

ระบบควบคุมเครื่องปรับอากาศสำหรับที่อยู่อาศัยโดยใช้ขอบข่ายงานการเรียนรู้ของเครื่องบนคลาวด์



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2564

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Cloud-based Machine Learning Framework for Residential Air Conditioning Control
System



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Electrical Engineering

Department of Electrical Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2021

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	ระบบควบคุมเครื่องปรับอากาศสำหรับที่อยู่อาศัยโดยใช้
	ขอบข่ายงานการเรียนรู้ของเครื่องบนคลาวด์
โดย	นายอรรถวุฒิ อิศระวิริยะกุล
สาขาวิชา	วิศวกรรมไฟฟ้า
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.วันเฉลิม โปรา

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.สุรีย์ พุ่มรินทร์)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(รองศาสตราจารย์ ดร.วันเฉลิม โปรา)

..... กรรมการภายนอกมหาวิทยาลัย
(รองศาสตราจารย์ ดร.เอกชัย ลีลารัมย์)

CHULALONGKORN UNIVERSITY

อรรถวุฒิ อิศระวีริยะกุล : ระบบควบคุมเครื่องปรับอากาศสำหรับที่อยู่อาศัยโดยใช้
 ขอบข่ายงานการเรียนรู้ของเครื่องบนคลาวด์. (Cloud-based Machine Learning
 Framework for Residential Air Conditioning Control System) อ.ที่ปรึกษาหลัก :
 รศ. ดร.วันเฉลิม โปธา

การทำนายพฤติกรรมผู้อยู่อาศัยเป็นหนึ่งในเทคโนโลยีที่มีบทบาทสำคัญสำหรับอาคาร
 อัจฉริยะ วิทยานิพนธ์ฉบับนี้เน้นการพัฒนากระบวนการควบคุมเครื่องปรับอากาศอัจฉริยะ เนื่องจาก
 เครื่องปรับอากาศเป็นเครื่องใช้ไฟฟ้าในอาคารที่กินพลังงานไฟฟ้าสูง และมีความเกี่ยวข้องกับ
 ความรู้สึกสบายของผู้อยู่อาศัยโดยตรง จากการศึกษางานวิจัยก่อนหน้า แบบจำลองทำนาย
 ความรู้สึกสบายเชิงความร้อนถูกสร้างจากข้อมูลที่เก็บโดยการตอบแบบสอบถาม จากนั้นผลลัพธ์
 ของแบบจำลองจะถูกใช้ในการควบคุมเครื่องปรับอากาศ การเปิดปิดเครื่องปรับอากาศใช้วิธีกำหนด
 ระยะเวลาจัด ระหว่างที่อยู่อาศัยกับผู้อยู่อาศัย ซึ่งเมื่อผู้อยู่อาศัยเข้าใกล้ที่อยู่อาศัยมากกว่ารัศมีที่
 กำหนด ระบบจะสั่งเปิดการทำงาน วิธีการที่กล่าวไปข้างต้นทั้งหมดมีปัญหาคือ หากผู้อยู่อาศัยไม่
 ป้อนข้อมูล แบบจำลองจะให้ผลลัพธ์ไม่ตรงกับความรู้สึกสบายเชิงความร้อนจริง และการกำหนด
 ระยะเวลารัศมี ไม่สามารถสะท้อนถึงพฤติกรรมที่เป็นกิจวัตร วิทยานิพนธ์ฉบับนี้จึงนำเสนอระบบควบคุม
 เครื่องปรับอากาศด้วยขอบข่ายงานการเรียนรู้ของเครื่องแบบปรับตัวได้ โดยใช้ข้อมูลสถานะ
 แวดล้อมที่เก็บค่าได้ ข้อมูลสภาพอากาศ และข้อมูลที่เกี่ยวข้องกับการเดินทางที่เป็นกิจวัตร ในการ
 สร้างแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย ซึ่งใช้ในการเปิดปิดเครื่องปรับอากาศโดย
 อัตโนมัติ และแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน ซึ่งใช้ในการปรับอุณหภูมิให้
 สอดคล้องกับความรู้สึกสบายผู้อยู่อาศัย ระบบที่พัฒนาขึ้นถูกประยุกต์ใช้บนคลาวด์ ทำให้สามารถ
 ลดภาระในการประมวลผลของอุปกรณ์ปลายทาง และสามารถพัฒนาเพิ่มเติมโดยปราศจาก
 ซิดจำกัดของอุปกรณ์ ระบบที่พัฒนาขึ้นสามารถควบคุมเครื่องปรับอากาศแบบเรียลไทม์ โดยการ
 ฝึกสอนแบบจำลองใหม่โดยอัตโนมัติทำให้การทำนายการมาถึงของผู้อยู่อาศัยล่วงหน้า 10 นาทีที่มี
 ความแม่นยำมากกว่า 90% และการจำแนกความรู้สึกสบายเชิงความร้อน มีค่าเรียกกลับของ
 ความรู้สึกสบายมากกว่า 80% ถึงแม้พฤติกรรมของผู้อยู่อาศัยเปลี่ยนแปลงไป

สาขาวิชา วิศวกรรมไฟฟ้า

ลายมือชื่อนิสิต

ปีการศึกษา 2564

ลายมือชื่อ อ.ที่ปรึกษาหลัก

6270363721 : MAJOR ELECTRICAL ENGINEERING

KEYWORD: Occupant behavior prediction, Smart buildings, HVAC control system, Thermal comfort

Atthawut Issaraviriyakul : Cloud-based Machine Learning Framework for Residential Air Conditioning Control System. Advisor: Assoc. Prof. WANCHALERM PORA, Ph.D.

Occupant behavior prediction has become a significant part of smart building technologies. This research focuses on residential air conditioning control as its operation is crucial in both energy consumption and user comfort. In previous research, thermal comfort classification is developed using the filled questionnaires. The prediction output is employed to control the air-conditioning system. On/Off control is developed using rule-based distance triggering that turns on/off the system when occupants enter/exit a specific perimeter. This research proposes HVAC control system with an adaptive cloud machine learning framework that utilizes room ambient condition, weather condition and travel behavior to create occupancy prediction model which is used to activate or deactivate air-conditioner automatically and thermal comfort classification model which is used for temperature adjustment. This research deployed a backend system on a cloud that can solve problems in processing power and storage of an end device, also provide scalability for future development. Findings show that models which are retrained constantly can automatically control the air-conditioner in real-time. Even when the occupant's behavior changes, these models can gradually adapt and maintain accuracy above 95% for the future 10 minutes occupancy prediction and recall above 80% for the thermal comfort classification.

Field of Study: Electrical Engineering

Student's Signature

Academic Year: 2021

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สามารถสำเร็จลุล่วงไปด้วยดี เนื่องจากได้รับความช่วยเหลือเป็นอย่างสูงจาก รศ. ดร. วันเฉลิม โปรา ซึ่งเป็นอาจารย์ที่ปรึกษาวิทยานิพนธ์ ข้าพเจ้าขอขอบพระคุณเป็นอย่างสูงที่กรุณาให้ความช่วยเหลือด้วยความเอาใจใส่อย่างดียิ่ง คอยเป็นแรงผลักดัน สนับสนุน รวมถึงให้คำแนะนำ ข้อคิดเห็น ทั้งในด้านวิชาการ งานวิจัย ความรู้ และอื่น ๆ อีกมาก

ขอขอบพระคุณ ผศ. ดร. สุรีย์ พุ่มรินทร์ และ รศ. ดร. เอกชัย ลีสารศรี เป็นอย่างสูงที่ให้เกียรติมาเป็นกรรมการวิทยานิพนธ์ รวมถึงการแสดงความคิดเห็น ตรวจสอบ และแก้ไขให้วิทยานิพนธ์ฉบับนี้ให้สำเร็จลุล่วงไปด้วยดี

ขอบพระคุณเหล่าคณาจารย์ ทั้งจากภาควิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมเครื่องกล และภาควิชาวิศวกรรมคอมพิวเตอร์ คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัยทุกท่าน ที่เป็นผู้ประสาขาวิชา ให้ความรู้ คำแนะนำ ให้การสนับสนุนแก่ข้าพเจ้าได้พัฒนาศักยภาพตนเองในหลาย ๆ ด้าน ขอบพระคุณบุคลากรและเจ้าหน้าที่ประจำภาควิชาวิศวกรรมไฟฟ้าทุกท่านที่คอยให้ความช่วยเหลือที่ดีตลอดมา และขอขอบคุณเหล่านิสิต เพื่อนพี่น้องในห้องปฏิบัติการ Embedded System and IC Design Research Laboratory (ESID) ทุกคนที่คอยสนับสนุน ให้ความช่วยเหลือ มุมมอง ความรู้ใหม่ๆ รวมถึงแลกเปลี่ยนประสบการณ์ที่ดีต่อกัน

สุดท้ายนี้ ข้าพเจ้าขอกราบขอบพระคุณบิดา มารดา ครอบครัว เป็นอย่างสูง ที่คอยให้ความช่วยเหลือคำจุน สนับสนุนส่งเสริม เช้าอกเข้าใจ และเป็นกำลังใจที่ดีแก่ข้าพเจ้าตลอดมาจนวิทยานิพนธ์สำเร็จลุล่วงไปได้ด้วยดี

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

อรรณวุฒิ อิศระวิริยะกุล

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ	ง
กิตติกรรมประกาศ	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฉ
สารบัญรูปภาพ.....	ฉ
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์	3
1.3 ขอบเขตของงานวิจัย.....	3
1.4 ขั้นตอนและวิธีการดำเนินงาน.....	4
1.5 ประโยชน์ที่คาดว่าจะได้รับจากวิทยานิพนธ์	5
1.6 โครงสร้างของวิทยานิพนธ์	6
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	7
2.1 สถาปัตยกรรมอินเทอร์เน็ตของสรรพสิ่งในอาคารอัจฉริยะ	7
2.2 การปรับอุณหภูมิของเครื่องปรับอากาศ.....	9
2.2.1 พารามิเตอร์ที่มีความเกี่ยวข้องกับสภาวะทางความร้อนภายในตัวอาคาร	9
2.2.2 ความรู้สึกสบายเชิงความร้อน.....	10
2.3 การเรียนรู้ของเครื่องแบบมีผู้สอน	11

2.3.1 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine; SVM).....	12
2.3.2 การถดถอยที่เป็นลำดับ (Ordinal Regression).....	14
2.3.3 โครงข่ายประสาทเทียม (Artificial Neural Network).....	15
2.3.5 การตรวจสอบความถูกต้อง (Cross Validation).....	17
2.3.6 การประเมินการแบ่งกลุ่ม (Classification Assessment).....	18
2.3.6.1 ค่าความแม่นยำ (Accuracy).....	19
2.3.6.2 ค่าการเรียกกลับ (Recall).....	20
2.3.6.3 ค่าความเที่ยงตรง (Precision).....	20
2.3.7 การเรียนรู้แบบจำลองทางความร้อนด้วยข้อมูลจากอินเทอร์เน็ตของสรรพสิ่ง.....	20
2.3.8 การใช้แบบจำลองโครงข่ายประสาทในการทำนายความรู้สึกทางความร้อน.....	21
2.4 การใช้บริการบอกตำแหน่ง.....	22
2.4.1 การคำนวณระยะกระจัดระหว่าง 2 พิกัด.....	22
2.4.2 การใช้รังสีวิทยาศาสตร์กับโปรแกรมประยุกต์บนโทรศัพท์มือถือ.....	23
2.5 การรับส่งข้อมูล.....	23
2.5.1 โพรโทคอล HTTP.....	23
2.5.2 สถาปัตยกรรม REST.....	24
2.6 การพัฒนาซอฟต์แวร์.....	25
2.6.1 สถาปัตยกรรมไมโครเซอร์วิส.....	25
2.6.2 ภาษาและแพลตฟอร์มที่ใช้ในการพัฒนา.....	26
บทที่ 3 สถาปัตยกรรมระบบควบคุมเครื่องปรับอากาศอัจฉริยะ.....	28
3.1 อุปกรณ์ปลายทาง (End Device).....	28
3.1.1 ไมโครคอนโทรลเลอร์ (Microcontroller).....	29
3.1.2 ตัวรับรู้ (Sensor).....	29
3.1.3 อุปกรณ์ทำงาน (Actuator).....	30

3.1.4 การพัฒนาซอฟต์แวร์ควบคุมอุปกรณ์ปลายทาง	30
3.2 ฐานข้อมูลแบบเรียลไทม์ (Real-time Database; RTDB).....	31
3.3 โปรแกรมประยุกต์บนโทรศัพท์มือถือ (Mobile Application)	32
3.4 คลาวด์ฟังก์ชัน (Cloud Function)	33
3.5 ฐานข้อมูลไฟร์สตอร์ (Firestore Database).....	34
3.6 ขอบข่ายงานการเรียนรู้ของเครื่อง (Machine Learning Framework).....	35
3.6.1 API การทำนายด้วยโมเดลการเรียนรู้ของเครื่อง.....	36
3.6.2 การรีเทรนแบบจำลอง (Model Retrain)	36
บทที่ 4 แบบจำลองการเรียนรู้ของเครื่อง	38
4.1 แบบจำลองการทำนายการมาถึงของผู้โดยสาร.....	39
4.1.1 พารามิเตอร์ของแบบจำลอง.....	39
4.1.2 การเตรียมข้อมูล.....	40
4.1.3 การแบ่งชุดข้อมูล.....	41
4.1.4 การฝึกสอนแบบจำลอง.....	41
4.1.5 การตรวจสอบแบบจำลอง.....	41
4.1.6 การประเมินแบบจำลอง	42
4.2 แบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน	43
4.2.1 พารามิเตอร์ของแบบจำลอง.....	43
4.2.2 การเตรียมข้อมูล.....	44
4.2.3 การแบ่งชุดข้อมูล.....	44
4.2.4 การฝึกสอนแบบจำลอง.....	44
4.2.5 การตรวจสอบแบบจำลอง.....	45
4.2.6 การประเมินแบบจำลอง	46
บทที่ 5 การประยุกต์ใช้แบบจำลองกับระบบควบคุมเครื่องปรับอากาศอัจฉริยะ.....	47

5.1 การบันทึกข้อมูลลงในที่เก็บข้อมูลบนคลาวด์	47
5.1.1 แบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย	48
5.1.2 สเกลเลอร์ของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย	48
5.1.3 แบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน	48
5.1.4 สเกลเลอร์ของแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน	48
5.1.5 ข้อมูลที่ใช้ในการฝึกสอนแบบจำลองใหม่	48
5.2 การปรับปรุงแบบจำลองตามพฤติกรรมของผู้อยู่อาศัย	49
5.3 การควบคุมเครื่องปรับอากาศโดยใช้ผลการทำนายของแบบจำลอง	50
บทที่ 6 ผลการทดลองและการอภิปรายผล	53
6.1 การสื่อสารระหว่างอุปกรณ์ปลายทางกับ RTDB	53
6.1.1 การส่งข้อมูลจาก RTDB ไปยังอุปกรณ์ปลายทาง	53
6.1.2 การส่งข้อมูลจากอุปกรณ์ปลายทางไปยัง RTDB	54
6.2 ประสิทธิภาพของแบบจำลอง	54
6.2.1 ประสิทธิภาพของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย	54
6.2.2 ประสิทธิภาพของแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย	56
6.3 ประสิทธิภาพของแบบจำลองหลังฝึกสอนใหม่	58
6.3.1 ประสิทธิภาพของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัยหลังฝึกสอนใหม่	58
6.3.2 ประสิทธิภาพของแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนหลังฝึกสอนใหม่	59
บทที่ 7 สรุปผลงานวิจัยและข้อเสนอแนะ	60
7.1 สรุปงานวิจัย	60
7.2 ข้อเสนอแนะและแนวทางในการพัฒนาต่อ	61
บรรณานุกรม	63
ประวัติผู้เขียน	66



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญตาราง

	หน้า
ตารางที่ 1 กรอบเวลาของขั้นตอนการดำเนินงาน	5
ตารางที่ 2 ระดับความรู้สึกเชิงความร้อน (Thermal Sensation Scale).....	10
ตารางที่ 3 แสดงชุดของไฮเปอร์พารามิเตอร์ของแบบจำลองที่ทำการตรวจสอบ.....	42
ตารางที่ 4 ชุดโคดแสดงการทำงานของอัลกอริทึมการระบุความรู้สึกสบายเชิงความร้อน.....	43
ตารางที่ 5 แสดงความแม่นยำของแบบจำลองบนข้อมูลชุดทดสอบระยะเวลา 1 เดือน	54
ตารางที่ 6 ตารางแสดงผลการจำแนกความรู้สึกสบายเชิงความร้อน	56
ตารางที่ 7 แสดงความแม่นยำของการทำนายล่วงหน้า 10 นาที	58
ตารางที่ 8 แสดงการเปรียบเทียบค่าเรียกกลับของการจำแนกว่า “พอดี”	59

สารบัญรูปภาพ

	หน้า
รูปที่ 1 ตลาดอินเทอร์เน็ตของสรรพสิ่ง (IoT) ตั้งแต่ปี 2018 ถึง 2033	1
รูปที่ 2 สถาปัตยกรรมอินเทอร์เน็ตของสรรพสิ่งในอาคารอัจฉริยะ	8
รูปที่ 3 กราฟแสดงความสัมพันธ์ระหว่าง PMV และ PPD	11
รูปที่ 4 การจำแนกข้อมูลออกเป็น 2 กลุ่มด้วยไฮเปอร์เพลน	12
รูปที่ 5 การจำแนกข้อมูลด้วย SVC	13
รูปที่ 6 การเพิ่มมิติของข้อมูลโดยการใช้ฟังก์ชันเคอร์เนล	13
รูปที่ 7 การเปรียบเทียบระหว่างการถดถอยที่เป็นลำดับกับอัลกอริทึมแบบอื่นๆ	14
รูปที่ 8 เซลล์ประสาทเทียม (Perceptron)	15
รูปที่ 9 โครงข่ายประสาทเทียม	15
รูปที่ 10 กราฟแสดงการลดลงของค่าความสูญเสียในแต่ละการปรับค่าถ่วงน้ำหนัก	16
รูปที่ 11 กระบวนการ Forward และ Backward Propagation	17
รูปที่ 12 กระบวนการครอสวาไลเดชัน	17
รูปที่ 13 สร้างแบบจำลองโดยใช้ครอสวาไลเดชันในการประเมิน	18
รูปที่ 14 แผนภาพแสดงความถูกต้องของการแบ่งกลุ่ม	19
รูปที่ 15 โครงสร้างของโครงข่ายประสาทที่ใช้ทำนายความรู้สึกเชิงความร้อน	22
รูปที่ 16 การสื่อสารด้วย HTTP ระหว่างไคลเอนต์กับเซิร์ฟเวอร์	24
รูปที่ 17 ไมโครเซอร์วิสภายในบ้านอัจฉริยะ	26
รูปที่ 18 ภาษาและแพลตฟอร์มที่ใช้ในการพัฒนา	27
รูปที่ 19 สถาปัตยกรรมของระบบปรับอากาศอัจฉริยะ	28
รูปที่ 20 แผนภาพองค์ประกอบย่อยของอุปกรณ์ปลายทาง	29
รูปที่ 21 ภาระงานของอุปกรณ์ปลายทาง	30

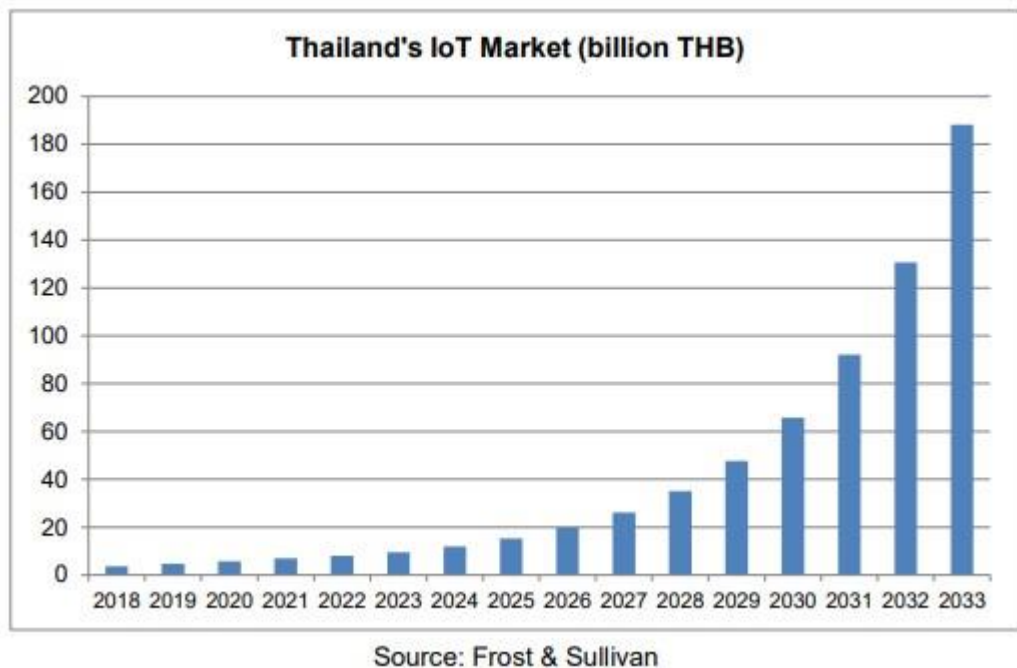
รูปที่ 22 การรับส่งข้อมูลระหว่าง RTDB กับอุปกรณ์อื่นๆ.....	32
รูปที่ 23 อินเตอร์เฟซของโปรแกรมประยุกต์บนโทรศัพท์มือถือ	33
รูปที่ 24 รูปแบบการจัดเก็บข้อมูลของฐานข้อมูล Firestore.....	34
รูปที่ 25 การรวบรวมข้อมูลลงในระเบียบที่มีดัชนีเป็นตัวชี้เวลา	35
รูปที่ 26 การทำงานของแบบจำลองที่ถูกสร้างเป็นไมโครเซอร์วิสภายในคอนเทนเนอร์	37
รูปที่ 27 กระบวนการการเรียนรู้ของเครื่อง.....	38
รูปที่ 28 หน้าต่างเลื่อนของพารามิเตอร์ในแต่ละช่วงเวลา	40
รูปที่ 29 แผนภูมิแสดงความน่าจะเป็นของชุดทดสอบ	45
รูปที่ 30 แผนภูมิแสดงความน่าจะเป็นของข้อมูลกลุ่ม “พอดี”	46
รูปที่ 31 การบันทึกข้อมูลลงในที่เก็บข้อมูลบนคลาวด์.....	47
รูปที่ 32 การสั่งการเมื่อมีการบันทึกข้อมูลล่าสุดในที่เก็บข้อมูลบนคลาวด์	49
รูปที่ 33 การปรับปรุงแบบจำลองตามพฤติกรรมของผู้ใช้อาศัย.....	49
รูปที่ 34 เมนูการตั้งค่าการเปิดใช้งานแบบจำลอง	50
รูปที่ 35 การควบคุมเครื่องปรับอากาศโดยใช้ผลการทำนายของแบบจำลอง	51
รูปที่ 36 การทดสอบการสื่อสารระหว่างอุปกรณ์ปลายทางกับ RTDB.....	53
รูปที่ 37 กราฟแสดงระยะการจัดจริง และการทำนายที่ถูกต้องของแบบจำลอง	55
รูปที่ 38 กราฟแสดงระยะการจัดจริง และการทำนายพลาดของแบบจำลอง.....	56
รูปที่ 39 แผนภูมิแสดงความน่าจะเป็นของข้อมูลใหม่จำนวน 6 สัปดาห์	57

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ปัจจุบัน ความก้าวหน้าของเทคโนโลยีการผลิตทำให้อุปกรณ์อิเล็กทรอนิกส์ที่สามารถเชื่อมต่อเครือข่ายอินเทอร์เน็ตมีประสิทธิภาพดีขึ้น และมีราคาถูกลง ส่งผลให้เกิดการประยุกต์ใช้ในทุกภาคส่วน ไม่ใช่เพียงภาคอุตสาหกรรม แต่รวมถึงภาคครัวเรือนอีกด้วย จากสถิติที่สำนักงานส่งเสริมเศรษฐกิจดิจิทัล (DEPA) พัฒนาร่วมกับบริษัทฟรอสต์ แอนด์ ซัลลิวัล [1] ในปีพ.ศ. 2562 มีการคาดการณ์ว่า ตลาดอินเทอร์เน็ตของสรรพสิ่ง (IoT) จะมีอัตราการเติบโตของพอร์ตเฉลี่ยต่อปีแบบทบต้น (Compound Annual Growth Rate - CAGR) อยู่ที่ 30.18% จากปี 2018 ถึงปี 2033 และระหว่างปี 2018 ถึง 2023 คาดว่าจะเติบโตจาก 3,600 ล้านบาท เป็น 9,500 ล้านบาทด้วยอัตราการเติบโตที่ 21.47% และยังคงคาดว่าจะขยายตัวถึง 188,200 ล้านบาทในปี 2033 ตามกราฟในรูปที่ 1



รูปที่ 1 ตลาดอินเทอร์เน็ตของสรรพสิ่ง (IoT) ตั้งแต่ปี 2018 ถึง 2033

การพัฒนาของอุปกรณ์อิเล็กทรอนิกส์ที่ก้าวไปข้างหน้าทำให้เกิดแนวคิดของบ้านอัจฉริยะ ที่ระบบเครื่องใช้ไฟฟ้าได้รับการออกแบบเพื่อใช้งานตามวัตถุประสงค์ต่างๆได้อย่างอัตโนมัติ และสามารถรับส่งข้อมูลซึ่งกันและกัน โดยปราศจากการแทรกแซงของมนุษย์ แต่การที่ระบบดังกล่าวจะสามารถทำงานได้อย่างมีประสิทธิภาพ จะต้องมีความชาญฉลาด ซึ่งเกิดจากการรู้จำพฤติกรรมของผู้

อยู่อาศัย วิทยานิพนธ์นี้เลือกพัฒนาระบบควบคุมอย่างชาญฉลาดสำหรับเครื่องปรับอากาศภายในบ้าน เนื่องจาก เครื่องปรับอากาศเป็นเครื่องใช้ไฟฟ้าภายในบ้านที่มีความเกี่ยวข้องโดยตรงกับความสบายของผู้อยู่อาศัย และจาก [2] 56% ของการใช้พลังงานภายในอาคารในแถบประเทศในเขตร้อนชื้น มาจากระบบปรับอากาศ

วิทยานิพนธ์ฉบับนี้มุ่งเน้นไปที่การปรับเครื่องปรับอากาศโดยใช้ผู้อยู่อาศัยเป็นศูนย์กลาง จาก การศึกษางานวิจัยในปัจจุบันและผลิตภัณฑ์ที่มีในท้องตลาดพบว่า สำหรับการเปิดเครื่องปรับอากาศ ก่อนผู้อยู่อาศัยจะเข้ามาในบ้าน มีการใช้ระบบจีพีเอส (GPS) ของโทรศัพท์มือถือเพื่อบอกว่าผู้อยู่อาศัย เข้ามาในรัศมี (Geo-Fencing) ที่จะทำการเปิดเครื่องปรับอากาศหรือไม่ และการปรับอุณหภูมิให้ สอดคล้องกับความต้องการของผู้อยู่อาศัย มีการสำรวจข้อมูลโดยใช้แบบสอบถามอิเล็กทรอนิกส์ใน โปรแกรมประยุกต์ ว่าผู้อยู่อาศัยมีความรู้สึกอย่างไรกับสภาวะปัจจุบันในห้องนั้น ได้แก่ ร้อนไป หนาว ไป หรือกำลังพอดี เพื่อใช้ข้อมูลเหล่านั้นในการสร้างแบบจำลองในการทำนายความรู้สึกสบายเชิง ความร้อน

วิทยานิพนธ์ฉบับนี้เล็งเห็นถึงความสำคัญของพฤติกรรมที่เป็นกิจวัตร เนื่องจากในบางกรณี การเข้ามาในรัศมีที่ระบบจะทำงาน ผู้อยู่อาศัยอาจไม่มีความประสงค์ที่จะเปิดเครื่องปรับอากาศ เนื่องจากยังไม่ถึงเวลาที่กลับที่อยู่อาศัย จึงมีความจำเป็นต้องนำพฤติกรรมการเข้าออกบ้านใน เวลาต่าง ๆ มาใช้วิเคราะห์ควบคู่กับข้อมูลจากบริการบอกตำแหน่ง เพื่อสร้างแบบจำลองในการทำ การทำนายการเข้าออกห้องของผู้อยู่อาศัยที่มีประสิทธิภาพสูงขึ้น อีกทั้งในส่วนของการจำแนกความรู้สึก สบายเชิงความร้อน (Thermal Comfort) ของผู้อยู่อาศัย วิทยานิพนธ์ฉบับนี้ได้นำข้อมูลการปรับ อุณหภูมิเครื่องปรับอากาศในช่วงแรกของผู้อยู่อาศัยควบคู่กับข้อมูลสภาวะของสภาพแวดล้อม วิธี ดังกล่าวจะเพิ่มความสะดวกให้แก่ผู้อยู่อาศัย เนื่องจากข้อมูลจะถูกเก็บจากพฤติกรรมการใช้งานอยู่ แล้ว ไม่จำเป็นต้องระบุข้อมูลให้แก่ระบบ อีกทั้งในกรณีที่ผู้อยู่อาศัยมีความรู้สึกสบายทางความร้อนที่ เปลี่ยนไป ระบบจะค่อยๆทำการปรับให้สอดคล้องกับความต้องการของผู้อยู่อาศัยอีกด้วย

ระบบที่พัฒนาขึ้นถูกประยุกต์ใช้ในอุปกรณ์ที่มีราคาไม่สูง และไม่มี ความจำเป็นต้องดัดแปลง เครื่องปรับอากาศในการติดตั้ง อีกทั้งระบบประมวลผลและระบบฐานข้อมูลถูกติดตั้งบนคลาวด์ซึ่งเพิ่ม ความยืดหยุ่นในการขยาย และลดความยุ่งยากในการบำรุงรักษา

1.2 วัตถุประสงค์

- 1.2.1 พัฒนาระบบที่เปิดปิดและปรับอุณหภูมิเครื่องปรับอากาศโดยอัตโนมัติ ให้สอดคล้องกับพฤติกรรมการเดินทาง และความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย
- 1.2.2 พัฒนาแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัยเพื่อเปิดเครื่องปรับอากาศ โดยต้องปรับปรุงตัวเองตามพฤติกรรมการเดินทางของผู้อยู่อาศัยได้
- 1.2.3 พัฒนาแบบจำลองการทำนายการปิดเครื่องปรับอากาศเมื่อผู้อยู่อาศัยไม่กลับมาในห้องอีกภายในเวลา 30 นาทีในอนาคต
- 1.2.4 พัฒนาแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย โดยต้องปรับปรุงตัวเองตามความรู้สึกสบายเชิงความร้อนที่เปลี่ยนแปลงไปของผู้อยู่อาศัยได้
- 1.2.5 พัฒนาโปรแกรมประยุกต์ (Application) บนโทรศัพท์มือถือที่สามารถสั่งงานเครื่องปรับอากาศ และส่งข้อมูลระบุพิกัดปัจจุบันไปบันทึกในฐานข้อมูล

1.3 ขอบเขตของงานวิจัย

- 1.3.1 สร้างต้นแบบอุปกรณ์ปลายทาง จากบอร์ดพัฒนา ESP32 (ESP32 Development Board) ในการสั่งงานตัวเปล่งแสงอินฟราเรด (IR Emitter) เพื่อควบคุมเครื่องปรับอากาศ และเก็บข้อมูลสถานะแวดล้อมโดยตัวรับรู้ (sensor) และส่งค่าไปเก็บในฐานข้อมูลผ่านสัญญาณวิทยุ (Wi-Fi) ข้อมูลสถานะแวดล้อมที่เก็บค่าประกอบไปด้วย
 1. อุณหภูมิภายในห้อง
 2. ปริมาณก๊าซคาร์บอนไดออกไซด์
 3. ความชื้นสัมพัทธ์
- 1.3.2 สร้างระบบฐานข้อมูลบนคลาวด์สำหรับ
 1. เก็บข้อมูลสถานะแวดล้อมจากตัวรับรู้
 2. เก็บพิกัดบนพื้นโลกปัจจุบันของผู้อยู่อาศัยจากบริการบอกตำแหน่งของโทรศัพท์มือถือ
 3. เก็บพิกัดทางภูมิศาสตร์ของบ้านผู้อยู่อาศัย
 4. เก็บข้อมูลสภาพอากาศภายนอกบ้านจากบริการข้อมูลสภาพอากาศ
- 1.3.3 สร้างต้นแบบโปรแกรมประยุกต์บนโทรศัพท์มือถือที่
 1. ผู้อยู่อาศัยสามารถควบคุมเครื่องปรับอากาศได้โดยตรง
 2. ผู้อยู่อาศัยสามารถเปลี่ยนโหมดเป็นโหมดอัตโนมัติ

3. ผู้อยู่อาศัยสามารถตั้งค่าตำแหน่งของบ้าน เพื่อเริ่มการใช้งาน

4. โทรศัพท์มือถือสามารถส่งข้อมูลพิกัด ในปัจจุบันไปยังฐานข้อมูลได้

1.3.4 สร้างแบบจำลองการเรียนรู้ของเครื่องเพื่อทำนายการมาถึงของผู้อยู่อาศัยเพื่อเปิดเครื่องปรับอากาศล่วงหน้าด้วยความแม่นยำ (accuracy) มากกว่า 90% และสามารถเปิดเครื่องปรับอากาศได้ผ่าน API (Application Programming Interface) โดยแบบจำลองสามารถปรับปรุงตัวเองตามพฤติกรรมการเดินทางของผู้อยู่อาศัยได้

1.3.5 สร้างแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย ที่ค่าเรียกกลับ (Recall) มากกว่า 80% และสามารถปรับอุณหภูมิเครื่องปรับอากาศได้ผ่าน API (Application Programming Interface) โดยแบบจำลองสามารถปรับปรุงตัวเองตามความรู้สึกสบายเชิงความร้อนที่เปลี่ยนแปลงไปของผู้อยู่อาศัยได้

1.3.6 สร้างแบบจำลองการปิดเครื่องปรับอากาศเมื่อผู้อยู่อาศัยออกจากห้องและไม่กลับมาในห้องอีกภายในระยะเวลา 30 นาทีในอนาคต โดยแบบจำลองที่ได้มีความแม่นยำ 80% ขึ้นไป และสามารถปิดเครื่องปรับอากาศได้ผ่าน API (Application Programming Interface) โดยแบบจำลองสามารถปรับปรุงตัวเองตามพฤติกรรมการออกจากห้องของผู้อยู่อาศัยได้

1.4 ขั้นตอนและวิธีการดำเนินงาน

1.4.1 ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์

1.4.2 วิเคราะห์พารามิเตอร์ที่เกี่ยวข้องกับพฤติกรรมการเข้าออก และความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย เพื่อออกแบบวิธีการเก็บข้อมูล

1.4.3 สร้างต้นแบบอุปกรณ์ปลายทาง

1.4.4 สร้างระบบฐานข้อมูล และระบบส่วนหลังที่ใช้ในการควบคุมระบบฐานข้อมูล

1.4.5 สร้างต้นแบบโปรแกรมประยุกต์บนโทรศัพท์มือถือ

1.4.6 พัฒนาการสื่อสารระหว่างองค์ประกอบต่างๆของระบบ

1.4.7 นำข้อมูลที่เก็บได้จากระบบฐานข้อมูลมาสร้างแบบจำลองการทำนาย

1.4.8 นำแบบจำลองมาทำนายเพื่อทดสอบประสิทธิภาพ

1.4.9 พัฒนาซอฟต์แวร์เพื่อรองรับการเรียกใช้งานแบบจำลอง

1.4.10 เขียนรายงานและวิทยานิพนธ์

1.4.11 ทดสอบการทำงานของแบบจำลองด้วยข้อมูลใหม่

1.4.12 สรุปและวิเคราะห์ประสิทธิภาพแบบจำลองเพื่อปรับปรุงแก้ไข

1.4.13 แผนพรวิทยานิพนธ์

ขั้นตอนการดำเนินงานที่ได้กล่าวไปข้างต้นมีกรอบเวลาดังแต่เริ่มต้น จนถึงสิ้นสุดตามแผนที่ได้วางไว้ ดังตารางที่ 1

ตารางที่ 1 กรอบเวลาของขั้นตอนการดำเนินงาน

ขั้นตอนการดำเนินงาน	2020										2022
	4	5	6	7	8	9	10	11	12	1	
1.4.1	■	■									
1.4.2		■									
1.4.3		■	■								
1.4.4			■	■							
1.4.5			■	■							
1.4.6				■	■						
1.4.7						■					
1.4.8						■					
1.4.9						■					
1.4.10						■	■	■	■		
1.4.11						■	■	■			
1.4.12									■		
1.4.13										■	

1.5 ประโยชน์ที่คาดว่าจะได้รับจากวิทยานิพนธ์

- 1.5.1 ได้แบบจำลองในการทำนายการมาถึงของผู้อยู่อาศัยเพื่อทำการเปิดเครื่องปรับอากาศ
- 1.5.2 ได้แบบจำลองการทำนายความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย
- 1.5.3 ได้แบบจำลองการทำนายการปิดเครื่องปรับอากาศเมื่อผู้อยู่อาศัยออกจากห้องโดยไม่กลับมาภายในระยะเวลา 30 นาทีในอนาคต
- 1.5.4 สามารถนำแบบจำลองมาประยุกต์ใช้กับระบบควบคุมเครื่องปรับอากาศอัจฉริยะ
- 1.5.5 ผู้อยู่อาศัยใหม่สามารถนำระบบที่สร้างขึ้นไปใช้งาน โดยประสิทธิภาพของระบบถูกปรับปรุงอย่างสม่ำเสมอ

1.6 โครงสร้างของวิทยานิพนธ์

บทที่ 1 บทนำ กล่าวถึงที่มาและความสำคัญของปัญหา วัตถุประสงค์ ขอบเขตของงานวิจัย ขั้นตอนและวิธีการดำเนินงาน ประโยชน์ที่คาดว่าจะได้รับจากวิทยานิพนธ์ รวมไปถึงโครงสร้างของวิทยานิพนธ์

บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง กล่าวถึงเนื้อหาที่ใช้เป็นความรู้พื้นฐานและใช้ในการอ้างอิง เกี่ยวข้องกับสถาปัตยกรรมอินเทอร์เน็ตของสรรพสิ่ง การปรับอุณหภูมิของเครื่องปรับอากาศ การเรียนรู้ของเครื่องแบบมีผู้สอน การใช้บริการบอกตำแหน่งของโทรศัพท์มือถือ การสื่อสารข้อมูล และการพัฒนาซอฟต์แวร์

บทที่ 3 สถาปัตยกรรมระบบปรับอากาศอัจฉริยะ กล่าวถึงการออกแบบสถาปัตยกรรมที่ใช้ในวิทยานิพนธ์ฉบับนี้ ตั้งแต่อุปกรณ์ปลายทาง ระบบฐานข้อมูล โปรแกรมประยุกต์บนโทรศัพท์มือถือ จนถึงการประยุกต์ใช้แบบจำลองการเรียนรู้ของเครื่องบนขอบข่ายงานการเรียนรู้ของเครื่อง เพื่อควบคุมเครื่องปรับอากาศอย่างอัตโนมัติ

บทที่ 4 แบบจำลองการเรียนรู้ของเครื่อง กล่าวถึงการสร้างแบบจำลอง ตั้งแต่การวิเคราะห์พารามิเตอร์ที่เกี่ยวข้อง การเตรียมข้อมูล จนถึงการเลือกใช้แบบจำลอง

บทที่ 5 การประยุกต์ใช้แบบจำลองกับระบบควบคุมเครื่องปรับอากาศอัจฉริยะ กล่าวถึงการนำแบบจำลองการเรียนรู้ของเครื่องที่กล่าวถึงในบทที่ 4 มาใช้งานจริงบนสถาปัตยกรรมระบบปรับอากาศอัจฉริยะที่กล่าวถึงในบทที่ 3

บทที่ 6 ผลการทดลองและอภิปรายผล กล่าวถึงผลการทดลองการสื่อสารระหว่างอุปกรณ์ปลายทางกับฐานข้อมูลแบบเรียลไทม์ (Real-time Database; RTDB) ผลการทดสอบประสิทธิภาพของแบบจำลอง และผลการทดสอบประสิทธิภาพของแบบจำลองหลักฝึกสอนใหม่

บทที่ 7 สรุปผลงานวิจัยและข้อเสนอแนะ กล่าวถึงข้อสรุปที่ได้จากการทดลองว่าสามารถตอบโจทย์วัตถุประสงค์ในด้านใดบ้าง และกล่าวถึงข้อเสนอแนะและแนวทางในการพัฒนาต่อ

บทที่ 2


ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ทฤษฎีและงานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์ฉบับนี้สามารถแบ่งได้เป็น 4 หัวข้อ คือ 1.) สถาปัตยกรรมอินเทอร์เน็ตของสรรพสิ่งในอาคารอัจฉริยะ 2.) การปรับอุณหภูมิของเครื่องปรับอากาศ 3.) การเรียนรู้ของเครื่องแบบมีผู้สอน 4.) การใช้บริการบอกตำแหน่ง 5.) การรับส่งข้อมูล 6.) การพัฒนาซอฟต์แวร์

2.1 สถาปัตยกรรมอินเทอร์เน็ตของสรรพสิ่งในอาคารอัจฉริยะ

บทความที่ [3] เสนอการแบ่งสถาปัตยกรรมอินเทอร์เน็ตของสรรพสิ่งในอาคารอัจฉริยะเป็น 6 ชั้น (Layer) ดังแสดงในรูปที่ 2 โดยมีรายละเอียดดังต่อไปนี้

- 1.) ชั้นรับรู้ (Sensing Layer) เป็นชั้นล่างสุดของระบบ ทำหน้าที่รับค่าทางกายภาพ ได้แก่ เก็บข้อมูลพฤติกรรมของผู้อยู่อาศัย ตรวจสอบความผิดปกติ นอกจากรับค่าแล้วยังสามารถส่งสัญญาณควบคุมอุปกรณ์ทำงาน (Actuator) เพื่อปฏิสัมพันธ์กับสภาพแวดล้อม
- 2.) ชั้นเครือข่าย (Network Layer) เป็นชั้นของการสื่อสาร ทำหน้าที่เป็นสื่อกลางในการส่งข้อมูลระหว่างชั้นการรับรู้กับชั้นที่สูงขึ้นไป เช่น GSM, GPRS, Ethernet, WLAN, WPAN เป็นต้น
- 3.) ชั้นซอฟต์แวร์สื่อกลาง (Middleware Layer) เป็นโพรโทคอลมาตรฐานที่ใช้เป็นสะพานเชื่อมระหว่างระบบสมองกลฝังตัว (Embedded System) ในชั้นการรับรู้กับระบบส่วนหลัง (Backend) ผ่านชั้นเครือข่าย
- 4.) ชั้นแปลความข้อมูล (Context and Semantic discovery Layer) มีหน้าที่นำข้อมูลที่ซับซ้อนมาจัดระเบียบภายใต้โครงสร้าง ทำให้สามารถจัดเก็บ สืบค้น และใช้งานข้อมูลได้อย่างเป็นระบบ
- 5.) ชั้นประมวลผลข้อมูล (Context Processing and Reasoning Layer) ทำหน้าที่สังเคราะห์ความรู้ จากข้อมูลเพื่อใช้ในการตัดสินใจ
- 6.) ชั้นประยุกต์ (Application Layer) ทำหน้าที่ให้บริการผ่านซอฟต์แวร์ประยุกต์ โดยมีช่องทาง (Interface) ที่รองรับการปฏิสัมพันธ์ระหว่างระบบกับผู้อยู่อาศัย



รูปที่ 2 สถาปัตยกรรมอินเทอร์เน็ตของสรรพสิ่งในอาคารอัจฉริยะ

ที่มา [3]

2.2 การปรับอุณหภูมิของเครื่องปรับอากาศ

เนื้อหาในส่วนนี้จะกล่าวถึงปัจจัยและทฤษฎีที่มีความเกี่ยวข้องกับการเปลี่ยนแปลงของอุณหภูมิของสภาวะแวดล้อม และความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย

2.2.1 พารามิเตอร์ที่มีความเกี่ยวข้องกับสภาวะทางความร้อนภายในตัวอาคาร

งานวิจัย [4] ได้เสนอวิธีการคำนวณอุณหภูมิในอนาคตอันใกล้ (T_{i+1}) โดยพิจารณาจากพารามิเตอร์ที่มีความเกี่ยวข้องคือ

1. อุณหภูมิ ณ เวลาปัจจุบัน (T_i)
2. ปริมาตรของห้องปิดที่สนใจ
3. ความจุการทำความเย็น (Cooling Capacity) และความจุการทำความร้อน (Heat Capacity) ของอาคาร
4. ขนาดพื้นที่ของ ผนัง หน้าต่าง ประตู และความต้านทานความร้อน ของวัสดุ
5. ระยะระหว่างเวลาปัจจุบันกับเวลาในอนาคตที่จะคำนวณ
6. อุณหภูมิภายนอกอาคาร ณ เวลาปัจจุบัน ($T_{out,i+1}$)
7. ค่าสัมประสิทธิ์การส่งผ่านความร้อนจากรังสีแสงอาทิตย์
8. ปริมาณการแผ่รังสีของแสงอาทิตย์
9. ปริมาณความร้อนที่ได้รับจากผู้อยู่อาศัย

งานวิจัย [5] เสนอว่าการคำนวณในวิธีที่ได้กล่าวข้างต้นมีข้อจำกัดคือ ความจำเป็นที่จะต้องทราบค่าของตัวแปรที่จำเพาะกับอาคารนั้นๆ อีกทั้งการเก็บค่าตัวแปร อาทิ ปริมาณการแผ่รังสีของแสงอาทิตย์ จะต้องอาศัยตัวรับรู้ชนิดพิเศษที่มีราคาสูง ดังนั้นวิธีนี้จึงไม่เหมาะกับการประยุกต์ใช้งานจริง และได้เสนอวิธี การขับเคลื่อนด้วยข้อมูล (Data-Driven Approach) ซึ่งสามารถคำนวณอุณหภูมิในอนาคตอันใกล้ด้วยการทำนายการเปลี่ยนแปลงของอุณหภูมิต่อหน่วยเวลา ($\frac{dT_i}{dt}$) โดยมีหลักการเลือกพารามิเตอร์ดังนี้

พารามิเตอร์ที่มีความจำเพาะกับตัวอาคาร เช่น ปริมาตรของห้องปิดที่สนใจ เป็นพารามิเตอร์ที่เป็นค่าคงที่ ไม่ส่งผลกระทบต่อ การเปลี่ยนแปลงของอุณหภูมิต่อหน่วยเวลาจึงสามารถละทิ้งได้ ความร้อนที่เกิดขึ้นภายในอาคาร และภายนอกอาคาร สามารถพิจารณาด้วย อุณหภูมิภายในอาคาร อุณหภูมิภายนอกอาคาร ความชื้นสัมพัทธ์ภายนอกอาคาร สภาพอากาศ เวลา และวันของสัปดาห์

โดยที่ เวลาในแต่ละวันสามารถใช้ในการประมาณปริมาณการแผ่รังสีของแสงอาทิตย์ เวลาและวันของ สัปดาห์ถูกใช้ในการประมาณจำนวนผู้อยู่อาศัยเพื่ออธิบายปริมาณความร้อนที่ได้รับจากผู้อยู่อาศัย

2.2.2 ความรู้สึกสบายเชิงความร้อน

มาตรฐาน ANSI/ASHRAE 55-2004 [6] อธิบายความรู้สึกสบายเชิงความร้อนไว้ว่าเป็น สภาวะความพึงพอใจที่มีต่อสภาวะทางความร้อนของสิ่งแวดล้อมซึ่งขึ้นกับตัวบุคคล โดยมีปัจจัยที่ ส่งผลต่อความรู้สึกสบายเชิงความร้อน 6 ปัจจัยดังนี้

1. อัตราเมตาบอลิซึม (Metabolic Rate)
2. ค่าความเป็นฉนวนความร้อนของเสื้อผ้าที่สวมใส่ (Clothing Insulation)
3. อุณหภูมิของอากาศ (Air Temperature)
4. อุณหภูมิการแผ่รังสีความร้อนเฉลี่ย (Mean Radiant Temperature)
5. ความเร็วของอากาศ (Air Velocity)
6. ความชื้นสัมพัทธ์ของอากาศ (Relative Humidity)


การประเมินความรู้สึกสบายเชิงความร้อนที่เป็นผลจาก 6 ปัจจัยข้างต้น อาศัยค่าดัชนีทำนายการ โหวตเฉลี่ย (Predicted Mean Vote; PMV) ซึ่งแบ่งดัชนีความรู้สึกเชิงความร้อน (Thermal Sensation Scale) ออกเป็น 7 ระดับดังตารางที่ 1

ตารางที่ 2 ระดับความรู้สึกเชิงความร้อน (Thermal Sensation Scale)

ดัชนี (Index)	ความรู้สึกทางความร้อน (Thermal Sensation)
3	ร้อน
2	อุ่น
1	ค่อนข้างอุ่น
0	พอดี
-1	ค่อนข้างเย็น
-2	เย็น
-3	หนาว

เนื่องจากความรู้สึกสบายของผู้อยู่อาศัยมีความแตกต่างกันในแต่ละบุคคล จึงได้มีการใช้ดัชนีชี้วัดเชิงปริมาณ เพื่อบ่งบอกร้อยละของกลุ่มคนที่รู้สึกไม่สบายต่อกลุ่มคนทั้งหมด นั่นคือ ดัชนี PPD

(Predicted Percentage of Dissatisfied) ดัชนี PPD และดัชนี PMV มีความสัมพันธ์ตามกราฟในรูปที่ 3



รูปที่ 3 กราฟแสดงความสัมพันธ์ระหว่าง PMV และ PPD

ที่มา : [6]

ในทางปฏิบัติ ค่าที่เหมาะสมของดัชนี PPD และ ดัชนี PMV อยู่ที่ น้อยกว่า 10 และ ระหว่าง -0.5 ถึง +0.5 ตามลำดับ

2.3 การเรียนรู้ของเครื่องแบบมีผู้สอน


การเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Machine Learning) คือ ชนิดของอัลกอริทึมที่สามารถสร้างฟังก์ชันหรือแบบจำลองเพื่อบอกความสัมพันธ์ระหว่างข้อมูลขาเข้าและข้อมูลขาออก ข้อมูลทั้งหมดจะถูกแบ่งเป็นสามส่วนคือ ชุดข้อมูลฝึกสอน (Training Dataset) ชุดตรวจสอบ (Validation Set) และชุดข้อมูลทดสอบ (Test Set) โดยแบบจำลองดังกล่าวถูกปรับพารามิเตอร์จากการนำชุดข้อมูลฝึกสอน ที่ประกอบไปด้วยข้อมูลขาเข้าและข้อมูลขาออกซึ่งถูกระบุไว้อย่างชัดเจน มาวิเคราะห์เพื่อหาความสัมพันธ์ จากนั้นนำมาทดสอบประสิทธิภาพและทำการปรับปรุงไฮเปอร์พารามิเตอร์บนข้อมูลชุดตรวจสอบ (Validation Set) เพื่อให้แบบจำลองสามารถหาความสัมพันธ์ของข้อมูลได้ดียิ่งขึ้น การปรับนี้อาจทำหลายยุค (Epoch) ตามแต่ผู้สร้างแบบจำลองกำหนด หลังจากถูกปรับจนครบทุกยุคแล้วประสิทธิภาพของแบบจำลองถูกวัดด้วยตัวชี้วัด (Metric) ซึ่งตัววัดที่ใช้จะแตกต่างกันไปขึ้นอยู่กับวัตถุประสงค์ของการใช้งาน โดยจะถูกวิเคราะห์ทดสอบด้วยข้อมูลชุดข้อมูลทดสอบ (Test Set) ซึ่งเป็นข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน

วิทยานิพนธ์ฉบับนี้ประยุกต์ใช้การเรียนรู้ของเครื่องแบบมีผู้สอนในการสร้างแบบจำลองการทำนาย เพื่อควบคุมเครื่องปรับอากาศโดยใช้ความรู้ดังรายละเอียดต่อไปนี้


2.3.1 ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine; SVM)

SVM คืออัลกอริทึมที่สามารถแก้ปัญหาได้ทั้ง ในกรณีการจัดกลุ่ม (Classification) และการถดถอย (Regression) แต่โดยส่วนใหญ่แล้วจะถูกใช้ในการจัดกลุ่ม นั่นคือการจัดกลุ่มด้วยซัพพอร์ตเวกเตอร์ (Support Vector Classification; SVC) หลักการทำงานของของ SVC คือการจัดวางข้อมูลลงในปริภูมิ N มิติ ซึ่ง N คือจำนวนฟีเจอร์ของข้อมูล ดังนั้นขนาดของข้อมูลในฟีเจอร์ใดๆ คือขนาดของเวกเตอร์ ในแกนนั้นๆ เช่นกัน จากนั้น SVC จะทำหน้าที่หาไฮเปอร์เพลน (Hyperplane) หรือปริภูมิย่อย (Subspace) ที่มีมิติ $N-1$ ซึ่งทำหน้าที่แบ่งกลุ่มข้อมูลบนปริภูมิ N มิติออกเป็น 2 กลุ่ม รูปที่ 4 แสดงการแบ่งกลุ่มของข้อมูลที่มี 2 และ 3 ฟีเจอร์ ซึ่งไฮเปอร์เพลนของ SVC คือเส้นตรง 1 มิติ และระนาบ 2 มิติตามลำดับ

A hyperplane in R^2 is a line




A hyperplane in R^3 is a plane



รูปที่ 4 การจำแนกข้อมูลออกเป็น 2 กลุ่มด้วยไฮเปอร์เพลน

ที่มา : <https://towardsdatascience.com/support-vector-machine-introduction-to-machine-learning-algorithms-934a444fca47>

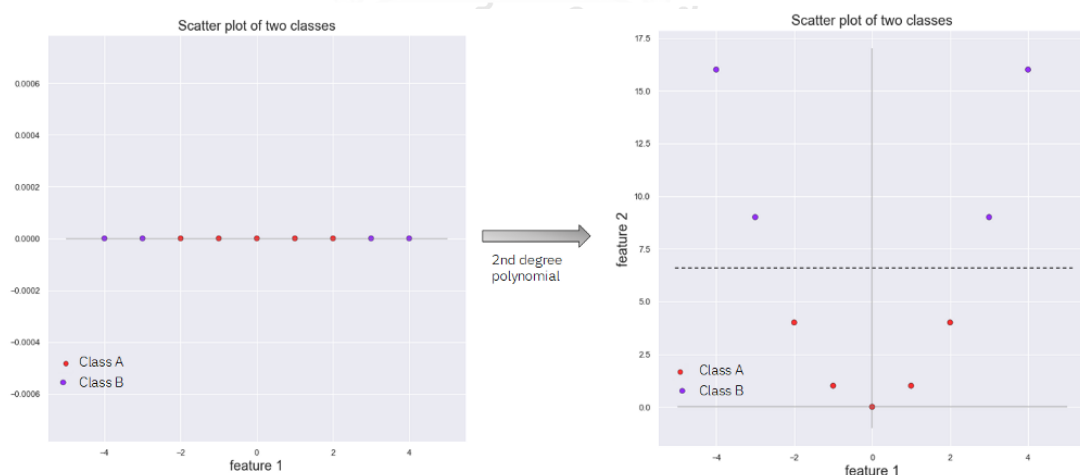
ซัพพอร์ตเวกเตอร์คือจุดข้อมูลที่อยู่ใกล้กับไฮเปอร์เพลน และมีอิทธิพลต่อตำแหน่งและทิศทางของไฮเปอร์เพลนนั้นๆ หลักการของ SVC คือการหาไฮเปอร์เพลนที่มีมาร์จิน (Margin) หรือระยะเผื่อระหว่าง 2 กลุ่มที่มีขนาดใหญ่ที่สุด (Maximum Margin) เพื่อให้ความผิดพลาดของการแยกข้อมูลน้อยที่สุด ซึ่งซัพพอร์ตเวกเตอร์ทำหน้าที่เป็นตัวกำหนดขนาดของมาร์จิน ดังแสดงในรูปที่ 5



รูปที่ 5 การจำแนกข้อมูลด้วย SVC

ที่มา : รศ. ดร. ศาสตรา วงศ์ธนวุธ, ปัญญาประดิษฐ์ ทฤษฎี โปรแกรม และการประยุกต์, สำนักพิมพ์ มหาวิทยาลัยขอนแก่น, 2560.

อย่างไรก็ตาม ข้อมูลที่วิเคราะห์อาจมีความซับซ้อน ทำให้ไม่สามารถใช้ไฮเปอร์เพลนที่เป็นเชิงเส้นในการแบ่งกลุ่ม ดังนั้นฟังก์ชันเคอร์เนล (Kernel Function) จึงถูกใช้ในการแปลงข้อมูลให้อยู่ในปริภูมิที่สูงขึ้น เพื่อให้สามารถแบ่งข้อมูลด้วยไฮเปอร์เพลนที่เป็นเชิงเส้นได้ เคอร์เนลที่ได้รับความนิยมคือ เคอร์เนลเส้นตรง (Linear Kernel) เคอร์เนลพหุนาม (Polynomial Kernel) และ เคอร์เนลเรเดียลเบสฟังก์ชัน (Radial Basis Function Kernel; RBF) รูปที่ 6 แสดงการแบ่งกลุ่มข้อมูลที่มี 1 ฟิเจอร์ และข้อมูลไม่สามารถแยกได้อย่างชัดเจนด้วยไฮเปอร์เพลนที่เป็นเชิงเส้น วิธีแก้ไขคือ การใช้เคอร์เนลพหุนาม ที่มีดีกรีอันดับ 2 ในการสร้างฟิเจอร์ที่สองขึ้นมา และเมื่อวิเคราะห์บนปริภูมิใหม่ จะสามารถหาไฮเปอร์เพลนที่ใช้แบ่งกลุ่มข้อมูลได้อย่างชัดเจน



รูปที่ 6 การเพิ่มมิติของข้อมูลโดยใช้ฟังก์ชันเคอร์เนล

อ้างอิง : [https://towardsdatascience.com/support-vector-machines-explained-](https://towardsdatascience.com/support-vector-machines-explained-25a685e4d228)

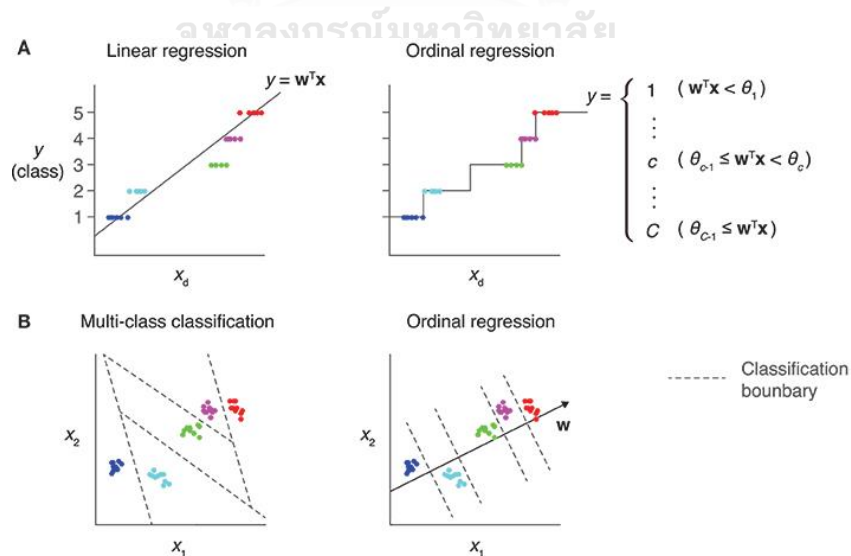
25a685e4d228

2.3.2 การถดถอยที่เป็นลำดับ (Ordinal Regression)

บทความ [7] อธิบายไว้ว่า แบบจำลองการแบ่งกลุ่ม (Classification) และการถดถอย (Regression) ไม่ใช่วิธีที่เหมาะสมสำหรับการแก้ปัญหาการแบ่งกลุ่มซึ่งแต่ละกลุ่มมีความสัมพันธ์กันเป็นลำดับ นั่นคือ กลุ่มที่ 2 จะต้องอยู่ตรงกลางระหว่างกลุ่มที่ 1 และกลุ่มที่ 3 เสมอ เพื่อให้ง่ายต่อความเข้าใจจะขอเรียกกลุ่มดังกล่าวว่าระดับ ในแง่ของการถดถอย ลำดับของระดับจาก 1 ไป 3 ถูกเรียงอย่างถูกต้อง แต่ด้วยวิธีการถดถอยระยะระหว่างแต่ละระดับจะถูกมองว่าเท่ากัน ซึ่งในทางปฏิบัติ ระยะระหว่างระดับอาจไม่เท่ากันทำให้ความสัมพันธ์ของข้อมูลมีความผิดพลาด ในทางกลับกัน หากใช้วิธีการแบ่งกลุ่ม แบบจำลองจะไม่สนใจความสัมพันธ์ที่เป็นลำดับ ทำให้ข้อมูลที่อาจเป็นตัวช่วยในการปรับแบบจำลองให้มีประสิทธิภาพสูงขึ้นไม่ถูกนำมาพิจารณา

ในทางปฏิบัติ การถดถอยที่เป็นลำดับใช้วิธีการกำหนดขีดเริ่มเปลี่ยน (Threshold) เพื่อแบ่งเส้นจำนวนจริงออกเป็นส่วนๆ ซึ่งแต่ละส่วนจะให้ผลลัพธ์ของฟังก์ชันที่แตกต่างกัน ในการทำนาย หากผลลัพธ์ตกอยู่ในช่วงจำนวนจริงของระดับใดๆ ผลเฉลยของการทำนายจะแสดงว่าข้อมูลถูกจำแนกอยู่ในระดับนั้นๆ ดังนั้นในการวิเคราะห์แบบจำลองการทำนาย นอกจากการปรับค่าถ่วงน้ำหนักแล้ว การปรับค่าขีดเริ่มเปลี่ยน สามารถทำให้การทำนายมีความแม่นยำมากยิ่งขึ้น

รูปที่ 7 แสดงการเปรียบเทียบระหว่างการถดถอยเชิงเส้น (Linear Regression) กับ การถดถอยที่เป็นลำดับ (A) และการเปรียบเทียบระหว่างการแบ่งหลายกลุ่ม (Multi-class Classification) กับ การถดถอยที่เป็นลำดับ (B)




รูปที่ 7 การเปรียบเทียบระหว่างการถดถอยที่เป็นลำดับกับอัลกอริทึมแบบอื่นๆ

ที่มา : [7]

2.3.3 โครงข่ายประสาทเทียม (Artificial Neural Network)

[8] ได้อธิบายไว้ว่าโครงข่ายประสาทเทียมมีหน่วยย่อยที่เล็กที่สุดคือ เซลล์ประสาทเทียม (Perceptron) ซึ่งทำหน้าที่รับข้อมูลขาเข้ามาประมวลผลเพื่อให้ได้ข้อมูลขาออกหรือผลลัพธ์ โดยเซลล์ประสาทเทียมมีส่วนประกอบดังรูปที่ 8 กระบวนการทำงานของเซลล์ประสาทเทียมคือ


1. รับข้อมูลขาเข้า (Input; X)
2. นำข้อมูลขาเข้ามาคูณกับค่าถ่วงน้ำหนัก (Weight; W) และบวกกับ bias (b)
3. นำผลลัพธ์ที่ได้จากขั้นที่ 2 มาเข้าฟังก์ชันกระตุ้น (Activation Function; σ)
4. ค่าที่เป็นผลลัพธ์จากฟังก์ชันกระตุ้นคือค่า Activation (\hat{y})



รูปที่ 8 เซลล์ประสาทเทียม (Perceptron)

ที่มา : [9]

เซลล์ประสาทเทียมสามารถแก้ไขปัญหาคือได้ดีเฉพาะระบบที่เป็นเชิงเส้น (Linear System) แต่ในระบบที่มีความซับซ้อน หรือไม่เป็นเชิงเส้น (Non-linear) โครงสร้างเซลล์ประสาทแบบหลายชั้น (Multilayer Neural Network) ดังแสดงในรูปที่ 9 สามารถใช้ในการระบุความสัมพันธ์ของข้อมูลขาเข้าและข้อมูลขาออกได้ดีกว่า โดยค่า Activation ที่ได้จากเซลล์ประสาท จะถูกใช้เป็นข้อมูลขาเข้าของเซลล์ประสาทชั้นถูกซ่อน (Hidden Layer) กระบวนการของเซลล์ประสาทชั้นต้นจะถูกทำซ้ำในทุกๆ ชั้น จนกระทั่งได้รับผลลัพธ์จากชั้นข้อมูลขาออก (Output Layer) ของโครงสร้างประสาท



รูปที่ 9 โครงข่ายประสาทเทียม

ที่มา :


https://commons.wikimedia.org/wiki/File:MultiLayerNeuralNetworkBigger_english.png

กระบวนการที่ได้กล่าวไปข้างต้นคือกระบวนการการแพร่ไปข้างหน้า (Forward Propagation) ค่าของข้อมูลขาออกในสมการที่ (2-1) จะถูกเปรียบเทียบกับผลเฉลยจริง ด้วย Cost Function ได้ผลลัพธ์เป็นค่า Loss ซึ่งในกรณีที่ใช้ Sigmoid เป็นฟังก์ชันกระตุ้น ค่าความสูญเสียที่เกิดขึ้นคือ Binary Cross-Entropy Loss ดังแสดงในสมการที่ (2-)

$$\hat{y} = \sigma(w^T x + b) \quad (2-1)$$

$$L = -(y \log \hat{y} + (1 - y) \log(1 - \hat{y})) \quad (2-2)$$

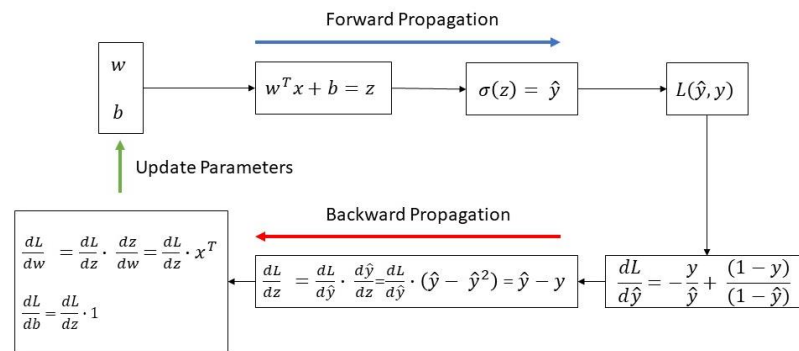
อนุพันธ์ของค่าความสูญเสียดังกล่าวเทียบกับค่าถ่วงน้ำหนักของแต่ละเซลล์ประสาทในแต่ละชั้น จะทำให้ทราบทิศทางของความผิดพลาดด้วยวิธีการแพร่ถอยหลัง (Backward Propagation) เมื่อนำมาคูณกับอัตราการเรียนรู้ (Learning Rate; α) ซึ่งหมายถึงขนาดของความเปลี่ยนแปลงที่จะทำการปรับค่าถ่วงน้ำหนัก ดังแสดงในรูปที่ 10 จะได้ค่าถ่วงน้ำหนักใหม่ดังแสดงในสมการที่ (2-3)



รูปที่ 10 กราฟแสดงการลดลงของค่าความสูญเสียในแต่ละการปรับค่าถ่วงน้ำหนัก
ที่มา : [10]

$$w = w - \alpha \left(\frac{dL}{dw} \right) \quad (2-3)$$


ในท้ายที่สุดเมื่อได้ค่าถ่วงน้ำหนักใหม่ จะทำการวนซ้ำกระบวนการ Forward และ Backward Propagation รูปที่ 11 และอัปเดตค่าถ่วงน้ำหนัก จนกระทั่งค่าความสูญเสียต่ำที่สุด



รูปที่ 11 กระบวนการ Forward และ Backward Propagation

2.3.5 ครอสวาไลเดชัน (Cross Validation)

ตามปกติแล้วประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่อง จะถูกทดสอบและปรับปรุงไฮเปอร์พารามิเตอร์บนข้อมูลชุดประเมินผล (Evaluation Set) แต่ในกรณีที่ข้อมูลมีขนาดเล็ก การใช้ชุดประเมินผลจำนวนจำกัดในการทดสอบประสิทธิภาพของแบบจำลองที่สร้างขึ้นจากข้อมูลที่มีจำนวนจำกัดอาจทำให้เกิดโอเวอร์ฟิต (Overfitting) หรือการพอดีเกินไปบนข้อมูลชุดฝึกสอน ทำให้แบบจำลองมีประสิทธิภาพต่ำเมื่อนำไปใช้งานจริง ปัญหานี้สามารถแก้ไขได้โดยวิธี K-Fold Cross Validation ซึ่งบทความ [11] ได้อธิบายขั้นตอนของวิธีการครอสวาไลเดชันดังนี้ ขั้นแรก แบ่งข้อมูลทั้งหมดออกเป็นชุดฝึกสอน และชุดทดสอบ และภายในชุดฝึกสอนนั้น ทำการสับเปลี่ยนข้อมูลอย่างสุ่ม จากนั้นทำการแบ่งข้อมูลออกเป็นกลุ่มที่มีจำนวนข้อมูลในแต่ละกลุ่มเท่ากัน ในแต่ละครั้งของการฝึกสอนข้อมูล 1 กลุ่มจะถูกใช้เป็นชุดประเมิน และข้อมูลชุดที่เหลือจะถูกใช้เป็นชุดฝึกสอน กระบวนการฝึกสอนจะถูกวนซ้ำโดยเปลี่ยนกลุ่มที่ใช้เป็นชุดประเมินผล ดังแสดงในรูปที่ 12




รูปที่ 12 กระบวนการครอสวาไลเดชัน

ที่มา : https://scikit-learn.org/stable/modules/cross_validation.html

การตรวจสอบความผิดพลาด (error) จากความเอนเอียง (bias) เนื่องจากข้อมูลทั้งหมดถูกใช้สำหรับการสร้างแบบจำลอง และในทางกลับกันยังช่วยลดความผิดพลาดจากความแปรปรวน (Variance) เป็นอย่างมาก เนื่องจากข้อมูลทุกชุดของชุดฝึกสอนถูกใช้ในการประเมินแบบจำลองแล้ว

ในการกำหนดไฮเปอร์พารามิเตอร์ของแบบจำลอง การตรวจสอบความผิดพลาด (error) ถูกใช้เพื่อประเมินแบบจำลองโดยอาศัยค่าเฉลี่ยของตัวชี้วัด (Metric) ของทุกๆ ชั้นที่ประเมิน ไฮเปอร์พารามิเตอร์ชุดที่สามารถสร้างแบบจำลองที่มีค่าเฉลี่ยของตัวชี้วัดที่ดีที่สุด เช่น มีความแม่นยำ (Accuracy) สูงที่สุด จะถูกใช้เป็นไฮเปอร์พารามิเตอร์ของแบบจำลองที่ใช้งานจริง รูปที่ 13 แสดงแผนผังการสร้างแบบจำลองโดยใช้การตรวจสอบความผิดพลาดในการประเมิน




รูปที่ 13 สร้างแบบจำลองโดยใช้การตรวจสอบความผิดพลาดในการประเมิน

ที่มา : https://scikit-learn.org/stable/modules/cross_validation.html

2.3.6 การประเมินการแบ่งกลุ่ม (Classification Assessment)

บทความ [12] ได้อธิบายวิธีการประเมินประสิทธิภาพของอัลกอริทึมการแบ่งกลุ่ม โดยใช้ตารางประเมินผลลัพธ์ของการทำนาย (Confusion Matrix) ดังแสดงในรูปที่ 14 ตัวชี้วัดประสิทธิภาพของแบบจำลอง (Metric) สามารถคำนวณได้จากการวิเคราะห์ตารางประเมินผลลัพธ์ของการทำนาย ซึ่งการเลือกใช้ตัวชี้วัดจะแตกต่างกันขึ้นอยู่กับวัตถุประสงค์ของแบบจำลอง



รูปที่ 14 แผนภาพแสดงความถูกต้องของการแบ่งกลุ่ม

ที่มา : [12]

ในกรณีการแบ่งเป็น 2 กลุ่ม (Binary Classification) ค่าที่แสดงในตารางประเมินผลลัพธ์การทำนายจะประกอบไปด้วย

1. ค่าจริงเชิงบวก (True Positive; TP) ในกรณีทำนายว่าเป็นจริงและผลเฉลยเป็นจริง
2. ค่าจริงเชิงลบ (True Negative; TN) ในกรณีทำนายว่าเป็นเท็จและผลเฉลยเป็นเท็จ
3. ค่าเท็จเชิงบวก (False Positive; FP) ในกรณีทำนายว่าเป็นจริงแต่ผลเฉลยเป็นเท็จ
4. ค่าเท็จเชิงลบ (False Negative; FN) ในกรณีทำนายว่าเป็นเท็จแต่ผลเฉลยเป็นจริง

ตัวชี้วัดของการแบ่งเป็น 2 กลุ่มมีหลายตัว ในวิทยานิพนธ์ฉบับนี้ เลือกใช้ค่าความแม่นยำ (Accuracy) ในการประเมินแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย และ เลือกใช้ ค่าการเรียกกลับ (Recall) ในการประเมินแบบจำลองการทำนายความรู้สึกสบายเชิงความร้อน โดยรายละเอียดของตัวชี้วัดทั้ง 2 มีดังนี้

2.3.6.1 ค่าความแม่นยำ (Accuracy)

ค่าความแม่นยำ เป็นตัวชี้วัดที่พบได้บ่อยที่สุดในการประเมินแบบจำลองการแบ่งกลุ่ม ความหมายของความแม่นยำคือ อัตราส่วนระหว่างจำนวนข้อมูลที่แบ่งกลุ่มได้ถูกต้อง ต่อจำนวนข้อมูลทั้งหมด จากตารางประเมินผลลัพธ์การทำนาย ค่าความแม่นยำสามารถคำนวณได้จากสมการที่ 2-4

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \quad (2-4)$$

ในกรณีที่ข้อมูลทั้งสองกลุ่มมีค่าใกล้เคียงกัน ค่าความแม่นยำ จะเป็นตัวชี้วัดที่ดีที่สุด แต่ในกรณีที่ข้อมูลทั้งสองกลุ่มมีจำนวนแตกต่างกันมาก เช่นข้อมูลในกลุ่มที่ 1 มีจำนวน 10 เท่าของข้อมูลกลุ่มที่ 2 ถึงแม้ความผิดพลาดในข้อมูลกลุ่มที่ 2 จะมากแค่ไหนก็ตาม แต่ถ้าข้อมูลในกลุ่มที่ 1 มี

ความถูกต้องมาก ค่าความแม่นยำก็จะลดลงผลกระทบจากกว่าผิดพลาดของกลุ่มที่มีจำนวนน้อยกว่า ทำให้ผลการชี้วัดออกมาดี ซึ่งในความเป็นจริงแล้วแบบจำลองไม่สามารถจำแนกกลุ่มที่ 2 ได้ ทั้งนี้ทั้งนั้นชุดข้อมูลที่ไม่สมดุล (Imbalanced Dataset) หมายถึงชุดข้อมูลที่มีจำนวนของข้อมูลในแต่ละกลุ่มต่างกันมาก แต่ในกรณีที่แตกต่างกันไม่มาก เช่น 60% ของข้อมูลอยู่ในกลุ่มที่ 1 และ 40% ของข้อมูลอยู่ในกลุ่มที่ 2 จะไม่ส่งผลกระทบต่อการใช้วัดของค่าความแม่นยำ

2.3.6.2 ค่าการเรียกกลับ (Recall)

ค่าการเรียกกลับ คือค่าที่บ่งบอกอัตราส่วนระหว่างค่าจริงเชิงบวกกับค่าจริงทั้งหมดที่ตั้งสมการที่ 2-5 หรืออีกนัยหนึ่งคือ เป็นค่าที่ใช้บอกความสามารถของแบบจำลองในการรวบรวมค่าที่เป็นจริง

$$Recall = \frac{TP}{TP+FN} \quad (2-5)$$

2.3.6.3 ค่าความเที่ยงตรง (Precision)

ค่าความเที่ยงตรง คือค่าที่บ่งบอกอัตราส่วนระหว่างค่าจริงเชิงบวกกับค่าเชิงบวกทั้งหมดที่ตั้งสมการที่ 2-6 หรืออีกนัยหนึ่งคือ เป็นค่าที่ใช้บอกความสามารถของแบบจำลองในการจำแนกว่าค่าที่รวบรวมมาได้มีอัตราส่วนของค่าที่เป็นความจริงอยู่เท่าไร

$$Precision = \frac{TP}{TP+FP} \quad (2-6)$$

2.3.7 การเรียนรู้แบบจำลองทางความร้อนด้วยข้อมูลจากอินเทอร์เน็ตของสรรพสิ่ง

งานวิจัย [5] ได้เสนอวิธีการเรียนรู้ของเครื่องเพื่อใช้ในการทำนาย การเปลี่ยนแปลงของอุณหภูมิต่อหน่วยเวลา โดยอาศัยข้อมูลจากที่เก็บรวบรวมจากแพลตฟอร์มอุปกรณ์อินเทอร์เน็ตของสรรพสิ่งที่ติดตั้งในอาคารทดสอบ อุปกรณ์ที่ใช้เก็บค่าสถานะภายในตัวอาคารคือ เทอร์มอสแตตอัจฉริยะ (Smart Thermostat) ซึ่งมีหน้าที่ส่งข้อมูลไปให้หน่วยประมวลผลต้นทาง (Edge Device) เพื่อบันทึกลงในฐานข้อมูลที่ไม่ใช่เชิงสัมพันธ์ การส่งข้อมูลดังกล่าว อาศัยระบบบริหารจัดการพลังงานในอาคารแบบโอเพนซอร์ส (BEMOSS) ในการสื่อสารระหว่าง หน่วยประมวลผลต้นทาง กับอุปกรณ์อินเทอร์เน็ตของสรรพสิ่งได้หลายอุปกรณ์

ข้อมูลที่ถูกบันทึกในฐานข้อมูล (อุณหภูมิภายใน/นอกอาคาร ความชื้นสัมพัทธ์ภายนอกอาคาร สภาพอากาศ เวลา และวันของสัปดาห์) จะถูกปรับให้เป็นค่ามาตรฐาน ซึ่งมีความเฉลี่ยเป็น 0 และความแปรปรวนเป็น 1 ค่าดังกล่าวถูกนำมาใช้ในโครงร่างการเรียนรู้ (Learning Framework)

เพื่อทำการฝึกสอน และเปรียบเทียบประสิทธิภาพของแบบจำลอง ซึ่งประกอบไปด้วย การถดถอยพหุคูณ (Polynomial Regression) การถดถอยแบบซัพพอร์ตเวกเตอร์ (SVR) แรนดอมฟอเรส (Random Forest) โครงข่ายประสาทเทียม (ANN) และเอกสตรึมเกรเดียนบูสต์ (XGB) ประสิทธิภาพของแบบจำลองถูกชี้วัดด้วยค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) กล่าวคือแบบจำลองที่ให้ค่า RMSE ต่ำที่สุดจะถือว่าเป็นแบบจำลองที่มีประสิทธิภาพดีที่สุด

ผลการทดสอบประสิทธิภาพของแบบจำลองโดยใช้ข้อมูลในแต่ละเดือนเป็นเวลาทั้งสิ้น 5 เดือนในการฝึกสอน ปรากฏว่าการถดถอยแบบซัพพอร์ตเวกเตอร์มีประสิทธิภาพในการทำความสัมพันธ์แบบไม่เชิงเส้นระหว่างฟีเจอร์ของข้อมูลกับอัตราการเปลี่ยนแปลงอุณหภูมิได้ดีที่สุด แต่ในกรณีที่จำนวนข้อมูลที่เก็บได้มีปริมาณน้อย การถดถอยพหุคูณจะมีประสิทธิภาพดีที่สุด ในทางกลับกัน วิธีการเรียนรู้โดยใช้โครงข่ายประสาทเทียมไม่สามารถทำนายได้อย่างแม่นยำเนื่องจากข้อมูลที่เก็บได้มีปริมาณไม่มากพอ อีกทั้งค่าพารามิเตอร์เพิ่มเติมของแบบจำลองหาได้ยากเพราะมีความซับซ้อนสูง

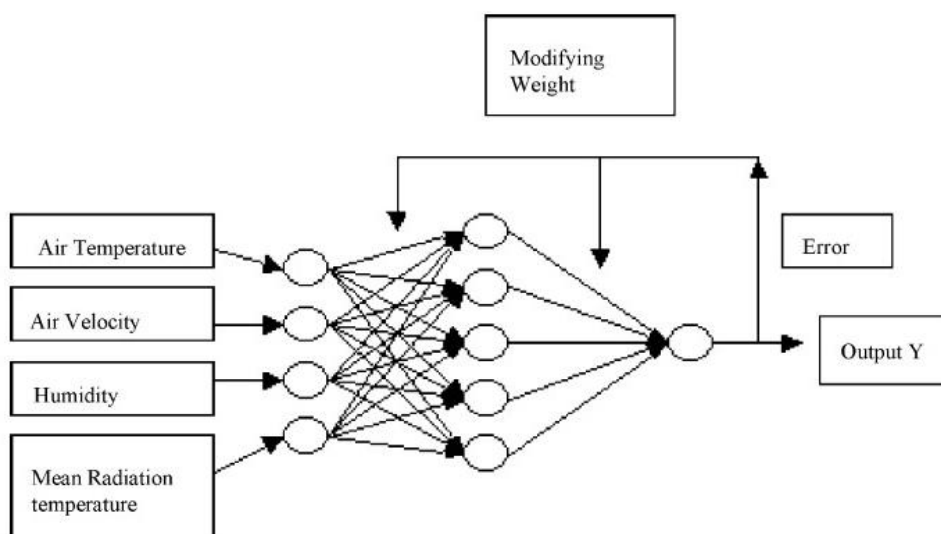
จากผลลัพธ์ของการทดลองทำนายอุณหภูมิในอนาคตเป็นเวลาครึ่งชั่วโมง พบว่าค่าผิดพลาดเฉลี่ยมีค่าประมาณ 0.3 องศาฟาเรนไฮต์ ในขณะที่การทำนายอุณหภูมิในอนาคตเป็นเวลา 3 ถึง 4 ชั่วโมงให้ค่าผิดพลาดเฉลี่ยอยู่ที่ 1 องศาฟาเรนไฮต์ ซึ่งมีผลน้อยมากต่อการรับรู้ของมนุษย์จึงถือว่าค่อนข้างแม่นยำ แต่สิ่งที่ควรปรับปรุงในอนาคตคือความสามารถในการทำนายอัตราการเปลี่ยนแปลงของอุณหภูมิของอาคาร ในกรณีที่มีการเปลี่ยนแปลงจำนวนของผู้อยู่อาศัย และการปรับปรุงระบบเพื่อรองรับการทำความร้อนและความเย็นได้หลายระดับ

2.3.8 การใช้แบบจำลองโครงข่ายประสาทในการทำนายความรู้สึกทางความร้อน

งานวิจัย [13] เสนอการใช้แบบจำลองโครงข่ายประสาท (Neural Network Models: NNM) ในการควบคุมเครื่องปรับอากาศ โดยใช้ค่าดัชนี PMV เป็นตัวแปรเป้าหมาย (Target Variable) ของการทำนาย โดยเปลี่ยนจากรู้สึกทางความร้อน 7 ระดับเป็น ค่าคงที่ 3 ค่า นั่นคือ 0 0.5 และ 1 หมายถึง หนาว ร้อน และ พอดี ตามลำดับ พารามิเตอร์ที่ใช้เป็นฟีเจอร์ของแบบจำลองมี 4 ค่า คือ อุณหภูมิของอากาศ ความเร็วลม ความชื้นสัมพัทธ์ และ อุณหภูมิการแผ่รังสีความร้อนเฉลี่ย

โครงข่ายประสาทดังกล่าวใช้อัลกอริธึมแบ็คพรอพาคชัน (Back Propagation) ในการปรับค่าถ่วงน้ำหนักของโครงข่ายประสาท กล่าวคือ ค่าผิดพลาด (Error) หรือค่าแตกต่างระหว่างผลเฉลย

จริงกับค่าทำนายจะถูก แพร่ย้อนกลับไปยัง เซลล์ประสาท (Neuron) ที่มีความเกี่ยวข้องกับผลเฉลย และทำการปรับค่าถ่วงน้ำหนัก (Weight) กระบวนการนี้จะถูกทำซ้ำจนกระทั่งค่าผิดพลาดอยู่ในช่วงที่รับได้ โครงสร้างของแบบจำลองโครงข่ายประสาทดังแสดงในรูปที่ 15 ประกอบไปด้วย เซลล์ประสาท 4 หน่วยในชั้นข้อมูลขาเข้า (Input Layer) ตามจำนวนของพีเจอร์ 5 หน่วยในชั้นกลาง (Hidden Layer) และ 1 หน่วยในชั้นข้อมูลขาออก (Output Layer) ตามจำนวนตัวแปรเป้าหมาย



รูปที่ 15 โครงสร้างของโครงข่ายประสาทที่ใช้ทำนายความรู้สึกเชิงความร้อน

ที่มา : [13]

2.4 การใช้บริการบอกตำแหน่ง

บริการบอกตำแหน่ง (Location-Based Service) ถูกใช้ในโปรแกรมประยุกต์บน โทรศัพท์มือถือ โดยมีวัตถุประสงค์ที่แตกต่างกัน เช่น การนำทาง (Navigation) การควบคุมการเปิดปิดของอุปกรณ์เมื่อผู้ใช้อาศัยเข้าสู่รัศมีรั้วภูมิศาสตร์ (Geofence Radius) โดยปกติแล้ว การระบุพิกัดละติจูดและลองจิจูด ที่แม่นยำจะใช้สัญญาณ GPS (Global Positioning System) จากดาวเทียม ดังนั้นการที่ผู้ใช้อยู่ในตำแหน่งที่มีสิ่งกีดขวาง เช่น อยู่ภายในอาคาร และการที่มีเมฆมากจนบดบังวิสัยของดาวเทียม จะทำให้ความแม่นยำในการระบุตำแหน่งลดลง อย่างไรก็ตาม โทรศัพท์มือถือสามารถใช้เครือข่ายอินเทอร์เน็ต ผ่าน เซลลูลาร์ หรือ ไวไฟ ในการบอกตำแหน่งในพื้นที่ที่สัญญาณ GPS

2.4.1 การคำนวณระยะการจัดระหว่าง 2 พิกัด

บทความ [14] ได้อธิบายการนำพิกัดละติจูดและลองจิจูดของผู้ใช้อาศัยที่เก็บค่าโดยโทรศัพท์มือถือ และส่งให้เซิร์ฟเวอร์เพื่อคำนวณระยะการจัดถึงพิกัดที่กำหนดไว้ โดยใช้วิธีเฮเวอร์ไซน์

(Haversine) ซึ่งวิธีเฮเวอร์ไซน์คือวิธีการคำนวณหาระยะทางที่สั้นที่สุดระหว่าง 2 จุดที่อยู่บนพื้นผิวของรูปทรงกลม ด้วยสมการ ที่ 2-6

$$d = 2r \cdot \arcsin \left(\sqrt{\sin^2 \left(\frac{\varphi_2 - \varphi_1}{2} \right) + \cos(\varphi_1) \cos(\varphi_2) \sin^2 \left(\frac{\lambda_2 - \lambda_1}{2} \right)} \right) \quad (2-6)$$

d คือระยะกระจัดระหว่าง 2 จุดบนทรงกลม (เมตร)

r คือรัศมีทรงกลม (เมตร)

φ_1, φ_2 คือค่าละติจูดของจุดที่ 1 และจุดที่ 2 ตามลำดับ (เรเดียน)

λ_1, λ_2 คือค่าลองจิจูดของจุดที่ 1 และจุดที่ 2 ตามลำดับ (เรเดียน)

2.4.2 การใช้รั้วภูมิศาสตร์กับโปรแกรมประยุกต์บนโทรศัพท์มือถือ

[15] ได้อธิบายความหมายของรั้วภูมิศาสตร์ (Geofence) ว่าเป็นการกำหนดเงื่อนไขการทำงานให้กับพื้นที่ทางภูมิศาสตร์ที่ล้อมรอบพิกัดของสถานที่ เพื่อทำการเรียกใช้การทำงานหากพิกัดของโทรศัพท์มือถือของผู้ใช้อาศัยอยู่ ภายในบริเวณที่กำหนด โดยมีการทำงานพื้นฐานดังนี้

1. สามารถรู้พิกัดของโทรศัพท์มือถือที่กำลังเคลื่อนที่
2. สามารถตรวจจับการเข้าออกจากบริเวณรั้วภูมิศาสตร์ได้อย่างอัตโนมัติ
3. ฟังก์ชันจะถูกเรียกใช้หากเงื่อนไขเป็นไปตามที่กำหนดไว้ ซึ่งเงื่อนไขอาจถูกกำหนดเมื่อเข้า-ออก หรืออยู่ภายในรั้วภูมิศาสตร์


รั้วภูมิศาสตร์ถูกใช้ในกลยุทธ์การตลาดของร้านค้า ด้วยการส่งการแจ้งเตือนไปยังโทรศัพท์มือถือของผู้ใช้อาศัยเมื่อเข้าสู่รั้วภูมิศาสตร์ ทำให้ผู้ใช้อาศัยได้รับรู้ถึงกิจกรรมส่งเสริมการขายที่จัดขึ้น ณ ขณะนั้น แนวคิดเดียวกันนี้ยังถูกประยุกต์ใช้กับการควบคุมอุปกรณ์ภายในอาคารอัจฉริยะ กล่าวคือ สามารถใช้เป็นสวิตช์จำลองเพื่อเปิดหรือปิดการทำงานของอุปกรณ์

2.5 การรับส่งข้อมูล

2.5.1 โพรโทคอล HTTP

[16] ได้อธิบายไว้ว่า HTTP (Hypertext Transfer Protocol) เป็นโพรโทคอลที่ใช้ในการสื่อสารระหว่างเซิร์ฟเวอร์ (Server) กับไคลเอนต์ (Client) ผ่านเครือข่ายอินเทอร์เน็ต โดยมีหลักการ

คือ ไคลเอนต์จะส่งคำขอ (HTTP Request) ไปที่เซิร์ฟเวอร์ ในทางกลับกันเซิร์ฟเวอร์มีหน้าตอบกลับไปที่ไคลเอนต์ (HTTP Response) ดังแสดงในรูปที่ 16



รูปที่ 16 การสื่อสารด้วย HTTP ระหว่างไคลเอนต์กับเซิร์ฟเวอร์

การสื่อสารด้วย HTTP เป็นการสื่อสารที่ไม่จดจำสถานะ (Stateless Protocol) กล่าวคือ ข้อมูลที่เกี่ยวข้องกับการเชื่อมต่อจะไม่ถูกบันทึกไว้ในหน่วยความจำ ทำให้ไม่มีภาระงานของเซิร์ฟเวอร์ในการจดจำข้อมูลของช่วงเวลา (session) ดังนั้น การสื่อสารระหว่างเซิร์ฟเวอร์กับไคลเอนต์จำนวนหลายอุปกรณ์จะมีประสิทธิภาพดีกว่าการสื่อสารแบบจดจำสถานะ (Stateful Protocol)

2.5.2 สถาปัตยกรรม REST

REST (Representational State Transfer) คือสถาปัตยกรรมการสื่อสารที่นิยมใช้ในบริการผ่านเว็บ (Web Service) ตั้งอยู่บนโพรโทคอล HTTP ทำหน้าที่เป็น เอพีไอ (Application Programming Interface; API)

REST ประกอบไปด้วยไคลเอนต์ และเซิร์ฟเวอร์ ซึ่งแยกส่วนกันอย่างอิสระ ทำให้สามารถพัฒนาส่วนของการแสดงผลบนหลายแพลตฟอร์มโดยไม่กระทบกับการทำงานของส่วนประมวลผล อีกทั้งยังสามารถลดความซับซ้อนของส่วนประมวลผลข้อมูลทำให้มีความยืดหยุ่นในการขยายขนาดของระบบ การสื่อสารระหว่าง 2 ส่วนอาศัยข้อความที่ส่งผ่านโพรโทคอล HTTP โดยคำขอที่มาจากไคลเอนต์จะต้องประกอบไปด้วย

1. เมธอด (Method) หรือคำสั่งที่ต้องการทำ
2. เฮดเดอร์ (Header) หรือส่วนที่ระบุข้อมูลที่เกี่ยวข้องกับคำขอ
3. เส้นทาง (Path) ไปยังที่เก็บข้อมูล
4. ตัวข้อความ (Body) ที่จะส่งไปพร้อมคำขอ เพื่อให้เซิร์ฟเวอร์นำไปใช้งาน

เมธอด (Method) ของ HTTP ที่ไคลเอนต์ใช้ในการส่งคำขอไปยังเซิร์ฟเวอร์เพื่อรับข้อมูลหรือเปลี่ยนแปลงข้อมูลในเซิร์ฟเวอร์ประกอบไปด้วย

1. GET – ทำหน้าที่ดึงข้อมูลจากเซิร์ฟเวอร์ (ข้อมูลที่ต้องการดึงถูกระบุด้วย ID)
2. POST – ทำหน้าที่สร้างข้อมูลใหม่บนเซิร์ฟเวอร์
3. PUT – ทำหน้าที่แก้ไขข้อมูลที่อยู่ในเซิร์ฟเวอร์ (ข้อมูลที่ต้องการแก้ไขถูกระบุด้วย ID)
4. DELETE – ทำหน้าที่ลบข้อมูลที่อยู่ในเซิร์ฟเวอร์ (ข้อมูลที่ต้องการลบถูกระบุด้วย ID)

2.6 การพัฒนาซอฟต์แวร์


เนื้อหาในส่วนนี้กล่าวถึงสถาปัตยกรรมที่ใช้ในการออกแบบซอฟต์แวร์ ภาษาและแพลตฟอร์มที่ใช้ในการพัฒนาซอฟต์แวร์ของงานวิจัยฉบับนี้

2.6.1 สถาปัตยกรรมไมโครเซอร์วิส

สถาปัตยกรรมไมโครเซอร์วิส (Microservice Architecture) เป็นการออกแบบระบบที่ประกอบไปด้วยบริการที่มีขนาดเล็ก และทำงานอย่างอิสระไม่ขึ้นต่อกัน เหตุผลที่แยกระบบออกเป็นบริการย่อยๆ นั้น เนื่องจากการพัฒนาโดยใช้สถาปัตยกรรมขนาดใหญ่ (Monolithic Architecture) มีปัญหาในการพัฒนา เมื่อระบบมีความซับซ้อนมากยิ่งขึ้น อีกทั้งการแก้ไขปรับปรุงส่วนใดส่วนหนึ่งอาจส่งผลกระทบต่อระบบในส่วนอื่นๆ ได้ ทำให้การเปลี่ยนแปลงเครื่องมือเพื่อรองรับเทคโนโลยีในอนาคตทำได้ยาก องค์ประกอบสำคัญในการพัฒนาไมโครเซอร์วิสคือ

1. เอพีไอ (Application Programming Interface; API) ทำหน้าที่เป็นช่องทางในการติดต่อสื่อสารระหว่างโปรแกรมหรือบริการ ซึ่งควรเลือก API ที่ไม่ได้มีความเฉพาะเจาะจงกับภาษาเช่น REST API
2. คอนเทนเนอร์ (Container) เป็นสิ่งแวดล้อมที่เอื้ออำนวยต่อการทำงานของแต่ละบริการ ซึ่งต้องใช้เครื่องมือจัดการ เช่น Docker Container

[17] ได้อธิบายการประยุกต์ใช้สถาปัตยกรรมแบบไมโครเซอร์วิสกับระบบอาคารอัจฉริยะดังแสดงในรูปที่ 17 ระบุว่า แต่ละเครื่องใช้ไฟฟ้าภายในอาคารอัจฉริยะสามารถทำงานได้อย่างอิสระด้วยไมโครเซอร์วิส เช่นภายในเครื่องชงกาแฟ มีไมโครเซอร์วิสที่ทำหน้าที่กำหนดปริมาณของส่วนผสมโดยอ้างอิงจากการบันทึกประวัติการใช้ของผู้อยู่อาศัย และข้อมูลใดๆ ที่เกี่ยวกับผู้อยู่อาศัยจะถูกบันทึกลงในฐานข้อมูลบนคลาวด์ นอกจากนี้ไมโครเซอร์วิสบนเครื่องใช้ไฟฟ้าแล้ว ไมโครเซอร์วิสยังสามารถใช้กับระบบวิเคราะห์พฤติกรรมของผู้อยู่อาศัยโดยอาศัยฐานข้อมูลบนคลาวด์ได้อีกด้วย



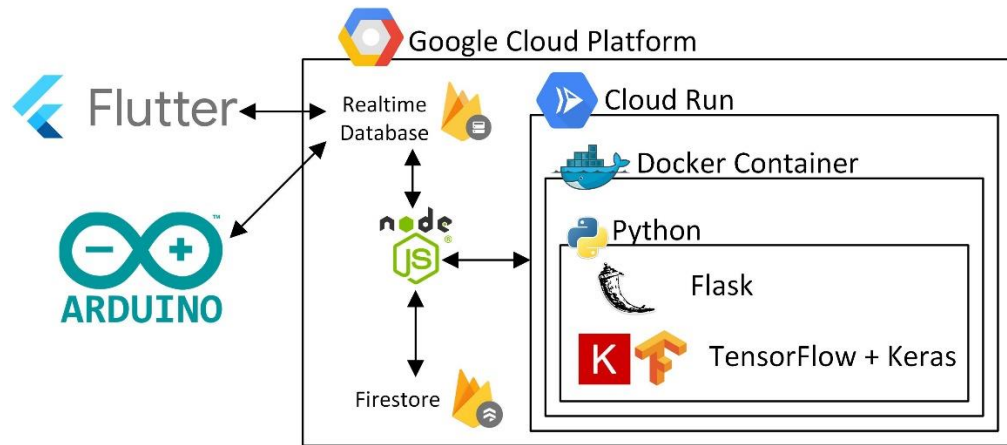
รูปที่ 17 ไมโครเซอร์วิสภายในบ้านอัจฉริยะ

2.6.2 ภาษาและแพลตฟอร์มที่ใช้ในการพัฒนา

บทความ [18] อธิบายไว้ว่าการประมวลผลบนคลาวด์ถูกใช้เป็นมาตรฐาน สำหรับการพัฒนาที่ต้องการความเร็ว และความยืดหยุ่นในการย่อหรือขยายระบบ โดยแพลตฟอร์มคลาวด์สามารถรองรับการทำงานในทุกๆด้าน เช่น การเก็บข้อมูล การเชื่อมต่อเครือข่าย การประมวลผล และการรักษาความปลอดภัย โดยผู้พัฒนาระบบไม่จำเป็นต้องลงทุนกับการติดตั้งระบบโครงสร้างพื้นฐาน และการบำรุงรักษาระบบดังกล่าว ด้วยความสามารถดังกล่าวแพลตฟอร์มคลาวด์จึงถูกประยุกต์ใช้กับระบบอุปกรณ์อินเทอร์เน็ตของสรรพสิ่งอย่างแพร่หลาย

ระหว่างผู้ให้บริการแพลตฟอร์มคลาวด์รายใหญ่ เช่น AWS, Microsoft Azure, Google Cloud Platform วิทยานิพนธ์ฉบับนี้เลือกพัฒนาสถาปัตยกรรมระบบบน Google Cloud Platform โดยเหตุผลที่เลือกใช้คือ ภายใน Google Cloud Platform มีแพลตฟอร์มการพัฒนาโปรแกรมประยุกต์ Firebase ซึ่งมีความเข้ากันได้ดีในการพัฒนาร่วมกับ เครื่องมือพัฒนาโปรแกรมประยุกต์บนโทรศัพท์มือถือคือ Flutter SDK (Software Development Kit) ที่สามารถพัฒนาโปรแกรมประยุกต์ที่ใช้งานได้ทั้งบนระบบปฏิบัติการ IOS และ Android นอกจากนี้ ใน Firebase ยังมีบริการระบบจัดเก็บข้อมูล Realtime Database และ Firestore ที่สามารถติดต่อสื่อสารกับบริการอื่นๆ ภายใน Google Cloud Platform ซึ่งวิทยานิพนธ์ฉบับนี้เล็งเห็นถึงประโยชน์ของการนำข้อมูลจากอุปกรณ์อินเทอร์เน็ตมาสังเคราะห์ความรู้ และนำความรู้ที่ได้ไปใช้งาน ซึ่งกระบวนการทั้งหมดสามารถทำได้บน Google Cloud Platform

ภาษาและแพลตฟอร์มที่ใช้ในการพัฒนาระบบในส่วนอุปกรณ์ปลายทาง ส่วนโปรแกรมประยุกต์บนโทรศัพท์มือถือ และส่วนระบบส่วนหลังบน Google Cloud Platform มีดังรูปที่ 18



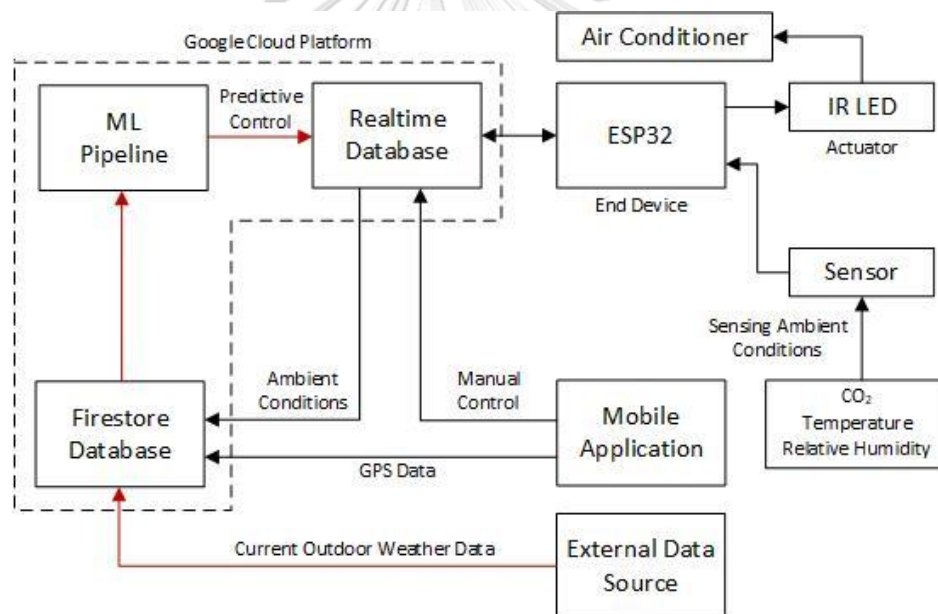
รูปที่ 18 ภาษาและแพลตฟอร์มที่ใช้ในการพัฒนา

บทที่ 3

สถาปัตยกรรมระบบควบคุมเครื่องปรับอากาศอัจฉริยะ

วิทยานิพนธ์ฉบับนี้นำเสนอระบบปรับอากาศอัจฉริยะ โดยสถาปัตยกรรมของระบบประกอบไปด้วย 6 องค์ประกอบดังรูปที่ 19 ซึ่งประกอบไปด้วย


1. อุปกรณ์ปลายทาง (End Device)
2. ฐานข้อมูลแบบเรียลไทม์ (Realtime Database; RTDB)
3. โปรแกรมประยุกต์บนโทรศัพท์มือถือ (Mobile Application)
4. คลาวด์ฟังก์ชัน (Cloud Function)
5. ฐานข้อมูลไฟร์สตอร์ (Firestore Database)
6. ขอบข่ายงานการเรียนรู้ของเครื่อง (ML Framework)



รูปที่ 19 สถาปัตยกรรมของระบบปรับอากาศอัจฉริยะ

3.1 อุปกรณ์ปลายทาง (End Device)

อุปกรณ์ปลายทางประกอบไปด้วยตัวรับรู้ (Sensor) ซึ่งทำหน้าที่รับข้อมูลทางกายภาพจากสิ่งแวดล้อมเพื่อบันทึกลงในฐานข้อมูล และอุปกรณ์ทำงาน (Actuator) ซึ่งทำหน้าที่ควบคุมเครื่องปรับอากาศโดยอาศัยข้อมูลที่ถูกประมวลผลในระบบ (Backend) หรือข้อมูลจากการสั่งงานโดยตรงของผู้ใช้ผ่านโปรแกรมประยุกต์บนโทรศัพท์มือถือ รูปที่ 20 แสดงแผนภาพองค์ประกอบย่อยของอุปกรณ์ปลายทาง โดยแต่ละองค์ประกอบย่อยมีรายละเอียดดังนี้



รูปที่ 20 แผนภาพองค์ประกอบย่อยของอุปกรณ์ปลายทาง

3.1.1 ไมโครคอนโทรลเลอร์ (Microcontroller)

ไมโครคอนโทรลเลอร์ที่เลือกใช้ในอุปกรณ์ปลายทางคือ ESP32 เนื่องจากมีความสามารถในการรองรับการเชื่อมต่อกับเครือข่ายผ่านสัญญาณวิทยุ และสามารถประมวลผลหลายภาระงาน (Multi-tasking) ในเวลาเดียวกัน ซึ่งทรัพยากรการประมวลผลของแต่ละภาระงาน (Task) จะถูกจัดสรรตามความสำคัญของภาระงาน (priority) โดยระบบปฏิบัติการแบบเรียลไทม์บนไมโครคอนโทรลเลอร์ (FreeRTOS) อีกทั้งยังสามารถตั้งค่าให้ภาระงานถูกแบ่งไปที่หน่วยประมวลผล (Microprocessor) ทั้ง 2 คอร์ (core) บน ESP32 เพื่อเพิ่มประสิทธิภาพในการประมวลผล จากเดิมที่ทำงานบน core เดียว ไฟเลี้ยงที่ใช้คือไฟเลี้ยงจากสาย USB ที่มีค่าความต่างศักย์ 5 VDC แต่ถูกแปลงให้มีค่าความต่างศักย์ 3.3 VDC ตามความต้องการของไมโครคอนโทรลเลอร์โดยวงจรรักษาระดับแรงดันในตัว (Built-in Voltage Regulator)

3.1.2 ตัวรับรู้ (Sensor)

วิทยานิพนธ์ฉบับนี้เลือกใช้ตัวรับรู้ SCD30 ซึ่งสามารถวัดปริมาณก๊าซคาร์บอนไดออกไซด์ได้ตั้งแต่ 400 ppm ถึง 10,000 ppm โดยมีค่าความคลาดเคลื่อนอยู่ระหว่าง $\pm (30 \text{ ppm} + 3\%)$ ของค่าที่วัดได้ สามารถวัดความชื้นสัมพัทธ์ (Relative Humidity; RH) ของอากาศตั้งแต่ 0%RH ถึง 100%RH โดยมีค่าความคลาดเคลื่อน $\pm 3\%$ และสามารถวัดอุณหภูมิได้ตั้งแต่ -40°C ถึง 70°C โดยมีค่าความคลาดเคลื่อนอยู่ระหว่าง $\pm (0.4^{\circ}\text{C} + 0.023 \times (\text{อุณหภูมิ } [^{\circ}\text{C}] - 25^{\circ}\text{C}))$


ค่าที่วัดได้จากตัวรับรู้จะถูกส่งไปที่ไมโครคอนโทรลเลอร์ผ่านการสื่อสารแบบ I2C ซึ่งใช้สายสัญญาณ 2 เส้นนั่นคือ สายสำหรับรับ-ส่งข้อมูล (Serial Data; SDA) และสายสัญญาณนาฬิกา (Serial Clock; SCL) ในการควบคุมการรับ-ส่งข้อมูล ตัวรับรู้ได้รับไฟเลี้ยงขนาด 3.3 VDC และกราวด์จากไมโครคอนโทรลเลอร์

3.1.3 อุปกรณ์ทำงาน (Actuator)

คำสั่งควบคุมเครื่องปรับอากาศที่ไมโครคอนโทรลเลอร์ได้รับผ่านสัญญาณวายฟายจะถูกมอดูเลตที่ความถี่ 38 กิโลเฮิร์ตซ์โดยชุดคำสั่งที่มีความเฉพาะเจาะจงกับยี่ห้อและรุ่นของเครื่องปรับอากาศ (วิทยานิพนธ์ฉบับนี้ทำการทดสอบบนเครื่องปรับอากาศชนิดซูบิชิ MU-SGD18V) สัญญาณที่ถูกปรับแล้วจะถูกส่งจากไมโครคอนโทรลเลอร์ไปยังอุปกรณ์ทำงานที่ใช้ในการควบคุมเครื่องปรับอากาศในการเปิด/ปิด เพิ่ม/ลดอุณหภูมิ และปรับความเร็วพัดลม นั่นคือ ไดโอดเปล่งแสงอินฟราเรด (IR LED) ที่ความยาวคลื่น 940 นาโนเมตร

3.1.4 การพัฒนาซอฟต์แวร์ควบคุมอุปกรณ์ปลายทาง

ซอฟต์แวร์ถูกพัฒนาขึ้นโดยแบ่งฟังก์ชันของการทำงานออกเป็นภาระงาน โดยอาศัยหลักการของการทำได้หลายงาน (Multi-tasking) และมีการขัดจังหวะ (Preemptibility) ของภาระงานที่ทำอยู่โดยภาระงานที่มีความสำคัญมากกว่า ภาระงานถูกกระจายไปยังหน่วยประมวลผลทั้ง 2 core ของไมโครคอนโทรลเลอร์ โดยที่ตัวเลขลำดับความสำคัญถูกเรียงจากมากไปน้อย นั่นคือจาก 3 ไป 1 ดังแสดงในรูปที่ 21



รูปที่ 21 ภาระงานของอุปกรณ์ปลายทาง


บนหน่วยประมวลผล core 0 ภาระงานที่มีความสำคัญที่สุด (ลำดับที่ 3) คือ การเก็บค่าสถานะแวดล้อมภายในห้องด้วยตัวรับรู้ ซึ่งไมโครคอนโทรลเลอร์จะทำการเก็บค่า และอัปเดตค่าตัวแปรตามค่าที่เก็บได้ทุกๆ 4 นาที ภาระงานที่มีความสำคัญลำดับที่ 2 คือการส่งข้อมูลไปเก็บในฐานข้อมูลบนคลาวด์ ซึ่งจะทำการจัดเก็บทุกๆ 4 นาทีเช่นเดียวกันกับการเก็บค่าสถานะแวดล้อมภายในห้องด้วยตัวรับรู้ และภาระงานที่มีความสำคัญน้อยที่สุด (ลำดับที่ 1) คือการรับข้อมูลการปรับเครื่องปรับอากาศมาจาก ฐานข้อมูลเรียลไทม์ (อธิบายในหัวข้อถัดไป) เนื่องจากเป็นภาระงานที่ทำหน้าที่สังเกตความเปลี่ยนแปลงของค่าตัวแปรในฐานข้อมูลอยู่ตลอดเวลา ดังนั้นหากกำหนดให้ลำดับความสำคัญมีค่าสูงจะทำให้ภาระงานอื่นๆ ถูกขัดจังหวะและไม่ได้ทำงาน ตามที่ได้ออกแบบไว้

บนหน่วยประมวลผล core 1 ภาระงานที่มีความสำคัญสูงสุด (ลำดับที่ 2) คือ การตรวจสอบการเชื่อมต่อสายพาย เนื่องจาก ระบบจะสามารถทำงานได้เฉพาะในกรณีที่อุปกรณ์ปลายทางเชื่อมต่อกับเครือข่ายอินเทอร์เน็ตเท่านั้น จึงมีความจำเป็นต้องตรวจสอบการเชื่อมต่อเป็นระยะๆ กล่าวคือทุกๆ 5 นาที หากถูกตัดการเชื่อมต่อ ไมโครคอนโทรลเลอร์จะทำการเชื่อมต่อไปยังเครือข่ายผ่านสัญญาณสายพายอีกครั้ง แต่ถ้าหากการเชื่อมต่อไม่สำเร็จเป็นระยะเวลา 60 วินาทีไมโครคอนโทรลเลอร์จะรีสตาร์ทตัวเอง ภาระงานถูกออกแบบให้มีลำดับความสำคัญเท่ากันนั่นคือ เมื่อได้รับข้อมูลมาจาก ฐานข้อมูลเรียลไทม์ ค่าตัวแปรที่ถูกอัปเดตจะส่งการให้ IR LED ส่งสัญญาณผ่านคลื่นรังสีอินฟราเรดไปยังเครื่องปรับอากาศเพื่อ เปิด/ปิด ปรับอุณหภูมิ และควบคุมความเร็วลมของเครื่องปรับอากาศ

3.2 ฐานข้อมูลแบบเรียลไทม์ (Real-time Database; RTDB)

ฐานข้อมูลแบบเรียลไทม์เป็นผลิตภัณฑ์ภายใต้ Google Cloud Platform ที่เก็บข้อมูลเชิงไม่สัมพันธ์ (Non-relational) และเป็นลำดับชั้น (Hierarchical) ในรูปแบบต้นไม้ของสายอักขระ JSON (JavaScript Object Notation) ซึ่งง่ายต่อการสื่อสารกับอุปกรณ์ปลายทาง และมีประสิทธิภาพดีในการเก็บข้อมูลซึ่งไม่ซับซ้อน เมื่อเกิดการเปลี่ยนแปลงขึ้นกับข้อมูลในฐานข้อมูล อุปกรณ์ที่ประสานเวลา (Synchronize) กับฐานข้อมูลซึ่งก็คืออุปกรณ์ปลายทาง จะรับรู้ถึงการเปลี่ยนแปลงในทันที วิทยานิพนธ์ฉบับนี้เลือกใช้ RTDB เป็นสื่อการในการแลกเปลี่ยนข้อมูลระหว่างอุปกรณ์ปลายทางกับระบบส่วนหลัง (Backend) และโปรแกรมประยุกต์บนโทรศัพท์มือถือ (Mobile Application) ดังแสดงในรูปที่ 22 โดยหลักการทำงานคือ ข้อมูลที่เก็บค่าโดยตัวรับรู้ของอุปกรณ์ปลายทางจะถูกส่งไปจัดเก็บในระบบ Backend บนคลาวด์ผ่าน RTDB ทุกๆ 4 นาที และในทางกลับกัน ผลลัพธ์จากการทำนายการเปิดปิดเครื่องปรับอากาศและความรู้สึกสบายเชิงความร้อนเพื่อใช้ในการตั้งค่าอุณหภูมิจะถูกส่งไปยังอุปกรณ์ปลายทางผ่าน RTDB และในกรณีที่ผู้อยู่อาศัยต้องการปรับเครื่องปรับอากาศเอง

คำสั่งจากโปรแกรมประยุกต์บนโทรศัพท์มือถือจะทำการอัปเดตข้อมูลใน RTDB ทำให้อุปกรณ์ปลายทางที่ประสานเวลากับ RTDB ได้รับข้อมูลใหม่และนำไปปรับเครื่องปรับอากาศโดย IR LED




รูปที่ 22 การรับส่งข้อมูลระหว่าง RTDB กับอุปกรณ์อื่นๆ

3.3 โปรแกรมประยุกต์บนโทรศัพท์มือถือ (Mobile Application)

วิทยานิพนธ์ฉบับนี้ ออกแบบโปรแกรมประยุกต์บนโทรศัพท์มือถือ ดังแสดงในรูปที่ 13 เพื่อใช้ตอบสนอง 3 วัตถุประสงค์นั้นคือ

1. เพื่อให้ผู้อยู่อาศัยสามารถปรับเครื่องปรับอากาศเอง (Manual Control) ในกรณีที่พฤติกรรมของผู้อยู่อาศัยเปลี่ยนไปจนทำให้อัลกอริทึมไม่สามารถทำนายความรู้สึกสบายเชิงความร้อนและพฤติกรรมการเปิด/ปิดเครื่องปรับอากาศได้อย่างแม่นยำ ซึ่งการพฤติกรรมการปรับเครื่องปรับอากาศของผู้อยู่อาศัยนี้ จะถูกบันทึกลงไปในฐานข้อมูล Firestore (อธิบายในหัวข้อถัดไป) เพื่อใช้ในการอัปเดตอัลกอริทึมให้มีความแม่นยำมากยิ่งขึ้น
2. เพื่อให้ผู้อยู่อาศัยสามารถตั้งค่าพิกัดของที่อยู่อาศัยลงในฐานข้อมูล Firestore โดยสามารถเลือกพิกัดได้จากแผนที่ โดยวิทยานิพนธ์ฉบับนี้ใช้ Maps SDK ซึ่งเป็นผลิตภัณฑ์ของบริษัท Google ในการพัฒนา นอกจากนี้ผู้อยู่อาศัยยังสามารถตั้งค่าตำแหน่งปัจจุบันของโทรศัพท์มือถือเป็นตำแหน่งของที่อยู่อาศัยได้อีกด้วย
3. เพื่อให้ผู้อยู่อาศัยสามารถเปิด/ปิด ระบบส่งพิกัดละติจูด และลองจิจูดปัจจุบันของโทรศัพท์มือถือไปยังฐานข้อมูล Firestore เพื่อใช้คำนวณหาระยะกระจัด (Displacement) ระหว่างผู้อยู่อาศัยกับที่อยู่อาศัย เพื่อใช้เป็นข้อมูลในการสร้างแบบจำลองการเปิด/ปิดเครื่องปรับอากาศโดยอัตโนมัติ

โปรแกรมประยุกต์บนโทรศัพท์มือถือที่แสดงในรูปแบบที่ ถูกพัฒนาขึ้นโดยใช้ *Flutter SDK* ที่ถูกพัฒนาขึ้นโดยบริษัท Google โดย Flutter เป็นเฟรมเวิร์คสำหรับการเขียนโปรแกรมประยุกต์บนโทรศัพท์มือถือด้วยภาษา Dart ซึ่งพัฒนาต่อมาจาก Javascript ที่รองรับทั้งระบบปฏิบัติการ IOS และ Android



รูปที่ 23 อินเทอร์เฟซของโปรแกรมประยุกต์บนโทรศัพท์มือถือ

3.4 คลาวด์ฟังก์ชัน (Cloud Function)

คลาวด์ฟังก์ชัน คือบริการที่ทำงานอยู่ในฝั่งเซิร์ฟเวอร์เพื่อใช้ในการติดต่อสื่อสารระหว่างบริการต่างๆ ภายในแพลตฟอร์ม Google Cloud วิทยานิพนธ์ฉบับนี้พัฒนาคลาวด์ฟังก์ชัน โดยใช้ NodeJS Runtime หรือสิ่งแวดล้อมในภาษา Javascript ที่ทำหน้าที่เป็นเว็บเซิร์ฟเวอร์ อัลกอริทึมที่ถูกพัฒนาภายในคลาวด์ฟังก์ชัน จะถูกเรียกใช้งาน (trigger) ด้วยวิธีต่างๆ วิทยานิพนธ์ฉบับนี้ได้ออกแบบการเรียกใช้งานคลาวด์ฟังก์ชันไว้ดังนี้

1. การเรียกใช้งานโดยการรีควีสต์ผ่านโปรโตคอล HTTPS ในกรณีการสร้างคลาวด์ฟังก์ชันเป็น rest API
2. การเรียกใช้งานเมื่อมีข้อมูลถูกแก้ไขภายในฐานข้อมูล
3. การเรียกใช้งานเมื่อไฟล์ถูกแก้ไขภายใน Cloud Storage

โดยรายละเอียดการทำงานจะถูกอธิบายอีกทีหนึ่งในแต่ละส่วนที่มีการประยุกต์ใช้คลาวด์ฟังก์ชัน

3.5 ฐานข้อมูลไฟร์สตอร์ (Firestore Database)

เช่นเดียวกับ RTDB ฐานข้อมูล Firestore เป็นฐานข้อมูลเชิงไม่สัมพันธ์ และเก็บข้อมูลเป็นลำดับขั้น แต่รูปแบบการจัดเก็บข้อมูลจะต่างกันนั่นคือ แทนที่จะเก็บข้อมูลในรูปแบบอักขระ JSON ฐานข้อมูล Firestore จะเก็บข้อมูลในรูปแบบ กลุ่ม (Collection) ซึ่งเปรียบเสมือนแฟ้มสำหรับเก็บเอกสาร (Document) และภายในเอกสารประกอบไปด้วยขอบเขตข้อมูล (data field) ที่ใช้ในการเก็บค่าของตัวแปรต่างๆ ดังแสดงในรูปที่ 24 ภายในเอกสารยังสามารถสร้างกลุ่มข้อมูลย่อย (Sub-collection) เพื่อเก็บเอกสารที่มีลำดับขั้นที่ลึกลงไป



รูปที่ 24 รูปแบบการจัดเก็บข้อมูลของฐานข้อมูล Firestore

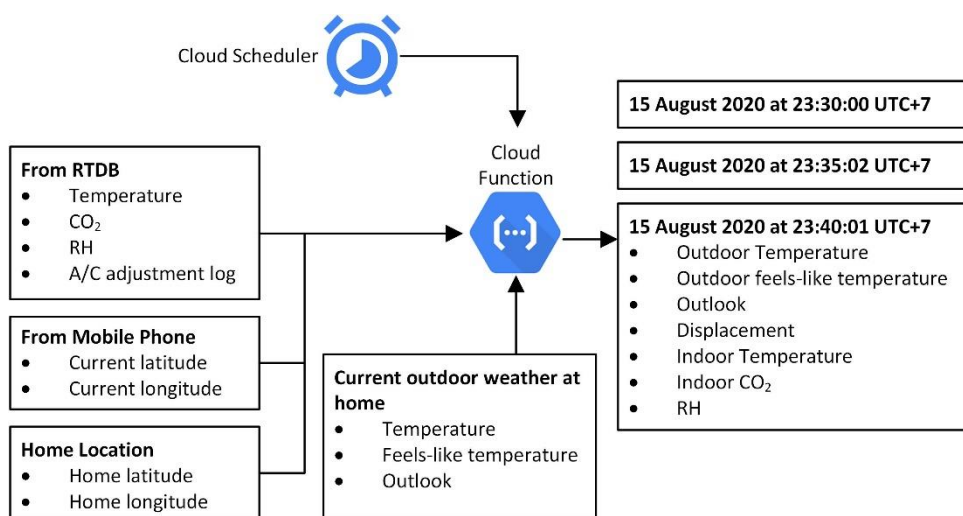
การเก็บข้อมูลในลักษณะนี้ทำให้ฐานข้อมูล Firestore สามารถจัดการกับข้อมูลที่มีความซับซ้อนสูง ซึ่งวิทยานิพนธ์ฉบับนี้เลือกใช้ Firestore ในการจัดเก็บข้อมูล โดยแบ่งกลุ่มข้อมูลตามบัญชีของผู้อยู่อาศัย (User Account) ภายในกลุ่มข้อมูลของผู้อยู่อาศัยแต่ละรายประกอบไปด้วยเอกสาร ซึ่งก็คือข้อมูลที่ได้รับจากอุปกรณ์ปลายทาง ข้อมูลพิกัดปัจจุบันที่ได้รับจากโปรแกรมประยุกต์บนโทรศัพท์มือถือ ข้อมูลพิกัดที่อยู่อาศัย และ ข้อมูลรวมที่ทำการจัดเก็บข้อมูลที่ได้จากแหล่งต่างๆ รวมลงไปในระยะเบี่ยงทุกๆ 5 นาทีโดยใช้ตัวบีมเวลา (timestamp) เป็นดัชนี

การจัดเก็บข้อมูลลงบนระยะเบี่ยงทำได้โดยการใช้ตัวกำหนดตารางเวลาในคลาวด์ (Cloud Scheduler) ในการเรียกใช้งาน API โดยการรีควีสต์ผ่านโพรโทคอล HTTPS ไปยังคลาวด์ฟังก์ชันทุกๆ 5 นาที เมื่อได้รับรีควีสต์ คลาวด์ฟังก์ชันจะทำหน้าที่รวบรวม

1. ข้อมูลสภาวะแวดล้อมภายในห้อง และข้อมูลการปรับเครื่องปรับอากาศ จาก RTDB
2. ข้อมูลพิกัดปัจจุบันของโทรศัพท์มือถือ
3. ข้อมูลพิกัดของที่อยู่อาศัยที่ทำการตั้งค่าผ่านโปรแกรมประยุกต์ในโทรศัพท์มือถือ
4. ข้อมูลสภาพอากาศภายนอกที่อยู่อาศัย ทราบค่าได้จากการส่งรีควีสต์ผ่านโพรโทคอล HTTPS ไปยังผู้ให้บริการข้อมูลสภาพอากาศ (openweathermap.org) ด้วยพิกัดของที่อยู่อาศัยเป็น

เนื้อหาของการรีควีสต์ จากนั้นจะได้รับการตอบกลับจากผู้ให้บริการข้อมูล ซึ่งข้อมูลที่ทำการเก็บในระเบียบนี้คือ อุณหภูมิภายนอก อุณหภูมิภายในที่รู้สึก และ สภาพอากาศ 4 รูปแบบ คือ สดใส มีเมฆมาก ฝนตก และมีพายุฝน

ข้อมูลที่ถูกรวบรวมแล้วถูกบันทึกลงในกลุ่มข้อมูลย่อย ที่ทำหน้าที่เก็บเอกสารใหม่ทุกๆ 5 นาที โดยชื่อของเอกสารคือดัชนี หรือ ตัวปัดเวลา ดังแสดงในรูปที่ 25



รูปที่ 25 การรวบรวมข้อมูลลงในระเบียบที่มีดัชนีเป็นตัวปัดเวลา

3.6 ขอบข่ายงานการเรียนรู้ของเครื่อง (Machine Learning Framework)

ขอบข่ายงานการเรียนรู้ของเครื่องคือการดำเนินการวิเคราะห์เพื่อปรับปรุงแบบจำลองการเรียนรู้ของเครื่องอย่างอัตโนมัติ ดังแสดงในรูปที่ 26 ตั้งแต่กระบวนการโหลดข้อมูลมาใช้ในการวิเคราะห์ จนกระทั่งกระบวนการนำแบบจำลองการทำงานมาใช้งานจริง เพื่อให้สอดคล้องกับพฤติกรรมและความรู้สึกสบายเชิงความร้อนที่เปลี่ยนไปของผู้อยู่อาศัย

ก่อนที่จะประยุกต์ใช้ขอบข่ายงานการเรียนรู้ของเครื่อง วิทยานิพนธ์ฉบับนี้ทำการเก็บข้อมูลของผู้อยู่อาศัยเป็นระยะเวลา 2 เดือนเพื่อทำการวิเคราะห์ ซึ่งรายละเอียดของการวิเคราะห์แบบจำลองจะถูกอธิบายในบทถัดไป เมื่อได้แบบจำลองดังกล่าว และสเกลเลอร์ (Scaler) ไฟล์ทั้งสองชนิดจะถูกเก็บลงไปในพื้นที่เก็บข้อมูลที่เกี่ยวข้องกับแบบจำลองที่ได้จัดสรรไว้ใน Cloud Storage เพื่อใช้งานจริง

3.6.1 API การทำนายด้วยโมเดลการเรียนรู้ของเครื่อง

ในการควบคุมเครื่องปรับอากาศ ข้อมูลปัจจุบัน (ข้อมูลล่าสุด) ที่ถูกจัดเก็บลงในฐานข้อมูล Firestore จะถูกใช้เป็นข้อมูลขาเข้าของการทำนาย ซึ่งแบบจำลองการเปิด/ปิดเครื่องปรับอากาศ และแบบจำลองความรู้สึกลบสบายเชิงความร้อน จะทำงานอย่างอิสระบน Cloud Run หรือผลิตภัณฑ์ของบริษัท Google ที่ใช้เป็นแพลตฟอร์มการประมวลผลบนคลาวด์ โดยซอฟต์แวร์ที่สามารถทำงานใน Cloud Run จะต้องเป็นไมโครเซอร์วิส (Microservice) ที่ถูกบรรจุลงในคอนเทนเนอร์ (Container) ที่พัฒนาด้วย Docker

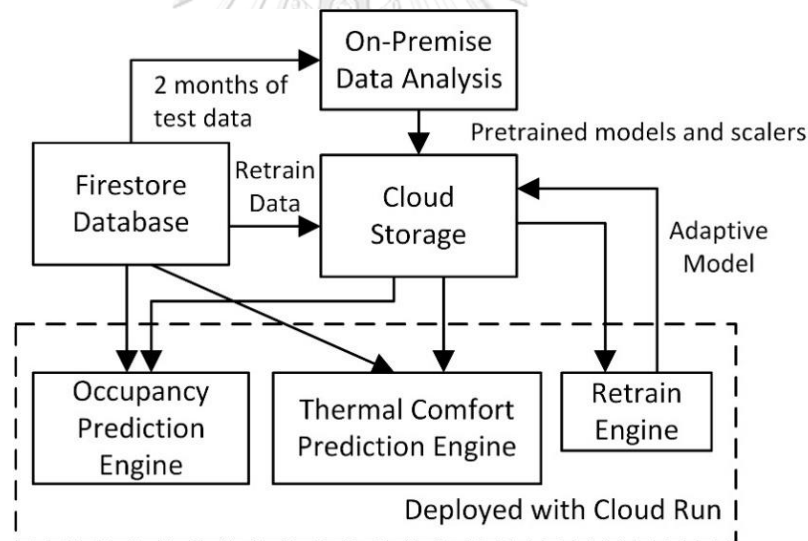
วิทยานิพนธ์ฉบับนี้พัฒนา API ของซอฟต์แวร์ทำนายดังกล่าวโดยใช้ Flask หรือขอบข่ายงานไมโครเว็บ (Microweb Framework) ในภาษา Python ซึ่งขั้นตอนการทำงานของซอฟต์แวร์มีดังต่อไปนี้

1. ทุกๆ 5 นาที ตัวกำหนดตารางเวลาในคลาวด์ จะทำการเรียกใช้งานคลาวด์ฟังก์ชัน โดยการรีควีสต์ผ่านโปรโตคอล HTTPS
2. คลาวด์ฟังก์ชันจะทำการรีควีสต์ผ่านโปรโตคอล HTTPS ไปยัง API ของซอฟต์แวร์ทำนายใน Cloud Run
3. ซอฟต์แวร์เรียกใช้แบบจำลอง และสเกเลอร์จาก Cloud Storage
4. ซอฟต์แวร์รับข้อมูลล่าสุดจากฐานข้อมูล Firestore
5. ซอฟต์แวร์ทำการปรับข้อมูลใหม่ให้มีการกระจายตัวเหมือนกับข้อมูลชุดฝึก ด้วยสเกเลอร์
6. ซอฟต์แวร์นำข้อมูลที่ถูกรับแล้วมาทำนาย
7. ซอฟต์แวร์ตอบผลเฉลยการทำนายเป็น HTTP Response ไปยังคลาวด์ฟังก์ชัน
8. คลาวด์ฟังก์ชันทำการอัปเดตค่าใน RTDB เพื่อปรับเครื่องปรับอากาศ

3.6.2 การรีเทรนแบบจำลอง (Model Retrain)

เนื่องจากพฤติกรรม และความรู้สึกลบสบายเชิงความร้อนของผู้อยู่อาศัยมีความแตกต่างกันอยู่กับตัวบุคคล แต่ถึงแม้จะเป็นผู้อยู่อาศัยคนเดิม พฤติกรรมและความรู้สึกอาจเปลี่ยนแปลงไปได้จึงมีความจำเป็นที่จะต้องปรับปรุงแบบจำลอง เพื่อป้องกันไม่ให้ประสิทธิภาพของการทำนายลดลง หลักการปรับปรุงแบบจำลอง คือนำข้อมูลชุดใหม่ ซึ่งในวิทยานิพนธ์ฉบับนี้ใช้ข้อมูลที่เก็บได้ทุกๆ 2 สัปดาห์ ในการรีเทรน เพื่อปรับค่าถ่วงน้ำหนักของแบบจำลอง เช่นเดียวกับซอฟต์แวร์ที่ใช้ในการทำนาย ซอฟต์แวร์ที่ใช้ในการรีเทรนทำงานบน Cloud Run โดยมีขั้นตอนการทำงานดังต่อไปนี้

1. ทุกๆ 2 สัปดาห์ ตัวกำหนดตารางเวลาในคลาวด์ จะส่งรีควีสต์ผ่านโปรโตคอล HTTPS ไปยังคลาวด์ฟังก์ชันเพื่อทำการโหลดข้อมูลที่ถูกสะสมภายในฐานข้อมูล Firestore ออกมาเป็นไฟล์นามสกุล CSV (Comma Separated Value) และนำไปเก็บในพื้นที่เก็บข้อมูลเพื่อใช้ในการรีเทรนที่ได้จัดสรรไว้ใน Cloud Storage
2. เมื่อข้อมูลใหม่ได้ถูกบันทึกลงใน Cloud Storage ในขั้นที่ 1 เป็นที่เรียบร้อย Cloud Function ซึ่งคอยสังเกตการเปลี่ยนแปลงที่เกิดขึ้นกับ Cloud Storage ในส่วนนี้ จะทำการรีควีสต์ผ่านโปรโตคอล HTTP ไปยังซอฟต์แวร์ใน Cloud Run
3. ซอฟต์แวร์เรียกใช้แบบจำลอง และสเกลเลอร์จาก Cloud Storage
4. ซอฟต์แวร์ทำการปรับข้อมูลใหม่ให้มีการกระจายตัวเหมือนกับข้อมูลชุดฝึก ด้วยสเกลเลอร์
5. ซอฟต์แวร์พิดข้อมูลใหม่เข้ากับแบบจำลองเพื่อปรับค่าถ่วงน้ำหนัก
6. ซอฟต์แวร์บันทึกแบบจำลองที่ถูกปรับค่าถ่วงน้ำหนักแล้วเพื่อใช้ในการทำนาย




รูปที่ 26 การทำงานของแบบจำลองที่ถูกสร้างเป็นไมโครเซอร์วิสภายในคอนเทนเนอร์

บทที่ 4

แบบจำลองการเรียนรู้ของเครื่อง

วิทยานิพนธ์ฉบับนี้ประยุกต์ใช้การเรียนรู้ของเครื่องในการสร้างแบบจำลองเพื่อควบคุมเครื่องปรับอากาศอย่างอัตโนมัติ โดยการออกแบบการจัดเก็บข้อมูลนั้นจำเป็นต้องวิเคราะห์เพื่อหาพารามิเตอร์ที่มีความเกี่ยวข้องกับฟังก์ชันเป้าหมาย (Target Function) จากนั้นใช้วิธีการของการเรียนรู้ของเครื่อง เพื่อหาแบบจำลองที่ใช้อธิบายความสัมพันธ์ระหว่างพารามิเตอร์ที่เกี่ยวข้องกับฟังก์ชันเป้าหมายนั้นอีกทีหนึ่ง กระบวนการการเรียนรู้ของเครื่องประกอบไปด้วยขั้นตอนตั้งแต่การดึงข้อมูลในรูปแบบไฟล์ CSV (Comma Separated Value) ที่เก็บเป็นระยะเวลา 2 เดือนมาจากฐานข้อมูล Firestore เพื่อใช้วิเคราะห์หาแบบจำลองเริ่มต้น (Pre-trained Model) จนถึงการนำแบบจำลองเริ่มต้นนั้นไปใช้งาน ดังแสดงในรูปที่ 27



รูปที่ 27 กระบวนการการเรียนรู้ของเครื่อง

4.1 แบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย

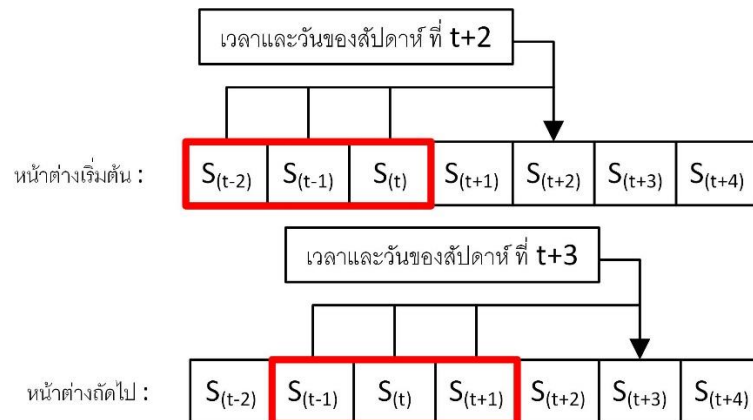
แบบจำลองนี้ถูกสร้างขึ้นโดยมีวัตถุประสงค์คือ ทำการทำนายเพื่อสั่งการเปิดเครื่องปรับอากาศก่อนที่ผู้อยู่อาศัยจะกลับถึงบ้าน เพื่อลดอุณหภูมิห้องจนถึงสภาวะสบายเชิงความร้อนของผู้อยู่อาศัย ขณะที่ผู้อยู่อาศัยเข้ามาภายในห้อง

วิทยานิพนธ์ฉบับนี้กำหนดระยะเวลาการทำนายว่าให้ระบบทำการเปิดเครื่องปรับอากาศก่อนที่ผู้อยู่อาศัยจะมาถึงเป็นระยะเวลา 10 นาที ซึ่งระยะเวลานี้ถูกกำหนดขึ้นโดยคำนึงถึง ความแม่นยำของแบบจำลอง ประสิทธิภาพในการปรับอุณหภูมิของเครื่องปรับอากาศ ความรู้สึกสบายเชิงความร้อนขณะเข้ามาในห้องของผู้อยู่อาศัย และการประหยัดพลังงาน

4.1.1 พารามิเตอร์ของแบบจำลอง

วิทยานิพนธ์ฉบับนี้มีแนวคิดการเลือกพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองเพื่อทำนายการกลับมาถึงของผู้อยู่อาศัยในอนาคต โดยพิจารณาระยะการจัดระหว่างผู้อยู่อาศัยกับบ้าน ณ เวลาปัจจุบันและอดีต ควบคู่กับกิจวัตรประจำวันของผู้อยู่อาศัย ซึ่งกิจวัตรประจำวันเป็นพารามิเตอร์ที่เก็บค่าไม่ได้ แต่สามารถอนุมานได้คร่าวๆจากเวลา และวันของสัปดาห์ เช่น ผู้อยู่อาศัยอาจกลับถึงบ้านเป็นเวลา 6 โมงเย็นในทุกๆวันยกเว้นวันศุกร์เย็นที่การจราจรหนาแน่น อาจใช้เวลานานกว่าปกติในการเดินทาง เมื่อแบบจำลองสามารถเรียนรู้รูปแบบของพฤติกรรมมาถึงดังกล่าวของผู้อยู่อาศัยแล้ว จะทำให้สามารถสั่งการเพื่อเปิดเครื่องปรับอากาศ ได้อย่างมีประสิทธิภาพมากกว่า การเปิดเครื่องปรับอากาศโดยการตั้งเวลา หรือการใช้รั้วภูมิศาสตร์

ข้อมูลที่ใช้งานถูกแบ่งเป็นขั้นเวลา (timestep) ตามดัชนีของข้อมูลในฐานข้อมูลนั้นคือ ขั้นละ 5 นาที เมื่อต้องการทำนายการมาถึงหรือระยะการจัดระหว่างผู้อยู่อาศัยกับบ้านที่ขั้น เวลา $t+2$ ใน 10 นาทีข้างหน้า (S_{t+2}) วิทยานิพนธ์ฉบับนี้เลือกใช้ระยะการจัด ณ เวลาปัจจุบัน $S_{(t)}$ ที่ขั้นเวลาย้อนหลัง 2 ขั้นเวลาจากเป้าหมายของการทำนาย และระยะการจัดในอดีต เมื่อ 5 นาทีก่อนหน้านี้ $S_{(t-1)}$ และ 10 นาทีก่อนหน้านี้ $S_{(t-2)}$ พารามิเตอร์ทั้ง 3 ถูกนำไปใช้ควบคู่กับเวลาและวันของสัปดาห์ ในหน้าต่างเลื่อน (Sliding Window) เพื่อทำนายการมาถึงของผู้อยู่อาศัย ใน 10 นาทีข้างหน้า ทุกๆขั้นเวลาของอนุกรมเวลา (Time Series) ดังแสดงในรูปที่ 28 สาเหตุที่ใช้ระยะการจัดจาก 3 ขั้นเวลาเนื่องจาก ข้อมูล 3 ขั้นเวลา ครอบคลุมช่วงเวลา 10 นาทีของการเดินทาง ซึ่งเพียงพอต่อการอธิบายแนวโน้มว่าผู้อยู่อาศัยจะกลับมาถึงที่พักหรือไม่ในอีก 10 นาทีข้างหน้าได้



รูปที่ 28 หน้าต่างเลื่อนของพารามิเตอร์ในแต่ละชั้นเวลา

4.1.2 การเตรียมข้อมูล

จากขั้นตอนการเลือกพารามิเตอร์ 5 พารามิเตอร์ประกอบไปด้วยระยะกระจัดระหว่างผู้อยู่อาศัยกับบ้าน เมื่อ 10 นาทีก่อน 5 นาทีก่อน และปัจจุบัน รวมทั้งเวลาและวันของสัปดาห์ ถูกใช้ในการสร้างแบบจำลอง อย่างไรก็ตาม วันและเวลาของสัปดาห์ซึ่งเป็นพารามิเตอร์ที่มีค่าวนซ้ำจะถูกเปลี่ยนให้อยู่ในรูปค่าที่มีความต่อเนื่องแบบเป็นวัฏจักร (Cyclic Continuous Value) ด้วยการทำให้ค่าที่มี 1 มิติกลายเป็นค่า 2 มิติ และใช้หลักการของการหมุนรอบจุดศูนย์กลางของวงกลมในการแสดงค่าดังกล่าว ดังสมการที่ 4-1 และ 4-2 ตามลำดับ

$$h1, h2 = \sin\left(\frac{h}{24} \cdot 2\pi\right), \cos\left(\frac{h}{24} \cdot 2\pi\right) \quad (4-3)$$

$$d1, d2 = \sin\left(\frac{d}{24} \cdot 2\pi\right), \cos\left(\frac{d}{24} \cdot 2\pi\right) \quad (4-4)$$

$h1, h2$ คือตัวแปรในสองมิติของพารามิเตอร์ชั่วโมงใน 1 วัน

$d1, d2$ คือตัวแปรในสองมิติของพารามิเตอร์วันใน 1 สัปดาห์

โดยสรุปแล้วจะสามารถสร้างความสัมพันธ์ของพารามิเตอร์กับฟังก์ชันเป้าหมาย นั่นคือระยะกระจัดใน 10 นาทีข้างหน้า ได้ดังสมการที่ 4-3

$$S_{t+2} = f(S_{t-2}, S_{t-1}, S_t, h1, h2, d1, d2) \quad (4-3)$$

ข้อมูลดังกล่าวจะถูกใช้ในการฝึกสอนแบบจำลอง ทั้งนี้ทั้งนั้น แบบจำลองจะมองว่าพารามิเตอร์ที่มีพิสัยมากกว่าว่าเป็นพารามิเตอร์ที่มีการเปลี่ยนแปลงมากกว่า ซึ่งส่งผลกระทบต่อกระบวนการปรับค่าถ่วงน้ำหนักของแบบจำลอง ปัญหานี้ถูกแก้ไขได้ด้วยวิธีการปรับพารามิเตอร์แต่ละตัวเป็นค่ามาตรฐาน (Standardization) โดยมีค่าเฉลี่ยเป็น 0 และมีค่าส่วนเบี่ยงเบนมาตรฐานเป็น 1

4.1.3 การแบ่งชุดข้อมูล

ข้อมูลที่เกี่ยวข้องรวมไว้ในฐานข้อมูลเป็นระยะเวลา 2 เดือนถูกใช้ในการพัฒนาแบบจำลองโดยข้อมูลทั้งหมดในส่วนนี้ถูกแบ่งเป็นข้อมูลชุดทดสอบ จำนวน 20 เปอร์เซ็นต์ และที่เหลือนั้นถูกใช้เป็นข้อมูลชุดฝึกสอน

4.1.4 การฝึกสอนแบบจำลอง

โครงสร้างประสาทถูกเลือกใช้ในการพัฒนาแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย เนื่องจากข้อมูลชุดฝึกสอน มีจำนวนประมาณ 13,000 ข้อมูล ซึ่งมากพอสำหรับอัลกอริทึมที่ต้องการจำนวนข้อมูลมากในการสร้างแบบจำลอง

วิทยานิพนธ์ฉบับนี้ใช้วิธีการครอสวาไลเดชันในการเลือกแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย โดยข้อมูลชุดฝึกสอนจะถูกแบ่งอีกรอบหนึ่งเป็นชุดที่มีขนาดเท่ากันจำนวน 5 ชุด และในแต่ละครั้งของการฝึกสอน จะใช้ข้อมูล 4 ชุดในการฝึกสอน และอีก 1 ชุดที่เหลือในการตรวจสอบกระบวนการนี้ถูกวนซ้ำจนแบบจำลองถูกตรวจสอบด้วยข้อมูลครบทั้ง 5 ชุด ค่าความแม่นยำเฉลี่ยของทั้ง 5 ชุดจะใช้เป็นตัววัดประสิทธิภาพของแบบจำลองนั้นๆ แบบจำลองที่ถูกประเมินประสิทธิภาพโดยวิธีนี้เป็นแบบจำลองโครงสร้างประสาทเทียมที่ประกอบไปด้วยจำนวนเซลล์ประสาท จำนวนชั้นของโครงสร้างประสาท และออปติไมเซอร์ (Optimizer) ที่แตกต่างกัน จำนวน 20 ชุด

4.1.5 การตรวจสอบแบบจำลอง

แบบจำลองที่มีไฮเปอร์พารามิเตอร์ที่แตกต่างกันทั้งหมด 20 ชุดถูกฝึกสอนด้วยข้อมูลชุดฝึกสอนทั้งหมดดังวิธีที่ได้กล่าวไปในขั้นตอนก่อนหน้า ผลลัพธ์ค่าความแม่นยำเฉลี่ยจากกระบวนการครอสวาไลเดชันของแต่ละชุดไฮเปอร์พารามิเตอร์ถูกแสดงในตารางที่ 3 ซึ่งจากการสังเกตจะพบว่า ชุดไฮเปอร์พารามิเตอร์ลำดับที่ 8 สามารถให้ค่าความแม่นยำเฉลี่ยโดยวิธีครอสวาไลเดชันที่สูงที่สุด นั่นคือ 96.5% ดังนั้นชุดไฮเปอร์พารามิเตอร์ลำดับที่ 8 นี้จะถูกใช้ในการสร้างแบบจำลองในการทำนายการมาถึงของผู้อยู่อาศัย

ตารางที่ 3 แสดงชุดของไฮเปอร์พารามิเตอร์ของแบบจำลองที่ทำการตรวจสอบ

ลำดับ	ออปติไมเซอร์	เซลล์ประสาทในแต่ละชั้น (ฟังก์ชันกระตุ้น)	ค่าความแม่นยำเฉลี่ยทุกชุดตรวจสอบ
1	SGD	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	95.9%
2	RMSprop	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.1%
3	Adadelta	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	95.7%
4	Adagrad	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.0%
5	Adamax	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.1%
6	Nadam	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.2%
7	Ftrl	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.1%
8	Adam	5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.5%
9	Adam	5(ReLU):5(ReLU):5(ReLU):2(Softmax)	96.3%
10	Adam	10(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.1%
11	Adam	5(ReLU):5(ReLU):2(Softmax)	96.0%
12	Adam	5(ReLU):5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.2%
13	Adam	10(ReLU):5(ReLU):5(ReLU):5(Softmax):2(Softmax)	96.1%
14	Adam	4(ReLU):4(ReLU):4(Softmax):2(Softmax)	96.0%
15	Adam	5(ReLU):4(ReLU):4(Softmax):2(Softmax)	95.8%
16	Adam	6(ReLU):5(ReLU):5(Softmax):2(Softmax)	95.2%
17	Adam	6(ReLU):6(ReLU):5(Softmax):2(Softmax)	96.4%
18	Adam	6(ReLU):5(ReLU):6(Softmax):2(Softmax)	96.1%
19	Adam	7(ReLU):5(ReLU):5(Softmax):2(Softmax)	95.9%
20	Adam	8(ReLU):5(ReLU):5(Softmax):2(Softmax)	95.6%

4.1.6 การประเมินแบบจำลอง

แบบจำลองที่ถูกฝึกสอนขึ้นจากขั้นตอนก่อนหน้าถูกนำมาทดสอบด้วยข้อมูล 20% ที่ถูกแบ่งไว้เป็นข้อมูลชุดทดสอบ ผลที่ได้คือสามารถทำนายการมาถึงของผู้โดยสารได้ด้วยความแม่นยำ 94.5%

4.2 แบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน

วิทยานิพนธ์ฉบับนี้พัฒนาแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน โดยมีวัตถุประสงค์คือการปรับอุณหภูมิของเครื่องปรับอากาศอย่างอัตโนมัติ ให้สอดคล้องกับความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย

การกำหนดฟังก์ชันเป้าหมายเพื่อทำการระบุความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย ภายใต้สภาวะแวดล้อมปัจจุบันของห้องทำได้โดย การแบ่งความรู้สึกของผู้อยู่อาศัยออกเป็น 3 กลุ่ม คือ รู้สึกร้อนเกินไป รู้สึกหนาวเกินไป และรู้สึกพอดี ซึ่งวิทยานิพนธ์ฉบับนี้ทำการแบ่งข้อมูลออกเป็น 3 กลุ่มดังกล่าว โดยการเก็บค่าการปรับอุณหภูมิเครื่องปรับอากาศในชั้นเวลาปัจจุบันเทียบกับค่าการปรับอุณหภูมิเครื่องปรับอากาศในชั้นเวลาก่อนหน้า (ประวัติการปรับเครื่องปรับอากาศผ่าน RTDB จะถูกเก็บไว้ในระเบียบของฐานข้อมูล Firestore) อัลกอริทึมที่ใช้ในการกำหนดความรู้สึกดังกล่าวแสดงด้วยซูโคโคดในตารางที่ 4

ตารางที่ 4 ซูโคโคดแสดงการทำงานของอัลกอริทึมการระบุความรู้สึกสบายเชิงความร้อน

<p>เมื่อ t คือชั้นเวลา ปัจจุบัน</p> <p>If สถานะเครื่องปรับอากาศ == เปิด:</p> <p style="padding-left: 40px;">If ค่าอุณหภูมิที่ผู้อยู่อาศัยปรับที่ชั้นเวลา t > ค่าอุณหภูมิที่ผู้อยู่อาศัยปรับที่ชั้นเวลา t-1:</p> <p style="padding-left: 80px;">ความรู้สึกเชิงความร้อน = “หนาวเกินไป”</p> <p style="padding-left: 40px;">Elif ค่าอุณหภูมิที่ผู้อยู่อาศัยปรับที่ชั้นเวลา t < ค่าอุณหภูมิที่ผู้อยู่อาศัยปรับที่ชั้นเวลา t-1:</p> <p style="padding-left: 80px;">ความรู้สึกเชิงความร้อน = “ร้อนเกินไป”</p> <p style="padding-left: 40px;">Else:</p> <p style="padding-left: 80px;">ความรู้สึกเชิงความร้อน = “พอดี”</p>

4.2.1 พารามิเตอร์ของแบบจำลอง

มาตรฐาน ANSI/ASHRAE 55-2004 [6] ได้ระบุไว้ถึงปัจจัย 6 อย่างที่มีผลต่อความรู้สึกสบายเชิงความร้อน แต่มีเพียงอุณหภูมิของอากาศ และความชื้นสัมพัทธ์เท่านั้นที่สามารถเก็บค่าได้โดยตรงผ่านตัวรับรู้ที่มีราคาถูก ซึ่งเหมาะสมกับการพัฒนาเป็นผลิตภัณฑ์

ทั้งนี้ทั้งนั้นพารามิเตอร์อื่นๆที่ไม่สามารถเก็บค่าได้โดยตรงยังสามารถอนุมานได้คร่าวๆจากข้อมูลอื่นๆ นั่นคือ อัตราเมตาบอลิซึมซึ่งเป็นอัตราที่มีความสัมพันธ์กับกิจกรรมของผู้อยู่อาศัยตลอดทั้งวัน ดังนั้น เวลา และวันของสัปดาห์สามารถอธิบายถึงรูปแบบการเปลี่ยนแปลงของกิจกรรมที่ส่งผล

กระทบต่ออัตราเมตาบอลิซึม ณ ขณะนั้น หรือแม้แต่การใส่เสื้อผ้าของผู้อยู่อาศัยได้ นอกจากนี้ เวลาใน 1 วัน สามารถใช้ในการอธิบายรูปแบบของอุณหภูมิการแผ่รังสีความร้อนเฉลี่ยได้ เนื่องจากเวลามีความสัมพันธ์กับ ทิศทาง และปริมาณแสงอาทิตย์ที่กระทบบนบ้าน แต่ในความเป็นจริงแล้วนอกจากปัจจัยจากผู้อยู่อาศัย และสภาวะแวดล้อมภายในห้องแล้ว [19] ยังได้อธิบายว่าสภาวะแวดล้อมภายนอกอาคารมีผลต่อความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัยอีกด้วย ดังนั้น วิทยานิพนธ์ฉบับนี้จึงได้นำ อุณหภูมิภายนอกอาคาร อุณหภูมิที่รู้สึกภายนอกอาคาร และ สภาพอากาศ 4 ประเภท ได้แก่ แดดออก (Sunny) เมฆคลุ้ม (Cloudy) ฝนตก (Rainy) และ พายุฝน (Thunderstorm) จากบริการสภาพอากาศมาใช้ควบคู่กับ พารามิเตอร์ที่เก็บได้จากอุปกรณ์ปลายทาง ปริมาณก๊าซคาร์บอนไดออกไซด์ที่เก็บได้จากตัวรับรู้ ไม่มีความเกี่ยวข้องกับการอธิบายสภาวะเชิงความร้อนโดยตรง แต่สามารถใช้ในการประมาณจำนวนผู้อยู่อาศัยภายในห้อง ณ ขณะนั้นได้

4.2.2 การเตรียมข้อมูล

เวลาและวันในสัปดาห์ถูกปรับให้เป็นค่า 2 มิติ เช่นเดียวกับแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย และในบางกรณี ไมโครคอนโทรลเลอร์ของอุปกรณ์ปลายทางจะทำการรีเซตตัวเอง ทำให้ค่าที่เก็บลงในฐานข้อมูลเป็น 0 ดังนั้นเมื่อนำข้อมูลมาวิเคราะห์จึงจำเป็นต้องตัดข้อมูลที่ใช้ไม่ได้เหล่านี้ออกเพื่อไม่ให้เกิดความคลาดเคลื่อน จากนั้นค่าของพารามิเตอร์ทุกตัวจะถูกปรับให้เป็นค่ามาตรฐาน

4.2.3 การแบ่งชุดข้อมูล

ข้อมูลที่เก็บรวบรวมไว้ในฐานข้อมูลเป็นระยะเวลา 2 เดือนถูกแบ่ง เป็นข้อมูลชุดทดสอบจำนวน 25 เปอร์เซ็นต์ และที่เหลือถูกใช้เป็นข้อมูลชุดฝึกสอน

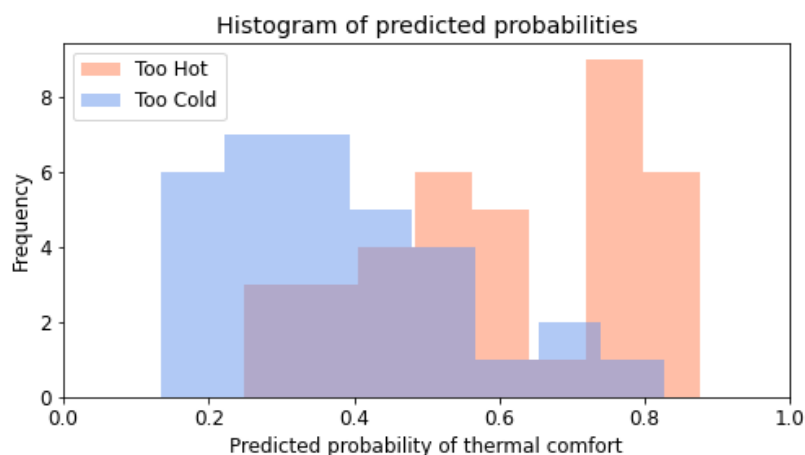
4.2.4 การฝึกสอนแบบจำลอง

หลังจากที่ได้ทำการแบ่ง ความรู้สึกสบายเชิงความร้อนออกเป็น 3 กลุ่ม นั่นคือ “ร้อนเกินไป” “หนาวเกินไป” และ “พอดี” แล้วจะใช้ฟังก์ชันเป้าหมายดังกล่าวควบคู่กับพารามิเตอร์ในการฝึกสอนแบบจำลอง อย่างไรก็ตาม ความรู้สึก “พอดี” เป็นฟังก์ชันเป้าหมายที่กำหนดขึ้นในกรณีที่ไม่มีการปรับอุณหภูมิเครื่องปรับอากาศ แต่ในความเป็นจริงแล้วอาจไม่ได้สะท้อนถึงความรู้สึกสบายเชิงความร้อนที่แท้จริง อีกทั้งความรู้สึก “พอดี” เป็นความรู้สึกที่อยู่กึ่งกลางระหว่าง “ร้อนเกินไป” กับ “หนาวเกินไป” วิทยานิพนธ์ฉบับนี้จึงเลือกใช้ แบบจำลองที่ทำการแบ่งกลุ่มโดยให้ผลลัพธ์ในรูปแบบความน่าจะเป็นระหว่าง “ร้อนเกินไป” กับ “หนาวเกินไป”

เนื่องจากจำนวนครั้งที่ผู้อยู่อาศัยทำการปรับเครื่องปรับอากาศมีน้อยมาก นั่นคือ 277 ครั้ง จากข้อมูลที่เก็บเป็นระยะเวลา 2 เดือน ดังนั้นโครงข่ายประสาทเทียมซึ่งเป็นอัลกอริทึมที่ต้องการข้อมูลจำนวนมาก จึงไม่เหมาะที่จะนำมาใช้ในการจำแนกความรู้สึกสบายเชิงความร้อนนี้ วิทยานิพนธ์ฉบับนี้เลือกใช้การจำแนกด้วยซัพพอร์ตเวกเตอร์ (SVC) เนื่องจากเป็นอัลกอริทึมที่มีประสิทธิภาพดี เมื่อในการจำแนกเมื่อมีจำนวนพารามิเตอร์ (มิติ) มาก แต่จำนวนข้อมูลมีน้อย ด้วยชุดคำสั่งในไลบรารีของ Scikit-learn อัลกอริทึม SVC สามารถบอกความน่าจะเป็นของการจำแนกได้ เช่น มีความน่าจะเป็นที่ผลลัพธ์จะอยู่ในกลุ่มที่ 0 อยู่ 0.3 และในทางกลับกัน มีความน่าจะเป็นที่ผลลัพธ์จะอยู่ในกลุ่มที่ 1 อยู่ 0.7 เป็นต้น ดังนั้นวิทยานิพนธ์ฉบับนี้จึงประยุกต์ใช้การจำแนกด้วยความน่าจะเป็นกับการถดถอยที่เป็นลำดับ กล่าวคือทำการกำหนดค่าขีดเริ่มเปลี่ยนในช่วง ระหว่าง 0 ถึง 1 ว่าค่าจำนวนจริงใดเป็นจุดเปลี่ยนระหว่าง “หนาวเกินไป” ไปเป็น “พอดี” และไปเป็น “ร้อนเกินไป” ในที่สุด

4.2.5 การตรวจสอบแบบจำลอง

อัลกอริทึม SVC ที่มีซิกมอยด์เป็นฟังก์ชันเคอร์เนล ถูกฝึกสอนด้วยข้อมูลจำนวน 75% ของ 277 ข้อมูล โครงสร้างภายในของ SVC จะมีการทำครอสวาเลเดชัน 5 ชั้น (5-fold cross-validation) ในการประเมินความน่าจะเป็นของผลลัพธ์ และเมื่อทำการตรวจสอบผลลัพธ์กับชุดทดสอบอีก 25% ที่เหลือ ทำให้ได้ผลลัพธ์ดังแผนภูมิในรูปที่ 29



รูปที่ 29 แผนภูมิแสดงความน่าจะเป็นของชุดทดสอบ

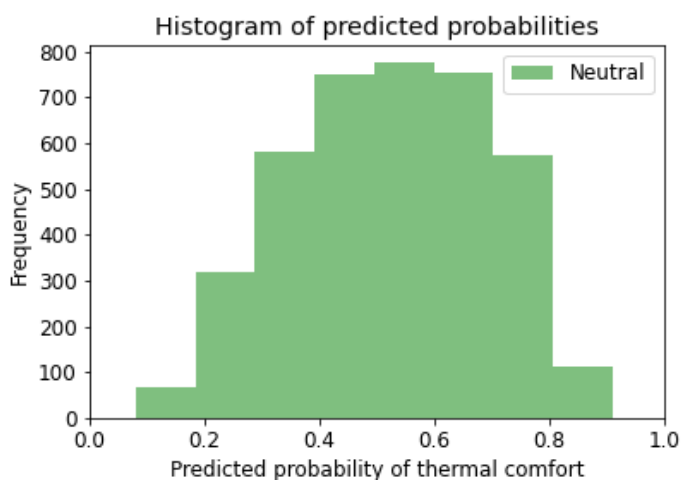
จากแผนภูมิในรูป 29 ค่าความน่าจะเป็นระหว่าง 0 ซึ่งหมายถึงถูกจำแนกว่า “หนาวเกินไป” จนถึง 1 ซึ่งถูกจำแนกว่า “ร้อนเกินไป” ของข้อมูลที่มีค่าจริงเป็นทั้ง “หนาวเกินไป” สีน้ำเงิน และ “ร้อนเกินไป” สีส้มมีการทับซ้อนกันในบริเวณค่าที่เป็นกึ่งกลางระหว่าง 0 กับ 1 อยู่มาก ด้วยเหตุนี้

วิทยานิพนธ์ฉบับนี้จึงทำการกำหนดค่าขีดเริ่ม (threshold) เปลี่ยนโดยพิจารณาจาก ค่าความเที่ยงตรง (precision) ของข้อมูลเมื่อกำหนดค่าขีดเริ่มเปลี่ยนนั้นๆ ดังนี้

1. กำหนดให้ข้อมูลที่มีความน่าจะเป็นน้อยกว่า 0.25 ถูกจำแนกว่า “หนาวเกินไป” ซึ่งจากกราฟในรูปที่ 22 พบว่ามีค่าความเที่ยงตรง 90%
2. กำหนดให้ข้อมูลที่มีความน่าจะเป็นมากกว่า 0.75 ถูกจำแนกว่า “ร้อนเกินไป” ซึ่งจากกราฟในรูปที่ 22 พบว่ามีค่าความเที่ยงตรง 91%
3. ดังนั้นกำหนดให้ข้อมูลที่มีค่าความน่าจะเป็นตั้งแต่ 0.25 ถึง 0.75 ถูกจำแนกอยู่ในกลุ่มความรู้สึก “พอดี”

4.2.6 การประเมินแบบจำลอง

นำแบบจำลองที่สังเคราะห์ได้มาทดสอบกับข้อมูลที่ถูกจำแนกอยู่ในกลุ่ม “พอดี” ที่ไม่ถูกใช้ในการสังเคราะห์และตรวจสอบแบบจำลอง ทำให้ได้ผลลัพธ์ดังแผนภูมิในรูปที่ 30



รูปที่ 30 แผนภูมิแสดงความน่าจะเป็นของข้อมูลกลุ่ม “พอดี”

จากผลลัพธ์ดังแผนภูมิในรูปที่ 30 แสดงให้เห็นการกระจายตัวของข้อมูลที่ถูกระบุว่าเป็นกลุ่ม “พอดี” โดยข้อมูลที่ถูกจำแนกในกลุ่มนี้จะมีความหนาแน่นมากในบริเวณกึ่งกลางระหว่าง ค่าความน่าจะเป็นของ “หนาวเกินไป” และ “ร้อนเกินไป” โดยหากพิจารณาการแบ่งกลุ่มโดยขีดเริ่มเปลี่ยนตั้งแต่ 0.25 ถึง 0.75 จะพบว่าผลลัพธ์มีค่าเรียกกลับ (Recall) เท่ากับ 84.5%

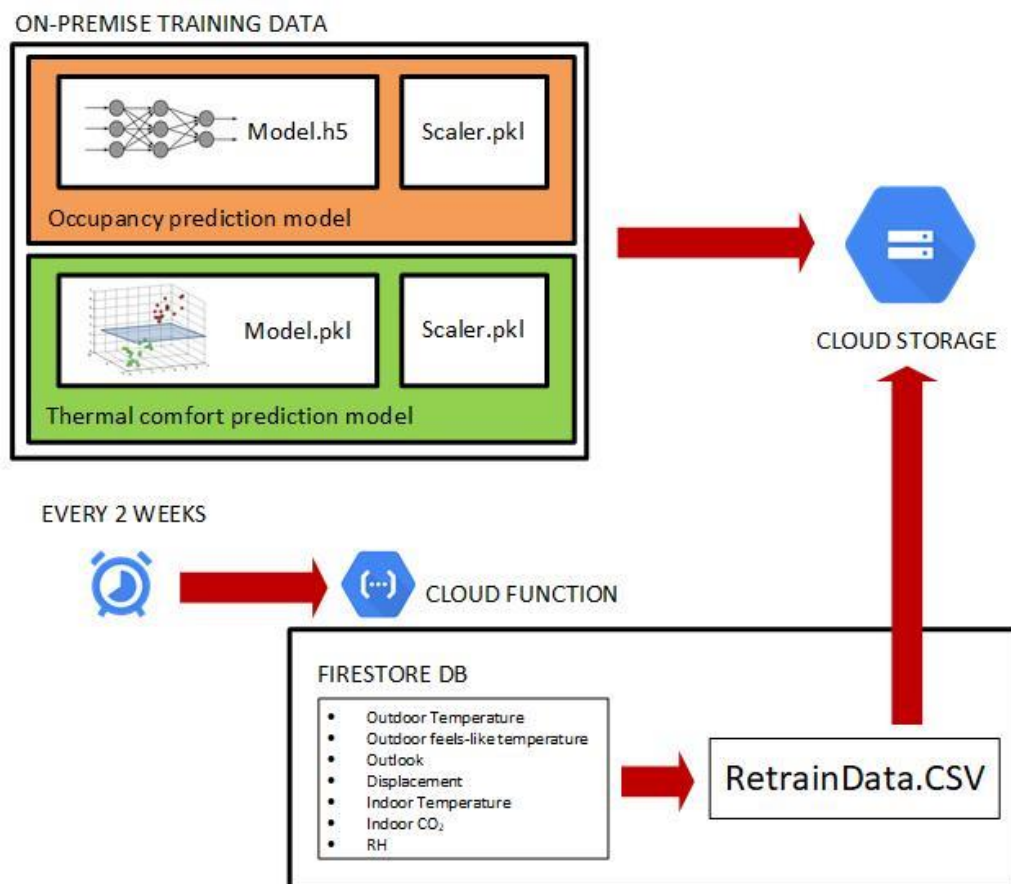
บทที่ 5

การประยุกต์ใช้แบบจำลองกับระบบควบคุมเครื่องปรับอากาศอัจฉริยะ

ระบบปรับอากาศอัจฉริยะที่ทำการพัฒนาขึ้นเป็นการประยุกต์ใช้แบบจำลองการเรียนรู้ของเครื่องบนสถาปัตยกรรมที่ได้ออกแบบขึ้นดังที่กล่าวในบทที่ 3 โดยในบทนี้จะอธิบายถึงการใช้อย่างจำลอง ในหัวข้อ 4.1 และ 4.2 ในโปรแกรมประยุกต์เพื่อควบคุมเครื่องปรับอากาศโดยอัตโนมัติโดยละเอียด

5.1 การบันทึกข้อมูลลงในที่เก็บข้อมูลบนคลาวด์

แบบจำลองที่สร้างขึ้นดังที่อธิบายในบทที่ 4 จะถูกนำมาใช้เป็นแบบจำลองตั้งต้นในการทำนายผลลัพธ์ที่จะถูกนำไปใช้ควบคุมเครื่องปรับอากาศโดยอัตโนมัติ และเมื่อพฤติกรรมของผู้ใช้อาศัยเปลี่ยนแปลงไปข้อมูลที่เกี่ยวข้องกับการใช้งานของผู้ใช้อาศัยนั้นๆจะถูกบันทึกลงในที่เก็บข้อมูลเพื่อทำการฝึกสอนแบบจำลองใหม่ โดยรายละเอียดของข้อมูลที่ถูกเก็บบนคลาวด์ ดังแสดงในรูปที่ 31 มีรายละเอียดดังนี้



รูปที่ 31 การบันทึกข้อมูลลงในที่เก็บข้อมูลบนคลาวด์

5.1.1 แบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย

แบบจำลองการทำนายการมาถึงของผู้อยู่อาศัยเป็นแบบจำลองโครงข่ายประสาทเทียมที่ถูกฝึกสอนโดยใช้ข้อมูลพฤติกรรมของผู้อยู่อาศัยตัวอย่างที่ถูกเก็บเป็นระยะเวลา 2 เดือน โดยการฝึกสอนดังกล่าวเป็นแบบ On-Premise ซึ่งหมายความว่าเป็นการฝึกสอนบนคอมพิวเตอร์ของผู้วิจัย แบบจำลองนี้ถูกบันทึกเป็นไฟล์สกุล .h5 (สกุลไฟล์ที่ใช้ในการบันทึกแบบจำลองของไลบรารี TensorFlow Keras) และส่งออกไปยังที่เก็บข้อมูลบนคลาวด์

5.1.2 สเกลเลอร์ของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย

ก่อนจะมีการสร้างแบบจำลอง 5.1.1 ข้อมูลดิบจะถูกประมวลผลผ่านขั้นตอนการเตรียมข้อมูล ซึ่งสเกลเลอร์ที่ใช้ในการปรับข้อมูลให้เป็นค่ามาตรฐาน (ชุดข้อมูลที่มีค่าเฉลี่ยเป็น 0 และส่วนเบี่ยงเบนมาตรฐานเป็น 1) จะต้องถูกบันทึก เพื่อใช้ปรับข้อมูลใดๆ ที่จะใช้ในการฝึกสอนใหม่หรือใช้เป็นข้อมูลขาเข้าของแบบจำลอง โดยสเกลเลอร์นี้ถูกบันทึกเป็นไฟล์สกุล .pkl (ไฟล์สกุล .pkl เป็นไฟล์ที่ใช้บันทึกแบบจำลองสำหรับไลบรารี Scikit-Learn) ที่ใช้บันทึกแบบจำลองและส่งออกไปยังที่เก็บข้อมูลบนคลาวด์

5.1.3 แบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน

แบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนเป็นแบบจำลองการจำแนกด้วยซัพพอร์ตเวกเตอร์ที่ถูกฝึกสอนโดยใช้ข้อมูลพฤติกรรมของผู้อยู่อาศัยตัวอย่างเช่นเดียวกับแบบจำลอง 5.1.1 โดยแบบจำลองนี้ถูกบันทึกเป็นไฟล์สกุล .pkl และส่งออกไปยังที่เก็บข้อมูลบนคลาวด์

5.1.4 สเกลเลอร์ของแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน


เช่นเดียวกับสเกลเลอร์ 5.1.2 แบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนก็ต้องมีสเกลเลอร์ที่จะใช้ในการปรับข้อมูลในอนาคต

5.1.5 ข้อมูลที่ใช้ในการฝึกสอนแบบจำลองใหม่

เพื่อให้แบบจำลองสอดคล้องกับพฤติกรรมปัจจุบันของผู้อยู่อาศัย ทุกๆ 14 วัน ตัวกำหนดตารางเวลาในคลาวด์ จะทริกเกอร์ให้คลาวด์ฟังก์ชันเก็บข้อมูลจากฐานไฟร์สตอร์ในช่วงเวลา 14 วัน นั้นในรูปแบบไฟล์สกุล .csv และส่งออกไปยังที่เก็บข้อมูลบนคลาวด์

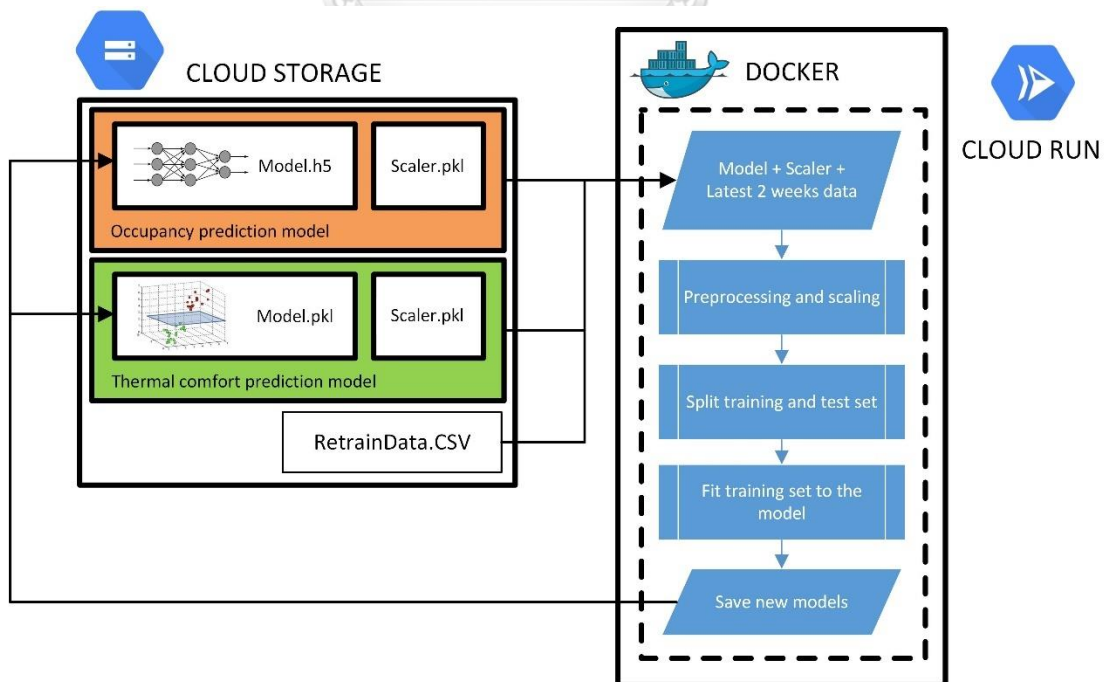
5.2 การปรับปรุงแบบจำลองตามพฤติกรรมของผู้อยู่อาศัย

เนื่องจากพฤติกรรมของผู้อยู่อาศัยอาจมีการเปลี่ยนแปลงเมื่อเวลาผ่านไป ดังนั้น วิทยานิพนธ์ฉบับนี้จึงได้พัฒนาระบบที่จะเรียกใช้งานฟังก์ชันการฝึกสอนใหม่โดยอัตโนมัติ ทุกๆ 14 วันโดยมีหลักการคือ เมื่อไฟล์สกุล .csv ที่บันทึกข้อมูลพฤติกรรมของผู้อยู่อาศัยในระยะเวลา 14 วันล่าสุด (RetrainData.CSV) ถูกบันทึกลงในที่เก็บข้อมูลบนคลาวด์ ระบบประมวลผลส่วนหลังจะทำการส่งคำขอโดยอัตโนมัติผ่านโปรโตคอล HTTPS ไปยัง Cloud Run (แพลตฟอร์มการประมวลผลบนคลาวด์) ดังแสดงในรูปที่ 32



รูปที่ 32 การล้งการเมื่อมีการบันทึกข้อมูลล่าสุดในที่เก็บข้อมูลบนคลาวด์

ภายใน Cloud Run ผู้วิจัยได้พัฒนาฟังก์ชันฝึกสอนแบบจำลองใหม่ และบรรจุลงใน Docker Container ดังแสดงในรูปที่ 33



รูปที่ 33 การปรับปรุงแบบจำลองตามพฤติกรรมของผู้อยู่อาศัย

ตามที่ได้อธิบายไปในหัวข้อที่ 3.6.2 แบบจำลองและสเกเลอร์ของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย และแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน ในที่เก็บข้อมูลบนคลาวด์จะถูกเรียกโดยฟังก์ชันฝึกสอนแบบจำลองใหม่ เพื่อปรับปรุงไฮเปอร์พารามิเตอร์ ให้สอดคล้องกับข้อมูล 14 วันล่าสุด (RetrainData.CSV) ที่ถูกบันทึกลงในที่เก็บข้อมูลบนคลาวด์ ผลลัพธ์ที่ได้จากการประมวลผลของฟังก์ชันใน Cloud Run คือแบบจำลองซึ่งถูกปรับปรุงไฮเปอร์พารามิเตอร์ใหม่ตามข้อมูลล่าสุด และถูกบันทึกทับแทนแบบจำลองเดิมภายในที่เก็บข้อมูลบนคลาวด์

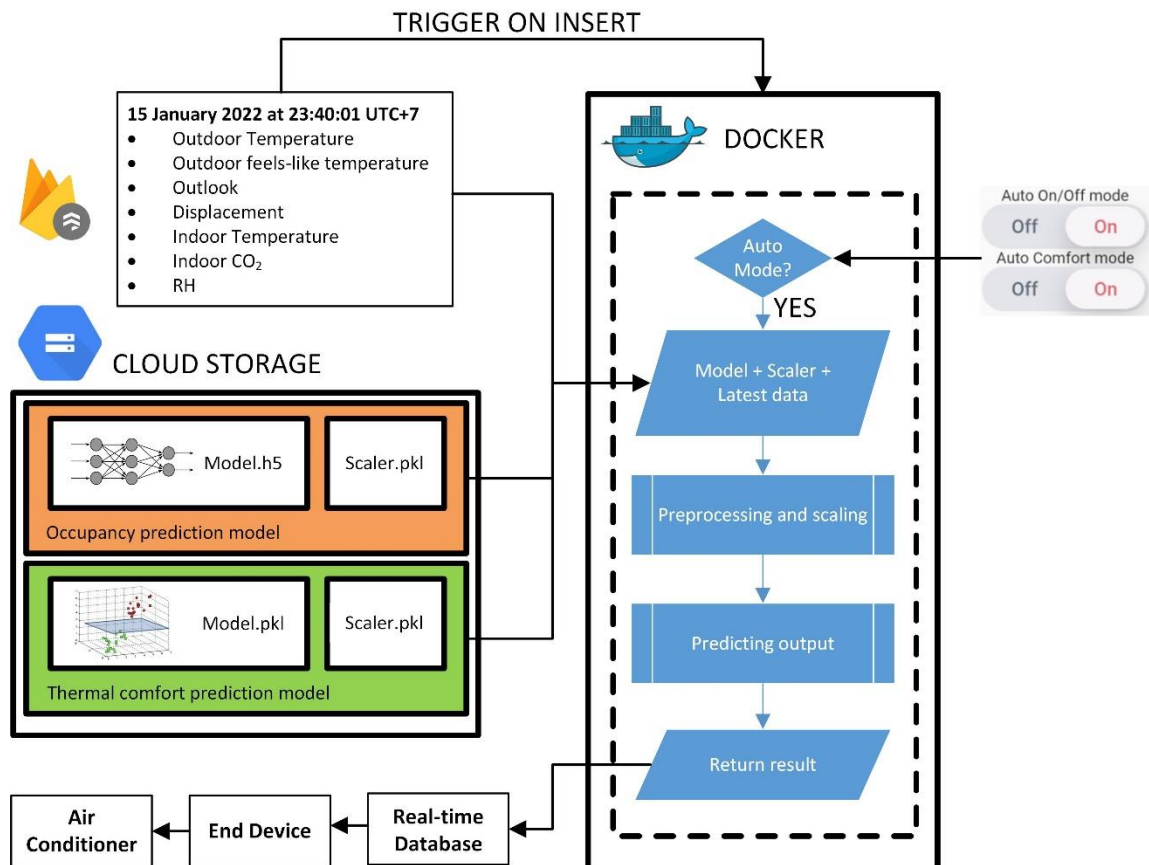
5.3 การควบคุมเครื่องปรับอากาศโดยใช้ผลการทำนายของแบบจำลอง

วิทยานิพนธ์ฉบับนี้ ได้พัฒนาระบบการควบคุมเครื่องปรับอากาศแบบอัตโนมัติ โดยการป้อนข้อมูลเข้าในปัจจุบันเข้าไปยังแบบจำลอง และใช้ผลเฉลยที่ได้รับจากแบบจำลองในการควบคุมเครื่องปรับอากาศ โดยการตั้งค่าเพื่อเปิดใช้ระบบอัตโนมัติสามารถทำได้โดยการปรับโหมด เพื่อเปิดใช้งานแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย และแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนตามลำดับ ดังแสดงในรูปที่ 34 อย่างไรก็ตามผู้อยู่อาศัยสามารถเปิดปิดหรือปรับการตั้งค่าเครื่องปรับอากาศได้เองในโหมด Manual Control ดังที่ได้อธิบายในหัวข้อ 3.3 เช่นกัน



รูปที่ 34 เมนูการตั้งค่าการเปิดใช้งานแบบจำลอง

การควบคุมเครื่องปรับอากาศแบบอัตโนมัติด้วยผลเฉลยของแบบจำลองที่ใช้ข้อมูลปัจจุบัน (ข้อมูลล่าสุดที่ถูกบันทึกลงในฐานข้อมูลไฟร์สตอร์) เป็นข้อมูลขาเข้า มีหลักการทำงานตามแผนผังในรูปที่ 35 และมีรายละเอียดดังต่อไปนี้



รูปที่ 35 การควบคุมเครื่องปรับอากาศโดยใช้ผลการทำนายของแบบจำลอง

1. ข้อมูลใหม่จะถูกบันทึกลงในฐานข้อมูลไฟร์สตอร์ในทุกๆ 5 นาที และเมื่อมีการบันทึกข้อมูลเกิดขึ้น ฟังก์ชันคลาวด์ในระบบส่วนหลังจะส่งคำขออัตโนมัติโดยโพรโตคอล HTTPS ไปยัง Cloud Run ที่ภายในประกอบไปด้วย Docker Container ที่มีฟังก์ชันการทำนายโดยแบบจำลองอยู่ในกรณีที่มีผู้อยู่อาศัยทำการเปิดใช้ระบบการควบคุมแบบอัตโนมัติ
2. ฟังก์ชันการทำนายโดยแบบจำลอง จะดึงข้อมูลล่าสุดจากฐานข้อมูลไฟร์สตอร์เพื่อใช้เป็นข้อมูลขาเข้า พร้อมทั้งแบบจำลองและสเกลเลอร์จากที่เก็บข้อมูลบนคลาวด์
3. ข้อมูลล่าสุดจะผ่านกระบวนการจัดการข้อมูล และถูกปรับสัดส่วนโดยสเกลเลอร์ให้ มีสัดส่วนของข้อมูลเท่ากับข้อมูลที่ใช้ในการสร้างแบบจำลอง

4. แบบจำลองทำการทำนายผลลัพธ์ และตอบกลับผลการทำนาย ซึ่งคลาวด์ฟังก์ชันจะบันทึกผลการทำนายนี้ลงในฐานข้อมูลแบบเรียลไทม์ (Real-time Database; RTDB)
5. ไมโครคอนโทรลเลอร์รับค่าข้อมูลจากฐานข้อมูลแบบเรียลไทม์ในรูปแบบสายอักขระ JSON และเก็บค่าเหล่านั้นในรูปแบบของตัวแปรที่เป็นพารามิเตอร์ในการควบคุมเครื่องปรับอากาศ ซึ่งประกอบไปด้วย อุณหภูมิที่ต้องการตั้งค่า และ สถานะเปิด/ปิดของเครื่องปรับอากาศ
6. เมื่อค่าของตัวแปรที่ใช้ในการควบคุมเปลี่ยนแปลงไป ไมโครคอนโทรลเลอร์จะส่งให้ฟังก์ชันควบคุมเครื่องปรับอากาศทำงาน โดยใช้ค่าตัวแปรที่ได้รับจากอักขระ JSON เป็นพารามิเตอร์ของฟังก์ชัน



บทที่ 6

ผลการทดลองและการอภิปรายผล

การทดสอบประสิทธิภาพของระบบประกอบไปด้วยการทดสอบการสื่อสารระหว่างอุปกรณ์ปลายทาง และประสิทธิภาพของแบบจำลอง

6.1 การสื่อสารระหว่างอุปกรณ์ปลายทางกับ RTDB

การทดสอบการสื่อสารมี 2 ส่วนคือ การส่งข้อมูลจากฐานข้อมูลแบบเรียลไทม์ (Real-time Database; RTDB) ไปยังอุปกรณ์ปลายทาง และอีกส่วนหนึ่งคือ การส่งข้อมูลจาก อุปกรณ์ปลายทาง ไปยัง RTDB

6.1.1 การส่งข้อมูลจาก RTDB ไปยังอุปกรณ์ปลายทาง

ข้อมูลการตั้งค่าเครื่องปรับอากาศที่ถูกกำหนดค่าโดยโปรแกรมประยุกต์บนโทรศัพท์มือถือหรือ ถูกกำหนดค่าโดยการใช้แบบจำลองการเรียนรู้ของเครื่อง จะทำการอัปเดต RTDB ในส่วนควบคุมเครื่องปรับอากาศ นับตั้งแต่ข้อมูลถูกปรับใน RTDB จะใช้ระยะเวลาประมาณ 1 วินาที ในการควบคุมเครื่องปรับอากาศโดยอุปกรณ์ปลายทาง (สังเกตได้จากตัวประทับตราเวลา (timestamp) ของ RTDB เทียบกับตัวประทับตราเวลาของการเปลี่ยนแปลงค่าข้อมูลภายในไมโครคอนโทรลเลอร์) ดังแสดงในกรอบสีแดงของรูปที่ 36

หน้าต่างอินเตอร์เฟซของ Realtime Database (RTDB)

The screenshot shows the RTDB interface with two nodes:

- MAPCsPueXDWFdx-hz6F**:
 - AC: 1 สถานะเครื่องปรับอากาศถูกเปลี่ยนจากปิด(0) เป็นเปิด(1)
 - FS: 1
 - T: 26
 - update: "2020-10-24 8:44:18"
 (Red box highlights the update time, arrow points to "ส่วนควบคุมเครื่องปรับอากาศ")
- MAPI3e3ReHksFxyPmQb**:
 - ACStatus: "1"
 - LDR: "1113"
 - PIR: "0"
 - RH: "72.27"
 - co2: "822.00"
 - setFan: "1"
 - setTemp: "26"
 - temp: "27.62"
 - update: "2020-10-24 8:44:58"
 (Green box highlights the update time, arrow points to "ส่วนเก็บข้อมูลสถานะแวดล้อมภายในห้อง")

Serial Monitor ของอุปกรณ์ปลายทาง

```
08:44:19.014 -> status: Turned on
08:44:58.282 -> /nodemcu/status/-MAPI3e3ReHksFxyPmQb/
08:44:58.282 -> json
08:44:58.282 -> {"co2":"822.00","setTemp":"26","setFan":"1","ACStatus":"1","PIR":"0","LDR":"1113","temp":"27.62","RH":"72.27"}
```

รูปที่ 36 การทดสอบการสื่อสารระหว่างอุปกรณ์ปลายทางกับ RTDB

ปัจจัยที่มีผลต่อความล่าช้าคือ ระยะเวลาในการเดินทางของข้อมูลจากเซิร์ฟเวอร์มายังอุปกรณ์ปลายทาง และการถูกขัดจังหวะโดยฟังก์ชันที่มีลำดับความสำคัญสูงกว่าภายในอุปกรณ์ปลายทาง อย่างไรก็ตามวัตถุประสงค์ของการส่งค่าในส่วนนี้คือการปรับเครื่องปรับอากาศซึ่งเป็นภาระงานที่มีความยืดหยุ่นในเชิงเวลาการทำงานได้ เพราะฉะนั้นความล่าช้าเพียง 1 วินาทีจึงไม่กระทบต่อวัตถุประสงค์ และข้อมูลที่ถูส่งมาในรูปแบบของสายอักขระ JSON ถูกนำไปกำหนดค่าตัวแปรเพื่อปรับเครื่องปรับอากาศผ่านตัวแปลงแสงอินฟราเรดได้อย่างถูกต้อง

6.1.2 การส่งข้อมูลจากอุปกรณ์ปลายทางไปยัง RTDB

การส่งข้อมูลในส่วนนี้เป็นการส่งข้อมูลที่เก็บค่าได้โดยตัวรับรู้ ค่าของพารามิเตอร์ต่างๆจะถูกรวบรวมในสายอักขระ JSON ซึ่งอุปกรณ์ปลายทางจะส่งสายอักขระ JSON นั้นไปที่ RTDB หากพิจารณาจากค่าในกรอบสีเขียวในรูปที่ 36 จะเห็นได้ว่าข้อมูลที่ถูส่งจากอุปกรณ์ปลายทางจะทำการอัปเดตสถานะภายใน RTDB ส่วนเก็บข้อมูลสถานะแวดล้อมในห้อง ภายในเวลาน้อยกว่า 1 วินาที

6.2 ประสิทธิภาพของแบบจำลอง

แบบจำลองที่สังเคราะห์ขึ้นโดยอาศัยข้อมูลที่ถูกเก็บเป็นระยะเวลา 2 เดือนถูกทดสอบประสิทธิภาพด้วยข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน

6.2.1 ประสิทธิภาพของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย


การทดสอบในส่วนนี้คือการทดสอบประสิทธิภาพของแบบจำลองโดยใช้ความแม่นยำ (Accuracy) เป็นตัวชี้วัด ข้อมูลระยะเวลา 1 เดือนที่แบบจำลองไม่เคยเห็นมาก่อนถูกใช้ในการทดสอบแบบจำลองโดยแบ่งเป็นรายสัปดาห์ และระยะเวลาในการทำนายถูกกำหนดให้เป็นตัวแปร คือ 5, 10, 15 และ 20 นาทีในขนาดตามลำดับ ผลลัพธ์ของการทำนายถูกแสดงในตารางที่ 5

ตารางที่ 5 แสดงความแม่นยำของแบบจำลองบนข้อมูลชุดทดสอบระยะเวลา 1 เดือน

	5 นาที	10 นาที	15 นาที	20 นาที
สัปดาห์ที่ 1	95.2%	94.5%	94.1%	92.8%
สัปดาห์ที่ 2	95.4%	94.1%	93.4%	88.6%
สัปดาห์ที่ 3	94.1%	92.5%	91.4%	90.3%
สัปดาห์ที่ 4	89.8%	89.1%	90.6%	88.7%

จากตารางที่ 5 จะเห็นได้ว่าค่าความแม่นยำจะลดลง โดยมีปัจจัยที่เกี่ยวข้อง 2 อย่างคือ ช่วงเวลาที่ใช้ทำนายอยู่ห่างจากเวลาที่ใช้ฝึกสอนแบบจำลอง นั่นหมายความว่า พฤติกรรมของผู้อยู่อาศัยค่อยๆเปลี่ยนไป ทำให้ในอนาคตแบบจำลองที่ถูกฝึกสอนจากพฤติกรรมเก่ามีประสิทธิภาพลดลง อีกหนึ่งปัจจัยคือระยะเวลาในอนาคตที่ทำการทำนาย กล่าวคือยิ่งแบบจำลองทำการทำนายอนาคตที่ไกลขึ้นเท่าไร ประสิทธิภาพจะลดลงเท่านั้น


ในทางปฏิบัติ วิทยานิพนธ์ฉบับนี้เลือกใช้การทำนายล่วงหน้า 10 นาทีว่าผู้อยู่อาศัยจะกลับมาถึงหรือไม่โดยอาศัยสมมติฐานว่า 10 นาทีในการทำความเย็นก่อนสามารถปรับสภาวะของห้องให้เข้าใกล้ความรู้สึกสบายของผู้อยู่อาศัยได้ อีกทั้งไม่ก่อให้เกิดค่าใช้จ่ายส่วนเกินจากการเปิดเครื่องปรับอากาศทิ้งไว้โดยไม่มีผู้อยู่อาศัยมากนัก ผลลัพธ์การทำนายที่ถูกต้องแสดงด้วยกราฟในรูปที่ 37 นั่นคือ เส้นกราฟสีแดงจะทำนายว่าผู้อยู่อาศัยจะกลับมาถึง ณ เวลานั้นๆหรือไม่ แบบจำลองทำนายว่าผู้อยู่อาศัยจะกลับมาถึงในเวลา 22:10 โดยอาศัยข้อมูลระยะกระจัด ณ เวลา 21:50, 21:55 และ 22:00 รวมทั้งเวลาและวันในสัปดาห์ในการทำนาย ซึ่งเมื่อเปรียบเทียบกับระยะกระจัดจริงตามกราฟเส้นสีน้ำเงินจะพบว่า ผู้อยู่อาศัยกลับมาถึงบ้านในเวลา 22:10 พอดี



รูปที่ 37 กราฟแสดงระยะกระจัดจริง และการทำนายที่ถูกต้องของแบบจำลอง

จากการวิเคราะห์ความผิดพลาดที่เกิดขึ้นของการทำนายโดยแบบจำลอง ความผิดพลาดส่วนใหญ่เกิดขึ้นเมื่อแบบจำลองทำนายว่าผู้อยู่อาศัยจะกลับมาถึงบ้าน แต่ในความจริงแล้ว ผู้อยู่อาศัยมีการหยุดแวะในสถานที่ใกล้เคียงเป็นระยะเวลาหนึ่ง ซึ่งแบบจำลองไม่ได้ถูกฝึกสอนด้วยพฤติกรรมนี้มาก่อน ทำให้ผลลัพธ์ของการทำนายบ่งบอกว่าผู้อยู่อาศัยจะกลับถึงบ้านก่อนความเป็นจริง ทำให้เปิดเครื่องปรับอากาศก่อน แต่หากผู้อยู่อาศัยมีพฤติกรรมในลักษณะนั้นเป็นกิจวัตร แบบจำลองก็จะทำการเรียนรู้และปรับผลลัพธ์ของการทำนาย จนใกล้เคียงกับพฤติกรรมปัจจุบันมากยิ่งขึ้น โดยความ

ผิดพลาดดังกล่าวถูกแสดงโดยกราฟในรูปที่ 38 นั่นคือ แบบจำลองใช้ระยะกระจัด ณ เวลา 14:30, 14:35 และเวลา 14:40 ตวบคู่กับเวลาและวันในสัปดาห์ในการทำนาย และให้ผลลัพธ์ว่าผู้อยู่อาศัยจะมาถึงในเวลา 14:50 แต่ในความเป็นจริงแล้วผู้อยู่อาศัยอาจแวะสถานที่ใกล้เคียงก่อนกลับทำให้ เวลาที่ผู้อยู่อาศัยเดินทางถึงบ้าน ช้ากว่าเวลาที่แบบจำลองทำนายว่าผู้อยู่อาศัยจะถึงบ้าน



รูปที่ 38 กราฟแสดงระยะกระจัดจริง และการทำนายพลาดของแบบจำลอง



6.2.2 ประสิทธิภาพของแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัย

ในการทดสอบประสิทธิภาพแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน วิทยานิพนธ์เลือกพิจารณาค่าความเที่ยงตรงของการจำแนกความรู้สึกไม่สบายเชิงความร้อนนั่นคือ “ร้อนเกินไป” และ “หนาวเกินไป” ควบคู่กับการพิจารณาค่าเรียกกลับของข้อมูลที่อยู่ในกลุ่ม “พอดี” โดยข้อมูลชุดทดสอบที่แบบจำลองไม่เคยเห็นมาก่อนมี 3 ชุด โดยมีระยะเวลาในการเก็บข้อมูลชุดละ 2 สัปดาห์นั้น ซึ่งหมายความว่า ข้อมูลชุดที่ 1 ชุดที่ 2 และ ชุดที่ 3 คือ ข้อมูลของสัปดาห์ที่ 1-2 สัปดาห์ที่ 3-4 และ สัปดาห์ที่ 5-6 ตามลำดับ โดยผลการจำแนกความรู้สึกสบายเชิงความร้อนถูกแสดงโดยแผนภูมิบอกความสัมพันธ์ระหว่างความน่าจะเป็นของผลลัพธ์ที่จำแนกโดยแบบจำลองกับความถี่ของข้อมูลจริงดังแสดงในรูปที่ 39 และมีรายละเอียดดังตารางที่ 6


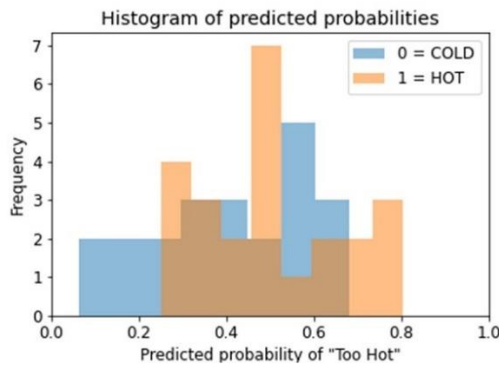
ตารางที่ 6 ตารางแสดงผลการจำแนกความรู้สึกสบายเชิงความร้อน

	ความเที่ยงตรงของการจำแนกว่า “ร้อนเกินไป”	ความเที่ยงตรงของการจำแนกว่า “หนาวเกินไป”	ค่าเรียกกลับของการจำแนกว่า “พอดี”
สัปดาห์ที่ 1-2	100.0%	79.3%	87.2%
สัปดาห์ที่ 3-4	83.3%	100.0%	91.2%
สัปดาห์ที่ 5-6	100.0%	92.3%	92.2%


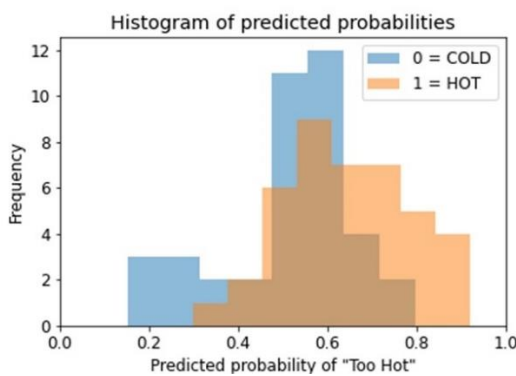
ผลลัพธ์การจำแนกของข้อมูลใหม่ (สัปดาห์ที่ 1-2)



ผลลัพธ์การจำแนกของข้อมูลใหม่ (สัปดาห์ที่ 3-4)



ผลลัพธ์การจำแนกของข้อมูลใหม่ (สัปดาห์ที่ 5-6)



รูปที่ 39 แผนภูมิแสดงความน่าจะเป็นของข้อมูลใหม่จำนวน 6 สัปดาห์

จากตารางที่ 6 และกราฟในรูปที่ 34 จะเห็นได้ว่าผู้อยู่อาศัยมีความรู้สึกสบายเชิงความร้อนที่เปลี่ยนไปเล็กน้อยในช่วงเวลา 2 สัปดาห์ อันเนื่องมาจากพฤติกรรมที่เปลี่ยนแปลงไป เช่น การห่มผ้า ขณะอยู่ในห้อง ทำให้ความรู้สึกสบายมีค่าค่อนข้างต่ำกลุ่มข้อมูลชุด “หนาวเกินไป”

6.3 ประสิทธิภาพของแบบจำลองหลังฝึกสอนใหม่

จากผลลัพธ์ของการทดสอบประสิทธิภาพของแบบจำลองทั้ง 2 ดังที่ได้กล่าวไปก่อนหน้านี้ จะเห็นได้ว่า ปัจจัยที่มีผลต่อประสิทธิภาพของแบบจำลองคือความคล้อยคลึงระหว่างข้อมูลที่ใช้ในการฝึกสอนแบบจำลอง กับข้อมูลในกรณีใช้งานจริง ดังนั้น การปรับปรุงแบบจำลองจึงมีความสำคัญอย่างยิ่งเนื่องจากการพัฒนาแบบจำลองนี้เพื่อใช้เป็นผลิตภัณฑ์นั้นพฤติกรรมและความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัยจริงย่อมแตกต่างไปจากพฤติกรรมและความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัยทดสอบที่ใช้ในการสร้างแบบจำลองในวิทยานิพนธ์ฉบับนี้

ดังนั้นวิทยานิพนธ์ฉบับนี้จึงได้วางแผนออกแบบแบบจำลองให้สามารถปรับปรุงประสิทธิภาพได้เองตามข้อมูลที่เรียนรู้ใหม่ (Adaptive Learning) โดยการนำโครงสร้างของแบบจำลองที่ถูกฝึกสอนด้วยข้อมูลชุดฝึกสอนมาเรียนรู้ใหม่อีกครั้ง (Retrain) เพื่อทำการปรับค่าถ่วงน้ำหนักให้สอดคล้องกับข้อมูลล่าสุด และนำผลลัพธ์ที่ได้จากแบบจำลองทั้ง 2 มาเรียกใช้งานผ่าน API เพื่อปรับเครื่องปรับอากาศ

6.3.1 ประสิทธิภาพของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัยหลังฝึกสอนใหม่

จากการทดสอบประสิทธิภาพของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัยโดยใช้ความแม่นยำเป็นตัวชี้วัดการทำนายล่วงหน้า 10 นาที จะสังเกตเห็นว่า ในสัปดาห์ที่ 4 ค่าความแม่นยำของการทำนายโดยแบบจำลองนี้ต่ำกว่า 90% ซึ่งต่ำกว่าค่าความแม่นยำที่กำหนดไว้ในขอบเขตของงานวิจัย และอาจส่งผลกระทบต่อให้เกิดความผิดพลาดในการควบคุมในโหมดอัตโนมัติ

หลังจากที่ฝึกสอนแบบจำลองใหม่โดยการนำข้อมูลในสัปดาห์ที่ 1 และสัปดาห์ที่ 2 เป็นระยะเวลา 14 วัน มาพิตกับแบบจำลองตั้งต้น ปรากฏว่าค่าความแม่นยำของการทำนายข้อมูลในสัปดาห์ที่ 3 และสัปดาห์ที่ 4 สูงขึ้นจนถึงระดับใกล้เคียงกับค่าความแม่นยำของการทำนายจากข้อมูลในสัปดาห์ที่ 1 และสัปดาห์ที่ 2 ดังแสดงในตารางที่ 7

ตารางที่ 7 แสดงความแม่นยำของการทำนายล่วงหน้า 10 นาที

	แบบจำลองไม่ผ่านการฝึกสอนใหม่	แบบจำลองผ่านการฝึกสอนใหม่
สัปดาห์ที่ 1	94.5%	97.5%
สัปดาห์ที่ 2	94.1%	94.1%
สัปดาห์ที่ 3	92.5%	97.2%
สัปดาห์ที่ 4	89.1%	95.8%

6.3.2 ประสิทธิภาพของแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนหลังฝึกสอนใหม่


จากผลการทดสอบประสิทธิภาพของแบบจำลองตามตารางที่ 6 แสดงให้เห็นว่า ถึงแม้ระยะเวลาผ่านไป ค่าเรียกกลับของการจำแนกว่า “พอดี” จะไม่เปลี่ยนแปลงหรือเปลี่ยนแปลงน้อยมาก เนื่องจากสภาพอากาศ และความรู้สึกสบายของผู้อยู่อาศัยมีค่าใกล้เคียงค่าคงที่ในช่วงระยะเวลา 1 เดือน อย่างไรก็ตาม หากเปลี่ยนตัวบุคคลผู้อยู่อาศัย ค่าเรียกกลับจะลดต่ำลงอย่างมีนัยสำคัญ ทำให้มีความจำเป็นที่จะต้องฝึกสอนแบบจำลองใหม่

หลังจากทดสอบประสิทธิภาพของแบบจำลอง กับผู้อยู่อาศัย 3 รายโดยใช้ระยะเวลา 9 สัปดาห์โดยมีการเปรียบเทียบประสิทธิภาพ ระหว่างค่าเรียกกลับโดยไม่ผ่านการฝึกสอนใหม่ และค่าเรียกกลับหลังผ่านการฝึกสอนใหม่ ดังแสดงในตารางที่ 8 ได้ผลสรุปดังนี้

1. การฝึกสอนแบบจำลองใหม่ด้วยการป้อนข้อมูล 14 วันล่าสุดที่ผ่านการจัดการข้อมูลแล้วเข้ากับแบบจำลองจำแนกความรู้สึกสบายเชิงความร้อน ทำให้การทำนายในสัปดาห์ถัดๆไปมีประสิทธิภาพสูง โดยใช้เกณฑ์ในการตัดสินใจว่าแบบจำลองนั้นมีประสิทธิภาพดีคือ มีค่าเรียกกลับของการจำแนกว่า “พอดี” ตั้งแต่ 80% ขึ้นไป
2. หากมีการเปลี่ยนแปลงผู้อยู่อาศัย แบบจำลองจะสามารถทำงานได้อย่างมีประสิทธิภาพเมื่อผู้อยู่อาศัยรายใหม่ใช้งานไปเป็นระยะเวลามากกว่า 14 วัน เนื่องจาก ภายในระยะเวลา 14 วันล่าสุดนั้นข้อมูลที่เก็บค่าของระบบจะเป็นข้อมูลที่เกิดขึ้นจากสภาพแวดล้อมและพฤติกรรมของผู้อยู่อาศัยรายล่าสุดแล้ว

ตารางที่ 8 แสดงการเปรียบเทียบค่าเรียกกลับของการจำแนกว่า “พอดี”

สัปดาห์ที่	ผู้อยู่อาศัย 1		ผู้อยู่อาศัย 2					ผู้อยู่อาศัย 3				
	1	2	3	4	5	6	7	8	9	10	11	12
ค่าเรียกกลับ โดยไม่ผ่านการ ฝึกสอนใหม่	85.6 %	84.3 %	72.4 %	69.5 %	73.5 %	71.8 %	70.6 %	77.4 %	76.1 %	79.6 %	78.2 %	78.8 %
ค่าเรียกกลับ หลังผ่านการ ฝึกสอนใหม่	85.6 %	84.3 %	71.9 %	70.2 %	83.2 %	84.1 %	82.9 %	73.8 %	79.4 %	80.2 %	83.5 %	84.1 %

↑ ↑ ↑ ↑ ↑


บทที่ 7

สรุปผลงานวิจัยและข้อเสนอแนะ

7.1 สรุปงานวิจัย

จากผลการทดลองในบทที่ 6 จะเห็นได้ว่าระบบควบคุมเครื่องปรับอากาศสำหรับที่อยู่อาศัย โดยใช้ซอฟต์แวร์การเรียนรู้ของเครื่องบนคลาวด์ที่พัฒนาขึ้นสามารถบรรลุวัตถุประสงค์ของงานวิจัย โดยมีรายละเอียดดังต่อไปนี้

1. ระบบที่พัฒนาขึ้นสามารถเปิดปิดและปรับอุณหภูมิเครื่องปรับอากาศได้โดยอัตโนมัติ และสามารถทำงานแบบเรียลไทม์ โดยผู้อยู่อาศัยไม่จำเป็นต้องปรับปรุงระบบปรับอากาศที่มีอยู่เดิม เพียงติดตั้งอุปกรณ์ปลายทางที่ส่งสัญญาณควบคุมเครื่องปรับอากาศผ่านไดโอดเปล่งแสงอินฟราเรด อุปกรณ์ปลายทางจะทำหน้าที่ติดต่อสื่อสารกับระบบประมวลผลส่วนหลัง อีกทั้งยังมีหน้าที่รับข้อมูลสภาพแวดล้อมภายในห้องโดยตัวรับรู้ที่ติดตั้งบนอุปกรณ์ปลายทาง
2. แบบจำลองการทำนายการมาถึงของผู้อยู่อาศัยสามารถใช้ในการเปิดและปิดเครื่องปรับอากาศโดยอัตโนมัติที่ความแม่นยำมากกว่า 90% เมื่อทำนายล่วงหน้า 10 นาที โดยอาศัยข้อมูลพฤติกรรมการเดินทางที่วิเคราะห์ได้จากระยะเวลากระจัดระหว่างโทรศัพท์มือถือของผู้อยู่อาศัยกับบ้าน ประกอบกับข้อมูลเวลาและวันของสัปดาห์ที่แสดงถึงกิจวัตรของผู้อยู่อาศัย แต่ระบบนี้ยังมีข้อจำกัดคือ โทรศัพท์มือถือของผู้อยู่อาศัยจำเป็นต้องเชื่อมต่อกับเครือข่ายอินเทอร์เน็ตและเข้าถึงบริการบอกตำแหน่งตลอดเวลา เพื่อให้ข้อมูลขาเข้าของแบบจำลองเป็นข้อมูลจริง ทำให้สามารถทำนายได้อย่างถูกต้อง อีกทั้งหากพฤติกรรมของผู้อยู่อาศัยเปลี่ยนแปลงไป แบบจำลองจะต้องใช้เวลาเก็บข้อมูลพฤติกรรมใหม่เป็นระยะเวลา 14 วันเพื่อปรับปรุงไฮเปอร์พารามิเตอร์ให้สามารถทำนายผลลัพธ์ที่ความแม่นยำมากกว่า 90% ดังเดิม
3. แบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อนสามารถใช้การปรับการตั้งค่าอุณหภูมิโดยอัตโนมัติที่ค่าเรียกกลับของความรู้สึก “พอดี” ในสภาวะแวดล้อมของผู้อยู่อาศัยมีค่ามากกว่า 80% ข้อจำกัดที่สำคัญคือเมื่อนำแบบจำลองไปใช้งานจริงจะพบว่าความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัยอาจมีความแตกต่างกับกลุ่มผู้อยู่อาศัยตัวอย่างที่วิทยานิพนธ์ฉบับนี้ใช้ในการพัฒนาแบบจำลองเริ่มต้น เพราะฉะนั้นการใช้งานในระยะเริ่มแรก ผู้อยู่อาศัยจำเป็นต้องปรับอุณหภูมิในโหมด Manual เป็นระยะเวลา 14 วันเพื่อให้ระบบปรับปรุง

ไฮเปอร์พารามิเตอร์ของแบบจำลองตามข้อมูลความรู้สึกสบายเชิงความร้อนของผู้อยู่อาศัยรายใหม่

4. ระบบควบคุมเครื่องปรับอากาศที่พัฒนาขึ้นสามารถปรับปรุงประสิทธิภาพตาม ข้อมูลพฤติกรรม และสภาวะแวดล้อมใหม่ทุก 14 วัน ซึ่งทำให้ผลลัพธ์มีความแม่นยำมากกว่า 90% สำหรับการเปิดปิดเครื่องปรับอากาศโดยใช้ผลเฉลยของแบบจำลองการทำนายการมาถึงของผู้อยู่อาศัย และให้ค่าเรียกกลับมากกว่า 80% สำหรับการปรับอุณหภูมิเครื่องปรับอากาศโดยใช้ผลเฉลยของแบบจำลองการจำแนกความรู้สึกสบายเชิงความร้อน
5. ผู้วิจัยได้พัฒนาโปรแกรมประยุกต์บนโทรศัพท์มือถือ เพื่อรองรับการทำงานจากระบบควบคุมเครื่องปรับอากาศสำหรับที่อยู่อาศัยโดยใช้ขอบข่ายงานการเรียนรู้ของเครื่องบนคลาวด์ซึ่งมีฟังก์ชันทั้งหมดประกอบไปด้วย
 - โปรแกรมเปิด/ปิดและตั้งค่าเครื่องปรับอากาศในโหมด Manual
 - โปรแกรมการตั้งค่าพิกัดตำแหน่งที่อยู่อาศัยของผู้อยู่อาศัย
 - กระบวนการทำงานเบื้องหลัง (Background Process) ซึ่งทำหน้าที่คำนวณระยะกระจัดระหว่างผู้อยู่อาศัยกับที่อยู่อาศัย และส่งข้อมูลไปยังระบบส่วนหลัง
 - การตั้งค่าการใช้งานระบบควบคุมอัตโนมัติด้วยแบบจำลองการเรียนรู้ของเครื่องซึ่งระบบส่วนหลังจะส่งข้อมูลการควบคุมเครื่องปรับอากาศไปยังโปรแกรมประยุกต์บนโทรศัพท์มือถือ และอุปกรณ์ปลายทาง
6. ผู้วิจัยได้ออกแบบและพัฒนาระบบส่วนหลังที่ทำหน้าที่เก็บข้อมูล เก็บแบบจำลอง และทำหน้าที่ประมวลผลบนคลาวด์ ซึ่งมีข้อดีคืออุปกรณ์ปลายทางที่เลือกใช้จะทำหน้าที่รับส่งข้อมูลและอำนวยความสะดวกสื่อสารระหว่างระบบเบื้องหลังกับสิ่งแวดล้อมทางกายภาพเท่านั้น จึงสามารถออกแบบอุปกรณ์ปลายทางให้มีราคาถูกโดยใช้ไมโครคอนโทรลเลอร์ ESP32 อีกทั้งยังสามารถย่อ หรือขยายระบบได้ตามจำนวนผู้อยู่อาศัยที่เปลี่ยนแปลงในอนาคตในรูปแบบ Pay-Per-Use โดยไม่จำเป็นต้องเสียค่าใช้จ่ายในการบำรุงรักษาเซิร์ฟเวอร์

7.2 ข้อเสนอแนะและแนวทางในการพัฒนาต่อ

ผู้วิจัยเล็งเห็นว่าระบบควบคุมเครื่องปรับอากาศสำหรับที่อยู่อาศัยโดยใช้ขอบข่ายงานการเรียนรู้ของเครื่องบนคลาวด์ที่พัฒนาขึ้น สามารถผลิตเพื่อจำหน่ายในเชิงพาณิชย์ได้ แต่ยังมีประเด็นที่จำเป็นจะต้องศึกษาและพัฒนาต่อได้แก่

1. ในอนาคตหากมีผู้อยู่อาศัยเพิ่มขึ้น ผู้พัฒนาหลีกเลี่ยงไม่ได้ที่จะต้องพัฒนาระบบบริหารจัดการผู้อยู่อาศัย เพื่อบริหารทรัพยากรที่ระบบใช้ในการเก็บข้อมูลและการประมวลผลบนคลาวด์ให้มีประสิทธิภาพสูงสุด เช่น การจัดการช่วงเวลาในการประมวลผลข้อมูลของแต่ละผู้อยู่อาศัย เพื่อลดความจำเป็นในการเลือกใช้ทรัพยากรการประมวลผลบนคลาวด์ที่เกินความพอดีและก่อให้เกิดค่าใช้จ่ายที่ไม่จำเป็น
2. ระบบที่พัฒนาขึ้นในวิทยานิพนธ์ฉบับนี้มุ่งเน้นการใช้งานของผู้อยู่อาศัยเป็นศูนย์กลาง แต่ในอนาคต สามารถนำมาต่อยอดเพื่อให้เกิดประโยชน์ในแง่ของการประหยัดพลังงานได้อีกด้วย กล่าวคือ สามารถนำข้อมูลจากระบบการตอบสนองด้านโหลดอัตโนมัติด้วยโปรโตคอล OpenADR มาจัดการปรับเปลี่ยนการใช้งานโหลดไฟฟ้า หรือปลดโหลดไฟฟ้า
3. ในอนาคต ระบบที่พัฒนาขึ้นสามารถนำมาต่อยอดในด้านสุขภาพของผู้อยู่อาศัย เช่น การตรวจสอบคุณภาพของอากาศ เพื่อแจ้งเตือนไปยังผู้อยู่อาศัย หรือ ส่งชุดคำสั่งเพื่อควบคุมเครื่องฟอกอากาศ

บรรณานุกรม

1. Sullivan, F. *Thailand Digital Technology Foresight 2035*. 2019; Available from: <https://www.depa.or.th/storage/app/media/file/Second%20Deliverable%20RevV1%20EN%20V12%20140819%20FIN.pdf>.
2. Katili, A.R., R. Boukhanouf, and R. Wilson. *Space cooling in buildings in hot and humid climates—a review of the effect of humidity on the applicability of existing cooling techniques*. in *14th International Conference on Sustainable Energy Technologies & SET*. 2015.
3. Basheer, Q., et al., *Leveraging machine learning and big data for smart buildings: A comprehensive survey*. IEEE Access. **7**: p. 90.
4. Shao, S., M. Pipattanasomporn, and S. Rahman, *Development of physical-based demand response-enabled residential load models*. IEEE Transactions on power systems, 2012. **28**(2): p. 607-614.
5. Zhang, X., et al., *An IoT-based thermal model learning framework for smart buildings*. IEEE Internet of Things Journal, 2019. **7**(1): p. 518-527.
6. Standard, A., *55, Thermal environmental conditions for human occupancy*. American Society of Heating, Refrigerating and Air conditioning Engineers, 1992. **145**.
7. Satake, E., et al., *Sparse ordinal logistic regression and its application to brain decoding*. Frontiers in neuroinformatics, 2018. **12**: p. 51.
8. Mitchel, T.M. and M. Learning, *McGraw-Hill*. New York, 1997.
9. Ng, A., *Neural networks and deep learning*. Coursera. <https://www.coursera.org/learn/neuralnetworks-deep-learning>, 2018. **325**.
10. Raschka, S. *Gradient Descent and Stochastic Gradient Descent*. Available from: https://rasbt.github.io/mlxtend/user_guide/general_concepts/gradient-optimization/.
11. Berrar, D., *Cross-validation*. Encyclopedia of Bioinformatics and Computational Biology, 2019. **1**: p. 542-545.
12. Tharwat, A., *Classification assessment methods*. Applied Computing and

- Informatics, 2020.
13. Liu, W., Z. Lian, and B. Zhao, *A neural network evaluation model for individual thermal comfort*. *Energy and Buildings*, 2007. **39**(10): p. 1115-1122.
 14. Winarno, E., W. Hadikurniawati, and R.N. Rosso. *Location based service for presence system using haversine method*. in *2017 International Conference on Innovative and Creative Information Technology (ICITech)*. 2017. IEEE.
 15. Bareth, U., A. Kupper, and P. Ruppel. *Geoxmart-a marketplace for geofence-based mobile services*. in *2010 IEEE 34th Annual Computer Software and Applications Conference*. 2010. IEEE.
 16. Zhao, J. *HTTP Overview*. 30 August 2020; 01 November 2017:[Available from: <https://www.dev2qa.com/http-overview/>].
 17. Salah, T., et al. *IoT Applications: From Mobile Agents to Microservices Architecture*. in *2018 International Conference on Innovations in Information Technology (IIT)*. 2018. IEEE.
 18. Biswas, A.R. and R. Giaffreda. *IoT and cloud convergence: Opportunities and challenges*. in *2014 IEEE World Forum on Internet of Things (WF-IoT)*. 2014. IEEE.
 19. Huang, C.-H., H.-H. Tsai, and H.-C. Chen, *Influence of Weather Factors on Thermal Comfort in Subtropical Urban Environments*. *Sustainability*, 2020. **12**(5): p. 2001.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ประวัติผู้เขียน

ชื่อ-สกุล	อรรณวุฒิ อิศระวิริยะกุล
วัน เดือน ปี เกิด	16 กันยายน 2535
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	ปริญญาตรี ภาควิชาเครื่องกล คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	60/33 หมู่ 7 เขตตลิ่งชัน ถนนบรมราชชนนี กรุงเทพมหานคร 10170
ผลงานตีพิมพ์	Cloud-based Machine Learning Framework for Residential HVAC Control System



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY