


การพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงไฟฟ้ากำลังสำหรับการประเมินสมรรถนะ
โดยใช้แบบจำลองการเรียนรู้ของเครื่อง



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมไฟฟ้า ภาควิชาวิศวกรรมไฟฟ้า
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2562
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Prediction of Top-Oil Temperature in Power Transformers for Performance Assessment Using
Machine Learning Model



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 2019

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงไฟฟ้ากำลังสำหรับการประเมินสมรรถนะโดยใช้แบบจำลองการเรียนรู้ของเครื่อง
โดย	นายสุวพันธุ์ อริเดช
สาขาวิชา	วิศวกรรมไฟฟ้า
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.ชาลยุทธรงค์ บาลมงคล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	ประธานกรรมการ
.....	
(ศาสตราจารย์ ดร.บุญชัย เตชะอำนาง)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.ชาลยุทธรงค์ บาลมงคล)	
.....	กรรมการภายนอกมหาวิทยาลัย
(รองศาสตราจารย์ ดร.นรเศรษฐ์ พัฒนเดช)	

สุวพันธุ์ อริเดช : การพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงไฟฟ้ากำลัง
สำหรับการประเมินสมรรถนะโดยใช้แบบจำลองการเรียนรู้ของเครื่อง. (Prediction of
Top-Oil Temperature in Power Transformers for Performance Assessment Using
Machine Learning Model) อ.ที่ปรึกษาหลัก : ผศ. ดร.ชาญณรงค์ บาลมงคล

อายุการใช้งานที่สูญเสียไปจากการใช้งานหม้อแปลงมีสาเหตุหลักมาจากค่าอุณหภูมิที่
เกิดขึ้นภายในหม้อแปลง ได้แก่ค่าอุณหภูมิขดลวดและอุณหภูมิน้ำมัน หม้อแปลงที่ทำงานใน
สภาวะการจ่ายโหลดและอุณหภูมิแวดล้อมค่าหนึ่งจะเกิดความร้อนภายในที่แตกต่างกันทั้งนี้
ขึ้นอยู่กับสภาพในปัจจุบันและการเสื่อมสภาพในอดีตของหม้อแปลง วิทยานิพนธ์นี้ศึกษา
แบบจำลองการเรียนรู้ของเครื่องที่สามารถเรียนรู้พฤติกรรมการเกิดความร้อนภายในหม้อแปลง
โดยใช้ข้อมูลในอดีตเพื่อพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดของหม้อแปลงที่
จะเกิดขึ้นก่อนการใช้งานจริง ข้อมูลดังกล่าวสามารถนำมาหาอายุการใช้งานที่คาดว่าจะสูญเสียไป
ของหม้อแปลงแต่ละตัวเพื่อใช้ในการวางแผนการส่งจ่ายกำลังไฟฟ้าและการเลือกบำรุงรักษา
อุปกรณ์ นอกจากนี้การใช้ขอบเขตการพยากรณ์ช่วยตรวจสอบข้อมูลพฤติกรรมทางความร้อน
ของหม้อแปลงเพื่อใช้ตรวจสอบหาสัญญาณที่อาจบ่งชี้ความผิดปกติหรือการเสื่อมสภาพของหม้อ
แปลงได้ โดยจากผลการทดสอบแสดงให้เห็นว่าข้อมูลจากแบบจำลองการเรียนรู้ของเครื่อง
สามารถพยากรณ์อายุการใช้งานที่สูญเสียของหม้อแปลงได้ใกล้เคียงกับการใช้ข้อมูลที่ตรวจวัดได้
จริง นอกจากนี้วิทยานิพนธ์ฉบับนี้เสนอการสร้างขอบเขตการพยากรณ์เป็นอีกหนึ่งวิธีที่ช่วยใน
การติดตามความเปลี่ยนแปลงพฤติกรรมทางความร้อนของหม้อแปลงซึ่งมีประโยชน์ในการ
บริหารจัดการหม้อแปลง

สาขาวิชา วิศวกรรมไฟฟ้า

ปีการศึกษา 2562

ลายมือชื่อนิติกร

ลายมือชื่อ อ.ที่ปรึกษาหลัก

6170317221 : MAJOR ELECTRICAL ENGINEERING

KEYWORD: Machine Learning Models, Artificial neural network, Recurrent neural network, Loss of life, Power transformer, Random forest, Prediction interval, Decision tree

Suwapan Aridej : Prediction of Top-Oil Temperature in Power Transformers for Performance Assessment Using Machine Learning Model. Advisor: Asst. Prof. Channarong Banmonkol, Ph.D.

Transformer loss-of-life mainly depends on the temperature of winding and oil inside the transformer. Transformers, which operate at a certain load and ambient temperature generate different levels of heat depending on present conditions and past deterioration. This thesis presents machine learning models which can learn transformer temperature behavior using past data to forecast top-oil and winding temperatures. These temperature forecasts are used for calculating the expected transformer loss-of-life that is useful to power transmission planning and equipment maintenance. Moreover, this thesis applies the prediction interval to examine transformer temperature behavior which can detect anomaly or deterioration in the transformer. The results showed that the machine learning models can predict transformer loss-of-life closely to that calculated from measured data. Moreover, this thesis proposes the prediction interval model as a tool to track a change in transformer thermal behavior for asset management.

Field of Study: Electrical Engineering

Student's Signature

Academic Year: 2019

Advisor's Signature

กิตติกรรมประกาศ

ในการทำวิทยานิพนธ์ครั้งนี้จะเกิดขึ้นไม่ได้ถ้าหากไม่ได้รับการแนะนำและการสนับสนุนของ ผศ. ดร.ชาญณรงค์ บาลมงคล ซึ่งเป็นอาจารย์ที่ปรึกษา ที่ให้ความรู้และคำแนะนำเกี่ยวกับแบบจำลองของหม้อแปลง พร้อมทั้งช่วยปรับปรุง แกไขจนวิทยานิพนธ์นี้เสร็จสมบูรณ์ และยังให้คำปรึกษาตลอดเวลาในการทำวิทยานิพนธ์นี้

ขอขอบคุณ ศ.ดร.บุญชัย เตชะอำนาจ และ รศ.ดร.นรเศรษฐ พัฒนเดช ที่สละเวลามาเป็นกรรมการสอบวิทยานิพนธ์ คอยให้คำแนะนำ เสนอมุมมองใหม่ๆที่ทำให้ได้การทดลองเพิ่มเติมจากเดิม

ขอขอบคุณฝ่ายบริหารจัดการสินทรัพย์ระบบส่ง กฟผ. ที่อนุเคราะห์ข้อมูลที่จำเป็นในการสร้างแบบจำลองและเขียนวิทยานิพนธ์ และได้แบ่งปันประสบการณ์การบริหารจัดการและบำรุงรักษาหม้อแปลง

ขอขอบคุณ การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย ที่ได้มอบทุนและโอกาสในการศึกษาในโครงการความร่วมมือทาง Smart grid ระหว่าง กฟผ.-จุฬาลงกรณ์มหาวิทยาลัย ซึ่งได้เปิดโลกทัศน์และความรู้ทางด้าน Smart grid ให้ข้าพเจ้าอย่างมาก

ขอขอบคุณมิตรสหายทุกคนรวมทั้งเจ้าหน้าที่ที่ดูแลฝ่ายธุรการที่ให้คำแนะนำในการเขียนวิทยานิพนธ์ รวมทั้งกระบวนการทางด้านเอกสารและขั้นตอนต่างๆ

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สุวพันธุ์ อริเดช

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ก
บทคัดย่อภาษาอังกฤษ	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง	ฉ
สารบัญรูป	ญ
บทที่ 1 บทนำ	13
1.1 แนวทางและเหตุผลในการทำวิทยานิพนธ์.....	13
1.2 ที่มาและความสำคัญของปัญหา.....	13
1.3 วัตถุประสงค์ของวิทยานิพนธ์.....	15
1.4 ขอบเขตของวิทยานิพนธ์.....	15
1.5 ขั้นตอนการศึกษาและวิธีการดำเนินการ	16
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	17
1.7 งานวิจัยที่เกี่ยวข้อง	17
1.8 เนื้อหาของวิทยานิพนธ์	20
บทที่ 2 ทฤษฎีและความรู้ที่เกี่ยวข้อง	21
2.1 อายุการใช้งานของกระดาษฉนวนหม้อแปลง[1].....	21
2.2 การสูญเสียอายุการใช้งานของหม้อแปลงจากปัจจัยทางความร้อน	21
2.3 ผลของอุณหภูมิแวดล้อมต่อการจ่ายโหลดของหม้อแปลง	25
2.4 การคำนวณอุณหภูมิจุดร้อนที่สุดของขดลวดหม้อแปลง.....	26
2.5 ความรู้พื้นฐานเกี่ยวกับแบบจำลองการเรียนรู้ของเครื่อง.....	29

โครงข่ายประสาทเทียม (Artificial Neural Network).....	31
ต้นไม้การตัดสินใจ (Decision tree).....	33
โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network)	36
การเพิ่มขึ้นอย่างมากและการหายไปของเกรเดียน (Exploding and Vanishing gradient).....	38
โครงข่ายประสาทเทียมแบบวนซ้ำชนิด Long Short-Term Memory (LSTM).....	39
2.6 การสร้างขอบเขตข้อมูลโดยใช้ Bollinger Bands	42
2.7 ต้นไม้การถดถอยที่เคลื่อนลงตามความชัน (Gradient Boosting Regression Tree-GBRT) ...	44
Quantile Loss function	46
2.8 ความน่าจะเป็นของขอบเขตการพยากรณ์ในการครอบคลุมข้อมูล (Prediction Interval coverage probability-PICP).....	46
2.9 Overfitting และ Underfitting ของแบบจำลอง	48
บทที่ 3 แบบจำลองและขอบเขตการพยากรณ์ในการพยากรณ์ค่าอนุกรมของน้ำมันดิบและอนุกรมขดลวดในหม้อแปลง.....	49
3.1 การจัดการข้อมูลก่อนสร้างแบบจำลอง.....	49
ความสัมพันธ์ระหว่างข้อมูลขาเข้าและข้อมูลขาออก	54
3.2 แบบจำลองการเรียนรู้ของเครื่องโดยใช้โครงข่ายประสาทเทียม	56
3.3 แบบจำลองการเรียนรู้ของเครื่องโดยใช้ต้นไม้การตัดสินใจแบบประกอบ(ป่าแบบสุ่ม)	64
3.4 แบบจำลองการเรียนรู้ของเครื่องโดยใช้โครงข่ายประสาทเทียมแบบวนซ้ำ.....	71
3.5 แบบจำลองการเรียนรู้ของเครื่องโดยใช้ต้นไม้การถดถอยที่เคลื่อนลงตามความชัน (Gradient Boosting Regression Tree model-GBR)	75
3.6 ขอบเขตการพยากรณ์ของแบบจำลองการเรียนรู้ของเครื่อง	81
3.7 การใช้ผลการพยากรณ์ค่าอนุกรมของน้ำมันดิบและอนุกรมขดลวดในการพยากรณ์ค่าอายุการใช้งานที่จะสูญเสียของหม้อแปลง	82
3.8 การใช้ Percent B ในการจำแนกข้อมูลที่มีค่าเกินขอบเขตการพยากรณ์	84
3.9 การบริหารจัดการหม้อแปลงโดยใช้ผลการพยากรณ์จากแบบจำลอง.....	85

3.9.1 การใช้ผลการพยากรณ์อายุการใช้งานที่สูญเสีย	85
3.9.2 การใช้ขอบเขตการพยากรณ์	86
บทที่ 4 สรุปผลการศึกษา.....	88
สมรรถนะของแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์อุณหภูมิน้ำมันด้านบนและ อุณหภูมิขดลวด	88
ผลการพยากรณ์อายุการใช้งานที่สูญเสียของหม้อแปลง	89
ขอบเขตการพยากรณ์และ %B	90
บรรณานุกรม	92
ประวัติผู้เขียน	94



สารบัญตาราง

หน้า

ตารางที่ 1 จำนวนชั่วโมงที่ใช้ในการทำให้กระดาษฉนวนหมดสภาพที่ค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดตั้งแต่ 110 – 200 °C.....	25
ตารางที่ 2 ค่าประมาณของการเพิ่มขึ้นหรือลดลงของกำลังพิกัด (kVA) ในการใช้งานหม้อแปลงที่สถานะอุณหภูมิแวดล้อมต่างไปจากค่าพื้นฐาน	26
ตารางที่ 3 ค่าตัวประกอบที่ใช้ในการกำหนดสมการอุณหภูมิ[1]	28
ตารางที่ 4 ค่าสมรรถนะของแบบจำลองโครงข่ายประสาทเทียมในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง A และ B.....	61
ตารางที่ 5 ค่าสมรรถนะของแบบจำลองป่าแบบสุ่มในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบน .69	
ตารางที่ 6 ค่าสมรรถนะของแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำชนิด LSTM ในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง A และ B.....	74
ตารางที่ 7 ค่าสมรรถนะของแบบจำลองต้นไม้การตัดสินใจที่เคลื่อนลงตามความชันในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง A และ B.....	79
ตารางที่ 8 สมรรถนะของแบบจำลองการเรียนรู้ของเครื่อง.....	80
ตารางที่ 9 สรุปแบบจำลองในการพยากรณ์ตามสมรรถนะความสมบูรณ์.....	81
ตารางที่ 10 สมรรถนะค่า PICP, NMPIW และ CWC ของขอบเขตการพยากรณ์ในแต่ละแบบจำลอง.....	82
ตารางที่ 11 ผลการคำนวณค่าอายุการใช้งานที่สูญเสียของแต่ละแบบจำลอง.....	83
ตารางที่ 12 ค่าความคลาดเคลื่อนในการพยากรณ์อายุการใช้งานที่สูญเสียที่จำนวนข้อมูลต่างกัน ...	84

สารบัญรูป

หน้า

รูปที่ 1 ความสัมพันธ์ระหว่างอายุการใช้งานของฉนวนกระดาษและค่าอุณหภูมิจุดที่ร้อนที่สุด [1]	22
รูปที่ 2 ความสัมพันธ์ระหว่างค่าตัวประกอบการเร่งการเสื่อมสภาพและค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดในหม้อแปลง [1].....	23
รูปที่ 3 กระบวนการเรียนรู้และพยากรณ์ข้อมูลของแบบจำลองการเรียนรู้แบบมีผู้สอน[12]	30
รูปที่ 4 การถดถอยแบบเชิงเส้น[12].....	31
รูปที่ 5 หลักการทำงานของเพอร์เซปตรอน	32
รูปที่ 6 แบบจำลองโครงข่ายประสาทเทียมแบบหลายปมและหลายชั้น	33
รูปที่ 7 ตัวอย่างการใช้เหตุผลของมนุษย์	34
รูปที่ 8 การหาการถดถอยของข้อมูลโดยใช้แบบจำลองต้นไม้การตัดสินใจ[12].....	36
รูปที่ 9 กระบวนการทำงานของโครงข่ายประสาทเทียมแบบวนซ้ำ.....	37
รูปที่ 10 ค่า U V และ ความคลาดเคลื่อนเมื่อเกิดการเพิ่มขึ้นอย่างมากของเกรเดียนต์ [13]	39
รูปที่ 11 โครงสร้างการทำงานภายในของ LSTM [13]	40
รูปที่ 12 ข้อมูลจากเซนเซอร์ที่ถูกจัดเก็บ.....	50
รูปที่ 13 กระบวนการจัดการข้อมูลจากเซนเซอร์ก่อนนำไปใช้.....	50
รูปที่ 13 กระบวนการจัดการข้อมูลจากเซนเซอร์ก่อนนำไปใช้.....	51
รูปที่ 14 กระบวนการปรับมาตราส่วนข้อมูล การสอนและทดสอบแบบจำลอง การใช้ผลจากแบบจำลองในการสร้างขอบเขตข้อมูลและหาอายุการใช้งานที่สูญเสียของหม้อแปลง	52
รูปที่ 15 รูปแบบการพยากรณ์อุณหภูมิของน้ำมันด้านบนในหม้อแปลงโดยใช้ข้อมูลแบบจุดและแบบใช้ข้อมูลเวลาก่อนหน้า 24 จุด	54
รูปที่ 16 ความสัมพันธ์ของค่าอุณหภูมิแวดล้อมและค่าโหลดที่ส่งผลต่อค่าอุณหภูมิน้ำมันด้านบน .	55
รูปที่ 17 ผลการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนในหม้อแปลง	55

รูปที่ 35 ผลการขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด78

รูปที่ 36 ค่า %B ของข้อมูลเป้าหมายจริงแต่ละจุดในการพยากรณ์ค่าอุณหภูมิด้านบนของหม้อแปลง
A และ B โดยใช้แบบจำลอง ANN และ RF ตามลำดับ.....85



บทที่ 1

บทนำ

1.1 แนวทางและเหตุผลในการทำวิทยานิพนธ์

การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย (กฟผ.) เป็นหน่วยงานรัฐวิสาหกิจในประเทศไทยที่ดำเนินกิจการผลิต รับซื้อ ควบคุม และส่งจ่ายพลังงานไฟฟ้ารวมไปถึงธุรกิจเกี่ยวเนื่องที่เกี่ยวข้อง รับผิดชอบดูแลระบบส่งกำลังไฟฟ้าแรงสูงเพื่อส่งจ่ายกำลังไฟฟ้าไปยังการไฟฟ้าส่วนภูมิภาค (กฟภ.) และการไฟฟ้านครหลวง (กฟน.) ในระบบจำหน่ายต่อไป สถานีไฟฟ้าแรงสูงมีความสำคัญในระบบส่งเนื่องจากเป็นตำแหน่งที่ใช้ควบคุมทิศทางและปริมาณการส่งจ่ายกำลังไฟฟ้าในแต่ละพื้นที่ การบริหารจัดการสินทรัพย์อุปกรณ์ในสถานีไฟฟ้าโดยเฉพาะหม้อแปลงไฟฟ้ากำลังจึงมีความสำคัญ เพื่อให้การส่งจ่ายกำลังไฟฟ้าไปยังผู้ใช้งานสามารถทำได้อย่างมีประสิทธิภาพ มีความเพียงพอต่อการใช้งานและมีต้นทุนค่าใช้จ่ายที่เหมาะสม

1.2 ที่มาและความสำคัญของปัญหา

หม้อแปลงไฟฟ้ากำลังเป็นอุปกรณ์ในระบบส่งไฟฟ้าที่ใช้ในการปรับค่าแรงดันในระบบ โดยสามารถปรับแรงดันที่ออกมาจากโรงไฟฟ้าให้สูงขึ้นและส่งจ่ายกำลังไฟฟ้าในระยะไกลให้มีค่ากระแสไฟฟ้าและกำลังสูญเสียที่ต่ำ และยังสามารถปรับค่าแรงดันให้ลดลงเพื่อให้เหมาะสมกับอุปกรณ์และลักษณะการใช้งานของผู้ใช้งาน ดังนั้นหม้อแปลงไฟฟ้ากำลังจึงเป็นหนึ่งในอุปกรณ์ที่มีความสำคัญในระบบส่งจ่ายกำลังไฟฟ้า การเกิดเหตุการณ์ชำรุดขัดข้อง หรือการหยุดทำงานของหม้อแปลงโดยไม่ได้วางแผนล่วงหน้าจะส่งผลกระทบต่อผู้ใช้ไฟตามบ้านเรือน รวมไปถึงอุตสาหกรรมในประเทศไทยได้ ดังนั้นการบริหารจัดการการใช้งานหม้อแปลงไฟฟ้าจึงเป็นประเด็นที่ควรให้ความสำคัญในการบริหารจัดการระบบส่ง ซึ่งในปัจจุบันได้มีการพัฒนาอุปกรณ์และระบบตรวจวัดที่มีสมรรถนะสูง มีความละเอียดแม่นยำ และมีการส่งผ่านข้อมูลที่รวดเร็วแบบเวลาจริง เช่นระบบตรวจวัดค่าอุณหภูมิน้ำมันหม้อแปลง อุณหภูมิแวดล้อม ค่ากระแสโหลด การวิเคราะห์ก๊าซที่ละลายในน้ำมันแบบออนไลน์ที่มีความละเอียดแม่นยำสูง ข้อมูลของหม้อแปลงแต่ละตัวสามารถนำมาใช้สร้างแบบจำลองเฉพาะของหม้อแปลงเพื่อบ่งบอกพฤติกรรมการทำงานในสถานะปกติและพฤติกรรมที่ผิดปกติ

แตกต่างเดิมในการวิเคราะห์การเสื่อมสภาพและนำมาบริหารจัดการการอุปกรณ์ในระบบส่งจ่ายกำลังไฟฟ้าเพื่อให้สามารถลดปัญหาและผลกระทบที่อาจเกิดจากการขัดข้องหม้อแปลงลงได้

วิทยานิพนธ์ฉบับนี้นำเสนอแนวทางการสร้างแบบจำลองเพื่อศึกษาพฤติกรรมทางความร้อนของหม้อแปลงไฟฟ้ากำลังโดยใช้ข้อมูลจากหม้อแปลงระดับแรงดัน 525/242-22 kV พิกัดกำลัง 250 MVA ของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย ใช้งานในการเพิ่มระดับแรงดันที่ออกมาจากโรงไฟฟ้าให้สูงขึ้นเพื่อส่งจ่ายไปยังระบบส่งไฟฟ้า โดยการทดลองสร้างแบบจำลองที่รับค่าปริมาณโหลด และอุณหภูมิแวดล้อมของหม้อแปลงเพื่อพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบน (Top-Oil Temperature - TOT) และอุณหภูมิขดลวด (Winding Temperature) ในหม้อแปลง ค่าปริมาณโหลดของหม้อแปลงในระบบส่งเป็นข้อมูลที่สามารถพยากรณ์ล่วงหน้าได้โดยศูนย์ควบคุมกำลังไฟฟ้าแห่งชาติ ในขณะที่อุณหภูมิแวดล้อมสามารถพยากรณ์ล่วงหน้าจากข้อมูลของกรมอุตุนิยมวิทยาหรือการสร้างแบบจำลองในการพยากรณ์จากข้อมูลในอดีตได้เช่นกัน ข้อมูลดังกล่าวจะนำมาสอนแบบจำลองการเรียนรู้ของเครื่อง โดยมีข้อมูลเป้าหมายเป็นค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง แบบจำลองจะปรับแต่งให้สามารถพยากรณ์ชุดข้อมูลทดสอบให้มีสมรรถนะที่ดีในการใช้งานกับข้อมูลใหม่ในอนาคต ข้อมูลอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลงที่พยากรณ์ได้จะนำมาคำนวณหาการอายุการใช้งานที่สูญเสียของหม้อแปลง (Transformer loss of life) ซึ่งสามารถใช้พิจารณาการเลือกหม้อแปลงในการติดตั้งทดแทนหม้อแปลงในระบบที่เกิดปัญหาระหว่างใช้งาน การประเมินการสูญเสียอายุการใช้งานล่วงหน้าในการใช้งานหม้อแปลงรวมถึงการใช้งานหม้อแปลงแบบต่อเนื่อง

ข้อมูลที่ได้จากการพยากรณ์โดยแบบจำลองจะเป็นข้อมูลที่มีลักษณะเป็นจุด กล่าวคือเมื่อกำหนดข้อมูลขาเข้า (อุณหภูมิแวดล้อมและค่าโหลด) แบบจำลองจะพยากรณ์ข้อมูลขาออก (อุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง) เป็นตัวเลขค่าเดียว ซึ่งหากข้อมูลในขั้นตอนเรียนรู้มีความกระจายที่สูง หรือตัวแปรสามารถมีผลจากความไม่แน่นอนของสิ่งแวดล้อมจะส่งผลให้ข้อมูลที่วัดได้จริงจากอุปกรณ์มีโอกาสที่จะไม่ตรงกับค่าที่พยากรณ์ได้อย่างสมบูรณ์ ดังนั้นข้อมูลที่พยากรณ์ได้จากแต่ละแบบจำลองจะนำมาหาขอบเขตการพยากรณ์ซึ่งเป็นขอบเขตบนและขอบเขตล่างของข้อมูลที่เป็นไปได้ที่เหมาะสมในการบ่งบอกว่าค่าที่วัดได้จริงและค่าที่พยากรณ์ได้จากแบบจำลองมีความใกล้เคียงกันและเชื่อถือได้ที่ค่าความเชื่อมั่นที่กำหนด นอกจากนี้การหาขอบเขต

บนและขอบเขตล่างดังกล่าวจะนำมาใช้ในการตรวจหาสถานะทางความร้อนที่ผิดปกติจากการสังเกต ข้อมูลที่อยู่นอกขอบเขตดังกล่าวได้ ค่าการสูญเสียอายุการใช้งานของหม้อแปลงและขอบเขตการพยากรณ์ของอุณหภูมิของน้ำมันด้านบนในหม้อแปลงในสถานะแวดล้อมและโหลดที่กำหนดสามารถนำมาพิจารณาาร่วมกันในการบริหารจัดการหม้อแปลงในการส่งจ่ายกำลังไฟฟ้าในระบบส่ง

วิทยานิพนธ์ฉบับนี้จะทำการศึกษาและเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่อง 4 รูปแบบได้แก่ โครงข่ายประสาทเทียม (Artificial Neural Network - ANN) ต้นไม้การตัดสินใจ (Decision tree) โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network) และต้นไม้การถดถอยที่เคลื่อนลงตามความชัน (Gradient Boosting Regression Tree-GBR) ในการใช้ค่าโหลดและอุณหภูมิแวดล้อมเพื่อเรียนรู้และพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง ข้อมูลดังกล่าวเป็นข้อมูลที่เก็บได้จริงจากหม้อแปลงระดับแรงดัน 525/242-22 kV พิกัดกำลัง 250 MVA แบบจำลองจะใช้ภาษาไพทอน (Python) ในการจัดเตรียมข้อมูล การสร้างแบบจำลอง การทดสอบสมรรถนะ ตลอดจนการแสดงผลข้อมูล

1.3 วัตถุประสงค์ของวิทยานิพนธ์

- 1) สร้างและเปรียบเทียบแบบจำลองในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลงที่เกิดขึ้นจากการจ่ายโหลดและปัจจัยอุณหภูมิแวดล้อม
- 2) คำนวณอายุการใช้งานที่สูญเสีย (Loss of life) ของหม้อแปลง โดยใช้ข้อมูลที่ได้จากการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดเพื่อใช้ในการเลือกใช้งานหม้อแปลงในระบบและการบริหารจัดการการส่งจ่ายกำลังไฟฟ้า
- 3) สร้างขอบเขตการพยากรณ์ (Prediction intervals) ของการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง เปรียบเทียบกับข้อมูลที่ได้จากการตรวจวัดและคำนวณการสูญเสียอายุการใช้งานที่มากที่สุด

1.4 ขอบเขตของวิทยานิพนธ์

- 1) ประยุกต์ใช้ข้อมูลที่ได้จากระบบตรวจวัดข้อมูลหม้อแปลงออนไลน์ชนิดเฟสเดียว ระดับแรงดัน 525/242-22 kV พิกัดกำลัง 250 MVA Insulation paper class 120 จำนวน 2 ตัวที่มี

คุณสมบัติเหมือนกันทุกประการ ใช้งานในโรงไฟฟ้าชนิดความร้อนร่วมที่ใช้ก๊าซธรรมชาติเป็นเชื้อเพลิง

- 2) ศึกษาข้อมูล โหลด อุณหภูมิแวดล้อม อุณหภูมิน้ำมันที่ส่วนบน และอุณหภูมิขดลวดภายในหม้อแปลง
- 3) สร้างแบบจำลองและขอบเขตการพยากรณ์ วิเคราะห์และแสดงผลข้อมูล โดยใช้โปรแกรมและไลบรารีภาษา Python
- 4) คำนวณการสูญเสียอายุการใช้งาน โดยวิธีการที่แนะนำในมาตรฐาน IEEE C57.91-2011

1.5 ขั้นตอนการศึกษาและวิธีการดำเนินการ

- 1) ศึกษาบทความและงานวิจัยที่เกี่ยวข้อง
 - 1.1) การเสื่อมสภาพทางความร้อนของหม้อแปลงฉนวนน้ำมัน
 - 1.2) การสร้างแบบจำลองการเรียนรู้ของเครื่องในกระบวนการเรียนรู้ข้อมูลแบบมีผู้สอนและการสร้างขอบเขตการพยากรณ์
 - 1.3) ตัวอย่างการใช้แบบจำลองการเรียนรู้ของเครื่องกับข้อมูลที่ตรวจวัดจากหม้อแปลง
- 2) ขอข้อมูลจากระบบตรวจวัดหม้อแปลงออนไลน์จาก กฟผ.
- 3) เลือกชนิดแบบจำลอง กรอบเวลา และทำความสะอาดข้อมูลเบื้องต้น
- 4) สร้างแบบจำลองในการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดของหม้อแปลง เปรียบเทียบสมรรถนะของแต่ละแบบจำลอง
- 5) คำนวณค่าการสูญเสียอายุการใช้งานของหม้อแปลงในสภาวะโหลดและอุณหภูมิแวดล้อมที่กำหนด เปรียบเทียบค่าดังกล่าวระหว่างแบบจำลอง
- 6) จำลองการทำงาน โดยกำหนดสภาวะการใช้งานล่วงหน้า (ค่าโหลดและอุณหภูมิแวดล้อม) ที่ใช้ข้อมูลบางส่วนจากข้อมูลทดสอบและใช้แบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง สร้างขอบเขตการพยากรณ์และเปรียบเทียบค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงที่เกิดขึ้นจริงกับข้อมูลที่พยากรณ์ได้จากแบบจำลองและขอบเขตการพยากรณ์

1.6 ประโยชน์ที่คาดว่าจะได้รับ

- 1) แบบจำลองที่มีประสิทธิภาพในการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดของหม้อแปลง โดยใช้ข้อมูลพฤติกรรมเฉพาะตัวของแต่ละหม้อแปลงพร้อมทั้งขอบเขตการพยากรณ์
- 2) ค่าการสูญเสียอายุการใช้งานของหม้อแปลงในสภาวะโหลดและอุณหภูมิแวดล้อมที่กำหนด ที่สามารถเปรียบเทียบค่าดังกล่าวระหว่างหม้อแปลง ช่วยในการตัดสินใจการเลือกใช้งานหม้อแปลงที่เหมาะสม
- 3) แนวทางในการวางแผนการบริหารจัดการหม้อแปลงในระบบส่ง การตรวจจับค่าสุดค่าที่อยู่นอกขอบเขตการพยากรณ์ที่อาจเกิดจากความผิดปกติของหม้อแปลง

1.7 งานวิจัยที่เกี่ยวข้อง

- มาตรฐาน IEEE C57.91[1] ได้กล่าวถึงแนวทางการจ่ายโหลดหม้อแปลงฉนวนน้ำมัน การคำนวณค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดภายในหม้อแปลง การคำนวณตัวประกอบภาระเร่งการเสื่อมสภาพและการสูญเสียอายุการใช้งานของกระดาษฉนวนจากความร้อน ที่สามารถนำมาใช้ร่วมกับแบบจำลองการเรียนรู้ของเครื่องในการบริหารจัดการหม้อแปลงในระบบส่ง
- บทความ[2] ได้แสดงตัวอย่างการคำนวณค่าตัวประกอบการเสื่อมสภาพสมมูล (equivalent-aging factor) ของหม้อแปลงตาม [1] อย่างละเอียดรวมถึงได้แสดงการนำผลการคำนวณไปใช้ในการลดขนาดพิกัดสูงสุดในการใช้งานของหม้อแปลงลงให้สอดคล้องกับการเสื่อมสภาพ
- บทความ[3] ได้กล่าวถึงการใช้แบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ค่าอุณหภูมิจุดร้อนของขดลวดหม้อแปลงที่ใช้งานในโรงไฟฟ้านิวเคลียร์เพื่อหาค่าอายุการใช้งานที่หลงเหลืออยู่ของหม้อแปลงโดยการพิจารณาค่าความคลาดเคลื่อนในการตรวจวัดและตัวแปรที่ไม่แน่นอนในการสร้างแบบจำลอง เปรียบเทียบกับการหาค่าอุณหภูมิจุดร้อนของขดลวดโดยวิธีเชิงวิเคราะห์ที่ไม่สามารถปรับตัวเข้ากับสถานการณ์การใช้งานหม้อแปลงที่แตกต่างกัน
- บทความ[4] กล่าวถึงการใช้และเปรียบเทียบแบบจำลองการเรียนรู้ของเครื่องรูปแบบต่างๆ ได้แก่ โครงข่ายประสาทเทียม โครงข่ายประสาทเทียมแบบวนซ้ำ และแบบจำลองค่าเฉลี่ยเคลื่อนที่ของการถดถอยอัตโนมัติ (Auto-Regressive Moving Average-ARX) ในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง

- บทความ[5] กล่าวถึงการเปรียบเทียบกระบวนการสร้างขอบเขตการพยากรณ์ (Prediction interval) ระหว่างวิธี Delta Method, Bayesian Method, Mean-Variance Estimation และ Bootstrap Method ในการกำหนดขอบเขตค่าที่พยากรณ์ได้จากแบบจำลองการเรียนรู้ของเครื่องและได้นำเสนอแนวทางใหม่ในการสร้างขอบเขตดังกล่าว
- หนังสือ[6] เกี่ยวกับการจัดจํารูปแบบและการสร้างแบบจำลองการเรียนรู้ของเครื่องโดยละเอียด
- บทความ[7] กล่าวถึงการตรวจจับการโจมตีทางไซเบอร์เพื่อการขโมยใช้ไฟฟ้าโดยการวิเคราะห์ข้อมูลการใช้ไฟฟ้าและพัฒนาแบบจำลองที่มีพื้นฐานจาก Bollinger bands และกระบวนการของ Markov process ในการตรวจจับสัญญาณที่มีความผิดปกติ
- บทความ[8] ได้กล่าวถึงการใช้แบบจำลองโครงข่ายประสาทเทียมแบบ Quantile และวิธีการ Kernel density estimation ในการสร้างขอบเขตการพยากรณ์ในการใช้ไฟฟ้าของบ้านเรือนเพื่อพยากรณ์ประมาณการใช้ไฟสูงสุดในการบริหารจัดการการส่งจ่ายไฟฟ้า
- บทความ[9] ได้เสนอการประยุกต์ใช้ประโยชน์ของ Bollinger bands และ %b ในการตรวจหาค่าสุดต่ำที่แสดงถึงความผิดปกติในสายไฟ
- บทความ[10] ได้เสนอกระบวนการในการการสร้างขอบเขตบน-ขอบเขตล่างเพื่อสร้างขอบเขตการพยากรณ์ซึ่งมีพื้นฐานจากโครงข่ายประสาทเทียมเพื่อป้องกันความไม่แน่นอนของค่าที่พยากรณ์ได้จากแบบจำลองการเรียนรู้ของเครื่อง
- บทความ[11] ได้เสนอกระบวนการสร้างขอบเขตบน-ขอบเขตล่างของการพยากรณ์ข้อมูลด้วยวิธีการหารูปแบบที่คล้ายคลึงกันระหว่างข้อมูลใหม่และข้อมูลที่ใช้สอนแบบจำลองและใช้การหาค่าความแข็งแกร่งของการพยากรณ์ (prediction strength) ในการสร้างขอบเขตการพยากรณ์
- หนังสือ [12], [13]และ[14] เป็นหนังสือที่เป็นพื้นฐานในการสร้างแบบจำลองการเรียนรู้ของเครื่องและแบบจำลองเชิงลึกโดยใช้ภาษา Python และ Keras library ทั้งแบบจำลองพื้นฐานได้แก่โครงข่ายประสาทเทียม ต้นไม้การตัดสินใจ และแบบจำลองเชิงลึกเช่นโครงข่ายประสาทเทียมแบบวนซ้ำ ป่าแบบสุ่มและแบบจำลองอื่น โดยมีตัวอย่างอย่างละเอียดในการสร้าง ทดสอบและปรับค่าแบบจำลองโดยใช้ภาษาไพทอน

จากการศึกษางานวิจัยที่เกี่ยวข้องพบว่าอายุการใช้งานที่สูญเสียของหม้อแปลงซึ่งคำนวณจากมาตรฐาน IEEE C57.91 ในสภาวะการใช้งานที่กำหนดสามารถพยากรณ์ได้โดยใช้แบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ค่าอุณหภูมิน้ำมันส่วนบนและอุณหภูมิขดลวดของหม้อแปลง แต่ทั้งนี้ในแต่ละบทความได้มีการนำเสนอการพยากรณ์ค่าอุณหภูมิดังกล่าวสำหรับหม้อแปลงที่มีคุณสมบัติภายใน พิกัดกำลัง การใช้งานและสภาพแวดล้อมที่แตกต่างกัน ซึ่งไม่สามารถใช้แบบจำลองชนิดใดชนิดหนึ่งในการพยากรณ์อุณหภูมิของหม้อแปลงทุกชนิดในทุกสภาวะการทำงานได้ ดังนั้นวิทยานิพนธ์ฉบับนี้จึงต้องทำการสร้างและเปรียบเทียบแบบจำลองหลายแบบเพื่อหาแบบจำลองที่มีความเหมาะสมและมีสมรรถนะที่ดีในการพยากรณ์ค่าอุณหภูมิจากข้อมูลหม้อแปลงที่นำมาใช้ ซึ่งในบทที่ 4 ได้แสดงให้เห็นว่าแม้หม้อแปลงทั้งสองตัวที่วิทยานิพนธ์ฉบับนี้นำข้อมูลมาใช้งานจะมีคุณสมบัติ พิกัดกำลังที่เหมือนกันแต่มีการใช้งานที่แตกต่างกัน แบบจำลองที่ใช้ในการพยากรณ์ก็มีความแตกต่างกันด้วยเนื่องจากพฤติกรรมการตอบสนองต่อข้อมูลขาเข้าของหม้อแปลงแต่ละตัวไม่เหมือนกัน ผลการพยากรณ์อายุการใช้งานที่สูญเสียของหม้อแปลงสามารถช่วยในการพิจารณาต้นทุนการติดตั้งหม้อแปลงเพื่อทดแทนหม้อแปลงในระบบได้ นอกจากนี้การสร้างขอบเขตการพยากรณ์ของข้อมูลเป็นกระบวนการที่ขยายมิติในการนำเสนอและใช้งานข้อมูลที่ได้จากการพยากรณ์ที่มีลักษณะเป็นจุดให้ออกมาเป็นช่วงของข้อมูลที่ค่าความเชื่อมั่นที่กำหนดโดยหากตั้งสมมุติฐานว่าข้อมูลที่พยากรณ์ได้จากแบบจำลองการเรียนรู้ของเครื่องเป็นข้อมูลที่สะท้อนพฤติกรรมภายในของหม้อแปลง (เนื่องจากแบบจำลองสร้างขึ้นโดยใช้พฤติกรรมของหม้อแปลงที่ตอบสนองต่อข้อมูลขาเข้าในอดีต) การใช้ขอบเขตการพยากรณ์จะสามารถตรวจหาข้อมูลอุณหภูมิ น้ำมันด้านบนที่สูงเกินขอบเขตในการใช้งานได้ นอกจากนี้การหาแนวโน้มจำนวนของข้อมูลที่เกินขอบเขตดังกล่าวจะสามารถบ่งชี้ถึงพฤติกรรมที่เปลี่ยนแปลงไปของหม้อแปลงในระยะยาวได้อีกด้วย

1.8 เนื้อหาของวิทยานิพนธ์


วิทยานิพนธ์ฉบับนี้แบ่งเป็น 4 บท โดยมีเนื้อหา ดังนี้

บทที่ 1 กล่าวถึง ที่มาและความสำคัญของปัญหา วัตถุประสงค์ ขอบเขตวิทยานิพนธ์ ขั้นตอนการศึกษาและวิธีดำเนินการ ประโยชน์ที่คาดว่าจะได้รับและเนื้อหาของวิทยานิพนธ์

บทที่ 2 กล่าวถึง ทฤษฎีและความรู้ที่เกี่ยวข้อง การเสื่อมสภาพของหม้อแปลงจากความร้อนแบบจำลองการเรียนรู้ของเครื่องและการวัดสมรรถนะของแบบจำลอง การใช้ Bollinger bands ในการสร้างขอบเขตการพยากรณ์

บทที่ 3 กล่าวถึง วิธีการดำเนินการจัดการข้อมูล การใช้แบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง ขอบเขตการพยากรณ์และการตรวจหาค่าสุดต่างของข้อมูลอุณหภูมิของน้ำมันด้านบนในหม้อแปลง

บทที่ 4 กล่าวถึง สรุปผลการศึกษา



บทที่ 2

ทฤษฎีและความรู้ที่เกี่ยวข้อง

2.1 อายุการใช้งานของกระดาษฉนวนหม้อแปลง[1]

การเสื่อมสภาพของฉนวนกระดาษภายในหม้อแปลงเป็นข้อบ่งชี้หลักในการเสื่อมสภาพของหม้อแปลงซึ่งเกิดได้จากปัจจัยได้แก่ อุณหภูมิ ความชื้น ปริมาณออกซิเจนและเวลา แต่เนื่องจากในปัจจุบันการจัดการคุณภาพน้ำมันภายในหม้อแปลงสามารถทำให้ปริมาณความชื้นและออกซิเจนที่จะส่งผลต่อการเสื่อมสภาพของกระดาษฉนวนน้อยลงได้ ทำให้ปัจจัยทางด้านอุณหภูมิเป็นสาเหตุหลักที่ทำให้เกิดการเสื่อมสภาพของกระดาษฉนวน นอกจากนี้ การกระจายของอุณหภูมิภายในหม้อแปลงไม่ได้อยู่ในลักษณะที่เท่ากันทั้งหม้อแปลง โดยทั่วไปชิ้นส่วนของหม้อแปลงที่มีอุณหภูมิสูงที่สุดจะมีการเสื่อมสภาพที่สูงที่สุด การศึกษาการเสื่อมสภาพอันเนื่องมาจากอุณหภูมิจึงสนใจที่อุณหภูมิจุดร้อนที่สุดภายในหม้อแปลง อย่างไรก็ตามเนื่องจากปัจจัยที่ส่งผลต่อการเสื่อมสภาพอยู่ในลักษณะที่เป็นการสะสมต่อเนื่องตามเวลา การพยากรณ์อายุการใช้งานของกระดาษฉนวนให้ได้ อย่างแม่นยำมีความเป็นไปได้ยากแม้ในการทดลองที่มีการควบคุมสภาวะอย่างใกล้ชิด อายุการใช้งานและการเสื่อมสภาพของกระดาษฉนวนในวิทยานิพนธ์ฉบับนี้จะหมายถึงอายุการใช้งานและการเสื่อมสภาพจากการคำนวณเท่านั้น

2.2 การสูญเสียอายุการใช้งานของหม้อแปลงจากปัจจัยทางความร้อน

จากการทดลองโดย [1] ได้บ่งชี้ถึงความสัมพันธ์ระหว่างการเสื่อมสภาพของกระดาษฉนวนภายในหม้อแปลงโดยปัจจัยทางความร้อนเป็นไปตามสมการการเกิดปฏิกิริยาทางเคมีของอาร์เรเนียส ซึ่งอยู่ในรูปดังต่อไปนี้


$$Per\ Unit\ Life = Ae^{\left[\frac{B}{\theta_H + 273}\right]} \quad (1)$$

โดยที่

θ_H คือ อุณหภูมิจุดที่ร้อนที่สุดของขดลวดหม้อแปลงในหน่วย °C

- A คือ ค่าคงที่ของการเกิดปฏิกิริยาทางเคมี
- B คือ ค่าคงที่ที่เกี่ยวข้องกับพลังงานกระตุ้นในการเกิดปฏิกิริยา
- e คือ ตัวเลขลอการิทึมฐานธรรมชาติ

รูปที่ 1 แสดงกราฟความสัมพันธ์ระหว่างอายุการใช้งานของฉนวนกระดาษและค่าอุณหภูมิจุดที่ร้อนที่สุดของของเหลวภายในหม้อแปลงสำหรับหม้อแปลงที่ใช้ฉนวนกระดาษที่ทำจากเซลลูโลส และแสดงให้เห็นถึงการเสื่อมสภาพของกระดาษฉนวนในกรณีที่อุณหภูมิสูงกว่า 110 °C ที่มีการเสื่อมสภาพของกระดาษฉนวนอย่างรวดเร็ว



รูปที่ 1 ความสัมพันธ์ระหว่างอายุการใช้งานของฉนวนกระดาษและค่าอุณหภูมิจุดที่ร้อนที่สุด [1]

สมการแสดงความสัมพันธ์ในรูปที่ 1 อยู่ในรูปดังนี้

$$\text{Per Unit Life} = 9.8 \times 10^{-18} e^{\left[\frac{15000}{\theta_H + 273} \right]} \quad (2)$$

กราฟความสัมพันธ์ระหว่างอายุการใช้งานของฉนวนกระดาษและค่าอุณหภูมิจุดที่ร้อนที่สุดในรูปที่ 1 สามารถนำมาคำนวณหาค่าตัวประกอบการเร่งการเสื่อมสภาพ (Aging acceleration factor - F_{AA})

สำหรับค่าอุณหภูมิและโหลดที่กำหนด โดยสามารถหาค่าตัวประกอบการเร่งการเสื่อมสภาพได้จากสมการดังนี้


$$F_{AA} = e^{\left[\frac{15000}{383} - \frac{15000}{\theta_H + 273} \right]} \quad (3)$$

โดยที่

F_{AA} คือ ค่าตัวประกอบการเร่งการเสื่อมสภาพ

θ_H คือ อุณหภูมิจุดที่ร้อนที่สุดของขดลวดหม้อแปลงในหน่วย $^{\circ}\text{C}$

รูปที่ 2 แสดงความสัมพันธ์ระหว่างค่าตัวประกอบการเร่งการเสื่อมสภาพและค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดในหม้อแปลงตั้งแต่ค่า 65°C เป็นต้นไปซึ่งกล่าวถึงในสมการ (3) และพบว่าค่าตัวประกอบการเร่งการเสื่อมสภาพจะมีค่ามากกว่า 1 ที่อุณหภูมิจุดที่ร้อนที่สุดของขดลวดหม้อแปลงสูงกว่า 110°C



รูปที่ 2 ความสัมพันธ์ระหว่างค่าตัวประกอบการเร่งการเสื่อมสภาพและค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดในหม้อแปลง [1]

ค่าตัวประกอบการเร่งการเสื่อมสภาพของหม้อแปลงสามารถนำมาใช้คำนวณหาค่าตัวประกอบการเสื่อมสภาพสมมูล (equivalent aging factor - F_{EQA}) ในช่วงเวลาและช่วงอุณหภูมิที่กำหนดได้โดยสมการดังนี้

$$F_{EQA} = \frac{\sum_{n=1}^N F_{AA,n} \Delta t_n}{\sum_{n=1}^N \Delta t_n} \quad (4)$$

โดยที่

F_{EQA}	คือ ค่าตัวประกอบการเสื่อมสภาพสมมูลในช่วงเวลาทั้งหมด
$F_{AA,n}$	คือ ค่าตัวประกอบการเร่งการเสื่อมสภาพสำหรับอุณหภูมิในช่วงเวลา Δt_n
n	คือ ดัชนีของช่วงเวลา Δt
N	คือ จำนวนเวลาทั้งหมดในช่วง
Δt_n	คือ ช่วงเวลา

อายุการใช้งานของกระดาษฉนวนที่สูญเสียไปจากปัจจัยความร้อนสามารถคำนวณได้จากค่าตัวประกอบการเสื่อมสภาพสมมูลในรูปแบบร้อยละของอายุการใช้งานทั้งหมดของกระดาษฉนวน

ค่าจำนวนชั่วโมงที่สูญเสียอายุการใช้งานซึ่งได้จากการคูณผลลัพธ์ในสมการ (4) ด้วยช่วงเวลา t จะนำมาใช้ในการหาค่าร้อยละของอายุการใช้งานที่สูญเสียไป (Percent loss of life) ของกระดาษฉนวนดังสมการ

$$\%Loss\ of\ life = \frac{F_{EQA} \times t \times 100}{Normal\ Insulation\ life} \quad (5)$$

โดยที่

F_{EQA} คือ ค่าตัวประกอบเสื่อมสภาพสมมูลในช่วงเวลาทั้งหมด

ทั้งนี้มาตรฐาน IEEE C57.12.00-2010 ได้กำหนดให้ค่าอายุการใช้งานต่ำสุดของกระดาษฉนวนอยู่ที่ 180,000 ชั่วโมง ค่าอื่นที่อยู่ในตารางที่ 1 กำหนดมาเพื่อใช้ในการศึกษาและทดลองเท่านั้น ผลการคำนวณจากสมการ (5) เมื่อกำหนดให้ค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดหม้อแปลงตั้งแต่ 110 °C ขึ้นไปแสดงในตารางที่ 2 ซึ่งจะจำนวนชั่วโมงที่ใช้ในการทำให้กระดาษฉนวนที่มีอายุการใช้งาน 180,000 ชั่วโมงหมดสภาพการทำงาน ค่าร้อยละของอายุการใช้งานที่สูญเสียไปที่ค่าพิกัดอุณหภูมิของหม้อแปลง (110 °C) ในเวลา 24 ชั่วโมงจะอยู่ที่ 0.0133% ซึ่งใช้เป็นมาตรฐานในการเทียบเคียงกับค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดค่าอื่น

ตารางที่ 1 จำนวนชั่วโมงที่ใช้ในการทำให้กระดาษฉนวนหมดสภาพที่ค่าอุณหภูมิจุดที่ร้อนที่สุดของขดลวดตั้งแต่ 110 – 200 °C

อุณหภูมิจุดร้อน (°C)	FAA	เวลา (ชั่วโมง)						
		ร้อยละของอายุการใช้งานที่สูญเสีย						
		0.0133	0.02	0.05	0.1	0.2	0.3	0.4
110	1	24	—	—	—	—	—	—
120	2.71	8.86	13.3	—	—	—	—	—
130	6.98	3.44	5.1	12.9	—	—	—	—
140	17.2	1.39	2.1	5.2	10.5	20.9	—	—
150	40.6	0.59	0.89	2.2	4.4	8.8	13.3	17.7
160	92.1	0.26	0.39	0.98	1.96	3.9	5.9	7.8
170	201.2	0.12	0.18	0.45	0.89	1.8	2.7	3.6
180	424.9	0.06	0.08	0.21	0.42	0.84	1.27	1.7
190	868.8	0.028	0.04	0.1	0.21	0.41	0.62	0.82
200	1723	0.014	0.02	0.05	0.1	0.21	0.31	0.42

2.3 ผลของอุณหภูมิแวดล้อมต่อการจ่ายโหลดของหม้อแปลง

อุณหภูมิแวดล้อมเป็นปัจจัยสำคัญในการกำหนดความสามารถในการจ่ายโหลดของหม้อแปลง การใช้งานหม้อแปลงในระบบปิดจึงต้องมีการควบคุมอุณหภูมิแวดล้อมที่เหมาะสม

ในขณะเดียวกันการใช้งานหม้อแปลงในระบบเปิดก็ควรพิจารณาผลและการเปลี่ยนแปลงของอุณหภูมิแวดล้อมเช่นกัน ตารางที่ 3 แสดงผลค่าประมาณของการเพิ่มขึ้นหรือลดลงของกำลังพิกัด (kVA) ในการใช้งานหม้อแปลงที่สภาวะอุณหภูมิแวดล้อมต่างไปจากค่าพื้นฐานได้แก่ 30 °C สำหรับหม้อแปลงที่ระบายความร้อนด้วยอากาศ และ 25 °C สำหรับหม้อแปลงที่ระบายความร้อนด้วยน้ำ การใช้งานจ่ายโหลดของหม้อแปลงตามตารางที่ 3 จะครอบคลุมถึงการใช้งานในอุณหภูมิแวดล้อมตั้งแต่ -30 °C ถึง 50 °C

ตารางที่ 2 ค่าประมาณของการเพิ่มขึ้นหรือลดลงของกำลังพิกัด (kVA) ในการใช้งานหม้อแปลงที่สภาวะอุณหภูมิแวดล้อมต่างไปจากค่าพื้นฐาน

ประเภทของการระบายความร้อน	ร้อยละของค่าพิกัดโวลต์-แอมป์	
	ค่าโหลดที่จ่ายได้ลดลงต่ออุณหภูมิในหน่วย °C ที่สูงกว่าค่าพื้นฐาน	ค่าโหลดที่จ่ายได้เพิ่มขึ้นต่ออุณหภูมิในหน่วย °C ที่ต่ำกว่าค่าพื้นฐาน
ระบายความร้อนด้วยตัวเอง—ONAN	1.5	1
ระบายความร้อนด้วยน้ำ—ONWF	1.5	1
ระบายความร้อนแบบบังคับด้วยอากาศ ONAN/ONAF, ONAN/ONAF/ONAF	1	0.75
ระบายความร้อนแบบบังคับด้วยน้ำมัน อากาศ และน้ำ—OFAF, OFWF, ODWF, and ONAN/OFAF/OFAF	1	0.75

2.4 การคำนวณอุณหภูมิจุดร้อนที่สุดของขดลวดหม้อแปลง

สมการ (3) เสนอวิธีการคำนวณค่าตัวประกอบการเร่งการเสื่อมสภาพของหม้อแปลง โดยค่าดังกล่าวขึ้นอยู่กับค่าอุณหภูมิจุดร้อนที่สูงที่สุดของขดลวดภายในหม้อแปลง แต่ทว่าอุณหภูมิดังกล่าวไม่สามารถวัดค่าและตำแหน่งให้มีความละเอียดที่สูงได้เนื่องจากในการใช้งานหม้อแปลงมีอาจทราบตำแหน่งที่จะเกิดอุณหภูมิที่สูงที่สุดได้อย่างแน่นอน ดังนั้น [1] ได้เสนอวิธีการประมาณค่าอุณหภูมิจุดร้อนที่สูงที่สุดของขดลวดภายในหม้อแปลงโดยใช้สมการดังนี้

$$\theta_H = \theta_A + \Delta\theta_{TO} + \Delta\theta_H \quad (6)$$

โดยที่

θ_A คือ อุณหภูมิแวดล้อมเฉลี่ยในวัฏจักรโหลดที่ศึกษาในหน่วย °C

$\Delta\theta_{TO}$ คือ อุณหภูมิผลต่างระหว่างอุณหภูมิของน้ำมันด้านบนในหม้อแปลงและอุณหภูมิแวดล้อม (top-oil rise over ambient temperature) ในหน่วย °C

$\Delta\theta_H$ คือ อุณหภูมิผลต่างระหว่างอุณหภูมิจุดที่ร้อนที่สุดของจลวดและอุณหภูมิของน้ำมันด้านบนในหม้อแปลง (winding hottest-spot rise over top-oil) ในหน่วย °C

อุณหภูมิผลต่างระหว่างอุณหภูมิของน้ำมันด้านบนในหม้อแปลงและอุณหภูมิแวดล้อมในสมการ

(6) สามารถคำนวณได้จาก

$$\Delta\theta_{TO} = (\Delta\theta_{TO,U} - \Delta\theta_{TO,i}) \left(1 - e^{-\frac{t}{\tau_{TO}}}\right) + \Delta\theta_{TO,i} \quad (7)$$

โดยที่

$\Delta\theta_{TO,U}$ คือ ค่าผลต่างระหว่างค่าขีดสุดของอุณหภูมิของน้ำมันด้านบนในหม้อแปลงและค่าอุณหภูมิแวดล้อม (ultimate top-oil rise over ambient temperature) สำหรับโหลดที่กำหนดในหน่วย °C

$\Delta\theta_{TO,i}$ คือ ค่าอุณหภูมิเริ่มต้นของอุณหภูมิผลต่างระหว่างอุณหภูมิของน้ำมันด้านบนในหม้อแปลงและอุณหภูมิแวดล้อม (initial top-oil rise over ambient temperature) ที่ $t=0$

τ_{TO} คือ ค่าคงที่ทางเวลาของน้ำมันหม้อแปลงเมื่อกำหนดค่าโหลดและอุณหภูมิที่แตกต่างกันระหว่าง ultimate top-oil rise over ambient และ initial top oil rise over ambient temperature ที่กำหนดในหน่วยชั่วโมง

ค่า $\Delta\theta_{TO,U}$ สามารถคำนวณได้ดังสมการต่อไปนี้

$$\Delta\theta_{TO,U} = \Delta\theta_{TO,R} \left[\frac{K_U^2 R + 1}{R + 1} \right]^n \quad (8)$$

โดยที่

$\Delta\theta_{TO,R}$ คือ ค่าผลต่างระหว่างค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงและค่าอุณหภูมิแวดล้อมที่ค่าโหลดพิกัดในตำแหน่ง Tap ที่ศึกษา (top-oil rise over ambient temperature at rated load on the tap position to be studied) ในหน่วย °C

K_U คือ อัตราส่วนระหว่างโหลดและโหลดพิกัดในหน่วย per unit

n คือ ค่าคงที่ที่ใช้บอกการเปลี่ยนแปลงของ $\Delta\theta_{TO}$ เมื่อโหลดมีการเปลี่ยนแปลง ค่าของ n ขึ้นอยู่กับชนิดของระบบระบายความร้อนของหม้อแปลง ในการประมาณผลของการเปลี่ยนแปลงของค่าความต้านทานจากโหลดที่เปลี่ยนแปลงโดยมีค่าตามตารางที่ 4

R คือ อัตราส่วนของกำลังสูญเสียที่ค่าโหลดพิกัดต่อกำลังสูญเสียที่สภาวะไม่มีโหลด

ตารางที่ 3 ค่าตัวประกอบที่ใช้ในการกำหนดสมการอุณหภูมิ[1]

ประเภทการระบายความร้อน	m	n
ONAN	0.8	0.8
ONAF, Non-directed OFAF or OFWF	0.8	0.9
Directed ODAF or ODWF	1.0	1.0

$\Delta\theta_H$ ในสมการ (6) สามารถหาได้จากความสัมพันธ์ต่อไปนี้

$$\Delta\theta_H = (\Delta\theta_{H,U} - \Delta\theta_{H,i}) \left(1 - e^{-\frac{t}{\tau_w}}\right) + \Delta\theta_{H,i} \quad (9)$$

โดยที่

$\Delta\theta_{H,U}$ คือ ค่าผลต่างระหว่างค่าขีดสุดของอุณหภูมิจุดที่ร้อนที่สุดของขดลวดและค่าอุณหภูมิแวดล้อม (ultimate winding rise over ambient temperature) สำหรับโหลดที่กำหนด ในหน่วย °C

$\Delta\theta_{H,i}$ คือ ค่าอุณหภูมิเริ่มต้นของอุณหภูมิผลต่างระหว่างอุณหภูมิขดลวดและอุณหภูมิแวดล้อม (initial winding rise over ambient temperature) ที่ $t=0$

τ_w คือ ค่าคงที่ทางเวลาของจุดร้อนในหน่วยชั่วโมง

$\Delta\theta_{H,U}$ และ $\Delta\theta_{H,i}$ สามารถคำนวณได้จากสมการต่อไปนี้

$$\Delta\theta_{H,U} = \Delta\theta_{H,R} K_U^{2m} \quad (10)$$

$$\Delta\theta_{H,i} = \Delta\theta_{H,R} K_i^{2m} \quad (11)$$

โดยที่

$\Delta\theta_{H,R}$ คือ ค่าผลต่างระหว่างอุณหภูมิจุดที่ร้อนที่สุดของขดลวดและอุณหภูมิของน้ำมันด้านบนในหม้อแปลง (winding hottest-spot rise over top-oil temperature) ที่ค่าโหลดพิกัดในตำแหน่ง Tap ที่สนใจในหน่วย °C

K_U คือ อัตราส่วนระหว่างโหลดและโหลดพิกัดในหน่วย per unit


K_i คือ อัตราส่วนระหว่างโหลดเริ่มต้นและโหลดพิกัดในหน่วย per unit

m คือ ค่าคงที่ที่ใช้บอกการเปลี่ยนแปลงแปลงของ $\Delta\theta_H$ ตาม โหลด ค่าของ m ขึ้นอยู่กับชนิดของระบบหล่อเย็นของหม้อแปลงในการประมาณผลของการเปลี่ยนแปลงของค่าความต้านทานจากโหลดที่เปลี่ยนแปลง โดยจะมีค่าตามตารางที่ 4


2.5 ความรู้พื้นฐานเกี่ยวกับแบบจำลองการเรียนรู้ของเครื่อง

แบบจำลองการเรียนรู้ของเครื่อง (Machine Learning models) เป็นขั้นตอนวิธีการทางคอมพิวเตอร์ที่สามารถค้นหาและเรียนรู้แบบแผนและความสัมพันธ์ระหว่างข้อมูลได้ด้วยตนเอง ในการแยกประเภท พยากรณ์หรือการตัดสินใจ โดยที่ไม่จำเป็นต้องให้มนุษย์กำหนดผลลัพธ์ไว้ล่วงหน้าแบบจำลองการเรียนรู้ของเครื่องสามารถแบ่งออกเป็น 3 ประเภทได้แก่ แบบจำลองการเรียนรู้แบบมีผู้สอน (Supervised learning models) ที่มีเรียนรู้ของแบบจำลองโดยใช้ข้อมูลที่ทราบผลลัพธ์แน่นอนในเหตุการณ์จำนวนหนึ่งเพื่อพยากรณ์ผลลัพธ์ในเหตุการณ์ใหม่ แบบจำลองการเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning models) ซึ่งเป็นการจัดการกับข้อมูลที่ไม่ทราบโครงสร้างภายในที่แน่ชัดเพื่อจำแนกและค้นหาข้อมูลที่มีประโยชน์มาใช้งาน และแบบจำลองการเรียนรู้แบบเสริมกำลัง (Reinforcement learning models) ที่มีจุดประสงค์ในการสร้างระบบหรือแบบจำลองที่สามารถเพิ่มสมรรถนะจากการมีปฏิสัมพันธ์กับสิ่งแวดล้อมเพื่อให้บรรลุเป้าหมายได้มากที่สุด

วิทยานิพนธ์ฉบับนี้จะใช้แบบจำลองการเรียนรู้แบบมีผู้สอนซึ่งมีเป้าหมายในการเรียนรู้และสร้างแบบจำลองจากข้อมูล เพื่อให้แบบจำลองเรียนรู้และพยากรณ์ข้อมูลใหม่ในอนาคต การมีผู้สอนของแบบจำลองหมายถึงแบบจำลองจะเรียนรู้จากข้อมูลขาเข้า (input features) และผลลัพธ์ (labels) ที่มีความชัดเจนและสอดคล้องกันดังรูปที่ 3 ได้แสดงถึงกระบวนการเรียนรู้และพยากรณ์ข้อมูลของแบบจำลองการเรียนรู้แบบมีผู้สอน แบบจำลองการเรียนรู้แบบมีผู้สอนสามารถแยกประเภทออกได้อีกสองประเภท ได้แก่แบบจำลองสำหรับการจำแนกประเภท (Classification models) เป็นแบบจำลองที่ใช้ในการเรียนรู้และจำแนกประเภทของข้อมูลว่าอยู่ในกลุ่มใด เช่นการจำแนกประเภทของ e-mail ว่าเป็นสแปมหรือไม่โดยการเรียนรู้ค่าและประโยชน์ภายใน อีกประเภทหนึ่งคือแบบจำลองแบบถดถอย (Regression models) ซึ่งเป็นแบบจำลองที่ใช้พยากรณ์ข้อมูลที่มีความต่อเนื่อง (continuous) โดยจะใช้ตัวแปรพยากรณ์ (predictor) จำนวนหนึ่งควบคู่กับผลตอบสนองแบบต่อเนื่อง (continuous outcome) ในการสอนแบบจำลองและพยากรณ์ค่าตัวแปรต้นใหม่ในอนาคต เช่นแบบจำลองถดถอยแบบเชิงเส้น (Linear regression model) ในรูปที่ 4 สัญลักษณ์กากบาทคือข้อมูลที่เป็นความสัมพันธ์ระหว่างตัวแปรต้นและผลตอบสนอง ในขณะที่เส้นตรงคือแบบจำลองถดถอยแบบเชิงเส้นที่ใช้อธิบายข้อมูลโดยรวมและใช้พยากรณ์ให้สามารถพยากรณ์ค่า y เมื่อมีค่า x ชุดใหม่ได้



รูปที่ 3 กระบวนการเรียนรู้และพยากรณ์ข้อมูลของแบบจำลองการเรียนรู้แบบมีผู้สอน [12]

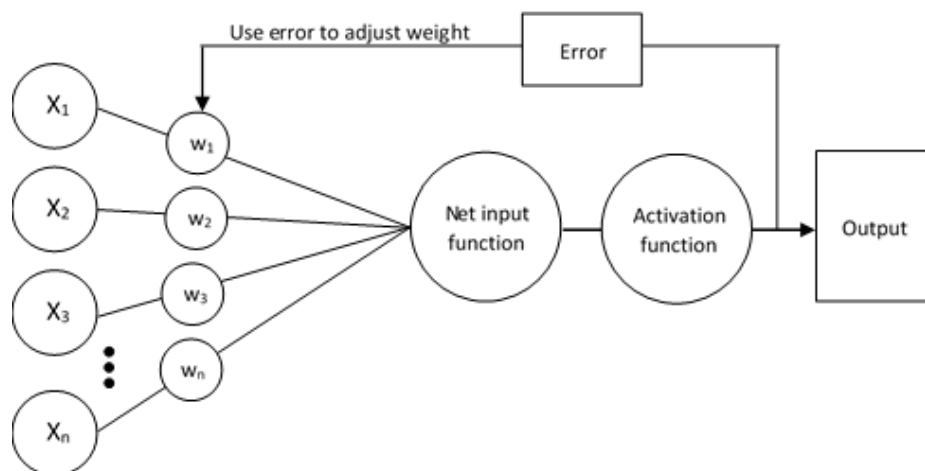


รูปที่ 4 การถดถอยแบบเชิงเส้น[12]

แบบจำลองการเรียนรู้แบบมีผู้สอนที่ใช้ในวิทยานิพนธ์ฉบับนี้จะมีทั้งหมด 3 แบบจำลองได้แก่ โครงข่ายประสาทเทียม (Artificial Neural Network - ANN) ต้นไม้การตัดสินใจ(Decision tree - DT) และ โครงข่ายประสาทเทียมแบบวนซ้ำ(Recurrent Neural Network - RNN) ชนิด Long Short-term Memory (LSTM)

โครงข่ายประสาทเทียม (Artificial Neural Network)

โครงข่ายประสาทเทียมเป็นขั้นตอนวิธีทางคอมพิวเตอร์ที่มีแรงบันดาลใจมาจากเซลล์สมองของมนุษย์ที่เรียกว่า “นิวรอน” โดยนิวรอนเป็นเซลล์ประสาทที่จะรับสัญญาณทางไฟฟ้าหรือเคมีเข้ามาประมวลผลเพื่อสร้างสัญญาณขาออกเพื่อส่งไปยังเซลล์อื่น การเรียนรู้ของเพอร์เซปตรอนภายใน ANN มีความคล้ายคลึงกับเซลล์นิวรอน สามารถรับสัญญาณขาเข้าเพื่อใช้ในกระบวนการเรียนรู้และปรับค่าสัมประสิทธิ์ที่ใช้ถ่วงน้ำหนักภายในตัวอย่างอัตโนมัติ ค่าสัมประสิทธิ์นี้เมื่อนำไปคูณกับสัญญาณขาเข้าที่และนำผลที่ได้ไปผ่านฟังก์ชันกระตุ้น (Activation function) ซึ่งเป็นฟังก์ชันที่ใช้ในกระบวนการตัดสินใจในขั้นสุดท้ายจะสามารถให้ผลลัพธ์ขาออกออกมาได้และหากมีการเรียนรู้และปรับค่าสัมประสิทธิ์ดังกล่าวได้มากเพียงพอ ค่าผลลัพธ์ก็จะสะท้อนคุณสมบัติของระบบได้ดีขึ้น แนวคิดของเพอร์เซปตรอนแสดงในรูปที่ 5



รูปที่ 5 หลักการทำงานของเพอร์เซปตรอน

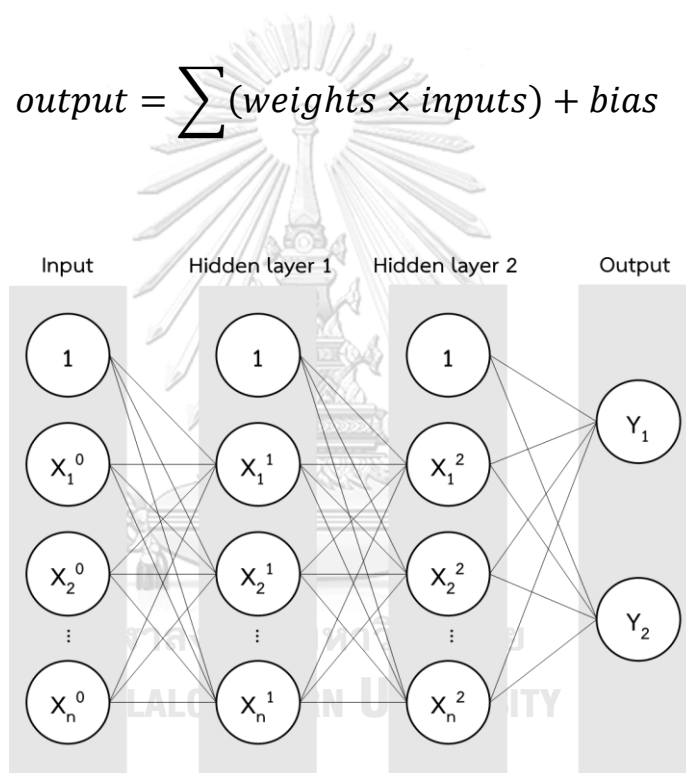
เพอร์เซปตรอนจะรับสัญญาณขาเข้า x และรวมสัญญาณทั้งหมดเข้ากับค่าถ่วงน้ำหนัก w และสร้างการรวมเชิงเส้น (Linear combination) สำหรับทุกสัญญาณขาเข้าจากนั้นจะนำไปผ่านฟังก์ชันกระตุ้น (แบบ Sigmoid, Unitstep, Softmax, ReLu, etc) เพื่อให้ได้ผลลัพธ์และจะถูกนำไปเทียบกับข้อมูลผลลัพธ์จริง (labels หรือ tags) เพื่อหาค่าความคลาดเคลื่อนระหว่างผลลัพธ์ที่ได้จากแบบจำลองและค่าจริงและนำกลับไปปรับปรุงค่าถ่วงน้ำหนักในรอบการเรียนรู้ต่อไปจนกว่าค่าความคลาดเคลื่อนจะลดลงมาอยู่ในระดับที่รับได้ซึ่งจะทำให้เพอร์เซปตรอนสามารถพยากรณ์ผลลัพธ์ได้ด้วยความแม่นยำมากขึ้น

การปรับปรุงค่าถ่วงน้ำหนักภายในแบบจำลองเป็นขั้นตอนที่สำคัญในการสร้างแบบจำลองโครงข่ายประสาทเทียม การปรับค่าถ่วงน้ำหนักจะขึ้นอยู่กับความพยายามลดค่าของฟังก์ชันสูญเสีย (Loss function) ลงในทุกรอบของการสอนแบบจำลอง ฟังก์ชันสูญเสียคือฟังก์ชันที่ใช้ออกถึงค่าความคลาดเคลื่อนโดยรวมระหว่างแบบจำลองที่สร้างได้และค่าจริงที่ใช้สอน อาจแสดงได้โดยใช้ Mean Square error, Mean Absolute error และฟังก์ชันอื่น การลดค่าในฟังก์ชันสูญเสียในแต่ละรอบของการสอนแบบจำลองสามารถทำได้โดยใช้อัลกอริทึมหรือ optimizer ได้หลายแบบ เช่น Gradient descent, Stochastic Gradient descent, Root Mean Square Propagation, ADAM และรูปแบบอื่น

แบบจำลองโครงข่ายประสาทเทียมสามารถมีจำนวนปม (Node) ของเพอร์เซปตรอนได้ไม่จำกัด แต่ละปมจะเชื่อมต่อกันในลักษณะเป็นชั้น (layer) โดยเริ่มจากชั้นของข้อมูลขาเข้า (input layer) ชั้นซ่อน (hidden layer) และชั้นข้อมูลขาออก (output layer) ข้อมูลขาเข้าจะถูกส่งเข้ามายัง input layer และส่งต่อไปยังชั้นซ่อนซึ่งสามารถมีจำนวนได้หลายชั้นและในแต่ละชั้นของชั้นซ่อนอาจมีจำนวนปมได้ไม่จำกัด ปมในแต่ละชั้นจะเรียนรู้ข้อมูลที่รับมาจากชั้นก่อนหน้า ปรับพารามิเตอร์ภายใน และส่งต่อไปยังชั้นต่อไปจนกระทั่งถึงชั้นข้อมูลขาออกโดยไม่มีการย้อนกลับ

ของข้อมูล แบบจำลองประเภทนี้เป็นแบบจำลองชนิดส่งไปข้างหน้า (Feed-forward neural network) รูปที่ 6 แสดงหลักการของแบบจำลองโครงข่ายประสาทเทียมแบบหลายปม หลายชั้นและส่งไปข้างหน้า ซึ่งในรูปที่ 6 ทุกชั้นของแบบจำลองยกเว้นชั้นข้อมูลขาออกจะมีปมหนึ่งที่ถูกใช้งานเสมอ (ปมที่มีเลข 1 ข้างใน) เรียกว่า bias node มีหน้าที่ในการปรับค่าข้อมูลขาออกในทำนองเดียวกับ intercepter ของการถดถอยแบบเชิงเส้น ในโครงข่ายประสาทเทียม ค่าถ่วงน้ำหนักจะส่งผลกระทบต่อความชันของฟังก์ชันกระตุ้นและค่า bias จะส่งผลต่อตำแหน่งและความเร็วในการทำงานของฟังก์ชันกระตุ้นทำให้สามารถเลื่อนกราฟไปท่ายซ้ายหรือขวาเพื่อปรับให้เข้ากับข้อมูลได้ดังสมการ (12)


$$output = \sum (weights \times inputs) + bias \quad (12)$$



รูปที่ 6 แบบจำลองโครงข่ายประสาทเทียมแบบหลายปมและหลายชั้น

ต้นไม้การตัดสินใจ (Decision tree)

ต้นไม้การตัดสินใจเป็นแบบจำลองที่เลียนแบบกระบวนการคิดและการใช้เหตุผลของมนุษย์ ด้วยการประมวลผลข้อมูลด้วยตรรกะและสามารถใช้ได้ทั้งกับปัญหาการจัดหมวดหมู่ (Classification) และการหาการถดถอย (Regression) การทำงานของต้นไม้การตัดสินใจจะเหมือนการแจกแจงข้อมูลและตัดสินใจในแต่ละขั้นผ่านการถามคำถามเพื่อให้สามารถจำแนกข้อมูลให้อยู่ในกลุ่มที่กำหนดได้



รูปที่ 7 ตัวอย่างการใช้เหตุผลของมนุษย์

รูปที่ 7 แสดงตัวอย่างการเลือกจัดกลุ่มของข้อมูลผ่านการถามคำถามหลายชั้น แบบจำลองต้นไม้การตัดสินใจจะทำงานคล้ายกับการตัดสินใจของมนุษย์ โดยในแต่ละปมจะแสดงโดยพีเจอร์และกฎการตัดสินใจจะแสดงโดยการใช้กิ่งก้าน (Branch/link) สุดท้าย ใบ (leaf) ของแบบจำลองจะเป็นปมสุดท้ายที่ไม่มีกิ่งก้านต่อออกไปซึ่งจะเป็นผลลัพธ์ของแบบจำลอง ผลลัพธ์นี้สามารถเป็นได้ทั้งข้อมูลเชิงตัวเลขและแบบชื่อประเภท/กลุ่ม การสร้างแบบจำลองต้นไม้การตัดสินใจจะเริ่มจากการเลือกพีเจอร์ที่จะเป็นพีเจอร์ราก (root) ของแบบจำลอง รากของแบบจำลองคือปมแรกที่ใช้เริ่มต้นในการสร้างแบบจำลองซึ่งสามารถหาได้โดยการคำนวณหาความไม่บริสุทธิ์ของข้อมูลหรือเอนโทรปี (Entropy) จากนั้นจึงคำนวณหาเกณฑ์ความรู้ (Information Gain -IG) ของทุกพีเจอร์และเลือกพีเจอร์ที่มีเกณฑ์ความรู้ที่สูงที่สุดเป็นพีเจอร์ราก ซึ่งพีเจอร์ดังกล่าวมีความสำคัญและส่งผลกระทบต่อผลการหาผลลัพธ์มากที่สุด จากนั้นจะทำการสร้างต้นไม้การตัดสินใจขึ้นมาโดยวิธีการแบบเดิมที่ปมอื่นในการแยกปมจนกว่าทุกใบของแบบจำลองจะมีความบริสุทธิ์ที่สูงโดยการคำนวณค่าเอนโทรปีหรือจนกว่าจะเข้าสู่เงื่อนไขที่กำหนด จากนั้นจึงสามารถใช้ข้อมูลขาเข้าใหม่เพื่อพยากรณ์ผลลัพธ์โดยใช้แบบจำลองได้

ต้นไม้การตัดสินใจสามารถนำมาใช้ทั้งในการจัดหมวดหมู่และการหาการถดถอยของข้อมูล ในการหาการถดถอยของข้อมูลนั้นข้อดีของแบบจำลองต้นไม้การตัดสินใจคือเป็นแบบจำลองที่สามารถนำข้อมูลมาใช้ได้โดยไม่ต้องมีการแปลงก่อนในข้อมูลที่ไม่เป็นเชิงเส้น ในการหาการถดถอยของข้อมูลโดยใช้ต้นไม้การตัดสินใจจะหาความไม่บริสุทธิ์ (Impurity - $I(t)$) ของข้อมูลของปม t โดยการใช้ค่ากำลังสองเฉลี่ยของความคลาดเคลื่อน (Mean Square Error - MSE) ตามสมการ


$$I(t) = MSE(t) = \frac{1}{N_t} \sum_{i \in D_t} (y^{(i)} - \hat{y}_t)^2 \quad (12)$$

โดยที่

- N_t คือ จำนวนของข้อมูลที่ใช้สอนที่ปม t
 D_t คือ จำนวนของสับเซตผลลัพธ์ที่ใช้สอนในปม t
 $y^{(i)}$ คือ ค่าเป้าหมายจริง
 \hat{y} คือ ค่าเป้าหมายจากการพยากรณ์



ตัวอย่างการหาการถดถอยโดยใช้ต้นไม้การตัดสินใจแสดงในรูปที่ 8 ซึ่งเส้นการถดถอยสามารถตรวจหาแนวโน้มหลักของข้อมูลได้ แต่ว่าแบบจำลองดังกล่าวมีข้อจำกัดในการติดตามข้อมูลแบบต่อเนื่องทำให้เส้นการถดถอยที่ได้มีลักษณะเป็นขั้นบันได ทั้งนี้การเลือกความลึกของแบบจำลองที่เหมาะสมจะส่งผลต่อสมรรถนะและการเกิด Overfitting ในการหาการถดถอยของข้อมูล แบบจำลองชนิดป่าแบบสุ่มมีข้อจำกัดด้านความอ่อนไหวต่อข้อมูลที่นำมาสอนแบบจำลองที่สูงและอาจส่งผลต่อสมรรถนะการพยากรณ์ของแบบจำลอง การใช้เทคนิคการประกอบกันของแบบจำลองแบบจำลองต้นไม้การตัดสินใจสามารถนำมาสร้างเป็นแบบจำลองชนิดป่าแบบสุ่ม (Random forest) ได้และทำให้มีสมรรถนะในการพยากรณ์การถดถอยที่สูงขึ้นกว่าเดิมโดยการใช้การสร้างแบบจำลองต้นไม้การตัดสินใจขึ้นมาหลายต้น แต่ละต้นจะมีความแตกต่างกันโดยจะสุ่มการเรียงลำดับของฟีเจอร์และการใช้เทคนิค Bootstrap Aggregation (Bagging) โดยการสร้างแบบจำลองต้นไม้การตัดสินใจมีโครงสร้างภายในแตกต่างกันขึ้นมาจำนวนหนึ่ง แต่ละแบบจำลองจะถูกสอนโดยใช้ข้อมูลเดียวกันซึ่งจะให้ผลที่แตกต่างกันจากนั้นจึงพิจารณาค่าเฉลี่ยของผลการพยากรณ์ของแต่ละแบบจำลองต้นไม้การตัดสินใจ เทคนิคดังกล่าวจะช่วยลดค่าความแปรปรวนของแบบจำลองและป้องกันการใช้แบบจำลองเดียวที่อาจมีปัญหา Overfitting ได้ นอกจากนี้แบบจำลองชนิดนี้ยังมีการตอบสนองต่อค่าสุดต่างในข้อมูลที่น้อยกว่าทำให้ไม่ต้องการการปรับจูนแบบจำลองที่มากนัก



รูปที่ 8 การหาการถดถอยของข้อมูลโดยใช้แบบจำลองต้นไม้การตัดสินใจ[12]

โครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network)

โครงข่ายประสาทเทียมแบบวนซ้ำเป็นโครงข่ายประสาทเทียมที่สามารถจัดการกับข้อมูลเชิงลำดับ (Sequential data) โครงข่ายประสาทเทียมแบบวนซ้ำสามารถนำข้อมูลในอดีตที่มีความยาวที่กำหนดมาใช้ในการพยากรณ์ผลลัพธ์ในอนาคต เช่นในระบบการทำนายค่าในประโยคที่จะเขียนต่อจากคำก่อนหน้า หรือราคาของหุ้นในตลาดหุ้นในช่วงเวลาที่กำหนด ข้อมูลเชิงลำดับคือข้อมูลที่มีความสัมพันธ์กันระหว่างแต่ละข้อมูลและลำดับก่อน-หลังของข้อมูลมีความสำคัญกับความหมายของข้อมูล ข้อมูลเชิงลำดับจะไม่สามารถสลับตำแหน่งกันได้แม้ว่าข้อมูลแต่ละตัวจะมีความหมายแต่จะทำให้ความหมายโดยรวมของข้อมูลเปลี่ยนแปลงไปเช่นการสลับตำแหน่งคำในประโยคทำให้ความหมายของทั้งประโยคเปลี่ยนแปลงไปแม้ว่าข้อมูลแต่ละคำจะมีความหมายของตัวเองก็ตาม

การทำงานของโครงข่ายประสาทเทียมแบบวนซ้ำจะทำงานโดยการใช้ฟังก์ชันกับข้อมูลในชุดลำดับของข้อมูลสามารถเขียนความสัมพันธ์ได้ดังนี้

$$s_t = f(s_{t-1}, x_t) \quad (13)$$

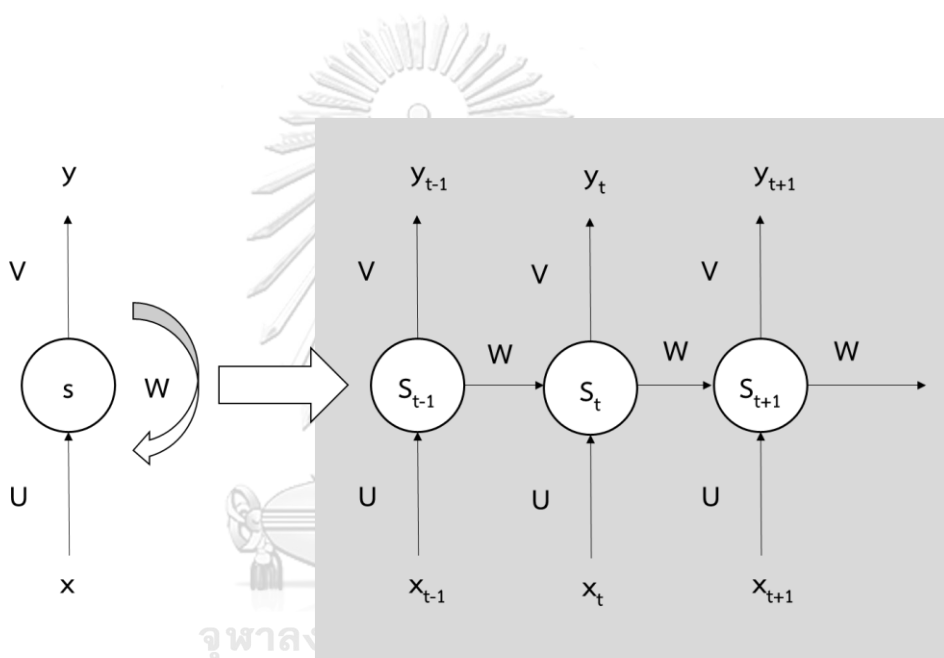
โดยที่

s_t คือ เวกเตอร์ของข้อมูลที่บ่งบอกสถานะ(state)ของโครงข่ายภายในที่ขั้นตอนที่ t

f คือ ฟังก์ชันที่สามารถหาอนุพันธ์ได้

x_t คือข้อมูลขาเข้าที่ขั้นตอนที่ t

แบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำจะมีความแตกต่างจากแบบจำลองโครงข่ายประสาทเทียมแบบธรรมดาที่สถานะของแบบจำลองจะขึ้นอยู่กับข้อมูลขาเข้าปัจจุบันและตัวถ่วงน้ำหนักภายในเท่านั้น แบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำจะมีสถานะในปัจจุบัน s_t ที่ขึ้นอยู่กับทั้งสถานะก่อนหน้า s_{t-1} ที่เสมือนเป็นผลรวมของสถานะก่อนหน้าทั้งหมดและข้อมูลขาเข้าในปัจจุบัน การวนซ้ำในแบบจำลองหมายถึงการพัฒนาแบบจำลองทีละขั้นตอนด้วยการใช้การวนกลับของข้อมูลในขั้นตอนก่อนหน้าเพื่อเลือกข้อมูลที่จะส่งต่อไปยังขั้นตอนต่อไปดังในรูปที่ 9



รูปที่ 9 กระบวนการทำงานของโครงข่ายประสาทเทียมแบบวนซ้ำ

โครงสร้างทางด้านซ้ายของรูปที่ 9 แสดงถึงการวนซ้ำของข้อมูลภายในแบบจำลอง ซึ่งอธิบายรายละเอียดในรูปขวา ข้อมูลที่สถานะ t จะรับข้อมูลจากสถานะ $t-1$ ผ่านค่าถ่วงน้ำหนัก W ในขณะเดียวกันก็จะรับข้อมูลขาเข้า x_t ผ่านค่าถ่วงน้ำหนัก U ด้วยเพื่อใช้ข้อมูลทั้งสองในการพยากรณ์ผลลัพธ์ y_t ผ่านค่าถ่วงน้ำหนัก V ผลลัพธ์ y สามารถหาได้จากทุกขั้นตอน t หรือหาได้เฉพาะจากขั้นตอนสุดท้ายของกระบวนการก็ได้ซึ่งขึ้นอยู่กับความต้องการและโครงสร้างของข้อมูล จากนั้นจะทำการส่งข้อมูลของสถานะต่อไปยังสถานะต่อไป เราสามารถกำหนดสถานะภายในและผลลัพธ์ที่ขั้นตอน t ได้ดังนี้

$$s_t = f(s_{t-1} * W + x_t * U) \quad (14)$$


$$y_t = s_t * V \quad (15)$$

โครงข่ายประสาทเทียมแบบวนซ้ำในรูปที่ 9 สามารถนำมาต่อกันเป็นชั้นในลักษณะเดียวกันกับการมีหลายชั้น (layer) ของโครงข่ายประสาทเทียมแบบปกติ การเพิ่มจำนวนชั้นของแบบจำลองจะลดข้อจำกัดในการเรียนรู้ของแบบจำลองให้มีสมรรถนะที่ดีขึ้นได้ สมการ (14) และ (15) แสดงให้เห็นว่า โครงข่ายประสาทเทียมแบบวนซ้ำเป็นแบบจำลองที่เสมือนมีความทรงจำของข้อมูลก่อนหน้า ความทรงจำนี้ในทางทฤษฎีสามารถมีความยาวย้อนหลังได้ไม่จำกัด แต่ทว่าในการใช้งานจริงแบบจำลองสามารถมีความทรงจำของข้อมูลย้อนหลังได้เพียงไม่กี่ขั้นตอนเท่านั้นเนื่องจากผลของการหายไปและการเพิ่มขึ้นอย่างมากของเกรเดียนต์ (Vanishing and exploding gradient)

การเพิ่มขึ้นอย่างมากและการหายไปของเกรเดียนต์ (Exploding and Vanishing gradient)

ในการสอนแบบจำลองโครงข่ายประสาทเทียมทั้งแบบธรรมดาและแบบวนซ้ำ วิธีการหนึ่งในการปรับค่าถ่วงน้ำหนักภายในคือการใช้วิธีการถ่ายทอดย้อนกลับ (Back propagation) ซึ่งเป็นวิธีการปรับค่าถ่วงน้ำหนักโดยการหาเกรเดียนต์ของฟังก์ชันสูญเสีย (Loss function) หรือเกรเดียนต์ของความคลาดเคลื่อน (error gradient) ที่สอดคล้องกับค่าถ่วงน้ำหนัก

เกรเดียนต์ของความคลาดเคลื่อนเป็นค่าที่บอกทิศทางและขนาดของค่าความคลาดเคลื่อนในกระบวนการสอนแบบจำลองเพื่อให้แบบจำลองสามารถปรับค่าถ่วงน้ำหนักภายในไปยังทิศทางที่ลดค่าความคลาดเคลื่อนของผลลัพธ์จากการพยากรณ์และผลลัพธ์จริงลงได้ ในแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำโครงสร้างการทำงานภายใน (รูปที่ 9) ที่มีลักษณะการทำงานที่ต่อกันเป็นขั้นตอน หากค่าเกรเดียนต์ของความคลาดเคลื่อนมีค่าสูงและสะสมผ่านการคูณในแต่ละขั้นตอนมากขึ้นอาจส่งผลให้เกิดการปรับค่าที่สูงเกินจริงของค่าถ่วงน้ำหนักทำให้แบบจำลองขาดเสถียรภาพ ค่าความคลาดเคลื่อนรวมของระบบที่แต่เดิมควรจะลดลงทุกกรอบที่ทำการสอนแบบจำลองจะเกิดการเพิ่มขึ้นอย่างมากส่งผลให้ไม่สามารถใช้แบบจำลองได้ตามที่ต้องการ เหตุการณ์ลักษณะนี้เรียกว่าการเพิ่มขึ้นอย่างมากของเกรเดียนต์ (exploding gradient) ตัวอย่างการเกิดการเพิ่มขึ้นอย่างมากของเกรเดียนต์ดังรูปที่ 10



รูปที่ 10 ค่า U V และ ความคลาดเคลื่อนเมื่อเกิดการเพิ่มขึ้นอย่างมากของเกรเดียนต์ [13]

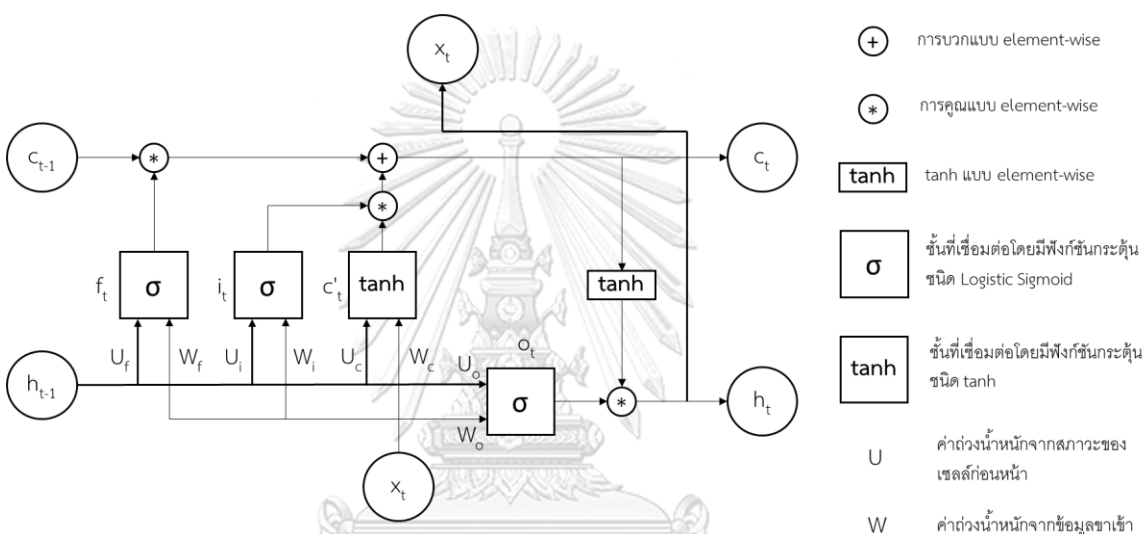
อีกกรณีหนึ่งที่อาจเกิดขึ้นได้กับเกรเดียนต์ซึ่งเป็นกรณีที่ตรงกันข้ามกับการเพิ่มขึ้นอย่างมากของเกรเดียนต์คือการหายไปของเกรเดียนต์ (Vanishing gradient) เกิดจากการที่ขนาดของเกรเดียนต์มีค่าน้อยและลดลงอย่างต่อเนื่องเมื่อคูณกับค่าเดิมในแต่ละขั้นตอน ส่งผลให้ค่าเกรเดียนต์ในการถ่ายทอดย้อนกลับมีค่าน้อยส่งผลให้เกรเดียนต์จากข้อมูลล่าสุดเท่านั้นที่ถูกนำมาใช้ในการสอนแบบจำลองทำให้ไม่สามารถใช้ข้อมูลในอดีตในการสอนแบบจำลองได้อีก แบบจำลองจะถูกสอนโดนขึ้นอยู่กับข้อมูลในปัจจุบันเท่านั้นซึ่งทั้งการเพิ่มขึ้นอย่างมากและการหายไปของเกรเดียนต์ดังกล่าวเป็นข้อจำกัดของโครงข่ายประสาทเทียมแบบวนซ้ำ

โครงข่ายประสาทเทียมแบบวนซ้ำชนิด Long Short-Term Memory (LSTM)

ปัญหาการเพิ่มขึ้นอย่างมากและการหายไปของเกรเดียนต์ในการสร้างแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำทำให้การใช้ข้อมูลในอดีตย้อนหลังที่เยอะเป็นไปได้ยาก Sepp Hochreiter และ Jürgen Schmidhuber ได้เสนอแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำชนิด Long Short-Term Memory (LSTM) ขึ้นเพื่อแก้ปัญหาดังกล่าวอย่างมีประสิทธิภาพ แนวคิดหลักของ LSTM คือการกำหนดเซลล์สถานะ (cell state) ที่มีคุณสมบัติพิเศษซึ่งพัฒนาเพิ่มเติมจากสถานะ s ในแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำเดิม ในเซลล์สถานะนี้ข้อมูลจะสามารถดำรงอยู่หรือถูกลบออกไปได้ เซลล์สถานะนี้จะถูกปรับค่าได้โดยการใช้ช่องทาง (gate) ที่จำเพาะซึ่งเป็นเส้นทางที่อนุญาตให้ข้อมูลผ่านได้ ในช่องทางนี้ข้อมูลจะผ่านฟังก์ชันกระตุ้นชนิด Logistic Sigmoid และผลคูณทางเมตริก (element-wise) และเนื่องจากผลลัพธ์ของ logistic sigmoid function จะมีค่าอยู่ระหว่าง 0 ถึง 1 เท่านั้น ข้อมูลที่ผ่านช่องทางนี้จะถูกลดทอนลง โดยทั่วไป LSTM จะประกอบด้วยช่องทางภายใน 3 ช่องทาง ได้แก่ ช่องทางลืม (forget gate) ช่องทางข้อมูลขาเข้า (input gate) และช่องทางข้อมูลขา

ออก (output gate) ซึ่งเซลล์สถานะ ข้อมูลขาเข้า และข้อมูลขาออกจะอยู่ในรูปของเวกเตอร์ โครงสร้างการทำงานภายในของ LSTM แสดงในรูปที่ 11

x_t , c_t และ h_t คือค่าข้อมูลขาเข้า สถานะเซลล์ก่อนหน้า และข้อมูลขาออกของ LSTM ในขั้นตอน t โดยที่ c_t คือสถานะเซลล์ที่ได้เสนอเพิ่มขึ้นใน LSTM ข้อมูลขาเข้า x_t และข้อมูลขาออกในเซลล์ก่อนหน้าจะเชื่อมต่อกับช่องทางทั้งสามรวมไปถึงเซลล์ c_t ด้วยค่าถ่วงน้ำหนัก U และ W ตามลำดับ ค่า c_t สัญลักษณ์สถานะของเซลล์ที่ขั้นตอน t สัญลักษณ์ f_t , i_t และ o_t คือช่องทางลืม ช่องทางข้อมูลและช่องทางข้อมูลขาออกของ LSTM ตามลำดับ



รูปที่ 11 โครงสร้างการทำงานภายในของ LSTM [13]

จุฬาลงกรณ์มหาวิทยาลัย

ช่องทางลืม f_t เป็นช่องทางที่เลือกและตัดสินใจว่าจะทำการลบสถานะของเซลล์หรือไม่ การทำงานของช่องทางลืมจะขึ้นอยู่กับข้อมูลขาออกของเซลล์ก่อนหน้า h_{t-1} และข้อมูลขาเข้าของเซลล์ปัจจุบัน x_t ดังนี้

$$f_t = \sigma(W_f x_t + U_f h_{t-1}) \tag{16}$$

ข้อมูลที่เข้าช่องทางลืมจะถูกนำมาผ่านฟังก์ชันกระตุ้นแบบ Logistic Sigmoid ซึ่งจะให้ผลลัพธ์ออกมาในช่วง $[0,1]$ และทำการคูณแบบ element-wise กับค่าสถานะของเซลล์ก่อนหน้า c_{t-1} ซึ่งหากผลลัพธ์จากช่องทางลืมมีค่าเท่ากับ 0 จะละทิ้งข้อมูลของเซลล์ก่อนหน้าไปทั้งหมด และหากผลลัพธ์จากช่องทางลืมมีค่าเท่ากับ 1 จะอนุญาตให้ข้อมูลจากเซลล์ก่อนหน้าทั้งหมดเข้ามาได้ ซึ่งช่องทางลืมนี้ทำให้แบบจำลองแบบ LSTM สามารถเลือกที่จะเก็บหรือลดทอนข้อมูลที่จะเข้ามาสู่เซลล์ได้

ช่องทางข้อมูลขาเข้า i_t เป็นช่องที่ทางจะตัดสินใจเลือกข้อมูลขาเข้าใหม่ที่จะเข้าสู่เซลล์ซึ่งจะแบ่งการทำงานออกเป็น 2 ส่วน โดยส่วนแรกจะทำการเลือกข้อมูลที่จะเข้ามาสู่เซลล์จากข้อมูลขาออกของเซลล์ก่อนหน้า h_{t-1} และข้อมูลขาเข้าปัจจุบัน x_t ซึ่งจะคล้ายคลึงกับการทำงานของช่องทางลืม โดยผลลัพธ์จะออกมาอยู่ในช่วง $[0,1]$ ผ่านฟังก์ชันกระตุ้นชนิด Logistic Sigmoid ดังนี้

$$i_t = \sigma(W_i x_t + U_i h_{t-1}) \quad (17)$$

ข้อมูลขาเข้าส่วนที่สองจะผ่านช่องทาง c'_t ซึ่งขึ้นอยู่กับข้อมูลขาออกของเซลล์ก่อนหน้า h_{t-1} และข้อมูลขาเข้าปัจจุบัน x_t เช่นกันแต่ข้อมูลทั้งสองจะถูกนำมาผ่านฟังก์ชันกระตุ้นชนิด \tanh ดังนี้

$$c'_t = \tanh(W_c x_c + U_c h_{t-1}) \quad (18)$$

ช่องทางลืมและช่องทางข้อมูลขาเข้าจะเป็นตัวกำหนดสถานะของเซลล์ใหม่โดยการเลือกจะให้ข้อมูลจากเซลล์ก่อนหน้าและข้อมูลใหม่ใดเข้ามาบ้าง

$$c_t = f_t * c_{t-1} \oplus i_t c'_t \quad (19)$$

ช่องทางข้อมูลขาออก o_t จะเป็นตัวกำหนดข้อมูลขาออกของเซลล์โดยจะรับข้อมูลขาออกของเซลล์ก่อนหน้า h_{t-1} และข้อมูลขาเข้าปัจจุบัน x_t ผ่านฟังก์ชันกระตุ้นชนิด Logistic Sigmoid ซึ่งจะอยู่ในช่วง $[0,1]$ ค่า 0 จะหมายถึงไม่มีข้อมูลขาออกเลย และ 1 หมายถึงมีข้อมูลขาออกทั้งหมด

$$o_t = \sigma(W_o x_t + U_o h_{t-1}) \quad (20)$$

และสุดท้าย ข้อมูลสถานะและข้อมูลขาออกของเซลล์ปัจจุบันจะส่งต่อไปให้กับเซลล์ถัดไปจะเป็นข้อมูลขาออกที่ประกอบด้วยฟังก์ชัน \tanh ของสถานะเซลล์

$$h_t = o_t * \tanh(c_t) \quad (21)$$

เนื่องจากสมการที่ (16)-(21) เป็นสมการที่สามารถหาอนุพันธ์ได้ เราจึงสามารถใช้การถ่ายทอดย้อนกลับในแต่ละขั้นตอนในการสอนแบบจำลอง LSTM ได้ในลักษณะเดียวกับแบบจำลองอื่น

จากการทำงานของ LSTM ในรูปที่ 11 พบว่าในกรณีที่ช่องทางลืมของแต่ละเซลล์มีค่า 1 และช่องทางข้อมูลขาเข้ามีค่า 0 จะทำให้ข้อมูลสถานะจากเซลล์ก่อนหน้าถูกคัดลอกอย่างสมบูรณ์

และส่งต่อไปยังเซลล์ถัดไป แสดงให้เห็นว่าการลบข้อมูลหรือความทรงจำในอดีตจะขึ้นอยู่กับการทำงานของช่องทางลึมนั้นๆ ทำให้สามารถบังคับข้อมูลในอดีตให้คงอยู่ได้แม้จะผ่านมาหลายเซลล์ นอกจากนี้ข้อมูลขาเข้าจะถูกนำไปผ่านฟังก์ชัน \tanh โดยช่องทาง c'_i ก่อนที่จะเข้าสู่สภาวะของเซลล์ปัจจุบันซึ่งทำให้สภาวะของเซลล์ไม่เกิดการเพิ่มขึ้นอย่างรวดเร็วและเกิดเสถียรภาพที่ดีภายในเซลล์ได้

2.6 การสร้างขอบเขตข้อมูลโดยใช้ Bollinger Bands

Bollinger bands เป็นวิธีการทางสถิติที่ออกแบบโดย John Bollinger ในปี ค.ศ. 1983 มีจุดประสงค์ในการใช้ประเมินราคาและความผันผวนของราคาหุ้น ตรวจสอบเงื่อนไขการตัดสินใจและการซื้อขายหุ้นด้วยการวิเคราะห์ทางเทคนิคโดยการนิยามค่าสูง-ต่ำของข้อมูลแบบสัมพัทธ์ Bollinger bands เป็นเส้นกราฟที่ประกอบด้วย 3 ส่วน ได้แก่ เส้นค่าเฉลี่ยเคลื่อนที่ (Moving average/middle band) เส้นขอบบน (Upper band) และเส้นขอบล่าง (Lower band) โดยเส้นค่าเฉลี่ยเคลื่อนที่ที่จะใช้ข้อมูลย้อนหลังที่มีความยาวตามที่ผู้ใช้กำหนดมาสร้างเส้นค่าเฉลี่ย นอกจากนี้ความกว้างของ Bollinger bands ซึ่งเป็นระยะห่างระหว่างเส้นค่าเฉลี่ยเคลื่อนที่กับเส้นขอบบนและเส้นขอบล่างมักจะถูกกำหนดโดยค่าส่วนเบี่ยงเบนมาตรฐาน (standard deviation) โดยทั่วไปจะใช้ค่าสองเท่าของส่วนเบี่ยงเบนมาตรฐานในการกำหนดระยะห่างระหว่างเส้นค่าเฉลี่ยเคลื่อนที่และเส้นขอบบนหรือขอบล่าง การสร้าง Bollinger bands จะทำได้ดังสมการ

$$\sigma = \sqrt{\frac{\sum_{n=1}^N (X_n - \bar{X})^2}{N}} \quad (22)$$

สมการที่ 22 เป็นการหาค่าส่วนเบี่ยงเบนมาตรฐานของชุดข้อมูล

โดยที่

- σ คือ ค่าส่วนเบี่ยงเบนมาตรฐานของชุดข้อมูล
- N คือ จำนวนข้อมูลทั้งหมดในชุด
- X_n คือ ข้อมูลตำแหน่งที่ n
- \bar{x} คือ ค่าเฉลี่ยของชุดข้อมูลซึ่งหาได้ดังนี้

$$\bar{X} = \frac{\sum_{j=1}^N X_j}{N} \quad (23)$$

$$\text{Upper band} = \bar{X} + 2\sigma \quad (24)$$

$$\text{Lower band} = \bar{X} - 2\sigma \quad (25)$$

ค่า X_j เป็นข้อมูลตำแหน่งที่ j ของชุดข้อมูล ในการสร้าง Bollinger bands จะคำนวณหาค่าเฉลี่ยเคลื่อนที่ \bar{x} และส่วนเบี่ยงเบนมาตรฐาน σ ในแต่ละจุดข้อมูล โดยการกำหนดค่า N ที่ต้องการและจึงย้อนใช้ข้อมูลก่อนหน้ามาคำนวณ จากนั้นค่า σ จะถูกนำมารวมกับค่าเฉลี่ยในการสร้างค่าขอบเขตบน และจะนำมาหักออกจากค่าเฉลี่ยในการสร้างขอบเขตล่างซึ่งจะใช้ค่า 2 เท่าของส่วนเบี่ยงเบนมาตรฐานเพื่อสร้างขอบเขตการพยากรณ์ที่ค่าความเชื่อมั่น 95% ดังสมการที่ (24)-(25) กระบวนการดังกล่าวจะทำให้ซ้ำด้วยวิธีการเดิมในจุดข้อมูลถัดไปเพื่อนำมาสร้างเป็นเส้นค่าเฉลี่ยและขอบเขตบน-ล่าง ของข้อมูล ทั้งนี้ค่าเฉลี่ยของชุดข้อมูลสมการข้างต้น เป็นค่าเฉลี่ยอย่างง่าย (Simple average) ซึ่งยังอาจมีการติดตามข้อมูลได้ไม่ไวพอ (lower sensitivity) การใช้ค่าเฉลี่ยชนิดอื่นเช่นค่าเฉลี่ยเอ็กซ์โพเนนเชียล (Exponential average) ในการสร้าง Bollinger bands จะสามารถเพิ่มความไวในการติดตามการเปลี่ยนแปลงของข้อมูลขึ้นได้

การใช้งาน Bollinger bands สามารถใช้ในการตรวจหาข้อมูลที่อยู่นอกขอบเขตที่อาจบ่งชี้ถึงค่าที่มากหรือน้อยกว่าปกติในชุดข้อมูลได้ นอกจากนั้นการเพิ่มขึ้นหรือลดลงของความกว้าง (bandwidth) ของ Bollinger bands ก็สามารถบ่งบอกถึงความผันผวนของข้อมูลได้เช่นกัน โดยเมื่อขนาดความกว้างของ Bollinger bands ลดลงจะสื่อถึงข้อมูลที่มีความผันผวนที่ต่ำและในทางกลับกันขนาดของ Bollinger bands ที่กว้างขึ้นจะสื่อถึงความผันผวนของข้อมูลที่สูงขึ้น ค่าอัตราส่วนร้อยละของ Bollinger bands (Bollinger band percent bandwidth -%b) สามารถใช้บอกตำแหน่งของข้อมูลเทียบกับตำแหน่งของขอบบนและขอบล่างของ Bollinger bands ซึ่งสามารถบอกภาพรวมและใช้ตรวจหาข้อมูลที่เกินขอบเขตของ Bollinger bands ได้ ค่า %b จะมีค่า 0 เมื่อข้อมูลอยู่ที่ขอบล่างของ Bollinger bands และมีค่า 1 เมื่ออยู่ที่ขอบบนของ Bollinger bands ขนาดความกว้างและ %b สามารถหาได้ดังนี้

$$\text{Bandwidth} = \frac{(\text{upper band} - \text{lower band})}{\text{middle band}} \quad (26)$$

$$\%B = \frac{(data - lower\ band)}{(upper\ band - lower\ band)} \quad (27)$$

ทั้งนี้การใช้งาน Bollinger bands ไม่ได้ถูกจำกัดเฉพาะในการลงทุนในตลาดหุ้นเท่านั้น บทความ [7] ได้ดัดแปลงการใช้ Bollinger bands ในการตรวจจับรูปแบบการโจมตีทางไซเบอร์เพื่อเปลี่ยนแปลงบิลค่าใช้ไฟฟ้า [9] ใช้ Bollinger bands ในการตรวจหาจุดบกพร่องบนลวดลายผ้าซึ่งสามารถตรวจหาได้ในอัตราสำเร็จที่สูงและสามารถแสดงให้เห็นถึงความผันผวนและการเปลี่ยนแปลงที่ผิดปกติของข้อมูลได้

2.7 ต้นไม้การถดถอยที่เคลื่อนลงตามความชัน (Gradient Boosting Regression Tree-GBRT)

แบบจำลองต้นไม้การตัดสินใจที่ใช้ในการหาการถดถอยหรือต้นไม้การถดถอยเป็นแบบจำลองที่มีความอ่อนไหวกับข้อมูลที่นำมาสร้างในกระบวนการสอน ในขณะที่แบบจำลองป่าแบบสุ่มได้เสนอแนวทางการใช้แบบจำลองที่แตกต่างกันของแบบจำลองต้นไม้ตัดสินใจจำนวนหนึ่งเพื่อหาค่าเฉลี่ยของผลลัพธ์ในการพยากรณ์ การใช้เทคนิคการเคลื่อนลงตามความชันก็เป็นอีกวิธีหนึ่งในการเพิ่มสมรรถนะของแบบจำลองต้นไม้การตัดสินใจ

หลักการทำงานของแบบจำลองต้นไม้การถดถอยแบบการเคลื่อนลงตามความชันจะเริ่มหลังจากสร้างแบบจำลองขั้นต้น (ต้นไม้การตัดสินใจ) ที่อาจมีสมรรถนะที่ต่ำในการพยากรณ์ชุดข้อมูลโดยข้อมูลขาเข้า x และข้อมูลขาออก y ใดๆจะอยู่ในรูป $(x_1, y_1), (x_2, y_2), \dots$ และแบบจำลองขั้นต้นดังกล่าวจะถูกแทนด้วย $F(x)$ ซึ่งจุดประสงค์ของการเคลื่อนลงตามความชันต้องการสร้างแบบจำลองต้นไม้การตัดสินใจ $h(x)$ ที่มีคุณสมบัติในการเพิ่มสมรรถนะโดยรวมของแบบจำลองโดยมีผลลัพธ์ที่คาดหวังดังนี้

$$F(x_1) + h(x_1) = y_1 \quad (28)$$

$$F(x_2) + h(x_2) = y_2$$

...

$$F(x_n) + h(x_n) = y_n$$

หรืออีกนัยหนึ่งคือการหาแบบจำลอง $h(x)=F(x)-y$ ซึ่ง $h(x)$ แสดงถึงแบบจำลองที่สามารถพยากรณ์ ส่วนต่างระหว่างข้อมูลจริงและข้อมูลที่พยากรณ์โดยแบบจำลอง $F(x)$ ดังนั้น จุดประสงค์ของการ เคลื่อนลงตามความชันคือการสร้างแบบจำลองที่มีความสัมพันธ์ดังนี้

$$(x_1, y_1 - F(x_1)), (x_2, y_2 - F(x_2)), \dots \quad (29)$$

นอกจากนี้ หากแบบจำลอง $h(x)$ ยังไม่สามารถเพิ่มสมรรถนะของแบบจำลอง $F(x)$ ได้ก็ตามที่ ต้องการ การสร้างแบบจำลองในลักษณะเดียวกันกับ $h(x)$ ก็สามารถสร้างเพิ่มสมรรถนะสูงให้สูงขึ้น ได้อีกเช่นกัน

ในการนำค่าผลต่างระหว่างค่าที่เกิดขึ้นจริงและค่าที่พยากรณ์ได้จากแบบจำลอง $F(x)$ มา สร้างเป็นแบบจำลอง $h(x)$ นั้นจะเขียนอยู่ในรูปฟังก์ชันสูญเสีย (Loss function) $L(y, F(x))$ ซึ่งเป็น สมการที่ใช้หาผลรวมค่าความคลาดเคลื่อนของข้อมูลแต่ละชุดเพื่อใช้ในการบ่งชี้การปรับ ค่าพารามิเตอร์ภายในของแบบจำลอง $h(x)$ โดยวิธีการเคลื่อนลงตามความชัน ในกระบวนการสอน แบบจำลอง $h(x)$ มีจุดประสงค์ในการทำให้ค่า $J = \sum_i L(y_i, F(x_i))$ มีค่าน้อยที่สุด ซึ่งหาก กำหนดให้ฟังก์ชัน สูญเสียที่ใช้เป็น ชนิด square loss ซึ่งนิยาม โดย $L(y, F(x)) = (y - F(x))^2/2$ จะสามารถหาเกรเดียนต์ของ J ได้ดังนี้

$$\frac{\partial J}{\partial F(x_i)} = \frac{\partial \sum_i L(y_i, F(x_i))}{\partial F(x_i)} = F(x_i) - y_i \quad (30)$$

หรือเขียนในรูปค่าลบของเกรเดียนต์ (Negative gradient) ได้เป็น

$$-\frac{\partial J}{\partial F(x_i)} = y_i - F(x_i) \quad (31)$$

ซึ่งสมการ (31) หมายถึงการหาค่าลบของเกรเดียนต์ของฟังก์ชันสูญเสียจะมีค่าเท่ากับจุดประสงค์ใน การสร้างแบบจำลอง $h(x)$ ตามสมการ (29) ซึ่งแบบจำลอง $h(x)$ จะใช้ข้อมูลขาเข้าในการสร้างเป็น ชุดเดียวกับข้อมูลที่แบบจำลอง $F(x)$ ใช้ในการสร้างครั้งแรกแต่ใช้ค่าลบของเกรเดียนต์เป็นข้อมูลขา ออกเป้าหมายในการสร้างแบบจำลองแทนค่า y จากนั้นนำผลลัพธ์ที่ได้จากแบบจำลอง $F(x)$ และ

$h(x)$ มารวมกันในลักษณะ $F(x) := F(x) + \rho h(x), \rho = 1$ โดยจำนวนครั้งในการปรับค่าดังกล่าวสามารถวนซ้ำได้จนได้ค่าสมรรถนะที่เหมาะสม นอกจากนี้ข้อดีของการใช้ค่าเกรเดียนต์ในการปรับสมรรถนะของแบบจำลองคือแบบจำลองสามารถใช้ฟังก์ชันสูญเสียใดๆ (ที่เหมาะสม) ในการสร้างแบบจำลองที่มีคุณสมบัติที่ต้องการได้

Quantile Loss function

ฟังก์ชันสูญเสียแบบควอนไทล์เป็นฟังก์ชันที่สามารถกำหนดค่าควอนไทล์ที่ต้องการซึ่งนอกจากจะเป็นฟังก์ชันสูญเสียที่ใช้สร้างแบบจำลองแล้ว การกำหนดค่าควอนไทล์ยังสามารถใช้ในการสร้างขอบเขตการพยากรณ์ของข้อมูลในแบบจำลองที่มีพื้นฐานจากต้นไม้การตัดสินใจได้ ซึ่งฟังก์ชันสูญเสียแบบควอนไทล์ดังกล่าวเป็นฟังก์ชันที่ขยายมาจากฟังก์ชันชนิด ค่าเฉลี่ยความผิดพลาดสัมบูรณ์ (MAE) โดยหากกำหนดค่าควอนไทล์ เท่ากับ 50% (หรือ 0.5) จะให้ผลเหมือนการใช้ MAE สมการที่ใช้กำหนดฟังก์ชันสูญเสียชนิดควอนไทล์เป็นดังนี้

$$L_\gamma(y, \hat{y}) = \sum_{i=y_i < \hat{y}_i} (\gamma - 1) \cdot |y_i - \hat{y}_i| + \sum_{i=y_i \geq \hat{y}_i} \gamma \cdot |y_i - \hat{y}_i| \quad (32)$$

เมื่อค่า γ คือ quantile ที่กำหนดมีค่าระหว่าง 0 ถึง 1, y_i คือข้อมูลขาออกที่เกิดขึ้นจริงในชุดข้อมูล i และ \hat{y}_i คือข้อมูลขาออกที่พยากรณ์ได้จากแบบจำลอง ค่า γ สามารถใช้ในการสร้างขอบเขตการพยากรณ์ของข้อมูลในแบบจำลองต้นไม้การตัดสินใจที่เคลื่อนลงตามความชันได้ เช่นการกำหนดค่า $\gamma = 0.95$ สำหรับขอบเขตบนและ 0.05 สำหรับขอบเขตล่างในการสร้างขอบเขตการพยากรณ์ของข้อมูล 90%

2.8 ความน่าจะเป็นของขอบเขตการพยากรณ์ในการครอบคลุมข้อมูล (Prediction Interval coverage probability-PICP)

ความน่าจะเป็นของขอบเขตการพยากรณ์ในการครอบคลุมข้อมูลเป็นค่าที่วัดจากการนับจำนวนข้อมูลเป้าหมาย (ข้อมูลจริงที่เกิดขึ้น) ที่อยู่ภายในขอบเขตการพยากรณ์ที่สร้างขึ้น ค่า PICP ที่สูงจะบ่งบอกถึงจำนวนข้อมูลเป้าหมายที่อยู่ในขอบเขตการพยากรณ์มากขึ้นโดยมีนิยามดังนี้

$$PICP = \frac{1}{N} \sum_{i=1}^N c_i \quad (33)$$

$$c_i \begin{cases} 1, t_i \in [L_i, U_i] \\ 0, t_i \notin [L_i, U_i] \end{cases}$$

เมื่อ N คือ จำนวนข้อมูลเป้าหมายทั้งหมด

t_i คือ ข้อมูลเป้าหมายตำแหน่งที่ i

L_i คือ ขอบเขตล่างที่ตำแหน่ง i

U_i คือ ขอบเขตบนที่ตำแหน่ง i

ค่า PICP มีความเกี่ยวข้องโดยตรงกับขนาดความกว้างของขอบเขตการพยากรณ์ ซึ่งในบางกรณีการเลือกใช้ขอบเขตการพยากรณ์ที่มีค่า PICP สูงจากค่าขอบเขตการพยากรณ์ที่กว้างมากเกินไปอาจไม่มีประโยชน์มากนัก ดังนั้นการแสดงค่า PICP จึงควรแสดงควบคู่กับค่าที่ใช้บ่งบอกความกว้างของขอบเขตการพยากรณ์ด้วยการใช้ค่าเฉลี่ยความกว้างของขอบเขตการพยากรณ์ (Mean Prediction Interval Width - MPIW)

$$MPIW = \frac{1}{N} \sum_{i=1}^N (U_i - L_i) \quad (34)$$

นอกจากค่า MPIW ที่นิยามโดยสมการ (34) ค่า NMPIW ซึ่งเป็นค่า MPIW ที่ได้ทำการปรับให้เป็นค่าต่อความยาวของจำนวนข้อมูลสามารถนำมาใช้ในการเปรียบเทียบขนาดความกว้างของขอบเขตการพยากรณ์ในข้อมูลเป้าหมายที่มีความยาวไม่เท่ากันได้

$$NMPIW = \frac{MPIW}{R} \quad (35)$$

เมื่อ R คือจำนวนข้อมูลเป้าหมาย

ขอบเขตการพยากรณ์ที่ดีค่า PICP ควรมีค่าสูงในขณะที่ค่า NMPIW ควรมีค่าน้อย กล่าวคือจำนวนข้อมูลเป้าหมายจริงอยู่ในขอบเขตการพยากรณ์ที่สร้างเขอะและขอบเขตมีความกว้างไม่มาก แต่ว่าการที่ความกว้างของขอบเขตการพยากรณ์มีค่าลดลงจะส่งผลให้โอกาสที่ข้อมูลเป้าหมายจะอยู่ในขอบเขตการพยากรณ์ลดลงเช่นกัน คชนี้ Coverage width-based criterion (CWC) สามารถใช้บ่ง-

บอกถึงปัจจัยหลักที่ส่งผลต่อสมรรถนะของขอบเขตการพยากรณ์ (PICP หรือ NMPIW) ซึ่งอาจใช้ในการปรับคุณสมบัติของขอบเขตการพยากรณ์ให้เหมาะสมได้

$$CWC = NMPIW(1 + \gamma(PICP)e^{-\eta(PICP-\mu)}) \quad (36)$$

$$\gamma = \begin{cases} 0, & PICP \geq \mu \\ 1, & PICP < \mu \end{cases}$$

โดยค่า η เป็นค่ากำหนดโดยผู้ใช้ในการปรับจูนค่า PICP และ NMPIW และค่า μ เป็นค่าความเชื่อมั่นที่กำหนดเพื่อใช้เปรียบเทียบกับขอบเขตการพยากรณ์โดยในวิทยานิพนธ์ฉบับนี้จะกำหนดค่าความเชื่อมั่นของข้อมูลที่ 0.95 หรือ 95% (เท่ากับวิธีการสร้างขอบเขตการพยากรณ์โดยใช้ Bollinger bands) ค่า PICP ที่น้อยกว่า μ (ความน่าจะเป็นที่ข้อมูลเป้าหมายจริงจะอยู่ในขอบเขตการพยากรณ์มีค่าน้อยกว่าที่คาดหวัง)จะทำให้ค่า CWC มีค่าสูงซึ่งอาจบ่งบอกทิศทางในการปรับขอบเขตการพยากรณ์ให้เพิ่มค่า PICP มากขึ้น ในขณะที่หากค่า PICP มีค่ามากกว่าหรือเท่ากับ μ จะหมายถึงความกว้างของขอบเขตการพยากรณ์ (NMPIW) เป็นตัวแปรหลักที่ส่งผลต่อสมรรถนะของขอบเขตการพยากรณ์

2.9 Overfitting และ Underfitting ของแบบจำลอง

การเกิด Overfitting หมายถึงแบบจำลองที่สร้างและเรียนรู้มีความสามารถในการเรียนรู้ข้อมูลที่สูงจน โครงสร้างภายในปรับตัวเข้าใกล้กับข้อมูลที่ใช้สอนมากเกินไปซึ่งส่วนใหญ่จะเกิดขึ้นกับแบบจำลองที่มีความซับซ้อนสูงเกินข้อมูลที่ได้รับ แบบจำลองจะมีสมรรถนะในขั้นตอนสอนที่สูงแต่กลับจะมีสมรรถนะในขั้นตอนทดสอบที่ต่ำเนื่องจากไม่สามารถพยากรณ์ข้อมูลขาเข้าใหม่ที่ไม่เคยเรียนรู้ได้ เป้าหมายของแบบจำลองการเรียนรู้ของเครื่องคือการปรับค่าพารามิเตอร์ภายในเพื่อหารูปแบบทั่วไป (Generalized) ของข้อมูล การเข้าใกล้ข้อมูลในขั้นตอนสอนมากเกินไปจะทำให้รับอิทธิพลของสัญญาณรบกวน (noise) บางจุดแทนที่จะเรียนรู้ความสัมพันธ์ระหว่างข้อมูลขาเข้าและข้อมูลขาออก

ในทางกลับกัน แบบจำลองที่เกิดการ Underfitting คือแบบจำลองที่มีความเรียบง่ายเกินไปเมื่อเทียบกับข้อมูลที่ได้รับ ทำให้ไม่สามารถเรียนรู้แนวโน้มและความสัมพันธ์ของข้อมูลได้ดีพอ แบบจำลองจะมีสมรรถนะที่ต่ำทั้งในกระบวนการเรียนรู้และในกระบวนการทดสอบ

บทที่ 3

แบบจำลองและขอบเขตการพยากรณ์ในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและ อุณหภูมิขดลวดในหม้อแปลง

3.1 การจัดการข้อมูลก่อนสร้างแบบจำลอง

โครงการนำร่องระบบตรวจวัดหม้อแปลงแบบออนไลน์ของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทยได้ติดตั้งเซนเซอร์สำหรับตรวจวัด ส่ง และจัดเก็บค่าของหม้อแปลงไฟฟ้ากำลังขนาด 500 kV ข้อมูลที่ได้จากเซนเซอร์ถูกจัดเก็บในฐานข้อมูลออนไลน์ในฐานข้อมูลของ Structured Query Language (SQL) ในรูปแบบค่าจริงในแต่ละเซนเซอร์ดังรูปที่ 12

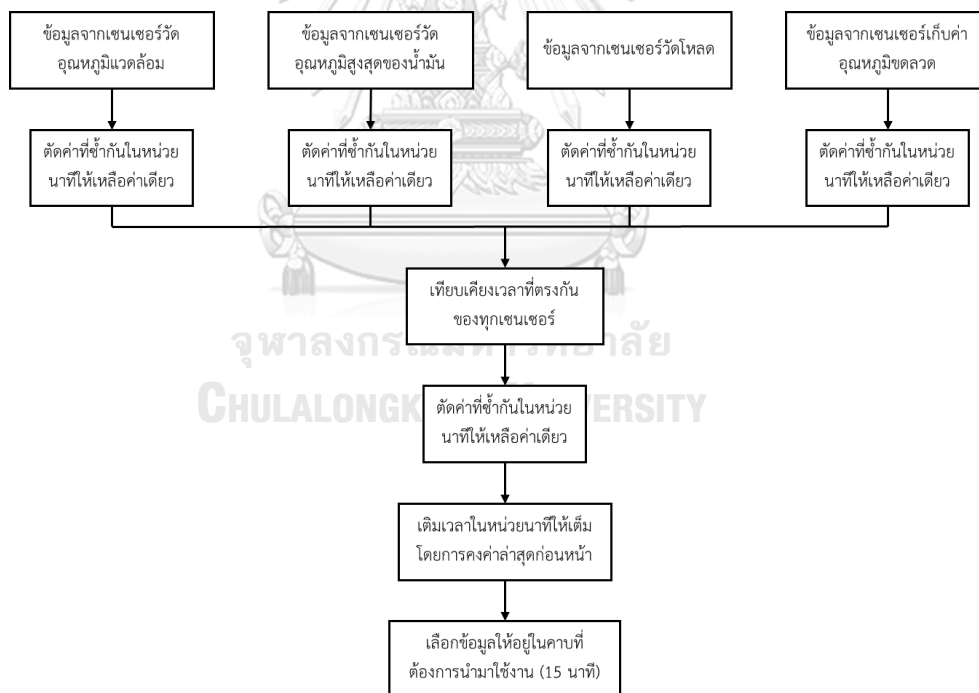
โดยที่	id	คือ เลขย่อที่ใช้เรียกหม้อแปลงในการจัดเก็บ
	Tx_id	คือ รหัสประจำตัวของหม้อแปลง
	phase	คือ เฟสที่อุปกรณ์ติดตั้ง(หม้อแปลงเป็นชนิด single phase)
	meas_id	คือ รหัสประเภทของเซนเซอร์ (AB0001 หมายถึงค่าอุณหภูมิ แวลดล้อม AP0001 หมายถึงค่าอุณหภูมิของน้ำมันด้านบนในหม้อ แปลง GN0001 หมายถึงค่าโวลต์ (MVA) ที่จ่าย)
	meas_time	คือ เวลาที่เซนเซอร์ตรวจวัดข้อมูล
	server_time	คือ เวลาที่ฐานข้อมูลได้รับข้อมูลที่ตรวจวัด
	data	คือ ข้อมูลที่ตรวจวัดได้ อ้างอิงหน่วยตาม meas_id

ข้อมูลที่ตรวจวัดได้จะอ้างอิงเวลาจากฐานข้อมูล (server_time) เป็นหลัก เนื่องจากมีการเชื่อมต่อกับนาฬิกาในระบบ GPS จึงความเที่ยงตรงกว่าเวลาที่บันทึกจากเซนเซอร์ แต่ทั้งนี้ข้อมูลที่จัดเก็บในช่วงของโครงการยังไม่มีข้อกำหนดความถี่ในการเก็บข้อมูลที่ชัดเจน ทำให้ข้อมูลบางส่วนมีการจัดเก็บซ้ำในช่วงนาฬิกาหรือวินาทีเดียวกัน นอกจากนี้ข้อมูลในแต่ละเซนเซอร์อาจมีการเหลื่อมเวลาในการติดตั้ง ดังนั้นจึงมีความจำเป็นในการหาจุดเวลาที่ตรงกันของทุกเซนเซอร์ก่อนนำไปใช้งาน การจัดการข้อมูลก่อนนำไปใช้มีความสำคัญในการเตรียมข้อมูลก่อนที่จะนำไปสร้างแบบจำลองการเรียนรู้ของเครื่อง การทำความสะอาดข้อมูลประกอบด้วยการคัดกรองข้อมูลที่ซ้ำกันในหน่วยนาฬิกาออก การเทียบเคียงข้อมูลที่ได้ในแต่ละเซนเซอร์ที่อยู่ในช่วงเวลาและจุดเวลาเดียวกัน เนื่องจากเซนเซอร์แต่ละตัวมีการวัดในคาบเวลาที่แตกต่างกัน การตัดค่าบางจุดหรือบางช่วงที่มีความผิดปกติ เช่นค่าที่สูงหรือต่ำเกินความเป็นไปได้ (เช่นค่าอุณหภูมิแวลดล้อมที่น้อยเกินไปที่ไม่อาจเกิดได้ในประเทศไทย) ซึ่งอาจหมายถึงการทำงานที่ผิดปกติของเซนเซอร์ และการจัดการข้อมูลให้อยู่ในคาบ

รายชื่อ 15 นาที กระบวนการจัดการข้อมูลก่อนนำไปใช้และตัวอย่างผลหลังการจัดการข้อมูลในวิทยานิพนธ์ฉบับนี้จะแสดงดังรูปที่ 13

	id	egatsn	phase	meas_id	meas_time	server_time	data
0	5	7000000104	B	GN0001	2018-09-01 00:00:07.000	2018-09-01 07:00:07.860	87.3371
1	5	7000000104	B	GN0001	2018-09-01 00:00:07.000	2018-09-01 07:00:07.937	87.3371
2	5	7000000104	B	GN0001	2018-09-01 00:02:09.000	2018-09-01 07:02:09.810	86.9867
3	5	7000000104	B	GN0001	2018-09-01 00:04:11.000	2018-09-01 07:04:11.693	88.3531
4	5	7000000104	B	GN0001	2018-09-01 00:06:13.000	2018-09-01 07:06:13.557	89.3406
5	5	7000000104	B	GN0001	2018-09-01 00:08:15.000	2018-09-01 07:08:15.320	91.7390
6	5	7000000104	B	GN0001	2018-09-01 00:10:17.000	2018-09-01 07:10:17.200	82.4241
7	5	7000000104	B	GN0001	2018-09-01 00:10:17.000	2018-09-01 07:10:17.247	82.4241
8	5	7000000104	B	GN0001	2018-09-01 00:12:19.000	2018-09-01 07:12:19.137	95.8295
9	5	7000000104	B	GN0001	2018-09-01 00:14:20.000	2018-09-01 07:14:21.017	95.7859

รูปที่ 12 ข้อมูลจากเซนเซอร์ที่ถูกจัดเก็บ




(ก) กระบวนการจัดการข้อมูลจากเซนเซอร์ก่อนนำไปใช้
รูปที่ 13 กระบวนการจัดการข้อมูลจากเซนเซอร์ก่อนนำไปใช้
และตัวอย่างผลหลังการจัดการข้อมูล

	Time	Amb	Load	TOT
0	2018-10-05 07:53:00	29.54	108.9150	50.72
1	2018-10-05 08:08:00	29.73	111.2916	51.06
2	2018-10-05 08:23:00	29.98	113.2434	51.20
3	2018-10-05 08:38:00	30.94	114.4917	50.74
4	2018-10-05 08:53:00	31.30	114.3112	50.94
5	2018-10-05 09:08:00	31.80	116.4070	50.66
6	2018-10-05 09:23:00	32.74	116.6077	50.84
7	2018-10-05 09:38:00	33.21	115.8620	53.06
8	2018-10-05 09:53:00	34.15	117.4138	53.22
9	2018-10-05 10:08:00	34.38	115.9443	54.08

(ข) ตัวอย่างผลหลังการจัดการข้อมูลในคาบ 15 นาที
รูปที่ 14 กระบวนการจัดการข้อมูลจากเซนเซอร์ก่อนนำไปใช้
และตัวอย่างผลหลังการจัดการข้อมูล(ต่อ)

ในการสร้างแบบจำลองการเรียนรู้ของเครื่องจะต้องมีการแบ่งข้อมูลบางส่วนเพื่อใช้ในการสอนแบบจำลอง ข้อมูลส่วนดังกล่าวจะเป็นข้อมูลที่แบบจำลองรับรู้ทั้งข้อมูลขาเข้าและข้อมูลขาออกเพื่อใช้ในการปรับพารามิเตอร์ภายในของตนเองซึ่งการมีข้อมูลสำหรับสอนจำนวนมากจะทำให้แบบจำลองสามารถเรียนรู้ได้มากขึ้นด้วย อีกส่วนหนึ่งของข้อมูลที่ถูกแบ่งจะเก็บไว้เป็นข้อมูลสำหรับทดสอบสมรรถนะของแบบจำลองว่าสามารถพยากรณ์ข้อมูลขาออกจากข้อมูลขาเข้าชุดใหม่ที่ไม่ได้รับการสอน(แต่มีความใกล้เคียงกับกับข้อมูลที่ใช้สอน) ได้ใกล้เคียงกับค่าเป้าหมายได้มากน้อยเพียงใด ดังนั้นข้อมูลที่ได้จากกระบวนการในรูปที่ 13(ก.) จะถูกนำมาแบ่งเป็นสองส่วน ได้แก่ ข้อมูลสำหรับการสอนแบบจำลอง และข้อมูลสำหรับการทดสอบแบบจำลอง โดยจะแบ่งออกเป็นอัตราส่วน 90:10 และเนื่องจากข้อมูลที่ใช้เป็นข้อมูลที่มีความต่อเนื่องทางเวลา การแบ่งส่วนข้อมูลจะไม่มีการสลับ (Shuffle) ตำแหน่งของข้อมูลเพื่อป้องกันไม่ให้เกิดการเปลี่ยนแปลงทางความหมายของข้อมูล จากนั้นก่อนนำไปใช้ในการสร้างแบบจำลองจะทำการปรับมาตรฐานส่วนของข้อมูลซึ่งสามารถทำได้หลายวิธี เช่น ในข้อมูลที่มีค่าที่อยู่ระหว่างขอบเขตของสองค่า (ข้อมูลแต่ละชุดมีค่าต่ำสุด สูงสุด และค่าที่อยู่ระหว่างค่าดังกล่าว) สามารถใช้การปรับมาตรฐานโดยใช้ค่าต่ำสุด-สูงสุด (Min-Max scaler) นำมาใช้เพื่อแปลงค่าจริงของแต่ละฟีเจอร์ให้อยู่ในขอบเขตเดียวกันที่กำหนด (เช่น $[0,1]$ หรือ $[-1,1]$) เพื่อให้สามารถเทียบค่าในแต่ละช่วงเวลาด้วยกันและกำจัดหน่วยของฟีเจอร์ ในวิทยานิพนธ์ฉบับนี้จะใช้วิธีการปรับมาตรฐานโดยใช้ค่าต่ำสุด-สูงสุดให้อยู่ในขอบเขต $[-1,1]$ ก่อนนำไปใช้งาน กระบวนการในการนำข้อมูลมาสร้าง ทดสอบสมรรถนะแบบจำลองในการพยากรณ์

สถานการณ์ใหม่ การสร้างขอบเขตข้อมูล โดยการใช้ Bollinger bands การหาค่าอายุการใช้งานที่สูญเสีย และการหาค่าอายุการใช้งานที่สูญเสียที่มากที่สุดที่เป็นไปได้ แสดงในรูปที่ 14



รูปที่ 15 กระบวนการปรับมาตราส่วนข้อมูล การสอนและทดสอบแบบจำลอง การใช้ผลจากแบบจำลองในการสร้างขอบเขตข้อมูลและหาอายุการใช้งานที่สูญเสียของหม้อแปลง

หลังจากแต่ละแบบจำลองได้เรียนรู้จากข้อมูลสำหรับสอน (Train data) เพื่อหาผลลัพธ์จากข้อมูลสำหรับทดสอบ (Test Data) แล้ว ในการบ่งชี้สมรรถนะของแต่ละแบบจำลองในการหาผลลัพธ์จากข้อมูลใหม่จะใช้ค่า R-Square (R^2), Mean Square Error (MSE), Explained Variance

Score (EVS) และ Mean Absolute Error (MAE) ในการบอกสมรรถนะของแต่ละแบบจำลอง โดยมีนิยามดังนี้

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (37)$$

$$MSE = \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n} \quad (38)$$

$$EVS = 1 - \frac{Var(y - \hat{y})}{Var(y)} \quad (39)$$

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (40)$$

โดยที่

y, y_i	คือ ผลลัพธ์จากข้อมูลทดสอบ
\hat{y}, \hat{y}_i	คือ ผลลัพธ์ที่ได้จากแบบจำลอง
Var	คือ ค่ากำลังสองของค่าเบี่ยงเบนมาตรฐานของข้อมูล
\bar{y}	คือ ค่าเฉลี่ยของข้อมูลทดสอบ
n	คือ จำนวนของข้อมูลที่นำมาคำนวณ

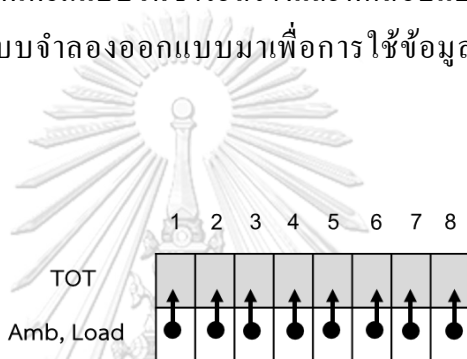
ในการสร้างและเปรียบเทียบสมรรถนะของแบบจำลอง จะให้ข้อมูลหม้อแปลง 2 เครื่อง ราย 15 นาที จำนวน 5334 ข้อมูล (ประมาณ 55.5 วัน) และ จำนวน 6187 ข้อมูล (ประมาณ 64.4 วัน) ชนิด เฟสเดี่ยว ระดับแรงดัน 525/242-22 kV พิกัดกำลัง 250 MVA และมีชนิด Insulation class ของ ฉนวนกระดาษที่ 120 ใช้งานในโรงไฟฟ้าชนิดความร้อนร่วมที่ใช้ก๊าซธรรมชาติเป็นเชื้อเพลิง โดยจะทดสอบการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลงโดยใช้ค่าอุณหภูมิแวดล้อมและโหลดของหม้อแปลงเป็นตัวแปรต้น ทั้งนี้ในแบบจำลองการเรียนรู้ของเครื่อง โดยใช้โครงข่ายประสาทเทียม ป่าแบบสุ่ม และการถดถอยแบบการส่งเสริมเกรเดียนต์จะทดลอง แบ่งเป็น 2 กรณีดังต่อไปนี้ ซึ่งจะแสดงตัวอย่างในรูปที่ 15

1. การพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงแบบใช้ข้อมูลจุดเวลา (point data) ซึ่งจะใช้ค่าอุณหภูมิแวดล้อมและโหลดของหม้อแปลง ณ ช่วงขณะหนึ่งใน


การเรียนรู้และพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงที่ช่วงขณะนั้นเท่านั้น

2. การพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงแบบใช้ข้อมูลเวลาก่อนหน้า (past data) ซึ่งจะใช้ค่าอุณหภูมิแวดล้อมและโหลดของหม้อแปลงย้อนหลังทั้งหมด 24 จุด จุดละ 15 นาที รวม 6 ชั่วโมงในการเรียนรู้และพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลงที่ขณะนั้น

แบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำจะสร้างและทดสอบแบบจำลองในกรณีนี้ 2 เท่านั้น เนื่องจากโครงสร้างของแบบจำลองออกแบบมาเพื่อการใช้ข้อมูลในอดีตในการเรียนรู้ของแบบจำลอง



(ก.) การพยากรณ์อุณหภูมิของน้ำมันด้านบนในหม้อแปลงโดยใช้ข้อมูลแบบจุด




(ข.) การพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนในหม้อแปลงแบบใช้ข้อมูลเวลาก่อนหน้า 24 จุด

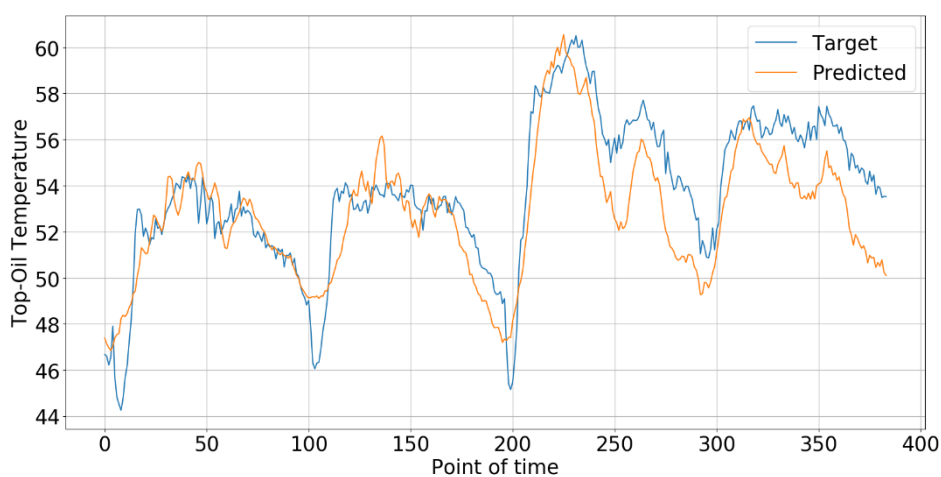
รูปที่ 16 รูปแบบการพยากรณ์อุณหภูมิของน้ำมันด้านบนในหม้อแปลงโดยใช้ข้อมูลแบบจุดและแบบใช้ข้อมูลเวลาก่อนหน้า 24 จุด

ความสัมพันธ์ระหว่างข้อมูลขาเข้าและข้อมูลขาออก

ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดของหม้อแปลงแปรผันตามค่าอุณหภูมิแวดล้อมและค่าโหลดที่หม้อแปลงจ่าย แต่ทั้งนี้ความสัมพันธ์ดังกล่าวอาจไม่มีความเป็นเชิงเส้น รูปที่ 16 แสดงถึงความสัมพันธ์ของข้อมูลขาเข้า (อุณหภูมิแวดล้อมและโหลด) ต่อค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลงซึ่งมีแนวโน้มของข้อมูลไปในทางเดียวกันแต่มีการกระจายของข้อมูลที่สูง



รูปที่ 17 ความสัมพันธ์ของค่าอุณหภูมิแวดล้อมและค่าโหลดที่ส่งผลต่อค่าอุณหภูมิน้ำมันด้านบน



CHULALONGKORN UNIVERSITY

รูปที่ 18 ผลการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนในหม้อแปลง

การทดลองสร้างแบบจำลองโดยใช้การถดถอยเชิงเส้น (Linear Regression) สองตัวแปรในการเรียนรู้และพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนของหม้อแปลงโดยใช้ข้อมูลแบบเวลาก่อนหน้าโดยมีผลลัพธ์การพยากรณ์ดังรูปที่ 17 และให้ผลค่าสมรรถนะดังนี้

- ค่า R-Square ในขั้นตอนสอนมีค่าเท่ากับ 0.6563
- ค่า R-Square ในขั้นตอนทดสอบมีค่าเท่ากับ 0.6667
- ค่า MSE ในขั้นตอนทดสอบเท่ากับ 4.592
- ค่า MSE ในขั้นตอนทดสอบเท่ากับ 3.425


แบบจำลองการถดถอยเชิงเส้นให้ผลสมรรถนะการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนที่ค่อนข้างต่ำ และเกิดเหตุการณ์ Underfitting (ค่า R-Square ในขั้นตอนทดสอบสูงกว่าในขั้นตอนเรียนรู้ ในขณะที่ MSE ในขั้นตอนทดสอบน้อยกว่าขั้นตอนเรียนรู้) นอกจากนี้แบบจำลองแบบเชิงเส้นเป็นแบบจำลองที่ไม่สามารถปรับปรุงคุณสมบัติของแบบจำลองเพื่อเพิ่มสมรรถนะในการพยากรณ์ข้อมูลที่ไม่เป็นเชิงเส้นได้ ดังนั้นแบบจำลองการเรียนรู้ของเครื่องที่มีคุณสมบัติในการสามารถปรับค่าคุณสมบัติภายในจึงมีความเหมาะสมในการสร้างแบบจำลองเพื่อเรียนรู้ความสัมพันธ์ของข้อมูลขาเข้าและข้อมูลขาออกได้ดีกว่า

3.2 แบบจำลองการเรียนรู้ของเครื่องโดยใช้โครงข่ายประสาทเทียม


แบบจำลองการเรียนรู้ของเครื่องโดยใช้โครงข่ายประสาทเทียมที่ใช้ในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลงถูกปรับค่าให้เหมาะสมเพื่อให้สามารถพยากรณ์ได้โดยมีสมรรถนะที่ดี ข้อมูลของหม้อแปลงจะถูกนำมาแบ่งส่วนสำหรับสอนและทดสอบในอัตราส่วน 90:10 และจึงทำการปรับมาตราส่วนให้อยู่ในช่วง $[-1,1]$ และจะทำการแปลงข้อมูลกลับให้อยู่ในรูปค่าจริงหลังทำการสอนและพยากรณ์แล้ว

ในการพยากรณ์อุณหภูมิของน้ำมันด้านบนในหม้อแปลงโดยใช้ข้อมูลแบบจุด ข้อมูลสำหรับสอนจะถูกนำมาผ่านแบบจำลองโครงข่ายประสาทเทียมโดยในแต่ละครั้งของการเรียนรู้จะมีตัวแปรต้นที่เป็น feature ได้แก่ ค่าอุณหภูมิแวดล้อม และค่าโหลดจำนวนละ 1 ค่าเพื่อเรียนรู้ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง 1 ค่า แบบจำลองมีจำนวนชั้นซ่อน 200 ชั้น ใช้ฟังก์ชันกระตุ้นชนิด Rectify linear unit (ReLU) และใช้การปรับค่าถ่วงน้ำหนักภายในด้วยวิธี Adaptive moment estimation (ADAM) การสอนแบบจำลองจะหยุดเมื่อค่า MSE ซึ่งเป็นฟังก์ชันสูญเสียของแบบจำลองเริ่มมีการเปลี่ยนแปลงที่น้อย แตกต่างจากค่าก่อนหน้าไม่เกิน 10^{-8}

รูปที่ 18-19 แสดงผลการทดสอบการพยากรณ์อุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลงโดยใช้ข้อมูลแบบจุดของหม้อแปลงทั้ง 2 ตัว





(a)




CHULALONGKORN UNIVERSITY (b)

รูปที่ 19 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลงโดย
ใช้ข้อมูลแบบจุดของหม้อแปลง A ด้วยแบบจำลองโครงข่ายประสาทเทียม





(a)




CHULALONGKORN UNIVERSITY (b)

รูปที่ 20 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลงโดย
ใช้ข้อมูลแบบจุดของหม้อแปลง B ด้วยแบบจำลองโครงข่ายประสาทเทียม

ในการพยากรณ์อุณหภูมิของน้ำมันด้านบนในหม้อแปลงโดยใช้ข้อมูลแบบเวลาก่อนหน้า
โครงสร้างของแบบจำลองจะใช้โครงสร้างเหมือนกับการใช้ข้อมูลแบบจุดแต่จะเปลี่ยนรูปแบบ
ข้อมูลที่ใช้ในการสอนและทดสอบแบบจำลอง ผลการพยากรณ์แสดงในรูปที่ 20-21




(a)

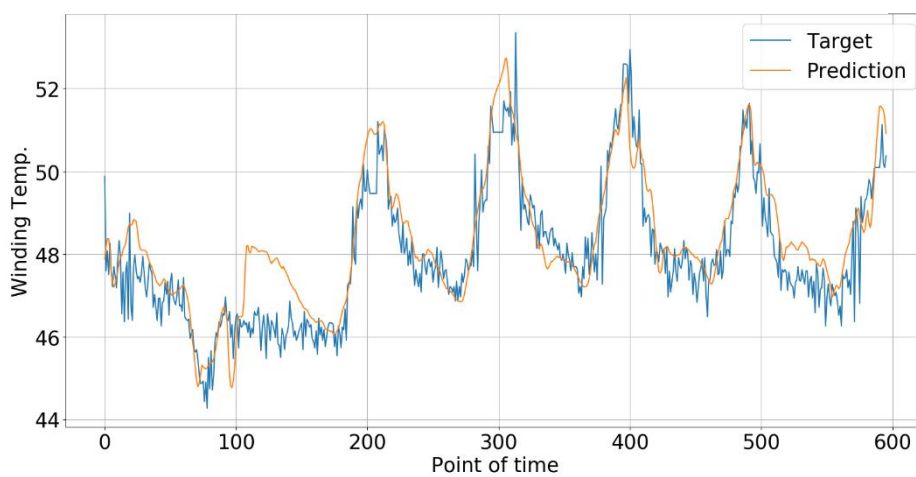


CHULALONGKORN UNIVERSITY

รูปที่ 21 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลงโดย
ใช้ข้อมูลแบบเวลาดำเนินการหน้าของหม้อแปลง A ด้วยแบบจำลองโครงข่ายประสาทเทียม



(a)



CHULALONGKORN UNIVERSITY (b)


รูปที่ 22 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลงโดย
ใช้ข้อมูลแบบเวลาก่อนหน้าของหม้อแปลง B ด้วยแบบจำลองโครงข่ายประสาทเทียม

ตารางที่ 4 ค่าสมรรถนะของแบบจำลองโครงข่ายประสาทเทียมในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง A และ B


Performance indicator	Transformer A			
	Top-Oil Temperature		Winding Temperature	
	ข้อมูลจุดเวลา	ข้อมูลเวลาก่อนหน้า	ข้อมูลจุดเวลา	ข้อมูลเวลาก่อนหน้า
R2 train	0.4752	0.8823	0.7374	0.9204
R2 test	0.3639	0.7819	0.7033	0.8271
MSE train	7.0031	1.5723	5.2706	1.5932
MSE test	7.2805	2.2417	5.1948	2.6251
EVS train	0.4753	0.8873	0.7383	0.9255
EVS test	0.4047	0.7963	0.7295	0.8859
MAE train	2.1276	0.9643	1.8534	0.9968
MAE test	2.1513	1.2170	1.8158	1.3518
Runtime(s)	10.4734		9.9404	
	Transformer B			
R2 train	0.7372	0.7948	0.6399	0.7638
R2 test	0.7834	0.7973	0.7318	0.7725
MSE train	0.6522	0.5054	1.3311	0.8696
MSE test	0.5168	0.4619	0.7513	0.6248
EVS train	0.7679	0.8606	0.6686	0.8041
EVS test	0.7959	0.8519	0.7449	0.8172
MAE train	0.6288	0.5667	0.9077	0.7311
MAE test	0.5768	0.5397	0.6862	0.6059
Runtime(s)	14.8550		22.4395	

ตารางที่ 5 แสดงการเปรียบเทียบผลการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดระหว่างการใช้อินพุตแบบจุดและแบบเวลาก่อนหน้า พบว่า ในส่วนของค่า R2 และ EVS หม้อแปลงทั้งสองเครื่องมีค่า R2 ที่สูงขึ้นเมื่อใช้อินพุตแบบเวลาก่อนหน้าและมีค่า MSE และ MAE ที่ลดลงทั้งในขั้นตอนสอนและทดสอบ การสร้างแบบจำลองโดยใช้อินพุตแบบเวลาก่อนหน้าจึงทำให้สามารถ

สร้างแบบจำลองที่มีสมรรถนะในการพยากรณ์ที่สูงกว่าการใช้ข้อมูลแบบจุดได้ ดังนั้นในการสร้างขอบเขตการพยากรณ์ดังรูปที่ 22-23 ของข้อมูลดังกล่าวจะสร้างโดยใช้ผลการพยากรณ์จากข้อมูลแบบเวลาก่อนหน้าเป็นหลัก




(a)




(b)

รูปที่ 23 ผลและขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลง A โดยใช้ข้อมูลแบบเวลาก่อนหน้าและ Bollinger bands ในแบบจำลอง ANN



(a)




(b)

รูปที่ 24 ผลและขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลง B โดยใช้ข้อมูลแบบเวลาดำเนินการและ Bollinger bands ในแบบจำลอง ANN


3.3 แบบจำลองการเรียนรู้ของเครื่องโดยใช้ต้นไม้การตัดสินใจแบบประกอบ(ป่าแบบสุ่ม)

แบบจำลองการเรียนรู้ของเครื่องโดยใช้ป่าแบบสุ่มที่ใช้ในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง ข้อมูลของหม้อแปลงจะถูกนำมาแบ่งส่วนสำหรับสอนและทดสอบในอัตราส่วน 90:10 โดยไม่จำเป็นต้องปรับมาตราส่วนของข้อมูล

ในการพยากรณ์อุณหภูมิของน้ำมันด้านบนในหม้อแปลงโดยใช้ข้อมูลแบบจุด ข้อมูลสำหรับสอนจะถูกนำมาผ่านแบบจำลองป่าแบบสุ่ม โดยแบ่งเป็นการสร้างและทดสอบโดยใช้ข้อมูลแบบจุดเวลาและแบบเวลาก่อนหน้าเช่นเดียวกับในการทดสอบแบบจำลองโครงข่ายประสาทเทียม แบบจำลองป่าแบบสุ่มที่ใช้ในทั้งสองกรณีจะมีค่าความลึกสูงสุดของต้นไม้ (maximum tree depth) ที่ไม่เกิน 35 ชั้นและมีค่าการสุ่มทำซ้ำของต้นไม้ (n-estimator) ทั้งหมด 100 รอบ ค่าความลึกสูงสุดของต้นไม้เป็นค่าที่กำหนดความสามารถในการเรียนรู้ของแบบจำลองต้นไม้การตัดสินใจ ซึ่งหากมีค่ามากเกินไปอาจทำให้ข้อมูลเกิดการ overfitting ส่งผลให้ข้อมูลสามารถเรียนรู้ในกระบวนการสอนได้ดีจนเกินไปการพยากรณ์ข้อมูลใหม่จะทำได้ด้วยสมรรถนะที่น้อย เทคนิคการใช้ป่าแบบสุ่มจะช่วยลดปัญหาการเกิด Overfitting ในต้นไม้ตัดสินใจ ทำให้สามารถสร้างแบบจำลองที่มีสมรรถนะที่ดีขึ้นได้ รูปที่ 24-27 แสดงผลการใช้แบบจำลองป่าแบบสุ่มในการพยากรณ์ค่าอุณหภูมิ น้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลง โดยใช้ข้อมูลแบบจุดและข้อมูลแบบเวลาก่อนหน้าของหม้อแปลง




(a)




CHULALONGKORN UNIVERSITY

รูปที่ 25 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวดในหม้อแปลง (b)

โดยใช้ข้อมูลแบบจุดของหม้อแปลง A ในแบบจำลองป่าแบบสุ่ม




(a)




CHULALONGKORN UNIVERSITY (b)

รูปที่ 26 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวดในหม้อแปลง (b)

โดยใช้ข้อมูลแบบจุดของหม้อแปลง B ในแบบจำลองป่าแบบสุ่ม




(a)




CHULALONGKORN UNIVERSITY

รูปที่ 27 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวดในหม้อแปลง (b) โดยใช้ข้อมูลแบบเวลาก่อนหน้าของหม้อแปลง A โดยแบบจำลองป่าแบบสุ่ม



(a)



CHULALONGKORN UNIVERSITY


(b)

รูปที่ 28 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวดในหม้อแปลง (b) โดยใช้ข้อมูลแบบเวลาก่อนหน้าของหม้อแปลง B โดยแบบจำลองป่าแบบสุ่ม


ตารางที่ 5 ค่าสมรรถนะของแบบจำลองป่าแบบสุ่มในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบน
ในหม้อแปลง A และ B

Performance indicator	Transformer A			
	Top-Oil Temperature		Winding Temperature	
	ข้อมูลจุดเวลา	ข้อมูลเวลา ก่อนหน้า	ข้อมูลจุดเวลา	ข้อมูลเวลา ก่อนหน้า
R2 train	0.8738	0.9999	0.9355	0.9999
R2 test	0.2776	0.7611	0.6734	0.8635
MSE train	1.6840	0.0008	1.2945	0.0014
MSE test	8.2679	2.4553	5.7189	2.0723
EVS train	0.8738	0.9999	0.9355	0.9999
EVS test	0.3155	0.7979	0.6951	0.8863
MAE train	0.9604	0.0243	0.8488	0.0318
MAE test	2.2957	1.3122	1.9075	1.2305
Runtime(s)	6.5315		7.1720	
	Transformer B			
R2 train	0.7842	0.9999	0.6891	0.9999
R2 test	0.7850	0.8520	0.7246	0.8140
MSE train	0.5356	0.0004	1.1495	0.0005
MSE test	0.5129	0.3373	0.7715	0.5108
EVS train	0.7842	0.9999	0.6891	0.9999
EVS test	0.7880	0.8566	0.7306	0.8140
MAE train	0.5765	0.0160	0.8504	0.0180
MAE test	0.5830	0.4591	0.6941	0.5488
Runtime(s)	6.7652		6.9231	

แบบจำลองป่าแบบสุ่มให้ผลไปในทำนองเดียวกันกับแบบจำลองโครงข่ายประสาทเทียมทั้งในการพยากรณ์อุณหภูมิของน้ำมันด้านบนและอุณหภูมิของขดลวด ในส่วนของค่า R2 และ EVS หม้อแปลงทั้งสองเครื่องมีค่า R2 ที่สูงขึ้นเมื่อใช้ข้อมูลแบบเวลาก่อนหน้าและมีค่า MSE และ MAE ที่ลดลงทั้งในขั้นตอนสอนและทดสอบ การสร้างแบบจำลองโดยใช้ข้อมูลแบบเวลาก่อนหน้าจึงทำให้สามารถสร้างแบบจำลองที่มีสมรรถนะในการพยากรณ์ที่สูงกว่าการใช้ข้อมูลแบบจุดได้แก่และเหมาะสมในการนำผลที่พยากรณ์ได้มาสร้างขอบเขตการพยากรณ์ดังรูปที่ 28-29




(a)




(b)

รูปที่ 29 ผลและขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวดในหม้อแปลง (b) โดยใช้ข้อมูลก่อนหน้าและ Bollinger bands ของหม้อแปลง A ในแบบจำลองป่าแบบสุ่ม



(a)




(b)

รูปที่ 30 ผลและขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลง B โดยใช้ข้อมูลก่อนหน้าและ *Bollinger bands* ในแบบจำลองป่าแบบสุ่ม


3.4 แบบจำลองการเรียนรู้ของเครื่องที่ใช้โครงข่ายประสาทเทียมแบบวนซ้ำ

แบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำชนิด LSTM จะใช้ข้อมูลแบบเวลาก่อนหน้า 24 จุด (6 ชั่วโมง) ในการสร้างและทดสอบแบบจำลอง โดยข้อมูลจะถูกแบ่งเป็นข้อมูลสำหรับสอนและทดสอบในอัตราส่วน 90:10 แล้วจึงทำการปรับมาตราส่วนข้อมูลให้อยู่ในช่วง $[-1,1]$ ในการสร้างแบบจำลองจะใช้ Tensorflow และ Keras library ในภาษาไพทอน โดยเริ่มจากการสร้างแบบจำลองเชิงลำดับ (Sequential model) ที่มีการซ้อนทับกันของแต่ละชั้น (layer) ของแบบจำลอง LSTM โดยกำหนดจำนวนรอบในการสอนที่ 150 รอบ แต่ละรอบใช้ข้อมูลที่ละ 100 ข้อมูลในการปรับค่าถ่วงน้ำหนัก (batch size = 100) การกำหนด batch size เท่ากับ 100 หมายถึงในข้อมูลจำนวน

ทั้งหมด 5334 ข้อมูลของหม้อแปลง A จะทำการปรับค่าถ่วงน้ำหนักภายในทุก 100 ข้อมูล รวมทั้งสิ้น 54 ครั้งต่อ 1 รอบการสอน แบบจำลองจะใช้ฟังก์ชันกระตุ้นชนิด Rectify linear unit (ReLU) และใช้การปรับค่าถ่วงน้ำหนักภายในด้วยวิธี Adaptive moment estimation (ADAM) เช่นเดียวกับแบบจำลองโครงข่ายประสาทเทียม เมื่อทำการสอนแบบจำลองและพยากรณ์ข้อมูลใหม่แล้วจะนำข้อมูลที่ได้ออกมาแปลงกลับให้เป็นค่าจริง รูปที่ 30-31 แสดงผลการใช้แบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำชนิด LSTM ในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในหม้อแปลงโดยใช้ข้อมูลแบบเวลาก่อนหน้าของหม้อแปลง A และ B


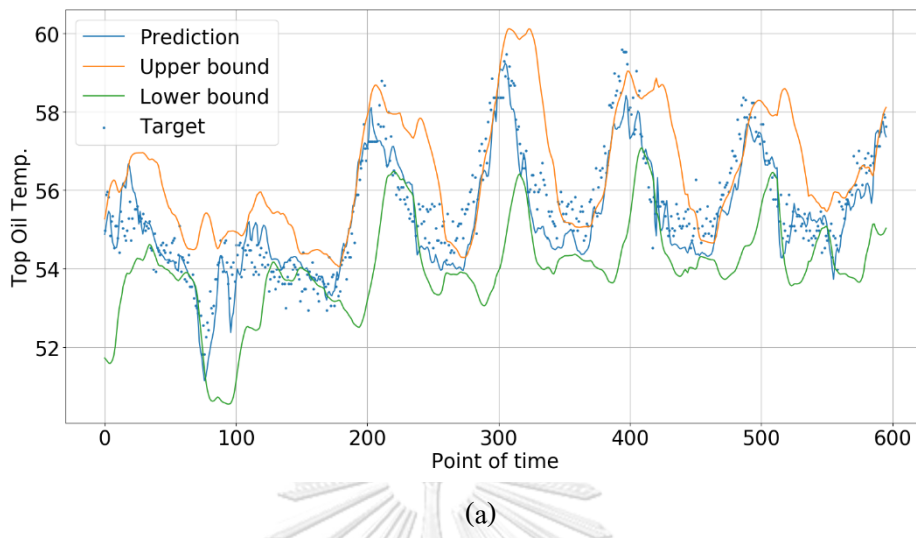


(a)



(b)

รูปที่ 31 ผลและขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในหม้อแปลง A โดยใช้ข้อมูลแบบเวลาก่อนหน้าด้วยแบบจำลอง LSTM




รูปที่ 32 ผลและขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด (b) ในมือแปลง A โดยใช้ข้อมูลแบบเวลาก่อนหน้าด้วยแบบจำลอง LSTM

ตารางที่ 6 ค่าสมรรถนะของแบบจำลองโครงข่ายประสาทเทียมแบบวนซ้ำชนิด LSTM ในการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง A และ B


Performance indicator	Transformer A	Transformer B
	ข้อมูลเวลา ก่อนหน้า	ข้อมูลเวลา ก่อนหน้า
	การพยากรณ์อุณหภูมิของน้ำมันด้านบน	
R2 train	0.9919	0.9234
R2 test	0.6223	0.7753
MSE train	0.1076	0.1886
MSE test	3.8843	0.5125
EVS train	0.9920	0.9323
EVS test	0.6894	0.8021
MAE train	0.2525	0.3381
MAE test	1.6016	0.5880
Runtime(s)	2513.6839	3821.0318
	การพยากรณ์อุณหภูมิขดลวด	
R2 train	0.9900	0.8776
R2 test	0.7381	0.6978
MSE train	0.1995	0.4511
MSE test	3.9839	0.8311
EVS train	0.9900	0.8796
EVS test	0.8102	0.7033
MAE train	0.3407	0.5156
MAE test	1.5640	0.7113
Runtime(s)	2323.8100	4271.8184

3.5 แบบจำลองการเรียนรู้ของเครื่องที่ใช้ต้นไม้การถดถอยที่เคลื่อนลงตามความชัน (Gradient Boosting Regression Tree model-GBR)

แบบจำลองต้นไม้การถดถอยที่เคลื่อนลงตามความชันที่ใช้พยากรณ์ค่าอุณหภูมิน้ำมัน-ด้านบนและอุณหภูมิขดลวดของหม้อแปลงจะพยากรณ์ทั้งในกรณีใช้ข้อมูลแบบจุดและข้อมูลแบบเวลาก่อนหน้าโดยเริ่มจากการสร้างแบบจำลองต้นไม้การตัดสินใจขั้นต้นขึ้นมา 1 แบบจำลอง จากนั้นจึงใช้ค่าลบของเกรเดียนต์ของฟังก์ชันสูญเสียชนิดควอนไทล์ที่ค่าควอนไทล์เท่ากับ 0.5 เพื่อสร้างแบบจำลองต้นไม้การตัดสินใจเพิ่มเติมในการพยากรณ์ให้ใกล้เคียงกับค่าจริงมากขึ้น จากการทดสอบคุณสมบัติของแบบจำลองจะประกอบด้วยความลึกสูงสุดของต้นไม้เท่ากับ 4 ชั้น โดยใช้การสร้างแบบจำลองเพิ่มเติม 3000 รอบ และในการสร้างขอบเขตการพยากรณ์จะใช้ค่าควอนไทล์ที่ 0.025 และ 0.975 ในการสร้างขอบเขตบนและขอบเขตล่างตามลำดับ ผลการพยากรณ์ของแบบจำลองในหม้อแปลง A และ B เป็นดังรูปที่ 32




จุฬาลงกรณ์มหาวิทยาลัย




(b)

รูปที่ 33 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวดในหม้อแปลง (b) โดยใช้ข้อมูลแบบจุดเวลาของหม้อแปลง A ในแบบจำลองต้นไม้การถดถอยที่เคลื่อนลงตามความชัน




(a)




CHULALONGKORN UNIVERSITY

(b)

รูปที่ 34 ผลการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวดในหม้อแปลง (b) โดยใช้ข้อมูลแบบจุดเวลาของหม้อแปลง B ในแบบจำลองต้นไม้การตัดสินใจที่เคลื่อนลงตามความชัน





(a)



CHULALONGKORN UNIVERSITY

รูปที่ 35 ผลและขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด
ในหม้อแปลง (b) โดยใช้ข้อมูลแบบเวลาดำเนินหน้าของหม้อแปลง A
ด้วยแบบจำลองต้นไม้การตัดสินใจที่เคลื่อนลงตามความชัน



รูปที่ 36 ผลการขอบเขตการพยากรณ์อุณหภูมิของน้ำมันด้านบน (a) และอุณหภูมิขดลวด
ในหม้อแปลง (b) โดยใช้ข้อมูลแบบเวลาก่อนหน้าของหม้อแปลง B
โดยแบบจำลองต้นไม้การถดถอยที่เคลื่อนลงตามความชัน

ตารางที่ 7 ค่าสมรรถนะของแบบจำลองต้นไม้การถดถอยที่เคลื่อนลงตามความชันในการพยากรณ์
ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง A และ B

Performance indicator	Transformer A			
	Top-Oil Temperature		Winding Temperature	
	ข้อมูลจุดเวลา	ข้อมูลเวลาก่อนหน้า	ข้อมูลจุดเวลา	ข้อมูลเวลาก่อนหน้า
R2 train	0.2793	0.7459	0.7409	0.9721
R2 test	-0.0417	0.7349	0.6858	0.8355
MSE train	5.2313	2.4317	4.0058	0.5158
MSE test	7.3643	2.2275	4.9116	2.4417
EVS train	0.2793	0.7482	0.7409	0.9721
EVS test	0.0281	0.7740	0.7108	0.8792
MAE train	1.7949	1.0891	1.5797	0.5613
MAE test	2.1529	1.2529	1.7462	1.3032
Runtime(s)	73.5074		79.5069	
	Transformer B			
R2 train	0.7213	0.8547	0.5444	0.8852
R2 test	0.7177	0.7915	0.6914	0.8018
MSE train	0.5390	0.2876	1.1526	0.3549
MSE test	0.5024	0.3333	0.7465	0.5022
EVS train	0.7213	0.8547	0.5444	0.8852
EVS test	0.7219	0.7951	0.6985	0.8021
MAE train	0.5788	0.4007	0.8518	0.4616
MAE test	0.5792	0.4527	0.6827	0.5385
Runtime(s)	84.1221		86.7741	

จากค่าสมรรถนะของแบบจำลองการเรียนรู้ของเครื่องทั้ง 4 รูปแบบในตารางที่ 5-8 พบว่า การใช้ข้อมูลแบบเวลาก่อนหน้าให้สมรรถนะที่สูงกว่าการใช้ข้อมูลแบบจุดเวลาในทุกแบบจำลอง

ทั้งนี้หากพิจารณาค่าที่ใช้บ่งชี้สมรรถนะของแต่ละแบบจำลอง ค่า R2 และ EVS จะบ่งบอกถึงความสมรูประหว่างค่าเป้าหมายและค่าที่พยากรณ์ได้ ในขณะที่ค่า MSE และ MAE จะบ่งบอกถึงค่าความคลาดเคลื่อนสะสมโดยรวมของค่าที่พยากรณ์ได้เทียบกับค่าเป้าหมาย ดังนั้นในการประยุกต์ใช้ค่าที่พยากรณ์ได้จากแบบจำลองการเรียนรู้ของเครื่องในการหาอายุการใช้งานที่สูญเสียของหม้อแปลง ในช่วงเวลาที่กำหนดจะให้ความสำคัญกับค่า MSE และ MAE เป็นหลักเนื่องจากการคำนวณอายุการใช้งานที่สูญเสียอยู่ในลักษณะการสะสมของข้อมูล (Cumulative) การเปรียบเทียบผลสมรรถนะของแต่ละแบบจำลองมีดังนี้

ตารางที่ 8 สมรรถนะของแบบจำลองการเรียนรู้ของเครื่อง

Indicator	Top-Oil Temp. Transformer A				Top-Oil Temp. Transformer B			
	LSTM	ANN	RF	GBR	LSTM	ANN	RF	GBR
R2 inner	0.9919	0.8823	0.9999	0.7459	0.9234	0.7948	0.9999	0.8547
R2 predict	0.6223	0.7819	0.7611	0.7349	0.7753	0.7973	0.8520	0.7915
MSE inner	0.1076	1.5723	0.0008	2.4317	0.1886	0.5054	0.0004	0.2876
MSE predict	3.8843	2.2417	2.4553	2.2275	0.5125	0.4619	0.3373	0.3333
EVS inner	0.9920	0.8873	0.9999	0.7482	0.9323	0.8606	0.9999	0.8547
EVS predict	0.6894	0.7963	0.7979	0.7740	0.8021	0.8519	0.8566	0.7951
MAE inner	0.2525	0.9643	0.0243	1.0891	0.3381	0.5667	0.0160	0.4007
MAE predict	1.6016	1.2170	1.3122	1.2529	0.5880	0.5397	0.4591	0.4527
Indicator	Winding Temp. Transformer A				Winding Temp. Transformer B			
	LSTM	ANN	RF	GBR	LSTM	ANN	RF	GBR
R2 inner	0.9900	0.9204	0.9999	0.9721	0.8776	0.7638	0.9999	0.8852
R2 predict	0.7381	0.8271	0.8635	0.8355	0.6978	0.7725	0.8140	0.8018
MSE inner	0.1995	1.5932	0.0014	0.5158	0.4511	0.8696	0.0005	0.3549
MSE predict	3.9839	2.6251	2.0723	2.4417	0.8311	0.6248	0.5108	0.5022
EVS inner	0.9900	0.9255	0.9999	0.9721	0.8796	0.8041	0.9999	0.8852
EVS predict	0.8102	0.8859	0.8863	0.8792	0.7033	0.8172	0.8140	0.8021
MAE inner	0.3407	0.9968	0.0318	0.5613	0.5156	0.7311	0.0180	0.4616
MAE predict	1.5640	1.3518	1.2305	1.3032	0.7113	0.6059	0.5488	0.5385

หากพิจารณาผลสมรรถนะของแบบจำลองทางด้านความสมบูรณ์ของแบบจำลองโดยใช้ค่า R-Square และ EVS และทางด้านความคลาดเคลื่อนสะสมของแบบจำลองโดยใช้ค่า MSE และ MAE สามารถสรุปผลได้ดังนี้

ตารางที่ 9 สรุปแบบจำลองในการพยากรณ์ตามสมรรถนะความสมบูรณ์และความคลาดเคลื่อนสะสม

สมรรถนะของแบบจำลอง	หม้อแปลง A	หม้อแปลง B
	แบบจำลองที่เหมาะสมในการพยากรณ์	
พิจารณาจาก R ² /EVS ของ อุณหภูมิน้ำมันด้านบน	ANN	RF
พิจารณาจาก MSE/MAE ของ อุณหภูมิน้ำมันด้านบน	ANN	GBR
พิจารณาจาก R ² /EVS ของ อุณหภูมิขดลวด	RF	RF
พิจารณาจาก MSE/MAE ของ อุณหภูมิขดลวด	RF	GBR

3.6 ขอบเขตการพยากรณ์ของแบบจำลองการเรียนรู้ของเครื่อง

จากผลการพยากรณ์โดยการใช้ข้อมูลแบบจุดเวลาและแบบเวลาก่อนหน้าของแบบจำลองการเรียนรู้ของเครื่องทั้ง 4 แบบที่ได้กล่าวข้างต้นพบว่าการพยากรณ์โดยการใช้ข้อมูลแบบเวลาก่อนหน้าให้ผลการพยากรณ์ข้อมูลสำหรับทดสอบและทดสอบได้ดีกว่าการใช้ข้อมูลแบบจุดเวลาในทุกแบบจำลอง ดังนั้นข้อมูลดังกล่าวจะถูกนำมาสร้างขอบเขตการพยากรณ์ของแต่ละแบบจำลองโดยแบบจำลอง ANN, RF และ LSTM จะทำการสร้างขอบเขตการพยากรณ์โดยการใช้ Bollinger bands และแบบจำลอง GBRT จะใช้การเปลี่ยนค่า γ ในสมการ (32) เพื่อสร้างขอบเขตการพยากรณ์ผลการสร้างขอบเขตการพยากรณ์ของแต่ละแบบจำลองมีสมรรถนะดังนี้ (กำหนดค่า $\eta = 1$ และ $\mu = 0.95$ ในการหาค่า CWC จากสมการ (36))

ตารางที่ 10 สมรรถนะค่า PICP, NMPIW และ CWC ของขอบเขตการพยากรณ์ในแต่ละแบบจำลอง

Transformer, Data	ANN			Transformer, Data	LSTM		
	PICP	NMPIW	CWC		PICP	NMPIW	CWC
Tx. A TOT	0.8615	5.974603	12.18374	Tx. A TOT	0.8338	6.68129	13.8199
Tx.A Winding Temp.	0.83102	7.251005	15.019801	Tx.A Winding Temp.	0.8615	8.50745	17.3489
Tx. B TOT	0.63758	2.259696	5.1974529	Tx. B TOT	0.61242	2.43399	5.67899
Tx.B Winding Temp.	0.63255	2.556387	5.8966328	Tx.B Winding Temp.	0.70805	3.00901	6.65474
Transformer, Data	RF			Transformer, Data	GBR		
	PICP	NMPIW	CWC		PICP	NMPIW	CWC
Tx. A TOT	0.72576	5.275594	11.555341	Tx. A TOT	0.759	5.25052	11.2961
Tx.A Winding Temp.	0.83934	7.401163	15.265214	Tx.A Winding Temp.	0.79224	4.50435	9.52119
Tx. B TOT	0.6745	2.130387	4.7996614	Tx. B TOT	0.82383	1.76349	3.66656
Tx.B Winding Temp.	0.71812	2.497432	5.4930246	Tx.B Winding Temp.	0.92953	2.63421	2.63421

จากนิยามของค่า PICP, NMPIW และ CWC ขอบเขตการพยากรณ์ที่มีสมรรถนะดีจะให้ค่า PICP ที่สูงในขณะที่มีค่า NMPIW ที่ต่ำซึ่งหมายถึงเป็นขอบเขตการพยากรณ์ที่มีความกว้างน้อยแต่มีจำนวนข้อมูลอยู่ในขอบเขตที่สูง ค่า CWC เป็นค่าที่ใช้บ่งบอกว่าสมรรถนะของขอบเขตการพยากรณ์ขึ้นอยู่กับค่า PICP หรือว่าความกว้างขอบเขตมากกว่ากันค่า CWC ที่เข้าใกล้ค่า NMPIW หมายถึงขอบเขตการพยากรณ์ที่มีค่า PICP สูงใกล้เคียง (และมากกว่า) ค่า μ ที่กำหนดไว้ และมีแนวโน้มว่าค่า PICP ที่สูงเกิดจากความกว้างของขอบเขตการพยากรณ์ที่มากเกินไป ค่า CWC ที่มากขึ้นบ่งบอกถึงส่วนต่างระหว่างค่า PICP และค่า μ ที่มากขึ้นซึ่งหมายถึงขอบเขตการพยากรณ์ที่แคบเกินไปหรือแบบจำลองที่ใช้พยากรณ์มีความไม่เหมาะสม ค่า CWC ดังกล่าวสามารถปรับพารามิเตอร์ η ในสมการที่ (36) และใช้ในการปรับจูนเพื่อหาขนาดความกว้างที่เหมาะสมของขอบเขตการพยากรณ์ได้

3.7 การใช้ผลการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนและอุณหภูมิขดลวดในการพยากรณ์ค่าอายุการใช้งานที่จะสูญเสียของหม้อแปลง

ในการคำนวณอายุการใช้งานที่สูญเสียของหม้อแปลงจะดำเนินการตามสมการ (3)-(11) โดยจะใช้ข้อมูลอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดจริงที่แบ่งไว้ใช้ในขั้นตอนทดสอบ (10%

ของข้อมูลทั้งหมด) ในการหาอายุการใช้งานที่สูญเสีย ใช้ข้อมูลที่พยากรณ์ได้จากแต่ละแบบจำลองที่สร้างโดยใช้ข้อมูลแบบเวลาก่อนหน้าในการหาอายุการใช้งานที่พยากรณ์ล่วงหน้าโดยแบบจำลองดังกล่าว และใช้ค่าขอบเขตบนของขอบเขตการพยากรณ์ในการพยากรณ์ค่าอายุการใช้งานที่สูญเสียไปมากที่สุด ผลการคำนวณค่าอายุการใช้งานที่สูญเสียไปในแต่ละกรณีและแต่ละแบบจำลองมีดังนี้

ตารางที่ 11 ผลการคำนวณค่าอายุการใช้งานที่สูญเสียของแต่ละแบบจำลอง

Loss of life	ANN	RF	LSTM	GBR
Predicted LOL Transformer A	0.0096	0.0092	0.0089	0.0092
Max LOL Transformer A	0.0141	0.0129	0.0136	0.0123
Actual LOL Transformer A	0.0102	0.0102	0.0102	0.0102
Predicted LOL Transformer B	0.0080	0.0075	0.0074	0.0076
Max LOL Transformer B	0.0094	0.0087	0.0087	0.0085
Actual LOL Transformer B	0.0077	0.0077	0.0077	0.0077
LOL Transformer A error (%)	5.88	9.8	12.75	9.8
LOL Transformer B error (%)	3.9	2.6	3.9	1.3

จากผลการคำนวณอายุการใช้งานที่สูญเสียที่พยากรณ์จากแต่ละแบบจำลองในแต่ละหม้อแปลงพบว่า ANN เหมาะสมกับข้อมูลหม้อแปลง A เนื่องจากมีค่าความคลาดเคลื่อนของอายุการใช้งานที่สูญเสียที่ได้จากการพยากรณ์ที่น้อยที่สุดเมื่อเทียบกับค่าที่เกิดขึ้นจริง ในขณะที่ GBR เหมาะสมกับข้อมูลหม้อแปลง B ที่สุด ซึ่งสอดคล้องกับสมรรถนะด้าน MSE และ MAE ในการพยากรณ์ของแต่ละแบบจำลอง ทั้งนี้ในการพยากรณ์อายุการใช้งานที่สูญเสียของหม้อแปลงจะอ้างอิงกับสมรรถนะในการพยากรณ์ตามตารางที่ 9 กล่าวคือในหม้อแปลง A จะใช้ผลการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดจากแบบจำลอง ANN และ RF ตามลำดับ ในขณะที่หม้อแปลง B จะใช้ผลการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดจากแบบจำลอง GBR ทั้งคู่ นอกจากนี้จากการทดลองเปลี่ยนแปลงข้อมูลที่ใช้ในการคำนวณค่าอายุการใช้งานที่สูญเสียของหม้อแปลง (ใช้อุณหภูมิน้ำมันด้านบนที่พยากรณ์จากแบบจำลอง ANN และใช้อุณหภูมิขดลวดที่พยากรณ์ได้จากแบบจำลองอื่น) พบว่าค่าอายุการใช้งานที่สูญเสียของหม้อแปลงเป็นผลมาจากค่าอุณหภูมิน้ำมันด้านบนมากกว่าจากอุณหภูมิขดลวด

นอกจากนี้เมื่อพิจารณาค่าความคลาดเคลื่อนของอายุการใช้งานที่สูญเสียที่ได้จากการพยากรณ์เทียบกับอายุการใช้งานที่สูญเสียที่คำนวณโดยใช้ค่าที่ตรวจวัดได้ที่จำนวนของข้อมูล


ต่างกัน (ความยาวตั้งแต่ 10% จนถึง 100% ของข้อมูลที่ใช้ในตารางที่ 12) พบว่าเมื่อใช้ข้อมูลตั้งแต่ 70% ขึ้นไป เปอร์เซ็นต์ความคลาดเคลื่อนที่เริ่มมีค่าใกล้เคียงกันทั้งในการพยากรณ์ของหม้อแปลง A และ หม้อแปลง B ดังตารางต่อไปนี้


ตารางที่ 12 ค่าความคลาดเคลื่อนในการพยากรณ์อายุการใช้งานที่สูญเสียที่จำนวนข้อมูลต่างกัน

%of data	10%	20%	30%	40%	50%	60%	70%	80%	90%	100%
Tx.A %error	0.10	6.25	4.76	3.44	3.03	4.12	4.47	5.26	4.39	5.88
Tx.B %error	0.15	0.20	5.55	3.70	3.21	2.32	1.88	1.67	1.45	1.30

3.8 การใช้ Percent B ในการจำแนกข้อมูลที่มีค่าเกินขอบเขตการพยากรณ์

สมการ (27) ได้เสนอการคำนวณค่า %B ซึ่งใช้เป็นตัวบ่งชี้ว่าข้อมูลจริงแต่ละจุดอยู่ตำแหน่งใดเมื่อเทียบกับขอบเขตล่างและขนาดความกว้างของขอบเขตการพยากรณ์ ค่า %B สามารถใช้บ่งบอกถึงค่าสุดต่างในบางสถานะซึ่งเป็นค่าที่มีความมากหรือน้อยเกินขอบเขตการพยากรณ์และอาจเป็นหนึ่งในค่าบ่งชี้ที่สื่อถึงการเสื่อมสภาพของหม้อแปลงหรือสมรรถนะในการระบายความร้อนของหม้อแปลงได้โดยหากพบค่า %B ที่สูง (เกิน 100%) และมีจำนวนมากขึ้นในอนาคต ค่า %B ของการพยากรณ์ค่าอุณหภูมิของน้ำมันด้านบนในหม้อแปลง A และหม้อแปลง B จากแบบจำลอง ANN และ GBR เป็นดังนี้





รูปที่ 37 ค่า %B ของข้อมูลเป้าหมายจริงแต่ละจุดในการพยากรณ์ค่าอุณหภูมิด้านบนของหม้อแปลง A และ B โดยใช้แบบจำลอง ANN และ RF ตามลำดับ

เมื่อพิจารณาจำนวนค่า %B ในกรอบช่วงเวลาของข้อมูลสำหรับทดสอบในแต่ละหม้อแปลงพบว่าหม้อแปลง A มีจำนวนข้อมูลที่มีค่า %B สูงเกิน 100% ทั้งหมด 7.76% ในขณะที่หม้อแปลง B มีจำนวนข้อมูลที่มีค่า %B สูงเกิน 100% ทั้งหมด 11.91% จำนวนข้อมูลที่มีค่าสูงเกิน 100% ดังกล่าวแสดงถึงค่าอุณหภูมิส่วนบนที่สูงเกินขอบเขตความเชื่อมั่นจากการพยากรณ์ การเพิ่มขึ้นของจำนวนดังกล่าวในอนาคตเป็นสิ่งที่ชี้วัดการเสื่อมสภาพของหม้อแปลงหรือการระบายความร้อนของหม้อแปลงที่ส่งผลให้ค่าอุณหภูมิน้ำมันด้านบนสูงขึ้นได้

3.9 การบริหารจัดการหม้อแปลงโดยใช้ผลการพยากรณ์จากแบบจำลอง

3.9.1 การใช้ผลการพยากรณ์อายุการใช้งานที่สูญเสีย

ตารางที่ 12 แสดงแบบจำลองการเรียนรู้ของเครื่องที่สามารถพยากรณ์อายุการใช้งานที่สูญเสียของหม้อแปลงในสถานะการทำงานที่กำหนด ในการบำรุงรักษาและบริหารสินทรัพย์หม้อแปลงในระบบส่ง ปัญหาหนึ่งที่เกิดขึ้นในระบบคือการเสียหายของหม้อแปลงที่ใช้งานในระบบซึ่งอาจมีสาเหตุจากทั้งการเสื่อมสภาพของอุปกรณ์ การเกิดความผิดปกติของระบบไฟฟ้า (Fault) หรือการเกิดอุบัติเหตุจากปัจจัยภายนอก การเปลี่ยนทดแทนหม้อแปลงที่ใช้ในระบบด้วยหม้อแปลงที่มีขนาดพิกัดและคุณสมบัติเหมือนหรือใกล้เคียงกันเป็นกระบวนการหนึ่งในการแก้ปัญหาดังกล่าว การเลือกหม้อแปลงที่จะนำมาเปลี่ยนทดแทนในสถานการณ์ดังกล่าวนอกจากข้อมูลคุณสมบัติจะมีความสำคัญแล้ว แบบจำลองการเรียนรู้ของเครื่องที่สามารถพยากรณ์อายุการใช้งานที่สูญเสียของหม้อแปลงสามารถเป็นอีกปัจจัยหนึ่งในการเลือกใช้งานหม้อแปลงได้เช่นกัน ตัวอย่างการใช้ค่าอายุ

การใช้งานที่สูญเสียของหม้อแปลงในการเลือกหม้อแปลงเพื่อติดตั้งทดแทนหม้อแปลงในระบบเป็นดังนี้

กำหนดให้มีหม้อแปลง ($T_1, T_2, T_3, \dots, T_n$) รวมทั้งหมด N ตัวที่สามารถนำมาเปลี่ยนทดแทนหม้อแปลงในระบบที่เกิดปัญหาไม่สามารถจ่ายไฟฟ้า โดยหม้อแปลงทุกตัวมีคุณสมบัติระดับแรงดันในการใช้งานและค่าพิกัด MVA ที่เท่ากันจัดเก็บในพื้นที่ที่ต่างกัน

หม้อแปลงแต่ละตัวมีแบบจำลองการเรียนรู้ของเครื่องที่สร้างโดยใช้ข้อมูลในการทำงานในอดีตซึ่งเป็นข้อมูลจำเพาะของแต่ละหม้อแปลง

กำหนดค่าใช้จ่ายในการดำเนินการนำหม้อแปลงแต่ละตัวมาติดตั้งทดแทนหม้อแปลงที่ปลดออกจากระบบมีค่า ($C_1, C_2, C_3, \dots, C_n$) ทั้งนี้ค่าใช้จ่ายดังกล่าวขึ้นอยู่กับระยะทางในการขนย้ายและการปรับปรุงสภาพของหม้อแปลง (ที่ไม่ใช่การเปลี่ยนทดแทนอุปกรณ์ภายในจำพวกขดลวด แกนเหล็กและกระดาษฉนวนซึ่งจะต้องใช้เวลานานในการปรับปรุงในโรงงานซ่อมจำเพาะ)

กำหนดค่าใช้จ่ายในการบำรุงรักษาต่ออายุการใช้งานที่สูญเสียของหม้อแปลงทุกตัวมีค่าเท่ากันและเท่ากับ h บาทต่อปี

จากการกำหนดตัวแปรข้างต้นดังกล่าว สามารถเขียนค่าใช้จ่ายของหม้อแปลงในการนำมาติดตั้งทดแทนและใช้งานในระยะเวลา n ปีได้ดังนี้

$$Cost_n = C_n + h(LOL_n) \quad (41)$$

โดย ค่า LOL_n คืออายุการใช้งานที่สูญเสียต่อปีของหม้อแปลงตัวที่ n ในสถานะฉุกเฉินแควดลุ่มและค่าโหลดที่กำหนด ได้จากการพยากรณ์

เมื่อนำค่าใช้จ่ายของหม้อแปลงในการนำมาติดตั้งทดแทนและใช้งานของหม้อแปลงแต่ละตัวจากสมการ (41) มาเปรียบเทียบกับกันและหาหม้อแปลงที่มีค่าดังกล่าวที่น้อยที่สุดจะสามารถใช้เป็นปัจจัยหนึ่งในการเลือกให้หม้อแปลงในการติดตั้งทดแทนหม้อแปลงที่ปลดออกจากระบบได้ นอกจากนี้หากหม้อแปลงที่นำมาเลือกใช้งานมีคุณสมบัติที่ไม่เหมือนกัน (แต่ผ่านหลักเกณฑ์ในการติดตั้งทดแทน) ก็สามารถใช้สมการ (41) ในการหาค่าใช้จ่ายโดยการปรับค่า h ของหม้อแปลงแต่ละตัวที่ต่างกันได้เช่นกัน

3.9.2 การใช้ขอบเขตการพยากรณ์

แบบจำลองการเรียนรู้ของเครื่องสามารถพยากรณ์ค่าฉุกเฉินน้ำมันด้านบนของหม้อแปลงในสถานะฉุกเฉินแควดลุ่มและค่าโหลดที่กำหนด ค่าที่พยากรณ์และขอบเขตการพยากรณ์สะท้อน

สมรรถนะภายในในการทำงานของหม้อแปลงเนื่องจากแบบจำลองถูกสร้างโดยใช้ข้อมูลที่ตรวจวัดได้จริงในอดีต การใช้ขอบเขตการพยากรณ์และ %B ในการเปรียบเทียบอุณหภูมิน้ำมันด้านบนที่ได้จากการตรวจวัดในการใช้งานกับค่าที่ได้จากการพยากรณ์จึงสามารถใช้ในการตรวจจับพฤติกรรมทางความร้อนที่มีความผิดปกติได้ โดยตัวอย่างการใช้งานขอบเขตการพยากรณ์เป็นดังนี้

- กำหนดให้คาบของการตรวจจับมีค่า p ซึ่งอาจจะเป็นกรอบเช่น 1 เดือน 3 เดือน หรือความยาวตามที่ผู้ใช้งานกำหนด

- ข้อมูลขาเข้าได้แก่ค่าอุณหภูมิแวดล้อมและค่าโหลดจะนำมาใช้ในการพยากรณ์ค่าอุณหภูมิ น้ำมันด้านบนพร้อมทั้งขอบเขตการพยากรณ์โดยแบบจำลองการเรียนรู้ของเครื่อง

- ข้อมูลอุณหภูมิน้ำมันด้านบนจริงที่เกิดขึ้นในแต่ละคาบจะถูกเก็บและนำมาหา %B เทียบกับขอบเขตการพยากรณ์ที่สร้างโดยแบบจำลองการเรียนรู้ของเครื่อง และหาร้อยละของข้อมูลที่มีค่า %B สูงเกิน 100%

- นำค่าร้อยละของข้อมูลที่มีค่า %B สูงเกิน 100% ในแต่ละคาบมาเรียงตามลำดับเวลาเพื่อใช้บ่งบอกแนวโน้มของข้อมูล

หม้อแปลงที่มีแนวโน้มของค่าร้อยละของข้อมูลที่มีค่า %B สูงเกิน 100% ที่เพิ่มขึ้นตามเวลา อาจเป็นการบ่งชี้ถึงพฤติกรรมทางความร้อนที่เปลี่ยนแปลงไปของหม้อแปลง ส่งผลให้ค่าอุณหภูมิ น้ำมันด้านบนมีค่าสูงกว่าค่าที่พยากรณ์ได้จากแบบจำลอง(ที่สะท้อนคุณสมบัติภายในหม้อแปลง) นอกจากนี้ ข้อมูลค่า %B ที่เกิดขึ้นในสภาวะอุณหภูมิแวดล้อมและค่าโหลดที่กำหนดหากนำมาใช้เปรียบเทียบกับข้อมูลในอดีตที่มีข้อมูลขาเข้าที่ใกล้เคียงกันจะสามารถบ่งบอกถึงพฤติกรรมที่เปลี่ยนแปลงไปของหม้อแปลงได้เช่นกัน เช่นที่ค่าอุณหภูมิแวดล้อม 28 °C และค่าโหลด 100 MVA ค่า %B ในอดีตมีค่าเฉลี่ยที่ 70% หากข้อมูลการใช้งานใหม่ที่เกิดขึ้นมีค่า %B อยู่ที่ 150% ทั้งค่าแนวโน้มของค่าร้อยละของข้อมูลที่มีค่า %B สูงเกิน 100% มีค่าเพิ่มขึ้น ก็สามารถเป็นตัวบ่งชี้ถึงพฤติกรรมของหม้อแปลงที่เปลี่ยนแปลงไปซึ่งอาจเกิดจากการเสื่อมสภาพภายในหรือของอุปกรณ์ประกอบของหม้อแปลงได้

บทที่ 4

สรุปผลการศึกษา

สมรรถนะของแบบจำลองการเรียนรู้ของเครื่องในการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวด

การทดลองใช้แบบจำลองการเรียนรู้ของเครื่อง 4 แบบในการเรียนรู้เพื่อสร้างแบบจำลองที่รับค่าอุณหภูมิแวดล้อมและค่าโหลดเพื่อพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิจดลวดโดยใช้ค่า R-Square, MSE, EVS และ MAE ในการวัดสมรรถนะในการพยากรณ์ ค่า R-Square และ EVS บ่งบอกความสมบูรณ์ของข้อมูลจริงและข้อมูลจากการพยากรณ์จะเหมาะสมกับการตรวจหาค่าอุณหภูมิส่วนบนที่สูงกว่าขอบเขตการพยากรณ์ในรูป %B ในขณะที่ค่า MSE และ MAE ที่บ่งบอกค่าความคลาดเคลื่อนสะสมในการพยากรณ์ของแบบจำลองจะเหมาะสมกับการใช้ค่าที่ได้ในการคำนวณอายุการใช้งานที่สูญเสียของหม้อแปลง และจากค่าสมรรถนะพบว่า

- ในการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนของหม้อแปลง A แบบจำลอง ANN ให้สมรรถนะในขั้นตอนทดสอบที่ดีที่สุดในการหาค่าอายุการใช้งานที่สูญเสียและการตรวจหาความผิดปกติของอุณหภูมิน้ำมันด้านบนโดยใช้ %B โดยมีความสมบูรณ์ (จากค่า R-Square) ที่สูงระหว่างข้อมูลที่พยากรณ์ได้และข้อมูลเป้าหมาย และมีค่าความคลาดเคลื่อนสะสมของข้อมูล (จากค่า MSE และ MAE) ที่ต่ำที่สุด ทั้งนี้ในส่วนของค่า EVS ในขั้นตอนทดสอบมีค่าน้อยกว่าแบบจำลอง RF เพียงเล็กน้อย
- ในการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนของหม้อแปลง B แบบจำลอง RF มีความสมบูรณ์ (จากค่า R-Square และ EVS) ที่สูงในขณะที่แบบจำลอง GBR มีค่าความคลาดเคลื่อนสะสมของข้อมูล (จากค่า MSE และ MAE) ที่ต่ำที่สุด ดังนั้นการใช้แบบจำลอง RF จะมีความเหมาะสมในการใช้งานร่วมกับค่า %B ในขณะที่แบบจำลอง GBR จะเหมาะสมในการคำนวณอายุการใช้งานที่สูญเสียของหม้อแปลง
- ในการพยากรณ์ค่าอุณหภูมิจดลวดของหม้อแปลง A แบบจำลอง RF มีความคลาดเคลื่อนสะสม (จากค่า MSE และ MAE) ที่ต่ำที่สุด ดังนั้นการใช้แบบจำลอง RF เพื่อพยากรณ์ค่าอุณหภูมิจดลวดจะมีความเหมาะสมในการคำนวณอายุการใช้งานที่สูญเสียของหม้อแปลง

- ในการพยากรณ์ค่าอุณหภูมิขดลวดของหม้อแปลง B แบบจำลอง GBR มีความคลาดเคลื่อนสะสม (จากค่า MSE และ MAE) ที่ต่ำที่สุด ดังนั้นการใช้แบบจำลอง GBR เพื่อพยากรณ์ค่าอุณหภูมิขดลวดจะมีความเหมาะสมในการคำนวณอายุการใช้งานที่สูญเสียของหม้อแปลง

ผลการพยากรณ์อายุการใช้งานที่สูญเสียของหม้อแปลง

ข้อมูลที่น่ามาพยากรณ์ค่าอายุการใช้งานที่สูญเสียของหม้อแปลงจะใช้ข้อมูลจากแบบจำลองที่มีค่าสมรรถนะที่เกี่ยวข้องกับความคลาดเคลื่อนสูงที่สุดในการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดได้แก่

- หม้อแปลง A จะใช้ผลจากแบบจำลอง ANN และ RF สำหรับข้อมูลอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดตามลำดับในการคำนวณอายุการใช้งานที่สูญเสีย
- หม้อแปลง B จะใช้ผลจากแบบจำลอง GBR สำหรับทั้งข้อมูลอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดในการคำนวณอายุการใช้งานที่สูญเสีย

ผลการคำนวณอายุการใช้งานที่สูญเสียเป็นผลที่มาจากการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดของหม้อแปลงล่วงหน้าก่อนที่จะใช้งานจ่ายกำลังไฟฟ้าในสภาวะที่กำหนด ซึ่งมีความใกล้เคียงกับอายุการใช้งานที่สูญเสียที่คำนวณจากค่าที่ตรวจวัดได้ โดยในหม้อแปลง A มีค่าความคลาดเคลื่อน 5.88% และในหม้อแปลง B มีค่าความคลาดเคลื่อน 1.3% ดังนั้นการใช้แบบจำลองการเรียนรู้ของเครื่องสามารถพยากรณ์และคำนวณอายุการใช้งานที่สูญเสียของหม้อแปลงเพื่อใช้ในการเลือกสรรหม้อแปลงสำรองในระบบในการใช้งานหรือใช้ค่าอายุการใช้งานที่คาดว่าจะสูญเสียของหม้อแปลงร่วมในการวางแผนเส้นทาง การส่งจ่ายกำลังไฟฟ้าได้ ทั้งนี้ผลการพยากรณ์ค่าอายุการใช้งานที่สูญเสียโดยใช้แบบจำลองการเรียนรู้ของเครื่องที่ข้อมูลทดสอบความยาวแตกต่างกันก็ให้ค่าความคลาดเคลื่อนที่ใกล้เคียงกัน แบบจำลองการเรียนรู้ของเครื่องดังกล่าวจึงสามารถที่ใช้งานกับข้อมูลในอนาคตที่ความยาวที่กำหนดได้

การตรวจวัดข้อมูลค่าโหลด อุณหภูมิแวดล้อม อุณหภูมิน้ำมันส่วนบนและอุณหภูมิขดลวดของหม้อแปลงที่มากขึ้นเพื่อนำมาสร้างแบบจำลองการเรียนรู้ของเครื่องจะสามารถทำให้สมรรถนะการพยากรณ์ค่าอายุการใช้งานที่สูญเสียของหม้อแปลงเพิ่มขึ้นได้ ทั้งนี้การปรับแบบจำลองในกระบวนการพยากรณ์ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดให้มีสมรรถนะการพยากรณ์ที่สูงขึ้นจะส่งผลให้ค่าอายุการใช้งานที่สูญเสียจากการพยากรณ์มีความใกล้เคียงกับค่าที่คำนวณโดยใช้ค่าที่ตรวจวัดได้เช่นกัน

ขอบเขตการพยากรณ์และ %B

ขอบเขตการพยากรณ์เป็นขอบเขตที่สร้างขึ้นเพื่อให้ข้อมูลเพิ่มเติมจากการพยากรณ์แบบจุดให้เป็นแบบช่วง การสร้างขอบเขตการพยากรณ์โดยใช้ Bollinger bands ที่กำหนดความกว้าง 2 เท่าของค่าส่วนเบี่ยงเบนมาตรฐานและการใช้ quantile ที่ 0.025 และ 0.975 มีจุดประสงค์เพื่อสร้างขอบเขตการพยากรณ์ที่มีค่าความเชื่อมั่น 95% ว่าข้อมูลจะอยู่ในขอบเขตดังกล่าวซึ่งหลังจากได้ใช้แบบจำลองการเรียนรู้ของเครื่องที่เหมาะสมในการสร้างและพยากรณ์ค่าอายุการใช้งานที่สูญเสียไปในการจ่ายโหลดของหม้อแปลงแล้ว เมื่อนำหม้อแปลงไปใช้งานตามสภาวะที่กำหนด การเก็บข้อมูลและตรวจสอบข้อมูลจริงที่เกิดขึ้นเทียบกับขอบเขตการพยากรณ์จะช่วยให้สามารถเห็นภาพรวมของพฤติกรรมทางความร้อนของหม้อแปลงที่อาจผิดแปลกไปจากพฤติกรรมเดิมที่แบบจำลองได้เรียนรู้ไปแล้วได้

ปัญหาหนึ่งพบในการบำรุงรักษาหม้อแปลงในระบบส่งของ กฟผ. คือตัวหม้อแปลงมีอุปกรณ์ที่จะแจ้งเตือนหรือตัดหม้อแปลงออกจากระบบเมื่ออุณหภูมิน้ำมันด้านบนเพิ่มขึ้นจนมีค่าถึงจุดหนึ่ง แต่ไม่มีข้อมูลที่จะบ่งชี้ได้ว่าพฤติกรรมทางความร้อนของหม้อแปลงใดที่ปกติและพฤติกรรมใดที่ผิดปกติหากใช้งานกับโหลดที่น้อยกว่าค่าปกติของหม้อแปลง ดังนั้นค่าขอบเขตบนของขอบเขตการพยากรณ์เมื่อถูกนำมาคำนวณหาอายุการใช้งานที่สูญเสียของหม้อแปลงจะบ่งบอกถึงอายุการใช้งานที่สูญเสียไปของหม้อแปลงมากที่สุดที่เป็นไปได้ที่ค่าความเชื่อมั่น 95% ซึ่งหากนำข้อมูลที่ได้จากการใช้งานจริงมาหาอายุการใช้งานที่สูญเสียไป ค่าดังกล่าวจึงไม่ควรเกินค่าอายุการใช้งานที่สูญเสียไปมากที่สุดจากแบบจำลอง เพราะอาจหมายถึงอุณหภูมิน้ำมันด้านบน(และอุณหภูมิขดลวด) มีการเพิ่มขึ้นอย่างมากจากความผิดปกติภายในหม้อแปลงหรืออาจเกิดความผิดปกติจากอุปกรณ์วัดอุณหภูมิของหม้อแปลงและควรเข้าไปตรวจสอบเพื่อการบำรุงรักษาต่อไป

นอกจากการเทียบค่าอายุการใช้งานที่สูญเสียไปจากการจ่ายโหลดกับค่าที่พยากรณ์ได้แล้วการใช้ %B จะทำให้สามารถติดตามการเพิ่มขึ้นของอุณหภูมิน้ำมันด้านบนได้เช่นกัน ผู้ใช้งานหม้อแปลงหรือหน่วยงานบำรุงรักษาสามารถกำหนดจำนวนที่ค่า %B ที่สูงเกิน 100% ในแต่ละช่วงเวลา

เพื่อเป็นเกณฑ์ประกอบการตัดสินใจว่าการจ่ายโหลดของหม้อแปลงสร้างความร้อนมากเกินไปหรือไม่ หม้อแปลงที่มีการเสื่อมสภาพและมีสมรรถนะในการระบายความร้อนที่ลดลงแบบถาวร ซึ่งอาจเกิดจากการเสื่อมสภาพที่ละเล็กละน้อยแต่ใช้เวลานานอาจมีจำนวน %B ที่สูงเกิน 100% เพิ่มมากขึ้นตามเวลาและนอกจากนี้เนื่องจากลักษณะการจ่ายโหลดของระบบไฟฟ้าขนาดใหญ่มักมีการจ่ายโหลดที่เป็นวัฏจักรซึ่งมีขนาดและรูปร่างใกล้เคียงกันในช่วงเวลาเดียวกัน จำนวนของค่า %B ที่สูงกว่า 100% ในช่วงที่มีความต้องการใช้ไฟฟ้าสูงอาจเป็นสัญญาณที่สื่อถึงการเสื่อมสภาพของหม้อแปลงที่ส่งผลทำให้ค่าอุณหภูมิน้ำมันด้านบนและอุณหภูมิขดลวดเพิ่มขึ้นจากเดิมได้



บรรณานุกรม

1. IEEE, *IEEE C57.91, IEEE Guide for Loading Mineral-Oil-Immersed Transformers and Step-Voltage Regulators* 2011.
2. Carlson, C.A.H.a.R.W., *Using Insulation Aging to Size Transformers in High-Ambient-Temperature Secondary-Selective Applications*. IEEE Transactions on Industry Applications, March-April 2014. 50: p. 1503-1508.
3. J. I. Aizpurua, S.D.J.M., B. G. Stewart, B. Lambert, J. G. Cross and V. M. Catterson, *Adaptive Power Transformer Lifetime Predictions Through Machine Learning and Uncertainty Modeling in Nuclear Power Plants*. IEEE Transactions on Industrial Electronics, June 2019. 66: p. 4726-4737.
4. Q. He, J.S.a.D.J.T., *Prediction of top-oil temperature for transformers using neural networks*. IEEE Transactions on Power Delivery, Oct. 2000. 15: p. 1205-1211.
5. A. Khosravi, S.N., D. Creighton and A. F. Atiya, *Comprehensive Review of Neural Network-Based Prediction Intervals and New Advances*. IEEE Transactions on Neural Networks, Sept. 2011. 22: p. 1341-1356.
6. Bishop, C.M., *Pattern Recognition and Machine Learning*. 2006: Springer Science+Business Media, LLC.
7. Hu, Y.L.a.S., *Cyberthreat Analysis and Detection for Energy Theft in Social Networking of Smart Homes*. IEEE Transactions on Computational Social Systems, Dec. 2015. 2: p. 148-158.
8. Haohui Lv., G.C., Mingbin Deng., Zhiyuan Tan., Wen Hu, *Power consumption interval prediction based on quantile regression neural network and kernel density estimation*, in *11th International Symposium on Computational Intelligence and Design*. 2008.
9. Henry Y. T. Ngan., a.G.K.H.P., *Novel method for patterned fabric inspection using Bollinger bands*. Optical Engineering August 2006. 45: p. 1-15.
10. A. Khosravi, S.N., D. Creighton and A. F. Atiya, *Lower Upper Bound Estimation Method for Construction of Neural Network-Based Prediction Intervals*. IEEE Transactions on Neural Networks, March 2011. 22: p. 337-346.
11. H. M. D. Kabir, M.A.H., S. Nahavandi and A. Khosravi, *Prediction interval with examples*

- of similar pattern and prediction strength*, in *2017 IEEE 30th Canadian Conference on Electrical and Computer Engineering (CCECE)*. 2017: Windsor, ON. p. 1-4.
12. Raschka, S., *Python Machine Learning*. 2016: Packt Publishing.
 13. Ivan Vasilev., D.S., Gianmario Spacagna., Peter Roelants., and Valentino Zocca, *Python deep learning* ed. 2. 2019: Packt Publishing.
 14. Antonio Gulli., a.S.P., *Deep learning with Keras*. 2017: Packt Publishing.



ประวัติผู้เขียน

ชื่อ-สกุล	Suwapan Aridej
วัน เดือน ปี เกิด	21 march 1992
สถานที่เกิด	Lampang
วุฒิการศึกษา	Bachelor degree-Chulalongkorn University, Faculty of Engineering, Department of Electrical Engineering
ที่อยู่ปัจจุบัน	153/106 Pratuma road, Weing Neua sub-district, Mueng district, Lampang, 52000

