

การพยากรณ์ความต้องการไฟฟ้าของประเทศไทยด้วยวิธีการเรียนรู้เชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์ ภาควิชาวิศวกรรมคอมพิวเตอร์

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2562

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Power Consumption Forecasting in Thailand Using Deep Learning Model



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Computer Science

Department of Computer Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2019

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพยากรณ์ความต้องการไฟฟ้าของประเทศไทยด้วย วิธีการเรียนรู้เชิงลึก
โดย	น.ส.ชัชวัญ สิริทิพากุล
สาขาวิชา	วิทยาศาสตร์คอมพิวเตอร์
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	
.....	ประธานกรรมการ
(ศาสตราจารย์ ดร.บุญเสริม กิจศิริกุล)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.พีรพล เวทีกุล)	
.....	กรรมการ
(อ. ดร.ดวงดาว วิชาตากุล)	
.....	กรรมการภายนอกมหาวิทยาลัย
(อ. ดร.ธนภัทร ชั่งคะจิตร)	

ชูขวัญ สิริทิพากุล : การพยากรณ์ความต้องการไฟฟ้าของประเทศไทยด้วยวิธีการเรียนรู้เชิงลึก. (Power Consumption Forecasting in Thailand Using Deep Learning Model) อ.ที่ปรึกษาหลัก : ผศ. ดร.พีรพล เวทีกุล

ในระบบไฟฟ้านั้นความมั่นคงของระบบไฟฟ้าเป็นสิ่งที่สำคัญที่สุดและไม่ควรที่จะเกิดไฟฟ้าดับ เพื่อเป็นการเพิ่มความมั่นคงให้ระบบไฟฟ้าจึงจำเป็นต้องพยากรณ์ความต้องการไฟฟ้าล่วงหน้าอย่างน้อย 1 วัน โดยงานวิจัยนี้จะทำการพยากรณ์ความต้องการไฟฟ้าของวันถัดไปรายครึ่งชั่วโมงรวมทั้งหมด 48 ช่วงเวลา ซึ่งในปัจจุบันมีงานวิจัยที่นำเทคนิคการเรียนรู้เชิงลึก (Deep Learning) มาใช้งานในการพยากรณ์ความต้องการไฟฟ้ามากขึ้น แต่แบบจำลองในอดีตไม่เหมาะสมกับสถานการณ์จริงที่เกิดขึ้น โดยในงานวิจัยนี้นำเสนอแบบจำลองสำหรับพยากรณ์ความต้องการไฟฟ้าหลายช่วงเวลาล่วงหน้าที่มีการใช้งานกลไกจุดสนใจ 2 ชั้น (Dual-Stage Attention Mechanism) ซึ่งจะพิจารณาทั้งผลกระทบจากช่วงเวลาในอดีตและผลกระทบจากคุณลักษณะที่ส่งผลถึงข้อมูลในอนาคต รวมถึงในแบบจำลองนี้จะมีการพิจารณาคุณลักษณะอื่น ๆ ที่มีผลกระทบต่อความต้องการไฟฟ้าด้วย นอกจากนี้งานวิจัยนี้จะมีการออกแบบฟังก์ชันต้นทุนแบบไม่สมมาตร (Asymmetric Loss Function) สำหรับการพยากรณ์ความต้องการไฟฟ้าเพื่อให้สอดคล้องกับสถานการณ์จริงมากยิ่งขึ้น โดยที่ฟังก์ชันต้นทุนนี้จะให้ค่าต้นทุนที่มากกว่ากับการพยากรณ์ที่ต่ำกว่าผลเฉลย เพื่อให้แบบจำลองพยากรณ์ความต้องการไฟฟ้าได้สูงขึ้นทำให้ลดโอกาสในการเกิดไฟฟ้าดับได้

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา วิทยาศาสตร์คอมพิวเตอร์
ปีการศึกษา 2562

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6170921221 : MAJOR COMPUTER SCIENCE

KEYWORD: Power consumption forecasting, Deep learning, Attention
Mechanism, Long short-term memory, Asymmetric Loss function

Chukwan Siridhipakul : Power Consumption Forecasting in Thailand Using
Deep Learning Model. Advisor: Asst. Prof. Dr. PEERAPON VATEEKUL

In the power system, stability is the most important and there should be no power outage. To increase the stability of power systems, it is crucial to forecast a power consumption demand at least one day in advance. In this research, we will forecast the next day's power consumption in the half-hour interval for a total of 48 intervals. There were many prior attempts, including the ones based on deep learning networks but the prior works are not appropriate with the real-world situation. In this research, we propose the model to do multi-step forecasting for power consumption which uses attention mechanism which considers both varying impacts from different time features. Moreover, we also consider exogenous that affect to the power consumption in our model and we propose a new loss function tailor made for the power consumption forecasting task base on real-world situation. It is asymmetric by giving more weight on the undersupplying loss in our deep learning networks. The model will be forecast higher so it can reduce the risk of power outages.

CHULALONGKORN UNIVERSITY

Field of Study: Computer Science

Student's Signature

Academic Year: 2019

Advisor's Signature

กิตติกรรมประกาศ

การที่วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดีนั้น นอกจากการทำงานของตัวผู้วิจัยแล้ว ยังมีบุคคลท่านอื่นที่เป็นส่วนสำคัญที่ได้ให้ความช่วยเหลือในการจัดทำวิทยานิพนธ์ฉบับนี้ขึ้นมา ผู้วิจัยรู้สึกซาบซึ้งในความกรุณาเหล่านี้เป็นอย่างมากจึงใคร่ขอใช้เนื้อหาในส่วนกิตติกรรมประกาศของวิทยานิพนธ์ฉบับนี้แสดงความขอบพระคุณเป็นอย่างสูงมา ณ ที่นี้

ขอขอบพระคุณอาจารย์ที่ปรึกษา ผศ. ดร. พีรพล เวทีกุล ผู้ที่คอยให้ความช่วยเหลือและให้คำปรึกษา รวมทั้งผลักดันให้งานวิจัยและวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้

ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ซึ่งประกอบไปด้วย ศ. ดร. บุญเสริม กิจศิริกุล อ. ดร. ดวงดาว วิชาดากุล และ อ. ดร. ธนภัทร ฆังคะจิตร ที่ได้กรุณาให้เกียรติเป็นคณะกรรมการรวมทั้งให้คำปรึกษาและข้อเสนอแนะอันเป็นประโยชน์อย่างมากต่อการทำวิจัยและวิทยานิพนธ์ฉบับนี้

ขอขอบพระคุณการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย และกรมอุตุนิยมวิทยาสำหรับข้อมูลในการทำวิจัยและวิทยานิพนธ์ฉบับนี้

ขอขอบคุณเพื่อน ๆ พี่ ๆ น้อง ๆ สมาชิก “Data Mining Group, MIND Lab” ทุกท่านสำหรับกำลังใจ และคำแนะนำต่าง ๆ เพื่อนำมาประยุกต์ใช้ในวิทยานิพนธ์ฉบับนี้

สุดท้ายนี้ขอขอบพระคุณครอบครัวของผู้วิจัยที่ให้การสนับสนุนในทุก ๆ ด้าน และคอยให้กำลังใจตลอดระยะเวลาในการดำเนินการทำงานวิจัยนี้

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ญ
สารบัญรูปภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 วัตถุประสงค์ของงานวิจัย.....	3
1.3 ขอบเขตการวิจัย.....	3
1.4 ประโยชน์ที่ได้รับ.....	3
1.5 วิธีดำเนินงานวิจัย.....	4
1.6 ผลงานวิจัยที่ตีพิมพ์.....	6
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	7
2.1 นิวรอลเน็ตเวิร์ก (Neural Network).....	7
2.2 นิวรอลเน็ตเวิร์กเชิงลึก (Deep Neural Network).....	7
2.3 กลไกจุดสนใจ (Attention Mechanism).....	13
บทที่ 3 งานวิจัยที่เกี่ยวข้อง.....	14
3.1 งานวิจัยที่เกี่ยวข้องกับการพยากรณ์ข้อมูลอนุกรมเวลา.....	14
3.2 งานวิจัยที่เกี่ยวข้องกับการใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร.....	17
บทที่ 4 แนวคิดและแบบจำลองที่นำเสนอ.....	18

4.1 การเตรียมข้อมูล	19
4.1.1 การปรับปรุงข้อมูล.....	19
4.1.2 การจัดแบ่งข้อมูล.....	19
4.1.3 การจัดรูปแบบข้อมูลสำหรับแบบจำลอง	19
4.2 แบบจำลองที่นำเสนอ.....	20
4.2.1 ข้อมูลนำเข้า.....	21
4.2.2 การพยากรณ์ข้อมูลคุณลักษณะ	21
4.2.3 การสกัดคุณลักษณะ	22
4.2.4 การพยากรณ์ความต้องการไฟฟ้าแบบหลายช่วงเวลา.....	22
4.2.5 ฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ความต้องการไฟฟ้า	23
บทที่ 5 การทดลอง	25
5.1 การสร้างแบบจำลองเพื่อใช้เปรียบเทียบประสิทธิภาพ.....	26
5.1.1 โครงข่ายประตูกลับสองทิศทาง (GRU).....	26
5.1.2 หน่วยความจำระยะสั้นแบบยาว (LSTM).....	26
5.1.3 นิวรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาว (CNN-LSTM)	26
5.1.4 กลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์กแบบวงกลับ (DA-RNN).....	26
5.2 ประสิทธิภาพของแบบจำลองที่พิจารณาข้อมูลเกี่ยวกับอากาศ และข้อมูลประเภทของวัน....	26
5.2.1 ชุดข้อมูล.....	26
5.2.2 การวัดผล.....	27
5.2.3 ประสิทธิภาพของแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์ก แบบวงกลับ ต่อกับหน่วยความจำระยะสั้นแบบยาว	28
5.2.4 ประสิทธิภาพของแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์กแบบวงกลับ ต่อกับหน่วยความจำระยะสั้นแบบยาวและการสกัดคุณลักษณะโดยใช้นิวรอลเน็ตเวิร์ก คอนโวลูชัน.....	29
5.3 ประสิทธิภาพของแบบจำลองเมื่อพิจารณาคุณลักษณะด้านพลังงานหมุนเวียน	31

5.3.1 ชุดข้อมูล.....	31
5.3.2 ผลการทดลอง.....	32
5.4 ประสิทธิภาพของแบบจำลองเมื่อพิจารณาค่าเฉลี่ยถ่วงน้ำหนักของความต้องการไฟฟ้า.....	33
5.4.1 ชุดข้อมูล.....	33
5.4.2 ผลการทดลอง.....	33
5.5 ประสิทธิภาพของแบบจำลองเมื่อพิจารณาคูณลักษณะด้านพลังงานหมุนเวียน และค่าเฉลี่ยถ่วงน้ำหนักของความต้องการไฟฟ้า	34
5.5.1 ชุดข้อมูล.....	34
5.5.2 ผลการทดลอง.....	35
5.6 ประสิทธิภาพเมื่อใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร.....	36
5.6.1 การวัดผล.....	36
5.6.2 พารามิเตอร์ที่ใช้การคำนวณฟังก์ชันต้นทุนแบบไม่สมมาตร.....	36
5.6.3 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของราคาที่สองของกำลังสองของความคลาดเคลื่อน	37
5.6.4 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน	40
5.6.5 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนแบบแยกค่าพยากรณ์	41
5.6.6 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยจำนวนครั้งที่เกิดไฟฟ้าดับ	42
บทที่ 6 สรุปผลการวิจัยและแนวทางการวิจัยในขั้นถัดไป	43
6.1 สรุปผลการวิจัย.....	43
6.2 แนวทางการวิจัยถัดไป.....	44
บรรณานุกรม.....	45
ประวัติผู้เขียน.....	49

สารบัญตาราง

หน้า

ตารางที่ 1 แผนภูมิแกนต์แสดงขั้นตอนการดำเนินงาน.....	5
ตารางที่ 2 ผลการทดลองเมื่อใช้แบบจำลอง D-LSTM กับแบบจำลองอื่น ๆ และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)..	28
ตารางที่ 3 ผลการทดลองเมื่อใช้แบบจำลอง D-LSTM กับแบบจำลองอื่น ๆ และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)	28
ตารางที่ 4 ผลการทดลองเมื่อใช้แบบจำลองที่มีและไม่มีส่วนของการสกัดคุณลักษณะ และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)	30
ตารางที่ 5 ผลการทดลองเมื่อใช้แบบจำลองที่มีและไม่มีส่วนของการสกัดคุณลักษณะ และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%).....	30
ตารางที่ 6 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคุณลักษณะด้านพลังงานหมุนเวียน และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW).....	32
ตารางที่ 7 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคุณลักษณะด้านพลังงานหมุนเวียน และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%).....	32
ตารางที่ 8 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคุณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีต และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW).....	33
ตารางที่ 9 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคุณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีต และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)	34

ตารางที่ 10 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาคุณลักษณะที่แตกต่างกัน และใช้ค่าเฉลี่ยของ ราคาที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)	35
ตารางที่ 11 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาคุณลักษณะที่แตกต่างกัน และใช้ค่าเฉลี่ยของ ค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%).....	35
ตารางที่ 12 ค่าพารามิเตอร์ที่ดีที่สุด (μ) สำหรับฟังก์ชันต้นทุนแบบไม่สมมาตร.....	37
ตารางที่ 13 ผลการทดลองเมื่อใช้ฟังก์ชันต้นทุนที่แตกต่างกัน และใช้ค่าเฉลี่ยของราคาที่สองของกำลัง สองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)	37
ตารางที่ 14 ผลการทดลองเมื่อใช้ฟังก์ชันต้นทุนที่แตกต่างกัน และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของ เปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%).....	40
ตารางที่ 15 ผลการทดลองเมื่อใช้ฟังก์ชันต้นทุนที่แตกต่างกัน และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของ เปอร์เซ็นต์ของความคลาดเคลื่อนแบบแยกค่าพยากรณ์เป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็น เปอร์เซ็นต์ (%).....	41
ตารางที่ 16 จำนวนครั้งที่ส่งผลให้เกิดไฟฟ้าดับของแบบจำลองต่าง ๆ เมื่อมีกำลังผลิตสำรองพร้อม จ่ายทันที 800 และ 1,500 เมกะวัตต์ โดยมีหน่วยเป็นครั้ง	42

สารบัญรูปภาพ

	หน้า
รูปที่ 1 โครงสร้างนิรอลเน็ตเวิร์กแบบวกกลับ	8
รูปที่ 2 โครงสร้างหน่วยความจำระยะสั้นแบบยาว	9
รูปที่ 3 โครงสร้างโครงข่ายประตูกกลับ	10
รูปที่ 4 โครงสร้างนิรอลเน็ตเวิร์กคอนโวลูชัน	11
รูปที่ 5 การทำคอนโวลูชันแบบแคบที่มีขนาดของตัวกรอง คือ 3x3	11
รูปที่ 6 การทำคอนโวลูชันแบบกว้างที่มีขนาดของตัวกรอง คือ 3x3 และมีการเสริมเต็ม	12
รูปที่ 7 การทำคอนโวลูชันที่ข้อมูลนำเข้าขนาด 4x4 ตัวกรองขนาด 2x2 และมีขนาดของการก้าวข้าม เป็น 2	12
รูปที่ 8 การทำคอนโวลูชันโดยมีจำนวนตัวกรองเท่ากับ 2	12
รูปที่ 9 ตัวอย่างขั้นการรวมโดยค่าที่มากที่สุดและค่าเฉลี่ย	13
รูปที่ 10 ขั้นการเชื่อมโยงเต็มรูปแบบ	13
รูปที่ 11 แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิรอลเน็ตเวิร์กแบบวกกลับ	15
รูปที่ 12 แบบจำลองนิรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาว	16
รูปที่ 13 การจัดเตรียมข้อมูลคุณลักษณะที่เกี่ยวข้อง	19
รูปที่ 14 การจัดเตรียมข้อมูลค่าความต้องการไฟฟ้าในอดีต	20
รูปที่ 15 แนวคิดของแบบจำลอง D-LSTM+F _{CNN} +Loss _{asym}	20
รูปที่ 16 แบบจำลอง D-LSTM+F _{CNN} +Loss _{asym}	21
รูปที่ 17 ตัวอย่างของข้อมูลที่ใช้ในกลไกจุดสนใจชั้นที่หนึ่ง	22
รูปที่ 18 ตัวอย่างของข้อมูลที่ใช้ในกลไกจุดสนใจชั้นที่สอง	23
รูปที่ 19 การทำงานของฟังก์ชันต้นทุนแบบไม่สมมาตร	24
รูปที่ 20 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาคกลาง	38

รูปที่ 21 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาค
ตะวันออกเฉียงเหนือ 38

รูปที่ 22 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาคใต้ 39

รูปที่ 23 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาคเหนือ 39

รูปที่ 24 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของเขตนคร
หลวง..... 40



บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญ

สถิติจากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย พบว่าระบบไฟฟ้าของประเทศไทยในปัจจุบันมีความต้องการใช้พลังงานไฟฟ้าที่เพิ่มขึ้นในทุก ๆ วัน และจำนวนผู้ผลิตไฟฟ้าที่ใช้พลังงานหมุนเวียนที่จะเชื่อมต่อและไม่ได้เชื่อมต่อกับระบบไฟฟ้าของประเทศไทยมีแนวโน้มเพิ่มขึ้นเรื่อย ๆ ทำให้การบริหารจัดการระบบไฟฟ้ามีความยุ่งยากมากขึ้น ซึ่งในการบริหารจัดการระบบไฟฟ้าจะมีเป้าหมายหลัก คือ การควบคุมความถี่ของระบบให้คงที่ ซึ่งจะหมายถึงปริมาณไฟฟ้าที่ระบบผลิตได้มีปริมาณใกล้เคียงกับความต้องการไฟฟ้าของผู้ใช้ไฟฟ้าภายในประเทศ

การพยากรณ์ความต้องการใช้การไฟฟ้าที่แม่นยำ ทำให้การบริหารจัดการระบบไฟฟ้าง่ายขึ้น และส่งผลกระทบต่อระบบเศรษฐกิจ อีกทั้งยังช่วยให้สามารถวางแผนการผลิตไฟฟ้าได้เพียงพอต่อความต้องการใช้ไฟฟ้า พลังงานไฟฟ้าเป็นสิ่งที่เมื่อมีการผลิตแล้วจะต้องใช้งานทันที ซึ่งในปัจจุบันอุปกรณ์จัดเก็บพลังงานยังมีราคาที่สูง และหากเราพยากรณ์ความต้องการไฟฟ้าสูงเกินไป จะทำให้ต้นทุนในการผลิตไฟฟ้าเพิ่มมากขึ้น แต่หากเราพยากรณ์ความต้องการไฟฟ้าต่ำเกินไป จะส่งผลให้พลังงานไฟฟ้าไม่เพียงพอต่อการใช้งาน ซึ่งเกิดความเสี่ยงที่ระบบไฟฟ้าจะล่ม ดังนั้นการพยากรณ์ความต้องการไฟฟ้าจึงเป็นสิ่งสำคัญที่สุด

ในงานวิจัย [1, 2] นำเสนอแบบจำลองทางสถิติในการพยากรณ์ความต้องการไฟฟ้า โดยใช้แบบจำลองอาร์มีมา (Autoregressive integrated moving average) และงานวิจัย [2] ได้เพิ่มประสิทธิภาพโดยใช้แบบจำลองอาร์มีมา ร่วมกับการถดถอยแบบเกาส์ (Gaussian process regression) เพื่อจัดการกับข้อมูลที่เป็นเชิงเส้นและไม่เชิงเส้น และงานวิจัย [3] ใช้ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) เพื่อพยากรณ์ค่าความต้องการไฟฟ้าสูงสุดรายวัน นอกจากนี้งานวิจัย [4, 5] ใช้การจัดกลุ่มแบบเคมีนส์ (K-means Clustering) เพื่อแบ่งกลุ่มของข้อมูลก่อนนำเข้าแบบจำลองที่แตกต่างกันในการพยากรณ์ ในงานวิจัย [4] ใช้หลักการจัดกลุ่มและการจำแนกประเภท โดยใช้การจัดกลุ่มแบบเคมีนส์และวิธีการเพื่อนบ้านใกล้สุด K ลำดับ (k-nearest neighbor) จากนั้นนำเข้าแบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network) และในงานวิจัย [5] ใช้หลักการป่าแบบสุ่ม (Random Forest) ส่วนในงานวิจัย [6] ใช้ต้นไม้ถดถอยด้วยวิธีการแบค (Bagged Regression Tree) และโครงข่ายประสาทเทียม พบว่าโครงข่ายประสาทเทียมสามารถพยากรณ์ได้แม่นยำมากกว่าในชุดข้อมูลทดสอบเดียวกัน ในขณะที่งานวิจัย [7] ใช้โครงข่ายประสาทเทียมร่วมกับซัพพอร์ตเวกเตอร์แมชชีน

ในปัจจุบัน การเรียนรู้เชิงลึกเป็นเทคนิคที่ได้รับความนิยมในงานวิจัยส่วนมาก เช่นงานวิจัย [8, 9] ใช้โครงข่ายประสาทเทียมเชิงลึก (Deep Neural Network) และในงานวิจัย [10] นำเสนอเทคนิคซัพพอร์ตเวกเตอร์แมชชีนร่วมกับโครงข่ายประสาทเทียมเชิงลึก นอกจากนี้ในงานวิจัย [11] ใช้นิวรอลเน็ตเวิร์กแบบคอนโวลูชัน (Convolutional Neural Network) และชั้นการเชื่อมโยงเต็มรูปแบบ (fully connected) ในขณะที่ [12, 13] ใช้นิวรอลเน็ตเวิร์กแบบวงกลับ (Recurrent Neural Network) ซึ่งในงานวิจัย [12] ใช้นิวรอลเน็ตเวิร์กแบบวงกลับร่วมกับเทคนิคการจัดกลุ่ม การเข้ารหัสและการถอดรหัส ส่วนงานวิจัย [13] ใช้เทคนิคการเรียนรู้เชิงลึก โดยนำเสนอแบบจำลองนิวรอลเน็ตเวิร์กแบบวงกลับต่อกันหลายชั้น

และงานวิจัย [14] นำเสนอหน่วยความจำระยะสั้นแบบยาว (Long-Short Term Memory) ทำงานร่วมกับนิรอรอลเน็ตเวิร์กแบบวงกลับ ขณะที่งานวิจัย [15, 16] ใช้เวฟเลท (Wavelet) เป็นส่วนหนึ่งของแบบจำลองที่นำเสนอ งานวิจัย [17] ใช้นิรอรอลเน็ตเวิร์กแบบคอนโวลูชันร่วมกับหน่วยความจำระยะสั้นแบบยาว โดยพิจารณาความสัมพันธ์ของคุณลักษณะต่างๆที่นำเข้าแบบจำลอง เพื่อพยากรณ์ค่าความต้องการไฟฟ้า และในงานวิจัย [18] นำเสนอแบบจำลองแบบขนานที่ประกอบด้วยนิรอรอลเน็ตเวิร์กแบบคอนโวลูชันและนิรอรอลเน็ตเวิร์กแบบวงกลับ

จากงานวิจัยที่กล่าวมาทั้งหมดข้างต้นพบว่าการเรียนรู้เชิงลึกมีประสิทธิภาพที่ดีกว่าการเรียนรู้ของเครื่อง (machine learning) และแบบจำลองทางสถิติ (statistic model) โดยในงานวิจัยนี้มีจุดประสงค์เพื่อพยากรณ์ความต้องการไฟฟ้าในวันถัดไปรายครึ่งชั่วโมง รวม 48 ช่วงเวลาล่วงหน้า และเนื่องจากปริมาณความต้องการไฟฟ้าได้รับผลกระทบจากหลายองค์ประกอบ และเทคนิคที่มิงงานวิจัยนำเสนอก่อนหน้านี้ให้ความสนใจกับผลกระทบจากช่วงเวลาก่อนหน้าเท่านั้น ไม่ได้ให้ความสำคัญที่แตกต่างกันต่อคุณลักษณะที่แตกต่างกัน โดยที่บางคุณลักษณะมีผลต่อผลเฉลย และสามารถเพิ่มประสิทธิภาพในการพยากรณ์มากกว่าคุณลักษณะที่เหลือ หากแบบจำลองไม่สามารถพิจารณาได้ว่าคุณลักษณะใดที่มีความสำคัญมากกว่าคุณลักษณะอื่น จะทำให้แบบจำลองให้ความสนใจกับคุณลักษณะที่มีสำคัญมากและมีความสำคัญน้อยเท่าเทียมกัน

กลไกจุดสนใจ 2 ชั้นร่วมกับนิรอรอลเน็ตเวิร์กแบบวงกลับ (A Dual-Stage Attention-Based Recurrent Neural Network หรือ DA-RNN) [19] เป็นแบบจำลองที่ทันสมัย (state of the art) ในด้านการพยากรณ์ข้อมูลอนุกรมเวลา และพิจารณาทั้งผลกระทบจากช่วงเวลาและคุณลักษณะที่แตกต่างกันที่มีผลต่อข้อมูลในอนาคต สำหรับการพยากรณ์ข้อมูลล่วงหน้า 1 ช่วงเวลา แต่งานวิจัยนี้ต้องการพยากรณ์ข้อมูลล่วงหน้าหลายช่วงเวลา จึงต้องปรับปรุงแบบจำลองให้สามารถพยากรณ์ข้อมูลล่วงหน้าหลายช่วงเวลาได้

นอกจากนั้นงานวิจัยที่กล่าวมาข้างต้น มีการใช้ฟังก์ชันต้นทุนที่นิยม ซึ่งพิจารณาให้ค่าของฟังก์ชันต้นทุนสำหรับข้อมูลพยากรณ์ที่มีค่าสูงกว่าผลเฉลยและข้อมูลพยากรณ์ที่มีค่าต่ำกว่าผลเฉลยเท่าเทียมกัน ซึ่งความเป็นจริงในการวางแผนผลิตไฟฟ้า การพยากรณ์ที่ต่ำกว่าผลเฉลยจะส่งผลกระทบต่อที่รุนแรงกว่าการพยากรณ์ที่สูงกว่าผลเฉลย เนื่องจากจะเพิ่มโอกาสการเกิดไฟฟ้าดับได้ และมีผลต่อเนื่องถึงระบบเศรษฐกิจด้วย ซึ่งมีหลายงานวิจัยที่พิจารณาถึงผลกระทบที่แตกต่างของการพยากรณ์สูงกว่าและต่ำกว่าผลเฉลย โดยการใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร (asymmetric loss function) ซึ่งในงานวิจัย [20-23] ประยุกต์ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรกับปัญหาต่างๆ และพบว่าการใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรสามารถเพิ่มประสิทธิภาพของแบบจำลองได้ และทำให้การพยากรณ์เหมือนกับในสถานการณ์จริงมากยิ่งขึ้น ซึ่งแต่ละงานวิจัยมีการออกแบบฟังก์ชันต้นทุนที่แตกต่างกัน เพื่อให้เหมาะสมกับปัญหาที่ต้องการในแต่ละงานวิจัย

งานวิจัยนี้จะปรับปรุงกลไกจุดสนใจ 2 ชั้นร่วมกับนิรอรอลเน็ตเวิร์กแบบวงกลับที่งานวิจัย [19] นำเสนอให้สามารถพยากรณ์ข้อมูลอนุกรมเวลาแบบหลายช่วงเวลาล่วงหน้าได้ เนื่องจากการพยากรณ์ความต้องการไฟฟ้ามีหลายองค์ประกอบที่เกี่ยวข้อง และมีความสัมพันธ์กับข้อมูลความต้องการไฟฟ้าในอดีต งานวิจัยนี้จึงนำแบบจำลองที่งานวิจัย [19] นำเสนอมาปรับปรุง เพราะแบบจำลองนี้พิจารณาให้ความสำคัญที่แตกต่างกันสำหรับคุณลักษณะที่แตกต่างกัน และพิจารณาให้ความสำคัญของช่วงเวลาที่แตกต่างกันได้ โดยใช้หลักการให้ค่าความน่าสนใจ (Attention weight) กับคุณลักษณะแต่ละตัวและช่วงเวลาแต่ละช่วงเวลาได้ นอกจากนั้นมีการพิจารณาถึงความเป็นจริงของการพยากรณ์ความต้องการไฟฟ้า จึงจะมีการใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร โดยจะออกแบบฟังก์ชันต้นทุนให้เหมาะสมกับการพยากรณ์ความต้องการไฟฟ้าด้วย นอกจากนั้นในปัจจุบันโรงไฟฟ้าพลังงานหมุนเวียนมีเพิ่ม

มากขึ้นเรื่อย ๆ จึงมีแนวคิดที่จะเพิ่มความเร็วลม และข้อมูลฝนเป็นคุณลักษณะเพิ่มเติมในการพยากรณ์ความต้องการไฟฟ้าเพื่อเพิ่มประสิทธิภาพในการพยากรณ์ ทั้งนี้ขอขอบคุณการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย และกรมอุตุนิยมวิทยาที่ให้การสนับสนุนข้อมูลในการทำงานวิจัยฉบับนี้

1.2 วัตถุประสงค์ของงานวิจัย

เพื่อนำเสนอวิธีการพยากรณ์ความต้องการไฟฟ้าของประเทศไทย โดยใช้แบบจำลองการเรียนรู้เชิงลึกที่สามารถพิจารณาความสำคัญของแต่ละคุณลักษณะที่แตกต่างกัน และความสัมพันธ์ของแต่ละคุณลักษณะที่เกี่ยวข้องกัน รวมถึงพิจารณาข้อมูลของช่วงเวลาในอดีตที่มีความสำคัญต่อข้อมูลอนาคตได้ เพื่อเพิ่มประสิทธิภาพในการพยากรณ์ โดยมุ่งเน้นการปรับปรุงแบบจำลองการเรียนรู้เชิงลึกให้สามารถพยากรณ์ความต้องการไฟฟ้าล่วงหน้า 48 ชั่วโมงให้มีความคลาดเคลื่อนน้อยที่สุด

1.3 ขอบเขตการวิจัย

1. งานวิจัยฉบับนี้ครอบคลุมเฉพาะการพยากรณ์ความต้องการไฟฟ้าของประเทศไทยเท่านั้น
2. ข้อมูลความต้องการไฟฟ้าของประเทศไทยที่ใช้ในงานวิจัยฉบับนี้ นำมาจากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย
3. ข้อมูลเกี่ยวกับอากาศใช้ในงานวิจัยฉบับนี้ นำมาจากกรมอุตุนิยมวิทยา
4. ทำการวัดประสิทธิภาพของแบบจำลองโดยการพิจารณาค่าความคลาดเคลื่อนเฉลี่ยจากการพยากรณ์ในแต่ละช่วงเวลาล่วงหน้า
5. เปรียบเทียบประสิทธิภาพของแบบจำลองกับแบบจำลองโครงข่ายประตูกลับสองทิศทาง หน่วยความจำระยะสั้นแบบยาว และนิเวรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาวโดยใช้ข้อมูลชุดเดียวกัน

1.4 ประโยชน์ที่ได้รับ

1. สามารถเพิ่มประสิทธิภาพการพยากรณ์ความต้องการไฟฟ้าจากระบบไฟฟ้าของประเทศไทยได้
2. สามารถช่วยในการบริหารจัดการระบบไฟฟ้าได้
3. สามารถลดค่าใช้จ่ายในการผลิตไฟฟ้าที่มากเกินไปจนความจำเป็นได้
4. สามารถวางแผนผลิตไฟฟ้าที่เหมาะสมได้
5. สามารถลดความเสี่ยงต่อการเกิดไฟฟ้าดับได้
6. สามารถนำกรอบงานวิจัยนี้ไปประยุกต์กับข้อมูลอื่น ๆ ที่มีลักษณะคล้ายกันได้

1.5 วิธีดำเนินงานวิจัย

1. ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง
2. ศึกษาเกี่ยวกับโครงข่ายประสาทเทียม และการเรียนรู้เชิงลึก
3. สร้างวิธีการทดลอง พัฒนาแบบจำลอง และเก็บผลการทดลอง
4. สรุปผลการทดลองทั้งหมด
5. สอบหัวข้อวิทยานิพนธ์
6. ทำการทดลองตามสิ่งที่นำเสนอ
7. ปรับค่าพารามิเตอร์ของแบบจำลองเพื่อให้ได้ประสิทธิภาพดีที่สุด
8. เขียนบทความเพื่อตีพิมพ์ผลงานทางวิชาการ
9. สรุปผลและเรียบเรียงวิทยานิพนธ์
10. สอบวิทยานิพนธ์



1.6 ผลงานวิจัยที่ตีพิมพ์

“Multi-step Power Consumption Forecasting in Thailand Using Dual-Stage Attentional LSTM” โดย ชุขวัญ สิริทิพากุล และ พีรพล เวทีกุล ในงานประชุมวิชาการ “2019 11th International Conference on Information Technology and Electrical Engineering (ICITEE)” ซึ่งจัดขึ้น ณ โรงแรมฮอติเดย์ อินน์ พัทยา จังหวัดชลบุรี ประเทศไทย ระหว่างวันที่ 10-11 ตุลาคม 2562

“Enhance Attentional LSTM Models for Power Consumption Forecasting Using Asymmetric Loss and Renewable Energy Factors” โดย ชุขวัญ สิริทิพากุล และ พีรพล เวทีกุล ในงานประชุมวิชาการ “The 8th International Conference on Computer and Communications Management (ICCCM 2020)” ซึ่งจัดขึ้น ณ ประเทศสิงคโปร์ ระหว่างวันที่ 17-19 กรกฎาคม 2563



บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

ทฤษฎีที่เกี่ยวข้องกับงานวิจัยนี้แบ่งออกได้เป็น 3 หัวข้อ ได้แก่ นิวรอลเน็ตเวิร์ก นิวรอลเน็ตเวิร์กเชิงลึก และกลไกจุดสนใจ

2.1 นิวรอลเน็ตเวิร์ก (Neural Network)

เป็นแบบจำลองที่ได้รับแรงบันดาลใจจากสมองของมนุษย์ โดยสามารถเรียนรู้จากชุดข้อมูลฝึกสอนเพื่อใช้พยากรณ์ข้อมูลทดสอบที่ไม่เคยเห็นขั้นตอนการฝึกสอนได้เป็นอย่างดี ในหัวข้อนี้จะอธิบายถึงฟังก์ชันต้นทุนที่นิยมใช้ และฟังก์ชันซึ่งมีการนำมาประยุกต์เพื่อใช้งานในงานวิจัยนี้

ฟังก์ชันต้นทุน (Loss function หรือ Cost Function หรือ Objective function) เป็นฟังก์ชันที่แสดงถึงต้นทุนของนิวรอลเน็ตเวิร์ก กล่าวคือในกระบวนการเรียนรู้ของนิวรอลเน็ตเวิร์กนั้น จะทำการปรับค่าน้ำหนักเพื่อที่จะลดค่าของฟังก์ชันต้นทุน โดยปกติฟังก์ชันต้นทุนของการพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลย จะใช้สูตรการคำนวณค่าฟังก์ชันต้นทุนเดียวกัน แม้ว่าในบางปัญหานั้นการพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลยให้ผลกระทบที่แตกต่างกัน ซึ่งฟังก์ชันต้นทุนที่เป็นที่นิยมมีดังต่อไปนี้ กำหนดให้ J แทนฟังก์ชันต้นทุน n คือ จำนวนข้อมูลทั้งหมดที่ใช้ในการเรียนรู้ y_i แทนผลลัพธ์จริงที่ได้จากชุดข้อมูลที่ i และ \hat{y}_i แทนผลลัพธ์ที่ทำนายได้จากข้อมูลชุดที่ i

- 1) ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Squared Error หรือ MSE)

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

- 2) ค่าเฉลี่ยครอสเอนโทรปีแบบทวิภาค (Binary Cross-entropy)

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

- 3) ค่าลบลอการิทึมของความเป็นไปได้ (Negative Log-Likelihood)

$$J = -\frac{1}{n} \sum_{i=1}^n y_i \log(\hat{y}_i) \quad (3)$$


โดยในงานวิจัยนี้ จะนำฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสองมาประยุกต์เพื่อใช้ในแบบจำลองสำหรับพยากรณ์ความต้องการไฟฟ้า เนื่องจากฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสองเป็นฟังก์ชันที่คำนวณค่าฟังก์ชันต้นทุน โดยค่าพยากรณ์ที่สูงกว่าผลเฉลยจะไม่หักล้างกับค่าพยากรณ์ที่ต่ำกว่าผลเฉลย

2.2 นิวรอลเน็ตเวิร์กเชิงลึก (Deep Neural Network)

คือ นิวรอลเน็ตเวิร์กที่มีชั้นซ่อน (Hidden Layer) จำนวนหลาย ๆ ชั้น ทำให้สามารถเรียนรู้คุณลักษณะ (Feature) ที่ซ่อนอยู่ในข้อมูลนำเข้าได้ดี จึงมีความแตกต่างกับนิวรอลเน็ตเวิร์กทั่วไปที่จะต้องสกัดข้อมูลตัวแทนก่อนนำเข้านิวรอลเน็ตเวิร์ก โดยนิวรอลเน็ตเวิร์กเชิงลึกที่ใช้ในงานวิจัยนี้ มีดังต่อไปนี้

2.2.1 นิวรอลเน็ตเวิร์กแบบวงกลับ (Recurrent Neural Network)

เป็นนิวรอลเน็ตเวิร์กที่ประมวลผลข้อมูลนำเข้าตามลำดับ จึงเหมาะสมกับปัญหาที่เกี่ยวข้องกับข้อมูลที่เป็นลำดับต่อเนื่อง (Sequence) ซึ่งในกระบวนการเรียนรู้จะมีการส่งต่อข้อมูลผลลัพธ์จากการประมวลผลในช่วงก่อนหน้าไปยังช่วงถัดไป โดยมีโครงสร้างนิวรอลเน็ตเวิร์กแสดงดังรูปที่ 1



รูปที่ 1 โครงสร้างนิวรอลเน็ตเวิร์กแบบวงกลับ

[ที่มา: <http://www.wildml.com/2015/09/recurrent-neural-networks-tutorial-part-1-introduction-to-rnns/> Accessed: August 15, 2019]

กำหนดให้ x_t แทนข้อมูลนำเข้าในช่วงเวลาที่ t ของชุดข้อมูลใด ๆ U แทนค่าน้ำหนักสำหรับข้อมูลนำเข้าในช่วงเวลา t ใด ๆ W แทนค่าน้ำหนักวงกลับ (Recurrent Weight) s_t แทนสถานะซ่อน (Hidden State) ในช่วงเวลาที่ t ใด ๆ V แทนค่าน้ำหนักของข้อมูลออก และ o_t แทนข้อมูลออกหลังจากรับข้อมูลนำเข้าในช่วงเวลาที่ t โดยผลลัพธ์ที่ได้จากข้อมูลนำเข้าแต่ละลำดับข้อมูลสามารถคำนวณได้จากสมการดังต่อไปนี้

$$s_t = \sigma(ws_{t-1} + Ux_t + b) \quad (4)$$


$$o_t = \sigma(vs_t + b) \quad (5)$$

โดย α แทนฟังก์ชันกระตุ้นในขั้นตอนการคำนวณข้อมูลออก ณ ลำดับใด ๆ และ b แทนไบแอส

ในการฝึกสอนจะใช้วิธีการแพร่กระจายย้อนกลับตามเวลา (Back Propagation Through Time หรือ BPTT) เพื่อปรับค่าน้ำหนัก ซึ่งหากความยาวของข้อมูลนำเข้ามีมากเกินไป อาจจะทำให้เกิดปัญหาเนื่องจากเกรเดียนของน้ำหนักวงกลับ W ซึ่งเกิดจากการคูณกันของลำดับก่อนหน้าที่ทำให้การแพร่กระจายย้อนกลับที่ค่าน้ำหนักของหน่วยย่อยบางหน่วยเปลี่ยนแปลงน้อยมาก จนแทบไม่มีการเปลี่ยนแปลงส่งผลให้ค่าเกรเดียนเลือนหาย (Vanishing Gradient) หรืออาจจะกล่าวได้ว่านิวรอลเน็ตเวิร์กแบบวงกลับเกิดอาการลืมข้อมูลในอดีตที่เคยเรียนรู้มาก่อนหน้านี้

2.2.2 หน่วยความจำระยะสั้นแบบยาว (Long-Short Term Memory หรือ LSTM)

เป็นนิวรอลเน็ตเวิร์กที่ออกแบบมาเพื่อใช้แก้ปัญหาเกรเดียนเลือนหาย เมื่อความยาวของข้อมูลมีมากเกินไป โดยใช้แนวคิดของหน่วยความจำ (Memory) เข้ามาเป็นส่วนประกอบ เพื่อให้นิวรอลเน็ตเวิร์กเลือกจำข้อมูลบางชุดเท่านั้น โดยมีโครงสร้างดังรูปที่ 2



รูปที่ 2 โครงสร้างหน่วยความจำระยะสั้นแบบยาว

[ที่มา: <https://medium.com/@saurabh.rathor092/simple-rnn-vs-gru-vs-lstm-difference-lies-in-more-flexible-control-5f33e07b1e57/> Accessed: August 15, 2019]

โดยที่สัญลักษณ์กรอบสี่เหลี่ยมผืนผ้าภายในหน่วยความจำหมายถึงนิรอลเน็ตเวิร์ก ซึ่งสัญลักษณ์ภายในคือ ฟังก์ชันกระตุ้นที่ใช้ในแต่ละขั้นตอน และสัญลักษณ์วงกลมสื่อถึงการกระทำเฉพาะข้อมูลในตำแหน่งที่ตรงกัน

การเรียนรู้ของหน่วยความจำระยะสั้นแบบยาวจะรับข้อมูลนำเข้าจากชั้นซ่อนในช่วงเวลาก่อนหน้า และข้อมูลนำเข้าในช่วงเวลาปัจจุบัน โดยอาศัยสถานะเซลล์ (Cell State) ในการส่งต่อการเรียนรู้ข้อมูลไปยังช่วงเวลาถัดไป เป็นการแก้ปัญหาค่าเกรเดียนต์หายได้ สำหรับการตัดสินใจของสถานะเซลล์จะขึ้นอยู่กับค่าที่จะได้รับจากประตูสัญญาณ (Gate) ซึ่งประกอบด้วย 3 ประตู ดังนี้

- 1) ประตูสัญญาณสำหรับข้อมูลนำเข้า (Input Gate) มีหน้าที่ประเมินความสำคัญของข้อมูลที่นำเข้ามาใหม่ สามารถคำนวณได้ตามสมการดังต่อไปนี้

$$i_t = \sigma(w_i \cdot [s_{t-1}, x_t] + b_i) \quad (6)$$

- 2) ประตูสัญญาณสำหรับการลืม (Forget Gate) มีหน้าที่ประเมินความสำคัญของข้อมูลที่เก็บอยู่ในสถานะเซลล์ว่าควรเก็บไว้หรือนำข้อมูลใหม่มาเก็บแทนที่ สามารถคำนวณได้จากสมการ

$$f_t = \sigma(w_f \cdot [s_{t-1}, x_t] + b_f) \quad (7)$$

- 3) ประตูสัญญาณสำหรับข้อมูลส่งออก (Output Gate)

$$o_t = \sigma(w_o \cdot [s_{t-1}, x_t] + b_o) \quad (8)$$

กำหนดให้ค่าสถานะเซลล์ ณ ช่วงเวลา t แทนด้วย c_t และข้อมูลสถานะซ่อน ณ ช่วงเวลา t แทนด้วย s_t โดยสามารถคำนวณได้จากสมการดังต่อไปนี้


$$c_t = f_t \circ c_{t-1} + (i_t \circ \tanh(w_c \cdot [s_{t-1}, x_t] + b_c)) \quad (9)$$

$$s_t = o_t \circ \tanh(c_t) \quad (10)$$

2.2.3 โครงข่ายประตูกกลับ (Gated Recurrent Unit หรือ GRU)

เป็นนิรอลเน็ตเวิร์กที่มีลักษณะคล้ายกับหน่วยความจำระยะสั้นแบบยาว แต่จะรวมประตูสัญญาณสำหรับข้อมูลนำเข้า และประตูสัญญาณสำหรับข้อมูลส่งออก กลายเป็นประตูสัญญาณอัปเดต (Update Gate)

และสถานะเซลล์รวมกับข้อมูลชั้นซ่อน S_t ส่งผลให้เหลือประตูสัญญาณเพียง 2 ประตู นอกจากนั้นประตูสัญญาณสำหรับการลืมจะใช้ชื่อว่าประตูสัญญาณรีเซ็ต (Reset Gate) โดยมีโครงสร้างแสดงดังรูปที่ 3



รูปที่ 3 โครงสร้างโครงข่ายประตูกลับ

[ที่มา: <https://medium.com/@saurabh.rathor092/simple-rnn-vs-gru-vs-lstm-difference-lies-in-more-flexible-control-5f33e07b1e57/> Accessed: August 15, 2019]

และมีสมการการคำนวณดังนี้

$$z_t = \sigma(w_z \cdot [s_{t-1}, x_t] + b_z) \quad (11)$$


$$r_t = \sigma(w_r \cdot [s_{t-1}, x_t] + b_r) \quad (12)$$

$$s_t = (1 - z_t) \circ s_{t-1} + z_t \circ (\tanh(w \cdot [r_t \circ s_{t-1}, x_t])) \quad (13)$$

โดย Z_t คือประตูสัญญาณอัปเดต และ r_t คือประตูสัญญาณรีเซ็ต

2.2.4 นิวรอลเน็ตเวิร์กคอนโวลูชัน (Convolutional Neural Network หรือ CNN)

นิวรอลเน็ตเวิร์กคอนโวลูชันเป็นนิวรอลเน็ตเวิร์กเชิงลึก จะแปลงข้อมูลนำเข้าเป็นเมตริกซ์แล้วนำเข้านิวรอลเน็ตเวิร์ก และจะใช้ตัวกรอง (filter) เพื่อสร้างฟีเจอร์ใหม่ (Feature Map) เพื่อเป็นข้อมูลนำเข้าของชั้นถัดไป โครงสร้างของนิวรอลเน็ตเวิร์กคอนโวลูชันเกิดจากการนำชั้นหลายๆประเภทมาประกอบเข้าด้วยกันแสดงดังรูปที่ 4



รูปที่ 4 โครงสร้างนิวรอลเน็ตเวิร์กคอนโวลูชัน

[ที่มา: <https://brilliant.org/wiki/convolutional-neural-network/> Accessed: August 15, 2019]

โดยข้อมูลรายละเอียดของชั้นต่าง ๆ ในนิวรอลเน็ตเวิร์กคอนโวลูชัน

1) ชั้นคอนโวลูชัน (Convolutional Layer)

มีหน้าที่หาฟีเจอร์ของกลุ่มข้อมูลใกล้เคียงกัน โดยใช้ผลคูณเชิงสเกลาร์ (dot product) ของเมตริกซ์กับตัวกรอง (filter) โดยที่ค่าน้ำหนักของตัวกรองจะใช้ร่วมกันในทุก ๆ การทำคอนโวลูชัน จำนวนผลลัพธ์ที่ได้จะเท่ากับจำนวนของตัวกรองที่ใช้ ซึ่งหลังจากการทำคอนโวลูชันจะมีการใช้ฟังก์ชันกระตุ้น และส่งผลลัพธ์ที่ได้ไปเป็นข้อมูลนำเข้าสำหรับเน็ตเวิร์กชั้นต่อไป โดยตัวอย่างแสดงดังรูปที่ 5

15	30	70	11	1	0	-1	-100	
7	20	37	70	1	0	-1		
15	8	30	12	1	0	-1		
20	9	25	13					

Input Kernel Output

รูปที่ 5 การทำคอนโวลูชันแบบแคบที่มีขนาดของตัวกรอง คือ 3x3

ในการทำคอนโวลูชันมีองค์ประกอบต่าง ๆ ดังนี้

1.1) ขนาดของตัวกรอง (Filter Size)

ความกว้างและความสูงของตัวกรองที่จะนำมาใช้


1.2) ชนิดของการทำคอนโวลูชัน (Convolution Type)

- คอนโวลูชันแบบแคบ (Narrow Convolution)

การทำคอนโวลูชันชนิดนี้นิยมใช้กันทั่วไป โดยตัวกรองที่นำมาจะไม่มีการทำเลเยอร์ของเมตริกซ์ของข้อมูลนำเข้าโดยผลลัพธ์ที่ได้จากข้อมูลนำเข้าที่มีขนาด $N \times N$ กับตัวกรองที่มีขนาด $M \times M$ จะได้เมตริกซ์ขนาด $(N-M+1) \times (N-M+1)$ แสดงตัวอย่างดังรูปที่ 5

- คอนโวลูชันแบบกว้าง (Wide Convolution)


การทำคอนโวลูชันชนิดนี้มีการกระทำเลขขอบเมตริกซ์ของข้อมูลนำเข้า เพื่อป้องกันการสูญเสียข้อมูลบริเวณขอบของข้อมูลนำเข้า โดยจะแทนค่า 0 ในพื้นที่ส่วนที่เกินขอบเมตริกซ์ เรียกว่า การเสริมเติม(Padding) และผลลัพธ์ที่ได้จากข้อมูลนำเข้าขนาด $N \times N$ กับตัวกรองขนาด $M \times M$ จะได้เมตริกซ์ขนาด $(N+M-1) \times (N+M-1)$ แสดงตัวอย่างดังรูปที่ 6



รูปที่ 6 การทำคอนโวลูชันแบบกว้างที่มีขนาดของตัวกรอง คือ 3×3 และมีการเสริมเติม

1.3) ขนาดของการก้าวข้าม (Stride Size)


จำนวนช่องของข้อมูลนำเข้าที่จะเลื่อนไปเมื่อทำการหาผลลัพธ์ของการคอนโวลูชันในแต่ละช่อง โดยทั่วไปจะใช้ขนาดเป็น 1 แสดงตัวอย่างดังรูปที่ 7



รูปที่ 7 การทำคอนโวลูชันที่ข้อมูลนำเข้าขนาด 4×4 ตัวกรองขนาด 2×2 และมีขนาดของการก้าวข้ามเป็น 2

1.4) จำนวนตัวกรอง (Number of Filters)

จำนวนของตัวกรองที่ใช้ในแต่ละชั้นสามารถมีได้มากกว่าหนึ่งตัว โดยน้ำหนักของแต่ละตัวมีความแตกต่างกันได้ การกำหนดจำนวนตัวกรอง จะเป็นการกำหนดจำนวนช่องสัญญาณของข้อมูลนำเข้าในชั้นถัดไป




รูปที่ 8 การทำคอนโวลูชันโดยมีจำนวนตัวกรองเท่ากับ 2

1.5) จำนวนช่องสัญญาณ (Channel)

ความลึกของข้อมูลนำเข้า เช่น ในการวิจัยทางด้านรูปภาพที่มีการใช้ช่องสัญญาณ 3 ช่องแทนค่าของแม่สี 3 สี หรืออาจเกิดจากจำนวนของตัวกรองในชั้นคอนโวลูชันก่อนหน้า

2) ชั้นการรวม (Pooling Layer)


มีหน้าที่ลดขนาดของข้อมูลให้เหลือเฉพาะข้อมูลที่มีความสำคัญเท่านั้น ซึ่งนิยมนำมาต่อจากชั้นคอนโวลูชัน โดยทั่วไปใช้การเลือกข้อมูลที่มีค่ามากที่สุด (Max Pooling) หรือ ค่าเฉลี่ย (Average Pooling) มาจากแต่ละช่วงของเมตริกซ์เพื่อสร้างเป็นเมตริกซ์ใหม่ที่มีขนาดเล็กลง ดังรูปที่ 9



รูปที่ 9 ตัวอย่างชั้นการรวมโดยค่าที่มากที่สุดและค่าเฉลี่ย

3) ชั้นการเชื่อมโยงเต็มรูปแบบ (Fully Connected Layer)

เป็นการเชื่อมโยงเต็มรูปแบบ หลังจากชั้นคอนโวลูชันและชั้นการรวม โดยจะประกอบด้วยชั้นย่อย ๆ ที่มีเพอร์เซ็ปตรอนอยู่จำนวนหนึ่ง โดยที่เพอร์เซ็ปตรอนทุกตัวจะมีเส้นเชื่อมกับเพอร์เซ็ปตรอนทุกตัวในชั้นก่อนหน้าและชั้นถัดไป ทำให้สามารถคำนวณการป้อนไปข้างหน้าและการแพร่กระจายย้อนกลับได้ แสดงดังรูปที่ 10



รูปที่ 10 ชั้นการเชื่อมโยงเต็มรูปแบบ

2.3 กลไกจุดสนใจ (Attention Mechanism)

หลักการคือการถ่วงน้ำหนักให้ข้อมูลแต่ละตัว เพื่อให้แบบจำลองสามารถทราบได้ว่าควรให้ความสนใจกับข้อมูลตัวใดมากหรือน้อย ซึ่งจะสร้างความน่าสนใจ (Attention) ให้กับข้อมูลทุกตัวในชุดข้อมูล โดยใช้ฟังก์ชันค่าสูงสุดอย่างอ่อน (Softmax function) ดังนั้นผลรวมของค่าความน่าสนใจของทุกตัวรวมกันจะเท่ากับ 1 จากนั้นนำค่าความน่าสนใจที่ได้ไปคูณกับข้อมูลแต่ละตัว เพื่อสร้างเวกเตอร์ผลลัพธ์สำหรับนำไปใช้กับแบบจำลองนิเวศเน็ตเวิร์กต่อไป ซึ่งจะช่วยให้แบบจำลองสามารถทราบได้ว่าข้อมูลตัวใดควรจะให้คะแนนใจมาก และข้อมูลตัวใดควรจะให้คะแนนใจน้อย เมื่อแบบจำลองสามารถให้ความสนใจมากกับข้อมูลที่น่าสนใจจะทำให้ช่วยเพิ่มประสิทธิภาพในการพยากรณ์ได้

$$\alpha_t^n = \frac{\exp(e_t^n)}{\sum_{i=1}^k \exp(e_t^i)} \quad (14)$$

บทที่ 3

งานวิจัยที่เกี่ยวข้อง

งานวิจัยที่เกี่ยวข้องกับวิทยานิพนธ์ฉบับนี้ มีหลายงานวิจัย ซึ่งงานวิจัยแต่ละงานจะมีโครงสร้างแบบจำลองที่แตกต่างกัน และมีจุดประสงค์ของงานวิจัยที่ต่างกัน ในหัวข้อนี้จะแบ่งงานวิจัยออกเป็น 2 กลุ่มได้แก่ 1) งานวิจัยที่เกี่ยวข้องกับการพยากรณ์ข้อมูลอนุกรมเวลา และ 2) งานวิจัยที่เกี่ยวข้องกับการใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร

3.1 งานวิจัยที่เกี่ยวข้องกับการพยากรณ์ข้อมูลอนุกรมเวลา


งานวิจัยที่เกี่ยวข้องกับการพยากรณ์ข้อมูลอนุกรมเวลาจะแบ่งออกเป็น 2 กลุ่มได้แก่ 1) แบบจำลองการเรียนรู้เชิงลึกที่พยากรณ์ล่วงหน้า 1 ช่วงเวลา และ 2) แบบจำลองการเรียนรู้เชิงลึกที่พยากรณ์ล่วงหน้าหลายช่วงเวลา

3.1.1 แบบจำลองการเรียนรู้เชิงลึกที่พยากรณ์ล่วงหน้า 1 ช่วงเวลา

งานวิจัยในหัวข้อนี้ เป็นงานวิจัยที่นำเสนอแบบจำลองการเรียนรู้เชิงลึก เพื่อพยากรณ์ข้อมูลล่วงหน้า 1 ช่วงเวลา เช่น ปริมาณการผลิตน้ำมัน ราคาหุ้น เป็นต้น

งานวิจัย Ashour และคณะ [24] ได้นำโครงข่ายประสาทเทียมเอลแมน (Elman Neural Network) มาใช้พยากรณ์ปริมาณการผลิตน้ำมันในวันถัดไป และเปรียบเทียบผลการพยากรณ์กับแบบจำลองทางสถิติ คือ อาริมา ผลลัพธ์จากการทดลองพบว่า โครงข่ายประสาทเทียมเอลแมนสามารถพยากรณ์ได้แม่นยำกว่าอาริมา และสามารถเพิ่มความแม่นยำสำหรับการพยากรณ์ค่าอนุกรมเวลาได้ เนื่องจากโครงข่ายประสาทเทียมเอลแมนสามารถเรียนรู้ได้ด้วยตัวเองและมีความยืดหยุ่น นอกจากนั้นสามารถจัดการกับข้อมูลที่มีลักษณะผิดปกติให้พยากรณ์ได้แม่นยำขึ้นได้

งานวิจัยของ Qin และคณะ [19] นำเสนอแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวกกลับ (A Dual-Stage Attention-Based Recurrent Neural Network หรือ DA-RNN) สำหรับการพยากรณ์ราคาหุ้นในวันถัดไป แบบจำลองที่งานวิจัยนี้นำเสนอประกอบด้วยกลไกจุดสนใจ 2 ชั้น โดยกลไกจุดสนใจชั้นที่หนึ่งใช้สำหรับให้ค่าความน่าสนใจกับแต่ละคุณลักษณะที่นำเข้ามาแบบจำลอง และพิจารณาแต่ละคุณลักษณะด้วยค่าความน่าสนใจที่ต่างกัน จากนั้นนำผลลัพธ์ที่ได้ไปเข้าหน่วยความจำระยะสั้นแบบยาว และกลไกจุดสนใจชั้นที่สองจะพิจารณาผลกระทบที่แตกต่างกันของแต่ละช่วงเวลาและส่งผลกระทบต่อค่าในอนาคต โดยใช้หลักการให้ค่าความน่าสนใจ จากนั้นนำเข้าหน่วยความจำระยะสั้นแบบยาวเพื่อพยากรณ์ข้อมูลในอนาคต งานวิจัยนี้สามารถเพิ่มความแม่นยำในการพยากรณ์ข้อมูลอนุกรมเวลาได้ เมื่อเปรียบเทียบกับงานวิจัยที่พิจารณาเพียงแค่ผลกระทบที่แตกต่างกันของแต่ละช่วงเวลาและส่งผลกระทบต่อค่าในอนาคต แต่แบบจำลองนี้ไม่สามารถพยากรณ์แบบหลายช่วงเวลาได้ เนื่องจากในกลไกจุดสนใจชั้นที่สอง จำเป็นต้องใช้ข้อมูลจริงในอดีตในการพยากรณ์ช่วงเวลาลัดไป นอกจากนั้นงานวิจัยนี้ไม่ได้พิจารณาความสัมพันธ์ของแต่ละคุณลักษณะที่เกี่ยวข้องกัน ทำให้สามารถพัฒนาประสิทธิภาพในส่วนนี้ได้ โดยโครงสร้างของแบบจำลองจากงานวิจัย [19] แสดงดังรูปที่ 11



รูปที่ 11 แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์กแบบวงกลับ

3.1.2 แบบจำลองการเรียนรู้เชิงลึกที่พยากรณ์ล่วงหน้าหลายช่วงเวลา

งานวิจัยในหัวข้อนี้ เป็นงานวิจัยที่นำเสนอแบบจำลองการเรียนรู้เชิงลึก เพื่อพยากรณ์ข้อมูลล่วงหน้าหลายช่วงเวลา เพื่อวางแผนการทำงานบางอย่าง เช่น การวางแผนปริมาณการใช้เชื้อเพลิง ความต้องการไฟฟ้า เป็นต้น

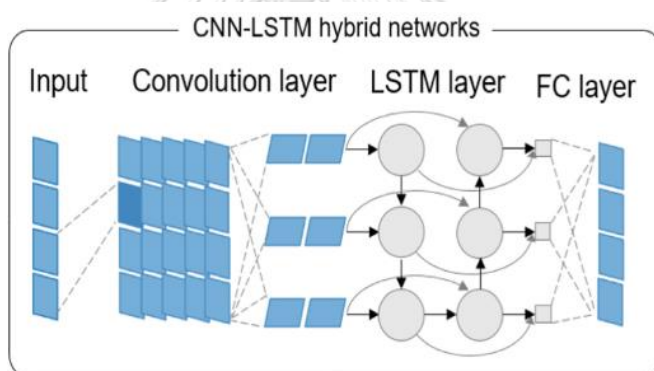
งานวิจัยของ Seunghyoung และคณะ [9] นำเสนอแบบจำลองที่ใช้เทคนิคการเรียนรู้เชิงลึก 2 แบบจำลอง คือ นิวรอลเน็ตเวิร์กเชิงลึกร่วมกับเครื่องจักรโบลทซ์มันน์ (Restricted Boltzmann Machine) ที่มีการเรียนรู้ก่อนด้วยฟังก์ชันซิกมอยด์ และนิวรอลเน็ตเวิร์กเชิงลึกโดยใช้เรคตีไฟต์เชิงเส้น (ReLU) เป็นฟังก์ชันกระตุ้น และใช้การตรวจสอบแบบไขว้กัน (K-fold cross validation) จากนั้นนำผลการทดลองมาเปรียบเทียบกับแบบจำลองโครงข่ายประสาทแบบตื้น (Shallow Neural Network) วิธีปรับเรียบแบบโฮลท์-วินเทอร์ 2 ชั้นที่มีฤดูกาล (Double Seasonal Holt-Winters) และอาร์ีมา (ARIMA) ผลการทดลองพบว่าแบบจำลองที่นำเสนอที่มีการใช้เทคนิคการเรียนรู้เชิงลึกมีประสิทธิภาพมากกว่าแบบจำลองที่นำมาเปรียบเทียบ แต่ในงานวิจัยนี้จะสนใจเฉพาะวันทำงานเท่านั้น ไม่ได้พยากรณ์ความต้องการไฟฟ้าในวันหยุด

ในปี 2017 มีหลายงานวิจัยที่นำนิวรอลเน็ตเวิร์กแบบวงกลับไปใช้สำหรับปัญหาการพยากรณ์ความต้องการไฟฟ้าล่วงหน้าแบบหลายช่วงเวลา ในงานวิจัยของ Jarábek และคณะ [12] ใช้นิวรอลเน็ตเวิร์กแบบวงกลับร่วมกับเทคนิคการจัดกลุ่มและการเข้ารหัสและการถอดรหัส ส่วนในงานวิจัยของ Shi และคณะ [13] ใช้เทคนิคการเรียนรู้เชิงลึก โดยนำเสนอแบบจำลองนิวรอลเน็ตเวิร์กแบบวงกลับต่อกันหลายชั้น พบว่าแบบจำลองนิวรอลเน็ตเวิร์กแบบวงกลับต่อกันหลายชั้นสามารถพยากรณ์ได้แม่นยำกว่านิวรอลเน็ตเวิร์กแบบวงกลับแบบปกติ นอกจากนั้น [12] และ [13] ทดลองการพยากรณ์ความต้องการไฟฟ้าทั้งระบบและแยกส่วน พบว่าการพยากรณ์แบบแยกส่วนให้ความแม่นยำที่สูงกว่าการพยากรณ์ทั้งระบบในครั้งเดียว และในงานวิจัยของ He [18] นำเสนอแบบจำลองการเรียนรู้เชิงลึก โดยใช้แบบจำลองขนานที่ประกอบด้วยนิวรอลเน็ตเวิร์กแบบคอนโวลูชันและนิวรอลเน็ตเวิร์กแบบวงกลับ เพื่อพยากรณ์ค่าความต้องการไฟฟ้า โดยใช้ข้อมูลความต้องการไฟฟ้าในอดีต ข้อมูลด้านอากาศและเวกเตอร์วันฮอทที่แสดงถึงประเภทของวัน เป็นข้อมูลสำหรับนำเข้าแบบจำลองที่นำเสนอ จากนั้นนำไปเปรียบเทียบกับกรถถอยเชิงเส้น (linear regression) ซัพพอร์ตเวกเตอร์แมชชีน นิวรอลเน็ตเวิร์กเชิงลึก และนิวรอลเน็ตเวิร์กแบบวงกลับต่อกันหน่วยความจำระยะสั้นแบบยาว พบว่าแบบจำลองแบบขนานที่ประกอบด้วยนิวรอลเน็ตเวิร์กแบบคอนโวลูชันและนิวรอลเน็ตเวิร์กแบบวงกลับมีประสิทธิภาพดีที่สุด

ในปีเดียวกัน Yunpeng และคณะ [25] ใช้หน่วยความจำระยะสั้นแบบยาวในการแก้ปัญหาการพยากรณ์แบบหลายช่วงเวลากับหลายชุดข้อมูล พบว่าหน่วยความจำระยะสั้นแบบยาวมีประสิทธิภาพที่ดีกว่าอาร์มา และนิรอลเน็ตเวิร์กแบบทั่วไป

ในปี 2018 Agrawal และคณะ [14] นำเสนอแบบจำลองที่ประกอบด้วยหน่วยความจำระยะสั้นแบบยาวและนิรอลเน็ตเวิร์กแบบวนกลับ สำหรับพยากรณ์ข้อมูลความต้องการไฟฟ้ารายชั่วโมง โดยแบบจำลองที่นำเสนอสามารถเรียนรู้ลักษณะของข้อมูลทั้งระยะสั้นและระยะยาวได้ นอกจากนี้ Fang [26] ใช้หน่วยความจำระยะสั้นแบบยาวร่วมกับซัพพอร์ตเวกเตอร์แมชชีน โดยไม่ได้ให้ความสำคัญที่แตกต่างกันในแต่ละคุณลักษณะเช่นเดียวกับงานวิจัยอื่น ๆ ที่กล่าวมาข้างต้น

ในขณะที่ Kim [17] นำเสนอแบบจำลองนิรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาวสำหรับพยากรณ์ความต้องการไฟฟ้า โดยแบบจำลองนี้สามารถเรียนรู้ความสัมพันธ์ของแต่ละคุณลักษณะและแต่ละช่วงเวลาได้ และพบว่ามีประสิทธิภาพที่ดีกว่าการถดถอยเชิงเส้น ต้นไม้ตัดสินใจ หลักการป่าแบบสุ่ม และเพอร์เซ็ปตรอนหลายชั้น จากงานวิจัยนี้พบว่า การพิจารณาความสัมพันธ์ของคุณลักษณะต่าง ๆ ร่วมกับการพิจารณาข้อมูลของช่วงเวลาในอดีตสามารถเพิ่มประสิทธิภาพในการพยากรณ์ของแบบจำลองได้ โดยโครงสร้างของแบบจำลองที่งานวิจัยนี้แนะนำเสนอแสดงดังรูปที่ 12



รูปที่ 12 แบบจำลองนิรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาว

3.2 งานวิจัยที่เกี่ยวข้องกับการใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร

งานวิจัยในหัวข้อนี้ เป็นงานวิจัยที่นำเสนอการปรับปรุงฟังก์ชันต้นทุน เพื่อให้คำนวณค่าต้นทุนของนิเวศน์เดวีร์กที่แตกต่างกันสำหรับค่าพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลี่ย โดยฟังก์ชันต้นทุนที่มีการคำนวณค่าต้นทุนแบบนี้มีชื่อเรียกว่า ฟังก์ชันต้นทุนแบบไม่สมมาตร (asymmetric loss function)

ในปี 2019 Ahn และคณะ [20] ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ข้อมูลเงินเพื่อของประเทศเกาหลี เนื่องจากต้องการให้ค่าฟังก์ชันต้นทุนที่มากกว่าสำหรับการพยากรณ์ที่ต่ำกว่าผลเฉลี่ย ส่วนในงานวิจัยของ Kusunoki และคณะ [21] มีการประยุกต์ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรกับปัญหาการจำแนกประเภท นอกจากนี้ในงานวิจัยของ Wang และคณะ [22] ใช้วิธีการเพื่อนบ้านใกล้สุด K ลำดับเพื่อพยากรณ์ข้อมูลจราจร และใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ข้อมูลจราจร เพื่อเพิ่มประสิทธิภาพของแบบจำลอง เนื่องจากหากค่าพยากรณ์สูงกว่าผลเฉลี่ยจะส่งผลให้ต้นทุนในการจัดการสูงขึ้น และทำให้ผู้ใช้ทางเลือกเส้นทางอื่นในการเดินทาง แต่หากค่าพยากรณ์ต่ำกว่าผลเฉลี่ยจะส่งผลให้เกิดความวุ่นวายในระบบจราจร และการจราจรทั้งระบบจะคาดการณ์ได้ยาก จึงปรับปรุงฟังก์ชันต้นทุนให้เหมาะสมกับข้อเท็จจริงมากยิ่งขึ้น

ในปี 2020 งานวิจัยของ Gkillas และคณะ [23] ได้ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ราคาน้ำมัน เนื่องจากการพยากรณ์ราคาน้ำมันต่ำกว่าผลเฉลี่ย จะทำให้ต้นทุนในการซื้อน้ำมันสูงกว่าการพยากรณ์ราคาน้ำมันสูงกว่าผลเฉลี่ย

งานวิจัยทั้งหมดที่กล่าวมาข้างต้น มีการประยุกต์ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรในงานวิจัย ซึ่งสามารถเพิ่มประสิทธิภาพของแบบจำลองได้ และทำให้การพยากรณ์ใกล้เคียงกับสถานการณ์จริงมากยิ่งขึ้น แต่การประยุกต์ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรนั้น ในแต่ละงานวิจัยมีการออกแบบฟังก์ชันต้นทุนเฉพาะสำหรับแต่ละปัญหาในแต่ละงานวิจัย ดังนั้นในงานวิจัยนี้จึงทำการออกแบบฟังก์ชันต้นทุนแบบไม่สมมาตรโดยเฉพาะเพื่อใช้ในแบบจำลองสำหรับพยากรณ์ความต้องการไฟฟ้า

บทที่ 4

แนวคิดและแบบจำลองที่นำเสนอ

งานวิจัยนี้จะทำการสร้างแบบจำลองเพื่อพยากรณ์ความต้องการไฟฟ้าของประเทศไทยรายครึ่งชั่วโมงของวันถัดไปรวม 48 ช่วงเวลาล่วงหน้า โดยทำการปรับปรุงงานวิจัยของ Qin และคณะ [19] ซึ่งเป็นแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวศวิทยาแบบวนกลับที่สามารถพิจารณาให้ค่าความน่าสนใจของคุณลักษณะที่แตกต่าง และพิจารณาให้ค่าความน่าสนใจให้กับข้อมูลในอดีตที่อยู่ในหน้าต่าง (window) เดียวกันได้ ทำให้แบบจำลองสามารถให้ความสำคัญได้ถูกคุณลักษณะ แต่ในแบบจำลองที่ Qin และคณะ [19] นำเสนอจำเป็นต้องใช้ข้อมูลคุณลักษณะและข้อมูลจริงในช่วงเวลาก่อนหน้าในอดีตเป็นองค์ประกอบในการพยากรณ์ ดังนั้นจึงไม่เหมาะสมกับการพยากรณ์ค่าล่วงหน้าแบบหลายช่วงเวลาได้

งานวิจัยนี้จึงทำการปรับปรุงแบบจำลองเพื่อให้สามารถพยากรณ์ข้อมูลล่วงหน้าหลายช่วงเวลาได้ โดยเพิ่มหน่วยความจำระยะสั้นแบบยาวเพื่อทำการพยากรณ์ข้อมูลคุณลักษณะ ซึ่งในงานวิจัย [25] พบว่าสามารถพยากรณ์ข้อมูลอนุกรมเวลาหลายช่วงเวลาได้ดี

แต่ในงานวิจัยของ Qin และคณะ [19] ไม่ได้มีการหาความสัมพันธ์ของคุณลักษณะต่าง ๆ ในการพยากรณ์ข้อมูลอนุกรมเวลา ใช้เพียงแค่อัลกอริทึมความสนใจเพื่อให้ค่าความน่าสนใจสำหรับแต่ละคุณลักษณะเท่านั้น จึงมีแนวคิดที่จะเพิ่มนิเวศวิทยาแบบวนกลับคอนโวลูชัน เพื่อหาความสัมพันธ์ของแต่ละคุณลักษณะที่เกี่ยวข้องกันด้วย และจากงานวิจัย [27-32] พบว่าหากพิจารณาทั้งความสำคัญและความสัมพันธ์ของคุณลักษณะ รวมถึงพิจารณาข้อมูลของช่วงเวลาในอดีต จะช่วยเพิ่มประสิทธิภาพของแบบจำลองได้ จึงมีแนวคิดที่จะนำนิเวศวิทยาแบบวนกลับคอนโวลูชันที่มีความสามารถในการหาความสัมพันธ์ของคุณลักษณะต่าง ๆ ที่เกี่ยวข้องกันได้มาประยุกต์เพิ่มในแบบจำลอง

การพิจารณาคุณลักษณะที่เกี่ยวข้องเพิ่มเติม มีแนวคิดที่จะเพิ่มข้อมูลความเร็วลม และข้อมูลฝนเป็นคุณลักษณะเพิ่มเติมในการพยากรณ์ความต้องการไฟฟ้าด้วย เนื่องจากในปัจจุบันจำนวนโรงไฟฟ้าพลังงานหมุนเวียนมีจำนวนเพิ่มขึ้นเรื่อย ๆ การพิจารณาข้อมูลความเร็วลม และข้อมูลฝน จะช่วยเพิ่มประสิทธิภาพของแบบจำลองและเพิ่มความแม่นยำในการพยากรณ์ได้

นอกจากนี้งานวิจัยก่อนหน้าที่เกี่ยวข้องกับการพยากรณ์ข้อมูลอนุกรมเวลา รวมถึงในงานวิจัย [19] และในแบบจำลองที่นำเสนอในเบื้องต้น มีการใช้งานฟังก์ชันต้นทุนแบบสมมาตร กล่าวคือ ใช้ฟังก์ชันเดียวกันในการคำนวณค่าต้นทุนของนิเวศวิทยาแบบวนกลับสำหรับค่าพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลย ซึ่งในบางปัญหาผลกระทบที่เกิดการค่าพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลยนั้นไม่เท่ากัน ฟังก์ชันต้นทุนที่มีการให้ค่าต้นทุนที่ไม่เท่ากันนี้จะเรียกว่า ฟังก์ชันต้นทุนแบบไม่สมมาตร โดยในแต่ละงานวิจัยจะมีการออกแบบฟังก์ชันต้นทุนเฉพาะสำหรับแต่ละปัญหานั้น ๆ ดังนั้นงานวิจัยนี้จะทำการออกแบบฟังก์ชันต้นทุนที่เหมาะสมกับการพยากรณ์ความต้องการไฟฟ้า และใช้งานกับแบบจำลองที่ปรับปรุงดังที่กล่าวมาข้างต้น

4.1 การเตรียมข้อมูล

หัวข้อนี้จะกล่าวถึงการเตรียมข้อมูลเพื่อนำไปใช้เป็นข้อมูลนำเข้าของแบบจำลองที่นำเสนอ ซึ่งมีดังต่อไปนี้

4.1.1 การปรับปรุงข้อมูล

ในงานวิจัยนี้จะแบ่งข้อมูลออกเป็น 2 ประเภท คือ 1) ข้อมูลแสดงประเภทหมวดหมู่ และ 2) ข้อมูลตัวเลข โดยข้อมูลแต่ละประเภท จะมีการปรับปรุงข้อมูลที่แตกต่างกันก่อนนำเข้าแบบจำลอง ดังนี้

1. ข้อมูลแสดงประเภทหมวดหมู่

แปลงข้อมูลเป็นเวกเตอร์วันฮอต (One-hot Vector) เพื่อระบุประเภท เช่น ข้อมูลวันหยุดพิเศษ ใช้สัญลักษณ์ 0 เป็นตัวแทนวันปกติและ 1 เป็นตัวแทนของวันหยุดพิเศษ เป็นต้น

2. ข้อมูลตัวเลข

นำข้อมูลไปทำการนอร์มอลไลซ์ด้วยค่ามาตรฐาน (Standardize Normalization) เพื่อปรับให้ข้อมูลมีขอบเขตที่ไม่แตกต่างกันมาก ทำให้ข้อมูลมีความสำคัญที่ไม่แตกต่างกันจนเกินไป สามารถคำนวณได้จากการสมการดังต่อไปนี้

$$\hat{v} = \frac{v - \text{mean}}{\text{std}} \quad (15)$$

เมื่อ v คือ ค่าจริง \hat{v} คือ ค่าที่ได้หลังจากการนอร์มอลไลซ์ mean คือ ค่าเฉลี่ยของข้อมูลทั้งหมด และ std คือ ค่าเบี่ยงเบนมาตรฐานของข้อมูล

4.1.2 การจัดแบ่งข้อมูล


ในงานวิจัยนี้ใช้ข้อมูลในอดีตรายครึ่งชั่วโมงตั้งแต่ 01/01/2010 ถึง 31/12/2018 รวม 9 ปี โดยจะแบ่งข้อมูลปี 2010 ถึง 2016 ใช้สำหรับฝึกสอน ข้อมูลปี 2017 ใช้สำหรับตรวจสอบ และปี 2018 สำหรับทดสอบประสิทธิภาพของแบบจำลอง

4.1.3 การจัดรูปแบบข้อมูลสำหรับแบบจำลอง

ในแบบจำลองที่นำเสนอมีข้อมูลที่ใช้ประกอบการพยากรณ์อยู่ 2 ส่วน ดังนี้

1. ข้อมูลคุณลักษณะที่เกี่ยวข้อง


จัดเตรียมข้อมูลสำหรับพยากรณ์ค่าคุณลักษณะที่ใช้ร่วมกับการพยากรณ์ความต้องการไฟฟ้าโดยจัดเรียงให้อยู่ในรูปของเมตริกซ์ 2 มิติ ขนาด $T \times n$ โดย T คือ ขนาดของช่วงเวลาในอดีตที่พิจารณา และจำนวนช่วงเวลาที่ต้องการพยากรณ์ n คือ จำนวนคุณลักษณะ ตัวอย่างแสดงดังรูป



รูปที่ 13 การจัดเตรียมข้อมูลคุณลักษณะที่เกี่ยวข้อง

2. ข้อมูลค่าความต้องการไฟฟ้าในอดีต


จัดเตรียมข้อมูลค่าความต้องการไฟฟ้าในอดีต เพื่อเป็นองค์ประกอบในการพยากรณ์ โดยในการพยากรณ์จะทำการพยากรณ์โดยข้อมูลย้อนหลัง $T-1$ ช่วงเวลาเพื่อพยากรณ์ข้อมูลช่วงเวลาถัดไป ซึ่งในขั้นตอนนี้จะจัดเรียงให้อยู่ในรูปของเวกเตอร์ที่มีความยาว T เพื่อความสะดวกในการจัดเตรียมข้อมูล



รูปที่ 14 การจัดเตรียมข้อมูลค่าความต้องการไฟฟ้าในอดีต


4.2 แบบจำลองที่นำเสนอ

แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวศน์เวกซ์แบบวนกลับต่อกับหน่วยความจำระยะสั้นแบบยาว และการสกัดคุณลักษณะโดยใช้นิเวศน์เวกซ์คอนโวลูชัน โดยใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร (Dual-Stage Attentional LSTM with Feature Extraction CNN and using Asymmetric Loss Function หรือ $D-LSTM+F_{CNN}+Loss_{asym}$) จะประกอบด้วยการพยากรณ์ข้อมูลคุณลักษณะที่เกี่ยวข้อง การพิจารณาความสัมพันธ์ของคุณลักษณะต่าง ๆ ที่เกี่ยวข้องกัน การพิจารณาให้ค่าความน่าสนใจกับคุณลักษณะแต่ละตัว และค่าความน่าสนใจกับข้อมูลในอดีตแต่ละช่วงเวลาที่อยู่ในหน้าต่างชุดเดียวกัน เพื่อให้แบบจำลองสามารถให้ความสำคัญกับคุณลักษณะที่น่าสนใจมากกว่าคุณลักษณะอื่น ๆ และยังสามารถสกัดคุณลักษณะด้วย ซึ่งสอนแบบจำลองโดยใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรที่ออกแบบมาสำหรับการพยากรณ์ความต้องการไฟฟ้า จากนั้นพยากรณ์ข้อมูลความต้องการไฟฟ้าส่งออกเป็นผลลัพธ์ของแบบจำลอง แสดงดังรูปที่ 15



รูปที่ 15 แนวคิดของแบบจำลอง $D-LSTM+F_{CNN}+Loss_{asym}$

โครงสร้างของแบบจำลองจะประกอบด้วย หน่วยความจำระยะสั้นแบบยาว และแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวศน์เวกซ์แบบวนกลับ ซึ่งแบบจำลอง $D-LSTM+F_{CNN}+Loss_{asym}$ จะสามารถพิจารณาทั้งคุณลักษณะและช่วงเวลาในอดีต โดยให้ความสำคัญที่แตกต่างกันสำหรับแต่ละคุณลักษณะและช่วงเวลาแต่ละช่วงได้ รวมถึงสกัดคุณลักษณะต่าง ๆ ที่เกี่ยวข้องกันด้วย นอกจากนี้จะใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรที่ออกแบบมาเพื่อการพยากรณ์ความต้องการไฟฟ้าโดยเฉพาะ แบบจำลอง $D-LSTM+F_{CNN}+Loss_{asym}$ แสดงดังรูปที่ 16 โดยหมายเลขกำกับในรูปจะอ้างอิงจากรูปที่ 15



รูปที่ 16 แบบจำลอง $D-LSTM+FCNN+LOSS_{asym}$

แบบจำลอง $D-LSTM+FCNN+LOSS_{asym}$ แบ่งออกเป็น 5 ส่วน ดังนี้

4.2.1 ข้อมูลนำเข้า

ข้อมูลนำเข้าจะแบ่งออกเป็น 2 ส่วน ดังนี้

- 1) คุณลักษณะที่เกี่ยวข้อง
 - ข้อมูลเกี่ยวกับอากาศ
 - ข้อมูลประเภทของวัน
 - ข้อมูลด้านพลังงานหมุนเวียน
 - ข้อมูลค่าเฉลี่ยถ่วงน้ำหนักของความต้องการไฟฟ้าในอดีต
- 2) ข้อมูลความต้องการไฟฟ้า
 - ข้อมูลรายครึ่งชั่วโมงของความต้องการไฟฟ้าในอดีต

4.2.2 การพยากรณ์ข้อมูลคุณลักษณะ

ส่วนนี้คือหมายเลข 1 ในรูปที่ 16 โดยจะใช้เมตริกซ์ข้อมูลคุณลักษณะที่จัดเตรียมไว้ตั้งที่กล่าวในหัวข้อก่อนหน้าที่มีขนาด $T \times n$ และใช้หน่วยความจำระยะสั้นแบบยาวจำนวนเท่ากับจำนวนคุณลักษณะ โดย 1 หน่วยความจำระยะสั้นแบบยาว ใช้สำหรับพยากรณ์ข้อมูล 1 คุณลักษณะ จากนั้นนำผลลัพธ์ที่ได้มาต่อกันในแนวตั้ง เพื่อให้ได้เมตริกซ์ 2 มิติ ขนาด $T \times n$ โดย T คือ ขนาดของช่วงเวลาในอดีตที่พิจารณา และจำนวนช่วงเวลาที่ต้องการพยากรณ์ และ n คือ จำนวนคุณลักษณะ ดังนั้นผลลัพธ์จากการพยากรณ์ข้อมูลคุณลักษณะจะมีขนาดของเมตริกซ์เท่ากับข้อมูลที่นำเข้าแบบจำลอง


4.2.3 การสกัดคุณลักษณะ

หมายเลข 2 ในรูปที่ 16 คือ การสกัดคุณลักษณะโดยใช้นิวรอลเน็ตเวิร์กคอนโวลูชันที่ประกอบด้วยชั้นคอนโวลูชัน 1 ชั้น โดยมีขนาดตัวกรอง (filter) เท่ากับจำนวนคุณลักษณะ ทำให้สามารถพิจารณาทุก ๆ คุณลักษณะในช่วงเวลาเดียวกันไปพร้อมกัน และใช้การเสริมเติม (padding) ทำให้ผลลัพธ์ที่ได้มีขนาดเท่ากับเมตริกซ์ที่นำเข้า ชั้นตอนนี้ทำเพื่อหาความสัมพันธ์ของคุณลักษณะต่าง ๆ ที่เกี่ยวข้องกัน จากนั้นนำผลลัพธ์ที่ได้เข้าแบบจำลองหมายเลข 3 ในรูปที่ 19 ซึ่งเป็นแบบจำลองที่มีโครงสร้างเดียวกันกับแบบจำลองที่ Qin และคณะ [19] นำเสนอไว้

4.2.4 การพยากรณ์ความต้องการไฟฟ้าแบบหลายช่วงเวลา

แบบจำลองที่ Qin และคณะ [19] นำเสนอไว้ คือ แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์กแบบวกกลับ โดยกลไกจุดสนใจชั้นที่หนึ่งใช้สำหรับให้ค่าความน่าสนใจของแต่ละคุณลักษณะ เพื่อให้แบบจำลองสามารถให้ความสำคัญที่มากกว่าสำหรับคุณลักษณะที่สำคัญได้ และช่วยเพิ่มประสิทธิภาพในการพยากรณ์ จากนั้นนำค่าความน่าสนใจไปคูณกับข้อมูลที่ได้จากการสกัดคุณลักษณะในข้อ 4.2.3 และนำเข้าหน่วยความจำระยะสั้นแบบยาว พิจารณาความน่าสนใจของแต่ละคุณลักษณะครั้งละ 1 ช่วงเวลาจนครบหน้าตาต่าง T รอบ


ข้อมูลนำเข้าสำหรับกลไกจุดสนใจชั้นที่หนึ่งประกอบด้วย 2 ส่วน คือ ผลลัพธ์จากการพยากรณ์คุณลักษณะในส่วนที่หนึ่งและข้อมูลจริงที่นำเข้าแบบจำลอง โดยในงานวิจัยนี้ใช้เทคนิคการเลื่อนหน้าต่าง (sliding window) โดยมีขนาดหน้าต่างเท่ากับ $T \times n$ ดังนั้นข้อมูลนำเข้าจะต้องเป็นเมตริกซ์ที่มีขนาด $T \times n$ ด้วย โดยตัวอย่างของข้อมูลนำเข้าสำหรับกลไกจุดสนใจชั้นที่หนึ่ง แสดงดังรูปที่ 17




สำหรับกลไกจุดสนใจชั้นที่สองสำหรับให้ค่าความน่าสนใจของข้อมูลในอดีตแต่ละช่วงเวลาในหน้าตาเดียวกัน และนำค่าความน่าสนใจไปคูณกับผลลัพธ์ที่ได้จากกลไกจุดสนใจชั้นที่หนึ่ง จากนั้นนำเข้าหน่วยความจำระยะสั้นแบบยาว เพื่อพยากรณ์ข้อมูลความต้องการไฟฟ้า และนำผลลัพธ์การพยากรณ์ความต้องการไฟฟ้าจากกลไกจุดสนใจชั้นที่สองมารวมกับข้อมูลในอดีต เพื่อใช้เป็นข้อมูลประกอบในการพยากรณ์ค่าความต้องการไฟฟ้าในช่วงเวลาถัดไป

ข้อมูลที่ใช้ในกลไกจุดสนใจชั้นที่สองเป็นข้อมูลความต้องการไฟฟ้าในอดีตที่ประกอบด้วย 2 ส่วน คือ ข้อมูลความต้องการไฟฟ้าจริงในอดีต และผลลัพธ์จากการพยากรณ์ความต้องการไฟฟ้าในช่วงเวลาที่ผ่านมา โดยตัวอย่างของข้อมูลแสดงดังรูปที่ 18

ผลการพยากรณ์ของช่วงเวลาก่อนหน้า ข้อมูลจริงในอดีต ผลการพยากรณ์ของช่วงเวลาก่อนหน้า ข้อมูลจริงในอดีต



ข้อมูลนำเข้าสำหรับการพยากรณ์ช่วงเวลาที่ 1



ข้อมูลนำเข้าสำหรับการพยากรณ์ช่วงเวลาที่ 2

รูปที่ 18 ตัวอย่างของข้อมูลที่ใช้ในกลไกจุดสนใจชั้นที่สอง

เมื่อกลไกจุดสนใจชั้นที่สองพยากรณ์ค่าความต้องการไฟฟ้าแล้ว จะเลื่อนหน้าต่างไป 1 ช่วงเวลา สำหรับข้อมูลนำเข้าในกลไกจุดสนใจชั้นที่หนึ่ง และข้อมูลในอดีตที่ใช้ในกลไกจุดสนใจชั้นที่สอง หลังจากนั้นแบบจำลองจะทำการพยากรณ์ความต้องการไฟฟ้าแบบวนซ้ำไปเรื่อย ๆ จนถึงเวลาที่ T และจะไปเริ่มต้นการทำงานใหม่จากข้อ 4.2.2 จนครบจำนวนข้อมูลทั้งหมด

4.2.5 ฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ความต้องการไฟฟ้า

ฟังก์ชันต้นทุนที่นิยมใช้กันทั่ว ๆ ไปจะเป็นฟังก์ชันเดียวกันในการคำนวณค่าต้นทุนของค่าพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลย ซึ่งในการพยากรณ์ความต้องการไฟฟ้านั้น ค่าพยากรณ์ที่สูงกว่าผลเฉลยจะส่งผลให้สูญเสียต้นทุนในการผลิตไฟฟ้าที่มากเกินไปจนเกินไป แต่ค่าพยากรณ์ต่ำกว่าผลเฉลยจะมีผลกระทบที่รุนแรงกว่าค่าพยากรณ์ที่สูงกว่าผลเฉลย เนื่องจากสามารถส่งผลทำให้เกิดไฟฟ้าดับได้ ดังนั้นการคำนวณฟังก์ชันต้นทุนนั้น ควรจะใช้ฟังก์ชันให้เหมาะสมกับความเป็นจริงของข้อมูลนั้น ๆ

งานวิจัยนี้จึงออกแบบฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ความต้องการไฟฟ้า ($Loss_{asym}$) โดยจะให้ค่าต้นทุนที่สูงกว่าสำหรับการพยากรณ์ที่ต่ำกว่าผลเฉลย ฟังก์ชันต้นทุนที่ใช้ในงานวิจัยนี้ มีขั้นตอนการทำงาน ดังนี้

1. เปรียบเทียบค่าพยากรณ์กับผลเฉลย
2. ฟังก์ชันต้นทุนจะเลือกใช้สูตรของฟังก์ชันต้นทุนที่เหมาะสมกับค่าพยากรณ์นั้น ๆ ดังนี้
กรณีค่าพยากรณ์สูงกว่าผลเฉลย จะใช้ฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง

$$Loss_{asym} = \frac{1}{n} \sum_{i=1}^n (\hat{y} - y)^2 \quad (16)$$

เมื่อ y คือ ค่าจริงที่เกิดขึ้น \hat{y} คือ ค่าที่พยากรณ์

n คือ จำนวนการพยากรณ์ทั้งหมด

μ คือ ค่าพารามิเตอร์ที่ต้องปรับ

กรณีค่าพยากรณ์ต่ำกว่าผลเฉลย จะให้ค่าฟังก์ชันต้นทุนมากกว่าการพยากรณ์ที่สูงกว่าผลเฉลย ซึ่งปรับปรุงจากฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง โดยสูตรคำนวณค่าฟังก์ชันต้นทุนจะใช้สมการดังนี้

$$Loss_{asym} = \mu * \left(\frac{1}{n} \sum_{i=1}^n (\hat{y} - y)^2\right)$$

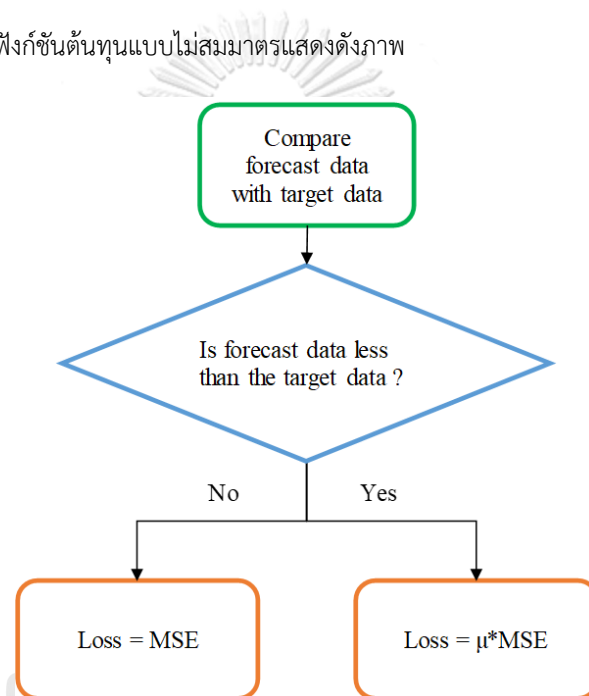
(17)

เมื่อ y คือ ค่าจริงที่เกิดขึ้น \hat{y} คือ ค่าที่พยากรณ์

n คือ จำนวนการพยากรณ์ทั้งหมด

μ คือ ค่าพารามิเตอร์ที่ต้องปรับ

การทำงานของฟังก์ชันต้นทุนแบบไม่สมมาตรแสดงดังภาพ



รูปที่ 19 การทำงานของฟังก์ชันต้นทุนแบบไม่สมมาตร

บทที่ 5

การทดลอง

ในบทนี้จะกล่าวถึงการทดลองต่าง ๆ ที่จัดทำขึ้นในงานวิจัยนี้ โดยจะกล่าวถึงการชุดข้อมูลที่ใช้ในแต่ละการทดลอง แบบจำลองอื่น ๆ ที่ถูกสร้างขึ้นเพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองที่นำเสนอ วิธีการวัดผล และผลการทดลอง ซึ่งข้อมูลคุณลักษณะที่เกี่ยวข้องที่ใช้ในงานวิจัยนี้มีทั้งหมด 4 ชุดข้อมูล คือ

- 1) ข้อมูลเกี่ยวกับอากาศ
- 2) ข้อมูลประเภทของวัน
- 3) ข้อมูลด้านพลังงานหมุนเวียน
- 4) ข้อมูลค่าเฉลี่ยถ่วงน้ำหนักของความต้องการไฟฟ้าในอดีต

นอกจากนั้นในงานวิจัยนี้จะมีการทดลองใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ความต้องการไฟฟ้าด้วย การทดลองทั้งหมดจะถูกแบ่งออกเป็น 6 หัวข้อ ดังนี้

- 1) แบบจำลองสำหรับเปรียบเทียบประสิทธิภาพ
เป็นการสร้างแบบจำลองขึ้นมาเพื่อใช้เปรียบเทียบประสิทธิภาพกับแบบจำลองที่นำเสนอในงานวิจัยนี้
- 2) ประสิทธิภาพของแบบจำลองที่พิจารณาข้อมูลเกี่ยวกับอากาศ และข้อมูลประเภทของวัน
เป็นการทดสอบประสิทธิภาพของแบบจำลอง D-LSTM และแบบจำลอง D-LSTM+F_{CNN} ที่พิจารณาข้อมูลเกี่ยวกับอากาศ และข้อมูลประเภทของวัน โดยจะทำการเปรียบเทียบประสิทธิภาพกับแบบจำลองในหัวข้อที่ 1
- 3) ประสิทธิภาพของแบบจำลองเมื่อทำการเพิ่มคุณลักษณะด้านพลังงานหมุนเวียน
เป็นการทดลองเพื่อทดสอบการเพิ่มคุณลักษณะด้านพลังงานหมุนเวียนลงในแบบจำลอง และจะเปรียบเทียบกับแบบจำลองที่ไม่ได้พิจารณาคุณลักษณะด้านพลังงานหมุนเวียน
- 4) ประสิทธิภาพของแบบจำลองเมื่อทำการเพิ่มคุณลักษณะความต้องการไฟฟ้าในอดีต
เป็นการทดลองเพื่อทดสอบการเพิ่มคุณลักษณะความต้องการไฟฟ้าในอดีตลงในแบบจำลอง และจะเปรียบเทียบกับแบบจำลองที่ไม่ได้พิจารณาความต้องการไฟฟ้าในอดีต
- 5) ประสิทธิภาพของแบบจำลองเมื่อทำการเพิ่มคุณลักษณะความต้องการไฟฟ้าในอดีต และคุณลักษณะด้านพลังงานหมุนเวียน
จากผลการทดลองของการทดลองที่ 4 และ 5 พบว่าสามารถเพิ่มประสิทธิภาพของแบบจำลองได้ ผู้วิจัยจึงมีแนวคิดที่จะเพิ่มทั้งคุณลักษณะด้านพลังงานหมุนเวียนและความต้องการไฟฟ้าในอดีตลงในแบบจำลอง
- 6) ประสิทธิภาพของแบบจำลองดีเอสเอแอลเมื่อทำการปรับปรุงฟังก์ชันต้นทุน
การทดลองนี้เป็นการทดลองของแบบจำลองเมื่อมีการใช้งานฟังก์ชันต้นทุนที่นำเสนอ เปรียบเทียบกับแบบจำลองที่ใช้งานฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง

5.1 การสร้างแบบจำลองเพื่อใช้เปรียบเทียบประสิทธิภาพ

ในหัวข้อนี้จะกล่าวถึงแบบจำลองอื่น ๆ ที่ถูกสร้างขึ้นเพื่อเปรียบเทียบประสิทธิภาพของแบบจำลองที่นำเสนอ ซึ่งแบบจำลองเหล่านี้จะใช้ข้อมูลนำเข้าชุดเดียวกันและใช้ค่าพารามิเตอร์ที่ดีที่สุดที่ได้จากการทดลองของแต่ละแบบจำลอง โดยแบบจำลองที่ Qin และคณะ [19] นำเสนอไม่ได้ถูกนำมาใช้ในการเปรียบเทียบประสิทธิภาพ เนื่องจากไม่สามารถพยากรณ์ค่าล่วงหน้าแบบหลายช่วงเวลาได้ แบบจำลองที่ใช้ในการเปรียบเทียบประสิทธิภาพมีดังต่อไปนี้

5.1.1 โครงข่ายประตูกลับสองทิศทาง (GRU)

แบบจำลองที่ประกอบด้วยโครงข่ายประตูกลับสองทิศทางต่อกัน 2 ชั้น

5.1.2 หน่วยความจำระยะสั้นแบบยาว (LSTM)

แบบจำลองที่ประกอบด้วยหน่วยความจำระยะสั้นแบบยาวต่อกัน 2 ชั้น

5.1.3 นิวรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาว (CNN-LSTM)

แบบจำลองที่ใช้ในการเปรียบเทียบประสิทธิภาพใช้โครงสร้างแบบจำลองเดียวกับ Kim [17] คือ นิวรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาว จากนั้นตามด้วยชั้นการเชื่อมโยงเต็มรูปแบบ

5.1.4 กลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์กแบบวนกลับ (DA-RNN)

เนื่องจากแบบจำลองที่นำเสนอนั้นทำการพยากรณ์ความต้องการไฟฟ้าล่วงหน้า โดยใช้เทคนิคการวนซ้ำในการพยากรณ์ช่วงเวลาถัดไป ซึ่งอาจจะทำให้เกิดการสะสมของค่าความคลาดเคลื่อนในการพยากรณ์ ผู้วิจัยจึงสร้างแบบจำลองที่ Qin และคณะ [19] นำเสนอไว้ คือ แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์กแบบวนกลับ (DA-RNN) ที่ผู้วิจัยนำมาเป็นส่วนหนึ่งของแบบจำลองที่นำเสนอไว้ มาพยากรณ์แบบหลายช่วงเวลาแบบไม่วนซ้ำเพื่อเปรียบเทียบประสิทธิภาพด้วย

5.2 ประสิทธิภาพของแบบจำลองที่พิจารณาข้อมูลเกี่ยวกับอากาศ และข้อมูลประเภทของวัน

ในหัวข้อนี้ผู้วิจัยจะทำการทดลองเพื่อทดสอบประสิทธิภาพของแบบจำลอง 2 แบบจำลอง คือ แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์ก แบบวนกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) และแบบจำลอง $D-LSTM+F_{CNN}$ โดยแบบจำลอง $D-LSTM+F_{CNN}$ คือแบบจำลองที่พัฒนามาจากแบบจำลอง D-LSTM โดยการเพิ่มส่วนของการสกัดคุณลักษณะเข้ามาในแบบจำลอง และทั้งสองแบบจำลองจะใช้งานฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง

5.2.1 ชุดข้อมูล

ชุดข้อมูลที่ใช้ในงานวิจัยนี้ได้แก่ ข้อมูลความต้องการไฟฟ้า ข้อมูลเกี่ยวกับอากาศ และข้อมูลประเภทของวันในอดีตตั้งแต่ 01/01/2010 ถึง 31/12/2018 โดยจะแบ่งข้อมูลปี 2010 ถึง 2016 ใช้สำหรับฝึกสอน ข้อมูลปี 2017 ใช้สำหรับตรวจสอบ และปี 2018 สำหรับทดสอบประสิทธิภาพของแบบจำลอง ชุดข้อมูลที่ใช้ในการทดลองแบ่งออกเป็น 2 ชุดข้อมูลดังนี้

1. ข้อมูลที่เป็นประเภทหมวดหมู่ คือ ข้อมูลที่นำเข้าแบบจำลองที่ไม่ใช่ตัวเลข

ในการทดลองนี้จะใช้ข้อมูลประเภทของวัน คือ ข้อมูลวันเสาร์-อาทิตย์ หรือวันจันทร์ถึงวันศุกร์ และ ข้อมูลวันหยุดพิเศษหรือไม่ เพื่อเป็นองค์ประกอบในการพยากรณ์ความต้องการไฟฟ้า

2. ข้อมูลที่เป็นตัวเลข คือ ข้อมูลที่นำเข้าแบบจำลองในชนิดตัวเลข ประกอบด้วย

2.1 ข้อมูลความต้องการไฟฟ้าของประเทศไทยในแต่ละพื้นที่ควบคุมของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทยในอดีต ซึ่งเป็นข้อมูลรายครึ่งชั่วโมง มีหน่วยเป็นเมกะวัตต์ (Megawatt หรือ MW) นำมาจากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย โดยแบ่งออกเป็น 5 พื้นที่ คือ เขตนครหลวง ภาคกลาง ภาคตะวันออกเฉียงเหนือ ภาคใต้ และภาคเหนือ โดยในงานวิจัยนี้จะทำแบบจำลอง 5 แบบจำลองที่ปรับพารามิเตอร์ให้เหมาะสมกับข้อมูลแต่ละพื้นที่

ความมั่นคงของระบบไฟฟ้าเป็นสิ่งสำคัญที่สุด ดังนั้นจะมีพลังไฟฟ้าจำนวนหนึ่งที่สำรองไว้เผื่อกรณีฉุกเฉิน เพื่อป้องกันการเกิดไฟฟ้าดับซึ่งจะส่งผลกระทบต่อระบบเศรษฐกิจและประชาชน พลังไฟฟ้าที่สำรองไว้เรียกว่า กำลังผลิตสำรองพร้อมจ่ายทันที (Spinning Reserve) ซึ่งในประเทศไทยนั้นมีกำลังผลิตสำรองพร้อมจ่ายทันทีอยู่ที่ 800 – 1,500 เมกะวัตต์ แปลว่าหากมีความต้องการไฟฟ้าสูงกว่าปริมาณไฟฟ้าที่สามารถผลิตได้เกินกว่ากำลังผลิตสำรองพร้อมจ่ายทันทีจะส่งผลให้เกิดไฟฟ้าดับได้ ดังนั้นการพยากรณ์ความต้องการไฟฟ้าหากพยากรณ์ได้ค่าความต้องการไฟฟ้าของทุกพื้นที่รวมกันมีค่าน้อยกว่าความต้องการไฟฟ้าจริงไม่เกินกำลังผลิตสำรองพร้อมจ่ายทันทีที่เตรียมไว้ ระบบจะยังสามารถจ่ายไฟฟ้าได้ตามปกติ

2.2 ข้อมูลเกี่ยวกับอากาศ ประกอบด้วย 1) อุณหภูมิ(องศาเซลเซียส) 2) จุดน้ำค้าง(องศาเซลเซียส) ความชื้นสัมพัทธ์(เปอร์เซ็นต์) 3) ความกดอากาศ(เฮกโตปาสกาล)

ในงานวิจัยนี้จะทำการพยากรณ์ความต้องการไฟฟ้าแยกตามพื้นที่ควบคุมของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย ซึ่งข้อมูลที่ใช้ในแบบจำลองเพื่อพยากรณ์ความต้องการไฟฟ้าแต่ละพื้นที่ จะใช้เป็นค่าเฉลี่ยถ่วงน้ำหนักตามปริมาณการใช้ไฟฟ้าของแต่ละจังหวัดในพื้นที่นั้น ๆ เช่น พื้นที่เขตนครหลวงมี 3 จังหวัด อุณหภูมิ คือ 25, 26, 27 และการใช้ไฟฟ้า คือ 1,500 1,200 และ 1,300 ตามลำดับ ดังนั้นอุณหภูมิที่เป็นตัวแทนของเขตนครหลวงจะคำนวณจาก $((25*1,500)+(26*1,200)+(27*1,300))/(1,500+1,200+1,300) = 25.95 \text{ }^{\circ}\text{C}$

5.2.2 การวัดผล

การวัดผลสำหรับการทดลองนี้ แบบจำลองจะถูกวัดประสิทธิภาพด้วยวิธีการดังต่อไปนี้

1. ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน (Root Mean Square Error, RMSE) เพื่อทำการวัดว่าแบบจำลองพยากรณ์ค่าความคลาดเคลื่อนเท่าใดจากจำนวนการพยากรณ์ทั้งหมด หน่วยของค่าความคลาดเคลื่อนจะเป็นหน่วยเดียวกับค่าที่เกิดขึ้นจริงและค่าที่พยากรณ์ สามารถคำนวณได้จากสมการดังต่อไปนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y} - y)^2}{n}} \quad (18)$$

เมื่อ y คือ ค่าจริงที่เกิดขึ้น \hat{y} คือ ค่าที่พยากรณ์ n คือจำนวนการพยากรณ์ทั้งหมด

ซึ่งในการพยากรณ์ความต้องการไฟฟ้าล่วงหน้า จะพยากรณ์ค่า 1 วันล่วงหน้า (48 ค่า) จากนั้นจะนำค่าความคลาดเคลื่อนที่ได้มาหาค่าเฉลี่ยของแต่ละแบบจำลอง มีหน่วยเป็นเมกะวัตต์ (Megawatt หรือ MW)

2. ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน (Mean absolute percent error, MAPE) เพื่อทำการวัดว่าแบบจำลองพยากรณ์ค่าความคลาดเคลื่อนร้อยละเท่าใดจากจำนวนการพยากรณ์ทั้งหมด ค่าความคลาดเคลื่อนสามารถคำนวณได้จากสมการดังต่อไปนี้

$$MAPE = \frac{\left[\frac{\sum_{i=1}^n |y - \hat{y}_i|}{y} \right]}{n} \times 100 \quad (19)$$

เมื่อ y คือ ค่าที่เกิดขึ้นจริง \hat{y}_i คือ ค่าที่พยากรณ์ n คือจำนวนการพยากรณ์ทั้งหมด

ซึ่งในการพยากรณ์ความต้องการไฟฟ้าล่วงหน้า จะพยากรณ์ค่า 1 วันล่วงหน้า (48 ค่า) จากนั้นจะนำค่าความคลาดเคลื่อนที่ได้มาหาค่าเฉลี่ยของแต่ละแบบจำลอง มีหน่วยเป็นเปอร์เซ็นต์ (%)

5.2.3 ประสิทธิภาพของแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวศน์เน็ตเวิร์ก แบบวงกลับ ต่อกับหน่วยความจำระยะสั้นแบบยาว

แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวศน์เน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) เป็นแบบจำลองที่ปรับปรุงมาจากแบบจำลองกลไกจุดสนใจสนใจ 2 ชั้นร่วมกับนิเวศน์เน็ตเวิร์กแบบวงกลับที่ Qin และคณะ [19] นำเสนอไว้ โดยทำการเพิ่มหน่วยความจำระยะสั้นแบบยาวเพื่อให้สามารถพยากรณ์ข้อมูลแบบหลายช่วงเวลาได้ ผลการทดลองแสดงดังตารางที่ 2 และตารางที่ 3

ตารางที่ 2 ผลการทดลองเมื่อใช้แบบจำลอง D-LSTM กับแบบจำลองอื่น ๆ และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)

แบบจำลอง	ภาคกลาง	ภาคตะวันออกเฉียงเหนือ	ภาคใต้	ภาคเหนือ	เขตนครหลวง
GRU	356.32	128.98	66.93	91.88	354.11
LSTM	357.43	135.99	67.60	97.30	289.68
CNN-LSTM	336.31	130.16	65.64	91.74	356.29
DA-RNN	440.85	171.74	97.43	122.76	453.28
D-LSTM	194.88	71.48	33.35	47.14	96.61

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

ตารางที่ 3 ผลการทดลองเมื่อใช้แบบจำลอง D-LSTM กับแบบจำลองอื่น ๆ และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

แบบจำลอง	ภาคกลาง	ภาคตะวันออกเฉียงเหนือ	ภาคใต้	ภาคเหนือ	เขตนครหลวง
GRU	2.95%	4.19%	2.33%	3.52%	3.37%
LSTM	3.02%	4.35%	2.42%	3.68%	3.79%
CNN-LSTM	2.82%	4.19%	2.32%	3.54%	3.34%
DA-RNN	3.96%	5.85%	3.59%	4.97%	4.24%
D-LSTM	1.87%	2.38%	1.24%	1.81%	1.03%

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

จากผลการทดลองที่แสดงในตารางที่ 2 และ 3 เปรียบเทียบผลการพยากรณ์ความต้องการไฟฟ้าโดยใช้แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) และแบบจำลองในหัวข้อ 5.1 พบว่าเมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน (RMSE) และค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน (MAPE) แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) สามารถพยากรณ์ค่าความต้องการไฟฟ้าล่วงหน้า 48 ชั่วโมงหรือ 1 วันได้มีความแม่นยำสูงกว่าแบบจำลองอื่น ๆ ทั้งหมดที่สร้างขึ้นเพื่อใช้เปรียบเทียบประสิทธิภาพ

แบบจำลองโครงข่ายประตูกลับสองทิศทาง (GRU) หน่วยความจำระยะสั้นแบบยาว (LSTM) และนิเวรอลเน็ตเวิร์กคอนโวลูชันต่อกับหน่วยความจำระยะสั้นแบบยาว (CNN-LSTM) มีการเรียนรู้โดยที่จะพิจารณาคุณลักษณะทุก ๆ คุณลักษณะเท่า ๆ กัน แม้ว่าความสำคัญของแต่ละคุณลักษณะที่มีต่อความต้องการไฟฟ้าจะแตกต่างกันก็ตาม จึงทำให้มีความคลาดเคลื่อนที่มากกว่าแบบจำลอง D-LSTM

สำหรับแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับ (DA-RNN) ที่พยากรณ์ความต้องการไฟฟ้าล่วงหน้า 48 ชั่วโมงแบบไม่วนซ้ำนั้นมีความคลาดเคลื่อนมากกว่าแบบจำลอง D-LSTM ที่มีการวนซ้ำและทุก ๆ แบบจำลองที่ทำการทดลอง ซึ่งทางผู้วิจัยได้ทำการวิเคราะห์ถึงผลการทดลองในส่วนนี้ไว้ คือแบบจำลอง DA-RNN ในขั้นตอนสุดท้ายที่จะพยากรณ์มีการใช้งานผลเฉลยของช่วงเวลาก่อนหน้า (t) มาพิจารณาเพื่อพยากรณ์ทำให้ค่าที่แบบจำลองพยากรณ์ได้จะมีความใกล้เคียงกับช่วงเวลาก่อนหน้าหรือเอนเอียงไปทางค่าของช่วงเวลาก่อนหน้า (bias) และการพยากรณ์แบบหลายช่วงเวลาจะมีจำนวนพารามิเตอร์มากทำให้ฝึกสอนได้ยากด้วย

นอกจากนั้นผู้วิจัยได้ศึกษางานวิจัยเพิ่มเติม และพบว่ามียางานวิจัยที่ทดลองและพบว่าการพยากรณ์ไฟฟ้าแบบวนซ้ำให้ค่าความคลาดเคลื่อนที่น้อยกว่า ซึ่งในงานวิจัย [33-35] ที่มีการเปรียบเทียบแบบจำลองที่พยากรณ์ข้อมูลอนุกรมเวลาแบบวนซ้ำ และแบบไม่วนซ้ำเช่นเดียวกันนั้น พบว่าการพยากรณ์แบบวนซ้ำสามารถลดค่าความคลาดเคลื่อนของแบบจำลองได้ในกรณีที่ข้อมูลอนุกรมเวลานั้น ๆ ไม่มีความเปลี่ยนแปลงมาก เช่นเดียวกับการพยากรณ์ความต้องการไฟฟ้าได้ เนื่องจากข้อมูลความต้องการไฟฟ้าที่เป็นค่ารวมทั้งเขตการควบคุมของ กฟผ. นั้นเป็นข้อมูลที่ไม่มีเปลี่ยนแปลงมาก รูปแบบของข้อมูลไม่ยุ่งยาก ทำให้สามารถคาดเดาได้ง่าย จึงทำให้การพยากรณ์แบบวนซ้ำให้ค่าความคลาดเคลื่อนที่น้อยกว่าการพยากรณ์แบบไม่วนซ้ำ นอกจากนี้แบบจำลองที่มีจำนวนตัวแปรมาก จะสามารถปรับพารามิเตอร์ให้ประสิทธิภาพที่ดีที่สุดได้ยากกว่าด้วย

5.2.4 ประสิทธิภาพของแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาวและการสกัดคุณลักษณะโดยใช้นิเวรอลเน็ตเวิร์กคอนโวลูชัน

หัวข้อนี้จะใช้งานแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาวและการสกัดคุณลักษณะโดยใช้นิเวรอลเน็ตเวิร์กคอนโวลูชัน (D-LSTM+F_{CNN}) และจะเปรียบเทียบผลการทดลองกับแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) เพื่อดูประสิทธิภาพของแบบจำลองจากการเพิ่มการสกัดคุณลักษณะในแบบจำลอง โดยผลการทดลองแสดงดังตารางที่ 4 และตารางที่ 5

ตารางที่ 4 ผลการทดลองเมื่อใช้แบบจำลองที่มีและไม่มีส่วนของการสกัดคุณลักษณะ และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)

พื้นที่	D-LSTM	D-LSTM+F _{CNN}		
		แบบที่ 1	แบบที่ 2	แบบที่ 3
ภาคกลาง	194.88	<u>189.48</u>	253.80	204.35
ภาคตะวันออกเฉียงเหนือ	71.48	<u>60.69</u>	64.45	96.99
ภาคใต้	33.35	31.36	<u>30.27</u>	30.94
ภาคเหนือ	47.14	46.31	<u>45.73</u>	47.68
เขตนครหลวง	96.61	<u>95.64</u>	173.39	147.65

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

ตารางที่ 5 ผลการทดลองเมื่อใช้แบบจำลองที่มีและไม่มีส่วนของการสกัดคุณลักษณะ และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

พื้นที่	D-LSTM	D-LSTM+F _{CNN}		
		แบบที่ 1	แบบที่ 2	แบบที่ 3
ภาคกลาง	1.87%	<u>1.81%</u>	2.53%	1.93%
ภาคตะวันออกเฉียงเหนือ	2.38%	<u>1.96%</u>	2.13%	3.51%
ภาคใต้	1.24%	1.16%	<u>1.12%</u>	1.14%
ภาคเหนือ	1.81%	1.78%	<u>1.76%</u>	1.85%
เขตนครหลวง	1.03%	<u>1.02%</u>	2.17%	1.83%

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

D-LSTM+F_{CNN} แบบที่ 1 แบบที่ 2 และแบบที่ 3 คือ แบบจำลองที่มีโครงสร้างของแบบจำลองเหมือนกัน แต่มีการจัดเรียงข้อมูลคุณลักษณะสำหรับนำเข้าแบบจำลองที่แตกต่างกัน โดยทั้ง 3 แบบจำลองมีพารามิเตอร์อื่น ๆ เหมือนกันทั้งหมด

จากผลการทดลองพบว่าแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาวและการสกัดคุณลักษณะโดยใช้นิเวรอลเน็ตเวิร์กคอนโวลูชัน (D-LSTM+F_{CNN}) ที่มีการใช้งานนิเวรอลเน็ตเวิร์กคอนโวลูชันในแบบจำลองตรงขั้นตอนนี้ก่อนที่จะเข้าแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวรอลเน็ตเวิร์กแบบวงกลับเพื่อหาค่าความสัมพันธ์ของคุณลักษณะต่าง ๆ ให้ประสิทธิภาพที่ดีกว่าแบบจำลอง D-LSTM ในทุกพื้นที่เมื่อใช้การจัดเรียงคุณลักษณะรูปแบบที่ 1 และให้ประสิทธิภาพที่ดีกว่าและแยกว่าแบบจำลอง D-LSTM ในบางพื้นที่เมื่อใช้การจัดเรียงคุณลักษณะรูปแบบที่ 2 และรูปแบบที่ 3

แบบจำลอง D-LSTM+F_{CNN} ที่มีการใช้งานนิรอลเน็ตเวิร์กคอนโวลูชันในแบบจำลองในขั้นตอนก่อนที่จะเข้าแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิรอลเน็ตเวิร์กแบบวกกลับนั้น ซึ่งผลลัพธ์จากนิรอลเน็ตเวิร์กคอนโวลูชันจะต้องเป็นเมตริกซ์ที่มีขนาดเท่ากับข้อมูลนำเข้าแบบจำลองเดิม เพื่อให้แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิรอลเน็ตเวิร์กแบบวกกลับสามารถทำงานในรูปแบบเดิมได้ โดยนิรอลเน็ตเวิร์กคอนโวลูชันที่เพิ่มเข้าไปในแบบจำลองจึงจำเป็นต้องใช้การเสริมเติม (padding) ซึ่งจะทำให้ตำแหน่งของคุณลักษณะในข้อมูลนำเข้าจะมีผลต่อประสิทธิภาพของแบบจำลอง โดยที่ไม่ได้แก้ไขโครงสร้างของแบบจำลอง

ผู้วิจัยจึงคิดว่าแบบจำลอง D-LSTM+F_{CNN} ที่มีการใช้งานนิรอลเน็ตเวิร์กคอนโวลูชันเพื่อสกัดคุณลักษณะนั้นไม่เหมาะสมในการเลือกใช้งาน เนื่องจากการสลับตำแหน่งของคุณลักษณะในการนำเข้าแบบจำลองส่งผลต่อประสิทธิภาพของแบบจำลองเพิ่มหรือลดได้ โดยแบบจำลองจะทดลองหลังจากนี้ผู้วิจัยจะเลือกใช้งานแบบจำลอง D-LSTM เพื่อปรับปรุงประสิทธิภาพให้สามารถพยากรณ์ได้มีความคลาดเคลื่อนน้อยที่สุด

หมายเหตุ การใช้งานนิรอลเน็ตเวิร์กคอนโวลูชัน มีการจัดเรียงตำแหน่งของข้อมูลนำเข้าได้หลากหลายรูปแบบ เพราะมี 10 คุณลักษณะ รวม 10! รูปแบบในการจัดเรียง โดยผู้วิจัยได้ทดลองมาเพียง 3 รูปแบบเท่านั้น ซึ่งผู้วิจัยอาจจะทดลองเจอในกรณีที่ส่งผลให้ค่าความคลาดเคลื่อนเปลี่ยนแปลง โดยที่อาจจะมียบางกรณีเมื่อสลับตำแหน่งของข้อมูลนำเข้าแล้ว ประสิทธิภาพของแบบจำลองอาจจะไม่เปลี่ยนแปลงเช่นกัน

5.3 ประสิทธิภาพของแบบจำลองเมื่อพิจารณาคุณลักษณะด้านพลังงานหมุนเวียน

การทดลองในหัวข้อนี้จะใช้การวัดผลและชุดข้อมูลจากหัวข้อ 5.2 แต่จะพิจารณาเพิ่มคุณลักษณะด้านพลังงานหมุนเวียนคือข้อมูลลม และข้อมูลฝนในแบบจำลอง D-LSTM โดยจะเรียกชื่อแบบจำลองนี้ว่า D-LSTM+wind+rain

5.3.1 ชุดข้อมูล

การทดลองนี้จะใช้แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิรอลเน็ตเวิร์กแบบวกกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) จะใช้คุณลักษณะเบื้องต้นเช่นเดียวกับการทดลองในหัวข้อก่อนหน้า และจะเพิ่มการพิจารณาคุณลักษณะด้านพลังงานหมุนเวียนเพิ่มเติม ดังนี้

1. ข้อมูลที่เป็นประเภทหมวดหมู่ คือ ข้อมูลที่นำเข้าแบบจำลองที่ไม่ใช่ตัวเลข

ในการทดลองนี้จะพิจารณาข้อมูลฝนเพิ่มเติม คือ ข้อมูลฝนตกหรือฝนไม่ตก เนื่องจากในประเทศไทยมีประชากรกลุ่มหนึ่งที่ใช้แผงโซลาร์ในการผลิตไฟฟ้าเพื่อใช้เองในครัวเรือนซึ่งมีจำนวนเพิ่มมากขึ้นเรื่อย ๆ ส่งผลให้ความต้องการไฟฟ้าจากระบบหลักนั้นมีรูปแบบที่เปลี่ยนแปลงไป โดยในเวลากลางวันจะมีความต้องการไฟฟ้าที่ลดลงจากสถิติเดิม นอกจากนั้นข้อมูลฝนตกหรือฝนไม่ตกจะส่งผลถึงรูปแบบการใช้ไฟฟ้าของประชากร เนื่องจากในวันที่ฝนไม่ตก อากาศจะร้อน ทำให้มีความต้องการไฟฟ้าเพิ่มมากขึ้นด้วย

2. ข้อมูลที่เป็นตัวเลข คือ ข้อมูลความเร็วลม (กม./ชม.) เพื่อพิจารณาถึงโรงไฟฟ้าพลังงานลม นอกจากนั้นความเร็วลมนั้นยังส่งผลต่อค่าอุณหภูมิตามความรู้สึกด้วย ซึ่งค่าอุณหภูมิตามความรู้สึก (Feels like temperature) เป็นอุณหภูมิอันใกล้เคียงความจริงที่ร่างกายจะได้สัมผัสหรืออุณหภูมิที่ผิวหนังจะรู้สึกได้จริง โดยค่าอุณหภูมิตามความรู้สึกเกิดจากการคำนวณค่าของอุณหภูมิ ความชื้น ความเร็วลม รังสีดวงอาทิตย์ รวมถึงปริมาณเมฆปกคลุมด้วย กล่าวคืออุณหภูมิที่วัดได้มีค่าเท่ากัน แต่หากองค์ประกอบของอากาศแตกต่างกัน ก็จะทำให้ความรู้สึกร้อนเย็นไม่เท่ากันนั่นเอง และทำให้ความต้องการไฟฟ้าแตกต่างกันด้วย

5.3.2 ผลการทดลอง

ผลการทดลองเมื่อมีการพิจารณาคุณลักษณะด้านพลังงานหมุนเวียนในแบบจำลอง D-LSTM พบว่าการเพิ่มข้อมูลความเร็วลมหรือข้อมูลฝน จะสามารถเพิ่มประสิทธิภาพของแบบจำลองได้ โดยการเพิ่มคุณลักษณะความเร็วลม (D-LSTM +wind) หรือฝน (D-LSTM+rain) สามารถลดค่าความคลาดเคลื่อนของแบบจำลองได้ ทั้งนี้การเพิ่มทั้งข้อมูลความเร็วลมและข้อมูลฝน (D-LSTM+wind+rain) ให้ค่าความคลาดเคลื่อนของ D-LSTM ที่น้อยที่สุด โดยผลการทดลองแสดงดังตารางที่ 6 และตารางที่ 7

ตารางที่ 6 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคุณลักษณะด้านพลังงานหมุนเวียน และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)

พื้นที่	D-LSTM	D-LSTM +wind	D-LSTM +rain	D-LSTM +wind+rain
ภาคกลาง	194.88	182.75	171.79	<u>163.65</u>
ภาคตะวันออกเฉียงเหนือ	71.48	54.06	54.2	<u>52.48</u>
ภาคใต้	33.35	30.14	29.44	<u>24.99</u>
ภาคเหนือ	47.14	45.25	44.19	<u>41.22</u>
เขตนครหลวง	96.61	75.42	76.03	<u>73.96</u>

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

ตารางที่ 7 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคุณลักษณะด้านพลังงานหมุนเวียน และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

พื้นที่	D-LSTM	D-LSTM +wind	D-LSTM +rain	D-LSTM +wind+rain
ภาคกลาง	1.87%	1.74%	1.62%	<u>1.59%</u>
ภาคตะวันออกเฉียงเหนือ	2.38%	1.74%	1.72%	<u>1.71%</u>
ภาคใต้	1.24%	1.09%	1.02%	<u>0.87%</u>
ภาคเหนือ	1.81%	1.75%	1.68%	<u>1.58%</u>
เขตนครหลวง	1.03%	0.81%	0.84%	<u>0.74%</u>

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

5.4 ประสิทธิภาพของแบบจำลองเมื่อพิจารณาค่าเฉลี่ยถ่วงน้ำหนักของความต้องการไฟฟ้า

การทดลองในหัวข้อนี้จะใช้การวัดผลและชุดข้อมูลจากหัวข้อ 5.2 แต่จะพิจารณาเพิ่มข้อมูลค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีตเพื่อให้แบบจำลองศึกษาแนวโน้มของข้อมูลเพื่อใช้พยากรณ์ข้อมูลความต้องการไฟฟ้าในอนาคต โดยจะเรียกชื่อแบบจำลองนี้ว่า D-LSTM+EMA

5.4.1 ชุดข้อมูล

การทดลองนี้จะใช้แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิวรอลเน็ตเวิร์กแบบวนกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) จะใช้คุณลักษณะเบื้องต้นเช่นเดียวกับการทดลองในหัวข้อ 5.2 แต่จะเพิ่มการพิจารณาคูณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีต (เมกะวัตต์) ด้วย

ความต้องการไฟฟ้าเป็นอนุกรมเวลาแบบที่มีฤดูกาล และมีความเกี่ยวข้องกับข้อมูลในอดีต ดังนั้นเราจะพิจารณาข้อมูล 2 ชุด เพื่อเป็นองค์ประกอบการพยากรณ์ความต้องการในอนาคต คือ ข้อมูลความต้องการไฟฟ้าในอดีตรายครึ่งชั่วโมง และข้อมูลค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน (Exponential Moving Average หรือ EMA) ซึ่งจะพิจารณา 2 ชุดข้อมูล คือ 1) ข้อมูลค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน 1 วัน และ 2) ข้อมูลค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อน 7 วัน เพื่อศึกษาแนวโน้มของความต้องการไฟฟ้าในอดีต โดยผู้วิจัยจะเรียกชื่อแบบจำลองที่มีการพิจารณาค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซ้ำซ้อนว่า D-LSTM+EMA

5.4.2 ผลการทดลอง

ผลการทดลองเมื่อมีการพิจารณาคูณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีตเป็นข้อมูลนำเข้าเพิ่มเติมในแบบจำลองดีเอสแอลแสดงดังตารางที่ 8 และตารางที่ 9

ตารางที่ 8 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคูณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีต และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)

พื้นที่	D-LSTM	D-LSTM +EMA
ภาคกลาง	194.88	<u>163.65</u>
ภาคตะวันออกเฉียงเหนือ	71.48	<u>52.48</u>
ภาคใต้	33.35	<u>24.99</u>
ภาคเหนือ	47.14	<u>41.22</u>
เขตนครหลวง	96.61	<u>73.96</u>

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

ตารางที่ 9 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาและไม่พิจารณาคูณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีต และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

พื้นที่	D-LSTM	D-LSTM +EMA
ภาคกลาง	1.87%	<u>1.58%</u>
ภาคตะวันออกเฉียงเหนือ	2.38%	<u>1.96%</u>
ภาคใต้	1.24%	<u>0.97%</u>
ภาคเหนือ	1.81%	<u>1.63%</u>
เขตนครหลวง	1.03%	<u>0.82%</u>

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

จากผลการทดลองพบว่าการเพิ่มคุณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีต เพื่อให้แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวโรลเน็ตเวิร์กแบบวกกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM+EMA) ศึกษาแนวโน้มของความต้องการไฟฟ้าในอดีตเพื่อพยากรณ์ค่าความต้องการไฟฟ้าในอนาคตนั้น สามารถเพิ่มประสิทธิภาพของแบบจำลองได้ โดยลดค่าความคลาดเคลื่อนของแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวโรลเน็ตเวิร์กแบบวกกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) ได้ในทุกชุดข้อมูลความต้องการไฟฟ้าในแต่ละพื้นที่ควบคุมของ กฟผ.

5.5 ประสิทธิภาพของแบบจำลองเมื่อพิจารณาคุณลักษณะด้านพลังงานหมุนเวียน และค่าเฉลี่ยถ่วงน้ำหนักของความต้องการไฟฟ้า

จากผลการทดลองในหัวข้อ 5.3 พบว่าการเพิ่มคุณลักษณะด้านพลังงานหมุนเวียนสามารถลดค่าความคลาดเคลื่อนของการพยากรณ์ได้ และผลการทดลองการเพิ่มคุณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีตที่แสดงในหัวข้อ 5.4 สามารถลดค่าความคลาดเคลื่อนของการพยากรณ์ได้เช่นกัน ดังนั้นผู้วิจัยจึงมีแนวคิดที่จะเพิ่มคุณลักษณะทั้งสองที่กล่าวมาข้างต้นมาใช้ในแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวโรลเน็ตเวิร์กแบบวกกลับต่อกับหน่วยความจำระยะสั้นแบบยาว เพื่อลดความคลาดเคลื่อนของแบบจำลองให้มากขึ้น โดยแบบจำลองในหัวข้อนี้จะใช้ชื่อว่า D-LSTM+wind+rain+EMA

5.5.1 ชุดข้อมูล

การทดลองนี้จะใช้แบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวโรลเน็ตเวิร์กแบบวกกลับต่อกับหน่วยความจำระยะสั้นแบบยาว จะใช้คุณลักษณะเบื้องต้นเช่นเดียวกับการทดลองในหัวข้อ 5.2 โดยจะเพิ่มทั้งการพิจารณาคูณลักษณะด้านพลังงานหมุนเวียน และคุณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีตด้วย

5.5.2 ผลการทดลอง

ตารางที่ 10 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาคุณลักษณะที่ต่างกัน และใช้ค่าเฉลี่ยของราคาทั้งสองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)

พื้นที่	D-LSTM	D-LSTM +wind+rain	D-LSTM +EMA	D-LSTM +wind+rain+EMA
ภาคกลาง	194.88	163.65	169.15	<u>162.50</u>
ภาคตะวันออกเฉียงเหนือ	71.48	52.48	59.3	<u>51.35</u>
ภาคใต้	33.35	24.99	26.16	<u>24.52</u>
ภาคเหนือ	47.14	41.22	42.02	<u>40.93</u>
เขตนครหลวง	96.61	73.96	76.58	<u>68.22</u>

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

ตารางที่ 11 ผลการทดลองเมื่อใช้แบบจำลองที่พิจารณาคุณลักษณะที่ต่างกัน และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

พื้นที่	D-LSTM	D-LSTM +wind+rain	D-LSTM +EMA	D-LSTM +wind+rain+EMA
ภาคกลาง	1.87%	1.59%	1.58%	<u>1.57%</u>
ภาคตะวันออกเฉียงเหนือ	2.38%	1.71%	1.96%	<u>1.66%</u>
ภาคใต้	1.24%	0.87%	0.97%	<u>0.86%</u>
ภาคเหนือ	1.81%	1.58%	1.63%	<u>1.55%</u>
เขตนครหลวง	1.03%	0.74%	0.82%	<u>0.71%</u>

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

จากผลการทดลองจากตารางที่ 10 และตารางที่ 11 พบว่าการทดลองที่มีการพิจารณาทั้งคุณลักษณะค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีต และคุณลักษณะด้านพลังงานหมุนเวียนในแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวศเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM+wind+rain+EMA) สามารถลดค่าความคลาดเคลื่อนของแบบจำลองกลไกจุดสนใจ 2 ชั้นร่วมกับนิเวศเน็ตเวิร์กแบบวงกลับต่อกับหน่วยความจำระยะสั้นแบบยาว (D-LSTM) ได้มากกว่าการเพิ่มคุณลักษณะเพียงอย่างเดียวหนึ่ง และแบบจำลอง D-LSTM+wind+rain+EMA เป็นแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

5.6 ประสิทธิภาพเมื่อใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร

การทดลองในหัวข้อนี้จะใช้ชุดข้อมูลเช่นเดียวกับหัวข้อ 5.5 และจะพิจารณาปรับปรุงฟังก์ชันต้นทุนเนื่องจากในการพยากรณ์ความต้องการไฟฟ้าที่พยากรณ์ได้ต่ำกว่าค่าความต้องการไฟฟ้าจริงจะส่งผลกระทบต่อระบบโดยสามารถทำให้เกิดไฟฟ้าดับ และกระทบต่อระบบเศรษฐกิจได้ ผู้วิจัยจึงมีแนวคิดที่จะออกแบบฟังก์ชันต้นทุนสำหรับงานพยากรณ์ความต้องการไฟฟ้า โดยจะให้ค่าฟังก์ชันต้นทุนที่สูงกว่ากับค่าพยากรณ์ที่ต่ำกว่าผลเฉลย เพื่อให้การพยากรณ์ความต้องการไฟฟ้าที่ต่ำกว่าผลเฉลยมีแนวโน้มของค่าพยากรณ์ที่สูงขึ้นเพื่อลดโอกาสการเกิดไฟฟ้าดับ

ในหัวข้อนี้จะแสดงการเปรียบเทียบผลการทดลองการพยากรณ์ความต้องการไฟฟ้า โดยใช้ฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง และใช้ฟังก์ชันต้นทุนแบบไม่สมมาตร ซึ่งผู้วิจัยจะนำแบบจำลองที่มีประสิทธิภาพที่ดีที่สุดจากการทดลองที่ผ่านมาทดลองต่อในหัวข้อนี้

5.6.1 การวัดผล

สำหรับการใช้งานฟังก์ชันต้นทุนที่ใช้ในงานวิจัยนี้ มีจุดประสงค์เพื่อให้ค่าพยากรณ์ที่ต่ำกว่าผลเฉลยมีแนวโน้มที่สูงขึ้น จึงจะมีการวัดประสิทธิภาพเพิ่มเติมจากหัวข้อ 5.2 ดังนี้

1. ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนของค่าพยากรณ์ที่สูงกว่าผลเฉลย เพื่อทำการวัดความคลาดเคลื่อนของแบบจำลองกรณีที่พยากรณ์**สูงกว่าผลเฉลย** ว่าแบบจำลองพยากรณ์ค่าความคลาดเคลื่อนร้อยละเท่าใดจากจำนวนการพยากรณ์ที่**สูงกว่าผลเฉลย**ทั้งหมด
2. ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนของค่าพยากรณ์ที่ต่ำกว่าผลเฉลย เพื่อทำการวัดความคลาดเคลื่อนของแบบจำลองกรณีที่พยากรณ์**ต่ำกว่าผลเฉลย** ว่าแบบจำลองพยากรณ์ค่าความคลาดเคลื่อนร้อยละเท่าใดจากจำนวนการพยากรณ์ที่**ต่ำกว่าผลเฉลย**ทั้งหมด
3. จำนวนครั้งที่เกิดไฟฟ้าดับ

5.6.2 พารามิเตอร์ที่ใช้การคำนวณฟังก์ชันต้นทุนแบบไม่สมมาตร

งานวิจัยนี้จะใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรสำหรับการพยากรณ์ความต้องการไฟฟ้า ($Loss_{asym}$) โดยจะให้ค่าต้นทุนที่สูงกว่าสำหรับการพยากรณ์ที่ต่ำกว่าผลเฉลย เพื่อให้การพยากรณ์ที่ต่ำกว่าผลเฉลยมีแนวโน้มที่สูงขึ้นและลดโอกาสการเกิดไฟฟ้าดับ

ฟังก์ชันต้นทุนแบบไม่สมมาตรที่ใช้งานนี้จะให้ค่าดังนี้

1. กรณีที่พยากรณ์สูงกว่าผลเฉลย : MSE
2. กรณีที่พยากรณ์ต่ำกว่าผลเฉลย : $\mu * MSE$

โดยค่า μ เป็นพารามิเตอร์

ค่า μ ที่ดีที่สุดสำหรับแต่ละพื้นที่ในการพยากรณ์ความต้องการไฟฟ้าดังตารางที่ 12

ตารางที่ 12 ค่าพารามิเตอร์ที่ดีที่สุด (μ) สำหรับฟังก์ชันต้นทุนแบบไม่สมมาตร

พื้นที่	ค่า μ กรณีพยากรณ์ต่ำกว่าผลเฉลย
ภาคกลาง	2.5
ภาคตะวันออกเฉียงเหนือ	1.5
ภาคใต้	2
ภาคเหนือ	1.5
เขตนครหลวง	3

ในเขตภาคกลางและเขตนครหลวงมีค่า μ ที่สูงกว่าพื้นที่อื่น ๆ เนื่องจากมีโรงงานและบริษัทจำนวนมาก โดยในวันทำงานความต้องการไฟฟ้าจะมีค่าน้อยในช่วงก่อนเริ่มงาน เพราะเป็นช่วงเวลาเดินทาง และความต้องการไฟฟ้าจะเพิ่มสูงขึ้นในช่วงเวลาทำงาน ส่งผลให้แบบจำลองพยากรณ์ไฟฟ้าได้มีค่าต่ำกว่าค่าความต้องการไฟฟ้าจริง ในช่วงที่ความต้องการไฟฟ้าสูงขึ้นอย่างรวดเร็ว จึงต้องมีค่า μ ที่สูงกว่าเขตปฏิบัติการอื่น ๆ

5.6.3 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน

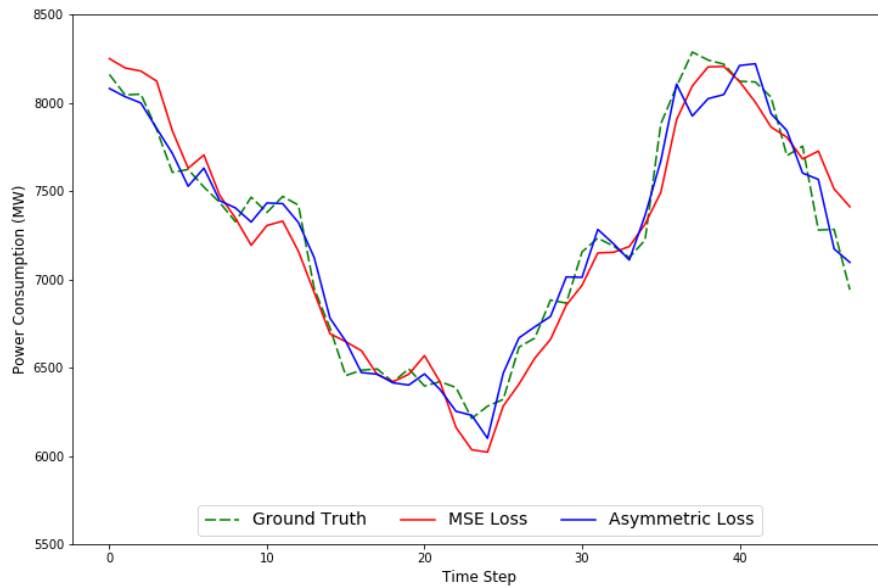
ตารางที่ 13 ผลการทดลองเมื่อใช้ฟังก์ชันต้นทุนที่ต่างกัน และใช้ค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเมกะวัตต์ (MW)

พื้นที่	D-LSTM +wind+rain+EMA	D-LSTM +wind+rain+EMA+Loss _{asym}
ภาคกลาง	162.50	148.23
ภาคตะวันออกเฉียงเหนือ	51.35	48.01
ภาคใต้	24.52	23.49
ภาคเหนือ	40.93	38.56
เขตนครหลวง	68.22	62.60

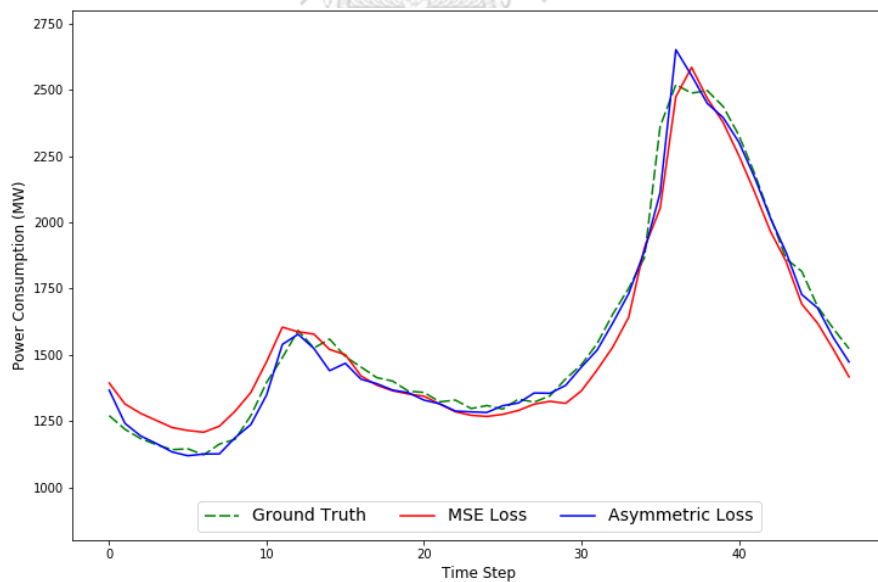
ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

จากผลการทดลองในตารางที่ 13 พบว่าการใช้ฟังก์ชันต้นทุนแบบไม่สมมาตรกับแบบจำลองที่ดีที่สุดจากหัวข้อ 5.5 (D-LSTM+wind+rain+EMA+Loss_{asym}) นั้นสามารถพยากรณ์ความต้องการไฟฟ้าได้คลาดเคลื่อนน้อยกว่าแบบจำลองเดียวกันที่ใช้งานฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง

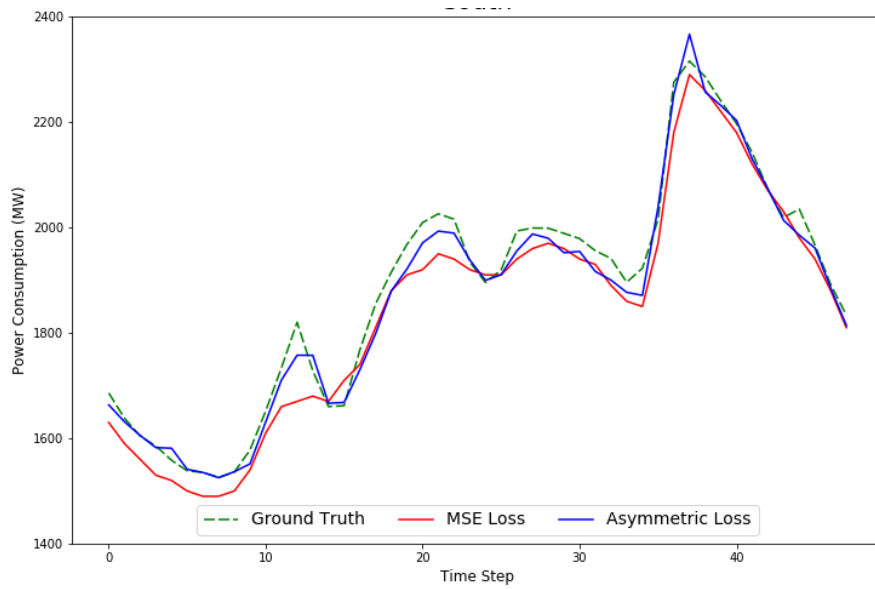
ผู้วิจัยได้ทำการสร้างกราฟเปรียบเทียบผลการพยากรณ์ขึ้นมาเพื่อตรวจสอบว่า การพยากรณ์ของแบบจำลองที่ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร ($Loss_{asym}$) นั้น สามารถพยากรณ์ได้ใกล้เคียงกว่าแบบจำลองที่ใช้งานฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสองหรือไม่ และในช่วงที่ฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสองพยากรณ์ได้ต่ำกว่าผลเฉลย การใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรสามารถพยากรณ์ให้สูงขึ้นได้หรือไม่



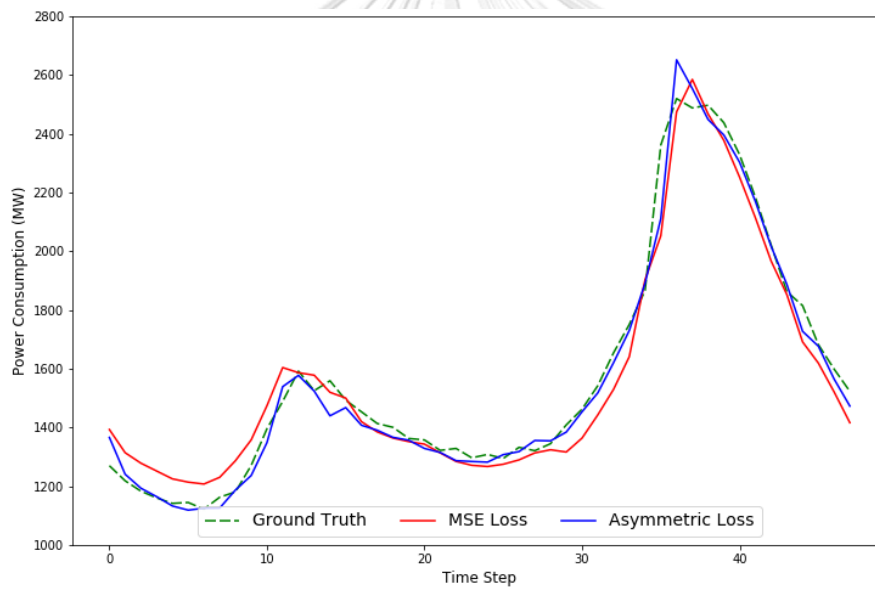
รูปที่ 20 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาคกลาง



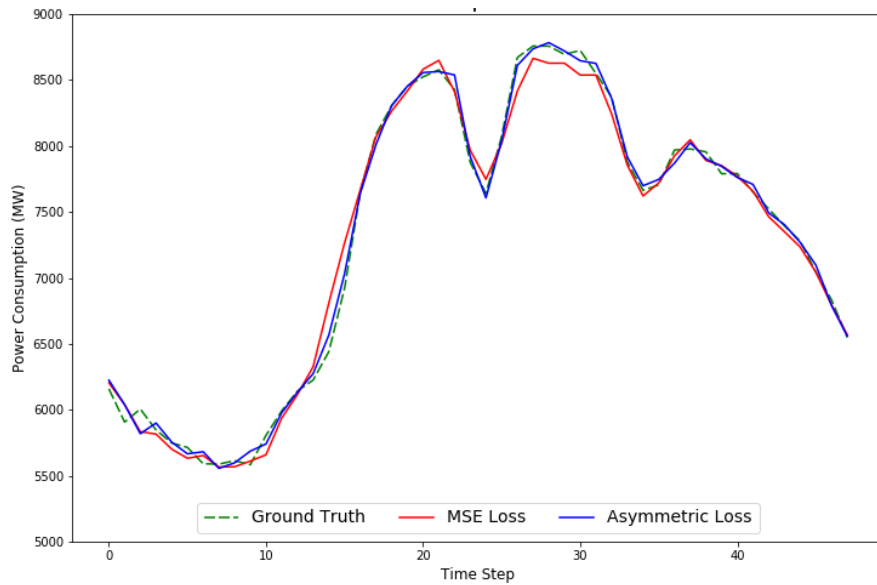
รูปที่ 21 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาคตะวันออกเฉียงเหนือ



รูปที่ 22 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาคใต้



รูปที่ 23 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของภาคเหนือ



รูปที่ 24 กราฟเปรียบเทียบการพยากรณ์เมื่อมีการใช้งานฟังก์ชันต้นทุนที่แตกต่างกันของเขตนครหลวง

จากรูปที่ 20-24 พบว่าแบบจำลองที่ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร ($Loss_{asym}$) ที่นำเสนอในงานวิจัยนี้ สามารถพยากรณ์ความต้องการไฟฟ้าได้ใกล้เคียงกับผลเฉลยในเกือบทุกช่วงเวลา โดยมีค่าความคลาดเคลื่อนน้อยกว่าแบบจำลองที่ใช้งานฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง

5.6.4 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน

ตารางที่ 14 ผลการทดลองเมื่อใช้ฟังก์ชันต้นทุนที่แตกต่างกัน และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนเป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

พื้นที่	D-LSTM +wind+rain+EMA	D-LSTM +wind+rain+EMA+ $Loss_{asym}$
ภาคกลาง	1.57%	<u>1.38%</u>
ภาคตะวันออกเฉียงเหนือ	1.66%	<u>1.53%</u>
ภาคใต้	0.86%	<u>0.85%</u>
ภาคเหนือ	1.55%	<u>1.44%</u>
เขตนครหลวง	0.71%	<u>0.65%</u>

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

จากผลการทดลองในตารางที่ 14 พบว่าแบบจำลอง D-LSTM+wind+rain+EMA+Loss_{asym} ที่ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรที่ออกแบบมานั้น มีค่าความคลาดเคลื่อนน้อยกว่าแบบจำลอง D-LSTM+wind+rain+EMA ที่ใช้งานฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง เมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อน ดังนั้นการเปลี่ยนฟังก์ชันต้นทุนทำให้สามารถลดค่าความคลาดเคลื่อนของแบบจำลองได้

5.6.5 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนแบบแยกค่าพยากรณ์

ตารางที่ 15 ผลการทดลองเมื่อใช้ฟังก์ชันต้นทุนที่แตกต่างกัน และใช้ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนแบบแยกค่าพยากรณ์เป็นตัววัดประสิทธิภาพ โดยมีหน่วยเป็นเปอร์เซ็นต์ (%)

พื้นที่	D-LSTM +wind+rain+EMA		D-LSTM +wind+rain+EMA+Loss _{asym}	
	ค่าพยากรณ์ต่ำกว่าผลเฉลี่ย	ค่าพยากรณ์สูงกว่าผลเฉลี่ย	ค่าพยากรณ์ต่ำกว่าผลเฉลี่ย	ค่าพยากรณ์สูงกว่าผลเฉลี่ย
ภาคกลาง	1.69%	1.34%	1.43%	1.32%
ภาคตะวันออกเฉียงเหนือ	1.65%	1.66%	1.50%	1.55%
ภาคใต้	0.91%	0.85%	0.88%	0.82%
ภาคเหนือ	1.48%	1.62%	1.41%	1.47%
เขตนครหลวง	0.69%	0.73%	0.60%	0.69%

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

จากผลการทดลองในตารางที่ 15 ที่เป็นการวัดประสิทธิภาพของแบบจำลองโดยจะแยกค่าพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลี่ย พบว่าแบบจำลอง D-LSTM+wind+rain+EMA+Loss_{asym} ที่ใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตรที่ออกแบบมานั้น สามารถลดค่าความคลาดเคลื่อนได้ทั้งการพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลี่ย เมื่อเปรียบเทียบกับแบบจำลอง D-LSTM+wind+rain+EMA ที่ใช้ฟังก์ชันต้นทุนค่าเฉลี่ยความผิดพลาดกำลังสอง

จากตารางที่ 14 และ 15 พบว่าการใช้งานฟังก์ชันต้นทุนแบบไม่สมมาตร (Loss_{asym}) นั้นสามารถลดค่าความคลาดเคลื่อนของข้อมูลทั้งหมดได้ รวมถึงสามารถลดค่าความคลาดเคลื่อนของการพยากรณ์ที่มีค่าสูงกว่าและต่ำกว่าผลเฉลี่ยด้วย

5.6.6 ประสิทธิภาพแบบจำลองเมื่อวัดประสิทธิภาพด้วยจำนวนครั้งที่เกิดไฟฟ้าดับ

ตารางที่ 16 จำนวนครั้งที่ส่งผลให้เกิดไฟฟ้าดับของแบบจำลองต่าง ๆ เมื่อมีกำลังผลิตสำรองพร้อมจ่ายทันที 800 และ 1,500 เมกะวัตต์ โดยมีหน่วยเป็นครั้ง

แบบจำลอง	จำนวนครั้งที่เกิดไฟฟ้าดับเมื่อมีกำลังผลิตสำรองพร้อมจ่ายทันทีค่าต่าง ๆ (ครั้ง)	
	800 เมกะวัตต์ (ค่าต่ำที่สุด)	1,500 เมกะวัตต์ (ค่าสูงที่สุด)
D-LSTM	279	4
D-LSTM+wind+rain+EMA	41	1
D-LSTM+wind+rain+EMA+Loss _{asym}	32	1

ตัวอักษรหนาและขีดเส้นใต้ คือแบบจำลองที่มีค่าความคลาดเคลื่อนน้อยที่สุด

ในการพยากรณ์ความต้องการไฟฟ้าสิ่งที่สำคัญมากที่สุดคือ ระบบไฟฟ้าจะต้องมีความมั่นคง ป้องกันไม่ให้เกิดไฟฟ้าดับซึ่งจะส่งผลกระทบต่อประชาชน และภาคอุตสาหกรรม ดังนั้นในระบบไฟฟ้าจึงจะมีกำลังผลิตสำรองพร้อมจ่ายทันทีเพื่อรองรับความเสี่ยงจากความผันผวนของความต้องการไฟฟ้า หากมีความต้องการไฟฟ้าจริงสูงกว่าปริมาณไฟฟ้าที่สามารถผลิตได้เกินกว่ากำลังผลิตสำรองพร้อมจ่ายทันทีจะส่งผลให้เกิดไฟฟ้าดับได้ ผู้วิจัยจึงนำผลการพยากรณ์ที่ใช้แบบจำลองต่าง ๆ มาวิเคราะห์ค่าพยากรณ์ที่ส่งผลทำให้เกิดไฟฟ้าดับได้

ผลการทดลองในตารางที่ 16 พบว่าการเพิ่มการพิจารณาคุณลักษณะด้านพลังงานหมุนเวียน และค่าเฉลี่ยถ่วงน้ำหนักของค่าความต้องการไฟฟ้าในอดีตสามารถลดจำนวนครั้งในการเกิดไฟฟ้าดับได้ และการนำฟังก์ชันต้นทุนแบบไม่สมมาตร (Loss_{asym}) มาประยุกต์ใช้ในการพยากรณ์ความต้องการไฟฟ้านั้น ช่วยลดโอกาสการเกิดไฟฟ้าดับได้มากยิ่งขึ้น

การนำฟังก์ชันต้นทุนแบบไม่สมมาตร (Loss_{asym}) มาประยุกต์ใช้ในการพยากรณ์ความต้องการไฟฟ้า สามารถเพิ่มประสิทธิภาพของแบบจำลองได้ โดยสามารถลดค่าความคลาดเคลื่อนได้ในทุกตัววัดประสิทธิภาพทั้งค่าเฉลี่ยของรากที่สองของกำลังสองของความคลาดเคลื่อน ค่าเฉลี่ยของค่าสัมบูรณ์ของเปอร์เซ็นต์ของความคลาดเคลื่อนแบบคำนวณจากข้อมูลทั้งหมด และคำนวณแบบแยกค่าพยากรณ์ที่สูงกว่าและต่ำกว่าผลเฉลย รวมถึงสามารถลดโอกาสในการเกิดไฟฟ้าดับได้ด้วย

บทที่ 6

สรุปผลการวิจัยและแนวทางการวิจัยในขั้นถัดไป

6.1 สรุปผลการวิจัย

วิทยานิพนธ์ชิ้นนี้ ได้นำเสนอแนวคิดและแบบจำลองที่ใช้พยากรณ์ความต้องการไฟฟ้าของประเทศไทยในแต่ละพื้นที่ควบคุมของการไฟฟ้าฝ่ายผลิตแห่งประเทศไทย ซึ่งแบบจำลองจะมุ่งเน้นการพยากรณ์ความต้องการไฟฟ้าของวันถัดไปรายครึ่งชั่วโมงรวมทั้งหมด 48 ช่วงเวลาให้มีความคลาดเคลื่อนน้อยที่สุด นอกจากนี้ยังได้นำเสนอฟังก์ชันต้นทุนแบบไม่สมมาตรที่ใช้ในการฝึกสอนแบบจำลองโดยมีเป้าหมายเพื่อลดความคลาดเคลื่อนของแบบจำลองและลดโอกาสการเกิดไฟฟ้าดับ

แบบจำลองที่นำเสนอ นั้นจะนำแบบจำลอง DA-RNN มาทำงานร่วมกับ LSTM และ CNN โดยใช้ Asymmetric Loss Function ในการฝึกสอนแบบจำลอง ซึ่งจะใช้ชื่อว่า $D\text{-LSTM}+F_{\text{CNN}}+\text{Loss}_{\text{asym}}$ โดยแบบจำลองที่นำเสนอ นั้นจะสามารถพิจารณาให้ค่า attention ที่ไม่เท่ากันสำหรับแต่ละช่วงเวลาในอดีต และสำหรับข้อมูลคุณลักษณะแต่ละตัวที่นำเข้าไปแบบจำลอง สำหรับข้อมูลที่นำเข้าไปแบบจำลองนั้นมีหลากหลายข้อมูลโดยมีการพิจารณาข้อมูลความต้องการไฟฟ้าในอดีต รวมถึงข้อมูลคุณลักษณะต่าง ๆ ที่เกี่ยวข้อง คือ ข้อมูลเกี่ยวกับอากาศ ข้อมูลประเภทของวัน ข้อมูลด้านพลังงานหมุนเวียน และข้อมูลค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อนของความต้องการไฟฟ้าเพราะคุณลักษณะต่าง ๆ นี้ส่งผลกระทบต่อความต้องการไฟฟ้า

จากผลการทดลองโดยใช้ข้อมูลความต้องการไฟฟ้ายรายครึ่งชั่วโมงจากการไฟฟ้าฝ่ายผลิตแห่งประเทศไทยปี 2010-2018 พบว่าแบบจำลองที่ดีที่สุดคือแบบจำลองที่มีการใช้งาน DA-RNN ร่วมกับ LSTM และพิจารณาคุณลักษณะทุก ๆ คุณลักษณะที่นำเสนอไว้ โดยใช้ฟังก์ชัน Asymmetric Loss Function ในการฝึกสอนแบบจำลอง ซึ่งแบบจำลองนี้มีชื่อเรียกว่า $D\text{-LSTM}+\text{wind}+\text{rain}+\text{EMA}+\text{Loss}_{\text{asym}}$ โดยแบบจำลองที่มีพิจารณาข้อมูลเกี่ยวกับอากาศ และข้อมูลประเภทของวันร่วมกับข้อมูลความต้องการไฟฟ้าในอดีต สามารถพยากรณ์ความต้องการไฟฟ้าให้มีความคลาดเคลื่อนน้อยกว่าแบบจำลองที่นำมาเปรียบเทียบประสิทธิภาพทุก ๆ แบบจำลอง คือค่าความคลาดเคลื่อน (MAPE) น้อยกว่าแบบจำลอง GRU 1.61% แบบจำลอง LSTM 1.79% แบบจำลอง CNN-LSTM 1.58% และแบบจำลอง DA-RNN 2.86% จากนั้นผู้วิจัยได้เพิ่มข้อมูลด้านพลังงานหมุนเวียนคือข้อมูลลมและข้อมูลฝนพบว่าความคลาดเคลื่อนเฉลี่ยลดลง 0.37% เมื่อพิจารณาข้อมูลค่าเฉลี่ยเคลื่อนที่แบบถ่วงน้ำหนักซับซ้อนของความต้องการไฟฟ้าเพิ่มเติมทำให้ค่าความคลาดเคลื่อนลดลงอีก 0.03% จากนั้นผู้วิจัยได้ทดลองฝึกสอนแบบจำลองโดยใช้งาน Asymmetric Loss Function พบว่ามีความคลาดเคลื่อนน้อยกว่าการใช้งาน Mean Squared Error Loss Function 0.1% และเมื่อวิเคราะห์จำนวนการเกิดไฟฟ้าดับพบว่าเมื่อมีค่ากำลังผลิตสำรองพร้อมจ่ายทันที 800 เมกะวัตต์ จะสามารถลดจำนวนการเกิดไฟฟ้าดับได้ 9 ครั้ง

6.2 แนวทางการวิจัยถัดไป

แนวทางการวิจัยถัดไปมีอยู่ 3 หัวข้อ ดังนี้

- 1) ในงานวิจัยนี้ใช้ข้อมูลตัวเลขเพียงอย่างเดียว ในการพยากรณ์ความต้องการไฟฟ้า แนวทางที่น่าสนใจคือ หากสามารถหาข้อมูลที่เป็นประเภทรูปภาพ เช่น ภาพถ่ายดาวเทียม เป็นต้น ซึ่งภาพถ่ายดาวเทียมจะสามารถบอกถึงตำแหน่งของพายุหรือพยากรณ์ช่วงเวลาพายุจะเข้าได้ เมื่อนำมาประกอบกับข้อมูลอนุกรมเวลาในการพยากรณ์ผู้วิจัยคาดว่ามีโอกาสที่จะช่วยลดความคลาดเคลื่อนของการพยากรณ์ความต้องการไฟฟ้าได้
- 2) ในงานวิจัยนี้ใช้ตัวบ่งชี้ (indicator) คือค่าเฉลี่ยถ่วงน้ำหนักเพียงตัวเดียว ซึ่งเราอาจจะเพิ่มการพิจารณาตัวบ่งชี้อื่น ๆ ที่เกี่ยวข้อง เพื่อให้สามารถช่วยลดความคลาดเคลื่อนของการพยากรณ์ได้
- 3) ในปัจจุบันเริ่มมีอุตสาหกรรมบางประเภท มีการผลิตกระแสไฟฟ้าเพื่อใช้เอง นอกจากนั้นยังขายคืนเข้าสู่ระบบด้วย ซึ่งในแบบจำลองของเรายังไม่สามารถรองรับในส่วนนี้ได้



บรรณานุกรม

- [1] P. K. Jain, W. Quamer, and R. Pamula, "Electricity Consumption Forecasting Using Time Series Analysis," vol. 906, pp. 327-335, 2018.
- [2] J. Song and E. Hwang, *Hybrid Day-ahead Load Forecasting with Atypical Residue based Gaussian Process Regression*. 2018, pp. 631-634.
- [3] S. Cosmis, R. De Leone, E. Kropat, S. Meyer-Nieberg, and S. Pickl, *Electric load forecasting using support vector machines for robust regression*. 2013.
- [4] C. C. Olegario, A. D. Coronel, R. P. Medina, and B. D. Gerardo, "A hybrid approach towards improved artificial neural network training for short-term load forecasting," presented at the Proceedings of the 2018 International Conference on Data Science and Information Technology, Singapore, Singapore, 2018.
- [5] A. Kell, A. S. McGough, and M. Forshaw, "Segmenting Residential Smart Meter Data for Short-Term Load Forecasting," pp. 91-96, 2018.
- [6] A. R. Khan, S. Razzaq, T. Alquthami, M. R. Moghal, A. Amin, and A. Mahmood, "Day ahead load forecasting for IESCO using Artificial Neural Network and Bagged Regression Tree," in *2018 1st International Conference on Power, Energy and Smart Grid (ICPESG)*, 2018, pp. 1-6.
- [7] C. Tong, J. Li, C. Lang, F. Kong, J. Niu, and J. Rodrigues, "An efficient deep model for day-ahead electricity load forecasting with stacked denoising auto-encoders," *Journal of Parallel and Distributed Computing*, vol. 117, 06/20 2017.
- [8] Z. Guo, K. Zhou, X. Zhang, and S. Yang, "A deep learning model for short-term power load and probability density forecasting," *Energy*, vol. 160, pp. 1186-1200, 2018.
- [9] R. Seunghyoung, N. Jaekoo, and K. Hongseok, "Deep neural network based demand side short term load forecasting," in *2016 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, 2016, pp. 308-313.
- [10] J. Yang and Q. Wang, *A Deep Learning Load Forecasting Method Based on Load Type Recognition*. 2018, pp. 173-177.
- [11] K. Amarasinghe, D. L. Marino, and M. Manic, "Deep neural networks for energy

- load forecasting," in *2017 IEEE 26th International Symposium on Industrial Electronics (ISIE)*, 2017, pp. 1483-1488.
- [12] T. Jarábek, P. Laurinec, and M. Lucká, "Energy load forecast using S2S deep neural networks with k-Shape clustering," in *2017 IEEE 14th International Scientific Conference on Informatics*, 2017, pp. 140-145.
- [13] H. Shi, M. Xu, Q. Ma, C. Zhang, R. Li, and F. Li, "A Whole System Assessment of Novel Deep Learning Approach on Short-Term Load Forecasting," *Energy Procedia*, vol. 142, pp. 2791-2796, 2017/12/01/ 2017.
- [14] R. K. Agrawal, F. Muchahary, and M. M. Tripathi, "Long term load forecasting with hourly predictions based on long-short-term-memory networks," in *2018 IEEE Texas Power and Energy Conference (TPEC)*, 2018, pp. 1-6.
- [15] M. Voß, C. Bender-Saebelkamp, and S. Albayrak, *Residential Short-Term Load Forecasting Using Convolutional Neural Networks*. 2018, pp. 1-6.
- [16] J.-L. Zhang, Y.-M. Wei, D. Li, Z. Tan, and J. Zhou, "Short term electricity load forecasting using a hybrid model," *Energy*, vol. 158, 06/01 2018.
- [17] T.-Y. Kim and S.-B. Cho, "Predicting the Household Power Consumption Using CNN-LSTM Hybrid Networks: 19th International Conference, Madrid, Spain, November 21–23, 2018, Proceedings, Part I," 2018, pp. 481-490.
- [18] W. He, "Load Forecasting via Deep Neural Networks," *Procedia Computer Science*, vol. 122, pp. 308-314, 2017/01/01/ 2017.
- [19] Y. Qin, D. Song, H. Cheng, W. Cheng, G. Jiang, and G. Cottrell, "A Dual-Stage Attention-Based Recurrent Neural Network for Time Series Prediction," 04/07 2017.
- [20] Y. Ahn and Y. Tsuchiya, "Asymmetric Loss and the Rationality of Inflation Forecasts: Evidence from South Korea: Asymmetry in Korea's Loss Functions," *Pacific Economic Review*, 03/01 2017.
- [21] Y. Kusunoki, J. Błaszczyszki, M. Inuiguchi, and S. Roman, "Interpretation of Variable Consistency Dominance-Based Rough Set Approach by Minimization of Asymmetric Loss Function," 2019, pp. 135-145.
- [22] Z. Wang, S. Ji, and B. Yu, "Short-Term Traffic Volume Forecasting with

- Asymmetric Loss Based on Enhanced KNN Method," *Mathematical Problems in Engineering*, vol. 2019, pp. 1-11, 2019.
- [23] K. Gkillas, R. Gupta, and C. Pierdzioch, "Forecasting realized oil-price volatility: The Role of financial stress and asymmetric loss," *Journal of International Money and Finance*, p. 102137, 01/01 2020.
- [24] M. A. H. Ashour and R. A. Abbas, "Improving Time Series' Forecast Errors by Using Recurrent Neural Networks," presented at the Proceedings of the 2018 7th International Conference on Software and Computer Applications, Kuantan, Malaysia, 2018.
- [25] L. Yunpeng, H. Di, B. Junpeng, and Q. Yong, "Multi-step Ahead Time Series Forecasting for Different Data Patterns Based on LSTM Recurrent Neural Network," in *2017 14th Web Information Systems and Applications Conference (WISA)*, 2017, pp. 305-310.
- [26] S. Li, H. Fang, and B. Shi, *Multi-Step-Ahead Prediction with Long Short Term Memory Networks and Support Vector Regression*. 2018, pp. 8104-8109.
- [27] Y.-Y. Chang, F.-Y. Sun, Y.-H. Wu, and S.-D. Lin, *A Memory-Network Based Solution for Multivariate Time-Series Forecasting*. 2018.
- [28] Y. Liang, S. Ke, J. Zhang, X. Yi, and Y. Zheng, *GeoMAN: Multi-level Attention Networks for Geo-sensory Time Series Prediction*. 2018, pp. 3428-3434.
- [29] Z. Pan, Y. Liang, J. Zhang, X. Yi, Y. Yu, and Y. Zheng, *HyperST-Net: Hypernetworks for Spatio-Temporal Forecasting*. 2018.
- [30] X. Wu, B. Shi, Y. Dong, C. Huang, L. Faust, and N. Chawla, *RESTFul: Resolution-Aware Forecasting of Behavioral Time Series Data*. 2018, pp. 1073-1082.
- [31] A. M. Ertugrul, Y.-R. Lin, and T. Taskaya Temizel, *CASTNet: Community-Attentive Spatio-Temporal Networks for Opioid Overdose Forecasting*. 2019.
- [32] Y. Liu, C. Gong, L. Yang, and Y. Chen, *DSTP-RNN: a dual-stage two-phase attention-based recurrent neural networks for long-term and multivariate time series prediction*. 2019.
- [33] S. A. R. Konakalla and R. d. Callafon, "Recursive power demand prediction based on multi-level clustering of power demand data," in *2017 IEEE International Conference on Smart Grid Communications (SmartGridComm)*, 2017, pp. 247-

252.

- [34] X. Shi, X. Lei, Q. Huang, S. Huang, K. Ren, and Y. Hu, "Hourly Day-Ahead Wind Power Prediction Using the Hybrid Model of Variational Model Decomposition and Long Short-Term Memory," *Energies*, vol. 11, no. 11, p. 3227, 2018.
- [35] A. Gasparin, S. Lukovic, and C. Alippi, *Deep Learning for Time Series Forecasting: The Electric Load Case*. 2019.



ประวัติผู้เขียน

ชื่อ-สกุล	ชูชวัญ สิริทิพากุล
วัน เดือน ปี เกิด	13 กรกฎาคม 2533
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	วศ.บ. (เกียรตินิยมอันดับหนึ่ง) วิศวกรรมคอมพิวเตอร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี (พ.ศ. 2552 - 2555)
ที่อยู่ปัจจุบัน	1/81 ซอย 60/1 ถนนพระรามที่ 2 แสมดำ บางขุนเทียน กทม. 10150



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY