



การจำแนกหน่วยสูญเสียที่ไม่ใช่ทางเทคนิคสำหรับมิเตอร์อ่านหน่วยอัตโนมัติในระบบ
จำหน่ายการไฟฟ้าส่วนภูมิภาค (กฟภ.) ด้วยปัญญาประดิษฐ์
Non-Technical Loss Classification for Automatic Meter Reading in
Provincial Electricity Authority Using Artificial Intelligence

ศุภกาญจน์ จันท์ทอง
Supakan Janthong

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า
มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Partial Fulfillment of the Requirement for the
Degree of Master of Engineering in Electrical Engineering
Prince of Songkla University

2566

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์



การจำแนกหน่วยสูญเสียที่ไม่ใช่ทางเทคนิคสำหรับมิเตอร์อ่านหน่วยอัตโนมัติในระบบ
จำหน่ายการไฟฟ้าส่วนภูมิภาค (กฟภ.) ด้วยปัญญาประดิษฐ์
Non-Technical Loss Classification for Automatic Meter Reading in
Provincial Electricity Authority Using Artificial Intelligence

ศุภกานูจน์ จันทร์ทอง
Supakan Janthong

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญา
วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า
มหาวิทยาลัยสงขลานครินทร์

A Thesis Submitted in Partial Fulfillment of the Requirement for the
Degree of Master of Engineering in Electrical Engineering
Prince of Songkla University

2566

ลิขสิทธิ์ของมหาวิทยาลัยสงขลานครินทร์

ชื่อวิทยานิพนธ์ การจำแนกหน่วยสูญเสียที่ไม่ใช่ทางเทคนิคสำหรับมิเตอร์อ่านหน่วยอัตโนมัติในระบบจำหน่ายการไฟฟ้าส่วนภูมิภาค (กฟภ.) ด้วยปัญญาประดิษฐ์

ผู้เขียน นายศุภกฤษฎณ์ จันทร์ทอง

สาขา วิศวกรรมไฟฟ้า

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก**คณะกรรมการสอบ**

.....ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.กฤษณ์ ฤทธิยานนท์) (รองศาสตราจารย์ ดร.พรชัย พลฤกษ์ภัทรานนท์)

อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม

.....กรรมการ
(ดร.วฤทธิ์ วิชกุล)

.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.รักกฤตว์ ดวงสร้อยทอง) (ศาสตราจารย์ ดร.นิพนธ์ ธีรอำพน)

.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.กฤษณ์ ฤทธิยานนท์)

.....กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.รักกฤตว์ ดวงสร้อยทอง)

บัณฑิตวิทยาลัย มหาวิทยาลัยสงขลานครินทร์ อนุมัติให้รับวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา ตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า

.....
(ผู้ช่วยศาสตราจารย์ ดร.เอกกิง วงศ์ศิริโชติ)

คณบดีบัณฑิตวิทยาลัย

ขอรับรองว่า ผลงานวิจัยนี้มาจากการศึกษาวิจัยของนักศึกษาเอง และได้แสดงความขอบคุณบุคคลที่มีส่วนช่วยเหลือแล้ว

ลงชื่อ.....

(ผู้ช่วยศาสตราจารย์ ดร.กุสุมาลย์ เฉลิมยานนท์)
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

ลงชื่อ.....

(ผู้ช่วยศาสตราจารย์ ดร.รักรัตน์ ดวงสร้อยทอง)
อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม

ลงชื่อ.....

(นายศุภกานูจน์ จันทร์ทอง)
นักศึกษา

ข้าพเจ้าขอรับรองว่า ผลงานวิจัยนี้ไม่เคยเป็นส่วนหนึ่งของการอนุมัติปริญญาในระดับใดมาก่อน และ
ไม่ได้ถูกใช้ในการยื่นอนุมัติปริญญาในขณะนี้

ลงชื่อ.....

(นายศุภกานจน์ จันทร์ทอง)

นักศึกษา

ชื่อวิทยานิพนธ์	การจำแนกหน่วยสูญเสียที่ไม่ใช่ทางเทคนิคสำหรับมิเตอร์อ่านหน่วยอัตโนมัติในระบบจำหน่ายการไฟฟ้าส่วนภูมิภาค (กฟภ.) ด้วยปัญญาประดิษฐ์
ผู้เขียน	นายศุภกานูญณ์ จันทร์ทอง
สาขาวิชา	วิศวกรรมไฟฟ้า
ปีการศึกษา	2566

บทคัดย่อ

หน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (Non-Technical Losses: NTL) ในระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาค (กฟภ.) เป็นหน่วยสูญเสียที่คำนวณจากผลต่างระหว่างหน่วยสูญเสียทั้งหมดกับหน่วยสูญเสียทางด้านเทคนิค (Technical Losses: TL) ไม่ได้พิจารณาจากที่มาของการเกิดขึ้นที่แท้จริง สาเหตุส่วนหนึ่งเกิดจากหน่วยที่ไม่ได้ถูกอ่านค่าผ่านเครื่องวัด การทำงานผิดพลาดของมิเตอร์ การวัดค่าผิดพลาด และการละเมิดหรือการขโมยใช้ไฟ เป็นต้น ระบบอ่านหน่วยการใช้ไฟอัตโนมัติ (Automatic Meter Reading: AMR) ถูกนำมาติดตั้งใช้งานให้กับผู้ใช้ไฟรายสำคัญ เพื่อเฝ้าระวัง ตรวจสอบและตรวจจับความผิดปกติที่อาจเกิดขึ้น ข้อจำกัดอย่างหนึ่งที่พบคือระบบดังกล่าวสามารถแจ้งเตือนความผิดปกติที่เกิดขึ้นได้ แต่ยังไม่สามารถจำแนกได้ว่าความผิดปกติที่เกิดขึ้นเป็นรูปแบบใด ด้วยความก้าวหน้าด้านเทคโนโลยีและความสามารถของปัญญาประดิษฐ์ในปัจจุบัน ได้นำมาประยุกต์ใช้เพื่อแก้ไขปัญหาในงานวิจัยนำข้อมูลจากมิเตอร์ AMR ในฐานข้อมูล กฟภ. และผลการตรวจสอบหน้างานจริงมาทำการสำรวจวิเคราะห์ สกัด และจำแนกข้อมูลโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ออกเป็น 3 รูปแบบ ได้แก่ ปกติ ชำรุด และละเมิด ประเด็นสำคัญในงานวิจัยนี้คือ การสกัดข้อมูลซึ่งประกอบด้วย ข้อมูลด้านสัญญาณไฟฟ้าและข้อมูลด้านกายภาพ โดยแบ่งออกเป็น 3 คุณลักษณะ (1) สกัดเป็นคุณลักษณะประเภทตาราง (2) สกัดโดยพิจารณาสัญญาณไฟฟ้าสำหรับอนุกรมเวลาที่อยู่ในรูปของค่าสัมประสิทธิ์ โดเมนความถี่ และการแปลงเวฟเล็ท และ (3) สกัดโดยการแปลงจากอนุกรมเวลาเป็นรูปภาพ ผลลัพธ์ที่ได้มีความความถูกต้อง 60-70%, 70-80% และ 80-90% ตามลำดับ ทั้งนี้ได้มีการนำข้อมูลมาทำการสมมูลโดยใช้สร้างโมเดลความผิดปกติ การสุ่มตัวอย่างแบบสังเคราะห์ปรับเปลี่ยนค่าได้ การเพิ่มข้อมูลโดยการปรับรูปภาพ การทำสมมูลข้อมูลช่วยเพิ่มประสิทธิภาพในการเรียนรู้ของโมเดล ลดการเกิด Overfitting และ Bias นอกจากนี้ยังมีการจัดกลุ่มประเภทลูกค้าโดยใช้ K-Means Clustering ลดความหลากหลายของรูปแบบการใช้ไฟและเพิ่มความแม่นยำในการจำแนก สุดท้ายนี้ โมเดลที่ได้ถูกนำออกมาทดสอบกับข้อมูลชุดใหม่จากเว็บไซต์ของ กฟภ. และกรณีศึกษาสำหรับเหตุการณ์จริงเพื่อประเมินผลการทำนายจากการออกตรวจสอบหน้างานจริง ผลลัพธ์ที่ได้มีประสิทธิภาพโดยรวมประมาณ 80-85%

คำสำคัญ: หน่วยสูญเสียที่ไม่ใช่ทางเทคนิค, ระบบอ่านหน่วยการใช้ไฟอัตโนมัติ, การละเมิด, มิเตอร์ชำรุด, การสกัดคุณลักษณะ, การสมมูลข้อมูล, การจัดกลุ่มข้อมูล, การเรียนรู้ของเครื่องจักร, การเรียนรู้เชิงลึก

Thesis Title Non-Technical Loss Classification for Automatic Meter Reading in Provincial Electricity Authority Using Artificial Intelligence
Author Mr. Supakan Janthong
Major Program Electrical Engineering
Academic Year 2023

ABSTRACT

Non-technical loss (NTL) in the distribution system of Provincial Electricity Authority (PEA) is a loss calculated from the difference between the total loss and the technical loss (TL), not considering the actual source of occurrence. Partly caused by loss not being read through meter, a defective meter, measurement error, electricity theft, etc. The Automatic Meter Reading (AMR) system has been installed for major electricity customers for monitoring, inspection, and to detect possible abnormalities. One of the limitations encountered by AMR systems is that the system can provide alarms for abnormalities but cannot classify anomaly patterns. With the advancement in technology and the ability of artificial intelligence today has been applied to solve this problem. In this research, AMR data from PEA database and the actual on-site inspection results were explored to visualize, analyze, extract, and classify data using machine learning and deep learning into three classes: normal conditions, defective meters, and energy theft patterns. The key points in this research are data extraction, which includes electrical signals and physical data. It is divided into three characteristics: (1) extracted as tabular features; (2) extracted by considering electrical signals in terms of time series as coefficients, frequency domains, and wavelet transforms; and (3) extracted by converting from time series to images. The results obtained have an accuracy of 60–70%, 70–80%, and 80–90%, respectively. Additionally, the data were balanced using an anomaly model, adaptive synthetic sampling, and image data augmentation to enhance model learning efficiency and reduce overfitting and bias. Moreover, we also provide customer categorization using K-means clustering, reducing multiple customer groups, and improving classification accuracy. Finally, the model has been exported to be tested with new data from PEA's website and case studies for real events to evaluate the prediction results from the actual on-site inspection. The results obtained are about 80–85% effective overall.

Keywords: Non-technical loss, Automatic meter reading, Energy theft, Defective meters, Feature extraction, Data balancing, Machine learning, Deep learning, Clustering patterns.

กิตติกรรมประกาศ

ข้าพเจ้าขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.กุสุมาลย์ เฉลิมยานนท์ อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก และผู้ช่วยศาสตราจารย์ ดร.รักรัตน์ ดวงสร้อยทอง อาจารย์ที่ปรึกษาวิทยานิพนธ์ร่วม ที่อุทิศเวลาในการให้คำปรึกษาแนะนำองค์ความรู้ที่มีประโยชน์ ช่วยพัฒนากระบวนการคิด การเรียนรู้และการแก้ปัญหาในการทำวิจัย รวมทั้งให้กำลังใจแก่ข้าพเจ้าเสมอมา ตลอดจนได้ช่วยตรวจทาน วิจารณ์ และแก้ไขวิทยานิพนธ์จนแล้วเสร็จสมบูรณ์

ข้าพเจ้าขอขอบพระคุณ รองศาสตราจารย์ ดร.พรชัย พงษ์ภักดิ์ทรานนท์ ประธานกรรมการสอบป้องกันวิทยานิพนธ์และกรรมการสอบโครงร่างวิทยานิพนธ์ ที่ได้กรุณาอุทิศเวลาให้คำแนะนำที่เป็นประโยชน์ต่อการทำงานวิจัย ถ่ายทอดองค์ความรู้ทั้งภาคทฤษฎีและภาคปฏิบัติ และช่วยตรวจทานวิทยานิพนธ์ให้ดำเนินไปได้อย่างสมบูรณ์

ข้าพเจ้าขอขอบพระคุณ ดร. วรุตี วิชกุล ที่ได้กรุณาอุทิศเวลามาเป็นกรรมการสอบป้องกันวิทยานิพนธ์และกรรมการสอบโครงร่างวิทยานิพนธ์ ซึ่งให้คำแนะนำที่เป็นประโยชน์ต่อการทำงานวิจัยเสมอมา

ข้าพเจ้าขอขอบพระคุณ รองศาสตราจารย์ ดร.นิพนธ์ อธิอำพน ที่ได้กรุณาอุทิศเวลาเพื่อมาเป็นคณะกรรมการสอบป้องกันวิทยานิพนธ์ ให้คำแนะนำที่เป็นประโยชน์ต่อการทำงานวิจัย และตรวจทานวิทยานิพนธ์ให้ดำเนินไปได้อย่างสมบูรณ์

ข้าพเจ้าขอขอบพระคุณ คณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์ ที่ได้ให้การสนับสนุนอุปกรณ์ ห้องปฏิบัติการ และสถานที่ในการทำวิทยานิพนธ์

ข้าพเจ้าขอขอบพระคุณ กองพัฒนาระบบมิเตอร์ การไฟฟ้าส่วนภูมิภาค ที่ช่วยสนับสนุนข้อมูลสำหรับการทำวิจัย การไฟฟ้าส่วนภูมิภาค ที่ให้การสนับสนุนทุนการศึกษาและให้โอกาสพนักงานได้ศึกษาต่อในระดับที่สูงขึ้น เพื่อนำองค์ความรู้ที่ได้กลับไปพัฒนาองค์กรต่อไป

ข้าพเจ้าขอขอบพระคุณ คณาจารย์ บุคลากร รวมถึงมิตรสหาย ในภาควิชาวิศวกรรมไฟฟ้าทุกท่าน ที่ให้คำปรึกษาและความช่วยเหลือที่ดีเสมอมา

สุดท้ายนี้ ข้าพเจ้าน้อมรำลึกถึงพระคุณของบิดามารดา และครอบครัว ที่ให้ความรัก ความห่วงใย คอยส่งเสริมสนับสนุน ให้คำปรึกษา และให้กำลังใจที่ดีเยี่ยมแก่ข้าพเจ้า จนกระทั่งทำให้ข้าพเจ้าประสบความสำเร็จ

ศุภกาญจน์ จันทร์ทอง

สารบัญ

	หน้า
บทคัดย่อ.....	(5)
ABSTRACT.....	(6)
กิตติกรรมประกาศ.....	(7)
สารบัญ.....	(8)
รายการตาราง.....	(18)
รายการภาพประกอบ.....	(22)
คำย่อและชื่อเต็ม.....	(27)
บทที่ 1 บทนำ.....	1
1.1 ความสำคัญและที่มาของงานวิจัย.....	1
1.2 งานวิจัยที่เกี่ยวข้อง.....	3
1.2.1 วิธีการและประเภทของข้อมูลในการวิเคราะห์กำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค.....	3
1.2.1.1 วิธีใช้ข้อมูลพื้นฐานด้านเศรษฐกิจและสังคม.....	3
1.2.1.2 วิธีการแบบใช้ฮาร์ดแวร์.....	4
1.2.1.3 วิธีการแบบไม่ใช้ฮาร์ดแวร์.....	4
1.2.1.4 วิธีใช้ข้อมูลพื้นฐาน ข้อมูลในระบบเครือข่าย และวิธีการแบบไฮบริด.....	4
1.2.2 ประเภทของเทคนิคที่ใช้ในการสกัดข้อมูลเพื่อหาลำดับไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค.....	9
1.2.2.1 คุณลักษณะที่สกัดจากการแจ้งเตือนตัวมิเตอร์ (QB Measurements).....	9
1.2.2.2 คุณลักษณะที่สกัดจากปริมาณการใช้ไฟ (Energy Consumption).....	10
1.2.2.3 คุณลักษณะที่สกัดจากระยะทางและความหนาแน่น (Distance and Density).....	10
1.2.2.4 คุณลักษณะที่สกัดจากการจำลองพฤติกรรมใช้ไฟ (Simulation Load Profiles).....	12

สารบัญ (ต่อ)

	หน้า
1.2.2.5 คุณลักษณะสกัดจากอนุกรมเวลาเป็นรูปภาพ (Time Series to Images)	12
1.2.3 เทคนิคในการจำแนกคุณลักษณะของกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค	15
1.2.3.1 การจำแนกโดยใช้เทคนิคการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)	15
1.2.3.2 การจำแนกโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning).....	17
1.2.3.3 การจำแนกโดยใช้เทคนิคอื่นๆ	22
1.2.4 การประเมินผลโมเดลที่ใช้จำแนกกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค	26
1.2.5 ตารางเปรียบเทียบการทบทวนวรรณกรรม.....	28
1.3 วัตถุประสงค์ของการวิจัย.....	29
1.4 ขอบเขตการวิจัย	30
1.5 ประโยชน์ที่คาดว่าจะได้รับ	30
1.6 ประเด็นการวิจัย	31
1.7 ขั้นตอนและวิธีการดำเนินการวิจัย	32
1.8 สถานที่ทำวิจัยและเก็บรวบรวมข้อมูล.....	35
1.9 แผนการดำเนินงานวิจัย	35
บทที่ 2 ทฤษฎีและหลักการ.....	36
2.1 รายละเอียดเกี่ยวกับพลังงานไฟฟ้าสูญเสีย	36
2.1.1 ผลกระทบและเกณฑ์วัดค่ากำลังไฟฟ้าสูญเสีย.....	36
2.1.2 ประเภทของกำลังไฟฟ้าสูญเสีย	38
2.1.2.1 กำลังไฟฟ้าสูญเสียทางเทคนิค (Technical Losses).....	38
2.1.2.2 กำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (Non-Technical Losses).....	39

สารบัญ (ต่อ)

	หน้า
2.1.3 มาตรการลดหน่วยสูญเสียของการไฟฟ้าส่วนภูมิภาค	43
2.1.3.1 มาตรการลดหน่วยสูญเสียทางด้านเทคนิค (Technical Losses)	43
2.1.3.2 มาตรการลดหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (Non-Technical Losses)	44
2.2 การอ่านหน่วยไฟฟ้าอัตโนมัติ (Automatic Meter Reading: AMR)	45
2.3 การแปลงจากอนุกรมเวลาเป็นโดเมนความถี่ (Time Domain to Frequency Domain)	47
2.4 การแปลงอนุกรมเวลาโดยวิธีเวฟเล็ต (Wavelet Transform)	49
2.5 การเรียนรู้แบบมีผู้สอน (Supervised Learning)	50
2.5.1 การวิเคราะห์การถดถอยโลจิสติก (Logistic Regression Analysis)	51
2.5.2 การเรียนรู้แบบต้นไม้ตัดสินใจ (Decision Tree Learning)	51
2.5.3 การเรียนรู้แบบเบย์ (Bayesian Learning)	52
2.5.4 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine)	52
2.5.5 วิธีการเพื่อนบ้านใกล้ที่สุด (k-Nearest Neighbors)	53
2.5.6 โครงข่ายประสาทเทียมอัจฉริยะ (Artificial Neuron Network)	53
2.6 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)	55
2.7 โครงข่ายประสาทเทียมคอนโวลูชัน Convolutional Neural Network (CNN)	55
2.7.1 LeNet	57
2.7.2 AlexNet	57
2.7.3 VGGNet	58
2.7.4 GoogLeNet	58
2.7.5 ResNet	59

สารบัญ (ต่อ)

	หน้า
2.7.6 DenseNet.....	60
บทที่ 3 อุปกรณ์และวิธีการ	61
3.1 รวบรวมข้อมูลเบื้องต้น (Data Collection).....	61
3.1.1 รายละเอียดของข้อมูล.....	61
3.1.2 ชนิดของข้อมูล	62
3.1.3 ประเภทของข้อมูล.....	63
3.1.3.1 รายละเอียดข้อมูลอุปกรณ์ชำรุด.....	63
3.1.3.2 รายละเอียดข้อมูลการละเมิด	66
3.1.4 การจำแนกลักษณะของข้อมูล	69
3.1.5 การเปรียบเทียบความแตกต่างของข้อมูลแต่ละชนิด	69
3.1.5.1 วิเคราะห์ความแตกต่างระหว่างลักษณะปกติ ละเมิด และชำรุด.....	70
3.1.5.2 เปรียบเทียบความแตกต่างระหว่างการละเมิดกับลักษณะชำรุด.....	72
3.1.5.3 สรุปรูปแบบความแตกต่างลักษณะละเมิดกับชำรุด.....	74
3.2 การเตรียมข้อมูล (Data Preparation).....	75
3.2.1 การปรับปรุงข้อมูลให้สมบูรณ์ (Interpolation).....	75
3.2.2 การทำข้อมูลให้เป็นมาตรฐาน (Normalization).....	76
3.3 การสกัดข้อมูล (Data Extraction).....	76
3.3.1 สกัดข้อมูลโดยใช้ข้อมูลจากคำมีเตอร์โดยตรง (AMR Data Extraction)	77
3.3.1.1 วิเคราะห์จากลักษณะความผิดปกติที่เกิดขึ้นในช่วงเวลาที่วิเคราะห์	77
3.3.1.2 วิเคราะห์จากลักษณะความผิดปกติที่เกิดขึ้นก่อนช่วงเวลาที่วิเคราะห์	78

สารบัญ (ต่อ)

	หน้า
3.3.1.3 วิเคราะห์ค่าระยะทางและความหนาแน่น (Distance and Density).....	80
3.3.2 สกัดข้อมูลโดเมนเวลาและโดเมนความถี่ (Time and Frequency Domain).....	80
3.3.2.1 วิเคราะห์โดยแบ่งข้อมูลออกเป็นช่วงและคำนวณโดยใช้ค่าทางสถิติ	81
3.3.2.2 วิเคราะห์โดยใช้วิธีแยกองค์ประกอบของอนุกรมเวลา	81
3.3.2.3 วิเคราะห์โดยใช้ Auto-Correlation.....	81
3.3.2.4 วิเคราะห์โดยใช้การแปลงฟูรีเยร์แบบไม่ต่อเนื่อง.....	82
3.3.2.5 วิเคราะห์โดยใช้ความหนาแน่นของสเปกตรัมพลังงาน	82
3.3.3 สกัดข้อมูลโดยใช้การแปลงเวฟเล็ต Wavelet Transform	83
3.3.4 สกัดข้อมูลโดยการแปลงเป็นรูปภาพ (Time Series to Image).....	84
3.3.4.1 Recurrence Plot (RP).....	84
3.3.4.2 Spectrogram (SG).....	85
3.3.4.3 Gramian Summation Angular Field (GASF).....	85
3.3.4.4 Markov Transition Field (MTF)	86
3.3.5 สกัดข้อมูลโดยใช้การสร้างแบบจำลองสัญญาณ (Signal Modeling).....	86
3.3.5.1 Pade Approximation	87
3.3.5.2 Prony's Method.....	87
3.3.5.3 Shanks' Method	88
3.3.5.4 Autocorrelation Method	88
3.3.5.5 Covariance Method.....	88
3.4 โมเดลสำหรับจำแนกข้อมูล (Model Classification).....	89

สารบัญ (ต่อ)

	หน้า
3.4.1 แบ่งข้อมูล (Splitting up Data)	89
3.4.2 โมเดลประเภทการเรียนรู้แบบมีผู้สอน (Supervised Learning).....	89
3.4.3 โมเดลประเภทการเรียนรู้เชิงลึก (Deep Learning).....	91
3.5 การประเมินผลโมเดล (Model Evaluation).....	92
3.6 เทคนิคการจัดการข้อมูลที่ไม่สมดุล (Unbalanced Data Handling Techniques).....	92
3.6.1 สร้างโมเดลความผิดปกติ (Anomaly Model)	93
3.6.1.1 โมเดลสำหรับสร้างข้อมูลชำรุด (Defective Models).....	93
3.6.1.2 โมเดลสำหรับสร้างข้อมูลละเมิด (Theft Models)	95
3.6.2 การสุ่มตัวอย่างแบบสังเคราะห์ปรับเปลี่ยนค่าได้ (Adaptive Synthetic Sampling).....	95
3.6.3 การเพิ่มข้อมูลโดยการปรับรูปภาพ (Image Data Augmentation).....	95
3.6.4 การแบ่งข้อมูลสำหรับสอนและทดสอบเทคนิคการจัดการข้อมูลที่ไม่สมดุล	98
3.7 วิธีการทดสอบโมเดล (Test Model).....	99
3.7.1 ทดสอบโมเดลจากข้อมูลชุดอื่น (Test with Real Data).....	99
3.7.2 ทดสอบโมเดลจากเหตุการณ์จริง (Test with Real Events)	99
3.8 การใช้เทคนิคการจัดกลุ่มข้อมูล	100
3.8.1 เทคนิคที่ใช้จัดกลุ่ม	100
3.8.2 การจัดกลุ่มก่อนจำแนกรูปแบบผิดปกติ	102
3.8.3 การจัดกลุ่มเพื่อแยกรูปแบบความผิดปกติตามสาเหตุการเกิด	104
บทที่ 4 ผลการวิจัย.....	105
4.1 ผลการสกัดข้อมูลโดยใช้ข้อมูลจากค่ามิเตอร์โดยตรง	105

สารบัญ (ต่อ)

	หน้า
4.1.1 ผลการสกัดข้อมูลโดยรวมการใช้เทคนิควิเคราะห์ข้อมูลโดยตรง.....	105
4.1.2 ผลการวิเคราะห์โดยใช้การสร้างภาพ (Visualization).....	108
4.1.3 ผลการหาความสัมพันธ์ของข้อมูล (Pearson Correlation).....	110
4.1.4 ผลลัพธ์การสอนและทดสอบโมเดล.....	111
4.2 ผลการสกัดข้อมูลโดเมนเวลาและโดเมนความถี่ (Time and Frequency Domain).....	112
4.2.1 พิจารณาการสกัดข้อมูลโดเมนเวลา	112
4.2.1.1 ผลการสกัดที่อยู่ในโดเมนอนุกรมเวลา (Time domain).....	112
4.2.1.2 ผลการสอนและทดสอบโมเดลจากข้อมูลโดเมนเวลา	119
4.2.2 ผลการสกัดข้อมูลจากโดเมนความถี่ (Frequency domain).....	121
4.2.2.1 ผลการสกัดพิจารณาจากโดเมนความถี่ (Frequency domain).....	121
4.2.2.2 ทำการสอนและทดสอบโมเดลจากข้อมูลโดเมนความถี่	125
4.2.3 พิจารณาผลการสอนและทดสอบรวม (Time domain and Freq domain)	126
4.3 ผลการสกัดข้อมูลโดยใช้ Wavelet Transform และการแปลงให้อยู่ในรูป 2D Image	126
4.3.1 ผลการสกัดข้อมูลอนุกรมเวลาโดยใช้ทั้ง 5 เทคนิค.....	128
4.3.2 แบ่งข้อมูลสำหรับสอนและทดสอบการแปลงอนุกรมเวลาเป็นรูปภาพ	131
4.3.3 ผลการสอนและทดสอบการแปลงอนุกรมเวลาเป็นรูปภาพ	132
4.4 ผลลัพธ์จากการใช้เทคนิคจัดการกับข้อมูลที่ไม่สมดุล	136
4.4.1 ผลการสร้างโมเดลความผิดปกติ (Anomaly Model)	136
4.4.1.1 ชุดข้อมูลปกติ (Normal Data Samples)	136
4.4.1.2 ตัวอย่างข้อมูลชำรุดที่ได้จาก Defective Models	136

สารบัญ (ต่อ)

	หน้า
4.4.1.3 ตัวอย่างข้อมูลละเมิดที่ได้จาก Theft Models	138
4.4.2 ผลการสุ่มตัวอย่างแบบสังเคราะห์ที่ปรับเปลี่ยนค่าได้ (ASASYN)	139
4.4.3 ผลการเพิ่มข้อมูลโดยการปรับแต่งรูปภาพ (Image Data Augmentation)	140
4.4.4 ผลการสอนและทดสอบเทคนิคการจัดการข้อมูลที่ไม่สมดุล	142
4.5 ผลลัพธ์การทดสอบโมเดล (Test Model)	144
4.5.1 ผลลัพธ์การทดสอบโมเดลจากข้อมูลชุดอื่น (Test with Real Data)	144
4.5.2 ผลลัพธ์การทดสอบโมเดลจากเหตุการณ์จริง (Test with Real Events)	147
4.6 ผลการจัดกลุ่ม	150
4.6.1 ผลการจัดกลุ่มตามลักษณะของข้อมูล	150
4.6.2 ผลการจัดกลุ่มก่อนจำแนกรูปแบบผิดปกติ	155
บทที่ 5 การอภิปรายและวิเคราะห์ผลการวิจัย	159
5.1 การใช้เทคนิควิเคราะห์ตามช่วงเวลา	159
5.1.1 วิเคราะห์ข้อมูลชนิดที่สกัดเป็นตัวเลข (Numerical)	159
5.1.2 วิเคราะห์ข้อมูลชนิดที่สกัดไม่เป็นตัวเลข (Nominal)	160
5.1.3 วิเคราะห์ข้อมูลจากค่า Pearson Correlation	160
5.1.4 ผลลัพธ์การสอนและทดสอบโมเดลเทคนิควิเคราะห์ตามช่วงเวลา	161
5.2 การใช้วิธีสกัดข้อมูลที่อยู่ในโดเมนอนุกรมเวลา (Time Domain)	161
5.2.1 ผลการสกัดโดยใช้ค่าทางสถิติ (Statistical)	161
5.2.2 ผลการสกัดโดยใช้วิธีแยกองค์ประกอบของอนุกรมเวลา	162
5.2.3 ผลการสกัดโดยใช้ Auto-Correlation	162

สารบัญ (ต่อ)

	หน้า
5.2.4 ผลการสกัดโดยใช้วิธีแบบจำลองสัญญาณ (Signal Modeling).....	162
5.2.5 ผลลัพธ์การทดสอบโดยวิธีสกัดข้อมูลที่อยู่ในโดเมนอนุกรมเวลา	163
5.3 การสกัดข้อมูลจากโดเมนความถี่ (Frequency Domain).....	163
5.4 การสกัดข้อมูลโดยรวม Time domain และ Freq domain.....	164
5.5 การสกัดข้อมูลโดยการแปลงให้อยู่ในรูป 2D Image	164
5.5.1 วิเคราะห์การสกัดโดยเทคนิคที่นำมาใช้แปลงภาพแต่ละชนิด	164
5.5.2 วิเคราะห์ผลทดสอบการแปลงอนุกรมเวลาเป็นรูปภาพ	167
5.6 วิเคราะห์ผลการใช้เทคนิคจัดการข้อมูลที่ไม่สมดุล.....	167
5.6.1 วิเคราะห์ผลจากโมเดลความผิดปกติ (Anomaly Model).....	167
5.6.2 วิเคราะห์ผลจากการสุ่มตัวอย่างแบบสังเคราะห์ที่ปรับเปลี่ยนค่าได้ (ASASYN)	168
5.6.3 วิเคราะห์การเพิ่มข้อมูลโดยการปรับปรุงภาพ (Image Data Augmentation)	169
5.6.4 ผลการทดสอบเปรียบเทียบแต่ละเทคนิค	170
5.7 การทดสอบโมเดล (Test Model)	170
5.7.1 วิเคราะห์ผลการทดสอบโมเดลจากข้อมูลชุดอื่น (Test with Real Data).....	170
5.7.2 วิเคราะห์ผลการทดสอบโมเดลจากเหตุการณ์จริง (Test with Real Event).....	172
5.8 วิเคราะห์ผลจากเทคนิคการจัดกลุ่ม	174
5.8.1 วิเคราะห์ผลจากการจัดกลุ่มตามรูปแบบผิดปกติ	174
5.8.2 วิเคราะห์ผลการจัดกลุ่มก่อนนำไปจำแนกรูปแบบผิดปกติ.....	174
5.8.3 วิเคราะห์ผลการจัดกลุ่มเพื่อแยกรูปแบบความผิดปกติตามสาเหตุการเกิด	175
บทที่ 6 บทสรุปและข้อเสนอแนะ	177

สารบัญ (ต่อ)

	หน้า
6.1 ข้อสรุปสำหรับเทคนิควิเคราะห์ตามช่วงเวลา	177
6.2 ข้อสรุปสำหรับการวิเคราะห์ใน Time domain และ Frequency domain	177
6.3 ข้อสรุปสำหรับเทคนิคการแปลงให้อยู่ในรูป 2D Image	178
6.4 ข้อสรุปสำหรับการจัดการข้อมูลที่ไม่สมดุล.....	178
6.5 ข้อสรุปการทดสอบโมเดลจากข้อมูลชุดอื่นและเหตุการณ์จริง	179
6.6 ข้อสรุปการใช้เทคนิคการจัดกลุ่มข้อมูล	179
6.7 บทสรุปรวม	179
6.8 ปัญหาและแนวทางแก้ไข	180
6.9 ข้อเสนอแนะและแนวทางการพัฒนาต่อไป	180
บรรณานุกรม.....	181
ภาคผนวก.....	185
ภาคผนวก ก.....	186
ภาคผนวก ข.....	220
ภาคผนวก ค.....	243
ประวัติผู้เขียน.....	273

รายการตาราง

หน้า

ตารางที่ 1-1 เปรียบเทียบวิธีใช้ข้อมูลพื้นฐาน ข้อมูลในระบบเครือข่าย และวิธีการแบบไฮบริด [10].....	5
ตารางที่ 1-2 คุณสมบัติหลักที่ใช้สำหรับการตรวจจับหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10].....	6
ตารางที่ 1-3 รายการข้อมูลแบบเมตริกที่ใช้ในการประเมินผลลัพธ์	27
ตารางที่ 1-4 ตารางเปรียบเทียบการทบทวนวรรณกรรม	28
ตารางที่ 2-1 ข้อมูลหน่วยสูญเสียของ กฟภ. แยกรายเขต ปี 2564 สะสม 4 ไตรมาส [3]	37
ตารางที่ 2-2 ประโยชน์ที่ได้รับจากการนำระบบการอ่านหน่วยไฟฟ้าอัตโนมัติ (AMR) มาใช้งาน [26]....	46
ตารางที่ 3-1 เปรียบเทียบค่า Element ระหว่างมิเตอร์ 3P4W และ 3P3W	62
ตารางที่ 3-2 สรุปข้อมูลอุปกรณ์ชำรุดประเภท 3P4W ที่พบในการไฟฟ้าส่วนภูมิภาค.....	63
ตารางที่ 3-3 ภาพตัวอย่างแสดงลักษณะการชำรุดแต่ละชนิด ที่พบในการไฟฟ้าส่วนภูมิภาค	64
ตารางที่ 3-4 สรุปข้อมูลการละเมิดประเภท 3P4W ที่พบในการไฟฟ้าส่วนภูมิภาค	67
ตารางที่ 3-5 ภาพตัวอย่างแสดงลักษณะการละเมิดแต่ละชนิด ที่พบในการไฟฟ้าส่วนภูมิภาค	67
ตารางที่ 3-6 ความผิดปกติที่ส่งผลต่อค่าแรงดัน (Voltage)	70
ตารางที่ 3-7 ความผิดปกติที่ส่งผลต่อค่ากระแส (Current).....	70
ตารางที่ 3-8 ความผิดปกติที่มีผลต่อค่ากำลังไฟฟ้า (Active power and energy).....	71
ตารางที่ 3-9 ความผิดปกติที่มีผลต่อค่ามุม (Angle).....	71
ตารางที่ 3-10 ความผิดปกติที่มีผลต่อค่ากำลังไฟฟ้าเสมือน (Reactive power)	72
ตารางที่ 3-11 เปรียบเทียบการละเมิดกับการชำรุด และความแตกต่างที่สามารถวิเคราะห์ได้เบื้องต้น...	73
ตารางที่ 3-12 เปรียบเทียบและข้อสังเกตรูปแบบการเกิดที่ส่งผลต่อลักษณะปกติ ชำรุด และละเมิด	75
ตารางที่ 3-13 รายละเอียดการแบ่งข้อมูลแยกแต่ละประเภท	77
ตารางที่ 3-14 การแบ่งช่วงเวลาวิเคราะห์ความผิดปกติที่เกิดขึ้นในช่วงเวลา	78
ตารางที่ 3-15 การแบ่งช่วงเวลาวิเคราะห์ความผิดปกติที่เกิดขึ้นก่อนช่วงเวลา	79
ตารางที่ 3-16 การแบ่งข้อมูลออกเป็น sample (1สัปดาห์).....	80
ตารางที่ 3-17 ข้อมูลแบ่งออกเป็น 3 กลุ่ม	84
ตารางที่ 3-18 ขนาดข้อมูลรูปภาพหลังการแปลง	84
ตารางที่ 3-19 การปรับค่าพารามิเตอร์ของโมเดลแต่ละชนิด.....	90

รายการตาราง (ต่อ)

	หน้า
ตารางที่ 3-20 การกำหนดค่าพารามิเตอร์ CNN (base)	91
ตารางที่ 3-21 โมเดลสำหรับสร้างข้อมูลซ้ำชุด.....	94
ตารางที่ 3-22 รูปแบบข้อมูลที่สร้างขึ้นแบบซ้ำชุดและละเมิดจากเหตุการณ์ที่พบจริง	94
ตารางที่ 3-23 โมเดลสำหรับสร้างข้อมูลละเมิด.....	96
ตารางที่ 3-24 โมเดลการสร้างข้อมูลทั้ง 3 classes โดยใช้ ADASYN	97
ตารางที่ 3-25 รายละเอียดและพารามิเตอร์ของวิธีการปรับเชิงตำแหน่ง (Position Augmentation)...	98
ตารางที่ 3-26 จำนวนข้อมูลแรงดันและกระแสที่ทดสอบทุกทั้ง 4 รูปแบบ	98
ตารางที่ 3-27 รูปแบบละเมิดที่พบจริงกับรูปแบบซ้ำชุดจากระบบแจ้งเตือน	104
ตารางที่ 4-1 การสกัดข้อมูลจากค่าแรงดัน และเทคนิคที่ใช้	105
ตารางที่ 4-2 การสกัดข้อมูลจากค่าแรงดัน และเทคนิคที่ใช้ (ต่อ).....	106
ตารางที่ 4-3 การสกัดข้อมูลจากค่ากระแส และเทคนิคที่ใช้.....	106
ตารางที่ 4-4 การสกัดข้อมูลจากค่ากระแส และเทคนิคที่ใช้.....	107
ตารางที่ 4-5 Feature ที่สกัดได้จากการวิเคราะห์ตามช่วงเวลา จำนวน 37 feature	107
ตารางที่ 4-6 แสดง Feature ที่สกัดได้จากการวิเคราะห์ตามช่วงเวลา จำนวน 37 feature	108
ตารางที่ 4-7 ผลการ train และ validation ข้อมูลโดยใช้เทคนิควิเคราะห์	111
ตารางที่ 4-8 Feature ที่สกัดได้ จำนวน 20 feature โดยใช้ค่าทางสถิติ.....	113
ตารางที่ 4-9 ตัวอย่างก่อนและหลังการสกัดโดยใช้แบบจำลองสัญญาณ	118
ตารางที่ 4-10 ผล minimum error ของโมเดลภายหลังสร้างสัญญาณกลับ	119
ตารางที่ 4-11 ผลการสอนและทดสอบโมเดลสำหรับค่าแรงดัน จาก 4 เทคนิค	119
ตารางที่ 4-12 ผลการสอนและทดสอบโมเดลสำหรับค่ากระแส จาก 4 เทคนิค	120
ตารางที่ 4-13 Feature ที่สกัดได้ จำนวน 20 feature จากเทคนิค DFT และ PSD.....	124
ตารางที่ 4-14 ผลการสอนและทดสอบโมเดล DTF และ PSD.....	125
ตารางที่ 4-15 ผลการสอนและทดสอบโมเดลรวม Time domain และ Freq domain	126
ตารางที่ 4-16 การแบ่งข้อมูลก่อนทำการแปลงทั้ง 5 เทคนิค.....	127

รายการตาราง (ต่อ)

	หน้า
ตารางที่ 4-17 การแบ่งข้อมูลสำหรับสอนและทดสอบทั้ง 5 เทคนิค	132
ตารางที่ 4-18 ผลการทดสอบประสิทธิภาพโมเดลสำหรับค่าแรงดันทั้ง 5 เทคนิค	132
ตารางที่ 4-19 ผลการทดสอบประสิทธิภาพโมเดลสำหรับค่ากระแสทั้ง 5 เทคนิค	133
ตารางที่ 4-20 กราฟแสดงผลการทดสอบโมเดลสำหรับค่าแรงดันทั้ง 5 เทคนิค	134
ตารางที่ 4-21 กราฟแสดงผลการทดสอบโมเดลสำหรับค่ากระแสทั้ง 5 เทคนิค	135
ตารางที่ 4-22 ผลลัพธ์จากการทดสอบทั้ง 4 รูปแบบ จากเทคนิคการสมมูลข้อมูลสำหรับค่าแรงดัน	142
ตารางที่ 4-23 ผลลัพธ์จากการทดสอบทั้ง 4 รูปแบบ จากเทคนิคการสมมูลข้อมูลสำหรับค่ากระแส	143
ตารางที่ 4-24 ผลการทดสอบข้อมูลค่าแรงดันของโมเดลจากข้อมูลชุดอื่น	146
ตารางที่ 4-25 ผลการทดสอบข้อมูลค่ากระแสของโมเดลจากข้อมูลชุดอื่น	146
ตารางที่ 4-26 ผลการทดสอบข้อมูลค่าแรงดันของโมเดลจากเหตุการณ์จริง	147
ตารางที่ 4-27 ผลการทดสอบข้อมูลค่ากระแสของโมเดลจากเหตุการณ์จริง	148
ตารางที่ 4-28 ผลการจัดกลุ่มของแรงดันและกระแสทั้ง 3 กลุ่ม	150
ตารางที่ 4-29 กลุ่มแรงดันปกติ	150
ตารางที่ 4-30 กลุ่มแรงดันชำรุด	151
ตารางที่ 4-31 แรงดันละเมิด	152
ตารางที่ 4-32 กลุ่มกระแสปกติ	153
ตารางที่ 4-33 กลุ่มกระแสชำรุด	154
ตารางที่ 4-34 กลุ่มกระแสละเมิด	155
ตารางที่ 4-35 ผลการจำแนกรูปแบบกระแส หลังจัดกลุ่มโดยใช้ DenseNet121	156
ตารางที่ 4-36 การจัดกลุ่มแยกตามสาเหตุสำหรับรูปแบบการละเมิด	156
ตารางที่ 4-37 การจัดกลุ่มแยกตามสาเหตุสำหรับรูปแบบการละเมิด (ต่อ)	157
ตารางที่ 4-38 การจัดกลุ่มแยกตามสาเหตุสำหรับรูปแบบชำรุด	157
ตารางที่ 4-39 เปรียบเทียบรูปแบบละเมิดที่พบจริงกับข้อมูลละเมิดที่ถูกสร้างขึ้น	158
ตารางที่ 4-40 เปรียบเทียบรูปแบบชำรุด ที่ระบบแจ้งเตือนกับข้อมูลชำรุดที่ถูกสร้างขึ้น	158

รายการตาราง (ต่อ)

	หน้า
ตารางที่ 5-1 เปรียบเทียบจุดเด่นและข้อจำกัดทั้ง 5 เทคนิค	165
ตารางที่ 5-2 เปรียบเทียบผลการแปลงเป็นรูปภาพแต่ละเทคนิคของค่าแรงดัน.....	166
ตารางที่ 5-3 เปรียบเทียบผลการแปลงเป็นรูปภาพแต่ละเทคนิคของค่ากระแส	166
ตารางที่ 5-4 เปรียบเทียบสัญญาณจากเหตุการณ์จริงกับสัญญาณที่ถูกสร้างขึ้น.....	168
ตารางที่ 5-5 เปรียบเทียบระหว่างการจำแนกโดยไม่จัดกลุ่มกับการจัดกลุ่มก่อนจำแนก	175
ตารางที่ 5-6 การจัดกลุ่มตามสาเหตุความผิดปกติ.....	176

รายการภาพประกอบ

หน้า

ภาพประกอบที่ 1-1 การจัดหมวดหมู่ความผิดปกติของสาเหตุการเกิดหน่วยสูญเสีย NTL [6].....	3
ภาพประกอบที่ 1-2 การจัดหมวดหมู่วิธีการตรวจจับกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10].....	6
ภาพประกอบที่ 1-3 การจัดหมวดหมู่ข้อมูลดับกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10].....	8
ภาพประกอบที่ 1-4 ตัวอย่างการสกัดการแจ้งเตือนจากตัวมิเตอร์โดยใช้ Quality bit (QB) [11]	9
ภาพประกอบที่ 1-5 อุปกรณ์ในการทดลองและ schematic diagram small-scaled AMI test [12].	12
ภาพประกอบที่ 1-6 การแปลง Time series โดยใช้พล็อตการเกิดซ้ำ Recurrence plot (RP) [13].....	13
ภาพประกอบที่ 1-7 การแปลง Time series โดยใช้สเปกโตรแกรม (Spectrogram) [13].....	14
ภาพประกอบที่ 1-8 การแปลง Time series กับ Gramian summation angular Field [13]	14
ภาพประกอบที่ 1-9 การแปลง Time series โดย Markov Transition Field (MTF) [13]	15
ภาพประกอบที่ 1-10 การประยุกต์ใช้ PCA-DBSCAN-Rule 2, SOM/k-means clustering [17].....	16
ภาพประกอบที่ 1-11 แบบจำลองโครงข่ายแบบไฮบริด Hybrid neural network (HNN-NTL) [18]...	18
ภาพประกอบที่ 1-12 โครงสร้างการทำงานแบบ wide และ deep CNN framework [19].....	18
ภาพประกอบที่ 1-13 Block diagram แบบจำลอง CNN-LSTM [20]	21
ภาพประกอบที่ 1-14 Convolutional neural network-based LSTM (CNN-LSTM) โมเดล [20] ...	21
ภาพประกอบที่ 1-15 แบบจำลองการเชื่อมต่อมิเตอร์ในระบบจำหน่าย Hamming Code [21].....	22
ภาพประกอบที่ 1-16 ตัวอย่างข้อมูลที่บันทึกได้จากมิเตอร์ AMR สำหรับ Rule-based Model [22] ...	24
ภาพประกอบที่ 1-17 ตารางแสดงตัวอย่าง Confusion Matrix ขนาด 2x2	26
ภาพประกอบที่ 1-18 กรอบแนวทางวิจัย	34
ภาพประกอบที่ 2-1 ตัวอย่างเหตุการณ์ละเมิดมิเตอร์ 1 เฟส ที่ถูกพบ	40
ภาพประกอบที่ 2-2 ตัวอย่างเหตุการณ์ละเมิดมิเตอร์ 3 เฟส ที่ถูกพบ	41
ภาพประกอบที่ 2-3 ตัวอย่างเหตุการณ์มิเตอร์วัดค่าได้ไม่ถูกต้อง	41
ภาพประกอบที่ 2-4 ตัวอย่างเหตุการณ์เกิดจากพฤติกรรมของโหลดบางชนิด	42
ภาพประกอบที่ 2-5 ตัวอย่างความผิดพลาดในการอ่านค่าของเครื่องวัดหรือมิเตอร์	42
ภาพประกอบที่ 2-6 ตัวอย่างความผิดพลาดจากการเรียกเก็บเงิน.....	43
ภาพประกอบที่ 2-7 ประเภทมิเตอร์ที่มีติดตั้งใช้งานใน กฟภ.	44

รายการภาพประกอบ (ต่อ)

	หน้า
ภาพประกอบที่ 2-8 โครงสร้างของระบบ AMR [26].....	45
ภาพประกอบที่ 2-9 การวิเคราะห์สัญญาณรายคาบด้วยการแปลงฟูรีเยร์	48
ภาพประกอบที่ 2-10 การวิเคราะห์สัญญาณด้วยฟังก์ชัน Discrete wavelet transform [27]	49
ภาพประกอบที่ 2-11 การแปลง Time series โดยใช้ Wavelet transform	50
ภาพประกอบที่ 2-12 โครงสร้างพื้นฐานโครงข่ายประสาทเทียม (Neuron network: NN) [29].....	54
ภาพประกอบที่ 2-13 สรุปลสมการ Non-linear activation functions [30]	55
ภาพประกอบที่ 2-14 การทำคอนโวลูชัน (Convolutional) [28]	56
ภาพประกอบที่ 2-15 ตัวอย่างสถาปัตยกรรมของ LeNet5 [31]	57
ภาพประกอบที่ 2-16 ตัวอย่างสถาปัตยกรรมของ AlexNet [31]	58
ภาพประกอบที่ 2-17 ตัวอย่างสถาปัตยกรรมของ VGGNet [31]	58
ภาพประกอบที่ 2-18 ตัวอย่างสถาปัตยกรรมของ GoogLeNet [31]	59
ภาพประกอบที่ 2-19 ตัวอย่างแนวคิดของสถาปัตยกรรม ResNet [31]	59
ภาพประกอบที่ 2-20 หลักการทำงานของสถาปัตยกรรมระหว่างชั้นของ DenseNet [31].....	60
ภาพประกอบที่ 3-1 ภาพรวมวิธีการวิจัย	61
ภาพประกอบที่ 3-2 คำสั่ง cwtfilterbank เลือกใช้ Morlet wavelet.....	83
ภาพประกอบที่ 3-3 แบบจำลองสัญญาณ ป้อนข้อมูลเข้า $v(n)$ เพื่อประมาณค่า $\hat{x}(n)$	87
ภาพประกอบที่ 3-4 การแบ่งข้อมูลสำหรับสอน ประเมินและทดสอบ	89
ภาพประกอบที่ 3-5 โครงสร้างพื้นฐาน CNN ที่ใช้และการกำหนดค่า	92
ภาพประกอบที่ 3-6 ขั้นตอนการทดสอบโมเดลจากข้อมูลชุดอื่น	99
ภาพประกอบที่ 3-7 ขั้นตอนการทดสอบโมเดลจากเหตุการณ์จริง	100
ภาพประกอบที่ 3-8 แสดงขั้นตอนการจัดกลุ่ม	101
ภาพประกอบที่ 3-9 ตัวอย่างการจัดกลุ่มแรงดันที่ชำรุด	101
ภาพประกอบที่ 3-10 Dendrogram และการจัดกลุ่มสำหรับกลุ่มแรงดันที่ชำรุด.....	102
ภาพประกอบที่ 3-11 ค่ากระแสปกติและชำรุด(ก-ข) และค่ากระแสปกติ(ค-ง) ผู้ใช้ไฟรายหนึ่ง	102

รายการภาพประกอบ (ต่อ)

	หน้า
ภาพประกอบที่ 3-12 การแบ่งกลุ่มอนุกรมเวลาของกระแสก่อนจำแนก	103
ภาพประกอบที่ 4-1 ลักษณะค่าสัญญาณไฟฟ้าของค่ากระแสและแรงดัน กรณีละเมิด	109
ภาพประกอบที่ 4-2 ลักษณะค่าสัญญาณไฟฟ้าของค่ากระแสและแรงดัน กรณีชำรุด	109
ภาพประกอบที่ 4-3 ค่าความสัมพันธ์ Pearson correlation แรงดัน	110
ภาพประกอบที่ 4-4 ค่าความสัมพันธ์ Pearson correlation กระแส	111
ภาพประกอบที่ 4-5 ผลการ validation เทคนิควิเคราะห์ตามช่วงเวลา	112
ภาพประกอบที่ 4-6 ตัวอย่าง Scatter plot Matrix ค่าเฉลี่ยของแรงดัน	114
ภาพประกอบที่ 4-7 ตัวอย่าง Scatter plot Matrix ค่าเฉลี่ยของกระแส	115
ภาพประกอบที่ 4-8 ตัวอย่างสัญญาณค่าแรงดันจากระบบ AMR.....	115
ภาพประกอบที่ 4-9 ตัวอย่างแนวโน้ม (trend) ค่าแรงดัน.....	116
ภาพประกอบที่ 4-10 ตัวอย่างการเกิดซ้ำ (seasonal) ค่าแรงดัน	116
ภาพประกอบที่ 4-11 ตัวอย่างความแปรปรวน (noise) ค่าแรงดัน	116
ภาพประกอบที่ 4-12 ตัวอย่างสัญญาณค่ากระแสจากระบบ AMR	116
ภาพประกอบที่ 4-13 ตัวอย่างแนวโน้ม (trend) ค่ากระแส	117
ภาพประกอบที่ 4-14 แสดงตัวอย่างการเกิดซ้ำ (seasonal) ค่ากระแส	117
ภาพประกอบที่ 4-15 แสดงตัวอย่างความแปรปรวน (noise) ค่ากระแส	117
ภาพประกอบที่ 4-16 แสดงค่า Auto-correlation ของแรงดัน.....	118
ภาพประกอบที่ 4-17 ค่า Auto-correlation ของกระแส	118
ภาพประกอบที่ 4-18 ผลการทดสอบค่าแรงดัน(V) และกระแส(A) เปรียบเทียบแต่ละโมเดล	120
ภาพประกอบที่ 4-19 ตัวอย่างสัญญาณค่าแรงดัน 672 ค่าจากระบบ AMR.....	121
ภาพประกอบที่ 4-20 ตัวอย่างค่า DFT ของแรงดัน	122
ภาพประกอบที่ 4-21 ตัวอย่างค่า PSD ของแรงดัน	122
ภาพประกอบที่ 4-22 แสดงตัวอย่างสัญญาณค่ากระแสจากระบบ AMR.....	122
ภาพประกอบที่ 4-23 ตัวอย่างค่า DFT ของกระแส	123

รายการภาพประกอบ (ต่อ)

	หน้า
ภาพประกอบที่ 4-24 ตัวอย่างค่า PSD ของค่ากระแส.....	123
ภาพประกอบที่ 4-25 ค่า Pearson Correlation ของแรงดัน ในโดเมนความถี่.....	124
ภาพประกอบที่ 4-26 ค่า Pearson Correlation ของกระแสในโดเมนความถี่.....	124
ภาพประกอบที่ 4-27 ผลการทดสอบโมเดลโดยใช้เทคนิค DFT และ PSD.....	125
ภาพประกอบที่ 4-28 การตัวอย่างการแปลงภาพทั้ง 5 วิธี.....	126
ภาพประกอบที่ 4-29 การปรับช่วงอนุกรมเวลาก่อนและหลัง.....	127
ภาพประกอบที่ 4-30 การเพิ่ม-ลดขนาดภาพเพื่อเปรียบเทียบ.....	127
ภาพประกอบที่ 4-31 ภาพค่าแรงดัน time series และ CWT.....	128
ภาพประกอบที่ 4-32 ภาพค่ากระแส time series และ CWT.....	128
ภาพประกอบที่ 4-33 ภาพค่าแรงดัน time series และ RP.....	129
ภาพประกอบที่ 4-34 ภาพค่ากระแส time series และ RP.....	129
ภาพประกอบที่ 4-35 ภาพค่าแรงดัน time series และ MTF.....	129
ภาพประกอบที่ 4-36 ภาพค่ากระแส time series และ MTF.....	130
ภาพประกอบที่ 4-37 ภาพค่าแรงดัน time series และ GSAF.....	130
ภาพประกอบที่ 4-38 ภาพค่ากระแส time series และ GSAF.....	130
ภาพประกอบที่ 4-39 ภาพค่าแรงดัน time series และ SG.....	131
ภาพประกอบที่ 4-40 ภาพค่ากระแส time series และ SG.....	131
ภาพประกอบที่ 4-41 ผลการทดสอบทั้ง 5 เทคนิคกับค่าแรงดัน.....	133
ภาพประกอบที่ 4-42 ผลการทดสอบทั้ง 5 เทคนิคกับค่ากระแส.....	134
ภาพประกอบที่ 4-43 ตัวอย่างข้อมูลปกติค่าแรงดันและกระแส.....	136
ภาพประกอบที่ 4-44 ตัวอย่างข้อมูลชำรุดค่าแรงดันและกระแสที่ถูกสร้างขึ้น.....	137
ภาพประกอบที่ 4-45 ตัวอย่างข้อมูลละเมิดค่าแรงดันและกระแสที่ถูกสร้างขึ้น.....	138
ภาพประกอบที่ 4-46 เปรียบเทียบการกระจายตัวระหว่างข้อมูลไม่สมดุลกับใช้เทคนิค ASASYN.....	139
ภาพประกอบที่ 4-47 ตัวอย่างเปรียบเทียบการสร้างสัญญาณก่อนและหลังโดยใช้เทคนิค ASASYN....	140

รายการภาพประกอบ (ต่อ)

	หน้า
ภาพประกอบที่ 4-48 ตัวอย่างสัญญาณที่ถูกแปลงโดยใช้ RP	140
ภาพประกอบที่ 4-49 ตัวอย่างการปรับแต่งเชิงตำแหน่ง (Position augmentation)	141
ภาพประกอบที่ 4-50 ตัวอย่างการใช้เทคนิคทั้ง 8 วิธีในการสุ่มสร้างภาพ	141
ภาพประกอบที่ 4-51 ผลการทดสอบเปรียบเทียบแต่ละเทคนิค.....	144
ภาพประกอบที่ 4-52 ตัวอย่างผลการจำแนกทั้ง 3 class โดยใช้ภาพ CWT.....	145
ภาพประกอบที่ 4-53 ผลการทำนายโมเดลจากข้อมูลชุดอื่น	145
ภาพประกอบที่ 4-54 ตัวอย่างผลการจำแนกโมเดลที่ 2 โดยใช้ RP image	148
ภาพประกอบที่ 4-55 ผลการตรวจสอบจากเหตุการณ์จริง.....	148
ภาพประกอบที่ 4-56 ผลการทำนายโมเดลจากเหตุการณ์จริง	149
ภาพประกอบที่ 4-57 กราฟแสดงผลการ train-test accuracy และ train-test loss	156
ภาพประกอบที่ 5-1 วงจรต่อใช้งานและไดอะแกรมของระบบ 3 เฟส 4 สาย [41].....	160
ภาพประกอบที่ 5-2 ตัวอย่างการกระจายค่า median ของแรงดัน.....	161
ภาพประกอบที่ 5-3 ตัวอย่าง trend ของแรงดันและกระแส	162
ภาพประกอบที่ 5-4 ตัวอย่างการประมาณสัญญาณกลับและเสถียรภาพของโมเดล	163
ภาพประกอบที่ 5-5 เปรียบลักษณะ DFT และ PSD ระหว่างรูปแบบซำรุดกับละเมิด.....	164
ภาพประกอบที่ 5-6 ตัวอย่างการกระจายตัวเพื่อสังเคราะห์ข้อมูลของ ASASYN.....	169
ภาพประกอบที่ 5-7 ตัวอย่างการสุ่มสร้างภาพโดยใช้ Position augmentation.....	169
ภาพประกอบที่ 5-8 การเปรียบเทียบข้อมูลแต่ละประเภทของแรงดัน	172
ภาพประกอบที่ 5-9 การเปรียบเทียบข้อมูลแต่ละประเภทของกระแส	172
ภาพประกอบที่ 5-10 เส้นโค้งแสดงคะแนนภาพเงาของแต่ละคลัสเตอร์	174

คำย่อและชื่อเต็ม

ชื่อย่อ	ชื่อเต็ม
ADASYN	Adaptive Synthetic Sampling
AI	Artificial Intelligence
AM	Anomaly model
AMI	Advanced Metering Infrastructure
AMR	Automatic Meter Reading
AUC-ROC	Area under curve and Receiver operating characteristic
CER	Commission for Energy Regulation
CNN	Convolution neural network
CSL	Cost-Sensitive Learning
CT	Current Transformer
CWT	Continuous Wavelet Transform
DEF	Defective meter
DFT	Discrete Fourier transform
DT	Decision tree
EC	Energy consumption
FFT	Fast Fourier transform
GASF	Gramian Summation Angular Field
GB	Gradient boosting
GPRS	General Packet Radio Service
GSM	Global Systems for Mobile
IA	Image data augmentation
IEEE	Institute of Electrical and Electronics Engineers
IM	Image data augmentation
k-fold cv	K fold cross validation
KNN	k-Nearest Neighbors
KPCA	Kernel Principal Component

คำย่อและชื่อเต็ม (ต่อ)

ชื่อย่อ	ชื่อเต็ม
LF	Load Factor
LR	Logistic Regression
MTF	Markov Transition Field
NaN	Not a number
NB	Naive Bayes
NN	Neural network
NOM	Normal condition
NTL	Non-Technical Losses
PCA	Principal Component Analysis
PEA	Provincial Electricity Authority
PSD	Power Spectral Density
PSO	Particle Swarm Optimization
QB	Quality bit
RF	Random forest
ROS	Random Oversampling
RP	Recurrence plot
RUS	Random Undersampling
SG	Smart grid
SPG	Spectrogram
SGCC	Smart grid corporation of China
SM	Smart meter
SMOTE	Synthetic Minority Oversampling Technique
SVM	Support vector machines
THF	Energy theft
TOU	Time of Use
VT	Voltage Transformer

บทที่ 1

บทนำ

ในบทนี้จะกล่าวถึงความสำคัญและที่มาของงานวิจัย งานวิจัยที่เกี่ยวข้อง วัตถุประสงค์ของการวิจัย ขอบเขตการศึกษาวิจัย ประโยชน์ที่คาดว่าจะได้รับ ประเด็นการวิจัย ขั้นตอนและวิธีดำเนินการวิจัย รวมถึงกรอบแนวทางการทำวิจัย และแผนการดำเนินงาน

1.1 ความสำคัญและที่มาของงานวิจัย

การไฟฟ้าส่วนภูมิภาค ชื่อย่อ กฟภ. (Provincial Electricity Authority ตัวย่อ PEA) หรือ การไฟฟ้าฝ่ายจำหน่าย เป็นรัฐวิสาหกิจสังกัดกระทรวงมหาดไทย มีหน้าที่บริการจำหน่ายไฟฟ้าแก่ประชาชน ภาคครัวเรือน ภาคธุรกิจ และภาคอุตสาหกรรมต่างๆ ในส่วนภูมิภาคทุกจังหวัดทั่วประเทศ ยกเว้นพื้นที่ กรุงเทพมหานคร จังหวัดนนทบุรี และจังหวัดสมุทรปราการ ซึ่งเป็นเขตรับผิดชอบของการไฟฟ้านครหลวง โดยมีพื้นที่การให้บริการครอบคลุมพื้นที่ประมาณ 510,000 ตารางกิโลเมตร คิดเป็นร้อยละ 99.1 ของพื้นที่ทั้งประเทศ

ในการส่งจ่ายพลังงานไฟฟ้าของการไฟฟ้าส่วนภูมิภาคไปสู่ผู้ใช้นั้น เริ่มต้นจากการรับซื้อพลังงานไฟฟ้ามาจากการไฟฟ้าฝ่ายผลิต (กฟผ.) ผ่านสายส่งแรงสูงที่ระดับแรงดัน 115 kV และ 69 kV ส่งเข้าสู่สถานีย่อย (Substation) จากนั้นทำการลดระดับแรงดันจากแรงดันสูงให้เหลือระดับแรงดันปานกลาง 22 kV หรือ 33 kV ทำการส่งต่อพลังงานไฟฟ้าผ่านสายป้อน (Feeder) ไปยังพื้นที่ของผู้ใช้ไฟในบริเวณที่การไฟฟ้านั้น ๆ รับผิดชอบ โดยจะมีการจ่ายไฟที่ระดับแรงดัน 22 kV หรือ 33 kV ให้กับผู้ใช้ไฟรายใหญ่ และส่วนหนึ่งจะแปลงระดับแรงดันให้ลดลงโดยใช้หม้อแปลงจำหน่าย (Distribution Transformer) ให้มีระดับแรงดันที่ 400/230 V ส่งผ่านสายไฟแรงต่ำไปยังผู้ใช้ไฟรายย่อย จากรูปแบบการจ่ายไฟในลักษณะดังกล่าวส่งผลให้เกิดกำลังไฟฟ้าสูญเสียขึ้นในระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาค โดยสามารถจำแนกกำลังไฟฟ้าสูญเสียที่เกิดขึ้นในระบบจำหน่าย [1][2] ได้เป็น 2 ประเภทหลักๆ คือ กำลังไฟฟ้าสูญเสียด้านเทคนิค (Technical Losses: TL) และกำลังไฟฟ้าสูญเสียที่ไม่ใช่ด้านเทคนิค (Non-Technical Losses: NTL)

จากรายงานผลการดำเนินงานตามแผนงานลดหน่วยสูญเสียทางเทคนิคและไม่ใช้เทคนิค ปี2564 สถานะสะสม 4 ไตรมาส (ม.ค. - ธ.ค.) [3] ข้อมูลหน่วยสูญเสียทั้งหมด 6.16% คิดเป็นหน่วยสูญเสียทางด้านเทคนิครวม 3.02% และหน่วยสูญเสียที่ไม่ใช่เทคนิค 3.14 % ซึ่งคิดเป็นหน่วยสูญเสียรวมทั้งหมด 4,546.41 ล้านหน่วย จะพบว่ามีหน่วยสูญเสียที่เกิดขึ้นในแต่ละปีเป็นจำนวนมาก โจทย์หนึ่งที่ทำ ทายและระบุสาเหตุยากกว่าเกิดจากปัจจัยใดนั้นคือหน่วยสูญเสียที่ไม่ใช่ทางด้านเทคนิค ในปัจจุบันการ คำนวณกำลังไฟฟ้าสูญเสียทางเทคนิคของการไฟฟ้าส่วนภูมิภาค [3] ได้จากวิธีการวิเคราะห์การไหลของ กำลังไฟฟ้า (Load Flow Analysis) โดยใช้โปรแกรมคอมพิวเตอร์ (Load Flow Program) คำนวณโดย ใช้ค่าโหลดแฟกเตอร์ (Load Factor) , ค่าสูญเสียในสาย (Line Loss) , และช่วงการใช้ไฟสูงสุด (Peak Load) แต่กำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิคนั้นจะคำนวณโดยนำหน่วยซื้อทั้งหมดมาหักลบออกจาก กำลังไฟฟ้าสูญเสียทางเทคนิคซึ่งจะพบว่าไม่ได้คำนวณค่ากำลังไฟฟ้าสูญเสียจากสาเหตุที่แท้จริงอีกทั้งยังไม่ ทราบที่มาว่ากำลังสูญเสียเกิดขึ้นจากส่วนใดของระบบ

ทางการไฟฟ้าส่วนภูมิภาคได้นำโปรแกรมบริหารจัดการหน่วยสูญเสีย (U-CUBE) [4] มา ใช้งานเพื่อเป็นการลดหน่วยสูญเสียที่เกิดขึ้นจากมิเตอร์ชำรุดสำหรับผู้ใช้ไฟรายย่อยหรือติดตั้งมิเตอร์แรง ต่ำ และโปรแกรมสำหรับดูข้อมูลการใช้ไฟมิเตอร์ Automatic Meter Reading (AMR) สำหรับผู้ใช้ไฟราย ใหญ่ [5] นั้น แต่ถึงอย่างไรก็ตาม โปรแกรมทั้งสองยังมีข้อจำกัดที่ยังไม่สามารถระบุหรือจำแนกความ ผิดปกติที่เกิดขึ้นได้ว่าความผิดปกติดังกล่าวเข้าข่ายความผิดปกติลักษณะใด รวมถึงยังไม่สามารถนำค่า สัญญาณค่าทางไฟฟ้ามาใช้วิเคราะห์ความผิดปกติในเชิงลึกได้ จึงทำให้ในปัจจุบันการตรวจสอบมิเตอร์ ดังกล่าวจำเป็นต้องเดินทางไปยังหน้างานเพื่อตรวจสอบ จึงจะรู้ว่ามีมิเตอร์ลูกดังกล่าวเกิดความผิดปกติ รูปแบบใด เกิดจากการชำรุด เกิดจากการละเมิดหรือปัจจัยอื่นๆ ใด ส่งผลให้ต้องเสียเวลา สิ้นเปลืองค่า เดินทางและกำลังคน


จากปัญหาดังกล่าวจึงได้มีความพยายามในการนำวิธีการใหม่ๆ เพื่อมาประยุกต์ใช้ในการ วิเคราะห์หาค่ากำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค รวมถึงการจำแนกความผิดปกติที่เกิดขึ้นเพื่อค้นหาว่า เกิดจากสาเหตุอะไร โดยวิธีการที่จะนำมาประยุกต์ใช้นั้นจะต้องมีความถูกต้อง แม่นยำ สะดวก และ รวดเร็ว อีกทั้งอำนวยความสะดวกให้กับพนักงานผู้รับผิดชอบ เพื่อใช้ในการวิเคราะห์หาความผิดปกติที่ ส่งผลต่อหน่วยสูญเสียที่ไม่ใช่ทางเทคนิคที่เกิดขึ้นในระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาคได้

1.2 งานวิจัยที่เกี่ยวข้อง

จากความสำคัญของปัญหาด้านหน่วยสูญเสียที่เกิดขึ้น ผู้วิจัยได้ทำการศึกษาบทความและงานวิจัยที่เกี่ยวข้องด้านการวิเคราะห์กำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค ไม่ว่าจะ เป็นระบบการอ่านหน่วยธรรมดาหรือเป็นระบบสมาร์ทกริด ซึ่งจะมีลักษณะของข้อมูลที่ใช้วิเคราะห์แตกต่างกัน และได้สรุปรายละเอียดดังต่อไปนี้

1.2.1 วิธีการและประเภทของข้อมูลในการวิเคราะห์กำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค

ในการศึกษาด้านกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค เมื่อพิจารณาจากปัจจัยที่ทำให้เกิดขึ้นและวิธีการที่สามารถระบุสาเหตุที่มาได้นั้น สามารถแบ่งประเภทออกได้เป็น 3 ประเภท [6] ได้แก่ วิธีใช้ข้อมูลพื้นฐานด้านเศรษฐกิจและสังคม, วิธีการแบบใช้ฮาร์ดแวร์และวิธีการแบบไม่ใช้ฮาร์ดแวร์ ภาพประกอบ 1-1



ภาพประกอบที่ 1-1 การจัดหมวดหมู่วิธีการค้นหาความผิดปกติของสาเหตุการเกิดหน่วยสูญเสีย NTL [6]

1.2.1.1 วิธีใช้ข้อมูลพื้นฐานด้านเศรษฐกิจและสังคม

วิธีนี้อาศัยความสัมพันธ์ระหว่างข้อมูลด้านประชากร สภาพแวดล้อม พื้นที่ และสังคม-เศรษฐกิจ มาประยุกต์กับเทคนิคด้านสถิติของข้อมูลผู้ใช้ไฟแต่ละราย แนวโน้มการเพิ่ม-ลด เพื่อหาความสัมพันธ์ระหว่างรูปแบบการบริโภคกับปริมาณการใช้ไฟฟ้ารายครัวเรือน ที่จะให้ความสำคัญกับกลุ่มที่ผิดปกติ ใกล้เคียงกับการละเมิด โดยการออกตรวจสอบยังสภาพหน้างานจริง เพื่อยืนยันผลการตรวจสอบที่ดำเนินการผ่านระบบ

1.2.1.2 วิธีการแบบใช้ฮาร์ดแวร์

แนวทางแก้ปัญหาโดยการใช้ฮาร์ดแวร์ เป็นวิธีการที่นักวิจัยส่วนใหญ่ใช้เป็นหลัก เน้นลักษณะสร้างและออกแบบเครื่องมือที่ช่วยให้สามารถระบุและการประเมินความผิดปกติจากการละเมิดการขโมยไฟ ตัวอย่างเช่น H.Henriques et al. [7] ผู้เขียนเสนอการสร้างอัลกอริธึมที่ช่วยป้องกันการปลอมแปลง จัดแ่งตัวมิเตอร์ กักับการติดตั้งเซนเซอร์ ช่วยให้บริษัทจำหน่ายไฟฟ้าออกตรวจสอบหน้างาน และสามารถระบุการปลอมแปลงที่ตัวมิเตอร์วัดค่าพลังงานได้ อีกทั้งยังสามารถแก้ไขปัญหากลล่บสาย การจ่ายไฟย้อนกลับและการเปิดฝาครอบเฟรมหรือขั้วต่อได้ ผู้เขียนใน A.Khoo et al. [8] ใช้ตัวประมวลผลเพื่อปกป้องเครื่องวัดพลังงานจากการใช้สายไฟต่อบายพาสชุดเฟสรวมถึงการตัดการเชื่อมต่อของสายนิวทรัลและการดัดแปลงตัวมิเตอร์เพื่อลดการไหลของกระแสไฟฟ้า และเสนอการแก้ไขปัญหาค่าหน่วยสูญเสียที่ไม่ใช่ทางเทคนิคโดยใช้การระบุความถี่วิทยุ (RFID) ในขณะที่ F.Depuru et al. [9] เสนอการใช้เครื่องกำเนิดสัญญาณฮาร์โมนิกสำหรับการตรวจจับ โดยสัญญาณถูกนำมาใช้เป็นตัวป้อนเข้าสู่ระบบซึ่งหลังจากมีการตัดการเชื่อมต่อจะสะท้อนผลลัพธ์กลับมา

1.2.1.3 วิธีการแบบไม่ใช้ฮาร์ดแวร์

เนื่องจากวิธีการที่ใช้ฮาร์ดแวร์จำเป็นต้องติดตั้งอุปกรณ์ใหม่เพิ่มเข้าสู่ระบบ เช่น เซนเซอร์ อุปกรณ์วัดค่า นั้นหมายความว่า ถ้าต้องการตรวจจับในหลายจุดจำเป็นต้องใช้อุปกรณ์จำนวนมากในการติดตั้ง ดังนั้นจึงไม่สามารถทำได้สำหรับบริษัทจำหน่ายพลังงานไฟฟ้าในหลายแห่ง จึงทำให้ในปัจจุบันนักวิจัยให้ความสำคัญกับวิธีการที่ไม่ใช่ ฮาร์ดแวร์มากขึ้นในการแก้ปัญหา การใช้วิธีที่ไม่ใช่ฮาร์ดแวร์จะขึ้นอยู่กับแนวทางการศึกษา ที่ต้องการแก้ปัญหาเฉพาะด้าน หลายงานวิจัยจะเน้นไปที่การละเมิดหรือการขโมยไฟฟ้าโดยใช้ข้อมูลการใช้พลังงานของผู้บริโภค แนวทางแก้ปัญหาที่ไม่ใช่ฮาร์ดแวร์สามารถจำแนกได้อีกเป็น 3 ประเภทหลัก [10] ได้แก่ วิธีการอาศัยข้อมูลพื้นฐาน วิธีการอาศัยข้อมูลในระบบเครือข่าย และวิธีการแบบไฮบริด ทั้งนี้มีการนำเสนอรายละเอียดการเปรียบเทียบทั้ง 3 วิธี ของการใช้ข้อมูลในแง่ของทรัพยากร ความไม่สมดุลของคลาส ผลตอบสนองด้านเวลา ดังตารางที่ 1-1

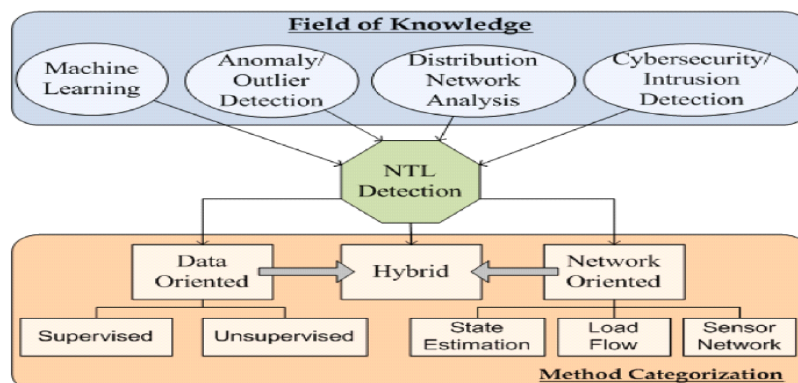
1.2.1.4 วิธีใช้ข้อมูลพื้นฐาน ข้อมูลในระบบเครือข่าย และวิธีการแบบไฮบริด

G. M. Messinis et al. [10] ได้นำเสนอแนวทางการตรวจสอบความผิดปกติของกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค สำหรับเป็นเครื่องมือวิเคราะห์การตรวจจับความ และการวิเคราะห์เครือข่ายของระบบจำหน่ายในระบบไฟฟ้า ปัจจัยหลักแบ่งได้เป็น 3 ประเภท คือ ตัวแปรที่มุ่งเน้นข้อมูล

ตัวแปรที่มุ่งเน้นเชิงเครือข่าย และตัวแปรแบบไฮบริด ความแตกต่างระหว่างตัวแปรคือ การใช้ข้อมูลจากระบบกริดพลังงาน (Power grid) เช่น โครงสร้างของระบบจำหน่ายภายในเครือข่าย หรือการวัดค่าพารามิเตอร์ในระบบโครงข่ายไฟฟ้า วิธีการเชิงข้อมูลใช้ประโยชน์จากข้อมูลที่ เกี่ยวข้องกับผู้บริโภคเท่านั้นเช่น การใช้พลังงานของผู้บริโภค เป็นต้น และไฮบริดคือใช้ทั้งสองประเภท ดังภาพประกอบที่ 1-2

ตารางที่ 1-1 เปรียบเทียบวิธีใช้ข้อมูลพื้นฐาน ข้อมูลในระบบเครือข่าย และวิธีการแบบไฮบริด [10]

ปัจจัย	ข้อมูลพื้นฐาน	ข้อมูลในระบบเครือข่าย	ไฮบริด
ทรัพยากร (Resources)	<ul style="list-style-type: none"> - ต้องการข้อมูลจำนวนมากเพื่อยืนยันแบบจำลอง - ต้องการข้อมูลที่มีผลลัพธ์ที่พึ่งพาข้อมูลที่หลากหลาย 	<ul style="list-style-type: none"> - ไม่ต้องการข้อมูลปริมาณมาก - ต้องการข้อมูลคุณภาพสูง - ต้องการข้อมูลจาก มิเตอร์, RTU และข้อมูลจากเครือข่าย 	<ul style="list-style-type: none"> - วิธีไฮบริดต้องการข้อมูลปริมาณมากหลากหลาย และชุดข้อมูลขนาดใหญ่
ผลดำเนินการ (Performance)	<ul style="list-style-type: none"> - แบบจำลองสามารถฝึก (train) ได้กับข้อมูลที่มีอยู่ - หากมีการเปลี่ยนแปลงการใช้ อาจผิดพลาดได้ 	<ul style="list-style-type: none"> - ทำงานได้ดีหลังการติดตั้งอุปกรณ์ต่างๆ เช่น มิเตอร์ เครื่องวัด และ RTU 	<ul style="list-style-type: none"> - กระบวนการที่ซับซ้อนอยู่กับการใช้งาน - เงื่อนไขของวิธีการจากข้อมูล
ความไม่สมดุลของคลาส (Class imbalance)	<ul style="list-style-type: none"> - อ่อนไหวต่อความไม่สมดุลของกลุ่มข้อมูล - โมเดลมีแนวโน้มที่จะ overfit หากกลุ่มข้อมูล (Class) มีน้อย 	<ul style="list-style-type: none"> - สำหรับวิธีที่ไม่ต้องการกลุ่มข้อมูล (Class) - ไม่มีผลกระทบสำหรับการฝึกอบรม (training) และการตรวจสอบ (Validation) 	<ul style="list-style-type: none"> - มีลักษณะคล้ายกัน เช่นเดียว กับวิธีการอาศัยข้อมูลพื้นฐาน
เวลาตอบสนอง (Response time)	<ul style="list-style-type: none"> - ความต้องการ บริโภค รายเดือน ตามฤดูกาล รายปี - ข้อมูลที่มากขึ้นจะส่งผลกระทบต่อเวลาตอบสนองต่างกัน 	<ul style="list-style-type: none"> - ต้องมีขนาดใหญ่เพื่อสรุปผลการตัดสินใจ - ข้อมูลเรียลไทม์ความละเอียดสูงเร็ว - ระยะเวลาที่มีผลต่อการเรียนรู้ 	<ul style="list-style-type: none"> - ลักษณะของปัญหาที่คล้าย คลึงกันเป็นวิธีการอาศัยข้อมูลพื้นฐาน
ค่าใช้จ่าย (Cost)	<ul style="list-style-type: none"> - ไม่ต้องการค่าใช้จ่ายเพิ่มเติมในการติดตั้งและบำรุงรักษา - สามารถพัฒนาวิธีการได้ทันทีที่ด้วยต้นทุนต่ำ 	<ul style="list-style-type: none"> - มีรายจ่ายจำนวนมาก ใช้ อุปกรณ์สื่อสารเพิ่มเติม, - ต้องใช้เครื่องวัดและผู้ตรวจสอบ 	<ul style="list-style-type: none"> - มีความผันผวนระหว่างทั้งสองตามความต้องการของอุปกรณ์เฉพาะ



ภาพประกอบที่ 1-2 การจัดหมวดหมู่วิธีการตรวจจับกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10]

จากหมวดหมู่และคำจำกัดความของประเภทข้อมูล เมื่อพิจารณาด้านคุณสมบัติหลักที่เหมาะสมในการนำมาวิเคราะห์ แสดงชนิดข้อมูลดังตารางที่ 1-2 เป็นการรวบรวมคุณลักษณะที่จำเป็นต่อการหาหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (NTL)

ตารางที่ 1-2 คุณสมบัติหลักที่ใช้สำหรับการตรวจจับหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10]

คุณสมบัติหลัก	คำอธิบาย
สถิติเฉลี่ย สูงสุด/นาที ส่วนเบี่ยงเบนมาตรฐาน (Average, Max/Min, Standard Deviation)	เป็นค่าทางสถิติสำหรับคำนวณค่าเฉพาะในช่วงเวลาหนึ่งๆ
ตัวประกอบกำลัง/ตัวประกอบค่าพลังงาน (Power/Energy factor)	ตัวประกอบกำลังไฟฟ้าถูกกำหนดเป็นค่าอัตราส่วนระหว่างกำลังไฟฟ้าจริง (kW) ต่อค่าพลังงานปรากฏ (kVA) ค่าพลังงานที่ได้จากการวัดเป็นสิ่งจำเป็นสำหรับการคำนวณ ซึ่งต้องใช้ข้อมูลที่มีความละเอียดสูง (น้อยกว่าหรือเท่ากับ 15 นาที) เพื่อผลลัพธ์ที่ดี
ตัวประกอบโหลด (Load factor)	อัตราส่วนระหว่างพลังงานที่ใช้เฉลี่ย (kWh) ต่อการใช้พลังงานสูงสุด (kWh)
เส้นแนวรีว (Streaks)	เส้นกราฟของจำนวนช่วงเวลาอยู่เหนือหรือต่ำกว่าค่าเฉลี่ย (กำหนดจากค่าเฉลี่ยเคลื่อนที่ของกราฟการบริโภค)

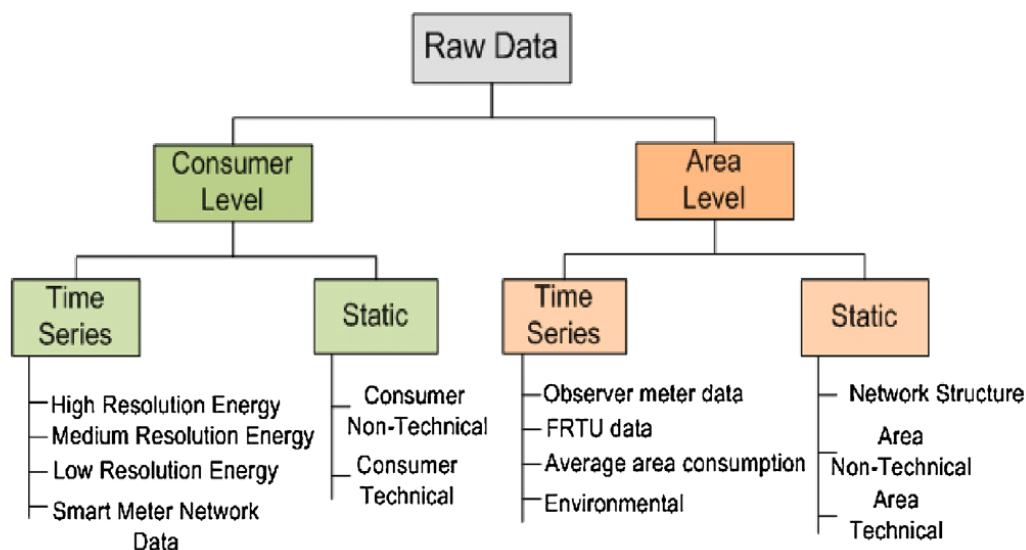
ตารางที่ 1-2 (ต่อ) คุณสมบัติหลักที่ใช้สำหรับการตรวจจับหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10]

คุณสมบัติหลัก	คำอธิบาย
ปริมาณการใช้ไฟรายวันต่อ กำลังไฟฟ้าตามสัญญา (Daily consumption)	ผลรวมของพลังงานที่ใช้งานอยู่ในระยะเวลาหนึ่ง (kWh) ต่อกำลังไฟฟ้าตามสัญญา (kW)
ค่าสัมประสิทธิ์เพียร์สัน (Pearson coefficient)	สัมประสิทธิ์เพียร์สันของเส้นกราฟการใช้พลังงานที่ใช้งานอยู่ในช่วง เวลาหนึ่ง (โดยทั่วไปจะใช้กับข้อมูลขนาดใหญ่)
ค่าสัมประสิทธิ์การใช้พลังงานที่เรียกเก็บเงิน (Billed-consumed energy coefficient)	ผลต่างของพลังงานที่เรียกเก็บ (kWh) ต่อพลังงานที่ใช้งาน (kWh) ทหาร ด้วยพลังงานตามสัญญา (kW) ที่คาดการณ์ไว้ kWh (Predicted kWh) การคาดการณ์การใช้พลังงานที่ใช้ งานอยู่(kWh)ที่กำหนดโดยแบบจำลองการคาดการณ์ใดๆ หรือความแตกต่างของค่าที่วัดได้
ค่าสัมประสิทธิ์เวฟเล็ต (Wavelet coefficients)	ผลต่างของค่าสัมประสิทธิ์เวฟเล็ตที่คำนวณจากเส้นกราฟ ลักษณะการบริโภคที่จะถูกจำแนกโดยใช้เวฟเล็ตคำนวณค่า สัมประสิทธิ์ของกราฟการบริโภคปีก่อนหน้า
ค่าสัมประสิทธิ์ฟูรีเยร์ (Fourier coefficients)	ผลต่างของสัมประสิทธิ์ฟูรีเยร์ที่คำนวณจากเส้นกราฟการ บริโภคที่ ถูกจัดประเภทและใช้ฟูรีเยร์แยกค่าสัมประสิทธิ์ ของกราฟ นอกจากนี้ เฟสของสัมประสิทธิ์ฟูรีเยร์ห้าตัวแรก สามารถใช้หาเส้นโค้งการใช้พลังงานที่ใช้งานอยู่ได้
สัมประสิทธิ์พหุนาม (Polynomial coefficients)	ผลต่างของสัมประสิทธิ์พหุนามที่เหมาะสมกับเส้นกราฟ การบริโภคจะถูกจำแนกและค่าสัมประสิทธิ์ของพหุนามที่ เหมาะสมที่สุดกับเส้นโค้งการบริโภคเทียบปีก่อนหน้า
ระยะทางแบบยูคลิดกับค่าเฉลี่ยของลูกค้า (Euclidean distance to mean customer Euclidean)	ระยะทางแบบยูคลิดของเส้นกราฟการใช้พลังงานจาก กำลังไฟฟ้าจริง (kW) ไปยังเส้นกราฟการบริโภคที่คำนวณ เป็นค่าเฉลี่ยการบริโภคของผู้บริโภคทั้งหมดในชุดข้อมูล
ความชันของเส้นโค้งการบริโภค (Consumption curve slope)	ความชันของสมการเชิงเส้นที่เหมาะสมที่สุดกับอนุกรมเวลา (Time Series) ของกราฟเส้นโค้งพลังงานที่ใช้งานอยู่

ตารางที่ 1-2 (ต่อ) คุณสมบัติหลักที่ใช้สำหรับการตรวจจับหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10]

คุณสมบัติหลัก	คำอธิบาย
ส่วนประกอบ PCA Principal Component Analysis (PCA)	ส่วนประกอบจำนวนหนึ่งจาก PCA หรือการวิเคราะห์ KPCA เกี่ยวกับกราฟการใช้พลังงานที่ใช้งานอยู่ สามารถใช้ค่าเฉลี่ยของเพื่อระบุส่วนประกอบเฉพาะ
อัตราการบริโภคตามฤดูกาล (Seasonal consumption rates)	ปริมาณการบริโภคของผู้บริโภคทั้งหมด (kWh) ในฤดูกาลต่อการบริโภค (kWh) เช่น ฤดูร้อน ฤดูหนาว ถึงการบริโภคเฉลี่ยของผู้บริโภคในสถานีย่อยเดียวกันในฤดูกาลเดียว
การอ่านค่าโดยประมาณ (Estimated readings)	จำนวนการอ่านมิเตอร์ที่ค่าประมาณโดยยูทิลิตี้ (Utility) เนื่องจากไม่สามารถเข้าถึงมิเตอร์ได้

ในการจำแนกข้อมูลเมื่อพิจารณาจากข้อมูลดิบ (Raw data) ในหลายงานวิจัยจะนำข้อมูลดิบมาใช้ในการวิเคราะห์แตกต่างกัน G. M. Messinis et al. [10] ได้รวบรวมและจัดแบ่งประเภทข้อมูลหลักได้ 2 ประเภท ได้แก่ ข้อมูลเชิงลูกค้ำและข้อมูลเชิงพื้นที่ ทั้ง 2 ข้อมูลถูกจำแนกโดยใช้ความสัมพันธ์ของข้อมูลที่มีลักษณะ เป็นอนุกรมเวลาที่มีความต่อเนื่อง (Time Series) กับข้อมูลด้านสถิติที่ไม่ต่อเนื่องรายละเอียดดังภาพประกอบที่ 1-3



ภาพประกอบที่ 1-3 การจัดหมวดหมู่ข้อมูลดิบกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) [10]

1.2.2 ประเภทของเทคนิคที่ใช้ในการสกัดข้อมูลเพื่อหาค่าพลังงานไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค

ในบางครั้งข้อมูลดิบ (Raw Data) ที่ได้จากการรวบรวมข้อมูลเพื่อใช้ประกอบเป็นคุณลักษณะ (feature) ก่อนป้อนเข้าสู่โมเดลนั้นไม่สามารถป้อนเข้าสู่โมเดลได้เนื่องจากมีความหลากหลาย มีจำนวนมากเกิดความจำเป็น หากป้อนข้อมูลเข้าโดยตรงอาจส่งผลให้โมเดลประมวลผลช้า หรือผลที่ได้จากโมเดลไม่ถูกต้อง จึงต้องทำการสกัดคุณลักษณะ (Feature Extraction) ก่อนป้อนเข้าโมเดล M. M. Buzau et al. [11] ได้เสนอวิธีการสกัดข้อมูลจากสมาร์ทมิเตอร์ (Smart Meter) ประกอบด้วย ข้อมูลการใช้พลังงาน ข้อมูลสัญญาณเตือน การแจ้งเตือนขนาดสัญญาณทางไฟฟ้า ข้อมูลลูกค้าด้านพฤติกรรมกรรมการบริโภค สถานที่ติดตั้งด้านกายภาพ ภูมิศาสตร์และคุณสมบัติ โครงสร้างของสมาร์ทมิเตอร์ สามารถแยกเป็นเทคนิคต่างๆ ดังต่อไปนี้

1.2.2.1 คุณลักษณะที่สกัดจากการแจ้งเตือนตัวมิเตอร์ (QB Measurements)

การวัดค่าโดยใช้ Quality Bit (QB) ใช้รหัส 8 บิต เพื่อประเมินคุณภาพของการวัด นำผลการแจ้งเตือน แต่ละรายการที่วัดซึ่งเดิมแสดงด้วยทศนิยม ถูกแปลงใหม่เป็นการแทนค่าด้วยเลขฐานสอง ค่าไบนารี ถูกแบ่งออกเป็นแปดค่าที่แยกจากกัน แต่ละค่าแสดงถึงการเตือน หากมีสัญญาณเตือนถูกกระตุ้นในช่วงเวลา ของการวัด (หนึ่งวันในกรณีที่เกิดขึ้น) ค่าจะถูกกำหนดเป็น 1 มิฉะนั้นค่าจะเป็นศูนย์ ตัวอย่างการคำนวณ แสดงดังภาพประกอบที่ 1-4

Bit	Alarm	Description
7	IV	The measurement is valid (IV = 0)
6	SINC	Synchronized meter during the period of measurement (SINC = 1)
5	OW	Overflow (OW = 1)
4	VH	Hourly verification VH during the period of measurement (VH = 1)
3	MP	Parameter modification during the period of measurement (MP = 1)
2	INT	An intrusion has occurred during the period of measurement (INT = 1)
1	AL	Incomplete period due to power fault (AL = 1)
0	U	Unit of measurement. 0 for kWh/kvarh and 1 for MWh/Mvarh

IV and AL alarms activated

IV	SINC	OW	VH	MP	INT	AL	U
1	0	0	0	0	0	1	0

130 decimal to binary

ภาพประกอบที่ 1-4 ตัวอย่างการสกัดการแจ้งเตือนจากตัวมิเตอร์โดยใช้ Quality bit (QB) [11]

1.2.2.2 คุณลักษณะที่สกัดจากปริมาณการใช้ไฟ (Energy Consumption)

การลดลงอย่างกะทันหันของปริมาณการใช้ไฟ (EC) สามารถสังเกตได้สำหรับความผิดปกติที่เกี่ยวข้องกับการละเมิดและการไม่ละเมิด ในบทความดังกล่าวจะแบ่งลักษณะความผิดปกติออกเป็น 3 ช่วงเวลาได้แก่ ความผิดปกติเริ่มต้นก่อนช่วงเวลาของการวิเคราะห์ ความผิดปกติที่เกิดขึ้นในช่วงเวลาของการวิเคราะห์ และความผิดปกติหลังช่วงเวลาวิเคราะห์ รายละเอียดประกอบด้วย

ก. คุณลักษณะที่สกัดจากการตรวจสอบพบความผิดปกติในช่วงเวลาที่วิเคราะห์

ในการจำแนกความสัมพันธ์ของข้อมูลจะใช้ค่าเพื่อกำหนดค่าโดยใช้ส่วนเบี่ยงเบนมาตรฐานและค่าเฉลี่ยของข้อมูลตามสมการที่ (1-1)

$$Z_{score} = \frac{X_i - \bar{X}_i}{\sigma_{x_i}} \quad (1-1)$$

โดยที่ X_i คือการวัดค่าพลังงานของลูกค้า i , \bar{X}_i คือ ค่าเฉลี่ยการใช้พลังงานของลูกค้า i และ σ_{x_i} คือ ค่าเบี่ยงเบนมาตรฐานของลูกค้า i

ข. คุณสมบัติที่สกัดจากความผิดปกติแบบเก่าหรือก่อนหน้า

เพื่อตรวจจับความผิดปกติที่เริ่มก่อนช่วงการวิเคราะห์ จัดกลุ่มโดยใช้ k-means clustering ซึ่งพิจารณาจากปริมาณการใช้ไฟเทียบกับเงื่อนไขสัญญาซื้อขายไฟ คัดเลือกกลุ่มที่เข้าเงื่อนไขและจัดกลุ่มที่กระจาย

1.2.2.3 คุณลักษณะสกัดจากรยะทางและความหนาแน่น (Distance and Density)

ก. ใช้หลักการวัดค่าระยะทาง (Based on Distance Measurements) [11]

หลังจากแยกกลุ่มผู้ใช้ไฟจากเงื่อนไขสัญญาซื้อขายไฟแล้ว รูปแบบการบริโภคการใช้ไฟแต่ละเดือนจะถูกจำแนกออกเป็นรายสัปดาห์ เพื่อวิเคราะห์รูปแบบความสัมพันธ์ของผู้ใช้ไฟในแต่ละราย สมการความสัมพันธ์ดังแสดงในสมการที่ (1-2)

$$B_{i,j,t}^k = \left\{ \frac{1}{N} \sum_{z \in M} P_{It}^z, \frac{1}{N} \sum_{z \in M} P_{IIt}^z, \frac{1}{N} \sum_{z \in M} P_{III}^z, \frac{1}{N} \sum_{z \in M} P_{IVt}^z, \frac{1}{N} \sum_{z \in M} P_{Vt}^z \right\} \quad (1-2)$$

โดยที่ $B_{i,j,t}^k$ คือ รูปแบบการใช้ไฟรายเดือนของเดือน i , ปี j ของกลุ่มลูกค้า k สำหรับประเภทของวัน t (วันธรรมดา เสาร์ และอาทิตย์) M เป็นตัวแทนของกลุ่มลูกค้า ลูกค้า k ที่มีผลการตรวจสอบโดยไม่พบความผิดปกติในขณะที่ N คือจำนวนลูกค้าเหล่านี้ $P_{It}^z, P_{III_t}^z, P_{IV_t}^z, P_{V_t}^z$ แสดงถึงค่าเฉลี่ยการใช้พลังงานสำหรับประเภทของวัน t ในช่วงเวลาที่ตรวจสอบ

แต่ละคุณสมบัติได้มาจากการคำนวณโดยใช้ความสัมพันธ์ยูคลิดีเนียน (Euclidean Distances) และแมนฮัตตัน (Manhattan Distances) ซึ่งระยะทางระหว่างแต่ละรูปแบบการบริโภค จากตัวอย่างของลูกค้า โมเดลแมนฮัตตัน (Manhattan Distances) ใช้คำนวณระยะทางสำหรับแต่ละกรอบเวลาและตลอดทั้งวัน ดังสมการที่ (1-3) ในขณะที่การคำนวณระยะทางแบบยูคลิดีเนียน (Euclidean Distances) ใช้เพียงหน้าต่าง (Window) ของเวลาทั้งหมด ดังสมการที่ (1-4)

$$M_{wt} = \left| P_{wt} - \frac{1}{N} \sum_{z \in M} P_{wt}^z \right| \quad (1-3)$$

$$M_{Tt} = \sum_{w=1}^v \left| P_{wt} - \frac{1}{N} \sum_{z \in M} P_{wt}^z \right| \quad (1-4)$$

โดยที่ M_{wt} คือระยะทางแมนฮัตตัน (Manhattan distances) ของตัวอย่างลูกค้าสำหรับกรอบเวลา w และสำหรับประเภทของวันที่ t และ M_{Tt} คือ ผลรวมระยะทางแมนฮัตตันของหน้าต่างเวลาทั้งหมด ระยะทางแบบยูคลิดีเนียน (Euclidean distances) คำนวณโดยใช้กรอบเวลาทั้งหมด ดังสมการที่ (1-5)

$$E_{Tt} = \sqrt{\sum_{w=1}^v \left(P_{wt} - \frac{1}{N} \sum_{z \in M} P_{wt}^z \right)^2} \quad (1-5)$$

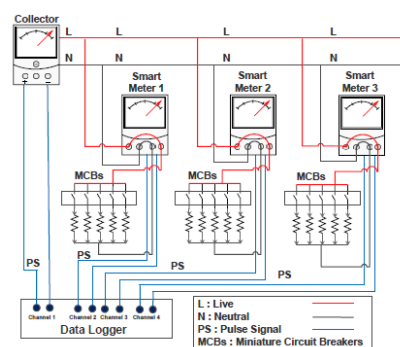

โดยที่ E_{Tt} คือระยะทางแบบยูคลิดีเนียน (Euclidean distances) รวมของกรอบเวลาทั้งหมด

ข. ใช้หลักการวัดค่าความหนาแน่น (Density Measurements) [14]

ปัจจัยภายนอกท้องถิ่น Local Outlier Factor (LOF) ถูกนำมาปรับใช้ในรูปเมตริกกับโปรไฟล์ลูกค้า แต่ละราย วัดค่าโดยการจำแนกความแตกต่างระหว่างโปรไฟล์การบริโภคของผู้ใช้ไฟเมื่อเปรียบเทียบกับโปรไฟล์ในกลุ่มใกล้เคียง ในการคำนวณ LOF ข้อมูลจากค่า EC ในแต่ละเดือนของลูกค้าแต่ละราย ถูกจัดกลุ่มรวมกันตามกลุ่มลูกค้าแต่ละประเภทของวัน t (วันธรรมดา วันเสาร์ วันอาทิตย์)

1.2.2.4 คุณลักษณะที่สกัดจากการจำลองพฤติกรรมผู้ใช้ไฟ (Simulation Load Profiles)

S. C. Yip et al. [12] ออกแบบการจำลองระบบโครงข่ายสมาร์ทมิเตอร์ในห้องทดลอง ประกอบด้วยสมาร์ทมิเตอร์จำนวน 4 เครื่อง 3 เครื่องแรกทำหน้าที่เป็นตัวแทนผู้ใช้ไฟ และอีกหนึ่งเครื่อง ทำหน้าที่เป็นตัววัดพลังงานไฟฟ้ารวม มีการจำลองโหลดโดยใช้ Miniature Circuit Breakers (MCBs) ควบคุมความแตกต่างของโหลดในแต่ละช่วงเวลาและมี Data logger รวบรวมข้อมูลเป็นอินพุตสำหรับ ประมวลผล แสดงดังภาพประกอบที่ 1-5



ภาพประกอบที่ 1-5 อุปกรณ์ในการทดลองและ schematic diagram small-scaled AMI test [12]


ในการทดลองข้อมูลจะถูกแบ่งออกเป็น 2 ช่วงเวลาหลักคือ Off-peak hours (08:00 P.M. to 07:59 A.M.) และ On-peak hours (08:00 A.M. to 07:59 P.M.) จากนั้นจำลองพฤติกรรมการใช้ไฟของผู้ใช้ไฟออกเป็นเหตุการณ์ทั้งหมด 7 เหตุการณ์ประกอบด้วย Honest, Cheating constantly, Faulty constantly, Cheating during on-Peak, Faulty during on-Peak, Cheating during off-Peak, Faulty during off-Peak ผ่านการควบคุมค่าสัมประสิทธิ์ความผิดปกติของผู้บริโภคและค่าสัมประสิทธิ์การตรวจจับของผู้บริโภคแต่ละตัวแทนผู้ใช้ไฟ

1.2.2.5 คุณลักษณะสกัดจากอนุกรมเวลาเป็นรูปภาพ (Time Series to Images)

A. A. Esmael et al. [13] นำเสนอการสกัดข้อมูลโดยการนำข้อมูลการใช้ไฟรายเดือนจำนวน 1 ปี ในลักษณะ Time series มาทำการแปลงให้อยู่ในลักษณะรูปภาพโดยใช้ 4 เทคนิคในการแปลง รายละเอียดดังนี้

ก. พล็อตการเกิดซ้ำ Recurrence Plot (RP)


พล็อตการเกิดซ้ำ Recurrence plot (RP) เป็นเทคนิคขั้นสูงของการวิเคราะห์ข้อมูลแบบไม่เชิงเส้น เป็นการแสดงภาพ (หรือกราฟ) ของเมทริกซ์สี่เหลี่ยมจัตุรัส ซึ่งองค์ประกอบเมทริกซ์สอดคล้องกับเวลาที่สถานะของระบบไดนามิกเกิดขึ้นซ้ำ (คอลัมน์และแถวจะสัมพันธ์กับคู่ของเวลาที่แน่นอน) ในทางเทคนิคแล้ว พล็อตการเกิดซ้ำจะแสดงตลอดเวลาเมื่อเส้นโคจรของพื้นที่เฟสของระบบไดนามิกเข้าสู่พื้นที่เดียวกันโดยประมาณในพื้นที่เฟส เช่นเดียวกับ Eckman et al. [14] นำเสนอรูปแบบการเกิดขึ้นซ้ำเพื่อแสดงความสัมพันธ์กับข้อมูลในระบบอนุกรมเวลาสำหรับใช้จำแนกลักษณะของสัญญาณไฟฟ้า ซึ่งให้ผลลัพธ์ที่ดีเมื่อนำไปใช้ในการตรวจจับข้อมูล แสดงตัวอย่างการแปลง RP ค่าดังภาพประกอบที่ 1-6



ภาพประกอบที่ 1-6 การแปลง Time series โดยใช้พล็อตการเกิดซ้ำ Recurrence plot (RP) [13]

ข. สเปกโตรแกรม (Spectrogram)



Spectrogram (SPG) สเปกโตรแกรม เป็นการแสดงค่าของสเปกตรัมของความถี่ของสัญญาณในขณะที่เกิดการเปลี่ยนแปลงและแตกต่างกันไปตามกาลเวลา จะแบ่งสัญญาณออกเป็นช่วงย่อยๆ โดยทั่วไปแกนแนวตั้งของสเปกโตรแกรมหมายถึงเวลา ในขณะที่แกนนอนแสดงถึงค่าความถี่ที่ไม่ต่อเนื่อง แอมพลิจูดของความถี่เฉพาะ ณ เวลาใดเวลาหนึ่งจะปรากฏเป็นความเข้มหรือจุดในภาพแต่ละสี [15] สเปกโตรแกรมถูกนำมาใช้อย่างกว้างขวางในงานประเภทดนตรี การประมวลผลคำพูด การตรวจคลื่นไฟฟ้าสมอง เป็นต้น สัญญาณที่ปรากฏแต่ละสเปกตรัมของย่านความถี่แตกต่างกันตามช่วงเวลา ตัวอย่างการแปลง SPG ค่าดังภาพประกอบที่ 1-7

Raw time series**Spectrogram**

ภาพประกอบที่ 1-7 การแปลง Time series โดยใช้สเปกโตรแกรม (Spectrogram) [13]

ค. Gramian Summation Angular Field (GASF)


Gramian Summation Angular Field (GASF) คือ วิธีการเข้ารหัสของอนุกรมเวลาที่เป็นภาพตามพิกัดเชิงขั้ว ในเมทริกซ์ Gramian แต่ละองค์ประกอบเป็นผลรวมของมุมโคไซน์ [16] ตามเงื่อนไขที่กำหนดจากนั้นวาดลงบนพิกัดเชิงมุมของ Gramian เชิงพื้นที่เมตริก ตัวอย่างการแปลงค่า GASF แสดงดังภาพประกอบที่ 1-8

Raw time series**Gramian Angular Field**

ภาพประกอบที่ 1-8 การแปลง Time series กับ Gramian summation angular Field [13]

ง. Markov Transition Field (MTF)

Markov Transition Field (MTF) เป็นภาพที่ได้จากกระบวนการคำนวณทางสถิติของการเปลี่ยนแปลงแบบไดนามิก [16] เกิดจากการสร้าง Markov เมทริกซ์ ของการสร้างควอนไทล์หลังจากแยกองค์ประกอบและเข้ารหัสความน่าจะเป็นของการเปลี่ยนแปลงแบบไดนามิกใน quasi-Gramian ตัวอย่างการแปลงค่า MTF แสดงดังภาพประกอบที่ 1-9



ภาพประกอบที่ 1-9 การแปลง Time series โดย Markov Transition Field (MTF) [13]

1.2.3 เทคนิคในการจำแนกคุณลักษณะของกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค

1.2.3.1 การจำแนกโดยใช้เทคนิคการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

G. M. Messinis [17] ได้เสนอการเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) มาใช้ในการแบ่งกลุ่มลักษณะความผิดปกติที่ส่งผลต่อกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค โมเดลที่ใช้ประกอบด้วย

ก. ระบบผู้เชี่ยวชาญ (Expert Systems)

ระบบผู้เชี่ยวชาญประกอบด้วยหลากหลายชุดกฎเกณฑ์ กฎเหล่านี้อาจอนุมานจากชุดข้อมูลหรือกำหนดโดยผู้เชี่ยวชาญตามประสบการณ์ในการตรวจสอบ ปัญหาหลักของกฎคือ ความยากในการออกแบบสำหรับคุณสมบัติที่ใช้ ในกรณีนี้ไม่สามารถกำหนดกฎผู้เชี่ยวชาญ สำหรับผลกระทบการตรวจสอบได้กรณีเกิดการละเมิดได้ จึงต้องอาศัยเทคนิคอื่นๆ ร่วมในการตรวจสอบด้วย [17]

ข. ระบุเป็นความผิดปกติตามความหนาแน่น (Local Outlier Factor)

Local Outlier Factor (LOF) เป็นการหาความผิดปกติตามความหนาแน่น [17] โดยวิธีการตรวจจับที่คำนวณความหนาแน่นภายในของชุดข้อมูลโดยคำนึงถึงความหนาแน่นของข้อมูลเทียบกับเพื่อนบ้าน LOF จะคำนวณสำหรับผู้บริโภคทุกคนที่ได้รับการจัดอันดับและระบุเปอร์เซ็นต์ของข้อมูลที่มีลักษณะการฉ้อโกง จุดอ่อนของ LOF คือ การที่ตรวจพบค่าผิดปกติ ซึ่งไม่ได้หมายความว่าเกิดจากการละเมิด แต่อาจเป็นค่าที่สูง (การบริโภคที่เพิ่มขึ้นอย่างกะทันหัน) อาจถูกระบุว่าเป็นการละเมิดได้

ค. Multivariate Gaussian Distribution

Multivariate Gaussian Distribution (MGD) ในงานวิจัยนี้ข้อมูลจะถูกจำลองโดยใช้ตัวแปรหลายตัวแปรแบบกระจาย ความหนาแน่นของความน่าจะเป็น [17] คำนวณตามสมการที่ 1-6


$$p(x, \mu, \Sigma) = \frac{1}{2^{n/2} |\Sigma|^{1/2}} \exp\left(-\frac{1}{2} (x - \mu)^T \Sigma^{-1} (x - \mu)\right) \quad (1-6)$$

x คือคุณสมบัติเวกเตอร์, μ เวกเตอร์เฉลี่ย, Σ เมทริกซ์ความแปรปรวนร่วม, n ขนาดของเวกเตอร์

ง. การจัดกลุ่ม Clustering

หลากหลายอัลกอริธึมสำหรับใช้จัดกลุ่มต่างๆ ในงานจำแนกประเภทที่ไม่ได้รับการดูแล (Unsupervised) [17] ปัญหาที่พบบ่อยคือ จำนวนคลัสเตอร์ที่ใช้น้อยและวิธีการกระจายเข้าหากลุ่มแบบตรงไปตรงมาทำให้ผลของกลุ่มที่เล็กกว่าเป็นตัวแทนของการละเมิด ซึ่งยังไม่ถูกต้อง ตามความเป็นจริง นั่นคือวิธีบางประเภท ไม่สามารถจัดกลุ่มภายใต้คลัสเตอร์เดียว ได้การเลือกจำนวนคลัสเตอร์ที่มากกว่า 2 สามารถแก้ปัญหานี้ได้ ในกรณีนี้ อนุกรมเวลาคลัสเตอร์ Cluster เฉลี่ย ประเมินค่าที่มีความชันเป็นลบสูงสุดคือ จะจัดเป็นกลุ่มละเมิด สิ่งสำคัญการเลือกจำนวนคลัสเตอร์ต้องเลือกเลือกอย่างเหมาะสมและค่าที่ศูนย์กลางของกลุ่มควรถูกประเมินโดยผู้เชี่ยวชาญในการตัดสินใจที่เป็นตัวแทนกลุ่ม ตัวอย่างแสดงดังภาพประกอบ 1-15 การแบ่งกลุ่มข้อมูลแบบเคมีนดังสมการที่ (1-7)

$$\arg, \min \sum_{i=1}^k \sum_{x \in S_i} \|X - \mu_i\|^2 \quad (1-7)$$



ภาพประกอบที่ 1-10 การประยุกต์ใช้ PCA-DBSCAN-Rule 2 และ SOM/k-means clustering [17]

จ. แผนที่จัดระเบียบตนเอง Self-Organizing Map

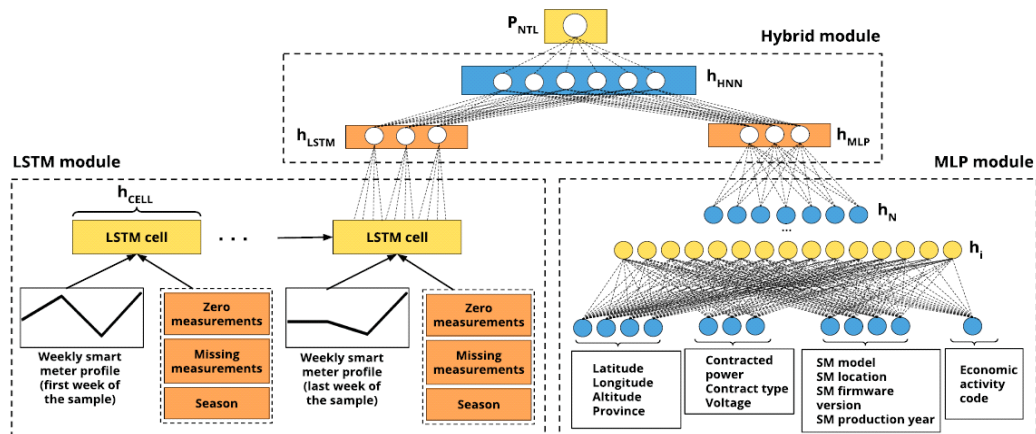
Self-organizing map (SOM) เป็นโครงข่ายประสาทเทียมชนิดหนึ่งที่ใช้บ่อยเพื่อลดมิติข้อมูล [17] ไม่ได้เป็นวิธีการจำแนกประเภท แต่สามารถใช้เป็นตัวแยกประเภทได้ SOM มีความสามารถในการสร้างภาพ 2 มิติที่ดี ผ่านการตรวจสอบการสร้างภาพร่วมกับ SOM เพื่อตรวจจับการละเมิด แสดงดังภาพประกอบที่ 1-10 รูปขนาดของชุดข้อมูล ตัวอย่างทั้งหมดที่อยู่ในคลัสเตอร์จะเล็กกว่าที่สร้างโดย k-mean มีการทำเครื่องหมายว่าเป็นการละเมิด นอกจากนี้ k-means ถูกดำเนินการ 100 ครั้งและการจัดกลุ่มที่ดีที่สุดคือเลือก คะแนน F1 สำหรับชุดข้อมูลเฉพาะนี้เท่ากับ 89.66%

1.2.3.2 การจำแนกโดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning)

Deep learning เป็นวิธีการเหมือนการเรียนรู้การทำงานของโครงข่ายประสาทของมนุษย์ (Artificial neural networks) โดยนำระบบโครงข่ายประสาทมาเชื่อมต่อกันหลายแบบชั้น (Layer) เพื่อทำการเรียนรู้ข้อมูล สามารถแบ่งได้ออกเป็นสองประเภท คือ Recurrent neural network เป็นการคาดการณ์ข้อมูลหรือทำนายผลโดยการนำข้อมูลปัจจุบันหรือที่ผ่านมาพิจารณา และ Feedforward neural network ข้อมูลปัจจุบันจะถูกป้อนผ่านตัวประมวลผลแบบทางเดียวเพื่อทำนายผลลัพธ์

ก. Hybrid Neural Network


M. M. Buzau et al. [18] นำเสนอการใช้โครงข่ายประสาทเทียมส่วนลึกแบบไฮบริด hybrid deep neural network ประกอบด้วย โครงข่ายประสาทเทียมแบบหน่วยความจำระยะสั้น Long Short-Term Memory Network (LSTM) และโครงข่ายประสาทเทียม แบบหลายชั้น Multi-Layer Perceptron Network (MLP) ทำงานประสานกัน แบบจำลองที่เสนอ สามารถบูรณาการทั้งแบบข้อมูลต่อเนื่องและแบบไม่ต่อเนื่องได้ ข้อมูลโครงสร้างการทำงาน ดังภาพประกอบ 1-11 ประกอบด้วย 3 องค์ประกอบ ได้แก่ โมดูล LSTM, โมดูล MLP และโมดูลไฮบริด HNN โมดูล LSTM ใช้ข้อมูลแบบมีลำดับข้อมูลจาก Smart meter เช่น EC ขณะที่โมดูล MLP ใช้ข้อมูลแบบไม่มีลำดับ non-sequential ข้อมูลเป็นอินพุต เช่น พิกัด สถานที่, โมเดล รายละเอียดมิติเตอร์) ผลลัพธ์ที่ได้จากโมดูล LSTM และโมดูล MLP จะถูกใช้เป็น อินพุตไปยังโมดูลไฮบริดHNN ซึ่งจะมีตัวจำแนกอีกชั้นเป็นขั้นสุดท้าย ผลที่ได้มีประสิทธิภาพสูงเพราะเป็นการรวมกันระหว่าง 2 โมเดล



ภาพประกอบที่ 1-11 แบบจำลองโครงข่ายแบบไฮบริด Hybrid neural network (HNN-NTL) [18]

ข. Wide and Deep Convolutional Neural Network

Z. Zheng et al. [19] ได้นำเสนอการตรวจจัดการโครงการหรือการละเมิดการใช้ไฟฟ้า โดยใช้โครงข่ายประสาทเทียม คอนโวลูชันแบบกว้างและลึก Wide and Deep convolutional โมเดล CNN ประกอบด้วย 2 ส่วน คือองค์ประกอบกว้างและองค์ประกอบลึก ส่วนประกอบ CNN เชิงลึก สำหรับข้อมูลในลักษณะที่ไม่เป็นช่วงเวลา และสำหรับข้อมูลที่เป็นช่วงระยะเวลา ปริมาณการใช้ไฟฟ้าจะวิเคราะห์ในรูปแบบข้อมูล 2 มิติ ในขณะที่คอนโวลูชันที่กว้างสามารถจับภาพ คุณสมบัติทั่วไปของข้อมูลการใช้ไฟฟ้า 1-D ได้ แสดงภาพประกอบ 1-12 โครงสร้าง Wide และ Deep CNN โดยรวมประกอบด้วย 2 องค์ประกอบหลัก ได้แก่ องค์ประกอบกว้างและองค์ประกอบ CNN ระดับลึก



ภาพประกอบที่ 1-12 โครงสร้างการทำงานแบบ wide และ deep CNN framework [19]

โครงสร้าง Wide และ Deep CNN โดยรวมประกอบด้วย 2 องค์ประกอบหลัก ได้แก่ องค์ประกอบกว้างและองค์ประกอบ CNN ระดับลึก รายละเอียดประกอบด้วยดังนี้

- องค์ประกอบรูปแบบกว้าง (Wide Component)

องค์ประกอบรูปแบบกว้างดึงภาพประกอบ 1-12 ส่วนประกอบแบบกว้าง (อยู่ในกล่องเส้นสีแดง) เป็นเลเยอร์ที่เชื่อมต่ออย่างสมบูรณ์ของโครงข่ายประสาทเทียมและเรียนรู้จากข้อมูลปริมาณการใช้ไฟฟ้า 1-D จากการวิเคราะห์เบื้องต้นปริมาณการใช้ไฟฟ้าของลูกค้ามีความผันผวนเป็นระยะๆ ในขณะที่การใช้ไฟฟ้าตามปกติ ส่วนระยะเวลาและปริมาณการใช้ไฟฟ้าของรูปแบบการขโมยพลังงานเป็นช่วงระยะน้อยหรือรูปแบบไม่เป็นช่วงในอนุกรมเวลา 1-D ตามสมการที่ (1-8) และ (1-9)

$$y_i = \sum_{i=1}^n W_{i,j} X_i + b_i \quad (1-8)$$

โดยที่ y_i คือ ผลลัพธ์ของเลเยอร์ที่เชื่อมต่ออย่างสมบูรณ์ในเซลล์ประสาท n คือความยาวของข้อมูลอินพุต 1-D $W_{i,j}$ เป็นค่าน้ำหนักของเซลล์ประสาทระหว่างค่าที่ป้อนเข้า และเซลล์ประสาทที่ j และ b คือค่าไบอัส (bias)

$$u_j = f(y_i) = \max(0, y_i) \quad (1-9)$$

โดยที่ u_j คือผลลัพธ์หลังจากการคำนวณการเปิดใช้งาน (activation) และ มาจากฟังก์ชันการเปิดใช้งาน activation function.

- องค์ประกอบส่วนลึก (Deep CNN Component)

ในส่วนลึกของ CNN ข้อมูลที่ใช้ฝึกสอนเป็นข้อมูลเกี่ยวกับข้อมูลการใช้ไฟฟ้า 2 มิติ ช่วงเวลาของการใช้ไฟฟ้าภาวะปกติและความไม่ต่อเนื่องของช่วงเวลาผิดปกติ ภาพประกอบ 1-12 CNN ส่วนลึก (อยู่ในช่องกรอบสีน้ำเงิน) ประกอบด้วย Multiple convolutional layers และชั้นที่เชื่อมต่ออย่างสมบูรณ์ เป็นหนึ่งในตัวควบคุมความสามารถในการปรับขนาดที่ประกอบด้วยหลายชั้น Layer R, Layer1, Layer2 เลือกใช้ d เป็นตัวแทนของจำนวนวันจากปริมาณการใช้ไฟฟ้าของลูกค้าในสัปดาห์ โดยเวกเตอร์ $V_{d,m}$ แทนการใช้ไฟฟ้า m สัปดาห์ ดังสมการที่ (1-10) ถึง (1-15)

$$V_{d:m} = \begin{bmatrix} V_1 \\ V_2 \\ V_3 \\ \vdots \\ V_m \end{bmatrix} \quad (1-10)$$

พิจารณาคูณสมบัติแต่ละเวกเตอร์ สร้างจากหน้าตาต่างของเมตริก C

$$C_{p+1}, C_{q+1} = f(W(g_1(V_{p:p+2,p:p+2}) + g_2(V_{p:p+2,p:p+2})) + b_2) \quad (1-11)$$

โดยค่า b_2 คือค่าไบอัส g_1 และ g_2 สำหรับการออกแบบ kernel functions ระบุข้อมูลการใช้ไฟ 2-D

$$g_1(\cdot) = g_1(V_{p:p+2,p:p+2}) \quad (1-12)$$

$$g_1(\cdot) = \begin{bmatrix} 2V_{p:p,p:p+2} - V_{p:p+1,p:p+2} - V_{p+2,p:p+2} \\ 2V_{p:p,+1+2,p:p+2} - V_{p,p,p:p+2} - V_{p+2,p:p+2} \\ 2V_{p:p+2+2,p:p+2} - V_{p,p,p:p+2} - V_{p+1,p:p+2} \end{bmatrix} \quad (1-13)$$

กำหนดให้ค่าที่ถูกแปลงจากตัวแปรในแต่ละแถวของ 2 คอลัมน์ ลบออกจากคอลัมน์ที่ 2 แนวโน้มคาบช่วงเวลาที่เกิดการแกว่งและเข้าสู่ filter block ได้แผนที่คุณลักษณะ (feature map)

$$g_2(\cdot) = g_1(V_{p:p+2,p:p+2})^T \quad (1-14)$$

โดยที่ C คือแผนที่คุณลักษณะ (feature map) ที่สร้างขึ้นซึ่งมีขนาดเท่ากับเมตริกซ์ข้อมูลดิบ ใช้ zero padding เท่ากับ 1, Pooling layer ขึ้นรวมเท่ากับ 7 ดังสมการที่ (1-32)

$$C = \begin{bmatrix} C_{1,1} & \cdots & C_{1,7} \\ \vdots & \ddots & \vdots \\ C_{m,1} & \cdots & C_{m,7} \end{bmatrix} \quad (1-15)$$


Fully connected layer เลเยอร์ที่เชื่อมต่อในส่วนลึกขององค์ประกอบ CNN คล้ายกับองค์ประกอบแบบกว้างโดยขนาดแตกต่างกัน ขนาดของส่วนประกอบกว้างคือ α และของ CNN คือ β ชั้นที่เชื่อมต่ออย่างเต็มที่ในส่วนลึกใช้เพื่อสร้างคุณสมบัติหลัก สามารถคำนวณได้ในลักษณะเดียวกัน กับชั้นของเลเยอร์ที่เชื่อมต่ออย่างสมบูรณ์ในองค์ประกอบแบบกว้าง (1D) แบบจำลองส่วนสุดท้ายของโมเดลแสดงดังสมการที่ (1-16)

$$P(Y=1|X) = \delta(W[X_{wide}, X_{CNN}] + b) \quad (1-16)$$

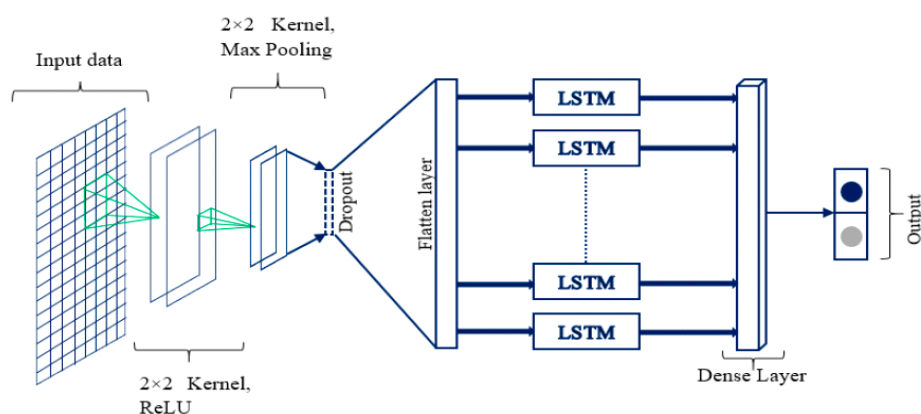
โดยที่ Y คือ คลาสไบนารี δ คือฟังก์ชันซิกมอยด์ sigmoid function ที่แสดงถึงคุณสมบัติของส่วนประกอบแบบกว้างและลึกตามลำดับ W คือจุดเชื่อมต่อกับน้ำหนัก b เป็นค่าไบอัส

ค. Convolutional Neural Network-Based LSTM (CNN-LSTM)

M. N. Hasan et al. [20] นำเสนอการรวมกันของโครงข่ายประสาทเทียมแบบคอนโวลูชัน Convolutional Neural Network (CNN) และโครงข่ายประสาทเทียมหน่วยความจำระยะสั้นแบบยาว Long Short-Term Memory (LSTM) เทคนิคการเรียนรู้เชิงลึก CNN-LSTM ใช้เพื่อระบุข้อมูลการขโมยไฟฟ้าจากรูปแบบการใช้พลังงานของผู้ใช้ไฟ วิธีการโดยรวมแสดงภาพประกอบ 1-25 และแบบจำลอง CNN-LSTM ดังภาพประกอบ 1-26



ภาพประกอบที่ 1-13 Block diagram แบบจำลอง CNN-LSTM [20]




ภาพประกอบที่ 1-14 Convolutional neural network-based LSTM (CNN-LSTM) โมเดล [20]

1.2.3.3 การจำแนกโดยใช้เทคนิคอื่นๆ

ก. Hamming Code

A. b. Shah et al. [21] ได้นำเสนออัลกอริธึมประกอบด้วยสองส่วนหลักคือ การประเมินกำลังไฟฟ้าสูญเสียจริง Real Power (kW) เมื่อการวัดค่าพลังงานจากสมาร์ทมิเตอร์ (Smart meter) ผิดพลาด และการประมาณค่าพลังงานที่ใช้โดยใช้อัลกอริธึมรหัสแฮมมิง ทดสอบโดยใช้การจำลองเพื่อตรวจสอบประสิทธิภาพของอัลกอริธึมในการระบุกำลังไฟฟ้าสูญเสียที่ไม่ใช่เทคนิค

รหัสแฮมมิง Hamming Code เป็นเทคนิคหนึ่งที่ยอมรับใช้ตรวจจับข้อผิดพลาดในระบบการสื่อสาร โทรคมนาคม A. b. Shah et al. ประยุกต์ใช้กับระบบจ่ายไฟและมิเตอร์อัจฉริยะ รูปแบบการวิเคราะห์ แสดงไว้ในภาพประกอบ 1-15 ระบบประกอบด้วยเครื่องวัดอัจฉริยะแบบทั่วไป 4 ตัว (มิเตอร์หมายเลข 1, 2, 3 และ 4) ในรูปสี่เหลี่ยม จำลองให้มีโหนด 4 ชุด เปรียบเสมือนโหนดเชื่อมต่อกับบัสในระบบจำหน่ายของการไฟฟ้าและเพิ่มมิเตอร์อัจฉริยะจำนวน 3 เครื่อง สำหรับตรวจสอบดังรูปสีแดง



ภาพประกอบที่ 1-15 แบบจำลองการเชื่อมต่อมิเตอร์ในระบบจำหน่าย Hamming Code [21]

$$X_p = [X_{p1} X_{p2} X_{p3} X_{p4} X_{p5} X_{p6} X_{p7}] \quad (1-17)$$

$$\hat{X}_p = [\hat{X}_{p1} \hat{X}_{p2} \hat{X}_{p3} \hat{X}_{p4} \hat{X}_{p5} \hat{X}_{p6} \hat{X}_{p7}] \quad (1-18)$$

โดยที่ X_p คือ ค่าที่วัดได้จากมิเตอร์อ่านค่าได้ลำดับมิเตอร์ที่ i เป็นเวกเตอร์ของกำลังไฟฟ้า ที่วัดได้ตามลำดับ มิเตอร์ทั้งหมด และ \hat{X}_p แทนการวัดกำลังของมิเตอร์ i เมื่อค่าที่ถูกวัดมีความถูกต้องจากมิเตอร์ทั้งหมด $X_p = \hat{X}_p$ ในทางกลับกันถ้ามิเตอร์บางเครื่องวัดค่าไม่ถูกต้อง เป็นไปตามความสัมพันธ์ในสมการที่ (1-17) และ (1-18) ดังนั้น $\hat{X}_p = X_p - e$ โดยที่ e คือ ขนาดเวกเตอร์ ของความคลาดเคลื่อนมิเตอร์ตรวจสอบ เชื่อมต่อในรูปแบบเมทริกซ์ G เป็นค่าที่ออกแบบบนพื้นฐาน รหัส

แฮมมิง Hamming Code มีเตอร์ตรวจสอบเชื่อมต่อเข้าระบบโดยสร้างให้อยู่ในรูปเมทริกซ์ G เพื่อตรวจสอบการวัดของสมาร์ทมิเตอร์และตรวจจับการวัดที่ไม่ถูกต้อง การวัดทั้งหมดของสมาร์ทมิเตอร์ จะถูกคูณด้วยเมทริกซ์ที่เรียกว่า เมทริกซ์ถอดรหัส (decoding matrix) D ผลคูณจะทำให้เกิดเวกเตอร์ที่เรียกว่า S_p ซินโดรมเวกเตอร์ ดังสมการที่ (1-19) และ (1-20)

$$S_p = \hat{X}_p \cdot [s_{p1} s_{p2} s_{p3}] \quad (1-19)$$


$$D = \begin{pmatrix} 1 & 1 & 0 \\ 1 & 0 & 1 \\ 0 & 1 & 1 \\ 1 & 1 & 1 \\ -1 & 0 & 0 \\ 0 & -1 & 0 \\ 0 & 0 & -1 \end{pmatrix} \quad (1-20)$$

e_i ค่าความผิดพลาดจากมิเตอร์ i , S_p ซินโดรมเวกเตอร์, $\hat{X}_{p(eor)}$ เป็นเวกเตอร์ที่มีเตอร์วัดค่าได้ถูกต้องและสอดคล้องกับสมการที่ (1-21)

$$\hat{X}_{p(eor)} = [\hat{X}_{p1} \hat{X}_{p2} \hat{X}_{p3} \hat{X}_{p4} \hat{X}_{p5} \hat{X}_{p6} \hat{X}_{p7}] \pm [e_1 e_2 e_3 e_4 e_5 e_6 e_7] \quad (1-21)$$

ข. Rule-Based Model Tuned by Particle Swarm Optimization

P. Fuangfung et al. [22] ได้นำเสนอเทคนิคการกำหนดกฎโดยใช้วิธีหาคำตอบที่เหมาะสมแบบฝูง ในการตรวจสอบความผิดปกติจากการวัดค่าของตัวมิเตอร์ ใช้ข้อมูลจากมิเตอร์ AMR ซึ่งเป็นมิเตอร์ที่ติดตั้งในระบบจำหน่ายแรงดัน 22 kV ของการไฟฟ้าส่วนภูมิภาค ข้อมูลจากมิเตอร์จะส่งเข้ามาเก็บที่ AMR data center ทุกๆ 15 นาที เป็นมิเตอร์ประเภท 3 เฟส 3 สาย คือ มีการวัดค่าผ่านเครื่องวัดกระแสแรงสูง (Current transformer: CT) และเครื่องวัดแรงดันสูง (Voltage transformer: VT/PT) หรือเรียกว่าการวัด 2 elements (two-watt method) โดยแรงดันเฟส B จะถูกใช้เป็นจุดอ้างอิงสำหรับการวัดค่าที่ใช้ประกอบด้วย วันที่ เวลา กระแส I_a, I_c แรงดัน V_{ab}, V_{cb} และค่าพลังงานการใช้ไฟ (kWh) ข้อมูลที่ใช้เริ่มเมื่อ 1 มกราคม 2015 ถึง 31 ธันวาคม 2016 (ช่วงเวลา 2 ปี) ประกอบด้วย 458 รายประเภทปกติ และ 42 รายที่ผิดปกติ คิดเป็น 92% ต่อ 8% ตัวอย่างดังภาพประกอบที่ 1-16



ภาพประกอบที่ 1-16 ตัวอย่างข้อมูลที่บันทึกได้จากมิเตอร์ AMR สำหรับ Rule-based Model [22]

ในการทดลองแบ่งออกเป็น 2 ส่วนหลัก ได้แก่

ส่วนที่ 1 การกำหนดกฎพื้นฐาน (Rule-based model) สำหรับตรวจสอบความผิดปกติของค่าแรงดันและกระแสที่เกิดขึ้น ดังสมการที่ 1-22)

$$\text{กำหนด } \text{Voltage Unbalance}(\%) = \frac{|V - V_{ref}|}{V_{ref}} \times 100\% \quad (1-22)$$

เมื่อ V คือ แรงดันของเฟสใด ๆ V_{ref} คือ แรงดันอ้างอิงฝั่งทุติยภูมิ, α คือ threshold แรงดัน Unbalance, X_1 คือเหตุการณ์ผิดปกติที่เกิดขึ้นใน 1 ชั่วโมง

Rule:1 กฎของแรงดัน (Rule of voltages)	
1	IF (แรงดันเฟสใดเป็น 0) AND (เกิดขึ้นมากกว่า X_1 ชั่วโมง ใน 1 วัน)
2	THEN (ลักษณะดังกล่าวคือรูปแบบผิดปกติ)
3	IF แรงดันเฟสใดเกิด $\text{Unbalance}(\%) > \alpha$ AND (เกิดขึ้นมากกว่า X_1 ชั่วโมง ใน 1 วัน)
4	THEN (ลักษณะดังกล่าวคือรูปแบบผิดปกติ)

$$\text{กำหนด } \text{Asymmetric Power}(\%) = \frac{\left| \frac{I_A + I_C}{2} - \max(I_A, I_C) \right|}{\max(I_A, I_C)} \times 100\% \quad (1-23)$$

กฎแรงดัน (Rule:1) ที่ถูกสร้างขึ้นจะอาศัยรูปแบบของความสัมพันธ์ระหว่างแรงดันเฟส A และแรงดันเฟส C ด้านแรงต่ำที่ผ่านเครื่องวัด VT และสำหรับกฎกระแส (Rule:2) จะเป็นค่าที่ถูกวัดผ่านเครื่องวัด CT ในสภาวะปกติทั้ง 2 กฎ ตามสมการที่ (1-23) ค่าแรงดันและค่ากระแสจะมีค่าใกล้เคียงและสมดุลกันในแต่ละเฟส ซึ่งเปลี่ยนแปลงตามการใช้โหลดแต่ละช่วงเวลา

Rule:2 กฎของกระแส (Rule of currents)	
1	<i>IF</i> (Asymmetric power (%) > X_2 AND Any phase current > $4 X_1$) OR (Asymmetric power (%) > $3 X_1$ AND Any phase current $4 \leq X_1$) AND เกิดขึ้น มากกว่า X_1 ชั่วโมง ใน 1 วัน
2	<i>THEN</i> (ลักษณะดังกล่าวคือรูปแบบผิดปกติ)
3	<i>IF</i> กระแสเฟสใดเป็น 0 AND (เกิดขึ้นมากกว่า X_1 ชั่วโมง ใน 1 วัน)
4	<i>THEN</i> (ลักษณะดังกล่าวคือรูปแบบผิดปกติ)
5	<i>IF</i> ถ้ากระแสเฟสใดเกิด <i>Over current</i> AND (เกิดขึ้นมากกว่า X_1 ชั่วโมง ใน 1 วัน)
6	<i>THEN</i> (ลักษณะดังกล่าวคือรูปแบบผิดปกติ)

เมื่อ X_2, X_3 คือ Threshold asymmetric power และ X_4 คือ Threshold any phase current

ส่วนที่2 หาคำตอบที่เหมาะสมแบบฝูง (Particle Swarm Optimization)

Particle Swarm Optimization เหมาะสำหรับการนำไปใช้เพื่อหาค่าพารามิเตอร์ที่ดีที่สุดสำหรับโมเดลตามกฎ การค้นหารายละเอียดเชิงลึกรวมถึงระยะเวลาของเหตุการณ์ที่ผิดปกติ ตามสมการที่ (1-24) และ (1-25)

$$\text{Objective Function} = \min(FP) \quad (1-24)$$

$$\text{Constraint: Meter}_{\text{abnormal}} = 100\% \quad (1-25)$$

ผลลัพธ์ที่ได้จากการใช้การกำหนดกฎพื้นฐาน (Rule-Based Model) และการหาคำตอบที่เหมาะสมแบบฝูง (Particle Swarm Optimization) โดยการตรวจสอบช่วงเวลาที่เกิดผิดปกติ Voltage unbalance และ Asymmetric power จากการกำหนดค่า Threshold โมเดลสามารถตรวจสอบความผิดปกติได้ 100% คิดเป็น MCC = 94.01% ,FRR = 1.09% ซึ่งผลการศึกษาที่ได้สามารถช่วยลดการภาระงานตรวจสอบและลดหน่วยสูญเสียที่ไม่ใช่เทคนิคได้

1.2.4 การประเมินผลโมเดลที่ใช้จำแนกกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค

ภายหลังจากการนำโมเดลมาวิเคราะห์ข้อมูล สิ่งสำคัญอย่างหนึ่งก่อนนำโมเดลไปใช้งานจริงนั้นคือ การวัดประสิทธิภาพของโมเดล Confusion Matrix เป็นหนึ่งในวิธีประเมินประสิทธิภาพที่อยู่ในรูปแบบตารางข้อมูลซึ่งนิยมใช้ในงาน ML [23] ตัวอย่างแสดงภาพประกอบที่ 1-17

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

ภาพประกอบที่ 1-17 ตารางแสดงตัวอย่าง Confusion Matrix ขนาด 2x2

หมายเหตุ True Positive (TP) = ทำนายตรงกับเกิดขึ้นจริง กรณีทำนายจริงและสิ่งที่เกิดขึ้นจริง

True Negative (TN) = ทำนายตรงกับที่เกิดขึ้น กรณีทำนายว่าไม่จริง และสิ่งที่เกิดขึ้นก็คือไม่จริง

False Positive (FP) = ทำนายไม่ตรงกับที่เกิดขึ้น คือทำนายว่าจริง แต่สิ่งที่เกิดขึ้นคือไม่จริง

False Negative (FN) = ทำนายไม่ตรงกับที่เกิดขึ้นจริง คือทำนายว่าไม่จริง แต่สิ่งที่เกิดขึ้นคือจริง

G. M. Messinis et al. [10] รวบรวมการประเมินผลลัพธ์ของข้อมูลแบบเมทริกที่ใช้ในการประเมินผล ที่สอดคล้องกับวิธีการตรวจหากำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) ซึ่งมีหลากหลายวิธี ที่นิยมใช้สามารถสรุปได้ดังในตารางที่ 1-3

ตารางที่ 1-3 รายการข้อมูลแบบเมตริกที่ใช้ในการประเมินผลลัพธ์

เมตริก	นิยาม	คำอธิบาย
Accuracy	$Accuracy = \frac{TP + TN}{TP + TN + FP + FN}$	เป็นการวัดค่าความถูกต้องของโมเดล โดยพิจารณารวมทุกคลาส
Detection rate (DR) (Recall)	$Recall = \frac{TP}{TP + FN}$	เป็นการวัดค่าความถูกต้องของโมเดล โดยพิจารณาแยกทีละคลาส
Precision	$Precision = \frac{TP}{TP + FP}$	เป็นการวัดค่าความแม่นยำของข้อมูล โดยพิจารณาแยกทีละคลาส
FPR	$FPR = \frac{FP}{FP + TN}$	เป็น Rate ของตัวประกอบการวัด False Positive Rate(FPR)
TNR	$TNR = \frac{TN}{FP + TN}$	เป็น Rate ของตัวประกอบการวัด True Negative Rate (TNR)
FNR	$FNR = \frac{FN}{FN + TP}$	เป็น Rate ของตัวประกอบการวัด False Negative Rate(FNR)
F1 score	$F1score = \frac{2TP}{2TP + FP + FN}$	F1-Score เป็น single metric ที่วัดความสามารถของโมเดล จากค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall
Recognition Rate	$Recognition Rate = 1 - 0.5 \left(\frac{FP}{N} + \frac{FN}{P} \right)$	อัตราการเรียนรู้
AUC (Area Under Curve)	The area under the ROC (Receiver Operating Curve) of the binary classifier.	พื้นที่ภายใต้ ROC curve เป็นตัวประเมิน test performance

1.2.5 ตารางเปรียบเทียบการทบทวนวรรณกรรม

ตารางที่ 1-4 ตารางเปรียบเทียบการทบทวนวรรณกรรม

บทความ	ตรวจสอบ	แหล่งข้อมูล	คุณลักษณะ	เทคนิค	ประสิทธิภาพ	จุดเด่นของวิธีการ	ข้อจำกัดของวิธีการ
[14] (2019)	ทุกรูปแบบ ละเมิด	หน้างาน จริง 57,304 ราย	QB EC Distance Density	K-Means KNN, LR SVM, NN XGBoost	Acc 91.00%	- ใช้เทคนิคที่หลากหลาย - การสกัดค่าใช้หลายวิธี - มีการจัดการกับข้อมูล ไม่สมดุล - ใช้ k-fold cv สุ่มข้อมูล	- เลือกบางกลุ่มข้อมูล มาใช้วิเคราะห์ ไม่ได้ เป็นข้อมูลทุกประเภท (ประเภทที่ใช้ไฟ มากกว่า 50 kW)
[15] (2017)	โจรกรรม, ละเมิด, การขำรุค	จำลอง เหตุการณ์ ในห้องทดลองใช้ SM 3 เครื่อง	จำลอง เหตุการณ์ 3 แบบ ได้แก่ ปกติ โกง และขำรุค	LR	Peak- Value R- Square	- ไม่ถูกจำกัดด้วยขนาดมิติ ของข้อมูล - สามารถแสดงจำนวน การละเมิด/สูญเสียดัง โดยไม่มี การสูญเสียดัง เทคนิค/สัญญาณรบกวน	- เป็นการจำลอง เหตุการณ์ที่เกิดขึ้นไม่ ได้นำรูปแบบจริงมาใช้ - ประเมินประสิทธิภาพ ของโมเดลบอกเพียง - รูปแบบมีน้อยเกินไป
[16] (2021)	โจรกรรม, ละเมิด,	หน้างาน จริง ผู้ใช้ไฟ 9,512 ราย	GASF MTF RP SPEC	DensNet Inception ResNet MobiNet VGG	Acc 90%	- ใช้เทคนิคที่แตกต่าง เน้นการประมวลผลโดย ใช้ภาพ 1-D และ 2-D เปรียบเทียบความ ผิดปกติในหลายรูปแบบ	- การจัดแบ่งกลุ่ม Cluster แต่ละพื้นที่จะ แตกต่างกัน - ขั้นตอนค่อนข้าง ซับซ้อน ใช้เวลานาน
[24] (2018)	ทุกรูปแบบ ละเมิด	ข้อมูล ย้อนหลัง 10 ปี 5,500 ราย	Expert, Outlier, SOM, Clustering	ES LOF MGD K-mean SOM	Acc 88.10%	- ใช้วิธีแบบที่ไม่มีผู้ดูแล ในการจำแนกความ ผิดปกติ ไม่ต้องมี class - ใช้เทคนิคที่หลากหลาย ในการทดสอบข้อมูล	- ความแม่นยำน้อย กว่าวิธีการเรียนรู้แบบ มีผู้สอน - ยังไม่สามารถระบุบาง รูปแบบได้ชัดเจน
[25] (2019)	ทุกรูปแบบ ละเมิด	หน้างาน จริง 57,304 ราย	Season Missing Zero Location Economic Activity	HNN (LSTM+ MLP)	Acc 83.6%	- ทำงานร่วมกัน 2 เทคนิค ในการทดสอบข้อมูล - สามารถใช้ข้อมูลป้อน เข้าโมเดลโดยไม่ต้องสกัด - ใช้ข้อมูล 2 ประเภทคือ มีลำดับกับไม่มีลำดับ	- ใช้ข้อมูลทั้งมีลำดับ กับไม่มีลำดับ ซึ่งหา ข้อมูลให้ครบถ้วนยาก - ใช้ train-test split ทำให้ผล Validation ได้ข้อมูลเดียวกับ train
[26] (2018)	ทุกรูปแบบ โจรกรรม ละเมิด	มิเตอร์ SG 35เดือน 42,372 ราย	1-D (day) 2-D (Week)	WD-CNN	Acc 92.97%	- รวม 2 เทคนิคในการ ทดสอบข้อมูล - ขั้นตอนการเตรียมข้อมูล ใช้เทคนิคที่ให้ผลลัพธ์ที่ดี	- ไม่ได้กล่าวถึง ประเภทของข้อมูลที่ใช้ - รูปแบบความผิดปกติ ยังไม่ครบถ้วน และ ไม่ได้แก้ข้อมูลไม่สมดุล

ตารางที่ 1-4 ตารางเปรียบเทียบการทบทวนวรรณกรรม (ต่อ)

บท ความ	ตรวจสอบ	แหล่ง ข้อมูล	คุณลักษณะ	เทคนิค	ประสิทธิ -ภาพ	จุดเด่นของวิธีการ	ข้อจำกัดของวิธีการ
[27] (2019)	โปรแกรม ละเมิด	มิเตอร์ SG ผู้ใช้ไฟ 17,120 ราย	2-D (daily)	CNN- LSTM	Acc 89.00%	- เป็นการนำจุดเด่นของ แต่ละเทคนิค CNN กับ LSTM มาประยุกต์ใช้ - LSTM มาช่วยในการ สกัดข้อมูล	- ไม่ได้แสดงให้เห็น การนำ 2 เทคนิคมาใช้ เชื่อมต่อในลักษณะใด - ไม่ได้อธิบายประเภท ข้อมูลอินพุต
[29] (2019)	มิเตอร์ ชำรุด	ฐานข้อมูล มิเตอร์ 200 เครื่อง	Load - factor Vector- power	Hamming Code	0% error	- ใช้ Hamming Code ตรวจสอบเปรียบเทียบ 3 ค่า คือ ค่าที่วัดได้ ค่าจริง และค่าที่ถูกต้อง	- ใช้ข้อมูลแบบจำลอง ในการทดสอบ ไม่ได้ แสดงผลการทดลอง กับข้อมูลจริง
[30] (2019)	ตรวจสอบ การทำงาน ผิดพลาด จากการวัด ค่าของ มิเตอร์	ฐานข้อมูล กฟภ. มิเตอร์ AMR 2 ปี 500 เครื่อง	ค่า kWh ค่า กระแส ค่า แรงดัน	Rule- based Model, PSO	MCC = 94.01%, FRR = 1.09%	- ใช้ข้อมูลมิเตอร์ AMR (two-watt method) ซึ่ง มีความต้องการใช้ไฟสูง ลด NTL ได้ - กำหนดกฎได้เหมาะสม และสอดคล้องกับการ ทำงานของมิเตอร์ - ลดการออกไปตรวจสอบ หน้างานได้	- ใช้ข้อมูล AMR เฉพาะ ระบบ 22 kV ซึ่งยังไม่ ครอบคลุมทั้งหมด - กรณีความผิดปกติที่ เกิดขึ้นเกิดจากละเมิด ไม่สามารถจำแนกได้ - วิธีการดังกล่าวยังไม่ สามารถนำไปปรับใช้ กับมิเตอร์ชนิดอื่นได้

1.3 วัตถุประสงค์ของการวิจัย

1.2.1 เพื่อศึกษากำลังไฟฟ้าสูญเสียทั้งด้านเทคนิคและไม่เทคนิค สาเหตุ รูปแบบความผิดปกติที่เกิดขึ้นในระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาค (กฟภ.)

1.2.2 เพื่อวิเคราะห์กำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิคที่เกิดขึ้นในระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาค (กฟภ.) โดยการนำข้อมูลที่มีอยู่ในองค์กรมาประยุกต์ใช้ให้เกิดประโยชน์

1.2.3 เพื่อสร้างโมเดลสำหรับตรวจสอบ และจำแนกลักษณะความผิดปกติที่เกิดขึ้น จากการชำรุดของตัวมิเตอร์รวมทั้งอุปกรณ์ประกอบและการละเมิดจากผู้ผู้ใช้ไฟ

1.2.4 เพื่อเพิ่มความแม่นยำ และความน่าเชื่อถือให้กับระบบจำหน่ายไฟฟ้าของการไฟฟ้าส่วนภูมิภาค (กฟภ.)

1.2.5 เพื่อพัฒนาและเพิ่มประสิทธิภาพของโมเดล ให้สามารถจำแนกหรือทำนายความผิดปกติได้อย่างแม่นยำและถูกต้อง

1.4 ขอบเขตการวิจัย

1.4.1 การวิจัยครั้งนี้มุ่งศึกษาการจำแนกลักษณะผู้ใช้ไฟแบ่งเป็น 3 ประเภท ได้แก่ ปกติ, มีประวัติการละเมิด และการชำรุดจากตัวมิเตอร์และอุปกรณ์ประกอบ ข้อมูลที่ใช้ในงานวิจัยได้รับข้อมูลจากกองพัฒนาระบบมิเตอร์ (กพร.) และดึงข้อมูลจากฐานข้อมูลในระบบ AMR ซึ่งปัจจัยดังกล่าวส่งผลให้เกิดกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิคในระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาค (กฟภ.)

1.4.2 ข้อมูลที่ใช้จะแบ่งออกเป็น 4 ภาค 12 เขต ครอบคลุมพื้นที่หลักๆของการไฟฟ้าส่วนภูมิภาค เป็นกลุ่มผู้ใช้ไฟรายใหญ่ที่ติดตั้งมิเตอร์ประเภท AMR (Automatic meter reading) มีความต้องการใช้พลังงานไฟฟ้าตั้งแต่ 30 กิโลวัตต์ขึ้นไปแต่ไม่เกิน 250 กิโลวัตต์ และมีการซื้อไฟจากการไฟฟ้าทางเดียว

1.4.3 ความผิดปกติประเภทละเมิดที่เกิดจากค่ากระแส แรงดัน มุมเฟส และกำลังไฟฟ้าที่ส่งผลต่อค่าพลังไฟฟ้าของผู้ใช้ไฟ ก่อให้เกิดหน่วยสูญเสียกับการไฟฟ้า และมีลักษณะที่ต่างจากการใช้ไฟปกติ

1.4.4 ความผิดปกติประเภทชำรุดที่เกิดจากตัวมิเตอร์และการทำงานผิดปกติจากอุปกรณ์ประกอบ เช่น สายไฟแรงต่ำชำรุด, Current Transformer (CT) ชำรุด, Drop out fuse, Low Tension Fuse Switch เป็นต้น และเกิดจากปรากฏการณ์ธรรมชาติ และมีเตอร์ตรวจจับความผิดปกติได้

1.5 ประโยชน์ที่คาดว่าจะได้รับ

1.3.1 สามารถนำผลที่ได้จากการศึกษาไปใช้วิเคราะห์ร่วมกับระบบ AMR เพื่อจำแนกกลุ่มผู้ใช้ไฟที่มีแนวโน้มผิดปกติจากพฤติกรรมการใช้ไฟได้

1.3.2 สามารถนำผลการวิเคราะห์มากำหนดเป็นแนวทางหรือมาตรการในการลดหน่วยหน่วยสูญเสียที่เกิดขึ้นในจำหน่ายของการไฟฟ้าส่วนภูมิภาคได้

1.3.3 สามารถนำผลที่ได้ไปประยุกต์ใช้กับหน่วยซื้อ-ขาย เพื่อหาสาเหตุของหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค ที่หายไปของการไฟฟ้าส่วนภูมิภาคได้

1.3.4 สามารถลดเวลา ลดการทำงานซ้ำซ้อน และลดหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค รวมถึงเพิ่มประสิทธิภาพในการทำงานของพนักงานการไฟฟ้าส่วนภูมิภาคได้

1.3.5 เป็นแนวทางในการพัฒนาและต่อยอดเพื่อรองรับโครงข่ายไฟฟ้าในอนาคต สำหรับระบบสมาร์ตกริดและ AMI ได้

1.6 ประเด็นการวิจัย

สรุปประเด็นของงานวิจัยก่อนหน้าและช่องว่างของการวิจัย (Research Gap) จากการศึกษาพบว่า ในงานวิจัยด้านกำลังไฟฟ้าสูญเสียที่ไม่ใช่เทคนิค (NTL) ประเด็นสำคัญประกอบด้วย

- ก. รูปแบบความผิดปกติที่ต้องการตรวจสอบมีความแตกต่างกันในหลายบทความ เช่น การเปลี่ยนแปลงการใช้ไฟกะทันหัน การชำรุด ระเบิด จึงทำให้พบว่ายังมีงานวิจัยส่วนน้อยที่จำแนกความผิดปกติที่พิจารณาทั้ง 3 class
- ข. แหล่งข้อมูลที่ใช้แตกต่างกัน งานวิจัยที่พบจะใช้ข้อมูลจากห้องทดลอง อินเทอร์เน็ต หรือจากการจำลองขึ้นตามสมการ ทำให้ข้อมูลที่นำมาใช้ขาดความหลากหลายและไม่ครอบคลุมประเภทของมิเตอร์ที่ใช้งานจริง
- ค. ชนิดของข้อมูลที่นำมาวิเคราะห์แตกต่างกัน ในงานด้านการตรวจจับความผิดปกติหรือระเบิดจะนำค่า EC มาใช้ ซึ่งสะท้อนให้เห็นถึงพฤติกรรมของผู้ใช้ไฟที่ชัดเจน แต่ในการจำแนกความผิดปกตินั้นอาจต้องลงลึกถึงการนำค่ากระแส แรงดัน และตัวประกอบกำลังไฟฟ้ามาใช้วิเคราะห์ร่วมด้วย เพื่อให้สามารถจำแนกความผิดปกติได้ดี
- ง. ใช้เทคนิคสกัดข้อมูลแตกต่างกัน การสกัดข้อมูลมีหลากหลายวิธี ขึ้นอยู่กับลักษณะของข้อมูล และสิ่งที่ต้องการสกัด โดยต้องเลือกให้เหมาะสมกับโมเดลที่จะใช้จำแนก
- จ. ข้อมูลที่ไม่สมดุลอาจส่งผลต่อการเรียนรู้ของโมเดล อาจเกิดการ bias สู่ข้อมูลจำนวนมากได้ การทำสมดุลข้อมูลก่อนการจำแนกมีหลากหลายวิธี และต้องเลือกให้เหมาะสมกับข้อมูล
- ฉ. กลุ่มผู้ใช้ไฟ 3 เฟส มีหลากหลายประเภท ไม่ว่าจะเป็นบ้านที่อยู่อาศัย กิจการขนาดเล็ก กิจการขนาดกลาง ซึ่งงานวิจัยส่วนใหญ่ไม่นิยมจัดกลุ่ม และโฟกัสเฉพาะกลุ่ม

- ข. หลายงานวิจัยไม่ได้ทดสอบข้อมูลกับเหตุการณ์จริง เพื่อประเมินประสิทธิภาพโมเดล ทำให้อาจเกิดความผิดพลาดได้ จึงควรนำโมเดลที่ได้ไปสอบทดกับสถานการณ์จริง

ดังนั้น จากที่กล่าวมาข้างต้นและผลจากการทบทวนวรรณกรรม ผู้วิจัยจึงได้เสนอแนวทางวิจัยที่จะจำแนกลักษณะปกติ ชำรุดและละเมิด ของมิเตอร์ AMR โดยใช้ข้อมูลย้อนหลังในอดีตจากฐานข้อมูล กฟภ. ซึ่งมีมิเตอร์ AMR เป็นมิเตอร์ที่ติดตั้งใช้งานให้กับผู้ใช้ไฟรายใหญ่ (ความต้องการใช้พลังงานมากกว่า 30 กิโลวัตต์) เกือบค่าทุก 15 นาที มีการติดตั้งใช้งานทั่วทุกจังหวัดที่อยู่ในพื้นที่ความรับผิดชอบของการไฟฟ้าส่วนภูมิภาค โดยใช้ข้อมูลวิเคราะห์หลากหลายตัวแปร อาทิเช่น แรงดัน กระแส เพาเวอร์แฟกเตอร์ กำลังไฟฟ้าจริง กำลังไฟฟ้าเสมือน กำลังไฟฟ้าปรากฏ และหน่วยการใช้ไฟ เป็นต้น เริ่มต้นจากการทำความสะอาดข้อมูล และใช้เทคนิคการสกัดข้อมูลที่หลากหลายวิธี เช่น Z_{score} , TOU, Statistics , Frequency domain , trend, seasonality, auto-correlation, FFT, PSD, Wavelet transform และการแปลง Time series แปลงให้อยู่ในรูป 2D (image) เป็นต้น จากนั้นป้อนข้อมูลที่สกัดได้เข้าสู่โมเดลการเรียนรู้ของเครื่อง และการเรียนรู้เชิงลึก เพื่อประเมินผลลัพธ์ในหลากหลายมุมมอง หาโมเดลที่เหมาะสมกับชุดข้อมูล นอกจากนี้ชุดข้อมูลทั้ง 3 กลุ่มจะถูกนำมาปรับสมดุล (Data balancing) โดยใช้เทคนิคต่างๆ เพื่อเปรียบเทียบระหว่างการสมดุลกับไม่สมดุล และยังนำข้อมูลมาทำการจัดกลุ่ม (Clustering) เพื่อแยกประเภทผู้ใช้ไฟ หาโมเดลเฉพาะกลุ่ม เพื่อให้ได้โมเดลที่เหมาะสมและนำไปประยุกต์ใช้งานกับระบบบริหารจัดการมิเตอร์อ่านหน่วยอัตโนมัติ (AMR monitoring systems) ของ กฟภ. ได้


1.7 ขั้นตอนและวิธีการดำเนินการวิจัย

กระบวนการและวิธีการจำแนกลักษณะความผิดปกติระหว่างชำรุดกับละเมิดสำหรับมิเตอร์อ่านหน่วยอัตโนมัติ สามารถดำเนินการวิจัยตามภาพประกอบที่ 1-36 ได้ดังนี้

1. เริ่มต้นจากการศึกษาและวิเคราะห์ หาแนวทางการจำแนกความผิดปกติที่ส่งผลต่อกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิคที่ถูกรับใน กฟภ. ทั้ง 3 รูปแบบ คือ ลักษณะปกติ ชำรุดและละเมิด
2. รวบรวมข้อมูลจากฐานข้อมูลของ กฟภ. ได้แก่ ค่าสถิติข้อมูลพื้นฐานผู้ใช้ไฟ ค่าสัญญาณทางไฟฟ้า ค่าหน่วยการใช้ไฟ เป็นต้น อีกส่วนหนึ่งเป็นข้อมูลทางด้านกายภาพ เช่น จากคนจดหน่วย ข้อ

ร่องเรียน สภาพมิเตอร์ ฤดูกาล สภาพพื้นที่ สถานที่ตั้ง ข้อมูลจากโครงข่ายไฟฟ้า เป็นต้น ซึ่งข้อมูลทั้งหมดจะถูกนำมาทำความสะอาดข้อมูล และปรับข้อมูลให้เป็นมาตรฐานเดียวกัน

3. วิเคราะห์ข้อโดยใช้แผนภาพ กราฟสถิติ หาความสัมพันธ์ของข้อมูล (Correlation) และวาดกราฟแนวโน้มของข้อมูล (Visualization) เพื่อค้นหาพฤติกรรมและรูปแบบลักษณะความผิดปกติแต่ละชนิดที่เกิดขึ้น
4. ทำการสกัดข้อมูลโดยใช้องค์ความรู้พื้นฐานด้านระบบไฟฟ้า จากการทบทวนวรรณกรรมและใช้การแปลงอนุกรมเวลาเป็นรูปภาพ เนื่องด้วยแต่ละเทคนิคการสกัดมีจุดเด่นที่แตกต่างกัน จึงเปรียบเทียบผลลัพธ์โดยใช้โมเดลแต่ละชนิดจำแนก
5. ข้อมูลที่ได้จากการสกัดจะถูกจำแนก แบ่งออกเป็น 3 ลักษณะได้แก่ ปกติ ชำรุดและละเมิด จากนั้นเลือกใช้การเรียนรู้ของเครื่องและโมเดลการเรียนรู้เชิงลึกมาใช้วิเคราะห์ข้อมูล ซึ่งจะถูกนำมาทำการสมดุลและจัดกลุ่มเพื่อเพิ่มประสิทธิภาพ
6. แบ่งกลุ่มข้อมูลออกเป็น 3 ประเภทได้แก่ ข้อมูลสำหรับสอน (Train) ข้อมูลสำหรับปรับจูนโมเดล (Validation) และข้อมูลสำหรับทดสอบ (Test) เปรียบเทียบผล
7. ทดสอบและปรับจูนโมเดลเพื่อหาโมเดลที่เหมาะสมกับข้อมูลและให้ได้ประสิทธิภาพสูงสุด มีการปรับค่าพารามิเตอร์ในตัวโมเดล ปรับค่าการเรียนรู้และเปรียบเทียบผลลัพธ์
8. เมื่อได้โมเดลจากการประเมินผลแล้ว โมเดลจะถูกนำไปทดสอบกับข้อมูลจากเว็บไซต์ที่โมเดลไม่เคยรู้จักมาก่อนและทดสอบกับสถานการณ์จริง



ภาพประกอบที่ 1-18 กรอบแนวทางวิจัย

บทที่ 2

ทฤษฎีและหลักการ

ในบทนี้นำเสนอทฤษฎีและหลักการในรายละเอียดที่เกี่ยวข้องกับพลังงานไฟฟ้าสูญเสีย ทั้งทางด้านทางเทคนิค และไม่ใช้เทคนิค ระบบการอ่านหน่วยไฟฟ้าอัตโนมัติ การแปลงอนุกรมเวลาให้อยู่ในโดเมนความถี่และเวฟเล็ต รวมถึงเทคนิคที่ใช้จำแนกข้อมูลประกอบด้วย การเรียนรู้แบบมีผู้สอน การเรียนรู้แบบไม่มีผู้สอน และโครงข่ายประสาทเทียมคอนโวลูชันชนิดต่างๆ

2.1 รายละเอียดเกี่ยวกับพลังงานไฟฟ้าสูญเสีย

2.1.1 ผลกระทบและเกณฑ์วัดค่ากำลังไฟฟ้าสูญเสีย

โดยทั่วไปแล้วพลังงานไฟฟ้าสูญเสียในระบบจำหน่ายนั้นจะถูกคำนวณและแสดงค่าในรูปแบบของร้อยละของพลังงานที่ถูกส่งออกมาจากแหล่งกำเนิด เช่น ถ้าระบุว่ามิพลังงานไฟฟ้าสูญเสีย 10% เกิดขึ้นในระบบ หมายความว่าจะมีค่าพลังงานไฟฟ้าเพียง 90% เท่านั้นที่ถูกส่งผ่านไปยังผู้ใช้ไฟหรือโหลด แสดงว่าการไฟฟ้าฝ่ายจำหน่ายจะมีรายได้จากการจำหน่ายพลังงานไฟฟ้าเพียง 90% แต่ในความจริงการไฟฟ้าฝ่ายจำหน่ายจะต้องจ่ายเงิน 100% สำหรับซื้อเสมอ ดังนั้น 10% ที่สูญหายไปจากกำลังไฟฟ้าสูญเสีย นั้นจะถือว่าเป็นค่าใช้จ่ายในการดำเนินการอีกตัวหนึ่งของการไฟฟ้าฝ่ายจำหน่าย ในปี 2564 รายงานประจำปีระบุว่า การไฟฟ้าส่วนภูมิภาคซึ่งแบ่งออกเป็นเขตย่อยทั้งหมด 12 เขต [3] มีหน่วยที่รับซื้อไฟมาทั้งหมด 147,736.61 ล้านหน่วย สามารถจำหน่ายพลังงานไฟฟ้าได้เพียง 139,687.22 ล้านหน่วย มิพลังงานไฟฟ้าสูญเสียเกิดขึ้นในระบบเป็นจำนวน 8,049.39 ล้านหน่วย คิดเป็น 5.45 % ทำให้การไฟฟ้าส่วนภูมิภาคสูญเสียรายได้ในส่วนนี้ไปเป็นจำนวน 23,826.19 ล้านบาท (เมื่อราคาขายไฟเฉลี่ยต่อหน่วยเท่ากับ 2.96 บาท) นั่นคือจำนวนเงินที่ต้องสูญเสียไปในแต่ละปีอันเนื่องมาจากพลังงานไฟฟ้าสูญเสียคิดเป็นเงินจำนวนมาก ดังนั้นจึงถือได้ว่าปัญหาเรื่องพลังงานไฟฟ้าสูญเสียเป็นปัญหาที่สำคัญมากสำหรับการไฟฟ้าฝ่ายจำหน่าย

ตามหนังสือเลขที่ ผคพ. 94/2564 อนุมัติ ผวก. ลว. 4 มี.ค. 2564 เรื่อง กำหนดค่าเกณฑ์ประเมินผลหน่วยสูญเสียในระบบไฟฟ้าของ กฟภ. ประจำปี 2564 เพื่อให้แต่ละการไฟฟ้าส่วนภูมิภาค ระดับเขต ใช้เป็นเกณฑ์ในการควบคุมและวางแผนกำหนดมาตรการต่างๆ เพื่อลดค่าหน่วยสูญเสียในระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาคให้อยู่ในเกณฑ์ที่กำหนด และจากรายงานผลการดำเนินงานตาม

แผนงานลดหน่วยสูญเสียทางเทคนิค ปี 2564 สหสม 4 ไตรมาส (หนังสือเลขที่ กจฟ. 148/2565 ลว. 25 ก.พ. 2565) แสดงดังตารางที่ 2-1

ตารางที่ 2-1 ข้อมูลหน่วยสูญเสียของ กฟภ. แยกรายเขต ปี 2564 สหสม 4 ไตรมาส [3]

เขต	หน่วยซื้อ	หน่วยจำหน่าย	หน่วยสูญเสียรวม	
	(ล้านหน่วย)	(ล้านหน่วย)	(ล้านหน่วย)	%
กฟน.1	8,499.61	7,961.20	538.42	6.33
กฟน.2	6,567.27	6,071.13	496.13	7.55
กฟน.3	7,418.34	6,841.81	576.54	7.77
กฟฉ.1	8,251.38	7,610.45	640.93	7.77
กฟฉ.2	7,369.74	6,780.67	589.07	7.99
กฟฉ.3	10,242.41	9,669.04	573.37	5.60
กฟก.1	24,741.99	23,784.14	957.85	3.87
กฟก.2	32,408.52	31,357.90	1050.62	3.24
กฟก.3	18,211.53	17,252.71	958.82	5.26
กฟต.1	7,636.07	7,063.54	572.54	7.50
กฟต.2	9878.33	9,204.66	673.67	6.82
กฟต.3	6511.42	6,089.99	421.43	6.47
รวม	147,736.61	139,687.22	8,049.39	5.45

ค่าพลังงานไฟฟ้าสูญเสียตามตารางที่ 2-1 เป็นรายงานข้อมูลจากแต่ละเขตรายงานให้กับกองควบคุมการจ่ายไฟ เพื่อรวบรวมและเก็บข้อมูลไว้สำหรับกำหนดแผนและค่าเกณฑ์วัดในปี 2565 จะคำนวณโดยการนำเอาหน่วยพลังงานไฟฟ้าที่การไฟฟ้าส่วนภูมิภาค รับซื้อมาจากการไฟฟ้าฝ่ายผลิตร่วมกับหน่วยที่การไฟฟ้าส่วนภูมิภาคผลิตได้เอง หักออกด้วยหน่วยพลังงานไฟฟ้าที่การไฟฟ้าส่วนภูมิภาคขายให้กับผู้ใช้ไฟและหน่วยงานที่ใช้ไฟสาธารณะ

2.1.2 ประเภทของกำลังไฟฟ้าสูญเสีย

เนื่องจากระบบจำหน่ายของการไฟฟ้าส่วนภูมิภาค มีทั้งระบบจำหน่ายแรงดันสูง แรงดันปานกลาง และแรงดันต่ำ เมื่อพิจารณาถึงกำลังไฟฟ้าสูญเสียในแต่ละระบบจะเกิดขึ้นแตกต่างกัน สามารถแบ่งออกเป็น 2 ประเภทหลัก [24] คือ

2.1.2.1 กำลังไฟฟ้าสูญเสียทางเทคนิค (Technical Losses)

เป็นกำลังไฟฟ้าสูญเสียที่เป็นผลเกี่ยวเนื่องกับความร้อนที่เกิดขึ้นในขดลวด สายตัวนำ หรือส่วนที่เกิดจากการทำงานของหม้อแปลงไฟฟ้าและอุปกรณ์ไฟฟ้าต่างๆ ทั้งนี้รวมถึงกำลังไฟฟ้าสูญเสียที่เกิดจากการเชื่อมต่ออุปกรณ์ ค่าความเป็นฉนวนของอุปกรณ์หรือสายไฟ การเกิดโคโรนาหรือการปล่อยประจุบางส่วน (Partial discharge) ในระบบไฟฟ้า ตามทฤษฎีกำลังไฟฟ้าสูญเสียทางด้านเทคนิคในระบบจำหน่ายส่วนหนึ่งเป็นกำลังไฟฟ้าที่เกิดมาจากประเภท ขนาด และการจัดวางของส่วนประกอบของระบบไฟฟ้า (Network Topology, τ) ขนาดของแรงดันไฟฟ้า (V) และปริมาณความต้องการพลังงานไฟฟ้าที่จุดต่างๆ (D) [24] ซึ่งจะสามารถเขียนความสัมพันธ์ระหว่างกำลังไฟฟ้าสูญเสีย กับพารามิเตอร์ต่างๆ ได้ตามสมการ (2-1)

$$P_{losses} = f(V, D, \tau) \quad (2-1)$$

เมื่อ P_{losses} คือกำลังไฟฟ้าสูญเสียทางด้านเทคนิค (w)

จากความสัมพันธ์ของ P_{losses} สามารถทำการคำนวณหาค่าพลังงานไฟฟ้าสูญเสียในช่วงเวลาที่ต้องการได้จากสมการ (2-2)

$$E_{losses} = \int_{T_{st}}^{T_{ed}} P_{losses}(t) dt \quad (2-2)$$

เมื่อ E_{losses} คือ พลังงานไฟฟ้าสูญเสีย (Wh) , $P_{losses}(t)$ คือกำลังไฟฟ้าสูญเสียที่เปลี่ยนแปลงตามเวลา (w) และ T_{st} คือ ช่วงเวลาเริ่มต้น T_{ed} คือ ช่วงเวลาสิ้นสุด

ซึ่งเมื่อพิจารณาจากสภาวะของโหลดโดยทั่วไปแล้วกำลังไฟฟ้าสูญเสียทางเทคนิคในระบบไฟฟ้าสามารถแยกออกได้เป็น 2 ประเภท [25] คือ

1. กำลังไฟฟ้าสูญเสียแบบคงที่ (Fix Losses) เป็นกำลังไฟฟ้าสูญเสียที่ไม่เปลี่ยนแปลงตามขนาดของโหลด กำลังไฟฟ้าสูญเสียดังกล่าวจะไม่เป็นไปตามสมการ I^2R โดยชนิดของกำลังไฟฟ้าสูญเสียแบบนี้ ได้แก่ กำลังไฟฟ้าสูญเสียในแกนเหล็ก (Core losses) ของหม้อแปลงในระบบจำหน่าย การตัดต่อวงจรในระบบไฟฟ้ากำลัง กระแสรั่วไหลภายในสถานีไฟฟ้า เป็นต้น

2. กำลังไฟฟ้าสูญเสียแบบไม่คงที่ (Variable Losses) เป็นกำลังไฟฟ้าสูญเสียที่เกิดจากกระแสไหลผ่านตัวต้านทานทำให้เกิดพลังงานไฟฟ้าสูญเสียในรูปของพลังงานความร้อน เป็นไปตามสมการ I^2R ซึ่งกำลังไฟฟ้าสูญเสียดังกล่าวจะเกิดขึ้นทุกส่วนของระบบ

เมื่อพิจารณาถึงกำลังไฟฟ้าสูญเสียทางเทคนิคในระบบจำหน่ายไฟฟ้า สามารถแยกประเภทของกำลังไฟฟ้าตามที่มาของส่วนประกอบต่างๆในระบบจำหน่าย แบ่งออกได้ 4 ส่วนหลัก ได้แก่

- ก. กำลังไฟฟ้าสูญเสียในสายป้อน
- ข. กำลังไฟฟ้าสูญเสียในหม้อแปลงจำหน่ายไฟฟ้า
- ค. กำลังไฟฟ้าสูญเสียเนื่องจากจุดต่อของอุปกรณ์
- ง. กำลังไฟฟ้าสูญเสียในสายแรงต่ำ

2.1.2.2 กำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (Non-Technical Losses)

เป็นกำลังไฟฟ้าสูญเสียที่เกี่ยวข้องกับการวัดค่าพลังงานที่ไม่ถูกต้อง ความผิดพลาดของการอ่านหน่วย ความคลาดเคลื่อนของอุปกรณ์วัดปริมาณไฟฟ้าหรือการติดตั้งมิเตอร์วัดค่าพลังงานไม่ถูกต้องครบถ้วน รวมถึงส่วนที่เกี่ยวข้องกับกระบวนการพิมพ์บิล เช่น การเรียกเก็บเงินการใช้พลังงานของลูกค้าไม่ถูกต้อง และการละเมิด การขโมยไฟ หรือการโจรกรรมที่ตัวมิเตอร์ ทำให้มิเตอร์อ่านหน่วยการใช้ไฟฟ้าได้น้อยกว่าความเป็นจริง สามารถแบ่งประเภทของกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค [2] ที่พบในการไฟฟ้าส่วนภูมิภาคได้ดังนี้

ก. การละเมิดหรือการขโมยไฟ

การละเมิดหรือการขโมยไฟเป็นสาเหตุหลักที่ส่งผลให้เกิดกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค (NTL) เนื่องด้วยค่าพลังงานที่เครื่องวัดค่าอ่านได้ไม่ถูกต้อง ค่าที่อ่านได้น้อยกว่าปริมาณการใช้ไฟจริง เป็นความตั้งใจของผู้ใช้ไฟส่งผลให้หน่วยการใช้ไฟส่วนหนึ่งหายไป สาเหตุการละเมิด การขโมยไฟ หรือการโจรกรรมที่ตัวมิเตอร์ เกิดจากผู้ที่ใช้ไฟกระทำบางอย่างกับตัวมิเตอร์ เช่น การแก้ไขเปลี่ยนแปลง

ภายในมิเตอร์หรือภายนอก ทำให้มิเตอร์ทำงานผิดพลาดวัด ค่าพลังงานไฟฟ้าคลาดเคลื่อนจากสภาพความเป็นจริง และการต่อตรงจากระบบจำหน่ายของ กฟภ. โดยตรง ไม่ผ่านมิเตอร์เหล่านี้ เป็นอีกสาเหตุหนึ่งของการสูญเสียพลังงานไฟฟ้า ผู้ใช้ไฟรายใหญ่ทั้งประเภทธุรกิจ หรืออุตสาหกรรมหากได้มีการละเมิด แล้วจะทำให้การสูญเสียเกิดขึ้นได้เป็นจำนวนมาก และในปัจจุบันอาคารตึกแถวมีจำนวนมาก มีการตกแต่งหน้าร้านปิดบังไม่สามารถตรวจสอบสายเมนชายคาได้ การกระทำดังกล่าวอาจก่อให้เกิดการละเมิดเกิดขึ้นได้ เนื่องจากพนักงานช่างไม่สามารถเข้าตรวจสอบที่ตัวมิเตอร์ได้ ซึ่งในการไฟฟ้าส่วนภูมิภาคพบลักษณะการละเมิดหลากหลายรูปแบบ แบ่งตามประเภทมิเตอร์ที่ใช้งานได้ 2 ประเภท ได้แก่

■ การละเมิดมิเตอร์ 1 เฟส

มิเตอร์ 1 เฟส ติดตั้งใช้งานให้กับผู้ใช้ไฟรายย่อยและผู้ใช้ไฟประเภทต่างๆ เช่น บ้านที่อยู่อาศัย ร้านค้า วัด ธุรกิจขนาดเล็ก ไฟสาธารณะ ไฟเทศบาล ไฟทางหลวง เป็นต้น ซึ่งโดยส่วนใหญ่เป็นมิเตอร์ประเภท Electromagnetic หรือแบบจานหมุน ตัวอย่างรูปแบบเหตุการณ์ละเมิดแสดงดังภาพประกอบที่ 2-1 การละเมิดที่ถูกรับใน กฟภ. ได้แก่

- สลับสายระหว่างสายเฟสและสายนิวทรัลด้านหน้าก่อนเข้ามิเตอร์
- การติดตั้งสายดินร่วมกับสายนิวทรัล
- ปลดวงจรนิวทรัลด้านหน้าก่อนเข้ามิเตอร์
- ติดตั้งอุปกรณ์ตัดต่อภายในโดยใช้สายดินร่วมกับสายนิวทรัล
- ต่อไฟฟ้าไปใช้งานโดยไม่ผ่านมิเตอร์ หรือต่อลัดลงจร Current Coil
- ตัด งดแฉะ ปลอมแปลงตราตะกั่ว
- คิว่า เอียงมิเตอร์ และการละเมิดในกรณีอื่น ๆ




ภาพประกอบที่ 2-1 ตัวอย่างเหตุการณ์ละเมิดมิเตอร์ 1 เฟส ที่ถูกรับ

■ การละเมิดมิเตอร์ 3 เฟส /ประกอบCT แรงต่ำ และแรงสูง

มิเตอร์ 3 เฟส ติดตั้งใช้งานให้กับผู้ใช้ไฟรายใหญ่ เช่น บริษัท โรงงาน โรงแรม หน่วยงานราชการ เป็นต้น มิเตอร์ที่ติดตั้งใช้งานมีหลายประเภทขึ้นอยู่กับประเภทอัตราของผู้ใช้ไฟ เช่น มิเตอร์งานหมุนธรรมดามีมิเตอร์ประเภท TOU มิเตอร์ประเภท AMR เป็นต้น ตัวอย่างรูปแบบการละเมิดแสดงดังภาพประกอบที่ 2-2 การละเมิดที่พบ ได้แก่


- สลับสาย สายเข้าเป็นสายออกหรือต่อสายสลับชุดหรือสลับกับสายนิวทอล
- ต่อลัดวงจร Current Coil
- แกะหรือจัดแงะ, ตัดตราตะกั่ว, ปลอมแปลงตราตะกั่ว
- ต่อไฟตรงโดยไม่ผ่านมิเตอร์
- การละเมิดที่ชุดสาย Control ทุกกรณี
- การละเมิดด้านซอฟต์แวร์



ภาพประกอบที่ 2-2 ตัวอย่างเหตุการณ์ละเมิดมิเตอร์ 3 เฟส ที่ถูกพบ

ข. มิเตอร์วัดค่าได้ไม่ถูกต้อง

ความสูญเสียอันเนื่องมาจากความไม่ถูกต้องในวัดค่าของเครื่องวัดหรือมิเตอร์ หมายถึง ความแตกต่างระหว่างปริมาณพลังงานที่ส่งผ่านมิเตอร์จริงกับปริมาณที่มิเตอร์อ่านค่าได้ เครื่องวัดพลังงานทั้งหมดที่ติดตั้งใช้งานจะต้องมีการตรวจสอบตามแผนการตรวจสอบประจำปีเพื่อทำการสอบเทียบหรือตรวจสอบค่าความผิดพลาดในตัวมิเตอร์ว่ายังอยู่ในเกณฑ์มาตรฐาน ดังภาพประกอบที่ 2-3



ภาพประกอบที่ 2-3 ตัวอย่างเหตุการณ์มิเตอร์วัดค่าได้ไม่ถูกต้อง

ค. เกิดจากพฤติกรรมของโหลดบางชนิด

ในช่วงเวลาจ่ายโหลดสูงสุด แรงดันไฟฟ้าที่ปลายสายมักตกหรือต่ำกว่าแรงดันปกติ ตัวอย่างอุปกรณ์ที่ใช้มอเตอร์เป็นองค์ประกอบ เมื่อแรงดันไฟฟ้าลด มอเตอร์จะต้องการกระแสไฟฟ้ามากขึ้นเพื่อให้พลังงานเกือบคงที่ เกิดการไหลของกระแสไฟฟ้ามากขึ้น ทำให้การสูญเสียในระบบสายส่ง ระบบจำหน่าย หม้อแปลงไฟฟ้ามากขึ้นตาม และโหลดอีกประเภทคือ ไฟสาธารณะ ไฟทางหลวง ไฟเหมาจ่าย เช่น Wi-Fi, CCTV โหลดดังกล่าวในบางครั้งเกิดความผิดพลาดจากอุปกรณ์ตัดต่อการทำงาน เช่น ไฟทางหลวงติดเองตอนกลางวัน หรือชุดกล่อง Wi-Fi, CCTV เกิดไฟรั่ว หรืออุปกรณ์ควบคุมการทำงานชำรุด ปัจจัยดังกล่าวส่งผลให้เกิดหน่วยสูญเสียเกิดขึ้นเช่นกัน ตัวอย่างแสดงดังภาพประกอบที่ 2-4



ภาพประกอบที่ 2-4 ตัวอย่างเหตุการณ์เกิดจากพฤติกรรมของโหลดบางชนิด

ง. ความผิดพลาดในการอ่านค่าของเครื่องวัดหรือมิเตอร์


มิเตอร์ที่ติดตั้งใช้งานควรมีการสอบเทียบเมื่อครบตามวาระในทวนสอบการวัดพลังงานไฟฟ้า ควรเปลี่ยนเครื่องวัดพลังงานที่ชำรุดทันที มิเตอร์ที่ชำรุดเกิดขึ้นได้หลายสาเหตุ เช่น การเผาไหม้ของมิเตอร์จากการใช้โหลดเกินพิกัด กล่องข้าวต่อสายของมิเตอร์ชำรุด อัตราส่วน CT ที่ไม่เหมาะสม อุปกรณ์ประกอบเครื่องวัดทำงานผิดพลาด และการเพิ่มโหลดภายในหรือเพิ่มขนาดหม้อแปลงโดยไม่แจ้งทางการไฟฟ้าส่วนภูมิภาค เป็นต้น ตัวอย่างแสดงดังภาพประกอบที่ 2-5



ภาพประกอบที่ 2-5 ตัวอย่างความผิดพลาดในการอ่านค่าของเครื่องวัดหรือมิเตอร์

จ. ปัญหาการเรียกเก็บเงิน

การเรียกเก็บเงินที่ผิดพลาดและไม่ถูกต้อง จัดเป็นส่วนหนึ่งของกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค รวมถึงเรื่องร้องเรียนเกี่ยวกับการพิมพ์บิลค่าไฟ การเรียกเก็บเงินไม่แจกบิล รับบิลซ้ำ ออกบิลผิด อ่านมิเตอร์ผิด คิดค่าไฟฟ้าผิด แจกบิลสลับ เป็นต้น เป็นสิ่งที่คุณภาพการบริการเกิดจากตัวบุคคล ตัวอย่างแสดงดังภาพประกอบที่ 2-6



ภาพประกอบที่ 2-6 ตัวอย่างความผิดพลาดจากการเรียกเก็บเงิน

2.1.3 มาตรการลดหน่วยสูญเสียของการไฟฟ้าส่วนภูมิภาค

มาตรการด้านการดำเนินงานลดค่ากำลังไฟฟ้าสูญเสียที่เกิดขึ้นของการไฟฟ้าส่วนภูมิภาค แบ่งออกเป็น 2 มาตรการหลัก [25] ประกอบด้วย

2.1.3.1 มาตรการลดหน่วยสูญเสียทางด้านเทคนิค (Technical Losses)

- ก. การจ่ายไฟสถานีไฟฟ้า (ชั่วคราว, ถาวร)
- ข. การตัดจ่ายไฟใหม่ระบบ 22/33kV
- ค. การเปลี่ยนสายขนาดใหญ่ขึ้น
- ง. การแก้ไขระบบ 22/33kV Unbalance เกินกว่า 10% โหลดสูงกว่า 5 MW
- จ. การติดตั้ง Capacitor 22/33kV (fixed และแบบ switching)
- ฉ. การแก้ไขคาปาซิเตอร์ 22/33kV ที่หลุดจากระบบให้ใช้งานได้
- ช. งานลดหน่วยสูญเสียทางเทคนิค แยกตามระดับแรงดัน
- ซ. แผนงานลดหน่วยสูญเสียทางเทคนิค แยกตามระดับแรงดัน
- ฌ. หม้อแปลงจำหน่าย (Unbalance เกิน 20%, โหลดเกิน 80%, แรงดันตก)
- ญ. ระบบจำหน่ายแรงต่ำ (การเปลี่ยนสายขนาดใหญ่ขึ้น, การตัดจ่ายใหม่)

2.1.3.2 มาตรการลดหน่วยสูญเสียที่ไม่ใช่ทางเทคนิค (Non-Technical Losses) ประกอบด้วย [7]

- ก. การตรวจสอบมิเตอร์สำหรับผู้ใช้ไฟรายย่อย (NL1)
- ข. การตรวจสอบมิเตอร์สำหรับผู้ใช้ไฟรายใหญ่
- ค. การตรวจสอบและแก้ไขมิเตอร์ที่มีสภาพผิดปกติ (NL2)
- ง. สํารวจและปรับปรุงอุปกรณ์ประกอบมิเตอร์ (Patrol Meter 05)
- จ. มาตรการตรวจสอบมิเตอร์ตามวาระ
- ฉ. การตรวจสอบมิเตอร์ที่มีความเสี่ยงต่อการละเมิดและมีประวัติละเมิด
- ช. การตรวจสอบมิเตอร์ไฟสาธารณะ ไฟทางหลวง อุปกรณ์สื่อสารต่างๆ
- ซ. การลดหน่วยสูญเสียของสถานีไฟฟ้า (NL3)
- ฅ. การตรวจสอบมิเตอร์ประกอบซีที แรงต่ำ และประกอบซีที วีที แรงสูง
- ญ. การอบรมเกี่ยวกับการตรวจสอบมิเตอร์ การประชาสัมพันธ์และรณรงค์

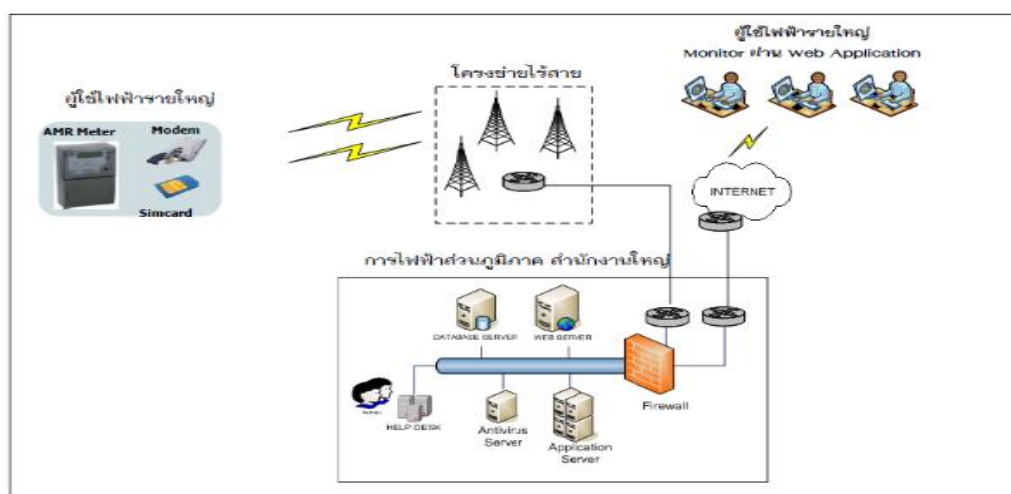
จากการวิเคราะห์ข้อมูลและประเภทของมิเตอร์ที่ติดตั้งใช้งานในการไฟฟ้าส่วนภูมิภาค นั้น มีหลากหลายชนิดแสดงตัวอย่างดังรูปภาพประกอบที่ 2-7 มิเตอร์แต่ละชนิดจะมีฟังก์ชันการทำงาน และการเข้าถึงข้อมูลที่แตกต่างกัน ดังนั้นเมื่อพิจารณาจากผลกระทบที่มีต่อหน่วยสูญเสียที่ไม่ใช่ทางเทคนิคและรายละเอียดของชุดข้อมูล ในงานวิจัยนี้เลือกมิเตอร์ AMR มาใช้ในการศึกษา ซึ่งจะอธิบายในหัวข้อลำดับถัดไป



ภาพประกอบที่ 2-7 ประเภทมิเตอร์ที่มีติดตั้งใช้งานใน กฟภ.

2.2 การอ่านหน่วยไฟฟ้าอัตโนมัติ (Automatic Meter Reading: AMR)

โครงการพัฒนาการอ่านหน่วยด้วยระบบอัตโนมัติสำหรับผู้ใช้ไฟฟ้ารายใหญ่ (Automatic meter reading: AMR) [26] ที่การไฟฟ้าส่วนภูมิภาคได้ลงทุนแบ่งเป็น 2 ระยะ ระยะที่ 1 จำนวน 30,000 ราย ซึ่งดำเนินการระหว่างปี 2549-2552 และระยะที่ 2 จำนวน 50,000 ราย ซึ่งดำเนินการระหว่างปี 2554-2557 โดยมีวัตถุประสงค์เพื่อให้ผู้ใช้ไฟฟ้าของ กฟภ. เกิดความมั่นใจว่าการอ่านหน่วยไฟฟ้า มีความถูกต้อง รวดเร็ว โปร่งใส สร้างความพึงพอใจให้กับลูกค้า เพิ่มประสิทธิภาพการให้บริการของ กฟภ. ให้ดียิ่งขึ้น และมีภาพลักษณ์ด้านการบริการที่ดี ตัวอย่างโครงสร้างของระบบ AMR ดังภาพประกอบที่ 2-8



ภาพประกอบที่ 2-8 โครงสร้างของระบบ AMR [26]

ลักษณะการทำงานของระบบ AMR

- ก. ระบบ AMR จะทำหน้าที่ในการอ่านข้อมูลจากมิเตอร์ผ่านอุปกรณ์ MIU (Meter Interface Unit) และเครือข่ายไร้สาย (GPRS) โดยส่งข้อมูลการใช้ไฟฟ้าของแต่ละรายทุกๆ 15 นาที มาเก็บไว้ใน Server ที่ตั้งอยู่ที่ศูนย์ AMR อาคาร 12 การไฟฟ้าส่วนภูมิภาค
- ข. ระบบ AMR Software จะทำการประมวลผลข้อมูลของมิเตอร์แต่ละเครื่องเพื่อส่งข้อมูลการใช้ไฟฟ้าของผู้ใช้ไฟฟ้าแต่ละราย ให้หน่วยงานที่รับผิดชอบในการพิมพ์ใบแจ้งค่าไฟฟ้า และยังมี ความสามารถที่จะนำข้อมูลการใช้ไฟฟ้าของผู้ใช้ไฟฟ้าแต่ละรายมาแสดงผลผ่าน Web Application เพื่อให้ผู้ใช้ไฟฟ้าแต่ละรายสามารถตรวจสอบปริมาณการใช้ไฟฟ้าของตนเองได้

- ค. กรณีเกิดปัญหาจากการใช้งาน เช่น มิเตอร์ชำรุด หรือมีการละเมิดการใช้ไฟฟ้า ระบบจะแจ้งเตือน กลับมายังศูนย์ AMR โดยอัตโนมัติ ทำให้ผู้ดูแลระบบรับทราบ และสามารถแจ้งการไฟฟ้าหน้า งาน เพื่อเข้าทำการตรวจสอบมิเตอร์ได้ทันที
- ง. กรณีมีการเปิดฝาตู้มิเตอร์ ได้กำหนดให้ระบบ AMR จะต้องแจ้งสถานะ การเปิดฝาตู้มิเตอร์ ส่งกลับมายังศูนย์ AMR หรือผู้รับผิดชอบได้ในทันทีซึ่งช่วยแจ้งเตือนการละเมิดการใช้ไฟฟ้าได้
- จ. กรณีเกิดปัญหาที่ระบบ GPRS ไม่สามารถรับ-ส่งข้อมูลการใช้ไฟฟ้าของผู้ใช้ไฟแต่ละราย โครงการ AMR ได้จัดทำระบบสำรอง (Backup) การรับ-ส่งข้อมูลขึ้นมาอีก 1 ระบบ คือ ระบบ GSM หรือ PSTN ซึ่ง กฟภ. ยังคงรับ-ส่งข้อมูลการใช้ไฟฟ้ากลับมายังศูนย์ AMR ได้ตลอดเวลา
- ฉ. ลักษณะของข้อมูลการใช้ไฟฟ้าที่ได้จากการอ่านผ่านระบบ AMR ข้อมูลการใช้ไฟฟ้าทุกๆ 15 นาที สามารถแสดงผลได้แบบเป็นรายวัน รายเดือน และรายปี อีกทั้งยังสามารถทำการเปรียบเทียบ การใช้ไฟฟ้าในแต่ละช่วงเวลาที่กำหนดได้
- ช. ระยะเวลาการติดตั้งใช้งานจะมีหน่วยงานที่ทำหน้าที่ตรวจสอบและวางแผนบำรุงรักษาประจำปี เป็นประจำทุกปี โดยในการตรวจสอบจะทำงานร่วมกับพนักงานของการไฟฟ้านั้นๆ เพื่อรับฟังถึง ปัญหาและแนวทางปรับปรุง

ตารางที่ 2-2 ประโยชน์ที่ได้รับจากการนำระบบการอ่านหน่วยไฟฟ้าอัตโนมัติ (AMR) มาใช้งาน [26]

ประโยชน์ที่ลูกค้าได้รับ	ประโยชน์ที่ กฟภ. ได้รับ
<ul style="list-style-type: none"> - สามารถตรวจสอบข้อมูลการใช้ไฟฟ้าของตนเอง ผ่าน Internet ได้ตลอดเวลา - สามารถเก็บข้อมูล Load profile ของตนเอง ผ่านทาง Web Site เพื่อจัดทำ Demand Management สำหรับกิจการของตนเองได้ - สามารถตรวจสอบคุณภาพของไฟฟ้าได้ - ลดข้อผิดพลาดในกระบวนการจดหน่วย - ลดข้อผิดพลาดในเรื่องของมาตรฐานเวลาในตัว มิเตอร์ - นำข้อมูล Load Profile มาใช้วางแผน กระบวนการผลิตได้ 	<ul style="list-style-type: none"> - ประหยัดเวลา ลดค่าใช้จ่าย ลดขั้นตอนจากการอ่านมิเตอร์ ทั้งด้านพนักงานและค่าล่วงเวลา - ช่วยลดหน่วยสูญเสีย ของ กฟภ. โดยสามารถ ตรวจสอบการทำงานของมิเตอร์และดำเนินการ ตรวจสอบได้ทันที กรณีที่มีการละเมิดหรือตรวจ พบการชำรุดของมิเตอร์และอุปกรณ์ประกอบ - นำข้อมูล Load Profile (ลักษณะการใช้ไฟฟ้า) ที่อ่านค่าได้จากมิเตอร์ ไปใช้ในการกำหนด โครงสร้างอัตราค่าไฟฟ้า - นำข้อมูล มาใช้วางแผนสำหรับจ่ายไฟฟ้า ซ่อม บำรุงรักษาสายส่งและพยากณ์ก่อสร้างสถานี

โดยรวมแล้วการนำระบบการอ่านหน่วยไฟฟ้าอัตโนมัติ (AMR) มาใช้งานมีข้อดีทั้งในส่วน
ของ กฟภ. และลูกค้า สามารถสรุปเป็นตารางแสดงได้ดังตารางที่ 2-2 แต่ถึงอย่างไรก็ตามการติดตั้ง
มิเตอร์ AMR แต่ละเครื่องยังมีค่าใช้จ่ายที่สูง กฟภ. จะติดตั้งให้เฉพาะลูกค้ารายใหญ่สำคัญเท่านั้น

จากการทบทวนวรรณกรรม มีหลากหลายเทคนิคที่นำมาใช้ในการวิเคราะห์ เพื่อคำนวณ
เป็นชุดคุณลักษณะของข้อมูล ในหัวข้อลำดับถัดไปจะนำเสนอทฤษฎีและหลักการที่นำมาใช้ในการศึกษา
ซึ่งประกอบด้วย การแปลงข้อมูลเป็นโดเมนความถี่ การแปลงโดยใช้เวฟเล็ต

2.3 การแปลงจากอนุกรมเวลาเป็นโดเมนความถี่ (Time Domain to Frequency Domain)

การแปลงข้อมูลจากโดเมนเวลาให้อยู่ในโดเมนความถี่ (Frequency domain) เป็น
เทคนิคหนึ่งที่สามารถนำมาปรับใช้ในการตรวจจับความผิดปกติของกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค
ได้ [27] เทคนิคที่นิยมใช้คือการแปลงฟูเรียร์ (Fourier transform) ซึ่งเป็นการแปลงทางคณิตศาสตร์ที่มี
การแยกองค์ประกอบ โดยมีฟังก์ชันขึ้นอยู่กับพื้นที่หรือเวลา เปลี่ยนแปลงตามความถี่เชิงพื้นที่หรือความถี่
ชั่วคราว ในการแปลงนิยมใช้ออนุกรมฟูเรียร์ (Fourier series) ผ่านเครื่องมือทางคณิตศาสตร์ในการแทน
สัญญาณคาบ (periodic signal) และสัญญาณไม่เป็นคาบ (aperiodic signal) ด้วยผลรวมเชิงเส้นของเลข
ชี้กำลังเชิงซ้อน ค่าที่ได้จากการแปลงถูกเรียกว่า สเปกตรัม (Spectrum) ในโดเมนความถี่จะทำให้ทราบถึง
แบนวิดท์ (Bandwidth) และรูปร่างของสเปกตรัมของสัญญาณ สามารถนำไปประยุกต์ใช้งานได้
หลากหลาย เช่น วงจรกรอง (Filter) อีควอลไลเซอร์ (Equalizer) เป็นต้น

การแปลงฟูเรียร์ พิจารณาสัญญาณ $X_p(t)$ ที่มีคาบเวลาเท่ากับ T และสัญญาณไม่เป็น
คาบ $X(t)$ เมื่อพิจารณาว่าคาบเวลา T มีค่าเข้าใกล้ค่าอนันต์จะได้ว่า $X_p(t)$ และ $X(t)$ คือสัญญาณเดียวกัน
สามารถเขียนให้อยู่ในรูปของอนุกรมฟูเรียร์ที่ต่อเนื่องทางเวลาได้ ดังสมการที่ (2-3) และ (2-4)

$$X_p(t) = \sum_{k=-\infty}^{\infty} a_k e^{jk\omega_0 t} \quad (2-3)$$

และ

$$a_k = \frac{1}{T} \int_{-T/2}^{T/2} X(t) e^{-jk\omega_0 t} dt \quad (2-4)$$

เมื่อ $\omega_0 = 2\pi / T$ หรือ $\omega_0 = 2\pi f$ คือความถี่เชิงมุมมีหน่วยเป็นเรเดียนต่อวินาที และพบว่าสัญญาณ
 $X(t) = X_p(t)$ ในช่วงเวลา $|t| < T / 2$ และ $|t| > -T / 2$ สำหรับ $T = 2\pi / \omega_0$

การแปลงฟูรีเยร์สามารถแปลงสัญญาณ $X(t)$ ให้อยู่ในรูปขององค์ประกอบของเลขชี้กำลังเชิงซ้อนที่ครอบคลุมทุกย่านความถี่ โดยค่าของ $X(j\omega)$ จะบ่งบอกขนาดของแอมพลิจูดของแต่ละองค์ประกอบความถี่ ω

สเปกตรัมฟูรีเยร์ (Fourier Spectrum) โดยทั่วไปผลการแปลงฟูรีเยร์ $X(j\omega)$ สามารถเขียนให้อยู่ในรูปของฟังก์ชันเลขชี้กำลังเชิงซ้อนที่เป็นฟังก์ชันของความถี่เชิงมุม ω ได้ดังสมการที่ (2-5) และ (2-6)

$$X(j\omega) = |X(j\omega)|e^{j\angle X(j\omega)} \quad (2-5)$$


$$\angle X(j\omega) = \tan^{-1} \left(\frac{\text{Im}\{X(j\omega)\}}{\text{Re}\{X(j\omega)\}} \right) \quad (2-6)$$

เมื่อ $|X(j\omega)|$ คือสเปกตรัมของแอมพลิจูดแบบต่อเนื่อง (Continuous amplitude spectrum)


และ $\angle X(j\omega)$ คือ สเปกตรัมเฟสแบบต่อเนื่อง (Continuous amplitude spectrum) สัญญาณ $X(t)$

ในทางปฏิบัติสเปกตรัมเชิงแอมพลิจูด $|X(j\omega)|$ และสเปกตรัมเชิงเฟส $\angle X(j\omega)$ รวมกันเรียกว่า

สเปกตรัมฟูรีเยร์ (Fourier spectrum) ตัวอย่างการแปลง DFT และ PSD แสดงดังภาพประกอบที่ 2-9



แรงดันเฟส A ปกติ



ภาพประกอบที่ 2-9 การวิเคราะห์สัญญาณรายคาบด้วยการแปลงฟูรีเยร์

2.4 การแปลงอนุกรมเวลาโดยวิธีเวฟเล็ต (Wavelet Transform)

การแปลงเวฟเล็ต (Wavelet Transform) เป็นกระบวนการทางคณิตศาสตร์วิธีหนึ่งที่ใช้ในการอธิบายโครงสร้างของระบบสัญญาณที่ประกอบด้วยสัญญาณเฉพาะหลายๆสัญญาณมารวมกันเป็นสัญญาณหนึ่ง [27] โดยสัญญาณเฉพาะนี้จะเป็รูปคลื่นเล็กๆที่เรียกว่า “เวฟเล็ต” สัญญาณขนาดเล็กที่ใช้ อธิบายการแปลงแบบเวฟเล็ต เรียกฟังก์ชันนี้ว่า Mother Wavelet โดยที่คลื่นเวฟเล็ตแต่ละอันในกลุ่มจะ เกิดจากการปรับสเกล (Scale ; a) จากการหดหรือการยืดของ Mother Wavelet และอีกส่วนคือการเลื่อน ของตำแหน่ง (Translation or Shifting ; b) เป็นการเปลี่ยนแปลงตำแหน่งของแกนเวลา ภาพประกอบที่ 2-10 จากความสัมพันธ์ดังกล่าวสามารถเขียนเป็นสมการของเวฟเล็ตได้ดังสมการที่ (2-7)


$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (2-7)$$

เมื่อ $\psi(t)$ คือ ฟังก์ชันของ Mother Wavelet ปรับ Scale, Translation ได้


a คือ พารามิเตอร์สำหรับปรับ Scaling

b คือ พารามิเตอร์สำหรับเลื่อนตำแหน่ง Shifting

การปรับค่าสเกลแล้วซึ่งพลังงานเท่ากับ Mother Wavelet ค่าที่ได้จากการปรับมีค่า $\frac{1}{\sqrt{a}}$ โดยทั่วไป นั้นสามารถแบ่งออกได้เป็น 2 แบบ คือการแปลงเวฟเล็ต CWT และการแปลงเวฟเล็ตแบบเต็มหน่วย DWT ตัวอย่างการแปลง CWT แสดงดังภาพประกอบที่ 2-9 และแสดงการเปรียบเทียบระหว่างค่า Time series กับการแปลงเวฟเล็ตแสดงดังรูปภาพที่ 2-11



ภาพประกอบที่ 2-10 การวิเคราะห์สัญญาณด้วยฟังก์ชัน Discrete wavelet transform [27]



ภาพประกอบที่ 2-11 การแปลง Time series โดยใช้ Wavelet transform

ปัญญาประดิษฐ์ (Artificial Intelligence) หรือ เอไอ (AI) [21] เป็นสิ่งหนึ่งที่ถูกนำมาประยุกต์ใช้ในงานตรวจสอบ ตรวจจับ หรือจำแนกความผิดปกติที่เกิดขึ้นด้านกำลังไฟฟ้าสูญเสียที่ไม่ใช่ทางเทคนิค โดยเฉพาะการเรียนรู้ของเครื่อง (Machine Learning) กับการเรียนรู้เชิงลึก (Deep Learning) ซึ่งเป็นองค์ประกอบหนึ่งในปัญญาประดิษฐ์ทำหน้าที่เปรียบเสมือนสมองของ AI ถือเป็นส่วนที่มีสำคัญในกระบวนการประมวลผล คิดวิเคราะห์และตัดสินใจ รายละเอียดสำหรับการนำแต่ละเทคนิคมาใช้ในการศึกษานี้จะแสดงในลำดับถัดไป

2.5 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

การเรียนรู้แบบมีผู้สอน (Supervised learning) [28] จะมีการกำหนดชนิดข้อมูลไว้ล่วงหน้า เพื่อให้โมเดลได้เรียนรู้ กลุ่มข้อมูลที่ใช้จะต้องเป็นข้อมูลที่มีความถูกต้อง เพราะถ้าป้อนข้อมูลที่ไม่ถูกต้องจะทำให้ผลลัพธ์ออกมาไม่ถูกต้อง สิ่งสำคัญของวิธีการนี้คือการกำหนดค่าเป้าหมายที่เหมาะสมและการจัดสรรข้อมูลที่มีความถูกต้อง เพราะข้อมูลที่ได้จะถูกนำไปใช้สำหรับการประมวลผล จำแนกหรือจัดหมวดหมู่ต่อไป โดยทั่วไปแล้วการเรียนรู้แบบมีผู้สอน ที่นิยมใช้แบ่งได้เป็น 2 ประเภท ได้แก่

- ก. วิธีการถดถอย (Regression) เป็นการหาคำตอบที่เป็นตัวเลขและให้ผลลัพธ์ออกมาในรูปแบบเชิงเส้น
- ข. วิธีการจำแนก (Classification) เป็นการหาคำตอบที่เป็นหมวดหมู่ การจัดกลุ่มหรือจำแนกกลุ่มของชุด หรือหลายกลุ่ม เรียกว่า Multiclass classification

ในบางงานวิจัยมีการนำการเรียนรู้ของเครื่องประเภทการเรียนรู้แบบมีผู้สอนมาใช้เพื่อค้นหาว่าโมเดลประเภทใดที่มีความเหมาะสมกับข้อมูลที่ใช้งาน หรือข้อมูลที่ผ่านมาการสกัดออกเป็นแต่ละคุณลักษณะแล้วใช้งานได้เหมาะสมกับเทคนิคใด ซึ่งในแต่ละเทคนิคนั้นจะมีจุดเด่นและจุดด้อย ทำให้

ผลลัพธ์ที่ได้ออกมาแตกต่างกัน M. M. Buzau et al. [11] ได้นำการเรียนรู้แบบมีผู้สอนมาประยุกต์ใช้ในการตรวจจับความผิดปกติระหว่างลักษณะที่พบความผิดปกติกับไม่พบความผิดปกติ ประกอบด้วย

2.5.1 การวิเคราะห์การถดถอยโลจิสติก (Logistic Regression Analysis)

เป็นการวิเคราะห์ตามเป็นตัวแปรเชิงคุณภาพ (Qualitative variable) แบ่งเป็น 2 ประเภทคือ การวิเคราะห์การถดถอยไบนารีโลจิสติก (Logistic binary regression analysis) การวิเคราะห์การถดถอย ตัวแปรตามมี 2 ค่า คือ ($x = 0$ หรือ $x = 1$) และการวิเคราะห์การถดถอยโลจิสติกพหุกลุ่ม (Multinomial logistic regression analysis) เป็นการวิเคราะห์ที่ตัวแปรตามที่มีค่ามากกว่า 2 กลุ่ม สมการพื้นฐานของตัวแปรแบบเชิงเส้นทั่วไป [28] ดังสมการที่ (2-8)

$$g(E(y)) = \alpha + \beta x_1 + \gamma x_2 \quad (2-8)$$

โดยที่ $g(E(y))$ คือ ฟังก์ชันลิงก์ $E(y)$ คือ ตัวแปรเป้าหมายที่ต้องการ และ $\alpha + \beta x_1 + \gamma x_2$ เป็นตัวทำนายเชิงเส้น (α, β, γ เป็นตัวที่ใช้ทำนาย)

2.5.2 การเรียนรู้แบบต้นไม้ตัดสินใจ (Decision Tree Learning)

เป็นโมเดลทางคณิตศาสตร์ที่ใช้ทำนายโดยพิจารณาจากลักษณะของข้อมูลและใช้ต้นไม้ตัดสินใจในการสร้างโมเดลสำหรับทำนาย ซึ่งจะเชื่อมโยงข้อมูลสังเกตการณ์เข้ากับข้อมูลปลายทาง ส่วนประกอบหลักของการเรียนรู้ประกอบด้วย เอนโทรปี (Entropy: $E(s)$) ปริมาณที่บอกถึงความไม่แน่นอนของระบบ [28] ดังสมการที่ (2-9) ถึง (2-11)

$$E(s) = -\sum_{j=1}^n ps(j) \log_2 ps(j) \quad (2-9)$$

s คือ ตัวอย่างที่ประกอบด้วยชุดของตัวแปรต้นและตัวแปรตามหลายๆกรณี

$ps(j)$ คือ อัตราส่วนของกรณีใน s ที่ตัวแปรตามหรือผลลัพธ์มีค่า j

ผลลัพธ์ต้นไม้การตัดสินใจจะมีผลลัพธ์เป็นแค่เพียงค่าตรรกะ (Boolean) ใช่กับไม่ใช่

$$E(s) = -p_{yes} \log_2(p_{yes}) - p_{no} \log_2(p_{no}) \quad (2-10)$$

และค่าเฉลี่ยของเอนโทรปีของชุดข้อมูลที่ถูกแบ่งออก (partition) โดยที่

$$Gain(S, A) = E(s) - \sum_{v=value(A)} \frac{|S_v|}{|S|} E_0(S_v) \quad (2-11)$$

เมื่อ S คือ ตัวอย่างที่ประกอบด้วยชุดของตัวแปรต้นและตัวแปรตามหลายๆกรณี E คือ เอนโทรปีของตัวอย่าง A คือ ตัวแปรต้น, $Value(A)$ คือ เซตของค่าของ A และ S_v คือ ตัวอย่างที่ A มีค่า v ทั้งหมด

2.5.3 การเรียนรู้แบบเบย์ (Bayesian Learning)

เป็นการจำแนกรูปแบบหนึ่ง ที่อาศัยหลักการของความน่าจะเป็นเข้ามาช่วยในการหาคำตอบของประเภทข้อมูล โดยใช้เทคนิคด้านทฤษฎีความน่าจะเป็น ตามกฎของเบย์ (Bayes' Theorem) เพื่อหาว่าสมมติฐานใดน่าจะถูกต้องที่สุด จากกฎของเบย์ เราสามารถคำนวณความน่าจะเป็นของสมมติฐานต่าง ๆ โดยใช้สมการที่ (2-12)

$$P(C|X) = \frac{P(X|C) \cdot P(C)}{P(X)} \quad (2-12)$$

โดยที่ C คือ Class, X คือ Attribute, P คือ ความน่าจะเป็น โดยที่ $P(X)$ คือ จำนวน attribute ทั้งหมด

$P(C|X)$ คือ ความน่าจะเป็นที่ข้อมูลที่มีแอตทริบิวต์เป็น X จะมีคลาส C

$P(X|C)$ คือ ความน่าจะเป็นที่ข้อมูลที่มีคลาส C และมีแอตทริบิวต์ X

$P(C)$ คือ จำนวน Class ที่อาจเกิดขึ้นต่อจำนวนทั้งหมดหรือความน่าจะเป็นของ class C

2.5.4 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine)

เป็นตัวจำแนกเชิงเส้น (Linear Classifier) แบบแบ่ง คลาสหรือกลุ่มข้อมูล ข้อได้เปรียบของ SVM คือมีประสิทธิภาพในการจำแนกข้อมูลที่มีมิติจำนวนมากได้ นอกจากนี้การใช้ฟังก์ชันเคอร์เนล (Kernel Function) เพื่อแปลงข้อมูลไปยังมิติที่สูงขึ้นในปริภูมิคุณลักษณะ (Feature Space) สามารถจำแนกข้อมูลที่มีความคลุมเครือได้อย่างมีประสิทธิภาพ SVM ถูกนำไปประยุกต์ใช้หลากหลายด้านเช่น Binary classification, Multiclass classification และ Linear regression ซึ่งทำงานได้ดี SVM นั้นจะมีการสร้างฟังก์ชันเชิงเส้นขึ้นมาสำหรับปัญหา m มิติซึ่งมี w เป็นค่าน้ำหนักในแต่ละมิติ และ b เป็นไบแอส ฟังก์ชันตัดสิน [28] ความสัมพันธ์เป็นไปตามสมการที่ (2-13) ถึง (2-15)

$$f(x) = \sum_{j=1}^m w_j x_j + b = w_1 x_1 + w_2 x_2 + \dots + b \quad (2-13)$$

ระยะห่างจากเวกเตอร์ w ค้ำยันไปยังเส้นแบ่งที่อยู่กึ่งกลางขอบแบ่งเป็น d

จะได้ว่า

$$d = \frac{1}{\|w\|} = \frac{1}{\sqrt{\sum_{j=1}^m w_j^2}}; \min \frac{\|w\|^2}{2} \quad (2-14)$$

และสำหรับฟังก์ชันที่ไม่เป็นเชิงเส้นนิยมใช้ วิธีการเคอร์เนล (kernel method)

$$K_{i,j} = K(X_i, X_j) = e^{-\gamma (X_i - X_j)^2} = e^{-\gamma (\sum_{k=1}^m x_{ik}^2 - 2 \sum_{k=1}^m x_{ik} x_{jk})} \quad (2-15)$$

โดยที่ X_i คือข้อมูลชุด i , X_j คือข้อมูลชุด j , γ คือ ค่าสัมประสิทธิ์ของโมเดล


2.5.5 วิธีการเพื่อนบ้านใกล้ที่สุด (k-Nearest Neighbors)

เป็นวิธีวัดค่าระยะทางกลุ่มประชากรโดยเลือกชุดข้อมูลที่สนใจและเปรียบเทียบกับกลุ่มที่มีความคล้ายกัน จากนั้นจะคำนวณว่าข้อมูลใดอยู่ใกล้มากที่สุด ในบริเวณนั้นโดยใช้การวัดค่าระยะทางระหว่างชุดข้อมูล ซึ่งจะจัดให้ชุดนั้นเป็นกลุ่มเดียวกัน การคำนวณระยะทางเพื่อหาเพื่อนบ้านใกล้ที่สุดใช้สูตรคำนวณระยะห่างยูคลิด (Euclidean distance) ระหว่างจุด p_k กับจุด q_k [28] ดังสมการที่ 2-16

$$dist(p, q) = \sqrt{\sum_{k=1}^n (p_k - q_k)^2} \quad (2-16)$$

2.5.6 โครงข่ายประสาทเทียมอัจฉริยะ (Artificial Neuron Network)

เป็นวิธีที่มีพื้นฐานมาจากการเลียนแบบการทำงานของสมองมนุษย์ซึ่งประกอบด้วย นิวรอน (Neurons) [29] ที่ใช้เชื่อมโยงเพื่อแก้ปัญหาต่าง ๆ โครงสร้างการทำงานดังภาพประกอบที่ 2-12



ภาพประกอบที่ 2-12 โครงสร้างพื้นฐานโครงข่ายประสาทเทียม (Neuron network: NN) [29]

ส่วนประกอบของโครงข่ายประสาทเทียมจากภาพประกอบที่ 2-12 ประกอบด้วย 3 ส่วนประกอบหลัก ได้แก่

- ก. ชั้นข้อมูลเข้า (Input Layer) ที่ชั้นนี้จะเป็นข้อมูลเข้า จำนวนของโหนดในชั้นนี้ขึ้นอยู่กับจำนวนของข้อมูลเข้าว่ามีข้อมูลอะไรบ้าง ปัจจัยที่นำมาวิเคราะห์เหล่านี้ว่าคุณลักษณะ (feature)
- ข. ชั้นซ่อน (Hidden Layer) เป็นชั้นที่อยู่ถัดไปจากชั้นแรกระหว่างกลาง เป็นชั้นที่สำคัญและส่งผลต่อการเรียนรู้ของข้อมูลในแบบจำลอง ซึ่งในชั้นซ่อนนั้นจะมีกี่ชั้นก็ได้ และแต่ละชั้นจะมีจำนวนของนิวรอน ซึ่งการเพิ่มชั้นและจำนวนนิวรอนจะส่งผลต่อการทำงานของโมเดล
- ค. ชั้นข้อมูลออก (Output Layer) ชั้นที่จะนำเอาข้อมูลจากการคำนวณไปใช้ และจำนวนของโหนดในชั้นนี้ขึ้นอยู่กับรูปแบบของข้อมูลออกที่จะเอาไปใช้

โครงข่ายประสาทเทียมจะประเมินข้อมูลและค่าน้ำหนักแต่ละชุดมาคูณกัน และนำค่าทั้งหมดมารวมกัน หากค่าที่รวมกันนี้เกินกว่าค่าแบ่งที่กำหนดไว้ (Threshold) จะทำการส่งต่อข้อมูลไปยังฟังก์ชันกระตุ้นซึ่งทำหน้าที่เป็นฟังก์ชันในการคำนวณเพื่อทำนายค่าของข้อมูลดังสมการที่ 2-17

$$y = f\left(b + \sum_{i=1}^n (X_i W_i) - T\right) \quad (2-17)$$

โดย X_i ที่เป็นข้อมูลเข้าจำนวนที่ i , W_i เป็นค่าน้ำหนักลำดับที่ j ค่า b คือค่าความลำเอียง (bias) และค่าแบ่งที่กำหนดไว้ (Threshold)

ในส่วนของ Non-linear activation functions แสดงดังรูปที่ 2-13

Name	Formula	Year
none	$y = x$	-
sigmoid	$y = \frac{1}{1+e^{-x}}$	1986
tanh	$y = \frac{e^{2x}-1}{e^{2x}+1}$	1986
ReLU	$y = \max(x, 0)$	2010
(centered) SoftPlus	$y = \ln(e^x + 1) - \ln 2$	2011
LReLU	$y = \max(x, \alpha x), \alpha \approx 0.01$	2011
maxout	$y = \max(W_1x + b_1, W_2x + b_2)$	2013
APL	$y = \max(x, 0) + \sum_{s=1}^S a_s^s \max(0, -x + b_s^s)$	2014
VReLU	$y = \max(x, \alpha x), \alpha \in 0.1, 0.5$	2014
RReLU	$y = \max(x, \alpha x), \alpha = \text{random}(0.1, 0.5)$	2015
PReLU	$y = \max(x, \alpha x), \alpha \text{ is learnable}$	2015
ELU	$y = x, \text{ if } x \geq 0, \text{ else } \alpha(e^x - 1)$	2015

ภาพประกอบที่ 2-13 สรุปสมการ Non-linear activation functions [30]

2.6 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เรียนรู้โดยไม่มีค่าเป้าหมายที่กำหนดไว้ล่วงหน้า ส่วนใหญ่ใช้เพื่อการแบ่งกลุ่มการเรียนรู้ (Clustering) พยายามที่จะจัดโครงสร้างและจัดเรียงข้อมูลที่ถูกป้อนเข้ามา ที่นิยมใช้แบ่งได้เป็น 2 ประเภท [30] ได้แก่

- ก. Clustering: จัดกลุ่มข้อมูล เป็นการจัดกลุ่มข้อมูลประเภทต่างๆ
- ข. Non-clustering: ปัญหาอื่นๆ ที่ไม่ใช้การจัดกลุ่ม

2.7 โครงข่ายประสาทเทียมคอนโวลูชัน Convolutional Neural Network (CNN)


โครงข่ายประสาทเทียมคอนโวลูชัน เป็นโครงข่ายประสาทเทียมชนิดหนึ่ง ประกอบด้วย การเชื่อมโยงของเพอร์เซพตรอนหลายตัวที่อยู่ใกล้กันเชื่อมต่อกันและอาศัยสมการทางคณิตศาสตร์ที่เรียกว่า คอนโวลูชัน เพื่อสร้างความสัมพันธ์ โครงสร้างพื้นฐานประกอบด้วยหลายชั้น [31] ดังนี้

การคำนวณแบบคอนโวลูชัน (Convolution) คือ การทำ dot product ของพื้นที่ในรูปภาพแต่ละส่วนย่อยระหว่าง kernel และ region เพื่อสกัดคุณลักษณะเด่น (Feature extraction) จากภาพ พื้นที่ส่วนย่อยขนาดเล็กของภาพถูกแบ่งเป็นเมทริกซ์จัตุรัส (Square matrix) การคำนวณ Convolutional สามารถทำได้ดังสมการที่ (2-18) และ (2-19) และแสดงการทำคอนโวลูชันดังภาพประกอบที่ 2-14

$$G = h * F \quad (2-18)$$

$$G[i, j] = \sum_{u=-k}^k \sum_{v=-k}^k h[u, v] F[i-u, j-v] \quad (2-19)$$

โดยที่ h คือ รูปภาพ และ F คือ เคอร์เนล (Kernel) ขนาด $k * k$



ภาพประกอบที่ 2-14 การทำคอนโวลูชัน (Convolutional) [28]

ก. Activation layer เป็นชั้นดำเนินการระหว่างชั้นหนึ่งไปอีกชั้นหนึ่งของฟังก์ชันกระตุ้น โดยอาศัยความสัมพันธ์ของฟังก์ชันทางคณิตศาสตร์ที่ผู้ใช้งานกำหนด เช่น ฟังก์ชัน ReLU สำหรับชั้นการประมวลผลซ่อน ฟังก์ชัน soft max สำหรับชั้นสุดท้ายของโครงข่ายเพื่อจำแนกและคาดการณ์ความน่าจะเป็นของผลลัพธ์ที่ได้

ข. Pooling or Sub-sampling layer เป็นชั้นที่มีหน้าที่ดำเนินการแบ่งชุดกลุ่มย่อย (sampling) เพื่อลดขนาดข้อมูล จำนวนค่าตัวแปร ลดพารามิเตอร์หรือลดขนาดเชิงพื้นที่ภายในโครงข่ายประสาท ตัวดำเนินการใช้ชั้นนี้เช่น average pooling (ชุดข้อมูลจะถูกสุ่มค่าเพื่อคำนวณค่าเฉลี่ยในแต่ละเมทริกซ์และใช้เป็นตัวแทนข้อมูล) max pooling (การสุ่มตัวอย่างค่าที่มากที่สุดในเมทริกซ์จากกลุ่มข้อมูล)

ค. Fully connected layer เป็นชั้นดำเนินการก่อนชั้นสุดท้ายของโครงข่าย มีการเชื่อมต่อแบบเต็มรูปแบบกับฟังก์ชันกระตุ้นทั้งหมดในชั้นก่อนหน้า โดยใช้ฟังก์ชัน soft max เพื่อเป็นตัวกำหนดความน่าจะเป็นของผลลัพธ์ที่ได้ (ข้อมูลขาออก)


ง. Upsampling layer ข้อมูลที่ได้ในบางครั้งมีการนำมาทำ up-sampling เพื่อปรับให้มีค่าใกล้เคียงกับภาพตั้งต้น อาจเรียกว่าเป็นการทำ deconvolution ก่อนป้อนข้อมูลทั้งหมดเข้าสู่ชั้น activation function และ soft max เพื่อคาดการณ์ความน่าจะเป็นของผลลัพธ์ขั้นสุดท้ายของโครงข่าย

จ. Merging layers เป็นชั้นการเชื่อมข้อมูลเพื่อผสานระหว่างชั้นดำเนินการ อาจมีมากกว่าสองชั้น โดยกระทำในลักษณะ concatenate layer

สำหรับโครงสร้างของ CNN ถูกพัฒนาต่อยอดเพื่อนำไปประยุกต์ใช้กับงานต่างๆ หลากหลาย ตัวอย่างสถาปัตยกรรมที่นิยมนำมาใช้ในงานจำแนกความผิดปกติมีดังนี้

2.7.1 LeNet


เป็นสถาปัตยกรรมที่ถูกพัฒนาขึ้นด้วยข้อจำกัดของ Multi-layer perceptron ที่ไม่สามารถสกัดข้อมูลแต่ละ pixel แบบละเอียดเชิงตำแหน่งได้ โดยทั่วไปจะประกอบด้วย 5 เลเยอร์ นิยมเรียกเป็น LeNet5 ดังภาพประกอบที่ 2-15 มีโครงสร้างที่ไม่ซับซ้อน สามารถจำแนกข้อมูลได้ดีสำหรับภาพประเภทข้อความหรืออักขระ แต่ด้วยโมเดลชนิดนี้มีชั้นที่ไม่ลึกมาก ผลการสกัดอาจได้ค่าที่ไม่ครอบคลุม



ภาพประกอบที่ 2-15 ตัวอย่างสถาปัตยกรรมของ LeNet5 [31]

2.7.2 AlexNet

โมเดล CNN ได้มีการพัฒนาต่อโดยการเพิ่มและปรับปรุงความสามารถการสกัดเพื่อเพิ่มความลึก AlexNet เป็นสถาปัตยกรรมหนึ่งที่มีทั้งหมด 8 เลเยอร์ ดังภาพประกอบที่ 2-16 มีการปรับปรุง gradient propagation ให้มีประสิทธิภาพดีขึ้น ด้วยโครงสร้างนี้สามารถสกัดคุณลักษณะได้ดีกว่า LeNet เป็นจุดเริ่มต้นที่มีการนำ GPU มาใช้ร่วมกันในการประมวลผล ทำให้มีความรวดเร็วมากขึ้น โดยทั่วไปแล้วจะนิยมนำมาใช้กับภาพสี



ภาพประกอบที่ 2-16 ตัวอย่างสถาปัตยกรรมของ AlexNet [31]

2.7.3 VGGNet

การทำ image classification เริ่มได้รับความนิยมและด้วยข้อจำกัดของ Neural network ที่มีจำนวนเลเยอร์น้อย สถาปัตยกรรม VGGNet ดังภาพประกอบที่ 2-17 ถูกพัฒนาขึ้น โดยแต่ละเลเยอร์จะมีความลึกมากขึ้น ซับซ้อนขึ้นผ่านการปรับตัวกรองในแต่ละชั้น และที่สำคัญช่วยเพิ่มความยืดหยุ่นของความไม่เป็นเชิงเส้นซึ่งเป็นผลดีต่อการเรียนรู้ของโมเดล แต่ถึงอย่างไรก็ตามด้วยในแต่ละชั้นมีหลายคอร์เนล ทำให้ใช้ระยะเวลาในการประมวลผลสำหรับการเรียนรู้ชุดข้อมูล


input (224 × 224 RGB image)					
conv3-64	conv3-64	conv3-64	conv3-64	conv3-64	conv3-64
	LRN	conv3-64	conv3-64	conv3-64	conv3-64
maxpool					
conv3-128	conv3-128	conv3-128	conv3-128	conv3-128	conv3-128
		conv3-128	conv3-128	conv3-128	conv3-128
maxpool					
conv3-256	conv3-256	conv3-256	conv3-256	conv3-256	conv3-256
conv3-256	conv3-256	conv3-256	conv3-256	conv3-256	conv3-256
		conv3-256	conv1-256	conv3-256	conv3-256
			conv3-256	conv3-256	conv3-256
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
			conv1-512	conv3-512	conv3-512
			conv3-512	conv3-512	conv3-512
maxpool					
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
conv3-512	conv3-512	conv3-512	conv3-512	conv3-512	conv3-512
			conv1-512	conv3-512	conv3-512
			conv3-512	conv3-512	conv3-512
maxpool					
FC-4096					
FC-4096					
FC-1000					
soft-max					

ภาพประกอบที่ 2-17 ตัวอย่างสถาปัตยกรรมของ VGGNet [31]

2.7.4 GoogLeNet

แนวคิดการนำ convolution มา concatenated กันเป็นอีกหนึ่งเทคนิคที่ช่วยเพิ่มความสามารถในการสกัด features ของข้อมูลให้ดีขึ้น ซึ่งแต่ละเลเยอร์จะทำ multi-level feature


extraction ระหว่างชั้นก่อนหน้าและชั้นถัดไป (คล้ายกับแนวคิดของ inception) เพิ่มประสิทธิภาพได้ดี ตัวอย่างดังภาพประกอบที่ 2-18



ภาพประกอบที่ 2-18 ตัวอย่างสถาปัตยกรรมของ GoogLeNet [31]

2.7.5 ResNet


ถูกพัฒนาขึ้นมาด้วยหลายๆ สถาปัตยกรรม ใช้ระยะเวลาในการสอนและเกิด gradient vanishing แต่ถึงอย่างไรก็ตาม ResNet มีการกำหนดเงื่อนไขในการชั้นการเรียนรู้คือถ้าเรียนรู้ feature แล้วให้เรียนรู้ชั้นถัดไปโดยไม่ต้องเรียนรู้ซ้ำ ให้เรียนรู้ในชั้นใหม่ต่อไป ทำแบบนี้ไปเรื่อยๆ แนวคิดนี้ช่วยปรับปรุงประสิทธิภาพในการสอนให้กับโมเดลได้ และได้ผลลัพธ์ที่มีประสิทธิภาพสูง ตัวอย่างการทำงานแสดงดังภาพประกอบที่ 2-19



ภาพประกอบที่ 2-19 ตัวอย่างแนวคิดของสถาปัตยกรรม ResNet [31]

2.7.6 DenseNet

หลักการทำงานของสถาปัตยกรรม DenseNet ดังภาพประกอบที่ 2-20 จะมีการเชื่อมโยงข้อมูลแต่ละชั้นของแต่ละเลเยอร์ ชั้นหนึ่งๆจะเชื่อมต่อกับทุกชั้นในแต่ละเลเยอร์ แนวคิดนี้เพื่อต้องการให้ feature ที่สกัดได้มีการเรียนรู้ในทุกๆชั้น เพิ่มความละเอียดและประสิทธิภาพในการสอนโมเดล




ภาพประกอบที่ 2-20 หลักการทำงานของสถาปัตยกรรมระหว่างชั้นของ DenseNet [31]

บทที่ 3

อุปกรณ์และวิธีการวิจัย

ในบทนี้จะนำเสนอรายละเอียดเกี่ยวกับวิธีการวิจัยประกอบด้วย การรวบรวมข้อมูล ขั้นตอนการเตรียมข้อมูล กระบวนการสกัดข้อมูล โมเดลที่ใช้จำแนก การสมมูลข้อมูลการจัดกลุ่มข้อมูล และการประเมินผลโมเดล ซึ่งหลังจากได้โมเดลออกมาแล้ว โมเดลจะถูกนำไปทดสอบกับเหตุการณ์จริง ภาพรวมของขั้นตอนวิธีการวิจัยแสดงดังภาพประกอบที่ 3-1



ภาพประกอบที่ 3-1 ภาพรวมวิธีการวิจัย

3.1 รวบรวมข้อมูลเบื้องต้น (Data Collection)

3.1.1 รายละเอียดของข้อมูล

ในการทำวิจัยรายละเอียดของข้อมูลที่เลือกมาใช้วิเคราะห์นำมาจากมิเตอร์อ่านหน่วยอัตโนมัติที่ติดตั้งใช้งานในการไฟฟ้าส่วนภูมิภาค ข้อมูลถูกรวบรวมจากฐานข้อมูลของกองพัฒนาระบบมิเตอร์ (กพร.) ซึ่งปัจจุบันมิเตอร์ดังกล่าวติดตั้งใช้งานมี 2 ประเภท ได้แก่ มิเตอร์ประเภท 3P3W และ

มิเตอร์ประเภท 3P4W ข้อแตกต่างของมิเตอร์ทั้ง 2 ประเภทคือ จำนวนองค์ประกอบหรือค่าพารามิเตอร์ที่อ่านค่าได้จากมิเตอร์จะไม่เท่ากันคือ 3P3W (2 element) เป็นมิเตอร์ที่ติดตั้งประกอบเครื่องวัดกระแสแรงสูง (Current Transformers : CT) กับเครื่องวัดแรงดันสูง (Voltage Transformers :VT) และ 3P4W (3element) จะติดตั้งประกอบเครื่องวัดกระแสแรงต่ำ รายละเอียดตามตารางที่ 3-1

ในงานวิจัยเบื้องต้นเลือกใช้ข้อมูลจากมิเตอร์ประเภท 3P4W มาวิเคราะห์เนื่องจาก

- ก. ลักษณะผิดปกติและการละเมิดส่วนใหญ่พบมากกว่ามิเตอร์ประเภท 3P3W
- ข. มีการติดตั้งใช้งานครอบคลุมทั่วทุกพื้นที่ กฟภ. รับผิดชอบ
- ค. เป็นมิเตอร์ที่ติดตั้งให้กับผู้ใช้ไฟรายใหญ่ มีความต้องการใช้ไฟสูง กรณีชำรุดหรือละเมิดเกิดขึ้นแต่ละครั้งส่งผลกระทบต่อการใช้งานของผู้ใช้ไฟ

ตารางที่ 3-1 เปรียบเทียบค่า Element ระหว่างมิเตอร์ 3P4W และ 3P3W

3P4W (3 element)			3P3W (2 element)		
VOLTA	VOLTB	VOLTC	VOLTA	-	VOLTC
AMPSA	AMPSB	AMPSC	AMPSA	-	AMPSC
THDVA	THDVB	THDVC	THDVA	-	THDVC
THDIA	THDIB	THDIC	THDIA	-	THDIC
ANGLEA	ANGLEB	ANGLEC	ANGLEA	-	ANGLEC

**หมายเหตุ 3P3W (2 element) ไม่มีการวัดค่าเฟส B

3.1.2 ชนิดของข้อมูล

ในการวิเคราะห์ข้อมูลแบ่งข้อมูลเป็น 2 ชนิด ได้แก่

ก. ข้อมูลพื้นฐาน (Physical data) เป็นข้อมูลด้านโครงสร้างพื้นฐานของระบบจำหน่ายและของผู้ใช้ไฟ รวมถึงตำแหน่งที่ติดตั้งอุปกรณ์ พฤติกรรมการใช้ไฟ ได้แก่ ข้อมูลด้านโครงสร้าง คุณลักษณะของมิเตอร์, คุณสมบัติของผู้ใช้ไฟ ประเภทอัตราการใช้ไฟ, สภาพภูมิศาสตร์, ฤดูกาล ช่วงเวลาการใช้ไฟ สัญญาซื้อขายไฟ และข้อร้องเรียน เป็นต้น

ข. ข้อมูลประเภทอนุกรมเวลา (Time Series) ประกอบด้วย ค่าที่ได้จากการวัดค่าผ่านตัวมิเตอร์ ได้แก่ วันที่ เวลา ค่าแรงดันทั้ง 3 เฟส (VOLTA, VOLTB, VOLTC) ค่ากระแสทั้ง 3 เฟส (AMPSA,

AMPSB, AMPSC) ค่าความผิดเพี้ยนฮาร์มอนิกรวมของแรงดัน (THDVA, THDVB, THDVC) ค่าความผิดเพี้ยนฮาร์มอนิกรวมของกระแส (THDIA, THDIB, THDIC) ค่ากำลังไฟฟ้าจริง (W) ค่ากำลังไฟฟ้าเสมือน (VARHIMP, VARHEXP) และค่าพลังงานไฟฟ้า (WHIMP, WHEXP)

3.1.3 ประเภทของข้อมูล

ข้อมูลที่ใช้ในการวิเคราะห์แบ่งออกเป็น 2 ชนิด ได้แก่ ข้อมูลละเมิดการใช้ไฟและข้อมูลอุปกรณ์ชำรุดที่ส่งผลให้มิเตอร์อ่านค่าผิดปกติ โดยอ้างอิงข้อมูลที่รวบรวมจากฐานข้อมูลมิเตอร์ AMR ของ กฟภ. ช่วงปี 2550-2564 และข้อมูลปี 2565 จะเป็นข้อมูลสำหรับใช้ทดสอบโมเดล รายละเอียดดังนี้

3.1.3.1 รายละเอียดข้อมูลอุปกรณ์ชำรุด

ความผิดปกติที่เกี่ยวข้องกับอุปกรณ์ชำรุดจะครอบคลุมทั้งการชำรุดจากตัวมิเตอร์ และอุปกรณ์ประกอบ ที่ทำให้มิเตอร์อ่านค่าได้ผิดปกติ รายละเอียดของข้อมูลอุปกรณ์ชำรุดจากมิเตอร์ AMR ประเภท 3P4W ที่พบในการไฟฟ้าส่วนภูมิภาค แสดงดังตารางที่ 3-2 และแสดงตัวอย่างลักษณะที่เกิดขึ้นจากการชำรุดแสดงดังตารางที่ 3-3

ตารางที่ 3-2 สรุปข้อมูลอุปกรณ์ชำรุดประเภท 3P4W ที่พบในการไฟฟ้าส่วนภูมิภาค


ลักษณะชำรุด	จำนวน (ราย)	ผลกระทบที่เกิดขึ้น
1.Asymmetric Power	3	อุปกรณ์ประกอบชำรุดหรือเกิด unbalance ในระบบ
2.Over Current	3	ค่ากระแสสูงกว่า ratio อาจทำให้อุปกรณ์ชำรุดได้
3.Voltage unbalance	5	แรงดันหายหรือมิเตอร์อ่านค่าผิดปกติ อุปกรณ์ชำรุด
4.Any phase current = 0	4	มิเตอร์อ่านค่ากระแสได้บางเฟส หรือใช้ไฟบางเฟส
5.Reverse power	3	กำลังไฟฟ้าไหลย้อนกลับ อาจเกิดอันตรายได้
6.Voltage Failure	2	แรงดันต่ำผิดปกติส่งผลต่ออุปกรณ์ภายใน
สรุปจำนวนทั้งหมด	20	

หมายเหตุ Current Transformer (CT) หม้อแปลงชุดกระแสแรงต่ำ


ตารางที่ 3-3 ภาพตัวอย่างแสดงลักษณะการชำรุดแต่ละชนิด ที่พบในการไฟฟ้าส่วนภูมิภาค

ลักษณะชำรุด	ภาพตัวอย่าง
<p>สายต่อแรงดัน ชำรุด</p>	<p>พบ CT เฟส A และ C ชำรุด</p>
<p>CT ชำรุด 3 ชุด</p>	<p>พบชุดสายต่อ CT ชำรุดทั้ง 3 เฟส</p>
<p>CT ชำรุด 1 ชุด</p>	<p>พบ CT เฟส A ชำรุด</p>

ตารางที่ 3-3 ภาพตัวอย่างแสดงลักษณะการชำรุดแต่ละชนิด ที่พบในการไฟฟ้าส่วนภูมิภาค (ต่อ)



ตารางที่ 3-3 ภาพตัวอย่างแสดงลักษณะการชำรุดแต่ละชนิด ที่พบในการไฟฟ้าส่วนภูมิภาค (ต่อ)



3.1.3.2 รายละเอียดข้อมูลการละเมิด

ข้อมูลการละเมิดที่เกิดขึ้นแล้วส่งผลให้มิเตอร์อ่านค่าผิดปกตินั้นมีหลากหลายรูปแบบ วัตถุประสงค์หลักของการละเมิดคือเพื่อต้องการให้หน่วยการใช้ไฟลดลงหรืออ่านได้น้อยกว่าที่ใช้งานจริง


ในงานวิจัยจะรวบรวมข้อมูลที่พบในมิเตอร์ AMR ประเภท 3P4W แต่ละพื้นที่ของการไฟฟ้าส่วนภูมิภาค รายละเอียดแสดงดังตารางที่ 3-4 และแสดงภาพตัวอย่างลักษณะการละเมิดแต่ละชนิดดังตารางที่ 3-5

ตารางที่ 3-4 สรุปข้อมูลการละเมิดประเภท 3P4W ที่พบในการไฟฟ้าส่วนภูมิภาค


ลักษณะละเมิด	จำนวน (ราย)	ผลกระทบที่เกิดขึ้น
1.ตัดแปลง/แก้ไขสาย Control ชุดแรงดัน	6	มิเตอร์อ่านค่าแรงดันได้น้อยกว่าความเป็นจริง
2.ตัดแปลง/แก้ไขสาย Control ชุดกระแส	11	มิเตอร์อ่านค่ากระแสได้น้อยกว่าความเป็นจริง
3.จัดแ่งชุด CT แรงต่ำ	3	ชุด CT แรงต่ำ ทำงานผิดพลาด
4.ต่อक्रमชุดแรงดัน	2	มิเตอร์อ่านค่าแรงดันผิดปกติ
5.ต่อक्रमชุดกระแส	2	มิเตอร์อ่านค่ากระแสผิดปกติ
6.ตัดสายนิวตรอน	2	ค่าแรงดันผิดปกติ
7.อื่นๆ	1	ใช้กาวหยอดทำให้แรงดันหายบางเฟส
สรุปจำนวนทั้งหมด	27	

หมายเหตุ Current Transformer (CT) หม้อแปลงชุดกระแสแรงต่ำ


ตารางที่ 3-5 ภาพตัวอย่างแสดงลักษณะการละเมิดแต่ละชนิด ที่พบในการไฟฟ้าส่วนภูมิภาค



ตารางที่ 3-5 ภาพตัวอย่างแสดงลักษณะการละเมิดแต่ละชนิด (ต่อ)



ตารางที่ 3-5 ภาพตัวอย่างแสดงลักษณะการละเมิดแต่ละชนิด (ต่อ)



3.1.4 การจำแนกลักษณะของข้อมูล

ในการจำแนกลักษณะของข้อมูลจะแบ่งกลุ่มของข้อมูลเป็น 3 ชนิด ได้แก่ ผู้ใช้ไฟที่ใช้ไฟปกติ ผู้ใช้ไฟที่พบอุปกรณ์ชำรุด และผู้ใช้ไฟที่มีประวัติการละเมิด โดยข้อมูลที่ระบุแต่ละประเภทจะเป็นข้อมูลที่อ้างอิงผลการตรวจสอบหน้างานจริง เป็นประเภทผู้ใช้ไฟรายใหญ่ที่มีความต้องการพลังไฟฟ้าตั้งแต่ 30 กิโลวัตต์ขึ้นไปแต่ไม่เกิน 250 กิโลวัตต์ และมีการซื้อไฟจากการไฟฟ้าทางเดียว ความผิดปกติที่เกิดขึ้นจากค่า กระแส แรงดัน มุมเฟส ที่ส่งผลต่อค่าพลังไฟฟ้าของผู้ใช้ไฟ ก่อให้เกิดหน่วยสูญเสียกับการไฟฟ้า และมีลักษณะที่ต่างจากการใช้ไฟปกติอย่างชัดเจนรายละเอียดของข้อมูลที่พบลักษณะการชำรุดจำแนกแต่ละราย แยกเป็นการไฟฟ้าได้ทั้งหมด 20 ราย ตามตารางที่ 1 ภาคผนวก ข และรายละเอียดลักษณะการละเมิดจำแนกแยกเป็นรายของแต่ละการไฟฟ้า ได้ทั้งหมด 27 ราย ตามตารางที่ 2 ภาคผนวก ค

3.1.5 การเปรียบเทียบความแตกต่างของข้อมูลแต่ละชนิด

จากข้อมูลที่ได้ทำการรวบรวมในหัวข้อที่ 3.1.3 จากนั้นจะทำการวิเคราะห์ความแตกต่างเบื้องต้นทั้ง 3 ลักษณะ ด้านข้อมูลพื้นฐานเนื่องจากได้กำหนดขอบเขต จำกัดกลุ่มผู้ใช้ไฟ, ชนิดมิเตอร์, ประเภทอัตราการใช้ไฟ และข้อมูลเฉพาะของผู้ใช้ไฟ จึงยังไม่นำมาประกอบในการวิเคราะห์เบื้องต้น ส่วนข้อมูลประเภทอนุกรมเวลาจะแบ่งออกเป็นส่วนประกอบหลักๆ ที่ส่งผลกระทบต่อความผิดปกติอย่างชัดเจน ได้แก่ ค่า กระแส, แรงดัน, มุมเฟส, กิโลวัตต์, กิโลวาร์, ซึ่งได้รวบรวมข้อมูลและสรุปความแตกต่างโดยยกตัวอย่างผลการตรวจสอบจากทางการไฟฟ้าที่พบจริงของผู้ใช้ไฟ แสดงดังต่อไปนี้

3.1.5.1 วิเคราะห์ความแตกต่างระหว่างลักษณะปกติ ละเมิด และชำรุด

ในการวิเคราะห์จะทำการแบ่งตามค่าพารามิเตอร์ ประกอบด้วย แรงดัน กระแส มุมเฟส กำลังไฟฟ้าจริง และกำลังไฟฟ้าเสมือน คือ 3 รูปแบบ ปกติ ชำรุด และละเมิด ดังตารางที่ 3-6 ถึง 3-10 ตารางที่ 3-6 ความผิดปกติที่ส่งผลต่อค่าแรงดัน (Voltage)

ปกติ	ละเมิด	ชำรุด
$V_{line} :$ $Volt_A = Volt_B = Volt_C = 400V$ $V_{phase} :$ $Volt_A = Volt_B = Volt_C = 230V$ 1.ค่าแรงดันจะมีลักษณะที่คงที่ ใกล้เคียงกันทั้ง 3 เฟส ในสภาวะปกติจะมีค่าคงที่ ประมาณ 230 V	$V_{line} :$ $Volt_A \neq Volt_B \neq Volt_C \neq 400V$ $V_{phase} :$ $Volt_A \neq Volt_B \neq Volt_C \neq 230V$ กรณีที่ 1 บางเฟสลดลงเท่ากับ 0 กรณีที่ 2 ละเมิดบางเฟส ทำให้ ลดลงเฟสที่ถูกละเมิด แต่ไม่เป็น 0 กรณีที่ 3 ละเมิดทั้ง 3 เฟส แรงดัน ผิดปกติทั้ง 3 เฟส กรณีที่ 4 แรงดันเกินบางเฟส	$V_{line} :$ $Volt_A \neq Volt_B \neq Volt_C \neq 400V$ $V_{phase} :$ $Volt_A \neq Volt_B \neq Volt_C \neq 230V$ กรณีที่ 1 ชำรุดบางเฟสทำให้ บางเฟสเท่ากับ 0 กรณีที่ 2 ชำรุดมากกว่าหนึ่ง เฟสและลดลง แต่ไม่เป็น 0 กรณีที่ 3 ชำรุดทั้ง 3 เฟส กรณีที่ 4 แรงดันเกินชั่วขณะ
หมายเหตุ: ค่าแรงดัน ในสภาวะปกติจะมีค่าคงที่ประมาณ 230 V กรณีมีการละเมิดหรือชำรุดเกิดขึ้น จะทำให้แรงดันลดลง หรือลดลงเป็นศูนย์ และบางครั้งอาจเกิดแรงดันเกินเกิดขึ้นได้		

ตารางที่ 3-7 ความผิดปกติที่ส่งผลต่อค่ากระแส (Current)

ปกติ	ละเมิด	ชำรุด
$Amps_A \approx Amps_B \approx Amps_C$ 1. กระแสทั้ง 3 เฟส มีค่า ใกล้เคียงกัน กรณีโหลดสมดุล 2. กระแสแตกต่างกันในบางเฟส กรณีโหลดไม่สมดุล 3.เปลี่ยนแปลงตามช่วงเวลาใช้ไฟ 4.จะเป็นคาบในรอบวันทำงาน	$Amps_A \neq Amps_B \neq Amps_C$ กรณีที่ 1 บางเฟสเท่ากับ 0 กรณีที่ 2 ละเมิดบางเฟส ทำให้ เฟสที่ละเมิดลดลง แต่ไม่เป็น 0 กรณีที่ 3 ละเมิดทั้ง 3 เฟส กระแสผิดปกติทั้ง 3 เฟส กรณีที่ 4 กระแสเกินบางเฟส	$Amps_A \neq Amps_B \neq Amps_C$ กรณีที่ 1 บางเฟสเท่ากับ 0 กรณีที่ 2 ชำรุดมากกว่าหนึ่งเฟส ลดลงในเฟสที่ชำรุด แต่ไม่เป็น 0 กรณีที่ 3 ชำรุดทั้ง 3 เฟส กระแส ผิดปกติทั้ง 3 เฟส กรณีที่ 4 เกินบางเฟสชั่วขณะ
หมายเหตุ: ในสภาวะปกติจะมีค่าเปลี่ยนแปลงตามการใช้ไฟของผู้ใช้ไฟ สำหรับผู้ใช้ไฟบางรายอาจพบ ค่ากระแสไม่สมดุล (กระแสทั้ง 3 เฟส ต่างกันมาก) กรณีมีการละเมิดหรือชำรุดเกิดขึ้น จะทำให้กระแส บางเฟสลดลง หรือลดลงเป็นศูนย์ บางครั้งอาจทำให้เกิดระบบไม่สมดุลมากผิดปกติ		

ตารางที่ 3-8 ความผิดปกติที่มีผลต่อค่ากำลังไฟฟ้า (Active power and energy)

ปกติ	ละเมิด	ชำรุด
$P_a = V_a I_a \cos \theta_a$ $P_b = V_b I_b \cos \theta_b$ $P_c = V_c I_c \cos \theta_c$ $P_{total} = P_a + P_b + P_c (kW)$ $kWh = P_{total} \times h$ WHIMP : 1. เปลี่ยนแปลงตามการใช้โหลด 2. มีลักษณะเป็นคาบ 3. คำนวณตามสมการข้างต้น 4. ลักษณะของข้อมูลจาก load profile ค่ารวมทั้ง 3 เฟส kWh 5. คิดค่าไฟเป็นประเภท TOU	กรณีที่ 1. จะผิดเพี้ยนไม่เป็นคาบและแกว่งตามช่วงการใช้ไฟ กรณีที่ 2. ค่าหน่วยการใช้ไฟมีแนวโน้มลดลงผิดปกติเมื่อเทียบกับสถิติการใช้ไฟที่ผ่านมา กรณีที่ 3. ค่ากำลังไฟฟ้าผิดปกติ	กรณีที่ 1. จะผิดเพี้ยนไม่เป็นคาบแกว่งผิดปกติ กรณีที่ 2. ค่าหน่วยการใช้ไฟมีแนวโน้มลดลงผิดปกติเมื่อเทียบกับสถิติการใช้ไฟที่ผ่านมา กรณีที่ 3. ค่ากำลังไฟฟ้าผิดปกติบางช่วงเวลา
หมายเหตุ: ค่ากำลังไฟฟ้าจริงและค่าพลังงาน ในสภาวะปกติจะมีลักษณะเป็นคาบ และมีค่าสม่ำเสมอ กรณีมีการละเมิดเกิดขึ้น ค่ากำลังไฟฟ้าจะมีแนวโน้มลดลง และไม่เป็นคาบ		

ตารางที่ 3-9 ความผิดปกติที่มีผลต่อค่ามุม (Angle)

ปกติ	ละเมิด	ชำรุด
$Angle_A \approx Angle_B \approx Angle_C$ 1. ค่ามุมจะ lag และ lead ตามการใช้โหลด 2. ค่ามุมเกิดการ lag และ lead ระหว่างค่ากระแสและแรงดันใกล้เคียงกัน	$Angle_A \neq Angle_B \neq Angle_C$ กรณีที่ 1. ค่าเฟสเซอร์ของเฟสใดเฟสหนึ่งมีค่า ≥ 110 องศา กรณีที่ 2. ขนาดเฟสเซอร์เฟสใดเฟสหนึ่งต่างกับเฟสอื่นผิดปกติ กรณีที่ 3. เฟสเซอร์ทั้ง 3 เฟสหรือเฟสใดเฟสหนึ่งกลับทิศทาง	$Angle_A \neq Angle_B \neq Angle_C$ กรณีที่ 1. ค่าเฟสเซอร์ของเฟสใดเฟสหนึ่งทำมุมผิดปกติ กรณีที่ 2. ขนาดเฟสเซอร์เฟสใดเฟสหนึ่งต่างกับเฟสอื่นผิดปกติ กรณีที่ 3. เฟสเซอร์ทั้ง 3 เฟสหรือเฟสใดเฟสหนึ่งติดลบ
หมายเหตุ: มุมในสภาวะปกติจะเกิดการ lagging และ leading ตามการใช้โหลด และค่าเฟสเซอร์ของกระแสกับแรงดันจะทำมุมกันไม่เกิน 120 องศา กรณีละเมิดหรือชำรุดเกิดขึ้น ค่ามุมจะผิดปกติ เกิดการ lagging และ leading มากผิดปกติ เฟสเซอร์อาจเกิดการกลับทิศทาง มีค่าติดลบหรือมีค่าเป็นศูนย์		

ตารางที่ 3-10 ความผิดปกติที่มีผลต่อค่ากำลังไฟฟ้าเสมือน (Reactive power)

ปกติ	ละเมิด	ชำรุด
$Q_a = V_a I_a \sin \theta_a$ $Q_b = V_b I_b \sin \theta_b$ $Q_c = V_c I_c \sin \theta_c$ $Q_{total} = Q_a + Q_b + Q_c (Var)$ $kVarh = Q_{total} \times h$ VARHIMP: 1. เปลี่ยนแปลงตามการใช้โหลดส่วนใหญ่ติดตั้ง cap bank ลูกค้ำ 2. มีลักษณะเป็นคาบ 3. ค่าที่ได้มาจากสมการข้างต้น 4. load profile จะเป็นค่ารวมทั้ง 3 เฟส ในหน่วย $kVarh$	กรณีที่ 1. จะผิดเพี้ยนไม่เป็นคาบและแกว่งตามค่ากระแส กรณีที่ 2. กรณี Cap bank ผิดปกติทำให้ค่ากระแสจะสูงผิดปกติ กรณีที่ 3. การใช้โหลดที่ส่งผลให้ค่ากำลังไฟฟ้าเสมือนผิดปกติ	กรณีที่ 1. จะผิดเพี้ยนไม่เป็นคาบแกว่งตามพฤติกรรมการใช้ไฟ กรณีที่ 2. กรณี Cap bank ของผู้ใช้ไฟเองจ่ายกระแสเกินจนทำให้อุปกรณ์ไฟฟ้าของ กฟภ.ชำรุด load profile ค่ากระแสจะสูงผิดปกติ กรณีที่ 3. เป็นค่าที่ถูกนำมาคิดค่าปรับ กรณีเกินกว่าร้อยละ 61.97 (มีค่าน้อยผิดปกติ)
หมายเหตุ: ค่ากำลังไฟฟ้าเสมือน มีรูปแบบที่คล้ายกับค่ากำลังไฟฟ้าจริงและค่าพลังงาน คือปกติจะเป็นคาบ และกรณีละเมิดค่าจะลดลง เปลี่ยนแปลงตามค่ามุมที่เปลี่ยนแปลงไปและไม่เป็นคาบ ในบางกรณีพบเป็นผลจากปัจจัยอื่นเช่น Capacitor ชำรุด จากภายใน การใช้โหลดที่น้อยเกินไปไม่เหมาะสม		

3.1.5.2 เปรียบเทียบความแตกต่างระหว่างการละเมิดกับลักษณะชำรุด

จากการวิเคราะห์แยกในตารางที่ 3-6 ถึงตารางที่ 3-10 แล้ว ข้อมูลที่น่าสนใจและเป็นโจทย์ที่ทำทนายคือ ความแตกต่างของรูปแบบความผิดปกติของละเมิดและชำรุดซึ่งมีรูปแบบการลดลงที่ใกล้เคียงกัน จึงนำมาวิเคราะห์เปรียบเทียบดังแสดงในตารางที่ 3-11 จะพบว่า มีบางรูปแบบที่พบความแตกต่างระหว่างทั้งสองรูปแบบ โดยพิจารณาแยกระหว่างค่าแรงดันและกระแส เพราะว่ามีรูปแบบการเปลี่ยนแปลงและการเกิดที่แตกต่างกัน

ตารางที่ 3-11 เปรียบเทียบการละเมิดกับการชำรุด และความแตกต่างที่สามารถวิเคราะห์ได้เบื้องต้น

ตัวแปร	การละเมิด	การชำรุด	ความแตกต่าง
แรงดัน	<ol style="list-style-type: none"> 1. แรงดันลดลงต่ำกว่าค่ามาตรฐาน 2. แรงดันเมื่อเปรียบเทียบทั้ง 3 เฟส ค่า Unbalance สูง 3. บางกรณีเกิดแรงดันหายชั่วคราวบางเฟส หรือแรงดันเป็นศูนย์ แต่ส่วนใหญ่จะเกิดถาวร 4. ส่วนใหญ่ตรวจสอบพบมีการเปิดตู้, เปิดฝา (Alarm limit switch หรือ Lid cover tamper) ในระยะเวลาใกล้เคียงกัน 5. บางกรณีเกิดแรงดันเกินทำให้มิเตอร์หรืออุปกรณ์ประกอบชำรุด 	<ol style="list-style-type: none"> 1. แรงดันลดลงต่ำกว่าค่ามาตรฐาน 2. แรงดันเมื่อเปรียบเทียบทั้ง 3 เฟส ค่า Unbalance สูง 3. บางกรณีเกิดชั่วคราวแรงดันหายชั่วคราวบางเฟส หรือแรงดันเป็นศูนย์ บางช่วงเวลา แล้วกลับมาปกติ 4. ไม่พบความผิดปกติในลักษณะการเปิดตู้หรือเปิดฝาคกรอบ 5. เกิดจากปัจจัยด้านธรรมชาติ สิ่งแวดล้อม และมาจากส่วนของผู้ใช้ไฟ 6. ชำรุดจากอายุการใช้งาน 	<ol style="list-style-type: none"> 1. รูปแบบการเกิดชั่วคราว และถาวร 2. ลักษณะการเกิดแบบค่อยๆเปลี่ยนแปลงกับเปลี่ยนแปลงแบบทันทีทันใด 3. การเปิด-ปิดตู้, เปิด-ปิดฝาคกรอบ 4. การละเมิดบางกรณีโปรแกรม AMR monitoring ตรวจสอบไม่พบ
กระแส	<ol style="list-style-type: none"> 1. กระแสลดลงต่ำบางเฟส เปรียบเทียบเฟสต่อเฟส 2. ค่ากระแสเมื่อเปรียบเทียบทั้ง 3 เฟส ค่า Unbalance สูง 3. บางกรณีเกิดกระแสเป็นศูนย์หายชั่วคราวบางเฟส แต่ส่วนใหญ่จะเกิดถาวร 	<ol style="list-style-type: none"> 1. กระแสลดลงต่ำบางเฟส เปรียบเทียบเฟสต่อเฟส 2. ค่ากระแสเมื่อเปรียบเทียบทั้ง 3 เฟส ค่า Unbalance สูง 3. บางกรณีเกิดกระแสเป็นศูนย์ หายชั่วคราวบางเฟส บางช่วงเวลา แล้วกลับมาปกติ 	<ol style="list-style-type: none"> 1. รูปแบบการเกิดชั่วคราว และถาวร 2. ลักษณะการเกิดแบบค่อยๆเปลี่ยนแปลงกับเปลี่ยนแปลงแบบทันทีทันใด 3. การเปิด-ปิดตู้, เปิด-ปิดฝาคกรอบ

ตารางที่ 3-11 เปรียบเทียบการละเมิดกับการชำรุด และความแตกต่างที่สามารถวิเคราะห์ได้เบื้องต้น (ต่อ)

ตัวแปร	การละเมิด	การชำรุด	ความแตกต่าง
กระแส	4. ส่วนใหญ่ตรวจสอบพบมีการเปิดตู้, เปิดฝา (Alarm limit switch หรือ Lid cover tamper) ในระยะเวลาใกล้เคียงกัน 5. บางกรณีเกิดกระแสเกิน ทำให้มีเตอรหรืออุปกรณ์ประกอบชำรุด	4. ไม่พบความผิดปกติในลักษณะการเปิดตู้หรือเปิดฝาคกรอบ 5. เกิดจากปัจจัยด้านธรรมชาติ สิ่งแวดล้อม และมาจากส่วนของผู้ใช้ไฟ 6. ชำรุดจากอายุการใช้งาน 7. เกิดจากปัจจัยด้านธรรมชาติ สิ่งแวดล้อม และมาจากส่วนของผู้ใช้ไฟ	4. การละเมิดบางกรณีโปรแกรม AMR monitoring ตรวจสอบไม่พบ
มูม	1. มูมระหว่างกระแสและแรงดันมีค่าผิดปกติ 2. เกิดการกลับทิศทางของค่าเฟสเซอร์กระแสและแรงดัน	1. มูมและเฟสเซอร์ระหว่างกระแสและแรงดันมีค่าผิดปกติ	1. การกลับทิศทางของค่าเฟสเซอร์ กระแสและแรงดัน
วัตต์ฮาวร์	1. รูปแบบการใช้ไฟจะเปลี่ยนแปลง ไม่เป็นคาบเหมือนการใช้ไฟก่อนหน้า 2. หน่วยการใช้ไฟลดลงผิดปกติ	2. รูปแบบการใช้ไฟมีแนวโน้มเข้าใกล้ศูนย์สำหรับบางกรณี 2. หน่วยการใช้ไฟลดลงผิดปกติ	1. รูปแบบคาบการใช้ไฟ และความต่อเนื่อง

3.1.5.3 สรุปรูปแบบความแตกต่างลักษณะละเมิดกับชำรุด

จากหัวข้อ 2.1.5.1 วิเคราะห์ความแตกต่างระหว่างลักษณะปกติ ละเมิด และชำรุด และหัวข้อ 3.1.5.2 เปรียบเทียบความแตกต่างระหว่างการละเมิดกับลักษณะชำรุด ผลการวิเคราะห์นำมาสรุปแยกตามรูปแบบการเกิดของแต่ละตัวแปร ได้แก่ แรงดัน กระแส มูม และค่าหน่วย(kWh) สรุปผลความแตกต่างได้ดังตารางที่ 3-12

ตารางที่ 3-12 เปรียบเทียบและข้อสังเกตรูปแบบการเกิดที่ส่งผลต่อลักษณะปกติ ขำรุด และละเมิด

ข้อมูลดิบ	รูปแบบการเกิด	ข้อสังเกต	ปกติ	ขำรุด	ละเมิด
แรงดัน	แรงดันลดลง หรือเป็นศูนย์	ค่าแรงดันผิดปกติ	-	✓	✓
	แรงดันไม่สมดุลเฟส	ค่าแรงดัน Unbalance	-	✓	✓
กระแส	กระแสลดลง	ใช้ไฟน้อยลง	✓	✓	✓
	กระแสบางเฟสเป็นศูนย์	ใช้ไฟบางเฟส	✓	✓	✓
	กระแสไม่สมดุลเฟส	ใช้ไฟไม่สมดุลเฟส	✓	✓	✓
มูมและเฟสเซอร์	เฟสเซอร์ทำมูมผิดปกติ	มูมกระแสและแรงดัน	-	✓	✓
	เฟสเซอร์/ทิศทางผิดปกติ	เฟสเซอร์กระแส/แรงดัน	-	✓	✓
วัตต์ฮาว์	วัตต์ฮาว์ลดลง	จากสถิติย้อนหลัง	✓	✓	✓

หมายเหตุ: เมื่อ [-] คือไม่มีโอกาสเกิดขึ้น และ [✓] คือมีโอกาสเกิดขึ้น ซึ่งกรณีปกติ อาจเกิดจากผู้ใช้ไฟไม่มีการใช้ไฟ ใช้ไฟไม่สมดุลเฟส หรือใช้ไฟเพียงบางเฟส บางเฟสเป็นศูนย์ กรณีขำรุดอาจเกิดจากมิเตอร์หรืออุปกรณ์ประกอบขำรุด และกรณีเกิดความผิดปกติเกิดขึ้น ระบบ Monitoring จะแจ้งเตือนผ่านระบบ

3.2 การเตรียมข้อมูล (Data Preparation)

ขั้นตอนการเตรียมข้อมูลถือเป็นส่วนหนึ่งที่มีความสำคัญ เป็นการปรับปรุงข้อมูลให้มีความถูกต้องครบถ้วนและเป็นมาตรฐานเดียวกัน ดังนั้นในขั้นตอนนี้จะประกอบด้วย 3 ส่วนหลัก ดังนี้

3.2.1 การปรับปรุงข้อมูลให้สมบูรณ์ (Interpolation)

มิเตอร์ AMR ติดตั้งใช้งานตั้งแต่ปี 2550 แบ่งออกเป็น 2 เฟส ในเฟส 2 ได้มีการอัปเดตการเก็บบันทึกข้อมูลเพื่อเพิ่มประสิทธิภาพ ทำให้ข้อมูลที่มีเตอร์ AMR บันทึกได้ไม่เหมือนกัน บางข้อมูลมีไม่ครบถ้วน หรือขาดหายไปบางส่วน ดังนั้นกระบวนการปรับแก้ไขข้อมูลให้ถูกต้องจึงมีความจำเป็น เพื่อปรับปรุงข้อมูลก่อนนำไปใช้งาน ในงานวิจัยเลือกใช้วิธีการหาค่าเฉลี่ยเพื่อปรับแก้ไขข้อมูลสำหรับข้อมูลที่ขาดหายไปบางส่วนหรือไม่มีค่า [32] ดังสมการที่ (3-1)

$$f(x_i) = \begin{cases} \frac{x_{i-1} + x_{i+1}}{2}; & x_i \in NaN, x_{i-1} \& x_{i+1} \notin NaN \\ 0 & ; x_i \in NaN, x_{i-1} \& x_{i+1} \in NaN \\ x_i & ; x_i \notin NaN \end{cases} \quad (3-1)$$

เมื่อ $f(x_i)$ คือ ค่าที่ได้จากการปรับปรุง และ x_i คือ ค่าของข้อมูลที่มีเตอร์บันทึกค่าได้

ในกรณีที่มีเตอร์ AMR เปลี่ยนแปลงการติดตั้ง หรือเลิกกิจการ เลิกใช้งานมิเตอร์ มิเตอร์ ลูกดังกล่าวจะถูกนำไปติดตั้งใช้งานให้กับผู้ใช้ไฟรายใหม่ หรือบางครั้ง มีการเปลี่ยนประเภทของผู้ใช้ไฟ เนื่องจากมีเพิ่มขนาดโหลดทำให้ต้องเปลี่ยนชนิดมิเตอร์ ทั้ง 2 สาเหตุส่งผลให้หน่วยที่มีเตอร์อ่านได้ไม่ต่อเนื่อง อาจเกิดหน่วยสูง-ต่ำ ผิดปกติ จึงต้องปรับปรุงหน่วยให้มีความถูกต้องและเหมาะสม โดยใช้กฎ สามซิกมา (three-sigma rule) เพื่อทำการแจกแจงปกติ ค่าของข้อมูลโดยใช้ค่าเฉลี่ยเลขคณิตที่เป็น จำนวนสามเท่าของส่วนเบี่ยงเบนมาตรฐาน [32] ดังสมการที่ (3-2)

$$f(x_i) = \begin{cases} avg(x) + 2 \cdot std(x) & ; \text{if } x_i > avg(x) + 2std(x) \\ x_i & ; \text{else} \end{cases} \quad (3-2)$$

เมื่อ $avg(x)$ คือค่าเฉลี่ยของข้อมูล $std(x)$ คือ ส่วนเบี่ยงเบนมาตรฐานของข้อมูล x_i

3.2.2 การทำข้อมูลให้เป็นมาตรฐาน (Normalization)

ภายหลังจากการปรับปรุงข้อมูลให้มีความถูกต้อง ครบถ้วนแล้ว ข้อมูลจะถูกนำมาทำให้เป็นมาตรฐานเดียวกันก่อนเข้าสู่การสกัดข้อมูล อีกทั้งด้วยโมเดลที่ใช้สำหรับจำแนกความผิดปกติมีความอ่อนไหวต่อข้อมูลประเภทตัวเลข ในงานวิจัยเลือกใช้การปรับมาตรฐานข้อมูลโดยใช้ MAX-MIN Scaling [32] ดังสมการที่ (3-3)

$$f(x_i) = \frac{x_i - \min(X)}{\max(X) - \min(X)} \quad (3-3)$$

เมื่อ $\min(X)$ คือ ค่าน้อยที่สุด, $\max(X)$ คือ ค่าที่มากที่สุดของช่วงข้อมูล X

3.3 การสกัดข้อมูล (Data Extraction)

ข้อมูลที่ได้จากการปรับให้เป็นมาตรฐานแล้วนั้นจะมีจำนวนมาก ในบางครั้งการป้อนข้อมูลทั้งหมดเข้าโมเดลโดยตรงอาจไม่เหมาะสม ทำให้โมเดลประมวลผลช้า อีกทั้งข้อมูลนั้นจะมีทั้งข้อมูลที่เป็นประโยชน์และไม่เป็นประโยชน์ ส่งผลให้โมเดลประมวลผลทั้ง 2 ส่วน ค่าที่ได้จึงไม่ถูกต้อง ดังนั้นการสกัดข้อมูลจึงเป็นส่วนสำคัญอย่างหนึ่งในงานวิจัยนี้ เพื่อปรับข้อมูลให้มีความถูกต้องและเหมาะสมก่อนป้อนเข้าสู่โมเดล เพราะหากข้อมูลที่สกัดได้ไม่มีคุณภาพจะทำให้โมเดลเรียนรู้และทำนายผลได้ไม่มีประสิทธิภาพเช่นกัน ดังนั้นในงานวิจัยนี้แบ่งการสกัดข้อมูลออกเป็น 4 ส่วนหลัก ดังนี้

3.3.1 สกัดข้อมูลโดยใช้ข้อมูลจากค่ามิเตอร์โดยตรง (AMR Data Extraction)

การเปลี่ยนแปลงลักษณะของโหนดที่เกิดขึ้นสามารถพิจารณาได้จากค่าพารามิเตอร์พื้นฐานได้แก่ แรงดัน กระแส และมุมเฟส โดยจะถูกแจ้งเตือนในระบบเฝ้าระวังของมิเตอร์ AMR ถึงลักษณะความผิดปกติที่เกิดขึ้นเช่น ค่ากระแสบางเฟสเป็นศูนย์ แรงดันไม่สมดุล เป็นต้น ซึ่งเหตุการณ์ดังกล่าวอาจเป็นได้ทั้งการละเมิดและเกิดอุปกรณ์ชำรุด ในบางกรณีหากความผิดปกติเริ่มต้นเกิดก่อนช่วงเวลาของการวิเคราะห์ ลักษณะการเปลี่ยนแปลงที่เกิดขึ้นจะตรวจสอบไม่พบ ดังนั้นในงานวิจัยได้รวบรวมข้อมูลที่ใช้ ประกอบด้วยผู้ใช้ไฟทั้งหมด 97 ราย แสดงรายละเอียดดังตารางที่ 3-13

จากข้อมูลในตารางที่ 3-13 สามารถสกัด feature ได้ทั้งหมด 37 features เป็นชนิด Numerical จำนวน 27 features และเป็นชนิด Nominal จำนวน 10 features (ใช้ one-hot encoding แปลงค่าเป็น column ย่อยๆ แบบ Binary 0/1 ตาม value ของข้อมูล) แบ่ง class 3 ลักษณะ คือ ปกติ (Normal), ชำรุด (Defective) และละเมิด (Theft) ข้อมูลแบ่งพิจารณาเป็น 2 ชุด คือ ค่าแรงดันและค่ากระแส ค่าทั้ง 2 ผ่านการทำ Normalization โดยใช้ Max-Min scaling และข้อมูลดิบประเภทค่าที่เป็นศูนย์ ข้อมูลที่หาย ข้อมูลที่เป็นช่องว่าง จะใช้ค่าเฉลี่ยในการเติมข้อมูล และคัดกรองข้อมูลที่ไม่สมบูรณ์ (มีเฉพาะบางค่า) ออก เพื่อตรวจจับลักษณะดังกล่าวในโดเมนเวลา การสกัดข้อมูลจะแบ่งตามลักษณะการวิเคราะห์จากค่ามิเตอร์โดยตรงได้ 3 วิธี ได้แก่

ตารางที่ 3-13 รายละเอียดการแบ่งข้อมูลแยกแต่ละประเภท

ลักษณะข้อมูล	จำนวนผู้ใช้ไฟ	ข้อมูลที่ใช้ (3 เดือน)
ปกติ	50 ราย	$50 \times 8,640 = 432,000$ ค่า
ชำรุด	20 ราย	$20 \times 8,640 = 172,800$ ค่า
ละเมิด	27 ราย	$27 \times 8,640 = 233,280$ ค่า
รวมทั้ง 3 ชนิด	97 ราย	$97 \times 8,640 = 838,080$ ค่า

หมายเหตุ ข้อมูลจากมิเตอร์เก็บค่าทุก 15 นาที 1 วันได้ 96 ค่า 3 เดือน เท่ากับ $96 \times 90 = 8,640$ ค่า

3.3.1.1 วิเคราะห์จากลักษณะความผิดปกติที่เกิดขึ้นในช่วงเวลาที่วิเคราะห์

แบ่งข้อมูลออกเป็นวันทำงาน(จันทร์-ศุกร์), วันเสาร์-วันอาทิตย์ และวันหยุดนักขัตฤกษ์ โดยในแต่ละวันจะถูกแบ่งเป็นช่วงเวลาเป็น 2 ช่วง คือช่วง Peak (09.00น.-22.00น.) และ Off-Peak

(22.00น.-09.00น.) จากการกำหนดจำนวนวัน 15,30,45,60,75,90 วัน ก่อนจนถึงระบบ AMR แจ้งเตือนความผิดปกติ แสดงรายละเอียดการแบ่งประเภทวัน ตามตารางที่ 3-14

ตารางที่ 3-14 การแบ่งช่วงเวลาวิเคราะห์ความผิดปกติที่เกิดขึ้นในช่วงเวลา

จำนวนวันที่ถูกแบ่ง (n)	ประเภทของวัน (t)	ช่วงเวลา (w)
The latest abnormality in 15 days ความผิดปกติที่พบล่าสุดในช่วง 15,30,45,60,75,90 วัน	วันทำงาน (Weekdays)	Peak
		Off-Peak
	วันเสาร์-อาทิตย์ (Saturdays or Sundays)	Peak
		Off-Peak
	(วันหยุด) Holiday	Peak
		Off-Peak

ข้อมูลที่ได้จากการแบ่งออกเป็นช่วงเวลา n , t และ w จะถูกนำมาสกัดโดยใช้ Z_{score} ตามสมการที่ (3-4)

$$Z_{score} = \frac{X_i - \hat{X}_i}{\sigma_{x_i}} \quad (3-4)$$

3.3.1.2 วิเคราะห์จากลักษณะความผิดปกติที่เกิดขึ้นก่อนช่วงเวลาที่วิเคราะห์

ก่อนช่วงเวลาที่วิเคราะห์จะพบบางเหตุการณ์ที่มีลักษณะลดลงแบบทันทีทันใด และลักษณะการไม่ใช้ไฟ [33] ในการสกัดจะใช้ข้อมูลหน่วยการใช้ไฟ (kWh) เพื่อจัดกลุ่มผู้ใช้ไฟแบ่งเป็น กลุ่มผู้ใช้ไฟสูงมาก กลุ่มผู้ใช้ไฟสูง กลุ่มผู้ใช้ไฟปานกลาง กลุ่มผู้ใช้ไฟน้อย และกลุ่มผู้ใช้ไฟน้อยมาก รวมถึงประเภทกิจการของผู้ใช้ไฟเช่น ธุรกิจขนาดเล็ก ธุรกิจขนาดกลาง ธุรกิจขนาดใหญ่ กิจการเฉพาะอย่าง เพื่อสกัดออกมาเป็นลักษณะที่ต้องใช้ ตารางที่ 3-15 แสดงการแบ่งขนาดของกิจการ ตามประเภทการคิดเงิน ประเภทแรงดัน ไฟฟ้า และกลุ่มการใช้ไฟ จากนั้นข้อมูลจะถูกนำมาคำนวณเพื่อกำหนดเป็นคุณลักษณะ (feature) ประกอบด้วย การคำนวณค่าตัวประกอบกำลังไฟฟ้า (Power factor), กำลังไฟฟ้าจริง (Real power) และกำลังไฟฟ้าเสมือน (Reactive Power) จากข้อมูลดิบโดยใช้สมการความสัมพันธ์ที่ (3-5) ถึง (3-12) มาคำนวณเพื่อสกัดเป็น feature

ตารางที่ 3-15 การแบ่งช่วงเวลาวิเคราะห์ความผิดปกติที่เกิดขึ้นก่อนช่วงเวลา

ขนาดของกิจการ	ประเภทการคิดเงิน	ประเภทแรงดันไฟฟ้า	แบ่งกลุ่มการใช้ไฟ
<ul style="list-style-type: none"> ▪ ขนาดของกิจการ ▪ บ้านอยู่อาศัย ▪ กิจการขนาดเล็ก ▪ กิจการขนาดกลาง ▪ กิจการขนาดใหญ่ ▪ กิจการเฉพาะอย่าง ▪ ส่วนราชการและองค์กรที่ไม่แสวงหากำไร ▪ สูบน้ำเพื่อการเกษตร ▪ ไฟฟ้าชั่วคราว 	<ul style="list-style-type: none"> ▪ DEMAND ▪ TOU ▪ TOD ▪ UNIT 	<ul style="list-style-type: none"> ▪ 115 kV ▪ 69 kV ▪ 22-33 kV ▪ 220/380 kV 	<ul style="list-style-type: none"> ▪ กลุ่มผู้ใช้ไฟสูงมาก ▪ กลุ่มผู้ใช้ไฟสูง ▪ กลุ่มผู้ใช้ไฟปานกลาง ▪ กลุ่มผู้ใช้ไฟน้อย ▪ กลุ่มผู้ใช้ไฟน้อยมาก

$$\text{Power Factor}(PF) = \cos \theta \quad (3-5)$$

$$\text{Active Power} = VI \cos \theta \quad (3-6)$$

$$\text{Total Active Power} = 3VI \cos \theta \quad (3-7)$$

$$\text{Re active Power} = VI \sin \theta \quad (3-8)$$

$$\text{Total Re active Power} = 3VI \sin \theta \quad (3-9)$$

$$P_{(t)} = V_{a(t)} I_{a(t)} \cos \theta_a + V_{b(t)} I_{b(t)} \cos \theta_b + V_{c(t)} I_{c(t)} \cos \theta_c \quad (3-10)$$

$$E_{(t)} = P_{a(t)} + P_{b(t)} + P_{c(t)} \quad (3-11)$$

$$E_{(dt)} = (P_{a(t)} + P_{b(t)} + P_{c(t)}) \cdot dt \quad (3-12)$$

เมื่อ $P_{(t)}$ คือ ค่ากำลังไฟฟ้าหน่วยเป็น kW, $E_{(t)}$ คือค่าพลังงานไฟฟ้า หน่วยเป็น kWh

3.3.1.3 วิเคราะห์ค่าระยะทางและความหนาแน่น (Distance and Density)

ในการวัดค่าระยะทาง จะใช้ข้อมูลหลังจากการจัดกลุ่มผู้ใช้ไฟ สร้างชุดข้อมูลเป็นค่าค่าหลักจากค่าเฉลี่ยรายเดือนของข้อมูลมิเตอร์ปกติ โดยแบ่งเป็น 3 ช่วงเวลา Weekdays ,Weekend และ Holiday จากนั้นคำนวณค่าระยะทางระหว่างค่าหลักกับค่าข้อมูลแต่ละ samples โดยใช้ Manhattan distance คำนวณสำหรับแต่ละกรอบเวลาและตลอดทั้งวัน ส่วน Euclidean distance และ จะคำนวณโดยใช้ window ทั้งหมด ดังสมการที่ (3-13) และ (3-14)

$$\text{Manhattan} = \left| P_{xi} - \frac{1}{N} \sum_{i=1}^k P_{xi} \right| \quad (3-13)$$

$$\text{Euclidean} = \sqrt{\sum_{i=1}^k \left(P_{xi} - \frac{1}{N} \sum_{i=1}^k P_{xi} \right)^2} \quad (3-14)$$

3.3.2 สกัดข้อมูลโดเมนเวลาและโดเมนความถี่ (Time and Frequency Domain)

การสกัดข้อมูลในหัวข้อนี้จะทำการแบ่งข้อมูลออกเป็น Window โดยการหา Window ที่เหมาะสม จากการสังเกตข้อมูลในระบบเฟ้าระวางของมิเตอร์ AMR จะพบว่ามิเตอร์ AMR จะแจ้งเตือนหลังพบความผิดปกติประมาณ 1-3 วัน จึงเลือก Window จากวันที่พบความผิดปกติ 1 วัน ก่อนหน้า 6 วัน รวม 7 วัน (มิเตอร์เก็บข้อมูลทุกๆ 15 นาที รวมทั้งหมด 672 ค่า) โดย 1 samples เท่ากับ 1 window (672 ค่า) ซึ่งเมื่อได้ window แล้วข้อมูลจะถูกนำไปสกัดใน 2 โดเมน แสดงรายละเอียดดังตารางที่ 3-16

ตารางที่ 3-16 การแบ่งข้อมูลออกเป็น sample (1สัปดาห์)

ลักษณะข้อมูล	จำนวนผู้ใช้ไฟ	ข้อมูล sample (1สัปดาห์)
ปกติ	50 ราย	50 samples
ชำรุด	20 ราย	20 samples
ละเมิด	27 ราย	27 samples
รวมทั้ง 3 ชนิด	97 ราย	97 samples

เมื่อแบ่งข้อมูลทั้งหมดออกเป็น window แล้ว ข้อมูลแต่ละกลุ่มจะถูกนำไปสกัดใน 2 โดเมนหลัก ประกอบด้วย โดเมนเวลา (Time domain) และโดเมนความถี่ (Frequency domain) รายละเอียดดังนี้

3.3.2.1 วิเคราะห์โดยแบ่งข้อมูลออกเป็นช่วงและคำนวณโดยใช้ค่าทางสถิติ

ในการวิเคราะห์จะแบ่งข้อมูลออกเป็น Window เท่ากับ 672 ค่า (7 วัน) เนื่องจากเป็นช่วงที่สอดคล้องกับการแจ้งเตือนของระบบ AMR จากนั้นทำการคำนวณค่าในช่วงเวลาที่เลือกโดยใช้ค่าทางสถิติดังนี้

- ก. ค่าสูงสุด (Maximum)
- ข. ค่าต่ำสุด (Minimum)
- ค. ค่าเฉลี่ย (Average)
- ง. ค่ามัธยฐาน (Median)
- จ. ค่าส่วนเบี่ยงเบนมาตรฐาน (standard deviation)

3.3.2.2 วิเคราะห์โดยใช้วิธีแยกองค์ประกอบของอนุกรมเวลา

การวิเคราะห์ในโดเมนเวลาจะเป็นการนำข้อมูลที่มีเตอร์ AMR เก็บค่าได้ทุก 15 นาที มาทำการวิเคราะห์ ในการสกัดข้อมูลโดยการแยกองค์ประกอบ Time series เป็นเทคนิคหนึ่งที่ยิยมใช้ในงานวิเคราะห์อนุกรมเวลา เป็นการนำองค์ประกอบในสัญญาณสกัดออกเป็น 4 ส่วน [34] ประกอบด้วย

- ก. Level คือ ค่าฐานสำหรับชุดข้อมูล
- ข. Trend คือ พฤติกรรมการเพิ่มขึ้นหรือลดลงเชิงเส้นของอนุกรมเมื่อเวลาผ่านไป
- ค. Seasonality คือ รูปแบบซ้ำหรือวงจรของพฤติกรรมเมื่อเวลาผ่านไป
- ง. Noise คือ ความแปรปรวนจากการสังเกต

3.3.2.3 วิเคราะห์โดยใช้ Auto-Correlation

ความสัมพันธ์อัตโนมัติ (Auto-Correlation) เป็นการวัดความสัมพันธ์ระหว่างค่าของชุดข้อมูลเดียวกันในช่วงเวลาที่ต่างกันเป็นค่าที่คำนวณได้ เพื่อใช้แสดงความสัมพันธ์ของค่าที่ประกอบอยู่ภายในอนุกรมเวลา (Time series) โดยที่ความยาวที่มีประสิทธิภาพของอนุกรมเวลาคือจำนวนจุดข้อมูลในชุดข้อมูลเดียวกันที่สอดคล้องกันในแต่ละลำดับ [35] แสดงดังสมการที่ (3-15) เมื่อ r_k คือ ความสัมพันธ์อัตโนมัติ สำหรับ $lag(k)$ และสมการที่ (3-16) เป็นการวิเคราะห์ข้อมูลโดยใช้ Pearson Correlation เพื่อวิเคราะห์หาความสัมพันธ์แต่ละ feature ที่มีนัยสำคัญต่อ class

$$r_k = \frac{\sum_{t=k+1}^n (y_t - \bar{y})(y_{t-k} - \bar{y})}{\sum_{t=1}^n (y_t - \bar{y})^2} \quad (3-15)$$

$$\rho(x_i, y_i) = \frac{\sum_{i=1}^n (x_i - \bar{x}_i)(y_i - \bar{y}_i)}{\sqrt{\sum_{i=1}^n (x_i - \bar{x}_i)^2 \sum_{i=1}^n (y_i - \bar{y}_i)^2}} \quad (3-16)$$

เมื่อ x_i, y_i เป็นข้อมูลของ feature x_i, y_i ตามลำดับ

3.3.2.4 วิเคราะห์โดยใช้การแปลงฟูรีเยร์แบบไม่ต่อเนื่อง

การวิเคราะห์ในโดเมนความถี่ ข้อมูลแต่ละค่าจะถูกแปลงให้อยู่ในรูปของค่าสัมประสิทธิ์ ซึ่งจะประกอบไปด้วยค่าที่เป็นจำนวนจริงและจำนวนจินตภาพ การแปลงฟูรีเยร์ แบบไม่ต่อเนื่องหรือการแปลงฟูรีเยร์ แบบเร็ว (FFT) เป็นอัลกอริทึมที่มีประสิทธิภาพวิธีหนึ่ง ซึ่งใช้ในการแปลงค่าจากอนุกรมเวลาให้อยู่ในโดเมนความถี่ ดังสมการที่ (3-17) การแปลงฟูรีเยร์นี้จะส่งต่อค่าสัญญาณแอมพลิจูดในลักษณะเป็นฟังก์ชันของความละเอียดในความถี่แปลงฟูรีเยร์ที่เป็นสัดส่วนโดยตรงกับความยาวของสัญญาณและการเปลี่ยนแปลงของลักษณะสัญญาณ

$$X[k] = \sum_{n=0}^{N-1} x(n) e^{-\frac{j2\pi kn}{N}} ; k = 0, \dots, N-1 \quad (3-17)$$

เมื่อ $x(n)$ เป็นค่าอนุกรมเวลาของสัญญาณ และ N เป็นจำนวน *window*

3.3.2.5 วิเคราะห์โดยใช้ความหนาแน่นของสเปกตรัมพลังงาน

การหาค่าความหนาแน่นสเปกตรัมพลังงาน (Power Spectral Density: PSD) จะเป็นการคำนวณต่อจากการแปลง FFT โดยใช้ค่าแอมพลิจูดคูณด้วยค่าคอนจูเกตเชิงซ้อนและกระจายค่าให้เป็นมาตรฐานตามความกว้างของช่องความถี่ ซึ่งช่วยให้เปรียบเทียบสัญญาณแบบสุ่มที่มีความยาวสัญญาณต่างกันได้อย่างแม่นยำ ดังสมการที่ (3-18)

$$P_x(e^{j\omega}) = \sum_{k=-\infty}^{\infty} r_x(k) e^{-jk\omega} \quad (3-18)$$

เมื่อ $r_x(k)$ คือ ความสัมพันธ์อัตโนมัติของสัญญาณ


3.3.3 สกัดข้อมูลโดยใช้การแปลงเวฟเลต Wavelet Transform

การแปลงเวฟเลต (Wavelet Transform) เป็นเทคนิคหนึ่งที่ถูกนำมาใช้ในการสกัดข้อมูล เนื่องด้วยการแปลงเวฟเลตนิยมนำมาใช้ในการวิเคราะห์ความแปรปรวน (variance) ของอนุกรมเวลาและความถี่ โดยในงานวิจัยจะทำการแปลงข้อมูลที่อยู่ในรูปอนุกรมเวลาที่เป็น 1 มิติ ให้เป็นรูปภาพ (image) หรือ 2 มิติ โดยใช้ Continuous wavelet transform (CWT) ซึ่งจะแปลงค่าจากอนุกรมเวลาเป็นค่าสัมประสิทธิ์ ตามสมการที่ (3-19) อยู่ในรูปของสแกโลแกรม (scalogram) ซึ่งในแต่ละสแกโลแกรมถูกนำเสนอเป็นภาพสี (color map) พิกเซล 128 สี

$$\psi(t) = \frac{1}{\sqrt{\pi B}} \exp\left(-\frac{t^2}{B}\right) \exp(j2\pi Ct) \quad (3-19)$$

เมื่อ $\psi(t)$ คือ Morlet, B คือพารามิเตอร์การเลื่อนตำแหน่ง C คือ พารามิเตอร์ของการปรับสเกล

ในการนำ CWT มาประยุกต์ใช้ จะวิเคราะห์โดยใช้ Morlet (amor) ซึ่งเป็นเวฟเลตที่มีค่าสเปกตรัมด้านเดียวและมีค่าเชิงซ้อนในโดเมนเวลา ในงานวิจัยใช้ CWT แบบ Single level (One dimensional continuous wavelet transform) โดยใช้คำสั่ง `cwtfilterbank` แสดงดังภาพประกอบที่ 3-2 ที่ซึ่งแสดงค่า time domain และ time-frequency domain ซึ่งข้อมูลจะแบ่งออกเป็น 2 ประเภท คือ ค่าแรงดันและค่ากระแส นำข้อมูลทั้ง 2 ค่าที่อยู่ในรูป time series ทำการแบ่งเป็น window ละ 7 วัน จำนวน 672 ค่า โดยแยกออกเป็น 3 เฟส (เฟส A เฟส B และเฟส C) จากนั้นทำการ reshape ข้อมูล แสดงดังตารางที่ 3-17 และตารางที่ 3-18



ภาพประกอบที่ 3-2 คำสั่ง `cwtfilterbank` เลือกใช้ Morlet wavelet

ตารางที่ 3-17 ข้อมูลแบ่งออกเป็น 3 กลุ่ม

ข้อมูล	เวกเตอร์ (mxn)
ปกติ	1X143,808
ชำรุด	1X56,448
ละเมิด	1X77,280
รวม	1X277,536

Reshape



ตารางที่ 3-18 ขนาดข้อมูลรูปภาพหลังการแปลง

ข้อมูล	เวกเตอร์ (mxn)	3 เฟส เวกเตอร์
ปกติ	214x672	642x672
ชำรุด	84x672	252x672
ละเมิด	115x672	345x672
ข้อมูลต่อกัน	413x672	1,239x672

3.3.4 สกัดข้อมูลโดยการแปลงเป็นรูปภาพ (Time Series to Image)

ข้อมูลที่อยู่ในลักษณะของอนุกรมเวลาบางรูปแบบมีความคล้ายกันเช่น กรณีผู้ใช้ไฟมีการใช้ไฟลดลง รูปแบบดังกล่าวเป็นสภาวะปกติเนื่องจากไม่มีการใช้โหลด หรืออาจเกิดจากการชำรุดของตัวอุปกรณ์ หรือการละเมิด ซึ่งอาจเป็นไปได้ทั้ง 3 กรณี ดังนั้นถ้าพิจารณาจากค่าตัวแปรที่มีเตอร์ AMR บันทึกราคาได้อาจไม่เพียงพอในการจำแนกความผิดปกติ การแปลงจาก 1 มิติ เป็น 2 มิติ เป็นอีกวิธีหนึ่งที่จะช่วยในการจำแนกความผิดปกติที่เกิดขึ้นได้ ในงานวิจัยเลือกใช้เทคนิคการแปลงทั้ง 4 เทคนิคประกอบด้วย

3.3.4.1 Recurrence Plot (RP)

พล็อตการเกิดซ้ำ Recurrence plot (RP) เป็นเทคนิคหนึ่งของการวิเคราะห์ข้อมูลแบบไม่เชิงเส้น เป็นการแสดงภาพ (หรือกราฟ) ของเมทริกซ์สี่เหลี่ยมจัตุรัส ซึ่งองค์ประกอบเมทริกซ์สอดคล้องกับเวลาที่สถานะของระบบไดนามิกเกิดขึ้นซ้ำ [36] สมการทางคณิตศาสตร์ พล็อตการเกิดซ้ำ (RP) จะถูกนิยามตามสมการที่ (3-20)

$$R_{i,j}(x(t)) = \begin{cases} 1, & \text{if } d(x(i), x(j)) < r, \\ 0, & \text{otherwise} \end{cases} \quad (3-20)$$

เมื่อ $R_{i,j}$ คือตัวแปรแสดงค่าตำแหน่งที่ (i, j) ใน พล็อตการเกิดซ้ำ (RP) เมทริกซ์ ที่ซึ่งเป็น 1 ถ้าระยะทางระหว่างองค์ประกอบ $x(i)$ และ $x(j)$ ของอนุกรมเวลา $x(t)$ มีค่าน้อยกว่าค่าเทรชโฮลด์ r หรือ เป็น 0 เมื่อเป็นค่าอื่น จากการจำกัดความนี้ พล็อตการเกิดซ้ำ (RP) จะประกอบด้วยกราฟแสดงค่าเป็นภาพไบนารี ที่ซึ่งมีเฉพาะพิกเซลที่มีความเข้มที่ต่ำกว่าค่าเทรชโฮลด์ r จะถูกเข้ารหัส อย่างไรก็ตามไม่

สามารถประมาณค่าเทรซโฮลด์ที่เหมาะสมได้ ดังนั้นค่าที่เปลี่ยนแปลงไปจากค่าเริ่มต้นของการเกิดซ้ำ (RP) ถูกเรียกว่า ระยะทางพล็อต โดยทั่วไปจะใช้จำแนกเมื่อต้องการกำหนดค่าเทรซโฮลด์ ในรูปแบบดังกล่าวการเปลี่ยนแปลง $d(x(i), x(j))$ จะถูกพล็อตและถูกพิจารณาค่ายกับภาพเชิงเส้น

3.3.4.2 Spectrogram (SG)

สำหรับการสร้างรูปภาพสเปกโตรแกรม spectrogram images (SG) ค่าสัญญาณอนุกรมเวลาจะถูกพิจารณาแยกเป็นส่วนๆ ในการกำหนดหน้าต่างต่าง(window) ที่ซึ่งปกติจะปรากฏในลักษณะการซ้อนทับและเกิด overlap จากนั้นจะใช้ Discrete Fourier Transform สำหรับทำการคำนวณขนาดของสเปกตรัมความถี่ในแต่ละหน้าต่าง กระบวนการแปลงสัญญาณนิยามดังสมการที่ (3-21)

$$X[k] = \sum_{n=0}^{N-1} x(n)\omega(n)e^{-\frac{2\pi i k n}{N}}; k = 0, \dots, N-1 \quad (3-21)$$

เมื่อ N คือ ความยาวของหน้าต่าง, $\omega(n)$ คือ ฟังก์ชันหน้าต่างแฮมมิง (Hamming window), k เป็นค่าที่เปลี่ยนแปลงตามค่าความถี่ $f(k) = kf(s)/n$, $f(s)$ คือ ค่าความถี่ในการสุ่มตัวอย่าง หน่วยเฮิร์ตซ์ สเปกโตรแกรมของสัญญาณที่แปลงแล้วคือ $x_t(k)$ ถูกกำหนดตามสมการที่ (3-22)

$$S(k, t) = |X_t(k)|^2 \quad (3-22)$$

จากนั้นเมทริกซ์ความถี่เวลาจะถูกทำให้เป็นค่ามาตรฐาน(normalize)เป็นภาพความเข้มระดับสีเทา (grey-scale intensity image) โดยมีช่วงที่ปรับขนาดระหว่าง $[0, 1]$ ใช้สมการที่ (3-23)

$$SI(k, t) = \frac{S(k, t) - \min(S)}{\max(S) - \min(S)} \quad (3-23)$$

3.3.4.3 Gramian Summation Angular Field (GASF)

Gramian Summation Angular Field (GASF) เป็นการแปลงรูปภาพที่ได้จากอนุกรมเวลา ซึ่งแสดงถึงความสัมพันธ์ชั่วคราวระหว่างค่าแต่ละคู่จากอนุกรมเวลา ซึ่งค่าอนุกรมเวลาจะถูกปรับขนาดและแปลงสัญญาณโดยใช้ระบบพิกัดเชิงขั้ว โดยเป็นไปตามสมการที่ (3-24)

$$GASF = \begin{cases} \phi = \arccos(x_i), -1 \leq x_i \leq 1, x_i \in \tilde{X} \\ r = \frac{t_i}{N}; t_i \in \mathbb{N} \end{cases} \quad (3-24)$$

โดยที่ t_i คือเวลาที่ถูกระบาย, N เป็นปัจจัยค่าคงที่ในการทำให้เป็นมาตรฐาน ของค่าสแปน (span) ระบบพิกัดเชิงขั้ว และ \tilde{X} คือ การรีสเกลของอนุกรมเวลา จากนั้นผลรวมตรีโกณมิติระหว่างจุดแต่ละจุดของอนุกรมเวลาที่แปลงแล้วคำนวณเพื่อระบุช่วงเวลาสหสัมพันธ์ (correlation) ภายในช่วงเวลาที่แตกต่างกันซึ่งได้มาจากสมการที่ (3-25) และ (3-26)

$$GASF = \begin{bmatrix} \cos(\phi_1 + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \\ \vdots & \ddots & \vdots \\ \cos(\phi_n + \phi_1) & \cdots & \cos(\phi_n + \phi_n) \end{bmatrix} \quad (2-25)$$

$$GASF = \tilde{X}' \cdot \tilde{X} - \sqrt{I - \tilde{X}^2} \cdot \sqrt{I - \tilde{X}^2} \quad (2-26)$$

I คือเวกเตอร์แถวหนึ่งหน่วย $[1, 1, \dots, 1]$ หลังจากแปลงรูปเป็นระบบพิกัดเชิงขั้ว โดยใช้อนุกรมเวลาในแต่ละครั้งเป็นพื้นที่เมตริก 1D

3.3.4.4 Markov Transition Field (MTF)

Markov Transition Field (MTF) เป็นการแปลงรูปภาพที่ได้มาจากอนุกรมเวลา ซึ่งแสดงถึงพื้นที่และการเปลี่ยนแปลงของความน่าจะเป็นสำหรับอนุกรมเวลาที่ไม่ต่อเนื่อง

กำหนดอนุกรมเวลา $X = \{x_1, \dots, x_n\}$ ดังสมการที่ (3-27)


$$MTF = \begin{bmatrix} w_{i,j} | x_1 \in q_i, x_1 \in q_1 & \cdots & w_{i,j} | x_1 \in q_i, x_n \in j \\ \vdots & \ddots & \vdots \\ w_{i,j} | x_n \in q_i, x_1 \in q_1 & \cdots & w_{i,j} | x_n \in q_i, x_n \in q_j \end{bmatrix} \quad (3-27)$$

เมื่อ q_i และ q_j ($q \in [1, Q]$) สอดคล้องกับ quantile bins ที่มีข้อมูล ณ เวลา i และ j และ $w_{i,j}$ หมายถึงความน่าจะเป็นการเปลี่ยนแปลงของ $q_i \rightarrow q_j$

3.3.5 สกัดข้อมูลโดยใช้การสร้างแบบจำลองสัญญาณ (Signal Modeling)

แรงบันดาลใจในการนำการสร้างแบบจำลองสัญญาณมาใช้คือ การลดขนาดของข้อมูล แต่ยังคงคุณสมบัติของข้อมูลเดิมไว้ ซึ่งวิธีนี้นิยมใช้ในงานด้านการพยากรณ์สัญญาณ การบีบอัดสัญญาณ และการลดปริมาณการส่งข้อมูลเพื่อทำการถอดรหัสที่ปลายทาง [37] ตัวอย่างโมเดลแสดงดัง

ภาพประกอบที่ 3-3 ข้อมูลที่อยู่ในรูปของอนุกรมเวลา $v(n)$ จะถูกป้อนผ่านโมเดล เพื่อประมาณค่าสัมประสิทธิ์ที่เหมาะสม $H(z)$ และประมาณค่าสัญญาณกลับเป็น $\hat{x}(n)$ โดยในงานวิจัยนี้เลือก 5 เทคนิคมาใช้สกัดข้อมูลเพื่อเปรียบเทียบความผิดพลาดเมื่อทำการแปลงข้อมูลกลับและความแม่นยำเมื่อใช้โมเดลจำแนก รายละเอียดประกอบด้วย



ภาพประกอบที่ 3-3 แบบจำลองสัญญาณ ป้อนข้อมูลเข้า $v(n)$ เพื่อประมาณค่า $\hat{x}(n)$

3.3.5.1 Pade Approximation

Pade approximation มีจุดเด่นที่สามารถประมาณค่าได้ดีสำหรับ $a_p(k)$ และ $b_q(k)$ ในช่วง $[0, p+q]$ ดังสมการที่ (3-28)

$$X(n+k) = \sum_{k=1}^p a_p(k)x(n-k) = \begin{cases} b_q(n) & ; n=0,1,\dots,q \\ 0 & ; n=q+1,\dots,q+p \end{cases} \quad (3-28)$$

เมื่อ สัญญาณ $x(n)$ เป็นจำนวนจริงหรือจำนวนเชิงซ้อนในช่วง $n=0,1,\dots,p+q$

3.3.5.2 Prony's Method

ด้วยข้อจำกัดวิธี Pade ซึ่งไม่รับประกันเสถียรภาพและความถูกต้องเมื่อข้อมูลออกนอกช่วง ซึ่งวิธี Prony ช่วยปรับปรุงข้อจำกัดนั้นได้ ดังสมการที่ (3-29) ถึง (3-31)

$$\sum_{l=0}^p a_p(l)r_x(k,l) = -r_x(k,0); k=1,2,\dots,p \quad (3-29)$$

$$r_x(k,l) = \sum_{n=q+1}^{\infty} x(n-l)x^*(n-k); k,l \geq 0 \quad (3-30)$$

$$b_q(n) = x(n) + \sum_{k=1}^p a_p(k)x(n-k); n=0,1,\dots,q \quad (3-31)$$

เมื่อ $r_x(k-l)$ คือ คอนจูเกตสมมาตรและ $b_q(n)$ เป็นเลขจำนวนเต็มสำหรับ $n=0,1,\dots,q$

3.3.5.3 Shanks' Method

วิธีการ Shanks เป็นการปรับปรุงวิธี Prony เพื่อลดความผิดพลาดของข้อมูลในช่วง $[0, \dots, q]$ สามารถทำการคำนวณค่าได้จากสมการที่ (3-32) ถึง (3-34)

$$\sum_{l=0}^q b_q(l) r_g(k-l) = r_{xg}(k); k=0, \dots, q \quad (3-32)$$

$$r_g(k-l) = \sum_{n=0}^{\infty} g(n-l) g^*(n-k) \quad (3-33)$$

$$r_{xg}(k) = \sum_{n=0}^{\infty} x(n) g^*(n-k) \quad (3-34)$$

เมื่อ r_g คือ autocorrelation ของ $g(n)$ และ $r_{xg}(k)$ เป็น cross-correlation sequence ระหว่าง $x(n)$ และ $g(n)$

3.3.5.4 Autocorrelation Method

สำหรับข้อมูลที่มีไม่จำกัดนั้น ข้อมูลที่อยู่นอกช่วง $[0, N]$ จะถูกกำหนดค่าเป็นศูนย์ ความสัมพันธ์ของวิธีการนี้แสดงดังสมการที่ (3-35) ถึง (3-36)

$$\sum_{l=1}^p a_p(l) r_x(k-l) = -r_x(k); k=1, 2, \dots, p \quad (3-35)$$

$$r_x(k) = \sum_{n=k}^N x(n) x^*(n-k); k \geq 0 \quad (3-36)$$

3.3.5.5 Covariance Method

สำหรับข้อมูลที่มีไม่จำกัดนั้น จะไม่กำหนดค่าข้อมูลที่อยู่นอกช่วง $n, n-1, \dots, n-p$ แต่ใช้สมการที่ (3-37) และ (3-38) สำหรับประมาณค่า

$$\sum_{l=1}^p a_p(l) r_x(k, l) = -r_x(k, 0); k=1, 2, \dots, p \quad (3-37)$$


$$r_x(k, l) = \sum_{n=p}^N x(n-l) x^*(n-k); k, l \geq 0 \quad (3-38)$$

3.4 โมเดลสำหรับจำแนกข้อมูล (Model Classification)

โมเดลที่ใช้สำหรับจำแนกข้อมูลเป็นส่วนที่มีความสำคัญอย่างหนึ่งในงานวิจัย เนื่องจากต้องพิจารณาเลือกให้เหมาะสมกับข้อมูลที่สกัดได้ ในปัจจุบันมีโมเดลหลากหลายชนิดที่ใช้ในงานประเภทจำแนก ในงานวิจัยนี้เลือกใช้โมเดลประเภทการเรียนรู้แบบมีผู้สอนและการเรียนรู้เชิง เนื่องจากได้มีการกำหนดประเภทข้อมูลซึ่งประกอบด้วย 3 กลุ่ม คือ กลุ่มผู้ใช้ไฟปกติ กลุ่มละเมิด และกลุ่มมิเตอร์ชำรุด

3.4.1 แบ่งข้อมูล (Splitting up Data)

ในการทดลองข้อมูลย้อนหลัง 15 ปี (ช่วงปี 2550-2564) จะถูกแบ่งข้อมูลสำหรับสอน (Training Set) คิดเป็น 70% และข้อมูลตรวจสอบความถูกต้อง (Validation set) คิดเป็น 30% ทดสอบ 10 ครั้ง ครั้งละ 20 รอบ และข้อมูลอีกชุดของปี 2565 สำหรับทดสอบโมเดล ตัวอย่างการแบ่งจำนวนข้อมูลสำหรับการสอน แสดงดังรูปภาพประกอบที่ 3-4



ภาพประกอบที่ 3-4 การแบ่งข้อมูลสำหรับสอน ประเมินและทดสอบ

3.4.2 โมเดลประเภทการเรียนรู้แบบมีผู้สอน (Supervised Learning)

เลือกโมเดล Machine learning สำหรับใช้ในการทดลอง โดยโมเดลที่เลือกใช้ทั้งหมด 8 ชนิด ประกอบด้วย SVM, NN, DT, KNN, LR, NB, GB, RF โดยใช้ scikit-learn versions 1.1.1 รันบนคอมพิวเตอร์ Intel Core i7-12700H CPU 2.30GHZ, 16 GB of RAM ในการรันโมเดลจะมีการปรับค่าพารามิเตอร์ที่เหมาะสม เพื่อให้โมเดลมีประสิทธิภาพสูงสุด รายละเอียดของการปรับค่าพารามิเตอร์ แสดงดังตารางที่ 3-19

ตารางที่ 3-19 การปรับค่าพารามิเตอร์ของโมเดลแต่ละชนิด

โมเดลแบบมีผู้สอน	กำหนดช่วงค่าพารามิเตอร์
Support vector machines (SVM)	C = 0.001, 0.01, 0.1 Kernel = Linear, Radial basis, Sigmoid
Neural network (NN)	C = 0.001, 0.01, 0.1 R = L1 norm, L2 norm
Decision tree (DT)	max_features = gini, entropy criterion = auto, sqrt, log2
k-Nearest Neighbors (KNN)	n_neighbors K = 3,5,7 p = 1 : manhattan_distance p = 2 : euclidean_distance p = arbitrary : minkowski_distance
Logistic Regression (LR)	C = 0.001, 0.01, 0.1 R = L1 norm, L2 norm
Naive Bayes (NB)	P = default V = 1e-09
Gradient boosting (GB)	n_estimators = 10,100,1000 learning_rate = 0.01, 0.1 max_depth = 3,5,7
Random forest (RF)	n_estimators = 10,100,1000 criterion = gini, entropy max_depth = none

หมายเหตุ: C: เป็นค่าที่ควบคุมส่วนผกผันการทำให้เป็นมาตรฐานและใช้เพื่อควบคุมการเกิด overfitting ของโมเดลในระหว่างการเรียนรู้ ; Kernel: เป็นการระบุประเภทเคอร์เนลที่จะใช้ในโมเดล; R: แสดงถึงประเภทของการทำให้เป็นมาตรฐาน; p: เป็นค่าสำหรับกำหนดตัววัดค่าระยะทางแต่ละชนิด; V: ส่วนของความแปรปรวนที่เพิ่มเข้าไปในผลต่างเพื่อความเสถียรในการคำนวณ ; learning_rate: เป็นการกำหนดค่าอัตราการเรียนรู้ในแต่ละชั้น; max_depth: การกำหนดค่าความลึกในแต่ละชั้น; n_estimators: กำหนดสาขาและแขนงย่อยของการแบ่งแยก

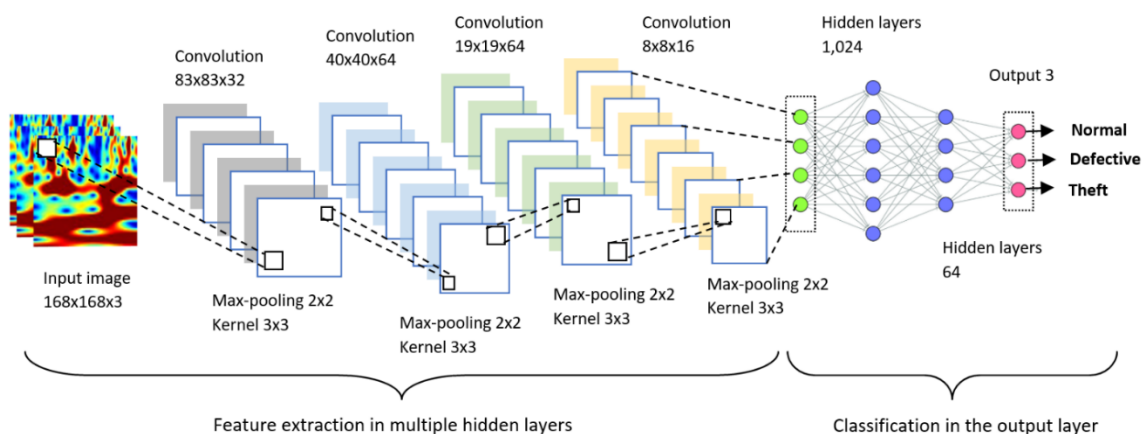
ในการปรับค่าจะใช้ค่าจากตารางที่ 3-19 โดยการทำ Hyperparameter tuning เพื่อหาค่าที่เหมาะสมกับโมเดล จะเลือกค่านั้นเป็นค่าหลักในการกำหนดค่าให้กับโมเดล

3.4.3 โมเดลประเภทการเรียนรู้เชิงลึก (Deep Learning)

ในงานวิจัยเลือกการเรียนรู้เชิงลึกประเภท Convolution Neural Network (CNN) และสถาปัตยกรรมที่พัฒนาต่อยอดจาก CNN เนื่องด้วยเป็นโมเดลที่นิยมใช้ในงานด้านจำแนกรูปภาพและมีโครงสร้างที่เหมาะสมในการจำแนกความผิดปกติ ได้แก่ CNN (base), LeNet5, AlexNet, VGGNet, GoogLeNet/Inception, ResNet และ DenseNet ในการสอนและทดสอบความถูกต้องแบ่งข้อมูลแบบเดียวกันกับหัวข้อที่ 3.4.1 แต่จะใช้ tensorflow และ keras เป็นเครื่องมือในการรันโปรแกรม ในส่วนค่าพารามิเตอร์ CNN (base), แสดงดังตารางที่ 3-20 และดังภาพประกอบที่ 3-5 ส่วนโมเดลที่เหลือกำหนดใช้ค่าตั้งต้นจากโปรแกรม (default) ในลักษณะ pre-trained

ตารางที่ 3-20 การกำหนดค่าพารามิเตอร์ CNN (base)

No.	Layer (type)	Output shape	Filter size	Stride size	Dropout
1.	Input	168x168x3	-	-	-
2.	Convolution1	166x166x32	3x3	-	-
3.	Relu	166x166x32	-	-	-
4.	Max pooling	83x83x32	-	2x2	-
5.	Convolution2	81x81x64	3x3	-	-
6.	Relu	81x81x64	-	-	-
7.	Max pooling	40x40x64	-	2x2	-
8.	Convolution3	38x38x64	3x3	-	-
9.	Relu	38x38x64	-	-	-
10.	Max pooling	19x19x64	-	2x2	-
11.	Convolution4	17x17x16	3x3	-	-
12.	Relu	17x17x16	-	-	-
13.	Max pooling	8x8x16	-	2x2	-
14.	Flatten	1x1x1,024	-	-	-
17.	Dropout	1x1x1,024	-	-	0.25
18.	Fully connected	1x1x64	-	-	-
19.	Softmax	1x1x64	-	-	-



ภาพประกอบที่ 3-5 โครงสร้างพื้นฐาน CNN ที่ใช้และการกำหนดค่า

3.5 การประเมินผลโมเดล (Model Evaluation)

สิ่งสำคัญก่อนนำโมเดลไปใช้งานคือ การประเมินผลประสิทธิภาพของโมเดล ในงานวิจัยนี้เลือกใช้ตัวประเมินโมเดลจำนวน 5 ชนิด ประกอบด้วย Accuracy Recall Precision F1-score False Positive Rate(FPR) และ AUC (Area Under Curve) รายละเอียดสมการและการประเมินผลแสดงอยู่ในบทที่ 1 หัวข้อ 1.2.4 การประเมินผลโมเดลที่ใช้จำแนก ตารางที่ 3-3 ซึ่งจากผลการทดลองยังพบว่า จำนวนข้อมูลที่ไม่สมดุลกันในแต่ละ class จะมีผลต่อการเรียนรู้ของโมเดลและมีโอกาสทำให้โมเดลเกิดการ bias ได้ ดังนั้น ทางผู้วิจัยได้ศึกษาเทคนิคการจัดการกับข้อมูลที่ไม่สมดุล ดังหัวข้อที่ 3.6 เพื่อนำมาปรับสมดุลข้อมูลเปรียบเทียบก่อนและหลังจำแนก ที่สำคัญเพื่อเพิ่มความแม่นยำในการเรียนรู้ของโมเดล

3.6 เทคนิคการจัดการข้อมูลที่ไม่สมดุล (Unbalanced Data Handling Techniques)

ปัญหาข้อมูลไม่สมดุล เป็นปัญหาหนึ่งที่มีความสำคัญในงานด้านวิทยาศาสตร์ข้อมูล เพราะสิ่งนี้จะส่งผลต่อการเรียนรู้ของโมเดล ข้อมูลที่ใช้ในการทดลองมีความไม่สมดุล ข้อมูลปกติจะมีจำนวนมากเพราะเป็นสิ่งที่เกิดขึ้นในทุกๆวัน เหตุการณ์มีเตอร์ชำรุด หรืออุปกรณ์ประกอบชำรุดจะเกิดขึ้นน้อยในแต่ละปี และเหตุการณ์การละเมิดของผู้ใช้ไฟเกิดขึ้นหรือพบค่อนข้างน้อยแต่ส่งผลกระทบต่อหน่วยสูญเสียค่อนข้างมาก ดังนั้นในงานวิจัยนี้ให้ความสำคัญการจัดการข้อมูลไม่สมดุล เพื่อโมเดลที่ถูกสร้างสามารถเรียนรู้และทำนายได้อย่างมีประสิทธิภาพ ในการแก้ปัญหาเหล่านี้ งานวิจัยนี้นำเสนอเทคนิคที่ทำให้ข้อมูลสมดุลประกอบด้วย 3 เทคนิค ดังนี้

- ก. การสร้างโมเดลความผิดปกติ (Anomaly model)
 - ข. การสุ่มตัวอย่างแบบสังเคราะห์ที่ปรับเปลี่ยนค่าได้ (Adaptive synthetic sampling (ADASYN))
 - ค. การเพิ่มข้อมูลโดยการปรับแต่งรูปภาพ (Image data augmentation)
- ทั้ง 3 เทคนิค จะถูกมาใช้เพื่อแก้ปัญหาข้อมูลไม่สมดุลโดยใช้ข้อมูลชนิดเดียวกัน

3.6.1 สร้างโมเดลความผิดปกติ (Anomaly Model)

หลากหลายรูปแบบของพฤติกรรมการใช้ไฟที่พบในมิเตอร์ AMR เป็นผลมาจากประเภทผู้ใช้ไฟ การเปลี่ยนแปลงของโหลดในแต่ละช่วงเวลา การสร้างโมเดลความผิดปกติพบในบทความ [38] ที่ถูกสร้างขึ้นเพื่อจำลองลักษณะความผิดปกติที่เกิดจากการละเมิด ดังนั้นในงานวิจัยนี้ได้ศึกษาและทำความเข้าใจ เพื่อสร้างโมเดลความผิดปกติขึ้นมาอาศัยและเทียบเคียงกับรูปแบบความผิดปกติที่พบใน AMR ซึ่งประกอบด้วย 2 โมเดลหลักคือ โมเดลสำหรับสร้างข้อมูลชำรุดและโมเดลสำหรับสร้างข้อมูลละเมิด รายละเอียดดังนี้

3.6.1.1 โมเดลสำหรับสร้างข้อมูลชำรุด (Defective Models)

ลักษณะชำรุดที่พบในมิเตอร์ AMR มีหลากหลายประเภทแต่สามารถแบ่งได้ 2 ส่วนหลักคือ เกิดขึ้นจากภายในมิเตอร์ เช่น เวลาคลาดเคลื่อนจากตัวโปรแกรม โปรแกรมคำนวณผิดปกติ ตัวแสดงผลผิดปกติ เป็นต้น และเกิดจากภายนอก เช่น เกิดจากผู้ใช้ไฟใช้โหลดเกิน เกิดจากจุดต่อชำรุด ฟิวส์ เป็นต้น จากรูปแบบที่กล่าวข้างต้นสามารถเขียนเป็นสมการได้ดังตารางที่ 3-21

ในตารางที่ 3-22 จะสรุปรูปแบบข้อมูลที่สร้างขึ้นแบบชำรุดและละเมิดจากเหตุการณ์ที่พบจริงโดยเรียนรู้รูปแบบความผิดปกติในบทความที่ได้ทำการทบทวนวรรณกรรมมาและนำมาสร้างเป็นสมการที่สอดคล้องกับรูปแบบที่พบจากมิเตอร์ AMR จากนั้น จำลองตัวอย่างในโปรแกรมเพื่อสร้างสัญญาณใหม่ที่ผิดปกติขึ้นมา

ตารางที่ 3-21 โมเดลสำหรับสร้างข้อมูลชำรุด

โมเดล	โมเดลสำหรับสร้างข้อมูลชำรุด
อินพุต	แรงดันเฟส $p : V_{t,i}^n(p)$, กระแสเฟส $p : I_{t,i}^n(p)$ ในการสร้างทั้ง 2 ถูกแทนด้วยตัวแปร $x_{t,i}^n(p)$, n : normal sample
ตัวแปร	ค่าคงที่ γ , ตัวแปรที่เปลี่ยนแปลงตามเวลา : α_t , ov_t , ค่าเฉลี่ยรวม : $\bar{x}_{t,i}^n$
ผลลัพธ์	$\tilde{x}_{t,i}^{df}(p)$ คือ ผลลัพธ์ที่ได้จากการประมาณตามสมการชำรุด
กรณี: ชำรุด-1	แรงดันหรือกระแสเฟสใดๆ ลดลง (แต่ละเฟสต่างกันเพียงบางเฟส) $[\tilde{x}_{t,i}^{df}(a) = 1.05 * x_{t,i}^n(a)] \parallel [\tilde{x}_{t,i}^{df}(b) = 0.9 * x_{t,i}^n(b)] \parallel [\tilde{x}_{t,i}^{df}(c) = 0.45 * x_{t,i}^n(c)]; random(t)$ และสลับค่าคงที่ระหว่างเฟสแบบสุ่ม
กรณี: ชำรุด-2	แรงดันหรือกระแสทั้ง 3 เฟสไม่สมดุล $[\tilde{x}_{t,i}^{df}(a) = \alpha_t * x_{t,i}^n(a)] \& \& [\tilde{x}_{t,i}^{df}(b) = \alpha_t * x_{t,i}^n(b)] \& \& [\tilde{x}_{t,i}^{df}(c) = \alpha_t * x_{t,i}^n(c)]; 0.15 \leq \alpha_t \leq 0.85$
กรณี: ชำรุด-3	แรงดันหรือกระแสเฟสใดๆ สูงกว่าค่ามาตรฐาน (กระแสบางเฟสสูงผิดปกติ) $[\tilde{x}_{t,i}^{df}(a) = ov_t * x_{t,i}^n(a)] \parallel [\tilde{x}_{t,i}^{df}(b) = ov_t * x_{t,i}^n(b)] \parallel [\tilde{x}_{t,i}^{df}(c) = ov_t * x_{t,i}^n(c)]; 1.5 \leq ov_t \leq 5$
กรณี: ชำรุด-4	แรงดันหรือกระแสทั้ง 3 เฟสลดลงอย่างสม่ำเสมอ $[\tilde{x}_{t,i}^{df}(a) = \alpha_t * \bar{x}_{t,i}^n(a)] \& \& [\tilde{x}_{t,i}^{df}(b) = \alpha_t * \bar{x}_{t,i}^n(b)] \& \& [\tilde{x}_{t,i}^{df}(c) = \alpha_t * \bar{x}_{t,i}^n(c)]; 0.5 \leq \alpha_t \leq 0.95$
กรณี: ชำรุด-5	แรงดันหรือกระแสเป็นศูนย์บางช่วงเวลาทั้ง 3 เฟส $\tilde{x}_{t,i}^{df}(a) = \tilde{x}_{t,i}^{df}(b) = \tilde{x}_{t,i}^{df}(c) = 0, \tau_0 - \tau_t$
กรณี: ชำรุด-6	แรงดันหรือกระแสเฟสใดเฟสหนึ่งลดลง $[\tilde{x}_{t,i}^{df}(a) = \gamma * x_{t,i}^n(a)] \& \& [\tilde{x}_{t,i}^{df}(b) = \gamma * x_{t,i}^n(b)] \& \& [\tilde{x}_{t,i}^{df}(c) = \gamma * x_{t,i}^n(c)],$ $\gamma = \begin{cases} random(0.125, 0.925), \tau_{st} - \tau_{ed} \\ 1, otherwise \end{cases}$

ตารางที่ 3-22 รูปแบบข้อมูลที่สร้างขึ้นแบบชำรุดและละเมิดจากเหตุการณ์ที่พบจริง

รูปแบบสำหรับสร้างข้อมูลชำรุด	รูปแบบสำหรับสร้างข้อมูลละเมิด
แรงดันหรือกระแส เฟสใดๆ ลดลง (ต่างกันบางเฟส)	เฟสใดๆ ลดลงเป็นศูนย์ เพียงบางเฟส
แรงดันหรือกระแสทั้ง 3 เฟสไม่สมดุล	ทั้ง 3 เฟสลดลงเป็นศูนย์ที่เวลาเดียวกัน
แรงดันหรือกระแสเฟสใดๆ สูงกว่าปกติ (กระแสบางเฟสสูงผิดปกติ)	ทั้ง 3 เฟส ลดลงแบบคงที่
แรงดันหรือกระแสทั้ง 3 เฟสลดลงอย่างสม่ำเสมอ	แรงดันหรือกระแสเป็นศูนย์บางช่วงเวลา
แรงดันหรือกระแสเป็นศูนย์บางช่วงเวลาทั้ง 3 เฟส	แรงดันหรือกระแสเฟสใดเฟสหนึ่งลดลง
แรงดันหรือกระแสเฟสใดเฟสหนึ่งลดลง	

3.6.1.2 โมเดลสำหรับสร้างข้อมูลละเมิด (Theft Models)

จุดประสงค์หลักของการละเมิดคือเพื่อต้องการให้เครื่องวัดหรือมิเตอร์อ่านค่าได้น้อยกว่าปริมาณการใช้ไฟจริง ตัวอย่างเหตุการณ์ที่พบใน กฟภ. เช่น การต่อคร่อมบริเวณเทอร์มินอล การต่อตรงไปใช้งานโดยไม่ผ่านมิเตอร์ การจัดแฉะจนทำให้มิเตอร์เสียหาย เป็นต้น จากเหตุการณ์ที่พบโดยรวมสามารถนำมาประกอบการสร้างเป็นสมการได้ดังตารางที่ 3-23 รูปแบบการละเมิดที่เกิดขึ้นจะมีความสอดคล้องกับเหตุการณ์จริง

3.6.2 การสุ่มตัวอย่างแบบสังเคราะห์ปรับเปลี่ยนค่าได้ (Adaptive Synthetic Sampling)

การสุ่มตัวอย่างแบบสังเคราะห์ที่ปรับเปลี่ยนค่าได้ (ADASYN) เป็นหนึ่งในวิธีที่มีประสิทธิภาพสำหรับนำมาแก้ปัญหาข้อมูลไม่สมดุล [39] โดยการสร้างชุดข้อมูลที่น้อยกว่า ปรับเพิ่มขึ้นมาโดยอาศัยความสัมพันธ์ของค่าภายในชุดข้อมูล ปรับตามระยะทางและการกระจายตัวอย่างเหมาะสม วิธี ADASYN ที่ใช้ในงานวิจัยนี้จะปรับค่าแบบ multi class คือจะปรับค่าทั้ง 3 class แสดงดังตารางที่ 3-24 ข้อมูลจะถูกประเมินค่าผ่านระยะทางของชุดข้อมูลในแต่ละกลุ่มระหว่างความสัมพันธ์ของค่ากระแสและแรงดัน

3.6.3 การเพิ่มข้อมูลโดยการปรับรูปภาพ (Image Data Augmentation)

ในงานด้านคอมพิวเตอร์วิทัศน์ (Computer Vision) การเพิ่มข้อมูลโดยการปรับรูปภาพเป็นเทคนิคหนึ่งที่ได้รับคามนิยมสำหรับปรับข้อมูลให้สมดุลก่อนสอนโมเดล [40] ซึ่งมีหลายหลายวิธีที่รวมอยู่ในเทคนิคดังกล่าว ในงานวิจัยนี้เลือกใช้วิธีการปรับเชิงตำแหน่ง (Position augmentation) ในการเพิ่มข้อมูล แสดงดังตารางที่ 3-25 จะประกอบด้วยรายละเอียดแต่ละเทคนิคและพารามิเตอร์ที่กำหนด ซึ่งในการปรับแต่งค่าแต่ละแบบจะใช้คำสั่งสำเร็จรูปในการปรับแต่งภาพ โดยการกำหนดค่าพารามิเตอร์แบบสุ่มให้ให้ได้รูปแบบที่หลากหลาย

ตารางที่ 3-23 โมเดลสำหรับสร้างข้อมูลละเมิด

โมเดล	โมเดลสำหรับสร้างข้อมูลละเมิด
อินพุต	แรงดันเฟส $p : V_{t,i}^n(p)$, กระแสเฟส $p : I_{t,i}^n(p)$ ในการสร้างทั้ง 2 ถูกแทนด้วยตัวแปร $x_{t,i}^n(p)$, n :normal sample
ตัวแปร	ค่าคงที่ β_1, β_2 , ตัวแปรที่เปลี่ยนตามเวลา α_t , ค่าเฉลี่ยรวม: $\bar{x}_{t,i}^n$
ผลลัพธ์	$\tilde{x}_{t,i}^{th}(p)$ ผลลัพธ์ที่ได้จากการประมาณตามสมการละเมิด
กรณี: ละเมิด-1	แรงดันหรือกระแสเฟสใดๆ ลดลงเป็นศูนย์ เพียงบางเฟส $[\tilde{x}_{t,i}^{th}(a) = \beta_1 * x_{t,i}^n(a)] \parallel [\tilde{x}_{t,i}^{th}(b) = \beta_1 * x_{t,i}^n(b)] \parallel [\tilde{x}_{t,i}^{th}(c) = \beta_1 * x_{t,i}^n(c)],$ $\beta_1 = \begin{cases} 0, & \tau_{st} < t < \tau_{ed} \\ 1, & otherwise \end{cases}$
กรณี: ละเมิด-2	แรงดันหรือกระแสทั้ง 3 เฟสลดลงเป็นศูนย์ที่เวลาเดียวกัน $[\tilde{x}_{t,i}^{th}(a) = \beta_2 * x_{t,i}^n(a)] \& \& [\tilde{x}_{t,i}^{th}(b) = \beta_2 * x_{t,i}^n(b)] \& \& [\tilde{x}_{t,i}^{th}(c) = \beta_2 * x_{t,i}^n(c)],$ $\beta_2 = \begin{cases} 0, & \tau_{st} < t < \tau_{ed} \\ 0.9, & otherwise \end{cases}$
กรณี: ละเมิด-3	แรงดันหรือกระแสทั้ง 3 เฟส ลดลงแบบคงที่ $[\tilde{x}_{t,i}^{th}(a) = \alpha_t * x_{t,i}^n(a)] \& \& [\tilde{x}_{t,i}^{th}(b) = \alpha_t * x_{t,i}^n(b)] \& \& [\tilde{x}_{t,i}^{th}(c) = \alpha_t * x_{t,i}^n(c)],$ $0.15 \leq \alpha_t \leq 0.85$
กรณี: ละเมิด-4	แรงดันหรือกระแสทั้ง 3 เฟสลดลงกะทันหันและใกล้เคียงกันทั้ง 3 เฟส $[\tilde{x}_{t,i}^{th}(a) = \alpha_t * x_{t,i}^n(a)] \parallel [\tilde{x}_{t,i}^{th}(b) = \alpha_t * x_{t,i}^n(b)] \parallel [\tilde{x}_{t,i}^{th}(c) = \alpha_t * x_{t,i}^n(c)],$ $random \alpha_t \text{ for } t \text{ in } 0 \leq \alpha_t \leq 0.75$
กรณี: ละเมิด-5	แรงดันหรือกระแสเฟสใด กลับทิศทางหรือไหลย้อนกลับ $[\tilde{x}_{t,i}^{th}(a) = inverse(x_{t,i}^n(a))] \parallel [\tilde{x}_{t,i}^{th}(b) = inverse(x_{t,i}^n(b))] \parallel [\tilde{x}_{t,i}^{th}(c) = inverse(x_{t,i}^n(c))],$

ตารางที่ 3-24 โมเดลการสร้างข้อมูลทั้ง 3 classes โดยใช้ ADASYN

โมเดล	การสร้างข้อมูลทั้ง 3 classes โดยใช้ ADASYN
อินพุต	$V_{t,i}(p)$ และ $I_{t,i}(p)$ ถูกแทนด้วย $x_{t,j}^c(p)$ สำหรับอาร์เรย์ของ $[X_t, y_t]$, ชุดข้อมูล $N(t=1, \dots, n)$
ตัวแปร	X_t คือตัวแทนของ n dimensional, y_t คือตัวกำหนดรูปแบบทั้ง 3 class ชุดข้อมูลของ $N = N_{ma} + N_{mi}$, $N_{mi} \leq N_{ma}$, โดยที่ N_{mi} คือ ชนกลุ่มน้อย (minority class), N_{ma} คือ ชนกลุ่มมาก (majority class)
ผลลัพธ์	S_t = ชุดข้อมูลใหม่ที่ถูกสร้างขึ้น
1	คำนวณระดับของกลุ่ม (degree of class) : $d = \frac{N_{mi}}{N_{ma}}$ โดยที่ $d \in [0,1]$
2	IF degree of class (d) < <i>preset threshold</i> (d_{thr})
3	then
4	จำนวนข้อมูลสังเคราะห์ทั้งหมด (G) = $(N_{ma} + N_{mi}) * \beta$ เมื่อ: β ค่าสมดุลของข้อมูลที่ต้องการโดยที่ $\beta \in [0,1]$
5	คำนวณอัตราส่วนของ $r_t = \frac{\Delta t}{K}$, $t = 1, \dots, N_{ma}$ เมื่อ Δt จำนวนของชุดข้อมูลใน K nearest neighbors (Euclidean distance), $r_t \in [0,1]$
6	Normalize r_t and density distribution $\hat{r}_t = \frac{r_t}{\sum r_t}$, $\sum_t \hat{r}_t = 1$
7	คำนวณและสังเคราะห์ชุดข้อมูลใหม่ $g_t = \hat{r}_t * G$ เมื่อ; G จำนวนข้อมูลสังเคราะห์ทั้งหมด
8	For $t = 1$ to g_t
9	สุ่มเลือกค่าชนกลุ่มน้อย(minority) X_{ct} จาก $K \in X_t$
10	สร้างกลุ่มข้อมูลสังเคราะห์ $S_t = X_t + (X_{ct} - X_t) * \lambda$ เมื่อ; λ คือข้อมูลที่ถูกสุ่มสำหรับช่วง $\lambda \in [0,1]$
11	end
12	end

ตารางที่ 3-25 รายละเอียดและพารามิเตอร์ของวิธีการปรับเชิงตำแหน่ง (Position Augmentation)

เทคนิคที่ใช้	คำอธิบายการทำงาน	พารามิเตอร์ที่กำหนด
Scaling	ภาพจะถูกปรับขนาดตามขนาดที่กำหนด	(126x126), (109x109), (92x92), (76x76), (59x59), (42x42)
Cropping	ภาพจะถูกเลือกบางส่วน (อ้างอิงตรงกลาง)	138, 108,78,48
Flipping	ภาพพลิกในแนวตั้งหรือแนวนอน	random p [0.5, 1]
Padding	ทุกด้านของรูปภาพถูกเสริมด้วยค่าที่กำหนด	random (a,b,c,d) range [1,30]
Rotation	ภาพจะถูกหมุนแบบสุ่ม	rotate range [0-270]
Translation	ภาพจะเคลื่อนไปตามแกน x-axis หรือแกน y-axis.	random translate [0.1-0.9]
Zooming	ภาพจะถูกซูมเข้าที่อัตราส่วนต่างๆ	random range [0.1,1]
Affine transform	การแปลงโดยจะคงไว้ซึ่งเส้นตรง ระนาบ และจุด	random degree [0,90], scale [0.1,0.9]

3.6.4 การแบ่งข้อมูลสำหรับสอนและทดสอบเทคนิคการจัดการข้อมูลที่ไม่สมดุล

ในการแบ่งข้อมูลสำหรับสอนและทดสอบหัวข้อนี้จะแตกต่างไปกับการทดลองที่ผ่านมา เนื่องจากข้อมูลทั้ง 3 เฟสจะถูกรวมเป็นข้อมูลชุดเดียวกัน แสดงดังตารางที่ 3-26 จากนั้นจะทำการเปรียบเทียบผลการจำแนกโดยใช้สถาปัตยกรรมของการเรียนรู้เชิงลึก (Deep learning Architecture) ซึ่งได้กล่าวทฤษฎีไว้เบื้องต้นในหัวข้อที่ 2.7 โครงข่ายประสาทเทียมคอนโวลูชัน (CNN) ในการทดลองประกอบด้วย 6 โมเดล ได้แก่ LeNet5 AlexNet VGGNet19 Densenet121 ResNet50 และ InceptionV3 โดยแต่ละโมเดลจะจับคู่กับ 4 รูปแบบคือ ข้อมูลไม่สมดุล (No balance) วิธีโมเดลความผิดปกติ (Anomaly model) วิธีการสุ่มตัวอย่างแบบสังเคราะห์ที่ปรับเปลี่ยนค่าได้ (ASASYN) และการเพิ่มข้อมูลโดยการปรับแต่งรูปภาพ (IM)

ตารางที่ 3-26 จำนวนข้อมูลแรงดันและกระแสที่ทำสมดุลทั้ง 4 รูปแบบ

วิธีการ	No balance		Anomaly model		ADASYN		Image augmentation	
	แรงดัน	กระแส	แรงดัน	กระแส	แรงดัน	กระแส	แรงดัน	กระแส
ปกติ	4,038	2,429	4,038	2,429	4,048	2,425	4,038	2,429
ชำรุด	530	1,263	4,038	2,429	4,037	2,447	4,038	2,429
ละเมิด	222	679	4,038	2,429	4,059	2,441	4,038	2,429
จำนวนรวม	4,790	4,371	12,114	7,287	12,144	7,313	12,114	7,287


จากผลที่ได้จากการสอนและปรับความถูกต้องของโมเดล โมเดลจะถูกนำไปทดสอบกับข้อมูลอีกชุด ซึ่งเป็นข้อมูลที่โมเดลไม่ได้เรียนรู้มาก่อนและกับหน้างานจริง รายละเอียดดังหัวข้อที่ 3.7

3.7 วิธีการทดสอบโมเดล (Test Model)

จากการรวบรวมข้อมูลแต่ละชนิดแล้วนำมาจำแนกเพื่อเตรียมข้อมูลก่อนทำการสกัดเป็น feature ข้อมูลจะต้องมีความถูกต้องและเป็นมาตรฐานเดียวกัน feature ที่สกัดได้นั้นจะแบ่งเป็น 2 ส่วน ได้แก่ ข้อมูลสำหรับสอนโมเดล (train) และข้อมูลสำหรับปรับโมเดลให้มีความถูกต้อง (validation) จากนั้น feature จะถูกป้อนเข้าสู่โมเดลเพื่อให้โมเดลเรียนรู้และจำแนกความแตกต่างของแต่ละรูปแบบ เมื่อโมเดลเรียนรู้ (train) และทำการปรับค่า validation แล้ว โมเดลจะถูกนำมาทดสอบ (test) กับข้อมูลอีกชุด ประกอบด้วย ข้อมูลในช่วงเวลาปัจจุบันและข้อมูลที่ได้จากเหตุการณ์จริง รายละเอียดดังต่อไปนี้

3.7.1 ทดสอบโมเดลจากข้อมูลชุดอื่น (Test with Real Data)

ด้วยในงานวิจัยใช้ข้อมูลในอดีตช่วงปี 2550-2564 สำหรับสอนและปรับโมเดล โดยข้อมูลปี 2565 จะถูกนำมาใช้ทดสอบจากการรวบรวมข้อมูลผ่านเว็บ AMR monitoring โดยการสุ่มเลือกข้อมูลจากทุกภาคทั่วทุกจังหวัดที่อยู่ในความรับผิดชอบของ กฟภ. ซึ่งสิ่งสำคัญในการทดสอบจะเลือกเฉพาะโมเดลที่ได้ผลลัพธ์ที่ดีเท่านั้น ขั้นตอนการทดสอบโมเดลกับชุดข้อมูลอื่นแสดงดังภาพประกอบที่ 3-6




AMR monitoring

ภาพประกอบที่ 3-6 ขั้นตอนการทดสอบโมเดลจากข้อมูลชุดอื่น

3.7.2 ทดสอบโมเดลจากเหตุการณ์จริง (Test with Real Events)

สำหรับการทดสอบนี้จะเป็นการทดลองนำโมเดลที่ได้ไปใช้งานจริง เริ่มต้นจากการตรวจสอบผ่านระบบ AMR monitoring เมื่อพบความผิดปกติ ข้อมูลจะถูกนำออกมาในรูปแบบไฟล์ excel และนำไฟล์ดังกล่าวป้อนเข้าสู่โมเดลโดยรันบนโปรแกรม Jupyter notebook เมื่อได้ผลลัพธ์แล้วจะออกไป

ตรวจสอบหน้างานจริงเพื่อพิสูจน์และยืนยันผลการจำแนกของโมเดล โดยกระบวนการขั้นตอนการทดสอบโมเดลกับเหตุการณ์จริงแสดงดังภาพประกอบที่ 3-7



ภาพประกอบที่ 3-7 ขั้นตอนการทดสอบโมเดลจากเหตุการณ์จริง

จากการทดลองยังคงพบประเด็นที่ว่า ข้อมูลที่ใช้มีหลายหลากกลุ่ม หลายหลายประเภท ผู้ใช้ไฟ ถึงแม้ว่าในงานวิจัยได้กำหนดของเขตแล้วบางส่วนก็ตาม ดังนั้นในหัวข้อที่ 2.8 จะเป็นการศึกษาและทดลองโดยใช้เทคนิคการแบ่งกลุ่มข้อมูลเพื่อนำมาเปรียบเทียบสำหรับเพิ่มประสิทธิภาพให้กับโมเดล


3.8 การใช้เทคนิคการจัดกลุ่มข้อมูล

3.8.1 เทคนิคที่ใช้จัดกลุ่ม

เมื่อพิจารณาข้อมูลที่น่าใช้วิเคราะห์เพื่อจำแนกความแตกต่างพบว่า ข้อมูลบางส่วนมีเพียงโหนดโปรไฟล์ ไม่มีรายละเอียดเกี่ยวกับประเภทผู้ใช้ไฟ ซึ่งข้อมูลที่ใช้ประกอบด้วยผู้ใช้ไฟหลากหลายประเภท ไม่ว่าจะเป็นบ้านที่อยู่อาศัย ร้านค้า ธุรกิจขนาดเล็ก กลางและใหญ่ ในบางรูปแบบมีพฤติกรรมการใช้โหนดที่ต่างกัน เช่นร้านค้าที่เปิดบริการเฉพาะกลางวัน แตกต่างกับธุรกิจโรงแรมหรืออพาร์ทเมนต์ ที่เปิดตลอด 24 ชั่วโมงและใช้โหนดสูงช่วงกลางคืน รวมถึงโรงงานอุตสาหกรรมที่เดินเครื่องตลอดเวลา เป็นต้น ดังนั้นการแบ่งประเภทโดยใช้เกณฑ์ของกลุ่มความผิดปกติอาจไม่เพียงพอสำหรับการนำมาจัดประเภทโหนด อีกทั้งหากต้องการจำแนกเชิงลึกเพื่อให้ทราบถึงสาเหตุของความผิดปกตินั้น การจัดกลุ่มก่อนและหลังแยกประเภทอีกวิธีหนึ่งที่จะช่วยเพิ่มประสิทธิภาพและความถูกต้องให้กับโมเดล


ในงานวิจัยนี้เลือกใช้วิธี k-mean clustering มาช่วยในการจัดกลุ่ม ดังแสดงในภาพประกอบที่ 3-8 ข้อมูลใน 1 window จำนวน 168 ค่าสำหรับ 1 ผู้ใช้ไฟ ถูกนำมาหาเฉลี่ยและค่าส่วน

เขียนมาตรฐาน เพื่อเป็นตัวแทนข้อมูล จากนั้นพล็อตเพื่อจัดกลุ่มโดยใช้ K-mean Clustering และใช้ Silhouette Coefficient เพื่อประเมินผลการจัดกลุ่ม




ภาพประกอบที่ 3-8 แสดงขั้นตอนการจัดกลุ่ม

ในการทดลองทำการปรับเปลี่ยนค่า k ตั้งแต่ k=2 ถึง k=7 และเลือก Silhouette Score ที่มีค่าสูงที่สุดมาใช้เพื่อจัดกลุ่ม ภาพประกอบที่ 3-9 แสดงตัวอย่างการจัดกลุ่มแรงดันที่ชำรุด เช่น เมื่อกำหนดค่า k=2 ค่า Silhouette Score เท่ากับ 0.5220 และเมื่อปรับเพิ่มค่า k=5 ทำให้ค่า Silhouette Score ลดลงเท่ากับ 0.4833 ดังนั้นพบว่าค่า k=4 ให้ค่า Silhouette Score เท่ากับ 0.5576 ซึ่งมีค่าสูงสุด และภาพประกอบที่ 3-10 แสดงตัวอย่างการทำ dendrogram กับการจัดกลุ่มสำหรับกลุ่มทั้ง 4 กลุ่มของแรงดันที่ชำรุด




ภาพประกอบที่ 3-9 ตัวอย่างการจัดกลุ่มแรงดันที่ชำรุด



ภาพประกอบที่ 3-10 Dendrogram และการจัดกลุ่มสำหรับกลุ่มแรงดันที่ชำรุด


3.8.2 การจัดกลุ่มก่อนจำแนกรูปแบบผิดปกติ

จากผลการจัดกลุ่มรูปแบบปกติค่าแรงดันมีเพียง 1กลุ่ม ในขณะที่ค่ากระแสมีจำนวน 3 กลุ่ม นั่นคือค่าแรงดันไม่มีผลต่อการจัดกลุ่มก่อนจำแนก แต่ค่ากระแสจะมีผลต่อการจำแนกเพราะรูปแบบผิดปกติจะเปลี่ยนแปลงตามลักษณะการใช้ไฟ ตัวอย่างเช่น ผู้ใช้ไฟรายหนึ่งดังภาพประกอบที่ 3-11 มีการใช้ไฟตลอด 24 ชั่วโมง (ก) เมื่อเกิดความผิดปกติ CT ชำรุด (ข) ค่ากระแสจะลดลงใกล้เคียงศูนย์ ซึ่งจะเห็นความแตกต่างกับปกติอย่างชัดเจน ในขณะที่ภาพด้านขวา เป็นรูปแบบปกติที่ผู้ใช้ไฟมีการใช้โหลดเฉพาะช่วงเวลากลางวัน (ค) และช่วงเทศกาลที่มีการใช้โหลดน้อยลง (ง) มีค่าช่วงเวลาที่ค่ากระแสใกล้เคียงศูนย์ ดังนั้นหากไม่จัดกลุ่มรูปแบบดังกล่าวก่อนจำแนก อาจทำให้โมเดลสับสนและทำนายผิดพลาดได้



ภาพประกอบที่ 3-11 ค่ากระแสปกติและชำรุด(ก-ข) และค่ากระแสปกติ(ค-ง) ผู้ใช้ไฟรายหนึ่ง

สำหรับการออกแบบการทดลองจะพิจารณาเฉพาะค่ากระแส เพราะว่าสามารถแบ่งกลุ่มลักษณะปกติได้มากกว่า 1 กลุ่ม ข้อมูลที่ได้จากการจัดกลุ่มสำหรับค่ากระแสจะแบ่งเป็น class จำนวน 3class และใช้โมเดล DenseNet121 ซึ่งมี 3 ชุดเพื่อจำแนก แสดงรายละเอียดดังภาพประกอบที่ 3-12



ภาพประกอบที่ 3-12 การแบ่งกลุ่มอนุกรมเวลาของกระแสก่อนจำแนก

3.8.3 การจัดกลุ่มเพื่อแยกรูปแบบความผิดปกติตามสาเหตุการเกิด

ในการจัดกลุ่มจะเห็นได้ว่าการนำรูปแบบความผิดปกติมาแยกออกเป็นแต่ละกลุ่มคือ แรงดันขั้วรูดและแรงดันละเมิดได้ 4 กลุ่ม กระแสขั้วรูดและกระแสละเมิดได้ 3กลุ่ม เป้าหมายหลักของการนำรูปแบบผิดปกติมาจัดกลุ่มคือต้องการวิเคราะห์หาความสัมพันธ์ระหว่างความผิดปกติแต่ละกลุ่มกับสาเหตุการเกิด เพื่อนำไปพัฒนาต่อสำหรับฝึกสอนโมเดลให้สามารถจำแนกได้ถึงสาเหตุที่เกิดขึ้น เมื่อสามารถวิเคราะห์ได้ว่ารูปแบบความผิดปกติใดเกิดจากสาเหตุใด รูปแบบดังกล่าวจะถูกนำไปประยุกต์กับการสร้างข้อมูลโดยใช้โมเดลความผิดปกติ (Anomaly model) ในหัวข้อที่ 3.6.1 เพื่อให้ได้ข้อมูลที่สอดคล้องกับสาเหตุ จากตารางที่ 3-27 แสดงลักษณะการละเมิดและลักษณะขั้วรูด สามารถแบ่งข้อมูลได้อย่างละ 6 class โดยจะถูกนำไปจัดกลุ่มกับผลการแยกกลุ่มที่ได้จากหัวข้อ 3.8.1

ตารางที่ 3-27 รูปแบบละเมิดที่พบจริงกับรูปแบบขั้วรูดจากระบบแจ้งเตือน

รูปแบบละเมิดที่พบจริง	รูปแบบขั้วรูด ที่ระบบแจ้งเตือน
1.ตัดแปลง/แก้ไขสาย Control ชุดแรงดัน	1.Asymmetric Power
2.ตัดแปลง/แก้ไขสาย Control ชุดกระแส	2.Over Current
3.จัดแ่งชุด CT แรงต่ำ	3.Voltage unbalance
4.ต่อคร่อมชุดแรงดัน	4.Any phase current = 0
5.ต่อคร่อมชุดกระแส	5.Reverse power
6.ตัดสายนิวตรอน	6.Voltage Failure

บทที่ 4

ผลการวิจัย

ในบทนี้เนื้อหาเริ่มต้นจากการนำผลที่ได้จากการสกัดข้อมูลมาทำการวิเคราะห์ ใช้วิธีการสร้างภาพ สถิติ แผนภูมิ เพื่อศึกษาและเพื่อเปรียบเทียบแต่ละเทคนิค จากนั้นนำคุณลักษณะป้อนเข้าสู่โมเดลและประเมินผล โดยจะนำเสนอแยกเป็นแต่ละเทคนิค รวมถึงผลความแตกต่างของการจัดกลุ่มแต่ละรูปแบบที่ได้

4.1 ผลการสกัดข้อมูลโดยใช้ข้อมูลจากค่ามิเตอร์โดยตรง

4.1.1 ผลการสกัดข้อมูลโดยรวมการใช้เทคนิควิเคราะห์ข้อมูลโดยตรง

ในหัวข้อนี้จะเป็นการนำข้อมูลจากมิเตอร์ AMR มาสกัดโดยใช้ 3 เทคนิค ได้แก่

- ก. สกัดจากลักษณะความผิดปกติที่เกิดขึ้นในช่วงเวลาที่วิเคราะห์
- ข. สกัดจากลักษณะความผิดปกติที่เกิดขึ้นก่อนช่วงเวลาที่วิเคราะห์
- ค. สกัดจากค่าระยะทางและความหนาแน่น (Distance and density measurements)

ในตารางที่ 4-1 และตาราง 4-2 แสดงการได้มาซึ่งเทคนิคที่ใช้ในการสกัดข้อมูลของแรงดันและกระแส

ตารางที่ 4-1 การสกัดข้อมูลจากค่าแรงดัน และเทคนิคที่ใช้

1. สกัดความแตกต่างของแรงดันระหว่างปกติกับ ผิดปกติ(รวมชำระดับละเมิด)		
ตัวแปร	ลักษณะของการเกิด	เทคนิคที่ใช้
แรงดันทั้ง 3 เฟสหรือบางเฟส	-ต่ำกว่าหรือลดลงผิดปกติ -เป็นศูนย์ -แตกต่างกันระหว่างเฟสมาก ผิดปกติ - แรงดันสูงผิดปกติ	แรงดันเฟส < 10% V_{avg} แรงดันเฟส = 0 V แรงดันเฟสไม่สมดุล จากสมการ $\Delta V = \frac{V_{max} - V_{min}}{V_{max}}$ แรงดันเฟส > 10% V_{avg} แรงดันเฟส ≤ 0 V (ใช่/ไม่ใช่) มุมเฟส > 120 องศา (ใช่/ไม่ใช่)

ตารางที่ 4-2 การสกัดข้อมูลจากค่าแรงดัน และเทคนิคที่ใช้ (ต่อ)

2. สกัดความแตกต่างของแรงดันรูปแบบ ขำรุด (Defective) และ ละเมิด (Theft)		
ตัวแปร	ลักษณะของการเกิด	เทคนิคที่ใช้
แรงดันทั้ง 3 เฟสหรือบางเฟส	<ul style="list-style-type: none"> -ต่ำกว่าหรือลดลงผิดปกติ -เป็นศูนย์ -แตกต่างกันระหว่างเฟสมาก ผิดปกติ - แรงดันสูงผิดปกติ 	พิจารณาช่วงเวลาการเกิดความผิดปกติ -วันทำงาน, วันเสาร์, อาทิตย์, วันหยุดนักขัตฤกษ์ -ช่วงเวลา on-peak off-peak -ค่าเฉลี่ย Z_{score} ใน 1 ช่วง -ค่าเฉลี่ย Z_{score} ในรอบ 1 วัน มุมเฟส > 120 องศา (ใช่/ไม่ใช่)

ตารางที่ 4-3 การสกัดข้อมูลจากค่ากระแส และเทคนิคที่ใช้

1. สกัดความแตกต่างของค่ากระแสระหว่างปกติ (Normal) กับผิดปกติ (รวมขำรุดกับละเมิด)		
ตัวแปร	ลักษณะของการเกิด	เทคนิคที่ใช้
กระแสทั้ง 3 เฟสหรือบางเฟส	<ul style="list-style-type: none"> -ต่ำกว่าหรือลดลงผิดปกติ -เป็นศูนย์บางเฟส -แตกต่างกันระหว่างเฟสมาก ผิดปกติ - กระแสสูงผิดปกติ 	กระแสเฟส < 10% I_{avg} กระแสเฟส = 0 A กระแสเฟส ไม่สมดุล จากสมการ $\Delta I = \frac{I_{max} - I_{min}}{I_{max}}$ กระแสเฟส > 10% I_{avg} กระแสเฟส ≤ 0 A (ใช่/ไม่ใช่) มุมเฟสกระแส > 120 องศา (ใช่/ไม่ใช่)

ตารางที่ 4-4 การสกัดข้อมูลจากค่ากระแส และเทคนิคที่ใช้

2. สกัดความแตกต่างของค่ากระแสรูปแบบ ชำรุด (Defective) และ ละเมิด (Theft)		
ตัวแปร	ลักษณะของการเกิด	เทคนิคที่ใช้
กระแสทั้ง 3 เฟสหรือบางเฟส	<ul style="list-style-type: none"> -ต่ำกว่าหรือลดลงผิดปกติ -เป็นศูนย์ -แตกต่างกันระหว่างเฟสมากผิดปกติ - กระแสสูงผิดปกติ 	พิจารณาช่วงเวลาการเกิดความผิดปกติ -วันทำงาน, วันเสาร์, อาทิตย์, วันหยุดนักขัตฤกษ์ -ช่วงเวลา on-peak off-peak -ค่าเฉลี่ย Z_{score} ใน 1 ช่วง -ค่าเฉลี่ย Z_{score} ในรอบ 1 วัน มุมเฟส > 120 องศา (ใช่/ไม่ใช่)

จากแต่ละเทคนิคในตารางที่ 3-1 และ 3-2 นั้น นำมาสกัดข้อมูลเป็นลักษณะ (feature) โดยใช้ค่าทางสถิติและค่าระยะทาง ประกอบด้วยชุดข้อมูลที่เป็นตัวเลข (Numerical) และไม่เป็นตัวเลข (Nominal) ได้ดังตารางที่ 4-3

ตารางที่ 4-5 Feature ที่สกัดได้จากการวิเคราะห์ตามช่วงเวลา จำนวน 37 feature


No.	Feature	Description	Type	Period Time
1	Va_raw	Raw data Va	Numerical	14 วัน
2	Vb_raw	Raw data Vb	Numerical	
3	Vc_raw	Raw data Vc	Numerical	
4	Va_zsc	Zscore Va	Numerical	
5	Vb_zsc	Zscore Vb	Numerical	
6	Vc_zsc	Zscore Vc	Numerical	
7	Va_zwa	Zscore Va Weekday	Numerical	วันธรรมดา
8	Vb_zwa	Zscore Vb Weekday	Numerical	
9	Vc_zwa	Zscore Vc Weekday	Numerical	
10	Va_zwa_p	Zscore Va On-Peak time Weekday	Numerical	
11	Vb_zwa_p	Zscore Vb On-Peak time Weekday	Numerical	
12	Vc_zwa_p	Zscore Vc On-Peak time Weekday	Numerical	

ตารางที่ 4-6 แสดง Feature ที่สกัดได้จากการวิเคราะห์ตามช่วงเวลา จำนวน 37 feature


No.	Feature	Description	Type	Period Time	
13	Va_zwa_op	Zscore Va Off-Peak time Weekday	Numerical		
14	Vb_zwa_op	Zscore Vb Off-Peak time Weekday	Numerical	วันธรรมดา	
15	Vc_zwa_op	Zscore Vc Off-Peak time Weekday	Numerical		
16	Va_zwd	Zscore Va Weeked	Numerical		
17	Vb_zwd	Zscore Vb Weeked	Numerical	วันหยุด สุดสัปดาห์	
18	Vc_zwd	Zscore Vc Weeked	Numerical		
19	Va_zwd_p	Zscore Va On-Peak time Weeked	Numerical		
20	Vb_zwd_p	Zscore Vb On-Peak time Weeked	Numerical		
21	Vc_zwd_p	Zscore Vc On-Peak time Weeked	Numerical		
22	Va_zwd_op	Zscore Va Off-Peak time Weeked	Numerical		
23	Vb_zwd_op	Zscore Vb Off-Peak time Weeked	Numerical		
24	Vc_zwd_op	Zscore Vc Off-Peak time Weeked	Numerical		
25	Va_drop	Voltage drop Phase A (Yes,No)	Nominal		14 วัน
26	Vb_drop	Voltage drop Phase B (Yes,No)	Nominal		
27	Vc_drop	Voltage drop Phase C (Yes,No)	Nominal		
28	Va_zero	Voltage =0 Phase A (Yes,No)	Nominal	14 วัน	
29	Vb_zero	Voltage =0 Phase B (Yes,No)	Nominal		
30	Vc_zero	Voltage =0 Phase C (Yes,No)	Nominal		
31	Vubal	$V_{unbalance}(\Delta V) = V_{max} - V_{min} / V_{max}$	Numerical	14 วัน	
32	Va_ove	Over Voltage Phase A (Yes,No)	Nominal	14 วัน	
33	Vb_ove	Over Voltage Phase B (Yes,No)	Nominal		
34	Vc_ove	Over Voltage Phase C (Yes,No)	Nominal		
35	V_man	Total manhattan distance for Voltage	Numerical	14 วัน	
36	V_euc	Total euclidean distance for Voltage	Numerical	14 วัน	
37	TOU	Time of use (P,OP)	Nominal	14 วัน	
38	STATUS	0 = Normal, 1=Defective, 2=Theft			

4.1.2 ผลการวิเคราะห์โดยใช้การสร้างภาพ (Visualization)

จากข้อมูลในแต่ละ feature ทำการ visualization แสดงดังภาพประกอบที่ 4-1 และ 4-2




ภาพประกอบที่ 4-1 ลักษณะค่าสัญญาณไฟฟ้าของค่ากระแสและแรงดัน กรณีละเมิด



ภาพประกอบที่ 4-2 ลักษณะค่าสัญญาณไฟฟ้าของค่ากระแสและแรงดัน กรณีชำรุด


4.1.3 ผลการหาความสัมพันธ์ของข้อมูล (Pearson correlation)

จากการสกัด Feature ได้ทั้งหมด 37 features เป็นชนิด Numerical จำนวน 27 features และเป็นชนิด Nominal จำนวน 10 features (ใช้ one-hot encoded แปลงค่าเป็น Column ย่อย ๆ แบบ Binary 0/1 ตาม value ของข้อมูล) แบ่ง class 3 ลักษณะ คือ ปกติ (Normal), ชำรุด (Defective) และละเมิด (Theft) ข้อมูลแบ่งพิจารณาเป็น 2 ชุด คือ ค่าแรงดันและค่ากระแส ค่าทั้ง 2 ผ่านการทำ Normalization โดยใช้ Max-Min scaling และข้อมูลดิบประเภทค่าที่เป็นศูนย์ ข้อมูลที่หาย ข้อมูลที่เป็นช่องว่าง จะใช้ค่าเฉลี่ยในการเติมข้อมูล และคัดกรองข้อมูลที่ไม่สมบูรณ์ (มีเฉพาะบางค่า) ออกหาความสัมพันธ์ของข้อมูลโดยใช้ Pearson's r Correlation แสดงดังค่าแรงดันดังภาพประกอบที่ 4-3 และค่ากระแสดังภาพประกอบที่ 4-4 พบว่าโดยส่วนใหญ่ของ Feature กระแสมีแนวโน้มเข้าใกล้ศูนย์



ภาพประกอบที่ 4-3 ค่าความสัมพันธ์ Pearson correlation แรงดัน

พบว่าข้อมูลโดยส่วนใหญ่ของ feature แรงดันมีแนวโน้มเป็น Negative correlation ในขณะที่ค่ากระแสนั้นบาง feature มีค่าน้อยและใกล้เคียงกับศูนย์ แต่ทั้ง 2 ตัวแปรมีแนวโน้มเหมือนกัน คือ feature ค่ากระแสไม่สมดุล ค่าที่เป็นศูนย์และค่าจากการใช้วัดระยะทางยูคลิเดียนมีค่าเป็นบวก แต่ถึงอย่างไรก็ตามค่าที่ได้ยังมีความสัมพันธ์กันค่อนข้างน้อย



ภาพประกอบที่ 4-4 ค่าความสัมพันธ์ Pearson correlation กระแส


4.1.4 ผลลัพธ์การสอนและทดสอบโมเดล

ทำการสอนโมเดลและทดสอบความถูกต้อง (Train and Validation the model) คำนวณจากค่าเฉลี่ยของการทดสอบทั้งหมดแสดงดังตารางที่ 4-4

ตารางที่ 4-7 ผลการ train และ validation ข้อมูลโดยใช้เทคนิควิเคราะห์

ML models/Parameters	Voltage		Current	
	Train	Validation	Train	Validation
Neural network (NN)	0.7047	0.7049	0.5408	0.5307
Logistic Regression (LR)	0.6849	0.6846	0.4903	0.4908
Decision tree (DT)	0.6704	0.6685	0.4589	0.4688
Random forest (RF)	0.6320	0.6308	0.5674	0.5320
Gradient boosting (GB)	0.6006	0.6566	0.5099	0.5098
Support vector machines (SVM)	0.6262	0.6208	0.5233	0.5433
k-Nearest Neighbors (KNN)	0.5877	0.5787	0.4798	0.4687
Naive Bayes (NB)	0.5855	0.5873	0.4775	0.4781

ผลจากการหาความสัมพันธ์ข้อมูลและสกัดเป็น feature พบว่าข้อมูลโดยส่วนใหญ่ของ feature แรงดันมีแนวโน้มเป็น Negative correlation โมเดล Neural network (NN) ผล Validation 70.49% สูงสุด และของ feature กระแสความสัมพันธ์ข้อมูลมีแนวโน้มเข้าใกล้ศูนย์ โมเดล Support vector machines (SVM) โชว์ผล Validation 54.33% เป็นค่าสูงสุด และเมื่อเปรียบเทียบผลจากภาพประกอบที่ 4-5 พบว่า NN ให้ค่าความถูกต้องสูงสุด โดยที่ค่าแรงดันได้ผลลัพธ์ที่ดีกว่าค่ากระแส



ภาพประกอบที่ 4-5 ผลการ validation เทคนิควิเคราะห์ตามช่วงเวลา

4.2 ผลการสกัดข้อมูลโดเมนเวลาและโดเมนความถี่ (Time and Frequency Domain)

4.2.1 พิจารณาการสกัดข้อมูลโดเมนเวลา

ในหัวข้อนี้จะนำข้อมูลมิเตอร์ที่เก็บทุกๆ 15 นาที รวมทั้งหมด 672 ค่า เท่ากับ 1 window คิดเป็น 1 Samples มาทำการสกัดโดยใช้ 5 เทคนิค โดยผลการสกัดข้อมูลจะถูกนำเสนอเป็น 3 รูปแบบ ประกอบด้วย

4.2.1.1 ผลการสกัดที่อยู่ในโดเมนอนุกรมเวลา (Time domain)

การสกัดข้อมูลในโดเมนอนุกรมเวลา จะเป็นการพิจารณาจากค่าของแรงดันและกระแส เนื่องด้วยเป็นค่าพารามิเตอร์พื้นฐานที่สะท้อนให้เห็นถึงลักษณะและรูปแบบความผิดปกติที่เกิดขึ้น ในการวิเคราะห์ใช้ 4 เทคนิค มาประยุกต์ซึ่งมีจุดเด่นที่แตกต่างกัน เช่น (ก) ค่าทางสถิติ จะใช้การคำนวณพื้นฐานทางคณิตศาสตร์ (ข) วิธีแยกองค์ประกอบของอนุกรมเวลา จะแยกค่าในลำดับอนุกรมออกมาเป็น 4 รูปแบบย่อย (ค) Auto-Correlation จะเป็นการวิเคราะห์ความสัมพันธ์ลำดับก่อนหลัง และ (ง) วิธี

แบบจำลองสัญญาณ ซึ่งจะเป็นการลดขนาดมิติของข้อมูลให้อยู่ในรูปของค่าสัมประสิทธิ์ก่อนป้อนเข้าสู่โมเดลเพื่อจำแนก โดยเมื่อสกัดได้คุณลักษณะแล้วแต่ละเทคนิคจะถูกนำไปเรียนรู้และทดสอบแยกกัน ทั้ง 4 เทคนิคประกอบด้วยดังนี้

- ก. วิเคราะห์โดยใช้ค่าทางสถิติ (Statistical)
- ข. วิเคราะห์โดยใช้วิธีแยกองค์ประกอบของอนุกรมเวลา (Time Series Components)
- ค. วิเคราะห์โดยใช้ Auto-Correlation
- ง. วิธีแบบจำลองสัญญาณ (Signal Modeling)

โดยจะแสดงผลการสกัดและตัวอย่างผลการแสดงรูปภาพ (Visualization) ดังต่อไปนี้

- ก. วิเคราะห์โดยใช้ค่าทางสถิติ (Statistical)

ในการสกัดโดยใช้ค่าสถิตินั้นประกอบด้วย 5 คุณลักษณะได้แก่ ค่าสูงสุด ค่าต่ำสุด ค่าเฉลี่ย ค่ามัธยฐาน และค่าส่วนเบี่ยงเบนมาตรฐาน ข้อมูลอนุกรมเวลาถูกสกัดเป็น feature ได้ จำนวน 20 feature ดังตารางที่ 4-5


ตารางที่ 4-8 Feature ที่สกัดได้ จำนวน 20 feature โดยใช้ค่าทางสถิติ

No.	Feature	Description
1	VOLTA_Max	Maximum Voltage Phase A
2	VOLTA_Min	Minimum Voltage Phase A
3	VOLTA_Mea	Mean Voltage Phase A
4	VOLTA_Med	Median Voltage Phase A
5	VOLTA_dev	Standard deviation Voltage Phase A
6	VOLTB_Max	Maximum Voltage Phase B
7	VOLTB_Min	Minimum Voltage Phase B
8	VOLTB_Mea	Mean Voltage Phase B
9	VOLTB_Med	Median Voltage Phase B
10	VOLTB_dev	Standard deviation Voltage Phase B
11	VOLTC_Max	Maximum Voltage Phase C
12	VOLTC_Min	Minimum Voltage Phase C
13	VOLTC_Mea	Mean Voltage Phase C


ตารางที่ 4-8 Feature ที่สกัดได้ จำนวน 20 feature โดยใช้ค่าทางสถิติ (ต่อ)

No.	Feature	Description
14	VOLTC_Med	Median Voltage Phase C
15	VOLTC_dev	Standard deviation Voltage Phase C
16	VOLT3P_Max	Maximum Voltage 3 Phase
17	VOLT3P_Min	Minimum Voltage 3 Phase
18	VOLT3P_Mea	Mean Voltage Phase 3 Phase
19	VOLT3P_Med	Median Voltage Phase 3 Phase
20	VOLT3P_dev	Standard deviation Voltage 3 Phase
	STATUS	Normal (0), Defective (1), Theft (2)

จากนั้นทำการวิเคราะห์โดยใช้การสร้างภาพ (Visualization) ผลการสกัด time domain โดยใช้ค่าทางสถิติ (Statistical) แสดง Scatter plot Matrix เปรียบเทียบแต่ละเฟส ดังภาพประกอบที่ 4-6 ค่าแรงดันและภาพประกอบที่ 4-7 ค่ากระแส




ภาพประกอบที่ 4-6 ตัวอย่าง Scatter plot Matrix ค่าเฉลี่ยของแรงดัน




ภาพประกอบที่ 4-7 ตัวอย่าง Scatter plot Matrix ค่าเฉลี่ยของกระแส

ข. วิเคราะห์โดยใช้วิธีแยกองค์ประกอบของอนุกรมเวลา (Time series components)


ข้อมูลดิบสำหรับค่าแรงดัน ดังภาพประกอบที่ 4-8 จะถูกแยกองค์ประกอบออกเป็น trend seasonality และ noise ดังภาพประกอบที่ 4-9 ถึง 4-11 ตามลำดับ ส่วนภาพประกอบที่ 4-12 ถึง 4-15 เป็นค่าตัวแปรกระแส raw data trend seasonality และ noise ตามลำดับ แต่ละ class จะถูกวิเคราะห์เพื่อค้นหาความแตกต่างในแต่ละองค์ประกอบที่เกิดขึ้น จะสังเกตเห็นว่า การเปลี่ยนแปลงเมื่อเกิดความผิดปกติเกิดขึ้นระหว่างขั้วรูดและละเมิดมีแนวโน้มการลดลงที่คล้ายกัน




ภาพประกอบที่ 4-8 ตัวอย่างสัญญาณค่าแรงดันจากระบบ AMR




ภาพประกอบที่ 4-9 ตัวอย่างแนวโน้ม (trend) ค่าแรงดัน




ภาพประกอบที่ 4-10 ตัวอย่างการเกิดซ้ำ (seasonal) ค่าแรงดัน




ภาพประกอบที่ 4-11 ตัวอย่างความแปรปรวน (noise) ค่าแรงดัน




ภาพประกอบที่ 4-12 ตัวอย่างสัญญาณค่ากระแสจากระบบ AMR



ภาพประกอบที่ 4-13 ตัวอย่างแนวโน้ม (trend) ค่ากระแส




ภาพประกอบที่ 4-14 แสดงตัวอย่างการเกิดซ้ำ (seasonal) ค่ากระแส




ภาพประกอบที่ 4-15 แสดงตัวอย่างความแปรปรวน (noise) ค่ากระแส

ค. วิเคราะห์โดยใช้ Auto-Correlation (time domain)

ภาพประกอบ 4-16 และ 4-17 แสดงค่า auto-correlation ของแรงดัน และกระแส ตามลำดับ เพื่อวิเคราะห์ความสัมพันธ์ของข้อมูลเทียบกับลำดับข้อมูลก่อนหน้า รูปแบบปกติจะแตกต่างกับรูปแบบชำรุดและละเมิดค่อนข้างชัดเจน ในขณะที่ชำรุดกับละเมิดยังมีความคล้ายกัน



ภาพประกอบที่ 4-16 แสดงค่า Auto-correlation ของแรงดัน



ภาพประกอบที่ 4-17 ค่า Auto-correlation ของกระแส

ง. วิธีแบบจำลองสัญญาณ (Signal modeling)

เป้าหมายหลักที่เลือกนำวิธีแบบจำลองสัญญาณ มาใช้งานเพื่อต้องการศึกษาและลดจำนวนข้อมูลจาก 1 window ให้เหลือเพียงค่าสัมประสิทธิ์ กระบวนการสกัดแสดงดังตารางที่ 4-6 และใช้ค่าสัมประสิทธิ์ที่ได้นั้นมาเป็นตัวแทนข้อมูลป้อนเข้าสู่โมเดล สำหรับตารางที่ 4-7 เป็นผลการนำค่าสัมประสิทธิ์ที่ได้มาประมาณค่ากลับเพื่อเปรียบเทียบ minimum error ที่เกิดขึ้น ในการเปรียบเทียบจะแยกออกเป็นแต่ละเฟสในแต่ละวิธีการที่ใช้ทั้งหมด 5 เทคนิค ผลลัพธ์ที่ได้ Covariance method ให้ค่า minimum error ต่ำที่สุด รองลงมาเป็น Prony method

ตารางที่ 4-9 ตัวอย่างก่อนและหลังการสกัดโดยใช้แบบจำลองสัญญาณ

Patterns	Before		Feature extraction	After			
	Voltage/Current			Voltage/Current			
Normal (N)	M_N	$w_1(1)$	$N1a_{(0)}$	$N1a_{(1)}$	$N1a_{(2)}$	$N1b_{(0)}$	
Defective (D)		$w_1(2)$	$N2a_{(0)}$	$N2a_{(1)}$	$N2a_{(2)}$	$N2b_{(0)}$	
Theft (T)		$w_1(3)$	$N3a_{(0)}$	$N3a_{(1)}$	$N3a_{(2)}$	$N3b_{(0)}$	
		$w_1(4)$	$N4a_{(0)}$	$N4a_{(1)}$	$N4a_{(2)}$	$N4b_{(0)}$	

ตารางที่ 4-10 ผล minimum error ของโมเดลภายหลังสร้างสัญญาณกลับ

Parameters	Phase	Pade	Prony	Shank	Autocorrelation	Covariance
Voltage	A	62.2289	1.0584	4.1277	1.9991	0.3590
	B	56.3503	1.0349	2.2051	2.0492	0.4239
	C	42.6933	0.9364	1.2810	1.9236	0.3971
Current	A	68.4215	0.9939	2.2459	1.3403	0.2743
	B	97.7940	1.0984	2.4319	1.6787	0.2703
	C	82.9018	0.9001	3.3441	1.7922	0.2334
All average error		68.3983	1.0037	2.6059	1.7972	0.3263

4.2.1.2 ผลการสอนและทดสอบโมเดลจากข้อมูลโดเมนเวลา

ข้อมูลที่ได้จากการสกัดทั้ง 4 วิธีจะถูกป้อนเข้าสู่โมเดลเพื่อจำแนก ผลลัพธ์ที่ได้แสดงดังตารางที่ 4-8 และ 4-9 โมเดลทั้ง 8 เทคนิคจะถูกปรับค่าโดยการทำ Hyperparameters เพื่อหาค่าที่ทำให้โมเดลได้ความแม่นยำสูงสุด


ตารางที่ 4-11 ผลการสอนและทดสอบโมเดลสำหรับค่าแรงดัน จาก 4 เทคนิค

โมเดล	วิธีทางสถิติ		วิธีแยกองค์ประกอบของอนุกรมเวลา		Auto Correlation		วิธีแบบจำลองสัญญาณ (Prony)	
	Train	Valid	Train	Valid	Train	Valid	Train	Valid
NN	0.6643	0.6048	0.4034	0.4537	0.5782	0.5358	0.6666	0.5555
LR	0.7005	0.7177	0.3339	0.3266	0.5762	0.5892	0.8069	0.8038
DT	0.4193	0.4838	0.2399	0.3572	0.4887	0.4160	0.7708	0.7166
RF	0.7446	0.7112	0.3893	0.3611	0.4741	0.4273	0.7458	0.8333
GB	0.7419	0.6919	0.5739	0.5202	0.4216	0.4937	0.7805	0.7028
SVM	0.7619	0.7435	0.6657	0.5021	0.4354	0.4525	0.5972	0.7638
KNN	0.5861	0.5677	0.4458	0.4448	0.5341	0.5013	0.7638	0.7082
NB	0.6823	0.6629	0.4170	0.4154	0.5932	0.5453	0.7055	0.7244

ตารางที่ 4-12 ผลการสอนและทดสอบโมเดลสำหรับค่ากระแส จาก 4 เทคนิค

โมเดล	วิธีทางสถิติ		วิธีแยกองค์ประกอบของอนุกรมเวลา		Auto Correlation		วิธีแบบจำลองสัญญาณ (Prony)	
	Train	Valid	Train	Valid	Train	Valid	Train	Valid
NN	0.7546	0.7580	0.5877	0.5584	0.3916	0.3254	0.7788	0.7501
LR	0.5650	0.7064	0.3894	0.4434	0.4270	0.4355	0.7887	0.7201
DT	0.6129	0.6558	0.3591	0.4060	0.4063	0.4401	0.7867	0.7299
RF	0.7058	0.7145	0.3275	0.4298	0.5116	0.5373	0.7877	0.7996
GB	0.6245	0.6838	0.3776	0.3874	0.4864	0.4369	0.7887	0.7106
SVM	0.7379	0.7566	0.3716	0.3278	0.4894	0.4313	0.7877	0.7491
KNN	0.5688	0.5758	0.3587	0.3276	0.4131	0.4300	0.7857	0.7353
NB	0.5570	0.5887	0.3464	0.3458	0.4805	0.4333	0.6888	0.6944

สำหรับการทดสอบและประเมินผลโมเดลข้อมูลของค่าแรงดันและกระแสแต่ละเฟสจะถูกแยกเพื่อทำการสกัด ผลการสกัดจะถูกนำมาเขียนรวมเป็น feature และป้อนเข้าสู่โมเดล ซึ่งสำหรับค่ากระแสพบว่าทั้งสองตัวแปรแรงดันและกระแส วิธีแบบจำลองสัญญาณให้ผลลัพธ์ที่ดีเมื่อเปรียบเทียบกับเทคนิคที่เหลือ



ภาพประกอบที่ 4-18 ผลการทดสอบค่าแรงดัน(V) และกระแส(A) เปรียบเทียบแต่ละโมเดล

ซึ่งในภาพประกอบที่ 4-18 แสดงการเปรียบเทียบเทคนิคการสกัดข้อมูลของกระแสและแรงดันจำนวน 4 เทคนิค เมื่อ M1 คือ สกัดโดยใช้ค่าทางสถิติ M2 คือ สกัดโดยใช้วิธีแยกองค์ประกอบของอนุกรมเวลา M3 สกัดโดยใช้ Auto-Correlation และ M4 คือ สกัดโดยใช้วิธีแบบจำลองสัญญาณ


4.2.2 ผลการสกัดข้อมูลจากโดเมนความถี่ (frequency domain)

4.2.2.1 ผลการสกัดพิจารณาจากโดเมนความถี่ (frequency domain)

ในการสกัดข้อมูล ข้อมูลจากอนุกรมเวลาถูกแปลงให้อยู่ในโดเมนความถี่ โดยใช้ 2 เทคนิคได้แก่

- ก. วิเคราะห์โดยใช้การแปลงฟูริเยร์แบบไม่ต่อเนื่อง (Discrete Fourier transform: DFT)
- ข. วิเคราะห์โดยใช้ความหนาแน่นของสเปกตรัมพลังงาน (Power Spectral Density: PSD)


ผลการแปลงจะแสดงการวิเคราะห์โดยใช้ Visualization เปรียบเทียบทั้ง 3 รูปแบบ แสดงค่าสัญญาณจริงในอนุกรมเวลา ภาพประกอบที่ 4-19 และ 4-22 แสดงตัวอย่างสัญญาณค่าแรงดันและกระแสจากระบบ AMR ตามลำดับ ในส่วนการแปลงฟูริเยร์และสเปกตรัมพลังงาน ดังภาพประกอบที่ 4-20 ถึง 4-21 สำหรับแรงดัน และภาพประกอบที่ 4-23 ถึง 4-24 สำหรับกระแส โดยที่แกน X จะเป็นค่าความถี่ ตัวอย่าง (frequency/samples) แกน Y เป็นค่า Amplitude และ Power spectral ตามลำดับ ผลการสกัดจะอยู่ในรูปของค่าสัมประสิทธิ์เพื่อกำหนดเป็น feature ต่อไป




ภาพประกอบที่ 4-19 ตัวอย่างสัญญาณค่าแรงดัน 672 ค่าจากระบบ AMR




ภาพประกอบที่ 4-20 ตัวอย่างค่า DFT ของแรงดัน




ภาพประกอบที่ 4-21 ตัวอย่างค่า PSD ของแรงดัน



ภาพประกอบที่ 4-22 แสดงตัวอย่างสัญญาณค่ากระแสจากระบบ AMR



ภาพประกอบที่ 4-23 ตัวอย่างค่า DFT ของกระแส




ภาพประกอบที่ 4-24 ตัวอย่างค่า PSD ของค่ากระแส


ภายหลังจากการวิเคราะห์โดยใช้รูปภาพ ข้อมูลที่สนใจเป็นค่าลำดับความถี่ต้นที่เกิดขึ้นจากเทคนิค DFT และ PSD ค่าที่ได้จะประกอบด้วยค่าแอมพลิจูดของแต่ละความถี่ต่อตัวอย่าง และใช้การคำนวณทางสถิติเพื่อกำหนดเป็น feature ได้จำนวน 20 feature จำแนก 3 class สอดคล้องกับตารางที่ 4-10 จากนั้นทำการหา Pearson Correlation แสดงดังภาพประกอบที่ 4-25 และ 4-26 จะพบว่าค่ากระแสและแรงดันมีความสัมพันธ์ที่แตกต่างกัน ค่ากระแส Correlation ส่วนใหญ่มีแนวโน้มติดลบ เนื่องด้วยค่าสัมประสิทธิ์ที่สกัดได้มีค่าน้อยและเข้าใกล้ศูนย์ ในขณะที่ค่าแรงดัน Correlation เป็นบวก แต่มีค่าต่ำ เมื่อพิจารณาโดยรวมของค่าจะมีความหลากหลายระหว่างรูปแบบละเมิดกับขำรุุด และบางค่าใกล้เคียงกัน

ตารางที่ 4-13 Feature ที่สกัดได้ จำนวน 20 feature จากเทคนิค DFT และ PSD

No.	Feature	No.	Feature	No.	Feature	No.	Feature
1	VOLTA_Max	6	VOLTB_Max	11	VOLTC_Max	16	VOLT3P_Max
2	VOLTA_Min	7	VOLTB_Min	12	VOLTC_Min	17	VOLT3P_Min
3	VOLTA_Mea	8	VOLTB_Mea	13	VOLTC_Mea	18	VOLT3P_Mea
4	VOLTA_Med	9	VOLTB_Med	14	VOLTC_Med	19	VOLT3P_Med
5	VOLTA_dev	10	VOLTB_dev	15	VOLTC_dev	20	VOLT3P_dev



ภาพประกอบที่ 4-25 ค่า Pearson Correlation ของแรงดัน ในโดเมนความถี่



ภาพประกอบที่ 4-26 ค่า Pearson Correlation ของกระแสในโดเมนความถี่


4.2.2.2 ทำการสอนและทดสอบโมเดลจากข้อมูลโดเมนความถี่

ผลการสอนและทดสอบแสดงดังตารางที่ 4-11 ประกอบด้วย 8 โมเดลกับการสกัดโดยใช้ 2 เทคนิค คือ DTF และ PSD

ตารางที่ 4-14 ผลการสอนและทดสอบโมเดล DTF และ PSD

โมเดล/ เทคนิค	แรงดัน				กระแส			
	DFT		PSD		DFT		PSD	
	Train	Valid	Train	Valid	Train	Valid	Train	Valid
NN	0.5570	0.4677	0.5397	0.4677	0.6200	0.6182	0.6686	0.6041
LR	0.6965	0.5775	0.6612	0.6774	0.6218	0.6081	0.6771	0.5785
DT	0.5536	0.4938	0.4896	0.4895	0.6134	0.5952	0.6366	0.5985
RF	0.7584	0.7274	0.7296	0.7306	0.6424	0.6595	0.6458	0.5793
GB	0.6483	0.6677	0.6896	0.6193	0.6239	0.6175	0.6211	0.6207
SVM	0.7024	0.6451	0.7682	0.7258	0.6045	0.6165	0.6318	0.5850
KNN	0.5930	0.5838	0.6169	0.6548	0.6261	0.6122	0.6185	0.5781
NB	0.6785	0.6419	0.4636	0.5080	0.6225	0.5830	0.6228	0.5581

จากผลการทดลองได้แสดงการเปรียบเทียบผลลัพธ์ระหว่าง DTF และ PSD ดังภาพประกอบที่ 4-27 จะเห็นได้ว่า RF สำหรับค่าตัวแปรแรงดันและกระแสให้ผลลัพธ์ที่ดีที่สุดเมื่อเปรียบเทียบกับโมเดลอื่น ทั้งสองเทคนิคที่ใช้ในการสกัดจะมีแนวโน้มเป็นไปในทิศทางเดียวกันและสอดคล้องกัน



ภาพประกอบที่ 4-27 ผลการสอนและทดสอบโมเดลโดยใช้เทคนิค DTF และ PSD

4.2.3 พิจารณาผลการสอนและทดสอบรวม (Time domain and Freq domain)


เมื่อทำการรวมทั้ง 2 โดเมนคือ Time domain และ Freq domain โดยใช้วิธีทางสถิติ ได้ทั้งหมด 40 feature พบว่าผลการเรียนรู้และทดสอบมีแนวโน้มเพิ่มขึ้นแสดงดังตารางที่ 4-12

ตารางที่ 4-15 ผลการสอนและทดสอบโมเดลรวม Time domain และ Freq domain

โมเดล/เทคนิค	Time + Freq domain (วิธีทางสถิติ)			
	Voltage	Current	Voltage	Current
	Train	Valid	Train	Valid
NN	0.69654	0.69194	0.720415	0.779032
LR	0.688235	0.68387	0.676654	0.667742
DT	0.741176	0.71129	0.703114	0.73871
RF	0.809677	0.798387	0.805657	0.791935
GB	0.626298	0.55645	0.764706	0.725806
SVM	0.69308	0.68387	0.723875	0.762903
KNN	0.665052	0.67484	0.662042	0.669355
NB	0.69654	0.69194	0.720415	0.779032

4.3 ผลการสกัดข้อมูลโดยใช้ Wavelet Transform และการแปลงให้อยู่ในรูป 2D Image

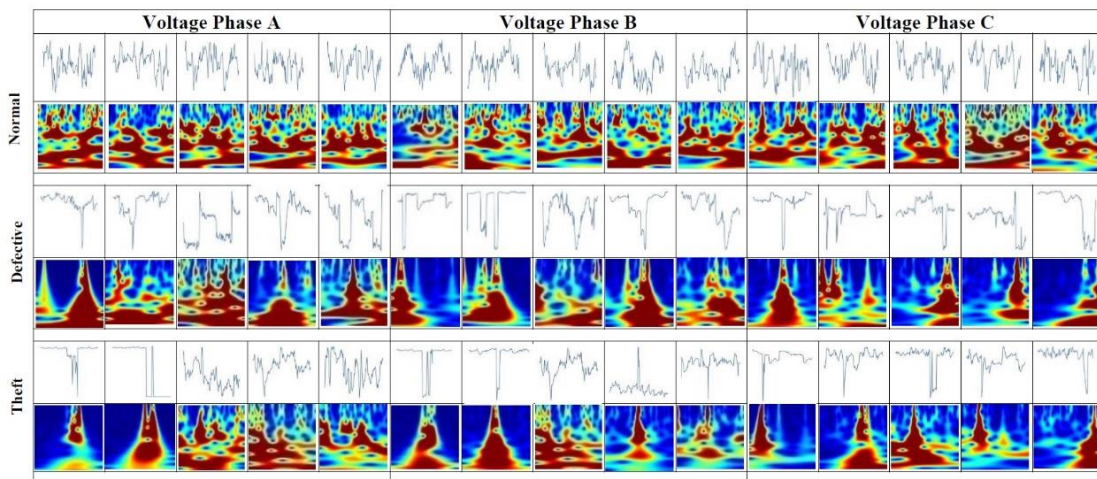
ในหัวข้อ 4.1-4.2 จะเป็นการพิจารณาข้อมูลที่อยู่รูปแบบหนึ่งมิติผ่านการสกัดและป้อนเข้าโมเดล แต่ในหัวข้อนี้ข้อมูลอนุกรมเวลาของแรงดันและกระแสจะถูกแปลงให้อยู่ในรูปแบบสองมิติหรือเป็นรูปภาพ (จากวิธีการในข้อ 3.3.3 และ 3.3.4) ด้วยจากการทบทวนวรรณกรรมพบว่ามีหลายงานวิจัยที่เลือกใช้ข้อมูลแบบสองมิติป้อนเข้าสู่โมเดลและได้ผลลัพธ์ที่ดี อีกทั้งการพิจารณาในเชิงรูปภาพจะปรากฏลักษณะเด่นเฉพาะของแต่ละรูปแบบ ซึ่งเทคนิคที่ใช้ในงานวิจัยนี้ประกอบด้วย 5 เทคนิค ได้แก่ Continuous Wavelet transform (CWT) Recurrence Plot (RP) Markov Transition Field (MTF) Gramian Summation Angular Field (GASF) Spectrogram (SG) ตัวอย่างดังรูปภาพประกอบที่ 4-28




ภาพประกอบที่ 4-28 การตัวอย่างการแปลงภาพทั้ง 5 วิธี

4.3.1 ผลการสกัดข้อมูลอนุกรมเวลาโดยใช้ทั้ง 5 เทคนิค


ตารางที่ 4-13 แสดงการแบ่งข้อมูล ซึ่งข้อมูลที่ถูกแบ่งจะพิจารณาจากช่วงที่ปกติและผิดปกติ จากนั้นทำการตัดแบ่งออกเป็นช่วง ตัวอย่างเช่น ผู้ใช้รายหนึ่งพบความผิดปกติมากกว่า 1 สัปดาห์ ประมาณ 1 เดือน ข้อมูลจะถูกตัดแบ่งออกมาเป็น 4 ช่วง ทำให้ผู้ใช้ไฟรายนี้มีรูปแบบที่แบ่งออกมาทั้งหมด 4 ช่วง และกรณีพบความผิดปกติน้อยกว่า 1 สัปดาห์ ข้อมูลจะถูกกำหนดจากค่าก่อนหน้าและหน้า ภายหลังจากเกิดเหตุการณ์ ซึ่งกำหนดใช้ข้อมูลช่วงละ 168 ค่า และทำการแปลงเป็นรูปภาพที่ขนาดภาพ 168x168 แสดงผลดังภาพประกอบที่ 4-31 ถึง 4-40




ภาพประกอบที่ 4-31 ภาพค่าแรงดัน time series และ CWT




ภาพประกอบที่ 4-32 ภาพค่ากระแส time series และ CWT




ภาพประกอบที่ 4-33 ภาพค่าแรงดัน time series และ RP




ภาพประกอบที่ 4-34 ภาพค่ากระแส time series และ RP




ภาพประกอบที่ 4-35 ภาพค่าแรงดัน time series และ MTF




ภาพประกอบที่ 4-36 ภาพค่ากระแส time series และ MTF




ภาพประกอบที่ 4-37 ภาพค่าแรงดัน time series และ GSAF



ภาพประกอบที่ 4-38 ภาพค่ากระแส time series และ GSAF



ภาพประกอบที่ 4-39 ภาพค่าแรงดัน time series และ SG



ภาพประกอบที่ 4-40 ภาพค่ากระแส time series และ SG

พิจารณาจากผลการแปลงจากอนุกรมเวลาเป็นรูปภาพ ในแต่ละเทคนิคปรากฏลักษณะเด่นที่แตกต่างกันในแต่ละวิธี เมื่อพิจารณาลงลึกในแต่ละประเภทของความผิดปกติจะพบความแตกต่างระหว่างรูปแบบขำรดกับละเมิด

4.3.2 แบ่งข้อมูลสำหรับสอนและทดสอบการแปลงอนุกรมเวลาเป็นรูปภาพ

จะได้ข้อมูลทั้งหมด 2,478 รูป ประกอบด้วยค่ากระแส 1,239 รูป ค่าแรงดัน 1,239 รูป แบ่งข้อมูลสำหรับ Train 70% และ Validation 30% กำหนดค่า epochs = 30, batch_size = 16 แสดงรายละเอียดการแบ่งข้อมูลสำหรับสอนและทดสอบทั้ง 5 เทคนิค ดังตารางที่ 4-14

ตารางที่ 4-17 การแบ่งข้อมูลสำหรับสอนและทดสอบทั้ง 5 เทคนิค

Type	Total	Train70%	Test30%	Description
NOM	642	449	193	ปกติ
DEF	252	176	76	ชำรุด
THF	345	242	103	ละเมิด

4.3.3 ผลการสอนและทดสอบการแปลงอนุกรมเวลาเป็นรูปภาพ

โมเดล CNN ถูกนำมาใช้ทดสอบผลการสกัดทั้ง 5 เทคนิค การกำหนดค่าพารามิเตอร์แสดงไว้ในบทที่ 3 ภาพประกอบที่ 3-5 โดยใช้ tensorflow และ keras รันโปรแกรม ผลลัพธ์มาจากการทดลองแสดงดังตารางที่ 4-15 และตารางที่ 4-16 ตัวอักษรตัวหนาคือค่าที่ดีที่สุด


ตารางที่ 4-18 ผลการทดสอบประสิทธิภาพโมเดลสำหรับค่าแรงดันทั้ง 5 เทคนิค

Phase	Method	Accuracy	Precision	Recall	F1-score	AUC-ROC	Overall
A	CWT	0.936	0.948	0.921	0.917	0.937	0.932
	SG	0.789	0.799	0.788	0.798	0.791	0.793
	RP	0.916	0.921	0.928	0.929	0.934	0.926
	MTF	0.894	0.882	0.883	0.906	0.901	0.893
	GSAF	0.927	0.919	0.932	0.938	0.924	0.928
B	CWT	0.953	0.975	0.962	0.959	0.954	0.961
	SG	0.901	0.908	0.908	0.910	0.906	0.907
	RP	0.946	0.958	0.965	0.964	0.971	0.961
	MTF	0.896	0.896	0.918	0.910	0.913	0.907
	GSAF	0.947	0.960	0.959	0.942	0.968	0.955
C	CWT	0.918	0.922	0.917	0.926	0.936	0.924
	SG	0.866	0.885	0.862	0.848	0.857	0.864
	RCP	0.910	0.917	0.921	0.901	0.923	0.914
	MTF	0.852	0.855	0.851	0.847	0.858	0.853
	GSAF	0.915	0.929	0.920	0.911	0.935	0.922


ตารางที่ 4-19 ผลการทดสอบประสิทธิภาพโมเดลสำหรับค่ากระแสทั้ง 5 เทคนิค

Phase	Method	Accuracy	Precision	Recall	F1-score	AUC-ROC	Overall
A	CWT	0.930	0.947	0.912	0.922	0.936	0.929
	SG	0.793	0.766	0.778	0.761	0.776	0.775
	RCP	0.912	0.916	0.898	0.904	0.917	0.909
	MTF	0.838	0.836	0.841	0.846	0.855	0.843
	GSAF	0.922	0.929	0.919	0.936	0.912	0.924
B	CWT	0.882	0.908	0.902	0.911	0.905	0.902
	SG	0.869	0.881	0.862	0.871	0.878	0.872
	RCP	0.909	0.908	0.919	0.928	0.911	0.915
	MTF	0.890	0.882	0.878	0.888	0.889	0.885
	GSAF	0.907	0.936	0.907	0.912	0.917	0.916
C	CWT	0.898	0.937	0.909	0.911	0.891	0.909
	SG	0.852	0.840	0.834	0.832	0.842	0.840
	RP	0.865	0.865	0.876	0.878	0.883	0.873
	MTF	0.789	0.801	0.807	0.817	0.810	0.805
	GSAF	0.886	0.899	0.898	0.904	0.902	0.898

กราฟแสดงผลการ train และ validation กำหนดค่าทดสอบ 30 รอบ คำนวณค่าเฉลี่ยแต่ละรอบแสดงดังตารางที่ 4-17 และตารางที่ 4-18 จะปรากฏลักษณะที่ต่างกันในแต่ละวิธี




ภาพประกอบที่ 4-41 ผลการทดสอบทั้ง 5 เทคนิคกับค่าแรงดัน

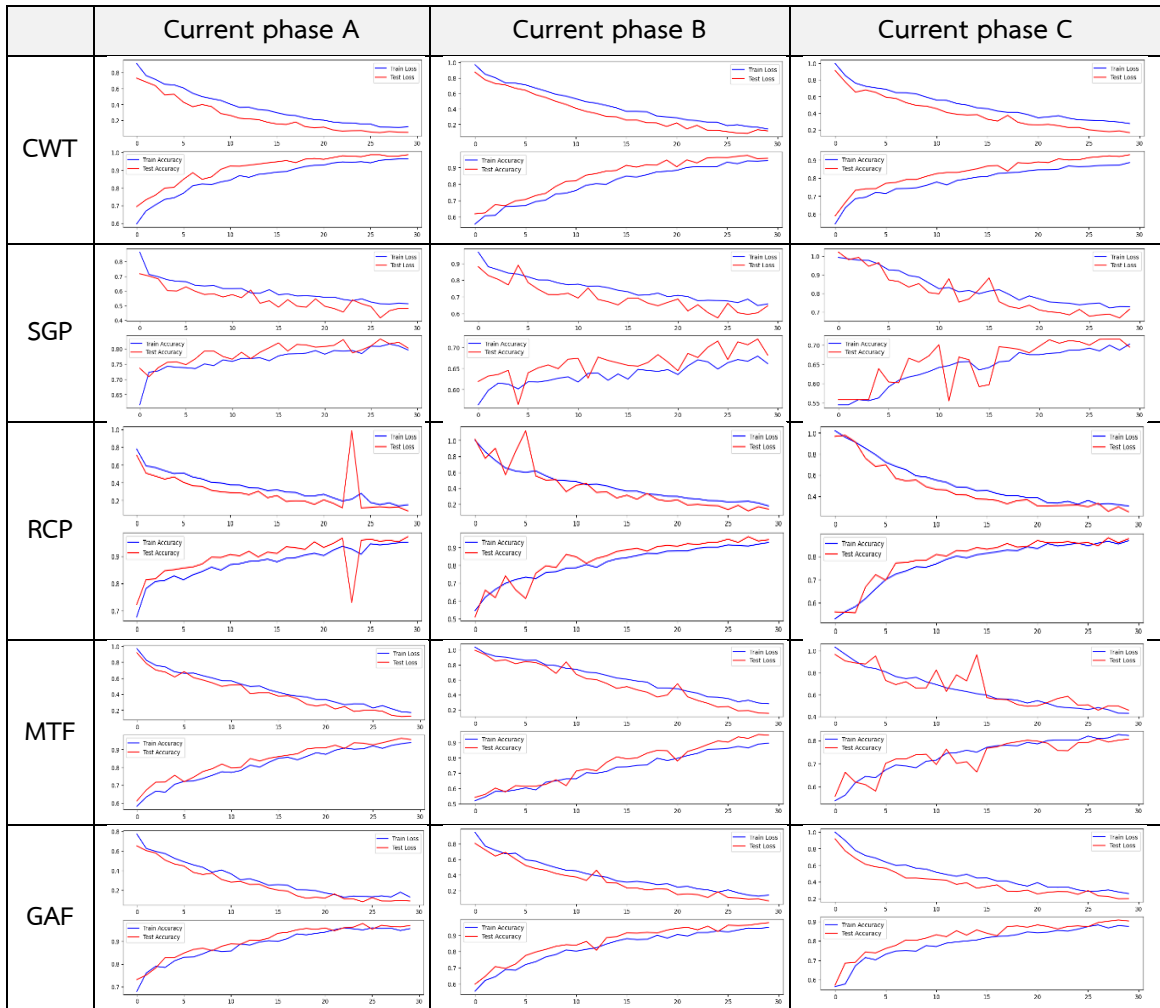


ภาพประกอบที่ 4-42 ผลการทดสอบทั้ง 5 เทคนิคกับค่ากระแส

ตารางที่ 4-20 กราฟแสดงผลการทดสอบโมเดลสำหรับค่าแรงดันทั้ง 5 เทคนิค



ตารางที่ 4-21 กราฟแสดงผลการทดสอบโมเดลสำหรับค่ากระแสทั้ง 5 เทคนิค




ลักษณะการเปลี่ยนแปลงของกราฟ train และกราฟ validation ประกอบด้วย 2 กราฟ คือ ค่า loss (รูปบน) และค่า accuracy (รูปล่าง) โดยแยก train และ validation ทั้ง 3 เฟสของแรงดัน และกระแส พบว่า กราฟ accuracy มีแนวโน้มเพิ่มขึ้นเมื่อจำนวนรอบของการสอนเพิ่มขึ้น ในขณะที่กราฟ loss มีแนวโน้มลดลงและเข้าใกล้ศูนย์เมื่อจำนวนรอบเพิ่มขึ้นเช่นกัน แต่สังเกตว่ามีบางค่ากราฟเกิดการกระเพื่อมเป็นผลมาจากการเกิด overfitting กับข้อมูล เมื่อพิจารณาภาพรวมจะพบว่า CWT มีแนวโน้มที่ลู่เข้าและเกิด overfit น้อยสุด ในขณะที่ SGP ทั้งกราฟ loss และ accuracy มีแนวโน้มแกว่งในขณะทำการ train และ validation โดยผลการทดสอบทั้ง 5 เทคนิคสำหรับค่าแรงดันและกระแสแสดงดังภาพประกอบที่ 4-41 และ 4-42 จะพบว่าโดยรวมแล้ว CWT ให้ค่าความถูกต้องที่สูงสุด รองลงมาเป็น GSAF และ SPG ให้ผลลัพธ์ที่ต่ำสุด

4.4 ผลลัพธ์จากการใช้เทคนิคจัดการกับข้อมูลที่ไม่สมดุล

4.4.1 ผลการสร้างโมเดลความผิดปกติ (Anomaly Model)

4.4.1.1 ชุดข้อมูลปกติ (Normal Data Samples)


หลังจากโมเดลผิดปกติทั้ง 2 ถูกสร้างขึ้น (โมเดลชำรุดและละเมิด) ในหัวข้อที่ 3.6.1 ข้อมูลปกติจะถูกป้อนเข้าโมเดล ตัวอย่างข้อมูลที่ป้อนแสดงดังรูปภาพประกอบที่ 4-43



ภาพประกอบที่ 4-43 ตัวอย่างข้อมูลปกติค่าแรงดันและกระแส


4.4.1.2 ตัวอย่างข้อมูลชำรุดที่ได้จาก Defective Models

ชุดข้อมูลปกติจากข้อ 4.4.1.1 ป้อนเข้าโมเดลในหัวข้อ 3.6.1.1 ได้ผลลัพธ์ดังภาพประกอบที่ 4-44



ชำรุด-1 (Volt)


ชำรุด-1 (Amps)




ชำรุด-2 (Volt)

ชำรุด-2 (Amps)


ภาพประกอบที่ 4-44 ตัวอย่างข้อมูลขำรุดค่าแรงดันและกระแสที่ถูกสร้างขึ้น




ขำรุด-3 (Volt)




ขำรุด-3 (Amps)




ขำรุด-4 (Volt)




ขำรุด-4 (Amps)




ขำรุด-5 (Volt)



ขำรุด-5 (Amps)



ขำรุด-6 (Volt)




ขำรุด-6 (Amps)


ภาพประกอบที่ 4-44 ตัวอย่างข้อมูลขำรุดค่าแรงดันและกระแสที่ถูกสร้างขึ้น (ต่อ)

4.4.1.3 ตัวอย่างข้อมูลละเมิดที่ได้จาก Theft Models


ชุดข้อมูลปกติจากข้อ 4.4.1.1 นำมาจัดเตรียมและป้อนเข้าโมเดลสำหรับสร้างข้อมูลละเมิดในหัวข้อ 3.6.1.2 ได้ผลลัพธ์แสดงดังรูปภาพประกอบที่ 4-45 รูปด้านซ้ายเป็นค่าสัญญาณแรงดันและรูปด้านขวาเป็นค่าสัญญาณกระแส




ละเมิด-1 (Volt)




ละเมิด-1 (Amps)




ละเมิด-2 (Volt)



ละเมิด-2 (Amps)




ละเมิด-3 (Volt)




ละเมิด-3 (Amps)


ภาพประกอบที่ 4-45 ตัวอย่างข้อมูลละเมิดค่าแรงดันและกระแสที่ถูกสร้างขึ้น




ละเมิด-4 (Volt)



ละเมิด-4 (Amps)



ละเมิด-5 (Volt)




ละเมิด-5 (Amps)


ภาพประกอบที่ 4-45 ตัวอย่างข้อมูลละเมิดค่าแรงดันและกระแสที่ถูกสร้างขึ้น (ต่อ)

4.4.2 ผลการสุ่มตัวอย่างแบบสังเคราะห์ที่ปรับเปลี่ยนค่าได้ (ASASYN)

ชุดข้อมูลประกอบด้วยค่าแรงดันและกระแสทั้งสองค่าจะถูกป้อนเข้าสู่ ASASYN เพื่อสุ่มค่าและสังเคราะห์ข้อมูลใหม่ขึ้นมา ตัวอย่างแสดงการกระจายตัวในภาพประกอบที่ 4-46 เปรียบเทียบระหว่างชุดข้อมูลที่ไม่ได้ทำการปรับค่า (ข้อมูลเดิมที่ไม่สมดุล) กับข้อมูลที่ทำการปรับค่าโดยใช้ โมเดลการสร้างข้อมูลทั้ง 3 classes สำหรับ ASASYN จากในบทที่ 3 ตารางที่ 3-24




No-balance



ADASYN

ภาพประกอบที่ 4-46 เปรียบเทียบการกระจายตัวระหว่างข้อมูลไม่สมดุลกับใช้เทคนิค ASASYN

พบว่าข้อมูลที่ถูกสังเคราะห์ขึ้นจะมีการปรับค่าและเพิ่มจำนวนมากขึ้นเพื่อปรับให้ข้อมูลมีความสมดุล จากภาพประกอบที่ 4-47 แสดงตัวอย่างรูปสัญญาณก่อนทำและหลังทำ สังเกตก่อนทำข้อมูล class 0 จะมากกว่า class 1 และ class 2 หลังใช้เทคนิค ASASYN ข้อมูลจะถูกสังเคราะห์ขึ้นมาทำให้ข้อมูลทั้ง 3 class เท่ากัน ซึ่งรูปร่างสัญญาณมีการเปลี่ยนแปลงตามข้อมูลที่ถูกรับค่า




ก่อนทำ

หลังทำ


ภาพประกอบที่ 4-47 ตัวอย่างเปรียบเทียบการสร้างสัญญาณก่อนและหลังโดยใช้เทคนิค ASASYN

4.4.3 ผลการเพิ่มข้อมูลโดยการปรับแต่งรูปภาพ (Image Data Augmentation)

ข้อมูลชุดเดียวกันกับสองวิธีข้างต้น จะถูกแปลงเป็นรูปภาพและทำการปรับแต่งเชิงตำแหน่ง (Position augmentation) สำหรับการแปลงจากอนุกรมเวลาเป็นภาพจะเลือกจากเทคนิคในบทที่ 3 หัวข้อที่ 3.3.4 การสกัดข้อมูลโดยการแปลงเป็นรูปภาพ (Time series to image) เลือกใช้เทคนิคพล็อตการเกิดซ้ำ Recurrence plot (RP) เนื่องด้วยเป็นเทคนิคที่แสดงลักษณะการเปลี่ยนแปลงเชิงการเกิดซ้ำของเส้นได้เด่นชัด แสดงตัวอย่างดังรูปภาพประกอบที่ 4-48 ภาพสัญญาณแรงดันก่อนแปลงและหลังแปลงโดยใช้ RP โดยแสดงเป็นภาพสีเพื่อบ่งบอกค่าความเข้มสีที่เปลี่ยนแปลงตามลักษณะของสัญญาณ




ภาพประกอบที่ 4-48 ตัวอย่างสัญญาณที่ถูกแปลงโดยใช้ RP



ภาพประกอบที่ 4-49 ตัวอย่างการปรับแต่งเชิงตำแหน่ง (Position augmentation)

การปรับแต่งเชิงตำแหน่ง (Position augmentation) ที่ใช้ในงานวิจัยนี้ประกอบด้วย 8 เทคนิคดังแสดงในตารางที่ 4-23 ซึ่งตัวอย่างผลลัพธ์การนำเทคนิคทั้ง 8 วิธีมาใช้แสดงดังภาพประกอบที่ 4-49 โดยแต่ละเทคนิคจะถูกสุ่มเพื่อสร้างภาพดังแสดงในรูปภาพประกอบที่ 4-50



ภาพประกอบที่ 4-50 ตัวอย่างการใช้เทคนิคทั้ง 8 วิธีในการสุ่มสร้างภาพ

4.4.4 ผลการสอนและทดสอบเทคนิคการจัดการข้อมูลที่ไม่สมดุล


จากเทคนิคที่กล่าวข้างต้นถูกนำมาทดสอบโมเดลผลลัพธ์แสดงดังตารางที่ 4-24 และ 4-25 ดังนี้
 ตารางที่ 4-22 ผลลัพธ์จากการทดสอบทั้ง 4 รูปแบบ จากเทคนิคการสมดุลข้อมูลสำหรับค่าแรงดัน

Method + model	Accuracy	Recall	Precision	F1-score	AUC-ROC	FPR
No balance+LeNet5	0.8421	0.7933	0.8558	0.4235	0.4043	0.2067
No balance+AlexNet	0.8701	0.8076	0.798	0.4091	0.4915	0.1924
No balance+VGGNet19	0.8542	0.7477	0.7309	0.4847	0.5088	0.2523
No balance+Densenet121	0.8375	0.7222	0.6597	0.5176	0.4736	0.2778
No balance+ResNet50	0.8729	0.6898	0.7569	0.5454	0.5113	0.3102
No balance+InceptionV3	0.8604	0.7894	0.7132	0.5782	0.5969	0.2106
AM+LeNet5	0.9069	0.8672	0.8911	0.8211	0.6958	0.1328
AM+AlexNet	0.9279	0.8164	0.8746	0.7355	0.6826	0.1836
AM+VGGNet19	0.9197	0.8713	0.9247	0.7765	0.7135	0.1287
AM+Densenet121	0.9404	0.9034	0.8635	0.8049	0.8701	0.097
AM+ResNet50	0.9199	0.8291	0.9011	0.8493	0.8574	0.1709
AM+InceptionV3	0.9375	0.7826	0.9372	0.8885	0.8064	0.2174
ADASYN +LeNet5	0.8798	0.9038	0.8846	0.7582	0.7125	0.2609
ADASYN +AlexNet	0.9014	0.8341	0.8798	0.7774	0.7678	0.2300
ADASYN +VGGNet19	0.8966	0.9014	0.8269	0.8341	0.7005	0.2359
ADASYN +Densenet121	0.9014	0.9138	0.8678	0.7750	0.6726	0.2180
ADASYN +ResNet50	0.8990	0.9014	0.8245	0.8389	0.7389	0.2581
ADASYN +InceptionV3	0.8966	0.8822	0.8438	0.8293	0.6606	0.2233
IA+LeNet5	0.6101	0.4855	0.5271	0.6756	0.5097	0.5145
IA+AlexNet	0.5485	0.6507	0.5999	0.6141	0.4323	0.3493
IA+VGGNet19	0.5959	0.4009	0.3932	0.5215	0.5556	0.5991
IA+Densenet121	0.5327	0.4005	0.6376	0.6249	0.4867	0.5995
IA+ResNet50	0.5152	0.4208	0.4481	0.5745	0.4723	0.5792
IA+InceptionV3	0.6173	0.5449	0.4181	0.5144	0.6007	0.4551

ตารางที่ 4-23 ผลลัพธ์จากการทดสอบทั้ง 4 รูปแบบ จากเทคนิคการสมมูลข้อมูลสำหรับค่ากระแส

Method + model	Accuracy	Recall	Precision	F1-score	AUC-ROC	FPR
No balance+LeNet5	0.8583	0.6136	0.8987	0.5338	0.5033	0.3864
No balance+AlexNet	0.7088	0.6140	0.7338	0.5269	0.5134	0.3860
No balance+VGGNet19	0.8792	0.5527	0.6968	0.6246	0.5685	0.4473
No balance+Densenet121	0.8417	0.6296	0.6829	0.5373	0.5521	0.3704
No balance+ResNet50	0.8833	0.7569	0.669	0.5275	0.6057	0.2431
No balance+InceptionV3	0.8396	0.7269	0.7361	0.5049	0.4886	0.2731
AM+LeNet5	0.9004	0.8375	0.8069	0.7948	0.5824	0.1625
AM+AlexNet	0.9089	0.8392	0.7834	0.8372	0.6298	0.1608
AM+VGGNet19	0.9347	0.8725	0.9113	0.7674	0.6562	0.1275
AM+Densenet121	0.9241	0.8756	0.7298	0.6916	0.7494	0.1244
AM+ResNet50	0.9134	0.8979	0.8069	0.8655	0.6269	0.1021
AM+InceptionV3	0.9094	0.8378	0.8273	0.8375	0.7793	0.1622
ADASYN +LeNet5	0.8658	0.8827	0.8423	0.7534	0.7269	0.2853
ADASYN +AlexNet	0.8790	0.8979	0.8504	0.7313	0.7005	0.2823
ADASYN +VGGNet19	0.8845	0.8979	0.8423	0.7987	0.7909	0.2747
ADASYN +Densenet121	0.8842	0.8948	0.8564	0.7413	0.7558	0.2545
ADASYN +ResNet50	0.7473	0.9060	0.8534	0.7537	0.7389	0.2466
ADASYN +InceptionV3	0.9119	0.8989	0.8605	0.7869	0.7029	0.2432
IA+LeNet5	0.6506	0.6254	0.4861	0.6025	0.5889	0.3746
IA+AlexNet	0.6176	0.4398	0.6927	0.5231	0.5325	0.5602
IA+VGGNet19	0.5775	0.4907	0.5394	0.6175	0.5085	0.5093
IA+Densenet121	0.6019	0.6533	0.4872	0.6352	0.5734	0.3467
IA+ResNet50	0.5278	0.5787	0.6966	0.5724	0.5856	0.4213
IA+InceptionV3	0.5089	0.4734	0.5769	0.4347	0.5829	0.5266

ผลลัพธ์จากการทดสอบพิจารณาจากภาพประกอบที่ 4-51 พบว่า วิธีการสร้างข้อมูลโดยใช้โมเดลความผิดปกติ (AM) ให้ประสิทธิภาพสูงสุดเมื่อเทียบกับวิธีอื่น (ตัวอักษรตัวหนาคือค่าที่ดีที่สุด) ทั้งตัวแปรค่าแรงดันและกระแส ในขณะที่วิธีการเพิ่มข้อมูลโดยการปรับแต่งรูปภาพ (IA) ให้ประสิทธิภาพโดยรวมต่ำสุด



ภาพประกอบที่ 4-51 ผลการทดสอบเปรียบเทียบแต่ละเทคนิค


4.5 ผลลัพธ์การทดสอบโมเดล (Test Model)

ในการทดสอบโมเดลที่นำมาใช้ประกอบด้วย 2 โมเดล โมเดลที่หนึ่ง ได้จากผลการทดลองในหัวข้อการสกัดข้อมูลโดยใช้ Wavelet Transform และแปลงให้อยู่ในรูปแบบ 2D Image (หัวข้อ 4.3) ในส่วนโมเดลที่ 2 ได้จากการปรับโมเดลโดยใช้เทคนิคจัดการข้อมูลที่ไม่สมดุล (หัวข้อ 4.4) ข้อมูลในปี 2565 และข้อมูลจากเหตุการณ์จริงจะถูกนำมาทดสอบ ผลลัพธ์ที่ได้แสดงรายละเอียดต่อไปนี้


4.5.1 ผลลัพธ์การทดสอบโมเดลจากข้อมูลชุดอื่น (Test with Real Data)

ข้อมูลสำหรับทดสอบประกอบด้วยผู้ใช้ไฟหลากหลายประเภทได้แก่ บ้านที่อยู่อาศัยขนาดใหญ่ ร้านค้า โรงงาน ธุรกิจขนาดเล็กและขนาดกลาง หน่วยงานราชการ เช่น สถานีตำรวจ โรงพยาบาล อบต. เป็นต้น ข้อมูลผู้ใช้ไฟแต่ละประเภทจะถูกทดสอบเป็น class และเก็บบันทึกผลทดสอบดังแสดงในตารางที่ 4-21 สำหรับค่าแรงดัน จำนวนผู้ใช้ไฟทั้งหมด 186 ราย จำแนกถูกต้องจำนวน 157

ราย โดยที่ผลการทดสอบความถูกต้องได้เท่ากับ 84.4% ความผิดพลาดส่วนใหญ่ถูกพบในกลุ่มปกติและ
 ชำรุด ส่วนตารางที่ 4-22 สำหรับค่ากระแสจำนวนผู้ใช้ไฟทั้งหมด 189 ราย จำแนกถูกต้องจำนวน 153
 ราย ได้ผลการทดสอบความถูกต้องเท่ากับ 80.9% ในโมเดลจะทำนายผลและแสดงตัวอย่างผลการ
 ทดสอบโดยจะบอกเป็นค่าเปอร์เซ็นต์และแสดงเป็นกราฟแท่งดังภาพประกอบที่ 4-52 ภาพ CWT จะเป็น
 ภาพที่ได้จากการแปลงจากอนุกรมเวลา ซึ่งแสดงตัวอย่างผลการจำแนกทั้ง 3 class เป็นกราฟแท่งและ
 บอกค่าเปอร์เซ็นต์ความน่าจะเป็นของผลการทำนายที่ได้ (ด้านนอกวงเล็บผลที่ทำนายได้ ส่วนในวงเล็บคือ
 class จริง) ผลการทดสอบในแต่ละกรณีแสดงดังภาพประกอบที่ 4-53 โดยส่วนใหญ่โมเดลสามารถทำนาย
 ได้ถูกต้อง (เครื่องหมายถูกสีเขียว) แต่ยังมีบางกรณีที่ทำนายไม่ถูกต้องเช่นเครื่องหมายผิดสีแดง



ภาพประกอบที่ 4-52 ตัวอย่างผลการจำแนกทั้ง 3 class โดยใช้ภาพ CWT



ภาพประกอบที่ 4-53 ผลการทำนายโมเดลจากข้อมูลชุดอื่น

ตารางที่ 4-24 ผลการทดสอบข้อมูลค่าแรงดันของโมเดลจากข้อมูลชุดอื่น

แรงดัน (ข้อมูล แต่ละกลุ่ม)	จำนวนผู้ใช้ไฟ	ผลการทดสอบข้อมูลค่าแรงดัน		
		จำแนกถูกต้อง(ราย)	จำแนกผิด(ราย)	จำแนกผิด(ราย)
ข้อมูลการใช้ไฟ ปกติ	107	93	8 ราย (ทำนาย เป็นชำรุด)	6 ราย (ทำนาย เป็นละเมิด)
ข้อมูลมิเตอร์ หรืออุปกรณ์ ประกอบชำรุด	66	55	4 ราย (ทำนาย เป็นปกติ)	7 ราย (ทำนาย เป็นละเมิด)
ข้อมูลผู้ใช้ไฟ ละเมิด	13	9	3 ราย (ทำนาย เป็นชำรุด)	1 ราย (ทำนาย เป็นปกติ)
รวมทั้งหมด	186	157	คิดเป็น 84.4 %	

หมายเหตุ: ข้อมูลที่ใช้ทดสอบมาจาก <https://www.amr.pea.co.th/AMRWEB/Index.aspx> จากปี 2022 เป็นการสุ่มเลือกในแต่ละพื้นที่โดยครอบคลุมทั้ง 12 เขต โดยการกรองข้อมูลเฉพาะแรงดันที่ระบบตรวจจับพบ

ตารางที่ 4-25 ผลการทดสอบข้อมูลค่ากระแสของโมเดลจากข้อมูลชุดอื่น

กระแส (ข้อมูล แต่ละกลุ่ม)	จำนวนผู้ใช้ไฟ	ผลการทดสอบข้อมูลค่ากระแส		
		จำแนกถูกต้อง(ราย)	จำแนกผิด(ราย)	จำแนกผิด(ราย)
ข้อมูลการใช้ไฟ ปกติ	103	88	7 ราย (ทำนาย เป็นชำรุด)	8 ราย (ทำนาย เป็นละเมิด)
ข้อมูลมิเตอร์ หรืออุปกรณ์ ประกอบชำรุด	72	56	5 ราย (ทำนาย เป็นปกติ)	11 ราย (ทำนาย เป็นละเมิด)
ข้อมูลผู้ใช้ไฟ ละเมิด	14	9	3 ราย (ทำนาย เป็นชำรุด)	2 ราย (ทำนาย เป็นปกติ)
รวมทั้งหมด	189	153	คิดเป็น 80.9 %	

หมายเหตุ: ข้อมูลที่ใช้ทดสอบมาจาก <https://www.amr.pea.co.th/AMRWEB/Index.aspx> จากปี 2022 เป็นการสุ่มเลือกในแต่ละพื้นที่โดยครอบคลุมทั้ง 12 เขต โดยการกรองข้อมูลเฉพาะค่ากระแสที่ระบบตรวจจับพบ

4.5.2 ผลลัพธ์การทดสอบโมเดลจากเหตุการณ์จริง (Test with Real Events)

ในการทดสอบจะทำการตรวจสอบข้อมูลโหลดการใช้ไฟในระบบและดึงข้อมูลออกมาเป็นไฟล์ excel ป้อนเข้าโมเดลให้โมเดลทำนายผลและออกไปตรวจสอบสภาพหน้างานจริง ตัวอย่างผลการจำแนกโดยใช้โมเดลที่ 2 แสดงดังภาพประกอบที่ 4-54 ผลการทดสอบแสดงดังตารางที่ 4-23 สำหรับค่าแรงดัน (ข้อมูลทั้งหมด 27 ราย ทำนายถูก 23 ราย คิดเป็น 85.2 %) และตารางที่ 4-24 สำหรับค่ากระแส (ข้อมูลทั้งหมด 31 ราย ทำนายถูก 25 ราย คิดเป็น 80.6 %) ด้วยในแต่ละกรณีเมื่อพบความผิดปกติจะทำการแก้ไขหน้างาน และกรณีรูปแบบการละเมิดจะเป็นการจำลองที่คลั่งมิเตอร์ แพนกมิเตอร์ กฟฟ. ระนอง เนื่องด้วยในช่วงเวลาที่ทดสอบไม่พบรูปแบบละเมิด ตัวอย่างการออกตรวจสอบหน้างานจริงแสดงดังภาพประกอบที่ 4-55 เป็นตัวอย่างผลการทำนายบางกรณี แต่ถึงอย่างไรก็ตาม สภาพหน้างานจริงมีหลายเหตุการณ์ที่ส่งผลให้โมเดลทำนายคลาดเคลื่อน เช่น หน้างานจริงปกติ แต่โมเดลทำนายเป็นชำรุด หรือหน้างานจริงชำรุดแต่โมเดลทำนายเป็นละเมิด เป็นต้น แสดงผลการทำนาย ดังภาพประกอบที่ 4-56 เครื่องหมายถูกคือทำนายถูกต้องตรงกับหน้างานจริงและเครื่องหมายผิดคือทำนายไม่ตรงกับหน้างานจริง


ตารางที่ 4-26 ผลการทดสอบข้อมูลค่าแรงดันของโมเดลจากเหตุการณ์จริง

แรงดัน (ข้อมูลแต่ละกลุ่ม)	จำนวนผู้ใช้ไฟ	ผลการทดสอบข้อมูลค่าแรงดัน		
		จำแนกถูกต้อง(ราย)	จำแนกผิด(ราย)	จำแนกผิด(ราย)
ข้อมูลการใช้ไฟปกติ	10	10	-	-
ข้อมูลมิเตอร์หรืออุปกรณ์ประกอบชำรุด	5	4	1 ราย (ทำนายเป็นปกติ)	-
ข้อมูลผู้ใช้ไฟละเมิด	12	9	1 ราย (ทำนายเป็นปกติ)	1 ราย (ทำนายเป็นชำรุด)
รวมทั้งหมด	27	23	คิดเป็น 85.2 %	


ตารางที่ 4-27 ผลการทดสอบข้อมูลค่ากระแสของโมเดลจากเหตุการณ์จริง

แรงดัน (ข้อมูลแต่ละกลุ่ม)	จำนวนผู้ใช้ไฟ	ผลการทดสอบข้อมูลค่าแรงดัน		
		จำแนกถูกต้อง(ราย)	จำแนกผิด(ราย)	จำแนกผิด(ราย)
ข้อมูลการใช้ไฟปกติ	10	10	-	-
ข้อมูลมิเตอร์หรืออุปกรณ์ประกอบชำรุด	6	4	1 ราย (ทำนายเป็นปกติ)	1 ราย (ทำนายเป็นละเมิด)
ข้อมูลผู้ใช้ไฟละเมิด	15	11	2 ราย (ทำนายเป็นปกติ)	2 ราย (ทำนายเป็นชำรุด)
รวมทั้งหมด	31	25	คิดเป็น 80.6 %	

หมายเหตุ: เป็นการสุ่มข้อมูลในระบบ <https://www.amr.pea.co.th/AMRWEB/Index.aspx> พื้นที่รับผิดชอบ กพอ.ระนอง ในช่วงวันที่ 1-20 กุมภาพันธ์ 2566 ซึ่งในช่วงวันเวลาดังกล่าวไม่พบรูปแบบการละเมิด แต่มีความจำเป็นต้องทดสอบจำลองเหตุการณ์เกิดขึ้นที่คลังแผนกมิเตอร์




ภาพประกอบที่ 4-54 ตัวอย่างผลการจำแนกโมเดลที่ 2 โดยใช้ RP image



ภาพประกอบที่ 4-55 ผลการตรวจสอบจากเหตุการณ์จริง



ภาพประกอบที่ 4-56 ผลการตรวจสอบจากเหตุการณ์จริง (ต่อ)



ภาพประกอบที่ 4-56 ผลการทำนายโมเดลจากเหตุการณ์จริง

4.6 ผลการจัดกลุ่ม

4.6.1 ผลการจัดกลุ่มตามลักษณะของข้อมูล

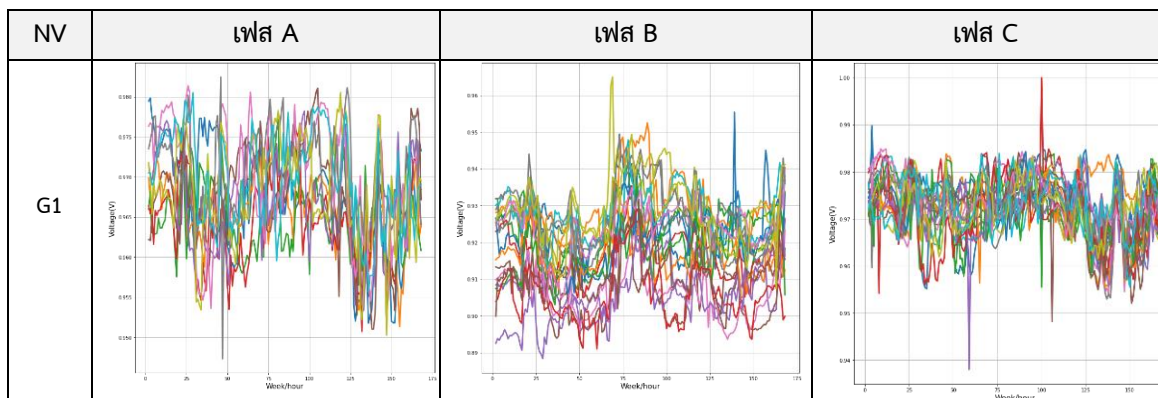
จากการนำ k-mean clustering มาใช้จัดกลุ่มในข้อที่ 3.8.1 และ 3.82 นั้น โดยสรุปผลการจัดกลุ่มของค่าแรงดันและกระแสทั้ง 3 กลุ่มได้ แสดงดังตารางที่ 4-25 และนำเสนอญาณมาพล็อตแยกแต่ละกลุ่มได้ดังตารางที่ 4-26 ถึง 4-31 จะพบว่าค่าแรงดันสำหรับปกติจะแบ่งได้เพียง 1 กลุ่ม และผิดปกติจะแบ่งกลุ่มได้มากกว่าหนึ่งกลุ่มนั่นคือ กลุ่มชั่วคราว 4 กลุ่ม และกลุ่มละเมิด 4 กลุ่ม ซึ่งมากกว่ากลุ่มค่ากระแสเนื่องจากรูปแบบผิดปกติมีความหลากหลายกว่า ในขณะที่ค่ากระแสจะมีความคล้ายกันทำให้แบ่งกลุ่มได้ยาก แต่ยังสามารถแบ่งกลุ่มได้ ผลที่ได้ของกระแสแบ่งออกเป็น 3 กลุ่ม ทั้ง 3 ลักษณะ

ตารางที่ 4-28 ผลการจัดกลุ่มของแรงดันและกระแสทั้ง 3 กลุ่ม


Parameters	Classes	Clusters	รายละเอียดของกลุ่ม
แรงดัน	ปกติ	1	NV_G1
	ชั่วคราว	4	DV_G1, DV_G2, DV_G3, DV_G4
	ละเมิด	4	TV_G1, TV_G2, TV_G3, TV_G4
กระแส	ปกติ	3	NA_G1, NA_G2, NA_G3
	ชั่วคราว	3	DA_G1, DA_G2, DA_G3
	ละเมิด	3	TA_G1, TA_G2, TA_G3

เมื่อ G คือ กลุ่ม NV คือ แรงดันปกติ DV คือ แรงดันชั่วคราว TV แรงดันละเมิด NA กระแสปกติ DA กระแสชั่วคราว TA กระแสละเมิด


ตารางที่ 4-29 กลุ่มแรงดันปกติ




ตารางที่ 4-30 กลุ่มแรงดันชำรุด




ตารางที่ 4-31 แรงดันละเมิด




ตารางที่ 4-32 กลุ่มกระแสปกติ



ตารางที่ 4-33 กลุ่มกระแสขั้วชุด



ตารางที่ 4-34 กลุ่มกระแสละเมิด




4.6.2 ผลการจัดกลุ่มก่อนจำแนกรูปแบบผิดปกติ

จากการนำข้อมูลปกติมาจัดกลุ่มและจำแนกในหัวข้อที่ 3.8.2 นั้น การจัดกลุ่มข้อมูลปกติของกระแสจะถูกแยกออกเป็นกลุ่มย่อยจำนวน 3 กลุ่ม และแต่ละกลุ่มจะแยกความผิดปกติที่อาจเกิดขึ้นโดยอ้างอิงรูปแบบปกติออกเป็นรูปแบบชำรุดและรูปแบบละเมิด จากนั้นข้อมูลในแต่ละกลุ่มจะถูกนำไปปรับสมดุลข้อมูล (อ้างอิงกลุ่มที่น้อยที่สุดปรับข้อมูลให้เท่ากันทั้ง 3 class) และจำแนกด้วย DenseNet121 เพื่อประเมินผลแยกแต่ละกลุ่มในแต่ละรูปแบบ

ตารางที่ 4-32 แสดงผลการจัดกลุ่มรูปแบบกระแส และนำข้อมูลฝึกปฏิตินแต่ละกลุ่มมากำหนดเป็น class สำหรับจำแนก แบ่งข้อมูล train 70% และ test 30% พบว่าผลลัพธ์ที่ได้จากการจำแนกโดยใช้ DenseNet121 ให้ค่าความถูกต้องและความแม่นยำที่สูงทั้ง 3 กลุ่ม และค่า FPR ต่ำ ดังภาพประกอบที่ 4-57 นั่นคือการจำแนกรูปแบบค่ากระแสก่อนจัดกลุ่มจะทำให้โมเดลทำนายได้แม่นยำขึ้น

ตารางที่ 4-35 ผลการจำแนกรูปแบบกระแส หลังจัดกลุ่มโดยใช้ DenseNet121

รูปแบบปกติ	Accuracy	Recall	Precision	F1-score	AUC-ROC	FPR
กลุ่ม 1	0.9874	0.958654	0.9893	0.9954	0.9803	0.147911
กลุ่ม 2	0.9803	0.971386	0.9880	0.9928	0.9803	0.169647
กลุ่ม 3	0.9846	0.972656	0.9925	0.9910	0.9833	0.141798



ภาพประกอบที่ 4-57 กราฟแสดงผลการ train-test accuracy และ train-test loss

4.6.3 ผลการจัดกลุ่มเพื่อแยกรูปแบบความผิดปกติตามสาเหตุการเกิด

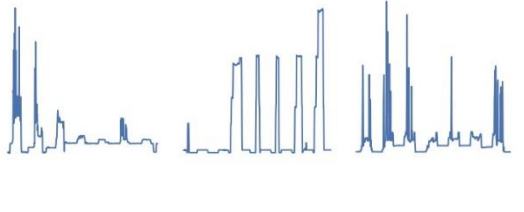
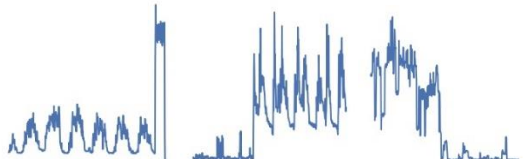
จากผลการเปรียบเทียบข้อมูลในการทดลองที่ 2.8.3 สามารถจัดรวมกลุ่มข้อมูลใหม่ได้ดังนี้

4.6.3.1 กลุ่มละเมิด

ตารางที่ 4-36 การจัดกลุ่มแยกตามสาเหตุสำหรับรูปแบบการละเมิด


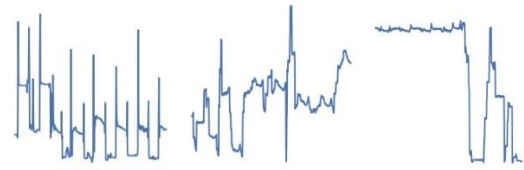
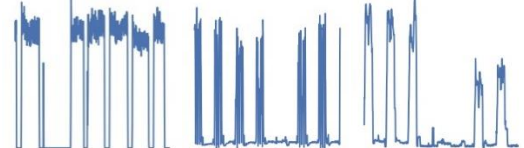
รูปแบบ	เหตุการณ์	รูปแบบที่คล้าย	ตัวอย่าง
ละเมิดแรงดัน	1.ตัดแปลง/แก้ไขสายControlแรงดัน	TV_G1 TV_G2	
	6.ตัดสายนิวตรอน		
แรงดัน	4. ต่อคร่อมชุดแรงดัน	TV_G3 TV_G4	

ตารางที่ 4-37 การจัดกลุ่มแยกตามสาเหตุสำหรับรูปแบบการละเมิด (ต่อ)

รูปแบบ	เหตุการณ์	รูปแบบที่คล้าย	ตัวอย่าง
ละเมิด กระแส	2.ตัดแปลง/แก้ไข สาย Control ชุด กระแส	TA_G1	
	3.จัดแ่งะCT แรงต่ำ		
กระแส	5.ต่อคร่อมชุดกระแส	TA_G2 TA_G3	

4.6.3.2 กลุ่มชำรุด

ตารางที่ 4-38 การจัดกลุ่มแยกตามสาเหตุสำหรับรูปแบบชำรุด

รูปแบบ	เหตุการณ์	รูปแบบที่คล้าย	ตัวอย่าง
ชำรุด แรงดัน	3. Voltage unbalance	DV_G1 DV_G2	
	6. Voltage Failure	DV_G3 DV_G4	
ชำรุด กระแส	1.Asymmetric Power	DA_G2 DA_G3	
	2.Over Current		
	4.Any phase current = 0	DA_G1	

พิจารณาจากตารางที่ 4-33 และ 4-34 พบว่าเมื่อทำการแบ่งรูปแบบระหว่างขำรูดกับละเมิดและนำสาเหตุความผิดปกติจากการเหตุการณ์ที่เกิดขึ้นจริงมาจับคู่กับรูปแบบที่ได้จากการจัดกลุ่มพบว่า สามารถแบ่งกลุ่มใหม่ได้อย่างละ 4 กลุ่ม ได้แก่ ขำรูด 4 กลุ่ม และละเมิด 4 กลุ่ม ตัวอย่างการแบ่งกลุ่มแสดงดังรูปด้านขวาของตาราง จากนั้นนำมาสรุปใหม่เป็นกลุ่ม โดยพิจารณาสาเหตุการเกิดทั้งหมด 8 กลุ่ม

จากแนวทางในการเพิ่มข้อมูลไม่สมดุลในหัวข้อที่ 2.6 ซึ่งประกอบด้วย 3 เทคนิค โดยจะนำมาเพิ่มจำนวนข้อมูลจากกลุ่มตามสาเหตุความผิดปกตินั้น จากผลการทดลองไม่สามารถนำมาประยุกต์ใช้ในการเพิ่มจำนวนข้อมูลได้ เนื่องจากรูปแบบที่เกิดขึ้นแต่ละสาเหตุจะมีความไม่แน่นอนสูงและแตกต่างกันในแต่ละกรณี ตัวอย่างเช่น ตารางที่ 4-35 และตารางที่ 4-36 เป็นการเปรียบเทียบระหว่างรูปแบบละเมิดที่พบจริงกับการใช้ Anomaly models ในการสร้างข้อมูลผิดปกติขึ้นมา ซึ่งผลลัพธ์ที่ได้ ไม่สามารถสร้างความผิดปกติแยกแต่ละสาเหตุได้ เพราะสมการที่ถูกสร้างขึ้นจะกำหนดเงื่อนไขเฉพาะผิดปกติคือทำให้ลดลงในรูปแบบต่างๆ แต่ไม่ได้เฉพาะเจาะจงในรูปแบบใดรูปแบบหนึ่ง

ตารางที่ 4-39 เปรียบเทียบรูปแบบละเมิดที่พบจริงกับข้อมูลละเมิดที่ถูกสร้างขึ้น

รูปแบบละเมิดที่พบจริง		รูปแบบสำหรับสร้างข้อมูลละเมิด
1.ตัดแปลง/แก้ไขสาย Control ชุดแรงดัน	Vs	1. เฟสใดๆ ลดลงเป็นศูนย์ เพียงบางเฟส
2.ตัดแปลง/แก้ไขสาย Control ชุดกระแส		2. ทั้ง 3 เฟสลดลงเป็นศูนย์ที่เวลาเดียวกัน
3.จัดแ่งะชุด CT แรงต่ำ		3. ทั้ง 3เฟส ลดลงแบบคงที่
4.ต่อคร่อมชุดแรงดัน		4. เป็นศูนย์บางช่วงเวลาทั้ง 3เฟส
5.ต่อคร่อมชุดกระแส		5. เฟสใดเฟสหนึ่งลดลง
6.ตัดสายนิวตรอน		

ตารางที่ 4-40 เปรียบเทียบรูปแบบขำรูด ที่ระบบแจ้งเตือนกับข้อมูลขำรูดที่ถูกสร้างขึ้น

รูปแบบขำรูด ที่ระบบแจ้งเตือน		รูปแบบสำหรับสร้างข้อมูลขำรูด
1.Asymmetric Power	Vs	1. เฟสใดๆ ลดลง (แต่ละเฟสต่างกันเพียงบางเฟส)
2.Over Current		2. ทั้ง 3 เฟสไม่สมดุล
3.Voltage unbalance		3. เฟสใดๆ สูงกว่าปกติ (กระแสบางเฟสสูงผิดปกติ)
4.Any phase current = 0		4. ทั้ง 3 เฟสลดลงอย่างสม่ำเสมอ
5.Reverse power		5. เป็นศูนย์บางช่วงเวลาทั้ง 3เฟส
6.Voltage Failure		6. เฟสใดเฟสหนึ่งลดลง

บทที่ 5

การอภิปรายและวิเคราะห์ผลการวิจัย

ในบทนี้จะเป็นการอธิบาย วิเคราะห์และตีความหมายโดยละเอียดของผลการวิจัยให้ชัดเจนมากยิ่งขึ้น และแสดงการเปรียบเทียบผลลัพธ์ที่ได้จากแต่ละวิธี การปรับสมดุลข้อมูล การจัดกลุ่มข้อมูล เพื่อหาวิธีที่เหมาะสม ผลการทดลองข้อมูลชุดอื่นและการทดสอบกับข้อมูลสถานการณ์จริง


5.1 การใช้เทคนิควิเคราะห์ตามช่วงเวลา

เทคนิคนี้อาศัยองค์ความรู้และประสบการณ์จากผู้เชี่ยวชาญ การสังเกตในที่ทำงานเพื่อสกัดออกมาเป็นคุณลักษณะ (feature) ซึ่งพิจารณา 2 พารามิเตอร์ที่สำคัญคือ ค่าแรงดันและกระแส จากผลความสัมพันธ์ Pearson Correlation เปรียบเทียบกับ feature ที่สกัดได้พบว่า

5.1.1 วิเคราะห์ข้อมูลชนิดที่สกัดเป็นตัวเลข (Numerical)

การพิจารณาตามช่วงเวลา ได้แก่ช่วงเวลา on-peak off-peak หรือช่วงในรอบวันเช่น วันทำงาน, วันเสาร์, อาทิตย์, วันหยุดนักขัตฤกษ์ โดยนำค่าเหล่านี้มาคำนวณเป็นค่า Z_{score} มีผลต่อ feature ที่สกัดได้ ซึ่งเมื่อเปรียบเทียบทั้ง 3 รูปแบบพบว่า ปกติกับผิดปกติจะมีความแตกต่างที่ชัดเจน เนื่องจากการแบ่งปริมาณการใช้ไฟตามช่วงเวลาส่งผลให้ค่าที่ได้มีปริมาณที่ใกล้เคียงกันสำหรับผู้ที่ใช้ไฟแต่ละราย แต่ในขณะที่รูปแบบชำรุดกับละเมิดยังมีความคล้ายกันอยู่ เป็นเพราะในช่วงเวลาที่เริ่มพบความผิดปกตินั้นยังไม่ถูกนำมาวิเคราะห์ว่ามีความแตกต่างกันอย่างไร

การพิจารณาไม่สมดุลเฟส (Unbalance Phase) ในสถานะผิดปกติลักษณะส่วนใหญ่ของแรงดันและกระแส 3 เฟส จะมีแนวโน้มลดลงและมีค่าไม่เท่ากัน จากความสัมพันธ์ของค่ากำลังไฟฟ้รวม ซึ่งเป็นผลรวมจากค่ากำลังไฟฟ้าแต่ละเฟสและเปลี่ยนแปลงตามเวลา ตามการใช้ไฟของผู้ใช้ไฟ มีความเกี่ยวข้องกับการใช้โหลดโดยตรง โดยปกติจะมีค่าใกล้เคียงทั้ง 3 เฟส แต่ด้วยมิเตอร์ที่ติดตั้งเป็นระบบสามเฟส 4 สาย การวัดค่ากระแสแต่ละเฟสจะเป็นอิสระต่อกัน ส่งผลให้มีโอกาสเกิดความไม่สมดุลเฟสได้ในสถานะที่ผู้ใช้ไฟปกติ ดังภาพประกอบที่ 5-1 แสดงการติดตั้ง CT จำนวน 3 ชุด และลักษณะของเฟสเซอร์ระบบ 3 เฟส 4 สาย กรณีที่ผู้ใช้ไฟใช้โหลด 3 เฟส ระบบจะมีความสมดุล แต่ถ้าใช้โหลด 1 เฟส แต่ติดตั้งเป็นระบบสามเฟส มีโอกาสเกิดไม่สมดุลเฟสได้



ภาพประกอบที่ 5-1 วงจรต่อใช้งานและไดอะแกรมของระบบ 3 เฟส 4 สาย [41]

พิจารณาค่าระยะทางโดยใช้ Manhattan distance คำนวณแต่ละกรอบเวลารวมถึงตลอดทั้งวัน ส่วน Euclidean distance สำหรับคำนวณค่าเฉลี่ยทั้งหมดนั้น ยังพบว่า ในกรณีที่ค่าใกล้เคียงศูนย์ (อาจเกิดจากผู้ใช้ไฟใช้โหลดน้อย) ค่าที่ได้มีค่าน้อยมากและการเปลี่ยนแปลงที่น้อยแต่เป็นความผิดพลาดนั้น ยังไม่สามารถแยกได้ชัดเจน เป็นผลมาจากการวัดโดยใช้ระยะทางในบางช่วงเวลามีการใช้โหลดไม่สม่ำเสมอ ซึ่งเมื่อคำนวณค่าออกมาจะมีความแปรปรวนสูง

5.1.2 วิเคราะห์ข้อมูลชนิดที่สกัดไม่เป็นตัวเลข (Nominal)

การพิจารณาแรงดันลดลง (voltage drop), แรงดันเป็นศูนย์ (voltage=0), แรงดันเกิน (over voltage), ความผิดปกติที่พบแต่ละช่วงเวลา (Time of use) ค่าดังกล่าวมีผลการสกัดอยู่ในรูปแบบที่ไม่เป็นตัวเลข ก่อนป้อนเข้าสู่โมเดล จำเป็นต้นใช้การเข้ารหัส one-hot encoding เพื่อแปลงเป็นตัวเลข ก่อน ค่าเหล่านี้พบว่าสามารถสะท้อนลักษณะความผิดปกติที่เกิดขึ้นได้ แต่ยังไม่ละเอียดมากกว่าพอที่จะบ่งบอกได้ว่าเกิดจากรูปแบบการชาร์จหรือละเมิด สามารถนำมาใช้ประกอบการสอนโมเดลได้

5.1.3 วิเคราะห์ข้อมูลจากค่า Pearson Correlation

จากข้อมูลทั้งหมด 37 features ถูกคำนวณโดยใช้สมการที่ 2-16 พบว่า ค่าแรงดันมีค่า Correlation เป็นบวก (Positive) จำนวน 7 ค่า และ 30 ค่าเป็นลบ (Negative) ส่วนกระแสมีค่า Correlation เป็นบวก (Positive) จำนวน 9 ค่า และ 28 ค่าเป็นลบ (Negative) จะพบว่าสัดส่วนของข้อมูลมีความสัมพันธ์ในด้านลบเป็นเพราะข้อมูลส่วนใหญ่ไม่มีผลหรือไม่เกี่ยวข้องกัน สะท้อนถึงเทคนิคที่นำมาใช้สกัดอาจไม่สอดคล้องกับคุณลักษณะของข้อมูลหรือพฤติกรรมการใช้ไฟของผู้ใช้ไฟ

5.1.4 ผลลัพธ์การสอนและทดสอบโมเดลเทคนิควิเคราะห์ตามช่วงเวลา


ผลที่ได้จากการทดสอบโมเดล พารามิเตอร์ค่าแรงดันให้ผลลัพธ์ที่สูงกว่าค่ากระแสเนื่องด้วยค่าแรงดันปกติกับผิดปกติมีความแตกต่างกันอย่างชัดเจนในขณะที่ค่ากระแสสภาวะปกติบางครั้งมีรูปแบบที่คล้ายกับผิดปกติเช่น ผู้ใช้ไฟเปลี่ยนแปลงโหลด ซึ่งโมเดลแต่ละชนิดมีแนวโน้มที่ให้ผลลัพธ์คล้ายกัน สิ่งสำคัญที่มีผลต่อการเรียนรู้ของโมเดลคือขั้นตอนการสกัดข้อมูล โดยรวมแล้วเทคนิควิเคราะห์ตามช่วงเวลาจากการสกัดโดยใช้ความรู้พื้นฐานยังให้ผลลัพธ์ที่ดี

5.2 การใช้วิธีสกัดข้อมูลที่อยู่ในโดเมนอนุกรมเวลา (Time Domain)

ด้วยข้อมูลของสัญญาณทางไฟฟ้าจะอยู่ในรูปของ time series การวิเคราะห์ใน time domain จึงเป็นสิ่งที่น่าสนใจที่จะช่วยเพิ่มประสิทธิภาพและการเรียนรู้ของโมเดล จากผลการทดลองทั้ง 5 เทคนิค ถูกนำมาใช้ในการทดสอบโมเดล ซึ่งผลที่ได้ถูกนำมาวิเคราะห์ดังต่อไปนี้

5.2.1 ผลการสกัดโดยใช้ค่าทางสถิติ (Statistical)


ค่าทางสถิติที่ใช้ประกอบด้วย 5 การคำนวณได้แก่ ค่าสูงสุด (Maximum) สำหรับตรวจสอบแรงดันหรือกระแสสูงผิดปกติ ค่าต่ำสุด (Minimum) สำหรับตรวจสอบค่าลดลงต่ำสุดในแต่ละช่วงเวลา ค่าเฉลี่ย (Mean) เพื่อคำนวณค่าโดยเฉลี่ยจากช่วงเวลาที่กำหนด ค่า (Median) เพื่อหาค่าการกระจายของข้อมูล และค่าส่วนเบี่ยงเบนมาตรฐาน (standard deviation) เพื่อวิเคราะห์การเบี่ยงเบนจากค่าค่าของกลุ่มข้อมูล จากที่กล่าวข้างต้นสกัดได้ 20 feature ซึ่งในแต่ละ feature ถูกนำมาทำ scatter plot ระหว่างค่าแรงดันและกระแสในแต่ละเฟส แสดงตัวอย่างดังรูปภาพประกอบที่ 5-2 พบว่าข้อมูลยังมีการซ้อนทับและเป็นกระจุก แสดงให้เห็นว่าข้อมูลมีค่าที่ใกล้เคียงกันแต่ละ class



ภาพประกอบที่ 5-2 ตัวอย่างการกระจายค่า median ของแรงดัน

5.2.2 ผลการสกัดโดยใช้วิธีแยกองค์ประกอบของอนุกรมเวลา

วิธีแยกองค์ประกอบของอนุกรมเวลาประกอบด้วย 4 ส่วนสำคัญ คือ Level Trend Seasonality และ Noise จากผลการทดลองพบว่าแต่ละองค์ประกอบมีความแตกต่างกันใน 3 class แต่ลักษณะโดยรวมระหว่างซำรุดกับละเมิดยังไม่ชัดเจน ตัวอย่างเช่นพิจารณาารูปภาพประกอบที่ 5-3 แสดงค่า trend ของแรงดันและกระแสซึ่งมีแนวโน้มลดลงเหมือนกันแต่มีรูปแบบที่คล้ายกันมาก นั่นคือ ข้อมูลอนุกรมเวลาที่ถูกแยกองค์ประกอบแล้วยังไม่สามารถบอกความแตกต่างของความผิดปกติที่เกิดขึ้นได้ จุดที่น่าสนใจจากเทคนิคนี้นั้นคือ รอยต่อของการเริ่มต้นผิดปกติที่แตกต่างกัน




ภาพประกอบที่ 5-3 ตัวอย่าง trend ของแรงดันและกระแส

5.2.3 ผลการสกัดโดยใช้ Auto-Correlation

ความสัมพันธ์อัตโนมัติ ถูกนำมาทดลองเพื่อวิเคราะห์ความแตกต่างของข้อมูล ค่าแรงดันและกระแสจะถูกคำนวณตามความสัมพันธ์อัตโนมัติระหว่างชุดข้อมูลที่เป็นลำดับก่อนหน้าและลำดับข้อมูลถัดไป ผลที่ได้ยังไม่สามารถแยกความแตกต่างระหว่างรูปแบบซำรุดกับละเมิด เพราะเป็นการอาศัยความสัมพันธ์ของอนุกรมก่อนหน้ากับอนุกรมถัดไปมาหาค่าเฉลี่ย ไม่ได้ใช้การคำนวณเชิงลึก

5.2.4 ผลการสกัดโดยใช้วิธีแบบจำลองสัญญาณ (Signal modeling)

วิธีแบบจำลองสัญญาณประกอบด้วย 5 เทคนิคที่ถูกนำมาใช้เพื่อเปรียบเทียบค่า minimum error ของโมเดล โดยจากผลการทดลองพบว่า Covariance Method ให้ค่าความผิดพลาดน้อยที่สุดและ Pade approximation มีค่าความผิดพลาดมากที่สุด แต่ถึงอย่างไรก็ตามปัจจัยหนึ่งที่สำคัญที่ต้องพิจารณาก่อนนำโมเดลไปใช้งานคือเสถียรภาพของระบบ แสดงตัวอย่างดังภาพประกอบที่ 5-4 การประมาณสัญญาณกลับต้องมีค่าใกล้เคียงกับข้อมูลต้นฉบับดังรูปด้านซ้าย Pole กับ Zero ต้องอยู่ในเส้นของวงกลมดังรูปด้านขวา




ภาพประกอบที่ 5-4 ตัวอย่างการประมาณสัญญาณกลับและเสถียรภาพของโมเดล

5.2.5 ผลลัพธ์การทดสอบโดยวิธีสกัดข้อมูลที่อยู่ในโดเมนอนุกรมเวลา

เมื่อพิจารณาจากตารางผลการสอนและทดสอบโมเดลสำหรับแรงดันและกระแส ซึ่งถูกนำมาพล็อตเป็นกราฟแท่งแสดงการเปรียบเทียบนั้น ประกอบด้วยทั้ง 4 เทคนิคกับ 8 โมเดล พบว่า วิธีแบบจำลองสัญญาณโดย Prony's method ให้ประสิทธิภาพสูงสุด สามารถลดขนาดข้อมูลได้ เพราะใช้เฉพาะค่าสัมประสิทธิ์ในการสอนและทดสอบ โมเดลสามารถประมวลผลได้เร็วขึ้น เพราะมีการสกัดข้อมูลจาก time series ผ่านโมเดลได้เป็นค่าสัมประสิทธิ์ แต่ยังคงเกิดค่า error ในบางชุดข้อมูล รองลงมาเป็นวิธีทางสถิติ Auto Correlation ที่ปรากฏชัดในลักษณะความแตกต่างระหว่างปกติกับผิดปกติ และวิธีแยกองค์ประกอบของอนุกรมเวลาที่ยังคงมีความคล้ายกัน

5.3 การสกัดข้อมูลจากโดเมนความถี่ (Frequency Domain)

การวิเคราะห์ในโดเมนความถี่ ถูกนำมาใช้ในการสกัด feature ซึ่งประกอบด้วย 2 เทคนิค ได้แก่ การแปลงฟูริเยร์แบบไม่ต่อเนื่อง (DFT) และการหาความหนาแน่นของสเปกตรัมพลังงาน (PSD) ภายหลังจากการแปลงให้อยู่ในโดเมนความถี่แล้ว ทั้ง 2 วิธีจะถูกคำนวณโดยใช้ค่าสถิติ ได้ทั้งหมด 20 feature ผลลัพธ์ที่ได้พบว่าความผิดปกติจะถูกลบที่ความถี่ลำดับต้น มีการกระเพื่อมและแกว่งตามรูปแบบการเปลี่ยนแปลงของสัญญาณแสดงตัวอย่างดังภาพประกอบที่ 5-5 โดยความถี่แรกคือความถี่มูลฐาน และความถี่ถัดไปจะเป็นความถี่ที่บ่งบอกถึงลักษณะที่เกิดขึ้น ลักษณะขรุขระจะแกว่งมากหรือมีความถี่สูงกว่าลักษณะการละเมิดแต่รูปแบบการละเมิดจะมีแนวโน้มที่ลดลงเร็วกว่า และถ้าพิจารณาผลการทดสอบโมเดลประกอบ พบว่าเทคนิค DFT จะจำแนกได้ผลลัพธ์ที่ดีกว่า PSD เป็นผลมาจากค่าสัมประสิทธิ์ที่ความถี่ลำดับต้นจะสะท้อนรูปแบบความผิดปกติได้ชัดเจนกว่าค่าผลรวมเฉลี่ยซึ่งก็คือค่าความหนาแน่นสเปกตรัม นั่นคือการคำนวณในมุมมองค่าสเปกตรัม ข้อมูลบางส่วนจะถูกเปลี่ยนค่าไป



ภาพประกอบที่ 5-5 เปรียบลักษณะ DFT และ PSD ระหว่างรูปแบบขำรุดกับละเมิด

5.4 การสกัดข้อมูลโดยรวม Time domain และ Freq domain

Time domain และ Freq domain ถูกนำมารวมกันทั้งหมด 40 feature และป้อนเข้าโมเดลทั้ง 8 ชนิด พบว่าการรวมกันของ feature มีส่วนช่วยให้โมเดลจำแนกได้ดีขึ้นเล็กน้อย ค่าสูงสุดของตัวแปรแรงดันอยู่ที่ RF: accuracy = 0.7983 และค่าสูงสุดของตัวแปรกระแสอยู่ที่ RF: accuracy = 0.7919 ซึ่งผลลัพธ์ที่ได้เป็นผลมาจากข้อมูลในแต่ละโดเมนไม่ได้สอดคล้องกันหรือเป็นไปในทิศทางเดียวกัน และค่าจากโดเมนความถี่มีค่าน้อยมากเมื่อเทียบกับค่าในโดเมนเวลา

5.5 การสกัดข้อมูลโดยการแปลงให้อยู่ในรูป 2D Image


5.5.1 วิเคราะห์การสกัดโดยเทคนิคที่นำมาใช้แปลงภาพแต่ละชนิด

ด้วยความก้าวหน้าของเทคโนโลยีด้าน Computer Vision ทำให้การประมวลผลประเภทรูปภาพสามารถทำได้รวดเร็วและแม่นยำ 5 เทคนิค ถูกนำมาใช้สำหรับแปลง time series เป็นรูปภาพ เหตุผลที่เลือกทั้ง 5 เทคนิคมาใช้ในการวิจัย เนื่องด้วยจากการทบทวนวรรณกรรม แต่ละเทคนิคจะถูกนำไปใช้ในงานที่แตกต่างกัน สำหรับด้านสัญญาณไฟฟ้ายังพบงานวิจัยส่วนน้อย จึงทำให้ต้องศึกษาในเชิงเปรียบเทียบทั้ง 5 เทคนิค เพื่อศึกษาจุดเด่นและข้อจำกัด โดยการประเมินผลโดยใช้ deep learning เป็นตัวจำแนก เพื่อให้ได้ศึกษาเทคนิคที่เหมาะสมกับข้อมูลทั้ง 3 class จากการทดลองและข้อสังเกตที่พบสรุปจุดเด่นและข้อจำกัดของแต่ละเทคนิคได้ดังตารางที่ 5-1 เมื่อพิจารณาจากจุดเริ่มต้นของการทดลองแต่ละรูปแบบมีความโดดเด่นที่แตกต่างกัน ส่งผลให้ในการศึกษาและทำวิจัยมีความจำเป็นต้องวิเคราะห์ในลักษณะเชิงเปรียบเทียบทั้ง 5 รูปแบบ


ตารางที่ 5-1 เปรียบเทียบจุดเด่นและข้อจำกัดทั้ง 5 เทคนิค

วิธีการ	จุดเด่น	ข้อจำกัด
CWT	<ul style="list-style-type: none"> - ผลการแปลงเวฟเล็ตจะได้ค่าสัมประสิทธิ์ที่เป็นฟังก์ชันของเวลาและสามารถทำการยืด-ขยาย(scale) หรือเคลื่อนรูปร่างได้(position) - ค่าสัมประสิทธิ์ของเวฟเล็ตถูกวาดในรูปของ scalogram โดยใช้โทนสี RGB ที่แสดงการเปลี่ยนแปลงของรูปสัญญาณ 	<ul style="list-style-type: none"> - มีข้อจำกัดในการกำหนดคุณลักษณะเฉพาะของเวฟเล็ตในเวลาและความถี่ - ค่าที่ได้จาก morlet wavelet จะมีค่าสัมประสิทธิ์ต่ำสำหรับค่าที่ใกล้เคียงศูนย์
RP	<ul style="list-style-type: none"> - RCP เหมาะสำหรับการวิเคราะห์พฤติกรรม การเกิดซ้ำที่แตกต่างกันในกระบวนการ - เพื่อระบุรูปแบบที่ไม่เด่นชัดในโดเนามิก 	<ul style="list-style-type: none"> - ข้อมูลสุ่มที่ไม่สัมพันธ์กัน (white noise) จะแสดงจุดที่แยกออกจากกันหลายจุดในแต่ละครั้ง
MTF	<ul style="list-style-type: none"> - MTF ใช้การเข้ารหัสและการเปลี่ยนข้อมูลความน่าจะเป็นในโดเมนเวลาของ quantile bins ที่สอดคล้องกัน - เมทริกซ์ MTF แสดงความน่าจะเป็นการเปลี่ยนแปลงบน magnitude axis 	<ul style="list-style-type: none"> - MTF ไม่ไวต่อการกระจายของอนุกรมเวลาและขึ้นอยู่กับช่วงเวลาที่เปลี่ยนแปลงแต่ละส่วน
GSAF	<ul style="list-style-type: none"> - อนุกรมเวลาถูกทำให้เป็นมาตรฐานโดยการแทนที่ช่วงของพิกัดเชิงขั้วด้วยพิกัดคาร์ทีเซียน (cartesian coordinates.) - ช่วงเวลาที่ต่างกันจะมีขอบเขตเชิงมุมที่สอดคล้องกับฟังก์ชันโคไซน์ในเมทริกซ์ 	<ul style="list-style-type: none"> - เมทริกซ์ Gramian มีขนาดใหญ่และต้องปรับขนาดก่อนสร้างขอบเขตเชิงมุม
SG	<ul style="list-style-type: none"> - ภาพที่แสดงสามารถบ่งบอกถึงลักษณะสัญญาณในความถี่สเปกตรัมของเวลาต่างๆได้ - ทุกความถี่ที่พบในสัญญาณจะถูกอธิบายเป็นตัวแทนของความเข้มของสัญญาณ - FFT ใช้ในการคำนวณขนาด magnitude แต่ละสเปกตรัมความถี่ 	<ul style="list-style-type: none"> - แผนภาพสเปกตรัมจะแสดงในรูปแบบแนวนอน สำหรับค่าความถี่ที่ใกล้เคียงกันหรือมีค่าต่ำจะปรากฏไม่ชัด

ตารางที่ 5-2 เปรียบเทียบผลการแปลงเป็นรูปภาพแต่ละเทคนิคของค่าแรงดัน



ตารางที่ 5-3 เปรียบเทียบผลการแปลงเป็นรูปภาพแต่ละเทคนิคของค่ากระแส



จากผลการแปลงในหัวข้อที่ 3.3.1 ซึ่งแสดงบางตัวอย่างในตารางที่ 5-2 และตารางที่ 5-3 ข้อสังเกตที่พบคือรูปแบบปกติ รูปร่างเมื่อแปลงเป็นรูปภาพจะมีความแตกต่างที่เด่นชัดเมื่อเปรียบเทียบกับรูปแบบผิดปกติทั้งสอง รูปแบบชำรุดลักษณะของภาพที่เกิดขึ้นจะมีลวดลายหรือแถบสีที่มีความเข้มมากกว่ารูปแบบละเมิด และรูปแบบละเมิดจะมีจุดเด่นที่การเปลี่ยนแปลงจะไล่ระดับสีจากสีเข้มไปหาสีอ่อน แต่ถึงอย่างไรก็ตามแต่ละเทคนิคจะปรากฏภาพที่แตกต่างกัน ผลการแปลงเป็นภาพเบื้องต้นสามารถเห็นความแตกต่างได้แต่ถ้าต้องจำแนกความแตกต่างทั้ง 3 class จำเป็นต้องใช้ deep learning มาช่วยในการจำแนก เพราะหลักการของการจำแนกข้อมูลประเภทรูปภาพนั้น รายละเอียดในภาพจะถูกแบ่ง

ออกเป็นพิกเซลย่อยและป้อนเข้าสู่โมเดลเพื่อเรียนรู้ ผ่านการกำหนด class ของแต่ละภาพ ด้วยการพัฒนาและการปรับโครงสร้างของโมเดลทำให้สามารถนำมาใช้สำหรับจำแนกรูปภาพได้ในงานวิจัยนี้ได้

5.5.2 วิเคราะห์ผลทดสอบการแปลงอนุกรมเวลาเป็นรูปภาพ

รูปภาพที่ผ่านการแปลงแต่ละเทคนิคถูกป้อนเข้าโมเดล CNN เพื่อจำแนกลักษณะ ออกเป็น 3 class โดยใช้ Performance matrix ในการประเมินผล ประกอบด้วย Accuracy Precision Recall F1-score และ AUC-ROC ผลการทดสอบแสดงไว้ในตารางที่ 4-19 และตารางที่ 4-20 แยกแต่ละเฟส จากนั้นนำแต่ละเฟสมาหาค่าเฉลี่ยเพื่อเป็นตัวแทนสำหรับเปรียบเทียบทั้ง 5 เทคนิค แสดงผลดังภาพประกอบที่ 4-41 และ 4-42 พบว่าทั้งค่าแรงดันและค่ากระแสจะให้ผลไปทิศทางเดียวกันคือ CWT มีความเหมาะสมในการนำมาสกัดข้อมูลมากที่สุด ถ้าพิจารณาจากรูปภาพที่ปรากฏตารางที่ 5-2 และ 5-3 สีแดงเข้มจะแสดงถึงค่าการเปลี่ยนแปลงของสัญญาณและค่าสัมประสิทธิ์ที่มีค่าสูงและสีน้ำเงินอ่อนจะแสดงถึงค่าสัมประสิทธิ์ต่ำ ถัดมาเป็น RP ซึ่งให้ผลลัพธ์ที่ดีใกล้เคียงกับ GASF แต่มีหลักการแปลงที่ต่างกัน RP จะพล็อตการเกิดซ้ำของสัญญาณและมีค่า threshold เป็นตัวกำหนดรูปแบบการเกิดขึ้น ในขณะที่ GASF จะพล็อตกราฟโดยอาศัยความสัมพันธ์เชิงมุมของโคไซน์โดยใช้ระบบพิกัดเชิงขั้ว ซึ่งค่ามุมที่เกิดขึ้นจะสัมพันธ์กับรูปแบบการเปลี่ยนแปลง ถัดมาเป็น MTF เป็นเทคนิคที่มีความซับซ้อน จะอาศัย markov transition ซึ่งเปลี่ยนแปลงตาม quantile bins และ SG ผลการจำแนกได้ค่าต่ำสุด เป็นเพราะค่าที่คำนวณได้จากขนาดของสเปกตรัมจาก DFT มีค่าต่ำ จึงปรากฏแถบคลื่นสเปกตรัมได้ไม่ชัดเจน


5.6 วิเคราะห์ผลการใช้เทคนิคจัดการข้อมูลที่ไม่สมดุล

5.6.1 วิเคราะห์ผลจากโมเดลความผิดปกติ (Anomaly model)

ข้อมูลปกติถูกสุ่มเลือกเพื่อป้อนเข้าโมเดลความผิดปกติสำหรับสร้างสัญญาณที่ผิดปกติซึ่งแบ่งเป็น 2 โมเดล คือโมเดลชำระจุดกับละเมิด ลักษณะข้อมูลที่สร้างขึ้นจะมีรูปแบบที่เกิดจากการสุ่มค่าทั้งแบบกำหนดเองและโปรแกรมกำหนด ทำให้ผลลัพธ์ที่สร้างขึ้นมีหลายหลายแต่ยังคงลักษณะที่ผิดปกติ ตารางที่ 5-4 แสดงตัวอย่างการเปรียบเทียบค่ากระแส สัญญาณจากเหตุการณ์จริงและสัญญาณที่สร้างจาก Anomaly model แบบ 3 เฟสดังรูปด้านซ้ายและรูปด้านขวาจะแยกออกมาเป็นแต่ละเฟสตามรูปแบบที่พบ เช่น พบปกติกับละเมิด พบปกติกับชำระจุด หรือละเมิดและชำระจุดทั้ง 3 เฟส เป็นต้น ซึ่งรูปแบบ


ที่สร้างขึ้นสามารถใช้เป็นตัวแทนข้อมูลสำหรับสอนโมเดลได้ ข้อสังเกตอย่างหนึ่งที่สำคัญคือรูปแบบที่สร้างขึ้นอาจเกิดค่าสูง-ต่ำผิดปกติ หรือบางครั้งค่าใกล้เคียงศูนย์ ซึ่งต้องกรองค่าออกมาและปรับตามความเหมาะสม

ตารางที่ 5-4 เปรียบเทียบสัญญาณจากเหตุการณ์จริงกับสัญญาณที่ถูกสร้างขึ้น



5.6.2 วิเคราะห์ผลจากการสุ่มตัวอย่างแบบสังเคราะห์ที่ปรับเปลี่ยนค่าได้ (ASASYN)


ค่าที่ได้จากเทคนิค ASASYN จะถูกสร้างขึ้นโดยอาศัยความสัมพันธ์ระหว่างชนกลุ่มน้อย (minority class) กับชนกลุ่มมาก (majority class) โดยการคำนวณจากค่าระดับของกลุ่ม (degree of class) และสังเคราะห์ข้อมูลโดยใช้ Euclidean distance ตัวอย่างการกระจายตัวเพื่อสังเคราะห์ข้อมูลใหม่แสดงดังภาพประกอบที่ 5-6 ข้อมูลชนกลุ่มน้อยจะถูกวัดค่าระยะทาง X_1 และคำนวณผ่าน K nearest neighbors เพื่อสร้างข้อมูลใหม่ขึ้นมา และข้อมูลใหม่นั้นก็จะถูกนำมาคำนวณค่าระยะทางใหม่ X_2 ต่อไป ทำแบบนี้ไปจนค่าชนกลุ่มน้อยและชนกลุ่มมากมีความสมดุลกัน ในงานวิจัยจะจับกลุ่มความสัมพันธ์ระหว่างค่ากระแสและแรงดันในแต่ละเฟส



ภาพประกอบที่ 5-6 ตัวอย่างการกระจายตัวเพื่อสังเคราะห์ข้อมูลของ ASASYN

5.6.3 วิเคราะห์การเพิ่มข้อมูลโดยการปรับรูปภาพ (Image data augmentation)

เทคนิคนี้จะเป็นการสุ่มค่าโดยการเขียนโค้ดในโปรแกรมประกอบด้วย 8 เทคนิคเพื่อปรับแต่งภาพและสร้างภาพรูปใหม่ขึ้นมาโดยใช้ภาพเก่า ตัวอย่างการสุ่มสร้างภาพแสดงดังภาพประกอบที่ 5-7 จะพบว่าภาพมีความแตกต่างจากรูปภาพเดิมในมุมมองต่างๆ แต่ถึงอย่างไรก็ตามด้วยข้อจำกัดด้านเทคนิคเช่น Cropping Padding และ Zooming เป็นต้น ค่าพารามิเตอร์ที่ใช้กำหนดการปรับแต่งภาพจึงมีความสำคัญ โดยทางผู้วิจัยได้ทำการทดลองปรับแบบ manual เพื่อควบคุมลักษณะของภาพเพื่อไม่ให้สูญเสียรายละเอียด ที่อาจส่งผลต่อการเรียนรู้ของโมเดล ซึ่งเพิ่มความยากในการจำแนกอาจทำให้โมเดลเกิดความสับสนได้



ภาพประกอบที่ 5-7 ตัวอย่างการสุ่มสร้างภาพโดยใช้ Position augmentation

5.6.4 ผลการทดสอบเปรียบเทียบแต่ละเทคนิค

จากผลการทดสอบใช้โมเดลจำแนกค่าพารามิเตอร์แรงดันและค่ากระแส ตัวประเมินผลที่ใช้ประกอบด้วย Accuracy, Recall, Precision, F1-score และ AUC-ROC ซึ่งใช้ประเมินความถูกต้องจากการจำแนกแต่ละ class ของโมเดลและ FPR สำหรับประเมินการจำแนกผิด ผลสรุปค่า Accuracy ในแต่ละเทคนิคซึ่งพบว่า AM ให้ผลลัพธ์ที่ดีที่สุดและ IA ให้ผลลัพธ์ต่ำสุดทั้ง 2 ตัวแปร จากการทดลองแสดงให้เห็นว่าการสมดุลงานก่อนป้อนเข้าโมเดลมีส่วนช่วยเพิ่มประสิทธิภาพให้กับโมเดล วิธี AM สร้างข้อมูลซ้ำและละเมิดจากการป้อนข้อมูลปกติผ่านสมการที่กำหนดขึ้น มีความหลากหลายและรูปแบบที่ถูกสร้างสอดคล้องกับความผิดปกติแต่ละแบบ วิธี ASASYN ให้ผลลัพธ์ที่ดีเช่นกันแต่ขนาดความหลากหลายเพราะข้อมูลถูกสังเคราะห์จากกลุ่มข้อมูลที่อยู่ใกล้กัน วิธี IA ไม่เหมาะสำหรับภาพที่ถูกสร้างผ่านการแปลงจากอนุกรมเวลาเป็นรูปภาพ เหมาะสำหรับภาพที่มีความแตกต่างระหว่างพื้นหลังกับวัตถุ และข้อมูลที่ไม่สมดุลงานจะมีจำนวนข้อมูลที่ไม่เท่ากัน อาจส่งผลให้เกิดความผิดพลาดได้เมื่อนำโมเดลไปใช้งาน การประเมินผลโดยใช้ FPR เป็นตัวหนึ่งที่มีความสำคัญเพราะจะเป็นตัวบ่งบอกถึงโอกาสที่โมเดลทำนายผิด ตัวอย่างเช่น เกิดการละเมิดแต่โมเดลทำนายว่าปกติ ซึ่งไม่ควรเกิดขึ้น

5.7 การทดสอบโมเดล (Test Model)


จากผลการทดลองทั้ง 2 โมเดล ข้อสังเกตและปัจจัยของผลลัพธ์ที่ได้สามารถอธิบายได้ดังต่อไปนี้

5.7.1 วิเคราะห์ผลการทดสอบโมเดลจากข้อมูลชุดอื่น (Test with Real Data)

จากผลการทดลองจะพบว่าโมเดลยังทำนายผิดพลาดในบางรูปแบบเมื่ออ้างอิงจากผลการทดสอบกับข้อมูลที่โมเดลไม่ได้เรียนรู้มาก่อน ตัวอย่างเหตุการณ์ที่ทำนายผิดพลาดเช่น ข้อมูลปกติแต่โมเดลทำนายว่าซ้ำ ข้อมูลซ้ำแต่โมเดลแต่ทำนายว่าปกติ ข้อมูลละเมิดแต่โมเดลแต่ทำนายว่าซ้ำ เป็นต้น พิจารณาจากภาพประกอบที่ 5-8 แสดงการเปรียบเทียบข้อมูลแต่ละประเภทซึ่งจะพบว่า รูปแบบปกติจะมีความแตกต่างจากรูปแบบซ้ำและละเมิดเพราะปรากฏลักษณะการเปลี่ยนแปลงที่สม่ำเสมอ เมื่อทำการแปลงโดยใช้ CWT จะมีการกระจายของค่าความสัมพันธ์ในหลายส่วนของภาพ ในขณะที่รูปแบบซ้ำลักษณะความผิดปกติจะมีการเปลี่ยนแปลงที่ลดลงและแกว่ง โดอนส่วนใหญ่จะไม่เป็นศูนย์ ทำให้ภาพที่เกิดขึ้นจะมีค่าความถี่เข้มข้นบริเวณจุดที่เปลี่ยนแปลง มีความคล้ายกับรูปแบบละเมิดแต่ส่วนใหญ่


เปลี่ยนแปลงลดลงเข้าใกล้ศูนย์ ดังนั้น เมื่อวิเคราะห์สาเหตุที่ทำให้โมเดลทำนายผิดพลาดสามารถสรุปประเด็นหลักๆได้ดังนี้

- ก. ช่วงเวลาที่เลือกมาวิเคราะห์ (Interval time) ปัจจุบันการนำข้อมูลมาวิเคราะห์นั้นจะพิจารณาจากวันที่ระบบ AMR monitoring แจ้งเตือนความผิดปกติ และทำจำนวนวันก่อนหน้า 3 วัน นับไปหลัง 4 วัน จนครบ 1 สัปดาห์ เป็นข้อมูลทุก 15 นาที ได้ทั้งหมด 672 ค่า จากนั้นจะทำการสกัดเบื้องต้นโดยคำนวณค่าเฉลี่ยรายชั่วโมง $672/4 = 168$ ค่า ถึงอย่างไรก็ตามในบางครั้งความผิดปกติที่เกิดขึ้นอาจมีจำนวนมากกว่า 1 สัปดาห์ หรือน้อยกว่า 1 สัปดาห์ทำให้ค่าที่นำมาพิจารณามีข้อมูลปกติรวมอยู่ด้วย
- ข. ข้อมูลที่ใช้สอนไม่สมดุล(Unbalanced data) ด้วยจำนวนสัดส่วนของข้อมูลที่ใช้สอนโมเดลประกอบด้วย ปกติ:ชำรุด:ละเมิด คือ 60:30:10 ดังนั้น ส่งผลให้โมเดลอาจเกิดการเรียนรู้และไบแอสไปยังข้อมูลส่วนมากได้
- ค. ค่าสัมประสิทธิ์จากการแปลง CWT มีค่าต่ำมาก(Low coefficients) จากสมการความสัมพันธ์ของ Morlet wavelet นั้น ค่าอนุกรมเวลาจะถูกคำนวณโดยใช้ค่าเอ็กโพเนนเชียล ทำให้ผลลัพธ์ที่ได้มีค่าต่ำเมื่อถูกนำไปแปลงเป็นรูปภาพโดยใช้ CWT อาจปรากฏค่าไม่ชัดเจน
- ง. ประเภทกลุ่มของผู้ใช้ไฟ(Cluster of customers) ในการจำแนกไม่ได้มีการแบ่งกลุ่มก่อน จะนำข้อมูลที่ได้ของทุกประเภทผู้ใช้ไฟมาพิจารณาร่วมกัน สิ่งนี้อาจทำให้กลุ่มที่มีพฤติกรรมการใช้ไฟแตกต่างกันมาก มีลักษณะที่ต่างกันและอาจใกล้เคียงกับกลุ่มที่ผิดปกติ
- จ. ผลกระทบด้านเศรษฐกิจ (Economic impact) ข้อมูลในอดีตกับปัจจุบันผู้ใช้ไฟมีพฤติกรรมรูปแบบการใช้ไฟที่เปลี่ยนแปลงไป ด้วยเป็นผลจากสถานการณ์ของโรคระบาด และผลกระทบด้านเศรษฐกิจที่มีการลดกำลังการผลิตลง ทำให้รูปแบบการบริโภคไฟฟ้าเปลี่ยนแปลงไป



ภาพประกอบที่ 5-8 การเปรียบเทียบข้อมูลแต่ละประเภทของแรงดัน

5.7.2 วิเคราะห์ผลการทดสอบโมเดลจากเหตุการณ์จริง (Test with real event)



ภาพประกอบที่ 5-9 การเปรียบเทียบข้อมูลแต่ละประเภทของกระแส

สำหรับการทดสอบกับเหตุการณ์จริงนั้น ข้อมูลจากระบบจะถูกออกมาเพื่อจำแนกความผิดปกติก่อนออกไปตรวจสอบหน้างานจริง จากภาพประกอบที่ 5-9 แสดงความแตกต่างทั้ง 3 รูปแบบของค่ากระแส พบว่ากระแสจะเปลี่ยนแปลงตามลักษณะการใช้โหลดของผู้ใช้ไฟ นั่นคือในสภาวะปกติจะมีลักษณะเป็นคาบ เมื่อพล็อตโดยใช้ RP จะเกิดรูปแบบการเปลี่ยนแปลงการเกิดซ้ำจำนวนมาก ในขณะที่ลักษณะซำรุด จะแกว่งและกระเพื่อมสูงตามพฤติกรรมการใช้ไฟเมื่อพล็อตโดยใช้ RP จะมีความเข้มของเส้นและความถี่สูงบริเวณจุดที่มีการเปลี่ยนแปลงมาก และลักษณะละเมิดจะเปลี่ยนแปลงแบบสุ่มและลดลงใกล้เคียง การเปลี่ยนแปลงโดยใช้ RP พล็อต มีค่าความเข้มที่ไม่สม่ำเสมอและมีค่าน้อยบริเวณที่ค่าการเปลี่ยนแปลงลดลง


เมื่อพิจารณาจากผลการทดสอบพบว่า กรณียกตินั้นโมเดลสามารถจำแนกได้ถูกต้องทุกกรณี แต่ในกรณีซำรุดพบว่ามีส่วนเหตุการณ์ที่โมเดลทำนายว่าปกติและละเมิด เนื่องด้วยผู้ใช้ไฟบางรายปรับเปลี่ยนโหลดภายในเพื่อลดค่าใช้จ่าย หรือเลิกกิจการ(ไม่ใช้โหลด 3 เฟส) และใช้เพียงโหลดหนึ่งเฟส สำหรับระบบแสงสว่างเท่านั้นกรณีละเมิดจะเป็นการจำลองเหตุการณ์ขึ้นและนำผลที่ได้ป้อนเข้าโมเดลเพื่อจำแนก มีกรณีละเมิดแต่โมเดลทำนายปกติ ซึ่งจากการวิเคราะห์พบว่ารูปแบบดังกล่าวมีลักษณะที่คล้ายผู้ใช้ไฟที่ใช้โหลดไม่สมดุล (กรณีละเมิดหักสายบางเฟส) จากประเด็นดังกล่าวสามารถสรุปข้อสังเกตได้ดังนี้

- ก. ในสถานการณ์ที่ทดสอบบางอย่างมีความคลุมเครือ เหตุการณ์การละเมิดจริงยังไม่ถูกพบ และรูปแบบซำรุดส่วนใหญ่มาจากการใช้โหลดภายในของผู้ใช้ไฟที่ทำให้เกิดความผิดปกติ
- ข. ผลกระทบจากค่าพารามิเตอร์ในการกำหนดค่าการแปลงอนุกรมเวลาไปเป็นรูปภาพ เช่น ค่าความหนาแน่นของการพล็อตซ้ำ (Recurrence rate), ค่าเฉลี่ยของการเกิดเส้นทะแยงมุม (Average length of diagonal lines) ทำให้ภาพที่ได้ในบางภาพ ปรากฏมุมมองที่ไม่ชัดเจน
- ค. ผลกระทบของโครงสร้างโมเดล DenseNet121 เนื่องด้วยในงานวิจัยไม่ได้ทำการปรับค่าพารามิเตอร์ภายใน ใช้ค่าตั้งต้นของโมเดลในการทดสอบ ทำให้อาจมีผลต่อการเรียนรู้ของโมเดล

5.8 วิเคราะห์ผลจากเทคนิคการจัดกลุ่ม

5.8.1 วิเคราะห์ผลจากการจัดกลุ่มตามรูปแบบผิดปกติ

จากผลการจัดกลุ่มจะพบว่าค่าแรงดันของผู้ใช้ไฟสามารถแบ่งกลุ่มประเภทปกติได้เพียง 1 กลุ่ม เพราะโดยปกติหรือตามมาตรฐานของหารไฟฟ้าส่วนภูมิภาค แรงดันไฟฟ้าประเภทแรงดันต่ำจะมีค่าประมาณ 400-380 V สำหรับ V_{line} และ 230-220 V สำหรับ V_{phase} แต่เมื่อจัดกลุ่มจากรูปแบบผิดปกติ จะพบว่าทั้งรูปแบบขำรุดและรูปแบบละเมิดสามารถแยกกลุ่มได้ถึง 4 กลุ่ม แสดงให้เห็นว่ากรณีเกิดความผิดปกติเกิดขึ้นมีการเปลี่ยนแปลงที่หลากหลาย การลดลงแต่ละเฟสกับความสัมพันธ์กับเฟสที่ปกติ สำหรับค่ากระแส เป็นค่าที่เปลี่ยนแปลงตามปริมาณการใช้โหลดของผู้ใช้ไฟ และเกี่ยวข้องกับชนิดของโหลดที่ต่อใช้ไฟ รูปแบบปกติ ขำรุดและละเมิด จัดกลุ่มได้ทั้งหมด 3 กลุ่ม ซึ่งกลุ่มที่ถูกจัดมีบางกลุ่มที่มีหลายหลายรูปแบบรวมเป็นกลุ่มเดียวกัน เทคนิคสำคัญของการจัดกลุ่มในงานวิจัยนี้ คือการใช้คลัสเตอร์ตามฟังก์ชันการให้คะแนนพิจารณาจากเส้นโค้ง(รูปซ้าย) และแสดงคะแนนภาพเงาของแต่ละคลัสเตอร์ในแต่ละกลุ่ม(รูปขวา) ดังรูปภาพประกอบที่ 5-10



ภาพประกอบที่ 5-10 เส้นโค้งแสดงคะแนนภาพเงาของแต่ละคลัสเตอร์

5.8.2 วิเคราะห์ผลการจัดกลุ่มก่อนนำไปจำแนกรูปแบบผิดปกติ

การจัดกลุ่มก่อนจำแนกเป็นการแบ่งข้อมูลออกเป็นกลุ่มย่อยเพื่อให้สอดคล้องกับรูปแบบการใช้ไฟ สำหรับผู้ใช้ไฟแต่ละประเภท เช่น ใช้โหลดตลอดเวลา ใช้โหลดเฉพาะช่วงเวลา(กลางวันหรือกลางคืน) เมื่อแบ่งกลุ่มแล้วความผิดปกติที่เกิดขึ้นจะเห็นความแตกต่างได้ชัดเจนขึ้นระหว่างรูปแบบขำรุดและละเมิด ข้อมูลจะถูกป้อนเข้าโมเดลเพื่อทำการสอน โมเดลจะเรียนรู้รูปแบบได้ดีขึ้น

ตารางที่ 5-5 เปรียบเทียบระหว่างการจำแนกโดยไม่จัดกลุ่มกับการจัดกลุ่มก่อนจำแนก

จำแนกโดยไม่จัดกลุ่ม	จัดกลุ่มก่อนจำแนก
ไม่จำเป็นต้องแบ่งกลุ่ม ข้อมูลที่มีแต่ละ class สามารถป้อนเข้าโมเดลเพื่อจำแนกได้เลยลดเวลา	จำเป็นต้องแบ่งข้อมูลย่อยแต่ละกลุ่มทำให้ใช้เวลาในการจัดกลุ่ม
ใช้เพียงโมเดลเดียวสำหรับจำแนก (โมเดลจำแนกสำหรับแรงดันและโมเดลจำแนกสำหรับกระแส)	ในแต่ละกลุ่มจะถูกสอนและปรับค่าแยกจากกันทำให้โมเดลที่ถูกสร้างมีจำนวนเท่ากับจำนวนกลุ่มที่แบ่งได้ นั่นคือถ้ามีหลายกลุ่มก็จำเป็นต้องใช้หลายโมเดล เป็นการสิ้นเปลืองทรัพยากร
ข้อมูลที่ป้อนเข้าโมเดลมีความหลากหลาย มีโอกาสที่ทำให้โมเดลทำนายผิดพลาดได้	มีการจัดกลุ่มก่อนจำแนกลดความหลากหลายข้อมูล ซึ่งขั้นตอนการจัดกลุ่มมีส่วนสำคัญต่อการจำแนก หากข้อมูลที่เข้ามาไม่เข้ากลุ่มหรือเข้ากลุ่มผิดอาจทำให้โมเดลทำนายผลผิดพลาดได้
มีความถูกต้องและแม่นยำปานกลาง	มีความถูกต้องและแม่นยำสูง
ขณะtrain โมเดลเกิด overfitting บางช่วงข้อมูล	ไม่เกิด overfitting ในขณะสอนโมเดล

แต่ถึงอย่างไรก็ตาม เมื่อเปรียบเทียบระหว่างการจำแนกโดยไม่จัดกลุ่มกับการจัดกลุ่มก่อนจำแนก ซึ่งสามารถแสดงการเปรียบเทียบได้ดังตารางที่ 5-5 กรณีต้องการโมเดลที่มีความเฉพาะแม่นยำสูง สามารถใช้โมเดลจัดกลุ่มก่อนจำแนกรูปแบบได้ แต่หากต้องการใช้ทรัพยากรที่น้อย รับผิดชอบผิดพลาดได้บางส่วน และใช้ได้กับหลากหลายรูปแบบ การจำแนกโดยไม่จัดกลุ่มก็เป็นอีกทางเลือกหนึ่งที่เหมาะสม

5.8.3 วิเคราะห์ผลการจัดกลุ่มเพื่อแยกรูปแบบความผิดปกติตามสาเหตุการเกิด

ผลที่ได้ทำให้มีข้อมูลแต่ละสาเหตุความผิดปกติ ซึ่งสามารถนำข้อมูลนี้ไปใช้จำแนกสาเหตุความผิดปกติที่เกิดขึ้นได้ ตัวอย่างเช่น รูปแบบละเมิด เดิมค่ากระแสแบ่งได้ 3 กลุ่ม และค่าแรงดันแบ่งได้ 4 กลุ่ม ในขณะที่รูปแบบซาร์ตก็แบ่งได้จำนวนกลุ่มเช่นเดียวกัน จำนวนกลุ่มทั้งหมดนำมาแบ่งตามสาเหตุได้ดังตารางที่ 5-6 ซึ่งไม่ได้แบ่งแยกระหว่างตัวแปรแรงดันและกระแส แต่เป็นการแยกตามสาเหตุการเกิด ทั้งหมดแบ่งได้ 8 กลุ่ม แต่ถึงอย่างก็ตาม ยังมีข้อจำกัดที่มีข้อมูลจำนวนน้อยในแต่ละกลุ่ม

ตารางที่ 5-6 การจัดกลุ่มตามสาเหตุความผิดปกติ

กลุ่ม	สาเหตุการเกิด	รูปแบบผิดปกติ
GT1	ตัดแปลง/แก้ไขสาย Control หรือตัดสายนิวตรอน	ละเมิด
GT2	ต่อคร่อมชุดแรงดัน	
GT3	ตัดแปลง/แก้ไขสาย Control ชุดกระแส หรือ จัดแฉะชุด CT แรงต่ำ	
GT4	ต่อคร่อมชุดกระแส	
GD1	เกิดออกไซด์หรือสายชำรุด	ชำรุด
GD2	ทรอปเอาร์ท์พีวส์คัทเอาร์ท์ บางเฟสตก หรือ LT ตก	
GD3	กำลังไฟฟ้าไม่สมดุลหรือกระแสเกิน	
GD4	CT ชำรุด	

บทที่ 6

บทสรุปและข้อเสนอแนะ

หลังจากที่ได้ทำการรวบรวมข้อมูล ศึกษาและวิเคราะห์โมเดลที่ใช้จำแนกในแต่ละเทคนิค แล้วนั้น ในบทนี้จะเป็นบทสรุปของงานวิจัยที่ได้ดำเนินการมาทั้งหมด ไม่ว่าจะเป็นการสอนหรือทดสอบ โมเดล จะกล่าวถึงปัญหาและอุปสรรคที่พบตลอดการทำงานวิจัย พร้อมทั้งข้อเสนอแนะและแนวทาง สำหรับการพัฒนา ต่อยอดในงานวิจัยนี้ต่อไป

6.1 ข้อเสนอสำหรับเทคนิควิเคราะห์ตามช่วงเวลา

การสกัดข้อมูลโดยพิจารณาตามช่วงเวลานั้นมีความสอดคล้องกับการคิดอัตราค่าไฟของ กฟภ. เช่น คิดค่าไฟตามช่วงเวลา (TOU) คิดค่าไฟแบ่งตามช่วงเวลาของวัน (TOD) เป็นต้น ซึ่งจากการ ทดลองข้อมูลจะถูกสกัดแยกช่วง Peak Off Peak และ Holiday จากนั้นใช้องค์ความรู้ของผู้เชี่ยวชาญ สกัดออกมาเป็น feature มีทั้งที่เป็นตัวเลข (Numerical) และไม่เป็นตัวเลข (Nominal) ผลจากการหาค่า Pearson Correlation ข้อมูลมีความสัมพันธ์ค่อนข้างต่ำ และเมื่อประเมินโดยใช้โมเดลของการเรียนรู้เชิง ลึก ผลลัพธ์ที่ได้มีค่าต่ำเช่นกัน สาเหตุอาจเป็นเพราะการกำหนดเงื่อนไขในการสกัด feature ยังไม่ถูกต้อง ช่วงเวลาที่แบ่งยังไม่ครอบคลุมแต่ละความผิดปกติ และข้อมูลมีความซับซ้อนในเชิงของ time series ดังนั้นวิธีวิเคราะห์ตามช่วงเวลาจึงไม่สามารถนำมาใช้เป็นโมเดลสำหรับจำแนกความผิดปกติได้

6.2 ข้อเสนอสำหรับการวิเคราะห์ใน Time domain และ Frequency domain

ด้วยในการทดลองจากเทคนิควิเคราะห์ตามช่วงเวลานั้นให้ประสิทธิภาพต่ำ Time domain และ frequency domain จึงถูกนำมาใช้เพื่อสกัดข้อมูลโดยพิจารณาจากค่า time series ของ แรงดันและกระแส เพราะเป็นตัวแปรหลักที่สะท้อนความผิดปกติเมื่อการชำรุดหรือละเมิด ในการทดลอง ประกอบด้วย 2 ส่วนหลักคือ ส่วนที่หนึ่ง แยกวิเคราะห์ใน Time domain และ Frequency domain ซึ่ง ในแต่ละโดเมนจะประกอบด้วยเทคนิคย่อย เช่น Time domain ประกอบด้วย วิธีทางสถิติ วิธีแยก องค์ประกอบของอนุกรมเวลา Auto-Correlation และวิธีแบบจำลองสัญญาณ ส่วน frequency domain ประกอบด้วย DFT และ PSD ส่วนที่สองการรวม feature ทั้ง Time domain และ Frequency domain ผลการทดลองพบว่าแต่ละเทคนิคให้จุดเด่นที่แตกต่างกัน วิธีทางสถิติ จะสกัดค่าได้ดีใน Window ที่มีการ

เปลี่ยนแปลงหลากหลาย แต่มีความละเอียดน้อย วิธีแยกองค์ประกอบของอนุกรมเวลา ค่า trend และ season ปรากฏความแตกต่างชัดเจนระหว่างปกติกับผิดปกติ แต่ยังไม่สามารถแยกได้ระหว่างซาร์ุดกับละเมิด Auto-Correlation ข้อมูลได้จากวิธีนี้ยังไม่ชัดเจนในรูปแบบของความผิดปกติ และวิธีแบบจำลองสัญญาณช่วยลดขนาดของข้อมูลที่ป้อนเข้าโมเดลได้ ค่าสัมประสิทธิ์ที่สกัดได้ในโมเดลบ่งบอกถึงค่าเดิมของ time series ได้ แต่มีข้อจำกัดช่วงของข้อมูลที่ส่งผลต่อเสถียรภาพของโมเดล DFT เป็นการแปลงให้อยู่ในรูปค่าจริงและค่าเชิงซ้อนของความถี่ โดยในการทดลองพิจารณาทั้งค่าขนาดและค่าเชิงซ้อน PSD จะนำค่าขนาดที่ได้มาคำนวณเป็นค่าความหนาแน่นของสเปกตรัม ทั้ง 2 วิธี พบว่าค่าที่ได้จากการแปลงมีค่าน้อยมาก และสำหรับการรวมกันของโดเมนเวลาและโดเมนความถี่ ค่า Pearson Correlation แสดงให้เห็นว่าส่วนใหญ่มีความสัมพันธ์กันแต่มีค่าน้อย ดังนั้นสำหรับเทคนิคการวิเคราะห์ทั้ง 2 โดเมนสามารถจำแนกความผิดปกติได้ทั้ง 3 รูปแบบ แต่ยังไม่ได้ประสิทธิภาพตามที่ต้องการ

6.3 ข้อสรุปสำหรับเทคนิคการแปลงให้อยู่ในรูป 2D Image

จากการทดลองที่ผ่านมาทั้งการวิเคราะห์ตามช่วงเวลาและการวิเคราะห์ในแต่ละโดเมน นั้นยังมีข้อจำกัดในการจำแนกระหว่างซาร์ุดกับละเมิดที่มีรูปแบบที่คล้ายกัน การสกัดโดยใช้เทคนิคการแปลงให้อยู่ในรูป 2D Image จึงถูกนำมาใช้ในการทดลอง ซึ่งประกอบด้วย 5 เทคนิค ได้แก่ CWT RP SG GSAF และ MTF แต่ละวิธีจะมีจุดเด่นที่ต่างกันขึ้นอยู่กับรูปร่างของสัญญาณ โดยหลังจากการแปลงอนุกรมเวลาให้เป็นรูปภาพแล้ว โมเดลการเรียนรู้เชิงลึก CNN ถูกนำมาใช้จำแนกรูปภาพแต่ละชนิด โดยการออกแบบและกำหนดค่าพารามิเตอร์โดยใช้ grid search และ hyperparameter tuning การทดลองเพื่อหาขนาด window และ size ที่เหมาะสม ผลลัพธ์ที่ได้จากการทดลองพบว่า การจำแนกโดยใช้รูปภาพให้ผลลัพธ์ที่ดีเมื่อเทียบกับสองเทคนิคที่ผ่านมา ดังนั้นการนำสัญญาณ time series มาแปลงให้อยู่ในรูปภาพ และใช้ deep learning (CNN) จำแนกให้ผลลัพธ์ที่ดี

6.4 ข้อสรุปสำหรับการจัดการข้อมูลที่ไม่สมดุล

ด้วยการนำข้อมูลที่ไม่สมดุลมาใช้สำหรับสอนและทดสอบโมเดล เมื่อนำโมเดลไปใช้งานจริงอาจเกิด bias ได้ ในงานวิจัยจึงได้ทำการศึกษาต่อระหว่างข้อมูลที่สมดุลกับไม่สมดุล และวิธีการสมดุลข้อมูลแบบต่างๆ ในการทดลองมีการเปรียบเทียบทั้ง 4 รูปแบบ ประกอบด้วย ข้อมูลไม่สมดุล ใช้โมเดลความผิดปกติเพื่อสร้างข้อมูล ใช้วิธี ASASYN และใช้การปรับแต่งภาพ ผลการทดลองแสดงให้เห็นว่าการ

ปรับข้อมูลให้สมดุลก่อนป้อนเข้าโมเดลเพื่อจำแนกนั้น มีช่วยส่วนเพิ่มประสิทธิภาพในการจำแนกของโมเดล และวิธีการสร้างรูปแบบความผิดปกติผ่านโมเดลให้ผลลัพธ์ที่ดีที่สุด ในขณะที่วิธีการปรับแต่งข้อมูลไม่เหมาะกับการนำมาใช้สำหรับรูปภาพที่ไม่มีความแตกต่างระหว่างพื้นหน้าและพื้นหลัง

6.5 ข้อเสนอการทดสอบโมเดลจากข้อมูลชุดอื่นและเหตุการณ์จริง

สำหรับการทดสอบข้อมูลพบว่าโมเดลสามารถใช้จำแนกความผิดปกติจากระบบ AMR monitoring ได้ ถึงแม้ว่าประสิทธิภาพโดยรวมจะได้เท่ากับ 85 % เพราะว่าการผิดพลาดที่เกิดขึ้นส่วนหนึ่งมาจากการทำนายผิดระหว่างชำระกับละเมิดซึ่งทั้งสองกรณีถ้าโมเดลทำนายถึงความผิดปกติดังกล่าวพนักงานต้องออกไปตรวจสอบเพื่อดำเนินการแก้ไขซึ่งเป็นกรณีที่ยอมรับได้ แต่กรณีละเมิดหรือชำระแล้วโมเดลทำนายว่าปกติ เป็นเหตุการณ์ที่ไม่ควรเกิดขึ้น ซึ่งจากการทดสอบจริงความผิดพลาดดังกล่าวอยู่ที่ประมาณ FPR= 5.5 % ดังนั้นเพื่อเป็นการป้องกันความผิดพลาดที่เกิดขึ้น อาจต้องมีการรวบรวมข้อมูลเพิ่มเติมในกรณีที่โมเดลทำนายผิดพลาดเพื่อ train โมเดลเพิ่ม

6.6 ข้อเสนอการใช้เทคนิคการจัดกลุ่มข้อมูล

เทคนิคการจัดกลุ่มถูกนำมาใช้โดยมีวัตถุประสงค์เพื่อ ต้องการแบ่งกลุ่มข้อมูลผู้ใช้ไฟที่มีอยู่เพื่อพิจารณาและวิเคราะห์รูปแบบ ต้องการเปรียบเทียบผลลัพธ์ระหว่างการจำแนกโดยไม่จัดกลุ่มกับการจัดกลุ่มก่อนจำแนก และต้องการจัดกลุ่มข้อมูลที่ผิดปกติแต่ละประเภทเพื่อเชื่อมโยงไปสู่สาเหตุของเหตุการณ์แต่ละความผิดปกติที่เกิดขึ้น โดยรวมแล้วเทคนิคดังกล่าวช่วยให้เห็นประเด็นของจุดเด่นและจุดด้อยของการจำแนกข้อมูล รูปแบบต่างๆที่ได้จากการจัดกลุ่มที่สะท้อนให้เห็นถึงความหลากหลายของผู้ใช้ไฟถึงแม้ว่าจะมีการกำหนดขอบเขตโดยใช้ขนาดของหม้อแปลงแล้วก็ตาม ที่สำคัญผลที่ได้จากการจัดกลุ่มตามสาเหตุยังมีข้อมูลน้อยซึ่งอาจไม่เพียงพอต่อการนำไปใช้จำแนกหรือสอนโมเดล

6.7 บทสรุปรวม

งานวิจัยนี้ นำเสนอโมเดลสำหรับการจำแนกความผิดปกติระหว่างมิเตอร์ชำระกับละเมิด โดยใช้ข้อมูลจากมิเตอร์ AMR ของ กฟภ. โดยในงานวิจัยมีการนำเทคนิควิเคราะห์ตามช่วงเวลา เทคนิคการวิเคราะห์ time series ใน time domain กับ frequency domain และการแปลง time series ไปเป็นรูปภาพ จากผลการทดลองพบว่า การแปลง time series เป็นรูปภาพ แล้วใช้ CNN ในการจำแนกให้

ประสิทธิภาพสูงทั้งพารามิเตอร์แรงดันและกระแส และจากผลการทดสอบกับข้อมูลจริงถึงแม้ว่าประสิทธิภาพจะลดลง แต่โดยส่วนใหญ่โมเดลสามารถจำแนกได้ถูกต้องทั้ง 3 class ซึ่งโมเดลที่ได้สามารถนำไปสร้างบนระบบ AMR monitoring เพื่อจำแนกความผิดปกติเบื้องต้นก่อนออกไปตรวจสอบหน้างานจริงได้ ผลที่ได้ช่วยลดเวลาในการตรวจสอบซ้ำ ลดการทำงานซ้ำซ้อน เพิ่มความสะดวกและรวดเร็วในการปฏิบัติงาน

6.8 ปัญหาและแนวทางแก้ไข

- ก. จำนวนข้อมูลที่ใช้ในการทดลอง มีส่วนสำคัญในการเรียนรู้ของโมเดล ซึ่งข้อมูลทั้งหมดของ AMR จะถูกรวบรวมไว้ที่ส่วนกลาง การขอข้อมูลและเข้าถึงข้อมูลใช้ระยะเวลานาน และมีข้อจำกัดเรื่องข้อมูลที่ไม่สามารถเปิดเผยได้
- ข. ความหลายหลายของรูปแบบความผิดปกติที่พบน้อยเกินไป เช่น กรณีละเมิดมีข้อมูลน้อย จำเป็นต้องมีการสังเคราะห์หรือจำลองรูปแบบเพื่อให้โมเดลเรียนรู้ได้หลายแบบ รวมถึงลักษณะความผิดปกติของประเภทของผู้ใช้ไฟแต่ละประเภท
- ค. การสอนและทดสอบโมเดลใช้ระยะเวลานาน ด้วยข้อจำกัดของสเปกคอมพิวเตอร์ และโมเดลที่สร้างขึ้นยังไม่ได้ถูกนำไปทดสอบกับมิเตอร์ประเภทอื่น เช่น มิเตอร์งานหมุน หรืออิเล็กทรอนิกส์ มิเตอร์

6.9 ข้อเสนอแนะและแนวทางการพัฒนาต่อไป

ในงานจำแนกความผิดปกติที่เกิดขึ้นไม่ว่าจะเกิดจากการชำรุดหรือละเมิด ยังคงใช้ข้อมูลในอดีตมาทำการสอนโมเดล ถึงแม้ว่าจะมีการนำไปโมเดลไปทดสอบกับข้อมูลจริงแล้วก็ตาม การใช้ข้อมูลแบบ online หรือ real-time เป็นสิ่งหนึ่งที่น่าสนใจที่ควรพัฒนาต่อ และด้วยความก้าวหน้าของเทคโนโลยีในปัจจุบัน มีระบบพลังงานทดแทน การซื้อขายพลังงานไฟผ่านระบบจำหน่ายของ กฟภ. ปัจจัยเหล่านี้ควรนำมาพิจารณาในการวิเคราะห์หน่วยสูญเสียที่ไม่ใช่ทางเทคนิคด้วย

บรรณานุกรม

- [1] A.A. Sallam, O.P. Malik, "Electric Distribution Systems," 1st ed., John Wiley & Sons: Hoboken, NJ, USA, pp. 17–18, 2011.
- [2] U.H. Bezerra, T.M. Soares, M.V. Nunes, M.E. Tostes, P.A. Vieira, R.C. de Oliveira, "Estimating Technical and Non-Technical Losses in Electrical Distribution Networks Using Power Measurement at the Substation and Customers," Natal, Rio Grande do Norte, Brazil, 23 May 2016.
- [3] การไฟฟ้าส่วนภูมิภาค, ผลการดำเนินงานตามแผนปฏิบัติการ: ไตรมาส 4, รายงานประจำปี 2564 หน้า 65-71 Provincial Electricity Authority, "Annual Report, Provincial Electricity Authority," Bangkok, 2018.
- [4] การไฟฟ้าส่วนภูมิภาค, ระบบสารสนเทศเพื่อการจัดการจากหน่วยการใช้ไฟ (U-CUBE), Available: <http://ucube2019.pea.co.th/ucube/>.
- [5] การไฟฟ้าส่วนภูมิภาค, Automatic Meter Reading: AMR monitoring load profile, Available: <https://www.amr.pea.co.th/AMRWEB/Index.aspx>.
- [6] M.S. Mustafa, M.W. Hamadneh, N.N. Alshammari, N.A. Sheikh, U.U. Jumani, T.A. Khalid, S.B.A. Khan, "Detection of Non-Technical Losses in Power Utilities: A Comprehensive Systematic Review," *Energies* 2020.
- [7] H.O. Henriques, A.P. Barbero, R.M. Ribeiro, M.Z. Fortes, W. Zanco, O.S. Xavier, R.M. Amorim, "Development of adapted ammeter for fraud detection in low-voltage installations," *Meas. J. Int. Meas. Confed.* pp.1–7, 2014.
- [8] A. Khoo, B. Cheng, Y. Using RFID for anti-theft in a Chinese electrical supply company: A cost-benefit analysis," In *Proceedings of the Wireless Telecommunications Symposium (WTS 2011)*, New York, NY, USA, pp.13–15, April 2011.
- [9] F. Depuru, S. Wang, L. Devabhaktuni, V. "A conceptual design using harmonics to reduce pilfering of electricity," In *Proceedings of the IEEE PES General Meeting (PES 2010)*, Providence, RI, USA, 25–29 July, pp. 1–7, 2010.

- [10] G. M. Messinis and N. D. Hatzargyriou, "Review of non-technical loss detection methods," *Electric Power Systems Research*, vol. 158, pp. 250–266, 2018.
- [11] M. M. Buzau, J. Tejedor-Aguilera, P. Cruz-Romero, and A. Gómez-Expósito, "Detection of Non-Technical Losses Using Smart Meter Data and Supervised Learning," *IEEE Transactions on Smart Grid*, vol. 10, no. 3, pp. 2661–2670, 2019.
- [12] S. C. Yip, C. K. Tan, W. N. Tan, M. T. Gan, and A. H. A. Bakar, "Energy theft and defective meters detection in AMI using linear regression," in *2017 IEEE International Conference on Environment and Electrical Engineering and 2017 IEEE Industrial and Commercial Power Systems Europe (EEEIC / I CPS Europe)*, pp. 1–6, June 2017.
- [13] A. A. Esmael, H.H Da-silva, T. Ji, and R. Da-silva, "Non-Technical Loss Detection in Power Grid Using Information Retrieval Approaches: A Comparative Study," *IEEE Trans. Smart Grid*, vol. 10, no. 3, pp. 40635-40648, March 2021.
- [14] J.-P. Eckmann, S. O. Kamphorst, and D. Ruelle, "Recurrence plots of dynamical systems," *Europhys. Lett.*, vol. 4, no. 9, pp. 973-977, Nov. 1987.
- [15] T. A. Lampert and S. E. M. O'Keefe, "A survey of spectrogram track detection algorithms," *Appl. Acoust.*, vol. 71, no. 2, pp. 87-100, Feb. 2010.
- [16] Z. Wang and T. Oates, "Imaging time-series to improve classification and imputation," in *Proc. 24th Int. Joint Conf. Artif. Intell. (IJCAI)*, Q. Yang and M. J. Wooldridge, Eds. Buenos Aires, Argentina: AAAI Press, 2015, pp. 3939-3945.
- [17] G. M. Messinis, N. D. Hatzargyriou, "Unsupervised Classification for Non-Technical Loss Detection," in *2018 Power Systems Computation Conference (PSCC)*, 2018.
- [18] M. M. Buzau, J. Tejedor-Aguilera, P. Cruz-Romero, and A. Gomez-Exposito, "Hybrid deep neural networks for detection of non-technical losses in electricity smart meters," *IEEE Transactions on Power Systems*, 2019.
- [19] Z. Zheng, Y. Yang, X. Niu, H.-N. Dai, and Y. Zhou, "Wide and deep convolutional neural networks for electricity-theft detection to secure smart grids," *IEEE Trans. Ind. Informat.*, vol. 14, no. 4, pp. 1606–1615, Apr. 2018.

- [20] M. N. Hasan, R. N. Toma, A.-A. Nahid, M. M. M. Islam, and J.-M. Kim, "Electricity theft detection in smart grid systems: A CNNLSTM based approach," *Energies*, vol. 12, no. 17, p. 3310, Aug. 2019.
- [21] A. b. Shah, W. M. Mesbah, A. T. Al-Awami, "An Algorithm for Detaching Technical Losses from Non-Technical Losses in Distribution Systems," *IET Generation, Transmission & Distribution*, vol. 13, no. 8, pp. 1315-1323, 2019.
- [22] P. Fuangfung and P. Raphisak, "Fault Electricity Metering Detection using A Rule-based Model Tuned by Particle Swarm Optimization", *IEEE PES Asia-Pacific Power and Energy Engineering Conference (APPEEC)*, Macao, China, 2019.
- [23] L. -E. Pomme, R. Bourqui, R. Giot and D. Auber, "Relative Confusion Matrix: Efficient Comparison of Decision Models," *2022 26th International Conference Information Visualisation (IV)*, Vienna, Austria, pp. 98-103, 2022.
- [24] การไฟฟ้าส่วนภูมิภาค, องค์ความรู้เรื่อง การสูญเสียพลังงานไฟฟ้า (Loss), องค์ความรู้ One Point Knowledge, รหัส OPK 59120015,22 มี.ค.2559 หน้า 1-22.
- [25] การไฟฟ้าส่วนภูมิภาค, งานวิจัยเพื่อแก้ปัญหาในระบบจำหน่ายแรงต่ำเหนือดินแบบบูรณาการ, RSD-02, ธันวาคม 2553.
- [26] คณะทำงานโครงการพัฒนาการอ่านหน่วยด้วยระบบอัตโนมัติ การไฟฟ้าส่วนภูมิภาค, คู่มือการปฏิบัติงาน โครงการพัฒนาการอ่านหน่วยด้วยระบบอัตโนมัติ ระยะที่ 2 , ปี 2555.
- [27] สไลด์บทที่ 3 มหาวิทยาลัยเชียงใหม่, การแปลงเวฟเล็ตและวิธีการสกัดลักษณะเด่นของสัญญาณ, Available: https://archive.lib.cmu.ac.th/full/T/2550/enel1050stt_ch3.pdf
- [28] Techsauce, ทำความรู้จัก AI, Machine learning, Deep learning, Available: <https://techsauce.co/tech-and-biz/ai-machine-learning-deep-learning-differences>.
- [29] ชิตพงษ์ กิตตินราดล. (2563). Neural Network Algorithm, Available: <https://guopai.github.io/ml-blog14.html>
- [30] Machine Learning Mastery, When to Use MLP, CNN, and RNN Neural Networks, Available: <https://machinelearningmastery.com/when-to-use-mlp-cnn-and-rnn-neural-networks/>.
- [31] Super AI Engineer, Evolution of Image Classification, Available: <https://medium.com/super-ai-engineer/>

- [32] F. Shehzad, N. Javaid, A. Almogren, A. Ahmed, S. M. Gulfam and A. Radwan, "A Robust Hybrid Deep Learning Model for Detection of Non-Technical Losses to Secure Smart Grids," in IEEE Access, vol. 9, pp. 128663-128678, 2021.
- [33] X. Xia, Y. Xiao, W. Liang and J. Cui, "Detection Methods in Smart Meters for Electricity Thefts: A Survey," in Proceedings of the IEEE, vol. 110, no. 2, pp. 273-319, Feb. 2022, doi: 10.1109/JPROC.2021.3139754.
- [34] Machine Learning Mastery, How to Decompose Time Series Data into Trend and Seasonality, Available: <https://machinelearningmastery.com/decompose-time-series-data-trend-seasonality/>.
- [35] Investopedia, Autocorrelation, Available: <https://www.investopedia.com/terms/a/autocorrelation.asp/>.
- [36] L. Kirichenko, T. Radivilova, "Time Series Classification Based on Visualization of Recurrence Plots", 5th International Conference on Computational Linguistics and Intelligent Systems, April 22–23, 2021.
- [37] M. H. Hayes, Statistical digital signal processing and modeling, John Wiley & Sons, Inc., New York, NY, 1996.
- [38] M.G. Chuwa, F.Wang, "A review of non-technical loss attack models and detection methods in the smart grid," Electr. Power Syst. Res., vol. 199, Oct. 2021, pp. 0378-7796.
- [39] Haibo He, Yang Bai, E. A. Garcia and Shutao Li, "ADASYN: Adaptive synthetic sampling approach for imbalanced learning," 2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence), Hong Kong, 2008, pp. 1322-1328.
- [40] C. Shorten, T.M. Khoshgoftaar, A survey on Image Data Augmentation for Deep Learning. J Big Data 6 (2019) 60, Available: <https://doi.org/10.1186/s40537-019-0197-0>.
- [41] กองมาตรฐานระบบไฟฟ้า การไฟฟ้าส่วนภูมิภาค, แบบมาตรฐานการติดตั้งมิเตอร์ 3เฟส 4สาย ประกอบซีทีแรงต่ำ, 2560

ภาคผนวก

ภาคผนวก ก
การตีพิมพ์เผยแพร่ผลงาน

การตีพิมพ์เผยแพร่ผลงาน

ได้รับการยอมรับและเผยแพร่ 3 รายการ

การประชุมวิชาการระดับชาติ

1. Supakan Janthong, Kusumal Chalermyanont and Rakkrit Duangsoithong, "Anomaly Pattern Analytics Based on Visualization for Non-Technical Losses in Automatic Meter Reading", PEACON & Innovation 2022: PEA Digital Utility for Sustainable Electricity Utility in VUCA World, Bangkok Thailand, pp. 67-72. 2022.

การประชุมวิชาการระดับนานาชาติ

2. S. Janthong, K. Chalermyanont and R. Duangsoithong, "Comparison of Feature Extraction Methods for Classifying Energy Theft and Defective Meters in Automatic Meter Reading," 2023 International Electrical Engineering Congress (iEECON), Krabi, Thailand, 2023, pp. 49-53, doi: 10.1109/iEECON56657.2023.10127065.

วารสารระดับนานาชาติ

3. S. Janthong, K. Chalermyanont and R. Duangsoithong, "Unbalanced Data Handling Techniques for Classifying Energy Theft and Defective Meters in the Provincial Electricity Authority of Thailand," in IEEE Access, vol. 11, pp. 46522-46540, 2023, doi: 10.1109/ACCESS.2023.3274543.

อยู่ระหว่างการตรวจทาน 2 รายการ

วารสารระดับนานาชาติ

4. Supakan Janthong, Kusumal Chalermyanont and Rakkrit Duangsoithong, "Imaging Time-Series to Classify Energy Theft and Defective Meters in Automatic Meter Reading Using Convolutional Neural Networks", Sustainable Energy, Grids and Networks journals, 2023, (Under review status: May 1, 2023).

วารสารระดับนานาชาติ

5. Supakan Janthong, Kusumal Chalermyanont and Rakkrit Duangsoithong, “Feature Engineering of Risk Group and Electricity Theft by Applying Domain Knowledge for Classification using Supervised Learning”, ECTI-CIT (Under review status: May 20, 2023).



Anomaly Pattern Analytics Based on Visualization for Non Technical Losses In Automatic Meter Reading

Mr. Supakan Janthong¹, Asst.Prof.Dr.Kusumal Chalermyanont², Asst.Prof.Dr.Rakkrit Duangsoithong³

¹ Meter Division, Ranot District, Provincial Electricity Authority, 6410120056@psu.ac.th

²Department of Electrical Engineering, Prince of Songkla University, Kusumal.c@psu.ac.th

³Department of Electrical Engineering, Prince of Songkla University, Rakkrit.d@psu.ac.th

Abstract

Power theft and defective meter are the two factors of Non-Technical Losses (NTL) that affect the revenue. This paper proposes an analysis and comparison of the abnormalities patterns caused from the Automatic Meter Reading (AMR). Load profile are visualized in three domains: time domain, frequency domain and wavelet domain. Three load profile patterns are compared including normal, defectives and theft. The voltage and current of customers are evaluated by using maximum, minimum, and average values. According to the results, wavelet domain can clearly classify the different characteristics of three patterns compared to the time domain and frequency domain.

KEY WORDS: Non-Technical Losses (NTL), Energy Theft, Defective Meter, Visualization, Automatic meter reading (AMR)

1. INTRODUCTION

Loss incurred in the distribution system divide into Technical Losses (TL) and Non-Technical Losses

(NTL). Technical Losses (TL) are naturally occurring due to energy dissipated in the electrical components and equipment used for transmission line. Non-Technical Losses (NTL) occur due to unidentified causes, misallocated or inaccurate meter reading, for example: power thefts, fraud energy consumption, defective meter, error in meter reading and billing problems.

Considering the physical of NTL, there are two main factors. The first factor is energy theft, such as bypass the current coil, tamper, forged lead seal and other theft. The second factor is defective meter including broken meter or defective measuring device for example: error in meter, oxide wire, Current Transformer (CT) or Voltage Transformers (VT) failure.

In many cases, load profile of normal use, energy theft and defective meter have a similar patterns, It is difficult to classify the causes of abnormalities. In this paper, the differences of three patterns are analyzed by visualization and statistics. After that, all patterns of customers are converted to each domain and compared. As the result of the comparison will help the meter inspectors able to distinguish

preliminary abnormalities from load profile before going out to real site inspection.

2. LITERATURE REVIEW

In 2016, Chandel et al. [1] presented theft issues from electromechanical meters and electronic energy meters, the simulation was created in the lab which the pattern will be differ according to the generated data. The traditional methods are used to find the features of smart meters for minimizing electricity theft [2]. In both studies, The data presented to determine the cause of the abnormal pattern from the experiment.

In 2019, Fuangfung et al. [3] proposed using the AMR data with rule-based in case of voltage unbalance and asymmetric power. Besides, Zheng et al. [4] proposed electricity consumption from smart grids applied to wide and deep convolutional neural networks. Both studies were able to detect energy theft and fault metering.

In 2021, Esmael et al. [5] presented covering of time series to images with four different visual technique, while [6] time series transformed to graph data with graph convolution and characteristic pool. Both methods extract data using transforms and do not show comparisons between abnormalities.

Previously, the studies have been specific to finding a model for using to classify abnormalities [5],[6], while [3],[4] compared normal and abnormal without distinguishing three types (normal, defectives and theft).

3. THEORY AND METHOD USED

The analysis of the AMR data consists of 3 domains, it will be applied using the theory and method of well-known property. There are 4 parts to be proposed in this chapter.

3.1 Automatic Meter Reading (AMR)

Automatic Meter Reading (AMR) is an electronic meters to collect energy consumption and communicated information for monitoring and billing customers. The AMR system consists of 3 parts including metering system , wireless communication system and data management system [7].




Figure 1. The structure of the AMR system

3.2 Time Series Components

Time series components is a series as a combination of level, trend, seasonality and noise according to Equation (1). These components are defined as follows:

- Level: The average value in the series.
- Trend: Decreasing or increasing value in the series.
- Seasonality: The repeating cycle in the series.
- Noise: The random variation in the series.

$$y(t) = \text{Level} + \text{Trend} + \text{Seasonality} + \text{Noise} \quad (1)$$

3.3 Discrete Fourier Transform (DFT) and Power Spectral Density (PSD)

Discrete Fourier Transform (DFT) converts a finite sequence signal of time to a signal in the frequency domain. A complex-valued is function of frequency, bandwidth, and shape of the spectrum of a signal. according to the Equation (2).

$$X[k] = \sum_{n=0}^{N-1} x(n)e^{-j2\pi kn/N} \quad k = 0, \dots, N - 1 \quad (2)$$

$x(n)$ = the sequence signal, N = number of windows

Power Spectral Density (PSD) describes the distribution of power into frequency components composing in signal. One of the PSD properties is the area under curve equal to the average power of that signal. according to the Equation (3).

$$P_x(e^{j\omega}) = \sum_{k=-\infty}^{\infty} r_x(k)e^{-jk\omega} \quad (3)$$

$r_x(k)$ = auto-correlation sequence

3.4 Wavelet Transform

Wavelet Transformation is method used to analyze variance of time, the structure of a signal system consists of several specific signals combined into one signal. Function of particular signal is a small waveform called Mother Wavelet, show in Equations (4). Wavelet ($\psi_{a,b}$) is formed by scaling (scale:a) and shift section (translation: b) according to time (t).

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) \quad (4)$$

4. PROPOSED FRAMEWORK

Figure 2. shows overview of the proposed framework. Data set (load profile) is compiled to correct and normalize in the data preparation before being visualized in 3 domains. In the last section, load profile is compared the results of each patterns.

5. EXPERIMENTAL SETUP

In the experiment, the data configuration is the three-watt method (3P4W) by recording data every 15 minutes include date, time, current, and voltage. Load profile used consists of 97 customers (normal=40, defectives=30, theft=27) with 3 classes by on-field inspections. The patterns is assessed on

data from the last 10 years, from January 2011 to December 2021.

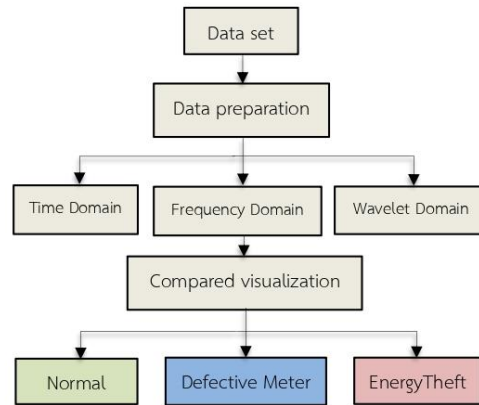


Figure 2. shows overview of the proposed framework.

5.1 Data set

The patterns of load profiles is selected from the abnormal range and divided window into 1-week intervals (window = 672 values). Voltage, current were analyzed in 3 class consist of normal condition, defective meter and energy theft.

5.2 Data preparation

AMR data often contain erroneous data and missing data, however in this case, data is corrected by data cleansing and interpolation according to Equation (5). After dealing missing values, the MAX-MIN scaling is used to normalize the data following Equation (6).

$$t(x_i) = \begin{cases} x_i & ; x_i \notin \text{NaN} \\ \frac{x_{i-1} + x_{i+1}}{2} & ; x_i \in \text{NaN} \\ 0 & ; x_i, x_{i-1}, x_{i+1} \in \text{NaN} \end{cases} \quad (5)$$

where x_i is stands value, if x_i is a null as NaN.

$$X(x_i) = \frac{X_i - \min(X)}{\max(X) - \min(X)} \quad (6)$$

where $X(x_i)$ is normalized data, $\max(x)$ is the maximum and $\min(x)$ is the minimum.

6. EXPERIMENTAL RESULT AND DISCUSSION

This section, the experiment will show data selection and the experimental results with data visualization including 5 parts to be proposed in this chapter.

6.1 Load Profile (Voltage and Current)




Figure 3. Voltage load profiles of raw data with 3 class




Figure 4. Current load profiles of raw data with 3 class

After the data has been normalized, individual customers are shown in the same graph. Figure 3,4 have statistically compared: maximum, minimum and average of characteristics to represent the customers of each domain analysis. The results show $V_{max} = 0.96$ or 232.53 V, $I_{max} = 0.92$ or 4.66 A, $V_{min} = I_{min} = 0$, $V_{avg} = 0.46$ or 225.64 V, $I_{avg} = 0.49$ or 2.23 A.

6.2 Time Series Components




Figure 5. Current trend with 3 class

Figure 6. Voltage seasonality with 3 class

Figure 5. show an example of the trend patterns for current, and the seasonality of the voltage as shown in the Figure 6. The trend of normal patterns are clearly different, but defectives and theft are similar patterns, while the seasonality have shown the difference in all 3 patterns.

6.3 Discrete Fourier Transform (DFT) and Power Spectral Density (PSD)

In the Figure 7, 8 show the DFT of current and PSD of voltage in the frequency domain. Both DFT and PSD will appear of frequency component that window is considered. The amplitude and power spectral of first order frequencies is clearly different with three patterns depend on the change and fluctuating frequency of signal.




Figure 7. DFT Current with 3 class




Figure 8. PSD Voltage with 3 class

6.4 Wavelet Transform

Continuous Wavelet Transform (CWT) is used to convert from time series to images. The coefficients are arranged to scalogram form with color map of the type jet of 128 colors. Table 1. shows the different intensity, tone, and shape of the image components by comparing images with all 3 patterns appear the difference in each class.

Table 1. Converting time series to images.

Time series	Image (CWT)	Time series	Image (CWT)
Normal voltage		Normal current	
Defective voltage		Defective current	
Theft voltage		Theft current	

6.5 Case Study: AMR Monitoring System

An example of 1 customer (7-eleven :TR 100 kVA) was found a low-voltage CT failure by checking through the AMR monitoring system as Figure 9. This case the B-phase current (green line) was abnormal caused by defective wires from real site inspection.




Figure 9. CT failure occurred (phase b)




Figure 10. Comparison between CT failure and average



Figure 11. Show DFT and PSD of CT failure case




Figure 12. Converting time series CT failure to images

Figure 10. show comparison of abnormal phase B currents with the mean currents of defectives, the trend of patterns change in similar characteristics. In Figure 11. Both DFT and PSD clearly appear the primary frequencies and CWT can show the signal component according to time variance as Figure 12.

Discussion separates for each anomaly. The normal patterns are characterized by periodic changes and consistent. Defective patterns, voltages are degraded from standard voltage while the current

it will change suddenly. Sometimes, current reduced to zero when using less load, at the same time, using increased load make the swing up. Theft patterns, both voltage and current are a downward trend in similar patterns but still change to ripple or swing according to the load using.

Time domain, trend and seasonality will change and convey the nature of time series. The amplitude of first order frequency for DFT is different each patterns corresponding power spectral of PSD in frequency domain. The wavelet domain or CWT as scalograms show a change in the RGB color format which is clearly visible image.

7. CONCLUSION

This paper has proposed anomaly pattern analysis based on visualization for NTL using load profiles of AMR. The methods used consist of trend, seasonality, DFT, PSD and CWT. The experimental results have shown the advantages of different visualization in each domain. Time domain: trend and seasonality can be clearly seen for the difference between normal and abnormal. Frequency domain, both the DFT and PSD considering from frequency show a difference both amplitude and power spectral. Wavelet domain, CWT converted to images using scalograms and RGB color format will appear depend on load characteristics and show different patterns. All three domains proposed above, by any means the methods can choose to tackle for monitoring of AMR. Our future research will focus on classified patterns by using machine learning and deep learning to improve efficiency and find the exact fit model for the data.

ACKNOWLEDGMENT

This paper supported by Provincial Electricity Authority (PEA) for providing load profiles of customers from AMR database, and Master's Degree

Scholarship in Electrical Engineering, Prince of Songkla University, Thailand.

Reference

- [1] P.Chandel, T.Thakur, B.A. Sawle and R.Sharma, "Power theft: Major cause of non technical losses in Indian distribution sector," Power India International Conference(PILCON), vol.7,no.1,pp.216–226,Jan. 2016.
- [2] P. Chandel, T. Thakur and B.A. Sawle, "Energy meter tampering: Major cause of non-technical losses in indian distribution sector," International Conference on Electrical Power and Energy Systems (ICEPES), vol. 4, no. 1, pp. 368–371, Dec. 2016.
- [3] P.Fuangfung and P. Raphisak, "Fault electricity metering detection using A rule-based model tuned by particle swarm optimization," Asia-Pacific Power and Energy Engineering Conference (APPEEC), Macao, China, 2019.
- [4] Z. Zheng, Y. Yang, X. Niu, H.-N. Dai and Y. Zhou, "Wide and deep convolutional neural networks for electricity-theft detection to secure smart grids," IEEE Trans., vol. 14, no.4, pp.1606-1615, Apr.2018.
- [5] A. A. Esmael, H.H. Da-silva, T. Ji and R. Da-silva, "Non-technical loss detection in power grid using information retrieval approaches: a comparative study," IEEE Trans. Smart Grid, vol. 10, no. 3, pp. 40635-40648, March 2021.
- [6] Z. Hu,Tao Wu, Y. Zhang, J.Li and L.Jiang, "Time series anomaly detection based on graph convolutional networks," International Conference on Applied Machine Learning (ICAML), vol.10, no.2, pp.138-145, Oct. 2020.
- [7] W. Ladarat and S. Naetiladdanon, "PEA Automatic Meter Reading system: Progress and lessons learned," International Conference on Electrical Engineering Computer, Telecommunications and Information Technology (ECTI-CON), Hua-Hin, Thailand, 2015.



The 2023 International Electrical Engineering Congress

March 8-10, 2023, Krabi, THAILAND



Session: Digital Signal Processing

PO2610

Comparison of Feature Extraction Methods for Classifying Energy Theft and Defective Meters in Automatic Meter Reading

Supakan Janthong, Kusumal Chalermyanont and Rakkrit Duangsoithong*

Abstract— Loss is an important factor for any organization that operates in the distribution of electric power. Non-Technical Loss (NTL) is one of the challenging losses. Most distributors attempt to find a way to reduce the NTL loss. In some cases, the anomaly patterns are complex, similar, and difficult to classify. This paper proposes a feature extraction method using signal modeling methods obtained from voltage and current in a 3-phase system for abnormalities in the Automatic Meter Reading (AMR) of the Provincial Electricity Authority (PEA). Focusing on the main causes of NTL include energy theft and defective meters using supervised learning for classification. All-pole modeling has been applied to extract the feature as a coefficient. The voltage and current load profiles are divided into 1-week intervals (672 values) and fed into the signal modeling to be extracted as 4 coefficients. The methods can reduce the number of features before input into the model, which makes the model process faster and improves performance. The experimental results show that extraction using Prony's method and k-Nearest Neighbors (kNN) model significantly outperforms other methods.

Keywords— *Non-Technical Losses (NTL), Automatic Meter Reading (AMR), Feature Extraction, Supervised Learning, Energy theft, Defective meters*

Department of Electrical Engineering, Prince of Songkla University Hatyai, Songkhla, Thailand.

* Corresponding author.

Email: supakan.jan@pea.co.th

Comparison of Feature Extraction Methods for Classifying Energy Theft and Defective Meters in Automatic Meter Reading

Supakan Janthong
Department of Electrical Engineering
Prince of Songkla University
Hatyai, Songkhla, Thailand
Supakan.jan@pea.co.th

Kusumal Chalermyanont
Department of Electrical Engineering
Prince of Songkla University
Hatyai, Songkhla, Thailand
Kusumal.c@psu.ac.th

Rakkrit Duangsoithong
Department of Electrical Engineering
Prince of Songkla University
Hatyai, Songkhla, Thailand
Rakkrit.d@psu.ac.th

Abstract— Loss is an important factor for any organization that operates in the distribution of electric power. Non-Technical Loss (NTL) is one of the challenging losses. Most distributors attempt to find a way to reduce the NTL loss. In some cases, the anomaly patterns are complex, similar, and difficult to classify. This paper proposes a feature extraction method using signal modeling methods obtained from voltage and current in a 3-phase system for abnormalities in the Automatic Meter Reading (AMR) of the Provincial Electricity Authority (PEA). Focusing on the main causes of NTL include energy theft and defective meters using supervised learning for classification. All-pole modeling has been applied to extract the feature as a coefficient. The voltage and current load profiles are divided into 1-week intervals (672 values) and fed into the signal modeling to be extracted as 4 coefficients. The methods can reduce the number of features before input into the model, which makes the model process faster and improves performance. The experimental results show that extraction using Prony's method and k-Nearest Neighbors (kNN) model significantly outperforms other methods.

Keywords— Non-Technical Losses (NTL), Automatic Meter Reading (AMR), Feature Extraction, Supervised Learning, Energy theft, Defective meters.

I. INTRODUCTION

The power distribution system has a significant role in the development of any country, the inevitable factor is loss unit occurred. Loss is classified into Technical Losses (TL) and Non-Technical Losses (NTL) [1]. TL was naturally occurring depend on the network characteristics, NTL is an abnormality that related meter reading, electricity thieves, error from the measuring device, broken meter, or faulty infrastructure.

Automatic Meter Reading (AMR) is one of the meters that PEA has installed for businesses, industrials, and commercial customers. The main objectives of PEA for AMR installation are to decrease time for meter reading, to monitor and to increase efficiency of billing [2]. AMR system composes of 3 main parts: metering system including digital energy meter and modem, wireless communication system by recording parameters every 15 minutes, and data management system.

Since installation, several types of abnormalities are found, whether it is the defective nature of the meters or infringement of customers. Currently, the admin monitors abnormalities from the information with AMR monitoring system. The monitoring can indicate anomalies, but it cannot distinguish characteristics that caused by energy theft or defective meters.

Therefore, in this paper, the data recorded by the AMR meter will be divided into 3 classes by on-field inspections.

The data is extracted using signal modeling to compare errors, after that, the supervised learning five models are used to classify and evaluated the performance of models using accuracy.

II. LITERATURE REVIEW

In this literature, feature extraction methods are discussed for NTL detection. The various data types can be categorized either consumer level and area level at each level comprise time series and static [3]. Buzau et al. proposed detecting NTL using information from smart meters. The features extracted are daily measurements, alarms, electrical magnitudes, and auxiliary databases. For the model to produce good results, many features are required [4]. Rakhi et al. proposed a model by applying machine learning and feature engineering; no data extraction was used, but feature engineering was used to restore the outliers [5]. Support Vector Machine (SVM), Decision Tree (DT), and Random Forest (RF) are used as classifiers, where RF gives the best accuracy of 98%. Toma et al. proposed the Support Vector Machine (SVM) for detecting NTL and the Principal Component Analysis (PCA) used to reduce the number of dimensions. As a result, the learning rate is reduced, and accuracy is increased by 90% [6]. Similarly, Lepolesa et al. proposed the extraction of time series data from smart meters as the form of time domains and frequency domains. Both domains combined and reduced feature dimensions using principal component analysis (PCA). To detect differences between the two classes, use feed-forward DNN (accuracy 91.8%) [7]. Aziz et al. extract data using Empirical Mode Decomposition (EMD) for breaking downs a signal staying in the time domain. For analyzing signals, which are typically non-stationary and non-linear in nature. K-nearest neighbors (KNN) was used to classify with a 91.0% accuracy [8]. However, the above-mentioned approach has the following limitations:

- 1) The types of customers that focus on residential customers.
- 2) Some studies enter the data without extracting or based on artificial feature extraction.
- 3) It is difficult to gather information if multiple variables are needed.

Compared to existing studies, differences from previous work by:

- 1) The voltage and current of the AMR are used to extract the features because both values are fundamental parameters that can indicate the abnormality.

- 2) Industrial and business customers who installed the 3P4W system were selected for classification.
- 3) Emphasis is the classification of abnormality: normal condition, defective meter, and energy theft while [4],[5],[6],[7],[8] focus on NTL detection.
- 4) Applying the signal modeling methods to extract the features into coefficients, this method can reduce number of features including interpretations of correlated variable.

III. THEORY AND METHOD USED

The motivation of selecting this method for studies is signal modeling [10], Figure 1. show the system having p poles and q zeros. Application of signal modeling is used the area of signal prediction and data compression. In this paper, signal modeling is applied to using classification, consist of five methods following sub-sections.




Fig. 1. Modeling a signal input $v(n)$ to approximate $\hat{x}(n)$.

A. Pade approximation

Pade approximant is one of the methods to approximate of a specific point by a rational function. The advantages can produce an exact fit to find the coefficients $a_p(k)$ and $b_q(k)$ that the model over the interval $[0, p+q]$. Pade method calculated from signal $x(n)$ and the summation of the convolution as follow to the equation (1).

$$x(n) + \sum_{k=1}^p a_p(k)x(n-k) = \begin{cases} b_q(n) & ; n = 0, 1, \dots, q \\ 0 & ; n = q+1, \dots, q+p \end{cases} \quad (1)$$

Where: signal $x(n)$ is a real or complex sequence for $n=0, 1, \dots, p+q$

B. Prony's method

The limitation of the Pade method is no guarantee to be stable and accuracy for the data outside the interval. Prony's method provide better accuracy for the data outside the interval $[0, p+q]$. as follow to the equations (2)-(4).

$$\sum_{l=1}^p a_p(l) r_x(k, l) = -r_x(k, 0) \quad ; k = 1, 2, \dots, p \quad (2)$$

$$r_x(k, l) = \sum_{n=q+1}^{\infty} x(n-l) x^*(n-k) \quad ; k, l \geq 0 \quad (3)$$

$$b_q(n) = x(n) + \sum_{k=1}^p a_p(k) x(n-k) \quad ; n = 0, 1, \dots, q \quad (4)$$

Where: $r_x(k, l)$ is a conjugate symmetric function and $b_q(n)$ is numerator of equation for $n=0, 1, \dots, q$

C. Shanks' Method

In Prony's method, those method focuses on the model to be exact over the interval $[0, q]$, while it does not consider the data for $n > q$. In this method, the denomination coefficients

$a_p(k)$ are fixed and the minimum error respect to the numerator coefficients $b_q(k)$ for $n=0, 1, \dots, q$ as follow:

$$\sum_{l=0}^q b_q(l) r_g(k-l) = r_{xg}(k) \quad ; k = 0, \dots, q \quad (5)$$

$$r_g(k-l) = \sum_{n=0}^{\infty} g(n-l) g^*(n-k) \quad (6)$$

$$r_{xg}(k) = \sum_{n=0}^{\infty} x(n) g^*(n-k) \quad (7)$$

Where: r_g is autocorrelation of $g(n)$ and $r_{xg}(k)$ is cross-correlation sequence between $x(n)$ and $g(n)$

In case of a finite data record, 2 popular methods are commonly used including autocorrelation method and covariance method.

D. Autocorrelation Method

The data outside the interval $[0, N]$ is set to zero by applying a data window of $x(n)$, when $x(n)$ is unknown outside of the interval and Prony's method is used to find a model for the window signal as follow:

$$\sum_{l=1}^p a_p(l) r_x(k-l) = -r_x(k) \quad ; k = 1, 2, \dots, p \quad (8)$$

$$r_x(k) = \sum_{n=k}^N x(n) x^*(n-k) \quad ; k \geq 0 \quad (9)$$

E. Covariance Method

This method does not make any assumptions about the data outside the interval $[0, N]$, but the values of $x(n)$ is necessary to know the interval at sequences $n, n-1, \dots, n-p$ as follow:

$$\sum_{l=1}^p a_p(l) r_x(k, l) = -r_x(k, 0) \quad ; k = 1, 2, \dots, p \quad (10)$$

$$r_x(k, l) = \sum_{n=p}^N x(n-l) x^*(n-k) \quad ; k, l \geq 0 \quad (11)$$

IV. PROPOSED FRAMEWORK

AMR data is categorized by type of customers, data pre-processing is used for data cleaning and missing values from data collection. An important part of this paper is data extraction that use to extract data and comparing each method. After that, the model of supervised learning is used for classification and evaluation. The flow of the overall framework shows in Fig 2.

V. EXPERIMENTAL SETUP

This section explains the data preparation for feature extraction from AMR data. The proposed model compile on the Scikit-learn library, Python 3.10.4 and run on the machine system configuration are Intel Core i7-12700H CPU 2.30

GHZ, 16 GB of RAM. These procedures are described in the following sub-sections.




Fig. 2. The overview of the proposed framework.

A. Data collection

The dataset is collected from PEA, Thailand. The data used to select 2 parameters are voltage and current from 60 customers. The customer groups are divided into 3 classes comprising normal electricity, defective meter, and energy theft by on-field inspections. The period covered over the last 10 years from January 2011 to December 2021.

B. Data Pre-processing

The AMR installation is divided 2 phases [2], phase II has been improved for recording the parameters. As a result, the measured data being erroneous values and missing value. To reduce this problem, data preprocessing is applied with the equation (12).

$$V, I(x_i) = \begin{cases} 0 ; x_i, x_{i-1}, x_{i+1} \in \text{NaN} \\ \frac{(x_{i-1} + x_{i+1})}{2} ; x_i \in \text{NaN} \\ x_i ; x_i \notin \text{NaN} \end{cases} \quad (12)$$

V = voltage, I = current, x_i = data collected every 15 minutes.

Another factor is the models used to classify having sensitive to the data. Data normalization to ensure the dataset is prepared for interpretation and can be parsed by supervised learning algorithms. Max-min scaling is used according to the equation (13).

$$V, I(x_i) = \frac{X_i - \min(X)}{\max(X) - \min(X)} \quad (13)$$

Where: V, I(x_i) is voltage or current of feature values, min(X) is minimum values and max(X) is maximum values.

C. Feature Extraction

The data for feature extraction comprise voltage 3 phase: Va, Vb, Vc and current 3 phases: Ia, Ib, Ic both data are scoped to 4 weeks for normal-anomalous periods (2,688 values). The patterns considered including normal (N), defectives (D), and theft (T) to separate into 1 week (672 values) of interval due

to the distinctive appearance. An example of 1 customer in case of normal consumption show the details as Table I.

TABLE I. EXAMPLE BEFORE-AFTER OF FEATURE EXTRACTION

Patterns	Before		Feature extraction	After			
	Voltage/Current			Voltage/Current			
Normal (N)	$M_N(1)$: Defective (D) : Theft (T)	$w_1(1)$	$N1a_{(0)}$ $N1a_{(1)}$ $N1a_{(2)}$ $N1b_{(0)}$	$N1a_{(0)}$	$N1a_{(1)}$	$N1a_{(2)}$	$N1b_{(0)}$
		$w_1(2)$		$N2a_{(0)}$	$N2a_{(1)}$	$N2a_{(2)}$	$N2b_{(0)}$
		$w_1(3)$		$N3a_{(0)}$	$N3a_{(1)}$	$N3a_{(2)}$	$N3b_{(0)}$
		$w_1(4)$		$N4a_{(0)}$	$N4a_{(1)}$	$N4a_{(2)}$	$N4b_{(0)}$

Before extracting, there are 3 patterns and the monthly M_N of n customer represents of 4 weeks, 1 customer divides to 4 periods $w_n(1) - w_n(4)$. In the data extraction process, 5 methods are used with a second-order all-pole model ($p=2$ and $q=0$), because the model is not complicated and the system is still stable when using data in the window. After data extraction, model will create coefficients obtain $a_{(0)}$, $a_{(1)}$, $a_{(2)}$ and $b_{(0)}$ for 1 window, it can be reduced data from 672 values to 4 coefficients, before import to the model.

- All-pole modeling

All-pole models (autoregressive) have been applied in these studies to provide a sufficiently accurate representation for many different types of anomaly patterns. An all-pole model form shows in the equation (14).

$$H(z) = \frac{B_q(z)}{A_p(z)} = \frac{b(0)}{1 + \sum_{k=1}^p a_p(k)z^{-k}} \quad (14)$$

Considering from Pade equation (1) with using $q=0$, the coefficients $a_p(k)$ become matrix form as follow:

$$\begin{bmatrix} x(0) & 0 & \dots & 0 \\ x(1) & x(0) & \dots & 0 \\ \vdots & \vdots & \ddots & \vdots \\ x(p-1) & x(p-2) & \dots & x(0) \end{bmatrix} \begin{bmatrix} a_p(1) \\ a_p(2) \\ \vdots \\ a_p(p) \end{bmatrix} = - \begin{bmatrix} x(1) \\ x(2) \\ \vdots \\ x(p) \end{bmatrix} \quad (15)$$

And from Prony equation (2) replacing $r_x(k)$ with $r_x(k-l)$ will get equation (16).

$$\sum_{l=1}^p a_p(l) r_x(k-l) = -r_x(k) \quad ; k = 1, \dots, p \quad (16)$$

when $q=0$, $r_x(k) = x(n)x^*(n-k)$, from (15) and (16) can be written in conjugate symmetry matrix form as follow:

$$\begin{bmatrix} r_x(0) & r_x^*(1) & r_x^*(2) & \dots & r_x^*(p-1) \\ r_x(1) & r_x(0) & r_x^*(1) & \dots & r_x^*(p-2) \\ r_x(2) & r_x(1) & r_x(0) & \dots & r_x^*(p-3) \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ r_x(p-1) & r_x(p-2) & r_x(p-3) & \dots & r_x(0) \end{bmatrix} \begin{bmatrix} a_p(1) \\ a_p(2) \\ a_p(3) \\ \vdots \\ a_p(p) \end{bmatrix} = - \begin{bmatrix} r_x(1) \\ r_x(2) \\ q r_x(3) \\ \vdots \\ r_x(p) \end{bmatrix} \quad (17)$$

The minimum error (ε_p) modeling for the all-pole model calculates as follow:

$$\varepsilon_p = r_x(0) + \sum_{k=1}^p a_p(k) r_x^*(k) \quad (18)$$

VI. EXPERIMENTAL RESULTS AND DISCUSSION

Table II. shows the minimum error comparison of each method using an all-pole model. Consider the average values of both current and voltage, the Covariance method gave the minimal error followed by Prony method and Autocorrelation respectively.

TABLE II. THE MINIMUM ERROR FOR THE ALL-POLE MODEL

Prm.	Phase	Pade	Prony	Shank	Autocorrelation	Covariance
Volt	A	62.2289	1.0584	4.1277	1.9991	0.3590
	B	56.3503	1.0349	2.2051	2.0492	0.4239
	C	42.6933	0.9364	1.2810	1.9236	0.3971
Amps	A	68.4215	0.9939	2.2459	1.3403	0.2743
	B	97.7940	1.0984	2.4319	1.6787	0.2703
	C	82.9018	0.9001	3.3441	1.7922	0.2334
All average error		68.3983	1.0037	2.6059	1.7972	0.3263

The Covariance method calculated a sum of the squares error $e(n)$ that the values of $x(n)$ be known at times $n, n-1, \dots, n-p$. While Prony method focus on $x(n)$ only specified for $n = 0, 1, \dots, N$ and the autocorrelation method is set to zero for the values of $x(n)$ outside window of interval $[0, N]$. Therefore, error occurred is evaluated from values of $x(n)$ that show the different result.

A. Classification

All coefficients are trained and tested on 5 different classifiers. Neural Network (NN), Support Vector Machines (SVM), k-Nearest Neighbors (kNN), Decision Tree (DT), and Naive Bayes (NB) are used to classify abnormal patterns. The normalized data split to train (70%) and test (30%) with 3 classes. Grid search is the process used to find the optimal values of the hyperparameters show in Table III.

TABLE III. THE HYPERPARAMETERS USING GRID SEARCH

Models	Hyperparameters	Optimizing values
NN	C	0.001, 0.01, 0.1
	R	L1 norm, L2 norm
SVM	C	0.001, 0.01, 0.1
	kemel	linear, rbf, sigmoid
KNN	K	3, 5, 7
	p	1, 2, 3
DT	criterion	gini, entropylog_loss
	max_features	auto, sqrt, log2
NB	P	default
	V	1e-09

B. Evaluation

The performance metrics are used in these studies to evaluate all classification models. The performance of the model is measured accuracy considering all classes, according to the equation (19).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (19)$$

Where: True Positive (TP), True Negative (TN), False Positive (FP), False Negative (FN)

TABLE IV. COMPARE THE ACCURACY (%) OF THE VOLTAGES

Method/Models	NN	SVM	KNN	DT	NB
Pade	66.66	59.72	55.55	76.38	62.50
Prony	80.69	76.38	96.38	90.82	83.21
Shank	77.08	80.55	91.66	92.44	79.16
Autocorrelation	74.58	68.05	83.33	88.88	69.44
Covariance	78.05	77.77	90.28	87.22	80.55

TABLE V. COMPARE THE ACCURACY (%) OF THE CURRENTS

Method/Models	NN	SVM	KNN	DT	NB
Pade	82.36	84.72	84.44	83.22	88.69
Prony	93.85	94.88	97.61	94.64	93.05
Shank	86.25	90.03	94.22	91.45	90.55
Autocorrelation	92.84	91.66	96.41	92.08	92.83
Covariance	92.32	88.88	91.02	90.22	90.04

The extracted coefficients from each method are defined as feature for concatenation all 3 phases, including 12 features with samples extracted from each window is 240 samples. The coefficients enter the model and the hyperparameters are adjusted according to the Table III. The evaluation of model divided two parts: voltage and current. The results show in Table IV. and Table V. Both voltage and current have the same best accuracy are obtained using Prony's method and kNN model with neighbors ($k=3$) and power parameter ($p = 2$), meaning the Euclidean distance.

From the experimental results, Pade method has the least accuracy and high error, because many data outside $[0, p+q]$, the estimated data is inconsistent with the original data. Shanks' method considered $n>q$ but all pole model is set the numerator $b_q(k) = b_q(0)$ as a result is high error values. The autocorrelation method forces $x(n) = 0$ for $n<0$ and $n>N$ if $x(n)$ in nonzero outside, sometimes the model will cause more errors. Covariance method give good results in minimum error because it does not apply a window to the data. Nevertheless, both models appropriate for the finite data record. Prony's method provide the best accuracy for the data outside the interval, the minimum error value is small, and the advantage is ensuring that the model will stable when using the all-pole modeling.

C. Comparison of the experiment with other studies

Principal component analysis (PCA) is one of the most popular techniques used to analyze large datasets and reduce the dimensionality of the data. PCA was used to reduce the number of variables into a smaller set to compare with the proposed method. In this study, the original data that is 60 dimensional into 2 dimensions. Which is after dimensionality reduction, there will be no particular meaning for the principal component. The experimental results are shown in the Table VI. When comparing time domain, frequency domain, combined domains, and PCA, the proposed method outperforms other features.

However, the amount of data in this study is minimal. The energy consumption (EC) of SGCC datasets [10], OEDI datasets [11], and ICER datasets [12] were used to evaluate the performance of the proposed method. The three sources consist of two classes, normality and theft of energy consumption that divided the window into 672 values. Then

use the Prony method for data extraction which each source is divided to train (70%) and test (30%). The results are shown in Table VII. A large amount of data leads to a drop in performance but it still has good accuracy.

TABLE VI. COMPARE THE SAME DATA WITH OTHER EXTRACTION

Features used	KNN (%Accuracy)	
	Volts (3Ph.)	Amps (3Ph.)
Time domain	56.77	57.66
Freq. domain	58.38	61.69
Time+Freq.	68.38	72.58
PCA Raw data	84.96	80.12
PCA Time+Freq.	79.98	75.56
This study (Prony)	96.38	97.61

TABLE VII. COMPARE OTHER DATA TO THIS TECHNIQUE.

Ref.	Datasets	Type of data	Number of customers	Prony+KNN (%Accuracy)
[10]	SGCC	EC	40,320	85.79
[11]	OEDI	EC	33,600	89.99
[12]	ICER	EC	25,536	90.01
This study	AMR, PEA	Volts	60	96.38
		Amps	60	97.61

TABLE VIII. COMPARISON WITH EXISTING STUDIES

Ref./year.	Extracted methods	Classified methods	Classes.	Acc. (%)
[4]/2019	Zscore, LOF Euclidean, Manhattan,	XGBoost	Normal vs Fraud	91.00
[5]/2021	-	RF	Normal vs Abnormal	98.00
[6]/2019	PCA	SVM	Normal vs Theft	90.00
[7]/2022	Time domain Freq. domain PCA	DNN	Faith vs Unfaith	91.80
[8]/2020	EMD	KNN	Normal vs Theft	91.00
This study	Prony	KNN	Normal, Defective, Theft	97.61

Table VIII. presents comparisons to existing studies. The highlight of this studies is the classification of three classes, the Prony method reduces the size of the data, and gave good results compared to other studies.

VII. CONCLUSION AND FUTURE WORK

This paper compares Pade, Prony, Shank, Autocorrelation, Covariance methods for feature extraction with minimum error, and using NN, SVM, kNN, DT, NB to classify abnormalities by comparing performance models (accuracy).

According to the results, Prony's method is most suitable for extracting data, although this method has more error values than the covariance method, it is a still suitable for

limited data records, in addition to the results obtained from the classification give the best results when used with kNN. Compare the experimental results with 3 cases: the same data but different features, other data with this method, and other existing studies. The results show that the model can be extracted and classified well, although large data cases result in performance degradation. Prony's method is a technique that helps extracting to reduce the number of features, reduce computational complexity, has high accuracy, and still provide excellent performance.

The model can be applied to the monitoring system of the AMR to identify the primary abnormality, before going out to inspect on-field. This method improves work efficiency and increasing the accuracy of the monitoring system.

ACKNOWLEDGMENT

This paper supported by Provincial Electricity Authority for providing load profile of customers from database AMR data center, and master's degree Scholarship in Electrical Engineering, Prince of Songkla University, Thailand.

REFERENCES

- [1] International Conference on Electricity Distribution, "Reduction of technical and non-technical losses in distribution networks," 2017.
- [2] W. Ladarat and S. Naetiladdanon, "PEA Automatic Meter Reading system: Progress and lessons learned," 12th ECTI-CON, Thailand, pp. 1-5, 2015.
- [3] G. M. Messinis and N. D. Hatzigiorgianni, "Review of non-technical loss detection methods," *Electr. Power Syst. Res.*, vol. 158, pp. 250-266, May 2018.
- [4] M. M. Buzau, J. Tejedor-Aguilera, P. Cruz-Romero, and A. Gomez-Exposito, "Detection of non-technical losses using smart meter data and supervised learning," *IEEE Trans. Smart Grid*, vol. 10, no. 3, pp. 2661-2670, May 2019.
- [5] R. Yadav, Y. Kumar, "Detection of non-technical losses in electric distribution network by applying machine learning and feature engineering", *Journal European des Systems Automatizes* Vol. 54, No. 3, pp. 487-493, June 2021,
- [6] R.N.Toma, M. N.Hasan, A.Al.Nahid, B.Li, "Electricity theft detection to reduce non-technical loss using support vector machine in smart grid", *International Conference on Advances in Science, Engineering and Robotics Technology (ICASERT)*, 2019.
- [7] L. J. Lepolesa, S. Achari and L. Cheng, "Electricity Theft Detection in Smart Grids Based on Deep Neural Network," in *IEEE Access*, vol. 10, pp. 39638-39655, 2022.
- [8] S. Aziz, S. Z. H. Naqvi, M. U. Khan, and T. Aslam, "Electricity theft detection using empirical mode decomposition and k-nearest neighbors," in *2020 International Conference on Emerging Trends in Smart Technologies (ICETST)*. IEEE, pp. 1-5, 2020.
- [9] M. H. Hayes, *Statistical digital signal processing and modeling*, John Wiley & Sons, Inc., New York, NY, 1996
- [10] State Grid Corporation of China: *New Energy Development Report 2020*, <http://www.sgcc.com.cn/>, 2020.
- [11] Z. salah, M. Alaeddine, M. Qaisar, S. Krichen, A. Haija, Qasem, "Theft detection in smart grid environment", *Mendeley Data*, 2022.
- [12] G. Martin, *Electricity smart metering customer behaviour trials (obt findings report, technical report, ICER 2011*.


 RESEARCH ARTICLE

Unbalanced Data Handling Techniques for Classifying Energy Theft and Defective Meters in the Provincial Electricity Authority of Thailand

SUPAKAN JANTHONG^{1,2}, KUSUMAL CHALERMYANONT¹,
AND RAKKRIT DUANGSOITHONG¹

¹Department of Electrical Engineering, Faculty of Engineering, Prince of Songkla University, Songkhla 90110, Thailand

²Meter Department, Provincial Electricity Authority, Bangkok 10900, Thailand

Corresponding author: Rakkrit Duangsoithong (rakkrit.d@psu.ac.th)

This work was supported in part by the Meter Development Division Area 3 (Southern) Yala Province Provincial Electricity Authority (PEA), Thailand; and in part by the Department of Electrical Engineering, Faculty of Engineering, Prince of Songkla University (PSU), under the PEA-PSU Program.

ABSTRACT Energy theft and defective meters not only lead to non-technical losses (NTLs) that are extremely detrimental to energy distributors and power infrastructure, but NTLs are also a major cause of damages to electricity and massive losses of revenue each year. Automatic meter reading (AMR) is a system used by the Provincial Electricity Authority (PEA) of Thailand for NTLs detection that works in conjunction with physical inspection. At present, using only AMR is unable to classify and identify the types of abnormalities that occur. In addition, another important issue that has been rarely studied and should not be neglected is the balancing of data. Because this issue has a negative impact on minorities, learners misclassify and leads to incorrect predictions. This paper proposes unbalanced data techniques for classifying energy theft, defective and normal customers based on AMR monitoring of PEA. In order to handle the multiclass imbalance problems, three methods were evaluated and compared: anomaly models (AM), adaptive synthetic sampling (ADASYN), and image data augmentation (IA). The data were extracted from time series into an image using a recurrence plot (RP) and classified as abnormal patterns of imaging time series using six deep learning models: LeNet5, AlexNet, VGGNet19, DenseNet121, ResNet50, and InceptionV3. The experimental results demonstrate that data generation techniques using anomaly models and DenseNet121 for classifying provided the best results compared to other techniques, and data extraction using images yields better results than time series. Moreover, compared to balanced and unbalanced data, classification evaluation using AUC-ROC and F1-score are the most appropriate evaluation methods, and importantly, balancing the data before classification improved the model performance.

INDEX TERMS Non-technical losses, automatic meter reading, unbalanced data, energy theft, defective meters, provincial electricity authority, deep learning.

I. INTRODUCTION

A. BACKGROUND

Loss is one of the inherent factors in the electricity distribution system that cannot be eliminated. In the transmission of electric power from the power station to the consumer, some of the electricity is lost. Loss incurred in the distribution

system is calculated as the difference between the energy delivered into the network and the measured energy consumed. Provincial Electricity Authority (PEA) as one of the electricity distributors has a main mission to provide electricity in 74 provinces in Thailand. PEA has given priority to the reduction of the loss unit either technical losses (TL) or non-technical losses (NTLs) [1]. TL occurs directly when current flows due to heat in the resistance conductors, connection points in the transmission line, an unbalance load,

The associate editor coordinating the review of this manuscript and approving it for publication was Hongli Dong.




FIGURE 1. Overview of AMR system.

abnormal operating conditions or switching on-off electrical equipment in the distribution system [2]. NTLs are the losses incurred due to metering faults, metering inaccuracies, frauds, thefts, billing problems, energy measurement errors, and other causes [3]. According to the PEA's loss report [1], NTLs have increased in recent years, indicating a more complicated, hard to find cause, and seen as a challenging problem.

B. AUTOMATIC METER READING: AMR

Automatic Meter Reading (AMR) is the technology that can collect data, show status, and process bills for consumption automatically, which covers water, gas, or energy meters. This technology is applied differently to customers and utilities in different countries [4]. In Thailand, PEA started investing in a project to develop automatic energy readings in 2007 [5]. The primary goals of using AMR are to provide major electricity customers with TOU rates. The implemented AMR function consists of three main components: the metering system (digital energy meter and modem unit), the wireless communication system (GPRS and GSM), and the data management system (monitoring and storing in a database) [6], as shown in Figure 1. The advantages of this system can benefit both the power grid and customers. AMR can detect to notify staff of power outages so they can diagnose billing issues and troubleshoot based on near real-time consumption. In addition, customers can view real-time data coupled with the analysis via a web application to better control their power consumption.

C. PROBLEM STATEMENT

The problem of unbalanced data might be inevitable. Naturally, each group may have different amounts of data in which more normal than abnormal features are found. For anomaly classification tasks, supervised learning models are preferred. That means there must be a label to teach the model. When models learn from unbalanced data and are applied to real-world applications, inaccurate results and prediction errors

may occur. In multi-class problems with samples of data from more than two groups, that occurs when one class refers to the small group and contains significantly fewer samples than the other classes. The small part or majority group can be both positive and negative. However, considering the data analyzed in the field of electricity theft detection (ETD), it was found that: normal data is the most available because it is an everyday event; followed by defects, which can occur from a variety of factors such as environment, duration of use, weather conditions; and thieves with minimal data, which are incidents of deliberate human action. For example, if training process exists has class imbalance data, the majority group will influence the increase in the prior probability that learners will over-classify and misclassify minorities more frequently than the other groups. Therefore, it is important to understand the data and class balance before entering the model.

II. LITERATURE REVIEW

In the real world, many applications are affected by data imbalances. According to the area of ETD research [3], class imbalance affects the classification and detection of abnormalities which increases learning difficulty and bias to most data. In extreme cases, minorities may be ignored altogether. Johnson et al. propose three methods for dealing with class imbalance using machine learning techniques [7]: 1) data-level techniques that reduce imbalanced data with sampling methods, 2) algorithm-level methods that handle class imbalance with weight or cost schema including the underlying learner, and 3) hybrid systems that combine both methods.

Most researchers have focused on the problem of class imbalance of binary classification [3]. In practice, many tasks were found in more than two groups (a multi-class problem). Ensemble algorithms based on AdaBoost.NC were used to investigate the multiclass and imbalance problems [8]. There are two types of imbalanced data: multi-small part and multi-majority. Each category was evaluated using the performance model and correlation analysis. Both types show that performance decreases as the number of class imbalances increase. For using random oversampling (ROS) does not affect classification, but it causes overfitting for the small classes. Different from the results of X.W. Liang et al. because they show that oversampling produces good results in the experiment for classification using LR-SMOTE [9]. The new data samples interpolate near the center with sample from six datasets with different imbalances. A random forest (RF) and support vector machine (SVM) algorithm were used to classify and compare the data after balancing, resulting in G-means of 0.98, F-measure of 0.96, and AUC of 0.97, which yield high results compared to the unbalanced data. The reason for its high efficiency is that SMOTE can reduce the occurrence of sample boundaries and sample random copies. But be careful with the use of ROS as it may lead to overfitting. However, ROS is still used to improve the small class (binary class is to increase fraud data) together

with random undersampling (RUS) to decrease the majority class (binary class is to reduce no-fraud data) in the problem of data imbalance [10]. Different proportions are used in each dataset, ranging from 0 (no oversampling) to 25 (max oversampling) with Linear SVM, RBF, MLP, NN, and SVM which were carried out to classify and compare results using eight different performance measures. Overall, higher oversampling proportions produce better predictions.

S.V. Oprea et al. proposed fraud detection in conventional meters using large datasets. Considering the input dataset is highly unbalanced, the majority are normal 135,493 consumers, while 7,566 consumers are a small part considered thieves. The data was handled with feature engineering and fed into various machine learning models to compare the results. Note that the studies have a point of view on unbalanced data and uncorrelated datasets that is challenging [11]. P. Glauner et al. subsampled 17 different data sets and used SVM, Fuzzy, and Boolean classifiers for 100K customers. The efficiency obtained is still low and did not explain the principle of solving the class of imbalanced data [12]. Generative adversarial networks (GAN) are a technique used in NTL detection and anomaly detection, such as using GANs for augmenting and balancing data before training the model [13]. Typically, GAN is an unsupervised learning that consists of a generator and a discriminator network. Both networks continue to compete until the generator generates enough similarity to the actual data of the discriminator. F. Shehzad et al. proposed a method to deal with unbalanced time series datasets using a least square generative adversarial network (TLSGAN), which is weighted to reduce the vanishing gradient and loss functions to generate fake samples. However, TLSGAN requires multiple forward passes through the generator network, which can be computationally expensive [14]. Similarly, M. Asif et al. proposed a bidirectional Wasserstein generative adversarial network (Bi-WGAN) for augmenting theft class samples that uses a Wasserstein distance metric to train the generator and discriminator networks. However, Bi-WGAN is sensitive to hyperparameters such as batch size or learning rate, which can significantly impact small class theft samples [15].

The most popular open data source used in the ETD is the SGCC from China [13], [14], [15], [16], [17], [18], [19], which was very unbalanced EC data. It is a challenge for many researchers to find solutions. Y. Huang et al. proposed an autoencoder (AE) to be applied as a stacked-sparse denoising autoencoder (SSDAE) focused on feature extraction and data reconstruction capabilities. The data balance was randomly modified by the anomalous samples representing the reduction in the energy bill in the case of stolen electricity [16]. An anomaly was generated similar to [17]. They synthesize the theft attack to balance the datasets with the actual consumption of the customer. Both [16] and [17] are anomalous additions that were randomly fed through the generated equation. Nevertheless, the above equation is suitable for single-phase EC-type input, in contrast to our proposed research. Because we focus on voltage and

current abnormalities in 3-phase 4-wire systems. SMOTE is an effective and popular technology used to solve high-class imbalance [18], [19], and [20]. While [21] proposed focal loss as another method for data balancing in order to focus the cross-entropy loss and handle hard misclassified samples. It is possible to lower the loss value for normal electricity consumers which have a higher probability. While the samples of anomalous electricity consumers have a low actual probability. From the studies mentioned above, considering the perspectives from various aspects. However, there are still some limitations to be found:

- 1) In NTLs detection, there are only two groups for detecting abnormalities that is between no-fraud and fraud, which use the electric energy (kWh) data from a smart meter. But for the multi-class problems in NTLs field or the analysis of other variables such as current and voltage, these have not been considered.
- 2) Some studies did not take into account the effects of unbalanced data. Despite the fact that the amount of data for two groups is very different. This will affect the accuracy of classification as well as the bias toward the majority group.
- 3) The data imbalance problem is solved differently, for example, by regrouping data, adding a few groups, or decreasing many groups. Sometimes the details obtained may not be comprehensive or truly appropriate, possibly causing the actual use may result in errors.
- 4) Handling unbalanced data by synthesis or modeling is found in most residential households with single-phase meters. These methods may not be applicable or practical to three-phase meters for major customers.

From the limitations mentioned above. We proposed a data balancing technique that has been evaluated and is suitable for classifying patterns of anomalies (defects and theft) for AMR monitoring systems to improve classification accuracy. The main contributions of this paper are summarized as follows:

- 1) Because of the significant sample imbalance, which is likely to cause primary bias and affect error in the classification model, we proposed a framework for optimization and comparison of three techniques for handling unbalanced data (multi-class).
- 2) For a 3-phase 4-wire system, the energy consumption (EC) can illustrate the change in effect, but it is difficult to identify the type of abnormality that occurs. To eliminate this concern, the voltage, and current parameters, which are components of real power (kW), are analyzed in depth to improve the accuracy of the classification.
- 3) Time series data are correlated in the time dimension, which causes volatility when the load or interval changes according to time of use. To solve this problem, we applied the recurrence plot (RP) for imaging, which is a technique that explicitly analyzes recurring behavior in natural processes to extract features for model training and classification.
- 4) In order to find a network that effectively classifies and a suitable method for our dataset. The various

architectures for types of image classifier networks from deep learning were tested to compare model optimization. Importantly, we evaluate networks using performance metrics for several perspectives.

The rest of this paper is organized as follows: Section III. highlights of the proposed methodology consist of data pre-processing, handling unbalanced data, feature extraction, classification, and a detailed discussion of results. Section IV. presents the differences in performance with other tasks: compare other imbalanced techniques, use data from open sources, compare the state-of-the-art benchmarks, compare with previous works, and discuss limitations. Finally, Section V summarizes the conclusion of this study.

III. PROPOSED METHODOLOGY

In this section, a framework of unbalanced data handling techniques and data classification procedures is described. Historical datasets for 3P4W low-voltage and current values are obtained from PEA's AMR data center. An overview of the proposed methods is shown in Figure 2. There are four primary parts:

- 1) **Data pre-processing:** The data preparation process consists of four main parts: exploring data, cleaning data, correcting data, and normalization. It is critical to have complete and accurate data so that the model can learn and classify efficiently.
- 2) **Data balancing:** The class imbalance solution consists of three main parts: anomaly models, adaptive synthetic sampling and image data augmentation. (Highlights of the current study)
- 3) **Feature extraction:** Considered a 2D image, the method of data extraction by converting time series data into images was chosen. One suitable and effective technique is the recurrence plot.
- 4) **Image classification:** Several types of deep learning are used to classify anomalies for comparison and evaluation with performance metrics.

A. HISTORICAL DATASETS

The AMR dataset was compiled from the PEA over a 10-year period, beginning in January 2011 and ending in December 2021. The AMR meter used in the study is a 3-phase 4-wire system rated at 380 volts and records data resolution every 15 minutes. Parameters are used to consider only the voltage and current from the data recorded separately for the three phases (A, B, and C). We defined the scope of major customers in electricity distribution, which include residential, business, hotel or lodging businesses, and factory or industrial customers. Importantly, we focused on the customer's installation of transformers sized 150–250 KVA. We consider the data to be within the scope of 1 week and scale up the data size from every 15 minutes to every 1 hour ($672/4 = 168$ values per event) while retaining its clear characteristics. The data group (labels) is determined by referring to the actual on-site inspection results that have been recorded in the AMR system. Normal customers are assigned a value of 0,

TABLE 1. Description of the dataset.

Explanation	Voltage			Current			
	Phase	A	B	C	A	B	C
Number of normal customers		1,159	1,146	1,463	823	805	801
Number of defective customers		246	116	168	419	424	420
Number of theft customers		66	71	85	212	252	215
The total number of customers		1,471	1,603	1,716	1,454	1,481	1,436
Timeline		01/01/2011 to 31/12/2021					

defective meters are assigned a value of 1, and energy theft is assigned a value of 2.

The detailed information shown in Table 1 shows that the amount of data in each phase and each class is not equal as a result of the data retrieved from AMR systems over a 10-year period, specific to low-voltage type customers and the difference in the number of events that occurred. All obtained data are filtered for normal, defective, and theft phase-by-phase to classify the data using documented on-site inspection results. For the analysis, both the voltage and current variables for each phase of the three phases (A, B, and C) are considered. The reason why each phase needs to be taken into account is because in some cases the fault only occurs in some phases and does not happen in all three phases. For example, in the case of a theft, the customer tampered with the meter, causing the A and B phase voltages to drop abnormally and the C phase voltage to remain normal. In this case, only the voltage value is distorted, while the three-phase current value is still measured normally. Therefore, phase A and B voltages are classified as a voltage theft group, and phase C voltage is in the normal voltage group. and all three sets will be classified in the normal current group for all three-phase current values. In another case, for example, it was found that the CT was damaged in all 3 phases and that the voltage control cable was broken in all 3 phases as well, in case both the current and voltage were completely distorted. The data is classified into defective current and voltage groups. Therefore, the number of records used in this study is not counted as the number of customers but considering the number of cases. Because in some cases there may be abnormal events that can occur repeatedly.

B. DATA PRE-PROCESSING

Data preparation is a very important step. If the prepared data is ineffective, it may result in misinterpretation. Therefore, the data should be interpreted in order to adjust the data to be accurate and complete before using it. Data pre-processing is divided into four steps as follows:

1) EXPLORING DATA

Understanding the information to be studied before analyzing it is important. In this research, the data used consisted of two variables: voltage and current values. The datasets exported

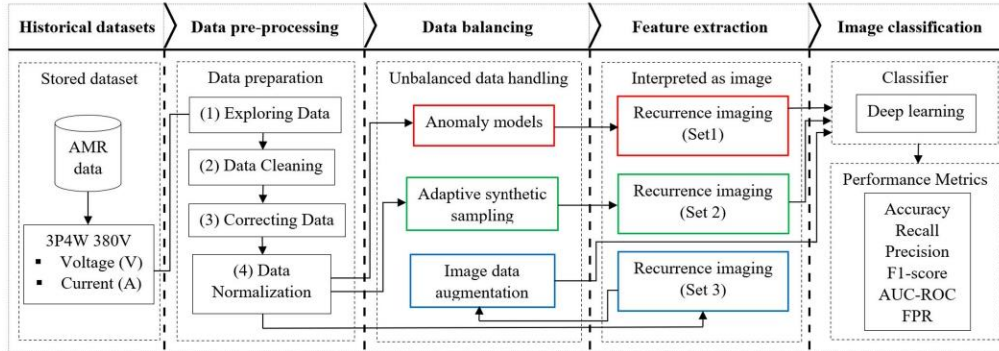


FIGURE 2. Framework of handling unbalanced data and a classification.




FIGURE 3. A comparison of the defective and theft patterns of three-phase voltages and currents.

will be in tabular form, and visualization was used to visualize the overall appearance that occurred. Figures 3. (a) and (b) depict the thefts that caused the voltage drops in phases A and B to be reduced to zero while the defective control wires found in phases A and C, respectively. In the two figures below, Figures 3. (c)-(d), we show the thefts for the current of phase B and the defective CT of phase B, respectively. For each event, the anomaly patterns observed in some phases and three phases were different. The study of various patterns of abnormalities that occur will be an important part of building an anomaly model.

For three-phase systems (three-watt method) that are installed in commercial and industrial customers. The electricity charge is calculated from the summing of the active power of the three phases, which is given as equations (1-4).

$$P_{(t)} = V_{a(t)}I_{a(t)} \cos \theta_a + V_{b(t)}I_{b(t)} \cos \theta_b + V_{c(t)}I_{c(t)} \cos \theta_c \quad (1)$$

where: $V_{(t)}$ is voltage measured at the input terminals, $I_{(t)}$ is current measured at the secretary side using a current

transformer (CT), $\cos \theta$ is the power factor of phase angle between current and voltage.

$$E_{(t)} = P_{a(t)} + P_{b(t)} + P_{c(t)} \quad (2)$$

$$E_{(dt)} = (P_{a(t)} + P_{b(t)} + P_{c(t)}) \cdot dt \quad (3)$$

$$E_{total} = \sum_{t=0}^T E_{(dt)} \quad (4)$$

where: $P_{a(t)}$, $P_{b(t)}$, $P_{c(t)}$ are the active power for three-phase, $E_{(t)}$ is the energy measured by AMR meter in each interval dt , and E_{total} is the total billed energy in a period. In the case of a balanced three-phase meter, the active power is approximately the same on all three-phase $P_{a(t)} \approx P_{b(t)} \approx P_{c(t)}$ depending on voltage, current and power factor. However, in the case of defective meters or electricity theft, the three-phase is unbalanced due to abnormal amplitude and angle.

2) DATA CLEANING

The data cleaning step is an important first step in data preprocessing. Preliminary must check for errors that occur with data such as incorrect data, duplicate data, and missing values. Incomplete data can be corrected by substituting or removing invalid data [22]. In this study, we manipulate data using equation (5).

$$F(x_{t,i}) = \begin{cases} \frac{x_{t,i-1} + x_{t,i+1}}{2}, & x_{t,i} \in NaN \\ 0, & x_{t,i-1} \text{ or } x_{t,i} \text{ or } x_{t,i+1}, \in NaN \\ x_{t,i}, & x_{t,i} \notin NaN \end{cases} \quad (5)$$

where: $x_{t,i}$ is defined as voltage or current for each class customer i at time interval t

3) CORRECTING DATA

In some instances, AMR meters are deactivated and installed for new customers. The recorded data contains erroneous values and outliers. Such anomalies are dealt with by the three-sigma rule of thumb [22] as follows equation (6), which is a rule based on the normal distribution principle.

$$F(x_{t,i}) = \begin{cases} \text{avg}(X_{t,i}) + 2 \cdot \text{std}(X_{t,i}), & \text{if } X_{t,i} > x_{t,i} \\ x_{t,i} & \text{else} \end{cases} \quad (6)$$

where: $X_{t,i}$ is computed by a vector of $x_{t,i}$ in a window for time interval.

4) DATA NORMALIZATION

The AMR meter type 3P4W is based on the three-element measurement principle. The low-side current and line to neutral voltage are measured. Transformers installed for customers have different sizes, resulting in different-rated current transformers installed. Min-max scaling [22] is used to normalize the data range according to the following equation:

$$Z(x_{t,i}) = \frac{x_{t,i} - \min(x_{t,i})}{\max(x_{t,i}) - \min(x_{t,i})} \quad (7)$$

where: $\min(x_{t,i})$ and $\max(x_{t,i})$ represent minimum and the maximum value of $x_{t,i}$, respectively.

Based on the above data pre-processing, the overall steps are shown in Algorithm 1.

Algorithm 1 Data Preprocessing Steps

Input:	$x_{t,i}$ is voltage or current of time series in a window and real dataset
Variables:	$X_{t,i}$
Result:	$x_{t,i}^n$ (normalized)

```

1  For  $i = 1$  to all do
2    Fill missing data:
3    if  $x_{t,i} == NaN \ \&\& \ x_{t,i-1} \parallel x_{t,i+1} \neq NaN$ 
4    | then  $x_{t,i} = (x_{t,i-1} + x_{t,i+1})/2$ 
5    end
6    if  $x_{t,i} == NaN \ \&\& \ x_{t,i-1} \parallel x_{t,i+1} == NaN$ 
7    | then  $x_{t,i} = 0$ 
8    end
9    Handling outliers
10   if  $x_{t,i} > \text{avg}(X_{t,i}) + 2 \cdot \text{std}(X_{t,i})$ 
11   | then  $x_{t,i} = \text{avg}(X_{t,i}) + 2 \cdot \text{std}(X_{t,i})$ 
12   else
13   |  $x_{t,i} = x_{t,i}$ 
14   end
15   Min-max scaling
16   |  $x_{t,i}^n = (x_{t,i} - \min(x_{t,i})) / (\max(x_{t,i}) - \min(x_{t,i}))$ 
17   end

```

C. DATA BALANCING

The class imbalance problem is one of the critical problems in data science that needs to be handled before entering the data




FIGURE 4. The input-output model structure for the generated data.




FIGURE 5. Example of normal data with voltage and current.

into a model for learning. Considering the historical datasets of AMR, normal customers are many available, while defective meters and energy theft rarely exist.

This section presents three methods for solving imbalanced datasets that create data to balance in different ways, consisting of generating new data using a model, data synthesis, and image adjustments. Each topic is described in the sub-sections as follows:

1) ANOMALY MODEL (AM)

Considering the abnormal patterns found with AMR meters, the consumption pattern of major customers often varies due to several factors. For example, changes caused by seasonality, customer behavior, and economic conditions can be permanent or temporary. NTLs attack models were proposed to generate abnormal patterns in different cases from normal data [23].

In this study, defects and theft patterns are analyzed separately for voltage and current. The difference between each type of abnormality is generated from normal data samples, which show an overview of the process as in Figure 4. An anomaly model was generated considering either a periodic decrease or an abrupt change in energy consumption. Attack models in [23] will be rebuilt to reflect the actual anomaly pattern found in the AMR meter and to assume the nature of real-world attack scenarios.

a: NORMAL DATA SAMPLES

Given that the normal condition for voltage is constant while the current varies depending on the load. For example,

a change in an electrical machine, production time, or environmental conditions would result in a reduction of EC. Figures 5 (a) and (b) represent the daily variation of normal data samples of voltage and current.

b: DEFECTIVE MODELS

The defective meters that have been found in many incidents can be divided into two categories: internal meters such as clock failure, data flash failure, program flash failure, or LCD error [2] and external meters, such as bumout from overload, defective terminals, current transformer failure, oxide formation, or internal loads of customers [2]. The aforementioned causes can be summarized into six models as shown in Mathematical model 1. Each phase of normal data is fed into the defective models (six cases) to generate a new dataset of defective patterns. Figure 6 shows an example of the generated voltage (left) and current (right) for time series.

Mathematical model: 1	Defective generating model
Input:	voltage phase $p: V_{i,j}^n(p)$, current phase $p: I_{i,j}^n(p)$ both will be represented $x_{i,j}^n(p)$, n is normal sample
Variables:	constant value: γ, α_i, ov_i change over time, $\bar{x}_{i,j}^n$ is average value
Result:	$\bar{x}_{i,j}^{df}(p)$ is defective generated
Cases:	<i>Any phase drops (differ phase)</i>
$df: 1$	$[\bar{x}_{i,j}^{df}(a) = 1.05 * x_{i,j}^n(a)] \parallel [\bar{x}_{i,j}^{df}(b) = 0.9 * x_{i,j}^n(b)]$ $\parallel [\bar{x}_{i,j}^{df}(c) = 0.45 * x_{i,j}^n(c)]; random(t)$ That toggle constants between phases.
Cases:	<i>All phase unbalance</i>
$df: 2$	$[\bar{x}_{i,j}^{df}(a) = \alpha_i * x_{i,j}^n(a)] \& \& [\bar{x}_{i,j}^{df}(b) = \alpha_i * x_{i,j}^n(b)]$ $\& \& [\bar{x}_{i,j}^{df}(c) = \alpha_i * x_{i,j}^n(c)]; 0.15 \leq \alpha_i \leq 0.85$
Cases:	<i>Any phase over standard (over same phase)</i>
$df: 3$	$[\bar{x}_{i,j}^{df}(a) = ov_i * x_{i,j}^n(a)] \parallel [\bar{x}_{i,j}^{df}(b) = ov_i * x_{i,j}^n(b)]$ $\parallel [\bar{x}_{i,j}^{df}(c) = ov_i * x_{i,j}^n(c)]; 1.5 \leq ov_i \leq 5$
Cases:	<i>All phases reduce invariably</i>
$df: 4$	$[\bar{x}_{i,j}^{df}(a) = \alpha_i * \bar{x}_{i,j}^n(a)] \& \& [\bar{x}_{i,j}^{df}(b) = \alpha_i * \bar{x}_{i,j}^n(b)]$ $\& \& [\bar{x}_{i,j}^{df}(c) = \alpha_i * \bar{x}_{i,j}^n(c)]; 0.5 \leq \alpha_i \leq 0.95$
Cases:	<i>All phase zero over time</i>
$df: 5$	$\bar{x}_{i,j}^{df}(a) = \bar{x}_{i,j}^{df}(b) = \bar{x}_{i,j}^{df}(c) = 0, \tau_0 - \tau_i$
Cases:	<i>Any phase drops</i>
$df: 6$	$[\bar{x}_{i,j}^{df}(a) = \gamma * x_{i,j}^n(a)] \& \& [\bar{x}_{i,j}^{df}(b) = \gamma * x_{i,j}^n(b)]$ $\& \& [\bar{x}_{i,j}^{df}(c) = \gamma * x_{i,j}^n(c)],$ $\gamma = \begin{cases} random(0.125, 0.925), \tau_{st} - \tau_{ed} \\ 1, otherwise \end{cases}$

c: DEFECTIVE MODELS

The purpose of energy theft is to commit a billing report for less energy than the actual energy consumed. Examples of incidents in PEA comprise switching between phase wires, direct connect without a meter, short-circuit current coils, forged lead seals, cutting the control cable of accessories CT [2]. From the events found, the patterns can be summarized as Mathematical model 2. In the same way, each phase of normal data is fed into the theft models (five cases) to generate a new dataset of theft patterns. Figure 7 shows an example of the generated voltage (left) and current (right) for time series.

Mathematical model: 2	Generated theft model
Input:	voltage phase $p: V_{i,j}^n(p)$, current phase $p: I_{i,j}^n(p)$ both will be represented $x_{i,j}^n(p)$, n : normal sample
Variables:	constant value: $\beta_1, \beta_2, \alpha_i$ change over time, average value: $\bar{x}_{i,j}^n$
Result:	$\bar{x}_{i,j}^{th}(p)$ is theft generated
Cases:	<i>Any phase drops to zero.</i>
$th: 1$	$[\bar{x}_{i,j}^{th}(a) = \beta_1 * x_{i,j}^n(a)] \parallel [\bar{x}_{i,j}^{th}(b) = \beta_1 * x_{i,j}^n(b)]$ $\parallel [\bar{x}_{i,j}^{th}(c) = \beta_1 * x_{i,j}^n(c)],$ $\beta_1 = \begin{cases} 0, \tau_{st} < t < \tau_{ed} \\ 1, otherwise \end{cases}$
Cases:	<i>All phase is zero some time</i>
$th: 2$	$[\bar{x}_{i,j}^{th}(a) = \beta_2 * x_{i,j}^n(a)] \& \& [\bar{x}_{i,j}^{th}(b) = \beta_2 * x_{i,j}^n(b)]$ $\& \& [\bar{x}_{i,j}^{th}(c) = \beta_2 * x_{i,j}^n(c)],$ $\beta_2 = \begin{cases} 0, \tau_{st} < t < \tau_{ed} \\ 0.9, otherwise \end{cases}$
Cases:	<i>All phases reduce constant</i>
$th: 3$	$[\bar{x}_{i,j}^{th}(a) = \alpha_i * x_{i,j}^n(a)] \& \& [\bar{x}_{i,j}^{th}(b) = \alpha_i * x_{i,j}^n(b)]$ $\& \& [\bar{x}_{i,j}^{th}(c) = \alpha_i * x_{i,j}^n(c)],$ $0.15 \leq \alpha_i \leq 0.85$
Cases:	<i>Any phase abrupt balance</i>
$th: 4$	$[\bar{x}_{i,j}^{th}(a) = \alpha_i * x_{i,j}^n(a)] \parallel [\bar{x}_{i,j}^{th}(b) = \alpha_i * x_{i,j}^n(b)]$ $\parallel [\bar{x}_{i,j}^{th}(c) = \alpha_i * x_{i,j}^n(c)],$ <i>random α_i for t in $0 \leq \alpha_i \leq 0.75$</i>
Cases:	<i>Any phase is reversal</i>
$th: 5$	$[\bar{x}_{i,j}^{th}(a) = inverse(x_{i,j}^n(a))] \parallel [\bar{x}_{i,j}^{th}(b) = inverse(x_{i,j}^n(b))]$ $\parallel [\bar{x}_{i,j}^{th}(c) = inverse(x_{i,j}^n(c))],$

2) ADAPTIVE SYNTHETIC SAMPLING (ADASYN)

One way to handle the datasets in the small class is by using an approach to synthesize new sampling. In this study, adaptive synthetic sampling (ADASYN) was used to increase




FIGURE 6. Some examples of defectively generated data.

the number of abnormal data points of both types (defects and theft). The motivation of using ADASYN is to adjust the weight compared to the most important classes, reduce the bias, and implement an adaptive learning procedure according to different distributions [24]. The synthetic data process is illustrated in Figure 8 and described in Algorithm 2.

3) IMAGE DATA AUGMENTATION (IA)

Data imbalance problems arise from insufficient data. To solve the data scarcity in terms of image datasets, one of the techniques is image data augmentation (IA). This technique generates new images from existing ones to




FIGURE 7. Some examples of the generated theft model.




FIGURE 8. The input-output ADASYN structure for synthetic sampling.

enhance a size, increase data, customize images, and improve the quality of training. IA is commonly used in computer vision. However, it can apply various changes to the initial

Algorithm 2 Generating 3 Classes With ADASYN

Input	$V_{t,i}(p)$ and $I_{t,i}(p)$ data represented $x_{t,j}^i(p)$ for array $[X_t, y_t]$, samples $N(t = 1, \dots, n)$
Variables	X_t is an instance n dimensional, y_t is class identity (3 class) Samples $N = N_{ma} + N_{mi}$, $N_{mi} \leq N_{ma}$ N_{mi} is small class, N_{ma} is majority class S_t is the new synthetic example
Result:	S_t is the new synthetic example

```

1 Calculate the degree of class:  $d = \frac{N_{mi}}{N_{ma}}$ 
  Where:  $d \in [0, 1]$ 
2 If degree of class( $d$ ) < preset threshold( $d_{thr}$ )
3   then
4     Total number of synthetic data
     ( $G$ ) =  $(N_{ma} + N_{mi}) * \beta$ 
     Where:  $\beta$  is desired balance level  $\beta \in [0, 1]$ 
5     Calculate the ratio  $r_t = \frac{\Delta t}{K}$ ,  $t = 1, \dots, N_{ma}$ 
     when  $\Delta t$  is the number of samples in  $K$  nearest
     neighbors (Euclidean distance),  $r_t \in [0, 1]$ 
6     Normalize  $r_t$  and density distribution
      $\hat{r}_t = \frac{r_t}{\sum r_t}$ ,  $\sum \hat{r}_t = 1$ 
7     Calculate synthetic data samples  $g_t = \hat{r}_t * G$ 
     where;  $G$  is total number of synthetic data
8     For  $t = 1$  to  $g_t$ 
9       Randomly select small part  $X_{zt}$  from  $K \in X_t$ 
10      Generate the synthetic data samples
       $S_t = X_t + (X_{zt} - X_t) * \lambda$  where;  $\lambda$  is a
      random number  $\lambda \in [0, 1]$ 
11    end
12  end

```

data as a useful solution for oversampling and reducing overfitting [25].

For image data augmentation techniques, the original dataset was extracted into images using a RP and defects and theft patterns were then created using position augmentation. An overview of the process is shown in Figure 13. The time series were converted to images using RP, and image manipulation was then performed using a set of eight augments, as shown in Table 2. Parameters were randomly adjusted according to Table 2, and each technique was randomly combined to increase the amount of abnormal data. For example, a combination of scaling (126×126) and rotation (30 degrees) or cropping (138) and flipping ($p = 0.5$) creates a new image, as shown in Figure 13.

D. FEATURE EXTRACTION

In many areas of data science, one of the most important procedures for classification using deep learning is data extraction. Time series are directly input to machine learning and various classifiers were classified to compare the results in [26] and [27]. However, many studies have been found to transform time series into other structures such as graphs or tables, images and wavelet transforms in [28], [29], and [30],

TABLE 2. Position augmentation and parameters setting.

Augmenting	Explanation	Parameters
Scaling	The image will be scaled to the specified size.	(126x126), (109x109), (92x92), (76x76), (59x59), (42x42)
Cropping	The image will be partially selected (center).	138, 108, 78, 48
Flipping	The image is flipped vertically or horizontally.	random p [0.5, 1]
Padding	All sides of the image are padded with a designated value.	random (a, b, c, d) range [1,30]
Rotation	The image will be randomly rotated.	rotate range [0-270]
Translation	The image will be moved along the x-axis or y-axis.	random translation [0,1-0.9]
Zooming	The image will be zoomed in at various aspect ratios.	random range [0,1,1]
Affine transformation	The affine transformation preserves straight lines, planes, and points.	random degrees [0,90] and scale [0,1,0.9]

TABLE 3. Generated result and voltage data balancing.

Classes/ Phase	Phase A		Phase B		Phase C	
	Before	After	Before	After	Before	After
Normal	1,159	1,159	1,416	1,416	1,463	1,463
Defects	246	246 + 913	116	116 + 1,300	168	168 + 1,295
Theft	66	66 + 1,093	71	71 + 1,345	85	85 + 1,378
Total	1,471	3,477	1,603	4,248	1,716	4,389

TABLE 4. Generated result and current data balancing.

Classes/ Phase	Phase A		Phase B		Phase C	
	Before	After	Before	After	Before	After
Normal	823	823	805	805	801	801
Defects	419	419 + 404	424	424 + 381	420	420 + 381
Theft	212	212 + 611	252	252 + 553	215	215 + 586
Total	1,454	2,469	1,481	2,415	1,436	2,403

which give good results compared to direct input of time series data. So, this is an interesting and challenging method for data extraction.

In this study, after generating and balancing the data, the total amount of data is shown in Tables 3-4. Each phase of theft and defective samples is generated with the same amount of data as the normal samples. One of the methods for extracting features that are used to transform time series data into images is the recurrence plot (RP) [31].

1) RECURRENCE PLOT (RP)

Recurrence plot are the original technique of nonlinear data analysis used to visualize the time series dynamics,

Algorithm 3 Recurrence Plot (RP)

Parameters:	Window size: 168 Dimension of the trajectory, $\dim = 1$ Time delay, $td = 1$, Threshold = none Percentage of black points, $pb = 10$ Color map: $color = plasma$ recurrenceplot function: using Eq.8 Classes: c (normal, defect, theft)
1	Data in 1D format: $x_{t,i}^c(p)$; $i, j = 1, 2, 3, \dots, n$ $x_{t,i,j}^c(p) = \{x_{t,i,1}^c(p), x_{t,i,2}^c(p), x_{t,i,3}^c(p), \dots, x_{t,i,n}^c(p)\}$
2	For sample $x_{t,i}^c(p) \in dataset$
3	do
4	For $im_{rp} =$ $recurrenceplot(x_{t,i}^c(p), color, \dim, td, pb)$
5	do
6	$RP_{(n,c)} = resize(im_{rp}, size)$
7	end
	Result: $RP_{(n,c)}$ is customer images n with class c

the periodic characters, and the complex dynamic systems [31]. This method represents time series using the repeat of states (recurrence) property of the trajectories of dissipative systems. Consider the recurrence plots are shown by the equation (8).

$$RP_{i,j} = \begin{cases} 1, & \|\vec{X}_i - \vec{X}_j\| \leq \varepsilon \\ 0, & otherwise \end{cases} \quad (8)$$

where: RP is a square matrix $RP_{i,j}$, $i, j = 1, \dots, N$, $\|\cdot\|$ is a norm, the state of the system of $RP_{i,j}$ is equal to 1 if the distance between points $x_{t,i}^c$ and $x_{t,j}^c$ in phase space does not exceed the recurrence threshold ε otherwise $RP_{i,j}$ is equal to 0.

The above relationship equations were applied to transform a time series into an image using the Python package for a recurrence plot, as shown in Algorithm 3. The interesting aspect of the recurrence plot applied in this research is as follows:

- 1) A nonstationary signal will show the nature of the occurrence or abrupt change.
- 2) The time interval between the periodic patterns corresponds to the interval that occurred. The diagonals with different distances reveal periodic or quasi-periodic patterns.
- 3) A single point with a heavy fluctuation pattern is represented as an uncorrelated random point.

2) RECURRENCE IMAGING (SET1)

After balancing the dataset (set1) using the anomaly model (AM). The window size was divided into 168 intervals (for 1week: 672/hour: 4) because it is consistent with the AMR monitoring system. The image was scaled to 168×168 based on the experimental results of optimum resolution. The results of the recurrence imaging are illustrated in




FIGURE 9. Current time series transformed using RP.

Figures 9 (a-b) and Figures 10 (a-b). Figure 9(a) shows the normal and defective events, while Figure 9(b) shows the normal and theft events in three-phase voltage. Similarly, in the case of three-phase current, Figure 10(a) represents the normal and defective events, while Figure 10(b) represents the normal and theft events. The data were then extracted for each phase and converted to recurrence imaging. The shapes that are formed change over time and have different characteristics for each class.

3) RECURRENCE IMAGING (SET2)

The datasets in each group are separated to be compiled for each phase of voltage and current (set 2). Subsequently, the type of defective meter and energy theft was generated using synthetic data with using Algorithm 2. Example results showing differences between no-balance data and ADASYN are shown in Figure 11. Before synthetic data, normal data consisted of two sets, one set of defects and the other set of thefts. The scatter plot of no-balance illustrates the sample data distribution of three classes in Figure 11(a), which is




FIGURE 10. Current time series transformed using RP.

represented as an individual image for each class, as shown in Figure 11(b). After generating synthetic data with ADASYN, it was found that the normal data had only minor data changes while the number of defects and thefts increased, as shown by the scatter plot (ADASYN) in Figure 12(a). At the same time, the plot shape changes according to the new data added and the results of defects and thefts data increased to 2 sets, as shown in Figure 12(b). The results were different, but the same features were found. Overall, the synthesized data corresponds to the amount of data in Tables 3 and 4.

4) RECURRENCE IMAGING (SET3)

In this technique, there is a difference between the two previous techniques because the unbalanced data were converted to recurrence imaging (set 3) before balancing. Defect and




FIGURE 11. Examples of No-balance for three classes of datasets.

theft data for voltage and current are randomly selected for image adjustment using the position augmentation, as shown in Figure 13. In this case, the normal data is unadjusted, but we adjusted only the abnormal patterns so that the abnormal group would have the same number of images as the normal group. The result of this adjustment is shown in Tables 3 and 4, respectively.

E. IMAGE CLASSIFICATION

The data were balanced using three techniques both before and after it was extracted into an image format for classification. The image input was split into a training set (75%) and a testing set (25%). The program ran on Windows 11 with an Intel Core i7-12700H 2.9 GHz CPU and 16 GB of RAM. The programming language used was Python and the libraries used were Tensorflow, Keras, Scikit-learn, Numpy, Pandas and PyTorch. For image classification, several deep learning classifiers were used in this study including LeNet5, AlexNet, VGGNet19, DenseNet121, ResNet50 and InceptionV3. The experiment was conducted with the Adam optimizer with an initial learning rate of 0.0001, a minibatch size of 10,




FIGURE 12. Examples of ADASYN for three classes of datasets.

L2 regularization of 0.0002, a batch size of 64, and training over 30 epochs. For model training, this study is divided into two parts: The first part is an implementation of the pre-trained model available in Keras Applications without any additional design or parameterization [32]. Because it is important to compare the results of classification after balancing data for each data type. In the second part, a CNN model is applied to compare the results of each balanced data approach, which are determined on a time-series basis (not converted to images). This part defines and designs the parameters for each layer by experimenting with hyperparameters to find the exact fit for the dataset.

1) PERFORMANCE METRICS

In order to comprehensively evaluate the experimental result, performance metrics were used to verify the effectiveness of the proposed method [33]. In addition, area under curve (AUC) and receiver operating characteristic (ROC) curves, the two metrics for evaluating the performance of a classifier,




FIGURE 13. The input-output structure of image augmentation.

were also used. The details are as follows:

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (9)$$

$$Recall \text{ or } TPR = \frac{TP}{TP + FN} \quad (10)$$

$$Precision = \frac{TP}{TP + FP} \quad (11)$$

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (12)$$

$$FPR = \frac{FP}{TN + FP} \quad (13)$$




FIGURE 14. Number of voltage datasets for classification.




FIGURE 15. Number of current datasets for classification.

where: TP is true positives, TN is true negatives, FP is false positives, FN is false negatives, TPR is true positive rate, and FPR is false positive rate.

2) ANALYSIS OF RESULTS AND DISCUSSION

a: EXPERIMENTAL SETUP

The data is separated from each phase for processing and extracted as image data using recurrence plots in the balancing data step. But for classifying data, all three-phase results in image form are combined into a single dataset that is shown in Figures 14-15. The data consists of four sets: no balance, anomaly model (AM), adaptive synthetic sampling (ADASYN) and image data augmentation (IA). No balance is original data for voltage (NOM: 2,429, DEF: 1,263, THF: 679) and current (NOM: 4,038, DEF: 530, THF: 222). The balanced data for AM, ADASYN and IA are almost equal in all three categories for voltage (NOM \approx DEF \approx THF \approx 2,429) and current (NOM \approx DEF \approx THF \approx 4,038).

b: EXPERIMENTAL RESULTS AND DISCUSSION

In order to analyze the effectiveness of the proposed methods, which are a combination of unbalanced data handling techniques and deep learning methods. To compare performance metrics among several evaluators, there are four methods with six networks that evaluate voltage and current data. The best results are highlighted in bold on each table and metric.

Tables 5-6 shows the results of data classification. Accuracy is the value that the model correctly predicts based on all of those values. AM+DenseNet121 is 94% (volts), and AM+VGGNet19 is 93.5% (amps), both give the best results. Recall or TPR are values that the model correctly

TABLE 5. The effectiveness of the combination for voltage.

Method + Network	Acc	Recall	Precis.	F1-score	AUC-ROC	FPR
No balance+LeNet5	84.2	79.3	85.6	42.4	40.4	20.7
No balance+AlexNet	87.0	80.8	79.8	40.9	49.2	19.2
No balance+VGGNet19	85.4	74.8	73.1	48.5	50.9	25.2
No balance+DenseNet121	83.8	72.2	66.0	51.8	47.4	27.8
No balance+ResNet50	87.3	69.0	75.7	54.5	51.1	31.0
No balance+InceptionV3	86.0	78.9	71.3	57.8	59.7	21.1
AM+LeNet5	90.7	86.7	89.1	82.1	69.6	13.3
AM+AlexNet	92.8	81.6	87.5	73.6	68.3	18.4
AM+VGGNet19	92.0	87.1	92.5	77.7	71.4	12.9
AM+DenseNet121	94.0	90.3	88.4	90.5	92.0	9.7
AM+ResNet50	92.0	82.9	90.1	84.9	85.7	17.1
AM+InceptionV3	93.8	78.3	93.7	88.9	80.6	21.7
ADASYN+LeNet5	88.0	90.4	88.5	75.8	71.3	26.1
ADASYN+AlexNet	90.1	83.4	88.0	77.7	76.8	23.0
ADASYN+VGGNet19	89.7	90.1	82.7	83.4	70.1	23.6
ADASYN+DenseNet121	90.1	91.4	86.8	77.5	67.3	21.8
ADASYN+ResNet50	89.9	90.1	82.5	83.9	73.9	25.8
ADASYN+InceptionV3	89.7	88.2	84.4	82.9	66.1	22.3
IA+LeNet5	61.0	48.6	52.7	67.6	51.0	51.5
IA+AlexNet	54.9	65.1	60.0	61.4	43.2	34.9
IA+VGGNet19	59.6	40.1	39.3	52.2	55.6	59.9
IA+DenseNet121	53.3	40.1	63.8	62.5	48.7	60.0
IA+ResNet50	51.5	42.1	44.8	57.5	47.2	57.9
IA+InceptionV3	61.7	54.5	41.8	51.4	60.1	45.5

predicted against true positives and false negatives. The experimental results show that ADASYN+DenseNet121 is 91.4% (volts) and ADASYN+ResNet50 is 90.6% (amps). These were the highest values. A good recall value should have the fewest false negatives. Precision is a positive predictive value where AM+InceptionV3 is 93.7% (volts) and AM+VGGNet19 is 91.1% (amps). Both provide high precision. F1-Score is the value obtained by combining recall and precision, AM+InceptionV3 has a maximum value of 88.9% (volts), and AM+ResNet50 has a maximum value of 86.6% (amps). AUC-ROC is a measure of the overall performance of all groups and distinguishes between classes, where AM+DenseNet121 is 87% (volts) and ADASYN+VGGNet19 is 79.1% (amps), both giving good results. FPR (False Positive Rate) is a measure of false predictions. The least valuable result is 9.7% (volts) for AM+DenseNet121 and 10.2% (amps) for AM+ResNet50. A good model must have a low FPR, which reflects the potential for error. Importantly, the occurrence of false positives in real events can result in errors and waste time on investigations.

Considering the technique used, the anomaly model was balanced and gives the best results in all evaluations. An anomaly model generated from equations extracted from real events. The actual data used was varied and was deformed into anomalies, the pattern of which also changed depending on customer behavior and load. In this way, the model can be learned in many patterns. However, in some events that have never been simulated or learned by the model before, this can be erroneous in actual use. Adaptive synthetic sampling generates new data sets by adaptively shifting the decision boundary on the learned for small class samples. Based on the idea of a consistent distribution for the original dataset, anomalous data (defects and theft) were adjusted and

TABLE 6. The effectiveness of the combination for current.

Method + Network	Acc	Recall	Precis.	F1-score	AUC-ROC	FPR
No balance+LeNet5	85.8	61.4	89.9	53.4	50.3	38.6
No balance+AlexNet	70.9	61.4	73.4	52.7	51.3	38.6
No balance+VGGNet19	87.9	55.3	69.7	62.5	56.9	44.7
No balance+DenseNet121	84.2	63.0	68.3	53.7	55.2	37.0
No balance+ResNet50	88.3	75.7	66.9	52.8	60.6	24.3
No balance+InceptionV3	84.0	72.7	73.6	50.5	48.9	27.3
AM+LeNet5	90.0	83.8	80.7	79.5	58.2	16.3
AM+AlexNet	90.9	83.9	78.3	83.7	63.0	16.1
AM+VGGNet19	93.5	87.3	91.1	76.7	65.6	12.8
AM+DenseNet121	92.4	87.6	73.0	69.2	80.8	12.4
AM+ResNet50	91.3	89.8	80.7	86.6	62.7	10.2
AM+InceptionV3	90.9	83.8	82.7	83.8	77.9	16.2
ADASYN +LeNet5	86.6	88.3	84.2	75.3	72.7	28.5
ADASYN +AlexNet	87.9	89.8	85.0	73.1	70.1	28.2
ADASYN +VGGNet19	88.5	89.8	84.2	79.9	79.1	27.5
ADASYN +DenseNet121	88.4	89.5	85.6	74.1	75.6	25.5
ADASYN +ResNet50	74.7	90.6	85.3	75.4	73.9	24.7
ADASYN +InceptionV3	91.2	89.9	86.1	78.7	70.3	24.3
IA+LeNet5	65.1	62.5	48.6	60.3	58.9	37.5
IA+AlexNet	61.8	44.0	69.3	52.3	53.3	56.0
IA+VGGNet19	57.8	49.1	53.9	61.8	50.9	50.9
IA+DenseNet121	60.2	65.3	48.7	63.5	57.3	34.7
IA+ResNet50	52.8	57.9	69.7	57.2	58.6	42.1
IA+InceptionV3	50.9	47.3	57.7	43.5	58.3	52.7

synthesized for Δt based on the number of samples in K nearest neighbors calculated by Euclidean distance, and synthetic data samples were randomly drawn from small groups. Nevertheless, in this study for multiple classes, all data were adapted and regenerated to balance the data, incorporating all anomalies into each class. So, when splitting the data into windows for each customer, a whole new dataset was yielded. In this way, the synthesized data may confuse the learning ability of the model. Image augmentation, although this method has good results in computer vision tasks for increasing the number of learning, is suitable for augmenting images where there is a difference between foreground and background. But for this study, classifying anomalies from time series conversion to images may not be appropriate. RP images using position augmentation that augmented images were too complex, difficult, and different and did not help the model learn better. Another interesting point is that no balance data produces good accuracy, recall, and precision results, but the F1-score and AUC-ROC were overall poor. The model has poor performance when used with unbalanced data, which is because it does not learn enough from the data.

Considering the network used, network training and testing were paired with each technique for evaluation. LeNet5 was very small and simple compared to other structures, which were commonly used with gray-scale images. While AlexNet was designed to be deeper with 8 layers and worked well with color images. However, VGGNet19, DenseNet121, ResNet50, and InceptionV3 have structural differences that are further enhanced by increasing the number of layers, improving model depth, removing limitations, expanding capabilities, and allowing for faster models. Consequently, different good results were obtained for each type of data. In this experiment, we focused on comparing model performance against each type of method obtained from balanced




FIGURE 16. Training vs. testing of accuracy and losses for Method + Network.

data. This gave us more options as to which network could best fit our application.

Figure 16 depicted examples of the voltage dataset for Method + Network that gave the best results during the training and testing phases. The left side shows the accuracy, and the right side shows the loss, which is set for 50 iterations of running. For average accuracy, No balance + ResNet50: 87.3%, AM + DenseNet121: 94.0%, ADASYN + AlexNet: 90.1%. When considering the above three graphs, the accuracy increases as the epoch value increases. AM was quite smooth and has less swing than no balance or ADASYN which fluctuate in some epochs. While IA+InceptionV3 has an average accuracy of 61.7%, which was a poor outcome, and the graph shows fluctuation, abrupt change, or overfitting in many epochs. For loss graphs, no balance, AM, and ADASYN found that it gradually increases when the epoch value increases. While the IA was trending down as well but with a high swing.

IV. COMPARISON OF PERFORMANCE WITH OTHER WORKS

A. COMPARISON WITH OTHER IMBALANCED TECHNIQUES

In order to further prove the difference between the proposed approach and other types of data balancing techniques,

TABLE 7. The CNN network parameter settings.

Layers	Parameter value
1	Input layer (168,1)
2	Convolution layer: 3x3
	Pooling layer(max): 2x2
3	Convolution layer: 3x3
	Pooling layer(max): 2x2
4	Convolution layer: 3x3
	Pooling layer(max): 2x2
5	Flatten:512
6	Fully connected: 64
7	Softmax:16
8	Output layer

TABLE 8. Comparison of other techniques using CNN (voltage).

Method	Acc	Recall	Precis.	F1-score	AUC-ROC	FPR
No-balance	81.0	80.8	81.1	67.5	76.1	19.2
RUS	83.3	83.8	83.0	86.2	68.0	16.3
ROS	84.1	83.8	84.0	87.3	83.2	15.1
RUS+ROS	83.6	83.8	83.6	86.7	83.2	17.0
SMOTE	82.1	82.3	82.4	85.7	81.3	12.7
CSL(weighting)	77.5	78.0	76.9	79.4	82.2	23.5
AM	90.6	91.0	91.9	89.1	92.0	10.1

five methods were designed for comparison on the same data. These methods consisted of random undersampling (RUS) which randomly removed samples from the majority class [34], random oversampling (ROS) which randomly samples duplicates in small classes. The combination of the two techniques [35], synthetic minority oversampling technique (SMOTE) synthesizes new examples from the existing examples [35], and Cost-Sensitive Learning (CSL) is used as a class weight to compensate for the small class [36].

The comparative experiments used a time series dataset, which differed from this current study because we wanted to demonstrate the effectiveness of using 1-D (time series) and 2-D (image) data. Our dataset was manipulated as time series features using the techniques mentioned above to balance the data. During this study, we proposed a method where the data was extracted for each customer and converted to images. Therefore, convolutional neural network (CNN) was used to classify, and the parameters were configured in Table 7. We set 3×3 kernels of convolution, 2×2 for pool layers at 3 layers, and SoftMax for the activation function. The results are shown as Tables 8-9 and AUC-ROC score compared to the other techniques in Figure 17. The results revealed CSL performance was poor, while RUS, ROS and combining the two gave low results when comparing to SMOTE. However, the method proposed (AM) for time series also outperform than other techniques, although the results are lower than those of image analysis. That shows that classifying normal defects and theft patterns for this research, which balances data and uses 2-D features yields better results than 1-D.

B. COMPARISON WITH EXISTING DATA SOURCES

Based on the matching between methods and networks in this study, this allows us to obtain the best model from experimentation, which is AM+DenseNet121. In order to determine




FIGURE 17. AUC-ROC based benchmark comparison using CNN.

TABLE 9. Comparison of other techniques using CNN (current).

Method	Acc	Recall	Precis.	F1-score	AUC-ROC	FPR
No-balance	74.7	74.9	72.9	58.0	67.9	25.3
RUS	75.2	75.6	72.7	69.4	62.3	24.8
ROS	75.3	73.0	74.4	78.2	78.9	24.7
RUS+ROS	75.9	80.0	74.3	81.3	79.5	24.1
SMOTE	76.5	74.8	75.0	72.2	72.3	23.5
CSL(weighting)	68.5	67.6	65.4	68.0	72.6	31.5
AM	89.3	89.8	88.2	80.1	81.4	11.9

whether the resulting model can be applied to other types of data, we then collect data available in open source for testing. Table 10 compares data from three sources: SGCC [37], CER [38], and OEDI [39] as only two classes (normal and theft) of EC values with different amounts of data. All data will be prepared and balanced using AM which considers only single-phase (Phase A) equations and compares before and after balancing data, then evaluates the results from multiple perspectives. The results showed that classification performed well on all three data sets. Importantly, it performs better than our data set because it has fewer classes and less data complexity (the difference between the two classes is quite clear). When considering the ROC-AUC, the value

TABLE 10. Comparison AM+Densenet121 with existing data sources.

Data source	Type of data	Total original data	Data balancing		Acc	Recall	Precis.	F1-score	AUC-ROC	FPR
			Before	After						
SGCC	SM data (Daily EC)	42,372	NOM =38,757 THF=3,615	NOM=THF=38,757 (Generated=35,142)	93.18	92.41	94.63	94.61	95.90	6.78
	SM data (Daily EC)		NOM=23,422 THF=2,114	NOM=THF=23,422 (Generated=21,308)						
CER	SM data (Daily EC)	25,536	NOM =31,612 THF=1,988	NOM=THF=31,612 (Generated=29,624)	93.23	92.90	93.04	93.36	93.54	6.71
	SM data (Daily EC)		NOM =31,612 THF=1,988	NOM=THF=31,612 (Generated=29,624)						




FIGURE 18. (a) AUC-ROC score of other sources. (b)-(c) AUC-ROC based benchmark comparison of voltage and current.

was high for all three sets, as shown in Figure 18(a). So, experimental results show that the model can be applied to other types of data and has high efficiency.

C. COMPARISON OF BALANCING TECHNIQUES AND NETWORKS USING OUR DATA

Another challenge we wanted to prove was to use the state-of-the-art benchmark models built using our data to compare them with our proposed methods. Each technique used to balance the data was matched to the network with different balanced data ratios. In the simulation, the data were divided into two sets: the voltages shown in Table 11 and the currents shown in Table 12. From the research that was compared, [10], [16], [18], [19], [21], and [38] are of the type of binary classification case. Some parameter values are recalculated for multi-label classification (three-class). For LSTM and MLP in [38], they used sequential and non-sequential data, but only sequential data was used in this experiment. The results showed that RUS reduced the majority of the data to balance the small class, and XGBoost, which was used to classify, had poor results. While considering the AUC-ROC in Figures 18 (b) and (c), AM+Densenet121 applied to voltage parameters provides the best efficiency of 92%. But for current parameters, where the data is more complex, the efficiency is only 80.8%. Nevertheless, it can be seen that the method that we present is suitable for our datasets.

D. COMPARISON WITH PREVIOUS WORKS

Table 13 summarizes similar studies so that detailed comparisons can be made between previous studies and the methods proposed in this paper. The most noticeable difference is the type of data used, the method, the network, Max-Min class size and the amount of data. Most class studies were divided into two groups but for this study, we were divided into three groups as well as performance evaluation and the overall results were evaluated differently.

E. LIMITATIONS

Although balancing data in the proposed framework outcomes achieved results, during the data extraction and classification procedure, we also found limitations at each step that affected the functionality and performance of the model. In summary, the three types of failures that can occur are as follows:

Case #1: Although the AM method enhances the anomaly data by using normal baseline data and produces good classification results. However, in this method, the data will be limited to the scope of creating a new dataset depending on the equation used to generate it. In the real world, there may be other variations or different abnormalities that can occur.

TABLE 11. Comparison of data balancing techniques and networks based on voltage datasets.

Method	Network	Balanced data ratio	Acc	Recall	Precis.	F1-score	AUC-ROC	FPR	Ref.
ROS	ANN	0: 2,429, 1: 2,429, 2: 2,429	78.5	76.7	79.5	76.4	83.9	21.9	[27]
CSL (weighting)	SVM	0: 2,429, 1: 1,263, 2: 679	77.2	74.3	76.7	74.3	83.4	24.5	[18]
RUS	XGBoost	0: 679, 1: 679, 2: 679	67.5	64.0	63.4	63.0	68.9	39.3	[34]
SMOTE	AdaBoost	0: 2,429, 1: 2,429, 2: 2,429	91.7	90.4	89.4	88.4	90.9	19.8	[35]
CBOS	Deep-CNN	0: 3,400, 1: 3,400, 2: 3,400	84.5	86.7	88.1	88.6	91.5	32.5	[40]
FL	WD-CNN	0: 2,429, 1: 1,263, 2: 679	87.7	87.5	87.5	87.4	91.9	12.6	[21]
-	MLP-LSTM	0: 2,429, 1: 1,263, 2: 679	74.2	74.4	73.4	73.8	91.0	26.1	[41]
AM	DenseNet121	0: 2,429, 1: 2,429, 2: 2,429	94.0	90.3	86.4	80.5	92.0	9.7	Our

Note: No-balance: (0: 2,429, 1: 1,263, 2: 679)

TABLE 12. Comparison of data balancing techniques and networks based on current datasets.

Method	Network	Balanced data ratio	Acc	Recall	Precis.	F1-score	AUC-ROC	FPR	Ref.
ROS	ANN	0: 4,038, 1: 4,038, 2: 4,038	77.1	77.1	76.3	76.4	72.2	23.0	[27]
CSL (weighting)	SVM	0: 4,038, 1: 530, 2: 222	62.2	61.1	64.5	63.1	74.9	37.0	[18]
RUS	XGBoost	0: 222, 1: 222, 2: 222	64.7	67.0	65.2	65.0	68.8	34.4	[34]
SMOTE	AdaBoost	0: 4,038, 1: 4,038, 2: 4,038	75.4	74.1	77.9	76.7	67.6	24.2	[35]
CBOS	Deep-CNN	0: 4,414, 1: 4,414, 2: 4,414	61.4	60.4	59.5	60.1	73.3	39.4	[40]
FL	WD-CNN	0: 4,038, 1: 530, 2: 222	71.6	73.6	70.2	72.7	66.5	28.1	[21]
-	MLP-LSTM	0: 4,038, 1: 530, 2: 222	66.3	67.8	67.2	66.6	71.4	33.2	[41]
AM	DenseNet121	0: 4,038, 1: 4,038, 2: 4,038	92.4	87.6	73.0	69.2	80.8	12.4	Our

Note: No-balance: (0: 4,038, 1: 530, 2: 222)

TABLE 13. Comparison of imbalanced techniques with previous works.

Ref. (Year)	Data source	Type of data	Method	Network	No. datasets	No. classes	Min class size	Max class size	Performance measure (%)
[10] (2017)	Honduras, Spanish	Daily EC (kWh)	ROS, RUS.	SVM, NN	4,145	2	133	3,295	Specificity: 93, Acc: 90
[12] (2016)	Brazil	Monthly EC (kWh)	subsampling data 17 different	Boolean, fuzzy, SVM	100k	2	10k	100k	TNR: 87, FPR: 65, FNR: 78, TPR: 75
[14] (2021)	SGCC, China	EC (kWh)	TLSGAN	GRU, GoogLeNet	42,372	2	3,615	38,757	ROC-AUC: 96, PR-AUC: 97
[15] (2020)	SGCC, China	EC (kWh)	Bi-WGAN	2D-CNN, Bi-LSTM	42,372	2	3,615	38,757	Acc:0.95, Prec: 97, Recall: 92, F1-score: 94, AUC-ROC: 97, MCC: 93
[18] (2020)	SGCC, China	EC (kWh)	CSL, RUS, ROS, K-medoids, SMOTE, CBOS.	LR, RF, SVM, and ANN	42,372	2	3,615	38,757	Acc: 91.63, AUC: 67.92, F1-score: 31.69
[19] (2021)	SGCC, China	EC (kWh)	Splitting percentage	DT, ANN, DANN, AdaBoost	42,372	2	3,615	38,757	Acc: 93.04, Recall: 61.03, Prec: 79.03, AUC: 73.6, F1-score: 53.8
[20] (2021)	CER, Ireland	EC (kWh)	SMOTE	ADB, CAT, ET, XGB, LGB, RF,	100	2	5	95	AUC: 0.90
[21] (2022)	SGCC, China	EC (kWh)	Focal loss	wide and deep CNN	42,372	2	3,615	38,757	MAP@100: 97.08, AUC: 83.61
[26] (2022)	-	EC (kWh)	-	Deep-CNN	45,970	2	7,815	38,155	Accuracy: 92, Prec: 90, AUC: 93, F1-score: 93
[40] (2021)	SGCC, China	EC (kWh)	CSL, RUS, ROS, SMOTE, CBOS.	CNN	42,372	2	3,615	38,757	Acc: 80.84, AUC: 68.33
[42] (2020)	SGCC, China	EC (kWh)	SMOTE, RUS, KPCA	SVM, AdaBoost	42,372	2	3,615	38,757	Precis: 85, Recall: 88, F1: 87, MCC: 86, MAP: 84
This work	PEA, Thailand	Voltage (V) and Current(A)	AM, IA, ADASYN	DenseNet121, LeNet5, AlexNet, VGGNet19, ResNet50, InceptionV3.	9,161	3	66	1,463	Acc: 94.04, Recall: 90.34, Prec: 86.35, F1-score: 80.49, AUC-ROC: 87.01, FPR: 9.7

Case #2: The similarity of events between theft and defective pattern is caused by abrupt changes causing the voltage or current to drop near zero, e.g., power outages for maintenance

of the distribution system, customer internal load changes, and unstable consumption behavior. Figure 19 shows some cases where the model predicted incorrectly.




FIGURE 19. An example of an event between the theft and the defective pattern.




FIGURE 20. Various customer groups of 3P4W AMR.

Case #3: A pattern or cluster of customers in a three-phase four-wire system has happened a variety. For example, a group that uses heavy loads during the day, such as offices or shops, some groups that use loads all the time such as industrial factories or groups that use unstable loads, such as hotels and large warehouses. These factors could affect the way in which sudden changes are captured. Figure 20 shows samples of normal (a) and defective (b), which current trends to decrease. While (c) the customer uses full loads during the day and (d) the customer uses less loads during the holidays, which looks similar to the anomaly but is normal.

V. CONCLUSION

This paper presents a technique for handling unbalanced data using voltage and current from a three-phase AMR meter. Three techniques were used: anomaly models (AM), adaptive synthetic sampling (ADASYN), and image data augmentation (IA). After balancing the data, each method was extracted and converted using a recurrence plot (RP). Imaging time series were then fed into six types of deep learning models to compare and classify the multiclass imbalance problems that comprise three classes: normal condition, energy theft, and defective meters. The results show that: (1) balanced data plays an important role in improving model performance compared to unbalanced data, (2) anomaly models designed to increase the number of abnormalities produce the best results and image data augmentation is ineffective for imaging time series, (3) classification of imaging (2-D) input data gives higher evaluation results than time series (1-D), (4) a comparison of classification results from six networks produced disparate results, whereas DenseNet121 gave overall good results, and (5) in order to evaluate the model for unbalanced data, AUC-ROC and FI-score are more suitable for benchmark than recall, accuracy, and precision. Moreover, comparing FPR values, the results reveal the potential error of the incorrectly predicted model. Finally, as a result of the experiment demonstrates a technique that helps handle

unbalanced data, how to extract features and compare models for data classification that can be adapted to work with the AMR monitoring system. Therefore, data balancing for classifying multiclass imbalance problems contributes to the learning pattern and prediction efficiency, reducing overfitting, bias, and errors when the model is implemented in real-world applications.

ACKNOWLEDGMENT

The authors would like to thank the Meter System Development Division, PEA Area 3 (Southern) Yala Province, for data support and valuable comments.

REFERENCES

- [1] Provincial Electricity Authority, *Performance Report According to the PEA Operational Plan for the Year 2021 Quarter 1–4*. Accessed: Mar. 1, 2021. [Online]. Available: <https://www.pea.co.th/en/About-PEA/Operating-Results/Performance-Report>
- [2] Provincial Electricity Authority, “Knowledge of loss of electricity,” One Point Knowl., PEA Code: 59120015, Mar. 2016, pp. 1–22.
- [3] F. D. S. Savian, J. C. M. Siluk, T. B. Garlet, F. M. do Nascimento, J. R. Pinheiro, and Z. Vale, “Non-technical losses: A systematic contemporary article review,” *Renew. Sustain. Energy Rev.*, vol. 147, Sep. 2021, Art. no. 111205.
- [4] *Automated Meter Reading (AMR) Technology*. Accessed: Mar. 19, 2023. [Online]. Available: <https://smartertechnologies.com/guides/smart-amr-meter-reading-systems-for-water-gas-electricity/>
- [5] Meter System Development Division, “Operation manual project to develop unit reading with automation,” Provincial Electr. Authority, Annu. Project Rep., Dec. 2012, pp. 45–56.
- [6] W. Ladarat and S. Naetiladdanon, “PEA automatic meter reading system: Progress and lessons learned,” in *Proc. 12th Int. Conf. Electr. Eng./Electron., Comput., Telecommun. Inf. Technol. (ECTI-CON)*, Jun. 2015, pp. 1–15.
- [7] J. M. Johnson and T. M. Khoshgoftaar, “Survey on deep learning with class imbalance,” *J. Big Data*, vol. 6, no. 1, p. 27, Mar. 2019.
- [8] S. Wang and X. Yao, “Multiclass imbalance problems: Analysis and potential solutions,” *IEEE Trans. Syst., Man, Cybern., B, Cybern.*, vol. 42, no. 4, pp. 1119–1130, Aug. 2012.
- [9] X. W. Liang, A. P. Jiang, T. Li, Y. Y. Xue, and G. T. Wang, “LR-SMOTE—An improved unbalanced data set oversampling based on K-means and SVM,” *Knowl. Based Syst.*, vol. 196, May 2020, Art. no. 105845.
- [10] G. Figueroa, Y. Chen, N. Avila, and C. Chu, “Improved practices in machine learning algorithms for NTL detection with imbalanced data,” in *Proc. IEEE Power Energy Soc. Gen. Meeting*, Chicago, IL, USA, Jul. 2017, pp. 1–5.
- [11] S. V. Oprea and A. Bara, “Machine learning classification algorithms and anomaly detection in conventional meters and Tunisian electricity consumption large datasets,” *Comput. Electr. Eng.*, vol. 94, Sep. 2021, Art. no. 107329.
- [12] P. Glauner, A. Boechat, L. Dolberg, R. State, F. Bettinger, Y. Rangoni, and D. Duarte, “Large-scale detection of non-technical losses in imbalanced data sets,” in *Proc. IEEE Power Energy Soc. Innov. Smart Grid Technol. Conf. (ISGT)*, Minneapolis, MN, USA, Sep. 2016, pp. 1–5.
- [13] T. Hu, Q. Guo, H. Sun, T.-E. Huang, and J. Lan, “Nontechnical losses detection through coordinated BiWGAN and SVDD,” *IEEE Trans. Neural Netw. Learn. Syst.*, vol. 32, no. 5, pp. 1866–1880, May 2021.
- [14] F. Shehzad, N. Javaid, A. Almogren, A. Ahmed, S. M. Gulfam, and A. Radwan, “A robust hybrid deep learning model for detection of non-technical losses to secure smart grids,” *IEEE Access*, vol. 9, pp. 128663–128678, 2021.
- [15] M. Asif, O. Nazeer, N. Javaid, E. H. Alkhamash, and M. Hadjouni, “Data augmentation using BiWGAN, feature extraction and classification by hybrid 2DCNN and BiLSTM to detect non-technical losses in smart grids,” *IEEE Access*, vol. 10, pp. 27467–27483, 2022.
- [16] Y. Huang and Q. Xu, “Electricity theft detection based on stacked sparse denoising autoencoder,” *Int. J. Electr. Power Energy Syst.*, vol. 125, Feb. 2021, Art. no. 106448.

- [17] N. Javaid, S. Javaid, M. Asif, M. U. Javed, A. S. Yahaya, and S. Aslam, "Synthetic theft attacks and long short term memory-based preprocessing for electricity theft detection using gated recurrent unit," *Energies*, vol. 15, no. 8, p. 2778, Apr. 2022.
- [18] J. Pereira and F. Saraiva, "A comparative analysis of unbalanced data handling techniques for machine learning algorithms to electricity theft detection," in *Proc. IEEE Congr. Evol. Comput. (CEC)*, Glasgow, U.K., Jul. 2020, pp. 1–8.
- [19] F. A. Bohani, A. Suliman, M. Saripuddin, S. S. Sameon, N. S. M. Salleh, and S. Nazeri, "A comprehensive analysis of supervised learning techniques for electricity theft detection," *J. Electr. Comput. Eng.*, vol. 2021, pp. 1–10, Jul. 2021.
- [20] S. K. Gunturi and D. Sarkar, "Ensemble machine learning models for the detection of energy theft," *Electr. Power Syst. Res.*, vol. 192, Mar. 2021, Art. no. 106904.
- [21] R. Xia, Y. Gao, Y. Zhu, D. Gu, and J. Wang, "An attention-based wide and deep CNN with dilated convolutions for detecting electricity theft considering imbalanced data," *Electr. Power Syst. Res.*, vol. 214, Oct. 2022, Art. no. 108886.
- [22] Z. Zheng, Y. Yang, X. Niu, H. Dai, and Y. Zhou, "Wide and deep convolutional neural networks for electricity-theft detection to secure smart grids," *IEEE Trans. Ind. Informat.*, vol. 14, no. 4, pp. 1606–1615, Apr. 2018.
- [23] M. G. Chuwa and F. Wang, "A review of non-technical loss attack models and detection methods in the smart grid," *Electr. Power Syst. Res.*, vol. 199, p. 378, Oct. 2021.
- [24] H. He, Y. Bai, E. A. Garcia, and S. Li, "ADASYN: Adaptive synthetic sampling approach for imbalanced learning," in *Proc. IEEE Int. Joint Conf. Neural Netw.*, Jun. 2008, pp. 1322–1328.
- [25] C. Shorten and T. M. Khoshgoftaar, "A survey on image data augmentation for deep learning," *J. Big Data*, vol. 6, no. 1, p. 60, Jul. 2019.
- [26] E. U. Haq, C. Pei, R. Zhang, H. Jianjun, and F. Ahmad, "Electricity-theft detection for smart grid security using smart meter data: A deep-CNN based approach," *Energy Rep.*, vol. 9, pp. 634–643, Mar. 2023.
- [27] S. Li, Y. Han, X. Yao, S. Yingchen, J. Wang, and Q. Zhao, "Electricity theft detection in power grids with deep learning and random forests," *J. Electr. Comput. Eng.*, vol. 2019, pp. 1–12, Oct. 2019.
- [28] A. A. Esmael, H. H. da Silva, T. Ji, and R. da Silva Torres, "Non-technical loss detection in power grid using information retrieval approaches: A comparative study," *IEEE Access*, vol. 9, pp. 40635–40648, 2021.
- [29] A. Tangborn, "Wavelet transforms in time series analysis," Global Modeling and Assimilation Office, Goddard Space Flight Center, Greenbelt, MD, USA, Tech. Rep., 301-614-6178, 2019.
- [30] R. Jiang, H. Tagaris, A. Lachs, and M. Jeffrey, "Wavelet based feature extraction and multiple classifiers for electricity fraud detection," in *Proc. IEEE/PES Transmiss. Distrib. Conf. Exhib.*, Yokohama, Japan, Apr. 2000, pp. 2251–2256.
- [31] N. Marwan, M. Carmenromano, M. Thiel, and J. Kurths, "Recurrence plots for the analysis of complex systems," *Phys. Rep.*, vol. 438, nos. 5–6, pp. 237–329, Jan. 2007.
- [32] *Keras Applications/Available Models*. Accessed: Mar. 19, 2023. [Online]. Available: <https://keras.io/api/applications/>
- [33] Z. Yan and H. Wen, "Performance analysis of electricity theft detection for the smart grid: An overview," *IEEE Trans. Instrum. Meas.*, vol. 71, pp. 1–28, 2022.
- [34] T. Hasanin and T. Khoshgoftaar, "The effects of random undersampling with simulated class imbalance for big data," in *Proc. IEEE Int. Conf. Inf. Reuse Integr. (IRI)*, Lake City, UT, USA, Jul. 2018, pp. 70–79.
- [35] C. Guo, Y. Ma, Z. Xu, M. Cao, and Q. Yao, "An improved over-sampling method for imbalanced data—SMOTE based on canopy and K-means," in *Proc. Chin. Automat. Congr. (CAC)*, Hangzhou, China, 2019, pp. 1467–1469.
- [36] V. S. Sheng, "Studying active learning in the cost-sensitive framework," in *Proc. 45th Hawaii Int. Conf. Syst. Sci.*, Maui, HI, USA, Jan. 2012, pp. 1097–1106.
- [37] (2020). *State Grid Corporation of China: New Energy Development Report*. [Online]. Available: <http://www.sgcc.com.cn/>
- [38] (2010). *CER Smart Metering Project—Electricity Customer Behaviour Trial*. [Online]. Available: <https://paperswithcode.com/paper/concept-for-automated-machine-learning-in/>
- [39] Open Energy Data Initiative (OEDI). (2022). *Theft Detection in Smart Grid Environment*. [Online]. Available: <https://data.mendeley.com/datasets/c3c7329tj/1>
- [40] J. Pereira and F. Saraiva, "Convolutional neural network applied to detect electricity theft: A comparative study on unbalanced data handling techniques," *Int. J. Electr. Power Energy Syst.*, vol. 131, Oct. 2021, Art. no. 107085.
- [41] M. Buzau, J. Tejedor-Aguilera, P. Cruz-Romero, and A. Gómez-Expósito, "Hybrid deep neural networks for detection of non-technical losses in electricity smart meters," *IEEE Trans. Power Syst.*, vol. 35, no. 2, pp. 1254–1263, Mar. 2020.
- [42] M. Anwar, N. Javaid, A. Khalid, M. Imran, and M. Shoaib, "Electricity theft detection using pipeline in machine learning," in *Proc. Int. Wireless Commun. Mobile Comput. (IWCMC)*, Limassol, Cyprus, 2020, pp. 2138–2142.



SUPAKAN JANTHONG received the B.Eng. degree in electrical engineering from the Prince of Songkla University, Songkhla, Thailand, in 2015. He is currently pursuing the M.Eng. degree. His research interests include data science, signal processing, deep learning, and power system analysis.



KUSUMAL CHALERMYANONT received the B.Eng. degree in electrical engineering from the Prince of Songkla University, Songkhla, Thailand, in 1993, and the M.Eng. and Ph.D. degrees in electrical engineering from the University of Colorado at Boulder, USA, in 1999 and 2003, respectively. She is currently an Assistant Professor with the Electrical Engineering Department, Faculty of Engineering, Prince of Songkla University. Her current research interests include power electronics, electric drives, renewable energy, and smart grids.



RAKKRIT DUANGSOITHONG received the B.Eng. degree in electrical engineering from Chiang Mai University, Thailand, in 1995, the M.Eng. degree in electrical engineering from the Prince of Songkla University, Songkhla, Thailand, in 2001, and the Ph.D. degree from the University of Surrey, Guildford, U.K., in 2013. He is currently an Assistant Professor with the Electrical Engineering Department, Faculty of Engineering, Prince of Songkla University. His current research interests include machine learning, computer vision, signal processing, and data analysis.

ภาคผนวก ข

ลักษณะการชำรุดจำแนกแยกเป็นรายการไฟฟ้าได้ทั้งหมด 20 รายการ ตามตารางที่ 1


ตารางที่ 1 ข้อมูลลักษณะการชำรุดประเภท 3P4W ทั้ง 20 รายได้ที่พบในการไฟฟ้าส่วนภูมิภาค

ที่	การไฟฟ้า	ขนาด CT	ลักษณะการชำรุด	สาเหตุการชำรุด
1.	กฟจ.ชุมพร	150/5	Voltage Unbalance	สายกราวด์ก่อนเข้ามิเตอร์เกิดจุดหลวม
2.	กฟย.บางสะพานน้อย	150/5 A.	VT Failure	พิวส์แรงสูงเฟส C ขาด
3.	กฟอ.จอมบึง	150/5 A.	Over Current	ตรวจสอบมิเตอร์สามารถวัดค่าได้ปกติ เบื้องต้นได้แนะนำให้ทางผู้ใช้ไฟดำเนินการบาลานซ์เฟส ก่อนหากมีการใช้ไฟหนักจริงๆ ก็แนะนำให้ทำเรื่องเพิ่มขนาดหม้อแปลง ป้องกันหม้อแปลงเครื่องเดิมทำงาน Over Load
4.	กฟจ.ชุมพร	150/5 A.	Asymmetric Power	ตรวจสอบพบ CT เฟส C ชำรุด มีการต่อตรงไว้โดยชุดแก่กระแสไฟฟ้า ได้ทำการแก้ไขโดยการเปลี่ยน CT
5.	กฟจ.สมุทรสงคราม	150/5 A.	Any Phase Current = 0	เนื่องจากปิดกิจการ จึงใช้ไฟเพียงแค่เฟสเดียว
6.	กฟส.ลิขล	150/5 A.	Voltage Unbalance	พิวส์ป้องกันไลน์ เฟส C ขาด ซื้อมาติดตั้งได้ดำเนินการแก้ไขแล้ว
7.	กฟจ.กระบี่	250/5 A.	Reverse Power	ตรวจสอบ มิเตอร์ทำงานปกติ ผขพ.ติดตั้ง Capacitor ในระบบ
8.	กฟส.ไชยา	250/5 A.	Over Current	ผขพ.ได้เพิ่มขนาดหม้อแปลง และได้ชำระเงินค่าใช้จ่ายเรียบร้อยแล้ว และกฟส.ได้ดำเนินการเปลี่ยนเครื่องวัดใหม่CTใหม่เรียบร้อยแล้ว
9.	กฟอ.ถลาง	250/5 A.	Any Phase Current = 0	ขณะทำการตรวจสอบพบว่าสายคอนโทรลชำรุด/และดำเนินการแก้ไขเรียบร้อยแล้ว ดำเนินการแจ้งแผนกบัญชีปรับปรุงค่าไฟเรียบร้อยแล้ว
10.	กฟย.ด่านนอก	150/5 A.	Voltage Unbalance	ตรวจสอบแรงดันไฟฟ้าจากเครื่องมือวัด (Clip-on kilowatt) เปรียบเทียบกับแรงดันไฟฟ้าจากมิเตอร์: พบว่า มิเตอร์ทำงานปกติ ตาม มต.ท.ม.5 ป.58 - ตรวจสอบ Fuse : พบว่า Fuse แรงสูงเฟส A ชำรุด **แจ้งส่วนเกี่ยวข้องเข้าดำเนินการแก้ไขเรียบร้อยแล้ว
11.	กฟจ.พัทลุง	400/5 A.	Reverse Power	แก้ไข capacitor เรียบร้อยแล้วเมื่อวันที่ 27/4/65 ค่า pf กลับมาปกติ


ตารางที่ 1 ข้อมูลลักษณะการชำรุดประเภท 3P4W ทั้ง 20 รายได้ที่พบในการไฟฟ้าส่วนภูมิภาค (ต่อ)

ที่	การไฟฟ้า	ขนาด CT	ลักษณะการชำรุด	สาเหตุการชำรุด
12.	กฟส.ควน ขนุน	150/5 A.	Any Phase Current = 0	มิเตอร์และ CT ปกติ พบไม่มีการใช้ Load ในเฟส C (กระแสC Primary = 0 A)
13.	กฟอ.ท่าศาลา	150/5 A.	Over Current	ขณะตรวจสอบใช้ไฟ เฟส B มากกว่า เฟส A B จริง และอุปกรณ์มิเตอร์ทำงานผิดปกติที่เฟสBอ่าน ค่ากระแสมากกว่าจากการตรวจสอบค่ากระแสไฟฟ้า จากเครื่องมือวัด (Clip-on kilowatt) เปรียบเทียบกับค่ากระแสไฟฟ้าที่อ่านได้จากมิเตอร์
14.	กฟอ.เกาะส มุย	150/5 A.	VT Failure	ทาง ผมต.กม ได้ดำเนินการตรวจสอบ ขณะ ตรวจสอบแรงดันไฟฟ้าปกติทั้ง 3 เฟส ผู้ใช้ไฟใช้โหลด ประมาณ 0.389 kw. การทำงานของมิเตอร์วัดได้ ประมาณ 0.393 kw. มิเตอร์ทำงานปกติ
15.	กฟส.สทิงพระ	250/5 A.	VT Failure	ขณะตรวจสอบแรงดันไฟฟ้าเฟส A B ผิดปกติ สาย control ชำรุด
16.	กฟส.สิงหนคร	400/5	VT Failure	แรงดันไฟฟ้าเฟส B ผิดปกติ สายcontrol ชำรุด
17.	กฟย.กระแส สินธุ์	150/5	VT Failure	แรงดันไฟฟ้าเฟส A B C ผิดปกติ สายcontrol ชำรุด
18.	กฟอ.ระโนด	250/5	Any Phase Current = 0	ค่ากระแสเฟส A B ผิดปกติ สายcontrol ชำรุด
19.	กฟจ.ยะลา	400/5	Any Phase Current = 0	ขณะตรวจสอบแรงดันไฟฟ้าเฟส C ผิดปกติ สาย control ชำรุด
20	กฟจ.ปัตตานี	250/5	Voltage Unbalance	ขณะตรวจสอบแรงดันไฟฟ้าเฟสBและ C ผิดปกติ


การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
1. กฟจ. ชุมพร	23/02/2022	17/03/2022	พบสายกราวด์ก่อนเข้ามิเตอร์เกิดจุดหลวม




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
2. กฟย. บางสะพานน้อย	14/03/2022	21/03/2022	พบสายกราวด์ก่อนเข้ามิเตอร์เกิดจุดหลวม




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
3.กฟส. ดำเนินสะดวก	06/02/2022	21/05/2022	พบผู้ใช้ไฟมีการติดตั้งคาปาซิเตอร์ร่วมกับระบบการใช้ไฟ




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
4. กฟอ. จอมบึง	28/04/2022	10/05/2022	ตรวจสอบมิเตอร์วัดค่าได้ปกติ ให้ทำเรื่องเพิ่มขนาดหม้อแปลง ป้องกันทำงาน Over Load




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
5. กฟจ. สมุทรสงคราม	10/01/2022	22/02/2022	เนื่องจากปิดกิจการ จึงใช้ไฟเพียงแค่เฟสเดียว




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
6. กฟส. สีชล	31/03/2022	18/04/2022	ฟิวส์ป้องกันไลน์ เฟส C ขาด ช้อตงูเขียว




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
7.กฟจ. กระบี่	23/01/2022	07/02/2022	ตรวจสอบ มิเตอร์ทำงานปกติ ผชฟ. ติดตั้ง Capacitor ในระบบ




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
8. กฟส. ไซยา	14/03/2022	28/04/2022	ผขฟ.ได้เพิ่มขนาดหม้อแปลง และได้ชำระเงินค่าใช้จ่ายเรียบร้อยแล้ว




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
9. กฟอ. กลาง	28/02/2022	24/03/2022	ขณะทำการตรวจสอบพบว่าสายคอนโทรลชำรุด




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
10. กฟย. ด่านนอก	27/03/2022	11/04/2022	ขณะทำการตรวจสอบพบว่า Fuse แรงสูงเฟส A ชำรุด




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
11. กฟจ. พัทลุง	27/02/2022	26/05/2022	เกิดจาก capacitor ทำให้เกิด Reverse Power




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
12. กฟส. ควนขนุน	16/03/2022	28/04/2022	มิเตอร์และ CT ปกติ พบไม่มีการใช้ Load ในเฟส C (กระแส C Primary = 0 A)




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
13. กฟอ. ท่าศาลา	11/10/2021	11/11/2021	ขณะตรวจสอบใช้ไฟ เฟส B มากกว่าเฟส A B จริง และอุปกรณ์มิเตอร์ทำงานผิดปกติ




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
14. กฟอ. เกาะสมุย	03/02/2021	16/04/2021	ขณะตรวจสอบแรงดันไฟฟ้าปกติทั้ง 3 เฟส




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
15. กฟส. สทิงพระ	15/01/2016	10/02/2016	ขณะตรวจสอบแรงดันไฟฟ้าเฟส A B ผิดปกติ สายcontrol ชำรุด




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
16. กฟส. สิงหนคร	15/03/2014	17/05/2014	แรงดันไฟฟ้าเฟส B ผิดปกติ สาย control ชำรุด




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
17 กพย. กระแสสินธ์	15/01/2016	10/02/2016	แรงดันไฟฟ้าเฟส A B C ผิดปกติ สาย control ชำรุด




การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
18. กฟอ. ระโนด	15/01/2016	10/02/2016	ค่ากระแสเฟส A B ผิดปกติ สาย control ชำรุด



การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
19. กฟจ. ยะลา	15/01/2016	10/02/2016	ขณะตรวจสอบแรงดันไฟฟ้าเฟส C ผิดปกติ สายcontrol ชำรุด



การไฟฟ้าที่พบ	วันที่เกิดความผิดปกติ	วันที่ปิดใบงาน	รายละเอียด
20. กฟจ. ปัตตานี	1/08/2020	30/09/2020	ขณะตรวจสอบแรงดันไฟฟ้าเฟสB และ C ผิดปกติ



ภาคผนวก ค

ลักษณะการละเมิดจำแนกแยกเป็นรายการไฟฟ้าได้ทั้งหมด 27 ราย ตามตารางที่ 1


ตารางที่ 1 ข้อมูลการละเมิดประเภท 3P4W ที่พบในการไฟฟ้าส่วนภูมิภาค

ที่	การไฟฟ้า	ขนาด CT	ลักษณะการละเมิด
1	กฟจ.ลำพูน	400/5	พบการละเมิดใช้ไฟฟ้า มีการตัดสายคอนโทรลชุดกระแสเฟส C (เส้นสีดำ)
2	กฟอ.สันป่าตอง	150/5	สายคอนโทรลเคเบิลสีดำ ปลายสายทองแดงของสายคอนโทรลเคเบิลถูกตัดขาดเหลือแค่ฉนวนหุ้มสาย
3	กฟส.บางมูลนาก	250/5	สายคอนโทรลสีขาวแถบดำที่เข้า CT ชุดที่ 2 ถูกหักตัวนำขาดออกจากกัน
4	กฟส.ชุมแสง	150/5	พบการมีการละเมิดโดยการดัดแปลงสายคอนโทรลชุดกระแส
5	กฟจ.ขอนแก่น	250/5	ผู้ใช้ไฟได้นำสายขนาด THW 16 ต.มม. และ ขนาด 25 ต.มม.มาต่อคร่อมสายเฟสทั้ง 3 ชุด มีผลทำให้โหลดผิดปกติ ซึ่งเป็นการละเมิดการใช้ไฟฟ้า
6	กฟจ.ขอนแก่น 2 (มะลิวัลย์)	250/5	จากการตรวจสอบสายคอลโทรลเคเบิลสีดำซึ่งต่อจากแรงดันจากสายเมนเฟสที่ไปเข้ามิเตอร์สายทองแดงถูกหัก จากกันมีผลทำให้มิเตอร์ชุดที่ 2 ไม่ทำงานได้ทำการแก้ไขแล้ว
7	กฟจ.ยโสธร	400/5	มีการละเมิดโดยใช้กาวหยอดที่ขั้วสายคอนโทรลเพื่อให้กระแสไหลน้อย
8	กฟจ.ร้อยเอ็ด	250/5	สายคอนโทรลเคเบิลสีดำแทบซึ่งต่อจาก ซีที.ไปเข้าเคเร็นท์คอล์ยชุดที่ 3 ของมิเตอร์ ถูกตัดขาด ทำให้มิเตอร์ชุดที่ 3 ไม่ทำงาน (ละเมิด)
9	กฟส.ครบุรี	150/5	ตรวจสอบพบว่ามีการตัดสายนิลตรอลออกจากระบบ ทำให้แรงดันไฟฟ้าหายไปทั้ง 3 เฟส
10	กฟจ.สระบุรี	400/5	ดัดแปลง/แก้ไขสายคอนโทรล (ไม่มีรายละเอียด)
11	กฟภ.รังสิต	400/5	ละเมิดตัดสายคอนโทรล แก้ไขอำพรางไว้
12	กฟอ.คลองหลวง	250/5	ตรวจพบตราตะกั่วฝากรอบซีที.แรงต่ำเฟส B,C มีร่องรอยจัดแ่งและเมื่อเปิดดูพบปลายสายคอนโทรลถูกหุ้มด้วยฉนวน
13	กฟอ.คลองหลวง	400/5	สายคอนโทรลเคเบิลเส้นสีแดง ซึ่งต่อกระแสจากซีที.แรงต่ำ มาเข้าเคเร็นท์คอล์ย ชุดที่ 3 ของมิเตอร์ ปลายสายลวดทองแดงถูกตัดขาดจากกัน
14	กฟอ.คลองหลวง	400/5	ตราตะกั่วฝากรอบซีที.แรงต่ำเฟส B มีร่องรอยจัดแ่งและเมื่อเปิดดูพบสายคอนโทรลถูกปลดออกจากขั้วต่อสายซีที.เฟส B
15	กฟจ.จันทบุรี	400/5	พบมิเตอร์ละเมิด จัดตราตะกั่ว และหยอดกาวที่ลิมิตสวิตซ์ให้ค้างสถานะปิด มีร่องรอยการถอดสายแรงดันออก
16	กฟส.ชลบุรี	400/5	มีการละเมิดการใช้ไฟ โดยตัดสายคอนโทรลกระแส เฟส B
17	กฟอ.สอยดาว	400/5	ตัดกระแสชุด 1 และ 3 ถูกตัดสายเข้าเทอร์มินอร์มิเตอร์
18	กฟส.ไทรโยค	400/5	ผู้ใช้ไฟละเมิดตัดสายคอนโทรล กระแส เฟส บี
19	กฟจ.สมุทรสาคร	150/5	มีสายทองแดงต่อคร่อม ซีที ทั้ง 3เฟส มิเตอร์ละเมิด
20	กฟภ.อ้อมน้อย	400/5	มีการตัดชุดแรงดันชุดที่ 2 ออก 1 ชุด


ตารางที่ 1 ข้อมูลการละเมิดประเภท 3P4W ที่พบในการไฟฟ้าส่วนภูมิภาค (ต่อ)

ที่	การไฟฟ้า	ขนาด CT	ลักษณะการละเมิด
21	กฟส.พุทธมณฑล	150/5	ตรวจพบหักสายซีทีเฟส c สีดำ-แดง ได้ดำเนินการแก้ไขโดยตัดต่อสายคอนโทรลใหม่
22	กฟอ.หลังสวน	250/5	มีการจัดแ่งและบีบอำพรางไว้ น๊อตเทอร์มินอลสายสีเทา เฟส B หลวมไม่สนิท
23	กฟจ.ภูเก็ต	150/5	การละเมิดการใช้ไฟฟ้า โดยการใช้กาวหรือซิลิโคนทาทำเป็นฉนวนหุ้มปลายสายทองแดงของสายคอนโทรลสีเขียวที่ต่อจากซีทีเข้ามิเตอร์ชุดที่ 1 (เฟส A) แล้วขันสกรูปิดอำพรางไว้
24	กฟจ.ภูเก็ต	250/5	โดยการใช้ฉนวนหุ้มปลายสายทองแดงของสายคอนโทรลสีเขียวที่ต่อจากซีทีเข้ามิเตอร์ชุดที่ 1 (เฟส A) แล้วขันสกรูปิดอำพรางไว้
25	กฟอ.กลาง	150/5	สายคอนโทรลชุดกระแส(สีเขียว)หลุดออกจากขั้วต่อสายและมีรอยตัดสงสัยว่ามีการกระทำจากบุคคล
26	กฟภ.ป่าตอง	250/5	ละเมิดโดยตัดสายคอนโทรลเส้นสีส้มขาดจากกัน
27	กฟอ.สุโขทัย	400/5	โดยสายคอนโทรลเคเบิลสีสีแดงซึ่งต่อจากซี.ที. ไปเข้าเคอร์เร็นท์คอยล์ชุดที่ 3 ของมิเตอร์ สายทองแดงภายในถูกหักขาดจากกัน และมีการหยอดกาวขั้วต่อสาย ซี.ที ทำให้ ซี.ที. ขำรูดและมิเตอร์ชุดที่ 3 ไม่ทำงาน


การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
1. กฟจ. ลำพูน	Jan 2017 – Mar 2017 Nov 2018 – Dec 2018	Apr 2017 - Oct 2018	พบการละเมิด กระทำการตัดสายคอนโทรลชุดกระแสเฟส C (เส้นสีดำ)




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
2.กฟอ. สันป่าตอง	Jan 2015– Feb 2015	Mar 2015 - Oct 2015	สายคอนโทรลเคเบิลสีดำ ปลายสายทองแดงของสายคอนโทรลถูกตัดขาด เหลือแค่ฉนวนหุ้มสาย




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
3.กฟส. บางมูลนาก	May 2016 - Nov 2017 Feb 2017- Mar 2017	Dec 2016 - Jan 2017	สายคอนโทรลลีสี่ขาขนาดต่ำที่เข้า CT ชุดที่ 2 ถูกหักตัวนำขาดออกจากกัน




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
4.กฟส. ชุมแสง	Jan 2017- Jun 2017	Jul 2017 - Aug 2017	พบการมีการละเมิดโดยการตัดแปลงสายคอนโทรลชุดกระแสทั้ง 3 เฟส




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
5.กฟข. ขอนแก่น	Jan 2016- Jul 2016	Aug 2016 -Sep 2016	ผู้ใช้ไฟได้นำสายขนาด THW 16 ต.มม. และ ขนาด 25 ต.มม.มาต่อ คร่อมสายเฟสทั้ง 3 ชุด มีผลทำให้ โหลดผิดปกติ




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
6.กฟจ. ขอนแก่น 2 (มะลิวัลย์)	Jun 2014-Sep 2014 Dec 2014-Jun 2015	Oct 2014 - Nov 2014	พบสายคอลโทรลเคเบิลสีดำชุด แรงดันจากสายเมนเฟสเข้ามิเตอร์ สายทองแดงถูกหักทำให้มิเตอร์ชุดที่ 2 ไม่ทำงาน




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาที่ละเมิด	รายละเอียด
7.กฟง. ยโสธร	Jan 2018-Api 2018 Sep 2018-Dec 2018	May 2018 - Aug 2018	มีการละเมิดโดยใช้กาวหยอดที่ชั่วสาย คอนโทรลเพื่อให้กระแสไหลน้อย




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาที่ละเมิด	รายละเอียด
8.กฟง. ร้อยเอ็ด	Jan 2016-Oct 2016	Nov 2016 - Dec 2016	สายคอนโทรลเคเบิลสปีดต่ำแบบซึ่งต่อจากซีที.ไปเข้าเคเร็นท์คอลย์ชุดที่ 3 ถูกตัดขาด ทำให้มิเตอร์ชุดที่ 3 ไม่ทำงาน




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
9.กฟส. นครบุรี	Jan 2015- May 2015 Sep 2015- Dec 2015	Jun 2015 - Aug 2015	ตรวจสอบพบว่ามีการตัดสายนิลตรอลออกจากระบบ ทำให้แรงดันไฟฟ้าหายไปทั้ง 3 เฟส




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
10.กฟจ. สระบุรี	Jan 2016-Oct 2016	Jul 2015 - Aug 2015	ดัดแปลง/แก้ไขสายคอนโทรลชุดแรงดันเฟส A




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
11.กฟภ.รังสิต	Aug 2015-Dec 2015	Jan 2015 - May 2015	ละเมิดตัดสายคอนโทรล แก้วไขำ พรางไว้




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
12.กฟอ. คลองหลวง	Sep 2013-Dec 2013	Mar 2013 - Aug 2013	ตรวจพบอัตราค่าไฟฟ้ารอบซีที.แรงต่ำ เฟส B,C มีร่องรอยจัดแ่งและพบปลายสายคอนโทรลถูกหุ้มด้วยฉนวน




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาที่ละเมิด	รายละเอียด
13.กฟอ. คลองหลวง	Aug 2013-Dec 2013	Jan 2013 - Jul 2013	สายคอนโทรล ซึ่งต่อกระแสจากซีที. แรงต่ำชุดที่ 3 ของมิเตอร์ ปลายสาย ลวดทองแดงถูกตัดขาดจากกัน




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
14.กฟอ. คลองหลวง	Jul 2013-Aug 2013	Aug 2012 - Jul 2013	ตราตะกั่วฝากรอบซีที.แรงต่ำเฟส B มีร่องรอยงัดแงะและพบสายคอนโทรลถูกปลดออกจากขั้วต่อสายซีที.เฟส B




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
15.กฟจ. จันทบุรี	Jan 2014-Jul 2014	Aug 2014 - Sep 2014	พบมิเตอร์ละเมิด จัดตราตะกั่ว และ หยุดการที่ลิมิตสวิตซ์ให้ค้างสถานะปิด มีร่องรอยการถอดสายแรงดันออก




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
16.กฟส. ชลบุรี	Jan 2014-Feb 2014 Jul 2014-Dec 2014	Mar 2014 - Jun 2014	มีการละเมิดการใช้ไฟ โดยตัดสายคอนโทรลกระแส เฟสB




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
17.กฟอ. สอยดาว	Mar 2013-Apr 2013 Apr 2014-May 2014	May 2013 - Mar 2014	ตัดกระแสชุด 1 และ 3 ถูกตัดสาย เข้าเทอร์มินัลมิเตอร์




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
18.กฟส. ไทรโยค	Mar 2014-Oct 2014	Nov 2014 - Feb 2015	ผู้ใช้ไฟละเมิดตัดสายคอนโทรล กระแส เฟส บี




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
19.กฟง. สมุทรสาคร	Feb 2014-May 2014	Dec 2013 - Jan 2014	มีสายทองแดงต่อคร่อม ซีที ทั้ง 3 เฟส มิเตอร์ละเมิด




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
20.กฟภ.อ้อมน้อย	Mar 2014-Feb 2014 Apr 2014-May 2014	Mar 2015 - Mar 2015	มีการตัดชุดแรงดันชุดที่ 2 ออก 1 ชุด




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาที่ละเมิด	รายละเอียด
21.กฟส. พุทธิ มณฑล	Mar 2013-Apr 2013 Apr 2014-May 2014	May 2013 - Mar 2014	ตรวจพบหักสายซีทีเฟส c สีดำ-แดง ได้ดำเนินการแก้ไขโดยตัดต่อสาย คอนโทรลใหม่




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
22.กฟอ. หลังสวน	Feb 2015-Jun 2015	Jul 2015 - Sep 2015	มีการจัดแ่งและบีบอำพรางไว้ น้อย เทอร์มินอลสายสีเทา เฟส B หลวม ไม่สนิท




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
23.กฟจ. ภูเก็ต	Mar 2013-Jul 2013	Aug 2013 - Oct 2014	ใช้กาวหรือซิลิโคนทาทำเป็นฉนวนหุ้มปลายสายทองแดงสายคอนโทรลชุดที่ 1 (เฟส A) แล้วชั้นสกรูปิดอำพรางไว้




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
24.กฟจ. ภูเก็ต	Jan 2016-Sep 2016	Oct 2016 - Dec 2016	ใช้ฉนวนหุ้มปลายสายทองแดงของสายคอนโทรลสีเขียวที่ต่อเข้ามิเตอร์ชุดที่ 1 (เฟส A) แล้วขันสกรูปิดอำพรางไว้




การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
25.กฟอ. กลาง	Jun 2014- Oct 2014	Jan 2014 - Jan 2014	สายคอนโทรลชุดกระแส(สีเขียว) หลุดออกจากขั้วต่อสายและมีรอย ตัดสงสัยว่ามีการกระทำจากบุคคล



การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
26.กฟภ.ป่าตอง	Mar 2014-Jun 2014	Jul 2013 - Feb 2014	ละเมิดโดยตัดสายคอนโทรลเส้นสีส้ม ขาดจากกัน



การไฟฟ้าที่พบ	ช่วงเวลาปกติ	ช่วงเวลาละเมิด	รายละเอียด
27.กฟอ. สุโขทัย-ลพ	Mar 2014-Oct 2014	Jan 2014 - Feb 2014	โดยสายคอนโทรลเคเบิลสี่สีแดงซึ่งต่อจากซี.ที. ถูกหักขาดจากกัน หยอดควาชั่วคราวสาย ซี.ที ทำชุดที่ 3 ไม่ทำงาน



ประวัติผู้เขียน

ชื่อ สกุล นายศุภกาญจน์ จันทร์ทอง

รหัสประจำตัวนักศึกษา 6410120056

วุฒิการศึกษา

วุฒิ	ชื่อสถาบัน	ปีที่สำเร็จการศึกษา	
	วิศวกรรมศาสตร์บัณฑิต (วิศวกรรมไฟฟ้า)	มหาวิทยาลัยสงขลานครินทร์	2558

ทุนการศึกษา

1. ทุนโครงการความร่วมมือทางวิชาการระหว่าง กฟผ. กับคณะวิศวกรรมศาสตร์ มหาวิทยาลัยสงขลานครินทร์

ตำแหน่งและสถานที่ทำงาน

วิศวกรระดับ 5 แผนกมิเตอร์ การไฟฟ้าส่วนภูมิภาคอำเภอระโนด จังหวัดสงขลา

การตีพิมพ์เผยแพร่ผลงาน

ได้รับการยอมรับและเผยแพร่ 3 รายการ

การประชุมวิชาการระดับชาติ

1. Supakan Janthong, Kusumal Chalermyanont and Rakkrit Duangsoithong, "Anomaly Pattern Analytics Based on Visualization for Non-Technical Losses in Automatic Meter Reading", PEACON & Innovation 2022: PEA Digital Utility for Sustainable Electricity Utility in VUCA World, Bangkok Thailand, pp. 67-72. 2022.

การประชุมวิชาการระดับนานาชาติ

2. S. Janthong, K. Chalermyanont and R. Duangsoithong, "Comparison of Feature Extraction Methods for Classifying Energy Theft and Defective Meters in Automatic Meter Reading," 2023 International Electrical Engineering Congress (iEECON), Krabi, Thailand, 2023, pp. 49-53, doi: 10.1109/iEECON56657.2023.10127065.

วารสารระดับนานาชาติ

6. S. Janthong, K. Chalermyanont and R. Duangsoithong, "Unbalanced Data Handling Techniques for Classifying Energy Theft and Defective Meters in the Provincial Electricity Authority of Thailand," in IEEE Access, vol. 11, pp. 46522-46540, 2023, doi: 10.1109/ACCESS.2023.3274543.

อยู่ระหว่างการตรวจทาน 2 รายการ

วารสารระดับนานาชาติ

7. Supakan Janthong, Kusumal Chalermyanont and Rakkrit Duangsoithong, "Imaging Time-Series to Classify Energy Theft and Defective Meters in Automatic Meter Reading Using Convolutional Neural Networks", Sustainable Energy, Grids and Networks journals, 2023, (Under review status: May 1, 2023).

วารสารระดับนานาชาติ

8. Supakan Janthong, Kusumal Chalermyanont and Rakkrit Duangsoithong, "Feature Engineering of Risk Group and Electricity Theft by Applying Domain Knowledge for Classification using Supervised Learning", ECTI-CIT (Under review status: May 20, 2023).