

ตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบปรับน้ำยา แปรผันโดยใช้การเรียนรู้ของเครื่อง

วริษฐ์ ศิริเจริญสุข^{1*} ประสงค์ ปราณีตพลกรัง² สุรศักดิ์ มั่งสิงห์³

^{1*,2,3}หลักสูตรวิทยาศาสตรมหาบัณฑิต คณะเทคโนโลยีสารสนเทศ, มหาวิทยาลัยศรีปทุม, กรุงเทพมหานคร, ประเทศไทย

*ผู้ประพันธ์บรรณกิจ อีเมล : warit.sir@spumail.net

รับต้นฉบับ : 1 มีนาคม 2567; รับบทความฉบับแก้ไข : 2 เมษายน 2567; ตอบรับบทความ : 13 เมษายน 2567

เผยแพร่ออนไลน์ : 26 ธันวาคม 2567

บทคัดย่อ

วัตถุประสงค์ในงานวิจัยนี้เพื่อพัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน โดยใช้การเรียนรู้ของเครื่อง ในส่วนเหตุการณ์การเสียของเครื่องปรับอากาศมาจากการสัมภาษณ์ผู้เชี่ยวชาญ ผู้วิจัยได้ใช้ชุดโปรแกรม RapidMiner Studio ในการสร้างตัวแบบจากอัลกอริทึมทั้ง 4 ประเภท ได้แก่ Decision Tree, Naïve Bayes, Support Vector Machine และ Neural Networks ทั้งนี้ ได้ใช้ชุดข้อมูลเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผันมาจาก บริษัท เบตเตอร์ คูล จำกัด จำนวน 402 รายการ ซึ่งภายในชุดข้อมูลประกอบไปด้วย แรงดันสารทำความเย็น ค่าความเย็นยิ่งยวด (subcooled value) ค่าความร้อนยิ่งยวด (superheated value) จำนวนเครื่องที่เปิด-ปิด และสถานะการทำงานของเครื่องที่ทำงานปกติและผิดปกติ เพื่อใช้ในการประเมินประสิทธิภาพค่าความแม่นยำ (accuracy) ค่าความเที่ยง (precision) ค่าความระลึก (recall) และค่าความถ่วงดุล (F-Measure) แล้วนำมาเปรียบเทียบกับประสิทธิภาพกับอัลกอริทึมต่าง ๆ ซึ่งอัลกอริทึมที่มีประสิทธิภาพสูงสุดได้แก่ Neural Networks โดยมีค่าความแม่นยำร้อยละ 95.04 ค่าความเที่ยงร้อยละ 94.17 ค่าความระลึกร้อยละ 100 และค่าความถ่วงดุลร้อยละ 97.00 ทำให้ได้ผลของการทำนายสถานะทำงานปกติหรือผิดปกติ

อย่างไรก็ดี ผู้วิจัยได้พัฒนาขยายผลตัวแบบโดยใช้เทคนิค Hybrid Ensemble Method แบบ Stacking มีการใช้อัลกอริทึมที่มีค่าประสิทธิภาพสูงสุดและรองลงมาสองอันดับ ได้แก่ Neural Networks, Decision Tree และ Naïve Bayes ในการจำแนก ทำให้ได้ค่าประสิทธิภาพที่สูงขึ้นจากเดิมด้วยค่าความแม่นยำมากถึงร้อยละ 95.52 ค่าความเที่ยงร้อยละ 97.21 ค่าความระลึกร้อยละ 97.21 และค่าความถ่วงดุลร้อยละ 97.21

คำสำคัญ : การเรียนรู้ของเครื่อง ตัวแบบทำนาย ระบบปรับน้ำยาแปรผัน

A Model to Predict the Failure of Centralized Air Conditioners with Variable Refrigerant Flow Using Machine Learning

Warit Siricharoensuk^{1*} Prasong Praneetpolgrang² Surasuk Mungsing³

^{1*,2,3} *Master of Science Program in Information Technology, Faculty of Information Technology,
Sripatum University, Bangkok, Thailand*

*Corresponding Author. E-mail address: warit.sir@spumail.net

Received: 1 March 2024; Revised: 2 April 2024; Accepted: 13 April 2024

Published online: 26 December 2024

Abstract

The objective of this research was to develop a predictive model for failure events of variable refrigerant flow air conditioning systems using machine learning techniques. The air conditioning failure events were attributed to the amount of refrigerant. The researcher utilized the RapidMiner Studio software to construct models from four algorithm types: Decision Tree, Naïve Bayes, Support Vector Machine, and Neural Networks. The dataset used consisted of 402 records of variable refrigerant flow air conditioning systems Better Cool Co., Ltd., containing features such as refrigerant pressure, subcooled value, superheated value, number of units turned on/off, and operational status (normal or faulty). To evaluate model performance, the accuracy, precision, recall, and F-measure metrics were calculated and compared across the algorithms. The Neural Networks algorithm demonstrated the highest performance, achieving 95.04% accuracy, 94.17% precision, 100% recall, and 97.00% F-measure, enabling accurate prediction of normal or faulty operational status.

Moreover, the researcher enhanced the model using the Stacking Hybrid Ensemble Method technique. This involved combining the top three performing algorithms: Neural Networks, Decision Tree, and Naïve Bayes, for classification. Consequently, the performance metrics improved, with an accuracy of 95.52%, precision of 97.21%, recall of 97.21%, and an F-measure of 97.21%.

Keywords: Deep learning, Predictive model, Variable refrigerant flow

1) บทนำ

ปัจจุบันการใช้เครื่องปรับอากาศมีการเพิ่มขึ้นอย่างมีนัยสำคัญ ในอาคารที่พัก ออฟฟิศ โรงงาน หรือพื้นที่ที่ต้องการปรับอากาศ เพื่อใช้ในการลดอุณหภูมิภายในพื้นที่ ซึ่งแม้แต่ทางภาครัฐให้ความสำคัญในการใช้งานระบบเครื่องปรับอากาศที่มีประสิทธิภาพสูง เพื่อลดค่าใช้จ่ายในด้านพลังงาน จากทางกรมโยธาธิการและผังเมือง สังกัดกระทรวงมหาดไทย [1] ได้มีแนวคิดในการพัฒนาคู่มือการออกแบบสำหรับอาคารภาครัฐใหม่เพื่อให้เป็นรูปแบบอาคารเขียว (Green Government Office Design Guidelines for New Construction) [2] นั้นเน้นไปที่การใช้ระบบเครื่องปรับอากาศที่มีประสิทธิภาพสูง จึงทำให้มีการเลือกใช้งานเครื่องปรับอากาศชนิดรวมศูนย์ระบบปรับน้ำยาแปรผัน (Variable Refrigerant Flow: VRF) มากขึ้นสำหรับอาคารประหยัดพลังงานในระดับที่สูงขึ้น เช่นการกำหนดให้ใช้งานเครื่องปรับอากาศตามมาตรฐานเบอร์ 5 ขึ้นไป

ปกติในงานบำรุงรักษาเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน มีสิ่งสำคัญที่ต้องคำนึงถึงสำหรับการดูแลรักษา คือจำเป็นต้องใช้บุคลากรที่มีความรู้ และทักษะทางวิศวกรในการดูแลรักษาระบบ เนื่องจากระบบมีความซับซ้อน รวมถึงชุดอุปกรณ์วัดค่าเซนเซอร์ที่อุปกรณ์ทั้งระบบ หากผู้ปฏิบัติงานไม่มีความเชี่ยวชาญจะทำให้เกิดความผิดพลาดในการวินิจฉัยจึงทำให้ผู้วิจัยเล็งเห็นถึงความสำคัญในการพัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน โดยใช้การเรียนรู้ของเครื่อง (Machine Learning) [3], [4] ในส่วนเหตุการณ์การเสียของเครื่องปรับอากาศมาจากปริมาณสารทำความเย็นซึ่ง เป็นสาเหตุและความสำคัญหลักของการวิจัยในครั้งนี้

2) วัตถุประสงค์ของการวิจัย


เพื่อพัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน โดยใช้การเรียนรู้ของเครื่อง ในส่วนเหตุการณ์การเสียของเครื่องปรับอากาศมาจากปริมาณสารทำความเย็น

3) ทบทวนวรรณกรรม

3.1) ประเภทของอัลกอริทึม

3.1.1) *Decision Tree* [5]: เป็นการตัดสินใจแบบต้นไม้ เป็นลักษณะการเรียนรู้แบบมีผู้สอน มีลักษณะการแบ่งชุดข้อมูลเป็นกลุ่มต่าง ๆ มีการใช้ คุณลักษณะในการจำแนกประเภทในแต่ละ

โหนด (node) เพื่อใช้ในการทำนายผล การตัดสินใจประเภทนี้ มีการตัดสินใจที่เลียนแบบมนุษย์และเข้าใจง่าย มีลักษณะในการเรียกได้แก่ 1) Root Node 2) Decision Node 3) Leaf Node มีลักษณะการจำแนกดังรูปที่ 1



รูปที่ 1 : การตัดสินใจแบบต้นไม้ [6]

3.1.2) *Naïve Bayes* [7]: เป็นลักษณะของอัลกอริทึมที่ใช้วิธีการคิดแบบลักษณะของความน่าจะเป็นการอาศัยค่าต่อเนื่องจากเหตุการณ์ก่อนหน้า ส่วนใหญ่ในการจัดกลุ่มและแยกประเภทด้วยการใช้สมการ (1) ในการคำนวณ ดังนี้

$$P(c|x) = \frac{P(x|c)P(c)}{P(x)} \quad (1)$$


โดยที่ P หมายถึง ความน่าจะเป็น (probability)

c หมายถึง ลำดับชั้น (class)


x หมายถึง คุณลักษณะ (attribute)

3.1.3) *Support Vector Machine* [8]: ลักษณะในการจำแนกชุดข้อมูลด้วยวิธีการหา Hyperplane ใช้สำหรับแบ่งข้อมูลที่ต่างกันเพื่อหาจุดต่างกันระหว่างแต่ละจุดเป็น Margin ที่มีความกว้างมากที่สุด และข้อดีของการจำแนกลักษณะนี้คือ มีความสามารถในการจำแนกข้อมูลที่มีมิติสูง มีลักษณะในการจำแนกดังรูปที่ 2

3.1.4) *Neural Networks* [9]: เป็นอัลกอริทึมที่เลียนแบบการคิดวิเคราะห์แบบมนุษย์ จากลักษณะในการคิดนี้โมเดลของอัลกอริทึมนี้จะมีส่วนประกอบหลัก 3 ส่วน ประกอบด้วย 1) Input Layer ซึ่งเป็นส่วนที่รับข้อมูลและส่งต่อ 2) Hidden Layer มีหน้าที่ในการวิเคราะห์ข้อมูลที่รับมาจากชั้น Input Layer เช่นการจัดการ การเรียงข้อมูล เป็นต้น ทำให้ช่วยในการตัดสินใจได้ดีขึ้น 3) Output Layer เป็นส่วนแสดงผลในการจำแนกประเภทในการตัดสินใจของข้อมูลที่ได้รับต่อมาจากชั้น Hidden Layer มีรูปแบบในการคิดดังรูปที่ 3



รูปที่ 2 : การตัดสินใจ Support Vector Machine [10]



รูปที่ 3 : การตัดสินใจ Neural Networks [11]

3.2) การรวมกลุ่มแบบไฮบริด (Hybrid Ensemble Method) [12], [13]: เป็นเทคนิคการเรียนรู้ของเครื่องแบบรวมโมเดล (Ensemble Learning) ซึ่งใช้อัลกอริทึม หลายประเภทมาผสมผสานกันเพื่อสร้างโมเดลที่มีประสิทธิภาพและแม่นยำมากขึ้น ในลักษณะการทำงานของ Hybrid Ensemble Method มีขั้นตอนดังนี้ 1) การสอนตัวแบบจากอัลกอริทึมมากกว่า 1 อัลกอริทึมจากชุดข้อมูลเดียวกัน จะได้ผลลัพธ์ที่หลากหลาย 2) นำอัลกอริทึมอีก 1 แบบนำมาตัดสินใจ

ข้อดีของ Hybrid Ensemble Method คือ มีความแม่นยำที่สูงกว่าการใช้อัลกอริทึมชนิดเดียวในการตัดสินใจ

3.3) การประเมินตัวแบบ (Model Evaluation) [14]

ในขั้นตอนสำหรับการประเมินค่าประสิทธิภาพตัวแบบนี้ หลังจากการใช้อัลกอริทึมในการทำนาย จะได้ค่าที่ทำนายจากตัวแบบ จากชุดคำสั่งในโปรแกรม RapidMiner Studio

ทำการประเมินค่าประสิทธิภาพของตัวแบบโดยใช้ค่าต่าง ๆ ได้แก่ ค่าความแม่นยำ (accuracy) ค่าความเที่ยง (precision) ค่าความระลึก (recall) และ ค่าความถ่วงดุล (F-measure) นั้นสามารถคำนวณได้จากสมการ (2)–(5)

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

$$\text{Precision} = \frac{TP}{TP+FP} \quad (3)$$

$$\text{Recall} = \frac{TP}{TP+FN} \quad (4)$$

$$\text{F-Measure} = 2 \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (5)$$

โดยที่ TP	เป็นค่าที่การเรียนรู้ของเครื่องสามารถตัดสินใจได้ถูกต้องตามที่คาดหวัง
TN	เป็นค่าที่การเรียนรู้ของเครื่องสามารถตัดสินใจตรงกับค่าที่ไม่ได้คาดหวัง
FP	เป็นค่าที่การเรียนรู้ของเครื่องตัดสินใจเป็นผลลบ แต่ไม่ตรงกับค่าที่คาดหวัง
FN	เป็นค่าที่การเรียนรู้ของเครื่องตัดสินใจเป็นผลลบ และตรงกับค่าที่ไม่ได้คาดหวัง
Accuracy	เป็นค่าความแม่นยำ ที่เกิดหลังการเรียนรู้ของเครื่อง เท่ากับ ผลบวกจริงรวมกับผลลบจริงหารด้วยจำนวนที่ทำนายทั้งหมด
Precision	เป็นค่าความเที่ยง คือค่าที่เกิดขึ้นเมื่อทำซ้ำได้เหมือนเดิม
Recall	เป็นค่าความระลึก คือค่าที่สนใจในค่าการทำนายที่เป็นจริงตรงตามข้อมูล

3.4) งานวิจัยที่เกี่ยวข้อง

Elmouatamid *et al.* [15] ได้วิจัยเรื่องการตรวจจับและวินิจฉัยข้อบกพร่องของระบบปรับอากาศแนวทางการตรวจจับและขับเคลื่อนด้วยข้อมูล ได้ใช้วิธีการในการตรวจจับความผิดปกติของระบบปรับอากาศด้วยวิธีการต่าง ๆ เช่น Rule Base ของระบบเครื่องปรับอากาศ และทฤษฎีของการทำความเข้าใจ เพื่อพัฒนาวิธีการตรวจจับข้อบกพร่องในระบบปรับอากาศให้มีประสิทธิภาพมากขึ้น รวมถึงมีการใช้อัลกอริทึมหลายประเภท ได้แก่ Support Vector Machine, Decision Tree, Extra Tree Classifies และ Ada Boost Classifiers สรุปในงานวิจัยชี้ให้เห็นถึงข้อบกพร่องของวิธีการตรวจจับข้อบกพร่องในระบบปรับอากาศปัจจุบัน เฉพาะการตรวจจับข้อบกพร่องเล็กน้อยที่ส่งผลต่อประสิทธิภาพการทำงานและการใช้พลังงาน รวมถึงความจำเป็นในการพัฒนา

วิธีการใหม่ที่ทำให้ตรวจจับข้อบกพร่องพร้อมกันได้ โดยใช้ประโยชน์จากข้อมูลและเทคโนโลยีสารสนเทศใหม่ ๆ เช่น ปัญญาประดิษฐ์ อินเทอร์เน็ตของสรรพสิ่ง และการเรียนรู้ของเครื่อง เพื่อเพิ่มประสิทธิภาพ ความแม่นยำ รวมถึงการทำให้ระบบปรับอากาศเป็น “Smart Service” ที่มีปฏิสัมพันธ์กับสภาพแวดล้อมและผู้ใช้ระบบ

4) วิธีดำเนินการวิจัย

ในขั้นตอนวิธีดำเนินการวิจัยนั้นทางผู้วิจัย ได้นำชุดข้อมูลที่เกี่ยวข้องของระบบปรับอากาศชนิดรวมศูนย์แบบปรับน้ำยาแปรผัน และใช้ชุดโปรแกรม RapidMiner Studio เพื่อประเมินค่าประสิทธิภาพตัวแบบ

4.1) ชุดข้อมูลระบบของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน


ชุดข้อมูลที่ได้นำมาใช้ในงานวิจัยนี้ได้รับจากทาง บริษัท เบตเตอร์ คูล จำกัด ซึ่งภายในชุดข้อมูลมีจำนวนเครื่องและอุปกรณ์ประกอบไปด้วย ชุดคอยล์ร้อน (outdoor unit) จำนวน 3 ชุด และชุดคอยล์เย็น (indoor unit) จำนวน 14 ชุด ภายในชุดข้อมูลจะประกอบไปด้วย

4.1.1) ชุดคอยล์ร้อน ประกอบด้วย ข้อมูลอุณหภูมิ และข้อมูลแรงดันสารทำความเย็นภายในระบบ

4.1.2) ชุดคอยล์เย็น ประกอบด้วย ข้อมูลอุณหภูมิ

4.1.3) ข้อมูลสถานะผิดปกติของตัวระบบเครื่องปรับอากาศ มีการแสดงถึงสถานะการทำงานที่ปกติและผิดปกติของตัวระบบจากปริมาณสารทำความเย็น R-410a

ชุดข้อมูลนี้ได้ทำการรวบรวมข้อมูลภายในระบบเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน ไว้ในชุดข้อมูล VRF_DATA_CSV_FCU_14.CSV ประกอบด้วยข้อมูลที่รวบรวมจากการวัดค่าภายในระบบ เป็นข้อมูลที่รวบรวมระหว่าง เดือนมีนาคม – พฤษภาคม พ.ศ. 2566 จึงได้นำมาใช้สำหรับพัฒนาตัวแบบ ข้อมูลที่ได้รวบรวมเป็นข้อมูลจากอุปกรณ์วัดอุณหภูมิ (thermistor) และอุปกรณ์วัดแรงดัน (pressure sensor) ที่อยู่ในระบบเครื่องปรับอากาศ ดังรูปที่ 4



รูปที่ 4 : ตำแหน่งอุปกรณ์วัดอุณหภูมิ และวัดแรงดันสารทำความเย็นในระบบปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน

4.2) การจัดการข้อมูล (Data Preparation)

ขั้นตอนที่สองในการวิจัย เมื่อได้ชุดข้อมูลเบื้องต้นจำนวน 402 รายการ นำมาวิเคราะห์ คัดเลือกคุณลักษณะ (attribute) สถานะเครื่องตามทฤษฎีระบบปรับอากาศที่เกี่ยวข้องกับปริมาณสารทำความเย็น จึงทำให้ได้ชุดข้อมูลที่มีผลต่อการทำงานของตัวระบบเครื่องปรับอากาศเพื่อทำการวิเคราะห์ตัวชุดข้อมูล ดังตารางที่ 1


ตารางที่ 1 : รายละเอียดคุณลักษณะ (Attribute)

คุณลักษณะ	คำอธิบายคุณลักษณะ	รายละเอียดข้อมูล
Pres_HL	ค่าเฉลี่ยของแรงดันสารทำความเย็น	Min: 0 Psi/g Max: 316 Psi/g
SC_Temp.	ค่าเฉลี่ยของค่าความเย็นยิ่งยวด (subcooled value)	Min: -90 °C Max: 30.93 °C
SH_Temp.	ค่าเฉลี่ยของค่าความร้อนยิ่งยวด (superheated value)	Min: -1.85 °C Max: 15.71 °C
Start	จำนวนเครื่องที่กำลังทำงาน	Min: 0 Max: 14
Stop	จำนวนเครื่องที่กำลังหยุดทำงาน	Min: 0 Max: 14
LABEL	สถานะการทำงานปกติ และ ผิดปกติ	Status Fail / Normal

คุณลักษณะตามตารางที่ 1 มีการวัดค่าดังนี้ Press_HL ปอนด์ต่อตารางนิ้ว (Pound per Square Inch), SC_Temp และ SH_Temp เป็น องศาเซลเซียส ($^{\circ}\text{C}$), Start และ Stop คือจำนวนที่เครื่องคอยล์เย็น กำลังทำงานหรือหยุดทำงาน ในสถานะ LABEL ของการทำงานนี้เป็นตัวกำหนดให้ตัวระบบเครื่องปรับอากาศรวมศูนย์แบบระบบปรับน้ำยาแปรผัน สามารถทำงานได้ปกติ (normal) หรือไม่สามารถทำงานได้ตามปกติ (fail) มีจำนวนและอัตราส่วน ดังตารางที่ 2

ตารางที่ 2 : สถานะการทำงานในระบบปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน

สถานะการทำงาน	จำนวน	อัตราส่วน (%)
ปกติ (normal)	323	80.30
ไม่ปกติ (fail)	79	19.70
รวมทั้งสิ้น	402	100.00




รูปที่ 5 : ขั้นตอนการดำเนินงานวิจัย

4.3) พัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน โดยใช้การเรียนรู้ของเครื่องทางผู้วิจัยได้ทำการทบทวนวรรณกรรมเพื่อทำการศึกษางานวิจัยที่เกี่ยวข้องกับการใช้การเรียนรู้ของเครื่อง และงานวิจัยในด้านระบบเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน รวมถึงการเปรียบเทียบค่าประสิทธิภาพของอัลกอริทึมประเภทต่าง ๆ ที่ใช้ในการจำแนก เพื่อให้สามารถเพิ่มประสิทธิภาพของตัวแบบ ตามที่แสดงในรูปที่ 5 ขั้นตอนการดำเนินการวิจัย และออกแบบการวิจัย

4.4) การสอนและการทดสอบ (Training & Testing)


ในขั้นตอนนี้จะเป็นการสอนและการทดสอบการเรียนรู้ของเครื่อง เป็นลักษณะของการสอนแบบมีผู้สอน ซึ่งทางผู้วิจัยได้ทำการแบ่งชุดข้อมูลเป็น ใช้สำหรับการสอนร้อยละ 70 และสำหรับการทดสอบร้อยละ 30 ใช้ซอฟต์แวร์ RapidMiner Studio เป็นเครื่องมือในงานวิจัย โดยเลือกในลักษณะของการแบ่งเป็นชนิด Sampling type Automatic ดังรูปที่ 6



รูปที่ 6 : แบ่งชุดข้อมูลสำหรับสอน และทดสอบการเรียนรู้ของเครื่อง ในชุดโปรแกรม RapidMiner Studio

4.5) ออกแบบตัวแบบ (Model Building)

ในขั้นตอนการออกแบบตัวแบบนี้ นำชุดข้อมูลมาเข้ากระบวนการในการสร้างตัวแบบ ซึ่งทางผู้วิจัยได้ใช้อัลกอริทึมในการออกแบบทั้งสิ้น 4 แบบ ได้แก่ Decision Tree, Naïve Bayes, Support Vector Machine, และ Neural Networks ทำการใช้ชุดคำสั่งภายในโปรแกรม RapidMiner Studio ทำตัวแบบ โดยมีลักษณะดังรูปที่ 7



รูปที่ 7 : การออกแบบสำหรับทดสอบ อัลกอริทึม Decision Tree, Naive Bayes, Support Vector Machine และ Neural Networks


เมื่อทางผู้วิจัยทำการสร้างตัวแบบตามรูปที่ 4 แล้ว จะได้ลักษณะตัวแบบดังต่อไปนี้

4.5.1) *Decision Tree* จะมีลักษณะตัวแบบอัลกอริทึมดังรูปที่ 8


4.5.2) *Naive Bayes* จะมีลักษณะตัวแบบอัลกอริทึมดังรูปที่ 9

4.5.3) *Support Vector Machine* จะมีลักษณะตัวแบบอัลกอริทึมดังรูปที่ 10


4.5.4) *Neural Networks* จะมีลักษณะตัวแบบอัลกอริทึมดังรูปที่ 11




รูปที่ 8 : ลักษณะตัวแบบอัลกอริทึม Decision Tree



รูปที่ 9 : ลักษณะตัวแบบอัลกอริทึม Naive Bayes



รูปที่ 10 : ลักษณะตัวแบบอัลกอริทึม Support Vector Machine



รูปที่ 11 : ลักษณะตัวแบบอัลกอริทึม Neural Networks

จากนั้นผู้วิจัยตัดสินใจเลือกใช้งานด้วยอัลกอริทึมทั้ง 4 รูปแบบนี้ทางผู้วิจัยได้ทำการประเมินตัวแบบขั้นต่อไป

4.6) การประเมินตัวแบบ (Model Evaluation) [14]

ในขั้นตอนสำหรับการประเมินตัวแบบนี้ เมื่อผู้วิจัยได้ใช้อัลกอริทึมในการทำนาย จะได้ค่าที่ทำนายจากตัวแบบจากชุด

คำสั่งในชุดโปรแกรม RapidMiner Studio จากนั้นทำการประเมินค่าประสิทธิภาพของตัวแบบด้วยการใช้ค่าต่าง ๆ ได้แก่ ค่าความแม่นยำ (accuracy) ค่าความเที่ยง (precision) ค่าความระลึก (recall) และ ค่าความถ่วงดุล (F-Measure) นั้นคำนวณได้จากสมการ (2) - (5)

5) ผลการวิจัย

ในงานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผันโดยใช้การเรียนรู้ของเครื่องจากชุดข้อมูลจำนวน 402 รายการเพื่อนำมาเปรียบเทียบค่าประสิทธิภาพ โดยใช้อัลกอริทึม 4 แบบ ได้แก่ Decision Tree, Naïve Bayes, Support Vector Machine และ Neural Networks เพื่อประเมินค่าประสิทธิภาพตัวแบบได้ค่าประสิทธิภาพดัง

ตารางที่ 3 : ค่าประสิทธิภาพของอัลกอริทึม Decision Tree, Naïve Bayes, Support Vector Machine และ Neural Networks

Algorithm	Accuracy (%)	Precision (%)	Recall (%)	F-Measure (%)
Decision Tree	93.39	93.20	98.97	96.00
Naïve Bayes	92.56	94.00	96.91	95.43
Support Vector Machine	83.47	85.32	95.88	90.29
Neural Networks	95.04	94.17	100.00	97.00

จากตารางที่ 3 ทำให้ทราบค่าประสิทธิภาพของอัลกอริทึมทั้ง 4 แบบดังนี้

1) Decision Tree ได้ค่าความแม่นยำเท่ากับ 93.39% ค่าความเที่ยงเท่ากับ 93.20% ค่าความระลึกเท่ากับ 98.97% และค่าความถ่วงดุลเท่ากับ 96.00%

2) Naïve Bayes ได้ค่าความแม่นยำเท่ากับ 92.56% ค่าความเที่ยงเท่ากับ 94.00% ค่าความระลึกเท่ากับ 96.91% และค่าความถ่วงดุลเท่ากับ 95.43%

3) Support Vector Machine ได้ค่าความแม่นยำเท่ากับ 83.47% ค่าความเที่ยงเท่ากับ 85.32% ค่าความระลึกเท่ากับ 95.88% และค่าความถ่วงดุลเท่ากับ 90.29%

4) Neural Network ได้ค่าความแม่นยำเท่ากับ 95.04% ค่าความเที่ยงเท่ากับ 94.17% ค่าความระลึกเท่ากับ 100.00% ค่าความถ่วงดุลเท่ากับ 97.00%


ทั้งนี้ มีการใช้เวลาในการคำนวณของอัลกอริทึมแต่ละประเภท โดยแสดงเวลาดังตารางที่ 4

ตารางที่ 4 : เวลาในการคำนวณของอัลกอริทึม Decision Tree, Naïve Bayes, Support Vector Machine และ Neural Networks

ครั้งที่	Decision Tree	Naïve Bayes	Support Vector Machine	Neural Networks
1	0.03	0.02	0.04	1.11
2	0.02	0.01	0.05	0.82
3	0.01	0.01	0.02	0.70
4	0.02	0.01	0.04	0.63
5	0.01	0.01	0.05	0.76
6	0.02	0.01	0.06	0.71
7	0.02	0.02	0.03	0.67
8	0.01	0.01	0.03	0.63
9	0.02	0.01	0.04	0.72
10	0.02	0.01	0.03	0.71
Average (S)	0.02	0.01	0.04	0.75


จากค่าเฉลี่ยของการคำนวณของอัลกอริทึมจำนวน 10 ครั้งที่ใช้เวลาในการทำน้อยที่สุดคือ Naïve Bayes ซึ่งได้ค่าเป็น 0.01 วินาที

จากวัตถุประสงค์เพื่อพัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน VRF โดยใช้การเรียนรู้ของเครื่อง ในส่วนเหตุการณ์การเสียของเครื่องปรับอากาศมาจากปริมาณสารทำความเย็นเพื่อการพัฒนาตัวแบบทางผู้วิจัยได้ทำการได้ใช้แนวคิดในการพัฒนาตัวแบบทำนายด้วยการใช้วิธีการเรียนรู้แบบ Hybrid Ensemble Method [13], [12] ในแบบการตัดสินใจด้วยวิธี Stacking [16] ด้วยวิธีการเรียนรู้เป็นการใช้อัลกอริทึมในหลาย ๆ แบบเพื่อเพิ่มประสิทธิภาพได้ทำการออกแบบจากอัลกอริทึมที่ได้ประเมินค่าประสิทธิภาพดังตารางที่ 3 ผู้วิจัยได้ใช้อัลกอริทึมที่มีค่าประสิทธิภาพสูงสุดและรองลงมาสองอันดับ ได้แก่ Neural Networks, Decision Tree และ Naïve Bayes ในการจำแนกดังรูปที่ 12



รูปที่ 12 : ขั้นตอนการพัฒนาตัวแบบ Stacking Model

ภายในขั้นตอนที่ 1 Input นำข้อมูลเครื่องปรับอากาศชนิดรวมศูนย์แบบน้ำยาแปรผัน โดยใช้ชุดโปรแกรม RapidMiner Studio ในการนำเข้าชุดข้อมูลสำหรับการฝึกสอน ขั้นตอนที่ 2 Process ทำการเลือกอัลกอริทึมในการสอนการเรียนรู้ของเครื่องเพื่อมาใช้เทคนิค Hybrid Ensemble Method แบบ Stacking ใช้อัลกอริทึม 3 ชนิด ในการตัดสินใจได้แก่ Neural Networks, Decision Tree และ Naive Bayes ในการตัดสินใจ เพื่อพัฒนาตัวแบบให้ค่าประสิทธิภาพที่เพิ่มขึ้น ดังรูปที่ 13



รูปที่ 13 : Hybrid Ensemble Method แบบ Stacking


ขั้นตอนที่ 3 Output จะได้รับผลทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบปรับน้ำยาแปรผัน และนำมาประเมินประสิทธิภาพตัวแบบ ได้ดังตารางที่ 5

ตารางที่ 5 : ค่าประสิทธิภาพของอัลกอริทึม Hybrid Ensemble Method

แบบ Stacking

Algorithm	Accuracy (%)	Precision (%)	Recall (%)	F-Measure (%)
Stacking	95.52	97.21	97.21	97.21
Neural Networks	95.04	94.17	100.00	97.00

จากตารางที่ 5 ตัวแบบมีค่าประสิทธิภาพ ค่าความแม่นยำ (accuracy) เท่ากับ 95.52% ค่าความเที่ยง (precision) เท่ากับ 97.21% ค่าความระลึก (recall) 97.21% และค่าความถ่วงดุล F-Measure 97.21%



รูปที่ 14 : กราฟแสดงประสิทธิภาพ Hybrid Ensemble

จากรูปที่ 14 กราฟค่าประสิทธิภาพที่ได้รับเพิ่มสูงขึ้นจากเดิมในการใช้อัลกอริทึม Neural Networks เทียบกับการใช้การเรียนรู้ของเครื่องจากการใช้เทคนิค Hybrid Ensemble Method แบบ Stacking ทำให้ได้ค่าประสิทธิภาพที่สูงขึ้นจากเดิมด้วยค่าความแม่นยำมากถึง 95.52% ค่าความเที่ยง 97.21% ค่าความระลึก 97.21% และค่าความถ่วงดุล 97.21% และเพื่อทำการเปรียบเทียบระยะเวลาในการทำงานระหว่างอัลกอริทึม Neural Networks และวิธีการ Hybrid Ensemble Method แบบ Stacking ผู้วิจัยได้ทำการทดสอบจำนวน 10 ครั้งเพื่อหาค่าเฉลี่ยระยะเวลาดังตารางที่ 6

ตารางที่ 6 : เวลาเปรียบเทียบการคำนวณของอัลกอริทึม Neural Networks และ Hybrid Ensemble Method แบบ Stacking

ครั้งที่	Neural Networks	Stacking
1	1.11	3.86
2	0.82	4.21
3	0.70	3.72
4	0.63	4.26
5	0.76	3.82
6	0.71	3.62
7	0.67	4.03
8	0.63	4.03
9	0.72	3.85
10	0.71	3.72
Average (S)	0.75	3.91

ทำให้ทราบเวลาในการคำนวณของอัลกอริทึม Neural Networks มีระยะเวลาในการคำนวณที่สั้นกว่าแบบ Stacking Model

6) อภิปรายผลการวิจัย

ผลการศึกษาการพัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศที่มีผลต่ออาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน โดยใช้การเรียนรู้ของเครื่องในส่วนเหตุการณ์การเสียของเครื่องปรับอากาศมาจากปริมาณสารทำความเย็นนี้ สามารถสรุปได้ว่าการเลือกใช้งานอัลกอริทึมสำหรับสร้างตัวแบบในการทำนายอาการเสียจากส่วนสารทำความเย็นนั้น การใช้เทคนิค Hybrid Ensemble Method แบบ Stacking ใช้อัลกอริทึมที่มีค่าประสิทธิภาพสูงสุดและรองลงมาสองอันดับ ได้แก่ Neural Networks และ Decision Tree และ Naive Bayes มีค่าประสิทธิภาพที่มีค่าความแม่นยำ ค่าความเที่ยง ค่าระลึก และค่าความถ่วงดุลที่สูงที่สุดในการเปรียบเทียบค่าจากอัลกอริทึมทั้ง 4 แบบ และแบบ Hybrid Ensemble Method แบบ Stacking

จึงทำให้สามารถสรุปผลการพัฒนาตัวแบบในการทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน โดยใช้การเรียนรู้ของเครื่องในส่วนสารทำความเย็นเพื่อช่วยในการทำนายอาการเสีย จากการใช้อัลกอริทึมแบบ Hybrid Ensemble Model ช่วยในการเรียนรู้ของเครื่อง

7) สรุปผลการวิจัย

งานวิจัยนี้ได้ทำการศึกษาวิจัยในวัตถุประสงค์นี้ เพื่อพัฒนาตัวแบบทำนายอาการเสียของเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผัน โดยใช้การเรียนรู้ของเครื่อง จากชุดข้อมูลระบบเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบปรับน้ำยาแปรผันที่มีข้อมูลในส่วนเหตุการณ์การเสียของเครื่องปรับอากาศมาจากปริมาณสารทำความเย็น และส่วนของ รายละเอียดข้อมูล อุณหภูมิ ข้อมูลแรงดัน และส่วนฉลากที่ระบุถึงสถานะอาการที่มีสาเหตุจากสารทำความเย็น นั้นมีระบุเป็นคุณลักษณะชื่อ Label โดยทางผู้วิจัยนำชุดข้อมูลมาทำการวิเคราะห์ โดยชุดโปรแกรม RapidMiner Studio ในการสร้างตัวแบบจากอัลกอริทึมทั้ง 4 ประเภท ได้แก่ Decision Tree, Naive Bayes, Support Vector Machine และ Neural Networks มาเพื่อใช้ในการประเมินประสิทธิภาพ

อย่างไรก็ตาม ในการขยายผลตัวแบบทำนาย ทางผู้วิจัยได้ทำการเลือกอัลกอริทึมในการสอนการเรียนรู้ของเครื่องโดยใช้เทคนิค Hybrid Ensemble Method แบบ Stacking ใช้อัลกอริทึม 2 ชนิด คือ Neural Networks และ Decision Tree และใช้อัลกอริทึมในการตัดสินใจเป็น Naive Bayes ทำให้ได้ค่าประสิทธิภาพที่เพิ่มสูงขึ้นจากเดิม ทำให้ตัวแบบสามารถทำนายอาการเสียของเครื่องได้แม่นยำมากยิ่งขึ้น โดยมีค่าความแม่นยำ (accuracy) 95.52%, ค่าความเที่ยง (precision) 97.21%, ค่าความระลึก (recall) 97.21% ค่าความถ่วงดุล (F-Measure) 97.00%

8) ข้อจำกัดของงานวิจัย

ในงานวิจัยนี้มุ่งเน้นในการศึกษาระบบสารทำความเย็นในระบบปรับอากาศชนิดรวมศูนย์แบบน้ำยาแปรผัน โดยที่ตัวแบบนี้สร้างขึ้นเฉพาะทำนายอาการเสียในส่วนเหตุการณ์การเสียของเครื่องปรับอากาศมาจากปริมาณสารทำความเย็นนั้นข้อจำกัดในเรื่องจำนวนชุดคอยล์ร้อน และชุดคอยล์เย็น

9) ข้อเสนอแนะ

จากงานวิจัยนี้ เนื่องจากระบบปรับอากาศชนิดรวมศูนย์มีข้อมูลและพีเจอร์ที่หลากหลายที่ใช้ในการทำนายอาการในลักษณะหรือสาเหตุอื่น และด้วยลักษณะของตัวระบบมีความซับซ้อนในการทำงานของระบบทำให้ ผู้ตรวจสอบอาจเกิดความผิดพลาดในการวิเคราะห์อาการเสีย รวมถึงความหลากหลายของ

ชนิดคอยล์เย็น และคอยล์ร้อน อาจทำให้มีความหลากหลายใน
อาการเสียมากขึ้น

ด้วยข้อจำกัดของชุดข้อมูลที่มีสถานะการทำงานปกติ และ
อาการเสียจากสารทำความเย็นภายในระบบไม่เท่ากัน โดยมีการ
ทำงานปกติที่มากกว่า อาจทำให้เกิดผลกระทบในการสอนการ
เรียนรู้ของเครื่องโดยตรง ในจุดที่กล่าวนี้สามารถใช้วิธีการ SMOTE
(Synthetic Minority Over-sampling Technique) เป็นวิธีการ
จัดการเกี่ยวกับข้อมูลที่ไม่สมดุล (Class imbalance) ได้อีกวิธี
เช่นกัน

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับความอนุเคราะห์จาก บริษัท เบตเตอร์ คู
จำกัด ในชุดข้อมูลเครื่องปรับอากาศชนิดรวมศูนย์แบบระบบ
ปรับน้ำยาแปรผัน (VRF_DATA_CSV_FCU_14.CSV) และขอ
ขอบคุณ ท่าน ศ. ดร.ประสงค์ ปราณีตพลกรัง อาจารย์ที่ปรึกษา
และคณะทำงานที่ให้คำปรึกษา สนับสนุนและแนะนำในงานวิจัย
นี้ จนเสร็จสมบูรณ์

REFERENCES

- [1] Department of Public Works and Town & Country Planning. "Roles and Responsibilities." DPT.go.th. <https://www.dpt.go.th/th/powers-and-duties-of-departments-and-government-agencies> (accessed Oct. 19, 2023).
- [2] Green Government Office Design Guidelines for New Construction. G-Goods : NC Version 1.0 (in Thai), Department of Public Works and Town & Country Planning, Dec. 2022. [Online]. Available: <https://www.dpt.go.th/th/documents-dpt/961>
- [3] R. E. Neapolitan and X. Jiang, *Artificial Intelligence: With an Introduction to Machine Learning*, 2nd ed. New York, NY, USA: Chapman and Hall/CRC Press, 2018.
- [4] T. Jo, "Introduction," in *Machine Learning Foundations: Supervised, Unsupervised, and Advanced Learning*. Cham, Switzerland: Springer International Publishing, 2021, ch. 1, pp. 1–15.
- [5] B. Charbuty and A. M. Abdulazeez, "Classification based on decision tree algorithm for machine learning," *J. Appl. Sci. Technol. Trends*, vol. 2, no. 1, pp. 20–28, Jan. 2021.
- [6] N. S. Chauhan. "Decision Tree Algorithm, Explained." KDNUGETS.com. <https://www.kdnuggets.com/2020/01/decision-tree-algorithm-explained.html> (accessed Feb. 19, 2024).
- [7] T. N. Viet, H. L. Minh, L. C. Hieu, and T. H. Anh, "The Naïve Bayes algorithm for learning data analytics," *Indian J. Comput. Sci. Eng.*, vol. 12, no. 4, pp. 1038–1043, 2021.
- [8] R. Akbani, S. Kwek, and N. Japkowicz, "Applying support vector machines to imbalanced datasets," in *Proc. 15th Eur. Conf. Mach. Learn.*, Pisa, Italy, Sep. 2004, pp. 39–50.
- [9] A. C. Müller and S. Guido, "Supervised Learning," in *Introduction to Machine Learning with Python: A Guide for Data Scientists*. Sebastopol, CA, USA: O'Reilly Media, 2016, ch. 2, pp. 106–120.
- [10] S. Bandgar. "Support Vector Machine." MEDIUM.com. <https://medium.com/nerd-for-tech/support-vector-machine92fa3c57d33b> (accessed Feb. 19, 2024).
- [11] S. Krishna. "Building an Artificial Neural Network(ANN)." MEDIUM.com. <https://medium.com/@saikrishna3599/building-an-artificial-neural-network-ann-502a63d76fb3> (accessed Jun. 30, 2020).
- [12] S. Pal and S. Paul, "Linking hydrological security and landscape insecurity in the moribund deltaic wetland of India using tree-based hybrid ensemble method in python," *Ecological Inform.*, vol. 65, Sep. 2021, Art. no. 101422.
- [13] J. Zhao, J. Jin, S. Chen, R. Zhang, B. Yu, and Q. Liu, "A weighted hybrid ensemble method for classifying imbalanced data," *Knowl.-Based Syst.*, vol. 203, Jun. 2020, Art. no. 106087.
- [14] T. Srivastava. "12 Important Model Evaluation Metrics for Machine Learning Everyone Should Know (Updated 2023)." ANALYTICSVIDHYA.com. <https://www.analyticsvidhya.com/blog/2019/08/11-important-model-evaluation-error-metrics/> (accessed Jan. 8, 2024).
- [15] A. Elmouatamid, B. Fricke, J. Sun, and P. W. T. Pong, "Air conditioning systems fault detection and diagnosis-based sensing and data-driven approaches," *Energies*, vol. 16, no. 12, Jun. 2023, Art. no. 4721.
- [16] M. Yang, L. Cheng, M. Cao, and X. Yan, "A stacking ensemble learning method to classify the patterns of complex road junctions," *ISPRS Int. J. Geo-Inf.*, vol. 11, no. 10, Oct. 2022, Art. no. 523, doi: 10.3390/ijgi11100523.