

การพัฒนาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ
โดยการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก

IMPROVING NON-INTRUSIVE LOAD MONITORING SYSTEM USING
DEEP LEARNING TECHNIQUE

สรายุทธ์ แยมประยูร

ดุขฎฐินิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิศวกรรมศาสตรดุขฎฐินิพนธ์บัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า
คณะวิศวกรรมศาสตร์

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

ปีการศึกษา 2564

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

การพัฒนาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ
โดยการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก

สรายุทธ์ แยมประยูร

ดุษฎีนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรดุษฎีบัณฑิต สาขาวิชาวิศวกรรมไฟฟ้า
คณะวิศวกรรมศาสตร์

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

ปีการศึกษา 2564

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

วิทยานิพนธ์ฉบับนี้เป็นงานวิจัยที่เกิดจากการค้นคว้าและวิจัย ขณะที่ข้าพเจ้าศึกษาอยู่ในคณะ
วิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี ดังนั้นงานวิจัยในวิทยานิพนธ์ฉบับนี้ถือเป็น
ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี และข้อความต่าง ๆ ในวิทยานิพนธ์ฉบับนี้ ข้าพเจ้า
ขอรับรองว่าไม่มีการคัดลอกหรือนำงานวิจัยของผู้อื่นมานำเสนอในชื่อของข้าพเจ้า

This thesis consists of research materials conducted at the Faculty of
Engineering, Rajamangala University of Technology Thanyaburi and hence the copyright
owner I hereby certify that the thesis does not contain any forms of plagiarism.

.....
(สรายุทธ์ แยมประยูร)



หัวข้อวิทยานิพนธ์

การพัฒนาระบบตรวจจับสถานะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำโดยการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก

Improving Non-Intrusive Load Monitoring System Using Deep Learning Technique

ชื่อ - นามสกุล

นายสรายุทธ์ แยมประยูร

สาขาวิชา

วิศวกรรมไฟฟ้า

อาจารย์ที่ปรึกษา

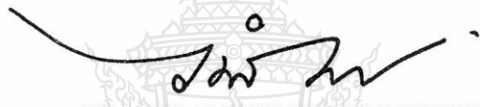
ผู้ช่วยศาสตราจารย์จักรี ศรีนนท์ฉัตร, Ph.D.


ปีการศึกษา

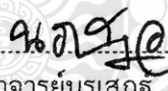
2564

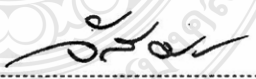
คณะกรรมการสอบวิทยานิพนธ์


..... ประธานกรรมการ
(รองศาสตราจารย์สมเกียรติ อุดมทรรษากุล, Ph.D.)



..... กรรมการ
(ผู้ช่วยศาสตราจารย์อำนาจ เรืองวารี, Dr.-Ing.)


..... กรรมการ
(อาจารย์วิเชียร อุปแก้ว, Ph.D.)


..... กรรมการ
(ผู้ช่วยศาสตราจารย์นรเสฏฐ์ วิชัยพาณิชย์, วศ.ด.)


..... กรรมการ
(ผู้ช่วยศาสตราจารย์จักรี ศรีนนท์ฉัตร, Ph.D.)

คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี อนุมัติวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต


.....
(รองศาสตราจารย์สรพงษ์ ภาสุปรีย์, Ph.D.)

วันที่ 23 เดือน มีนาคม พ.ศ. 2565

หัวข้อคุณิพนธ์	การพัฒนาาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ โดยการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก
ชื่อ - นามสกุล	นายสรายุทธ์ แยมประยูร
สาขาวิชา	วิศวกรรมไฟฟ้า
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์จักรี ศรีนนท์ฉัตร, Ph.D.
ปีการศึกษา	2564

บทคัดย่อ

ในปัจจุบันการพัฒนาาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ (Non-Intrusive Load Monitoring: NILM) เป็นสิ่งที่สำคัญและท้าทายสำหรับระบบบริหารจัดการด้านพลังงานและนำไปสู่การสร้างมิเตอร์อัจฉริยะ ทั้งนี้การออกแบบระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำจำเป็นอย่างยิ่งที่จะต้องเก็บข้อมูลจำนวนมากของคุณลักษณะเฉพาะของอุปกรณ์ไฟฟ้าเพื่อนำมาวิเคราะห์ ในการออกแบบระบบจึงจำเป็นต้องอาศัยเครื่องมือและเทคนิคการประมวลผลที่รวดเร็วและแม่นยำในการวิเคราะห์และตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ งานวิจัยนี้นำเสนอการพัฒนาาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำโดยการประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกโดยอาศัยการประมวลสัญญาณในสภาวะสัญญาณทรานเซียนส์เท่านั้น

ในการศึกษาและพัฒนาาระบบที่นำเสนอนี้ได้แบ่งออกเป็น 3 ส่วนคือ 1) การออกแบบวงจรควบคุมกระแสและแรงดันร่วมกับอุปกรณ์ลอจิกแบบโปรแกรม (Field-programmable gate array: FPGA) 2) การเปลี่ยนแปลงลักษณะข้อมูลแบบเคอร์โทแกรม และ 3) การปรับปรุงโครงข่ายของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน ระบบที่ออกแบบได้ทำการทดสอบกับอุปกรณ์ไฟฟ้าจำนวน 5 ชนิดในสภาวะการทำงานของเครื่องใช้ไฟฟ้าที่ละตัวและพร้อมกัน (2 ชนิด 3 ชนิด และ 4 ชนิด)

เทคนิคของ F1-score และ Recall ถูกนำมาใช้ในการวัดประสิทธิภาพของระบบที่ออกแบบ ผลการทดลองพบว่า ระบบสามารถให้ประสิทธิภาพสูงสุดในการแยกแยะอุปกรณ์ไฟฟ้าในขณะที่กำลังเริ่มทำงาน หนึ่งชนิด สองชนิด สามชนิด และ สี่ชนิด ที่ร้อยละ 100, 99.95, 99.95 และ 99.85 และใช้เวลา น้อยสุดในการประมวลผลที่ 05.29, 05.35, 05.30 และ 05.12 นาที่ตามลำดับ

คำสำคัญ: ตรวจรู้สภาวะโหลดแบบไม่ล่วงล้ำ อุปกรณ์ลอจิกแบบโปรแกรม การเรียนรู้เชิงลึก

Dissertation Title Improving Non-Intrusive Load Monitoring System
 Using Deep Learning Technique

Name-Surname Mr. Sarayut Yaemprayoon

Program Electrical Engineering

Dissertation Advisor Assistant Professor Jakkree Srinonchat, Ph.D.

Academic Year 2021

ABSTRACT

The development of Non-Intrusive Load Monitoring (NILM) is recently a key challenge for energy management systems and intelligent meters design. Designing a NILM is imperative to collect large amounts of electrical appliances characteristics for analysis, and system design requires fast and accurate processing tools and techniques for non-intrusive analysis and detection of electrical load conditions. This research presents the development of a NILM system by applying deep learning techniques based on the inrush current signal processing under transient signal condition only.

The study and development of the proposed system are divided into three parts: 1) design of current and voltage control circuits with a field-programmable gate array (FPGA), 2) data pre-processing with the kurtogram technique, and 3) development of a convolutional neural network (CNN). The designed system was tested on five different electrical appliances while working individually and simultaneously (two types, three types, and four types).

F1-score and Recall techniques were applied to evaluate the efficiency of the proposed system. The results showed that the system provided the maximum efficiency to classify appliances while working individually and simultaneously at 100, 99.95, 99.95 and 99.85%, and timeless processing at 05.29, 05.35, 05.30 and 05.12 min, respectively.

Keywords: non-intrusive load monitoring, field-programmable gate array, deep learning

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยความช่วยเหลือเป็นอย่างดีจากผู้ช่วยศาสตราจารย์ ดร.จักรี ศรีนนท์ฉัตร อาจารย์ที่ปรึกษาวิทยานิพนธ์ และคณาจารย์ในภาควิชาวิศวกรรมอิเล็กทรอนิกส์และโทรคมนาคม ซึ่งได้ให้คำแนะนำ ข้อคิดเห็น และ แนวทางการแก้ปัญหา รวมถึงสนับสนุนในการทำวิทยานิพนธ์ตลอดมา ผู้จัดทำวิจัยขอกราบขอบพระคุณมา ณ ที่นี้

ขอขอบคุณ รุ่งพี เพื่อน และน้องนักศึกษาที่ห้องปฏิบัติการและวิจัยทางด้านการประมวลผลสัญญาณที่ให้ความช่วยเหลือ แนะนำ และ ข้อคิดเห็นต่างๆ ตลอดจนการทำวิจัยเป็นอย่างดี

สุดท้ายนี้ผู้จัดทำวิจัยขอกราบขอบพระคุณ บิดา มารดาที่ให้การสนับสนุนแก่ผู้ทำวิจัยเสมอมา จนสำเร็จการศึกษา

สรายุทธ์ แยมประยูร



สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	(3)
บทคัดย่อภาษาอังกฤษ.....	(4)
กิตติกรรมประกาศ.....	(5)
สารบัญ.....	(6)
สารบัญ (ต่อ).....	(7)
สารบัญตาราง.....	(8)
สารบัญรูป.....	(9)
สารบัญรูป (ต่อ).....	(10)
บทที่ 1 บทนำ.....	11
1.1 ความเป็นมาและความสำคัญ.....	11
1.2 วัตถุประสงค์ของการศึกษา.....	12
1.3 ขอบเขตของการศึกษา.....	12
1.4 คำจำกัดความในการวิจัย.....	12
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	12
บทที่ 2 ทฤษฎีการวิจัยและงานวิจัยที่เกี่ยวข้อง.....	13
2.1 การตรวจรู้สภาวะโหลตทางไฟฟ้าแบบไม่ล่งล้า.....	13
2.2 ประเภทของอุปกรณ์ใช้ไฟฟ้าและการเข้าถึงอุปกรณ์ใช้ไฟฟ้า.....	16
2.3 สเปกตรัมเคอร์โทแกรม.....	19
2.4 การเรียนรู้เชิงลึก.....	20
2.5 งานวิจัยที่เกี่ยวข้อง.....	25
บทที่ 3 วิธีดำเนินการวิจัย.....	31
3.1 ขั้นตอนการทำงานของ การตรวจรู้สภาวะโหลตแบบไม่ล่งล้าโดยการเรียนรู้เชิงลึก.....	31
3.2 การออกแบบและการตรวจวัดอุปกรณ์ใช้ไฟฟ้าด้วยไมโครคอนโทรลเลอร์.....	32
3.3 การออกแบบและการตรวจรู้สภาวะโหลตแบบไม่ล่งล้าด้วยการวิเคราะห์แบบไบนารี.....	36
3.4 การตรวจรู้สภาวะโหลตแบบไม่ล่งล้าด้วยการเรียนรู้เชิงลึกแบบคอนโวลูชัน.....	39
3.5 การทดลองด้วย AlexNet สำหรับข้อมูลเคอร์โทแกรม.....	53
3.6 การทดลองด้วย Deep C-NN และการเปรียบเทียบผลการทดลอง.....	56

สารบัญ (ต่อ)

	หน้า
บทที่ 4 ผลการวิเคราะห์ข้อมูล.....	57
4.1 ผลการวัดสัญญาณไฟฟ้า.....	57
4.2 ผลการตรวจรู้สภาวะไหลด้วยอุปกรณ์ลอจิกแบบโปรแกรมบนพื้นฐานเทคนิคไบนารี	58
4.3 ผลการวิเคราะห์ข้อมูล.....	61
4.4 ผลการทดสอบโมเดลการเรียนรู้เชิงลึกแบบคอนโวลูชัน.....	62
4.5 ผลการปรับปรุงโครงข่ายคอนโวลูชันบนพื้นฐานของ VGG.....	66
4.6 ผลการทดลองด้วย AlexNet สำหรับการทำงานแบบเปิด-ปิด.....	69
4.7 ผลการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึก.....	71
บทที่ 5 สรุปผลการวิจัย และ ข้อเสนอแนะการวิจัย.....	73
5.1 สรุปผลการวิจัย.....	73
5.2 ข้อเสนอแนะการวิจัย.....	73
บรรณานุกรม.....	75
ภาคผนวก.....	82
ภาคผนวก ก ผลการตรวจรู้สภาวะไหลแบบไม่ล่วงล้ำ.....	83
ภาคผนวก ข งานวิจัยที่เผยแพร่.....	90
ประวัติผู้เขียน.....	96

สารบัญตาราง

	หน้า
ตารางที่ 2.1 การเปรียบเทียบระหว่างชุดข้อมูลความถี่ต่ำ.....	17
ตารางที่ 2.2 การเปรียบเทียบระหว่างชุดข้อมูลความถี่สูง.....	17
ตารางที่ 2.3 การเปรียบเทียบชุดข้อมูลภาพ.....	18
ตารางที่ 3.1 การตรวจรู้ด้วยเทคนิคแบบไบนารี.....	38
ตารางที่ 3.2 ตัวอย่างลักษณะรูปคลื่นไซน์ของอุปกรณ์.....	41
ตารางที่ 3.3 ข้อมูลของอุปกรณ์ทางไฟฟ้าแบบเคอร์โตแกรม.....	43
ตารางที่ 3.4 ข้อมูลแบบเคอร์โตแกรม.....	43
ตารางที่ 3.5 พารามิเตอร์และลำดับชั้นของโมเดลที่ 6, 7, 8, 9 และ โมเดลที่ 10.....	52
ตารางที่ 4.1 ประสิทธิภาพการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและประสิทธิภาพ การทดสอบของโมเดลที่ 1.....	62
ตารางที่ 4.2 ประสิทธิภาพการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและประสิทธิภาพ การทดสอบของโมเดลที่ 2.....	63
ตารางที่ 4.3 ประสิทธิภาพการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและประสิทธิภาพ การทดสอบของโมเดลที่ 3.....	64
ตารางที่ 4.4 ประสิทธิภาพการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและประสิทธิภาพ การทดสอบของโมเดลที่ 4.....	65
ตารางที่ 4.5 ประสิทธิภาพการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและประสิทธิภาพ การทดสอบของโมเดลที่ 5.....	66
ตารางที่ 4.6 ประสิทธิภาพการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและประสิทธิภาพ การทดสอบของโมเดลที่ 6, 7, 8, 9 และ โมเดลที่ 10.....	67
ตารางที่ 4.7 ประสิทธิภาพของการตรวจรู้.....	68
ตารางที่ 4.8 ผลการฝึกฝนด้วยโมเดล AlexNet.....	70
ตารางที่ 4.9 ผลการทดสอบตรวจรู้โหนดด้วย AlexNet.....	71
ตารางที่ 4.10 ผลการฝึกฝน Deep C-NN ด้วยการถ่ายโอนการเรียนรู้.....	72
ตารางที่ 4.11 ผลเวลาการฝึกฝน Deep C-NN ด้วยการถ่ายโอนการเรียนรู้.....	72

สารบัญรูป

	หน้า
รูปที่ 2.1 พื้นฐานของระบบตรวจรู้กำลังไฟฟ้า.....	14
รูปที่ 2.2 ผลของการตรวจรู้ค่ากำลังงาน.....	15
รูปที่ 2.3 ประสิทธิภาพการตรวจรู้และผลคาดการณ์การใช้ไฟฟ้าของแต่ละอุปกรณ์.....	16
รูปที่ 2.4 ภาพเคอร์โทแกรม.....	19
รูปที่ 2.5 โครงข่ายประสาทเทียม.....	20
รูปที่ 2.6 ฟังก์ชันการแปลง.....	21
รูปที่ 2.7 การประมวลผลของโครงข่ายประสาทเทียม.....	21
รูปที่ 2.8 การฝึกฝนประสาทเทียม.....	22
รูปที่ 2.9 ชั้นคอนโวลูชัน.....	23
รูปที่ 2.10 การเรียนรู้ของโมเดล.....	25
รูปที่ 2.11 การวิเคราะห์โครงสร้างของเส้นกราฟ.....	27
รูปที่ 2.12 ประสิทธิภาพของ C-NN ร่วมกับ R-NN และ LSTM.....	27
รูปที่ 2.13 โครงข่ายประสาทเทียมแบบ C-NN ร่วมกับ GLU.....	28
รูปที่ 2.14 โครงข่าย C-NN จำนวน 18 ชั้น.....	29
รูปที่ 2.15 โครงข่าย C-NN แบบ 1 มิติ.....	29
รูปที่ 2.16 โครงข่าย BiLSTM.....	30
รูปที่ 3.1 การดำเนินการวิจัย.....	31
รูปที่ 3.2 แผนผังการออกแบบการตรวจรู้โหลดด้วยไมโครคอนโทรลเลอร์.....	32
รูปที่ 3.3 บล็อกไดอะแกรม.....	33
รูปที่ 3.4 การต่อไอซีวัดพลังงาน CS5490 กับ PIC32.....	34
รูปที่ 3.5 วงจรไอซีวัดพลังงาน CS5490.....	34
รูปที่ 3.6 (A) ภาคจ่ายไฟ (B) วงจรไอซีวัดพลังงาน (C) Voltage Divider Sensor Current Sensor	35
รูปที่ 3.7 ออกแบบ PCB ของไอซีวัดพลังงาน CS5490.....	36
รูปที่ 3.8 การออกแบบระบบตรวจรู้โหลดแบบไม่ล่วงล้ำ.....	36
รูปที่ 3.9 ภาพรวมของการต่ออุปกรณ์ใช้ไฟฟ้าร่วมกับเพาเวอร์มิเตอร์.....	37
รูปที่ 3.10 การทำงานของอุปกรณ์ลอจิกแบบโปรแกรม.....	37
รูปที่ 3.11 การดำเนินการตรวจรู้สถานะโหลดแบบไม่ล่วงล้ำด้วยการเรียนรู้เชิงลึกแบบคอนโวลูชัน.....	39

สารบัญรูป (ต่อ)

	หน้า
รูปที่ 3.12 วงจรควบคุมระดับสัญญาณและ PCB ของวงจร.....	40
รูปที่ 3.13 การออกแบบวงจรภายใน FPGA โดยใช้โปรแกรม Quartus II.....	41
รูปที่ 3.14 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 1.....	44
รูปที่ 3.15 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 2.....	45
รูปที่ 3.16 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 3.....	46
รูปที่ 3.17 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 4.....	47
รูปที่ 3.18 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 5.....	47
รูปที่ 3.19 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 6.....	48
รูปที่ 3.20 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 7.....	49
รูปที่ 3.21 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 8.....	50
รูปที่ 3.22 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 9.....	51
รูปที่ 3.23 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 10.....	51
รูปที่ 3.24 ผลของระบบ NILM สำหรับตรวจรู้สภาวะโหลดแบบต่อเนื่อง.....	54
รูปที่ 3.25 การเปรียบเทียบเทคนิคการตรวจรู้สภาวะและการเรียนรู้เชิงลึก.....	56
รูปที่ 4.1 การวัดกำลัง 4 โหลด; (A) soldering iron a (B) Bulb (C) soldering iron b (D) hot melt glue gun.....	57
รูปที่ 4.2 การวัดกระแส 4 โหลด; (A) soldering iron a (B) Bulb (C) soldering iron b (D) hot melt glue gun.....	58
รูปที่ 4.3 ผลการวัดกำลังไฟฟ้าของอุปกรณ์ร่วมกัน 4 ชนิด.....	58
รูปที่ 4.4 ตัวอย่างผลของการตรวจรู้สภาวะโหลดแบบไม่ล่องล้ำแบบ 2 อุปกรณ์.....	59
รูปที่ 4.5 ตัวอย่างผลของการตรวจรู้สภาวะโหลดแบบไม่ล่องล้ำแบบ 3 อุปกรณ์.....	59
รูปที่ 4.6 ตัวอย่างผลของการตรวจรู้สภาวะโหลดแบบไม่ล่องล้ำแบบ 4 อุปกรณ์.....	60
รูปที่ 4.7 การวิเคราะห์องค์ประกอบของฐานข้อมูลด้วย Principal Component Analysis.....	61

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

เมื่อเร็ว ๆ นี้, ความต้องการของการตรวจสอบการใช้พลังงานอุปกรณ์ใช้ไฟฟ้าแต่ละชนิดเป็นเป้าหมายสำคัญต่อการเพิ่มประสิทธิภาพระบบสมาร์ตกริด [1-3] ส่งผลให้สาธารณูปโภคสามารถปรับเปลี่ยนวิธีการใช้พลังงานได้อย่างมีประสิทธิภาพ เพียงแต่สมาร์ตกริดไม่สามารถจัดการพลังงานในระดับชุมชน หรือ ระดับครัวเรือนได้ ดังนั้น การพัฒนาเทคนิคตรวจสอบสถานะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ (NILM) [4, 5] เป็นทางเลือกที่น่าสนใจในการแก้ปัญหาดังกล่าว

จากการศึกษา NILM มีองค์ประกอบสำคัญหลายส่วน [6, 7] เช่น การเข้าถึงอุปกรณ์ การประมวลผลข้อมูล การตรวจสอบอุปกรณ์และการวิเคราะห์พลังงาน เป็นต้น ดังที่กล่าวมาการศึกษาโดยมากพบปัญหาที่เกิดจากลายเซ็นของอุปกรณ์ เช่น ปัญหาที่เกิดจากการใช้งานไฟฟ้าในแต่ละภูมิภาค [8], ปัญหาเฉพาะอุปกรณ์ [2], โดเมนความถี่ [9], หรือ ข้อมูลรูปคลื่นกราฟ [10] เป็นต้น เพื่อปรับเปลี่ยนคุณลักษณะของอุปกรณ์มีการวิจัยที่นำพารามิเตอร์ทางไฟฟ้า (รูปคลื่น แรงดัน และ กระแส อื่นๆ) เปลี่ยนให้อยู่ในลักษณะรูปภาพ เช่น การแมพข้อมูลไฟฟ้าแบบ VI-trajectory [11] นอกจากนี้ การพัฒนาเทคนิคการตรวจสอบซึ่งถึงชนิดของอุปกรณ์เป็นอีกส่วนที่มีความสำคัญ ซึ่งการเรียนรู้เชิงลึกได้รับความนิยมในการประยุกต์และพัฒนา [12, 13]

การศึกษานี้เสนอการพัฒนาตรวจสอบสถานะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ มุ่งเน้นไปยังการตรวจสอบสถานะการทำงานที่แตกต่างกัน การทดลองประกอบด้วยอุปกรณ์ 4 ชนิด (5 อุปกรณ์) ได้แก่ เครื่องปรับอากาศ 38,000 BTU, เครื่องปรับอากาศ 12,000 BTU ปั๊มน้ำ 500 วัตต์ หลอดไฟสำนักงาน 500 วัตต์ และ ไมโครเวฟ 1,200 วัตต์ การทดลองในส่วนแรกเป็นการวัดกำลังไฟฟ้าด้วยไมโครคอนโทรลเลอร์ ต่อมาประยุกต์ใช้โมดูล CS5490 ร่วมกับ FPGA วิเคราะห์แบบไบนารี ผลการทดลองพบว่าสามารถตรวจสอบสถานะการทำงานได้ 100 เปอร์เซ็นต์ ทั้งยังสามารถนำไปทดลองกับอุปกรณ์ชนิดอื่นๆ แบบเวลาจริง แต่ทว่า วิธีแบบไบนารีไม่สามารถตรวจสอบอุปกรณ์ที่มีกำลังวัตต์ใกล้เคียงกันได้ ด้วยเหตุนี้ ได้พัฒนางจรควบคุมกระแสและแรงดันร่วมกับ FPGA เพื่ออ่านค่าระหว่างเริ่มต้นการทำงาน ใช้การเปลี่ยนรูปร่างการทำงานให้อยู่ในรูปเคอร์โทรแกรม (สเปกตรัม) พัฒนาเป็นชุดข้อมูล และพัฒนาเทคนิคการเรียนรู้เชิงลึกในการตรวจสอบสถานะโหลด การทดลองเป็นการปรับเปลี่ยนโครงข่ายของ C-NN และ เปรียบเทียบผลกับวิธีล้ำสมัย ต่อมาได้ศึกษาการทำงานของอุปกรณ์แบบ ON/OFF ทดลองด้วยโมเดล AlexNet ดังที่กล่าวมา ผู้ศึกษาคาดหวังว่าเทคนิคดังกล่าวจะสามารถตรวจสอบสถานะโหลดที่ทำงานแตกต่างกัน และ โหลดที่ทำงานร่วมกันมากกว่าสองชนิด

1.2 วัตถุประสงค์ของการศึกษา

ศึกษาและออกแบบระบบตรวจสอบสถานะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำด้วยการวิเคราะห์พฤติกรรมของสัญญาณไฟฟ้าร่วมกับเทคนิคการเรียนรู้เชิงลึก เพื่อเป็นอัลกอริทึมสำหรับตรวจสอบสถานะโหลดที่ทำงานแตกต่างกัน และ โหลดที่ทำงานร่วมกันมากกว่าสองชนิด

1.3 ขอบเขตของการศึกษา

พัฒนาอัลกอริทึมสำหรับตรวจสอบสถานะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ โดยอาศัยการประมวลผลจากอุปกรณ์ลอจิกแบบโปรแกรมร่วมกับเทคนิคการเรียนรู้เชิงลึก สามารถตรวจสอบสถานะโหลดไม่น้อยกว่า 4 ชนิด โดยมีประสิทธิภาพไม่น้อยกว่าร้อยละ 80

1.4 คำจำกัดความในการวิจัย

1.4.1 การตรวจสอบสถานะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ (NILM) คือ การตรวจสอบอุปกรณ์จากการวัดค่ากำลังงานด้วยอัลกอริทึม หรือ เครื่องมือวิเคราะห์ทางไฟฟ้า โดย NILM เป็นส่วนหนึ่งของสมาร์ตโฮม ทำหน้าที่จัดการการทำงานของอุปกรณ์ใช้ไฟฟ้า

1.4.2 การเรียนรู้เชิงลึก (Deep Learning) คือ การเรียนรู้ทางคณิตศาสตร์ที่เรียนแบบการทำงานของสมองมนุษย์ โดยการนำข้อมูลที่ศึกษาผ่านการเรียนรู้และตัดสินใจ เทคนิคดังกล่าวเป็นส่วนย่อยของระบบปัญญาประดิษฐ์

1.5 ประโยชน์ที่คาดว่าจะได้รับ

จากวัตถุประสงค์การศึกษา เพื่อพัฒนาเทคนิคที่สามารถวิเคราะห์และจัดการพลังงานภายในบ้านที่ส่งผลต่อการลดค่าใช้จ่ายในครัวเรือน และ พัฒนาระบบบ้านอัจฉริยะ


บทที่ 2

ทฤษฎีการวิจัยและงานวิจัยที่เกี่ยวข้อง

การตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำโดยใช้เทคนิคการเรียนรู้เชิงลึกจำเป็นต้องผ่านกระบวนการเข้าถึงการทำงานของอุปกรณ์ การเปลี่ยนแปลงคุณลักษณะสเปกตรัม และ การตรวจรู้สภาวะโหลดเพื่อจะให้ได้ผลลัพธ์ที่ถูกต้อง โดยบทนี้จะกล่าวถึงทฤษฎี องค์ความรู้ต่างๆ และ งานวิจัยที่เกี่ยวข้อง ที่มีส่วนในการนำมาพัฒนาในดัชนีฉบับนี้

2.1 การตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ

การตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ (Nonintrusive Load Monitoring: NILM) พัฒนาเพื่อแก้ปัญหาการวัดค่าพลังงานในหลายๆจุด ให้มีการวัดค่ากำลังงานในจุดเดียวแต่สามารถแยกแยะเครื่องใช้ไฟฟ้าในแต่ละชนิดได้ จากการศึกษา, NILM ถูกพัฒนาในปี 1980 โดย GEORGE W. Hart [4] เป็นการตรวจรู้สภาวะโหลดด้วยการวิเคราะห์สถานะแรงดันไฟฟ้า 2 ลักษณะ คือ การวิเคราะห์แบบคงตัว (Steady State Analysis: SSA) [14] และ การวิเคราะห์แบบชั่วคราว (Transient State Analysis: TSA) [15] การพัฒนาได้รับการศึกษาอย่างต่อเนื่อง ในปัจจุบันมีการวิจัยที่น่าอัศจรรย์ที่อื่น ๆ มาประยุกต์ใช้เพื่อเพิ่มความสามารถการตรวจรู้สภาวะโหลด เช่น การตรวจรู้จากสถานะของเส้นกราฟ (GSP) โดยค่ากำลังวัตต์ที่ได้จะมีลักษณะแตกต่างกันในช่วงสถานการณ์ใช้งานของเครื่องใช้ไฟฟ้า [10] หรือ การประยุกต์ใช้โมเดลของมาโคร (Hidden Markov Models: HMM) สำหรับตรวจรู้โหลดแบบไม่ล่วงล้ำ [16] ดังที่กล่าวมา การพัฒนา NILM มีหลักการทำงานคล้ายกับสมาร์ทมิเตอร์ (Smart Meter) [17] ซึ่งมีความสามารถในการตรวจวัดอุปกรณ์ แต่แตกต่างตรงที่ความสามารถของสมาร์ทมิเตอร์เป็นการประยุกต์ใช้เทคโนโลยีแบบออนไลน์ ซึ่งเป็นการประยุกต์ใช้ร่วมกับสมาร์ทโฮม (Smart Home) [1-3] ควบคุมอุปกรณ์ภายในบ้านจากสถานที่ภายนอกผ่านเครือข่ายอินเทอร์เน็ตโดยใช้มือถือหรืออุปกรณ์อิเล็กทรอนิกส์เป็นตัวกลาง แต่สมาร์ทมิเตอร์ไม่มีความสามารถแยกแยะหรือตรวจรู้ค่ากำลังทำงานของอุปกรณ์ กล่าวอีกคือ NILM เป็นการพัฒนาเพิ่มเติมจากสมาร์ทมิเตอร์ก็ได้ โดยเพิ่มเติมความสามารถในการตรวจรู้และแสดงสถานะของอุปกรณ์ ซึ่ง NILM ยังสามารถพัฒนาเป็นระบบขนาดใหญ่สำหรับเมืองอัจฉริยะ ดังที่กล่าวมาแสดงให้เห็นถึงประโยชน์ของ NILM แต่การพัฒนาจำเป็นต้องเสียค่าใช้จ่ายจำนวนมาก การพัฒนาอุปกรณ์เพื่อลดต้นทุนการผลิตกำลังเป็นที่สนใจ เช่น Arduino Mega [18] หรือ Raspberry Pi [19] มาพัฒนา เป็นอุปกรณ์ที่มีราคาถูกแต่การทดลองยังมีข้อจำกัดในการตรวจรู้สภาวะโหลด แสดงองค์ประกอบและการทำงานของ NILM ในรูปที่ 2.1



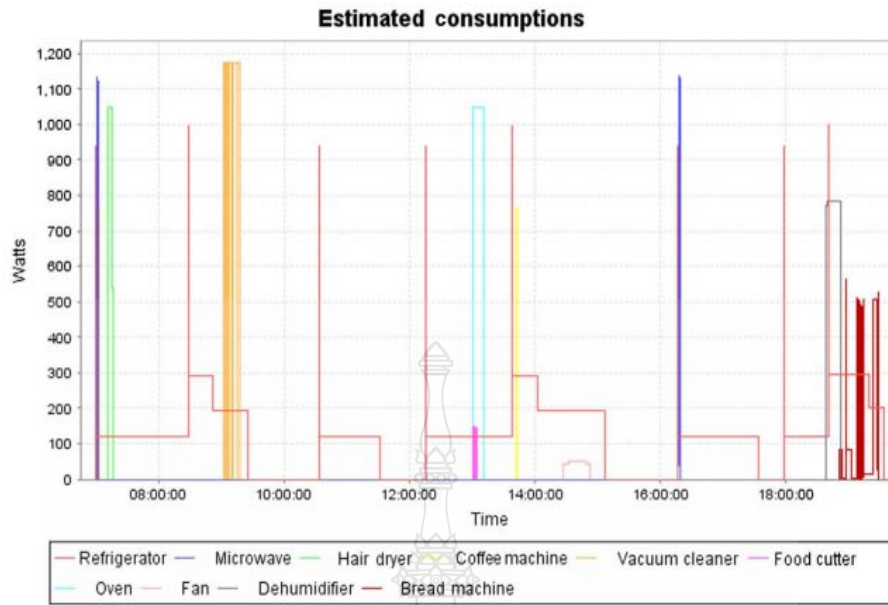
รูปที่ 2.1 พื้นฐานของระบบตรวจรูกำลังไฟฟ้า

จากรูปที่ 2.1 อธิบายองค์ประกอบของระบบตรวจรูกำลังไฟฟ้าแบบไม่ล่งล้าไว้ดังนี้ การเข้าถึงข้อมูลการทำงานของอุปกรณ์ใช้ไฟฟ้า (Acquisition) เป็นการวัดแรงดัน กำลังวัตต์ กระแส อื่นๆ ซึ่งเป็นค่ารวมของอุปกรณ์ผ่านการวัดเพียง 1 ตำแหน่ง พื้นฐานการพัฒนาอาศัยวงจร RLC รวมถึงวงจรกรองสัญญาณ เช่น โมเดล CUSUM (Cumulative Sum Control Chart) นอกจากนี้, วงจรพื้นฐานในปัจจุบันสามารถใช้เซนเซอร์วัดกระแสเข้าร่วมได้ เช่น เซนเซอร์ SCT-013-030 หรือ ESEN141 Non-Invasive Current Sensor เป็นต้น

การประมวลผล (Preprocessing) คือ การนำข้อมูลการวัดอุปกรณ์ที่ได้จากขั้นตอนการเข้าถึงอุปกรณ์ แปลงสัญญาณดิจิทัลเป็นสัญญาณอนาล็อก (A/D) โดยพื้นฐานสามารถทำได้หลายวิธี เช่น ใช้วงจรแปลงแบบ Ramp วงจรเทียบแรงดัน วงจรแบบ Parallel Comparator หรือ ปัจจุบันมีการผลิต IC แปลงสัญญาณอนาล็อกเป็นดิจิทัลเบอร์ ADC เป็นต้น

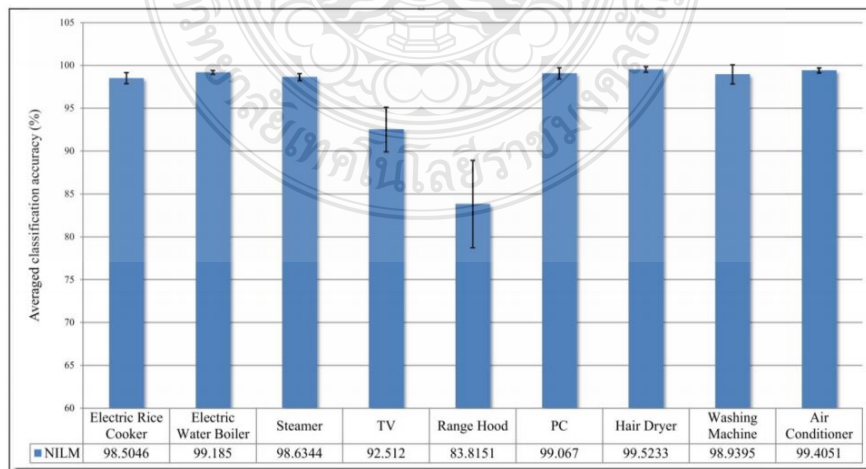
การตรวจจับสัญญาณ (Detection) เมื่อแปลงสัญญาณไฟฟ้าเป็นแบบอนาล็อกแล้วนำสัญญาณดังกล่าวมาวิเคราะห์ ส่วนใหญ่จะเป็นการตัดสัญญาณเป็นช่วงๆ คำนวณจากเวลา (Time) ที่มีผลต่อสัญญาณหรือพฤติกรรมของสัญญาณ เช่น การตรวจจับสัญญาณในช่วง Overload สัญญาณในช่วงทำงาน (Stable) หรือ สัญญาณในช่วง Overshot เป็นต้น

การตรวจรูกำลัง คือ การบ่งบอกถึงประเภทของอุปกรณ์แต่ละชนิด กล่าวอีกคือเป็นการแสดงสถานการณ์การทำงานของอุปกรณ์นั้นๆ จากการศึกษาในส่วนนี้เป็นนำข้อมูลการทำงานที่ได้จากการตรวจจับพฤติกรรมต่างๆ หรือ ข้อมูลการทำงานในช่วงเวลานั้นๆ มาวิเคราะห์ด้วยอัลกอริทึมหรือวิธีทางคณิตศาสตร์ เช่น ใน [1, 12] เป็นการนำสภาวะโหลตมาตรวจรูกำลังด้วยการเรียนรู้เชิงลึก ใน [13] ตรวจรูกำลังโหลตด้วยการเรียนรู้เชิงลึกแบบคอนโวลูชัน (CNN) ใน [14] ตรวจรูกำลังโหลตด้วยโครงข่ายประสาทเทียมแบบย้อนกลับ (BP-NN) ใน [20] ตรวจรูกำลังโหลตแบบไม่ล่งล้าด้วย Fuzzy Transitions เป็นต้น แสดงตัวอย่างดังรูปที่ 2.2

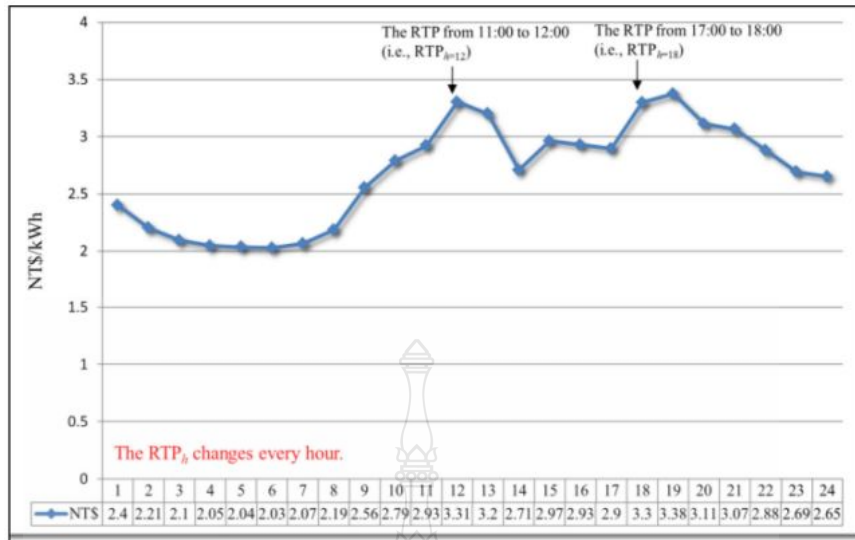


รูปที่ 2.2 ผลของการตรวจรู้ค่ากำลังงาน [20]

การวิเคราะห์ค่าพลังงาน (Energy estimation) คือ การนำผลของการตรวจรู้สถานะโหนดมาวิเคราะห์เพื่อคาดการณ์การใช้พลังงานในแต่ละช่วงเวลา และ วิเคราะห์การใช้ค่าพลังงาน เช่น Yu-Hsiu Lin และ คณะ [21] ได้กล่าวถึงการจัดการพลังงานภายในบ้านรวมถึงค่าพลังงานที่เหมาะสมในครัวเรือน (HEMS) งานวิจัยฉบับนี้พัฒนาด้วยอัลกอริทึมแบบ NSGA เพื่อความสะดวกในการตรวจรู้สถานะโหนดแบบหลายจุด ผลการทดลองดังรูปที่ 2.3 แสดงให้เห็นถึงข้อมูลที่สามารถตรวจรู้การทำงานของโหนด ผลวิเคราะห์ข้อมูลการทำงาน รวมถึงผลคาดการณ์การใช้พลังงานในเดือนมีนาคม



(ก) ความถูกต้องของการตรวจรู้อุปกรณ์แต่ละชนิด



(ข) ผลคาดการณ์การใช้ไฟฟ้าของแต่ละอุปกรณ์ในเดือนมีนาคม

รูปที่ 2.3 ประสิทธิภาพการตรวจรู้และผลคาดการณ์การใช้ไฟฟ้าของแต่ละอุปกรณ์ [21]

2.2 ประเภทของอุปกรณ์ใช้ไฟฟ้า และการเข้าถึงอุปกรณ์ใช้ไฟฟ้า

2.2.1 ประเภท และ พฤติกรรมของอุปกรณ์ใช้ไฟฟ้า

การเข้าใจคุณสมบัติของอุปกรณ์ใช้ไฟฟ้าจำเป็นต้องศึกษาพฤติกรรมการทำงานของอุปกรณ์สามารถแบ่งเป็นสี่ประเภท คือ (1): อุปกรณ์ประเภทเปิด/ปิด (ON/OFF) มีสถานะพลังงานแบบไบนารี มีคุณสมบัติที่ชัดเจน อย่างไรก็ตามหากอุปกรณ์สองเครื่องที่มีการใช้พลังงานแบบเดียวกัน จะไม่สามารถตรวจรู้ได้ จำเป็นต้องหาปัจจัยเพิ่มเติมเพื่อตรวจรู้; (2): อุปกรณ์มีกำลังไฟหลายสถานะ (Finite State Machine: FSM) มีรูปแบบการใช้พลังงานเปลี่ยนแปลงตามการใช้งาน เช่น หลอดไฟ สถานะการทำงานตามความสว่าง ดังนั้นจึงเป็นเรื่องง่ายที่จะตรวจรู้เครื่องใช้ไฟฟ้าเพียงเครื่องเดียว อย่างไรก็ตามเมื่อรวมการใช้พลังงานหลายอย่างเข้าด้วยกันการตรวจรู้เกิดความซับซ้อน เป็นการยากที่จะเข้าใจว่ากำลังทำงานเกิดขึ้นในรูปแบบตัวแปรใด ดังนั้นจำเป็นต้องสังเกตรูปแบบในระยะเวลาดำเนินการเพื่อจัดตรวจรู้เครื่องใช้ไฟฟ้า; (3): อุปกรณ์มีรูปแบบพลังงานที่เปลี่ยนแปลงต่อเนื่อง เช่น เครื่องซักผ้าหรือไฟหรี่ การใช้พลังงานจะผันผวนในขณะที่ความร้อน/ซักหรือล้าง/อบแห้งผ้า ซึ่งนั่นคือ อุปกรณ์หลายสถานะ การตรวจรู้ประเภทนี้ต้องเข้าใจคุณสมบัติและสังเกตรูปแบบระยะยาว; (4): อุปกรณ์ทำงานเสมอ หรือทำงานยกเว้นกรณีพิเศษ ตัวอย่างเช่น ตู้เย็น ทำงานอย่างสม่ำเสมอ อาจมีรูปแบบเป็นระยะ หรือแบบเดียวกันก็ได้ (Hart, 1993) เป็นการยากในการตรวจรู้ เนื่องจากมีสถานการณ์ทำงานไม่ชัดเจน

ดังที่กล่าวมา มีการรวบรวมชุดข้อมูลที่เผยแพร่สาธารณะสำหรับศึกษา และ พัฒนาเพื่อตรวจรู้พฤติกรรมการใช้พลังงานดังนี้:

1) ชุดข้อมูลความถี่ต่ำ

ข้อมูลของอุปกรณ์ถูกจัดกลุ่มการทำงานด้วยความถี่ต่ำ (Sampling frequency up to 1 Hz) ได้รับการวิเคราะห์และเปรียบเทียบ: GREEND, AMPds, REFIT, RAE และ iAWE ไว้ใน [22] ความเกี่ยวข้องของชุดข้อมูลเหล่านี้เกิดจากอุปกรณ์ที่เป็นมาตรฐาน การเปรียบเทียบระหว่างคุณลักษณะบางอย่างของอุปกรณ์ ได้แก่ ความถี่ต่ำประเภทต่างๆ โดยความถี่ในการสุ่มสอดคล้องกับเวลาของการบันทึกผล สรุปไว้ในตารางที่ 2.1

ตารางที่ 2.1 การเปรียบเทียบระหว่างชุดข้อมูลความถี่ต่ำ

ชุดข้อมูล	ปี (พ.ศ.)	ความถี่	วัน/เวลา (บันทึก)
GREEND	2014	1 Hz	3-6 เดือน
AMPds	2015	16.67 mHz	2 ปี
REFIT	2017	125 mHz	2 ปี
RAE	2018	1 Hz	72 วัน
iAWE	2013	1 Hz	73 วัน

2) ชุดข้อมูลความถี่สูง

ข้อมูลของอุปกรณ์ถูกจัดกลุ่มการทำงานด้วยความถี่สูง (High frequency) ได้รับการวิเคราะห์และเปรียบเทียบ: REDD, BLUED, PLAID, WHIETED และ UK-DALE สรุปไว้ใน [22] ความเกี่ยวข้องของชุดข้อมูลเหล่านี้เกิดจากอุปกรณ์ที่เป็นมาตรฐาน การเปรียบเทียบระหว่างคุณลักษณะบางอย่างของอุปกรณ์ ได้แก่ ความถี่ในการสุ่มตัวอย่างสอดคล้องกับเวลาของการบันทึกผล สรุปไว้ในตารางที่ 2.2

ตารางที่ 2.2 การเปรียบเทียบระหว่างชุดข้อมูลความถี่สูง

ชุดข้อมูล	ปี (พ.ศ.)	ความถี่	วัน/เวลา (บันทึก)
REDD	2011	15 KHz	119 วัน / (10 ชั่วโมง)
BLUED	2012	12 KHz	8 วัน / (1 ชั่วโมง)
PLAID	2014	30 KHz	1,094 สัญญาณ / 1 วินาที
WHIETED	2016	44.1 KHz	5,123 สัญญาณ / 5 วินาที
UK-DALE	2015	16 KHz	655 วัน

3) ชุดข้อมูลรูปภาพ

ข้อมูลการทำงานของอุปกรณ์ใช้ไฟฟ้า ได้แก่ กำลังวัตต์ กระแส หรือ แรงดัน ซึ่งเป็นข้อมูลการทำงานช่วงระยะหนึ่ง (ชั่วขณะ หรือ ระยะยาว) ถูกเปลี่ยนแปลงรูปทรง และ บันทึกในลักษณะข้อมูลภาพ รวบรวมไว้โดยวิเคราะห์และเปรียบเทียบดัง: V-I Trajectory [11], Color Map [23], และ AWRG [24] สรุปไว้ในตารางที่ 2.3

ตารางที่ 2.3 การเปรียบเทียบชุดข้อมูลภาพ

ชุดข้อมูล	ปี (พ.ศ.)	ข้อมูลใช้งาน	ผู้พัฒนา
V-I Trajectory	2016	กำลังวัตต์, กระแส	L. Du et al.
Color Map	2019	กำลังวัตต์, กระแส	Y. Liu et al.
AWRG	2020	กำลังวัตต์, กระแส	A. Faustine et al.

2.2.2 การเข้าถึง และ บันทึกพฤติกรรมการทำงานของอุปกรณ์ใช้ไฟฟ้า

กระบวนการได้มาซึ่งชุดข้อมูลเป็นหัวข้อสำคัญของการวิจัย จากปัญหาความแตกต่างของชุดข้อมูล แม้ชุดข้อมูลที่เผยแพร่สาธารณะเป็นประโยชน์อย่างมาก แต่มักประสบปัญหาของการศึกษาเมื่อนำไปทดลองใช้งานกับอุปกรณ์อื่นๆ เนื่องจากแหล่งกำเนิดพลังงานของอุปกรณ์ที่มีกำลังวัตต์เหมือนกันมีลักษณะที่แตกต่างกัน ส่งผลให้มีการพัฒนาเทคนิคและการเข้าถึงชุดข้อมูลใหม่ๆ อย่างต่อเนื่อง จากการศึกษา, มีการพัฒนางจรอิเล็กทรอนิกส์เฉพาะ และ อุปกรณ์วัดสัญญาณที่มีอยู่ พัฒนาเป็นระบบตรวจวัดการทำงานของอุปกรณ์ เช่น บอร์ด Arduino ตัวอย่าง โดย Arun K.R. et al. [25] นำเสนอการเข้าถึงและควบคุมอุปกรณ์แบบเกตเวย์ (การใช้ตัวรับการทำงานแบบสองทิศทาง) ผ่านเซนเซอร์วัดกระแสและแรงดัน ส่งต่อไปยัง Arduino board ควบคุมอุปกรณ์แบบอัตโนมัติ หรือ การใช้บอร์ด Raspberry Pi ตัวอย่างโดย A. Harsha et al. [26] ประยุกต์ใช้ raspberry pi ร่วมกับ smart meter ในการตรวจจับลักษณะอุปกรณ์ มุ่งเน้นไปยังกำลังงานรวม (power rating) พัฒนาร่วมกับ k-mean algorithms ในการบ่งชี้ถึงพฤติกรรมของอุปกรณ์ อื่นๆ [27], บอร์ด FPGA ตัวอย่างโดย Y. Sarayut et.al. [28] เสนอ FPGA ร่วมกับ CS5490 สำหรับการเข้าถึงอุปกรณ์ มุ่งเน้นไปยังอุปกรณ์สี่ชนิดที่มีกำลังไฟฟ้าต่างกัน อีกทั้ง ออกแบบวงจรวัดกระแสและแรงดันเพื่อควบคุมระดับการทำงานของอุปกรณ์ นอกจากนี้กระบวนการตรวจรู้อาศัยเทคนิคไบนารีที่มีความเร็วในการคำนวณ และ ความยืดหยุ่นเมื่อมีจำนวนอุปกรณ์เพิ่มขึ้น อื่นๆ [29-31]

จากแนวทางก่อนหน้า, การศึกษานี้ออกแบบวงจรควบคุมอุปกรณ์ใช้ไฟฟ้า ทำหน้าที่วัดและเปลี่ยนค่าสัญญาณเป็น Digital อีกทั้งนำ FPGA มาใช้งาน ซึ่งมีความเร็วในการสุ่มสัญญาณ และ ลดภาระค่าใช้จ่ายในการพัฒนา (low cost) การทดลองมุ่งเน้นไปยังอุปกรณ์ใช้ไฟฟ้าที่มีความแตกต่างกัน 5 ชนิด และ เปลี่ยนแปลงลักษณะของอุปกรณ์ให้อยู่ในลักษณะ 2 มิติ (2D) ซึ่งจะกล่าวในหัวข้อถัดไป

2.3 สเปกตรัมเคอร์โทแกรม


การแปลงข้อมูลให้อยู่ในลักษณะของรูปภาพหรือข้อมูลแบบ 2 มิติ [32] เป็นการเพิ่มลักษณะของข้อมูลให้มีความแตกต่าง ช่วงที่ผ่านมามีการพัฒนาโดยสรุปไว้ในตารางที่ 2.3 ซึ่งเป็นที่ยอมรับอย่าง ต่อเนื่อง การศึกษานี้ประยุกต์ใช้สเปกตรัมเคอร์โทแกรม เป็นวิธีทางสถิติที่บ่งชี้ถึงโดเมนของเวลาและ ความถี่ที่พิจารณาจากการสุ่มสัญญาณ ดังสมการที่ 1 เมื่อ K_f คือ ค่าที่หาได้จากความถี่ของ f และ $[\cdot]$ คือ ค่าเฉลี่ยในช่วงเวลาหนึ่ง, $H(t, f)$ คือ ช่วงของเวลา และ ความถี่ของสัญญาณ $y(t)$ ดัง:

$$K_f = \frac{\langle H^4(t, f) \rangle}{\langle H^2(t, f) \rangle^2} \quad (1)$$

จากสมการที่ 1 แปลงฟูริเยร์ระยะสั้น (STFT) ดังสมการที่ 2:

$$H(t, f) = \sum_{n=t}^{t+N_w-1} W(n-t) \cdot x(n) e^{-j2\pi fn} \quad (2)$$

เมื่อ $W(t)$ คือ หน้าต่างของสัญญาณกับความยาวของ N_w ตัวอย่างการแปลงดังรูปที่ 2.4




รูปที่ 2.4 ภาพเคอร์โทแกรม

2.4 การเรียนรู้เชิงลึก

2.4.1 โครงข่ายประสาทเทียม

ปัญญาประดิษฐ์ (Artificial Intelligence : AI) มีรูปแบบโครงสร้างและการประมวลผลเหมือนกับสมองของสิ่งมีชีวิต มีการปรับเปลี่ยนตัวเองต่อการตอบสนองของอินพุตตามกฎของการเรียนรู้ (learning rule) หลังจากที่โครงข่ายได้เรียนรู้สิ่งที่ต้องการแล้ว โครงข่ายนั้นจะสามารถทำงานที่กำหนด ดังที่กล่าว การเรียนรู้มีแนวคิดคล้ายคลึงกับการทำงานของสมองมนุษย์ ซึ่งประกอบด้วยหน่วยประมวลผลเรียกว่า นิวรอน (เซลล์ประสาท หรือ neuron) จำนวนนิวรอนในสมองมีการเชื่อมต่อมากมาย จึงสามารถกล่าวได้ว่าสมองเป็นคอมพิวเตอร์ที่มีการปรับตัวเอง (adaptive) แบบไม่เป็นเชิงเส้น (non-linear) และทำงานแบบขนาน (parallel) ลักษณะการทำงานร่วมกันของนิวรอนดังรูปที่ 2.5



รูปที่ 2.5 โครงข่ายประสาทเทียม

2.4.1.1 ข้อมูลอินพุต (Input Data) คือข้อมูลที่เป็นตัวเลข เป็นข้อมูลเชิงคุณภาพและสามารถแปลงให้อยู่ในรูปเชิงปริมาณ อธิบายในรูปของมิติที่หลากหลายที่โครงข่ายประสาทยอมรับได้

2.4.1.2 ข้อมูลเอาต์พุต (Output Data) คือผลลัพธ์ที่เกิดขึ้นจริง เป็นผลจากกระบวนการเรียนรู้ของโครงข่ายประสาทเทียม ความแม่นยำขึ้นอยู่กับข้อมูลที่นำมาฝึกฝน

2.4.1.3 ค่าน้ำหนัก (Weight) คือน้ำหนักของแต่ละโหนดที่ได้จากการเรียนรู้ของโครงข่ายประสาท หรือ เรียกอีกอย่างหนึ่งว่าค่าความรู้ (Knowledge) ค่านี้ถูกเก็บเป็นทักษะเพื่อใช้ในการจดจำข้อมูลอื่นๆ ที่อยู่ในมิติเดียวกัน สามารถปรับเปลี่ยนได้ขึ้นอยู่กับข้อมูลที่นำมาฝึกฝน

2.4.1.4 ฟังก์ชันผลรวม (Summation function) เป็นผลรวมของข้อมูลป้อนเข้าและค่าน้ำหนัก


2.4.1.5 ฟังก์ชันการแปลง (Activation function) คือฟังก์ชันที่ทำหน้าที่รวมค่าเชิงตัวเลขจากเอาต์พุต แล้วตัดสินใจส่งออกไปในรูปใด เป็นได้ทั้งแบบเชิงเส้นหรือไม่เป็นเชิงเส้น การเลือกใช้ฟังก์ชันจะ

ขึ้นอยู่กับลักษณะของโครงข่ายประสาทที่นำไปใช้ ฟังก์ชันการแปลงมีอยู่หลายรูปแบบเช่น ฮาร์ตลิมิต ฮาร์ตลิมิตแบบสมมาตร แบบเส้นตรง แบบเส้นตรงบวก แบบซิกมอย แบบซิกมอยเส้นสัมผัส ซิกมอยแบบไฮเปอร์ ดังรูปที่ 2.6

Unit step (Heaviside)	$\phi(z) = \begin{cases} 0, & z < 0, \\ 0.5, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Sign (Signum)	$\phi(z) = \begin{cases} -1, & z < 0, \\ 0, & z = 0, \\ 1, & z > 0, \end{cases}$	Perceptron variant	
Linear	$\phi(z) = z$	Adaline, linear regression	
Piece-wise linear	$\phi(z) = \begin{cases} 1, & z \geq \frac{1}{2}, \\ z + \frac{1}{2}, & -\frac{1}{2} < z < \frac{1}{2}, \\ 0, & z \leq -\frac{1}{2}, \end{cases}$	Support vector machine	
Logistic (sigmoid)	$\phi(z) = \frac{1}{1 + e^{-z}}$	Logistic regression, Multi-layer NN	
Hyperbolic tangent	$\phi(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}}$	Multi-layer Neural Networks	
Rectifier, ReLU (Rectified Linear Unit)	$\phi(z) = \max(0, z)$	Multi-layer Neural Networks	

รูปที่ 2.6 ฟังก์ชันการแปลง [33]

จากส่วนประกอบของโครงข่ายประสาทในรูปที่ 2.5 อธิบายลักษณะค่าเทรโดไฮลของฟังก์ชันหรือระดับการเปรียบเทียบค่าน้ำหนักของข้อมูลในรูปที่ 2.7 เมื่อได้ค่าผลรวมของข้อมูลน้ำหนักแล้วนำมาเปรียบเทียบกับฟังก์ชันการแปลงจะได้เอาต์พุตเป็นค่าของข้อมูลและส่งไปยังโหนดต่อไป




รูปที่ 2.7 การประมวลผลของโครงข่ายประสาทเทียม [34]

จากรูปที่ 2.7 การเรียนรู้ด้วยการนำเสนอกลุ่มตัวอย่าง (examples หรือ training set) ให้กับโครงข่ายในรูปของเป้าหมาย (target) ที่ต้องการให้โครงข่ายตอบสนอง โดยพิจารณาคู่อินพุตและเป้าหมายดัง:

$$\{p_1, t_1\}, \{p_2, t_2\}, \dots, \{p_n, t_n\} \quad (3)$$

เมื่ออินพุตถูกป้อนไปยังโครงข่าย จะถูกนำมาเปรียบเทียบกับเป้าหมายของอินพุต แล้วโครงข่ายจะทำการปรับค่าน้ำหนักและไบอัสตามกฎการเรียนรู้ ซึ่งเป็นการส่งค่าย้อนกลับไปเรื่อยๆ เพื่อให้เอาต์พุตโครงข่ายให้ผลใกล้เคียงเป้าหมาย ดังรูปที่ 2.8




รูปที่ 2.8 การฝึกฝนประสาทเทียม [34]

2.4.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

1) ชั้นคอนโวลูชัน (Convolutional Layer)

ชั้นคอนโวลูชันประกอบด้วยคอร์เนลฟิลเตอร์ แต่ละคอร์เนลจะถูกกำหนดโดยการสุ่ม หลังจากนั้นปรับค่าโดยการเรียนรู้แบบแพร่กระจายย้อนกลับ จำนวนผลลัพธ์ที่ได้จากชั้นคอนโวลูชันจะเท่ากับจำนวนของคอร์เนลฟิลเตอร์ เรียกว่า ฟีเจอร์แมพ (Feature map) ในชั้นของคอนโวลูชันมักจะตามด้วยฟังก์ชันกระตุ้น ซึ่งเป็นฟังก์ชันแบบไม่เชิงเส้น (Non-linear Function) องค์ประกอบของชั้นคอนโวลูชันในรูปที่ 2.9



รูปที่ 2.9 ชั้นคอนโวลูชัน

- ขนาดของตัวกรอง (Filter Size) คือความกว้างและความสูงของตัวกรองที่จะนำมาใช้ในการทำคอนโวลูชัน

- การทำคอนโวลูชันแบบแคบ (Narrow Convolution) คือ การนำตัวกรองทำการดอทพริกซ์ โดยรับข้อมูลขนาด $N \times N$ กับตัวกรองขนาด $m \times m$ จะได้เมทริกซ์ขนาด $(N-m+1) \times (N-m+1)$

- ขนาดของการก้าวข้าม (Stride Size) คือจำนวนช่องของข้อมูลรับเข้า จะถูกเลื่อนเมื่อนำผลลัพธ์ของคอนโวลูชันในแต่ละช่อง

- จำนวนตัวกรอง (Number of Filters) ในแต่ละชั้นของคอนโวลูชันมีตัวกรองได้มากกว่าหนึ่ง โดยน้ำหนักของตัวกรองแต่ละตัวไม่เท่ากัน จำนวนตัวกรองในชั้นคอนโวลูชันใดๆ จะเป็นการกำหนดจำนวนช่องของข้อมูลรับเข้าในลำดับถัดไป

2) ชั้นพูลลิง (Pooling Layer หรือ Subsampling Layer)

การทำพูลลิงมีเป้าหมายเพื่อลดขนาดของข้อมูลที่ผ่านการคอนโวลูชัน นิยมต่อจากชั้นคอนโวลูชัน ซึ่งจะขึ้นอยู่กับกรอกแบบ การพูลลิงที่เป็นที่นิยมมีสองวิธีคือ

- พูลลิงแบบค่ามากที่สุด (Max Pooling) เป็นการหาค่าเฉลี่ยบริเวณ map ของกลุ่มข้อมูลที่สนใจ โดยคัดเฉพาะค่ามากที่สุดจากการ map ข้อมูลและส่งไปชั้นถัดไป

- พูลลิงแบบค่าเฉลี่ย (Average Pooling) เหมือนกับการพูลลิงแบบค่ามากที่สุด แต่ผลลัพธ์ที่ได้จากการพูลลิงจะเป็นค่าเฉลี่ย

3) การเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer)

โครงข่ายประสาทเทียมแบบเต็มรูปแบบ ถูกประยุกต์ใช้สำหรับการจำแนกร่วมกับชั้นคอนโวลูชัน โดยหลังจากชั้นคอนโวลูชันและชั้นพูลลิง ชั้นนี้ประกอบด้วยชั้นย่อยๆ ที่มีเพอร์เซ็ปตรอนอยู่จำนวนมาก แต่ละตัวมีเส้นเชื่อมเพอร์เซ็ปตรอนทุกๆ ตัวจากชั้นก่อนหน้าและชั้นถัดไป

2.4.3 ไฮเปอร์พารามิเตอร์และการฝึกฝนโมเดล

1) ไฮเปอร์พารามิเตอร์

ไฮเปอร์พารามิเตอร์ทำหน้าที่ควบคุมพฤติกรรมและการทำงานของอัลกอริทึม อีกทั้งส่งผลอย่างมากต่อประสิทธิภาพการเรียนรู้ จากการศึกษาพารามิเตอร์ที่สำคัญต่อประสิทธิภาพต่อการทดลองสรุปไว้ดังนี้:

รอบการฝึกฝน (epoch) และ ขนาดของ batch (batch size) การเรียนรู้ของโมเดลอาศัยการกำหนดจำนวนรอบการเรียนรู้โดยสัมพันธ์กับขนาดของ batch หรือ กลุ่มข้อมูลที่ถูกป้อนไปยังโมเดลในการฝึกฝนต่อจำนวนรอบ ซึ่ง epoch และ batch ทำหน้าที่ดังกล่าว การทดลองโดยมากเป็นส่วนหนึ่งของการ fit-tune การพัฒนาโมเดลใหม่ๆ หรือ การทดลองด้วยวิธีการถ่ายโอนมักเปลี่ยนแปลงพารามิเตอร์ดังกล่าว [32].


อัตราการเรียนรู้ (Learning Rate) เป็นค่าคงที่ๆ มีผลต่อความแปรผันของค่าน้ำหนัก (weight) ในแต่ละโหนดของโครงข่ายประสาท ทำงานโดยการหาค่าร่วมกับค่าความผิดพลาด (error rate) รวมเข้ากับค่าน้ำหนักในแต่ละโหนดเพื่อให้ได้ค่าน้ำหนักใหม่ ความเหมาะสมของอัตราการเรียนรู้อย่างส่งผลต่อเวลาการฝึกฝน มีการศึกษาและพัฒนาจำนวนมากที่ทดลองโดยการเปลี่ยนอัตราการเรียนรู้ ซึ่งเป็นการหาค่าสูญเสียของโมเดลสำหรับการตรวจรู้ การทดลองอยู่ในลักษณะของการ fit-tune เพื่อหาผลที่ดีที่สุดของโมเดล [10], [35].

การเพิ่มประสิทธิภาพโมเดล [36] ความสัมพันธ์ของพารามิเตอร์ของเทคนิคการเรียนรู้เชิงลึก เป็นการลด loss ในขณะที่โมเดลเรียนรู้แต่ละรอบตามการคำนวณของเส้นโค้ง สามารถปรับให้เหมาะสมต่อการสูญเสีย (objective function) ได้รับการพัฒนาโดยสรุปไว้: Gradient Descent, Momentum, Minibatch, RMSProp, และ Adam

ค่าเฉลี่ยของ Cross-Entropy คือ ค่าความสูญเสียของแบบจำลอง อธิบายได้จากผลลัพธ์ที่มีความน่าจะเป็นระหว่าง 0 ถึง 1 ได้จากการเพิ่มขึ้นตามความน่าจะเป็นที่คาดการณ์ไว้ หรือ ผลที่แตกต่างจากป้ายกำกับ ทั้งนี้ cross-entropy และ loss function แตกต่างกันขึ้นอยู่กับบริบท แต่การเรียนรู้ของ DL คำนวณอัตราข้อผิดพลาดระหว่าง 0 ถึง 1 สามารถแก้ไขและใช้เป็นส่วนเดียวกัน

2) การฝึกฝน

การเรียนรู้เชิงลึกมีขั้นตอนการฝึกฝนดังรูป 2.10 ชุดข้อมูลที่ได้รับการ normalized และ ผ่านการตั้งเป้าหมาย (label) ถูกส่งไปยังโครงข่ายประสาท (NN) และ ฟังก์ชันการสูญเสีย (loss function) โดยมีโหนด (node) ทำหน้าที่หาความสัมพันธ์ของข้อมูล และ ส่งค่าย้อนกลับ (prediction) เพื่อเปรียบเทียบกับเป้าหมาย (label) ของชุดข้อมูลผ่าน loss function ซึ่งผลของค่า loss คือ จุดต่ำสุดของฟังก์ชันผ่านที่มี gradient function (เป็นการเปรียบเทียบระหว่าง loss กับ ผลที่ได้จากการเรียนรู้) ต่อมาส่งผ่านผลของ gradient ไปยังส่วนเพิ่มประสิทธิภาพ (optimizer) มีหน้าที่เพิ่มประสิทธิภาพ (upgrade (weights, bias)) ของโมเดล มีกระบวนการเรียนรู้ตามจำนวนรอบที่กำหนด (epochs)



รูปที่ 2.10 การเรียนรู้ของโมเดล

เทคนิคการเรียนรู้เชิงลึกเป็นอัลกอริทึมที่สามารถพัฒนาและปรับเปลี่ยนโครงสร้างโดยขึ้นกับชุดข้อมูลนั้นๆ ซึ่งการศึกษานี้นำมาพัฒนาโดยการแก้ไขโครงข่าย พารามิเตอร์ รวมถึงลำดับของโครงข่าย เพื่อเพิ่มประสิทธิภาพของโมเดลและลดระยะเวลาการฝึกฝน โดยจะกล่าวถึงในลำดับถัดไป

2.4.4 วิธีการวัดประสิทธิภาพของโมเดล

การพัฒนาเทคโนโลยีปัญญาประดิษฐ์ อาศัยการวัดประสิทธิภาพ ความแม่นยำของเทคนิค เพื่อบ่งบอกถึงข้อมูลและประสิทธิผลนั้นๆ ในบางครั้งมีการพิสูจน์ถึงการใช้งาน จำนวนข้อมูลที่มีผลต่อความแม่นยำของโมเดล ในปัจจุบันการวัดประสิทธิภาพของปัญญาประดิษฐ์มีหลายแบบ โดยในการทดลองนี้ได้สรุปไว้ในดังสมการที่ (4), (5), (6), (7), (8) และ สมการที่ (9)

$$\text{Accuracy} = \frac{TP + TN}{TP + FP + FN + TN} \quad (4)$$

$$\text{Precision} = \frac{TP}{TP + FP} \quad (5)$$

$$\text{Recall} = \frac{TP}{TP + FN} \quad (6)$$

$$\text{F1 - Score} = \frac{\text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (7)$$

$$\text{MSE} = \frac{1}{n} \sum_{t=1}^n e_t^2 \quad (8)$$

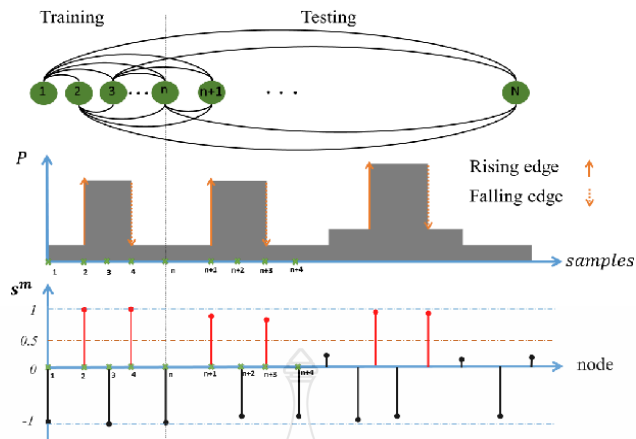
$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{t=1}^n e_t^2} \quad (9)$$

เมื่อ Precision: คือความแม่นยำ, Recall คือความถูกต้อง, F1-Score คือค่าเฉลี่ยของ Precision และ Recall, Accuracy คือจำนวนข้อมูลที่ทายถูกของทุกคลาส, TP คือข้อมูลที่ทำนายแล้วถูกต้องเมื่อเทียบกับข้อมูลจริง, FP คือข้อมูลที่เฉลยแต่ไม่มีการทำนาย, FN คือข้อมูลที่ทำนายแล้วไม่ถูกต้องเมื่อเทียบกับข้อมูลจริง, MSE และ RMSE คือ loss ที่มีหน่วยเดียวกับตัวแปร y

2.5 งานวิจัยที่เกี่ยวข้อง

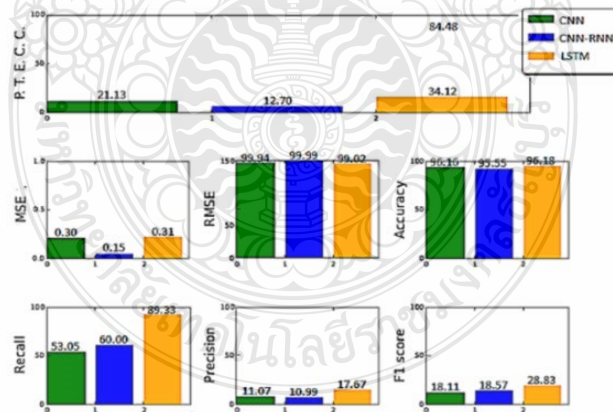
การพัฒนาเทคนิคการตรวจสอบสถานะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำเป็นที่ยอมรับเป็นวงกว้าง ทำให้มีความหลากหลายทั้งการออกแบบ การวิเคราะห์สัญญาณ อุปกรณ์เพิ่มความเร็วในการประมวลผล และอัลกอริทึมในการตรวจสอบสถานะโหลด ตลอดจนการใช้งานจริง ดังนั้นจึงสรุปและคัดเลือกบทความที่เกี่ยวข้องไว้ดังนี้:

ใน [10] อธิบายถึงการออกแบบระบบ NILM โดยการใช้เส้นกราฟสำหรับการตรวจสอบโหลดแบบไม่ล่วงล้ำ ดังภาพที่ 2.11 งานวิจัยนี้ยังกล่าวถึงการออกแบบระบบ 2 แบบ คือ การตรวจจับความผันของเส้นกราฟ กล่าวคือเป็นการลดสัญญาณรบกวนของเส้นกราฟและตรวจจับเส้นกราฟที่มีความราบเรียบ แบบที่สอง คือการปรับแต่งและแก้ไขสัญญาณกราฟ เพื่อเปรียบเทียบกับความสมดุลของกราฟ อัลกอริทึมดังกล่าวพัฒนาร่วมกับโมเดลแบบมาร์โคเวียลเปรียบเทียบประสิทธิภาพกับอัลกอริทึมแบบต้นไม้



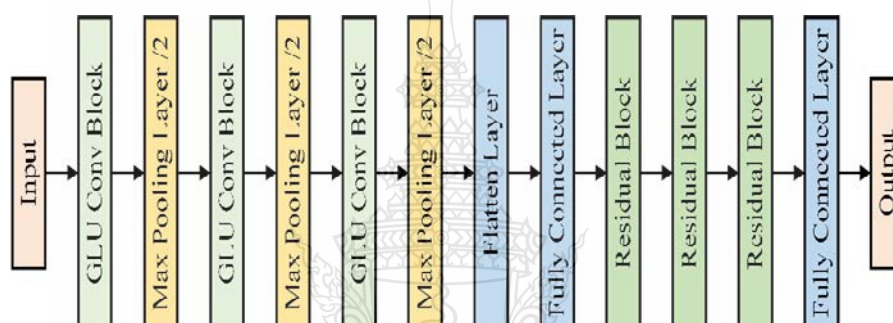
รูปที่ 2.11 การวิเคราะห์โครงสร้างของเส้นกราฟ

ใน [37] อธิบายถึงการประยุกต์ใช้อัลกอริทึมปัญญาประดิษฐ์ (C-NN ร่วมกับ R-NN และ LSTM) เปรียบเทียบประสิทธิภาพของแต่ละอัลกอริทึม โดยประยุกต์โมเดลของ TensorFlow (Free-Model) หรือ API ของ Deep Learning Model ทดสอบด้วยฐานข้อมูลของ REDD ซึ่งเป็นฐานข้อมูลที่ได้รับ ความนิยม โดยมีลักษณะของสัญญาณไฟฟ้าแบบ 1 มิติ และบันทึกการใช้งานด้วยบ้านจำนวน 6 หลังคา เรือน ประกอบไปด้วยอุปกรณ์ 8 ชนิด ได้ประสิทธิภาพของอัลกอริทึมร้อยละ 80 ของการฝึกฝน ผลการ ทดลองแสดงไว้ในรูปที่ 2.12




รูปที่ 2.12 ประสิทธิภาพ C-NN ร่วมกับ R-NN และ LSTM

ใน [38] อธิบายถึงการประยุกต์ใช้ hybrid-convolutional ของโมเดล CNN ร่วมกับ GLU สำหรับการตรวจรู้สภาวะโหลดแบบไม่ล่วงล้ำ โครงข่ายของ C-NN ประกอบด้วยชั้นการกรอง (sequence to sequence: seq2seq) ดังรูปที่ 2.13, Activation function และชั้น Full Connected ร่วมกับการกรองแบบ Residual ทั้งหมด 12 ชั้น ทดสอบด้วยฐานข้อมูลสภาวะโหลดแบบ REDD เป็นข้อมูลที่เปิดเผยสาธารณะ ประกอบด้วยข้อมูลของบ้าน 2 หลัง มีอุปกรณ์การทำงาน 6 ชนิด ได้แก่ หลอดไฟ ไมโครเวฟ เครื่องอบ เครื่องซักผ้า ตู้เย็น และเครื่องล้างจาน อุปกรณ์มีกำลังวัตต์แตกต่างกันชัดเจน อุปกรณ์แต่ละชนิดเปิดใช้งาน 14 วัน ประสิทธิภาพของ seq2seq ดีกว่าในส่วนของอุปกรณ์ หลอดไฟ ตู้เย็น และ เครื่องล้างจาน




รูปที่ 2.13 โครงข่ายประสาทเทียมแบบ C-NN ร่วมกับ GLU

ใน [39] มุ่งเน้นทดลองอุปกรณ์ใช้ไฟฟ้าประเภทที่สอง ได้แก่ เครื่องใช้ไฟฟ้าที่มีลักษณะการทำงานของโหลดแบบเปลี่ยนสถานการณ์ทำงานตลอดเวลา (multi-functional: Type II appliances) การเก็บข้อมูลมีลักษณะแบบ 1 มิติ ทดลองด้วยข้อมูลกำลังวัตต์รวม บันทึกการทำงานของอุปกรณ์จากการเปิด-ปิด (ON-OFF) การทดลองปรับโครงข่ายประสาทเทียมแบบคอนโวลูชัน ประมวลผลด้วยจำนวนของลำดับชั้น C-NN จำนวน 18 ชั้น ประกอบด้วยชั้น Convolution 10 ชั้น, ชั้น MaxPooling 4 ชั้น, ชั้น Full Connected 3 ชั้น แต่ละชั้นประกอบด้วย 1000 โหนด โดยมี 1 คลาสเป็นเอ๊าท์พุท ดังรูปที่ 2.14




รูปที่ 2.14 โครงข่าย C-NN จำนวน 18 ชั้น

ใน [40] มุ่งเน้นไปยังการระบุการเปลี่ยนแปลงของโหลดในการตรวจจับทรานเซียนท์ โดยอาศัยการตรวจจับแบบ zero-cross หรือ ความคล้ายคลึงกันของอุปกรณ์ ลดระดับชั้นของโครงข่าย (100*32, 50*32, 50*64, 25*64, 25*32, 12*32) โดยมี fully connected จำนวน 2 ชั้น ดังรูปที่ 2.15 ผลการฝึกฝนมีประสิทธิภาพ ใช้เวลาดาวน์โหลดประมาณ 7 นาที เวลาในการประมวลผลต่อ 1 รอบโดยเฉลี่ย 105 ms ผลการทดสอบสามารถจดจำอุปกรณ์ได้ทั้งอุปกรณ์แบบเดี่ยวหรือใช้ร่วมกับโหลดอื่นๆ ผลลัพธ์มีอัตราความผิดพลาดประมาณ 3% ในการตรวจจับอุปกรณ์



รูปที่ 2.15 โครงข่าย C-NN แบบ 1 มิติ

ใน [41] จากรูปที่ 2.16 นำเสนอ BiLSTM ร่วมกับ dAE มุ่งเน้นไปยังการสร้างโมเดลแบบใหม่สำหรับระบุโหนดแบบไม่ลวงล้ำ โมเดลมีลักษณะการ convolutional ใหม่ตามบล็อกเพื่อลดระยะเวลาโดยมีการเพิ่มเลเยอร์สำหรับการเรียนรู้คุณลักษณะที่มีความซับซ้อน อีกทั้ง ลดระดับของโครงข่ายและชั้นข้อมูลลง เพื่อลดปริมาณพารามิเตอร์ของแบบจำลองที่มากเกินไป สามารถรับหน้าต่างคอร์เนลขยายกว้างขึ้น และสามารถเรียนรู้คุณลักษณะการทำงานร่วมกันของอุปกรณ์ได้ยิ่งขึ้น ทดลองโดยใช้ฐานข้อมูล UK-DALE ซึ่งเป็น ฐานข้อมูล NILM ที่ได้รับการยอมรับ



รูปที่ 2.16 โครงข่าย BiLSTM

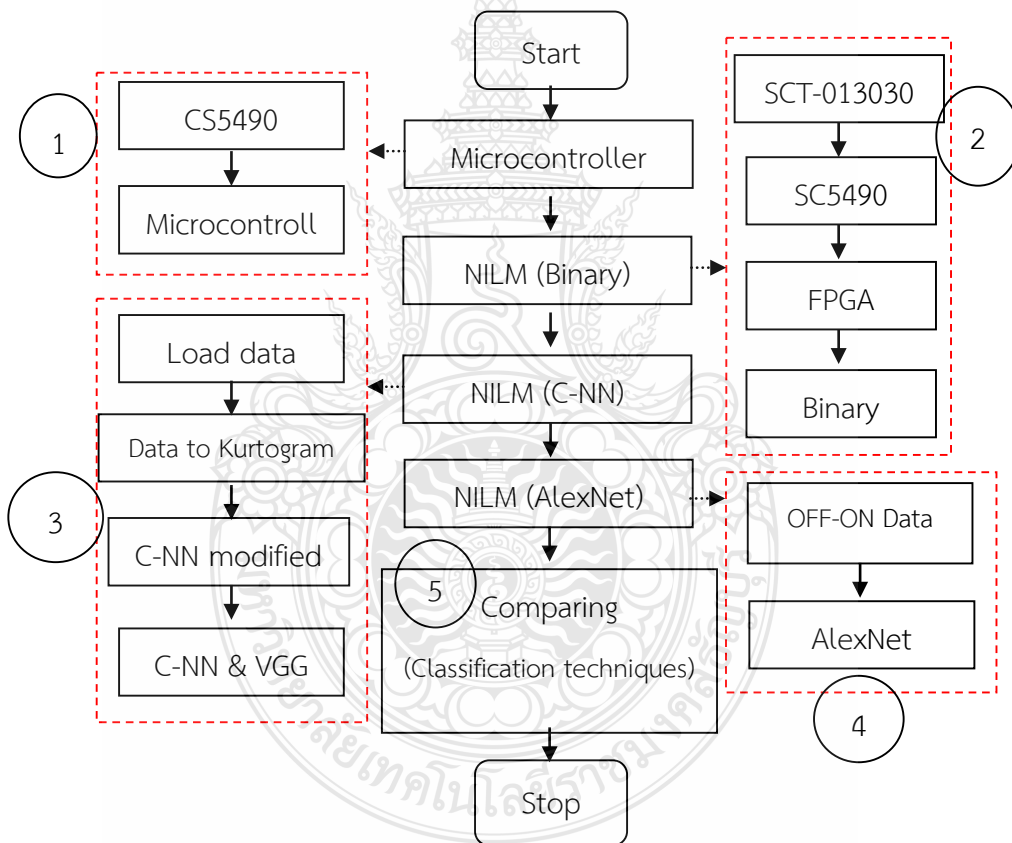
ดังที่กล่าวมาข้างต้น, การศึกษานี้นำเสนอการพัฒนาเทคนิคการตรวจรู้สภาวะโหนดแบบไม่ลวงล้ำ โดยใช้เทคนิคการเรียนรู้เชิงลึก มุ่งเน้นไปยังการออกแบบวงจรวัดสัญญาณ ลักษณะข้อมูลภาพแบบสเปกตรัม (เคอร์โทแกรม) สำหรับเพิ่มลักษณะเด่นที่แตกต่าง นอกจากนี้ ได้ปรับเปลี่ยนโครงข่ายการเรียนรู้เชิงลึกเพื่อเพิ่มประสิทธิภาพของการตรวจรู้โหนด และ ลดเวลาในฝึกฝน ดังนั้นจะกล่าวถึงในการทดลองลำดับถัดไป

บทที่ 3

วิธีดำเนินการวิจัย

3.1 ขั้นตอนการทำงานของ การตรวจรู้สภาวะโหลดแบบไม่ล่วงล้ำ

บทนี้จะกล่าวถึงรายละเอียดการดำเนินการวิจัย ดังรูปที่ 3.1 แบ่งออกเป็นห้าส่วนได้แก่ 1). การตรวจวัดอุปกรณ์ใช้ไฟฟ้าด้วยไมโครคอนโทรลเลอร์, 2). การออกแบบระบบตรวจรู้โหลดทางไฟฟ้าด้วยการวิเคราะห์แบบไบนารี, 3). การตรวจรู้โหลดด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน, 4). ศึกษาสภาวะ ON/OFF ร่วมกับโมเดล AlexNet, 5). การเปรียบเทียบประสิทธิภาพของวิธีดังเสนอ



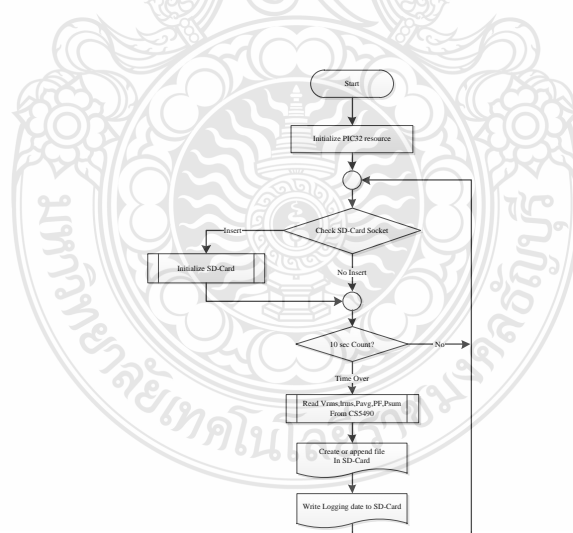
รูปที่ 3.1 การดำเนินการวิจัย

วิธีดำเนินการวิจัยดังรูปที่ 3.1 การประมวลผลอันดับแรก, อธิบายถึงการออกแบบวิธีตรวจวัดการทำงานของอุปกรณ์ใช้ไฟฟ้าด้วยไมโครคอนโทรลเลอร์ร่วมกับ CS5490 ส่วนที่สอง, อธิบายถึงการออกแบบระบบด้วยเพาเวอร์มิเตอร์, CS5490, อุปกรณ์ลอจิกแบบโปรแกรม (FPGA) ในการเข้าถึงและบันทึก

ข้อมูลของอุปกรณ์ อีกทั้งอธิบายถึงการตรวจรู้ไหลดด้วยเทคนิคดิจิทัลไบนารี (digital binary) ซึ่งเป็นการคำนวณแบบขนาน การประมวลผลอันดับที่สาม, อธิบายถึงเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันที่มีข้อดีในด้านการสกัดคุณลักษณะของข้อมูล ทดลองด้วยการปรับเปลี่ยนโครงข่ายและพารามิเตอร์ที่เหมาะสมสำหรับการตรวจรู้สถานะไหลดที่มีความซับซ้อน การประมวลผลอันดับที่สี่, การทดลองด้วย AlexNet เป็นการศึกษาสถานะ ON/OFF ภายใต้อข้อมูลแบบเคอร์โทแกรม วิธีดั่งนำเสนอเป็นการทดลองแบบใหม่ในการพัฒนา NILM สุดท้าย, ทดลองด้วย Deep C-NN เพื่อเปรียบเทียบผลกับวิธีดั่งเสนอ อธิบายไว้โดยละเอียดดั่งต่อไปนี้

3.2 การออกแบบและการตรวจวัดอุปกรณ์ใช้ไฟฟ้าด้วยไมโครคอนโทรลเลอร์

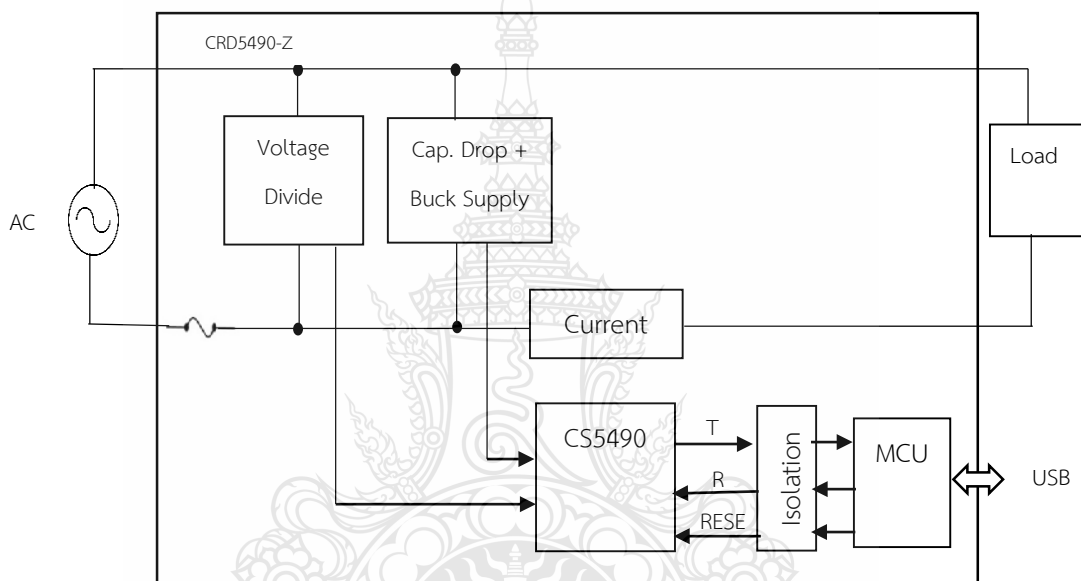
จากการดำเนินการวิจัยในรูปที่ 3.1 (การทดลองที่ 1) มีแนวคิดที่จะพัฒนาวงจรที่มีความสามารถตรวจวัดกำลังไฟฟ้าและบันทึกการทำงานของอุปกรณ์ โดยแสดงผลข้อมูลทางไฟฟ้าแบบเรียลไทม์ เพื่อตรวจสอบข้อมูลการใช้ไฟฟ้า และปรับเปลี่ยนพฤติกรรมการใช้ไฟฟ้าให้มีประสิทธิภาพ เพื่อช่วยให้ผู้ใช้ไฟฟ้าสามารถประหยัดค่าใช้จ่ายได้ ผู้ศึกษาพัฒนาโดยใช้ไมโครคอนโทรลเลอร์ PIC32 ซึ่งเป็นไมโครคอนโทรลเลอร์ที่นิยม เนื่องจากความเร็วในการประมวลผลสำหรับชุดไมโครคอนโทรลเลอร์ อีกทั้งการพัฒนารองรับการส่งข้อมูลการใช้พลังงานแบบเรียลไทม์ พัฒนาร่วมกับไอซีตรวจวัดพลังงาน CS5490 ที่มีความสะดวก รวดเร็ว และ วัดค่าได้หลายค่า แสดงขั้นตอนการทำงานดั่งรูปที่ 3.2



รูปที่ 3.2 แผนผังการออกแบบการตรวจรู้ไหลดด้วยไมโครคอนโทรลเลอร์


จากรูปที่ 3.2 การออกแบบการตรวจรู้ไหลดด้วยไมโครคอนโทรลเลอร์ เริ่มต้นจาก PIC32 กำหนดขาอินพุต เอาต์พุต และ เปิดการใช้งานโมดูล จากนั้นโปรแกรมจะทำการเช็คสถานะของ SD Card ที่ใช้

บันทึกผลการใช้พลังงานว่ามีหรือไม่ หากไม่มีจะทำการตรวจสอบสถานะวนซ้ำในทุกๆ 10 วินาที หากโปรแกรมตรวจสอบเจอ SD Card จะทำการโปรแกรมค่าเริ่มต้นให้ SD Card เพื่อบันทึกผลการวัดพลังงานจากเซ็นเซอร์ในทุกๆ 10 วินาที แล้วเก็บค่า Irms, Vrms, Psum, Pavg จากนั้นไอซี CS5490 จะทำหน้าที่วัดค่าพลังงาน และ ทำการสร้างไฟล์ขึ้นมาเพื่อเก็บค่าพารามิเตอร์ต่างๆ แล้วบันทึกลง SD Card และ วนโปรแกรมตรวจสอบสถานะ SD Card อีกครั้ง โดยวนซ้ำแบบนี้เรื่อยๆ กำหนดการทำงานซ้ำของโปรแกรมในการตรวจสอบว่ามีไฟล์อยู่หรือไม่ หากไม่มีไฟล์จะสร้างขึ้นใหม่ หากมีไฟล์อยู่แล้วจะทำการบันทึกผลการวัดพลังงานต่อจากไฟล์เดิม



รูปที่ 3.3 บล็อกไดอะแกรม

การออกแบบวิธีการวัดค่าใช้พลังงานไฟฟ้าด้วย CS5490 เมื่อส่งข้อมูลผ่านหน่วยประมวลผล PIC32 จากรูปที่ 3.3 อินพุตของไอซีวัดพลังงานรับค่ากระแสไฟจาก CURRENT SENSOR และ ค่าแรงดัน จาก Voltage Divide Sensor โดย Cap Drop Buck Supply เป็นภาคจ่ายไฟเลี้ยง 3.3 โวลต์ ให้แก่ไอซีวัดพลังงาน เมื่อต่อโหลดให้ไอซีวัดพลังงาน ไอซีจะทำส่งค่ากระแสและแรงดันจากอินพุต ส่งข้อมูลออกไปยังวงจร Isolation เป็นวงจรเชื่อมต่อระหว่างไอซีวัดพลังงานและหน่วยประมวลผล PIC32 ผ่านระบบ RS232 เมื่อหน่วยประมวลผล PIC32 ได้รับข้อมูล จะทำการบันทึกข้อมูลต่างๆ จากไอซีลง SD CARD เพื่อใช้ข้อมูลเหล่านี้ไปใช้ในการวิเคราะห์การใช้พลังงานต่อไป




รูปที่ 3.4 การต่อไอซีวัดพลังงาน CS5490 กับ PIC32

จากรูป 3.4 และ รูปที่ 3.5 การต่อวงจรไอซี CS5490 กับบอร์ดไมโครคอนโทรลเลอร์ PIC32 โดยหน่วยประมวลผล PIC32 (A) เป็นตัวรับข้อมูลจากวงจรไอซี CS5490 (B) ผ่านมาตรฐานการส่งข้อมูลแบบ UART ด้วยระบบ RS232 ก่อนที่จะส่งค่าการใช้พลังงานไปยัง SD Card (C) โดย (D) คือแหล่งจ่ายไฟให้กับวงจร การทดลองนี้ต่อเข้ากับโหลด 4 ชนิด และทำการทดลองปิด-เปิดแต่ละโหลดเพื่อให้เห็นการเปลี่ยนแปลงของข้อมูลที่น่ามาวิเคราะห์




รูปที่ 3.5 ไอซีวัดพลังงาน CS5490

ระยะเวลาในการเก็บข้อมูลสามารถเปลี่ยนแปลงความถี่ (sampling) ในการเก็บข้อมูลโดยละเอียด เพื่อนำไปวิเคราะห์ได้อย่างถูกต้อง ค่าเวลา 10 วินาที เป็นเพียงความถี่ในการเก็บข้อมูลของการทดลองเท่านั้น



รูปที่ 3.6 (A) ภาคจ่ายไฟ (B) วงจรไอซีวัดพลังงาน (C) Voltage Divider Sensor Current Sensor


จากรูปที่ 3.6 การออกแบบวงจรวัดพลังงานแบ่งออกเป็น 3 ส่วน จากรูป (A) จ่ายไฟเลี้ยง 3.3 โวลต์ให้ไอซีวัดพลังงาน โดยใช้ไดโอด 1N4007 เรียงกระแสไปยังไอซีเรกกูเลเตอร์ LM2575HV เป็นตัวลดระดับแรงดัน และ รักษาระดับแรงดันด้วยซีเนอร์ 1N5817 จากรูป (B) วงจรไอซีวัดพลังงาน รับไฟเลี้ยงจากภาคจ่ายไฟ โดยต่อคริสตอล 4.096MHz ให้กับไอซี ส่วนเอาต์พุตที่ขา Rx และ Do ต่อผ่าน PC817C เพื่อเชื่อมต่อสัญญาณระหว่างวงจรไอซีวัดพลังงานกับวงจร Isolator ที่เป็นส่วนเชื่อมระหว่างไอซีวัดพลังงานกับหน่วยประมวลผล PIC32 สัญญาณไฟฟ้าจากไอซีวัดพลังงานมีขนาด 3.3V ใช้ PC817C เชื่อมต่อส่งสัญญาณไฟฟ้าไปยังวงจร Isolator ขนาด 5V เพื่อป้องกันการรบกวนของสัญญาณ โดยขา Tx ที่รับสัญญาณจากวงจร Isolator ต่อผ่าน PC817C ก่อนเข้ามาที่ไอซีวัดพลังงานเพื่อลดการรบกวนของสัญญาณเช่นกัน จากรูป (c) วงจรด้านบนเป็นภาค current sensor วัดค่ากระแสโดยต่อกับ CT และ ให้เอาต์พุตไปยังไอซี CS5490 ที่จุด IIN+ และ IIN- ส่วนวงจรด้านล่างเป็นภาค voltage sensor วัดค่าแรงดันจากโวลต์ และ ส่งเอาต์พุตไปยังไอซี CS5490 ที่จุด VIN+ และ VIN- ซึ่งแสดงการออกแบบ PCB จริง ดังรูปที่ 3.7 แสดงผลการวัดค่าพลังงานในรูปที่ 4.1, รูปที่ 4.2 และ รูปที่ 4.3



รูปที่ 3.7 ออกแบบ PCB ของไอซีวัดพลังงาน CS5490

3.3 การออกแบบและการตรวจรู้สภาวะโหลดแบบไม่ล่วงล้ำด้วยการวิเคราะห์แบบไบนารี

จากขั้นตอนการทำงานในรูปที่ 3.1 (การทดลองที่ 2) ผู้ศึกษาออกแบบ NIML ดังรูปที่ 3.8 เป็นการนำผลรวมของการทำงานของอุปกรณ์ใช้ไฟฟ้า (กำลัง, กระแสไฟฟ้า หรือ แรงดัน) มาวิเคราะห์ด้วยประยุกต์ใช้อุปกรณ์ทางไฟฟ้าหรือวิธีทางคณิตศาสตร์




รูปที่ 3.8 การออกแบบระบบตรวจรู้สภาวะโหลด

3.3.1 การเข้าถึงอุปกรณ์ด้วยเพาเวอร์มิเตอร์และโมดูล CS5490

จากรูปที่ 3.8 การเข้าถึงอุปกรณ์ทางไฟฟ้า อันดับแรกทำการวัดกำลังใช้งาน (Watt) โดยอาศัย SCT-013-030 ซึ่งเป็นเซนเซอร์วัดกระแสและแรงดันแบบแกนแยกมีความสามารถในการรับรู้กระแสได้สูงสุดที่ 30A มีแรงดันเอาต์พุต 1 (V_{p-p}) ลักษณะทางสัญญาณโดยรวมที่ได้จากเพาเวอร์มิเตอร์ส่งต่อไปยังโมดูล CS5490 A/D แปลงสัญญาณดิจิตอลเป็นสัญญาณอนาล็อก แสดงการเชื่อมต่อดังรูปที่ 3.9 (ก)

เมื่อ A คือ สายสัญญาณ RS เชื่อมระหว่างเฟาเวอร์มิเตอร์ร่วมกับ data logger, B คือตำแหน่งของการวัดระดับแรงดัน/กระแส, C คือตำแหน่งของการบันทึกค่าพลังงาน และ ในรูปที่ 3.9 (ข) คือ ภาพรวมของ circuit breaker



(ก) ตำแหน่งของการวัดค่าพลังงาน




(ข) ภาพรวมของการเชื่อมต่ออุปกรณ์

รูปที่ 3.9 ภาพรวมของการต่ออุปกรณ์ใช้ไฟฟ้าร่วมเฟาเวอร์มิเตอร์

3.3.2 อุปกรณ์ลอจิกแบบโปรแกรมและการตรวจรู้ไหลดด้วยเทคนิคไบนารี

จากรูปที่ 3.9 สัญญาณดิจิตอลที่ผ่านโมดูล CS5490 จะถูกป้อนให้กับ FPGA ทดลองโดยบอร์ด DE2-115 จากโปรแกรม QUARTUS 15.0 มีหน้าที่ตรวจรู้สภาวะไหลดทางไฟฟ้าแบบไม่ลวงล้าโดยใช้เทคนิค digital binary ดังรูปที่ 3.10 (a) การทำงานของอุปกรณ์ลอจิกแบบโปรแกรม และ รูปที่ 3.10 (b) logic element ของ FPGA



(ก) ภาพรวมการจำแนกไหลดด้วย FPGA

Device	EP4CE115F29C7
Timing Models	Final
Total logic elements	6,565 / 114,480 (6 %)
Total combinational functions	5,276 / 114,480 (5 %)
Dedicated logic registers	4,263 / 114,480 (4 %)
Total registers	4313
Total pins	525 / 529 (99 %)
Total virtual pins	0
Total memory bits	2,188,160 / 3,981,312 (55 %)

(ข) logic element ของ FPGA

รูปที่ 3.10 การทำงานของอุปกรณ์ลอจิกแบบโปรแกรม

จากรูปที่ 3.10 การตรวจรัฐสภาวะโหนดแบบไม่ลวงล้ำด้วยการวิเคราะห์ไบนารี อาศัยการหาค่ากำลังวัตต์โดยรวม $P_{max} = P_1 + P_2 + P_3 + P_4 + P_{n+1}$ เมื่อ P_{max} คือ กำลังไฟฟารวมของอุปกรณ์ และ P_1, P_2, P_3, P_4 คือ กำลังไฟฟ้าของแต่ละอุปกรณ์, การแยกแยะอุปกรณ์นั้นเทคนิค digital binary คำนวณในลักษณะเลขไบนารีหรือเลขฐานสองบนพื้นฐานของ FPGA มีการประมวลผลข้อมูลแบบขนานทำให้สามารถเพิ่มจำนวนของโหนดทางไฟฟ้าที่ทดลองได้จำนวนมากโดย:

ตารางที่ 3.1 การตรวจรัฐอุปกรณ์โดยใช้เลขไบนารี (Look Up-Table) ต้องคำนึงถึงสถานะของกำลังไฟฟ้าที่ใช้จริง Power on หรือ (P_{on}) เปรียบเทียบกับกำลังไฟฟ้าอ้างอิง Power reference หรือ (P_{ref}) การเปรียบเทียบเลขไบนารีสามารถอธิบายได้ เช่น เมื่อ P_1 อยู่ในสภาวะ “ON” หรือ P_{ON} ค่าที่ FPGA คำนวณได้จะมีค่าตามเงื่อนไข คือ $P_{1ON} \approx P_{1ref}$ และ เงื่อนไขการตัดสินใจมีสภาวะเท่ากับ “0001” ในเลขไบนารี ซึ่งเป็นการเปรียบเทียบสถานการณ์ทำงานของอุปกรณ์ตัวที่ 1

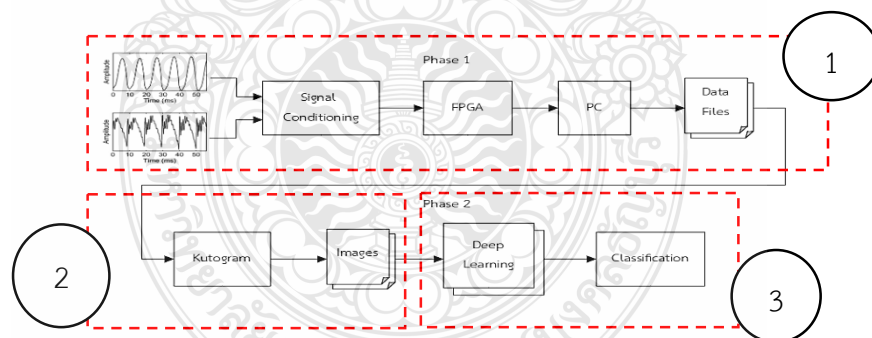
ตารางที่ 3.1 การจำแนกด้วยเทคนิคแบบไบนารี

Condition	P_{4ref}	P_{3ref}	P_{2ref}	P_{1ref}	P_{nref}
0	F	F	F	F	0
1	F	F	F	N	P_{1ref}
2	F	F	N	F	P_{2ref}
3	F	F	N	N	$P_{2ref} + P_{1ref}$
4	F	N	F	F	P_{3ref}
5	F	N	F	N	$P_{3ref} + P_{1ref}$
6	F	N	N	F	$P_{3ref} + P_{2ref}$
7	F	N	N	N	$P_{3ref} + P_{2ref} + P_{1ref}$
8	N	F	F	F	P_{4ref}
9	N	F	F	N	$P_{4ref} + P_{1ref}$
10	N	F	N	F	$P_{4ref} + P_{2ref}$
11	N	F	N	N	$P_{4ref} + P_{2ref} + P_{1ref}$
12	N	N	F	F	$P_{4ref} + P_{3ref}$
13	N	N	F	N	$P_{4ref} + P_{3ref} + P_{1ref}$
14	N	N	N	F	$P_{4ref} + P_{3ref} + P_{2ref}$
15	N	N	N	N	$P_{4ref} + P_{3ref} + P_{2ref} + P_{1ref}$
n	N	N	N	N	P_{MAX}

การทดลองนี้ใช้อุปกรณ์ไฟฟ้าจำนวน 4 ชนิด " 38 ' อร์ขนาด 30,000 BTU ($\approx 8,792$ W), แอร์ขนาด 18,000 BTU ($\approx 5,275$ W), ตู้แช่เย็น (≈ 70 ะ บีมน้ำ (≈ 150 W) แบ่งแยกตามลักษณะการทำงานอยู่ในหมวดที่ (1), หมวดที่ (2) และ หมวดที่ (4) มีกระบวนการทดลองตามลักษณะการทำงานได้แก่ อุปกรณ์ทำงานพร้อมกัน 2 ชนิดเป็นการทดลองที่ 1, อุปกรณ์ทำงานพร้อมกัน 3 ชนิดเป็นการทดลองที่ 2 และอุปกรณ์ทำงานพร้อมกัน 4 ชนิดเป็นการทดลองที่ 3 ผลการทดลองในรูปที่ 4.4, รูปที่ 4.5 และ รูปที่ 4.6

3.4 การตรวจรู้โหลดด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน

การพัฒนาในดั่งหัวข้อก่อนหน้า, ประสบปัญหาการตรวจรู้อุปกรณ์ชนิดเดียวกันทำงานพร้อมกันสาเหตุจากการวิเคราะห์ไบนารีเป็นการกำหนดจำนวนวัตต์ตามจำนวนของอุปกรณ์ ด้วยเหตุนี้ผู้ทดลองนำเทคนิคการเรียนรู้เชิงลึกมาพัฒนา จากรูป 3.1 (การทดลองที่ 3) แบ่งเป็นสามส่วนได้แก่ การเข้าถึงข้อมูล การพัฒนาลักษณะข้อมูลที่แตกต่างโดยเปลี่ยนลักษณะชุดข้อมูลให้อยู่ในรูปสองมิติ (2D images) เพื่อเพิ่มความสามารถในการเรียนรู้ลักษณะจำเพาะ หรือ พฤติกรรมข้อมูลนั้นๆ และ การตรวจรู้โหลดด้วยการเรียนรู้เชิงลึก อธิบายการทดลองโดยละเอียดในรูปที่ 3.11




รูปที่ 3.11 การดำเนินการตรวจรู้สถานะโหลดแบบไม่ล่วงล้ำด้วยการเรียนรู้เชิงลึกแบบคอนโวลูชัน


3.4.1 วงจรควบคุมระดับกระแสแรงดันและอุปกรณ์ลอจิกแบบโปรแกรม

จากรูปที่ 3.11, การทดลองส่วนที่หนึ่ง, เป็นการเข้าถึงข้อมูลอุปกรณ์หรือการออกแบบระบบบันทึกข้อมูลทางไฟฟ้าโดยผู้วิจัยแบ่งออกเป็นสองส่วนดัง:

1). วงจรปรับระดับสัญญาณ (Signal Conditioning: SC) มีหน้าที่ปรับระดับแรงดันไฟฟ้าให้เหมาะสมก่อนส่งให้กับบอร์ด ออกแบบโดยใช้ Op-Amp ทำหน้าที่ขยายสัญญาณทั้งสองได้แก่ สัญญาณที่มาจาก PT และ CT มีอัตราขยายสัญญาณขึ้นกับตัวต้านทานปรับค่าได้ (VR) ทั้งนี้ยังเป็นการออกแบบเพื่อให้สามารถปรับแรงดันได้อย่างอิสระ เนื่อง ับสัญญาณอินพุตที่ได้มีมาก-น้อยต่างกันขึ้นอยู่กับกำลังทำงานของอุปกรณ์แต่ละชนิด ดังรูปที่ 3.1




(ก) วงจรควบคุม Schematic




(ข) PCB ของ Schematic

รูปที่ 3.12 วงจรควบคุมระดับสัญญาณและ PCB ของวงจร


2). การออกแบบวงจรภายใน FPGA ใช้โปรแกรม Quartus II ดังรูปที่ 3.13 (ก) ข้อมูลที่ผ่าน SC เป็นแรงดัน PT และ CT ส่งไปยังบอร์ด DECA Altera MAX 10 FPGA Evaluation board แสดงภาพรวมของวงจรภายในดังรูปที่ 3.13 (ข) และ ภาพรวมการเชื่อมต่อของการเข้าถึงข้อมูลของโหนดดังรูปที่ 3.13 (ค) ทั้งนี้ผลจากการเก็บแรงดันจาก FPGA ผู้วิจัยนำมาพัฒนาฐานข้อมูลด้วยการแปลงเป็นข้อมูลแบบเคอร์โทแกรม ซึ่งสามารถแสดงลักษณะเด่นของสัญญาณทางไฟฟ้าโดยจะอธิบายในลำดับต่อไป



(ก) ออกแบบวงจรภายใน FPGA โดยใช้โปรแกรม Quartus II



(ข) วงจรภายใน FPGA

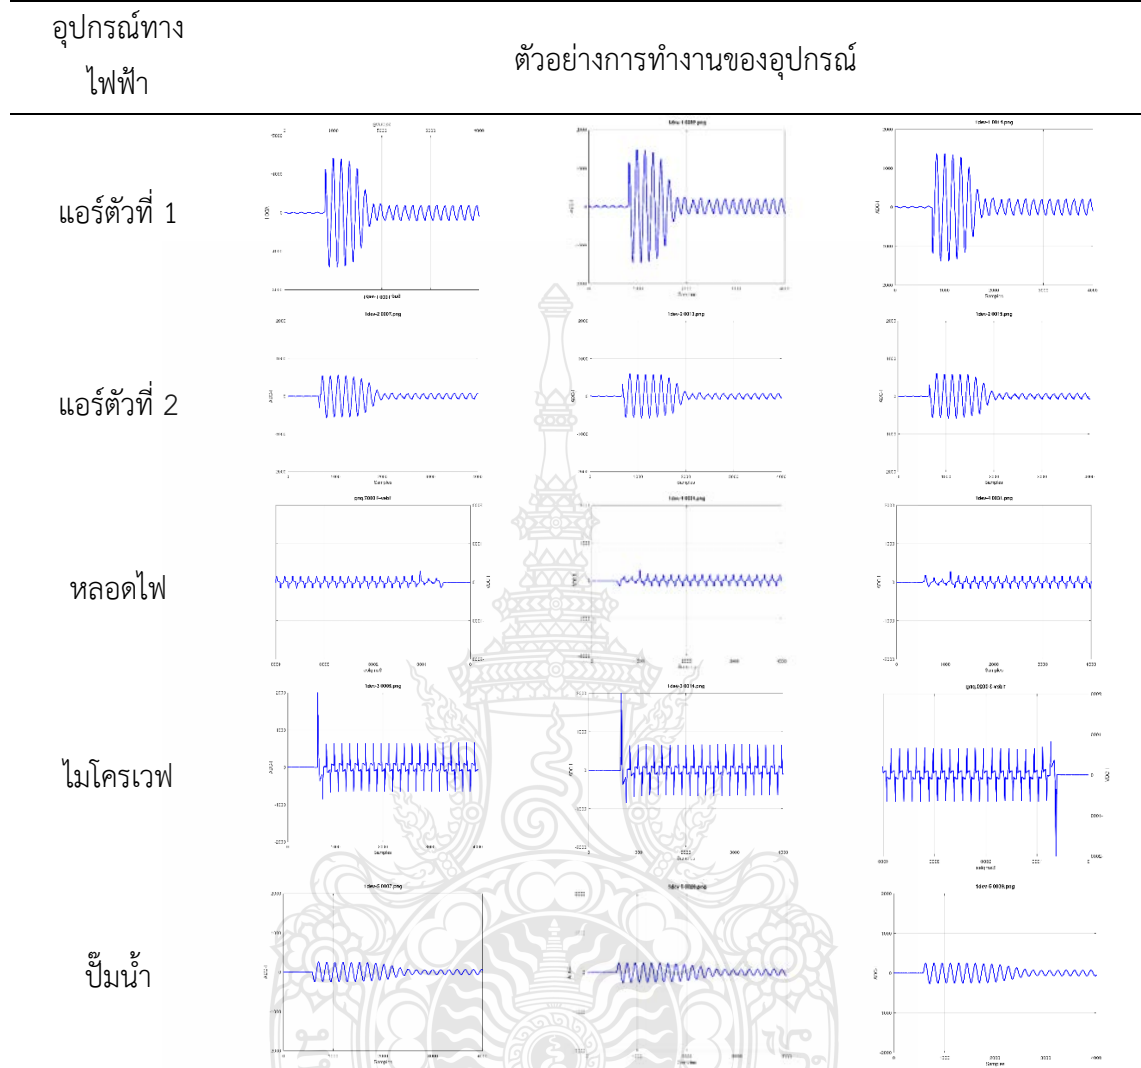


(ค) ภาพรวมของการเก็บข้อมูลสัญญาณ

รูปที่ 3.13 การออกแบบวงจรภายใน FPGA โดยใช้โปรแกรม Quartus II

การทดลองนี้บันทึกการทำงานของอุปกรณ์จำนวน 5 ชนิด ได้แก่ แอร์ขนาด 30,000 BTU ($\approx 8,792$ W), แอร์ขนาด 18,000 BTU ($\approx 5,275$ W), หลอดไฟ (≈ 100 W), ไมโครเวฟ (≈ 800 W) และ ปั้มน้ำ (≈ 150 W), การทดลองเปลี่ยนแปลงและเพิ่มอุปกรณ์จากการทดลองในรูปที่ 3.8 เพื่อให้มีลักษณะการทำงานในหมวดที่ (1) ถึงหมวดที่ (4) โดยบันทึกการทำงานตั้งแต่เปิดเครื่องจนถึงช่วงอิมตัว (stable) ดังตารางที่ 3.2


ตารางที่ 3.2 ตัวอย่างลักษณะรูปคลื่นไซน์ของอุปกรณ์



3.4.2 การพัฒนาฐานข้อมูลแบบเคอร์โทแกรม

จากรูปที่ 3.11, การทดลองส่วนที่สอง, แปลงข้อมูลการทำงานในตารางที่ 3.2 ให้อยู่ในลักษณะของเคอร์โทแกรม ดังในสมการที่ 1 และสมการที่ 2 โดยที่ข้อมูลอินพุตเป็นการทำงานของอุปกรณ์, ข้อมูลเอาต์พุตคือ ข้อมูลภาพสองมิติ (สเปกตรัม) ผลของการแปลงเคอร์โทแกรม ดังตารางที่ 3.3

ตารางที่ 3.3 ข้อมูลของอุปกรณ์ทางไฟฟ้าแบบเคอร์โทแกรม



รายละเอียดการบันทึกจำนวนภาพเคอร์โทแกรมในแต่ละชุดข้อมูล ภาพถูกปรับขนาดเป็น $100 \times 100 \times 3$ พิกเซล แบ่งข้อมูลเป็นชุดฝึกฝน ชุดตรวจสอบ และชุดทดสอบ ตามลำดับ แบ่งจำนวนของข้อมูลจากการสุ่มและรักษาสัดส่วนของคลาสเดียวกันกับภาพทั้งหมด สรุปจำนวนภาพในแต่ละชุดข้อมูลไว้ในดังตารางที่ 3.4

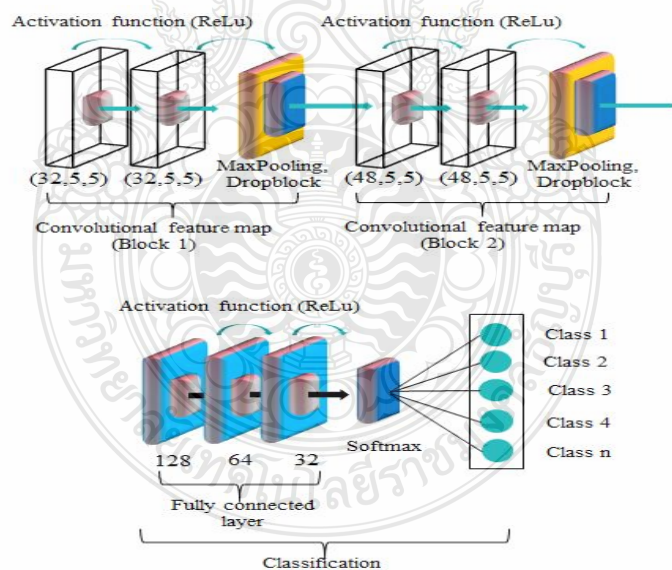
ตารางที่ 3.4 ข้อมูลแบบเคอร์โทแกรม

ชุดข้อมูล	ชุดฝึกฝน (จำนวน)	ชุดตรวจสอบ (จำนวน)	ชุดทดสอบ (จำนวน)
แบบเดี่ยว (5 class)	4,000	500	500
ทำงานพร้อมกันสองชนิด (5 class)	4,000	500	500
ทำงานพร้อมกันสามชนิด (5 class)	4,000	500	500
ทำงานพร้อมกันสี่ชนิด (5 class)	4,000	500	500

3.4.3 การตรวจรู้สภาวะโหลตแบบไม่ล่วงล้ำด้วยโครงข่ายคอนโวลูชัน

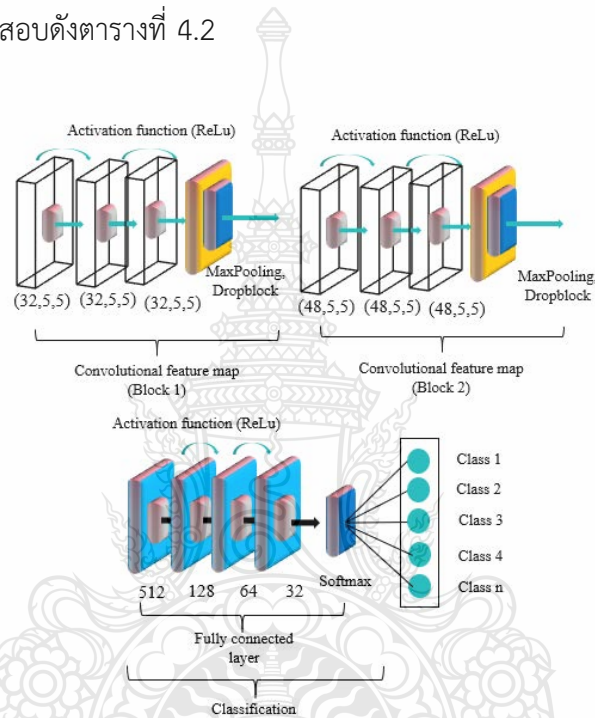
จากรูปที่ 3.1 การทดลองส่วนที่สี่, ดำเนินการด้วยการเรียนรู้เชิงลึกแบบคอนโวลูชัน ทดลองด้วยการปรับเปลี่ยนโครงข่ายใหม่เพื่อให้มีประสิทธิภาพที่ดียิ่งขึ้น วิธีดังกล่าวมีความยืดหยุ่นในการวิเคราะห์ข้อมูล การทดลองนี้ออกแบบโมเดลดังนี้:

จากรูปที่ 3.14 เทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 1) โครงสร้างของ C-NN ผู้วิจัยปรับโครงข่ายของ LeNet-5 ร่วมกับ DropBlock กำหนดพารามิเตอร์การเรียนรู้แบบ Adam มีระดับการเพิ่มประสิทธิภาพในช่วง (Bata 0.9 ถึง 0.999) จำนวนการฝึกฝน 500 รอบ มีรายละเอียดโครงข่ายประกอบด้วย ConV ขนาด (32, 5, 5) จำนวน 2 ชั้น ขนาดของตัวกรอง 5*5 และ ConV ขนาด (48, 5, 5) จำนวน 2 ชั้น ขนาดของตัวกรอง 5*5 ซึ่งเพิ่มเทคนิคการ optimizer ด้วย DropBlock โดยมีขนาดของบล็อก (bz = 5) และพารามิเตอร์ควบคุม (KP=0.7) มีหน้าที่คัดข้อมูลออกแบบบล็อกจากการตั้งลักษณะ ทั้งนี้ส่วนของการจำแนกทดลองโดยใช้ FC จำนวน 3 ชั้น ขนาด 128 โหนด, 64 โหนด และ 32 โหนด มีฟังก์ชันผลรวมแบบ Softmax ฝึกฝนด้วยอัตราการเรียนรู้ (Lr) ที่ 0.0001 ขนาดของ batch ที่ 36 ผลการทดลองแสดงประสิทธิภาพการฝึกฝน การตรวจสอบ การทดสอบ และ เวลาการฝึกฝน สรุปไว้ในตารางที่ 4.1




รูปที่ 3.14 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 1

จากรูปที่ 3.15 เทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 2) โครงสร้างของ C-NN ประกอบด้วย ConV ขนาด (32, 5, 5) จำนวน 3 ชั้น ขนาดของตัวกรอง 5*5 และ ConV ขนาด (48, 5, 5) จำนวน 3 ชั้น ขนาดของตัวกรอง 5*5 และ ชั้นของการจำแนกทดลองโดย FC จำนวน 4 ชั้น ขนาด 512 โหนด, 128 โหนด, 64 โหนดและ 32 โหนด มีฟังก์ชันผลรวมของโมเดลแบบ Softmax ฝึกฝนด้วย อัตราการสูญเสีย (Lr) ที่ขนาด 0.0001 ขนาดของ batch ที่ 36 จำนวนการฝึกฝน 500 รอบ แสดง ประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาในการฝึกฝนและ ประสิทธิภาพของการทดสอบดังตารางที่ 4.2




รูปที่ 3.15 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 2

จากรูปที่ 3.16 เทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 3) โครงสร้างของ CNN ประกอบด้วย ConV ขนาด (45, 5, 5) จำนวน 6 ชั้น, ซึ่งมีองค์ประกอบของชั้นซ้อน MaxP ขนาด 5*5 ซึ่งเพิ่มเทคนิคการ optimizer ด้วย DropBlock โดยมีขนาดของบล็อก (bz = 5) และพารามิเตอร์ควบคุม (kp=0.7) จำนวน 2 ชั้นซึ่งอยู่หลังขนาดของ MaxP หน้าที่ตัดข้อมูลออกจากการดึงลักษณะของภาพ ทั้งนี้ส่วนของการจำแนกทดลองโดยใช้ FC จำนวน 3 ชั้นขนาด 1024 โหนด, 512 โหนดและ 128 โหนด มีฟังก์ชันผลรวมแบบ Softmax ตัวอย่างผลการทดลองด้วย Lr ที่ขนาด 0.0001 ขนาดของ batch ที่ 36 จำนวนการฝึกฝน 500 รอบ แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาในการฝึกฝนและประสิทธิภาพของการทดสอบดังตารางที่ 4.3




รูปที่ 3.16 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 3

จากรูปที่ 3.17 เทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 4) ผู้ทดลองได้ทำการขยายโครงสร้างของโมเดลที่มีขนาดของชั้นการกรองเพิ่มขึ้นจากโมเดลดังรูปที่ 3.16 ประกอบด้วย 3 บล็อก โดยบล็อกที่ 1 และบล็อกที่ 2 มีชั้น Conv ขนาด (45, 5, 5) จำนวน 3 ชั้น มี MaxP ขนาด 5*5 ทำหน้าที่กรองค่าสูงสุดที่ตัวกรองทับอยู่ บล็อกที่ 3 มีชั้น Conv ขนาด (60, 5, 5) จำนวน 3 ชั้น มี MaxP ขนาด 5*5 ร่วมกับ DropBlock ขนาด $bz = 5$ และ $kp = 0.7$ ทำหน้าที่คัดข้อมูลออกจากการดึงลักษณะของภาพ โครงข่ายมีฟังก์ชันการถ่ายโอนข้อมูลขนาดของเมทริกซ์ที่ 36 (batch size) ในส่วนการจำแนกใช้ FC จำนวน 3 ชั้นขนาด 1024 โหนด, 512 โหนดและ 128 โหนด มีฟังก์ชันผลรวมของโมเดลแบบ Softmax ฝึกฝนด้วยอัตราการเรียนรู้ (Lr) ที่ขนาด 0.0001 จำนวนการฝึกฝน 500 รอบ แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาในการฝึกฝนและประสิทธิภาพของการทดสอบดังตารางที่ 4.4



รูปที่ 3.17 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของโมเดลที่ 4

จากรูปที่ 3.18 ด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 5) โครงสร้างของ C-NN ในบล็อกที่ 1, บล็อกที่ 2 ประกอบด้วย Conv ขนาด (45, 5, 5) จำนวน 3 ชั้นเรียงกันอยู่ และ ในบล็อกที่ 3, บล็อกที่ 4 มี Conv ขนาด (60, 5, 5) จำนวน 3 ชั้น ทุกๆ ชั้นมีตัวกรองขนาด 5*5 (kernel) ร่วมกับ DropBlock ขนาด $bz = 5$ และ $kp = 0.7$ ทำหน้าที่คัดข้อมูลออกแบบบล็อก ในส่วนการจำแนกทดลอง โดยใช้ FC จำนวน 3 ชั้นขนาด 1024 โหนด, 512 โหนด, 128 โหนด มีฟังก์ชันผลรวมแบบ Softmax ฝึกฝนด้วยอัตราการสูญเสีย (Lr) ที่ 0.0001 ขนาดของ batch ที่ 32 ฝึกฝนด้วยจำนวน 500 รอบ แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝน และ ประสิทธิภาพของการทดสอบในตารางที่ 4.5

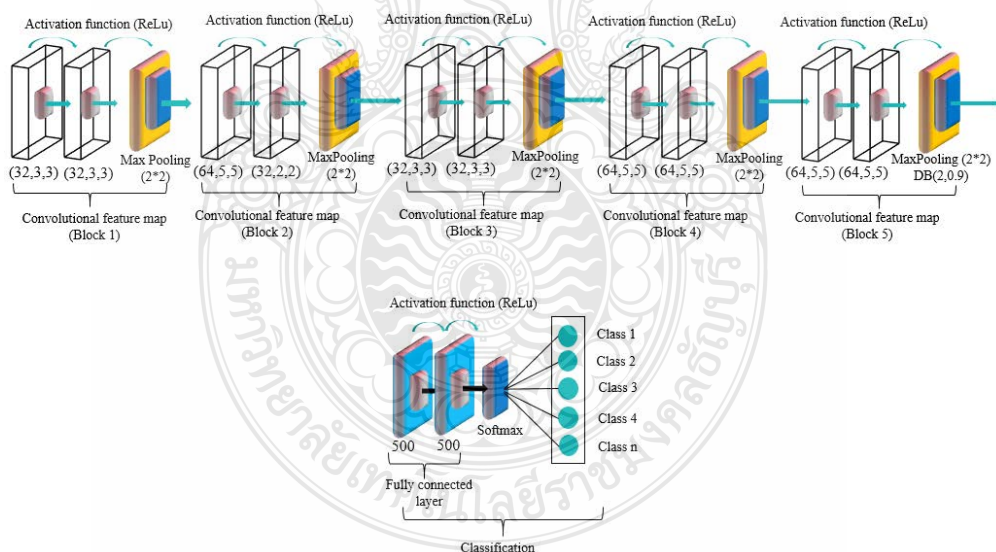


รูปที่ 3.18 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของโมเดลที่ 5

3.3.3 การปรับปรุงโครงข่ายคอนโวลูชันบนพื้นฐานของ VGG


จากการปรับโครงข่ายจากการทดลองของโครงข่าย CNN ในโมเดลที่ 1, 2, 3, 4 และโมเดลที่ 5 แสดงให้เห็นถึงประสิทธิภาพของโมเดล ผลการทดสอบ และ เวลาการทดลอง นอกจากนี้ การทดลองยังสามารถขยายขึ้นได้อีกเนื่อง จากการศึกษา, โมเดลดังเสนอมารถปรับขนาดและการทำงานให้เข้า สอดคล้องกับ VGG Net [40] ซึ่งโมเดลขนาดใหญ่ มีข้อดีที่ความหลากหลาย แต่โมเดลมีข้อดีจากการ เรียนรู้ข้อมูลขนาดเล็ก อีกทั้งเป้าหมายของการลดเวลาที่สูญเสียจากการฝึกฝน

จากรูปที่ 3.19 ด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 6) โครงสร้างของ C-NN ในบล็อกที่ 1, บล็อกที่ 3 ประกอบด้วย ConV ขนาด (32, 3, 3) จำนวน 2 ชั้นเรียงกันอยู่ และ ในบล็อก ที่ 2, 4 และ บล็อกที่ 5 มี ConV ขนาด (64, 5, 5) จำนวน 2 ชั้น ทุกๆชั้นมีตัวกรองขนาด 2*2 (kernel) มี DropBlock ขนาด bz = 2 และ kp = 0.9 ในบล็อกที่ 5 ทำหน้าที่คัดข้อมูลออกจากการดึงลักษณะ ในส่วนการจำแนกทดลองใช้ FC จำนวน 2 ชั้น 1 ชั้นต่อ 500 โหนด มีฟังก์ชันผลรวมแบบ Softmax ฝึกฝนด้วยอัตราการสูญเสีย (Lr) ที่ 0.0001 ขนาดของ batch ที่ 24 ฝึกฝนด้วยจำนวน 100 รอบ แสดง ประสิทธิภาพของโมเดลสำหรับการฝึกฝน แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การ ตรวจสอบความถูกต้อง เวลาการฝึกฝน และ ประสิทธิภาพของการทดสอบในตารางที่ 4.6



รูปที่ 3.19 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 6


จากรูปที่ 3.20 ด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 7) โครงสร้างของ C-NN มีลักษณะของชั้นการสกัดคุณสมบัติคล้ายคลึง UNet โดยในบล็อกที่ 1, ประกอบด้วย ConV ขนาด (512, 5, 5) จำนวน 3 ชั้นเรียงกันอยู่ ในบล็อกที่ 2 และ บล็อกที่ 4 มี ConV ขนาด (64, 5, 5) จำนวน 3 ชั้นเรียงกันอยู่, ในบล็อกที่ 3 มี ConV ขนาด (32, 3, 3) จำนวน 3 ในบล็อกที่ 5 มี ConV ขนาด (128, 5, 5) จำนวน 3 ชั้นเรียงกันอยู่ ทุกๆ ชั้นมีตัวกรองขนาด 2*2 (kernel) มี DropBlock ขนาด bz = 5 และ kp = 0.7 ทำหน้าที่คัดข้อมูลออกจากการดึงลักษณะ ในส่วนการจำแนกทดลองใช้ FC จำนวน 2 ชั้น 1 ชั้นต่อ 1000 โหนด มีฟังก์ชันผลรวมแบบ Softmax ผูกพันด้วยอัตราการเรียนรู้ (Lr) ที่ 0.0001 ขนาดของ batch ที่ 24 ผูกพันด้วยจำนวน 100 รอบ แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝน และประสิทธิภาพของการทดสอบในตารางที่ 4.7



รูปที่ 3.20 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 7

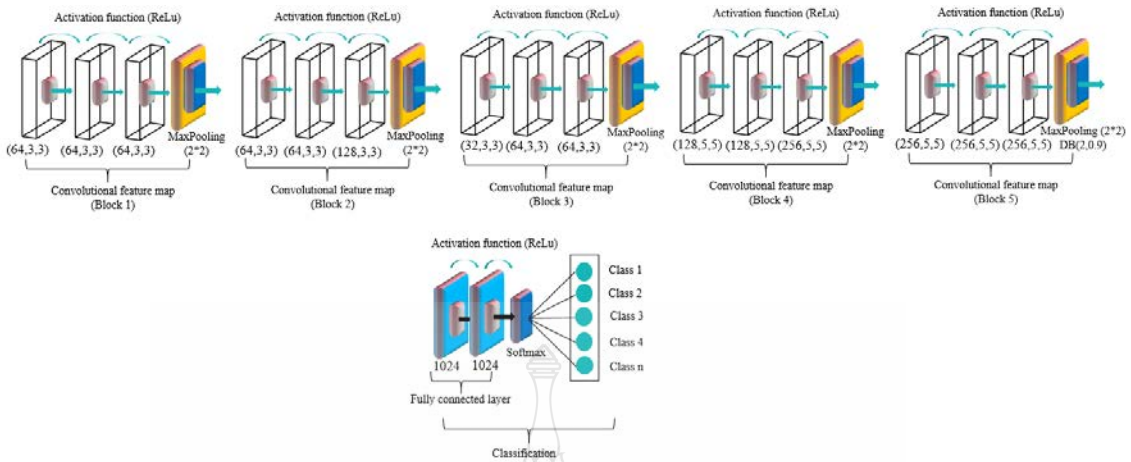
จากรูปที่ 3.21 ด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 8) โครงสร้างของ C-NN ในบล็อกที่ 1, ประกอบด้วย ConV ขนาด (32, 3, 3) จำนวน 1 ชั้น และ ConV ขนาด (64, 3, 3) จำนวน 1 ชั้น เรียงกันอยู่; ในบล็อกที่ 2 และ บล็อกที่ 3 มี ConV ขนาด (32, 3, 3), ConV ขนาด (64, 3, 3) และ ConV ขนาด (128, 3, 3) จำนวน 1 ชั้น (เรียงลำดับ) ซึ่งเป็นการเรียงลำดับขนาดของชั้นการกรอง; ในบล็อกที่ 4 ประกอบด้วย มี ConV ขนาด (128, 5, 5), ConV ขนาด (256, 5, 5) และ ConV ขนาด (512, 5, 5) จำนวน 1 ชั้น (เรียงลำดับ) และ ในบล็อกที่ 5 ประกอบด้วย ConV ขนาด (512, 5, 5) จำนวน 3 ชั้น ทุกๆชั้นมีตัวกรองขนาด 2*2 (kernel) โดยมี DropBlock ขนาด bz = 2 และ kp = 0.9 ในบล็อกที่ 5 ทำหน้าที่คัดข้อมูลออกจากการดึงลักษณะ ในส่วนการจำแนกทดลองใช้ FC จำนวน 2 ชั้น

1 ชั้นต่อ 1000 โหนด มีฟังก์ชันผลรวมแบบ Softmax ฝึกฝนด้วยอัตราการเรียนรู้ (Lr) ที่ 0.0001 ขนาดของ batch ที่ 24 ฝึกฝนด้วยจำนวน 100 รอบ แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝน และประสิทธิภาพของการทดสอบในตารางที่ 4.8




รูปที่ 3.21 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 8

จากรูปที่ 3.22 ด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 9) โครงสร้างของ C-NN ในบล็อกที่ 1, ประกอบด้วย Conv ขนาด (45, 5, 5) จำนวน 3; ในบล็อกที่ 2 ประกอบด้วย Conv ขนาด (45, 5, 5) จำนวน 3 ชั้น; ในบล็อกที่ 3 ประกอบด้วย Conv ขนาด (45, 5, 5) จำนวน 3 ชั้น; ในบล็อกที่ 4 มี Conv ขนาด (60, 5, 5) จำนวน 3 ชั้น และ ในบล็อกที่ 5 ประกอบด้วย Conv ขนาด (45, 5, 5) จำนวน 3 ชั้น และ DropBlock ขนาด $bz = 2$ และ $kp = 0.9$ ทำหน้าที่ตัดข้อมูลออกจากการดึงลักษณะ ทุกๆชั้นมีตัวกรองขนาด 2×2 (kernel) ในส่วนการจำแนกทดลองใช้ FC จำนวน 2 ชั้น 1 ชั้นต่อ 1000 โหนด มีฟังก์ชันผลรวมแบบ Softmax ฝึกฝนด้วยอัตราการเรียนรู้ (Lr) ที่ 0.0001 ขนาดของ batch ที่ 24 ฝึกฝนด้วยจำนวน 100 รอบ แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝน และประสิทธิภาพของการทดสอบในตารางที่ 4.9



รูปที่ 3.22 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 9

จากรูปที่ 3.23 ด้วยเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชัน (โมเดลที่ 10) โครงสร้างของ CNN ในบล็อกที่ 1, ประกอบด้วย ConV ขนาด (128, 5, 5) จำนวน 3; ในบล็อกที่ 2 ประกอบด้วย ConV ขนาด (128, 3, 3) จำนวน 3 ชั้น; ในบล็อกที่ 3 ประกอบด้วย ConV ขนาด (256, 5, 5) จำนวน 3 ชั้น; ในบล็อกที่ 4 มี ConV ขนาด (512, 5, 5) จำนวน 3 ชั้น และ ในบล็อกที่ 5 ประกอบด้วย ConV ขนาด (1024, 3, 3) จำนวน 3 ชั้น ทุกๆชั้นมีตัวกรองขนาด 2*2 (kernel) ในส่วนการจำแนกทดลองใช้ FC จำนวน 2 ชั้น 1 ชั้นต่อ 1000 โหนด มีฟังก์ชันผลรวมแบบ Softmax ฝึกฝนด้วยอัตราการเรียนรู้ (Lr) ที่ 0.0001 ขนาดของ batch ที่ 24 ฝึกฝนด้วยจำนวน 100 รอบ แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน แสดงประสิทธิภาพของโมเดลสำหรับการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝน และประสิทธิภาพของการทดสอบในตารางที่ 4.10



รูปที่ 3.23 โครงสร้างของเทคนิคการเรียนรู้เชิงลึกแบบคอนโวลูชันของการทดลองที่ 10

แสดงการเปรียบเทียบรายละเอียดของโมเดลที่ 6, 7, 8, 9 และ โมเดลที่ 10 ไว้ดังตารางที่ 3.5 ผลการทดลองแบ่งออกเป็นสามสี่ส่วน: ประสิทธิภาพของการฝึกฝน ผลกระทบต่อความเร็วของการเรียนรู้ ผล loss ของโมเดล และ ประสิทธิภาพของการจำแนกอุปกรณ์ ในตารางที่ 4.6, 4.7, 4.8. 4.9 และ ตารางที่ 4.10

ตารางที่ 3.5 พารามิเตอร์และลำดับชั้นของโมเดลที่ 6, 7, 8, 9 และ โมเดลที่ 10

บล็อก	โมเดลที่ 6	โมเดลที่ 7	โมเดลที่ 8	โมเดลที่ 9	โมเดลที่ 10
บล็อก 1	ConV(32,3,3)(2L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 2 L); MaxP (2, 2); St: (2,2)	ConV(512,5,5)(3L); Act: "ReLU"; PaD: "Same"; (all: 3 L); MaxP (2, 2); St: (2, 2); DB: (5, 0.70)	ConV(32,3,3)(1L)& ConV(64,3,3)(1L); (Act: "ReLU", PaD: "Same", (3 L)); MaxP (2, 2), St: (2,2)	ConV(64,3,3)(3L); (Act: "ReLU", PaD: "Same", (all: 3 L)); MaxP (2, 2), St: (2,2)	ConV(128,5,5)(3L); (Act: "ReLU", PaD: "Same", (all: 3 L)); MaxP (3, 3); St: (2,2)
บล็อก 2	ConV(64,5,5)(2L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 2 L); MaxP (2, 2); St: (2,2)	ConV(64,5,5)(3L); Act: "ReLU"; PaD: "Same"; (all: 3 L); MaxP (2, 2); St: (2,2); DB: (5, 0.70)	ConV(32,3,3)(1L)& ConV(64,3,3)(1L)& ConV(128,3,3)(1L); (Act: "ReLU", PaD: "Same", (3 L)); MaxP (2, 2), St: (2,2)	ConV(64,5,5)(2L)& ConV(128,3,3)(1L); (Act: "ReLU", PaD: "Same", (3 L)); MaxP (2, 2), St: (2,2)	ConV(128,3,3)(3L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 3 L); MaxP (3, 3); St: (2,2)
บล็อก 3	ConV(32,3,3)(2L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 2 L); MaxP (2, 2); St: (2,2)	ConV(32,3,3)(3L); Act: "ReLU"; PaD: "Same" (all: 3 L); MaxP (2, 2); St: (2,2); DB: (5, 0.70)	ConV(32,3,3)(1L)& ConV(64,3,3)(1L)& ConV(128,3,3)(1L); (Act: "ReLU", PaD: "Same", (3 L)); MaxP (2, 2), St: (2,2)	ConV(32,3,3)(1L)& ConV(64,3,3)(2L); (Act: "ReLU", PaD: "Same", (3 L)); MaxP (2, 2), St: (2,2)	ConV(256,5,5)(3L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 3 L); MaxP (3, 3); St: (2,2)
บล็อก 4	ConV(64,5,5)(2L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 2 L); MaxP (2, 2); St: (2,2)	ConV(64,5,5)(3L); Act: "ReLU"; PaD: "Same" (all: 3 L); MaxP (2, 2); St: (2,2); DB: (5, 0.70)	ConV(128,5,5)(1L)& ConV(256,5,5) (1L)& ConV(512,5,5) (1L); (Act: "ReLU", PaD: "Same", (all: 3 L)); MaxP (2, 2), St: (2,2); DB: (2, 0.90)	ConV(128,5,5)(2L)& ConV(256,5,5) (1L); (Act: "ReLU", PaD: "Same", (all: 3 L)); MaxP (2, 2), St: (2,2)	ConV(512,5,5)(3L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 3 L); MaxP (3, 3); St: (2,2)
บล็อก 5	ConV(64,5,5)(2L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 2 L); MaxP (2, 2); St: (2,2); DB: (2, 0.90)	ConV(128,5,5)(3L); Act: "ReLU"; PaD: "Same" (all: 3 L); MaxP (2, 2); St: (2,2); DB: (5, 0.70)	ConV(512,5,5)(3L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 3 L); MaxP (2, 2); St: (2,2); DB: (2, 0.90)	ConV(256,5,5)(3L); Act: "ReLU"; PaD: "Same" (all: 3 L); MaxP (2, 2); St: (2,2); DB: (2, 0.90)	ConV(1024,3,3)(3L); Act: "ReLU"; PaD: "Same"; AcT: "ReLU" (all: 3 L); MaxP (3, 3); St: (2,2)

(ต่อ)


ตารางที่ 3.5 พารามิเตอร์และลำดับชั้นของโมเดลที่ 6, 7, 8, 9 และ โมเดลที่ 10 (ต่อ)

บล็อกการ	FC1: 500; (AcT)	FC1: 1024; (ReLu)	FC1: 1024; (AcT)	FC1: 1024; (ReLu)	FC1: 1024; (AcT)
จำแนก	FC2: 500; (AcT)	FC2: 1024; (ReLu)	FC2: 1024; (AcT)	FC2: 1024; (ReLu)	FC2: 1024; (AcT)
	SoftMax	SoftMax	SoftMax	SoftMax	SoftMax

จากรูปที่ 3.19 ถึงรูปที่ 3.23 สรุปการเปรียบเทียบรายละเอียดของโมเดลในตารางที่ 3.5 การปรับโครงสร้างโมเดลที่ 6 พัฒนาจากรูปที่ 3.18 และ VGG 11 ทำการปรับลำดับการขยาย convolutional layers จากขนาด 64, 128, 256 และ 512 เป็น 32, 64, 32, 64, 64 เหตุจากเป็นการปรับขนาดโมเดลต่อชุดข้อมูลที่มี resolution ขนาดเล็ก ในที่นี้รวมถึง kernel โดยเพิ่ม DB ในบล็อกที่ Conv Block 5 กำหนด DB: (2, 0.90); การปรับโครงสร้างโมเดลที่ 7 เป็นการต่อยอดจากโมเดล 6 โดยออกแบบโครงสร้างแบบ U-Nat [43] ด้วยการขยาย Input layers ให้มีขนาด 512, 64, 32, 64, 128 และ DB โดยกำหนด DB: (5, 0.70) เพื่อศึกษาลักษณะความสัมพันธ์ของ kernel ที่ส่งผลต่อ feature ซึ่งพัฒนาต่อเนื่องในโมเดลที่ 8 มีลำดับการเรียงของชั้น Convolutional โดยลดพารามิเตอร์ในบล็อกที่ 1, 2 และ 3 อีกทั้งเพิ่ม DB ในบล็อกที่ 4 และ บล็อกที่ 5 กำหนด DB: (2, 0.90) การออกแบบนี้มีข้อได้เปรียบในการเรียงลำดับของ kernel เหตุจากการขยายโครงสร้างมีลำดับชั้นการขยายที่สูญเสีย้น้อย ทั้งนี้ โมเดลที่ 9, 10 และ โมเดลที่ 11 ต่อยอดจากการทดลองก่อนหน้า ซึ่งเป็นการลดระดับพารามิเตอร์ลงจาก เพื่อลดเวลาในการฝึกฝนและประสิทธิภาพที่ดีในการทดลอง

3.5 ศึกษาสถานะ ON/OFF ร่วมกับโมเดล AlexNet

จากขั้นตอนการทำงานในรูปที่ 3.1 (การทดลองที่ 4), เป็นการพัฒนามาโมเดล AlexNet ที่ได้รับการเผยแพร่มาทดลองร่วมกับชุดข้อมูลเคอร์โทแกรม มุ่งเน้นในการเปรียบเทียบสถานะการเปิดปิดการทำงานของอุปกรณ์ (ON-OFF) ดังรูปที่ 3.24 โดยจัดกลุ่มการทดลองเป็น 10 ชุดข้อมูล คือ Class1-ON, Class1-OFF, Class2-ON, Class2-OFF, Class3-ON, Class3-OFF, Class4-ON, Class4-OFF, Class5-ON และ Class5-OFF, ซึ่งมีวิธีการเก็บข้อมูลแบ่งออกเป็น 10 กรณีดัง:



รูปที่ 3.24 ผลของระบบ NILM สำหรับตรวจรู้สถานะโหลดแบบต่อเนื่อง

1. Class1-ON กรณีเปิดเครื่องใช้ไฟฟ้า Class1 หรือ Air condition1 เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้า แล้วทำการเปิดเครื่องใช้ไฟฟ้า Class1 และทำการบันทึกค่า Current ในช่วง Transient Power On ของเครื่องใช้ไฟฟ้า Class1 และเก็บข้อมูลไว้เป็น Class1-On ใน Dataset

2. Class1-OFF กรณีเปิดเครื่องใช้ไฟฟ้า Class1 ถูกเปิดไว้เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้าด้วย เมื่อมีการปิดเครื่องใช้ไฟฟ้า Class1 และทำการบันทึกค่า Current ในช่วง Transient Power OFF ของเครื่องใช้ไฟฟ้า Class1 และเก็บข้อมูลไว้เป็น Class1-Off ใน Dataset

3. Class2-ON กรณีเปิดเครื่องใช้ไฟฟ้า Class2 หรือ Air condition2 เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้า แล้วทำการเปิดเครื่องใช้ไฟฟ้า Class2 และทำการบันทึกค่า Current ในช่วง Transient Power On ของเครื่องใช้ไฟฟ้า Class2 และเก็บข้อมูลไว้เป็น Class2-On ใน Dataset

4. Class2-OFF กรณีเปิดเครื่องใช้ไฟฟ้า Class2 ถูกเปิดไว้เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้าด้วย เมื่อมีการปิดเครื่องใช้ไฟฟ้า Class2 และทำการบันทึกค่า Current ในช่วง Transient Power OFF ของเครื่องใช้ไฟฟ้า Class2 และเก็บข้อมูลไว้เป็น Class2-Off ใน Dataset

5. Class3-ON กรณีเปิดเครื่องใช้ไฟฟ้า Class3 หรือ Lamp เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้า แล้วทำการเปิดเครื่องใช้ไฟฟ้า Class3 และทำการบันทึกค่า Current

ในช่วง Transient Power On ของเครื่องใช้ไฟฟ้า Class1 และเก็บข้อมูลไว้เป็น Class3-On ใน Dataset

6. Class3-OFF กรณีเปิดเครื่องใช้ไฟฟ้า Class3 ถูกเปิดไว้เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้าด้วย เมื่อมีการปิดเครื่องใช้ไฟฟ้า Class3 และทำการบันทึกค่า Current ในช่วง Transient Power OFF ของเครื่องใช้ไฟฟ้า Class3 และเก็บข้อมูลไว้เป็น Class3-Off ใน Dataset

7. Class4-ON กรณีเปิดเครื่องใช้ไฟฟ้า Class4 หรือ Microwave เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้า แล้วทำการเปิดเครื่องใช้ไฟฟ้า Class4 และทำการบันทึกค่า Current ในช่วง Transient Power On ของเครื่องใช้ไฟฟ้า Class4 และเก็บข้อมูลไว้เป็น Class4-On ใน Dataset

8. Class4-OFF กรณีเปิดเครื่องใช้ไฟฟ้า Class4 ถูกเปิดไว้เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้าด้วย เมื่อมีการปิดเครื่องใช้ไฟฟ้า Class4 และทำการบันทึกค่า Current ในช่วง Transient Power OFF ของเครื่องใช้ไฟฟ้า Class4 และเก็บข้อมูลไว้เป็น Class4-Off ใน Dataset

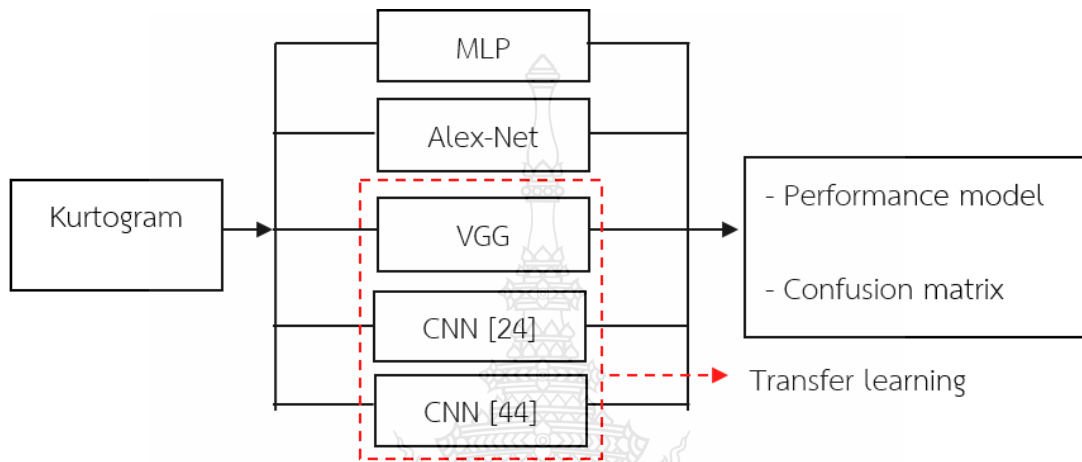
9. Class5-ON กรณีเปิดเครื่องใช้ไฟฟ้า Class5 หรือ Pump เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้า แล้วทำการเปิดเครื่องใช้ไฟฟ้า Class5 และทำการบันทึกค่า Current ในช่วง Transient Power On ของเครื่องใช้ไฟฟ้า Class4 และเก็บข้อมูลไว้เป็น Class5-On ใน Dataset

10. Class5-OFF กรณีเปิดเครื่องใช้ไฟฟ้า Class5 ถูกเปิดไว้เพียงตัวเดียว หรือมีการเปิดเครื่องใช้ไฟฟ้าอื่นอยู่ก่อนหน้าด้วย เมื่อมีการปิดเครื่องใช้ไฟฟ้า Class5 และทำการบันทึกค่า Current ในช่วง Transient Power OFF ของเครื่องใช้ไฟฟ้า Class5 และเก็บข้อมูลไว้เป็น Class5-Off ใน Dataset

การทดลองแต่ละกรณีทำการบันทึกข้อมูลไว้ 1000 ครั้งเพื่อเป็นชุดข้อมูลที่นำไปทดสอบกับ CNN โดยทำการแบ่งข้อมูลในแต่ละชุดสำหรับทำการฝึกฝน 50% และ ทำการทดสอบ 50% ข้อมูลที่ถูกบันทึกไว้เป็นค่ากระแสที่ถูกอ่านค่าได้ขณะเปิดเครื่องใช้ไฟฟ้าแต่ละตัว ระยะเวลาในการบันทึก 500 ms แสดงผลการทดลองในตารางที่ 4.7 และ ตารางที่ 4.8

3.6 การทดลองด้วย Deep Convolutional Net และ การเปรียบเทียบผลการทดลองของโมเดล

จากขั้นตอนการทำงานในรูปแบบที่ 3.1 (การทดลองที่ 5), เป็นการพัฒนานำโมเดลที่ได้รับการเผยแพร่มาทดลองร่วมกับชุดข้อมูลคอร์โทแกรมเพื่อเปรียบเทียบกับโมเดลดั้งเดิมโดยมีรายละเอียดในรูปแบบที่ 3.25



รูปที่ 3.25 การเปรียบเทียบเทคนิคการตรวจจู้และการเรียนรู้เชิงลึก


จากรูปที่ 3.25 ประกอบด้วยเทคนิค MLP, AlexNet, VGG, CNN [24] มีชั้น ConV ขนาด 25, 5, 2 ของชั้นที่ 1; ConV ขนาด 32, 5, 2 ของชั้นที่ 2; และ ConV ขนาด 64, 5, 2 โดยมีฟังก์ชันการรวมแบบ ReLu มีชั้นการจำแนก 2 ชั้น (1 ชั้นต่อ 1000 โหนด) และ CNN [44] มีชั้น ConV ขนาด 16, 32 และ 64 โดยมีเคอร์เนล 3*3 มี stride 2 x 1 แบบ padding การทดลองฝึกฝนด้วยวิธีถ่ายโอนการเรียนรู้ (Transfer learning (TL) สรุปผลไว้ในตารางที่ 4.8 เพื่อความเป็นมาตรฐานการกำหนดพารามิเตอร์อื่นๆ เพื่อความเป็นมาตรฐานสำหรับการฝึกฝน กำหนดรอบการฝึกฝน 100 รอบ batch กำหนดไว้ที่ 24 ระหว่างขั้นตอนการฝึกอบรมได้รับการปรับแต่ง learning rate ในช่วง 0.0001, การฝึกฝนอาศัย Adam optimizer ช่วยแก้ปัญหา decaying ของ gradients สำหรับการเรียนรู้ในแต่ละรอบ อัตราการสลายตัวกำหนดเป็น 0.9 และ 0.9999 ฟังก์ชันการเรียนรู้แบบ Categorical Cross-Entropy Loss กำหนดพารามิเตอร์ที่ช่วยในการฝึกฝนไว้ที่ 1e-8 (Epsilon). ประมวลผลบนระบบปฏิบัติการ Windows 10, RAM 32 GB เร่งความเร็วในการคำนวณอาศัย NVidia GeForce RTX 2070 Super Gaming OC, GPU memory 8 GB ไรบารีโออกแบบ Deep Learning พัฒนาด้วย Tensorflow และ Numpy 1.15.0 โดยภาษา Python 3.6

บทที่ 4


ผลการทดลอง

4.1 ผลการทดลองการวัดสัญญาณไฟฟ้า


จากการทดลองในรูปที่ 3.2 ผลการทดลองทั้ง 3 แบบของการการตรวจวัดอุปกรณ์ใช้ไฟฟ้าด้วยไมโครคอนโทรลเลอร์ เป็นการนำเสนอที่มีข้อดีในการวัดอุปกรณ์โดยง่าย เป็นวิธีที่เหมาะสมในการพัฒนาระบบตรวจรู้ไหลเพื่อลดค่าใช้จ่าย (Low cost) มีขั้นตอนการทดลองหลังจากต่อวงจรจริง โดยวัดค่าการใช้พลังงานจากโหลด 4 ชนิด ได้แก่ ปืนกา, หลอดไฟ และ หัวแรง 2 อัน โดยเปิด-ปิดอุปกรณ์แต่ละชนิดในช่วงเวลาที่ต่างกัน ผลของการใช้พลังงานที่วัดจากไอซี CS5490 ต่อเข้ากับหน่วยประมวลผล PIC32 ผลการทดลองดังรูปที่ 4.1, รูปที่ 4.2 และ รูปที่ 4.3 เห็นได้ว่า ช่วงเวลาที่เปิด-ปิดอุปกรณ์ต่างชนิดกัน มีการใช้พลังงานที่แตกต่างกัน และ บางช่วงของกราฟที่มีค่าสวิงขึ้นไป นั่นคือช่วงเวลาต่อโหลดเป็นหัวแรง ซึ่งมีการกินกระแสสูงในช่วงต้น



รูปที่ 4.1 การวัดกำลัง 4 โหลด; (A) soldering iron a (B) Bulb (C) soldering iron b (D) hot melt glue gun




รูปที่ 4.2 การวัดกระแส 4 โหลด; (A) soldering iron a (B) Bulb (C) soldering iron b (D) hot melt glue gun




รูปที่ 4.3 การรวมกำลังจาก 4 โหลด

4.2 ผลการตรวจรู้โหลดด้วยอุปกรณ์ลอจิกแบบโปรแกรมร่วมกับเทคนิคไบนารี


จากการทดลองในรูปที่ 3.8 ผลการทดลองเมื่อเก็บค่ากำลังวัตต์โดยรวม (P_{max}) เป็นสัญญาณที่ผ่านการแปลงสัญญาณด้วย SCT-013-030 ร่วมกับ CS5490 module ดังรูปที่ 4.4 (ก), รูปที่ 4.5 (ก) และรูปที่ 4.6 (ก) ในขั้นตอนนี้จะยังไม่สามารถแยกแยะชนิดของอุปกรณ์ไฟฟ้าได้ ลำดับต่อมาส่งข้อมูลข้างต้นไปยัง FPGA ทำการตรวจรู้โหลดจากการวิเคราะห์แบบ binary แสดงความสัมพันธ์ในรูปแบบของเลขฐานสองดังรูปที่ 4.4 (ข), รูปที่ 4.5 (ข) และรูปที่ 4.6 (ข), แสดงผลที่ได้จากการตรวจรู้โหลดดังรูปที่ 4.4 (ค), รูปที่ 4.5 (ค) และรูปที่ 4.6 (ค)



(ก) ผลรวมของกำลังวัตต์




(ข) ความสัมพันธ์ของเลขไบนารีต่ออุปกรณ์




(ค) ผลของการแยกแยะอุปกรณ์แต่ละชนิด

รูปที่ 4.4 ตัวอย่างผลของการตรวจรู้สภาวะโหลดแบบไม่ลวงล้ำแบบ 2 อุปกรณ์




(ก) ผลของกำลังวัตต์รวม

(ข) ความสัมพันธ์ของเลขไบนารีต่ออุปกรณ์




(ค) ผลของการแยกแยะอุปกรณ์แต่ละชนิด


รูปที่ 4.5 ตัวอย่างผลของการตรวจรู้สภาวะโหลดแบบไม่ลวงล้ำแบบ 3 อุปกรณ์



(ก) ผลของกำลังวัตต์รวม



(ข) ความสัมพันธ์ของเลขไบนารีต่ออุปกรณ์



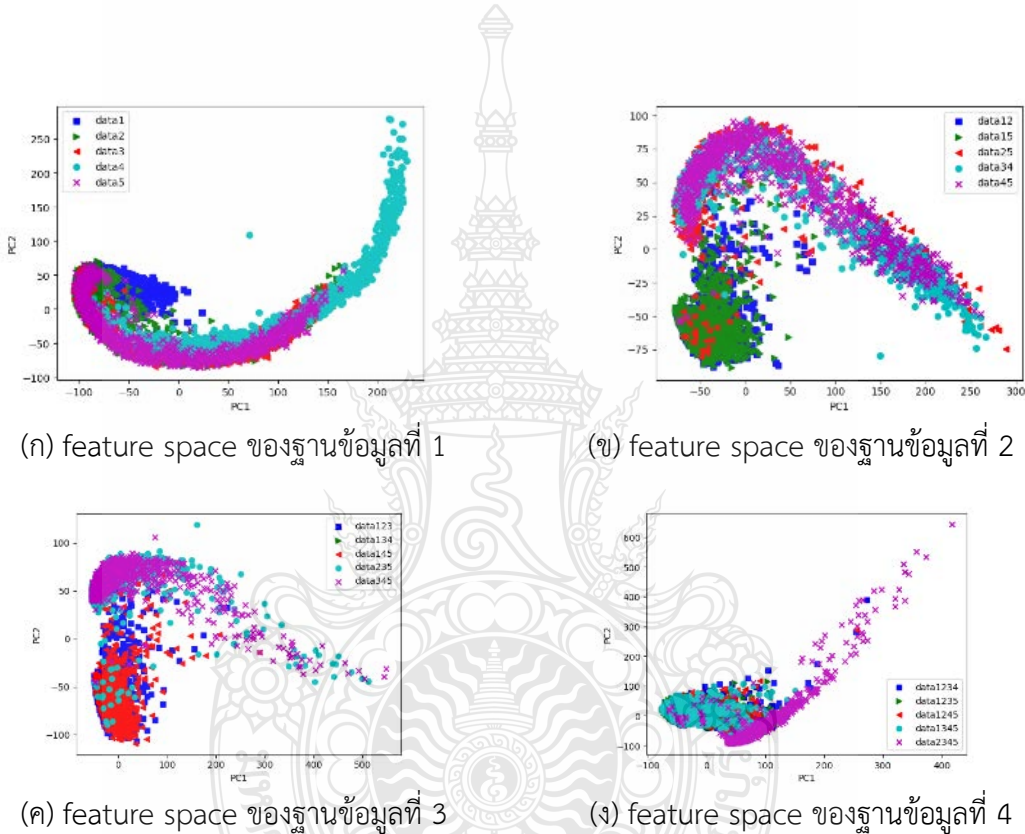
(ค) ผลของการแยแยะอุปกรณ์แต่ละชนิด

รูปที่ 4.6 ตัวอย่างผลของการตรวจรู้สภาวะโหลดแบบไม่ล่วงล้ำแบบ 4 อุปกรณ์

การประยุกต์ใช้เพาเวอร์มิเตอร์ร่วมอุปกรณ์ลอจิกแบบโปรแกรมในการอ่านค่าพลังงานไฟฟ้าและประยุกต์ใช้เทคนิคไบนารีสำหรับการตรวจรู้โหลด ผลการทดลองดังรูปที่ 4.1, รูปที่ 4.2 และ รูปที่ 4.3, วิธีดังเสนอมีข้อดีที่สามารถเข้าถึงอุปกรณ์ได้โดยง่าย รองรับการเพิ่มจำนวนของอุปกรณ์โดยไม่คำนึงถึงข้อมูลของอุปกรณ์ และยังสามารถพัฒนาให้มีการคำนวณที่เร็วขึ้นจากประสิทธิภาพของอุปกรณ์ลอจิกแบบโปรแกรม ซึ่งวิธีการดังกล่าวเหมาะสมเป็นอย่างยิ่งในการพัฒนาระบบตรวจรู้โหลดเพื่อลดค่าใช้จ่าย (Low cost) เมื่อเทียบการพัฒนาก่อนหน้า แต่ในทางกลับกัน, วิธีข้างต้นมีข้อจำกัดหลายประเด็น เช่น ไม่สามารถตรวจรู้โหลดได้เมื่ออุปกรณ์มีกำลังไฟฟ้าใกล้เคียงกัน ไม่สามารถตรวจรู้โหลดได้เมื่ออุปกรณ์มีกำลังงานไม่คงที่ ปัญหาในด้านการวิเคราะห์ช่วงโอเวอร์ชูตของอุปกรณ์ ดังที่กล่าวมาผู้วิจัยเสนอวิธีการพัฒนาฐานข้อมูลแบบเคอร์โทแกรมและการเรียนรู้เชิงลึกแบบคอนโวลูชัน เป็นอัลกอริทึมที่แพร่หลายและได้รับการพิสูจน์ถึงประสิทธิภาพเมื่อนำมาพัฒนาระบบควบคุมทางไฟฟ้า เช่น สมาร์ทกริด สมาร์ทโฮมส์ หรือ สมาร์ทมิเตอร์ วิธีดังกล่าวผู้วิจัยนำมาทดลองในหัวข้อการศึกษาที่ 3.4 ผลการทดลองในหัวข้อที่ 4.4

4.3 ผลการวิเคราะห์ข้อมูล

การเข้าถึงอุปกรณ์ใช้ไฟฟ้าจากรูปที่ 3.11, ส่วนที่หนึ่ง ตัวอย่างลักษณะรูปคลื่นไซน์ของอุปกรณ์ในตารางที่ 3.2 และ ข้อมูลของอุปกรณ์ทางไฟฟ้าแบบเคอร์โทแกรมในตารางที่ 3.3 เมื่อวิเคราะห์ด้วย Principal Component Analysis (PCA) เป็นวิธีการค้นหาว่าตัวแปรใดมีความสัมพันธ์กัน ตัวแปรใดเป็นอิสระ ตัวแปรใดมีความสัมพันธ์ในกลุ่มเดียวกัน และ ตัวแปรใดเป็นอิสระกับตัวแปรที่อยู่ในกลุ่มอื่นๆ เมื่อนำชุดข้อมูลภาพเคอร์โทแกรมมาวิเคราะห์แสดงดังรูปที่ 4.7



รูปที่ 4.7 การวิเคราะห์องค์ประกอบของฐานข้อมูลด้วย Principal Component Analysis : (PCA)

การวิเคราะห์นี้สร้างตัวแปร 100 component ของแต่ละข้อมูล อธิบายการกระจายของข้อมูล โดยไม่ลดมิติลง และ แสดงความสัมพันธ์ของ feature space ของชุดข้อมูล ดังรูปที่ 4.7 (ก), (ข), (ค) และ รูปที่ 4.7 (ง) สรุปได้ดังนี้:

ฐานข้อมูลที่ 1: ลักษณะการกระจายของข้อมูลอยู่ในช่วง -100 ถึง 250 บนระนาบ PC1 และในช่วง -100 ถึง 300 บนระนาบ PC2 ซึ่ง data1, data2, data3 และ data5 อยู่ในกลุ่มเดียวกัน โดยมีเพียงเวกเตอร์ของ data4 ที่มีบางส่วนแปรผันกระจายในช่วง 150 ถึง 250 ของระนาบ PC1 และช่วง 80 ถึง 300 ในระนาบ PC2 ดังรูปที่ 4.7 (ก)

ฐานข้อมูลที่ 2: ลักษณะการกระจายของข้อมูลอยู่ในช่วง -100 ถึง 300 บนระนาบ PC1 และในช่วง -100 ถึง 100 บนระนาบ PC2 ลักษณะของข้อมูลมีความแปรผัน ซึ่งไม่สามารถแยกแยะการกระจายของข้อมูลได้ดังรูปที่ 4.7 (ข)

ฐานข้อมูลที่ 3: ลักษณะการกระจายของข้อมูลอยู่ในช่วง -100 ถึง 600 บนระนาบ PC1 และในช่วง -150 ถึง 150 บนระนาบ PC2 ลักษณะของข้อมูลมีความแปรผันของเวกเตอร์ ซึ่งไม่สามารถแยกแยะการกระจายของข้อมูลได้ดังรูปที่ 4.7 (ค)

ฐานข้อมูลที่ 4: ลักษณะการกระจายข้อมูลอยู่ในช่วง -100 ถึง 450 บนระนาบ PC1 และในช่วง -100 ถึง 150 บนระนาบ PC2 ลักษณะการกระจายของข้อมูลแต่ละชุดอยู่ในช่วงเดียวกัน ทั้งนี้มีเพียง data1234 และ data2345 มีผลบางส่วนกระจายแตกต่างกันดังรูปที่ 4.7 (ง)

4.4 ผลการทดสอบโมเดลการเรียนรู้เชิงลึกแบบคอนโวลูชัน

จากรูปที่ 3.14 เมื่อทดลองด้วยชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 แสดงประสิทธิภาพการฝึกฝน ประสิทธิภาพการตรวจสอบ เวลาการฝึกฝน และ ประสิทธิภาพการทดสอบดังนี้:

ตารางที่ 4.1 ประสิทธิภาพของโมเดลของการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและประสิทธิภาพการทดสอบของโมเดลที่ 1

การทดลอง	ประสิทธิภาพการฝึกฝน	ประสิทธิภาพตรวจสอบความถูกต้อง	เวลาในการฝึกฝน (นาที)	ประสิทธิภาพการทดสอบ
ชุดที่ 1	98.79 ± (0.09)	98.69 ± (0.05)	42.61 ± (3.52)	98.10 ± (0.15)
ชุดที่ 2	91.81 ± (0.41)	97.80 ± (0.89)	92.50 ± (2.28)	85.39 ± (1.32)
ชุดที่ 3	84.16 ± (0.83)	89.31 ± (0.71)	75.83 ± (3.02)	55.41 ± (1.44)
ชุดที่ 4	85.22 ± (1.33)	89.85 ± (1.62)	39.23 ± (2.40)	66.34 ± (1.36)

#หมายเหตุ ผลการทดลองในบทที่สี่เป็นผลการทดลองซ้ำและหาค่าเฉลี่ยความถูกต้องของโมเดล

ผลการทดลองในตารางที่ 4.1 จากชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 ประสิทธิภาพของชุดการฝึกฝนร้อยละ $98.79 \pm (0.09)$, $91.81 \pm (0.41)$, $84.16 \pm (0.83)$ และ $85.22 \pm (1.33)$ เปอร์เซ็นต์ ผลของชุดตรวจสอบความถูกต้องมีความแม่นยำร้อยละ $98.69 \pm (0.05)$, $97.80 \pm (0.89)$, $89.31 \pm (0.71)$ และ $89.85 \pm (1.62)$ เปอร์เซ็นต์ สูญเสียเวลาฝึกฝน $42.61 \pm (3.52)$, $92.50 \pm (2.28)$, $75.83 \pm (3.02)$ และ $39.23 \pm (2.40)$ นาที เมื่อนำโมเดลไปทดสอบมีประสิทธิผลร้อยละ $98.10 \pm (0.10)$, $85.39 \pm (0.32)$, $55.41 \pm (0.44)$ และ $66.34 \pm (0.16)$ เปอร์เซ็นต์ แสดง confusion matrix ของการจำแนกอุปกรณ์ในรูปแบบที่ ก.1 แม้ผลการทดลองมีประสิทธิภาพที่ดี แต่โครงข่ายดังกล่าวยังประสบปัญหาจากพหุนามขนาดเล็กที่ได้จากหน้าตาของคอนโวลูชัน ซึ่งยังสามารถปรับเปลี่ยนและพัฒนาต่อยอดได้ ทั้งนี้ได้ปรับโครงข่ายใหม่โดยมีรายละเอียดดังนี้

จากรูปที่ 3.15 เมื่อทดลองด้วยชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 แสดงประสิทธิภาพการฝึกฝน ประสิทธิภาพการตรวจสอบ เวลาการฝึกฝน และ ประสิทธิภาพการทดสอบดัง:

ตารางที่ 4.2 ประสิทธิภาพของโมเดลของการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและ ประสิทธิภาพการทดสอบของโมเดลที่ 2

การทดลอง	ประสิทธิภาพการฝึกฝน	ประสิทธิภาพตรวจสอบความถูกต้อง	เวลาในการฝึกฝน (นาที)	ประสิทธิภาพการทดสอบ
ชุดที่ 1	$99.88 \pm (0.04)$	$98.45 \pm (0.14)$	$68.33 \pm (2.44)$	$97.31 \pm (1.16)$
ชุดที่ 2	$99.40 \pm (0.02)$	$98.41 \pm (0.26)$	$134.24 \pm (1.43)$	$85.59 \pm (1.22)$
ชุดที่ 3	$98.20 \pm (0.02)$	$92.20 \pm (0.42)$	$126.67 \pm (1.04)$	$55.46 \pm (1.52)$
ชุดที่ 4	$99.26 \pm (0.18)$	$91.37 \pm (0.40)$	$66.45 \pm (1.48)$	$65.94 \pm (1.50)$

#หมายเหตุ ผลการทดลองในบทที่สี่เป็นผลการทดลองซ้ำ เพื่อหาค่าเฉลี่ยความถูกต้องของโมเดล

ผลการทดลองในตารางที่ 4.2 จากชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 ประสิทธิภาพของชุดการฝึกฝนร้อยละ $99.88 \pm (0.04)$, $99.40 \pm (0.02)$, $98.20 \pm (0.02)$ และ $99.26 \pm (0.18)$ เปอร์เซ็นต์ ผลของชุดตรวจสอบความถูกต้องมีความแม่นยำร้อยละ $98.45 \pm (0.14)$, $98.41 \pm (0.26)$, $92.20 \pm (0.42)$ และ $91.37 \pm (0.40)$ เปอร์เซ็นต์ สูญเสียเวลาการฝึกฝน $68.33 \pm (2.44)$, $134.24 \pm (1.43)$, $126.67 \pm (1.04)$ และ $66.45 \pm (1.48)$ นาที เมื่อนำโมเดลไปทดสอบด้วยชุดข้อมูลการทดสอบมีประสิทธิภาพร้อยละ $97.31 \pm (0.10)$, $85.59 \pm (0.22)$, $55.46 \pm (0.22)$ และ $65.94 \pm (0.34)$ เปอร์เซ็นต์ แสดง confusion matrix ของการจำแนกอุปกรณ์ในรูปแบบที่ ก.2

เมื่อเทียบประสิทธิภาพของโมเดลที่ 1 และ โมเดลที่ 2, ผลการทดลองด้วยชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 ของโมเดลที่ 2 มีประสิทธิภาพที่ดีกว่าโมเดลที่ 1 โดยมากกว่าร้อยละ 1.09, 7.59, 14.04 และร้อยละ 14.04 (ของชุดฝึกฝน) มีประสิทธิภาพเพิ่มขึ้นของชุดข้อมูลที่ 2, 3 และ 4 ร้อยละ 0.61, 2.86 และ ร้อยละ 1.52 (ของชุดตรวจสอบความถูกต้อง) ทั้งนี้, ประสิทธิภาพการทดสอบมีผลใกล้เคียงกัน ผลการทดลองดังกล่าวเป็นที่พอใจในด้านของประสิทธิภาพแต่มีข้อเสียด้านเวลา เนื่องจากจำนวนของชั้นและนิเวรอนส่งผลต่อเวลาการคำนวณ จากผลการทดลองด้วยวิธีการขยายโครงข่ายแสดงให้เห็นว่าประสิทธิภาพสามารถเพิ่มขึ้นได้จากความเหมาะสมของโครงข่าย ปริมาณข้อมูล ลักษณะเด่นของข้อมูล ดังนั้น, เพื่อตอบรับวิธีการทดลองได้ทำการทดลองเพิ่มตั้งในโมเดลที่ 3, 4 และโมเดลที่ 5

จากรูปที่ 3.16 เมื่อทดลองด้วยชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 แสดงประสิทธิภาพการฝึกฝน ประสิทธิภาพการตรวจสอบ เวลาการฝึกฝน และ ประสิทธิภาพการทดสอบดังนี้:

ตารางที่ 4.3 ประสิทธิภาพของโมเดลของการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและ ประสิทธิภาพการทดสอบของโมเดลที่ 3

การทดลอง	ประสิทธิภาพการฝึกฝน	ประสิทธิภาพตรวจสอบความถูกต้อง	เวลาในการฝึกฝน (นาที)	ประสิทธิภาพการทดสอบ
ชุดที่ 1	99.90 ± (0.01)	98.77 ± (0.01)	92.04 ± (3.10)	97.08 ± (1.02)
ชุดที่ 2	99.72 ± (0.11)	98.41 ± (0.16)	182.34 ± (1.64)	85.44 ± (1.22)
ชุดที่ 3	99.47 ± (0.14)	92.67 ± (0.43)	167.41 ± (2.36)	56.21 ± (1.15)
ชุดที่ 4	99.08 ± (0.25)	91.72 ± (1.41)	90.44 ± (1.62)	66.82 ± (1.28)

#หมายเหตุ ผลการทดลองในบทที่สี่เป็นผลการทดลองซ้ำ เพื่อหาค่าเฉลี่ยความถูกต้องของโมเดล

ผลการทดลองในตารางที่ 4.3 จากชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 ประสิทธิภาพของชุดการฝึกฝนร้อยละ 99.90 ± (0.01), 99.72 ± (0.11), 99.47 ± (0.14) และ 99.08 ± (0.25) เปอร์เซ็นต์ ผลของชุดตรวจสอบมีความแม่นยำร้อยละ 98.77 ± (0.01), 98.41 ± (0.16), 92.67 ± (0.43) และ 91.72 ± (1.41) เปอร์เซ็นต์ สูญเสียเวลาฝึกฝน 92.04 ± (3.10), 182.34 ± (1.64), 167.41 ± (2.36) และ 90.44 ± (1.62) นาที เมื่อนำโมเดลไปทดสอบด้วยชุดข้อมูลการทดสอบมีประสิทธิภาพร้อยละ 97.08 ± (1.02), 85.44 ± (1.22), 56.21 ± (1.12) และ 66.82 ± (0.28), เปอร์เซ็นต์ แสดง confusion matrix ของการจำแนกอุปกรณ์ในรูปที่ ก.3

จากรูปที่ 3.17 เมื่อทดลองด้วยชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 แสดงประสิทธิภาพการฝึกฝน ประสิทธิภาพการตรวจสอบ เวลาการฝึกฝน และ ประสิทธิภาพการทดสอบดัง:

ตารางที่ 4.4 ประสิทธิภาพของโมเดลของการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและ ประสิทธิภาพการทดสอบของโมเดลที่ 4

การทดลอง	ประสิทธิภาพการฝึกฝน	ประสิทธิภาพตรวจสอบความถูกต้อง	เวลาในการฝึกฝน (นาที)	ประสิทธิภาพการทดสอบ
ชุดที่ 1	99.77 ± (0.13)	98.69 ± (0.10)	87.07 ± (2.22)	95.91 ± (1.02)
ชุดที่ 2	99.64 ± (0.08)	97.45 ± (0.28)	68.58 ± (2.10)	84.34 ± (2.18)
ชุดที่ 3	99.36 ± (0.06)	91.42 ± (1.15)	59.53 ± (1.45)	54.97 ± (1.38)
ชุดที่ 4	99.10 ± (0.38)	91.06 ± (1.05)	32.44 ± (1.01)	69.38 ± (1.04)

#หมายเหตุ ผลการทดลองในบทที่สี่เป็นผลการทดลองซ้ำ เพื่อหาค่าเฉลี่ยความถูกต้องของโมเดล

ผลการทดลองในตารางที่ 4.4 จากชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 ประสิทธิภาพของชุดการฝึกฝนร้อยละ 99.77 ± (0.13), 99.64 ± (0.08), 99.36 ± (0.06) และ 99.10 ± (0.38) เปอร์เซ็นต์ ผลของชุดตรวจสอบมีความแม่นยำร้อยละ 98.69 ± (0.10), 97.45 ± (0.28), 91.42 ± (1.15) และ 91.06 ± (1.05) เปอร์เซ็นต์ สูญเสียเวลาฝึกฝน 87.07 ± (2.22), 68.58 ± (2.10), 59.53 ± (1.45) และ 32.44 ± (1.01) นาที เมื่อนำโมเดลไปทดสอบด้วยชุดข้อมูลการทดสอบมีประสิทธิภาพร้อยละ 95.91 ± (1.02), 84.34 ± (2.18), 54.97 ± (1.38) และ 69.38 ± (2.34) เปอร์เซ็นต์ แสดง confusion matrix ของการจำแนกอุปกรณ์ในรูปที่ ก.4

จากรูปที่ 3.18 เมื่อทดลองด้วยชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 แสดงประสิทธิภาพการฝึกฝน ประสิทธิภาพการตรวจสอบ เวลาการฝึกฝน และ ประสิทธิภาพการทดสอบดังนี้:

ตารางที่ 4.5 ประสิทธิภาพของโมเดลของการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและ ประสิทธิภาพการทดสอบของโมเดลที่ 5

การทดลอง	ประสิทธิภาพการฝึกฝน	ประสิทธิภาพตรวจสอบความถูกต้อง	เวลาในการฝึกฝน (นาที)	ประสิทธิภาพการทดสอบ
ชุดที่ 1	100.0 ± (0)	98.28 ± (0.04)	87.21 ± (2.45)	96.91 ± (0.26)
ชุดที่ 2	99.88 ± (0.04)	98.09 ± (0.26)	218.08 ± (4.02)	85.59 ± (1.48)
ชุดที่ 3	99.73 ± (0.08)	92.90 ± (0.22)	189.55 ± (3.36)	55.11 ± (1.12)
ชุดที่ 4	99.85 ± (0.05)	91.84 ± (0.31)	175.54 ± (3.02)	68.42 ± (1.33)

#หมายเหตุ ผลการทดลองในบทที่สี่นี้เป็นผลการทดลองซ้ำ เพื่อหาค่าเฉลี่ยความถูกต้องของโมเดล

ผลการทดลองในตารางที่ 4.5 จากชุดข้อมูลที่ 1, 2, 3 และ ชุดที่ 4 ประสิทธิภาพของชุดการฝึกฝนร้อยละ 100.0 ± (0), 99.88 ± (0.04), 99.73 ± (0.08) และ 99.85 ± (0.05) เปอร์เซ็นต์ ผลของชุดตรวจสอบมีความแม่นยำร้อยละ 99.88 ± (0.04), 98.09 ± (0.26), 92.90 ± (0.22) และ 91.84 ± (0.31) เปอร์เซ็นต์ สูญเสียเวลาฝึกฝน 87.21 ± (2.45), 218.08 ± (4.02), 169.55 ± (3.36) และ 175.54 ± (3.02) นาที เมื่อนำโมเดลไปทดสอบด้วยชุดข้อมูลการทดสอบมีประสิทธิภาพร้อยละ 218.08 ± (4.02), 85.59 ± (1.48), 55.11 ± (1.12) และ 68.42 ± (1.33) เปอร์เซ็นต์ แสดง confusion matrix ของการจำแนกอุปกรณ์ในรูปแบบที่ ก.5

โมเดลที่ 3, 4 และ โมเดลที่ 5 มีผลการฝึกฝนอยู่โดยประมาณ 99% ถึง 100 % ซึ่งเป็นผลที่ดีในการออกแบบโครงข่าย แต่ยังคงมีข้อด้อยจากเวลาการฝึกฝน ด้วยเหตุนี้ยังคงพัฒนาต่อเนื่อง โดยจะอธิบายถึงการทดลองลำดับต่อไป

4.5 ผลการปรับปรุงโครงข่ายคอนโวลูชันบนพื้นฐานของ VGG

จากการทดลองในรูปแบบที่ 3.19 ถึง รูปแบบที่ 2.23 ผลการทดลองในตารางที่ 4.6 ผลการฝึกฝนด้วยชุดข้อมูล 1, 2 และชุดข้อมูลที่ 3, โมเดลที่ 10 มีประสิทธิภาพสูงสุดที่ $\approx 99.96\%$ (ACC), $\approx 99.95\%$ (ACC), และ $\approx 99.95\%$ (ACC). แต่ว่า, ชุดข้อมูลที่ 4, โมเดลที่ 9 มีประสิทธิภาพสูงสุดที่ $\approx 98.85\%$; โมเดลที่ 6 มีประสิทธิภาพเวลาที่เร็วที่สุดที่ 05.29 ± 0.21 , 05.35 ± 0.36 , 05.30 ± 0.32 และ 05.12 ± 0.46 นาที; ผลของ loss ด้วยการวัดประสิทธิภาพ mse และ rmse , โมเดลที่ 9 มีผลที่ดีในชุดข้อมูล 1 ที่ 0.0221 ± 0.007 (mse), 0.1447 ± 0.018 (rmse) และ ชุดข้อมูล 2 ที่ 0.0448 ± 0.002 (mse), 0.2038 ± 0.012 (rmse); โดยผล loss ของ ชุดข้อมูล 3 โมเดลที่ 10 มีผลดีที่เร็วที่สุดที่ 0.0549 ± 0.008 (mse), 0.2325 ± 0.014 (rmse) และ ผล loss ของชุดข้อมูล 4 โมเดล 8 มีผลดีที่เร็วที่สุดที่ 0.0682 ± 0.026 (mse), 0.2506 ± 0.036 (rmse).

ตารางที่ 4.6 ประสิทธิภาพของโมเดลของการฝึกฝน การตรวจสอบความถูกต้อง เวลาการฝึกฝนและ ประสิทธิภาพการทดสอบของโมเดลที่ 6, 7, 8, 9 และ โมเดลที่ 10

โมเดล	ชุดข้อมูลที่ 1			
	ผลของ MSE	ผลของ RMSE	ผลฝึกฝน (%)	เวลาการฝึกฝน
โมเดลที่ 6	0.0283±0.008	0.1685±0.011	99.30±0.13	05.29±0.21
โมเดลที่ 7	0.0390±0.002	0.2013±0.002	97.43±0.49	74.05±1.26
โมเดลที่ 8	0.0227±0.003	0.1468±0.006	99.26±0.15	17.11±1.15
โมเดลที่ 9	0.0221±0.007	0.1447±0.018	99.69±0.21	14.51±1.28
โมเดลที่ 10	0.0282±0.003	0.1553±0.007	99.96±0.01	45.83±2.12
	ชุดข้อมูลที่ 2			
โมเดลที่ 6	0.0549±0.002	0.2287±0.003	96.52±1.11	05.35±0.36
โมเดลที่ 7	0.0704±0.006	0.2704±0.015	90.42±1.27	21.16±1.48
โมเดลที่ 8	0.0481±0.003	0.2371±0.006	96.87±1.28	17.12±1.46
โมเดลที่ 9	0.0448±0.002	0.2038±0.012	98.31±0.32	15.12±1.51
โมเดลที่ 10	0.0465±0.006	0.2658±0.010	99.09±0.16	45.03±1.53
	ชุดข้อมูลที่ 3			
โมเดลที่ 6	0.0726±0.003	0.2611±0.002	95.65±0.33	05.30±0.32
โมเดลที่ 7	0.0955±0.018	0.3024±0.018	85.59±1.03	81.85±1.44
โมเดลที่ 8	0.0573±0.005	0.2352±0.006	99.05±0.16	15.06±0.55
โมเดลที่ 9	0.0586±0.007	0.2658±0.012	99.32±0.06	13.45±1.08
โมเดลที่ 10	0.0549±0.008	0.2325±0.014	99.55±0.11	41.41±1.45
	ชุดข้อมูลที่ 4			
โมเดลที่ 6	0.0821±0.012	0.2894 ±0.051	93.59±1.05	05.12±0.46
โมเดลที่ 7	0.1150±0.038	0.3465±0.048	69.57±1.53	39.53±2.02
โมเดลที่ 8	0.0682±0.026	0.2506±0.036	97.85±0.33	25.05±1.02
โมเดลที่ 9	0.0779±0.011	0.2658±0.042	98.38±0.52	13.66±1.49
โมเดลที่ 10	0.0708±0.035	0.2614±0.030	97.65±0.36	45.30±1.16

จากตารางสามารถเปรียบเทียบผลและความสำคัญดังนี้:

ขนาดของคอร์เนล และ จำนวนชั้นของโครงข่ายที่ได้รับการปรับเปลี่ยนส่งผลคุณลักษณะคอร์โตนแกรม ตัวอย่างการเปรียบเทียบผลระหว่างโมเดลที่ 1 (ชุดข้อมูลที่ 4) สูญเสียเวลา $39.23 \pm (2.40)$ นาที กับ โมเดลที่ 9 (ชุดข้อมูลที่ 4) สูญเสียเวลา 13.66 ± 1.49 นาที แม้ผลการฝึกฝนมีประสิทธิภาพใกล้เคียงกัน แต่การปรับโครงข่ายของโมเดลส่งผลต่อเวลาการฝึกฝน ทั้งนี้ ผลการทดลองและเวลาที่สูญเสียสามารถยืนยันได้ว่าวิธีดั่งเสนอมีผลเทียบเท่าการวิจัยที่ได้รับการเผยแพร่ [24], [44] นอกจากนี้ผลของโมเดลในตารางที่ 4.6 เมื่อทดสอบด้วยชุดข้อมูลการทดสอบแสดงผลของการตรวจรู้ในตารางที่ 4.7

ตารางที่ 4.7 ประสิทธิภาพของการตรวจรู้

อุปกรณ์	โมเดลที่ 6		โมเดลที่ 7		โมเดลที่ 8		โมเดลที่ 9		โมเดลที่ 10	
	F1-score	Recall	F1-score	Recall	F1-score	Recall	F1-score	Recall	F1-score	Recall
ชุดข้อมูลที่ 1										
data1	0.99±0.01	1.00±0.00	0.99±0.01	0.99±0.01	1.00±0.00	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01
data2	0.96±0.01	0.99±0.01	0.91±0.03	0.96±0.01	0.96±0.02	0.99±0.01	0.96±0.01	0.98±0.01	0.95±0.04	0.99±0.01
data3	0.95±0.02	0.91±0.03	0.87±0.05	0.77±0.02	0.96±0.01	0.95±0.02	0.95±0.02	0.92±0.01	0.95±0.02	0.90±0.02
data4	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01	0.99±0.01
data5	0.93±0.01	0.94±0.02	0.86±0.02	0.88±0.02	0.94±0.01	0.93±0.01	0.95±0.01	0.96±0.01	0.96±0.01	0.96±0.04
เฉลี่ย	0.964	0.966	0.924	0.918	0.970	0.970	0.968	0.968	0.968	0.966
ชุดข้อมูลที่ 2										
data12	0.85±0.06	0.85±0.08	0.72±0.02	0.74±0.02	0.90±0.04	0.92±0.04	0.91±0.03	0.93±0.07	0.92±0.01	0.96±0.01
data15	0.85±0.06	0.87±0.05	0.72±0.01	0.71±0.03	0.92±0.01	0.92±0.07	0.90±0.04	0.89±0.02	0.92±0.08	0.89±0.02
data25	0.94±0.04	0.92±0.03	0.92±0.01	0.86±0.01	0.94±0.01	0.90±0.03	0.94±0.05	0.92±0.02	0.94±0.02	0.92±0.01
data34	0.98±0.01	0.99±0.04	0.92±0.06	0.90±0.05	0.96±0.02	0.99±0.01	0.97±0.02	0.98±0.01	0.98±0.06	0.98±0.01
data45	0.96±0.03	0.95±0.06	0.90±0.05	0.95±0.02	0.96±0.05	0.96±0.02	0.95±0.01	0.96±0.05	0.95±0.02	0.96±0.05
เฉลี่ย	0.916	0.916	0.836	0.832	0.936	0.938	0.934	0.936	0.942	0.942
ชุดข้อมูลที่ 3										
data124	0.55±0.01	0.55±0.01	0.35±0.03	0.31±0.05	0.60±0.02	0.57±0.04	0.58±0.02	0.55±0.01	0.58±0.08	0.52±0.01
data135	0.60±0.05	0.55±0.04	0.46±0.06	0.38±0.08	0.68±0.02	0.73±0.02	0.62±0.04	0.64±0.01	0.67±0.03	0.74±0.01
data145	0.63±0.02	0.67±0.04	0.56±0.01	0.68±0.05	0.65±0.03	0.63±0.01	0.61±0.01	0.60±0.02	0.63±0.01	0.60±0.03
data235	0.83±0.02	0.85±0.03	0.79±0.02	0.75±0.01	0.86±0.01	0.92±0.05	0.82±0.05	0.87±0.04	0.86±0.02	0.93±0.01
data345	0.82±0.01	0.79±0.02	0.83±0.02	0.86±0.01	0.84±0.01	0.78±0.02	0.84±0.02	0.80±0.02	0.85±0.02	0.77±0.06
เฉลี่ย	0.686	0.682	0.598	0.596	0.726	0.726	0.694	0.692	0.718	0.712
ชุดข้อมูลที่ 4										
data1234	0.48±0.09	0.52±0.03	0.24±0.07	0.32±0.08	0.52±0.04	0.61±0.03	0.53±0.05	0.56±0.01	0.50±0.08	0.55±0.01
data1235	0.75±0.02	0.71±0.02	0.45±0.02	0.33±0.05	0.77±0.08	0.68±0.01	0.78±0.09	0.75±0.03	0.75±0.03	0.70±0.03
data1245	0.53±0.04	0.53±0.05	0.28±0.02	0.21±0.05	0.55±0.02	0.59±0.05	0.55±0.06	0.57±0.03	0.54±0.01	0.58±0.01
data1345	0.65±0.03	0.64±0.01	0.36±0.05	0.29±0.04	0.68±0.02	0.64±0.03	0.67±0.03	0.65±0.01	0.66±0.04	0.62±0.01
data2345	0.98±0.01	0.95±0.01	0.96±0.01	0.93±0.02	0.98±0.01	0.96±0.02	0.98±0.01	0.96±0.01	0.98±0.01	0.95±0.02
เฉลี่ย	0.678	0.670	0.458	0.416	0.700	0.696	0.702	0.698	0.686	0.680

- ชุดข้อมูลที่ 1: คะแนน F1-score ให้ความแม่นยำสูงสุดที่ 1.00, 0.96, 0.96, 0.99 และ 0.96 และ ผลของ recall ยังเสนอ 1.00, 0.99, 0.95, 0.99 และ 0.96 สำหรับ data1, data2, data3, data4 และ data5 ตามลำดับ โมเดล CNN ที่กำลังพัฒนาที่ดีที่สุดคือ โมเดลที่ 8 ซึ่งให้คะแนน F1-score เฉลี่ยสูงสุดและผลของ recall เฉลี่ยที่ 0.970 และ 0.970 ตามลำดับ ในเวลาเดียวกัน โมเดลที่ 7 เสนอคะแนน F1-score เฉลี่ยต่ำสุดและ ผลของ recall เฉลี่ยใน data3

- ชุดข้อมูลที่ 2: คะแนน F1-score ให้ความแม่นยำสูงสุดเท่ากับ 0.96, 0.92, 0.92, 0.99 และ 0.96 และผลของ recall ยังเสนอ 0.96, 0.92, 0.92, 0.99 และ 0.96 สำหรับ data15, data25, data34 และ data45 ตามลำดับ โมเดล CNN ที่กำลังพัฒนาที่ดีที่สุดคือ โมเดลที่ 10 ซึ่งให้คะแนน F1-score เฉลี่ยสูงสุด และ ผลของ recall เฉลี่ยที่ 0.942 และ 0.942 ตามลำดับ ในเวลาเดียวกัน โมเดล 7 ให้ผลคะแนน F1-score เฉลี่ยต่ำสุด และ ผลของ recall เฉลี่ยในอุปกรณ์ประเภท 1

- ชุดข้อมูลที่ 3: คะแนน F1-score ให้ความแม่นยำที่ดีที่สุดเท่ากับ 0.60, 0.68, 0.65, 0.86 และ 0.86 และผลของ recall เสนอ 0.57, 0.74, 0.68, 0.93 และ 0.86 สำหรับ data124, data135, data145, data 235 และ data345 ตามลำดับ โมเดล CNN ที่กำลังพัฒนาที่ดีที่สุดคือโมเดลที่ 8 ซึ่งให้คะแนน F1-score เฉลี่ยสูงสุด และ ผลของ recall เฉลี่ยที่ 0.726 และ 0.726 ตามลำดับ ในเวลาเดียวกันโมเดลที่ 8 มีผล F1-score เฉลี่ยต่ำสุด และ ผลของ recall เฉลี่ยในอุปกรณ์คลาส 1 และ 4

- ชุดข้อมูลที่ 4: คะแนน F1-score ให้ความแม่นยำสูงสุดเท่ากับ 0.53, 0.78, 0.55, 0.68 และ 0.98 และ ผลของ recall เป็น 0.61, 0.75, 0.59, 0.65 และ 0.96 สำหรับ data1234, data1245, data1345, data 1235 และ data2345 ตามลำดับ โมเดล CNN ที่กำลังพัฒนาที่ดีที่สุดคือโมเดลที่ 9 ให้คะแนน F1-score เฉลี่ยสูงสุดและผลของ recall เฉลี่ยที่ 0.702 และ 0.698 ตามลำดับ ในเวลาเดียวกันโมเดลที่ 7 มีผล F1-score เฉลี่ยต่ำสุดและผลของ recall เฉลี่ยในคลาสอุปกรณ์ 1 และ 4

4.6 ผลการทดลองด้วย AlexNet สำหรับการทำงานแบบเปิด-ปิด

จากรูปที่ 3.1 (การทดลองที่ 4) การนำ AlexNet ที่ได้รับการวิจัยก่อนหน้านี้มาทดลองก่อนหน้า มีเป้าหมายเพื่อแสดงความแตกต่างของการทำงานระหว่างช่วงเปิด ปิด ซึ่งจากการเงื่อนไขการทดลองที่ 1 ถึง 10 แสดงผลการทดลองดัง:

ตารางที่ 4.8 ผลการฝึกฝนด้วย Alex Net

อัตราการเรียนรู้	ขนาดของ Batch	เวลาการฝึกฝน (วินาที)	ผลการฝึกฝน (%)
0.0001	16	2,167	98.10
0.0001	32	1,854	98.18
0.001	16	2,210	98.52
0.001	32	1,871	98.56

ผลการทดสอบที่ได้พบว่าเมื่อใช้ อัตราการเรียนรู้ 0.001 ร่วมกับขนาดของ Batch ที่ 32 ให้ความถูกต้องเฉลี่ยสูงสุดเท่ากับ 98.56% ผลการทำนาย Class3-ON และ Class3-OFF (Lamp) มีความถูกต้องสูงที่สุดโดยมีความถูกต้อง 100 % ส่วนการทำนายที่มีความถูกต้องต่ำสุดคือ Class1-On มีความถูกต้อง 94.8% ผลการทำนายที่ผิดพลาดเกิดจากการไปทำนายผลเป็น Class2-On และในทำนองเดียวกันผลการทำนาย Class2-On มีผลการทำนายผิดเป็น Class1-On ความผิดพลาดดังกล่าวเกิดจากอุปกรณ์ Class1 และ Class2 เป็น Air conditioner ซึ่งมีการทำงานที่คล้ายกัน

ในส่วนนี้เป็นผลการทำงานแยกแยะอุปกรณ์ที่กำลังทำงานโดยใช้การบันทึก Transient Current ขณะเปิด-ปิดเครื่องใช้ไฟฟ้าหลายตัวโดนใช้ Model ที่ Training มาจากหัวข้อที่ผ่านมาโดยในการทดลองได้ทำการเปิด-ปิดเครื่องใช้ไฟฟ้าและส่งค่า Transient Current ที่อ่านได้มาทำการทดสอบ ผลที่ได้จากการทดสอบแสดงดังตารางที่ 4.9 ซึ่งพบว่าการทำนายผลมีความถูกต้อง ในรูปที่ 4.10 กราฟบันทึกค่ากระแสไฟฟ้าที่เกิดจากการเปิด-ปิดอุปกรณ์ไฟฟ้าต่อเนื่องและค่าทำนายผลที่เกิดจากการเปิด-ปิดอุปกรณ์ไฟฟ้าแต่ละตัว และ แสดง confusion matrix สำหรับการจำแนกในรูป ก.11

ตารางที่ 4.9 ผลการทดสอบตรวจรู้อุปกรณ์ด้วย AlexNet

ลำดับที่	เวลา (วินาที)	สถานะสั่งงาน	ค่าทำนายผล	ผลค่าทำนาย
1	60	Class1-ON	Class1-On	ถูกต้อง
2	1000	Class2-ON	Class2-On	ถูกต้อง
3	1500	Class3-ON	Class3-On	ถูกต้อง
4	2000	Class1-OFF	Class1-OFF	ถูกต้อง
5	2500	Class2-OFF	Class2-OFF	ถูกต้อง
6	3000	Class4-ON	Class4-On	ถูกต้อง
7	3500	Class5-ON	Class5-On	ถูกต้อง
8	4000	Class3-OFF	Class3-OFF	ถูกต้อง
9	4500	Class4-OFF	Class4-OFF	ถูกต้อง
10	5000	Class5-OFF	Class5-OFF	ถูกต้อง

4.7 ผลการเปรียบเทียบประสิทธิภาพของการเรียนรู้เชิงลึก

จากรูปที่ 3.25 การนำ Deep C-NN ที่ได้รับการวิจัยร่วมกับเทคนิค NILM ก่อนหน้ามาทดลองด้วยชุดข้อมูลตั้งเสนอเพื่อเปรียบเทียบถึงวิธีการก่อนหน้า โดยนำ MLP, AlexNet และ Deep C-NN ได้แก่ VGG Net, C-NN [24] และ C-NN [44] มาทดลองเพื่อความเป็นมาตรฐานการวิจัย ทดลองด้วยวิธี Transfer learning เพื่อหลีกเลี่ยงการเรียนรู้เชิงลบ โดยการปรับเปลี่ยนลำดับชั้นและโหนด (1 layers : 500 node) มี Relu และ Softmax เป็นฟังก์ชันผลรวม เพิ่มประสิทธิภาพการเรียนรู้ด้วย Adam optimizer ฝึกฝนโมเดล 100 รอบ และ กำหนด batch size ไว้ที่ 16 สรุปผลไว้ในตารางที่ 4.9 และ เวลาที่สูญเสียในตารางที่ 4.11

ผลการทดลองของวิธีที่ได้รับการเผยแพร่ เราไม่สามารถเปรียบเทียบความถูกต้องได้โดยตรง เนื่องจากความแตกต่างหลายปัจจัย เช่น ขนาดภาพอินพุต ขนาดเน็ตเวิร์ก พารามิเตอร์ ชุดข้อมูล พารามิเตอร์สำหรับทดลอง ขนาดโมเดล อื่นๆ อย่างไรก็ตามผลลัพธ์ในตารางที่ 4.9 และ ตารางที่ 4.10 เพื่ออ้างอิงผลที่มีประสิทธิภาพและให้แน่ใจว่าวิธีตั้งเสนอเป็นการพัฒนาที่แตกต่าง จากการสังเกตผลการทดลองประสบผลสำเร็จกับชุดข้อมูลของอุปกรณ์ทำงานร่วมกัน

ตารางที่ 4.10 ผลการฝึกฝน Deep C-NN ด้วยการถ่ายโอนการเรียนรู้

โมเดล	ข้อมูลชุดที่ 1	ข้อมูลชุดที่ 2	ข้อมูลชุดที่ 3	ข้อมูลชุดที่ 4
MLP	87.2±1.02	60.68±2.23	51.08±2.55	54.13±1.38
Alex-Net	99.34±0.18	93.21±1.26	86.83±0.49	80.22±1.10
VGG-16	99.30±0.11	97.89±0.15	91.53±0.46	89.94±1.12
VGG-19	99.15±0.12	95.04±0.20	87.17±1.34	82.08±1.44
C-NN [24]	95.77±1.03	83.96±1.59	77.20±1.02	74.03±1.58
C-NN [44]	99.28±0.13	98.34±0.22	97.10±0.64	97.76±1.02

ตารางที่ 4.11 ผลเวลาการฝึกฝน Deep C-NN ด้วยการถ่ายโอนการเรียนรู้

โมเดล	ข้อมูลชุดที่ 1 เวลา (m)	ข้อมูลชุดที่ 2 เวลา (m)	ข้อมูลชุดที่ 3 เวลา (m)	ข้อมูลชุดที่ 4 เวลา (m)
MLP	01.51±0.13	02.45±0.10	02.41±0.16	02.21±0.27
Alex-Net	11.2±1.56	11.2±0.58	12.4±1.15	12.4±1.16
VGG-16	32.7±1.28	37.4±1.44	41.4±1.02	37.2±1.41
VGG-19	69.5±1.32	98.4±2.04	75.3±2.36	58.5±1.53
C-NN [24]	4.08±0.51	4.23±0.30	4.04±0.31	3.50±0.26
C-NN [44]	3.24±0.11	3.49±0.32	3.31±0.11	3.40±0.18

บทที่ 5

สรุปผลการทดลอง

5.1 สรุปผลการทดลอง

คุณลักษณะที่นำเสนอนี้เสนอเทคนิคการเรียนรู้เชิงลึกสำหรับการตรวจรู้สภาวะไหลตแบบไม่ล่วงล้ำ ซึ่งได้ตรวจสอบวิธีการบางอย่างเพื่อลดการคำนวณของโครงข่ายประสาท การทดลองนี้ ทดลองด้วยการเปลี่ยนแปลงโครงข่ายและกำหนดพารามิเตอร์ในการคำนวณที่น้อยกว่า นอกจากนี้ ผู้ทดลองได้ปรับความซับซ้อนในการคำนวณของแบบจำลอง เพื่อลดเวลาที่สูญเสียจากการฝึกฝน การทดลองประกอบด้วยเครื่องมือที่เป็นมาตรฐานเพื่ออธิบายประสิทธิภาพของโมเดลและการตรวจรู้สภาวะไหลตที่ทำงานแบบเดี่ยว และ ทำงานร่วมกัน

การออกแบบการเข้าถึงอุปกรณ์และลักษณะของอุปกรณ์แบบเคอร์โทแกรม มุ่งเป้าไปยังการสร้างแนวทางการเข้าถึงและพัฒนาคุณลักษณะที่แตกต่าง ซึ่งเป็นทางเลือกที่เสถียรและเพิ่มความแตกต่างมากกว่าการตรวจรู้ไหลตด้วยวิธีแบบไบนารี เป็นที่สังเกตว่าคุณลักษณะแบบเคอร์โทแกรม ให้ผลลัพธ์ที่ดีกับอุปกรณ์ที่ทำงานพร้อมกัน และ อุปกรณ์ที่ใช้พลังงานสูง อย่างไรก็ตาม การพัฒนาต้องดำเนินการต่อเนื่องเพื่อให้ได้ผลลัพธ์ที่ดีที่สุดสำหรับตรวจรู้อุปกรณ์ที่มีความซับซ้อน

การปรับปรุงโครงข่าย C-NN มุ่งเป้าไปที่การปรับเปลี่ยนพารามิเตอร์ในสภาพแวดล้อมที่จำกัด เราคิดว่าการออกแบบและฝึกอบรมโมเดลขนาดเล็กตามขนาดของภาพ เป็นทางเลือกที่เสถียรกว่าการบีบอัดเครือข่ายขนาดใหญ่ ผลการทดลองแสดงให้เห็นว่าวิธีดังกล่าวมีความแม่นยำเพิ่มขึ้นและลดเวลาลงเมื่อเทียบกับแบบจำลองอื่นๆ หรือ การใช้เคอร์เนลขนาดใหญ่ สิ่งเหล่านี้ได้รับการตามแบบจำลอง VGG และ AlexNet ซึ่งชี้ให้เห็นการพัฒนาอย่างมีประสิทธิภาพ แม้ว่าชุดข้อมูลมีโดเมนที่ต่างกันแต่ไม่ส่งผลต่อการปรับแต่งโครงข่ายอย่างละเอียดในขณะฝึกฝนโมเดล ทั้งนี้, วิธีที่นำเสนอเป็นแนวทางสำหรับการใช้งานจริง อย่างไรก็ตาม ด้วยผลลัพธ์ที่มีประสิทธิภาพแสดงให้เห็นถึงความเป็นไปได้ในการพัฒนา NILM อย่างเป็นรูปธรรม ซึ่งยืนยันได้ว่าแนวคิดนี้เป็นที่ยอมรับจากการกำลังดำเนินการก่อนหน้านี้ และ มีความสำคัญต่อการศึกษาและพัฒนาในอนาคต

5.2 ข้อเสนอแนะการวิจัย

การศึกษาในอนาคต เราได้เห็นแล้วว่าเทคโนโลยีที่มีความฉลาดได้รับการพัฒนาอย่างต่อเนื่องและมีคุณลักษณะที่ซับซ้อนมากขึ้น ดังนั้นในอนาคตข้างหน้าจึงมีความคิดที่จะพัฒนาเทคนิคการตรวจรู้แบบไม่ล่วงล้ำที่สามารถวิเคราะห์ความแปรผันของข้อมูลที่มีความซับซ้อนมากขึ้น บนระบบการตรวจรู้แบบเวลาจริงร่วมกับการพัฒนาเทคนิคการเรียนรู้เชิงลึกแบบใหม่ เพื่อตอบสนองต่อการพัฒนาระบบที่นำไปใช้ภายในบ้าน

บรรณานุกรม

- [1] Y. Yang, J. Zhong, W. Li, T. A. Gulliver & S. Li. (2020). Semisupervised Multilabel Deep Learning Based Nonintrusive Load Monitoring in Smart Grids. **IEEE Transactions on Industrial Informatics**. **16**(11), pp. 6892-6902. doi: 10.1109/TII.2019.2955470
- [2] P. Franco, J. M. Martínez, Y. C. Kim, & M. A. Ahmed. (2021). IoT Based Approach for Load Monitoring and Activity Recognition in Smart Homes. **IEEE Access**, **9**, pp. 45325-45339. doi: 10.1109/ACCESS.2021.3067029
- [3] A. Kadechkar, J. Riba, M. Moreno-Eguilaz, & J. Sanllehi. (2019). Real-Time Wireless, Contactless, and Coreless Monitoring of the Current Distribution in Substation Conductors for Fault Diagnosis. **IEEE Sensors Journal**, **19**(5), pp. 1693-1700. doi: 10.1109/JSEN. 2018.2884566
- [4] G. W. Hart. Nonintrusive appliance load monitoring. (1992). **Proceedings of the IEEE**. **80**(12), pp. 1870-1891. doi: 10.1109/5.192069
- [5] B. Zhao, K. He, L. Stankovic & V. Stankovic. (2018). Improving Event-Based Non-Intrusive Load Monitoring Using Graph Signal Processing. **IEEE Access**. **6**, pp. 53944-53959. doi: 10.1109/ACCESS.2018.2871343
- [6] F. D. Garcia, W. A. Souza, I. S. Diniz, & F. P. Marafão. (2020). NILM-based approach for energy efficiency assessment of household appliances. **Energy Informatics**. **3**(10). doi: 10.1186/s42162-020-00131-7
- [7] T. K. Nguyen, E. Dekneutel, G. Jacquemod, B. Nicolle, O. Zammit, & V. C. Nguyen. (2017). Development of a real-time non-intrusive appliance load monitoring system: An application level model. **International Journal of Electrical Power & Energy Systems**. **90**, pp. 168-180. doi: 10.1016/j.ijepes.2017.01.012

บรรณานุกรม (ต่อ)

- [8] H. K. Iqbal, F. H. Malik, A. Muhammad, M. A. Qureshi, M. N. Abbasi, & A. R. Chishti. (2021). A critical review of state-of-the-art non-intrusive load monitoring datasets. **Electric Power Systems Research. 192**, pp. 106921. doi: 10.1016/j.epsr.2020.106921
- [9] P. Held, F. Laasch, D. O. Abdeslam, & D. Benyoucef. (2016). Frequency invariant transformation of periodic signals (FIT-PS) for signal representation in NILM. **IECON 2016 - 42nd Annual Conference of the IEEE Industrial Electronics Society**. pp. 5149-5154. doi: 10.1109/IECON.2016.7793617
- [10] K. He, L. Stankovic, J. Liao, & V. Stankovic. (2016). Non-Intrusive Load Disaggregation Using Graph Signal Processing. **IEEE Transactions on Smart Grid. 9**(3), pp. 1739-1747. doi: 10.1109/TSG.2016.2598872
- [11] L. Du, D. He, R. G. Harley, & T. G. Habetler. (2015). Electric Load Classification by Binary Voltage–Current Trajectory Mapping. **IEEE Transactions on Smart Grid. 7**(1), pp. 358-365. doi: 10.1109/TSG.2015.2442225
- [12] E. Gomes and L. Pereira. (2020). PB-NILM: Pinball Guided Deep Non-Intrusive Load Monitoring. **IEEE Access. 8**, pp. 48386-48398. doi: 10.1109/ACCESS.2020.2978513
- [13] M. Kaselimi, E. Protopapadakis, A. Voulodimos, N. Doulamis, & A. Doulamis. (2019). Multi-Channel Recurrent Convolutional Neural Networks for Energy Disaggregation. **IEEE Access. 7**, pp. 81047-81056. doi: 10.1109/ACCESS.2019.2923742
- [14] H. H. Chang, C. L. Lin & J. K. Lee. (2010). Load identification in nonintrusive load monitoring using steady-state and turn-on transient energy algorithms. **The 2010 14th International Conference on Computer Supported Cooperative Work in Design**. pp. 27-32. doi: 10.1109/CSCWD.2010.5472008

บรรณานุกรม (ต่อ)

- [15] H. H. Chang. (2012). Non-Intrusive Demand Monitoring and Load Identification for Energy Management Systems Based on Transient Feature Analyses. **Energies**, **5**, pp. 4569-4589. doi: 10.3390/en5114569
- [16] W. Kong, Z. Y. Dong, D. J. Hill, J. Ma, J. H. Zhao, and F. J. Luo. (2018). A Hierarchical Hidden Markov Model Framework for Home Appliance Modeling. **IEEE Transactions on Smart Grid**. **9**(4), pp. 3079 – 3090. doi: 10.1109/TSG.2016.2626389
- [17] W. Souza, F. Garcia, A. Moreira, F. Marafao, & L. Silva. (2020). Automatic Consumption Management for Prepaid Electricity Meter with NILM. **IEEE Latin America Transactions** **18**(6), pp. 1102 – 1110. doi: 10.1109/TLA.2020.9099748
- [18] S. Houidi, F. Auger, P. Frétaud, D. Fourer, L. Miègeville, & H. B. A. Sethom. (2019). Design of an electricity consumption measurement system for Non Intrusive Load Monitoring. **International Renewable Energy Congress (IREC)**. doi: 10.1109/IREC.2019.8754586
- [19] S. Khan, A. F. Latif, & S. Sohaib. (2018). Low-cost real-time non-intrusive appliance identification and controlling through machine learning algorithm. **International Symposium on Consumer Technologies (ISCT)**, pp. 2159-1423. doi: 10.1109/ISCE.2018. 8408911
- [20] P. Ducange, F. Marcelloni, & M. Antonelli. (2014). A Novel Approach Based on Finite-State Machines with Fuzzy Transitions for Nonintrusive Home Appliance Monitoring. **IEEE Transactions on Industrial Informatics**. **10**(2), pp. 1185 - 1197. doi: 10.1109/TII.2014. 2304781

บรรณานุกรม (ต่อ)

- [21] Y. H. Lin, & M. S. Tsai. (2015). An Advanced Home Energy Management System Facilitated by Nonintrusive Load Monitoring With Automated Multiobjective Power Scheduling. **IEEE Transactions on Smart Grid**. 6(4), pp. 1839 – 1851. doi: 10.1109/TSG.2015. 2388492
- [22] D. P. B. Renaux, F. Pottker, H. C. Ancelmo, A. E. Lazzaretti, C. R. E. Lima, & R. R. Linhares. A Dataset for Non-Intrusive Load Monitoring: Design and Implementation. **Energies**. 13(20), 5371. doi: 10.3390/en13205371
- [23] Y. Liu, X. Wang, and W. You. (2019). Non-Intrusive Load Monitoring by Voltage–Current Trajectory Enabled Transfer Learning. **IEEE Transactions on Smart Grid**. 10(5), pp. 5609-5619. doi: 10.1109/TSG.2018.2888581
- [24] A. Faustine, L. Pereira, & C. Klemenjak. Adaptive Weighted Recurrence Graphs for Appliance Recognition in Non-Intrusive Load Monitoring. **IEEE Transactions on Smart Grid**. 12(1). pp. 398 – 406. doi: 10.1109/TSG.2020.3010621
- [25] Arun K.R., N. Muhamed, FawazHanif Ch, Sathyapriya M.S, & Anish M.N. (2019). Non-Intrusive Load Monitoring and Controlling of Home Appliances Using Bidirectional Counter. **Fifth International Conference on Science Technology Engineering and Mathematics (ICONSTEM)**. doi: 10.1109/ICONSTEM.2019.8918809
- [26] S.R. Tito, A. U. Rehman, Y. Kim, P. Nieuwoudt, S. Aslam, S. Soltic, T. T. Lie, N.Pandey, & M. D. Ahmed. (2021). **Image Segmentation-based Event Detection for Non-Intrusive Load Monitoring using Gramian Angular Summation Field**. doi: 10.1109/IEACon 51066.2021.9654789
- [27] A. Ridi, C. Gisler, & J. Hennebert. (2014). A Survey on Intrusive Load Monitoring for Appliance Recognition. **22nd International Conference on Pattern Recognition**. pp. 1051-4651. doi: 10.1109/ICPR.2014.636

บรรณานุกรม (ต่อ)

- [28] จักรี ศรีนนท์ฉัตร และ สรยุทธ แยมประยูร. (2020). การพัฒนาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำโดยอุปกรณ์ลอจิกแบบโปรแกรม. **EAU HERITAGE JOURNAL Science and Technology**. ปีที่ 14 (ฉบับที่ 2). หน้า 200-209.
- [29] Á. Hernández, R. Nieto, D. Fuentes, & J. Ureña. (2020). Design of a SoC Architecture for the Edge Computing of NILM Techniques. **XXXV Conference on Design of Circuits and Integrated Systems (DCIS)**. doi. 10.1109/DCIS51330.2020.9268626
- [30] K. N. Trung, O. Zammit, E. Dekneuve, B. Nicolle, C. N. Van, & G. Jacquemod. (2012). An innovative non-intrusive load monitoring system for commercial and industrial application. **The 2012 International Conference on Advanced Technologies for Communications**. doi: 10.1109/ATC.2012.6404221
- [31] S. Sawaguchi, & H. Nishi. (2016). Hardware accelerator for data anonymization using dynamic partial reconfiguration. **IEEE International Conference on Smart Grid Communications (SmartGridComm)**. doi: 10.1109/SmartGridComm.2016.7778745
- [32] S. S. Udmale, S. K. Singh, R. Singh, & A. K. Sangaiah. (2020). Multi-Fault Bearing Classification Using Sensors and ConvNet-Based Transfer Learning Approach. **IEEE Sensors Journal**. 20(3). pp. 1433 – 1444. doi: 10.1109/JSEN.2019.2947026
- [33] J. L. Hellerstein. (2018). **Neural Networks**. สืบค้นจาก <https://vikram-bajaj.gitbook.io/cs-gy-6923-machine-learning/types-of-machine-learning/supervised-learning/neural-networks>
- [34] J. D. Rios, A. Y. Alanis, N. Ar. Daniel & C. L. Franco. (2020). Artificial neural networks. **In Neural Networks Modeling and Control**. doi: 10.1016/B978-0-12-817078-6.00016-7

บรรณานุกรม (ต่อ)

- [35] L. Wen, X. Li, & L. Gao. (2021). A New Reinforcement Learning Based Learning Rate Scheduler for Convolutional Neural Network in Fault Classification. **IEEE Transactions on Industrial Electronics**. **68**(12). pp. 12890 – 12900. doi: 10.1109/TIE.2020.3044808
- [36] S Ruder. (2017). **An overview of gradient descent optimization algorithms**. สืบค้นจาก <https://ruder.io/optimizing-gradient-descent/>
- [37] I. Hakki & V. FARYA. (2019). New Design of a Supervised Energy Disaggregation Model Based on the Deep Neural Network for a Smart Grid. **Energies**. **12**(7). 1217, doi: 10.3390/en12071217
- [38] Chen, K., Wang, Q., He, Z., Chen, K., Hu, J., & He, J. (2018). Convolutional Sequence to Sequence Non-intrusive Load Monitoring. **ArXiv**, doi: 10.1049/joe. 2018.8352
- [39] W. Kong, Z. Y. Dong, B. Wang, J. Zhao, & J. Huang. (2019). A Practical Solution for Non-Intrusive Type II Load Monitoring based on Deep Learning and Post-Processing. **IEEE Transactions on Smart Grid**. **11**(1), pp. 148 – 160. doi: 10.1109/TSG.2019.2918330
- [40] F. Ciancetta, G. Bucci, E. Fiorucci, S. Mari, A. Fioravanti. (2020). A New Convolutional Neural Network-Based System for NILM Applications. **IEEE Transactions on Instrumentation and Measurement**. **70**. doi: 10.1109/TIM.2020.3035193
- [41] G. Zhou, Z. Li, M. Fu, Y. Feng, X. Wang, & C. Huang. (2020). Sequence-to-Sequence Load Disaggregation Using Multiscale Residual Neural Network. **IEEE Transactions on Instrumentation and Measurement**. **70**. doi: 10.1109/TIM.2020.3034989
- [42] K. Simonyan, & A. Zisserman. (2015). Very Deep Convolutional Networks for Large-Scale Image Recognition. **ArXiv**. doi: arxiv-1409.1556

บรรณานุกรม (ต่อ)

- [43] O. Ronneberger, P. Fischer, & T. Brox. (2015). U-Net: Convolutional Networks for Biomedical Image Segmentation. **ArXiv**. doi: arxiv.org/abs/1505.04597
- [44] A. Faustine and L. Pereira. (2020). Improved Appliance Classification in Non-Intrusive Load Monitoring Using Weighted Recurrence Graph and Convolutional Neural Networks. **Energies**. **13**(13). 3374, doi: 10.3390/en13133374
- [45] L. Wang, S. Mao, B. M. Wilamowski, & M. Nelms. (2021). Pre-Trained Models for Non-Intrusive Appliance Load Monitoring. **IEEE Transactions on Green Communications and Networking**. **6**(1), pp. 56 – 68. doi: 10.1109/TGCN.2021.3087702
- [46] M. D. Incecco, S. Squartini, M. Zhong. (2020). Transfer Learning for Non-Intrusive Load Monitoring. **IEEE Transactions on Smart Grid**. **11**(2), pp. 1419 – 1429. doi: 10.1109/TSG. 2019.2938068
- [47] Y. Zhang, G. Tang, Q. Huang, Y. Wang, X. Wang, & J. Lou. (2021). FedNILM: Applying Federated Learning to NILM Applications at the Edge. **ArXiv**. doi: arxiv-2106.07751


ภาคผนวก




ภาคผนวก ก

ผลการวิจัย







(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.1 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 1




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.2 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 2




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.3 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 3




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.4 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 4




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.5 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 5




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.6 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 6




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.7 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 7




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.8 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 8




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3




(ง) ผลการจำแนกชุดข้อมูลที่ 4


รูปที่ ก.9 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 9




(ก) ผลการจำแนกชุดข้อมูลที่ 1



(ข) ผลการจำแนกชุดข้อมูลที่ 2




(ค) ผลการจำแนกชุดข้อมูลที่ 3



(ง) ผลการจำแนกชุดข้อมูลที่ 4

รูปที่ ก.10 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วยโมเดลที่ 10



รูปที่ ก.11 ผลการจำแนกอุปกรณ์ใช้ไฟฟ้าด้วย AlexNet; (a) Initial Learning Rate 0.0001 ร่วมกับ MiniBatchSize 16, (b) Initial Learning Rate 0.0001 ร่วมกับ MiniBatchSize 32, (c) Initial Learning Rate 0.001 ร่วมกับ MiniBatchSize 16 และ (d) Initial Learning Rate 0.001 ร่วมกับ MiniBatchSize 32

ภาคผนวก ข
งานวิจัยที่ได้รับการเผยแพร่

- [1] Y. Sarayut & S. Jakkree. (2016). Developing an innovation smart meter based on CS5490. **International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology (ECTI-CON)**. pp. 1-4. doi: 10.1109/ECTICon.2016.7561400
- [2] จักรี ศรีนนท์ฉัตร และ สรยุทธย์ แยมประยูร. (2020). การพัฒนาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำโดยอุปกรณ์ลอจิกแบบโปรแกรม. **EAU HERITAGE JOURNAL Science and Technology**. ปีที่ 14 (ฉบับที่ 2). หน้า 200-209.
- [3] Y. Sarayut & S. Jakkree. (2022). Appliance Classification Using Convolutional Neural Network Based on Kurtogram image for Non-Instructive Load Monitoring. **CMC-Computers, Materials & Continua**.
- [4] Y. Sarayut & S. Jakkree. (2022). Non-Intrusive Load Monitoring using Multi-Layer Perceptron for Appliances Classification. **International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology**.
- [5] สรยุทธย์ แยมประยูร และ จักรี ศรีนนท์ฉัตร. (2022). การพัฒนาระบบ NILM สำหรับการจัดการพลังงานโดยการประยุกต์ใช้ AlexNet Model. **วารสารวิชาการพลังงานทดแทนสู่ชุมชน**.

Developing an innovation smart meter based on CS5490

Sarayut Yaemprayoon¹
Signal Processing Research Laboratory
Department of Electronics and
Telecommunication Engineering,
Rajamangala University
of Technology Thanyaburi
E-mail: sarayut_yae@epro.co.th

Vishnu Boonplian²
Signal Processing Research Laboratory
Department of Electronics and
Telecommunication Engineering,
Rajamangala University
of Technology Thanyaburi
E-mail: vishnu_rav@hotmail.com

Jakkree Srinonchat^{3*}
Signal Processing Research Laboratory
Department of Electronics and
Telecommunication Engineering,
Rajamangala University
of Technology Thanyaburi
E-mail:jakkree.s@en.rmutt.ac.th

Abstract— This paper proposes developing an innovation smart meter based on CS5490. It uses to measure the energy data and send to PIC 32-bit microcontrollers via RS232 standard. Then it records energy usage data into SD card that consumer can monitor their energy usage and cost forecasting. The experiment result shows that energy measurement circuit can record the energy usage into SD card. It can be used for NILM system

Keywords—smart meter; energy measurement IC; 32-bit PIC microcontrollers

I. INTRODUCTION

Smart grid is the electrical grid that uses information and communication technology to manage the electrical production and distribution. It use to support the connection between main electrical source and renewable source. This technology will be stability when it is supported smart meter. The smart meter can check the energy consumption each period and cost forecasting. Also the smart meter can use wifi to connect to the electrical instrument to manage the energy using in home. There are many researches to develop the efficiency of the smart meter such as [1] smart meter using ADE7758 energy metering chip with PIC microcontroller 18F452. It uses only 8-bits microcontroller which has slow duty cycles. [2] smart meter using hall effect sensor LEM LA 100-P/SP12 for 100A [3] home appliance load modeling from aggregated smart meter. Explicit-Duration Hidden Markov Model with differential observations (EDHMM-diff), for detecting and estimating individual home appliance. [4] ZigBee based real time home automation system which be analyze efficiency ZigBee system base on home automation system. It can check the electrical instrument load to monitor the total energy consumption with CS5490 energy measurement IC which can provide accurate data for analysis. From these research, the smart meter can use to control and check the energy consumption in home by design the circuit. This paper proposes the energy measurement circuit design to check the energy consumption that can record and show the data that consumer can check their energy consumption and cost forecasting. The microcontroller that be used in this paper is 32-bit microcontroller PIC32 that be suitable for real time with high speed clock and work with CS5490 energy measurement IC that can provide needful parameter of energy for analysis.

II. THEORY

A. Energy measurement (CS5490)

The CS5490 is CMOS measurement integrated circuit that being able to measure voltage and current by converting A/D especially, ability of the CS5490 is calculating active, reactive apparent power, RMS voltage and current, power factor and instantaneous voltage etc. in the part of other system-related function of the CS540 as show in Fig.1.




Fig. 1. structure of The CS5490.

It is strongly recommended that no connection other than the required filter capacitor be made to VREF±. The Voltage at is measured across the temperature range. From these measurements the following formula is used to calculate the VREF temperature coefficient:

$$TC_{VREF} = \left(\frac{VREF_{MAX} - VREF_{MIN}}{VREF_{AVG}} \right) \left(\frac{1}{T_{A,MAX} - T_{A,MIN}} \right) (1.0 \times 10^4) \quad (1)$$

Specified at maximum recommended output of 1μA sourcing. VREF is a very sensitive signal, the output of the VREF circuit has a very high output impedance so that the 0.1μF

การพัฒนาาระบบตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ
โดยใช้อุปกรณ์ลอจิกแบบโปรแกรม
Improving Non-Intrusive Load Monitoring System Based on
Field Programmable Gate Array

จักรี ศรีนนท์ฉัตร¹ และ สรยุทธ แยมประยูร²

Jakkree Srinonchat¹ and Sarayut Yaemprayoon²

¹ภาควิชาอิเล็กทรอนิกส์และโทรคมนาคม คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

¹Department of Electronics and Telecommunication Engineering, Faculty of Engineering,

Rajamangala University of Technology Thanyaburi

²ห้องปฏิบัติการด้านวิจัยและการประมวลผลสัญญาณ

²Signal Processing Research Laboratory

Received: November 18, 2019

Revised: March 12, 2020

Accepted: March 19, 2020

บทคัดย่อ

ในปัจจุบันการพัฒนาระบบบ้านอัจฉริยะ ระบบโครงข่ายไฟฟ้าอัจฉริยะมีจำเป็นที่จะต้องใช้เทคนิคและเครื่องมือสำหรับการวัดค่ากระแสไฟฟ้า แรงดันไฟฟ้าและพลังงานไฟฟ้า ซึ่งเทคนิคดังกล่าวมีด้วยกันอยู่หลายรูปแบบ เทคนิคการตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำเป็นหนึ่งในเทคนิคที่ได้รับความนิยมในการนำมาประยุกต์ใช้วัดค่าการใช้พลังงานไฟฟ้าซึ่งเทคนิคนี้สามารถวัดค่าการใช้พลังงานไฟฟ้าแยกแยะตามชนิดของแต่ละอุปกรณ์ได้ งานวิจัยนี้มุ่งเน้นที่จะพัฒนาระบบการตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำโดยใช้อุปกรณ์ลอจิกแบบโปรแกรม อุปกรณ์ลอจิกแบบโปรแกรมถูกนำมาใช้ในการตรวจวัดค่าพลังงานทางไฟฟ้า และแยกแยะชนิดของการใช้พลังงานไฟฟ้าร่วมกับเทคนิคดิจิทัลโบนารีบนระบบฐานเวลาจริง ทั้งนี้อุปกรณ์ลอจิกแบบโปรแกรมถูกนำมาใช้ในการวิจัยนี้เนื่องจากอุปกรณ์ลอจิกแบบโปรแกรมมีข้อดี คือ มีอัตราการผลิตตัวอย่างที่มากและสามารถคำนวณการทำงานแบบขนานได้ ผลการทดลองพบว่าระบบการตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำซึ่งออกแบบโดยใช้อุปกรณ์ลอจิกแบบโปรแกรมสามารถตรวจวัดค่าพลังงานไฟฟ้า และแยกแยะชนิดของอุปกรณ์ไฟฟ้าได้ ระบบที่ออกแบบสามารถให้ความถูกต้องในการแยกแยะชนิดของอุปกรณ์ 100% จากการสุ่มสัญญาณ 1 ครั้งต่อเวลา 1 วินาที บนฐานเวลาจริง และสามารถที่จะพัฒนาให้มีการคำนวณที่เร็วขึ้นได้ในอนาคต

คำสำคัญ: การตรวจรู้สภาวะโหลดทางไฟฟ้าแบบไม่ล่วงล้ำ, อุปกรณ์ลอจิกแบบโปรแกรม, บ้านอัจฉริยะ

Exploring CNN model with Inrush Current Pattern for Non-Intrusive Load Monitoring

Sarayut Yaemprayoon and Jakkree Srinonchat

Faculty of Engineering, Rajamangala University of Technology Thanyaburi, Pathum Thani, 12110, Thailand
*Corresponding Author: Jakkree Srinonchat. Email: jakkree_s@enrmutt.ac.th
Received: XX Month 202X; Accepted: XX Month 202X

Abstract: Non-Intrusive Load Monitoring (NILM) has gradually become a research focus in recent years to measure the power consumption in households for energy conservation. Most of the existing algorithms on NILM models independently measure when the total current load of appliances occurs. This paper presents a distinguish NILM design to measure and classify the appliances by investigating the inrush current pattern when the appliances begin. The proposed method is implemented while the five appliances operate simultaneously. The high sampling rate of field-programmable gate array (FPGA) is used to sample the inrush current, then the five proposed modifications Convolutional Neural Network (CNN), which is based on VGG, are designed to implement as a classification model to compare with the previous models. The F1 score and Recall are used to measure the accuracy classification. The results showed that the proposed system could be achieved at 99.06 accuracy classification.

Keywords: Non-instructive load monitoring; kurtogram image; convolutional neural network; deep Learning

1 Introduction

Smart Home is a technology for energy consumption control in electrical appliances, and this technology can increase the efficiency of better energy allocation. The examination process of appliance load is based on real-time [1-3]. However, system development that can identify types and energy management must consider the specification of a particular appliance, e.g., the motor as a critical component of an electrical appliance [4] or the heating element inside a heater [5]. It is challenging to study these variables. Therefore, the development of non-intrusive load monitoring (NILM) is an exciting option [1, 3, 6, 7]. The development of NILM requires an understanding of three key components, i.e., data acquisition, appliance classification, and energy analysis [8-10]. According to studies, NILM usually undergoes the problem of signatures of the appliance (caused by the usage of appliances in terrain) [11], particular problems of each appliance (signatures obtained by the operation of electrical appliances) [1, 12, 13], domains [14, 15], and graph [16]. It also undergoes the operational problems of appliances, divided into four types [10]. 1) ON/OFF state of appliances [17, 18]: It refers to binary operation status, e.g., lamp by their switches, with short operational time. It is barely feasible for differentiation. 2) Multi-state appliances [19]: The operational status of appliances changed with usage, e.g., the operation of kettles changes with adjusted values. It is challenging to understand signatures in any form of variables. Therefore, the analysis primarily relies on observation of their forms for a while to make sure of their clarity. 3) Variable power appliances [20]: The operational status of appliances changes continuously, e.g., the energy consumption of washing machines varies during



This work is licensed under a Creative Commons Attribution 4.0 International License, which permits unrestricted use, distribution, and reproduction in any medium, provided the original work is properly cited.

Non-Intrusive Load Monitoring using Multi-Layer Perceptron for Appliances Classification

Sarayut Yaemprayoon
 Department of Electronics and Telecommunication Engineering
 Faculty of Engineering, Rajamangala University of Technology
 Thanyaburi
 Pathum Thani, Thailand
 sarayut_y@mail.rmutt.ac.th

Jakkree Srinonchat
 Department of Electronics and Telecommunication Engineering
 Faculty of Engineering, Rajamangala University of Technology
 Thanyaburi
 Pathum Thani, Thailand
 jakkree_s@rmutt.ac.th

Abstract—Non-Intrusive Load Monitoring (NILM) is widely developed to serve the digital platform. The essential key factor is recognizing the appliance used for energy management. Therefore, this article proposed a design technique for NILM based on Multi-Layer Perceptron (MLP). The experiment uses five different appliances to be input. The MLP is adjusted based on batch size and nodes to recognize the load signatures extracted from the kurtogram technique. The experiment shows that the proposed technique performs well with a high power consumption load.

Keywords—non-intrusive load monitoring, appliance classification, smart meter, multi-layer perceptron

I. INTRODUCTION

Recently, load monitoring has been a significant key for the energy management system, especially in intelligent grid systems, for identity and controlling power consumption. Non-Intrusive Load Monitoring (NILM) is widely used to identify electrical appliances by recognizing load signatures.

The load signatures are the individual characteristic of the electrical appliance when it is functioning. The NILM extracted the load feature such as current harmonics [1], power harmonics [2, 3], and current waveforms [4, 5]. Many techniques used to extract the features, such as the wavelet transform [6], Color Encoding [7], V-I trajectory [8] and [9], was employed to extract the load signatures. However, these techniques provide recognition accuracy of about 80%. Moreover, intelligent methods are exploited to apply for NILM such as Adaptive Weighted Recurrence Graphs [10, 11]. Therefore the Artificial Neural Networks (ANN) is investigated to be the proposed technique in this experiment. The five different appliances are used to test this system.

II. METHODOLOGY

A. Kurtogram technique

Usually, the kurtogram is a spectral function to detect non-stationarities in a signal. It can be effectively used to determine feature extraction [12]. However, the effectiveness of the kurtogram operated in time-varying conditions. This article proposes a kurtogram technique for feature extraction and converting the current signal to image pattern.

B. Multi-layer perceptron

Multi-layer perceptron (MLP) is a feed-forward artificial neural network consisting of the input, hidden, and output layers as shown in Fig 1. The input layer gets the input signal processed, and the hidden layer typically operates as the computational process. The output layer is arranged for the prediction and classification class. MLPs are designed to solve any problem of non-linear function such as in pattern classification, recognition and prediction [13].




Fig. 1. Neural Network Algorithm

III. EXPERIMENT AND RESULTS

The experiment has four stages: 1) data collection, 2) data to kurtogram, 3) MLP and 4) output, as shown in Fig 2.




Fig. 2. Proposed MLP Algorithm for NILM

Five appliances have been set to be input, and then those current signals are sampled with a high sampling rate of FPGA. The kurtogram technique extracts the current feature and converts it to image patterns. Then the MLP is utilized for training and recognition of the image pattern for the NILM system [14], in Fig 3. This experiment used CPU core i7 and RAM 8.0 GB. The results of the experiment have described in the following section.




Fig. 3. FPGA System for Data Collection.

ประวัติผู้เขียน

ชื่อ-สกุล นายสรายุทธ์ แยมประยูร
วัน เดือน ปีเกิด วันที่ 31 เดือน พฤษภาคม พ.ศ. 2529
ที่อยู่ 50/1 หมู่ 1 ตำบลคลอง 7 อำเภอคลองหลวง ปทุมธานี 12120
การศึกษา - ปริญญาตรี วศ.บ. (วิศวกรรมไฟฟ้า - อิเล็กทรอนิกส์)
คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
- ปริญญาโท วศ.ม. (วิศวกรรมไฟฟ้า)
คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
เบอร์โทรศัพท์ 095-197-8962
อีเมล sarayut_y@mail.rmutt.ac.th

