

การใช้เทคนิคโครงข่ายประสาทเทียมเชิงลึกเพื่อพยากรณ์
ผลผลิตต่อไร่ข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือของไทย

USING DEEP NEURAL NETWORKS FOR THAI JASMINE RICE YIELD
PREDICTION IN THE NORTHEASTERN REGION OF THAILAND



นายอานนท์ บุญญวัฒน์
ANON BOONYAWATTANA

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาสถิติและวิเคราะห์ธุรกิจ
ภาควิชาสถิติ คณะวิทยาศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2567

KMITL-2024-SC-M-050-034

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

USING DEEP NEURAL NETWORKS FOR THAI JASMINE RICE YIELD
PREDICTION IN THE NORTHEASTERN REGION OF THAILAND



An INDEPENDENT STUDY SUBMITTED IN PARTIAL FULFILLMENT OF THE
REQUIREMENT FOR THE DEGREE OF MASTER OF SCIENCE IN STATISTICS AND
BUSINESS ANALYTICS

DEPARTMENT OF STATISTICS SCHOOL OF SCIENCE
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2024

KMITL-2024-SC-M-050-034

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2024

SCHOOL OF SCIENCE

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อการค้นคว้าอิสระ	การใช้เทคนิคโครงข่ายประสาทเทียมเชิงลึกเพื่อพยากรณ์ผลผลิตต่อไร่ข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือของไทย
ชื่อนักศึกษา	อานนท์ บุญญวัฒน์
รหัสประจำตัว	64605127
ปริญญา	วิทยาศาสตรมหาบัณฑิต (สถิติและการวิเคราะห์ธุรกิจ)
ภาควิชา	สถิติ
พ.ศ.	2567
อาจารย์ที่ปรึกษาการค้นคว้าอิสระ	ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิศักดิ์

บทคัดย่อ

งานวิจัยฉบับนี้มีวัตถุประสงค์เพื่อศึกษาปัจจัยที่มีอิทธิพลต่อผลผลิตต่อไร่ของข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือด้วยวิธีการถดถอยแบบป่าสุ่มและเปรียบเทียบประสิทธิภาพของโมเดลพยากรณ์ระหว่าง Bidirectional Long Short-Term Memory (BiLSTM) กับ Bidirectional Gated Recurrent Unit (BiGRU) ผลการศึกษาพบว่าปัจจัยที่มีผลต่อผลผลิตต่อไร่ของข้าวหอมมะลิทั้งหมด 9 ปัจจัย พบว่าทุกปัจจัยมีผลต่อผลผลิตต่อไร่ของข้าวหอมมะลิทั้งหมดและถ้านำมาเรียงลำดับจากมากไปน้อย 5 ปัจจัยแรก ได้แก่ ปริมาณเมล็ดพันธุ์ต่อไร่ การเพาะปลูกในเดือนพฤษภาคม เนื้อที่เก็บเกี่ยว ปริมาณปุ๋ยเคมีต่อไร่ และจำนวนวันฝนตก ส่วนโมเดลที่มีประสิทธิภาพในการพยากรณ์มากที่สุดคือ BiGRU ด้วยจำนวน Layer เท่ากับ 10 และขนาดของ Batch เท่ากับ 4 มีค่า MAPE อยู่ที่ร้อยละ 2.11 โดยใช้เวลาในการสร้างโมเดล 60.69 วินาที

คำสำคัญ : ปัจจัยที่มีผลต่อผลผลิตข้าวหอมมะลิ พยากรณ์ผลผลิตข้าวหอมมะลิ วิธีการถดถอยแบบป่าสุ่ม BiLSTM BiGRU

Independent Study Title	Using Deep Neural Networks for Thai Jasmine Rice Yield Prediction in the Northeastern Region of Thailand
Student Name	Anon Boonyawattana
Student ID	64605127
Degree	Master of Science (Statistics and Business Analytics)
Department	Statistics
Year	2024
Independent Study Advisor	Asst.Prof.Dr.Pornpimol Chaiwuttisak

Abstract

The objective of this research study was to investigate the factors influencing the yield per Rai (1 Rai = 1,600 Square Meters) of jasmine rice in the northeastern region of Thailand using Random Forest Regression and compare the performance of predictive models between Bidirectional Long Short-Term Memory (BILSTM) and Bidirectional Gated Recurrent Unit (BIGRU). The study found that all nine factors studied had an impact on the yield per Rai of jasmine rice. When ranked in descending order, the top five factors were the percentage of cultivation in May, harvested area, quantity of chemical fertilizer per Rai, and the number of rainy days. The most efficient predictive model was found to be BIGRU with 10 layers and a batch size of 4, achieving a MAPE (Mean Absolute Percentage Error) of 2.11%, with a model construction time of 60.69 seconds.

Keywords: Factors affecting jasmine rice fields, Model for forecasting, Random Forest Regressor, BILSTM, and BIGRU

กิตติกรรมประกาศ

การค้นคว้าอิสระฉบับนี้สำเร็จลุล่วงได้ เนื่องด้วยความอนุเคราะห์จาก ผู้ช่วยศาสตราจารย์ ดร.พรพิมล ชัยวุฒิศักดิ์ ที่ปรึกษาการวิจัยในครั้งนี้ ที่กรุณาสละเวลาอันมีค่าให้คำแนะนำ คำปรึกษา และชี้แนะสิ่งที่มีประโยชน์ต่าง ๆ ที่เกี่ยวข้องกับการจัดทำการค้นคว้าอิสระในครั้งนี้ ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

ขอขอบคุณกรรมการสอบการค้นคว้าอิสระ ผู้ช่วยศาสตราจารย์ ดร.สิทธิชัย เจริญเศรษฐศิลป์ และ ผู้ช่วยศาสตราจารย์ ดร.กนกวรรณ ลี้โรจนประภา ที่ให้คำแนะนำ ทิชม และชี้ให้เห็นข้อบกพร่องต่าง ๆ ที่เกิดขึ้น จนนำไปสู่การเรียนรู้ แก้ไข ทำให้งานวิจัยฉบับนี้ ดำเนินไปตามวัตถุประสงค์ จนกระทั่งเสร็จสมบูรณ์ได้ในครั้งนี้

ขอขอบคุณสำนักงานเศรษฐกิจการเกษตร ที่ให้ความอนุเคราะห์ข้อมูลสำหรับการทำการค้นคว้าอิสระ

สุดท้ายนี้ขอขอบคุณครอบครัวที่มีส่วนช่วยสนับสนุนให้กำลังใจ กำลังทรัพย์และพยายามผลักดันให้งานวิจัยฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี

นายอานนท์ บุญญวัฒน์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ก
บทคัดย่อภาษาอังกฤษ.....	ก
กิตติกรรมประกาศ.....	ก
สารบัญ.....	ง
สารบัญตาราง.....	ฉ
สารบัญรูป.....	ช
บทที่ 1 บทนำ	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ในการศึกษา.....	5
1.3 ขอบเขตของงานวิจัย.....	5
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	5
1.5 นิยามศัพท์เฉพาะ.....	5
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง	6
2.1 ทฤษฎีเกี่ยวกับวิธีการถดถอยแบบป่าสุ่ม (Random Forest Regressor).....	6
2.2 ทฤษฎีเกี่ยวกับการเรียนรู้เชิงลึก (Deep Learning).....	7
2.3 ทฤษฎีเกี่ยวกับ Recurrent Neural Network (RNN).....	9
2.4 ทฤษฎีเกี่ยวกับ Long Short-Term Memory (LSTM).....	10
2.5 ทฤษฎีเกี่ยวกับ Gated Recurrent Unit (GRU).....	13
2.6 ทฤษฎีเกี่ยวกับ Bidirectional.....	15
2.7 ทฤษฎีเกี่ยวกับการประเมินวัดความแม่นยำ.....	16
2.8 งานวิจัยที่เกี่ยวข้อง.....	16
บทที่ 3 วิธีการดำเนินงานวิจัย	21
3.1 ประชากรและกลุ่มตัวอย่าง.....	21
3.2 กรอบแนวคิดในการวิจัย.....	21
3.3 เครื่องมือที่ใช้ในการวิจัย.....	21
3.4 วิธีการเก็บข้อมูล.....	22
3.5 วิธีการวิเคราะห์.....	24
บทที่ 4 ผลการวิจัยและการอภิปรายผล	32
4.1 ลักษณะเฉพาะของตัวแปร.....	32

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญ

	หน้า
4.2 สถิติเชิงพรรณนา.....	38
4.3 Heatmap Pearson Correlation	39
4.4 ความสำคัญของปัจจัยที่มีผลต่อผลผลิตต่อไร่ของข้าวหอมมะลิ.....	40
4.5การสร้างโมเดล BILSTM และ BIGRU	41
4.5.1 BILSTM และ BIGRU โดยกำหนดให้ จำนวน Layer เท่ากับ 1.....	41
4.5.2 BILSTM และ BIGRU โดยกำหนดให้ จำนวน Layer เท่ากับ 5	43
4.5.3 BILSTM และ BIGRU โดยกำหนดให้ จำนวน Layer เท่ากับ 10.....	45
4.6 การทดสอบประสิทธิภาพของโมเดลพยากรณ์ที่มีการกำหนดค่าพารามิเตอร์แตกต่างด้วย One-way ANOVA ด้วย One-way ANOVA.....	46
4.7 การทดสอบประสิทธิภาพของโมเดลพยากรณ์ที่ไม่มี/มีการตัดตัวแปรความสำคัญต่ำกว่า 5% ด้วย T-Test.....	50
4.8 อภิปรายผล	51
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	54
5.1 สรุปผลการวิจัย	54
5.5.1 วัตถุประสงค์ข้อที่ 1.....	54
5.5.2 วัตถุประสงค์ข้อที่ 2	54
5.2 ข้อจำกัด	55
5.3 ข้อเสนอแนะ.....	56
เอกสารอ้างอิง.....	57
ภาคผนวก	60
ประวัติผู้วิจัย	69

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่	หน้า
3.1 รายละเอียด Hardware.....	22
3.2 รายละเอียด Software.....	22
3.3 รายละเอียด Library.....	22
3.4 รายละเอียดตัวแปร.....	23
3.5 รายละเอียดพารามิเตอร์ที่ศึกษาทดลองของ BILSTM และ BIGRU	29
4.1 สถิติเชิงพรรณนาของตัวแปรที่ใช้ในการศึกษา.....	38
4.2 ผลการทดลองสร้างโมเดลแบบ 1 Layer.....	42
4.3 ผลการทดลองสร้างโมเดลแบบ 5 Layer.....	43
4.4 ผลการทดลองสร้างโมเดลแบบ 10 Layer.....	45



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
1.1 ปริมาณการส่งออกสินค้าเกษตรด้านพืช	1
1.2 มูลค่าการส่งออกข้าวรายชนิด.....	2
2.1 สถาปัตยกรรมของ Random Forest Regressor (Ha, 2023).....	7
2.2 สถาปัตยกรรมของ Artificial Neural Network (TechVidvan, 2023).....	8
2.3 สถาปัตยกรรมของ Deep Learning (Kirwai, 2021).....	8
2.4 สถาปัตยกรรมของ Recurrent Neural Network (Das, 2020).....	9
2.5 สถาปัตยกรรมของ Long Short-Term Memory (Dobilas, 2022).....	10
2.6 สถาปัตยกรรมของ Gated Recurrent Unit (Phi, 2018).....	13
2.7 สถาปัตยกรรมของ Bidirectional (Mungalpara, 2021).....	15
3.1 กรอบแนวคิดในการวิจัย	21
3.2 ตัวอย่างข้อมูลจากสำนักงานเศรษฐกิจการเกษตร	24
3.3 หน้าต่าง The Power Project NASA	25
3.4 ตัวอย่างรายละเอียดข้อมูลจาก The Power Project NASA	25
3.5 ตัวอย่างข้อมูลจากกรมอุตุนิยมวิทยา	26
3.6 ตัวอย่างข้อมูลที่เตรียมพร้อมนำไปใช้ในการสร้างโมเดล	27
3.7 ตรวจสอบความครบถ้วนของข้อมูล	27
3.8 ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน ค่าสูงสุดและค่าต่ำสุด	27
3.9 ตัวแปร X หลังทำ Min-Max Scaling	28
3.10 ตัวแปร Y หลังทำ Min-Max Scaling	29
4.1 เนื้อที่เก็บเกี่ยวข้าวนาปี.....	32
4.2 การใช้ปุ๋ยเคมีของเกษตรกร.....	33
4.3 การใช้เมล็ดพันธุ์กับวิธีเพาะปลูกโดยวิธีนาดำ	34
4.4 สัดส่วนการเพาะปลูกเดือนพฤษภาคม	35
4.5 สัดส่วนการเพาะปลูกปี 2563.....	35
4.6 สภาพอากาศในช่วงเวลาเพาะปลูก	36
4.7 ค่าเฉลี่ยสภาพอากาศและค่าผิดปกติ.....	37
4.8 ค่าความสัมพันธ์ระหว่างผลผลิตต่อไร่กับตัวแปรอื่นในรูปแบบ Heatmap.....	40
4.9 ค่าที่ได้จาก Random Forest Regressor	41
4.10 ค่า Loss จาก BILSTM model แบบ 1 Layer	41
4.11 ค่า Loss จาก BILSTM model แบบ 5 Layer	43

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญรูป

รูปที่	หน้า
4.12 ค่า Loss จาก BILSTM model แบบ 10 Layer	45
4.13 การทดสอบ One-way ANOVA ความแตกต่างของการกำหนดค่า Layer	47
4.14 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Layer ในโมเดล BILSTM	47
4.15 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Layer ในโมเดล BIGRU	47
4.16 การทดสอบ One-way ANOVA ความแตกต่างของการกำหนดค่า Batch ในโมเดล BILSTM	48
4.17 การทดสอบ One-way ANOVA ความแตกต่างของการกำหนดค่า Batch ในโมเดล BIGRU	49
4.18 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Batch ในโมเดล BILSTM	49
4.19 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Batch ในโมเดล BIGRU	50
4.20 การเปรียบเทียบเฉลี่ย MAPE ของโมเดลพยากรณ์ที่ไม่มี/มีการตัดตัวแปร ความสำคัญต่ำกว่า 5%	51
4.21 ประสิทธิภาพการพยากรณ์จากโมเดล BIGRU	52


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

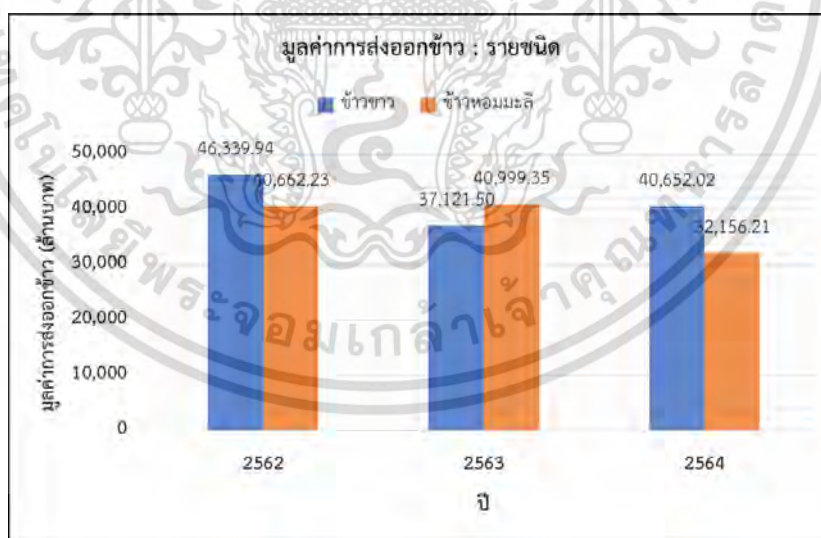
ประเทศไทยเป็นหนึ่งในกลุ่มประเทศที่มีรายได้หลักมาจากการส่งออกผลิตภัณฑ์ด้านการเกษตรโดยเฉพาะอย่างยิ่งสินค้าเกษตรในส่วนของพืชไร่และไม้ยืนต้น ในแต่ละปีมีมูลค่าการส่งออกมากกว่าปีละ 4 แสนล้านบาท หรือคิดเป็นปริมาณมากกว่าปีละ 15 ล้านตันต่อปี (สำนักงานปลัดกระทรวงพาณิชย์ ศูนย์เทคโนโลยีสารสนเทศและการสื่อสาร, 2022) จากรูปที่ 1.1 จะเห็นได้ว่าสินค้าที่มีปริมาณการส่งออกมากที่สุดตั้งแต่ปี 2560-2564 คือ ข้าว โดยครองอันดับ 1 ตั้งแต่ปี 2560-2562 ก่อนที่จะประสบปัญหาภัยแล้งและอุทกภัยในช่วงปี 2563-2564 ส่งผลต่อปริมาณการส่งออกที่ลดลงแต่อย่างไรก็ตามข้าวก็ยังเป็นพืชที่ได้รับความนิยมจากเกษตรกรของไทยมาอย่างต่อเนื่องยาวนานจนเป็นพฤติกรรมการเพาะปลูกที่เคยชินโดยเฉพาะเกษตรกรในภาคตะวันออกเฉียงเหนือของประเทศไทย



รูปที่ 1.1 ปริมาณการส่งออกสินค้าเกษตรด้านพืช

โดยหากพิจารณาข้าวในประเทศไทยพบว่ามีสายพันธุ์ข้าวมากกว่า 100 สายพันธุ์ (กรมการข้าว กองวิจัยและพัฒนาข้าว, 2022) และเมื่อจำแนกเป็นกลุ่มพันธุ์ใหญ่ ๆ ของประเทศไทยสามารถแบ่งได้ 5 กลุ่มพันธุ์ ได้แก่ ข้าวหอมมะลิในพื้นที่ ข้าวหอมมะลินอกพื้นที่ ข้าวเจ้าปทุมธานี 1 ข้าวเจ้าอื่น ๆ เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และข้าวเหนียว (สำนักงานเศรษฐกิจการเกษตร, 2022) ซึ่งจะเห็นได้ว่าการจำแนกข้าวหอมมะลิออกตามบริเวณเพาะปลูกเนื่องจากผลผลิตที่ออกมามีลักษณะที่ต่างกันถึงแม้จะเป็นสายพันธุ์เดียวกันก็ตามโดยตามความหมายของกรมการข้าว ข้าวหอมมะลิในพื้นที่ได้แก่ ข้าวหอมมะลิที่เพาะปลูกในภาคตะวันออกเฉียงเหนือ 20 จังหวัด และจังหวัดในภาคเหนือ 3 จังหวัด (เชียงใหม่ เชียงราย และพะเยา) ข้าวหอมมะลิในพื้นที่จะมีเอกลักษณ์ที่ชัดเจนมีกลิ่นหอมและคุณภาพของข้าวที่แตกต่างกับข้าวหอมมะลิในภาคอื่นของประเทศ โดยเฉพาะอย่างยิ่งข้าวหอมมะลิในบริเวณภาคตะวันออกเฉียงเหนือ ที่ได้รับความนิยมจากผู้บริโภคมาอย่างยาวนาน ยกตัวอย่างเช่น ข้าวหอมมะลิทุ่งกุลาร้องไห้และข้าวหอมมะลิสุนทร เกษตรกรในภาคนี้นิยมเพาะปลูกข้าวหอมมะลิในช่วงฤดูฝนเริ่มตั้งแต่ เดือนพฤษภาคม จนกระทั่งเก็บเกี่ยวในช่วงเดือนพฤศจิกายน ถึงเดือนธันวาคมของทุกปี มีเนื้อที่เพาะปลูกข้าวหอมมะลิเป็นอันดับที่ 1 ของประเทศไทยมาอย่างต่อเนื่องยาวนานเฉลี่ยมากกว่าปีละ 20 ล้านไร่ ผลผลิตรวมมากกว่าปีละ 8 ล้านตัน (สำนักงานเศรษฐกิจการเกษตร, 2022) จากรูปที่ 1.2 จะเห็นได้ว่าในปี 2563 ข้าวหอมมะลิเพียงสายพันธุ์เดียวมีมูลค่าการส่งออกมากกว่าข้าวสายพันธุ์อื่นรวมกันและถึงแม้ในปี 2564 มูลค่าการส่งออกข้าวหอมมะลิจะลดลงไปเนื่องจากปัญหาภัยธรรมชาติแต่ก็ยังคงสามารถรักษาสัดส่วนการส่งออกในระดับมากกว่า 40% เมื่อเปรียบเทียบกับข้าวสายพันธุ์อื่นได้ ข้าวหอมมะลิจึงเป็นพืชที่สำคัญกับระบบเศรษฐกิจของประเทศไทยอย่างมากการวางแผนการจัดการที่ดีอย่างเป็นระบบย่อมเป็นตัวช่วยระบบเศรษฐกิจของประเทศไทยได้



รูปที่ 1.2 มูลค่าการส่งออกข้าวรายชนิด

ในปัจจุบันปัญหาการจัดการผลผลิตข้าวกำลังเป็นปัญหาที่เกิดขึ้นต่อเนื่องในหลายปีที่ผ่านมาทั้งในเรื่องของผลผลิตที่ขาดแคลน ผลผลิตที่ล้นตลาด หรือการวางแผนไม่เป็นไปตามเป้าหมายที่กำหนดไว้ ยกตัวอย่างเช่นในช่วงปี 2561 ราคาข้าวหอมมะลิลู่ที่ 15,300-16,300 เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บาทต่อตัน จากเดิมประมาณ 9,500-10,600 บาทต่อตัน (กรมการค้าภายใน, 2021) โดยการวางแผนที่ผิดพลาดส่วนหนึ่งก็เกิดปัญหาจากการใช้ข้อมูลจากผลการสำรวจด้วยแบบสอบถามที่มีความลำช้า โดยข้อมูลทางสถิติจะออกหลังจากเกษตรกรเก็บเกี่ยวผลผลิตไปแล้วถึง 9-12 เดือน เนื่องจากการเก็บข้อมูลจากการสอบถามเกษตรกรหลังจากเก็บเกี่ยวแล้วเสร็จ นำมาผ่านการวิเคราะห์ด้วยเครื่องมือทางสถิติ และนำเสนอผ่านคณะกรรมการต่าง ๆ เพื่อเห็นชอบในข้อมูลดังกล่าวก่อนที่จะนำมาเผยแพร่ได้ทำให้เกิดความล่าช้าไม่ทันต่อการวางแผน ในระยะหลังจึงมีการปรับมาใช้ข้อมูลการพยากรณ์เพื่อให้สามารถวางแผนการผลิตได้ทันเวลา แต่อย่างไรก็ตามการพยากรณ์ข้าวในปัจจุบันยังไม่สามารถที่จะพึ่งพาผลการพยากรณ์จากตัวแบบพยากรณ์แต่เพียงอย่างเดียวได้ เนื่องจากความซับซ้อนของปัจจัยที่มีผลกระทบต่อการเพาะปลูกข้าว เช่น ดิน น้ำ อุณหภูมิ แสงลม ช่วงเวลาการเพาะปลูก โรค แมลง และพฤติกรรมของเกษตรกรแต่ละราย ทำให้การพยากรณ์ในปัจจุบันจำเป็นต้องจัดการประชุมร่วมขอความคิดเห็นจากหลายฝ่ายตลอดช่วงระยะเวลาการเพาะปลูกเพื่อปรับแก้ผลการพยากรณ์หลายครั้งในรอบปี ส่งผลให้ข้อมูลการพยากรณ์ที่มีความถูกต้องนั้นแล้วเสร็จใกล้กับเวลาที่เกษตรกรเริ่มทำการเก็บเกี่ยวผลผลิต บางครั้งจำเป็นต้องใช้ข้อมูลการพยากรณ์ที่ยังไม่มีการประชุมหารือร่วมกับหน่วยงานอื่นในการวางแผนการจัดการผลผลิตข้าว หรือในบางครั้งผลการพยากรณ์ที่ออกมามีระดับขีดทำให้การวางแผนจัดการผลผลิตข้าวล่าช้าออกไป ทำให้การวางแผนนั้นขาดประสิทธิภาพขาดการยอมรับจากภาคเอกชน ไม่มีตัวแบบพยากรณ์ที่ชัดเจน ไม่เกิดการบูรณาการร่วมอย่างเป็นระบบระหว่างภาครัฐ และภาคเอกชน

การสร้างตัวแบบพยากรณ์ผลผลิตการเกษตรในช่วงที่เทคโนโลยียังไม่ทันสมัยเป็นไปอย่างยากลำบากเนื่องจากความซับซ้อนของปัจจัยการผลิตพืชที่หลากหลาย ใช้เวลาในการเพาะปลูกที่ยาวนานและความต้องการปัจจัยการผลิตของพืชในแต่ละช่วงเวลามีระดับแตกต่างกันตามการเจริญเติบโตของพืช จนกระทั่งในปัจจุบันที่เทคโนโลยีมีการพัฒนามากยิ่งขึ้นทำให้มีการประยุกต์ใช้เทคนิค Machine learning (ML) มาช่วยในการพยากรณ์ผลผลิตทางการเกษตร ยกตัวอย่างเช่น การใช้ภาพถ่ายต้นข้าวในแปลงศึกษาเพื่อการอ่านค่าสเปกตรัมของพืชหลังจากนั้นทำการแปลงเป็นค่า Normalized Difference Vegetative Index (NDVI) เพื่อประเมินสุขภาพของพืชก่อนจะแปลงเป็นผลผลิตต่อไร่ (Onwuchekwa-Henry et al., 2022) หรือการประยุกต์ใช้ภาพถ่ายดาวเทียมในการวิเคราะห์การติดโรคของพืชก่อนนำมาวิเคราะห์ร่วมกับปัจจัยทางสภาพแวดล้อมเช่น อุณหภูมิ ความชื้น แสงอาทิตย์ ผ่านตัวแบบ Convolutional Neural Network (CNN) ในการวิเคราะห์ผลผลิตต่อไร่ (Lee et al., 2019) ถึงแม้ทั้งสองวิธีที่กล่าวมาจะมีความน่าสนใจในการศึกษา แต่ด้วยฐานข้อมูลภาพถ่ายในปัจจุบันยังคงประสบปัญหาหลายประการเช่น ปัญหาการเลือกแปลงตัวอย่าง เนื่องจากการเพาะปลูกข้าวหอมมะลิเพาะปลูกในช่วงฤดูฝนของประเทศไทย ปัญหาเรื่องค่าใช้จ่ายในการใช้ภาพถ่ายความละเอียดสูง ปัญหาเรื่องขอบเขตพื้นที่ที่ทำการแปลงภาพถ่ายกับขอบเขตพื้นที่จริงไม่สอดคล้องกัน จากปัญหาที่กล่าวมาข้างต้นทำให้งานวิจัยฉบับนี้มุ่งเน้น

การใช้ข้อมูลในรูปแบบของตัวเลขเป็นหลักในการทำการพยากรณ์ ซึ่งในปัจจุบันก็มีการใช้ตัวแบบเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลายชนิดในการพยากรณ์ผลผลิตต่อไร่ เช่น การใช้วิธี Random Forest ร่วมกับ Deep Neural Network ในการสร้างตัวแบบพยากรณ์โดยใช้ตัวแปรด้านสภาพอากาศร่วมกับตัวแปรด้านปัจจัยการผลิตและสถานที่เพาะปลูก ก่อนที่จะใช้ Confusion Matrix ในการจำแนกความถูกต้องของผลการทำนาย (Banua & Geethab, 2021) หรือในงานวิจัยผลผลิตต่อไร่ในประเทศอินเดียที่ใช้ตัวแปรข้อมูลสภาพแวดล้อมรวมกับปัจจัยอื่นที่เกี่ยวข้อง 38 ตัวแปรร่วมกับการใช้ Deep Recurrent Q-Network Model (DRQN) ในการพยากรณ์คู่กับปัจจัยการผลิตซึ่งสามารถแก้ปัญหา Vanishing Gradient Problem ดีกว่าตัวแบบ Recurrent Neural Network (RNN) (Elavarasan & Vincent, 2020) และอีกหนึ่งงานวิจัยที่น่าสนใจคือการใช้ข้อมูลด้านสภาพแวดล้อมโดยการเก็บข้อมูลเริ่มตั้งแต่หวานเมล็ดพันธุ์จนกระทั่งเก็บเกี่ยวผลผลิตและใช้ตัวแบบ Long Short-Term Memory (LSTM) ซึ่งสามารถแก้ปัญหา Vanishing Gradient Problem ที่เมื่อทำการฝึกสอนโมเดลไปหลาย ๆ ชั้นทำให้ Gradient ที่ถูกส่งต่อมามีขนาดเล็กจนเข้าใกล้ 0 ทำให้ไม่สามารถนำค่าไปใช้ในการคำนวณต่อไปได้ เช่นเดียวกับการใช้ DRQN การพยากรณ์ผลผลิต (Khaki et al., 2019)

ซึ่งจากการศึกษาวิจัยที่กล่าวมาข้างต้นพบว่าข้อมูลที่ใช้ส่วนใหญ่จะถูกแบ่งออกเป็นสองส่วนคือ 1. ปัจจัยที่เกี่ยวข้องกับพฤติกรรมและการเพาะปลูกของเกษตรกร เช่น ช่วงเวลา วิธีการเพาะปลูก การใช้ปุ๋ยและยา 2. ปัจจัยด้านสภาพแวดล้อม เช่น อุณหภูมิ ความชื้น ความกดอากาศ และปัจจัยอื่น ดังนั้นในงานวิจัยฉบับนี้ข้อมูลที่เกี่ยวข้องเนื่องกับพฤติกรรมของเกษตรกร จะอ้างอิงจากสำนักงานเศรษฐกิจการเกษตรในบริเวณภาพตะวันออกเฉียงเหนือ และส่วนที่สองมาจากข้อมูลของ NASA's Climate Data Services ซึ่งเป็นข้อมูลภายใต้โครงการ Power Project NASA โดยโครงการนี้มีวัตถุประสงค์ในการเก็บข้อมูลสภาพอากาศของโลกเพื่อวิเคราะห์การเปลี่ยนแปลงสภาพอากาศในปัจจุบัน ผ่านตัวโมเดลด้านอุตุนิยมวิทยา โมเดลข้อมูลพลังงานแสงอาทิตย์ และแปลงออกมาเป็นค่าต่าง ๆ เช่น อุณหภูมิ ความชื้นของแสง แร่ลม และความกดอากาศ อีกส่วนหนึ่งที่สำคัญของงานวิจัยฉบับนี้คือการเลือกใช้ตัวแบบในการพยากรณ์ ซึ่งเมื่อพิจารณาจากงานวิจัยที่กล่าวมาข้างต้นจะเห็นได้ว่าการพยากรณ์ผลผลิตทางการเกษตรส่วนใหญ่จะประสบปัญหา Vanishing Gradient Problem ทำให้ผลการพยากรณ์ไม่มีประสิทธิภาพเท่าที่ควร ดังนั้นในงานวิจัยฉบับนี้จึงเลือกใช้วิธีการถดถอยแบบป่าสุ่ม (Random Forest Regressor) ในการคัดเลือกตัวแปรก่อนที่จะนำตัวแปรดังกล่าวไปใช้ในโมเดลที่สามารถแก้ปัญหา Vanishing Gradient Problem ได้อย่างตัวแบบ LSTM และ GRU มาพิจารณาเปรียบเทียบและวัดประสิทธิภาพการพยากรณ์ด้วยค่าร้อยละค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE) ที่วัดค่าออกมาเป็นร้อยละไม่อ้างอิงหน่วยตามตัวแปรตาม ซึ่งมีประโยชน์ในการเปรียบเทียบความแม่นยำกับโมเดลอื่นที่ตัวแปรตามมีค่าแตกต่างกัน และไม่อ่อนไหวกับ Outlier เช่นเดียวกันกับค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1.2 วัตถุประสงค์ในการศึกษา

- 1) ศึกษาความสำคัญของปัจจัยที่มีอิทธิพลต่อผลผลิตต่อไร่ของข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือด้วยวิธีการถดถอยแบบป่าสุ่ม (Random Forest Regressor)
- 2) เปรียบเทียบประสิทธิภาพของโมเดลเพื่อพยากรณ์ ผลผลิตต่อไร่ข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือของไทยด้วยอัลกอริทึม BILSTM และ BIGRU โดยอาศัยปัจจัยตามที่ศึกษาด้วยวิธีการถดถอยแบบป่าสุ่ม

1.3 ขอบเขตของงานวิจัย

การศึกษาปัจจัยที่มีผลกระทบต่อผลผลิตต่อไร่ข้าวหอมมะลิที่ผลิตได้ภายในภาคตะวันออกเฉียงเหนืออาศัยข้อมูลการเพาะปลูกของเกษตรกรจากสำนักงานเศรษฐกิจการเกษตร กรมอุตุวิทยา และข้อมูลการเปลี่ยนแปลงสภาพอากาศจากนาซ่าตั้งแต่ปี 2537 – 2563

1.4 ประโยชน์ที่คาดว่าจะได้รับ

- 1) เพิ่มทางเลือกในการพยากรณ์ผลผลิตต่อไร่ของข้าวหอมมะลิในประเทศไทย
- 2) ภาครัฐ เอกชน และเกษตรกรสามารถนำข้อมูลผลการพยากรณ์มาใช้วางแผนบริหารจัดการผลผลิตข้าวหอมมะลิในแต่ละปีได้อย่างมีประสิทธิภาพมากขึ้น
- 3) นำข้อมูลพยากรณ์ข้าวหอมมะลิที่ได้ไปใช้ในการคำนวณปริมาณคาร์โบไฮเดรตและสารอาหารอื่นที่มีอยู่ในเมล็ดข้าวเพื่อใช้ในการวางแผนความมั่นคงด้านอาหารร่วมกับหน่วยงานต่างประเทศ
- 4) ใช้เป็นแนวทางในการนำข้อมูลจากหลายแหล่งมาบูรณาการร่วมกันทำให้เกิดประโยชน์ในการพยากรณ์
- 5) นำโมเดลที่ได้ไปประยุกต์ใช้เป็นแนวทางในการพัฒนาการพยากรณ์ผลผลิตต่อไร่ของข้าวสายพันธุ์อื่น

1.5 นิยามศัพท์เฉพาะ

- 1) ข้าวหอมมะลิ หมายถึง ข้าวหอมมะลิที่เพาะปลูกระหว่างวันที่ 1 พฤษภาคม ถึง 31 ตุลาคม ไม่รวมข้าวหอมมะลิที่ปลูกนอกฤดูกาลเนื่องจากผลผลิตแตกต่างกันไปจากปกติ
- 2) รูปแบบผลผลิต หมายถึง ลักษณะของผลผลิตข้าวหอมมะลิที่เกษตรกรเก็บเกี่ยวในรูปของข้าวเปลือกที่ความชื้น 15 % เป็นมาตรฐานกลางในการวัดน้ำหนักผลผลิตของข้าวหอมมะลิ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

2.1 ทฤษฎีเกี่ยวกับวิธีการถดถอยแบบป่าสุ่ม (Random Forest Regressor)

Random Forest Regressor เป็นการนำเอาอัลกอริทึมแบบต้นไม้ตัดสินใจ (Decision Trees) หลายต้นมารวมกัน (Ensemble Model) ชุดข้อมูลที่ใช้ประกอบด้วย N แทนข้อมูลจำนวนตัวอย่างทั้งหมด M แทนปัจจัย X แทนกลุ่มของปัจจัยเขียนได้ตามสมการที่ 2.1 และ Y แทนค่าเป้าหมายที่ต้องการพยากรณ์

$$X = \{x_1, x_2, x_3, \dots, x_M\} \quad (2.1)$$

โดยขั้นแรกเริ่มจากการสุ่มตัวอย่างจากจำนวนตัวอย่างทั้งหมดแบบใส่คืน (random sampling with replacement) จากสมการที่ 2.2

$$D = \{(X_1, y_1), (X_2, y_2), \dots, (X_N, y_N)\} \quad (2.2)$$

เมื่อ D แทนชุดข้อมูลที่ใช้สำหรับการฝึกสอน

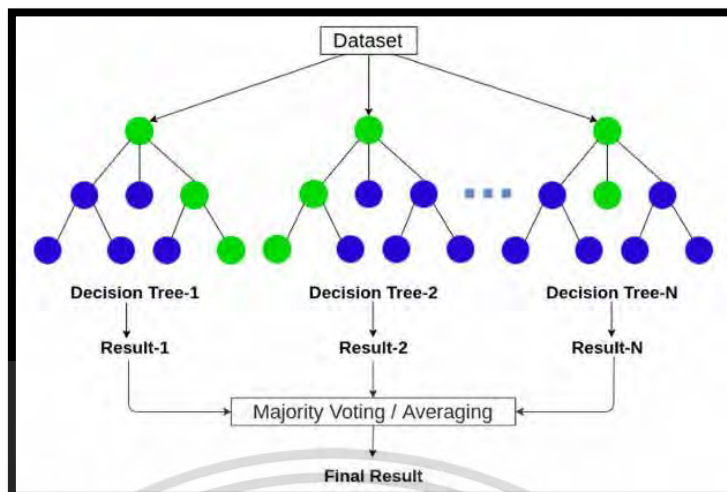
จนครบตามจำนวนที่ต้องการแทนค่าด้วย K เป็นจำนวนชุดข้อมูลที่ต้องการในการสร้างต้นไม้ตัดสินใจและเรียกกลุ่มตัวอย่างที่ถูกสร้างขึ้นมาว่า Bootstrap Sample แทนค่าด้วย D_k ต่อมานำ D_k ที่ได้รับทำการสร้างเป็นต้นไม้ตัดสินใจ ซึ่งในระหว่างการสร้างต้นไม้ตัดสินใจในแต่ละโหนดจะทำการสุ่ม m จาก M และเลือกปัจจัยที่ให้ค่า Mean Squared Error (MSE) ต่ำที่สุด เรียกขั้นตอนนี้ว่า Feature Bagging หรือ Random Subspace Method ซึ่งกระบวนการนี้จะดำเนินการสร้างต้นไม้ไปทีละต้นจนครบตามจำนวนที่กำหนดไว้ ซึ่งต้นไม้แต่ละต้นที่ถูกสร้างขึ้นมาจะมีความเป็นอิสระต่อกัน จากนั้นต้นไม้ตัดสินใจจะทำการพยากรณ์ผลลัพธ์ตามสมการที่ 2.3

$$y = \frac{1}{K} \sum_{k=1}^K y_k \quad (2.3)$$

หลังจากนั้นนำผลการเลือกปัจจัยของต้นไม้แต่ละต้นมาโหวตร่วมกันหาผลลัพธ์ที่ทำการโหวตเยอะที่สุดเรียกวิธีการนี้ว่า Bagging (Bootstrap Aggregation)

โดยหากค่าเฉลี่ยของตัวแปรใดมีค่าสูงก็จะบ่งบอกถึงความสำคัญของตัวแปรนั้นที่มีต่อโมเดล ดังรูปที่ 2.1

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 2.1 สถาปัตยกรรมของ Random Forest Regressor (Ha, 2023)

2.2 ทฤษฎีเกี่ยวกับการเรียนรู้เชิงลึก (Deep Learning)

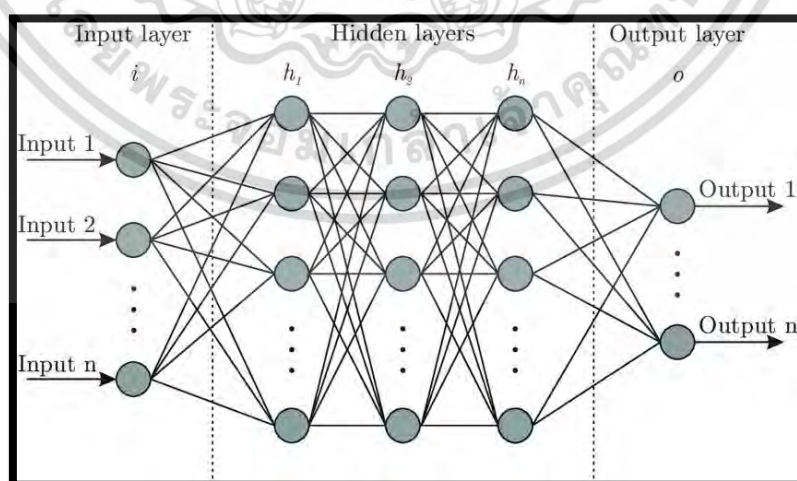
การเรียนรู้เชิงลึกเป็นส่วนหนึ่งของการเรียนรู้ด้วยเครื่องจักร (Machine Learning) ซึ่งเป็นอัลกอริทึมที่ใช้สำหรับการเรียนรู้ที่สามารถทำให้เครื่องจักรสามารถตัดสินใจด้วยตนเองได้เช่นเดียวกับมนุษย์ โดยการเรียนรู้ของเครื่องเป็นการประยุกต์ใช้ความรู้ทางด้านสถิติในการวิเคราะห์ข้อมูลและสร้างโมเดลในการพยากรณ์

การเรียนรู้เชิงลึกมีพื้นฐานมาจากโครงข่ายประสาทเทียม (Artificial Neural Network) เป็นอัลกอริทึมที่คิดค้นขึ้นมาจากการเลียนแบบการทำงานของระบบประสาทของมนุษย์สามารถวิเคราะห์สิ่งต่าง ๆ ที่มีความละเอียดซับซ้อนเป็นจำนวนมากได้อย่างมีประสิทธิภาพ โดยเริ่มตั้งแต่การจำลองการทำงานของเซลล์ประสาทขึ้นมา ซึ่งแต่ละเซลล์จะมีการเชื่อมต่อเพื่อรับส่งข้อมูลไปหาแต่ละเซลล์เพื่อใช้ในการตัดสินใจ เชื่อมต่อกันได้อย่างทั่วถึงและมีการกระจายตัวในการวิเคราะห์ข้อมูลให้แต่ละเซลล์อย่างชัดเจน โดยการทำงานเบื้องหลังของโครงข่ายประสาทเทียมนั้นมีหน่วยย่อยที่ทำงานคล้ายกับเซลล์ประสาทของมนุษย์เรียกว่า Node ซึ่ง Node สามารถรวมตัวกันเป็นชั้น จะเรียกว่า Layer โดยแต่ละ Node จะมีขั้นตอนการทำงานที่แบ่งกันตามหน้าที่ตาม Layer เช่น Input Layer, Hidden Layer และ Output Layer ดังรูปที่ 2.2



รูปที่ 2.2 สถาปัตยกรรมของ Artificial Neural Network (TechVidvan, 2023)

การเรียนรู้เชิงลึกเป็นหนึ่งในอัลกอริทึมที่ถูกพัฒนาต่อยอดมาจากโครงข่ายประสาทเทียม ซึ่งเป็นการเลียนแบบการเรียนรู้ของระบบประสาทของมนุษย์ โดยทำการวางโครงสร้างในรูปแบบวางซ้อนกันหลาย ๆ ชั้น โดยมีทั้งการวางซ้อนในรูปแบบของประเภทเดียวกันในทุกชั้นและการวางซ้อนกันโดยแต่ละชั้นนั้นทำงานไม่เหมือนกัน เพิ่มประสิทธิภาพในการวิเคราะห์ที่ดียิ่งขึ้น (LeCun et al., 2015) ในปัจจุบันการเรียนรู้เชิงลึกได้ทำให้ประสิทธิภาพในการวิเคราะห์และทำนาย ผลได้ดีกว่าการใช้อัลกอริทึมของการเรียนรู้ของเครื่องแบบเดิมเป็นอย่างมาก ทั้งในด้านของจำนวนข้อมูลที่เพิ่มขึ้นอย่างก้าวกระโดด และหน่วยประมวลผลของคอมพิวเตอร์ที่มีประสิทธิภาพสูงขึ้น ทำให้การเรียนรู้เชิงลึกนั้นสามารถใช้ตัวแปรจำนวนมากในการวิเคราะห์ เพื่อเพิ่มประสิทธิภาพในการวิเคราะห์ตามรูปที่ 2.3



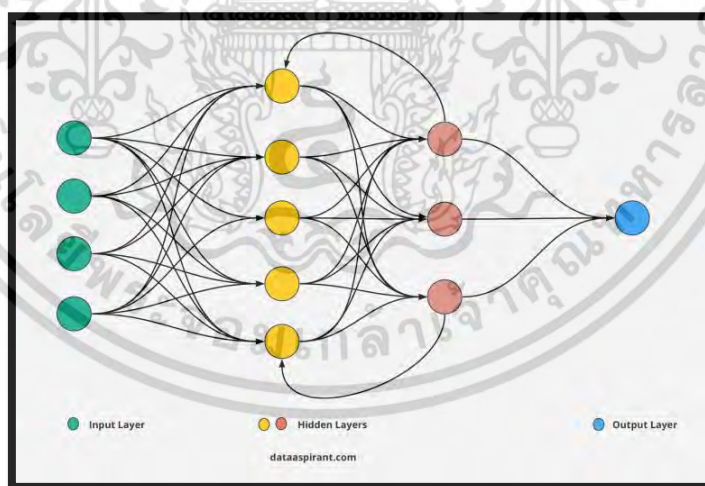
รูปที่ 2.3 สถาปัตยกรรมของ Deep Learning (Kirwai, 2021)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ไม่เพียงแต่การเพิ่มจำนวนชั้นเท่านั้น การเรียนรู้เชิงลึกได้ทำการปรับความสามารถในการเรียนรู้ของอัลกอริทึม โดยการนำการเรียนรู้แบบ Backpropagation มาปรับปรุงโดยแยกอัลกอริทึมที่ใช้ในการเรียนรู้ออกเป็น 2 ตัว ได้แก่ Loss Function และ Optimize Function โดย Loss Function ใช้ในการคำนวณเพื่อหาค่าความผิดพลาดที่ได้จากการเปรียบเทียบระหว่างผลที่ได้จากโมเดลและผลลัพธ์ที่ใช้ในการฝึกสอน จากนั้นนำค่า Loss ที่ได้มาใช้กับ Optimize Function ซึ่งเป็นฟังก์ชันสำหรับการปรับค่าพารามิเตอร์ที่ใช้ในการเรียนรู้ของโมเดลที่สร้างขึ้นมาโดยมีการคิดค้น Loss Function และ Optimize Function ต่าง ๆ ขึ้นมาให้เลือกใช้งานในปัจจุบัน

2.3 ทฤษฎีเกี่ยวกับ Recurrent Neural Network (RNN)

RNN เป็นหนึ่งในอัลกอริทึมของการเรียนรู้เชิงลึกซึ่งใช้หลักการการวิเคราะห์ข้อมูลในรูปแบบของอนุกรมลำดับเหตุการณ์ (Sequence) ซึ่งข้อมูลในรูปแบบนี้จะมีลำดับการเกิดของเหตุการณ์ที่ชัดเจนและสามารถเปลี่ยนบริบทของเหตุการณ์ตามลำดับได้ในรูปแบบของอนุกรมเวลา (Time Series) และข้อมูลที่มีลักษณะเป็นข้อความต่าง ๆ (Medsker & Jain, 2001) RNN ได้รับการพัฒนาเพิ่มเติมขึ้นมาจากเดิมที่โครงข่ายประสาทเทียมนั้นจะมีการป้อนค่า Input เข้าไปแล้วได้ค่า Output ออกมาโดย RNN ได้ทำการออกแบบใหม่ให้สามารถนำค่า Output ไปคำนวณย้อนกลับเป็น Input ได้อีกครั้ง ดังแสดงในรูปที่ 2.4



รูปที่ 2.4 สถาปัตยกรรมของ Recurrent Neural Network (Das, 2020)


จากรูปที่ 2.4 โครงข่ายประสาทแบบ RNN นั้นจะมีโครงสร้างที่แตกต่างจากโครงข่ายประสาทเทียม โดยโครงสร้างของ RNN ที่เล็กที่สุดจะเรียกว่า Cell โดย Cell ของ RNN จะมีทั้งในส่วนของ Hidden State ที่ใช้ในการเก็บข้อมูลการวิเคราะห์จากข้อมูลในชุดที่ผ่านมา เพื่อใช้ในการวิเคราะห์ในตัวถัดไป ในการปรับค่าพารามิเตอร์ต่าง ๆ นั้น RNN จะใช้วิธีการป้อนข้อมูลแบบย้อนกลับเพื่อทำการปรับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปเผยแพร่โดยไม่ได้รับอนุญาต
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ค่าพารามิเตอร์ต่าง ๆ ในโมเดลที่ได้ทำการพัฒนาขึ้น โดยใช้หลักการของกฎลูกโซ่ในการปรับค่าพารามิเตอร์ โดยทำการคำนวณเพื่อหาค่า Gradient ที่ได้จาก Error สำหรับการปรับพารามิเตอร์ของโมเดล ในการปรับค่าพารามิเตอร์ในส่วนของ Hidden State นั้นได้เกิดปัญหาขึ้นจากการใช้งานโครงข่ายประสาทแบบ RNN ได้เนื่องจากการกำหนดลำดับของข้อมูลที่มีขนาดที่ยาวเกินไป ทำให้ค่า Gradient มีค่าลดลงจนไม่สามารถเห็นการเปลี่ยนแปลงได้ ส่งผลต่อการพยากรณ์และเป็นข้อจำกัดของ RNN

2.4 ทฤษฎีเกี่ยวกับ Long Short-Term Memory (LSTM)

LSTM ได้ถูกพัฒนาเพื่อแก้ไขปัญหา Vanishing Gradient ของวิธี RNN โดย LSTM มีหลักการทำงาน คือสามารถเก็บสถานะหรือข้อมูลของแต่ละ Node เอาไว้สำหรับการย้อนกลับมาพิจารณา และใช้ในการตัดสินใจ (Hochreiter & Schmidhuber, 1997) โดยจุดเด่นของ LSTM คือ ฟังก์ชันพิเศษที่มีหน้าที่เสมือนประตู (Gate) ประกอบด้วย Input Gate, Memory Cell State Gate, Output Gate และ Forget Gate ซึ่งจะเป็นสิ่งที่ควบคุมการไหลของข้อมูล โดยที่เมื่อ LSTM ได้รับข้อมูลมาจากชั้น Input เป็นครั้งแรก LSTM จะเข้าสู่ Input Gate ก่อนที่จะส่งต่อไปยัง Output Gate ในการตัดสินใจว่าจะเก็บค่าที่ได้ไว้แล้วจะวนซ้ำหรือไม่ หากเลือกที่จะวนซ้ำจะนำข้อมูลกลับมาเพื่อเข้าสู่ Forget Gate ซึ่งจะตัดสินใจว่าจะลบค่าที่เก็บไว้ทิ้ง หรือยังคงเก็บค่าไว้ หากเก็บไว้จะไปรอกการอัปเดตจาก Input Gate ซึ่งจะตัดสินใจว่าจะอัปเดตค่านั้นหรือไม่ และจะอัปเดตด้วยค่าอะไร แล้วส่งค่าขึ้นไป Output Gate เพื่อตัดสินใจว่าจะนำข้อมูลนั้น ออกไปแสดงหรือจะนำข้อมูลกลับไปวนซ้ำอีกรอบ ดังนั้น LSTM จึงสามารถเรียนรู้จากข้อมูลที่เป็น ลำดับและเก็บหรือลบข้อมูลทิ้ง ถ้าข้อมูลนั้นไม่จำเป็นตามรูปที่ 2.5



รูปที่ 2.5 สถาปัตยกรรมของ Long Short-Term Memory (Dobilas, 2022)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยพื้นฐาน Activation Function ของ LSTM จะใช้ Sigmoid คู่กับการใช้ Tanh แต่อย่างไรก็ตามจากการศึกษางานวิจัยที่เกี่ยวข้อง (Cetiner & Burhan ,2022) ได้มีการปรับ Activation Function จาก Sigmoid มาเป็น ReLU งานวิจัยฉบับนี้จึงใช้ ReLU จากการศึกษางานวิจัยดังกล่าว

Input Gate ทำหน้าที่ในการกำหนดข้อมูลที่จะนำเข้ามาวิเคราะห์ใน Cell โดยรับข้อมูลเข้ามาเพื่อทำการเขียนค่าลงไปในแต่ละ Cell ดังสมการที่ 2.4

$$i_t = R(W_{xi}x_t + W_{hi}h_{t-1} + W_{ci}c_{t-1} + b_i) \quad (2.4)$$

- เมื่อ i_t แทนผลลัพธ์ที่ได้จาก Input Gate
 R แทนฟังก์ชัน ReLU
 W_{xi} แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Input Gate
 x_t แทนค่า Input ที่นำเข้ามาคำนวณ
 W_{hi} แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Input Gate
 h_{t-1} แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า
 W_{ci} แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Input Gate
 c_{t-1} แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า
 b_i แทนค่า Bias ที่ใช้ในการคำนวณใน Input Gate

Forget Gate ทำหน้าที่ในการกำหนดข้อมูลที่จะนำเข้ามาวิเคราะห์ใน Cell โดยทำการกำหนดว่าข้อมูลนั้นควรที่จะถูกบันทึกหรือถูกลืม โดยสามารถกำหนดได้จากสมการที่ 2.5

$$f_t = R(W_{xf}x_t + W_{hf}h_{t-1} + W_{cf}c_{t-1} + b_f) \quad (2.5)$$

- เมื่อ f_t แทนผลลัพธ์ที่ได้จาก Forget Gate
 R แทนฟังก์ชัน ReLU
 W_{xf} แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Forget Gate
 x_t แทนค่า Input ที่นำเข้ามาคำนวณ
 W_{hf} แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Forget Gate
 h_{t-1} แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า
 W_{cf} แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Forget Gate
 c_{t-1} แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

b_f แทนค่า Bias ที่ใช้ในการคำนวณใน Forget Gate

Memory Cell State Gate เป็นหน่วยย่อยในการกำหนดข้อมูลที่น่าเข้ามาวิเคราะห์ใน Cell และทำการคำนวณค่าสถานะ เพื่อใช้ในการคำนวณในครั้งถัดไป โดยมีสมการดังสมการที่ 2.6

$$c_t = f_t c_{t-1} + i_t * \tanh(W_{xc} x_t + W_{hc} h_{t-1} + b_c) \quad (2.6)$$

- เมื่อ c_t แทนค่า Memory Cell State ในช่วงหน่วยเวลา
 f_t แทนผลลัพธ์ที่ได้จาก Forget Gate
 c_{t-1} แทนค่า Memory Cell State จากหน่วยเวลาก่อนหน้า
 i_t แทนผลลัพธ์ที่ได้จาก Input Gate
 \tanh แทนฟังก์ชัน Hyperbolic tangent
 W_{xc} แทนค่าน้ำหนักสำหรับคำนวณค่า Input จาก Memory Cell State Gate
 x_t แทนค่า Input ที่นำเข้ามาคำนวณ
 W_{hc} แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Memory Cell State Gate
 h_{t-1} แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า
 b_c แทนค่า Bias ที่ใช้ในการคำนวณใน Forget Gate

Output Gate เป็นหน่วยย่อยสำหรับการคำนวณ Output ของ Cell ซึ่งผลลัพธ์ที่ได้จาก Cell นี้จะมีอยู่ 2 อย่าง ได้แก่ Output และ Hidden State สำหรับใช้ในการคำนวณครั้งถัดไป โดยมีสมการที่ 2.7 และ 2.8 ตามลำดับ

$$o_t = R(W_{xo} x_t + W_{ho} h_{t-1} + W_{co} c_{t-1} + b_o) \quad (2.7)$$

$$h_t = o_t * \tanh(c_t) \quad (2.8)$$

- เมื่อ o_t แทนผลลัพธ์ที่ได้จาก Output Gate
 R แทนฟังก์ชัน ReLU
 W_{xo} แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Output Gate
 x_t แทนค่า Input ที่นำเข้ามาคำนวณ
 W_{ho} แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Output Gate
 h_{t-1} แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า
 W_{co} แทนค่าน้ำหนักสำหรับคำนวณ Memory Cell State ใน Output Gate

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

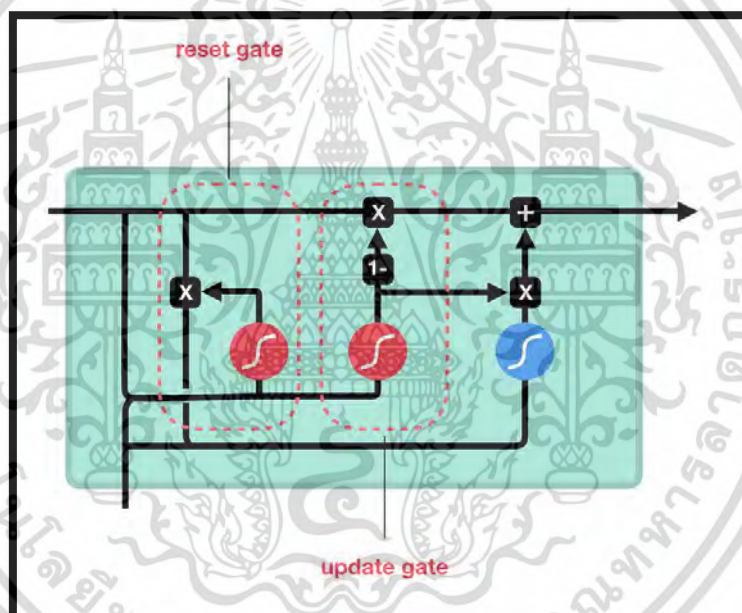
c_{t-1} แทนค่า Memory Cell State ที่ได้จากการคำนวณในหน่วยเวลาก่อนหน้า

b_o แทนค่า Bias ที่ใช้ในการคำนวณใน Output Gate

h_t แทนค่า Hidden State จากการคำนวณ

2.5 ทฤษฎีเกี่ยวกับ Gated Recurrent Unit (GRU)

GRU ถูกพัฒนาต่อยอดมาจาก LSTM เพื่อลดความซับซ้อนในการทำงานของโครงข่ายประสาทแบบ LSTM เนื่องจากจำนวนหน่วยย่อยใน Cell จำนวนมาก ซึ่งมีผลต่อประสิทธิภาพในการวิเคราะห์และทำนายผล (Chung et al., 2014) โดย GRU ได้ทำการลดความซับซ้อนในการทำงานของโครงข่ายประสาทแบบ LSTM โดยการลดหน่วยย่อยใน Cell เหลือเพียง 2 ส่วน ได้แก่ Update Gate และ Reset Gate ดังแสดงในรูปที่ 2.6



รูปที่ 2.6 สถาปัตยกรรมของ Gated Recurrent Unit (Phi, 2018)

ในเรื่องของ Activation Function ดังที่กล่าวไปก่อนหน้านี้ในหัวข้อของ LSTM ผู้วิจัยได้ทำการปรับ Activation Function จาก Sigmoid เป็น ReLU เพื่อใช้สำหรับ GRU เช่นเดียวกับใน LSTM

Update Gate เป็นหน่วยย่อยที่ทำการนำข้อมูลไปคำนวณเพื่อกำหนดสถานะของ Cell สำหรับใช้ในการคำนวณในขั้นถัดไป โดยทำการคำนวณในทุก ๆ รอบที่มีข้อมูลเข้ามา ดังสมการที่ 2.9

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$z_t = R(W_{xz}x_t + W_{hz}h_{t-1} + b_z) \quad (2.9)$$

- เมื่อ z_t แทนค่าที่ได้จาก Update Gate
 R แทนฟังก์ชัน ReLU
 W_{xz} แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Update Gate
 x_t แทนค่า Input ที่นำเข้ามาคำนวณ
 W_{hz} แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Update Gate
 h_{t-1} แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า
 b_z แทนค่า Bias ที่ใช้ในการคำนวณใน Update Gate

Reset Gate เป็นหน่วยย่อยที่ใช้ในการกำหนดข้อมูลว่าควรที่จะเก็บค่าสถานะที่ได้จากการคำนวณในครั้งที่แล้วมากน้อยเพียงใด ดังสมการที่ 2.10

$$r_t = R(W_{xr}x_t + W_{hr}h_{t-1} + b_r) \quad (2.10)$$

- เมื่อ r_t แทนค่าที่ได้จาก Reset Gate
 R แทนฟังก์ชัน ReLU
 W_{xr} แทนค่าน้ำหนักสำหรับคำนวณ Input ใน Reset Gate
 x_t แทนค่า Input ที่นำเข้ามาคำนวณ
 W_{hr} แทนค่าน้ำหนักสำหรับคำนวณ Hidden State ใน Reset Gate
 h_{t-1} แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า
 b_r แทนค่า Bias ที่ใช้ในการคำนวณใน Reset Gate

สำหรับการคำนวณหาค่า Output และ Hidden State ของ GRU นั้น หน่วยย่อยสำหรับใช้คำนวณ ผลลัพธ์ที่ได้จากทั้ง 2 Gate มาทำการคำนวณด้วยฟังก์ชัน tanh จากนั้นค่าที่ได้จาก Reset Gate จะกำหนดว่าจะทำการจำค่าเดิม หรือทำการล้างค่าเดิมออกไป และทำการควบคุมปริมาณของข้อมูลด้วยค่าจาก Update Gate ดังสมการที่ 2.11

$$h_t = (1 - z_t) * \tanh(r_t * W_{hh}h_t + W_{xh}x_t) + z_t h_{t-1} \quad (2.11)$$

- เมื่อ h_t แทนค่า Hidden State จากการคำนวณ

- z_t แทนค่าที่ได้จาก Update Gate

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

\tanh แทนฟังก์ชัน Hyperbolic tangent

r_t แทนค่าที่ได้จาก Reset Gate

W_{hh} แทนค่าน้ำหนักสำหรับคำนวณ Hidden State จากหน่วยเวลาก่อนหน้า

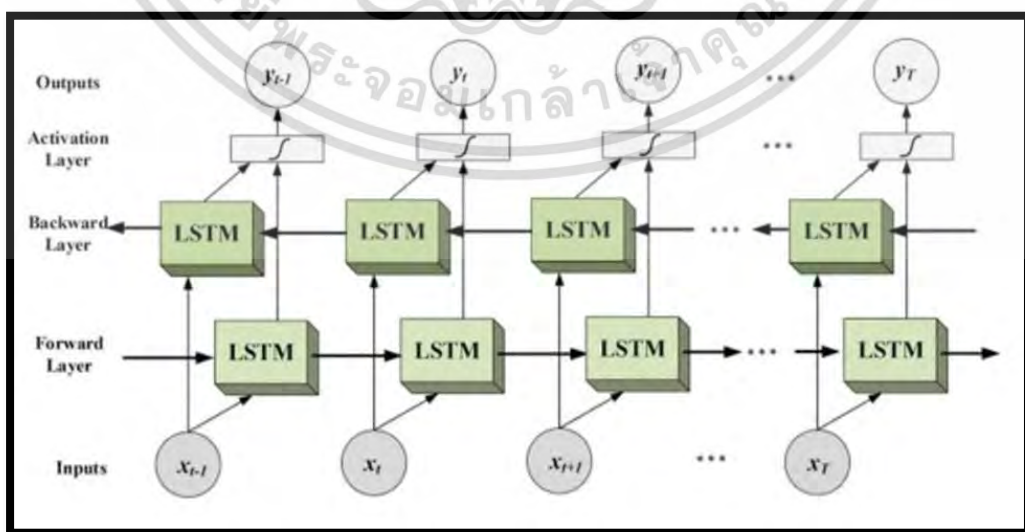
h_{t-1} แทนค่า Hidden State ที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

W_{xh} แทนค่าน้ำหนักสำหรับคำนวณค่า Input

ในการทำงานของโครงข่ายประสาทแบบ GRU นั้นมีความแตกต่างจากโครงข่ายประสาทแบบ LSTM ในส่วนของการทำงานที่ Cell ของโครงข่ายประสาทแบบ GRU นั้นจะไม่ทำการเก็บค่าสถานะจากการคำนวณในครั้งก่อนหน้ามาใช้ในการวิเคราะห์โครงข่ายประสาทแบบ GRU ส่งผลต่อประสิทธิภาพในการวิเคราะห์ข้อมูลเมื่อเปรียบเทียบกับโครงข่ายประสาทแบบ LSTM แต่โครงข่ายประสาทแบบ GRU นั้นสามารถแสดงจุดเด่นในด้านของการลดจำนวนพารามิเตอร์ในการฝึกสอนลงทำให้โมเดลนั้นสามารถทำงานได้อย่างรวดเร็วยิ่งขึ้น

2.6 ทฤษฎีเกี่ยวกับ Bidirectional

Bidirectional เป็นอีกรูปแบบหนึ่งของ LSTM และ GRU พัฒนาขึ้นมาเพื่อให้โมเดลสามารถเข้าใจความสัมพันธ์ระหว่างลำดับของตัวแปรได้ดียิ่งขึ้นมีหลักการทำงานเหมือนกับ LSTM และ GRU เพียงแต่มีการเพิ่มหนึ่งฟังก์ชันการทำงานกลายเป็นแบบ 2 ทิศทางโดยการใส่ Input แบบไปข้างหน้าและแบบไปข้างหลัง จากนั้นให้ Activation Layer เป็นตัวตัดสินใจ Output ที่ออกมา ตามตัวอย่างในรูป 2.7 นั้นหมายความว่าขั้นตอนในการทดสอบแบบ BILSTM และ BIGRU จะช้ากว่า LSTM และ GRU แบบปกติ (Siarni-Namini et al., 2019)



รูปที่ 2.7 สถาปัตยกรรมของ Bidirectional (Mungalpara, 2021)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.7 ทฤษฎีเกี่ยวกับการประเมินวัดความแม่นยำ

Mean Absolute Percentage Error (MAPE) คือ เป็นการวัดความแม่นยำที่วัดค่าออกมาเป็นร้อยละไม่อ้างอิงหน่วยตามตัวแปรตาม ซึ่งมีประโยชน์ในการเปรียบเทียบความแม่นยำกับโมเดลอื่นที่ตัวแปรตามมีค่าแตกต่างกันตามสมการที่ 2.12

$$MAPE = \frac{\sum_{i=1}^n \left| \frac{Y_i - \hat{Y}_i}{Y_i} \right| * 100}{n} \quad (2.12)$$

เมื่อ Y_i แทนค่าจากข้อมูลจริง

\hat{Y}_i แทนค่าจากการพยากรณ์

n แทนจำนวนตัวอย่างทั้งหมด

โดยค่า MAPE ที่ต่ำกว่า 10% จะถือว่าการพยากรณ์มีความแม่นยำ ถ้าค่าอยู่ระหว่าง 10% ถึง 20% ถือว่าการพยากรณ์ใช้ได้ดี ถ้าอยู่ระหว่าง 20% ถึง 50% ถือว่าอยู่ในระดับพอใช้ และถ้าค่า MAPE มากกว่า 50% ถือว่าการพยากรณ์ไม่แม่นยำ (Lewis, 1982)

2.8 งานวิจัยที่เกี่ยวข้อง

Onwuchekwa-Henry et al., (2022) ศึกษาตัวแบบในการประมาณการผลิตจากภาพถ่ายการสะท้อนในภาพถ่ายและตัวแปรด้านสภาพภูมิอากาศ ทางผู้วิจัยได้ทำการลงพื้นที่ในบริเวณภาคตะวันออกเฉียงเหนือของประเทศกัมพูชา โดยใช้โปรแกรม Canopeo ในการอ่านค่าสเปกตรัมเพื่อประเมินสุขภาพของพืชและใช้อุปกรณ์ที่ชื่อว่า GreenSeeker ในการประเมินค่า Normalised Difference Vegetative Index (NDVI) ใช้การสะท้อนจากภาพถ่ายเพื่อบอกความสมบูรณ์ของพืชนำข้อมูลไปเปรียบเทียบกับค่าพยากรณ์กับวิธี Canopeo index-weather model โดยทั้งสองตัวแบบถูกพัฒนาผ่าน The Generalised Additive Model (GAM) ซึ่งเป็นตัวแบบในการอธิบายตัวแปรที่มีความสัมพันธ์ที่ไม่ใช่เส้นตรงระหว่างตัวแปรต้นและตัวแปรตามสามารถพัฒนาตัวแบบให้มีความถูกต้องมากยิ่งขึ้น ในงานวิจัยฉบับนี้มีการเก็บข้อมูลทำในระหว่างช่วงปี 2018-2019 ผลการวิจัยที่ได้จากตัวแบบที่ใช้ Canopeo Index-Weather Model ในการสร้างนั้นมีค่า R^2 อยู่ที่ 0.53 ส่วนตัวแบบที่ได้จาก NDVI-weather model มีค่า R^2 อยู่ที่ 0.46 โดยสรุปตัวแบบ Canopeo index-weather model มีความยืดหยุ่นและมีประสิทธิภาพในการพยากรณ์พื้นที่ขนาดเล็กหรือสามารถนำไปประยุกต์ใช้เพื่อเพิ่มประสิทธิภาพในการผลิต งานวิจัยดังกล่าวเป็นอีกทางเลือกหนึ่งของการพยากรณ์ผลผลิตด้วยการใช้ภาพถ่ายดาวเทียม แต่ด้วยข้อมูลที่จำเป็นจะต้องใช้ภาพถ่ายต้นพืช

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ของแต่แปลงจึงเหมาะกับการพยากรณ์ผลผลิตเป็นรายแปลงเท่านั้น ไม่เหมาะสำหรับการนำไปใช้พยากรณ์ผลผลิตในเนื้อที่เพาะปลูกขนาดใหญ่

Cetiner and Burhan (2022) ศึกษาการพยากรณ์ผลผลิตข้าวสาลีในประเทศตุรกีระหว่างปี 1980-2020 โดยใช้วิธี Gated Recurrent Unit (GRU) และ Long Short-Term Memory (LSTM) ในการพยากรณ์ จากตัวแปรทั้งหมด 38 ตัวแปรแบ่งเป็นค่าเฉลี่ยรายเดือน 12 เดือนของตัวแปร อุณหภูมิ ความชื้น และปริมาณน้ำฝน รวม 36 ตัวแปร รวมกับตัวแปร เนื้อที่เก็บเกี่ยวและผลผลิตรวม อีก 2 ตัวแปร จากนั้นวัดประสิทธิภาพของตัวแบบด้วย R^2 , MSE, RMSE, MAE, MAPE พบว่าผลที่ได้จากตัวแบบ LSTM มีค่า $R^2 = 0.9667$ MSE = 0.0054 ,RMSE = 0.0280 ,MAE = 0.0614 และ MAPE = 7.45 ซึ่งเมื่อพิจารณาด้วยค่า R^2 พบว่ามีค่ามากกว่าตัวแบบ GRU ที่มีค่า $R^2 = 0.955$ ส่วนค่า MSE ,RMSE ,MAE ,MAPE มีค่าใกล้เคียงกัน แต่อย่างไรก็ตามความรวดเร็วในการฝึกตัวแบบนั้น GRU สามารถทำได้เร็วกว่า LSTM โดยงานวิจัยดังกล่าวมีผลการวิจัยที่มีประสิทธิภาพสูง เมื่อพิจารณาจากค่า MAPE ที่ 10% มาจากการใช้โมเดล LSTM และ GRU ที่สามารถแก้ปัญหาเรื่อง Vanishing Gradient และ Exploding Gradient ได้และตัวแปรมีหลายตัวที่เหมาะสมสำหรับนำมาประยุกต์ใช้กับข้อมูลที่มีอยู่ในปัจจุบัน แต่อย่างไรก็ตามตัวแปรส่วนใหญ่จะเป็นตัวแปรที่เกี่ยวข้องกับสภาพอากาศเป็นหลัก ยังขาดตัวแปรที่เกี่ยวข้องกับพฤติกรรมและการเพาะปลูกของเกษตรกรในแต่ละพื้นที่ เช่น ปริมาณเมล็ดพันธุ์ต่อไร่ ปริมาณการใส่ปุ๋ยต่อไร่ และวิธีการเพาะปลูกของเกษตรกร

Banua and Geethab (2021) ศึกษาการพยากรณ์ในเขต Tamilnadu ของประเทศอินเดีย โดยใช้วิธี Random forest และ Deep neural network เป็นวิธีที่ใช้ในการสร้างโมเดลจากข้อมูลชุดเดียวกันหลาย ๆ ครั้งโดยในแต่ละครั้งจะเลือกส่วนของข้อมูลในการฝึกสอนตัวแบบที่ไม่เหมือนกัน นำตัวแบบที่ได้ทั้งหมดมาพิจารณาว่าปัจจัยใดที่ส่งผลต่อตัวแบบมากที่สุด ผู้วิจัยได้กำหนดตัวแปรต้นทั้งหมด 8 ตัวแปรได้แก่ ชื่อแขวง ฤดูกาล ผลผลิตต่อปี ปีที่นำมาใช้ ความชื้น อุณหภูมิ ปริมาณน้ำฝน และปริมาณการใส่ปุ๋ย โดยใช้ข้อมูลตั้งแต่ปี 2009 – 2018 และใช้ Confusion Matrix ในการจำแนกความถูกต้องของผลการทำนายพบว่าการใช้ Random Forest คู่กับ Deep Neural Network ได้ค่า Accuracy สูงสุดอยู่ที่ 0.921 โดยงานวิจัยดังกล่าวได้ทำการประยุกต์ใช้ Random Forest คู่กับ Deep Neural Network เพื่อหาความสำคัญของตัวแปรแต่ละตัวก่อนที่นำมาใช้สร้างโมเดลและมีการใช้ตัวแปรทั้งสภาพอากาศและพฤติกรรมในการเพาะปลูกอย่างปริมาณการใส่ปุ๋ยต่อไร่ ร่วมกันในการสร้างโมเดล แต่อย่างไรก็ตามการใช้โมเดล Deep Neural Network มีจุดอ่อนอยู่ที่การเกิดปัญหาเรื่อง Vanishing Gradient และ Exploding Gradient ที่ทำให้ผลลัพธ์ในการพยากรณ์มีความคลาดเคลื่อนได้

Chu and Yu (2020) ศึกษาการพยากรณ์ผลผลิตต่อไร่ของข้าวโดยการเก็บข้อมูลเป็นเวลา 3 ปีครอบคลุมพื้นที่ 81 มณฑลในประเทศจีนแบ่งการพยากรณ์ออกเป็น 2 ค่าคือ ผลผลิตต่อไร่ของข้าวในฤดูร้อน และผลผลิตต่อไร่ของข้าวในฤดูหนาว ตัวแปรที่ใช้ในการพยากรณ์ ได้แก่ ช่วงเวลาที่พระอาทิตย์ออก แรงแลมเฉลี่ย อุณหภูมิสูงสุด อุณหภูมิต่ำสุด อุณหภูมิเฉลี่ย ความชื้น

ความกดอากาศเฉลี่ย ปริมาณน้ำค้าง หลังจากนั้นนำข้อมูลที่ได้มาใช้วิธี Back-propagation neural networks (BPNNs) เป็นวิธีที่ใช้หา Error จากการพยากรณ์ด้วย Neural Network แบบปกติ เปรียบเทียบกับค่าจริงที่เกิดขึ้นจากนั้นนำค่า Error ที่ได้มาปรับเพื่อให้ผลการพยากรณ์ใกล้เคียงกับค่าจริงมากยิ่งขึ้น ร่วมกับวิธี Independently Recurrent Neural Network (IndRNN) ประโยชน์สำคัญคือการใช้กับข้อมูลที่มีลำดับขั้นและแก้ปัญหาเรื่อง Vanishing Gradient และ Exploding Gradient จากการฝึกสอนข้อมูลไปเรื่อย ๆ จนข้อมูลมีขนาด เล็กหรือใหญ่จนเกิดไปจนไม่สามารถทำการฝึกสอนต่อไปได้ เรียกโมเดลนี้ว่า BI-model โดยแบ่งขั้นตอนออกเป็น 3 ขั้นตอนหลักได้แก่ 1. เตรียมข้อมูล 2. นำข้อมูลเชิงพื้นที่เข้าโมเดล BPNNs และข้อมูลเชิงอนุกรมเวลาอื่น ๆ เข้าโมเดล IndRNN 3. นำข้อมูลที่ได้จากขั้นตอนที่ 2 จากทั้ง 2 วิธีมาวิเคราะห์ร่วมกัน ผลที่ได้จากการศึกษาพบว่าตัวแบบจะพยากรณ์ได้ดีที่สุดเมื่อกำหนดให้ตัวแบบเรียนรู้อยู่ที่ 6 ชั้น และการใช้ตัวแบบผสมทำให้ Error น้อยกว่าการใช้ตัวแบบใดตัวแบบหนึ่ง ซึ่งตัวแบบที่ออกมามีความแม่นยำสูงสามารถทำนายได้ทั้งชั่วโมง ช่วงฤดูร้อนและหนาว โดยงานวิจัยดังกล่าวมีการเพิ่มปัจจัยแรงลมเข้ามาเพื่อใช้ในการพยากรณ์ผลผลิตต่อไร่ของข้าวประกอบกับมีการใช้วิธีใหม่ในการสร้างโมเดลที่สามารถแก้ปัญหา Vanishing Gradient และ Exploding Gradient ได้เช่นเดียวกับวิธี LSTM แต่อย่างไรก็ตามด้วยวิธี IndRNN ยังไม่มีการใช้อย่างแพร่หลายมากนัก ทำให้ยากแก่การศึกษาและนำมาประยุกต์ใช้อีกทั้งโมเดลดังกล่าวยังขาด library ที่รองรับทำให้การสร้างโมเดลจำเป็นที่จะต้องใช้เวลาอย่างมากในการนำมาปรับใช้กับงานวิจัยฉบับนี้

Elavarasan and Vincent (2020) ศึกษาการพยากรณ์ผลผลิตต่อไร่ของข้าวโดยการใช้ข้อมูลย้อนหลัง 35 ปี ในประเทศอินเดีย ซึ่งส่วนใหญ่เป็นข้อมูลสภาพแวดล้อมเช่น ดิน น้ำ และตัวแปรอื่นที่เกี่ยวข้อง รวมทั้งสิ้น 38 ตัวแปร วิธีการที่เลือกใช้คือ Deep Recurrent Q-Network Model (DRQN) ซึ่งเป็นการเรียนรู้ส่วนหนึ่งของ Recurrent Neural Network Deep Learning Algorithm เป็นการใช้ Recurrent Neural Network ในการหาค่าพยากรณ์สำหรับข้อมูลที่มีลำดับขั้นก่อนจะส่งข้อมูลไปยัง Q-learning network ในการพยากรณ์ผลผลิตต่อไร่ต่อไป ซึ่งเป็นวิธีที่ทำให้สามารถเชื่อมโยงข้อมูลดิบเข้ากับข้อมูลจากการพยากรณ์ได้โดยผลลัพธ์ที่ได้จากตัวแบบมีความถูกต้องอยู่ที่ 93.7% ซึ่งเป็นวิธีที่ดีที่สุดเมื่อเปรียบเทียบกับค่า R^2 กับวิธี Long Short-Term Memory (LSTM) ที่มีค่า R^2 0.68 และ RMSE 0.22 ,Artificial Neural Network ที่มีค่า R^2 0.62 และ RMSE 0.37 Random Forest ที่มีค่า R^2 0.37 และ RMSE 0.72 และ Gradient Boosting ที่มีค่า R^2 0.54 และ RMSE 0.53 ถึงแม้งานวิจัยฉบับนี้จะสนับสนุนการใช้ DRQN ที่ให้ประสิทธิภาพสูงกว่าวิธีอื่น แต่อย่างไรก็ตามเนื่องด้วยวิธีนี้ไม่มี Library รองรับโดยตรงและไม่มีการใช้งานที่หลากหลายมากนัก ทำให้ยากต่อการนำมาประยุกต์ใช้ นอกจากนี้ยังมีโมเดลปัญหาเรื่อง Vanishing Gradient Problem มีอาจส่งผลกระทบต่อผลลัพธ์ที่ออกมาได้

Khaki et al. (2019) ศึกษาการพยากรณ์ผลผลิตต่อไร่โดยการใช้ข้อมูลด้านสภาพแวดล้อมอย่างค่าเฉลี่ยผลผลิต ข้อมูลสภาพอากาศ และข้อมูลดิน ร่วมกับข้อมูลการจัดการเพาะปลูกพืชที่เก็บข้อมูลเอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อใช้ในการศึกษาวิจัยเท่านั้น ไม่อนุญาตให้เผยแพร่โดยไม่ได้รับอนุญาตไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การเจริญเติบโตของพืชรายสัปดาห์ตั้งแต่เริ่มปลูกจนกระทั่งเก็บเกี่ยวเสร็จ ซึ่งข้อมูลทั้งสองชุด จะถูกนำมาวิเคราะห์ด้วยตัวแบบ Convolutional Neural Networks (CNNs) และ Recurrent Neural Networks (RNNs) โดยได้ค่า RMSE อยู่ที่ 8% และ 9% ตามลำดับ โดยงานวิจัยดังกล่าว มีการใช้ข้อมูลพฤติกรรมการเพาะปลูกของเกษตรกรอย่างละเอียดตั้งแต่เริ่มต้นการเพาะปลูกร่วมกับ ข้อมูลสภาพอากาศ ครอบคลุมปัจจัยที่อาจเกี่ยวข้องกับผลผลิตมากกว่างานวิจัยฉบับอื่น แต่การเก็บ ข้อมูลการเพาะปลูกอย่างละเอียดนั้น ทำให้ยากต่อการนำตัวแปรดังกล่าวมาประยุกต์ใช้กับ เนื้อที่เพาะปลูกขนาดใหญ่ ประกอบกับโมเดล CNNs และ RNNs เมื่อทำการฝึกสอนโมเดลไป เป็นเวลานานอาจทำให้เกิดปัญหา Vanishing gradient problem ทำให้ไม่สามารถฝึกสอนต่อไปได้

Piyaporn (2019) ศึกษาการพยากรณ์ผลผลิตข้าวหอมมะลิในจังหวัดนครราชสีมาตั้งแต่ปี 2545-2559 จำนวน 15 ข้อมูล โดยใช้วิธีการวิเคราะห์การถดถอยพหุคูณ (Multiple Regression Analysis) โดยวิธีการถดถอยแบบลำดับขั้น (Stepwise Regressions) และวิธีการวิเคราะห์อนุกรม เวลา (Time Series Analysis) โดยวิธีบ็อกซ์-เจนกินส์ (Box-Jenkins Method) และใช้ค่าเฉลี่ยของ ร้อยละความคลาดเคลื่อนสัมบูรณ์เป็นเกณฑ์ในการเปรียบเทียบวิธีการพยากรณ์ทั้ง 2 วิธี พบว่า วิธีวิเคราะห์การถดถอยพหุคูณเป็นตัวแบบที่เหมาะสมที่สุดโดยมีการใช้ตัวแปรต้นทั้งหมด 4 ตัว ได้แก่ เนื้อที่เพาะปลูก จำนวนชั่วโมงที่มีแสงแดดเฉลี่ย ปริมาณน้ำฝนเฉลี่ย และอุณหภูมิเฉลี่ย ซึ่งผลที่ได้จากการใช้วิธีการถดถอยแบบลำดับขั้นได้ตัวแปรต้นเพียงตัวเดียวคือ เนื้อที่เพาะปลูก และมีค่า R^2 อยู่ที่ 0.625 และมีค่า MAPE อยู่ที่ 0.0395 งานวิจัยนี้เป็นงานวิจัยที่เกี่ยวข้องกับข้าวหอมมะลิ ในบริเวณภาคตะวันออกเฉียงเหนือของไทย โดยพบว่าการใช้วิธีการวิเคราะห์การถดถอยพหุคูณ ให้ผลลัพธ์ที่ดีกว่าวิธีการวิเคราะห์อนุกรมเวลา ซึ่งจากโมเดลดังกล่าวใช้ตัวแปรเพียงตัวเดียว คือ เนื้อที่เพาะปลูก ให้ค่า MAPE ที่ต่ำและสามารถใช้เปรียบเทียบกับงานวิจัยฉบับอื่นที่เกี่ยวข้องได้ แต่อย่างไรก็ตามโมเดลดังกล่าวขาดการนำข้อมูลที่เกี่ยวข้องกับพฤติกรรมกรเพาะปลูกของเกษตรกร มาร่วมพิจารณาด้วย

Lee et al. (2019) ศึกษาการพยากรณ์ผลผลิตจากภาพถ่ายดาวเทียมเพื่อวิเคราะห์ การติดโรคของพืชก่อนจะนำเข้าตัวแบบพยากรณ์ Convolutional Neural Network (CNN) โดยใช้ ข้อมูลจากภาพถ่ายวิเคราะห์ร่วมกับปัจจัยทางสภาพอากาศเช่น อุณหภูมิ ความชื้น แสงอาทิตย์ น้ำค้าง และอื่น ๆ นอกจากนี้ยังมีการเก็บปัจจัยจำพวก วันเก็บเกี่ยว ข้อมูลโรค สถานของพืช และ อุณหภูมิพื้นดิน จากการศึกษาพบว่าการใช้ภาพถ่ายในการวิเคราะห์โรคพืชก่อนนำเข้าตัวแบบ พยากรณ์ร่วมกับปัจจัยอื่นช่วยลด Prediction error rate ได้สูงถึง 20-30 % และถ้านำโรคมาร่วม พิจารณาด้วยอย่างน้อย 1 โรคจะช่วยลด Error ได้ 5-10 % เมื่อเทียบกับการนำโรคมาร่วมพิจารณา มากกว่า 2 โรคขึ้นไป นอกจากนี้งานวิจัยยังทำการเปรียบเทียบตัวแบบพยากรณ์พบว่าพยากรณ์ ด้วยตัวแบบ CNN มีค่าความถูกต้องมากกว่าวิธี Region-CNN (RNN) และ You only look once (YOLO) โดยงานวิจัยดังกล่าวเป็นการใช้ภาพถ่ายดาวเทียมในการวิเคราะห์ข้อมูลของโรค คู่กับข้อมูล

ปัจจัยทางสภาพอากาศซึ่งเป็นอีกหนึ่งทางเลือกที่น่าสนใจในการนำมาประยุกต์ใช้กับการพยากรณ์ข้าว เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการใช้งานเท่านั้น เมื่อผู้ดูแลเห็นชอบให้ใช้ขอสงวนสิทธิ์ในค่า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หอมมะลิในประเทศไทย แต่อย่างไรก็ตามการใช้ภาพถ่ายดาวเทียมเพื่อวิเคราะห์โรคเป็นการใช้ภาพถ่ายรายแปลง ทำให้ยากต่อการนำมาประยุกต์ใช้กับการพยากรณ์เนื้อที่เพาะปลูกในบริเวณกว้าง นอกจากนี้การใช้โมเดล CNN หรือ RNN ยังทำให้เกิดปัญหา Vanishing gradient problem

Kongtanajaruanunand and Cheamuangphan (2018) ศึกษาเกี่ยวประสิทธิภาพการผลิตข้าวในบริเวณภาคเหนือตอนบนของประเทศไทยโดยเปรียบเทียบวิธีนาดำ และวิธีนาหว่าน โดยใช้ DEA วิเคราะห์หาประสิทธิภาพการผลิตพบว่าการผลิตข้าวด้วยวิธีนาดำมีประสิทธิภาพมากกว่าวิธีนาหว่าน มีตัวแปรด้านผลผลิตเฉลี่ยด้วยวิธีนาดำเท่ากับ 8,204.59 กิโลกรัม ซึ่งสูงกว่าผลผลิตเฉลี่ยด้วยวิธีนาหว่านที่เท่ากับ 6,408.42 กิโลกรัม จากงานวิจัยสามารถสรุปได้ว่าการเพาะปลูกด้วยวิธีนาดำให้ผลผลิตมากกว่าการเพาะปลูกด้วยวิธีนาหว่าน ซึ่งเป็นอีกปัจจัยหนึ่งที่เกี่ยวข้องกับพฤติกรรมการเพาะปลูกของเกษตรกรที่ส่งผลต่อผลผลิตต่อไร่ แต่อย่างไรก็ตามการศึกษาดังกล่าวทำในบริเวณภาคเหนือของประเทศไทยเท่านั้น ซึ่งอาจส่งผลแตกต่างกันในบริเวณภาคอื่นของประเทศไทย

Kumboonreang (2011) ศึกษาอิทธิพลของช่วงแสงต่อการกำเนิดช่อดอกของข้าวพันธุ์ขาวดอกมะลิ 105 โดยทำการศึกษาในเรือนเพาะชำทั้งหมด 4 ช่วงแสง ได้แก่ปรับ 1. ช่วงแสง 10 ชม. 2. ช่วงแสง 11 ชม. 3. ช่วงแสง 12 ชม. และ 4. แสงธรรมชาติโดยมีค่าเฉลี่ยช่วงแสงอยู่ที่ 12.40 ชม. ผลการทดลองพบว่า ในแปลงที่ 1 และ 2 เกิดช่อดอกภายใน 37 วัน ส่วนในแปลงที่ 3 และ 4 กำเนิดช่อดอกใน 82 วัน สำหรับผลผลิตต่อไร่พบว่าข้าวในแปลงที่ 3 และ 4 มีผลผลิตเฉลี่ยอยู่ที่ 296 กิโลกรัมต่อตารางเมตร ซึ่งมากกว่าแปลงที่ 1 และ 2 ที่มีค่าเฉลี่ยผลผลิตอยู่ที่ 280 กิโลกรัมต่อตารางเมตร งานวิจัยดังกล่าวเป็นการอธิบายถึงช่วงเวลาของแสงแดดในแต่ละวันที่มีผลต่อผลผลิตต่อไร่ของข้าวหอมมะลิ ยิ่งเวลาของแสงต่อวันน้อยลงจะทำให้ข้าวหอมมะลิออกผลผลิตไวยิ่งขึ้น ส่งผลให้ผลผลิตต่อไร่ที่ออกมานั้นต่ำลง ซึ่งการปรับเปลี่ยนช่วงแสงของประเทศไทยนั้น จะเกิดขึ้นในช่วงเดือนตุลาคมของทุกปีเมื่อประเทศไทยเข้าสู่ฤดูหนาว เพราะฉะนั้นหากเกษตรกรยังเพาะปลูกใกล้กับเดือนตุลาคมมากเท่าไร ยิ่งส่งผลให้ผลผลิตต่อไร่ลดลงตามไปด้วยเช่นเดียวกัน แต่งานวิจัยดังกล่าวทั้งหมดดำเนินการในแปลงทดลอง ยังขาดการทดสอบในพื้นที่จริงซึ่งอาจให้ผลลัพธ์ที่แตกต่างออกไป

บทที่ 3

วิธีการดำเนินงานวิจัย

ในบทนี้จะกล่าวถึงหัวข้อย่อยดังนี้ ประชากรและกลุ่มตัวอย่าง กรอบแนวคิดในการวิจัย เครื่องมือที่ใช้ในการวิจัย วิธีการเก็บข้อมูล ขั้นตอนการเตรียมข้อมูลและวิเคราะห์ข้อมูล


3.1 ประชากรและกลุ่มตัวอย่าง

งานวิจัยนี้ได้ทำการเลือกใช้ข้อมูลจากสำนักงานเศรษฐกิจการเกษตร กรมอุตุนิยมวิทยา และ ข้อมูลการเปลี่ยนแปลงสภาพอากาศจากนาซ่าตั้งแต่ปี 2537 – 2563 ประกอบด้วย ตัวแปรทั้งหมด 13 ตัวแปร และข้อมูลจะถูกแบ่งเป็น 2 ชุด คือ ชุดสำหรับสร้างโมเดล (Train Dataset) ร้อยละ 70 และชุดสำหรับทดสอบโมเดล (Test Dataset) ร้อยละ 30

3.2 กรอบแนวคิดในการวิจัย

ตัวแปรอิสระ

ตัวแปรตาม



รูปที่ 3.1 กรอบแนวคิดในการวิจัย

3.3 เครื่องมือที่ใช้ในการวิจัย

เครื่องมือที่ใช้แบ่งออกเป็น 3 ประเภทได้แก่ Hardware Software และ Library โดย Hardware ใช้สำหรับการประมวลผลข้อมูล ส่วน Software ใช้สำหรับเรียกใช้ชุดคำสั่งและ Library เป็นกลุ่ม ของชุดคำสั่งสำเร็จรูปพร้อมใช้งาน โดยมีรายละเอียดดังตาราง 3.1, 3.2 และ 3.3 ตามลำดับ

ตารางที่ 3.1 รายละเอียด Hardware

Hardware	Detail
CPU	Intel® Core™ i5-8300H CPU @ 2.30GHz
GRU	NVIDIA GeForce GTX 1050 Ti
RAM	8 GB

ตารางที่ 3.2 รายละเอียด Software

Software	Detail
Google Colaboratory	ใช้สำหรับเขียนโค้ดและประมวลผล
Python	เวอร์ชัน 3.10.6 ที่ให้บริการบน Google Colaboratory

ตารางที่ 3.3 รายละเอียด Library

Library	Detail
Pandas	ใช้สำหรับจัดการ Dataframe
Numpy	ใช้สำหรับคำนวณ และสร้าง Array
Matplotlib	ใช้สำหรับสร้างกราฟ
Time	ใช้สำหรับจับเวลาในการสร้างโมเดล
Sklearn	ใช้สำหรับจัดเตรียมข้อมูลให้พร้อมประมวลผล
Tensorflow	ใช้สำหรับสร้างและประมวลผลโมเดล LSTM และ GRU

3.4 วิธีการเก็บข้อมูล

งานวิจัยฉบับนี้ได้ทำการรวบรวมข้อมูลจาก 3 แหล่งข้อมูล ได้แก่

1) ข้อมูลจากสำนักงานเศรษฐกิจการเกษตรประกอบด้วยตัวแปรทั้งหมด 6 คอลัมน์ ได้แก่ HA ,S ,CF ,P1 ,MP1 ,Yield โดยตัวแปรทั้งหมดอ้างอิงจากงานวิจัยต่าง ๆ ที่เกี่ยวข้อง ซึ่งแสดงเป็นข้อมูลผลรวมของการผลิตข้าวหอมมะลิ 1 รอบการผลิตในบริเวณภาคตะวันออกเฉียงเหนือ ตั้งแต่ วันที่ 1 พฤษภาคม ถึง 31 ตุลาคม ตั้งแต่ปี 2537 ถึง 2563 (Cetiner & Burhan ,2022; Banua & Geethab, 2021; Kongtanajaruanunand & Cheamuangphan, 2018; Kumboonreang, 2011; Suwnnasaen, 2020)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2) ข้อมูลจาก The Power Project NASA โดยดึงข้อมูลผ่าน API ของทาง Power Project NASA โดยตรงและระบุรายละเอียดข้อมูล ดังนี้ ช่วงของระยะเวลาระหว่างเดือนเมษายน ถึง กันยายน ความถี่ของข้อมูลรายเดือน พิกัดพื้นที่ระดับอำเภอที่มีเนื้อที่เพาะปลูกมากที่สุดปี 2563 ของแต่ละจังหวัดรวมทั้งสิ้น 20 จังหวัด ได้แก่ อำเภอวังสะพุง จังหวัดเลย, อำเภอเมือง จังหวัดหนองบัวลำภู, อำเภอบ้านดุง จังหวัดอุดรธานี, อำเภอโพธิ์ชัย จังหวัดหนองคาย, อำเภอเซกา จังหวัดบึงกาฬ, อำเภอมัญจาคีรี จังหวัดขอนแก่น, อำเภอเมือง จังหวัดนครพนม, อำเภอเมือง จังหวัดมุกดาหาร, อำเภอเลิงนกทา จังหวัดยโสธร, อำเภอเมือง จังหวัดอำนาจเจริญ, อำเภอเดชอุดม จังหวัดอุบลราชธานี, อำเภอชานุมัน จังหวัดศรีสะเกษ, อำเภอเมือง จังหวัดสุรินทร์, อำเภอประโคนชัย จังหวัดบุรีรัมย์, อำเภอพยัคฆภูมิพิสัย จังหวัดมหาสารคาม, อำเภอเกษตรวิสัย จังหวัดร้อยเอ็ด, อำเภอยางตลาด จังหวัดกาฬสินธุ์, อำเภอเมือง จังหวัดขอนแก่น, อำเภอเมืองจังหวัดชัยภูมิ และอำเภอโนนสูง จังหวัดนครราชสีมา, โดยข้อมูลที่ใช้ประกอบด้วยตัวแปรทั้งหมด 3 คอลัมน์ ได้แก่ T2M_Avg ,RH2M_Avg ,WS2N_Avg โดยอ้างอิงจากงานวิจัยที่เกี่ยวข้อง แสดงเป็นข้อมูลเฉลี่ยรายเดือน ตั้งแต่ปี 2537 ถึง 2563 (Chu & Yu, 2020)

3) ข้อมูลจากกรมอุตุนิยมวิทยามีเพียงตัวแปร RD_Avg แสดงเป็นข้อมูลเฉลี่ยรายเดือน ในบริเวณภาคตะวันออกเฉียงเหนือ ตั้งแต่ปี 2537 ถึง 2563 (Suwannaen, 2020) รายละเอียดของตัวแปรทั้งหมดที่ใช้ในการศึกษา แสดงดังตารางที่ 3.4

ตารางที่ 3.4 รายละเอียดตัวแปร

ตัวแปร	คำอธิบาย	สเกลตัวแปร	งานวิจัย
HA	เนื้อที่เกี่ยวเกี่ยว (ไร่)	Ratio	Cetiner and Burhan, 2022
S	ปริมาณเมล็ดพันธุ์ข้าวหอมมะลิต่อไร่ (กิโลกรัม)	Ratio	Kongtanajaruanunand & Cheamuangphan, 2018
CF	ปริมาณปุ๋ยต่อไร่ (กิโลกรัม)	Ratio	Banua & Geethab, 2021
P1	สัดส่วนเนื้อที่ปลูกข้าวด้วยวิธีนาดำ (ร้อยละ)	Ratio	Kongtanajaruanunand & Cheamuangphan, 2018
MP1	สัดส่วนเนื้อที่เพาะปลูก ณ เดือนพฤษภาคม (ร้อยละ)	Ratio	Kumboonreang, 2011
T2M_Avg	ค่าเฉลี่ยอุณหภูมิ เดือน พฤษภาคม – กันยายน (เซลเซียส)	Interval	Chu and Yu, 2020

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตัวแปร	คำอธิบาย	สเกลตัวแปร	งานวิจัย
RH2M_Avg	ความชื้นสัมพัทธ์ในอากาศ เดือน พฤษภาคม - กันยายน (ร้อยละ)	Ratio	Chu and Yu, 2020
WS2M_Avg	ค่าเฉลี่ยความเร็วลม เดือน พฤษภาคม - กันยายน (เมตรต่อวินาที)	Ratio	Chu and Yu, 2020
RD_Avg	จำนวนวันฝนตกเฉลี่ย เดือน พฤษภาคม - กันยายน (วัน)	Ratio	Suwnnasaen, 2020
Yield	ผลผลิตข้าวหอมมะลิต่อไร่ (กิโลกรัม)	Ratio	Suwnnasaen, 2020

สำหรับข้อมูล S, CF และ Yield ที่แสดงผลเป็นผลผลิตต่อไร่ คำนวณมาจากปริมาณทั้งหมดหารด้วยเนื้อที่เพาะปลูก จะได้ผลผลิตต่อไร่ของตัวแปรนั้น ๆ

3.5 วิธีการวิเคราะห์


1) รวบรวมข้อมูลจากสำนักงานเศรษฐกิจการเกษตรและคัดเลือกข้อมูลเฉพาะข้าวหอมมะลิที่เพาะปลูกในบริเวณภาคตะวันออกเฉียงเหนือ พร้อมทั้งจัดรูปแบบให้เหมาะสมพร้อมนำไปใช้ประโยชน์แสดงรายละเอียดตามรูปที่ 3.2

Year	HA	S	CF	P1	MP1	Yield
2537	10568292	8.29	20.94	74.17242	3.7	284
2538	10986747	7.87	21.21	74.88627	6.6	287
2539	9801374	7.74	21.84	75.41266	5.74	280
2540	12331757	8.3	24.94	72.52169	3.9	281
2541	11987165	8.59	21.31	71.08505	5.41	268
2542	12913863	7.99	24.41	79.60799	8.22	278
2543	12199474	7.49	23.72	88.844	6.805	310
2544	12891730	9.23	23.83	71.21606	8.44	329

รูปที่ 3.2 ตัวอย่างข้อมูลจากสำนักงานเศรษฐกิจการเกษตร

2) รวบรวมข้อมูล The Power Project NASA โดยดึงข้อมูลผ่าน API ของทาง Power Project NASA รายละเอียดตามรูปที่ 3.3 และ 3.4 โดยดึงข้อมูลจากอำเภอซึ่งเป็นจุดที่เพาะปลูกมากที่สุดของจังหวัดเพื่อเป็นตัวแทนของแต่ละจังหวัด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.3 หน้าต่าง The Power Project NASA

PARAMETER	YEAR	MAY	JUN	JUL	AUG	SEP
RH2M	1989	66.94	84.94	84.88	87.12	86.38
RH2M	1990	69.62	83.12	84.38	87.12	87
RH2M	1991	68.06	76.56	81.75	86.19	86.75
RH2M	1992	64.31	81.06	82.19	86.06	87.5
RH2M	1993	67.56	76.81	80.25	85.38	85.81
RH2M	1994	72.75	86.5	86.38	86.25	88.19
RH2M	1995	68.25	84.25	88.31	89.31	87.12
T2M_RANGE	1989	15.69	9.76	9.81	9.29	10.39
T2M_RANGE	1990	20.12	10.3	9.83	10.25	8.96
T2M_RANGE	1991	14.4	13.91	10.16	10.72	9.26
T2M_RANGE	1992	18.21	14.1	12.07	9.34	8.05
T2M_RANGE	1993	17.03	12.52	10.94	10.55	9.52
T2M_RANGE	1994	18.67	8.37	9.54	9.59	10.8
T2M_RANGE	1995	15.96	9.2	8.16	7.79	11.88
WS2M_RANGE	1989	5.54	4.59	5.4	4.13	3.72
WS2M_RANGE	1990	5.22	4.27	4.07	6.48	4.16
WS2M_RANGE	1991	4.35	6.14	5.31	8.76	3.83
WS2M_RANGE	1992	5	5.04	4.61	4.08	3.61
WS2M_RANGE	1993	5.06	4.51	5.06	4.72	3.32
WS2M_RANGE	1994	5.09	5.77	5.75	4.95	4.09
WS2M_RANGE	1995	5.36	4.37	5.14	6.02	4.4

รูปที่ 3.4 ตัวอย่างรายละเอียดข้อมูลจาก The Power Project NASA

เมื่อได้รับข้อมูลตามรูปที่ 3.4 ข้อมูลแต่ละตัวแปรจะอยู่ในลักษณะรายเดือนยังไม่สามารถใช้เป็นตัวแทนได้ จึงดำเนินการใช้วิธีหาค่าเฉลี่ยของทุกเดือนเพื่อเป็นตัวแทนในแต่ละปีของแต่ละจังหวัด หลังจากนั้นจะนำค่าเฉลี่ยที่ได้จากทุกจังหวัดมาหาค่าเฉลี่ยร่วมกันอีกครั้งหนึ่งเพื่อเป็นตัวแทนในแต่ละปีของภาคตะวันออกเฉียงเหนือ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) รวบรวมข้อมูลกรมอุตุนิยมวิทยาจากฐานข้อมูลที่เชื่อมต่อไว้กับสำนักงานเศรษฐกิจการเกษตร โดยเป็นข้อมูลจำนวนวันฝนตกเฉลี่ยตั้งแต่เดือนพฤษภาคม ถึง กันยายน รายจังหวัด ตามรูปที่ 3.5

PROVINCE	REGION	YEAR	MAY	JUN	JUL	AUG	SEP
Loei	NE	2537	19.0	25.0	12.0	25.0	28.6
UdonThani	NE	2537	18.0	26.0	24.0	27.0	25.6
NongKhai	NE	2537	19.0	29.0	23.0	26.0	25.4
SakonNakho	NE	2537	19.0	28.0	24.0	28.0	24.0
NakhonPhan	NE	2537	17.0	30.0	27.0	29.0	24.0
Mukdahan	NE	2537	19.0	25.0	27.0	24.0	20.6
Yasothon	NE	2537	17.0	25.0	25.0	22.0	19.0
UbonRatcha	NE	2537	17.0	25.0	25.0	22.0	27.0
SiSaKet	NE	2537	19.0	25.0	19.0	4.0	18.8
Surin	NE	2537	19.0	30.0	23.0	27.0	26.4
BuriRum	NE	2537	18.0	19.0	15.0	21.0	26.0
MahaSarakh	NE	2537	14.0	17.0	11.0	25.0	22.8
RoiEt	NE	2537	20.0	23.0	16.0	24.0	24.4
Kalasin	NE	2537	12.0	16.0	12.0	16.0	19.4

รูปที่ 3.5 ตัวอย่างข้อมูลจากกรมอุตุนิยมวิทยา

เมื่อได้รับข้อมูลตามรูปที่ 3.5 ข้อมูลแต่ละตัวแปรจะยังอยู่ในลักษณะรายเดือนไม่สามารถใช้เป็นตัวแทนได้ จึงดำเนินการใช้วิธีหาค่าเฉลี่ยเพื่อเป็นตัวแทนในแต่ละปีของแต่ละจังหวัด หลังจากนั้นจะนำค่าเฉลี่ยที่ได้จากทุกจังหวัดมาหาค่าเฉลี่ยร่วมกันอีกครั้งหนึ่งเพื่อเป็นตัวแทนในแต่ละปีของภาคตะวันออกเฉียงเหนือ เป็นไปในลักษณะเดียวกันกับข้อมูลจาก The Power Project NASA

4) รวบรวมข้อมูลจากสำนักงานเศรษฐกิจการเกษตร The Power Project NASA และกรมอุตุนิยมวิทยา ที่ดำเนินการหาค่าเฉลี่ยเพื่อเป็นตัวแทนของภาคตะวันออกเฉียงเหนือเรียบร้อยแล้ว โดยตัวแปรส่วนใหญ่จะถูกอ้างอิงมาจากงานวิจัยอื่น ๆ ที่ใช้ในการสร้างโมเดลโดยตรง ยกเว้นบางตัวแปรที่ใช้อธิบายข้าวหอมมะลิโดยเฉพาะ หรือลักษณะการเพาะปลูกที่แตกต่างจากประเทศอื่น ประกอบไปด้วย ร้อยละเนื้อที่เพาะปลูกรายเดือนที่แตกต่างกันมีผลกระทบต่อผลผลิตตามการเปลี่ยนแปลงของช่วงแสงที่ต้นข้าวได้รับ ทำให้ปริมาณผลผลิตที่ออกมาแตกต่างกัน (Kumboonreang ,2011) ซึ่งเป็นลักษณะเฉพาะของข้าวหอมมะลิ 105 เนื่องจากเป็นข้าวกลุ่มไวแสงที่จะเต็มโตเมื่อช่วงเวลาระหว่างกลางวันและกลางคืนมีสัดส่วนเปลี่ยนแปลงไป ทำให้ข้าวหอมมะลิในประเทศไทยจะออกผลผลิตมากในช่วงปลายปี อีกตัวแปรก็คือสัดส่วนเนื้อที่เพาะปลูกด้วยวิธีนาดำ ซึ่งเป็นลักษณะวิธีที่นิยมใช้ในการเพาะปลูกในประเทศไทย ซึ่งให้ผลผลิตแตกต่างจากวิธีอื่นชัดเจน จึงเป็นอีกปัจจัยที่ส่งผลกระทบต่อผลผลิตอ้างอิงจากงานวิจัย (Kongtanajaruanunand ,2018) โดยแสดงในรูปที่ 3.6

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Year	HA	S	CF	P1	RH2M_Avg	T2M_Avg	WS2M_Avg	RD_Avg	MP1	Yield
2537	10568292	8.29	20.94	74.17242	74.024	25.9175	1.8445	21.996	3.7	284
2538	10986747	7.87	21.21	74.88627	70.825	26.041	1.8615	22.208	6.6	287
2539	9801374	7.74	21.84	75.41266	78.3625	25.9545	1.632	22.168	5.74	280
2540	12331757	8.3	24.94	72.52169	67.935	25.6805	1.971	18.278	3.9	281
2541	11987165	8.59	21.31	71.08505	64.873	26.344	1.7615	18.506	5.41	268
2542	12913863	7.99	24.41	79.60799	84.604	25.732	1.658	14.652	8.22	278
2543	12199474	7.49	23.72	88.844	84.8445	25.2775	1.583	17.314	6.805	310
2544	12891730	9.23	23.83	71.21606	77.963	26.0975	1.9245	19.432	8.44	329
2545	12679992	10.19	23.49	72.73763	76.435	25.6275	1.9675	22.306	13.75	325

รูปที่ 3.6 ตัวอย่างข้อมูลที่เตรียมพร้อมนำไปใช้ในการสร้างโมเดล

5) ตรวจสอบความถูกต้องของข้อมูล เช่น การใช้เมล็ดพันธุ์ต้องมากกว่า 0 ผลผลิตไม่ติดลบ อุณหภูมิเฉลี่ยไม่ติดลบ ข้อมูลครบถ้วนไม่มี Null ตามรูปที่ 3.7 และคำนวณค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน ค่าสูงสุดและค่าต่ำสุด ตามรูปที่ 3.8

```
<class 'pandas.core.frame.DataFrame'>
RangeIndex: 27 entries, 0 to 26
Data columns (total 11 columns):
#   Column      Non-Null Count  Dtype
---  ---
0   Year        27 non-null    int64
1   HA          27 non-null    float64
2   S           27 non-null    float64
3   CF          27 non-null    float64
4   P1          27 non-null    float64
5   RH2M_Avg   27 non-null    float64
6   T2M_Avg    27 non-null    float64
7   WS2M_Avg   27 non-null    float64
8   RD_Avg     27 non-null    float64
9   MP1        27 non-null    float64
10  Yield      27 non-null    int64
dtypes: float64(9), int64(2)
memory usage: 2.4 KB
```

รูปที่ 3.7 ตรวจสอบความครบถ้วนของข้อมูล

	HA	S	CF	P1	RH2M_Avg	T2M_Avg	WS2M_Avg	RD_Avg	MP1	Yield
count	27.00	27.00	27.00	27.00	27.00	27.00	27.00	27.00	27.00	27.00
mean	15,023,070.13	11.81	23.90	57.50	73.13	26.05	1.78	21.15	18.49	333.37
std	3,186,561.13	3.35	1.57	19.83	5.81	0.36	0.20	2.20	12.95	32.40
min	9,801,374.00	7.49	20.94	14.29	62.53	25.28	1.15	14.65	3.70	268.00
25%	12,768,140.00	8.91	23.46	52.99	68.46	25.81	1.67	19.86	8.33	317.50
50%	13,698,252.00	11.10	23.76	60.56	74.02	26.04	1.81	22.00	12.64	345.00
75%	18,065,251.00	13.29	24.51	71.87	77.47	26.29	1.93	22.32	31.88	356.00
max	21,012,067.00	18.53	27.07	88.84	84.84	26.80	2.12	23.78	41.23	376.00

รูปที่ 3.8 ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน ค่าสูงสุดและค่าต่ำสุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

6) คำนวณความสำคัญของปัจจัยที่ส่งผลต่อผลผลิตต่อไร่ด้วยวิธี Random Forest Regressor โดยประโยชน์ของวิธีนี้ช่วยแสดงให้เห็นความสำคัญของปัจจัยต่าง ๆ ที่นำมาใช้ในการสร้างโมเดล สามารถจัดลำดับตามความสำคัญของแต่ละปัจจัยและสามารถนำไปทำการฝึกสอนเปรียบเทียบระหว่างโมเดลที่ใช้ครบทุกปัจจัยกับโมเดลที่ตัดปัจจัยที่มีความสำคัญต่ำกว่า 5% แสดงความแตกต่างของประสิทธิภาพที่ได้รับ

7) นำข้อมูลที่ได้จากขั้นตอนที่ 6 มาทำ Cross-Validation โดยใช้การตั้งค่า k-fold อ้างอิงจากบทความของ Jason Brownlee (2021) เกี่ยวกับการตั้งค่าของ k-fold พบว่าการตั้งค่า k-fold ที่นิยมใช้ในปัจจุบันคือการตั้งค่าที่ 5 k-fold และ 10 k-fold ซึ่งการตั้งค่าที่ 10 k-fold นั้นเหมาะสมสำหรับตัวอย่างที่มีขนาดเล็กและมีความเสถียรมากกว่าการตั้งค่าแบบ 5 k-fold ผู้วิจัยจึงเลือกการตั้งค่าที่ 10 k-fold เป็นเกณฑ์

8) ทำการปรับค่าข้อมูลด้วย Min-Max Scaler เพื่อเตรียมข้อมูลให้พร้อมนำไปใช้กับโมเดล ซึ่งเป็นหนึ่งในหลายวิธีในการทำตัวแปร Scaling เพื่อปรับข้อมูลทุกตัวให้อยู่ในช่วงเดียวกันเพื่อนำไปประมวลผลต่อไปหรือเรียกว่าการทำ Data Normalization โดยสาเหตุที่ต้องทำเนื่องจากข้อมูลดิบที่ได้รับมานั้นมีความหลากหลายทั้งในรูปแบบของชนิด หน่วยวัด และช่วงของข้อมูลการปรับค่าให้อยู่ในมาตรฐานเดียวกัน ช่วยทำให้สร้างตัวแบบได้มีความแม่นยำมากขึ้น โดยแสดงในรูปที่ 3.9 และ 3.10 จะเห็นได้ว่าหลังจากทำการปรับตัวแปร Scaling แล้วค่าของทุกตัวแปรจะมีค่าที่ใกล้เคียงกันเหมาะสมสำหรับนำไปใช้ในโมเดล BILSTM และ BIGRU ต่อไป

```
array([[7.24637681e-02, 0.00000000e+00, 6.84095444e-02, 4.19397117e-01,
7.18701700e-01, 5.15025884e-01, 8.04381161e-01, 0.00000000e+00,
8.03199062e-01],
[3.44202899e-02, 4.40456770e-02, 1.05735926e-01, 5.00327654e-01,
7.36218444e-01, 3.71646909e-01, 8.27601314e-01, 7.72715161e-02,
8.12774559e-01],
[2.26449275e-02, 1.46818923e-01, 0.00000000e+00, 4.43643512e-01,
4.99742401e-01, 7.09477175e-01, 8.23220153e-01, 5.43565148e-02,
8.19835388e-01],
[7.33695652e-02, 6.52528548e-01, 2.25711559e-01, 2.64089122e-01,
8.49046883e-01, 2.42117294e-01, 3.97152245e-01, 5.32907008e-03,
7.81056610e-01],
[9.96376812e-02, 6.03588907e-02, 1.94973763e-01, 6.98885976e-01,
6.33178774e-01, 1.04878650e-01, 4.22124863e-01, 4.55635492e-02,
7.61785920e-01],
[4.52898551e-02, 5.66068515e-01, 2.77635736e-01, 2.97837484e-01,
5.26532715e-01, 9.89220805e-01, 0.00000000e+00, 1.20436984e-01,
8.76110410e-01],
```

รูปที่ 3.9 ตัวแปร X หลังทำ Min-Max Scaling

```
array([[0.14814815],
       [0.17592593],
       [0.11111111],
       [0.12037037],
       [0.          ],
       [0.09259259],
       [0.38888889],
       [0.56481481],
       [0.52777778],
       [0.62962963],
       [0.62962963],
       [0.71296296],
       [0.69444444],
       [0.73148148],
       [0.72222222],
       [0.68518519],
       [0.90740741],
```

รูปที่ 3.10 ตัวแปร Y หลังทำ Min-Max Scaling

9) สร้างโมเดลโดยใช้ อัลกอริทึม Bidirectional Long Short-Term Memory และ Bidirectional Gated Recurrent Unit โดยทำการทดลองสร้างโมเดลตามเงื่อนไขที่กำหนด ซึ่งอ้างอิงมาจากงานวิจัย (Cetiner & Burhan, 2022) ตามตารางที่ 3.5 จากตารางสามารถแบ่งการตั้งค่าได้ทั้งหมด 9 วิธี เลือกใช้ Loss Function เป็น MSE เนื่องจาก MSE เหมาะสมกับการแก้ปัญหาในเชิงถดถอยซึ่งตรงกับงานวิจัยในครั้งนี้และเหมาะสมสำหรับชุดข้อมูลที่มีความผิดปกติไม่มาก นอกจากนี้ยังกำหนดค่า Epoch เบื้องต้นเป็นจำนวน 100 ครั้ง แต่กำหนดเงื่อนไขในการหยุดทำงานเมื่อค่า Value Loss เข้าใกล้ 0 และไม่ลดลงเกิน 10 Epoch

ตารางที่ 3.5 รายละเอียดพารามิเตอร์ที่ศึกษาทดลองของ BiLSTM และ BiGRU

พารามิเตอร์	ค่าที่กำหนด
Layer	1, 5, 10
Loss	Mean Square Error
Optimizer	Adam
Batch size	4, 16, 64
Buffer size	100
Drop out	0.2
Dense	20
Activation	ใช้ Tanh และ ReLU ร่วมกัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

10) นำผลลัพธ์ที่ได้วัดประสิทธิภาพของโมเดลด้วย MAPE โดยมีเกณฑ์ขั้นต่ำในการพิจารณาไม่เกิน 10% นอกจากนี้ยังทำการเปรียบเทียบความแตกต่างของโมเดลด้วยวิธี One-way ANOVA ระดับความเชื่อมั่นที่ 95% ในการทดสอบสมมติฐานทางสถิติ ถ้าค่า p-value มากกว่า 0.05 แสดงว่าค่าเฉลี่ย MAPE ไม่มีความแตกต่างกันอย่างมีนัยสำคัญ แต่ถ้าค่า p-value น้อยกว่า 0.05 แสดงว่าค่าเฉลี่ย MAPE มีความแตกต่างกัน ผู้วิจัยได้แบ่งการทดสอบสมมติฐานทางสถิติ ออกเป็น 2 กรณี ได้แก่

1) กรณีทำการฝึกสอนด้วย Layer ที่แตกต่างกัน ในขณะที่ Batch size เท่ากัน

$$H_0 : \mu_1 = \mu_5 = \mu_{10}$$

H_a : มีค่าเฉลี่ยอย่างน้อย 1 คู่มีค่าแตกต่างกัน

เมื่อ μ_1 แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 1 Layer
 μ_5 แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 5 Layer
 μ_{10} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 10 Layer

2) กรณีทำการฝึกสอนด้วย Layer เท่ากัน ในขณะที่ Batch size แตกต่างกัน

$$H_0 : \mu_4 = \mu_{16} = \mu_{64}$$

H_a : มีค่าเฉลี่ยอย่างน้อย 1 คู่มีค่าแตกต่างกัน

เมื่อ μ_4 แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 4 Batch
 μ_{16} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 16 Batch
 μ_{64} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 64 Batch

11) เปรียบเทียบค่า MAPE ของโมเดลที่มีค่า MAPE ต่ำที่สุดกับโมเดลที่ทำการตัดตัวแปรที่มีความสำคัญต่ำกว่า 5% ออกโดยใช้สถิติทดสอบ T-Test เพื่อทดสอบความแตกต่างของค่าเฉลี่ยของ MAPE ระหว่างโมเดลพยากรณ์ที่ไม่มีและมีการตัดตัวแปรที่มีความสำคัญต่ำกว่า 5% ในการทดสอบสมมติฐานทางสถิติ ถ้าค่า p-value มากกว่า 0.05 แสดงว่าค่าเฉลี่ย MAPE ไม่มีความแตกต่างกันอย่างมีนัยสำคัญ แต่ถ้าค่า p-value น้อยกว่า 0.05 แสดงว่าค่าเฉลี่ย MAPE มีความแตกต่างกัน

$$H_0 : \mu_{normal} = \mu_{adjust}$$

$$H_a : \mu_{normal} \neq \mu_{adjust}$$

เมื่อ μ_{normal} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 10 Layer 4 Batch
 μ_{adjust} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 10 Layer 4 Batch แต่ทำการตัด
 โมเดลที่มีความสำคัญต่ำกว่า 5% ออกจากการฝึกสอน



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

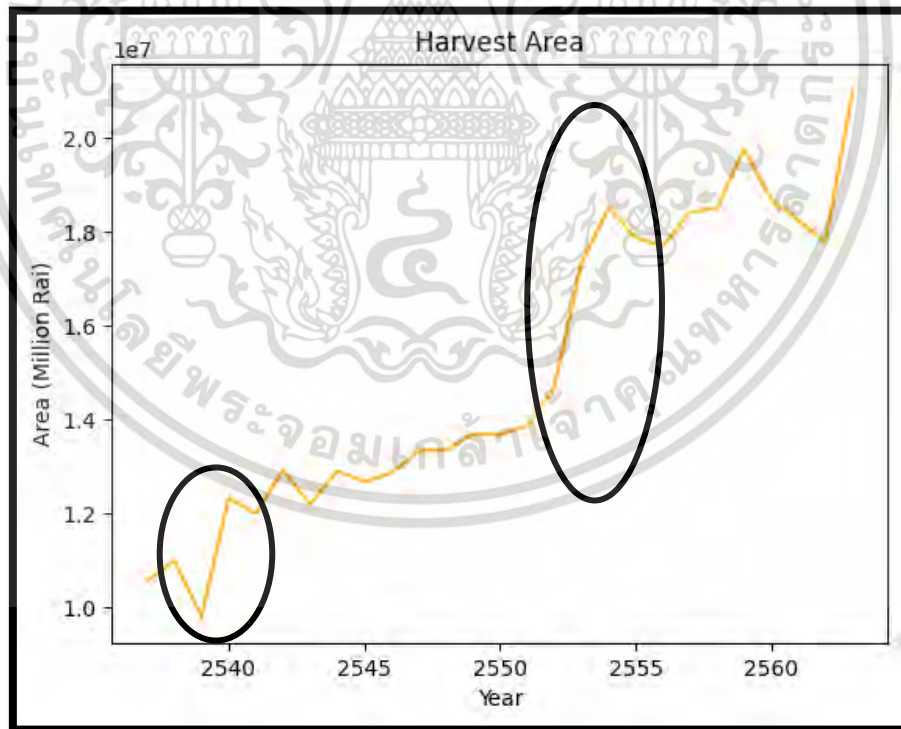
บทที่ 4

ผลการวิจัยและการอภิปรายผล

เนื้อหาในบทนี้จะถูกแบ่งออกเป็น 2 หัวข้อย่อย โดยหัวข้อแรกจะเป็นการอธิบายลักษณะของตัวแปรที่นำมาใช้ในการสร้างโมเดลเพื่อให้ทราบถึงลักษณะเฉพาะของตัวแปรแต่ละตัวและพฤติกรรมของเกษตรกรที่มีอิทธิพลต่อตัวแปรดังกล่าว ในหัวข้อที่สองจะเป็นการอธิบายผลลัพธ์จากการทดลองในแต่ละเงื่อนไขตามที่ได้กำหนดไว้ในบทที่ผ่านมาและอภิปรายผลที่เกิดขึ้น

ในหัวข้อที่หนึ่งการอธิบายเกี่ยวกับตัวแปรจะเริ่มจากการอธิบายกลุ่มของตัวแปรที่เกี่ยวข้องกับพฤติกรรมของเกษตรกร โดยจะแบ่งการอธิบายออกเป็น 3 ส่วน ส่วนแรกจะเป็นการอธิบายพฤติกรรมในการดูแลรักษาที่เกี่ยวข้องกับผลผลิตโดยตรง ส่วนที่สองจะเป็นการอธิบายเกี่ยวกับช่วงเดือนที่เกษตรกรทำการเพาะปลูก และในที่สุดท้ายจะเป็นการอธิบายความสัมพันธ์ระหว่างตัวแปรด้วยค่า Correlation ในรูปแบบของ Heatmap


4.1 ลักษณะเฉพาะของตัวแปร



รูปที่ 4.1 เนื้อที่เก็บเกี่ยวข้าวนาปี

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

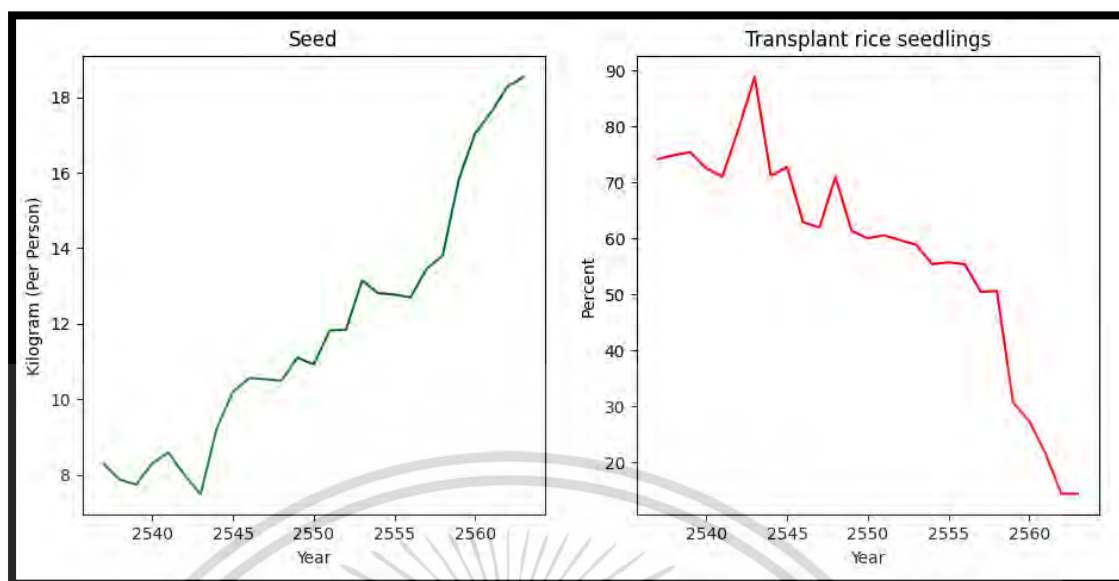
จากรูปที่ 4.1 อธิบายเกี่ยวกับแนวโน้มเนื้อที่เก็บเกี่ยว (HA) ของเกษตรกรจากอดีตจนถึงปัจจุบัน จากรูปจะสังเกตเห็นว่าการเพิ่มขึ้นอย่างผิดปกติของเนื้อที่เก็บเกี่ยวเกิดขึ้น 2 ช่วงด้วยกันโดยช่วงแรกอยู่ในปี 2540 เป็นช่วงที่ประเทศไทยเผชิญหน้ากับวิกฤตต้มยำกุ้ง เกิดปัญหาประชากรว่างงานเป็นจำนวนมากทำให้กลุ่มคนที่มีพื้นที่การเกษตรเดิมกลับไปปลูกข้าวในช่วงเวลาดังกล่าว ทั้งจากที่นาเดิมที่เคยปล่อยว่างและทดแทนการเพาะปลูกพืชชนิดอื่น ต่อมาในช่วงปี 2554 เป็นอีกช่วงเวลา เนื้อที่เก็บเกี่ยวเพิ่มขึ้นอย่างมากจากอิทธิพลของโครงการรับจำนำข้าว เนื่องจากเป็นโครงการที่จ่ายเงินช่วยเหลือเกษตรกรสูงกว่าพืชชนิดอื่นอย่างชัดเจน ทำให้ในช่วงปีดังกล่าวเกษตรกรปรับเปลี่ยนพฤติกรรมจากปลูกข้าวไว้กินในครัวเรือนเป็นไปทางการค้ามากยิ่งขึ้น และส่งผลต่อเนื่องมาจนถึงปัจจุบัน



รูปที่ 4.2 การใช้ปุ๋ยเคมีของเกษตรกร

จากรูปที่ 4.2 แนวโน้มปริมาณการใช้ปุ๋ยเคมี (CF) โดยในช่วงต้นพบว่าเกษตรกรไม่ได้ให้ความสำคัญกับการใช้ปุ๋ยเคมีมากนักยังมีการใช้ปุ๋ยอินทรีย์ควบคู่ไปกับการใช้ปุ๋ยเคมีจนกระทั่งในช่วงปี 2558 เกษตรกรเริ่มให้ความสำคัญกับการใช้ปุ๋ยเคมีมากยิ่งขึ้น มีการปรับเปลี่ยนพฤติกรรมลดการใช้ปุ๋ยอินทรีย์และใช้ปุ๋ยเคมีแต่เพียงอย่างเดียวในช่วงเวลาดังกล่าวจนกระทั่งถึงปัจจุบัน

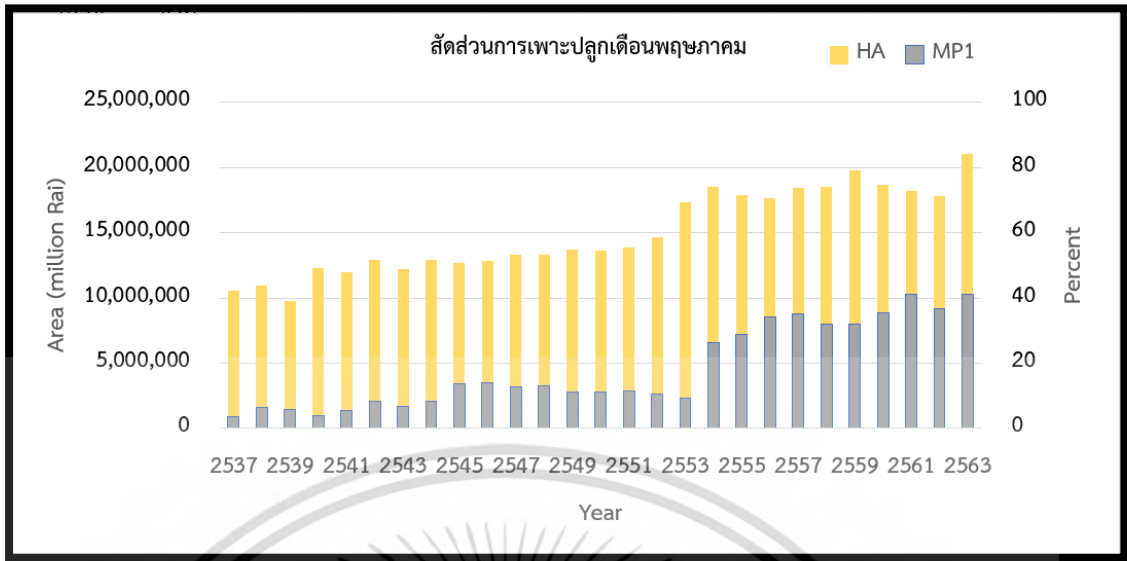
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 4.3 การใช้เมล็ดพันธุ์กับวิธีเพาะปลูกโดยวิธีนาดำ

จากรูปที่ 4.3 อธิบายแนวโน้มการใช้เมล็ดพันธุ์ (S) และแนวโน้มการเพาะปลูกโดยวิธีนาดำ (P1) จะสังเกตเห็นว่าปริมาณการใช้เมล็ดพันธุ์ในการเพาะปลูกและร้อยละการเพาะปลูกด้วยวิธีนาดำมีทิศทางที่ตรงกันข้ามกันเนื่องจากการปรับเปลี่ยนพฤติกรรมกรรมการเพาะปลูกของเกษตรกร โดยในช่วงต้นเกษตรกรนิยมทำการเพาะปลูกด้วยวิธีนาดำเป็นหลักซึ่งเป็นวิธีที่ใช้เมล็ดพันธุ์ในการเพาะปลูกน้อยเนื่องจากเกษตรกรต้องเพาะต้นกล้าให้เจริญเติบโตก่อนในช่วงแรกก่อนนำไปปักลงในดินทำให้ต้นข้าวเติบโตเป็นแถวและมีช่องว่างอย่างชัดเจน แต่อย่างไรก็ตามวิธีการเพาะปลูกด้วยวิธีนาดำจำเป็นที่จะต้องใช้แรงงานเป็นจำนวนมากไม่สอดคล้องกับสภาพสังคมในปัจจุบันที่เกษตรกรเริ่มมีอายุเฉลี่ยสูงขึ้นอย่างต่อเนื่องทำให้วิธีดังกล่าวได้รับความนิยมลดลงอย่างต่อเนื่องจนถึงปัจจุบัน แตกต่างกับการเพาะปลูกด้วยวิธีหว่านที่ใช้แรงงานในการเพาะปลูกที่น้อยกว่าและไม่จำเป็นต้องเพาะต้นกล้าก่อนการเพาะปลูก แต่อย่างไรก็ตามก็แลกมาด้วยการที่เกษตรกรจำเป็นที่ต้องใช้เมล็ดพันธุ์ที่เพิ่มขึ้นเพื่อให้หว่านได้เต็มพื้นที่เพื่อเพิ่มโอกาสในการงอกของต้นข้าวในแปลงนาทำให้มีการใช้เมล็ดพันธุ์ที่มากกว่าการดำอย่างชัดเจน

ในหัวข้อต่อมาเป็นส่วนของพฤติกรรมกรรมการเพาะปลูกของเกษตรกรที่แสดงแนวโน้มการปรับเปลี่ยนไปตามช่วงเวลา



รูปที่ 4.4 สัดส่วนการเพาะปลูกเดือนพฤษภาคม

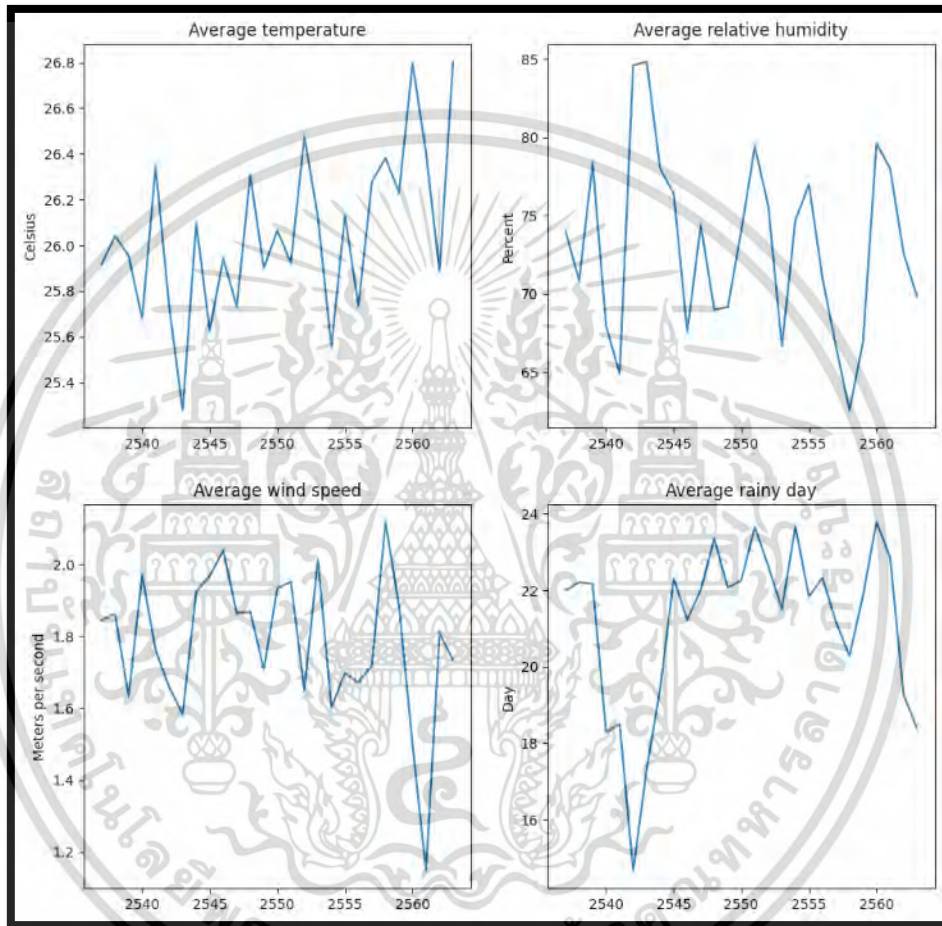


รูปที่ 4.5 สัดส่วนการเพาะปลูกปี 2563

จากรูปที่ 4.4 และรูปที่ 4.5 สัดส่วนการเพาะปลูกช่วงเดือนพฤษภาคมของเกษตรกร (MP1) ในปี 2537 ถึง 2554 ไม่ค่อยมีการปรับเปลี่ยนพฤติกรรมมากนักเนื่องจากเกษตรกรนิยมเพาะปลูกด้วยวิธีดำนาทำให้ช่วงต้นของฤดูฝนเกษตรกรอยู่ในช่วงเพาะเลี้ยงต้นกล้าอ่อนไม่สามารถทำการเพาะปลูกได้ ก่อนที่จะมีการปรับเปลี่ยนพฤติกรรมในช่วงปี 2554 เนื่องจากโครงการรับจำนำข้าวของภาครัฐ เกษตรกรปรับเปลี่ยนจากวิธีดำนาเป็นวิธีหว่านแห้งหรือหว่านน้ำตามทดแทน เพื่อเพิ่มจำนวนเนื้อที่ในการเพาะปลูกทำให้สามารถขึ้นทะเบียนเกษตรกรและเข้าร่วมโครงการรับจำนำข้าวได้มากกว่าปกติ ซึ่งสาเหตุที่สามารถเพิ่มเนื้อที่เพาะปลูกได้นั้นมาจากการที่เกษตรกรลดเวลาในการเพาะเลี้ยงต้นกล้าและ

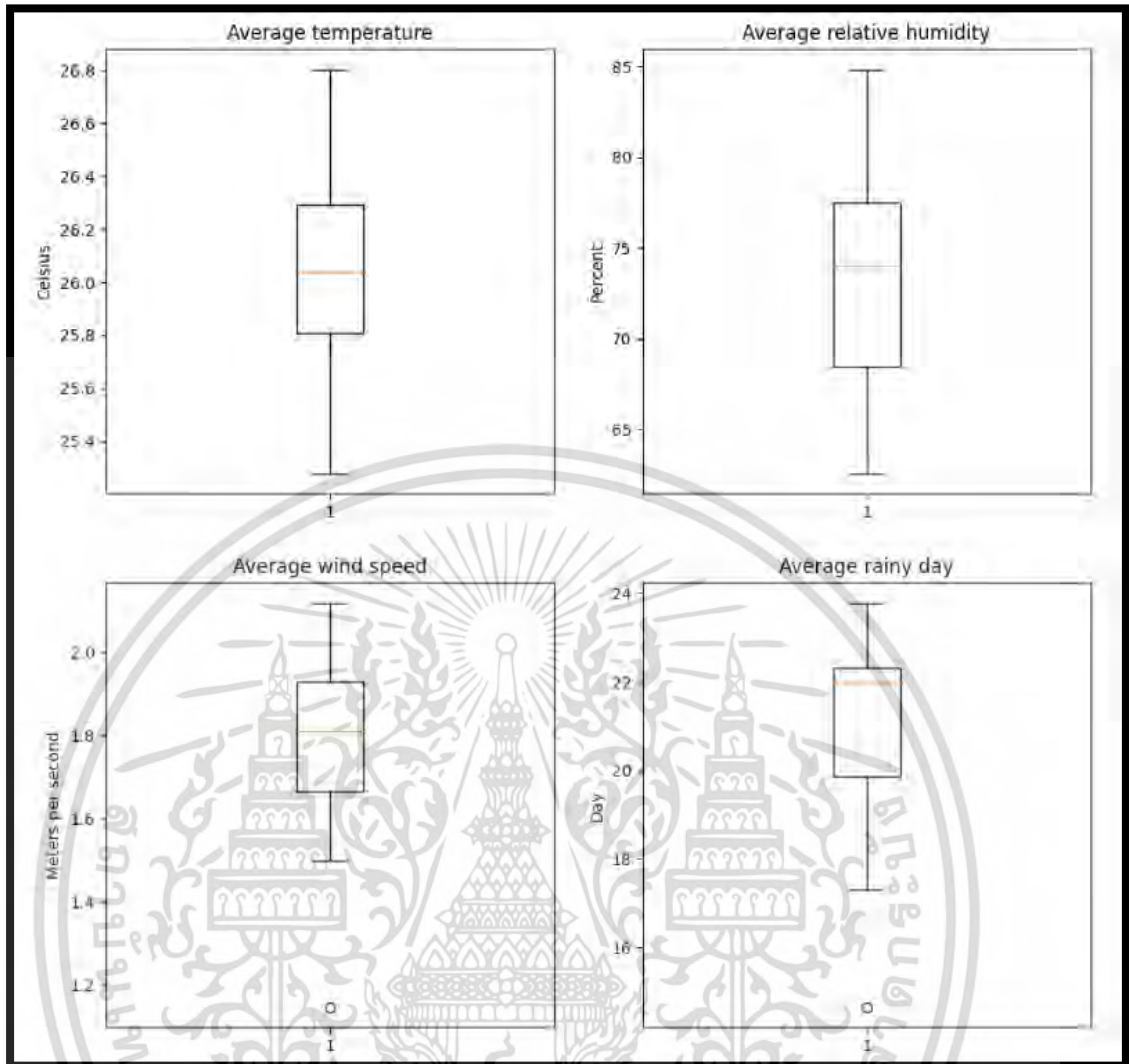
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แรงงานในการปักดำที่ใช้เวลาเป็นจำนวนมากลงไปและปรับเปลี่ยนเป็นการหว่านด้วยเมล็ดพันธุ์ให้ทั่วแปลงนาโดยเกษตรกรสามารถเริ่มการเพาะปลูกได้ตั้งแต่ช่วงต้นของฤดูฝนและแล้วเสร็จภายในเวลา 1-2 วัน และจากรูปที่ 4.5 ในปี 2563 การเพาะปลูกในช่วงเดือนพฤษภาคมเป็นเดือนที่เกษตรกรทำการเพาะปลูกมากที่สุดจึงเป็นสาเหตุที่ผู้วิจัยเลือกเดือนนี้เป็นตัวแทนของเดือนทั้งหมดมาใช้งานวิจัยฉบับนี้



รูปที่ 4.6 สภาพอากาศในช่วงเวลาเพาะปลูก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.7 ค่าเฉลี่ยสภาพอากาศและค่าผิดปกติ

สำหรับส่วนสุดท้ายจะอธิบายกลุ่มของปัจจัยที่เกี่ยวข้องกับสภาพอากาศตามรูปที่ 4.6 ได้แก่ ปัจจัยค่าเฉลี่ยอุณหภูมิ ค่าเฉลี่ยความชื้นสัมพัทธ์ ค่าเฉลี่ยแรงลม และค่าเฉลี่ยวันฝนตก โดยกลุ่มของปัจจัยกลุ่มนี้เป็นกลุ่มที่ไม่สามารถควบคุมได้ ขึ้นอยู่กับหลายปัจจัยและปรากฏการณ์ที่สำคัญ เช่น ปัญหาโลกร้อน เอลนีโญ ลานีญา ซึ่งปรากฏการณ์จะมีลักษณะเกิดขึ้นเป็นรอบ ๆ ซึ่งแต่ละรอบใช้เวลาประมาณ 3-5 ปี ความรุนแรงในแต่ละครั้งก็จะแตกต่างกันออกไป ส่งผลให้กราฟที่ออกมาจะมีลักษณะเป็นฟันปลาสลับขึ้นลง ส่วนในรูปที่ 4.7 ปัจจัยค่าเฉลี่ยอุณหภูมิและค่าเฉลี่ยความชื้นสัมพัทธ์มีค่าเฉลี่ยอยู่ใกล้กึ่งกลาง คล้ายกับการแจกแจงปกติ มีความแปรปรวนสูง ไม่มีค่าผิดปกติ ในส่วนของค่าเฉลี่ยแรงลมและค่าเฉลี่ยวันฝนตก มีค่าผิดปกติที่ชัดเจน ความแปรปรวนสูง แต่สำหรับค่าเฉลี่ยวันฝนตก มีลักษณะคล้ายการแจกแจงแบบเบ้ซ้าย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.2 สถิติเชิงพรรณนา

ตารางที่ 4.1 สถิติเชิงพรรณนาของตัวแปรที่ใช้ในการศึกษา

ตัวแปร	ค่าเฉลี่ย	ส่วนเบี่ยงเบน มาตรฐาน	C.V.	Skewness	Kurtosis
HA	15,023,070.13	3,186,561.13	21.21	0.2170	-1.2820
S	11.81	3.35	28.37	0.6050	-0.6115
CF	23.90	1.57	6.57	0.1206	0.0680
P1	57.50	19.83	34.49	-0.9184	0.0093
MP1	18.49	12.95	70.04	0.5481	-1.3316
T2M_Avg	26.05	0.36	1.38	0.2097	-0.1029
RH2M_Avg	73.13	5.81	7.94	0.2173	-0.6727
WS2M_Avg	1.78	0.20	11.24	-1.0016	1.8138
RD_Avg	21.15	2.20	10.40	-1.2028	1.0222
Yield	333.37	32.40	9.72	-0.8218	-0.7336

จากข้อมูลในตารางที่ 4.1 หากพิจารณาจากค่า C.V. เป็นหลัก โดยเรียงลำดับจากตัวแปรที่มีค่า C.V. สูงไปหาตัวแปรที่มีค่า C.V. ต่ำที่สุดจะเรียงลำดับได้ดังนี้ $MP1 > P1 > S > HA > WS2M_Avg > RD_Avg > Yield > RH2M_Avg > CF > T2M_Avg$ จะให้เห็นได้ว่าค่าของ MP1 จะเป็นตัวแปรที่มีค่า C.V. สูงที่สุดและแตกต่างจากตัวแปรอื่น สาเหตุส่วนใหญ่ดังที่กล่าวไว้ในหัวข้อลักษณะเฉพาะของตัวแปรในรูปที่ 4.4 เกษตรกรมีพฤติกรรมที่เปลี่ยนไปอย่างชัดเจนในช่วงประมาณ 10 ปีหลังจากปัจจัยภายนอกหลายอย่างหนึ่งในนั้นก็คือผลกระทบจากนโยบายของภาครัฐที่ส่งผลกระทบต่อมากที่สุด ตัวแปรกลุ่มต่อมาที่มีค่า C.V. อยู่ที่ประมาณ 20-40 ได้แก่กลุ่มตัวแปรเกี่ยวกับพฤติกรรมเพาะปลูกของเกษตรกรได้แก่ P1, S, HA ที่มีการปรับเปลี่ยนไปตามปัจจัยภายนอกจากเดิมที่ทำเกษตรเก็บไว้เพื่อบริโภคในครัวเรือน ทำนาในพื้นที่ขนาดเล็ก เพาะปลูกด้วยวิธีนาดำใช้การลงแขกใช้เมล็ดพันธุ์น้อยในการเพาะปลูกในแต่ละแปลง ก็ถูกปรับมาทำการพาณิชย์มากยิ่งขึ้น เกษตรกรขยายเนื้อที่เพาะปลูกออกไปโดยมีวัตถุประสงค์เพื่อขาย ลดการใช้เมล็ดพันธุ์ที่ซ้ำและใช้แรงงานมากเป็นการหว่านน้ำตามที่ใช้แรงงานน้อยทำได้ครั้งละมาก ๆ และเพิ่มปริมาณเมล็ดพันธุ์ให้มากขึ้นให้มีต้นข้าวเต็มพื้นที่ นาลดช่องว่างในการเติบโตของหญ้าวัชพืช ตัวแปรกลุ่มสุดท้ายที่น่าสนใจคือกลุ่มที่เกี่ยวข้องกับสภาพอากาศ ได้แก่ตัวแปร WS2M_Avg, RD_Avg, RH2M_Avg, T2M_Avg เป็นกลุ่มตัวแปรที่เกษตรกรไม่สามารถกำหนดได้เปลี่ยนแปลงไปตามธรรมชาติจะมีค่า C.V. ที่ค่อนข้างต่ำอยู่ในช่วงระหว่าง 1-12 ซึ่งแตกต่างจากปัจจัยอื่นอย่างชัดเจน ต่อมาเมื่อพิจารณา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

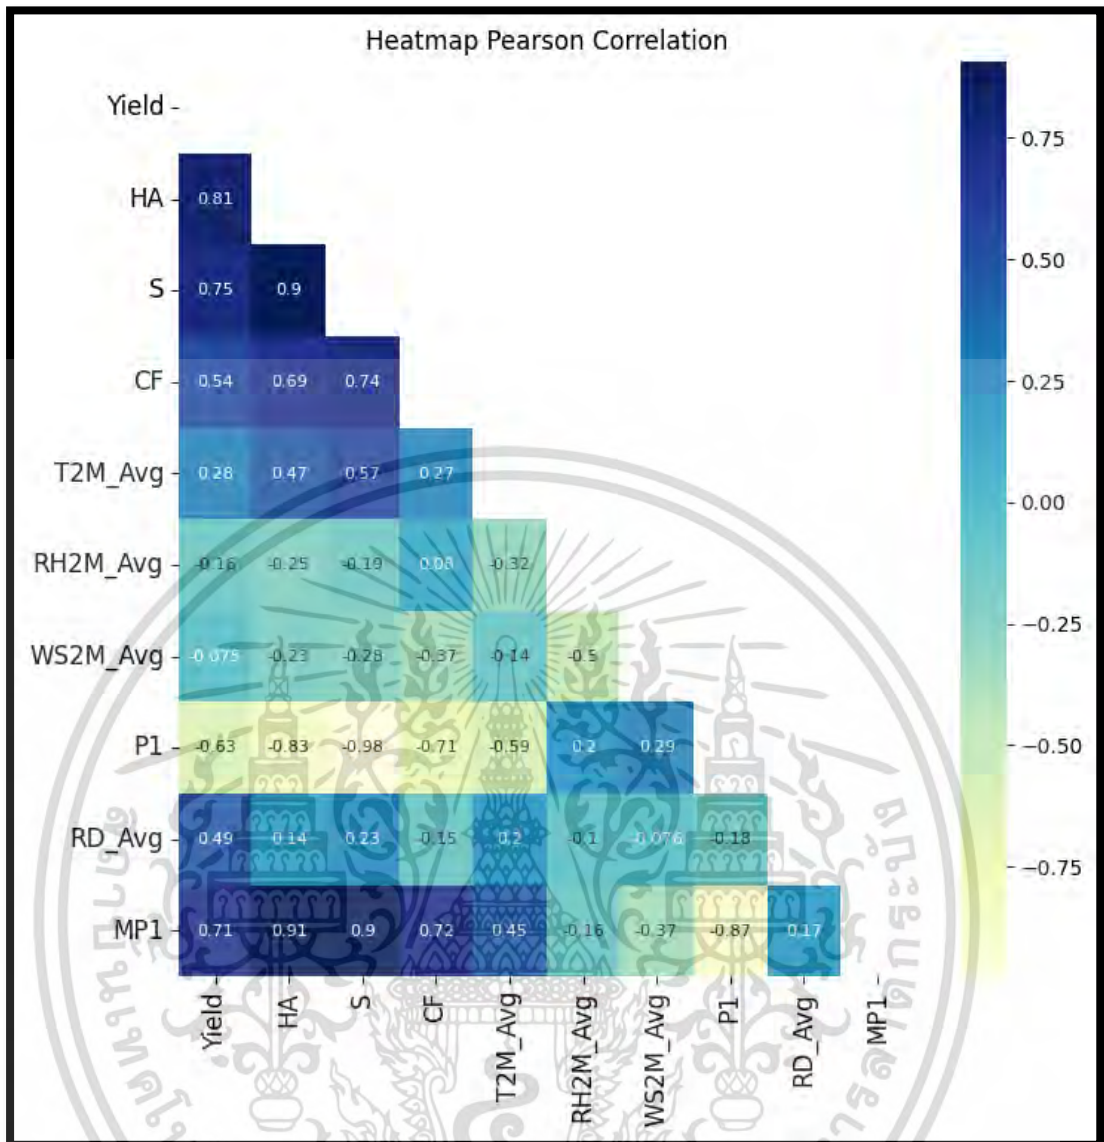
ค่า Skewness สามารถจัดกลุ่มตัวแปรได้ทั้งหมด 3 กลุ่มคือ กลุ่มที่มีค่าระหว่าง -0.5 ถึง 0.5 มีลักษณะข้อมูลใกล้เคียงกับการแจกแจงปกติ ได้แก่ ปัจจัย CF, T2M_Avg, HA และ RH2M_Avg กลุ่มต่อมาเป็นกลุ่มที่มีค่าระหว่าง -1 ถึง -0.51 และ 0.51 ถึง 1 ข้อมูลเริ่มมีลักษณะการเบ้หากข้อมูลมีค่าติดลบจะมีลักษณะเบ้ซ้าย ได้แก่ ปัจจัย Yield, P1 แต่ถ้าหากข้อมูลมีค่าเป็นบวกจะมีลักษณะเป็นเบ้ขวา ได้แก่ ปัจจัย MP1 และ S กลุ่มสุดท้ายหากค่าเกิน -1 ถึง 1 จะเป็นปัจจัยที่มีความเบ้มาก ได้แก่ ปัจจัย WS2M_Avg และ RD_Avg ค่าสุดท้ายที่จะพิจารณาได้แก่ค่า Kurtosis จากปัจจัยในตารางสามารถแบ่งออกได้ 2 กลุ่มคือ กลุ่มที่มีค่าใกล้เคียง 0 มีลักษณะใกล้เคียงกับการแจกแจงปกติ ได้แก่ P1, CF, T2M_Avg, S, RH2M_Avg และ Yield กลุ่มต่อมาเป็นกลุ่มที่มีค่าน้อยกว่า -1 จะเป็นกลุ่มที่มีความโด่งที่แบนราบกว่าปกติ ได้แก่ HA และ MP1 กลุ่มสุดท้ายคือกลุ่มที่มีความมากกว่า 1 เป็นกลุ่มที่มีความโด่งที่สูงกว่าปกติ ได้แก่ RD_Avg และ WS2M_Avg

4.3 Heatmap Pearson Correlation

จากรูปที่ 4.8 แสดงความสัมพันธ์ระหว่างผลผลิตต่อไร่ กับ ตัวแปรอื่นที่ใช้ในการสร้างโมเดลประกอบไปด้วย HA, S, CF, T2M_Avg, RH2M_Avg, WS2M_Avg, P1, RD_Avg และ MP1 โดยหากเรียงลำดับความสัมพันธ์โดยไม่สนใจเครื่องหมายจะสามารถเรียงลำดับได้ดังนี้ $HA > S > MP1 > P1 > CF > RD_Avg > T2M_Avg > RH2M_Avg > WS2M_Avg$ แต่ถ้าหากจัดกลุ่มตัวแปรแบ่งตามความสัมพันธ์เชิงบวกและความสัมพันธ์เชิงลบเป็น 2 กลุ่มจะสามารถเรียงลำดับได้ดังนี้

1) กลุ่มที่มีความสัมพันธ์เชิงบวกแบ่งออกมาได้ทั้งหมด 6 ตัวแปร เรียงลำดับได้ตามนี้ $HA > S > MP1 > CF > RD_Avg > T2M_Avg$ สังเกตได้ว่าในกลุ่มตัวแปรที่เกี่ยวข้องกับการเพาะปลูกโดยตรงอย่าง HA, S และ CF ยิ่งเกษตรกรเพิ่มปัจจัยดังกล่าวจะส่งผลทำให้ผลผลิตต่อไร่เพิ่มขึ้นตามไปด้วย ต่อมาในตัวแปร MP1 ยิ่งเกษตรกรสามารถดำเนินการเพาะปลูกได้เร็วตั้งแต่ช่วงเดือนพฤษภาคม จะส่งผลต่อผลผลิตที่เพิ่มขึ้นเช่นเดียวกัน และตัวแปร RD_Avg สะท้อนถึงพฤติกรรมของเกษตรกรที่พึ่งพาน้ำฝนในการเพาะปลูกเป็นหลัก ยิ่งจำนวนวันฝนตกในช่วงเวลาเพาะปลูกมากยิ่งส่งผลต่อผลผลิตมากเช่นเดียวกัน สุดท้ายเป็นตัวแปร T2M_Avg มีผลกระทบในเชิงบวกกับผลผลิตเช่นเดียวกันแต่มีความสัมพันธ์กับผลผลิตน้อยกว่าตัวแปรอื่น ๆ

2) กลุ่มที่มีความสัมพันธ์เชิงลบแบ่งออกมาได้ทั้งหมด 3 ตัวแปร เรียงลำดับได้ตามนี้ $P1 > RH2M_Avg > WS2M_Avg$ ปัจจัยที่มีความสัมพันธ์เชิงลบกับผลผลิตต่อไร่สูงที่สุดเป็นตัวแปรวิธีการเพาะปลูกด้วยวิธีดำนา ซึ่งเป็นการยืนยันถึงช่วงเวลาในการเพาะปลูกของเกษตรกรมีผลต่อผลผลิตต่อไร่ กล่าวคือยิ่งเกษตรกรเพาะปลูกช้าจะส่งผลทำให้ผลผลิตต่อไร่ลดลงตามไปด้วย ส่วนตัวแปรด้านสภาพอากาศอย่างความชื้นและแรงลม ถึงแม้จะมีความสัมพันธ์เป็นลบกับผลผลิตต่อไร่แต่กลับมีค่าที่ไม่สูงนัก



รูปที่ 4.8 ค่าความสัมพันธ์ระหว่างผลผลิตต่อไร่กับตัวแปรอื่นในรูปแบบ Heatmap

4.4 ความสำคัญของปัจจัยที่มีผลต่อผลผลิตต่อไร่ของข้าวหอมมะลิ

งานวิจัยฉบับนี้ได้กำหนดให้วิธี Random Forest Regressor เป็นวิธีที่ใช้ในการอธิบายความสำคัญของตัวแปร สำหรับการนำไปใช้ในการสร้างโมเดล BILSTM และ BIGRU โดยสาเหตุที่เลือกใช้วิธีนี้ เนื่องจากเป็นวิธีที่ใช้สำหรับอธิบายผลกระทบระหว่างตัวแปรต้นและตัวแปรตามแต่ละตัวที่ใส่เข้าไปในโมเดล ML ซึ่งมีลักษณะเหมือนกล่องดำที่ทราบเพียง input และ output เท่านั้น ทำให้ไม่สามารถอธิบายความสำคัญของตัวแปรต้นต่อตัวแปรตามแต่ละตัวแบบปกติได้ โดยค่าที่ได้หลังจากนำไปประมวลผล แล้วสามารถสรุปผลที่ออกมาได้ตามรูปที่ 4.9 สามารถเรียงลำดับตัวแปรที่มีความสำคัญได้ดังนี้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

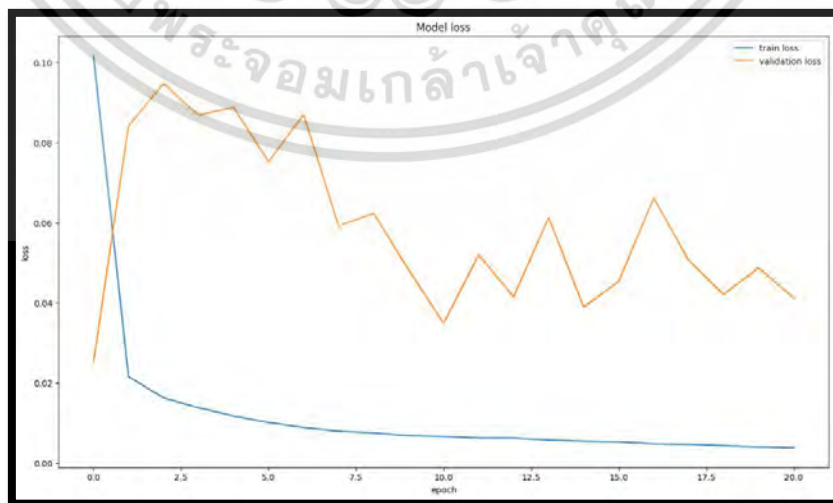
Varname	Imp
S	38.603156
MP1	21.796054
P1	14.905708
HA	11.058536
CF	7.558564
RD_Avg	2.025988
RH2M_Avg	1.822033
WS2M_Avg	1.131123
T2M_Avg	1.098837

รูปที่ 4.9 ค่าที่ได้จาก Random Forest Regressor

S > MP1 > P1 > HA > CF > RD_Avg > RH2M_Avg > WS2M_Avg > T2M_Avg พบว่ากลุ่มตัวแปรที่มีผลต่อโมเดลมากที่สุดจะเป็นกลุ่มตัวแปรที่เกี่ยวข้องกับพฤติกรรมของเกษตรกร โดยมีค่าอยู่ในช่วงประมาณ 7% ถึง 38% .โดยตัวแปรที่มีค่าโดดเด่นที่สุดคือ ประมาณเมล็ดพันธุ์ที่ใช้ต่อไร่และเปอเซ็นต์การเพาะปลูกในช่วงเดือนพฤษภาคม ในขณะที่ตัวแปรด้านสภาพอากาศมีค่าอยู่ในช่วงประมาณ 1% ถึง 2% เท่านั้น หลักจากได้ข้อมูลจาก Random Forest มาเบื้องต้นแล้วผู้วิจัยจึงใช้วิธี Cross Validation โดยกำหนดค่า k-fold ที่ 10 (Jason, 2021) เพื่อพิจารณาความสำคัญของตัวแปรอีกครั้งหนึ่งสำหรับนำไปใช้ในการสร้างโมเดล BILSTM และ BIGRU ซึ่งผลปรากฏว่าทุกตัวแปรมีความสำคัญสำหรับนำไปใช้สร้างโมเดล

4.5 การสร้างโมเดล BILSTM และ BIGRU

4.5.1 BILSTM และ BIGRU โดยกำหนดให้ จำนวน Layer เท่ากับ 1



รูปที่ 4.10 ค่า Loss จาก BILSTM model แบบ 1 Layer

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ผลการทดลองที่ใช้ในการสร้างโมเดล จะแบ่งออกตามกลุ่มของ Layer ที่ใช้ในการทดลองคือ 1, 5 และ 10 Layer ก่อนจะอธิบายภาพรวมในตอนสุดท้าย โดยเริ่มจาก 1 Layer เป็นอันดับแรกในการสร้างโมเดลแบบ 1 Layer จากรูปที่ 4.10 จะเห็นได้ว่าเมื่อทำการฝึกสอนด้วยจำนวนรอบที่มากขึ้นเรื่อย ๆ พบว่าค่า Train Loss มีค่าลดลงอย่างต่อเนื่อง ในขณะที่ค่า Validation Loss จะลดลงในช่วงแรก แต่ในช่วงการฝึกสอนหลังจาก 10 epoch กลับพบค่าที่ได้ไม่สามารถลดลงได้อีกมีลักษณะขึ้นลงไม่คงที่ซึ่งเป็นลักษณะของโมเดลที่เกิด Overfitting ซึ่งสาเหตุมาจากโมเดลที่เรียนรู้จาก Training Data มากจนเกินไปทำให้ไม่สามารถพยากรณ์ข้อมูลใหม่ได้ดีเท่าที่ควรส่งผลทำให้ค่า MAPE สูงตามตารางที่ 4.2 ด้านล่าง

ตารางที่ 4.2 ผลการทดลองสร้างโมเดลแบบ 1 Layer

Layer	Batch	โมเดล	MAPE	เวลาในการประมวลผล (วินาที)
1	4	BILSTM	4.17	25.39
1	4	BIGRU	8.44	24.94
1	16	BILSTM	3.79	25.85
1	16	BIGRU	8.80	25.41
1	64	BILSTM	3.84	25.99
1	64	BIGRU	8.68	26.18

ผลการทดลองในตารางที่ 4.2 พบว่าโมเดลแบบ 1 Layer เมื่อเพิ่ม Batch ที่ใช้ในการสร้างโมเดลค่า MAPE ที่ได้จากทั้ง BILSTM และ BIGRU จะมีลักษณะผันผวนไม่สามารถบอกแนวโน้มได้ โดย BILSTM ทำการฝึกสอนได้ดีที่สุดที่ 16 Batch และ BIGRU ทำการฝึกสอนได้ดีที่สุดที่ 4 Batch ในขณะที่เวลาในการประมวลผลจะเพิ่มขึ้นเป็นทิศทางเดียวกันตามการเพิ่มขึ้นของ Batch ต่อมาเมื่อพิจารณาในเรื่องของประสิทธิภาพระหว่าง BILSTM และ BIGRU พบว่าโมเดล BILSTM มีประสิทธิภาพในการทำนายมากกว่า BIGRU ในทุก Batch แต่อย่างไรก็ตาม BIGRU ใช้เวลาในการประมวลผล ส่วนใหญ่น้อยกว่า BILSTM ยกเว้นใน 64 Batch ที่ BILSTM ใช้เวลาในการประมวลผลน้อยกว่า BIGRU เมื่อพิจารณาทั้งปัจจัยด้านประสิทธิภาพและเวลาในการประมวลผลควบคู่กันพบว่าการใช้ BILSTM ในโมเดลแบบ 1 Layer มีความเหมาะสมมากกว่าการใช้ BIGRU เนื่องจากประสิทธิภาพที่ได้จาก BILSTM ดีกว่า BIGRU อย่างชัดเจน ในขณะที่เวลาในการประมวลผลแตกต่างกันเพียงเล็กน้อยเท่านั้นและดีกว่าใน 64 Batch

4.5.2 BILSTM และ BIGRU โดยกำหนดให้ จำนวน Layer เท่ากับ 5



รูปที่ 4.11 ค่า Loss จาก BILSTM model แบบ 5 Layer

จากรูปที่ 4.11 พบว่าโมเดลแบบ 5 Layer เมื่อจำนวน Epoch เพิ่มขึ้นค่า Train Loss และ Validation Loss มีแนวโน้มที่ใกล้เคียงกันมากขึ้นเรื่อยๆ โดยเฉพาะตั้งแต่ช่วง Epoch ที่มีรอบมากกว่า 15 รอบเป็นต้นไป ที่ค่า Train Loss และ Validation Loss ใกล้เคียงกันอย่างมากและมีความเสถียรที่มากขึ้น ซึ่งเมื่อเปรียบเทียบกับโมเดลแบบ 1 Layer พบว่าค่า Validation Loss ของโมเดลแบบ 5 Layer มีค่าที่ต่ำกว่าอย่างชัดเจนตั้งแต่เริ่มต้นและจะลดลงจนมีค่าต่ำที่สุดในช่วง 20 epoch ในขณะที่โมเดลแบบ 1 Layer มีค่าต่ำที่สุดอยู่ที่ประมาณ 0.04 ซึ่งมีค่าสูงกว่าค่าสูงสุดของโมเดลแบบ 5 Layer ทำให้เมื่อเปรียบเทียบกับโมเดลแบบ 1 Layer แล้วโมเดลแบบ 5 Layer มีความเหมาะสมในการฝึกสอนโมเดลที่มากกว่า

ตารางที่ 4.3 ผลการทดลองสร้างโมเดลแบบ 5 Layer

Layer	Batch	โมเดล	MAPE	เวลาในการประมวลผล (วินาที)
5	4	BILSTM	3.40	30.65
5	4	BIGRU	3.04	30.24
5	16	BILSTM	3.91	27.44
5	16	BIGRU	2.87	28.28
5	64	BILSTM	3.68	27.47
5	64	BIGRU	3.09	29.02

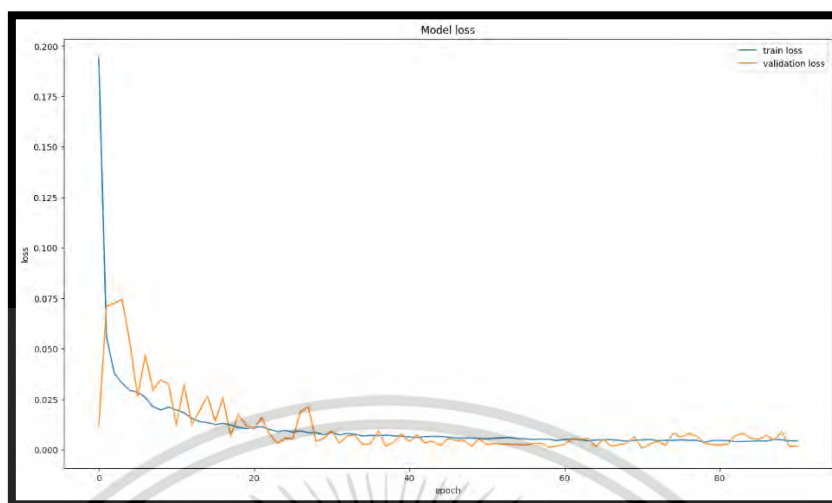
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดลองในตารางที่ 4.3 พบว่าผลการวัดประสิทธิภาพแตกต่างกันไปจากโมเดลแบบ 1 Layer จากเดิม BILSTM ฝึกสอนได้ดีที่ 16 Batch กลับทำได้ดีเมื่อเป็น 4 Batch และ BIGRU จากเดิมทำได้ดีใน 4 Batch กลับทำได้ดีเมื่อเป็น 16 Batch แทน ส่วนเวลาในการประมวลผลมีทิศทางเพิ่มขึ้นตามจำนวน Batch เมื่อพิจารณาเฉพาะในการประมวลผลแบบ 16 Batch และ 64 Batch ส่วนในการประมวลผลแบบ 4 Batch ใช้เวลาในการประมวลผลสูงที่สุดเมื่อเปรียบเทียบกับจำนวน Layer ที่เท่ากัน โดยสาเหตุเกิดจากจำนวน Epoch เฉลี่ยที่ใช้ในการประมวลผลสูงกว่าปกติ

ต่อมาหากเปรียบเทียบประสิทธิภาพระหว่าง BILSTM และ BIGRU พบว่าในโมเดลแบบ 5 Layer ผลที่ได้แตกต่างกันไปจาก 1 Layer อย่างชัดเจน จากเดิมที่ BILSTM มีประสิทธิภาพเหนือ BIGRU ในทุก Batch กลับกลายเป็น BIGRU มีประสิทธิภาพมากกว่า BILSTM เช่นเดียวกัน ในขณะที่เดียวกันระยะเวลาที่ใช้ในการประมวลผลกลับต่ำกว่า BIGRU ในการทดสอบ 16 Batch และ 64 Batch ซึ่งจากการสังเกตพบว่า BILSTM ทำการ Optimize ได้ไวกว่า BIGRU ทำให้มีค่า Epoch ที่ต่ำส่งผลให้เวลาที่ใช้ในการประมวลผลต่ำไปด้วย ในขณะที่ BIGRU ใช้จำนวน Epoch ที่มากกว่าส่งผลให้เวลาที่ใช้ในการประมวลผลสูงตามไปด้วยเช่นเดียวกัน แต่อย่างไรก็ตามหากทั้ง BILSTM และ BIGRU ใช้จำนวน Epoch ที่เท่ากัน BIGRU จะใช้เวลาในการประมวลผลน้อยกว่า BILSTM สุดท้ายในเรื่องของประสิทธิภาพนั้นในการสร้างโมเดลแบบ 5 Layer โมเดล BIGRU มีประสิทธิภาพสูงกว่า BILSTM ในทุก Batch Size

ต่อมาเมื่อเปรียบเทียบระหว่างโมเดลแบบ 1 Layer และ 5 Layer แล้วพบว่าการสร้างโมเดล 5 Layer มีประสิทธิภาพเพิ่มขึ้นอย่างเห็นได้ชัด จากตารางที่ 4.2 โดยโมเดล BILSTM มีค่า MAPE อยู่ในช่วงประมาณ 3.79 ถึง 4.17 และ BIGRU มีค่า MAPE อยู่ในช่วงประมาณ 8.44 ถึง 8.80 แตกต่างกับข้อมูลในตารางที่ 4.3 ที่ BILSTM จะมีค่าอยู่ในช่วงประมาณ 3.40 ถึง 3.91 และ BIGRU มีค่า MAPE อยู่ในช่วงประมาณ 2.87 ถึง 3.91 แต่อย่างไรก็ตามประสิทธิภาพที่เพิ่มขึ้นก็ทำให้เวลาที่ใช้ในการสร้างโมเดลเพิ่มขึ้นเช่นกัน โดยในตารางที่ 4.2 ระยะเวลาในการสร้างโมเดลอยู่ในช่วง 24 ถึง 26 วินาที ส่วนในตารางที่ 4.3 จะมีค่าอยู่ในช่วง 27 ถึง 30 วินาที

4.5.3 BILSTM และ BIGRU โดยกำหนดให้ จำนวน Layer เท่ากับ 10



รูปที่ 4.12 ค่า Loss จาก BILSTM model แบบ 10 Layer

จากรูปที่ 4.12 พบว่าโมเดลแบบ 10 Layer มีลักษณะใกล้เคียงกับโมเดลแบบ 5 Layer เมื่อจำนวน Epoch เพิ่มขึ้นค่า Train Loss และ Validation Loss มีแนวโน้มที่ใกล้เคียงกันมากขึ้นเรื่อยๆ แต่แตกต่างกันที่ค่า Loss ต่ำกว่าโมเดลแบบ 5 Layer และใช้ Epoch ในการฝึกสอนที่สูงกว่า เมื่อดูลักษณะของเส้นจะเห็นได้ว่าหลังจาก Epoch ที่ 25 เป็นต้นไปค่า Train Loss และ Validation Loss มีค่าใกล้เคียงกันอย่างมากและมีความเสถียรที่มากขึ้น

ตารางที่ 4.4 ผลการทดลองสร้างโมเดลแบบ 10 Layer

Layer	Batch	โมเดล	MAPE	เวลาในการประมวลผล (วินาที)
10	4	BILSTM	2.15	55.36
10	4	BIGRU	2.11	60.69
10*	4*	BIGRU*	2.27	67.15
10	16	BILSTM	3.08	44.75
10	16	BIGRU	2.81	45.17
10	64	BILSTM	3.08	45.94
10	64	BIGRU	2.68	49.79

หมายเหตุ * หมายถึง โมเดลที่ทำการตัดปัจจัยที่มีความสำคัญต่ำกว่า 5% ได้แก่ปัจจัย T2M_Avg, RH2M_Avg, WS2M_Avg และ RD_Avg, ออกจากการฝึกสอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากผลการทดลองในตารางที่ 4.4 พบว่าโมเดล BILSTM และ BIGRU มีผลการวัดประสิทธิภาพที่ดีที่สุดเมื่อใช้ BIGRU 4 Batch ในการสร้างโมเดลและเป็นค่าที่ดีที่สุดเมื่อเปรียบเทียบกับผลการทดลองที่ผ่านมา ส่วนเวลาในการประมวลผลนั้นมีลักษณะเหมือนกับการสร้างโมเดลแบบ 5 Layer คือใน 16 Batch และ 64 Batch เวลาในการประมวลผลจะเพิ่มขึ้นตามจำนวน Batch ที่เพิ่มขึ้นและใช้เวลาในการประมวลผลมากที่สุดโมเดลแบบ 4 Batch นอกจากนี้เมื่อทำการเปรียบเทียบโมเดล 10 Layer 4 Batch ที่ให้ค่า MAPE ต่ำที่สุดระหว่างใช้ทุกปัจจัย กับ ตัดปัจจัยที่มีความสำคัญต่ำกว่า 5% ออกจากการฝึกสอน ผลปรากฏว่าโมเดลที่ทำการตัดปัจจัยนั้นให้ค่า MAPE ที่สูงขึ้นและใช้เวลาในการประมวลผลที่เพิ่มขึ้นเป็นไปในทิศทางเดียวกัน

ต่อมาเมื่อเปรียบเทียบกับโมเดลแบบ 5 Layer พบว่าโมเดลแบบ 10 Layer เป็นโมเดลที่มีประสิทธิภาพเพิ่มขึ้นจาก 5 Layer อย่างชัดเจน ค่า MAPE ลงในทุก Batch แต่ก็ใช้เวลาในการประมวลผลมากขึ้นด้วยเช่นเดียวกัน

4.6 การทดสอบประสิทธิภาพของโมเดลพยากรณ์ที่มีการกำหนดค่าพารามิเตอร์แตกต่างด้วย One-way ANOVA ด้วย One-way ANOVA

หลังจากทำการสร้างโมเดลตามเงื่อนไขที่กำหนดไว้ครบเรียบร้อยแล้วขั้นตอนต่อไปจะเป็นการทดสอบเปรียบเทียบประสิทธิภาพของโมเดลพยากรณ์ที่มีการกำหนดค่าพารามิเตอร์แตกต่างกัน ได้แก่ จำนวน Layer และ Batch Size ด้วยวิธี BILSTM และ BIGRU ตามลำดับ โดยถ้าผลการทดสอบทางสถิติพบว่ามีค่าเฉลี่ย MAPE ของโมเดลอย่างน้อย 1 โมเดลที่แตกต่างกัน แสดงว่าการกำหนดค่าพารามิเตอร์ต่างกันทำให้ประสิทธิภาพของโมเดลพยากรณ์ต่างกัน ดังนั้นควรกำหนดค่าพารามิเตอร์ของโมเดลพยากรณ์ตามค่าดังกล่าว แต่ถ้าหากผลการทดสอบทางสถิติพบว่ามีค่าเฉลี่ย MAPE ของทุก ๆ โมเดลไม่มีความแตกต่างกัน อาจกล่าวได้ว่าการกำหนดค่าพารามิเตอร์ของโมเดลไม่มีผลต่อประสิทธิภาพของโมเดลที่ได้

เริ่มต้นจากการทดสอบ One-way ANOVA เพื่อพิจารณาความแตกต่างของการกำหนดค่าจำนวน Layer ได้แก่ 1 Layer, 5 Layer และ 10 Layer โดยแสดงผลตามรูปที่ 4.13 และมีสมมติฐานทางสถิติ ดังนี้

$$H_0 : \mu_1 = \mu_5 = \mu_{10}$$

$$H_a : \text{มีค่าเฉลี่ยอย่างน้อย 1 คู่มีค่าแตกต่างกัน}$$

เมื่อ	μ_1	แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 1 Layer
	μ_5	แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 5 Layer
	μ_{10}	แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 10 Layer

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway Anova BILSTM.csv'
data=pd.read_csv(uri)

f_oneway(data.OneLayer,data.FiveLayer,data.TenLayer) #BILSTM
F_onewayResult(statistic=46.17656507643088, pvalue=8.172185900725129e-20)

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway Anova BIGRU.csv'
data=pd.read_csv(uri)

f_oneway(data.OneLayer,data.FiveLayer,data.TenLayer) #BIGRU
F_onewayResult(statistic=150.9273887456744, pvalue=3.1666519903196827e-57)
    
```

รูปที่ 4.13 การทดสอบ One-way ANOVA ความแตกต่างของการกำหนดค่า Layer

จากผลการทดสอบทางสถิติ ณ ระดับความเชื่อมั่นที่ 95% พบว่ามีการกำหนดค่าพารามิเตอร์อย่างน้อย 1 แบบที่มีค่าเฉลี่ย MAPE แตกต่างกันทั้งจากโมเดล BILSTM และ BIGRU สรุปได้ว่าการกำหนดค่า Layer มีผลทำให้ผลลัพธ์แตกต่างกัน ต่อจากนั้นจึงทำการทดสอบด้วย Tukey HSD Test ณ ระดับความเชื่อมั่นที่ 95% เพื่อทดสอบความแตกต่างโดยการเรียงลำดับการทดสอบความแตกต่างไปที่ละคู่จนครบทุกคู่ได้ผลลัพธ์ตามรูปที่ 4.14 และ 4.15

Multiple Comparison of Means - Tukey HSD, FWER=0.05						
group1	group2	meandiff	p-adj	lower	upper	reject
1	5	-0.3189	0.0436	-0.6307	-0.0071	True
1	10	-1.2297	0.0	-1.5414	-0.9179	True
5	10	-0.9108	0.0	-1.2225	-0.599	True

[1 5 10]

รูปที่ 4.14 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Layer ในโมเดล BILSTM

Multiple Comparison of Means - Tukey HSD, FWER=0.05						
group1	group2	meandiff	p-adj	lower	upper	reject
1	5	-2.2782	0.0	-2.6756	-1.8809	True
1	10	-2.7494	0.0	-3.1468	-2.352	True
5	10	-0.4712	0.0151	-0.8685	-0.0738	True

[1 5 10]

รูปที่ 4.15 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Layer ในโมเดล BIGRU

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 4.15 พบว่าการกำหนดค่า Layer ของทั้งโมเดล BILSTM และ BIGRU ให้ผลการปฏิบัติสมมติฐานว่าง ในทุกการทดสอบ จึงสามารถสรุปได้ว่าค่าเฉลี่ยของ MAPE ของโมเดลที่มีการกำหนดค่า Layer ต่างกันจะมีความแตกต่างกันด้วย

ต่อไปเป็นการทดสอบความแตกต่างของการกำหนดค่า Batch size ได้แก่ 4 Batch, 16 Batch, 64 Batch โดยกำหนดให้จำนวน Layer เท่ากัน ซึ่งแสดงผลตามรูปที่ 4.16 และ 4.17 มีสมมติฐานทางสถิติ ดังนี้

$$H_0 : \mu_4 = \mu_{16} = \mu_{64}$$

H_a : มีค่าเฉลี่ยอย่างน้อย 1 คู่มีค่าแตกต่างกัน

เมื่อ

μ_4 แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 4 Batch

μ_{16} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 16 Batch

μ_{64} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 64 Batch

```
uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway ANOVA BILSTM 1 Layer.csv'
data=pd.read_csv(uri)

f_oneway(data.aBatch ,data.bBatch ,data.cBatch) #BILSTM 1 Layer
F_onewayResult(statistic=1.4947455735558752, pvalue=0.2259881079118342)

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway ANOVA BILSTM 5 Layer.csv'
data=pd.read_csv(uri)

f_oneway(data.aBatch ,data.bBatch ,data.cBatch) #BILSTM 5 Layer
F_onewayResult(statistic=2.1619067903281395, pvalue=0.11691348783242549)

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway ANOVA BILSTM 10 Layer.csv'
data=pd.read_csv(uri)

f_oneway(data.aBatch ,data.bBatch ,data.cBatch) #BILSTM 10 Layer
F_onewayResult(statistic=23.63139810077444, pvalue=2.993326407075554e-10)
```

รูปที่ 4.16 การทดสอบ One-way ANOVA ความแตกต่างของการกำหนดค่า Batch ในโมเดล BILSTM

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway ANOVA BIGRU 1 Layer.csv'
data=pd.read_csv(uri)

f_oneway(data.aBatch ,data.bBatch ,data.cBatch) #BIGRU 1 Layer
F_onewayResult(statistic=0.07789027635782311, pvalue=0.9250848127240306)

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway ANOVA BIGRU 5 Layer.csv'
data=pd.read_csv(uri)

f_oneway(data.aBatch ,data.bBatch ,data.cBatch) #BIGRU 5 Layer
F_onewayResult(statistic=0.500113981640587, pvalue=0.6069713229397006)

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway ANOVA BIGRU 10 Layer.csv'
data=pd.read_csv(uri)

f_oneway(data.aBatch ,data.bBatch ,data.cBatch) #BIGRU 10 Layer
F_onewayResult(statistic=12.166793070435128, pvalue=8.343509707298434e-06)
    
```

รูปที่ 4.17 การทดสอบ One-way ANOVA ความแตกต่างของการกำหนดค่า Batch ในโมเดล BIGRU

จากผลการทดสอบทางสถิติ ณ ระดับความเชื่อมั่นที่ 95% พบว่าโมเดล BILSTM และ BIGRU ที่มีการกำหนด 1 Layer และ 5 Layer และ ค่าทุก Batch size ไม่ทำให้ค่าเฉลี่ย MAPE แตกต่างกันในขณะทำการตั้งค่าแบบ 10 Layer มีอย่างน้อย 1 Batch Size ที่ทำให้ค่า MAPE แตกต่างกัน ต่อจากนั้นจึงทำการทดสอบทางสถิติด้วย Tukey HSD Test ณ ระดับความเชื่อมั่นที่ 95% เพื่อทดสอบความแตกต่างโดยการเรียงลำดับการทดสอบความแตกต่างไปที่ละคู่จนครบทุกคู่ได้ผลลัพธ์ตามรูปที่ 4.18 และ 4.19

Multiple Comparison of Means - Tukey HSD, FWER=0.05						
group1	group2	meandiff	p-adj	lower	upper	reject
4	16	0.8755	0.0	0.5175	1.2335	True
4	64	0.9314	0.0	0.5735	1.2894	True
16	64	0.0559	0.9281	-0.302	0.4139	False

[4 16 64]

รูปที่ 4.18 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Batch ในโมเดล BILSTM

Multiple Comparison of Means - Tukey HSD, FWER=0.05						
group1	group2	meandiff	p-adj	lower	upper	reject
4	16	0.7046	0.0	0.3473	1.062	True
4	64	0.5707	0.0006	0.2133	0.928	True
16	64	-0.134	0.6515	-0.4913	0.2234	False

[4 16 64]

รูปที่ 4.19 การทดสอบ Tukey HSD Test ความแตกต่างของการกำหนดค่า Batch ในโมเดล BIGRU

จากรูปที่ 4.19 พบว่าประสิทธิภาพของโมเดลพยากรณ์ด้วยวิธี BILSTM และ BIGRU ที่มีการกำหนดค่า Batch ต่าง ๆ จะมีความแตกต่างกัน ดังจะเห็นว่ามีค่าแตกต่างกันระหว่างโมเดลที่มีการกำหนดค่า Batch เท่ากับ 4 Batch กับ 16 Batch และ 4 Batch กับ 64 Batch ในขณะที่ค่าเฉลี่ย MAPE ของโมเดลที่มีการกำหนดค่า Batch เท่ากับ 16 Batch และ 64 Batch ไม่มีความแตกต่างกัน

4.7 การทดสอบประสิทธิภาพของโมเดลพยากรณ์ที่ไม่มี/มีการตัดตัวแปรความสำคัญต่ำกว่า 5% ด้วย T-Test

การทดสอบเพื่อเปรียบเทียบค่าเฉลี่ย MAPE ระหว่างโมเดลพยากรณ์ที่มีการปรับแต่งค่าพารามิเตอร์ซึ่งให้ค่า MAPE ต่ำที่สุด หรือก็คือโมเดล BIGRU ที่มีการกำหนดค่า 10 Layer 4 Batch ที่พิจารณาทุกปัจจัยกับโมเดลพยากรณ์ที่มีมีการปรับแต่งค่าพารามิเตอร์ในลักษณะเดียวกันแต่ตัดตัวแปรที่มีความสำคัญต่ำกว่า 5% ออกจากการฝึกสอน แสดงผลตามรูปที่ 4.20 และมีสมมติฐานทางสถิติ ดังนี้

$$H_0 : \mu_{normal} = \mu_{adjust}$$

$$H_a : \mu_{normal} \neq \mu_{adjust}$$

เมื่อ μ_{normal} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 10 Layer 4 Batch
 μ_{adjust} แทนค่าเฉลี่ยของ MAPE ของโมเดลแบบ 10 Layer 4 Batch แต่ทำการตัดโมเดลที่มีความสำคัญต่ำกว่า 5% ออกจากการฝึกสอน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/T-Test.csv'
data=pd.read_csv(uri)

a=np.array(data.Normal)
b=np.array(data.Adjust)

stats.ttest_ind(a,b)

TtestResult(statistic=0.6268105577294911, pvalue=0.5315054717712364, df=198.0)

```

รูปที่ 4.20 การเปรียบเทียบค่าเฉลี่ย MAPE ของโมเดลพยากรณ์ที่ไม่มี/มีการตัดตัวแปรความสำคัญต่ำกว่า 5%

จากผลการทดสอบทางสถิติ ณ ระดับความเชื่อมั่นที่ 95% พบว่าโมเดลพยากรณ์ที่มีการตัดตัวแปรที่มีความสำคัญต่ำกว่า 5% ออกจากการฝึกสอน พบว่าค่าเฉลี่ย MAPE ไม่มีความแตกต่างกันหรือสรุปได้ว่าค่า MAPE ไม่มีความแตกต่างกัน ถึงแม้ว่าจะมีการเพิ่มตัวแปรที่มีความสำคัญต่ำเข้าไปในการฝึกสอนก็ตาม

4.8 อภิปรายผล

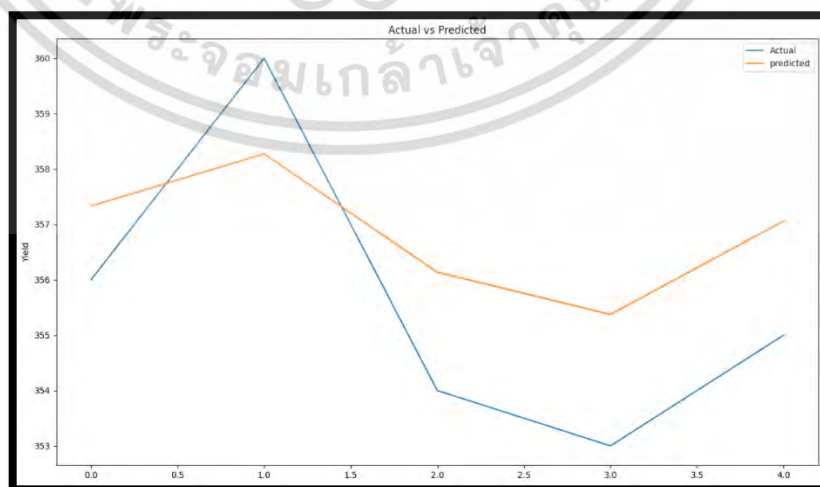
ผลการศึกษาปัจจัยที่มีผลต่อผลผลิตต่อไร่ของข้าวหอมมะลิพบว่าทุกปัจจัยมีความสำคัญต่อผลผลิตต่อไร่ของข้าวหอมมะลิทั้งหมด ได้แก่ปัจจัย เนื้อที่เก็บเกี่ยว สัดส่วนการปลูกนาดำ ปริมาณการใช้เมล็ดพันธุ์ต่อไร่ ปริมาณการใส่ปุ๋ยเคมีต่อไร่ อุณหภูมิ แร่ลงม จำนวนวันฝนตก ความชื้นในอากาศ และสัดส่วนการเพาะปลูกในเดือนพฤษภาคม สอดคล้องกับงานวิจัยต่าง ๆ ที่ผู้วิจัยใช้ในการอ้างอิงเพื่อนำปัจจัยมาฝึกสอนโมเดลในงานวิจัยฉบับนี้ (Cetiner & Burhan ,2022; Banua & Geethab, 2021; Kongtanajaruanunand & Cheamuangphan, 2018; Kumboonreang, 2011; Suwnnasaen, 2020; Chu & Yu, 2020) แต่อย่างไรก็ตามกลุ่มของปัจจัยสภาพอากาศกลับมีความสำคัญต่อผลผลิตต่อไร่ของข้าวหอมมะลิ อยู่ในระดับที่ต่ำกว่า 5% ทั้งหมด แตกต่างไปจากสมมติฐานที่ว่าข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือ ต้องพึ่งพาน้ำฝนและสภาพอากาศเป็นปัจจัยหลักในการเพาะปลูกทำให้ผลผลิตต่อไร่มากหรือน้อยในแต่ละปีนั้นขึ้นอยู่กับสภาพอากาศที่เกิดขึ้น ตามความคิดเห็นของผู้วิจัยสาเหตุที่เป็นเช่นนี้อาจเนื่องมาจากเกษตรกรทำการปรับเปลี่ยนพฤติกรรมการเพาะปลูกไปตามสภาพอากาศที่เกิดขึ้นในแต่ละปี เช่น การเปลี่ยนพฤติกรรมการเพาะปลูกจากนาดำเป็นนาหว่านเมื่อฝนตกสามารถทำนาได้ทันทีไม่จำเป็นต้องเพาะต้นกล้าเป็นเวลานาน การใช้เครื่องสูบน้ำจากคลองชลประทานแทนการพึ่งพาน้ำฝนเพียงอย่างเดียว การส่งเสริมความรู้การทำนาเปียกสลับแห้งทำให้ปริมาณการใช้น้ำต่อไร่ลดลง จึงทำให้พฤติกรรมการเพาะปลูกของเกษตรกรมีความสำคัญ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.5 โมเดลที่มีประสิทธิภาพสูงสุดจากการทดลองแต่ละ Layer

Layer	Batch	โมเดล	MAPE	เวลาในการประมวลผล (วินาที)
1	16	BILSTM	3.79	25.85
1	4	BIGRU	8.44	24.94
5	4	BILSTM	3.40	30.65
5	16	BIGRU	2.87	28.28
10	4	BILSTM	2.15	55.36
10	4	BIGRU	2.11	60.69

ต่อมาเมื่อเปรียบเทียบประสิทธิภาพของโมเดลที่ดีที่สุดเพียงอย่างเดียวงานวิจัยฉบับนี้ได้ค่า MAPE ที่ต่ำกว่างานวิจัยของ Cetiner & Burhan (2022) แต่เมื่อพิจารณาในรายละเอียดพบว่าผลลัพธ์ของการสร้างโมเดลผลที่ออกมาแตกต่างจากงานวิจัยที่ใช้อ้างอิงในตั้งค่าโมเดลที่ใช้ในการฝึกสอน โดยพบว่าโมเดลแบบ LSTM จะมีค่า MAPE ต่ำกว่าโมเดลแบบ GRU แต่โมเดล GRU จะใช้เวลาในการประมวลผลน้อยกว่าโมเดลแบบ LSTM เช่นเดียวกัน ซึ่งผลลัพธ์ที่ดีที่สุดของงานวิจัยฉบับนั้นเป็นการตั้งค่าที่ LSTM 10 Layer ในขณะที่งานวิจัยฉบับนี้ผลลัพธ์ที่ได้จากตารางที่ 4.5 คือ BILSTM จะมีประสิทธิภาพสูงกว่า BIGRU เมื่อเป็นการฝึกสอนโมเดลแบบ 4 Layer เท่านั้น ส่วนในการฝึกสอนแบบ 5 และ 10 Layer BIGRU จะทำงานได้ดีกว่า BILSTM เมื่อพิจารณาถึงเวลาที่ใช้ในการฝึกสอน BILSTM กลับใช้เวลาน้อยกว่า BIGRU และโมเดลที่มีประสิทธิภาพสูงสุดของงานวิจัยฉบับนี้คือ BIGRU 10 Layer ซึ่งได้แสดงผลการพยากรณ์ไว้ในรูปที่ 4.21 เปรียบเทียบระหว่างค่าจริงใน Test Set โมเดลแบบ BIGRU 10 Layer 4 Batch ให้ผลการพยากรณ์ที่ดีที่สุดเส้นมีการขึ้นลงเป็นทิศทางเดียวกันกับค่าจริงใน Test Set



รูปที่ 4.21 ประสิทธิภาพการพยากรณ์จากโมเดล BIGRU

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากความแตกต่างที่กล่าวมาผลลัพธ์ที่ได้เป็นไปในทิศทางตรงกันข้ามกับงานวิจัยที่อ้างอิงเกือบทั้งหมด โดยเฉพาะในเรื่องของเวลาที่ใช้ในการฝึกสอนซึ่งตามความคิดเห็นของผู้วิจัยผลลัพธ์ที่ได้มีสาเหตุมาจากการที่ผู้วิจัยกำหนดเงื่อนไขในการหยุดทำงานเมื่อค่า Value Loss เข้าใกล้ 0 และไม่ลดลงเกิน 10 Epoch ทำให้การใช้ Epoch ของ BILSTM และ BIGRU ในแต่ละรอบไม่เท่ากัน BILSTM ใช้จำนวน Epoch โดยเฉลี่ยที่ต่ำกว่า BIGRU ส่งผลให้ผลลัพธ์ที่ออกมา BILSTM ใช้เวลาในการประมวลผลต่ำกว่าตามไปด้วย แต่อย่างไรก็ตามจากการทดสอบหากจำนวน Epoch ที่เท่ากัน BIGRU จะใช้เวลาในการประมวลผลต่ำกว่า BILSTM

สุดท้ายเรื่องของ การทดสอบ One-way ANOVA และ T-Test พบว่าสำหรับการสร้างโมเดลที่มีการกำหนด 1 Layer และ 5 Layer นั้น การกำหนดค่า Batch size ไม่ให้ผลลัพธ์ที่แตกต่างกัน และเริ่มมีความแตกต่างกันเมื่อทำการทดสอบกับโมเดลที่มีการกำหนด 10 Layer แต่เมื่อทดสอบด้วย Tukey HSD Test กลับพบว่าความแตกต่างนั้นเกิดขึ้นเฉพาะโมเดลแบบ 4 Batch เปรียบเทียบกับ 16, 64 Batch เท่านั้น ซึ่งแตกต่างไปจากสมมติฐานที่วางไว้ว่าการตั้งค่าแต่ละ Batch size ควรให้ผลลัพธ์ที่แตกต่างกัน นอกจากการทดสอบดังกล่าวผู้วิจัยได้ทำการเปรียบเทียบความแตกต่างของค่า MAPE ระหว่างโมเดลที่ใช้ทุกปัจจัยในการสร้างโมเดลกับโมเดลที่ตัดปัจจัยที่มีความสำคัญต่ำกว่า 5% ด้วยวิธี T-Test ณ ระดับความสำคัญที่ 95% ผลปรากฏว่าทั้ง 2 โมเดลกลับให้ผลลัพธ์ที่ไม่แตกต่างกัน ดังนั้นการพัฒนาโมเดลต่อไปในอนาคตการตัดปัจจัยด้านสภาพอากาศจากการฝึกสอนโมเดลจะช่วยลดความยุ่งยากในการเตรียมข้อมูล เช่น แหล่งที่มาของข้อมูลจะถูกลดเหลือเพียงแหล่งเดียว การระบุจุดพิกัดที่ใช้เป็นตัวแทนของพื้นที่ การพึ่งพาแหล่งข้อมูลจากภายนอกประเทศ และลดระยะเวลาในการเตรียมข้อมูล

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

การศึกษาการใช้เทคนิคโครงข่ายประสาทเทียมเชิงลึกเพื่อพยากรณ์ผลผลิตต่อไร่ข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือ มีวัตถุประสงค์เพื่อศึกษาและคัดเลือกปัจจัยที่มีอิทธิพลต่อผลผลิตต่อไร่ของข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือด้วยวิธีการถดถอยแบบป่าสุ่ม ระหว่างปี 2537 ถึงปี 2563 โดยมีตัวแปรอิสระทั้งหมด 9 ปัจจัย หลังจากนั้นนำปัจจัยที่ได้ไปสร้างตัวแบบพยากรณ์ BILSTM และ BIGRU เพื่อเปรียบเทียบประสิทธิภาพระหว่าง 2 โมเดล ได้ผลสรุปเพื่อตอบวัตถุประสงค์ดังนี้

5.1.1 วัตถุประสงค์ข้อที่ 1

ความสำคัญของปัจจัยที่มีอิทธิพลต่อผลผลิตต่อไร่ของข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือด้วยวิธีการถดถอยแบบป่าสุ่มพบว่าทั้ง 9 ปัจจัย มีความสำคัญต่อผลผลิตต่อไร่ โดยเรียงลำดับปัจจัยที่มีความสำคัญจากมากไปน้อยได้ดังนี้ ปริมาณเมล็ดพันธุ์ต่อไร่ การเพาะปลูกในเดือนพฤษภาคม เนื้อที่เก็บเกี่ยว ปริมาณปุ๋ยเคมีต่อไร่ จำนวนวันฝนตก ความชื้นในอากาศ แรงแลม และอุณหภูมิ ตามลำดับ

5.1.2 วัตถุประสงค์ข้อที่ 2

การทดสอบ One-way ANOVA ทั้งโมเดล BILSTM และ BIGRU ผลลัพธ์ที่ได้คือ การกำหนดจำนวน Layer ได้แก่ 1 Layer และ 5 Layer นั้น Batch size ไม่ทำให้ค่าเฉลี่ย MAPE มีความแตกต่างกัน ส่วนถ้าการกำหนดค่าโมเดลที่มี 10 Layer การกำหนดค่า Batch size มีผลให้ค่าเฉลี่ย MAPE อย่างน้อย 1 ตัวมีความแตกต่างกัน ผู้วิจัยจึงทำการทดสอบ Tukey HSD Test ในการกำหนด Batch Size ของโมเดลที่มี 10 Layer พบว่าสำหรับการกำหนดค่า 4 Batch ค่าเฉลี่ย MAPE มีความแตกต่างจากการกำหนดค่า 16 Batch และ 64 Batch ส่วนการกำหนดค่า 16 Batch กับ 64 Batch ไม่มีความแตกต่างกัน

เมื่อพิจารณาประสิทธิภาพของโมเดล BILSTM และ BIGRU มีค่าสูงสุดเมื่อตั้งค่าแบบ 10 Layer 4 Batch มีค่าอยู่ที่ 2.15 และ 2.11 ตามลำดับ ส่วนเวลาในการฝึกสอนมีค่าอยู่ที่ 55.36 และ 60.69 วินาที ตามลำดับ จากการเปรียบเทียบประสิทธิภาพ โมเดล BIGRU มีประสิทธิภาพที่สูงกว่า BILSTM ส่วนเวลาที่ใช้ในการประมวลผลนั้นใช้เวลามากกว่า BILSTM เพียง 5.33 วินาที หรือ 9.62% ดังนั้นการใช้ BIGRU ในการพยากรณ์ผลผลิตต่อไร่ของข้าวหอมมะลิในภาคตะวันออกเฉียงเหนือ จึงมีความเหมาะสมมากกว่า BILSTM ถึงแม้ค่า MAPE จะแตกต่างกันเพียงเล็กน้อย แต่เนื่องจากค่าที่ได้จะต้องนำไปใช้วางแผนการผลิตและจัดจำหน่ายข้าวหอมมะลิ ทำให้ตัวเลขที่ได้เกี่ยวข้องกับทั้งภาครัฐและเอกชน ส่งผลให้ผลกระทบสูงหากพยากรณ์ผิดพลาด

หลังจากได้โมเดลที่ดีที่สุดคือ BIGRU 10 Layer 4 Batch ผู้วิจัยจึงใช้การตั้งค่าดังกล่าวในการฝึกสอน เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โมเดลที่ทำการตัดปัจจัยที่มีความสำคัญต่อออกจากการฝึกสอนและทำการเปรียบเทียบความแตกต่างของค่าเฉลี่ย MAPE ด้วย T-Test ผลปรากฏว่าไม่มีความแตกต่างกัน การตัดตัวแปรที่มีความสำคัญต่อออกจากการฝึกสอนจะทำให้การเตรียมข้อมูลทำได้รวดเร็ว ลดความซับซ้อน และสะดวกในการนำมาประยุกต์ใช้

5.2 ข้อจำกัด

ในส่วนข้อจำกัดในงานวิจัยฉบับนี้ มีข้อจำกัดที่เกี่ยวข้องหลากหลายประเด็นทั้งในประเด็นของงบประมาณและช่วงเวลาในการจัดทำที่มีไม่เพียงพอ ทำให้ไม่สามารถทำโมเดลพยากรณ์ข้าวทุกสายพันธุ์ในทุกภาคของประเทศได้ ผู้วิจัยจึงเลือกเฉพาะข้าวสายพันธุ์หอมมะลิในบริเวณภาคตะวันออกเฉียงเหนือ ซึ่งเป็นสายพันธุ์และแหล่งผลิตที่มีชื่อเสียงเป็นที่ยอมรับในระดับโลก มีมูลค่าการส่งออกในแต่ละปีสูงต่อเนื่องยาวนาน มาใช้ศึกษาในงานวิจัยฉบับนี้แทน เป็นผลทำให้งานวิจัยฉบับนี้ยังขาดการนำข้อมูลข้าวหอมมะลิในบริเวณภาคเหนือซึ่งเป็นอีกแหล่งหนึ่งที่สำคัญในการผลิตข้าวหอมมะลิของประเทศไทยมาพิจารณา ประเด็นต่อมาคือเรื่องของจำนวนตัวอย่างที่ใช้ในการทำงานวิจัย เนื่องจากประเทศไทยเริ่มทำการเก็บข้อมูลสถิติของข้าวเป็นปีแรกในปี 2524 ก่อนที่จะมีข้อมูลรายละเอียดเพิ่มเติมในช่วงปี 2531 และเริ่มจัดทำข้อมูลร่วมกับหน่วยงานอื่นที่เกี่ยวข้องในช่วงปี 2537 ทำให้หากต้องการอ้างอิงข้อมูลที่มีความน่าเชื่อถือและมีข้อมูลรายละเอียดที่มากพอจะมีข้อมูลย้อนหลังประมาณ 30 ปี ซึ่งถือว่าไม่น้อยเกินไปหากเปรียบเทียบกับประเทศอื่น แต่อย่างไรก็ตามด้วยข้อจำกัดของพันธุ์ข้าวหอมมะลิที่เป็นพันธุ์ข้าวไวแสงสามารถเพาะปลูกได้ปีละ 1 รอบ ทำให้ปริมาณตัวอย่างเท่ากับจำนวนปีอย่างหลีกเลี่ยงไม่ได้ แตกต่างจากพันธุ์ข้าวกลุ่มไม่ไวแสงการเติบโตของข้าวขึ้นอยู่กับจำนวนวันที่ทำการเพาะปลูกทำให้ในแต่ละปีสามารถเพาะปลูกได้หลายรอบ ซึ่งทำให้จำนวนตัวอย่างมากขึ้นตามไปด้วยอย่างชัดเจน ข้อจำกัดต่อมาคือเรื่องของภาพถ่ายดาวเทียมมาใช้ควบคู่กับข้อมูลทางสถิติ เนื่องด้วยการพยากรณ์ผลผลิตของสินค้าเกษตรมีงานวิจัยออกมาเป็นจำนวนมากทั้งงานวิจัยที่ใช้ข้อมูลทางภาพถ่ายดาวเทียม ข้อมูลสถิติ หรือในบางงานวิจัยใช้ทั้งข้อมูลทางสถิติร่วมกับภาพถ่ายดาวเทียม แต่การนำข้อมูลภาพถ่ายดาวเทียมมาใช้ในปัจจุบันจำเป็นต้องใช้ผู้เชี่ยวชาญด้านภาพถ่ายดาวเทียมโดยเฉพาะในการอ่านค่าและแปลงค่าต่าง ๆ ออกมาทำให้ยากต่อการนำมาประยุกต์ใช้ ดังนั้นหากในอนาคตสามารถลดขั้นตอนและความซับซ้อนดังกล่าวลงได้ การนำข้อมูลภาพถ่ายดาวเทียมมาใช้ควบคู่กับข้อมูลทางสถิติในประเทศไทยจะช่วยเพิ่มทางเลือกในการพยากรณ์ได้อีกทางหนึ่ง แต่อย่างไรก็ตามภายใต้งานวิจัยที่ใช้ข้อมูลทางสถิติ นั้น ก็ประกอบด้วยหลากหลายวิธีตั้งแต่ Deep Q-learning, RNN, IndRNN, MLP, LSTM, GRU, BILSTM, BIGRU ผู้วิจัยเพียงตัดสินใจเลือกวิธี BILSTM มาเปรียบเทียบกับ BIGRU โดยพิจารณาจากความเหมาะสมของข้อมูลและประสิทธิภาพจากงานวิจัยในต่างประเทศเท่านั้น เชื่อมโยงกับข้อจำกัดข้อต่อไปคืองานวิจัยที่เกี่ยวข้องกับการพยากรณ์ผลผลิตด้วย ML ในประเทศไทยมีปริมาณค่อนข้างน้อยอยู่ในช่วงกำลัง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พัฒนาไปสู่การนำไปใช้จริง จึงยากที่จะสรุปได้ว่าวิธีการใดเหมาะสมกับข้อมูลของประเทศไทยมากกว่ากัน

5.3 ข้อเสนอแนะ

จากผลการวิจัยที่ออกมาการนำงานวิจัยฉบับนี้ไปประยุกต์ใช้จริงโดยการตัดตัวแปรสภาพอากาศออกจากการฝึกสอนจะทำให้แหล่งข้อมูลเหลือเพียงแหล่งเดียวคือจากสำนักงานเศรษฐกิจการเกษตร ทำให้ง่ายต่อการนำข้อมูลมาใช้ในการฝึกสอน มีช่วงเวลาที่แน่นอนในการออกข้อมูล แต่อย่างไรก็ตามข้อมูลจากสำนักงานเศรษฐกิจการเกษตรนั้น เป็นข้อมูลการสำรวจหลังจากช่วงเวลาเก็บเกี่ยวของเกษตรกรทำให้ข้อมูลที่ออกมามีความล่าช้าประมาณ 8-9 เดือนหลังจากการเก็บเกี่ยว อาจแก้ไขโดยการพยากรณ์ล่วงหน้าเป็นเวลานานขึ้นหรือหากต้องการข้อมูลที่ใกล้เคียงปัจจุบัน ในส่วนของข้อมูลเนื้อที่เก็บเกี่ยว สามารถขอข้อมูลการขึ้นทะเบียนเบื้องต้นจากกรมส่งเสริมการเกษตร และประมาณการเนื้อที่เสียหายจากพื้นที่ภัยพิบัติเพื่อคำนวณหาเนื้อที่เก็บเกี่ยวได้ นอกจากนี้ปัจจัยการเพาะปลูกในช่วงเดือนพฤษภาคมก็สามารถใช้ข้อมูลการขึ้นทะเบียนโดยตรงได้เช่นเดียวกัน สุดท้ายส่วนของปัจจัยสัดส่วนการเพาะปลูกด้วยวิธีนาดำ ปริมาณการใช้ปุ๋ยเคมีต่อไร่ ปริมาณการใช้เมล็ดพันธุ์ การเปลี่ยนแปลงในแต่ละปีมีการเปลี่ยนแปลงค่อนข้างน้อยเบื้องต้นอาจใช้ค่าเฉลี่ยย้อนหลัง 3 ปี ในการพยากรณ์แทนการใช้ข้อมูลจริง ต่อมาในส่วนของงานวิจัยในอนาคตสามารถนำงานวิจัยฉบับนี้ไปใช้เป็นแนวทางในการศึกษาเกี่ยวกับการใช้ BILSTM และ BIGRU ในการพยากรณ์ผลผลิตข้าวหอมมะลิหรือนำไปใช้พยากรณ์ข้าวในกลุ่มสายพันธุ์อื่นที่เกี่ยวข้อง นอกจากนี้ยังสามารถนำข้อมูลภาพถ่ายดาวเทียม เช่น การอ่านค่าความสมบูรณ์ของต้นข้าว การเกิดโรคในต้นข้าว การแพร่กระจายของศัตรูพืช ปัจจัยต่าง ๆ มาพยากรณ์ผลผลิตต่อไร่ร่วมกับโมเดลในงานวิจัยฉบับนี้

เอกสารอ้างอิง

- กรมการค้าภายใน. 2022. ราคาขายส่งข้าว เดือนพฤศจิกายน 2022. [Online]. เข้าถึงได้จาก : <https://www.dit.go.th/RiceProductBag.aspx>
- กรมการข้าว กองวิจัยและพัฒนาข้าว. 2022. องค์ความรู้เรื่องข้าว เดือนพฤศจิกายน 2022. [Online]. เข้าถึงได้จาก : <https://www.ricethailand.go.th/rkb3/Varieties.htm>
- สำนักงานปลัดกระทรวงพาณิชย์. ศูนย์เทคโนโลยีสารสนเทศและการสื่อสาร. 2022. สินค้าส่งออกสำคัญของไทยตามโครงสร้างสินค้าส่งออกไปโลก เดือนพฤศจิกายน 2022. [Online]. เข้าถึงได้จาก : <https://tradereport.moc.go.th/Report/Default.aspx?Report=MenucomRecodeandImExType=1andLang=Th>
- สำนักงานเศรษฐกิจการเกษตร. 2022. ตารางแสดงรายละเอียดข้าวนาปี เดือนพฤศจิกายน 2022. [Online]. เข้าถึงได้จาก : <https://www.oae.go.th/view/1/ตารางแสดงรายละเอียดข้าวนาปี/TH-TH>
- Banua, E., & Geethab, A. 2021. Rice crop yield prediction using random forest and deep neural network-An integrated approach. <https://doi.org/http://dx.doi.org/10.2139/ssrn.3852547>
- Çetiner, H., & Burhan, K. 2022. Recurrent neural network based model development for wheat yield forecasting. *Adiyaman Üniversitesi Mühendislik Bilimleri Dergisi*, 9(16), 204-218.
- Chu, Z., & Yu, J. 2020. An end-to-end model for rice yield prediction using deep learning fusion. *Computers and Electronics in Agriculture*, 174, 105471.
- Chung, J., Gulcehre, C., Cho, K., & Bengio, Y. (2014). Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv preprint arXiv:1412.3555.
- Elavarasan, D., & Vincent, P. M. D. 2020. Crop Yield Prediction Using Deep Reinforcement Learning Model for Sustainable Agrarian Applications. *IEEE Access*, 8, 86886-86901. <https://doi.org/10.1109/access.2020.2992480>
- Gianluca Malato. 2021. **Feature selection with Random Forest**. [Online]. เข้าถึงได้จาก : <https://www.yourdatateacher.com/2021/10/11/feature-selection-with-random-forest/>
- Hochreiter, S., & Schmidhuber, J. 1997. Long short-term memory. *Neural computation*, 9(8), 1735-1780.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Jaimin Mungalpara. 2021. **What does it mean by Bidirectional LSTM?**. [Image].
เข้าถึงได้จาก : <https://medium.com/analytics-vidhya/what-does-it-mean-by-bidirectional-lstm-63d6838e34d9>
- Jason Brownlee. 2023. **A Gentle Introduction to k-fold Cross-Validation**. [Online].
เข้าถึงได้จาก : <https://machinelearningmastery.com/k-fold-cross-validation/>
- Kaushik Das. 2020. **HOW RECURRENT NEURAL NETWORK (RNN) WORKS**. [Image].
เข้าถึงได้จาก : <https://dataaspirant.com/how-recurrent-neural-network-rnn-works/>
- Khaki, S., Wang, L., & Archontoulis, S. V. 2019. A CNN-RNN Framework for Crop Yield Prediction. *Front Plant Sci*, 10, 1750. <https://doi.org/10.3389/fpls.2019.01750>
- Kongtanajaruanunand, R., & Cheamuangphan, A. 2018. Efficiency of Rice Production between Transplanting and Direct Seeding Method in the Upper Northern Region. *Journal of Agri. Research & Extension*, 35(3), 1-8.
- Kumboonreang, N. 2011. EFFECTS OF LIGHT DURATION ON PANICLE INITIATION AND ADVANTAGES OF OFF- SEASON GROWING KDML105 RICE USING SHORT DAY PERIOD Suranaree University of Technology].
- LeCun, Y., Bengio, Y., & Hinton, G. 2015. Deep learning. *nature*, 521(7553), 436-444.
- Lee, S., Jeong, Y., Son, S., & Lee, B. 2019. A Self-Predictable Crop Yield Platform (SCYP) Based On Crop Diseases Using Deep Learning. *Sustainability*, 11(13).
<https://doi.org/10.3390/su11133637>
- Lewis, C. D. 1982. "Industrial and business forecasting methods," London: Butterworths,
- Medsker, L. R., & Jain, L. 2001. Recurrent neural networks. *Design and Applications*, 5, 64-67.
- Michael Phi. 2018. **Illustrated Guide to LSTM's and GRU's: A step by step explanation**. [Image]. เข้าถึงได้จาก : <https://towardsdatascience.com/illustrated-guide-to-lstms-and-gru-s-a-step-by-step-explanation-44e9eb85bf21>
- Onwuchekwa-Henry, C. B., Ogtrop, F. V., Roche, R., & Tan, D. K. Y. 2022. Model for Predicting Rice Yield from Reflectance Index and Weather Variables in Lowland Rice Fields. *Agriculture*, 12(2). <https://doi.org/10.3390/agriculture12020130>
- Piyaporn Saelim. 2019. Forecasting Jasmine Rice Yield in Nakhon Ratchasima Province. *Science and Technology Research Journal Nakhon Ratchasima Rajabhat University Vol.4 No.2*

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Sandeep Kirwai. 2021. **Understand Deep Learning with a simple exercise -PyTorch.** [Image]. เข้าถึงได้จาก : <https://becominghuman.ai/understand-deep-learning-with-a-simple-exercise-pytorch-4be98cd1ca48>
- Saul Dobilas. 2022. **LSTM Recurrent Neural Networks — How to Teach a Network to Remember the Past.** [Image]. เข้าถึงได้จาก : <https://towardsdatascience.com/lstm-recurrent-neural-networks-how-to-teach-a-network-to-remember-the-past-55e54c2ff22e>
- Siarni-Namini, S., Tavakoli, N., & Namin, A. S. 2019. The performance of LSTM and BiLSTM in forecasting time series. 2019 IEEE International Conference on Big Data (Big Data)
- TechVidvan. 2023. **Artificial Neural Network – Applications, Algorithms and Examples.** [Image]. เข้าถึงได้จาก : <https://techvidvan.com/tutorials/artificial-neural-network/>
- The Power Project NASA. 2022. **Prediction Of Worldwide Energy Resource.** [Online]. เข้าถึงได้จาก : <https://power.larc.nasa.gov/>
- Vo Thanh Ha. 2023. **Experimental Study on Remaining Useful Life Prediction of Lithium-Ion Batteries Based on Three Regressions Models for Electric Vehicle Applications.** [Image]. เข้าถึงได้จาก : https://www.researchgate.net/publication/371581286_Experimental_Study_on_Remaining_Useful_Life_Prediction_of_Lithium-Ion_Batteries_Based_on_Three_Regressions_Models_for_Electric_Vehicle_Applications



ภาคผนวก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ชุดคำสั่งโปรแกรมภาษาไพธอนบน Google colab

```

#===== Import Library =====
import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
from sklearn import metrics
from sklearn.preprocessing import LabelEncoder,MinMaxScaler
from sklearn.model_selection import train_test_split
from sklearn.ensemble import RandomForestRegressor
from sklearn.feature_selection import RFECV
import tensorflow as tf
import time

#===== Import Data =====
from google.colab import drive
drive.mount('/content/drive')
uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/ DATA 19.5.67.csv'
data=pd.read_csv(uri)

#===== Data exploration =====
data.info()
data.isnull().sum()
data.describe().applymap('{:,.2f}'.format)
## Define X, Y
x = data.drop(["Yield","Year"], axis=1)
y = data["Yield"]

#===== Normalization =====
X_scaler = MinMaxScaler()
Y_scaler = MinMaxScaler()
X_data = X_scaler.fit_transform(data[['S','CF','HA',
                                     'T2M_Avg','WS2M_Avg','RH2M_Avg','RD_Avg','MP1','P1']])
Y_data = Y_scaler.fit_transform(data[['Yield']])

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#===== Feature Importance =====

##Randomforest Regressor

```
x_train, x_test, y_train, y_test = split(x, y, train_size=0.7)
rf_model = RandomForestRegressor(random_state=0 ,oob_score=True)
rf_model.fit(x_train, y_train)
importances = rf_model.feature_importances_
columns = x.columns
i = 0
```

```
while i < len(columns) :
```

```
    print(f'{columns[i]} {round(importances[i]*100, 2)}%")
```

```
    i += 1
```

```
rfe = RFECV(rf_model,cv=10,scoring="neg_mean_squared_error")
```

```
rfe.fit(x_train,y_train)
```

```
selected_features = np.array(x_train.columns)[rfe.get_support()]
```

##Heatmap Pearson Correlation

```
rice_df = data[['Yield','HA','S','CF','T2M_Avg'
```

```
                , 'RH2M_Avg','WS2M_Avg','P1','RD_Avg','MP1']]
```

```
plt.figure(figsize=(8,8))
```

```
matrix = np.triu(rice_df.corr(method='pearson'))
```

```
heat_map =
```

```
sns.heatmap(rice_df.corr(method='pearson'),annot=True,annot_kws={"size":8},cmap=
'YlGnBu',mask=matrix)
```

```
heat_map.set_yticklabels(heat_map.get_yticklabels())
```

```
heat_map.set_xticklabels(heat_map.get_xticklabels())
```

```
plt.tick_params(labelsize=12)
```

```
plt.title('Heatmap Pearson Correlation')
```

```
plt.style.use('fivethirtyeight')
```

#===== Model =====

##Data Preparation

```
def custom_ts_multi_data_prep(dataset, target, start, end, window, horizon):
```

```
    X = []
```

```
    y = []
```

```
    start = start + window
```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

if end is None:
    end = len(dataset) - horizon
for i in range(start, end):
    indices = range(i-window, i)
    X.append(dataset[indices])
    indicey = range(i+1, i+1+horizon)
    y.append(target[indicey])
return np.array(X), np.array(y)

```

##Split training set and test set

```

hist_window = 3
horizon = 5
TRAIN_SPLIT = 18
x_train, y_train = custom_ts_multi_data_prep(X_data, Y_data, 0, TRAIN_SPLIT,
hist_window, horizon)
x_vali, y_vali = custom_ts_multi_data_prep(X_data, Y_data, TRAIN_SPLIT, None,
hist_window, horizon)

```

##Model Settings

```

batch_size = 64
buffer_size = 100
train_data = tf.data.Dataset.from_tensor_slices((x_train, y_train))
train_data = train_data.cache().shuffle(buffer_size).batch(batch_size).repeat()
val_data = tf.data.Dataset.from_tensor_slices((x_vali, y_vali))
val_data = val_data.batch(batch_size).repeat()

```

##Bidirectional Long Short-Term Memory (BiLSTM) Setting

```

lstm_model = tf.keras.models.Sequential([
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(20, return_sequences=True),
                                input_shape=x_train.shape[-2:]),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(20)),
    tf.keras.layers.Dropout(0.2),
    tf.keras.layers.Dense(20, activation='relu'),
    tf.keras.layers.Dropout(0.2),
    tf.keras.layers.Dense(20, activation='relu'),
    tf.keras.layers.Dropout(0.2),

```

```

tf.keras.layers.Dense(20, activation='relu'),
tf.keras.layers.Dropout(0.2),
tf.keras.layers.Dense(20, activation='relu'),
tf.keras.layers.Dropout(0.2),
tf.keras.layers.Dense(20, activation='relu'),
tf.keras.layers.Dropout(0.2),
tf.keras.layers.Dense(20, activation='relu'),
tf.keras.layers.Dropout(0.2),
tf.keras.layers.Dense(20, activation='relu'),
tf.keras.layers.Dropout(0.2),
tf.keras.layers.Dense(units=horizon),
])
lstm_model.compile(optimizer='adam', loss='mse')
lstm_model.summary()
##Run BILSTM
model_path = 'Bidirectional_LSTM_Multivariate.h5'
early_stopings = tf.keras.callbacks.EarlyStopping(monitor='val_loss', min_delta=0,
patience=20, verbose=1, mode='min')
checkpoint = tf.keras.callbacks.ModelCheckpoint(model_path, monitor='val_loss',
save_best_only=True, mode='min', verbose=0)
callbacks=[early_stopings,checkpoint]
t0 = time.time()
history =
lstm_model.fit(train_data,epochs=100,steps_per_epoch=100,validation_data=val_dat
a,validation_steps=50,verbose=1,callbacks=callbacks)
##BILSTM loss Graph
plt.figure(figsize=(16,9))
plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Model loss')
plt.ylabel('loss')

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


```

    tf.keras.layers.Dense(units=horizon),
    ])
GRU_model.compile(optimizer='adam', loss='mse')
GRU_model.summary()
##Run BIGRU
    model_path = 'Bidirectional_GRU_Multivariate.h5'
    early_stopings = tf.keras.callbacks.EarlyStopping(monitor='val_loss', min_delta=0,
    patience=20, verbose=1, mode='min')
    checkpoint = tf.keras.callbacks.ModelCheckpoint(model_path, monitor='val_loss',
    save_best_only=True, mode='min', verbose=0)
    callbacks=[early_stopings,checkpoint]
    t00 = time.time()
    history =
GRU_model.fit(train_data,epochs=100,steps_per_epoch=100,validation_data=val_dat
a,validation_steps=50,verbose=1,callbacks=callbacks)
##BIGRU loss Graph
plt.figure(figsize=(16,9))
plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('Model loss')
plt.ylabel('loss')
plt.xlabel('epoch')
plt.legend(['train loss', 'validation loss'])
plt.show()
##BIGRU Results
data_val1 = X_scaler.fit_transform( data[['S','CF','HA',
'T2M_Avg','WS2M_Avg','RH2M_Avg','RD_Avg','MP1','P1']].tail(3))
val_rescaled = data_val1.reshape(1, data_val1.shape[0], data_val1.shape[1])
pred1 = GRU_model.predict(val_rescaled)
pred_Inverse1 = Y_scaler.inverse_transform(pred1)
##Time spent building BIGRU
GRUtime = time.time()-t00

```

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

#===== Performance measures =====
def timeseries_evaluation_metrics_func(y_true, y_pred):
    def mean_absolute_percentage_error(y_true, y_pred):
        y_true, y_pred = np.array(y_true), np.array(y_pred)
        return np.mean(np.abs((y_true - y_pred) / y_true)) * 100
    print('Evaluation metric results:-')
    print(f'MAPE is : {mean_absolute_percentage_error(y_true, y_pred)}')
validate =
data[['Yield','S','CF','HA','T2M_Avg','WS2M_Avg','RH2M_Avg','RD_Avg','MP1','P1']].tail(5)
##Performance of BILSTM
timeseries_evaluation_metrics_func(validate['Yield'],pred_Inverse[0])
plt.figure(figsize=(16,9))
plt.plot( list(validate['Yield']))
plt.plot( list(pred_Inverse[0]))
plt.title("Actual vs Predicted")
plt.ylabel('Yield')
plt.legend(('Actual','predicted'))
plt.show()
##Performance of BIGRU
timeseries_evaluation_metrics_func(validate['Yield'],pred_Inverse1[0])
plt.figure(figsize=(16,9))
plt.plot( list(validate['Yield']))
plt.plot( list(pred_Inverse1[0]))
plt.title("Actual vs Predicted")
plt.ylabel('Yield')
plt.legend(('Actual','predicted'))
plt.show()
##One-way ANOVA
uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/Oneway Anova.csv'
data=pd.read_csv(uri)
a = np.array(data.onelayer)
b = np.array(data.fivelayer)
c = np.array(data.tenlayer)

```

เอกสารนี้เป็นเอกสารที่สงวนลิขสิทธิ์ไว้เพื่อการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
f_oneway(a,b,c)
```

##T-Test

```
uri = '/content/drive/MyDrive/Colab Notebooks/Hommali Dataset/T-Test.csv'
```

```
data=pd.read_csv(uri)
```

```
a=np.array(data.Normal)
```

```
b=np.array(data.Adjust)
```

```
stats.ttest_ind(a,b)
```



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้วิจัย

นักศึกษา นายอานนท์ บุญญวัฒน์
สาขาวิชา สถิติและวิเคราะห์ธุรกิจ
วัน-เดือน-ปีเกิด 2 ตุลาคม 2531
ที่อยู่ 181/8 ถนนพหลโยธิน แขวงอนุสาวรีย์ เขตบางเขน กทม. 10220
สถานที่ทำงาน สำนักงานเศรษฐกิจการเกษตร
ตำแหน่ง นักวิชาการสถิติปฏิบัติการ
ประวัติการศึกษา

พ.ศ. 2558 ปริญญาโท บริหารธุรกิจ (การเงิน)
 สถาบันบัณฑิตพัฒนบริหารศาสตร์
 พ.ศ. 2553 ปริญญาตรี เศรษฐศาสตร์ มหาวิทยาลัยเกษตรศาสตร์



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
 ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้