดยรวมอย่างมีนัยสำคัญ

จากตารางที่ 3 พบว่าเหตุการณ์การหยุดชะงักชั่วคราวของเครื่องจักรในระยะสั้นส่วนใหญ่จัดอยู่ในกลุ่ม General-Minor Stoppage (GM) มีจำนวนสูงสุดถึง 1,535 ครั้ง คิดเป็นร้อยละ 62.83 ของข้อมูลทั้งหมด ซึ่งสะท้อนให้เห็นว่าสภาพปัญหาหลักของสาย การบรรจุเกิดจากการหยุดชะงักระยะสั้นแบบปกติ รองลงมาคือ กลุ่ม Non-Minor Stoppage (X) จำนวน 745 ครั้ง คิดเป็นร้อยละ 30.50 ซึ่งแสดงให้เห็นถึงความสามารถของโมเดลในการแยกแยะเหตุการณ์ที่ไม่ใช่จากช่วงเวลาหยุดเครื่องจักรมีปัญหา (Downtime) หรือเหตุการณ์ปกติออกจากปัญหาจริงช่วยลดความสับสนในการวิเคราะห์ข้อมูลในขณะที่กลุ่ม Major-Minor Stoppage (Mi) ซึ่งเป็นเหตุการณ์ที่มีความรุนแรงหรือเป็นปัญหาเรื้อรัง มีจำนวนน้อยที่สุดเพียง 163 ครั้ง หรือคิดเป็นร้อยละ 6.67 อย่างไรก็ตาม แม้จะมีสัดส่วนน้อยแต่ถือเป็นกลุ่มเป้าหมายสำคัญที่ต้องเร่งดำเนินการแก้ไข (Priority for Improvement) เนื่องจากเป็นต้นตอของความสูญเสียประสิทธิภาพการผลิตที่แท้จริง

ผลการจำแนกเหตุการณ์ออกเป็น General-Minor และ Major-Minor มีได้สิ้นสุดเพียงการรายงานค่าความแม่นยำ แต่ถูกออกแบบให้เชื่อมโยงกับกระบวนการปฏิบัติการในสายการผลิต โดยเมื่อโมเดลทำนายเหตุการณ์เป็นประเภท

Major-Minor ระบบจะส่งสัญญาณแจ้งเตือนไปยังหัวหน้างานทันทีผ่านระบบ Notification เพื่อให้ดำเนินการตรวจสอบเชิงลึกสำหรับเหตุการณ์ประเภท General-Minor ข้อมูลจะถูกบันทึกสะสมเพื่อนำไปวิเคราะห์เชิงแนวโน้ม (Trend Analysis) และจัดทำ One-Point Lesson (OPL) เพื่อป้องกันการเกิดซ้ำ แนวทางดังกล่าวช่วยให้ทีมซ่อมบำรุงสามารถจัดลำดับความสำคัญของปัญหาลดความสูญเสียสะสมและ OEE

4.3 การเปรียบเทียบกับงานวิจัยก่อนหน้า (Comparative Performance Benchmark)

งานวิจัยก่อนหน้าส่วนใหญ่มุ่งเน้นการเพิ่ม Accuracy หรือ F1-score โดยไม่ได้กล่าวถึงการปรับเทียบความน่าจะเป็น (Probability Calibration) และการกำหนด Threshold รายคลาส ซึ่งเป็นประเด็นสำคัญในการประยุกต์ใช้จริงในภาคอุตสาหกรรม

ผลการทดลองให้ค่าเฉลี่ย Macro-F1 ร้อยละ 92.00 และ Mi-F1 ร้อยละ 84.48 จากกระบวนการ Walk-Forward Validation ซึ่งอยู่ในระดับสูงเมื่อเทียบกับงานก่อนหน้า เช่น Arima et al. (2012) และ Lee et al. (2019) ที่รายงานค่า F1-score อยู่ในช่วงประมาณ 0.80–0.90 ผลลัพธ์ดังกล่าว

สะท้อนถึงความสามารถของโมเดลในการรักษาสมดุลความแม่นยำระหว่างคลาส (Macro-F1) และความสามารถในการตรวจจับกลุ่ม Minor Stoppages ที่มีความไม่สมดุลของข้อมูล (Mi-F1)

ความโดดเด่นที่สำคัญของงานวิจัยนี้คือการจัดการกับข้อมูลที่มีลักษณะไม่สมดุลอย่างมาก หรือการจดจำข้อมูลแบบ Long-tailed recognition โดยเฉพาะในคลาส Mi ซึ่งมีสัดส่วนข้อมูลเพียงร้อยละ 6.67 ของเหตุการณ์ทั้งหมด ในขณะที่งานวิจัยส่วนใหญ่มักมีประสิทธิภาพลดลงเมื่อเผชิญกับสถานะข้อมูลที่ไม่สมดุล (Class Imbalance) แต่ด้วยการประยุกต์ใช้เทคนิคการปรับเทียบความน่าจะเป็นตามแนวทางที่ทันสมัยส่งผลให้โมเดล MLP ที่พัฒนาขึ้นสามารถรักษาสมดุลความแม่นยำระหว่างคลาสได้ดีเยี่ยม โดยเฉพาะความสามารถในการตรวจจับกลุ่ม Minor Stoppages ที่เป็นสาเหตุหลักของความสูญเสีย

ในเชิงปฏิบัติ โรงงานสามารถนำค่าความน่าจะเป็นที่ผ่านการปรับเทียบแล้วไปใช้ในระบบแจ้งเตือนอัตโนมัติได้อย่างแม่นยำมากกว่าโมเดลที่ใช้ค่า Softmax ปกติ โดยเมื่อโมเดลทำนายเหตุการณ์เป็นประเภท Mi ระบบจะทำการแจ้งเตือนหัวหน้างานทันทีผ่านระบบ Notification เพื่อให้เข้าดำเนินการตรวจสอบเชิงลึกและลดความสูญเสียสะสมเรื้อรัง (Chronic Loss) นอกจากนี้ ข้อมูล GM และ Mi ที่ได้ยังสามารถนำไปวิเคราะห์สาเหตุรากเหง้า (Root Cause Analysis) เพื่อพัฒนามาตรการป้องกันในระยะยาวได้อย่างเป็นระบบ ผลลัพธ์เหล่านี้สะท้อนถึงความสำเร็จของแนวทาง Calibrated Hybrid MLP ในการประยุกต์ใช้ปัญญาประดิษฐ์เชิงอุตสาหกรรมภายใต้เงื่อนไขข้อมูลที่ซับซ้อนตามลำดับเวลาจริง

5. บทสรุปและข้อเสนอแนะ

งานวิจัยนี้มุ่งพัฒนาโมเดลปัญญาประดิษฐ์โดยใช้โครงข่ายประสาทเทียมแบบหลายชั้น (Multilayer Perceptron: MLP) เพื่อจำแนกเหตุการณ์การหยุดชะงักของเครื่องจักรในระยะเวลาสั้น (Minor Stoppage: MS) บนสายการบรรจุกระป๋อง โดยใช้ข้อมูลจริงจำนวน 2,443 เหตุการณ์ในช่วงปี พ.ศ. 2565 – พ.ศ. 2567 และประเมินผลด้วยการตรวจสอบความถูกต้องแบบไขว้สำหรับข้อมูลอนุกรมเวลาแบบเดินหน้า

(Walk-Forward Time-Series Cross-Validation) 5 รอบ ผลการประเมินพบว่าโมเดลมีประสิทธิภาพโดยรวมอยู่ในระดับสูง (Mean Macro-F1 = ร้อยละ 92.00, $\sigma = 8.40$) และสามารถจำแนกคลาสกลุ่มน้อยประเภท Mi ได้ดี (Mean Mi-F1 = ร้อยละ 84.48, $\sigma = 15.97$)

นอกจากนี้ ผลการจำแนกเชิงสัดส่วนแสดงให้เห็นว่าเหตุการณ์ส่วนใหญ่เป็นกลุ่ม General-Minor Stoppage (GM) ร้อยละ 62.83 รองลงมาคือกลุ่ม Non-Minor Stoppage (X) ร้อยละ 30.50 ขณะที่กลุ่ม Major-Minor Stoppage (Mi) มีเพียงร้อยละ 6.67 แม้มีสัดส่วนน้อยแต่เป็นกลุ่มเหตุการณ์วิกฤติที่ส่งผลต่อความสูญเสียเชิงประสิทธิภาพอย่างมีนัยสำคัญ โดยสรุปโมเดล MLP ที่พัฒนาขึ้นมีศักยภาพในการใช้เป็นเครื่องมือสนับสนุนการติดตาม การจัดลำดับความสำคัญของปัญหา และการแจ้งเตือนเชิงรุกเพื่อยกระดับค่า OEE ในโรงงานผลิตเครื่องดื่มได้อย่างเป็นรูปธรรม

ในด้านการนำผลการวิจัยไปประยุกต์ใช้งานจริง (Practical Implementation) ผลการจำแนกระดับความรุนแรงของ Minor Stoppage สามารถนำไปใช้เป็นเกณฑ์ในการจัดทำคู่มือบทเรียนจุดเดียว (One-Point Lesson: OPL) เพื่อกำหนดขอบเขตความรับผิดชอบและมาตรฐานการตอบสนองที่ชัดเจน โดยแยกแยะระหว่างอาการขัดข้องเบื้องต้นที่พนักงานควบคุมเครื่องจักร (Operator) สามารถแก้ไขได้เองทันที และอาการระดับรุนแรงหรือมีความซับซ้อน (Mi) ที่จำเป็นต้องแจ้งช่างซ่อมบำรุง (Technician) เข้าดำเนินการ นอกจากนี้ ข้อมูลที่ถูกจำแนกอย่างเป็นระบบยังสามารถนำไปบูรณาการร่วมกับการจัดทำพจนานุกรมรหัสแจ้งเตือน (Alarm Dictionary) เพื่อช่วยให้ช่างซ่อมบำรุงสามารถอ้างอิงความหมายของ Alarm และวิธีการแก้ไขปัญหาของแต่ละเครื่องจักรในสายการผลิตได้อย่างรวดเร็วและแม่นยำ แนวทางเหล่านี้ไม่เพียงแต่ช่วยลดความสับสนในการปฏิบัติงานหน้างาน แต่ยังช่วยลดระยะเวลาในการเข้าแก้ไขปัญหา (Mean Time to Repair) ได้อย่างมีประสิทธิภาพ

จากงานวิจัยนี้สามารถนำไปประยุกต์ปรับเข้ากับสายการผลิตอื่นในอุตสาหกรรมการบรรจุเครื่องดื่มหรืออุตสาหกรรมที่มีลักษณะการหยุดชะงักระยะสั้นคล้ายกันได้โดยไม่ต้องปรับเกณฑ์การนิยามฉลากเหตุการณ์ให้สอดคล้องกับบริบทของแต่ละไลน์ เช่น เกณฑ์เวลาและความถี่การเกิดซ้ำ

สุดท้ายควรต่อยอด ทดสอบกับข้อมูลระยะยาวและพิจารณาใช้โมเดลลำดับเวลาและเทคนิค Explainable AI เพื่อเพิ่มความไวในการตรวจจับและความเชื่อมั่นในการนำไปใช้งานจริงในระดับโรงงาน

5.1 ข้อจำกัดของงานวิจัย

แม้งานวิจัยนี้จะแสดงผลลัพธ์ที่น่าพอใจ แต่ยังมีข้อจำกัดบางประการ ได้แก่

(1) โมเดลถูกพัฒนาจากข้อมูลของโรงงานผลิตเครื่องดื่มเพียงแห่งเดียว การประยุกต์ใช้ในบริบทอื่นอาจต้องมีการปรับเทียบหรือฝึกโมเดลใหม่ (Re-training)

(2) ยังไม่ได้พิจารณาปัจจัยภายนอก เช่น สภาพแวดล้อมหรือภาระงานของพนักงาน ซึ่งอาจมีผลต่อการเกิด Minor Stoppage

(3) ยังไม่ได้เปรียบเทียบกับโมเดลเชิงลำดับเวลา (Sequence Models) เช่น Transformer ซึ่งเป็นแนวทางที่ควรศึกษาเพิ่มเติมในอนาคต

กิตติกรรมประกาศ

งานวิจัยนี้สำเร็จลุล่วงได้ด้วยความกรุณา และการสนับสนุนจากหลายฝ่าย ผู้วิจัยขอขอบพระคุณสถานประกอบการภาคอุตสาหกรรมเครื่องดื่มกรณีศึกษาที่ให้โอกาสในการศึกษากระบวนการสายการบรรจุเครื่องดื่มจริงรวมถึงเจ้าหน้าที่และพนักงานในสายการบรรจุที่ให้ข้อมูลและความร่วมมือในการเก็บรวบรวมข้อมูลอย่างดียิ่ง

เอกสารอ้างอิง

- [1] 360i Research. Beverage market by beverage type, packaging format, distribution channel, flavor profile global forecast to 2030. 2025. Available from: <https://www.researchandmarkets.com/report/beverage> [Accessed 12 Nov 2025].
- [2] Nakajima S. *Introduction to total productive maintenance*. Cambridge (MA): Productivity Press; 1988.
- [3] Bengtsson M, Johansson A, Andersson J. Managing chronic losses through continuous

improvement and TPM. *International Journal of Production Research*. 2022;60(12):3752–3767.

- [4] Arima S, Sumita U, Yoshii J. Development of sequential association rules for preventing minor-stoppages in semiconductor manufacturing. In: *Proceedings of the 1st International Conference on Operations Research and Enterprise Systems (ICORES 2012)*. 2012. p.1–8.
- [5] Corrales LdCN, Lambán MP, Körner MEH, Royo J. Overall equipment effectiveness: systematic literature review and overview of different approaches. *Applied Sciences*. 2020;10(18):6469. DOI:10.3390/app10186469.
- [6] Hedman R, Subramaniyan M, Almström P. Analysis of hidden losses in manufacturing: a case study in continuous improvement. *Journal of Manufacturing Technology Management*. 2016;27(1):78–95. DOI:10.1108/JMTM-02-2015-0017.
- [7] Perumal A, Hasan N, Lam J. Reducing minor stoppages in food manufacturing using Lean Six Sigma. *Journal of Cleaner Production*. 2019;234:1203–1213. DOI:10.1016/j.jclepro.2019.06.188.
- [8] Lee J, Kao HA, Yang S. Deep learning-based anomaly detection in manufacturing systems. *IEEE Transactions on Industrial Informatics*. 2019;15(9):5079–5088. DOI:10.1109/TII.2019.2894262.
- [9] Goodfellow I, Bengio Y, Courville A. *Deep learning*. Cambridge (MA): MIT Press; 2016.
- [10] Hubicki R, Richert M, Lebkowski P, Hubicka N. Impact of micro-stoppages on overall equipment effectiveness measure. *Enterprise Management (Zarządzanie Przedsiębiorstwem)*. 2020;23(1):1015.
- [11] Carver D, Sapkota DN, Hossain DS. Precision in production: understanding the ripple effects of minor stops and adaptive speed strategies. In:

Proceedings of the International Conference on Industrial Engineering and Operations Management. 2024.

- [12] Suthikunsombat P, Ruangchoengchum P. The loss reduction from downtime by improving overall equipment effectiveness and speed controlling in the offset printing process. *Journal of Accountancy and Management Mahasarakham University*. 2020;12(3):144–156. (in Thai).
- [13] Stryker C, Kavlakoglu E. What is artificial intelligence (AI). IBM. 2024. Available from: <https://www.ibm.com/think/topics/artificial-intelligence> [Accessed 12 Nov 2025].
- [14] Digital Government Development Agency (DGA). *AI and the public sector: a beginner's guide to using AI with good governance*. Bangkok: Digital Government Development Agency; 2023. (in Thai).
- [15] Wosu D, George A, Aikhuele DO, Nwosu HU. Development of artificial intelligent-based model for improving productivity and reducing manufacturing cost. *Saudi Journal of Engineering and Technology*. 2025;10(1):13–16.
- [16] Zaid S, Diao A, Osintsev K. Prediction by artificial neural networks of wind turbine outages for maintenance to reduce energy losses. *E3S Web of Conferences*. 2025;614:01010. DOI:10.1051/e3sconf/202561401010.
- [17] Nixon J, Dusenberry MW, Zhang L, Jerfel G, Tran D. Measuring calibration in deep learning. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops*. 2019.
- [18] Zhong Z, Lin C, Wang J, Li S. Improving calibration for long-tailed recognition. In: *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition*. 2021. p.16489–16498.