

ระบบคาดการณ์ผลผลิตและทิศทางราคาครึ่งแบบอัตโนมัติ



ทศพร มาเนียม

วิทยานิพนธ์เสนอมหาวิทยาลัยพะเยา เพื่อเป็นส่วนหนึ่งของการศึกษา

หลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์

พฤษภาคม 2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยพะเยา

ระบบคาดการณ์ผลผลิตและทิศทางราคาครั้งแบบอัตโนมัติ



วิทยานิพนธ์เสนอมหาวิทยาลัยพะเยา เพื่อเป็นส่วนหนึ่งของการศึกษา

หลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมคอมพิวเตอร์

พฤษภาคม 2568

ลิขสิทธิ์เป็นของมหาวิทยาลัยพะเยา



TOSSAPORN MANIAM

A Thesis Submitted to University of Phayao
in Partial Fulfillment of the Requirements
for the Master of Engineering Degree in Computer Engineering
May 2025

Copyright 2025 by University of Phayao

วิทยานิพนธ์

เรื่อง

ระบบคาดการณ์ผลผลิตและทิศทางราคาครึ่งแบบอัตโนมัติ

ของ ทศพร มาเนียม

ได้รับพิจารณาอนุมัติให้เป็นส่วนหนึ่งของการศึกษา

หลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมคอมพิวเตอร์

ของมหาวิทยาลัยพะเยา

..... ประธานกรรมการสอบวิทยานิพนธ์

(ผู้ช่วยศาสตราจารย์ ดร. วีรพล จิรจรีต)

..... ประธานที่ปรึกษาวิทยานิพนธ์

(ผู้ช่วยศาสตราจารย์ ดร. จีราพร ไชยวงศ์สาย)

..... กรรมการที่ปรึกษาวิทยานิพนธ์

(ผู้ช่วยศาสตราจารย์ ดร. พรเทพ โรจนวสุ)

..... อาจารย์บัณฑิตศึกษามหาวิทยาลัยพะเยา

(ผู้ช่วยศาสตราจารย์ ดร. บวรศักดิ์ ศรีสังสิทธิสันติ)

..... อาจารย์บัณฑิตศึกษามหาวิทยาลัยพะเยา

(ดร. นราศักดิ์ บุญเทพ)

..... คณบดีคณะเทคโนโลยีสารสนเทศและการสื่อสาร

(ผู้ช่วยศาสตราจารย์ ดร. พรเทพ โรจนวสุ)

เรื่อง:

ผู้วิจัย:

ทศพร มาเนียม, วิทยานิพนธ์: วศ.ม. (วิศวกรรมคอมพิวเตอร์), มหาวิทยาลัยพะเยา, 2567

อาจารย์ที่ปรึกษา:

ผู้ช่วยศาสตราจารย์ ดร. จิราพร ไชยวงศ์สาย อาจารย์ที่ปรึกษาร่วม ผู้ช่วยศาสตราจารย์ ดร.พรเทพ โรจนวสุ

คำสำคัญ:

การพยากรณ์ผลผลิต, , ราคาครึ่ง, สภาพอากาศ, การเพาะเลี้ยงครึ่ง

บทคัดย่อ

ครึ่งเป็นผลิตภัณฑ์ธรรมชาติที่ได้จากแมลงเพาะเลี้ยงบนต้นไม้ ซึ่งมีบทบาทสำคัญในอุตสาหกรรมเคมีภัณฑ์ ยา และเครื่องสำอาง โดยเฉพาะในเขตร้อน เช่น ประเทศไทย อย่างไรก็ตาม การผลิตและราคาครึ่งมีความผันผวนสูง อันเนื่องมาจากปัจจัยหลายประการ ทั้งสภาพอากาศที่แปรปรวนตามฤดูกาล ภาวะ El Niño และ La Niña รวมถึงความไม่แน่นอนของตลาด ส่งผลให้เกษตรกรขาดความมั่นใจในการวางแผนเพาะเลี้ยง ไม่มีเครื่องมือคาดการณ์ที่แม่นยำ และไม่สามารถตัดสินใจได้ทันท่วงทีว่าจะขยายพื้นที่การผลิตหรือชะลอการขาย

การวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการคาดการณ์ผลผลิตและแนวโน้มราคาขายของครึ่ง โดยใช้เทคนิค MA-LSTM (Moving Average – Long Short-Term Memory) ซึ่งมีศักยภาพสูงในการวิเคราะห์ข้อมูลอนุกรมเวลา (Time-Series) ที่มีความผันผวน ข้อมูลที่นำมาใช้ประกอบกรวิเคราะห์ ได้แก่ ปริมาณการส่งออกมูลค่าการส่งออก และดัชนี ONI (Oceanic Niño Index) ซึ่งสะท้อนสภาวะภูมิอากาศที่ส่งผลต่อการผลิตครึ่งครอบคลุมระยะเวลา 10 ปี (พ.ศ. 2555–2565) โดยมีการประมวลผลข้อมูลอย่างเป็นขั้นตอน ตั้งแต่การกรอง (Filtering) การจัดเรียง (Sorting) การลดความผันผวน (Smoothing) และการทำนายผล (Prediction)

ผลการทดลองพบว่า MA-LSTM เป็นแบบจำลองที่ให้ผลลัพธ์แม่นยำที่สุดเมื่อเปรียบเทียบกับโมเดลพื้นฐาน เช่น RNN และ Random Forest โดยการใช้ค่า EMA (Exponential Moving Average) ช่วยลดความผันผวนของข้อมูลก่อนนำเข้าโมเดล ทำให้สามารถจับแนวโน้มสำคัญได้อย่างมีประสิทธิภาพ นอกจากนี้ ยังได้พัฒนาระบบ Dashboard เพื่อแสดงผลการพยากรณ์ร่วมกับการวิเคราะห์ตรรกะเชิงทิศทางระหว่างราคา ปริมาณ และค่า ONI โดยออกแบบเป็นเงื่อนไข 8 รูปแบบ เพื่อให้ระบบสามารถแนะนำเกษตรกรได้อย่างเหมาะสม เช่น การขยายหรือชะลอการเพาะปลูก การทยอยขาย หรือการเก็บผลผลิตเพื่อรอช่วงเวลาที่เหมาะสม

จากผลการศึกษา แสดงให้เห็นว่า MA-LSTM เป็นเครื่องมือที่มีศักยภาพสูงในการคาดการณ์ข้อมูลเกษตรที่ซับซ้อนอย่างครึ่ง โดยสามารถนำไปประยุกต์ใช้ในระบบสนับสนุนการตัดสินใจเพื่อเพิ่มประสิทธิภาพและความยั่งยืนของภาคเกษตรกรรมได้อย่างเป็นรูปธรรม

Title: AUTOMATIC LAC YIELD AND PRICE TREND PREDICTION SYSTEM
Author: Tossaporn Maniam, Thesis: M.En. (Computer Engineering), University of Phayao, 2024
Advisor: Assistant Professor Ph.D. Jirabhorn Chaiwongsai Co–advisor Assistant Professor
Ph.D.Pornthep Rojanavasu
Keywords: MA–LSTM, Forecasting System, ENSO, Lac

ABSTRACT

Lac is a natural product obtained from insects cultivated on host trees and plays an important role in the chemical, pharmaceutical, and cosmetics industries, particularly in tropical countries such as Thailand. However, lac production and pricing are highly volatile due to various factors, including seasonal climate variability, El Niño and La Niña events, and market uncertainty. These fluctuations undermine farmers' confidence in production planning, leaving them without reliable forecasting tools and unable to make timely decisions on whether to expand production or delay sales.

This research aims to develop a forecasting model for predicting lac yield and price trends using the MA–LSTM (Moving Average – Long Short–Term Memory) technique, which is well suited for analyzing volatile time–series data. The dataset used in this study includes export volumes, export values, and the Oceanic Niño Index (ONI), which reflects climate conditions affecting lac production, covering a period of ten years (2012–2022). The data were processed through systematic steps, including filtering, sorting, smoothing, and prediction.

The experimental results demonstrate that MA–LSTM delivers the most accurate performance compared to baseline models such as RNN and Random Forest. Applying the Exponential Moving Average (EMA) method to reduce data volatility before feeding it into the model significantly enhanced its ability to capture critical trends. Additionally, a dashboard system was developed to present the forecasting results along with directional logic analysis between price, volume, and ONI. This system was designed with eight conditional patterns, allowing it to provide practical recommendations for farmers, such as expanding or reducing cultivation, gradual selling, or stockpiling products to wait for optimal market conditions.

Overall, the study shows that MA–LSTM is a highly promising tool for forecasting complex agricultural data like lac, and it can be effectively integrated into decision–support systems to enhance the efficiency and sustainability of the agricultural sector.

กิตติกรรมประกาศ

ข้าพเจ้าขอกราบขอบพระคุณอย่างสูงมายัง อาจารย์ที่ปรึกษา ผศ.ดร.จิราพร ไชยวงศ์ สาย ซึ่งได้ให้คำแนะนำ ความรู้ แนวคิด และข้อเสนอแนะอันทรงคุณค่า ตลอดจนเอื้อเฟื้อเวลา และความเมตตาในการตรวจสอบ แก้ไข และพัฒนางานวิจัยชิ้นนี้ให้สำเร็จลุล่วง

ขอขอบพระคุณ คณะกรรมการสอบวิทยานิพนธ์ ทุกท่าน ที่ให้คำแนะนำอย่างรอบด้าน และช่วยยกระดับคุณภาพของผลงานวิจัยนี้ให้ดียิ่งขึ้น

ขอบคุณ บริษัท นอร์ทเทอรัน สยาม ซีด แลค จำกัด ที่ให้ข้อมูลภาคสนามอันเป็น ประโยชน์อย่างยิ่งต่อการวิเคราะห์เชิงลึก และสนับสนุนข้อเท็จจริงในมุมมองของอุตสาหกรรม

ข้าพเจ้าขอขอบคุณเพื่อนร่วมชั้นเรียน อาจารย์ และเจ้าหน้าที่ของหลักสูตรที่ให้ความ ช่วยเหลือ ให้กำลังใจ และสนับสนุนในด้านต่าง ๆ ตลอดระยะเวลาการศึกษา

ท้ายที่สุด ข้าพเจ้าขอขอบคุณ ครอบครัว ที่เป็นแรงสนับสนุนที่มั่นคงทั้งด้านจิตใจและ กำลังใจ ซึ่งมีส่วนสำคัญอย่างยิ่งให้ข้าพเจ้ามีความมุ่งมั่นจนสามารถดำเนินงานวิจัยฉบับนี้จนแล้ว เสร็จ

ทศพร มาเนียม



สารบัญ


หน้า

บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ	จ
กิตติกรรมประกาศ	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ญ
สารบัญภาพ.....	1
บทที่ 1 บทนำ	1
1.1 ที่มาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์.....	2
1.3 ขอบเขตของวิทยานิพนธ์.....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	2
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง	3
2.1 แลงครั้ง.....	3
2.1.1 ครั้ง	3
2.2 สภาพอากาศที่มีผลต่อการเลี้ยงครั้ง	5
2.3 อัลกอริทึมสำหรับการคาดการณ์.....	6
2.4 งานวิจัยที่เกี่ยวข้อง	9
2.4.1 การทำนายสภาพอากาศ ENSO	10
The impact of global warming on ENSO from the perspective of objective signals (Chen, Li et al. 2024).....	10

A transformer-based coupled ocean-atmosphere model for ENSO studies (Zhang, Zhou et al. 2024)	11
Prediction of ENSO Beyond Spring Predictability Barrier Using Deep Convolutional LSTM Networks (Gupta, Kodamana et al. 2022)	12
Transformer for El Niño–Southern Oscillation Prediction(Ye, Hu et al. 2022) .	13
2.4.2 การคาดการณ์ข้อมูลราคาหรือผลผลิต	14
Linear Regression–Based Prediction Model For Real Estate Properties in India (Verma, Singh et al. 2023).....	18
Time Series Prediction of Agricultural Products Price Based on Time Alignment of Recurrent Neural Networks (Kurumatani 2018)	19
Forecasting Vegetation Behavior Based on PlanetScope Time Series Data Using RNN–Based Models(Marsetič and Kanjir 2024)	21
Crop Yield Prediction Using Deep Reinforcement Learning Model for Sustainable Agrarian Applications (Elavarasan and Vincent 2020)	22
An Analysis of Recurrent Neural Network variants to predict yield of Wheat crop in Punjab region (Bali and Singla 2021)	24
Deep–LSTM Model for Wheat Crop Yield Prediction in India (Saini and Nagpal 2022).....	26
Interpretable Long Short–Term Memory Networks for Crop Yield Estimation (Mateo–Sanchis, Adsua et al. 2023).....	28
Crop Recommendation System using Antlion Optimization and Decision Tree Algorithm (Avanija, Ambati et al. 2024)	29
Application of an Ensemble Method Based on XGBoost and Transformer in Predicting Sugarcane and Dragon Fruit Yields in Guangxi Region (Jing and Bingxiang 2024)	31
Integration of Crop Growth Model and Random Forest for Winter Wheat Yield Estimation From UAV Hyperspectral Imagery (Yang, Hu et al. 2021)	32

Predicting Agriculture Yields Based on Machine Learning Using Regression and Deep Learning (Sharma, Dadheech et al. 2023)	34
บทที่ 3 วิธีการดำเนินงานวิจัย	40
3.1 ภาพรวมการทำงาน (System Overview)	40
3.2 การเก็บรวบรวมข้อมูล (Data Collection)	41
3.3 การเตรียมข้อมูล (Pre-processing)	42
3.3.1 การทำความสะอาดข้อมูล (Data Cleaning)	42
3.3.2 การแปลงข้อมูล (Data Transformation)	43
3.4 โมเดลการฝึกฝน (Training Model)	44
บทที่ 4 ผลการทดลอง	46
4.1 ผลการทำนายผลผลิต(Yield Prediction)	46
4.2 การพยากรณ์แนวโน้มผลผลิตและราคาครึ่ง	51
4.3 การนำแบบจำลอง MA-LSTM ไปใช้ในเชิงปฏิบัติ	55
4.4 การทดสอบโมเดลกับข้อมูลจริงและการประเมินผล	66
บทที่ 5 สรุปผลการศึกษา อภิปรายผล และข้อเสนอแนะ	68
5.1 สรุปผลการศึกษา	68
5.2 อภิปรายผล	69
5.3 ข้อเสนอแนะสำหรับงานวิจัยในอนาคต	70
5.3.1 การเพิ่มปัจจัยด้านเศรษฐกิจและตลาด	70
5.3.2 การพัฒนาโมเดลที่ซับซ้อนขึ้น	70
5.2.3 การนำโมเดลไปใช้งานจริง	70
5.2.4 การปรับปรุงความละเอียดของข้อมูล	70
5.4 ข้อเสนอแนะในการขยายขอบเขตของตัวแปรนำเข้าไปในแบบจำลอง	71
ภาคผนวก	72

ภาคผนวก ก ข้อมูลที่ใช้ในการวิเคราะห์.....	73
ก.1 วิธีใช้งานเว็บไซต์ดึงข้อมูลปริมาณการส่งออกครั้ง.....	73
ภาคผนวก ข การวิเคราะห์ข้อมูล.....	77
ข.1 การจัดเตรียมข้อมูล	77
ข.2 โค้ดการฝึกโมเดล LSTM สำหรับการทำนายผลผลิตครั้ง	78
ข.3 การทำนายผล (Prediction).....	79
ภาคผนวก ค การใช้งาน Dashboard.....	80
บรรณานุกรม	81
ประวัติผู้วิจัย	84



สารบัญตาราง

	หน้า
ตาราง 1 งานวิจัยที่เกี่ยวข้องกับสภาพอากาศ	9
ตาราง 2 งานวิจัยที่เกี่ยวข้องกับการคาดการณ์ผลผลิตและทิศทางการค้า.....	16
ตาราง 3 การเปรียบเทียบค่าความผิดพลาดของแบบจำลอง.....	48
ตาราง 4 สรุปแนวโน้มของปริมาณการส่งออกและราคาครั้ง.....	53
ตาราง 5 สรุปแนวโน้มของปริมาณการส่งออกและ ONI.....	55
ตาราง 6 ตารางแสดงคำแนะนำเชิงปฏิบัติสำหรับเกษตรกร	56



สารบัญภาพ

หน้า

ภาพ 1 รังครึ่ง (Sharma 2017)	3
ภาพ 2 อยู่อาศัยครึ่ง ครึ่งดิบและ การใช้ประโยชน์ในอุตสาหกรรม (Bashir, Chen et al. 2022) .	4
ภาพ 3 การทำงาน LSTM	8
ภาพ 4 การใช้ 3D-Geoformer ในการทำนาย ENSO (Zhang, Zhou et al. 2024)	11
ภาพ 5 สถาปัตยกรรม Conv-LSTM (Gupta, Kodamana et al. 2022)	13
ภาพ 6 สถาปัตยกรรมแบบจำลอง ENSOTR (Ye, Hu et al. 2022)	14
ภาพ 7 คาดการณ์ราคาในอนาคตโดยตัวทำนายอนุกรมเวลา LSTM (Kurumatani 2018)	20
ภาพ 8 ตารางแสดง ค่า Error Rate	21
ภาพ 9 แผนภาพการทำงานของ Deep Recurrent Q-Network (Elavarasan and Vincent 2020)	22
ภาพ 10 ตัวชี้วัดการประเมินผลการศึกษา	23
ภาพ 11 ฟังก์ชันการทำงาน Basic RNN	24
ภาพ 12 ฟังก์ชันการทำงาน LSTM	25
ภาพ 13 ฟังก์ชันการทำงาน GRU neuron	25
ภาพ 14 ตารางเปรียบเทียบผลการทำงานแบบจำลอง(Bali and Singla 2021)	26
ภาพ 15 ฟังก์ชันการทำงาน Deep-LSTM (Saini and Nagpal 2022)	27
ภาพ 16 ตารางเปรียบเทียบผลการทำงาน Deep-LSTM กับโมเดลต่างๆ.....	27
ภาพ 17 ตารางเปรียบเทียบผลการทำงานของแต่ละอัลกอริทึม (Mateo-Sanchis, Adsua et al. 2023)	28
ภาพ 18 กราฟเปรียบเทียบสมรรถนะการทำงานในโมเดลที่แตกต่างกัน	30
ภาพ 19 ภาพผลสมมติจริงตามข้อมูลไฮเปอร์สเปกตรัมของ UAV (a) Jointing stage. (b) Heading stage (Yang, Hu et al. 2021)	32

ภาพ 20 แผนผังแนวคิดสำหรับการประมาณผลผลิตข้าวสาลีฤดูหนาวโดยอิงจากการบูรณาการแบบจำลอง CERES-ข้าวสาลีและอัลกอริทึมของฟอเรสต์แบบสุ่ม (Yang, Hu et al. 2021)	33
ภาพ 21 การผลิตพืชผลตามฤดูกาล (Sharma, Dadheech et al. 2023).....	35
ภาพ 22 ผลผลิตพืชเฉลี่ยต่อปี 2540–2563.....	36
ภาพ 23 K-Fold Cross Validation	36
ภาพ 24 ผลการทำนาย Random Forest.....	37
ภาพ 25 ผลการทำนาย LSTM.....	38
ภาพ 26 ภาพรวมระบบคาดการณ์.....	40
ภาพ 27 ข้อมูลปริมาณการส่งออก และราคา จากกรมศุลกากร	41
ภาพ 28 ข้อมูลสภาพอากาศ Oceanic Niño Index (ONI).....	42
ภาพ 29 เปรียบเทียบการแปลงข้อมูล.....	43
ภาพ 30 การแบ่งข้อมูลเพื่อฝึก และทดสอบ.....	44
ภาพ 31 ผลการทดสอบโมเดลสำหรับการคาดการณ์.....	47
ภาพ 32 ผลการทำนาย 2 ปีจ้จ้ย	49
ภาพ 33 วิเคราะห์แนวโน้มระหว่างผลผลิตและราคาครึ่ง.....	52
ภาพ 34 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาขึ้น ปริมาณเพิ่มขึ้น ภายใต้สภาพอากาศ La Niña.....	58
ภาพ 35 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาขึ้น ปริมาณลดลง ภายใต้สภาพอากาศ La Niña.....	59
ภาพ 36 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาลดลง ปริมาณเพิ่มขึ้น สภาพอากาศ La Niña	60
ภาพ 37 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาลดลง ปริมาณลดลง ภายใต้สภาพอากาศ La Niña.....	61

ภาพ 38 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาขึ้น ปริมาณเพิ่มขึ้น ภายใต้สภาพอากาศ El Niño	62
ภาพ 39 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาขึ้น ปริมาณลดลง ภายใต้สภาพอากาศ El Niño	63
ภาพ 40 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาลดลง ปริมาณเพิ่มขึ้น ภายใต้สภาพอากาศ El Niño	64
ภาพ 41 กราฟคาดการณ์ทิศทางและคำแนะนำ ช่วงราคาลดลง ปริมาณลดลง ภายใต้สภาพอากาศ El Niño	65
ภาพ 42 แสดงกราฟคาดการณ์ทิศทางและคำแนะนำ เพื่อเปรียบเทียบระหว่างข้อมูลจริง ผลลัพธ์จริง และผลลัพธ์จากการพยากรณ์	66
ภาพ 44 วิธีการใช้งานเว็บไซต์กรมศุลกากร	73
ภาพ 45 ไฟล์ Excel ข้อมูลการส่งออกครั้ง	74
ภาพ 46 ข้อมูลดัชนีสภาพอากาศ ONI	75
ภาพ 47 ข้อมูลราคา ปริมาณการส่งออก และสภาพอากาศ รูปแบบ CSV	76
ภาพ 48 โค้ดการจัดเตรียมข้อมูล	77
ภาพ 49 โค้ดการปรับสเกลข้อมูล และจัดรูปแบบข้อมูล	78
ภาพ 50 การสร้างและฝึกโมเดล LSTM สำหรับการทำนายผลผลิตครั้ง	79
ภาพ 51 ขั้นตอนการทำนายผลลัพธ์จากโมเดล LSTM และ Random Forest	79
ภาพ 52 ตัวอย่าง Dashboard แสดงการพยากรณ์ราคาครั้ง ปริมาณการส่งออก และค่า ONI	80

บทที่ 1

บทนำ

1.1 ที่มาและความสำคัญของปัญหา

ครึ่ง คือ ยางหรือชั้นชนิดหนึ่งที่มีกำเนิดจากตัวแมลงครึ่ง โดยมีลักษณะนิ่มเหนียวสีเหลืองทองเมื่อถูกอากาศนาน เมื่อถูกเก็บได้จากต้นไม้เรียกว่าครึ่งดิบ และมีส่วนประกอบที่สำคัญได้แก่ เรซิน, ขี้ผึ้ง, ลี, ซาก, ตัวครึ่ง, และสารอื่น ๆ ครึ่งมีความสำคัญในการปกป้องตัวจากอันตรายภายนอกโดยการขับถ่ายมูลครึ่งออกมาจากตัวเสมอ นอกจากนี้, ครึ่งยังมีการนำไปใช้ประโยชน์ในอุตสาหกรรม, เช่น การใช้เป็นสี และเนื้อครึ่ง

การประยุกต์ใช้ครึ่งในรูปแบบพอลิเมอร์ที่มีศักยภาพในอุตสาหกรรมอาหารมีความน่าสนใจเพิ่มขึ้นอย่างรวดเร็ว ซึ่งส่งผลให้มีการพัฒนาและใช้ประโยชน์จากครึ่งที่มีบทบาทสำคัญในอุตสาหกรรมอาหารในอนาคต ครึ่งเป็นหนึ่งในพอลิเมอร์ที่มีคุณสมบัติที่โดดเด่นมากในการประยุกต์ใช้ในอาหาร โดยมีคุณสมบัติที่แตกต่าง เช่น การตอบสนองต่อค่า pH, ความสามารถในการย่อยสลาย, และความเข้ากันได้ทางชีวภาพ

ครึ่งมีคุณสมบัติพิเศษเช่น การขึ้นรูป การยึดเกาะ ความเป็นพลาสติก และการย่อยสลายได้ง่าย เนื่องจากคุณสมบัติที่หลากหลาย ทำให้ครึ่ง กลายเป็นที่ต้องการตลาดโลก ซึ่งในประเทศไทย มีปริมาณการส่งออกครึ่งต่อปีเป็นจำนวนมาก ทำให้ผลผลิตไม่เพียงพอ อีกหนึ่งปัจจัยสำคัญที่ทำให้ผลผลิตไม่เพียงพอคือ จำนวนการเพาะเลี้ยงครึ่งลดน้อยลง อันเนื่องมาจากสภาพอากาศ สภาวะโลกร้อน อุณหภูมิในอากาศในแต่ละปีมีความไม่คงที่ ซึ่งยากต่อการคาดการณ์ ทำให้สูญเสียผลผลิต และยากต่อการฟื้นฟู จนทำให้เกษตรกรเพาะเลี้ยงครึ่งหลายราย ล้มเลิกการเพาะเลี้ยงครึ่งไป จากประเด็นปัญหาดังกล่าว จึงทำให้เกิดระบบคาดการณ์ผลผลิต จากสภาวะอากาศ แบบอัตโนมัติ เพื่อช่วยสนับสนุนการตัดสินใจให้เกษตรกร เพาะเลี้ยงครึ่ง ได้มีข้อมูลเพื่อวางแผนการเพาะปลูก ให้ได้รับการสูญเสียที่น้อยที่สุด

1.2 วัตถุประสงค์

1. เพื่อออกแบบและพัฒนา ระบบคาดการณ์ผลผลิต และราคาขายครั้งอัตโนมัติเพื่อวางแผนการเพาะเลี้ยงครั้ง โดยใช้ข้อมูล ปริมาณการส่งออก มูลค่าการส่งออก และ สภาพอากาศ บนเว็บแอปพลิเคชันได้
2. เพื่อวิจัยและพัฒนา แบบจำลองการคาดการณ์ผลผลิต และทิศทางราคาขายครั้ง โดยใช้หลักการเรียนรู้เชิงลึก เพื่อช่วยเกษตรกรในการตัดสินใจขยายหรือชะลอการเพาะเลี้ยงครั้ง
3. เพื่อวิจัยและออกแบบ โมเดลการคาดการณ์ ปริมาณผลผลิต และทิศทางราคา โดยประเมินอัตราความผิดพลาดที่ต่ำที่สุด

1.3 ขอบเขตของวิทยานิพนธ์

1. ระบบคาดการณ์ผลผลิต และราคาขายครั้งอัตโนมัติ สามารถช่วยการตัดสินใจ ของเกษตรกรในการ ชะลอ หรือ เพิ่ม พื้นที่การเลี้ยงครั้ง และ จังหวะขายหรือ ชะลอ การขาย
2. วิจัยและพัฒนา แบบจำลองการคาดการณ์ผลผลิต และทิศทางราคาขายครั้งโดยใช้ ข้อมูล ปริมาณการส่งออก มูลค่าการส่งออก และ สภาพอากาศในระยะเวลา 10 ปี ได้แก่วางเวลา พ.ศ.2555- พ.ศ.2565 ถูกออกแบบมาให้มีชุดข้อมูลฝึกฝน (Training Set) จำนวน 8 ปี และข้อมูลทดสอบ (Testing set) จำนวน 2 ปี เพื่อหาแบบจำลองที่เหมาะสมที่ให้อัตราความผิดพลาดต่ำที่สุด
3. โมเดลการคาดการณ์ ปริมาณผลผลิต และทิศทางราคาครั้ง ถูกประเมินอัตราความผิดพลาดด้วยวิธี Mean Absolute Error (MAE) และ Root Mean Square Error (RMSE) ของอัลกอริทึม Recurrent Neuron Network (RNN) Long Short Term Memory (LSTM) และ Random Forest (RF)

1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. ระบบคาดการณ์ผลผลิต และราคาขายครั้งอัตโนมัติถูกออกแบบมาเพื่อช่วยวางแผนการเพาะเลี้ยงครั้ง จากข้อมูล ปริมาณการส่งออก มูลค่าการส่งออก และ สภาพอากาศ จึงช่วยลดความเสี่ยงในการสูญเสียผลผลิตของเกษตรกรเมื่อสภาพอากาศแปรปรวน

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

2.1 แมลงครั่ง


2.1.1 ครั่ง

ยางครั่งเป็นสารที่ครั่งใช้ในการป้องกันตัวเอง โดยครั่งจะได้มาจากการดูดกินน้ำเลี้ยงจากกิ่งไม้ที่เป็นแหล่งอาหารของมัน(สุบรรณเสณ 2014) เมื่อครั่งได้รับสารอาหารเพียงพอ มันจะขับถ่ายยางครั่งออกมาจากภายในตัวมันเองอย่างต่อเนื่อง เพื่อใช้เป็นเกราะห่อหุ้มตัวเพื่อป้องกันตัวจากอันตรายภายนอก



ภาพ 1 รังครั่ง (Sharma 2017)

ยางครั่งมีลักษณะที่เหนียวสีเหลือง และเมื่อถูกสัมผัสกับอากาศเป็นเวลา จะแข็งตัวเป็นสีน้ำตาลแดง ครั่งที่เก็บมาจากการกะเทาะกิ่งไม้แล้วจะเรียกว่าครั่งดิบ ซึ่งมีส่วนประกอบที่สำคัญคือ เรซิน ซีฟิ่ง สี ซากตัวครั่ง และสารอื่น ๆ ครั่งที่นำมาใช้ประโยชน์ทางอุตสาหกรรมมักจะแบ่งเป็นสองประเภทหลัก คือ สีครั่ง (lac dye) และครั่งเม็ด (seed lac) โดยครั่งเม็ดสามารถได้มาจากการล้างครั่งดิบและต่อจากนั้นจึงถูกนำไปใช้งานในอุตสาหกรรมต่าง ๆ



ภาพ 2 อยู่อาศัยครั้ง ครั่งดิบและ การใช้ประโยชน์ในอุตสาหกรรม (Bashir, Chen et al. 2022)

ครั่งเป็นโพลิเมอร์ธรรมชาติที่มีคุณสมบัติพิเศษ ที่มีความน่าสนใจในอุตสาหกรรมอาหาร ดังแสดงในภาพ 2 เรื่องนี้เป็นที่น่าสนใจของผู้วิจัยและผู้ประกอบการในอุตสาหกรรมอาหารมากขึ้นเรื่อย ๆ ด้วยคุณสมบัติที่สำคัญ เช่น การตอบสนองต่อ pH, การถูกย่อยสลายได้ และความเข้ากันได้กับสิ่งมีชีวิต การวิจัยและการพัฒนาเซลล์ในอุตสาหกรรมอาหารมีความหลากหลายและมีความสำคัญ โดยการนำเสนอข้อมูลเกี่ยวกับแหล่งที่มาของเซลล์ วิธีการสกัดและการประมวลผลต่าง ๆ รวมถึงคุณสมบัติทางเคมี-ทางกายภาพของเซลล์ ซึ่งเป็นส่วนสำคัญของการศึกษา

ครั่งเป็นสารที่มีชื่อเสียงมานานในประเทศอินเดียและจีนมาหลายพันปี ในอดีต ครั่งถูกใช้เป็นสมุนไพรในการรักษาโรค เช่น โรคโลหิตจาง และยังใช้สีครั่งในการย้อมผ้าและหนังสือตัว ในปัจจุบัน เรายังเห็นการใช้ครั่งในการย้อมไหมและเป็นส่วนผสมของอาหาร เช่น ขนมชั้น เป็นต้น การใช้ครั่งมีบทบาททางเศรษฐกิจที่สำคัญอย่างมากในประเทศ ในปัจจุบันมีการเพาะเลี้ยงครั่งในหลายประเทศ เช่น อินเดีย จีน พม่า ลาว กัมพูชา อินโดนีเซีย และไทย โดยในประเทศไทยมีการเพาะเลี้ยงครั่งมากที่สุดในภาคเหนือตอนบน เช่น จังหวัดลำปาง จังหวัดเชียงใหม่ และจังหวัดพะเยา และในภาคเหนือตอนล่าง เช่น จังหวัดกำแพงเพชร และจังหวัดนครสวรรค์ นอกจากนี้ยังมีการเพาะเลี้ยงครั่งในภาคตะวันออกเฉียงเหนือและทางภาคใต้เพิ่มขึ้นเรื่อย ๆ ในระยะเวลาที่ผ่านมา

2.2 สภาพอากาศที่มีผลต่อการเลี้ยงกุ้ง

สภาพอากาศที่มีผลต่อการเจริญเติบโตและการผลิตของกุ้งเอง สภาพอากาศเป็นปัจจัยสำคัญที่มีผลต่อการพัฒนาและประสิทธิภาพของกุ้งในหลายด้าน ตัวอย่างเช่น ปริมาณน้ำฝนที่ได้รับ อุณหภูมิ และความชื้นในอากาศ สามารถมีผลต่อการเจริญเติบโตของพืชเจริญเติบโตของกุ้งได้ เนื่องจาก แมลงครึ่งชอบความอบอุ่นภูมิอากาศและกระจายอยู่ในเขตร้อนและกึ่งเขตร้อน (Sharma 2019)

เมื่อพูดถึงสภาพดินและอากาศ หมายถึงความร้อน ความชื้น และปริมาณน้ำฝน ทั้งสามปัจจัยนี้มีความสำคัญในการเลี้ยงกุ้ง การเปลี่ยนแปลงของสภาพดินและอากาศไม่ว่าจะเป็นเย็นหรือร้อน เป็นแหล่งกำเนิดสภาพแวดล้อมที่ไม่เหมาะสมสำหรับการเจริญเติบโตของกุ้ง โดยเฉพาะในปัจจุบันที่อากาศมีแนวโน้มที่ร้อนต่อเนื่อง มีผลต่อประสิทธิภาพในการเลี้ยงกุ้ง เนื่องจากสภาพอากาศที่มีความร้อนสูงหรือความชื้นต่ำเกินไปสามารถทำให้แมลงครึ่งตายหรือไม่เจริญเติบโตได้ดี โดยเฉพาะในช่วงเวลาที่อากาศร้อนจัดซึ่งทำให้กุ้งอ่อนตัวและติดเชื้อหายใจ ทำให้แมลงครึ่งขาดอากาศและเสียชีวิต นอกจากนี้ หากฝนตกมากเกินไปก็จะทำให้กุ้งมีความชื้นมากเกินไปและเสี่ยงต่อการเกิดเชื้อรา (สุบรรณเสถ 2014)

ผลกระทบจากสภาพอากาศที่เปลี่ยนแปลง โดยเฉพาะ El Niño และ La Niña ก็มีผลอย่างมากต่อการเลี้ยงกุ้ง อาจทำให้เกษตรกรลดการเลี้ยงกุ้งหรือหยุดการเพาะเลี้ยงเป็นไปได้ บางรายยังมีการตัดไม้ก้ามปูขายไปเพื่อรับราคาที่ดี แต่สถิติการเลี้ยงกุ้งก็ลดลงอย่างน่าสังเกต บางรายที่เคยเลี้ยงกุ้งก็รู้สึกว่าการพยายามที่จะหาครั้งพันธุ์มาเพื่อเริ่มการเลี้ยงใหม่นั้นมีความยากลำบาก เนื่องจากมีการหยุดเลี้ยงมานาน บางรายก็ปล่อยให้ครั้งเข้ามาเพาะพันธุ์บนต้นไม้เป็นระยะเวลา 2-3 ปี ทำให้กิ่งไม้มีอยู่เยอะเกินไปและรับลักษณะของคราบรังครั้งเก่าบางส่วน ซึ่งนอกจากนี้เมื่อนำครั้งมาเพาะพันธุ์ ผลลัพธ์ที่ได้รับอาจจะไม่มีความสำเร็จเท่าที่คาดหวัง

2.3 อัลกอริทึมสำหรับการคาดการณ์

การคาดการณ์ผลผลิตและราคาสินค้าทางการเกษตรใช้หลายอัลกอริทึมที่มีประสิทธิภาพในการวิเคราะห์ข้อมูลและทำนายแนวโน้มต่าง ๆ เช่น **Linear Regression** ที่ใช้วิเคราะห์ความสัมพันธ์ระหว่างตัวแปรต้นและตัวแปรตามโดยใช้สมการเส้นตรง เหมาะสำหรับทำนายแนวโน้มจากข้อมูลประวัติศาสตร์ และ **Time Series Analysis** ที่ใช้ข้อมูลประวัติศาสตร์ที่เก็บรวบรวมเป็นช่วงเวลาต่อเนื่องในการทำนายราคาสินค้าเกษตร เช่น การทำนายราคาข้าวในอดีตโดยใช้ **Recurrent Neural Networks (RNN)** เพื่อปรับปรุงเสถียรภาพในการทำนาย

นอกจากนี้ยังมีการใช้ **Machine Learning Algorithms** เช่น **Decision Trees** และ **Random Forests** ที่ใช้ในการทำนายราคาสินค้าเกษตรจากข้อมูลทางเศรษฐกิจและสภาพอากาศ และ **Neural Networks** เช่น **LSTM** ในการทำนายพฤติกรรมของพืชพรรณ และ **Precision Agriculture** ที่ใช้การวิเคราะห์ข้อมูลทางภูมิศาสตร์เพื่อปรับปรุงการจัดการที่ดิน และการให้น้ำให้เหมาะสมที่สุด อัลกอริทึมเหล่านี้ช่วยในการทำนายแนวโน้มและปรับปรุงการดำเนินงานในวงการเกษตรได้อย่างมีประสิทธิภาพ


จากอัลกอริทึมต่าง การใช้ **LSTM** ในการคาดการณ์ช่วยให้การทำนายผลผลิตและราคาสินค้าทางการเกษตรมีความแม่นยำมากขึ้น โดยเฉพาะในกรณีที่ข้อมูลมีความผันผวนหรือความสัมพันธ์ที่ซับซ้อน เช่น ข้อมูลสภาพอากาศ การใช้ปุ๋ย และปัจจัยอื่น ๆ ที่ส่งผลต่อผลผลิต **LSTM** ช่วยให้เกษตรกรและผู้ประกอบการสามารถวางแผนการเพาะปลูกและการจัดการทรัพยากรได้อย่างมีประสิทธิภาพ ตอบสนองต่อการเปลี่ยนแปลงของสภาพแวดล้อมได้ดียิ่งขึ้น เนื่องจากความสามารถในการจัดการกับข้อมูลเชิงลำดับที่มีความสัมพันธ์ในระยะยาว **LSTM** ถูกออกแบบมาเพื่อแก้ปัญหการสูญเสียมูลค่า (Vanishing Gradient Problem) ที่พบใน **RNN** แบบดั้งเดิม โดยใช้โครงสร้างที่ประกอบด้วยหน่วยความจำ (memory blocks) และเกต (gates) ที่ช่วยเก็บข้อมูลระยะยาวได้อย่างมีประสิทธิภาพ

Long Short-Term Memory (LSTM) เป็นรูปแบบหนึ่งของ Recurrent Neural Networks (RNN) ที่ถูกออกแบบมาเพื่อแก้ปัญหาที่พบใน RNN แบบดั้งเดิม โดยเฉพาะอย่างยิ่งการเรียนรู้ความสัมพันธ์ระยะยาวในข้อมูลเรียงลำดับ (Sequential Data) เช่น ข้อมูลเวลา (Time Series) หรือข้อความในประโยคของภาษาธรรมชาติ ปัญหาหลักของ RNN แบบดั้งเดิมคือการ "หายไปของกราเดียนต์" (Vanishing Gradient) ซึ่งเป็นปรากฏการณ์ที่เกิดขึ้นเมื่อข้อมูลหรือสัญญาณย้อนกลับไปหายไปอย่างรวดเร็วในขณะที่ฝึกฝนโมเดล ทำให้ RNN ไม่สามารถจำข้อมูลที่อยู่ห่างไกลในลำดับได้ดี ส่งผลให้การทำนายหรือการเรียนรู้ข้อมูลที่ต้องใช้ความสัมพันธ์ระยะยาวนั้นขาดประสิทธิภาพ LSTM จึงถูกพัฒนาขึ้นมาเพื่อแก้ปัญหานี้โดยการใช้หน่วยความจำภายในที่สามารถเก็บรักษาข้อมูลไว้ได้ยาวนานขึ้น ซึ่งทำให้สามารถจับความสัมพันธ์ที่เกิดขึ้นระหว่างข้อมูลในระยะไกลได้ดีขึ้นกว่า RNN ทั่วไป

โครงสร้างภายในของ LSTM ประกอบไปด้วย "สถานะของเซลล์" (Cell State) และ "สถานะที่ซ่อนอยู่" (Hidden State) ซึ่งสถานะของเซลล์ทำหน้าที่เป็นแถบข้อมูล (Conveyor Belt) ที่คอยส่งผ่านข้อมูลไปตลอดทั้งเครือข่ายโดยไม่ถูกปรับเปลี่ยนมากนัก ยกเว้นในกรณีที่ได้รับการควบคุมจากกลไกที่เรียกว่า "เกต" (Gates) โดยเกตเหล่านี้ทำหน้าที่ควบคุมการไหลของข้อมูลเข้าและออกจากสถานะของเซลล์ ซึ่งช่วยให้ LSTM สามารถเก็บรักษาหรือทิ้งข้อมูลได้อย่างมีประสิทธิภาพตามความจำเป็น ประเภทของเกตใน LSTM มีทั้งหมด 3 ประเภท ได้แก่ Forget Gate, Input Gate, และ Output Gate ซึ่งแต่ละเกตมีหน้าที่เฉพาะในการจัดการข้อมูลในหน่วยความจำ

Forget Gate ทำหน้าที่ตัดสินใจว่าจะทิ้งข้อมูลส่วนใดของสถานะเซลล์จากช่วงเวลาก่อนหน้านี้ โดยใช้สถานะที่ซ่อนอยู่จากเวลาที่ผ่านมาและข้อมูลอินพุตปัจจุบัน จากนั้นนำข้อมูลเหล่านี้มาผ่านฟังก์ชัน Sigmoid เพื่อกำหนดว่าจะเก็บหรือทิ้งข้อมูลใดบ้าง ค่า Sigmoid ที่ได้จะอยู่ระหว่าง 0 และ 1 ซึ่งค่า 1 หมายถึง "เก็บข้อมูลทั้งหมด" และค่า 0 หมายถึง "ลบข้อมูลทิ้งทั้งหมด" ขั้นตอนถัดไปคือ Input Gate

Input Gate ที่ทำหน้าที่ตัดสินใจว่าจะเพิ่มข้อมูลใหม่ใดบ้างเข้าไปในสถานะเซลล์ โดยเกตนี้จะประกอบไปด้วยสองส่วน ส่วนแรกคือเลเยอร์ Sigmoid ที่กำหนดว่าจะอัปเดตที่ตำแหน่งใดในสถานะเซลล์ และส่วนที่สองคือเลเยอร์ Tanh ที่สร้างค่าข้อมูลใหม่ที่เป็นไปได้เพื่อนำมารวมกับข้อมูลเดิมในสถานะเซลล์ หลังจากนั้นสถานะเซลล์จะได้รับการอัปเดตโดยการรวมข้อมูลจากเกตลืมและเกตอินพุตเข้าด้วยกัน ซึ่งช่วยให้ LSTM สามารถบันทึกข้อมูลที่สำคัญในระยะยาวได้อย่างเหมาะสม



ภาพ 3 การทำงาน LSTM

Output Gate มีหน้าที่กำหนดค่าของเอาต์พุตที่จะส่งออกไปยังสถานะที่ซ่อนอยู่สำหรับขั้นตอนถัดไป โดยเกตนี้จะใช้ข้อมูลสถานะเซลล์ที่ผ่านการปรับปรุงแล้ว และนำข้อมูลนี้ไปผ่านฟังก์ชัน Tanh เพื่อบีบอัดค่าให้อยู่ในช่วงระหว่าง -1 ถึง 1 จากนั้นใช้ค่าที่ได้จากการผ่านฟังก์ชัน Sigmoid มากำหนดว่าเอาต์พุตส่วนใดจะถูกส่งออกมาเป็นสถานะที่ซ่อนอยู่ (Hidden State) สำหรับขั้นตอนถัดไป ความสามารถของ LSTM ในการควบคุมการเพิ่มและลบข้อมูลผ่านเกตทั้งสามนี้ ทำให้ LSTM มีความสามารถในการจดจำข้อมูลที่สำคัญในระยะยาวและละทิ้งข้อมูลที่ไม่จำเป็น จึงสามารถนำไปใช้กับงานที่มีความซับซ้อนในเชิงลำดับได้อย่างมีประสิทธิภาพ เช่น การประมวลผลภาษาธรรมชาติ (Natural Language Processing), การแปลภาษา, การรู้จำเสียงพูด, และการทำนายข้อมูลแบบอนุกรมเวลา

2.4 งานวิจัยที่เกี่ยวข้อง

El Niño และ La Niña เป็นปรากฏการณ์ทางมีเหตุในระบบอุทกนิยมในมหาสมุทรแปซิฟิก ซึ่งสามารถส่งผลกระทบต่อลมและการไหลของน้ำในมหาสมุทร นักวิทยาศาสตร์ได้ระบุว่า El Niño และ La Niña มีผลต่อสภาพอากาศทั่วโลก โดยมีผลกระทบต่อการเจริญเติบโตของพืชและการเลี้ยงสัตว์ งานวิจัยนี้ได้ทำการรวบรวมงานวิจัยที่เกี่ยวข้องกับ ENSO ในตารางที่ 1

ตาราง 1 งานวิจัยที่เกี่ยวข้องกับสภาพอากาศ

ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
1	The impact of global warming on ENSO from the perspective of objective signals (Chen, Li et al. 2024)	journal	ใช้ข้อมูลที่เป็นจริงช่วยลดความไม่แน่นอนที่เกิดจากการจำลองการทดลองและใช้วิธีการแยกพารามิเตอร์ช่วยให้ได้สัญญาณที่มีความแม่นยำสูง	การศึกษาจำกัดเฉพาะที่ระดับ 250 hPa ซึ่งอาจไม่ครอบคลุมการเปลี่ยนแปลงทั้งหมดในบรรยากาศ	ใช้ ICA เพื่อแยกสัญญาณภาวะโลกร้อนและ ENSO
2	A transformer-based coupled ocean-atmosphere model for ENSO studies (Zhang, Zhou et al. 2024)	journal	3D-Geoformer สามารถทำนาย ENSO ได้แม่นยำกว่าโมเดลทั่วไปและใช้ข้อมูลจากหลายเดือนที่ผ่านมาในการทำนายทำให้เกิดความแม่นยำที่มากขึ้น	การใช้งานโมเดลมีความซับซ้อนสูงในการคำนวณและการใช้หน่วยความจำมาก	ใช้ข้อมูลเริ่มต้นจากหลายเดือนที่ผ่านมาในการทำนายเดือนถัดไปต่อเนื่องกันและปรับปรุงพารามิเตอร์ที่เป็นประโยชน์เพื่อเรียนรู้ความสัมพันธ์ระหว่างข้อมูลต่าง ๆ อย่างมีประสิทธิภาพ
3	Prediction of ENSO Beyond Spring Predictability Barrier Using Deep Convolutional LSTM Networks (Gupta, Kodamana et al. 2022)	journal	โมเดล Conv LSTM สามารถพยากรณ์เหตุการณ์เอลนีโญได้อย่างแม่นยำถึงหนึ่งปีล่วงหน้า	การฝึกโมเดลต้องใช้ทรัพยากรคอมพิวเตอร์ที่สูงและเวลานาน	ใช้ Conv LSTM layers ร่วมกับ Conv 3D และ Max Pooling layers เพื่อสร้างโมเดลที่สามารถประมวลผลข้อมูลเชิงซ้อนตามลำดับเวลา
4	Transformer for El Niño–Southern Oscillation Prediction(Ye, Hu et al. 2022)	journal	จับภาพรวมได้ดีพยากรณ์ระยะยาวแม่นยำ โมเดล ENSOTR สามารถพยากรณ์ดัชนี Niño3.4 ล่วงหน้าได้ถึง 18 เดือน	ต้องการข้อมูลฝึกที่มากซับซ้อนและใช้เวลาในการประมวลผล	ใช้ CNN ในการเรียนรู้คุณลักษณะท้องถิ่นและใช้ Transformer ในการเรียนรู้การเป็นตัวแทนระยะไกล

2.4.1 การทำนายสภาพอากาศ ENSO

The impact of global warming on ENSO from the perspective of objective signals
(Chen, Li et al. 2024)

ปรากฏการณ์ El Niño–Southern Oscillation (ENSO) และภาวะโลกร้อนเป็นปัจจัยสำคัญที่ส่งผลกระทบต่อระบบภูมิอากาศของโลก ENSO เกิดขึ้นในแปซิฟิกเขตร้อนและเป็นโหมดภูมิอากาศภายในที่แข็งแกร่งที่สุดในช่วงเวลาหลายปี มันไม่เพียงส่งผลกระทบต่อความผิดปกติของสภาพภูมิอากาศในเขตร้อนของมหาสมุทรแปซิฟิกเท่านั้น แต่ยังมีอิทธิพลสำคัญต่อความผิดปกติของสภาพภูมิอากาศในเขตร้อนและแม้แต่ระดับโลกผ่านการเชื่อมโยงทางบรรยากาศ ภาวะโลกร้อนหมายถึงการเพิ่มขึ้นของอุณหภูมิเฉลี่ยผิวโลกในระยะยาวที่เกิดจากกิจกรรมของมนุษย์ที่ปล่อยก๊าซเรือนกระจกสู่ชั้นบรรยากาศ มันมีผลกระทบที่ลึกซึ้งต่อระบบ

นิเวศ เศรษฐกิจ และความมั่นคงทางสังคม การเข้าใจการเปลี่ยนแปลงลักษณะของ ENSO ภายใต้ภาวะโลกร้อนเป็นสิ่งสำคัญสำหรับการทำนายการเปลี่ยนแปลงสภาพภูมิอากาศในอนาคต

งานวิจัยนี้ศึกษาเกี่ยวกับความสัมพันธ์ระหว่างภาวะโลกร้อนและปรากฏการณ์ ENSO โดยเน้นการใช้ข้อมูลที่เป็นวัตถุประสงค์และวิธีการวิเคราะห์ขั้นสูงเพื่อลดความไม่แน่นอนที่เกิดจากการทดลองแบบจำลอง มีจุดประสงค์เพื่อศึกษาภาวะโลกร้อนที่ส่งผลกระทบต่อ ENSO ทั้งบนพื้นผิวโลกและในบรรยากาศ โดยเฉพาะในชั้นบรรยากาศชั้นบนที่ระดับ 250 hPa


งานวิจัยนี้ ใช้การวิเคราะห์องค์ประกอบอิสระ Independent component analysis (ICA) ร่วมกับวิธีไม่อิงพารามิเตอร์ เพื่อแยกสัญญาณภาวะโลกร้อนและ ENSO ที่เป็นค่ากลาง วิธีการนี้จัดการกับคุณลักษณะไม่ใช่ข้อมูลเชิงเส้นในของอนุกรมเวลาสำหรับภูมิอากาศ และแยกข้อมูลออกจากสัญญาณรบกวนในข้อมูลที่มีมิติสูง

การวิเคราะห์จากงานวิจัยนี้พบว่า ภาวะโลกร้อนนำหน้า ENSO อยู่ประมาณสามเดือนและมีความสัมพันธ์อย่างมีนัยสำคัญ โดยเฉพาะในช่วงเหตุการณ์ ENSO ที่รุนแรง ความถี่และความรุนแรงของเหตุการณ์ ENSO เพิ่มขึ้นภายใต้ภาวะโลกร้อน ทำให้มีการเชื่อมโยงทางบรรยากาศเปลี่ยนไป และทำให้เกิดเหตุการณ์ El Niño ที่รุนแรงมากขึ้น

A transformer-based coupled ocean-atmosphere model for ENSO studies (Zhang, Zhou et al. 2024)

โมเดลทางฟิสิกส์ที่ใช้ในการทำนาย ENSO ได้แสดงผลในการทำนายเหตุการณ์ ENSO รวมถึงการเปลี่ยนแปลงของ SST ในแถบเส้นศูนย์สูตรแปซิฟิก แต่ยังคงมีข้อจำกัดในความแม่นยำของการทำนาย ซึ่งยังมีความแตกต่างระหว่างโมเดลต่าง ๆ มากมายในการทำนาย SST การพยายามปรับปรุงทักษะการทำนาย ENSO ยังต้องการการผสมผสานข้อมูลที่แม่นยำมากขึ้นเพื่อให้การทำนายมีความถูกต้อง

เมื่อไม่นานมานี้ โมเดลที่ใช้การเรียนรู้เชิงลึก (DL) ได้รับการพัฒนาและแสดงให้เห็นว่าสามารถทำนาย ENSO ได้ดีกว่าโมเดลฟิสิกส์ทั่วไป อย่างไรก็ตาม โมเดล DL ปัจจุบันยังไม่สามารถแสดงการเชื่อมต่อระหว่างมหาสมุทร และบรรยากาศได้อย่างชัดเจนในระหว่างการทำนาย ทำให้มีการพัฒนาโมเดลใหม่ ที่ใช้กลไกแปลงความสนใจ (Attention-based transformer) ที่มีชื่อว่า 3D-Geoformer ซึ่งสามารถทำนายหลายปัจจัยที่เกี่ยวข้องกับ ENSO โดยใช้ข้อมูลอุณหภูมิพื้นผิวมหาสมุทร และทิศทางลมที่มีความสัมพันธ์กันในรูปแบบ 3 มิติ การทำนายใน 3D-Geoformer จะดำเนินการในลักษณะการทำนายต่อเนื่อง (rolling) ทำให้สามารถทำนายอนาคตได้โดยใช้ข้อมูลในอดีตหลายเดือน



ภาพ 4 การใช้ 3D-Geoformer ในการทำนาย ENSO (Zhang, Zhou et al. 2024)


โมเดล 3D-Geoformer แสดงในภาพ 3 มีข้อดีหลายประการ เช่น การสามารถรวมข้อมูลจากหลายช่วงเวลา (time intervals) เพื่อใช้เป็นข้อมูลเริ่มต้น ซึ่งสามารถปรับปรุงทักษะการทำนายได้ นอกจากนี้ยังสามารถใช้ในการศึกษาความไวต่อการทำนาย และค้นหาปัจจัยสำคัญที่มีผลต่อการทำนาย ENSO

แม้ว่าโมเดล 3D-Geoformer จะมีข้อดีมากมาย แต่มันยังมีข้อจำกัดทางเทคนิคเช่น ความซับซ้อนทางการคำนวณและการใช้งานหน่วยความจำที่สูง นอกจากนี้ยังมีความไม่เพียงพอของข้อมูลสังเกตการณ์ที่สามารถนำมาใช้ในการฝึกฝนโมเดลได้อย่างเต็มที่

Prediction of ENSO Beyond Spring Predictability Barrier Using Deep Convolutional LSTM Networks (Gupta, Kodamana et al. 2022)

ENSO มีผลกระทบต่อสภาพอากาศทั่วโลก ความแปรปรวนของอุณหภูมิผิวน้ำทะเล (SST) ในมหาสมุทรแปซิฟิกสามารถใช้เป็นตัวทำนายสภาพอากาศตามฤดูกาล แม้จะมีความพยายามในการพัฒนาความสามารถในการพยากรณ์ ENSO มาหลายทศวรรษ แต่ยังมีปัญหาการพยากรณ์ในฤดูใบไม้ผลิ การพัฒนาเทคโนโลยี deep learning ช่วยให้สามารถพยากรณ์ได้แม่นยำยิ่งขึ้นโดยใช้ข้อมูล SST จาก Hadley Centre SST (HadISST) และ NOAA Optimum Interpolated SST ข้อมูลถูกปรับขนาดและจัดเก็บเป็นภาพ 2 มิติ Conv-LSTM โมเดลนี้ถูกใช้ในการพยากรณ์ Nino3.4 ในภาพแบบรายเดือน ภาพ 4

Conv-LSTM สามารถพยากรณ์ค่าความผิดปกติของ SST ใน Nino3.4 ได้แม่นยำถึง 12 เดือน และสามารถพยากรณ์ El Niño ได้อย่างแม่นยำในปี 1997-1998 และ 2015-2016 นอกจากนี้ Conv-LSTM ยังมีความสามารถในการพยากรณ์เหตุการณ์อากาศร้อนมากกว่าเหตุการณ์ La Niña และ Conv-LSTM ยังสามารถเอาชนะแบบจำลองเชิงสถิติและเชิงพลศาสตร์ในการพยากรณ์เหตุการณ์ El Niño




ภาพ 5 สถาปัตยกรรม Conv-LSTM (Gupta, Kodamana et al. 2022)

ข้อสรุป Conv-LSTM มีความสามารถในการพยากรณ์เหตุการณ์ ENSO ล่วงหน้าถึง 12 เดือน และแบบจำลอง Conv-LSTM สามารถแก้ไขปัญหาการพยากรณ์ในฤดูใบไม้ผลิได้ดีกว่าแบบจำลองอื่น ๆ การเพิ่มตัวแปรเพิ่มเติมใน Conv-LSTM อาจนำไปสู่การพยากรณ์ SST และสภาพอากาศตามฤดูกาลที่แม่นยำยิ่งขึ้น

Transformer for El Niño–Southern Oscillation Prediction(Ye, Hu et al. 2022)

ENSO มีความสัมพันธ์กับการเปลี่ยนแปลงของอุณหภูมิพื้นผิวทะเลในมหาสมุทรแปซิฟิกและมีผลกระทบอย่างมากต่อภูมิอากาศทั่วโลก งานวิจัยก่อนหน้านี้ใช้โมเดลแบบพลวัตและสถิติในการพยากรณ์ ENSO แต่มีข้อจำกัดในเรื่องการพยากรณ์ระยะยาว โมเดลการเรียนรู้ด้วยเครื่องเช่น CNN ได้แสดงผลการพยากรณ์ที่ดีขึ้น แต่ยังมีข้อจำกัดในการจับลักษณะเด่นที่เป็นภาพรวม

งานวิจัยนี้ได้ประยุกต์ใช้โมเดล Transformer ในการพยากรณ์ ENSO ในภาพ 5 โดยมี การผสมผสานการเรียนรู้คุณลักษณะจาก CNN และการเรียนรู้ระยะไกลจาก Transformer โมเดล ENSOTR ได้รับการฝึกด้วยข้อมูล SST และความจุความร้อนของมหาสมุทรเป็นเวลา สามเดือนต่อเนื่อง และดัชนี Niño3.4 ในช่วงเวลาต่างๆ



ภาพ 6 สถาปัตยกรรมแบบจำลอง ENSOTR (Ye, Hu et al. 2022)

ผลการวิจัยโมเดล ENSOTR สามารถพยากรณ์ดัชนี Niño3.4 ได้อย่างมีประสิทธิภาพล่วงหน้าถึง 18 เดือน โดยเฉพาะการพยากรณ์เหตุการณ์ El Niño มีความแม่นยำสูง นอกจากนี้ยังพบว่าโมเดล ENSOTR มีประสิทธิภาพดีกว่าโมเดล CNN และโมเดลพลวัตอื่นๆ ในทุกช่วงเวลาโมเดล ENSOTR ที่ผสมผสานความสามารถของ CNN และ Transformer สามารถพยากรณ์ ENSO ได้อย่างมีประสิทธิภาพและดีกว่าโมเดลอื่นๆ ที่มีอยู่ในปัจจุบัน

2.4.2 การคาดการณ์ข้อมูลราคาหรือผลผลิต

การคาดการณ์ราคาและผลผลิตทางการเกษตรเป็นปัจจัยสำคัญที่มีผลต่อความสำเร็จของธุรกิจเกษตรและเศรษฐกิจในภาพรวม ในยุคที่เทคโนโลยีพัฒนาอย่างรวดเร็ว การใช้ อัลกอริทึมที่มีประสิทธิภาพในการวิเคราะห์ข้อมูลและคาดการณ์ราคาและผลผลิตมีบทบาทสำคัญต่อการบริหารจัดการภาคเกษตร เพื่อให้สามารถวางแผนและตัดสินใจได้อย่างเหมาะสมและแม่นยำ

ทั้งนี้ อัลกอริทึมที่ได้รับความนิยมและถูกนำมาใช้ทั้งในงานวิจัยและการปฏิบัติงาน ได้แก่ Linear Regression ซึ่งช่วยวิเคราะห์และทำนายแนวโน้มราคาสินค้าเกษตร โดยอ้างอิงข้อมูลประวัติราคาและปัจจัยสำคัญ เช่น ปริมาณการผลิตและสภาพอากาศ อีกทั้ง Time Series Analysis ซึ่งใช้วิเคราะห์แนวโน้มตามช่วงเวลา โดยอาศัยข้อมูลที่เก็บต่อเนื่อง เช่น ราคาข้าวในช่วง 5 ปีที่ผ่านมา

ในด้าน Machine Learning มีการใช้อัลกอริทึมเชิงลึก เช่น Decision Trees, Random Forests และ Neural Networks เพื่อทำนายราคาจากข้อมูลหลากหลาย เช่น ปัจจัยเศรษฐกิจ สภาพอากาศ และเทคโนโลยีสำหรับการทำนายผลผลิต (Crop Yield Prediction) มักใช้ Decision Trees และ Neural Networks โดยอิงข้อมูลสภาพอากาศ การใช้ปุ๋ย และการให้น้ำในส่วนการคาดการณ์การผลิตสัตว์เลี้ยง (Livestock Production Forecasting) นิยมใช้ Support Vector Machines และ Long Short-Term Memory (LSTM) โดยใช้ข้อมูลอาหาร สุขภาพสัตว์ และสิ่งแวดล้อมสำหรับ Precision Agriculture มีการใช้ k-means clustering เพื่อแบ่งพื้นที่เพาะปลูกตามลักษณะดินและสภาพอากาศ เพื่อเพิ่มประสิทธิภาพการจัดการที่ดินและการให้น้ำ การเลือกใช้อัลกอริทึมที่เหมาะสมช่วยให้สามารถทำนายแนวโน้มและปรับการดำเนินงานได้อย่างมีประสิทธิภาพท่ามกลางความเปลี่ยนแปลงในภาคเกษตร ทั้งนี้ งานวิจัยนี้ได้รวบรวมงานวิจัยที่เกี่ยวข้องไว้ในตารางที่ 2

ตาราง 2 งานวิจัยที่เกี่ยวข้องกับการคาดการณ์ผลผลิตและทิศทางราคา

ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
1	Linear Regression-Based Prediction Model For Real Estate Properties in India (Verma, Singh et al. 2023)	Conferences	ใช้งานและตีความผลได้ง่าย ใช้เวลาประมวลผลน้อยเมื่อเทียบกับแบบจำลองที่ซับซ้อน	เหมาะสำหรับข้อมูลเชิงเส้น ซึ่งจะมีความแม่นยำต่ำเมื่อใช้กับข้อมูลที่มีความซับซ้อนหรือไม่เป็นเชิงเส้น	Linear Regression
2	Time Series Prediction of Agricultural Products Price Based on Time Alignment of Recurrent Neural Networks (Kurumatani 2018)	Conferences	ช่วยให้ผู้ผลิตและผู้บริโภคสามารถวางแผนและตัดสินใจการซื้อขายได้ดีขึ้นลดความผันผวนของราคาผลผลิตทางการเกษตร	อาจไม่สามารถคาดการณ์ราคาที่แม่นยำในระยะยาวได้	Recurrent Neural Networks (RNNs), LSTM
3	Forecasting Vegetation Behavior Based on PlanetScope Time Series Data Using RNN-Based Models(Marsetić and Kanjir 2024)	journal	แบบจำลอง SRNN สามารถทำนายพฤติกรรมของพืชพรรณได้อย่างแม่นยำและมีประสิทธิภาพ	แบบจำลองมีการประเมินค่าดัชนี NDVI ต่ำกว่าความเป็นจริงในช่วงฤดูใบไม้ร่วง ซึ่งเกิดจากความเปลี่ยนแปลงของสภาพอากาศที่ไม่เป็นไปตามปกติ	ใช้แบบจำลองการเรียนรู้เชิงลึก RNN, LSTM, และ GRU เพื่อทำนายค่าดัชนี NDVI จากภาพถ่ายดาวเทียม
4	Crop Yield Prediction Using Deep Reinforcement Learning Model for Sustainable Agrarian Applications (Elavarasan and Vincent 2020)	journal	แบบจำลอง DRQN มีความแม่นยำสูงถึง 93.7% และสามารถรักษาคุณสมบัติการกระจายตัวของข้อมูลเดิมได้	DRL อาจมีปัญหาค่าข้อมูลมากเกินไป หรือค่าเกรเดียนต์หายเมื่อข้อมูลอนุกรมเวลามีความยาวมาก	ใช้แบบจำลอง DRQN ซึ่งรวม RNN เข้ากับ Q-Learning เพื่อสร้างกรอบการทำนายผลผลิต
5	An Analysis of Recurrent Neural Network variants to predict yield of Wheat crop in Punjab region (Bali and Singla 2021)	Conferences	แบบจำลอง RNN ที่ใช้ LSTM มีความแม่นยำสูงในการทำนายผลผลิตข้าวสาลีและสามารถจดจำแนวโน้มระยะยาวได้ดี	แบบจำลอง Simple RNN อาจมีปัญหา vanishing gradient ซึ่งทำให้ความแม่นยำในการทำนายลดลงในบางช่วงเวลา	ใช้แบบจำลอง RNN แบบ Simple RNN

ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
6	Deep-LSTM Model for Wheat Crop Yield Prediction in India (Saini and Nagpal 2022)	Conferences	แบบจำลอง Deep-LSTM มีความแม่นยำสูงในการทำนายผลผลิตข้าวสาลีด้วยค่า RMSE ต่ำสุดที่ 0.20	ต้องการข้อมูลฝึกที่มีปริมาณมากและการฝึกแบบจำลองใช้เวลานาน	ใช้แบบจำลอง Deep-LSTM ที่มีชั้น LSTM สามชั้นและชั้น Dense หนึ่งชั้น
7	Interpretable Long Short-Term Memory Networks for Crop Yield Estimation (Mateo-Sanchis, Aduara et al. 2023)	Conferences	แบบจำลอง LSTM มีความแม่นยำสูง ($R^2 > 0.56$) และสามารถใช้อ้างอิงข้อมูลจากหลายแหล่งเพื่อเพิ่มความแม่นยำในการทำนาย	การคำนวณค่าต้องใช้เวลามาก เนื่องจากมีความซับซ้อนเชิงคณิตศาสตร์สูง	ใช้แบบจำลอง LSTM พร้อมด้วยวิธีการอธิบายแบบ Integrated Gradients และ Shapley Values เพื่อทำนายผลผลิตพืชจากข้อมูลดาวเทียมและสภาพอากาศ
8	Crop Recommendation System using Antlion Optimization and Decision Tree Algorithm (Avanija, Ambati et al. 2024)	Conferences	แบบจำลอง ALO-DT มีความแม่นยำสูงถึง 98.86%	การใช้ ALO อาจใช้เวลานานในการค้นหาพารามิเตอร์ที่เหมาะสมที่สุด เนื่องจากมีความซับซ้อนของการคำนวณสูง	ใช้การผสมผสานระหว่างอัลกอริทึม Antlion Optimization (ALO) และ Decision Tree (DT) เพื่อปรับแต่งพารามิเตอร์และสร้างแบบจำลองที่มีประสิทธิภาพในการแนะนำการเพาะปลูก
9	Application of an Ensemble Method Based on XGBoost and Transformer in Predicting Sugarcane and Dragon Fruit Yields in Guangxi Region (Jing and Bingxiang 2024)	Conferences	แบบจำลองผสมผสาน XGBoost และ Transformer มีความแม่นยำสูงและสามารถจับความสัมพันธ์เชิงเวลาระหว่างข้อมูลทางภูมิอากาศและผลผลิตได้ดี	การใช้แบบจำลองผสมผสานอาจต้องใช้ข้อมูลที่มีคุณภาพสูงและครบถ้วน	ใช้วิธีการผสมผสานระหว่างอัลกอริทึม XGBoost และ Transformer ในการทำนายผลผลิต โดยใช้ข้อมูลทางภูมิอากาศและผลผลิตจากปี 2000-2022

ลำดับ	ชื่องานวิจัย	ชนิด	ข้อดี	ข้อจำกัด	วิธีการ
10	Integration of Crop Growth Model and Random Forest for Winter Wheat Yield Estimation From UAV Hyperspectral Imagery (Yang, Hu et al. 2021)	Journal	แบบจำลอง CW-RF สามารถทำนายผลผลิตข้าวสาลีได้อย่างแม่นยำ ด้วยค่า RMSE ต่ำ และเพิ่มความแม่นยำในการทำนายด้วยข้อมูลจาก UAV	การเก็บข้อมูลไฮเปอร์สเปกตรัมด้วย UAV มีค่าใช้จ่ายสูงและต้องการการควบคุมสภาพแวดล้อมที่เข้มงวด	ผสานแบบจำลองการเติบโตของพืช CERES-Wheat กับอัลกอริทึม Random Forest โดยใช้ข้อมูลสภาพอากาศ ดิน และภาพถ่ายไฮเปอร์สเปกตรัมจาก UAV
11	Predicting Agriculture Yields Based on Machine Learning Using Regression and Deep Learning (Sharma, Dadheech et al. 2023)	journal	ใช้การผสมผสานระหว่างการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกเพื่อให้ผลลัพธ์ที่มีความแม่นยำสูงในการทำนายผลผลิตทางการเกษตร	ความซับซ้อนของแบบจำลองที่ใช้ต้องการข้อมูลจำนวนมากและมีคุณภาพสูงเพื่อให้ผลลัพธ์ที่แม่นยำ	ใช้อัลกอริทึมการเรียนรู้ของเครื่อง ได้แก่ Decision Tree, Random Forest, และ XGBoost รวมถึงเทคนิคการเรียนรู้เชิงลึก ได้แก่ Convolutional Neural Network และ Long Short-Term Memory Network เพื่อนำเสนอผลลัพธ์การทำนายผลผลิตทางการเกษตร

Linear Regression-Based Prediction Model For Real Estate Properties in India

(Verma, Singh et al. 2023)

งานวิจัยนี้นำเสนอแบบจำลองการพยากรณ์ราคาที่อยู่อาศัยในประเทศอินเดียโดยใช้วิธีการทางการเรียนรู้ของเครื่อง (Machine Learning) โดยมุ่งเน้นที่การถดถอยเชิงเส้น (Linear Regression) ซึ่งมีประสิทธิภาพสูงสุดในการพยากรณ์ราคาที่อยู่อาศัย นอกจากนี้ยังได้มีการใช้เทคนิคการเข้ารหัสค่าเฉลี่ยเป้าหมาย (Mean Target Encoding) เพื่อเพิ่มประสิทธิภาพของแบบจำลอง

ราคาที่อยู่อาศัยเป็นหัวข้อที่ได้รับความนิยมมากเนื่องจากมีผลกระทบต่อเสถียรภาพทางเศรษฐกิจและสังคมของอินเดีย การพยากรณ์ราคาที่อยู่อาศัยช่วยในการวางแผนการลงทุนและลดความเสี่ยง นอกจากนี้ยังช่วยรัฐบาลในการควบคุมราคาอสังหาริมทรัพย์

งานวิจัยนี้ใช้ข้อมูลการทำธุรกรรมอสังหาริมทรัพย์ในอินเดีย รวมถึงคุณลักษณะต่าง ๆ เช่น จำนวนห้องนอน ขนาดพื้นที่ และที่ตั้ง โดยมีการทำความสะอาดข้อมูล การปรับขนาดข้อมูล และการแบ่งข้อมูลสำหรับการฝึกและทดสอบ แบบจำลองการถดถอยเชิงเส้นและ Grid Search CV ถูกนำมาใช้เพื่อหาค่าพารามิเตอร์ที่ดีที่สุดสำหรับแบบจำลอง

ผลการวิจัยแบบจำลองการถดถอยเชิงเส้นและ Grid Search CV แสดงให้เห็นถึงประสิทธิภาพสูงในการพยากรณ์ราคาที่อยู่อาศัย โดยผลการวิจัยยืนยันว่าเทคนิคเหล่านี้มีคุณค่าในอุตสาหกรรมอสังหาริมทรัพย์

สรุปการใช้เทคนิคการเรียนรู้ของเครื่องสามารถช่วยให้การตัดสินใจซื้อและขายอสังหาริมทรัพย์มีความรอบคอบมากขึ้น โดยการวิเคราะห์คุณลักษณะต่าง ๆ ของข้อมูลที่อยู่อาศัยจะสามารถพยากรณ์ราคาที่เหมาะสมได้ ซึ่งจะช่วยลดความเสี่ยงในการลงทุนและเพิ่มความโปร่งใสในตลาดอสังหาริมทรัพย์ พบว่าแบบจำลองนี้มีความแม่นยำสูงถึง 98.6%


Time Series Prediction of Agricultural Products Price Based on Time Alignment of Recurrent Neural Networks (Kurumatani 2018)

งานวิจัยนี้เสนอระบบการพยากรณ์ราคาผลิตภัณฑ์การเกษตรแบบอนุกรมเวลา (Time Series) โดยใช้โครงข่ายประสาทเทียมแบบเวียน (Recurrent Neural Networks) และการจัดการเวลา จุดประสงค์ของระบบนี้คือเพื่อสร้างเสถียรภาพในการเคลื่อนไหวของราคาโดยการแบ่งปันข้อมูลระหว่างผู้ผลิตและผู้บริโภคของผลิตภัณฑ์

เพื่อแก้ปัญหาเหล่านี้ งานวิจัยนี้เสนอกรอบงาน "การแบ่งปันข้อมูลระหว่างผู้ผลิตและผู้บริโภค" ซึ่งทั้งผู้ผลิตและผู้บริโภคสามารถเข้าถึงข้อมูลเกี่ยวกับการค้าผลิตภัณฑ์การเกษตร เช่น สถานะปัจจุบันและประวัติการเจริญเติบโตของพืชที่ปลูก การพยากรณ์สภาพอากาศ ความสมดุลของ อุปสงค์ และอุปทาน ความนิยมของผลิตภัณฑ์เฉพาะ และการพยากรณ์ราคาของผลิตภัณฑ์ ส่วนหนึ่งที่สำคัญที่สุดของกรอบงานนี้คือการพยากรณ์ราคาของผลิตภัณฑ์การเกษตรหากผู้ผลิตและผู้บริโภคสามารถแบ่งปันข้อมูลราคากันได้ การเคลื่อนไหวของราคาสามารถคาดหวังให้มีเสถียรภาพมากขึ้น

ระบบพยากรณ์ราคาผลิตภัณฑ์เกษตรนี้ใช้โครงข่ายประสาทเทียมแบบวนซ้ำ (RNN) และการจัดแนวเวลา เพื่อให้การเคลื่อนไหวของราคามีความเสถียรโดยแบ่งปันข้อมูลราคา ระหว่างผู้ผลิตและผู้บริโภค ผลลัพธ์ที่ได้จะถูกประเมินไม่เพียงแต่ความแม่นยำเท่านั้น แต่ยังรวมถึงการกระจายตัวของความน่าจะเป็นของการเคลื่อนไหวของราคา

ในการพยากรณ์ราคาผลิตภัณฑ์เกษตร ระบบจะใช้ข้อมูลราคาผลิตภัณฑ์ในอดีตเพื่อฝึกโครงข่ายประสาทเทียมแบบวนซ้ำ (RNN) โดยใช้การจัดแนวเวลาในการสร้างแบบจำลองที่สามารถพยากรณ์ราคาที่จุดเวลาเฉพาะในอนาคต การฝึกแบบจำลองจะครอบคลุมทั้งการพยากรณ์ระยะสั้นและระยะยาว ซึ่งผลลัพธ์ที่ได้จะถูกเปรียบเทียบกับข้อมูลจริง เพื่อประเมินความแม่นยำและประสิทธิภาพของแบบจำลองในการจับแนวโน้มและการเปลี่ยนแปลงของราคาผลิตภัณฑ์เกษตรอย่างถูกต้อง



ภาพ 7 คาดการณ์ราคาในอนาคตโดยตัวทำนายอนุกรมเวลา LSTM (Kurumatani 2018)

สรุปการใช้โครงข่ายประสาทเทียมแบบวนซ้ำเพื่อพยากรณ์ราคาผลิตภัณฑ์เกษตร สามารถจับความซับซ้อนของข้อมูลและแนวโน้มตามฤดูกาลได้ดีในภาพ 6 อย่างไรก็ตาม การฝึกและการปรับปรุงประสิทธิภาพของแบบจำลองยังต้องการการวิจัยเพิ่มเติมเพื่อลดความเสี่ยงต่อการเกิด Overfitting และเพิ่มความแม่นยำในการพยากรณ์

Forecasting Vegetation Behavior Based on PlanetScope Time Series Data Using RNN-Based Models(Marsetič and Kanjir 2024)

งานวิจัยนี้มีวัตถุประสงค์เพื่อทำนายพฤติกรรมของพืชพรรณโดยใช้ข้อมูลภาพถ่ายดาวเทียม PlanetScope และแบบจำลองที่ใช้การเรียนรู้เชิงลึกประเภท Recurrent Neural Network (RNN) ซึ่งรวมถึงแบบจำลอง RNN ง่ายๆ (SRNN), Long Short-Term Memory (LSTM), และ Gated Recurrent Unit (GRU) ข้อมูลที่ใช้ในการศึกษาคือค่าดัชนีพืชพรรณแบบต่างๆ (Normalized Difference Vegetation Index – NDVI) จากภาพถ่ายดาวเทียมที่ได้จากช่วงเวลาต่างๆ ระหว่างเดือนเมษายน 2017 ถึงเดือนมกราคม 2023 โดยเฉพาะอย่างยิ่งแบบจำลอง SRNN ได้แสดงให้เห็นถึงความแม่นยำสูงสุดในการทำนายพฤติกรรมของพืชพรรณ

Method	RMSE train	RMSE test
SRNN	0.012	0.051
LSTM	0.032	0.093
GRU	0.025	0.065
Conv1D	0.013	0.053
RF	0.015	0.084
ARIMA	0.039	0.088


ภาพ 8 ตารางแสดง ค่า Error Rate

จากภาพ 6 ตารางผลการศึกษาแสดงให้เห็นว่าแบบจำลอง SRNN สามารถทำนายค่าดัชนี NDVI ได้อย่างแม่นยำ โดยมีค่า RMSE (Root Mean Square Error) เฉลี่ยอยู่ที่ 0.051 เมื่อเปรียบเทียบกับค่าจริงในปี 2022 แบบจำลอง SRNN ให้ผลทำนายที่ดีในทุกเดือน ยกเว้นช่วงฤดูใบไม้ร่วงที่มักจะประเมินค่าดัชนี NDVI ต่ำกว่าความเป็นจริง การศึกษายังได้เปรียบเทียบผลลัพธ์กับข้อมูล NDVI จาก Sentinel-2 และข้อมูลสภาพภูมิอากาศ (อุณหภูมิและปริมาณน้ำฝน) พบว่าความแตกต่างส่วนใหญ่เกิดจากการเปลี่ยนแปลงทางสภาพอากาศที่ไม่เป็นไปตามปกติในช่วงเวลาที่ศึกษา

ผลการวิจัยสรุปได้ว่าแบบจำลอง SRNN มีความสามารถในการทำนายพฤติกรรมของพืชพรรณได้อย่างมีประสิทธิภาพ และสามารถปรับปรุงได้โดยการรวมข้อมูลสภาพภูมิอากาศเข้าไปในกระบวนการทำนาย การศึกษานี้ยังชี้ให้เห็นว่าแบบจำลองการเรียนรู้เชิงลึกมีศักยภาพสูงในการนำมาใช้ในการทำนายพฤติกรรมของพืชพรรณและสามารถนำไปใช้ในการจัดการและอนุรักษ์ทรัพยากรธรรมชาติได้อย่างมีประสิทธิภาพ

Crop Yield Prediction Using Deep Reinforcement Learning Model for Sustainable Agrarian Applications (Elavarasan and Vincent 2020)

งานวิจัยนี้มุ่งเน้นการทำนายผลผลิตทางการเกษตรโดยใช้แบบจำลองการเรียนรู้เชิงลึกแบบเสริมแรง (Deep Reinforcement Learning – DRL) สำหรับการประยุกต์ใช้ในภาคการเกษตรที่ยั่งยืน แบบจำลองที่พัฒนาขึ้นคือ Deep Recurrent Q-Network (DRQN) ซึ่งเป็นการรวมเอาอัลกอริทึม Recurrent Neural Network (RNN) เข้ากับ Q-Learning เพื่อสร้างกรอบการทำงานที่สามารถแปลงข้อมูลดิบไปสู่ค่าทำนายผลผลิตได้อย่างมีประสิทธิภาพ ข้อมูลที่ใช้ในการศึกษารวมถึงปัจจัยทางสิ่งแวดล้อม ดิน น้ำ และพืช แสดงในภาพ 8



ภาพ 9 แผนภาพการทำงานของ Deep Recurrent Q-Network (Elavarasan and Vincent 2020)

Model	Training Dataset				Validation Dataset			
	MAE	MSE	RMSE	R ²	MAE	MSE	RMSE	R ²
Deep Reinforcement Learning	0.19	0.02	0.14	0.8	0.13	0.03	0.17	0.87
Deep Learning	0.19	0.07	0.25	0.61	0.18	0.05	0.22	0.68
Artificial Neural Network	0.28	0.09	0.35	0.68	0.22	0.09	0.37	0.62
Random forest	0.6	0.63	0.79	0.22	0.62	0.51	0.72	0.37
Gradient Boosting	0.48	0.31	0.64	0.49	0.41	0.28	0.53	0.54


ภาพ 10 ตัวชี้วัดการประเมินผลการศึกษา

ผลการศึกษาในภาพ 9 แสดงให้เห็นว่าแบบจำลอง DRQN สามารถทำนายผลผลิตพืชได้อย่างแม่นยำ ด้วยความแม่นยำถึง 93.7% โดยที่แบบจำลองสามารถแสดงให้เห็นถึงความสามารถในการรักษาคุณสมบัติการกระจายตัวของข้อมูลเดิมได้เป็นอย่างดี ทั้งนี้ การทดสอบประสิทธิภาพของแบบจำลองได้ถูกเปรียบเทียบกับแบบจำลองอื่น ๆ เช่น Deep LSTM, ANN, Gradient Boosting และ Random Forest ซึ่งผลการทดสอบแสดงให้เห็นว่าแบบจำลอง DRQN มีความสามารถในการทำนายที่ดีกว่าแบบจำลองอื่น ๆ ที่ถูกทดสอบ


งานวิจัยนี้ยังระบุถึงข้อดีของการใช้ DRL ในการทำนายผลผลิตพืชว่า สามารถลดการพึ่งพาความเชี่ยวชาญของผู้เชี่ยวชาญและความรู้ล่วงหน้าในการพัฒนาแบบจำลองทำนายผลผลิต นอกจากนี้ ยังชี้ให้เห็นว่าการปรับปรุงประสิทธิภาพการคำนวณของกระบวนการฝึกอบรมเป็นสิ่งที่น่าสนใจที่จะมุ่งเน้นในอนาคต รวมถึงการสำรวจพารามิเตอร์การทำนายผลผลิตเพิ่มเติม เช่น การติดเชื้อของแมลงและความเสียหายของพืชเพื่อสร้างแบบจำลองการทำงานที่แข็งแกร่งขึ้น

An Analysis of Recurrent Neural Network variants to predict yield of Wheat crop in Punjab region (Bali and Singla 2021)


งานวิจัยนี้มุ่งเน้นการวิเคราะห์และทำนายผลผลิตข้าวสาลีในภูมิภาคปัญจาบ ประเทศอินเดีย โดยใช้แบบจำลอง Recurrent Neural Network (RNN) และรูปแบบต่างๆ ของ RNN ได้แก่ Simple RNN ภาพ 10 LSTM ภาพ 11 และ GRU ภาพ 12



ภาพ 11 ฟังก์ชันการทำงาน Basic RNN



ภาพ 12 ฟังก์ชันการทำงานของ LSTM



ภาพ 13 ฟังก์ชันการทำงานของ GRU neuron

โดยข้อมูลที่ใช้ในการศึกษารวบรวมจากข้อมูลสภาพอากาศ และผลผลิตทางการเกษตรที่บันทึกไว้เป็นเวลา 50 ปี ตั้งแต่ปี 1970 ถึงปี 2019 จากแหล่งข้อมูลของรัฐบาลปัญจาบ และแผนกอุตุนิยมวิทยา การศึกษานี้มุ่งเป้าหมายเพื่อพัฒนาความแม่นยำในการทำนายผลผลิตข้าวสาลีซึ่งเป็นพืชหลักที่มีความสำคัญในภูมิภาคนี้

Layers	Simple RNN			RNN with LSTM			RNN with GRU		
	RMSE	MSE	MAE	RMSE	MSE	MAE	RMSE	MSE	MAE
1	431	1.85E+05	364	668	4.47E+05	649	671	4.51E+05	648
2	1399	1.95E+06	1340	695	4.84E+05	679	704	4.96E+05	509
3	1599	2.55E+06	1501	555	3.08E+05	481	654	4.28E+05	602
4	362	1.31E+05	343	47	0.22E+03	36	356	1.27E+05	309
5	1305	1.70E+06	1262	241	5.83E+04	228	903	8.17E+05	692

ภาพ 14 ตารางเปรียบเทียบผลการทำงานแบบจำลอง(Bali and Singla 2021)


ภาพ 13 แสดงการเปรียบเทียบผลการทดลอง จะเห็นว่า แบบจำลอง RNN ที่ใช้ LSTM มีประสิทธิภาพสูงสุดในการทำนายผลผลิตข้าวสาลีเมื่อเทียบกับแบบจำลองอื่นๆ โดยมีค่าความแม่นยำสูงสุดในการทำนายเนื่องจาก LSTM มีความสามารถในการจดจำแนวโน้มระยะยาวจากข้อมูลในอดีต นอกจากนี้ยังพบว่า การเพิ่มจำนวนชั้นซ่อนในแบบจำลอง RNN มีผลต่อความแม่นยำในการทำนาย ซึ่งแบบจำลองที่มี 4 ชั้นซ่อนให้ผลลัพธ์ที่ดีที่สุดสำหรับทุกแบบจำลอง

งานวิจัยสรุปว่า การใช้แบบจำลอง RNN โดยเฉพาะแบบ LSTM และ GRU มีศักยภาพสูงในการทำนายผลผลิตข้าวสาลีในภูมิภาคปัญจาบ อย่างไรก็ตามยังมีความท้าทายเรื่อง vanishing gradient ที่ส่งผลต่อความแม่นยำในบางช่วงเวลา การศึกษาต่อไปอาจมุ่งเน้นการเพิ่มประสิทธิภาพของแบบจำลองโดยการปรับแต่งพารามิเตอร์และเพิ่มข้อมูลสภาพอากาศที่หลากหลายขึ้น เพื่อเพิ่มความแม่นยำในการทำนายผลผลิตของพืชในอนาคต

Deep-LSTM Model for Wheat Crop Yield Prediction in India (Saini and Nagpal 2022)

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบทำนายผลผลิตข้าวสาลีในอินเดียโดยใช้แบบจำลอง Deep Long Short-Term Memory (Deep-LSTM) แสดงในภาพที่ 14 ซึ่งเป็นวิธีการเรียนรู้เชิงลึกที่มีประสิทธิภาพสูงในการจัดการข้อมูลเชิงลำดับเวลา ข้อมูลที่ใช้ในการศึกษานี้รวบรวมจากข้อมูลผลผลิตข้าวสาลีตั้งแต่ปี 1950 ถึงปี 2019 โดยใช้ตัวชี้วัดทางสถิติเช่น Root

Mean Square Error (RMSE) และ Mean Square Error (MSE) เพื่อประเมินความแม่นยำของแบบจำลองและเปรียบเทียบกับวิธีการทำนายผลผลิตแบบอื่น ๆ เช่น Gaussian Process Regression (GPR) และ Holt–Winter Time Series Method



ภาพ 15 ผังการทำงานของ Deep-LSTM (Saini and Nagpal 2022)

Model	RMSE	MSE
Deep-LSTM	0.20	0.11
GPR	0.51	0.26
Holt Winter	0.61	0.37

ภาพ 16 ตารางเปรียบเทียบผลการทำงาน Deep-LSTM กับโมเดลต่างๆ

ผลการศึกษาพบว่าแบบจำลอง Deep-LSTM มีค่าความแม่นยำสูงที่สุดในการทำนายผลผลิตข้าวสาลี โดยมีค่า RMSE ต่ำสุดที่ 0.20 เมื่อเปรียบเทียบกับ GPR และ Holt–Winter ที่มีค่า RMSE อยู่ที่ 0.51 และ 0.61 ตามลำดับ นอกจากนี้ แบบจำลองยังสามารถทำนายแนวโน้มการเติบโตของผลผลิตในปีถัดไปได้เป็นอย่างดีมีประสิทธิภาพ การศึกษานี้ได้แสดงให้เห็นว่าเทคนิคการเรียนรู้เชิงลึกสามารถค้นหารูปแบบที่ไม่เชิงเส้นในข้อมูลจริงได้ดี ซึ่งช่วยเพิ่มประสิทธิภาพในการทำนายผลผลิต

การวิจัยนี้มีความสำคัญต่อเกษตรกรและผู้วางนโยบายในการตัดสินใจเกี่ยวกับการปลูกพืชและการจัดการทรัพยากรทางการเกษตร ผลการศึกษานี้ให้เห็นว่าการใช้แบบจำลอง Deep-LSTM สามารถปรับปรุงการทำนายผลผลิตข้าวสาลีได้อย่างมีนัยสำคัญ และในอนาคต

สามารถเพิ่มประสิทธิภาพโดยใช้ข้อมูลเพิ่มเติมและเทคนิคการเรียนรู้เชิงลึกแบบไฮบริดเพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของแบบจำลอง

Interpretable Long Short-Term Memory Networks for Crop Yield Estimation
(Mateo-Sanchis, Aduara et al. 2023)

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและทดสอบแบบจำลอง Long Short-Term Memory (LSTM) ที่สามารถทำนายผลผลิตพืชได้อย่างมีประสิทธิภาพ โดยใช้ข้อมูลจากดาวเทียมหลายแหล่งและข้อมูลสภาพอากาศในพื้นที่สหรัฐอเมริกา แบบจำลองนี้ถูกออกแบบมาเพื่อให้มีความสามารถในการอธิบายการคาดการณ์เพื่อสนับสนุนการตัดสินใจในภาคเกษตรกรรม งานวิจัยนี้ได้ใช้ข้อมูลผลผลิตของข้าวโพด ถั่วเหลือง และข้าวสาลีจากกระทรวงเกษตรของสหรัฐอเมริกา โดยใช้วิธีการอธิบายแบบบูรณาการ (Integrated Gradients) และค่าสแชพลีย์ (Shapley Values) เพื่อทำความเข้าใจการเรียนรู้ของแบบจำลอง

Crop	N	Var. Comb	HU	R	R ²	RMSE
Corn	1744	EVI	2	0.71	0.50	1.47
			5	0.75	0.56	1.38
			10	0.74	0.55	1.42
		EVI+SM+TMX	15	0.74	0.55	1.43
			2	0.72	0.52	1.48
			5	0.77	0.59	1.34
			10	0.78	0.61	1.32
			15	0.77	0.59	1.33
Soy	2060	EVI	2	0.78	0.61	1.42
			5	0.79	0.62	1.40
			10	0.80	0.64	1.38
		EVI+VOD+TMX	15	0.79	0.62	1.40
			2	0.76	0.58	1.52
			5	0.81	0.66	1.34
			10	0.82	0.67	1.33
			15	0.83	0.69	1.28
Wheat	1036	EVI	2	0.77	0.59	1.33
			5	0.79	0.62	1.30
			10	0.77	0.59	1.31
		EVI+VOD+TMX	15	0.79	0.62	1.32
			2	0.56	0.31	1.74
			5	0.74	0.55	1.42
			10	0.80	0.64	1.26
			15	0.81	0.66	1.25


ภาพ 17 ตารางเปรียบเทียบผลการทำงานของแต่ละอัลกอริทึม (Mateo-Sanchis, Aduara et al. 2023)

ผลการศึกษพบว่าแบบจำลอง LSTM มีความแม่นยำสูง ($R^2 > 0.56$) และการใช้ข้อมูลจากหลายแหล่งช่วยเพิ่มความแม่นยำในการทำนายมากกว่าแบบจำลองที่ใช้ข้อมูลเพียงแหล่งเดียว นอกจากนี้ วิธีการอธิบายทั้งสองแบบที่ใช้ในการศึกษามีความสามารถเทียบเท่ากันในการตรวจสอบปัจจัยที่สำคัญและการมีส่วนร่วมของปัจจัยต่างๆ ในการทำนายผลผลิต ผลการศึกษายังชี้ให้เห็นว่า ดัชนีพืชพรรณ (EVI) และความลึกทางแสงของพืช (VOD) จากดาวเทียม พร้อมกับข้อมูลอุณหภูมิสูงสุด (TMX) เป็นปัจจัยที่สำคัญที่สุดในการทำนายผลผลิตพืช

การศึกษานี้เน้นย้ำถึงความสำคัญของการใช้แบบจำลองเชิงลึกที่สามารถอธิบายการตัดสินใจได้ในภาคเกษตรกรรม โดยแบบจำลองที่พัฒนาขึ้นสามารถระบุช่วงเวลาที่สำคัญของการเจริญเติบโตของพืชและปัจจัยสิ่งแวดล้อมที่เกี่ยวข้อง ซึ่งสามารถนำไปใช้ในการจัดการทรัพยากรทางการเกษตรได้อย่างมีประสิทธิภาพ นอกจากนี้ ผลการศึกษายังเสนอแนวทางในการปรับปรุงแบบจำลองด้วยการใช้ข้อมูลจากหลายแหล่งและวิธีการอธิบายเพิ่มเติมในอนาคตเพื่อเพิ่มความแม่นยำและความน่าเชื่อถือของการทำนายผลผลิตพืช

Crop Recommendation System using Antlion Optimization and Decision Tree Algorithm (Avanija, Ambati et al. 2024)

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาระบบแนะนำพืชที่เหมาะสมสำหรับการเพาะปลูก โดยใช้การผสมผสานระหว่างอัลกอริทึม Antlion Optimization (ALO) และ Decision Tree (DT) เพื่อให้คำแนะนำที่แม่นยำและมีประสิทธิภาพ ระบบนี้ถูกฝึกด้วยชุดข้อมูลจาก Kaggle ซึ่งประกอบด้วยข้อมูลเกี่ยวกับดินและสภาพอากาศในอดีต การใช้ ALO ช่วยในการปรับแต่งพารามิเตอร์สำหรับ Decision Tree เพื่อให้ได้ผลลัพธ์ที่ดีที่สุด ระบบแนะนำพืชนี้มุ่งเน้นให้เกษตรกรสามารถตัดสินใจได้อย่างมีข้อมูลและเพิ่มผลผลิตทางการเกษตร



ภาพ 18 กราฟเปรียบเทียบสมรรถนะการทำงานในโมเดลที่แตกต่างกัน

ผลการศึกษาพบว่า แบบจำลอง ALO-DT มีความแม่นยำสูงถึง 98.86% ซึ่งสูงกว่าแบบจำลองอื่น ๆ ที่ถูกนำมาเปรียบเทียบ เช่น Decision Tree แบบปกติ, KNN, Random Forest และ Neural Network การผสมผสานระหว่าง ALO และ DT ช่วยให้ระบบสามารถสำรวจพื้นที่การค้นหได้อย่างทั่วถึงและหาพารามิเตอร์ที่เหมาะสมที่สุดสำหรับการสร้าง Decision Tree นอกจากนี้ ผลการทดสอบยังแสดงให้เห็นถึงความแม่นยำสูงในการทำนายพืชที่เหมาะสมสำหรับการเพาะปลูกในสภาพแวดล้อมต่าง ๆ

การศึกษานี้ชี้ให้เห็นถึงศักยภาพของการใช้เทคนิคการเพิ่มประสิทธิภาพด้วยอัลกอริทึมทางธรรมชาติร่วมกับการเรียนรู้ของเครื่องในการพัฒนาระบบแนะนำพืชที่มีความแม่นยำสูง การนำเสนอระบบที่ผสมผสาน ALO กับ DT ช่วยเพิ่มความน่าเชื่อถือและความแข็งแกร่งในการทำนายผลผลิตพืช งานวิจัยนี้มีความสำคัญต่อการพัฒนาการเกษตรที่ยั่งยืน และในอนาคตสามารถขยายการใช้งานด้วยการรวมข้อมูลสภาพอากาศและดินแบบเรียลไทม์เพื่อเพิ่มความแม่นยำในการทำนายมากยิ่งขึ้น

Application of an Ensemble Method Based on XGBoost and Transformer in Predicting Sugarcane and Dragon Fruit Yields in Guangxi Region (Jing and Bingxiang 2024)

งานวิจัยนี้มุ่งเน้นการทำนายผลผลิตอ้อยและแก้วมังกรในเขต Guangxi โดยใช้วิธีการผสมผสานระหว่างอัลกอริทึม XGBoost และ Transformer ซึ่งถูกออกแบบมาเพื่อให้สามารถทำนายผลผลิตได้อย่างแม่นยำโดยพิจารณาความสัมพันธ์เชิงซับซ้อนระหว่างปัจจัยทางภูมิอากาศ เช่น อุณหภูมิ ความชื้น และปริมาณน้ำฝน ระบบนี้ใช้ข้อมูลทางภูมิอากาศและผลผลิตที่สะสมมาเป็นเวลาสี่สิบปี (2000–2022) เพื่อสร้างและทดสอบแบบจำลองการทำนาย


ผลการศึกษาพบว่า แบบจำลองผสมผสานระหว่าง XGBoost และ Transformer สามารถทำนายผลผลิตอ้อยและแก้วมังกรได้อย่างมีประสิทธิภาพและความแม่นยำสูง โดยมีค่า R^2 สูงกว่า 0.90 ในการทดสอบทุกปีตั้งแต่ 2019 ถึง 2022 แบบจำลองนี้สามารถจับความสัมพันธ์เชิงเวลาของข้อมูลทางภูมิอากาศและผลผลิตได้ดี ทั้งยังแสดงให้เห็นว่ามีความมั่นคงและความสามารถในการปรับตัวต่อข้อมูลใหม่ๆ

วิธีการผสมผสานนี้ไม่เพียงแต่สามารถนำไปใช้ในการทำนายผลผลิตในเขต Guangxi เท่านั้น แต่ยังสามารถปรับใช้ในภูมิภาคและพืชอื่นๆ ได้ด้วย นอกจากนี้ยังมีศักยภาพในการสนับสนุนการวางแผนการเกษตร การจัดการความเสี่ยง และการพัฒนาที่ยั่งยืนในภาคการเกษตร ผลการศึกษายังระบุว่าในอนาคต การเพิ่มข้อมูลทางภูมิอากาศและพารามิเตอร์อื่นๆ อาจช่วยเพิ่มประสิทธิภาพและความแม่นยำในการทำนายมากยิ่งขึ้น


ในการประยุกต์ใช้ผลการวิจัยสามารถใช้วิธีการรวมโมเดล (Ensemble Model) โดยนำ XGBoost ที่มีความสามารถในการทำนายข้อมูลที่ไม่เป็นเชิงเส้นและซับซ้อน ร่วมกับ Transformer ที่มีความสามารถในการวิเคราะห์รูปแบบเชิงเวลาในข้อมูลอนุกรมวิธาน เพื่อสร้างโมเดลที่สามารถคาดการณ์ผลผลิตและราคาของอ้อยและแก้วมังกรได้อย่างแม่นยำและมีความเสถียรสูง การใช้วิธีนี้จะช่วยเพิ่มความแม่นยำในการคาดการณ์และช่วยสนับสนุนการตัดสินใจในกระบวนการเกษตรและการบริหารความเสี่ยงของผู้ผลิตอ้อยและแก้วมังกรได้อย่างมีประสิทธิภาพ

Integration of Crop Growth Model and Random Forest for Winter Wheat Yield Estimation From UAV Hyperspectral Imagery (Yang, Hu et al. 2021)

งานวิจัยนี้มีจุดประสงค์เพื่อพัฒนาแบบจำลองการทำนายผลผลิตข้าวสาลีฤดูหนาวโดยผสานแบบจำลองการเติบโตของพืช CERES-Wheat กับอัลกอริทึม Random Forest และใช้ข้อมูลภาพถ่ายไฮเปอร์สเปกตรัมจาก UAV ภาพ 18 งานวิจัยนี้ใช้ข้อมูลจากสถานีการทดลองในเมืองหลัวเหอ มณฑลเหอหนาน ประเทศจีน โดยใช้ข้อมูลสภาพอากาศ ดิน พันธุ์ข้าวสาลี และการจัดการฟาร์ม เพื่อสร้างชุดข้อมูลจำลองที่ใช้ในการฝึกและทดสอบแบบจำลองการทำนายผลผลิตข้าวสาลี



ภาพ 19 ภาพผสมสีจริงตามข้อมูลไฮเปอร์สเปกตรัมของ UAV (a) Jointing stage. (b) Heading stage (Yang, Hu et al. 2021)



ภาพ 20 แผนผังแนวคิดสำหรับการประมาณผลผลิตข้าวสาลีฤดูหนาวโดยอิงจากการบูรณาการแบบจำลอง CERES-ข้าวสาลีและอัลกอริทึมของฟอเรสต์แบบสุ่ม (Yang, Hu et al. 2021)

ผลการศึกษาแสดงให้เห็นว่า แบบจำลอง CW-RF (Crop Growth Model and Random Forest) สามารถทำนายผลผลิตข้าวสาลีได้อย่างแม่นยำ โดยค่าความคลาดเคลื่อนเฉลี่ยของการทำนายผลผลิตอยู่ที่ 9.36% และค่า RMSE อยู่ที่ 1008.08 กิโลกรัมต่อเฮกตาร์ การตรวจสอบผลลัพธ์การทำนายพบว่าค่าที่ได้ใกล้เคียงกับค่าจริงที่วัดได้ นอกจากนี้ แบบจำลองยังสามารถประเมินค่าพารามิเตอร์การเจริญเติบโตของข้าวสาลี เช่น ดัชนีพื้นที่ใบ (LAI) และปริมาณไนโตรเจนในใบ (LNC) ได้อย่างแม่นยำจากข้อมูลภาพถ่ายไฮเปอร์สเปกตรัมของ UAV

การวิจัยนี้เน้นย้ำถึงความสำคัญของการใช้ UAV ในการเก็บข้อมูลภาพถ่ายที่มีความละเอียดสูง เพื่อเพิ่มความแม่นยำในการทำนายผลผลิตทางการเกษตร นอกจากนี้ยังชี้ให้เห็นว่าการผสานแบบจำลองการเติบโตของพืชเข้ากับอัลกอริทึมการเรียนรู้ของเครื่องสามารถช่วยแก้ไขปัญหาการขาดแคลนข้อมูลการวัดภาคสนาม และลดความไม่แน่นอนในการทำนายผลผลิต การทดลองใช้ในพื้นที่ต่าง ๆ แสดงให้เห็นถึงความสามารถในการปรับตัวของแบบจำลอง และความเป็นไปได้ที่จะนำไปใช้ในการทำนายผลผลิตพืชในภูมิภาคอื่น ๆ


สรุปได้ว่า การใช้แบบจำลอง CW-RF ที่ผสานข้อมูลจากการจำลองและข้อมูลจากการสำรวจด้วย UAV สามารถช่วยเพิ่มความแม่นยำในการทำนายผลผลิตข้าวสาลี ซึ่งมีความสำคัญต่อการจัดการทรัพยากรทางการเกษตรและการวางแผนการผลิตในอนาคต งานวิจัยนี้ยังชี้ให้เห็นว่าการใช้เทคโนโลยีไฮเปอร์สเปกตรัมและ UAV สามารถนำไปสู่การพัฒนาแบบทำนายผลผลิตที่มีประสิทธิภาพและน่าเชื่อถือมากยิ่งขึ้นในอนาคต

ผลการวิจัยนี้สามารถนำไปประยุกต์ใช้ได้โดยใช้โมเดล Random Forest ร่วมกับข้อมูลไฮเปอร์สเปกตรัมจาก UAV ในการเก็บข้อมูลต่างๆ เช่น ดัชนีพืชพันธุ์และเนื้อหาไนโตรเจนของใบพืชที่มีผลต่อผลผลิตครั้ง นอกจากนี้ ยังสามารถใช้แบบจำลองการเจริญเติบโตของพืชเพื่อจำลองข้อมูลการเจริญเติบโตของครั้งและฝึกโมเดลคาดการณ์ ซึ่งจะช่วยให้สามารถคาดการณ์ผลผลิตและราคาของครั้งได้อย่างแม่นยำมากขึ้น การใช้เทคโนโลยีนี้จะช่วยให้ผู้ผลิตครั้งสามารถตัดสินใจและวางแผนการเพาะปลูกและการขายได้ดียิ่งขึ้น


Predicting Agriculture Yields Based on Machine Learning Using Regression and Deep Learning (Sharma, Dadheech et al. 2023)

การเกษตรมีความสำคัญอย่างยิ่งต่อเศรษฐกิจของอินเดีย โดยเฉพาะอย่างยิ่งเพื่อความมั่นคงทางอาหาร การทำนายผลผลิตพืชเป็นเครื่องมือสนับสนุนการตัดสินใจที่ใช้เทคโนโลยีการเรียนรู้ของเครื่อง (Machine Learning) และการเรียนรู้เชิงลึก (Deep Learning) ในการวิจัยนี้ใช้เทคนิคการเรียนรู้ของเครื่องเช่น Decision Tree, Random Forest และ XGBoost regression และเทคนิคการเรียนรู้เชิงลึกเช่น Convolutional Neural Network (CNN) และ Long-Short Term Memory Network (LSTM) เพื่อทำนายผลผลิตพืช ผลการทดสอบพบว่า Random Forest และ CNN มีประสิทธิภาพดีที่สุด โดย Random Forest มีความแม่นยำสูงสุด 98.96% และ CNN มีการสูญเสียที่น้อยที่สุดที่ 0.00060

การเกษตรมีบทบาทสำคัญในการจัดหาอาหารและสนับสนุนเศรษฐกิจ การเพิ่มผลผลิตพืชเป็นสิ่งจำเป็นเนื่องจากการเพิ่มจำนวนประชากรและการเปลี่ยนแปลงสภาพภูมิอากาศ การใช้เทคโนโลยีสมัยใหม่และการพัฒนาเทคนิคการเกษตรที่มีประสิทธิภาพมากขึ้นเป็นสิ่งจำเป็น การทำนายผลผลิตพืชช่วยให้เกษตรกรสามารถตัดสินใจได้อย่างมีประสิทธิภาพยิ่งขึ้นงานวิจัยนี้มีวัตถุประสงค์เพื่อ พัฒนากลไกที่แข็งแกร่งในการทำนายผลผลิตพืชในอินเดีย โดยใช้ข้อมูลสถิติการผลิตในอดีต วิเคราะห์และเปรียบเทียบประสิทธิภาพของเทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก




ภาพ 21 การผลิตพืชผลตามฤดูกาล (Sharma, Dadheech et al. 2023)



ภาพ 22 ผลผลิตพืชเฉลี่ยต่อปี 2540-2563


อินเดียถูกเลือกเป็นพื้นที่การศึกษาเนื่องจากมีสภาพภูมิอากาศที่หลากหลาย โดยศึกษาผลผลิตพืชหลัก 10 ชนิด ได้แก่ ข้าว, ข้าวสาลี, ข้าวโพด, ฯลฯ ข้อมูลถูกรวบรวมจากเว็บไซต์ทางการของรัฐบาลอินเดีย (<https://data.gov.in> และ <https://aps.dac.gov.in>) ข้อมูลรวมถึงชื่อรัฐ, ชื่อเขต, ปีเพาะปลูก, ฤดูกาล, ประเภทพืช, ปริมาณน้ำฝน, ความเร็วลม, ความชื้น, พื้นที่ชลประทาน, พื้นที่ปลูก, ผลผลิต, และผลผลิตต่อหน่วย




ภาพ 23 K-Fold Cross Validation

เทคนิคที่ใช้

1. K-Fold Cross Validation ใช้การแบ่งข้อมูลเป็น k ชุด โดยในแต่ละรอบการทดสอบ จะใช้ k-1 ชุดเป็นข้อมูลฝึกและ 1 ชุดเป็นข้อมูลทดสอบ
2. Decision Tree: ใช้ในการจัดประเภทและทำนายผลผลิตโดยการสร้างต้นไม้การตัดสินใจ
3. Random Forest: เป็นการรวมต้นไม้การตัดสินใจหลายต้นเข้าด้วยกันเพื่อลดความสับสนระหว่างต้นไม้
4. XGBoost: ใช้การเพิ่มประสิทธิภาพในการทำนายผลผลิตพืชโดยการรวมต้นไม้การตัดสินใจหลายต้น
5. Convolutional Neural Network (CNN): ใช้สำหรับการทำนายผลผลิตพืชโดยมีชั้นข้อมูลหลายชั้น
6. Long-Short Term Memory (LSTM): ใช้สำหรับการจัดการข้อมูลตามลำดับเวลา เช่น ข้อมูลเกี่ยวกับพืชและภูมิอากาศ



ภาพ 24 ผลการทำนาย Random Forest



ภาพ 25 ผลการทำนาย LSTM

การทดสอบพบว่า Random Forest มีความแม่นยำสูงสุด 98.96%, MAE 1.97, RMSE 2.45 และ SD 1.23 CNN มีการสูญเสียที่น้อยที่สุด 0.00060 Decision Tree และ XGBoost มีประสิทธิภาพน้อยกว่า Random Forest

สรุปการใช้เทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกสามารถช่วยในการทำนายผลผลิตพืชได้อย่างแม่นยำ การวิจัยนี้แสดงให้เห็นว่า Random Forest และ CNN เป็นเทคนิคที่มีประสิทธิภาพที่สุดในการทำนายผลผลิตพืชในอินเดีย ข้อมูลเพิ่มเติมและการใช้โมเดลการเรียนรู้เชิงลึกเพิ่มเติมอาจช่วยเพิ่มความแม่นยำในการทำนายผลผลิตพืชได้

สามารถใช้แนวทางการวิเคราะห์ข้อมูลและการคาดการณ์ที่คล้ายกัน โดยการใช้โมเดลการเรียนรู้ของเครื่อง (Machine Learning) เช่น Random Forest และ XGBoost Regression หรือโมเดลการเรียนรู้เชิงลึก (Deep Learning) เช่น Convolutional Neural Networks (CNN) และ Long Short-Term Memory (LSTM) ที่มีประสิทธิภาพในการพยากรณ์ผลผลิตได้อย่างแม่นยำ การใช้โมเดลเหล่านี้สามารถช่วยในการคาดการณ์ผลผลิตของครั้งจากข้อมูลที่เกี่ยวข้อง เช่น อุณหภูมิ ปริมาณน้ำฝน ความชื้น และข้อมูลประวัติการผลิต เพื่อสนับสนุนการตัดสินใจของเกษตรกรในการวางแผนการเพาะปลูกและการจัดการทางการตลาด

นอกจากนี้ การรวบรวมและเตรียมข้อมูลจากหลายแหล่ง เช่น ข้อมูลสภาพอากาศ ข้อมูลราคาครั้งในอดีต และข้อมูลเกี่ยวกับปัจจัยสิ่งแวดล้อมที่มีผลต่อการผลิต สามารถเพิ่มความแม่นยำในการคาดการณ์ได้ การใช้วิธีการตรวจสอบความถูกต้องของแบบจำลอง เช่น การใช้เทคนิคการตรวจสอบแบบไขว้ (Cross-Validation) สามารถช่วยให้มั่นใจว่าโมเดลมีความสามารถในการทำนายที่ดีและมีประสิทธิภาพเมื่อใช้กับข้อมูลที่ไม่เคยเห็นมาก่อน ทำให้ระบบคาดการณ์ผลผลิตและราคาขายครั้งแบบอัตโนมัติมีความน่าเชื่อถือและเป็นประโยชน์ต่อเกษตรกรในการวางแผนการผลิตและการตลาดได้อย่างมีประสิทธิภาพมากขึ้น


จากการทบทวนวรรณกรรม พบว่าโมเดล MA-LSTM และ Random Forest มีศักยภาพสูงในการประมวลผลข้อมูลอนุกรมเวลา (time series) โดยเฉพาะในบริบทของการพยากรณ์ผลผลิตและราคาในภาคเกษตรกรรม งานวิจัยของ Gupta et al. (2022) และ Ye et al. (2022) แสดงให้เห็นว่า MA-LSTM สามารถลดปัญหา vanishing gradient และจับความสัมพันธ์ระยะยาวของข้อมูลได้อย่างมีประสิทธิภาพ ในขณะที่ Random Forest มีความยืดหยุ่นสูงและทนทานต่อข้อมูลที่มี noise หรือ missing value ดังเช่นในงานของ Yang et al. (2021) และ Elavarasan et al. (2020) ดังนั้น งานวิจัยนี้จึงเลือกใช้ MA-LSTM เพื่อการพยากรณ์ระยะสั้นถึงกลาง และ Random Forest เพื่อการตรวจสอบความถูกต้องและช่วยในการตีความเชิงปฏิบัติ โดยหวังว่าจะช่วยให้คำแนะนำที่เหมาะสมแก่เกษตรกร เช่น การวางแผนการเพาะปลูกหรือการตัดสินใจขาย

บทที่ 3

วิธีการดำเนินงานวิจัย

3.1 ภาพรวมการทำงาน (System Overview)

การวิจัยนี้มุ่งเน้นการคาดการณ์ผลผลิตและราคาครั้ง โดยใช้เทคนิคทางการเรียนรู้ของเครื่อง ได้แก่ การลดความผันผวนด้วย Moving Average และการคาดการณ์ด้วยโมเดล LSTM (Long Short-Term Memory) ข้อมูลที่ใช้ในการวิจัยประกอบด้วยข้อมูลสภาพอากาศ ปริมาณการส่งออก ราคา และวันที่ ขั้นตอนการดำเนินงานประกอบด้วย การเก็บรวบรวมข้อมูล การเตรียมข้อมูล การฝึกฝนโมเดล และการทำนายผลผลิตและราคา ตามรายละเอียดดังต่อไปนี้



ภาพ 26 ภาพรวมระบบคาดการณ์

กระบวนการคาดการณ์ผลผลิตครั้งประกอบด้วยสามขั้นตอนหลัก: การกรองข้อมูล (Filtering) ซึ่งข้อมูลปริมาณและเวลาถูกกรองและปรับให้อยู่ในภาพแบบของ Time Series ที่เหมาะสม, การฝึกฝนโมเดล (Model Training) โดยใช้ข้อมูล Time Series Quantity เพื่อฝึกโมเดล MA-LSTM ให้สามารถคาดการณ์ได้อย่างแม่นยำ, และการทำนายผลผลิต (Yield Prediction) โดยใช้โมเดลที่ฝึกฝนแล้วในการทำนายผลผลิตครั้งในอนาคตและแสดงผลลัพธ์ที่สามารถนำไปใช้ในการวิเคราะห์และตัดสินใจในเชิงธุรกิจหรือการเกษตรได้อย่างมีประสิทธิภาพ

3.2 การเก็บรวมข้อมูล (Data Collection)

ขั้นตอนการเก็บรวบรวมข้อมูลเป็นขั้นตอนที่สำคัญ การเก็บรวบรวมข้อมูลในการวิจัยนี้ ประกอบด้วยราคาครั้งย้อนหลัง ปริมาณผลผลิต และสภาพอากาศ จะถูกรวบรวมจากฐานข้อมูลของกรมศุลกากร โดยข้อมูลนี้จะให้รายละเอียดเกี่ยวกับปริมาณครั้งที่ถูกส่งออกในแต่ละช่วงเวลา ซึ่งจะช่วยให้สามารถวิเคราะห์แนวโน้มการผลิตและการส่งออกได้ ข้อมูลราคาครั้ง ข้อมูลราคาครั้งในอดีตจะถูกรวบรวมจากฐานข้อมูลของกรมศุลกากรเช่นกัน โดยข้อมูลนี้จะให้รายละเอียดเกี่ยวกับราคาครั้งที่ถูกซื้อขายในแต่ละช่วงเวลา และในแต่ละประเทศ ซึ่งเป็นข้อมูลสำคัญในการวิเคราะห์แนวโน้มของตลาดและการกำหนดราคาในอนาคต

HS CODE				May 2024	
				Quantity	FOB (BAHT)
13012000	0	KGM	Gum Arabic (KGM)	10,703	1,728,749
13019040	0	KGM	Lac (KGM)	66,320	22,632,277
13019090	1	KGM	Gambier or catechu (KGM)	0	0
13019090	2	KGM	Gumboyie (KGM)	1,510	291,001
13019090	4	KGM	Kobuak powder (KGM)	148,100	3,941,492
13019090	6	KGM	Natural resins, unmodified (KGM)	2,000	490,520
13019090	7	KGM	Gum resins (KGM)	0	0
13019090	8	KGM	Gum benjamin (KGM)	14	31,452
13019090	9	KGM	Gum damar (KGM)	323,155	26,981,663
13019090	90	KGM	Other (KGM)	239,770	58,569,601
SUM				791,572	114,666,755

ภาพ 27 ข้อมูลปริมาณการส่งออก และราคา จากกรมศุลกากร

จากภาพ 25 แสดงข้อมูลที่ได้รับจากกรมศุลกากรซึ่งเป็นข้อมูลดิบ จะเห็นได้ชัดว่ายังมีข้อมูลอื่นที่ไม่ใช่ครั้งแต่อยู่ในหมวดเดียวกันซึ่งจำเป็นต้องทำการกรองข้อมูลในลำดับถัดไป

ข้อมูลปัจจัยทางสิ่งแวดล้อม: ข้อมูลปัจจัยทางสิ่งแวดล้อม เช่น ENSO (El Niño–Southern Oscillation) และ Oceanic Niño Index (ONI) จะถูกรวบรวมจากแหล่งข้อมูลเชื่อถือได้ เช่น เว็บไซต์ของ Climate Prediction Center ข้อมูลเหล่านี้มีผลกระทบต่อสภาพอากาศที่สามารถส่งผลต่อการผลิตครั้งดังแสดงในภาพ 26 ในเว็บไซต์นี้จะเก็บรวบรวม ONI ตั้งแต่ปี 1950จนถึงปัจจุบัน แล้วจะอัปเดตโดยอัตโนมัติในวันพฤหัสบดีแรกของแต่ละเดือน

Year	DJF	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ
1950	-1.5	-1.3	-1.2	-1.2	-1.1	-0.9	-0.5	-0.4	-0.4	-0.4	-0.6	-0.8
1951	-0.8	-0.5	-0.2	0.2	0.4	0.6	0.7	0.9	1.0	1.2	1.0	0.8
1952	0.5	0.4	0.3	0.3	0.2	0.0	-0.1	0.0	0.2	0.1	0.0	0.1
1953	0.4	0.6	0.6	0.7	0.8	0.8	0.7	0.7	0.8	0.8	0.8	0.8
1954	0.8	0.5	0.0	-0.4	-0.5	-0.5	-0.6	-0.8	-0.9	-0.8	-0.7	-0.7
1955	-0.7	-0.6	-0.7	-0.8	-0.8	-0.7	-0.7	-0.7	-1.1	-1.4	-1.7	-1.5
1956	-1.1	-0.8	-0.6	-0.5	-0.5	-0.5	-0.6	-0.6	-0.5	-0.4	-0.4	-0.4
1957	-0.2	0.1	0.4	0.7	0.9	1.1	1.3	1.3	1.3	1.4	1.5	1.7
1958	1.8	1.7	1.3	0.9	0.7	0.6	0.6	0.4	0.4	0.4	0.5	0.6
1959	0.6	0.6	0.5	0.3	0.2	-0.1	-0.2	-0.3	-0.1	0.0	0.0	0.0
Year	DJF	JFM	FMA	MAM	AMJ	MJJ	JJA	JAS	ASO	SON	OND	NDJ
1960	-0.1	-0.1	-0.1	0.0	0.0	0.0	0.1	0.2	0.3	0.2	0.1	0.1
1961	0.0	0.0	0.0	0.1	0.2	0.3	0.1	-0.1	-0.3	-0.3	-0.2	-0.2
1962	-0.2	-0.2	-0.2	-0.3	-0.3	-0.2	0.0	-0.1	-0.1	-0.2	-0.3	-0.4
1963	-0.4	-0.2	0.2	0.3	0.3	0.5	0.9	1.1	1.2	1.3	1.4	1.3
1964	1.1	0.6	0.1	-0.3	-0.6	-0.6	-0.6	-0.7	-0.8	-0.8	-0.8	-0.8
1965	-0.6	-0.3	-0.1	0.2	0.5	0.8	1.2	1.5	1.9	2.0	2.0	1.7
1966	1.4	1.2	1.0	0.7	0.4	0.2	0.2	0.1	-0.1	-0.1	-0.2	-0.3
1967	-0.4	-0.5	-0.5	-0.4	-0.2	0.0	0.0	-0.2	-0.3	-0.4	-0.3	-0.4
1968	-0.6	-0.7	-0.6	-0.4	0.0	0.3	0.6	0.5	0.4	0.5	0.7	1.0
1969	1.1	1.1	0.9	0.8	0.6	0.4	0.4	0.5	0.8	0.9	0.8	0.6

ภาพ 28 ข้อมูลสภาพอากาศ Oceanic Niño Index (ONI)

ข้อมูลทั้งหมดนี้จะถูกจัดเก็บในรูปแบบ CSV (Comma-Separated Values) ซึ่งเป็นรูปแบบที่สามารถนำไปใช้ในการวิเคราะห์และประมวลผลได้อย่างง่ายดาย โดยเฉพาะในการเขียนโค้ดเพื่อการวิเคราะห์ข้อมูลและการสร้างโมเดลการคาดการณ์


3.3 การเตรียมข้อมูล (Pre-processing)

3.3.1 การทำความสะอาดข้อมูล (Data Cleaning)

เนื่องจากข้อมูลที่ได้รับมามีข้อมูลอื่นที่ไม่เกี่ยวข้องกับการวิจัย จึงจำเป็นต้องทำความสะอาดข้อมูลให้เหลือเฉพาะข้อมูลที่เกี่ยวข้องกับครั้งเท่านั้น กระบวนการนี้รวมถึงการคัดกรองและลบข้อมูลที่ไม่จำเป็นออกไป จากนั้นทำการเติมข้อมูลบางส่วนที่ขาดหายไป เพื่อให้ข้อมูลมีความครบถ้วนและเหมาะสมสำหรับการวิเคราะห์ต่อไปในขั้นตอนถัดไป การทำความสะอาดและเติมเต็มข้อมูลนี้จะช่วยให้การคาดการณ์ผลผลิตและราคาครั้งมีความแม่นยำมากยิ่งขึ้น

3.3.2 การแปลงข้อมูล (Data Transformation)

หลังจากทำความสะอาดข้อมูลดิบเรียบร้อยแล้ว ข้อมูลจะถูกนำไปแปลงด้วยการใช้ Moving Average เพื่อลดความผันผวน ทำให้ข้อมูลต่อเนื่องและสม่ำเสมอ ช่วยให้โมเดลเรียนรู้แนวโน้มได้ดีขึ้น และลดผลกระทบจากค่าที่ไม่ต้องการ ทั้งนี้ ภาพที่ 27 แสดงตัวอย่างการประมวลผลเบื้องต้นด้วย Moving Average ซึ่งมีส่วนสำคัญในการสร้างโมเดลคาดการณ์ผลผลิตและราคาครั้งที่มีความแม่นยำและเชื่อถือได้



ภาพ 29 เปรียบเทียบการแปลงข้อมูล

จากกราฟที่แสดงข้อมูลก่อนและหลังการแปลงด้วย Moving Average จะเห็นได้ว่า ข้อมูลหลังการแปลงมีความต่อเนื่องและสม่ำเสมอมากขึ้น การใช้วิธีนี้ช่วยลดความผันผวนและความไม่เสถียรของข้อมูลพื้นฐาน ทำให้การวิเคราะห์และการคาดการณ์แนวโน้มในอนาคตมีความชัดเจนและแม่นยำยิ่งขึ้น อีกทั้งยังช่วยให้สามารถระบุแนวโน้มระยะยาวได้ง่ายขึ้น ซึ่งเป็นประโยชน์อย่างยิ่งต่อการนำไปใช้ในโมเดลคาดการณ์ผลผลิตและราคาครั้ง

3.4 โมเดลการฝึกฝน (Training Model)

การออกแบบโครงสร้างโมเดล LSTM ให้เหมาะสมกับลักษณะข้อมูล โดยพิจารณาจำนวนเลเยอร์ หน่วยความจำในแต่ละเลเยอร์ และฟังก์ชันกระตุ้น (Activation Function) ที่สอดคล้องกับปัญหา

ก่อนการฝึกฝน จะต้องแบ่งข้อมูลออกเป็นชุดฝึกฝน (Training Set) และชุดทดสอบ (Test Set) โดยใช้อัตราส่วนที่เหมาะสม ซึ่งในงานวิจัยนี้กำหนดสัดส่วน 80% สำหรับฝึกฝน และ 20% สำหรับทดสอบ เพื่อให้มั่นใจว่าโมเดลสามารถทำนายข้อมูลใหม่ได้อย่างแม่นยำ




ภาพ 30 การแบ่งข้อมูลเพื่อฝึก และทดสอบ

หลังจากการเตรียมข้อมูลและออกแบบโครงสร้างโมเดลที่เหมาะสมแล้ว จึงทำการฝึกอบรมโมเดลด้วยชุดข้อมูลฝึกฝน โดยกำหนดค่าพารามิเตอร์สำคัญ เช่น อัตราการเรียนรู้ (Learning Rate), จำนวนรอบการฝึก (Epochs) และขนาดชุดข้อมูลย่อย (Batch Size) เพื่อให้โมเดลสามารถเรียนรู้รูปแบบของข้อมูลได้อย่างมีประสิทธิภาพ

เพื่อให้ได้ค่าพารามิเตอร์ที่เหมาะสม งานวิจัยนี้ได้ทำการทดลองปรับค่า ด้วยวิธีการทดสอบหลายชุดค่าพารามิเตอร์ โดยครอบคลุมการเปลี่ยนแปลงค่า Learning Rate, Epochs และ Batch Size ผลการทดลองพบว่า Learning Rate ที่ 0.01, Batch Size ที่ 64 และ Epochs ที่ 25-50 สามารถให้ค่าความผิดพลาดต่ำสุด โดยมีค่า MAE ต่ำสุดประมาณ 7.98 และ RMSE ประมาณ 11.80 การทดสอบในลักษณะ trial-and-error นี้ช่วยเพิ่มความมั่นใจว่าโมเดลสามารถทำงานได้อย่างเสถียร และให้ผลลัพธ์ที่แม่นยำเมื่อนำไปประเมินกับชุดข้อมูลทดสอบ

เมื่อฝึกอบรมเสร็จสิ้น จะทำการประเมินความแม่นยำของโมเดลด้วยชุดข้อมูลทดสอบ โดยใช้ตัวชี้วัด เช่น Mean Absolute Error (MAE) และ Root Mean Square Error (RMSE) เพื่อประเมินประสิทธิภาพและความแม่นยำของการทำนาย ทั้งนี้ ค่าที่ได้จากการประเมินจะถูกนำมาใช้เปรียบเทียบกับโมเดลอื่น ๆ เพื่อเลือกโมเดลที่มีศักยภาพสูงสุดสำหรับการนำไปใช้งานเชิงปฏิบัติ

บทที่ 3 ได้อธิบายกระบวนการทั้งหมด ตั้งแต่การเตรียมข้อมูล การประมวลผลเบื้องต้น (Preprocessing) การออกแบบโมเดล ไปจนถึงการฝึกอบรมและการปรับค่าพารามิเตอร์ เพื่อให้ได้โมเดลที่มีประสิทธิภาพสูงสุด ข้อมูลเหล่านี้ถือเป็นรากฐานสำคัญสำหรับการประเมินผลลัพธ์ในบทถัดไป และเป็นส่วนสำคัญในการพัฒนาระบบที่สามารถนำไปใช้งานจริงได้อย่างมีประสิทธิภาพ



บทที่ 4

ผลการทดลอง


บทนี้นำเสนอผลการประเมินและทดสอบโมเดลที่พัฒนาขึ้น โดยมุ่งเน้นการเปรียบเทียบค่าตัวชี้วัดความแม่นยำระหว่างโมเดล MA-LSTM, Random Forest และ RNN เพื่อหาความเหมาะสมที่สุดในการพยากรณ์ผลผลิตและราคาครั้ง โดยจะนำเสนอทั้งผลการทำนายผลผลิต (Yield Prediction) และผลการทำนายราคา (Price Prediction) พร้อมทั้งอภิปรายถึงประสิทธิภาพของแต่ละโมเดลในมุมมองของค่าความคลาดเคลื่อน เช่น MAE และ RMSE นอกจากนี้ยังกล่าวถึงการนำผลลัพธ์ไปประยุกต์ใช้กับระบบ Dashboard เพื่อสร้างคำแนะนำเชิงปฏิบัติสำหรับเกษตรกร ช่วยสนับสนุนการตัดสินใจและยกระดับการบริหารจัดการในภาคการเกษตรอย่างมีประสิทธิภาพ

4.1 ผลการทำนายผลผลิต(Yield Prediction)

ภาพที่ 31 แสดงการเปรียบเทียบประสิทธิภาพของโมเดลการพยากรณ์ Time Series จำนวน 5 แบบ ได้แก่ RNN, RF, ARIMA, Prophet และ MA-LSTM โดยทำการเปรียบเทียบระหว่างข้อมูลการฝึกฝน (Train Data) ซึ่งแสดงด้วยเส้นสีน้ำเงิน ข้อมูลทดสอบ (Test Data) แสดงด้วยเส้นสีเขียว และผลลัพธ์การพยากรณ์ของแต่ละโมเดล ได้แก่ โมเดล RNN เส้นสีน้ำตาล, โมเดล RF เส้นสีม่วง, โมเดล ARIMA เส้นสีเทา, โมเดล Prophet เส้นสีแดง และโมเดล MA-LSTM เส้นสีส้ม

จากภาพสามารถสังเกตได้ว่า โมเดล MA-LSTM ให้ผลการพยากรณ์ที่มีความใกล้เคียงกับข้อมูลทดสอบมากที่สุด โดยเส้นพยากรณ์ของโมเดลมีการซ้อนทับแนวนุ่มกับข้อมูลจริงอย่างต่อเนื่องและราบรื่น ซึ่งสะท้อนให้เห็นถึงความสามารถของ MA-LSTM ในการประมวลผลข้อมูลที่มีความไม่แน่นอนสูงและมีลักษณะเชิงฤดูกาลได้อย่างมีประสิทธิภาพ เมื่อเปรียบเทียบกับโมเดลอื่น พบว่าโมเดล RNN และ Prophet มีแนวโน้มเกิดความผันผวนและเบี่ยงเบนจากข้อมูลจริงในบางช่วงเวลา ส่วน ARIMA และ RF แม้จะมีช่วงที่ให้ผลใกล้เคียงกับข้อมูลจริง แต่ยังคงแสดงลักษณะเบี่ยงเบนในบางจุด โดยเฉพาะในช่วงปลายของชุดข้อมูล

Model Comparisons: RNN, LSTM, Random Forest, ARIMA, Prophet



ภาพ 31 ผลการทดสอบโมเดลสำหรับการคาดการณ์

เพื่อประเมินประสิทธิภาพของแบบจำลอง ได้ทำการเปรียบเทียบผลลัพธ์ระหว่าง MA-LSTM, Random Forest และ RNN โดยใช้ตัวชี้วัด Mean Absolute Error (MAE) คือค่าความผิดพลาดเฉลี่ยระหว่างค่าจริงกับค่าที่โมเดลทำนายได้ ซึ่งแสดงถึงความคลาดเคลื่อนในหน่วยเดียวกับข้อมูลจริง ส่วน Root Mean Square Error (RMSE) เป็นตัวชี้วัดที่ให้ความสำคัญกับความผิดพลาดที่มีค่ามาก (outlier) มากกว่า เนื่องจากเป็นการถอยรากที่สองของค่าเฉลี่ยกำลังสองของความผิดพลาด ทั้งสองตัวชี้วัดนี้ถูกใช้ในการเปรียบเทียบประสิทธิภาพของโมเดลของโมเดลในตารางที่ 3


ตาราง 3 การเปรียบเทียบค่าความผิดพลาดของแบบจำลอง

Prediction Model	Mean absolute error (MAE)	Root Mean Square Error (RMSE)
MA-LSTM	2.13%	3.60%
Random Forest	2.94%	4.42%
RNN	3.75%	4.97%
ARIMA	21.71%	22.92%
Prophet	9.01%	11.82%


จากผลการประเมิน พบว่าโมเดล Basic RNN สามารถทำนายข้อมูลทดสอบได้ในระดับหนึ่ง โดยมีค่า MAE 3.75% และ RMSE 4.97% ซึ่งสะท้อนถึงความคลาดเคลื่อนค่อนข้างสูง และมีความผันผวนบางช่วงที่ไม่สอดคล้องกับข้อมูลจริง โมเดล Random Forest ให้ค่า MAE 2.94% และ RMSE 4.42% แสดงถึงความแม่นยำที่ดีขึ้นแต่ยังพบการผันผวนในช่วงท้ายการพยากรณ์ ในขณะที่ MA-LSTM ให้ค่า MAE ต่ำสุด 2.13% และ RMSE 3.60% รวมถึงค่าใหม่ที่วัดในชุด ARIMA และ Prophet โดย ARIMA ให้ MAE 21.713, RMSE 22.925 และ Prophet ให้ MAE 9.006, RMSE 11.825 ซึ่งยืนยันว่า MA-LSTM มีประสิทธิภาพสูงที่สุด MSE ที่ 3.60% ทำให้สามารถทำนายได้แม่นยำที่สุดเมื่อเปรียบเทียบกับโมเดลอื่น ๆ โดยผลการทำนายมีความสม่ำเสมอและใกล้เคียงกับข้อมูลทดสอบมากที่สุด

ดังนั้น เพื่อเพิ่มความแม่นยำของการพยากรณ์และให้ได้ผลลัพธ์ที่สามารถนำไปใช้วางแผนการผลิตและการตลาดได้จริง จึงได้ทำการทดลองใช้ สองปัจจัยหลักร่วมกัน ได้แก่ ปริมาณการส่งออก และค่า ONI และอีกหนึ่งคู่คือ ปริมาณการส่งออก และค่าอุณหภูมิ ซึ่งเป็นตัวชี้วัดสภาพอากาศที่ส่งผลโดยตรงต่อผลผลิตครั้ง การใช้สองปัจจัยนี้รวมกันจะช่วยให้สามารถ จับความสัมพันธ์เชิงลึกของข้อมูล และให้ผลลัพธ์การพยากรณ์ที่มีประสิทธิภาพมากขึ้นสำหรับการตัดสินใจของเกษตรกรและผู้ประกอบการ

Model Predictions 2 factor [Quantity ,season] | MAE : 2.73 | RMSE : 3.15 |



Model Predictions 2 factor [Quantity ,temperature] | MAE : 2.35 | RMSE : 3.53 |



ภาพ 32 ผลการทำนาย 2 ปัจจัย

การวิเคราะห์ประสิทธิภาพของโมเดล LSTM โดยใช้ปัจจัยที่แตกต่างกัน ได้แก่ เดือน ONI ราคา ฤดูกาล อุณหภูมิ และปี ดังแสดงในภาพที่ 32 ข้อมูลฝึกฝนเส้นสีน้ำเงิน ข้อมูลทดสอบเส้นสีเขียว และข้อมูลพยากรณ์เส้นสีเหลืองพบว่าปัจจัยฤดูกาลและอุณหภูมามีความสำคัญอย่างยิ่งต่อความแม่นยำ โดยโมเดลที่ใช้ฤดูกาลให้ค่า MAE 2.73 และ RMSE 3.15 ส่วนโมเดลที่ใช้อุณหภูมิให้ค่า MAE 2.35 และ RMSE 3.53 ซึ่งเป็นค่าที่ต่ำที่สุดในบรรดาปัจจัยทั้งหมด ทั้งนี้ ปัจจัยด้านเดือนยังแสดงถึงความสำคัญของช่วงเวลาในการทำนาย โดยให้ผลลัพธ์ที่ค่อนข้างแม่นยำเช่นกัน

ในทางตรงกันข้าม ปัจจัยอื่น ๆ เช่น ONI ราคา และปี แม้จะมีความสัมพันธ์กับผลผลิตบ้าง แต่ไม่ได้แสดงความสำคัญเชิงนัยสำคัญในการทำนาย โมเดลที่ใช้ปัจจัยเหล่านี้มักให้ผลลัพธ์ที่ผันผวนและคลาดเคลื่อนจากข้อมูลจริง โดยเฉพาะในช่วงที่มีการเปลี่ยนแปลงอย่างรวดเร็ว เช่น ราคาที่แกว่งตัวแรง หรือค่าดัชนี ONI ที่ผันแปรตามฤดูกาล

จากผลการวิเคราะห์สามารถสรุปได้ว่า การพัฒนาโมเดลทำนายผลผลิตที่มีประสิทธิภาพควรให้ความสำคัญกับตัวแปรที่เกี่ยวข้องโดยตรงกับการเจริญเติบโตของพืช โดยเฉพาะฤดูกาลและอุณหภูมิ การผนวกข้อมูลเชิงเวลา เช่น เดือน เข้ามาร่วมด้วยอาจช่วยยกระดับความแม่นยำได้อย่างมีนัยสำคัญ ส่วนตัวแปรทางเศรษฐกิจและสิ่งแวดล้อม เช่น ราคา และดัชนี ONI ควรใช้เป็นองค์ประกอบเสริมมากกว่าปัจจัยหลัก การศึกษานี้จึงให้ข้อมูลเชิงลึกที่เป็นประโยชน์ต่อการพัฒนาระบบทำนายผลผลิตที่แม่นยำและมีศักยภาพสูงในอนาคต

ผลลัพธ์จากการประเมินโมเดล โดยเฉพาะ MA-LSTM ซึ่งแสดงค่าความแม่นยำสูงสุด มีความสำคัญเชิงปฏิบัติอย่างยิ่ง เนื่องจากช่วยให้สามารถพยากรณ์ผลผลิตและราคาครั้งได้อย่างแม่นยำมากขึ้น ซึ่งเป็นประโยชน์ต่อการวางแผนการผลิตและการตัดสินใจทางธุรกิจของเกษตรกร เช่น การกำหนดช่วงเวลาที่เหมาะสมในการเพาะปลูก การจัดการพื้นที่เพาะปลูก และการวางแผนการขายเพื่อให้ได้ราคาที่ดีที่สุด สาเหตุที่ MA-LSTM เหมาะสมกับชุดข้อมูลนี้เป็นเพราะข้อมูลอนุกรมเวลาที่ใช้มีความผันผวนสูงและมีความสัมพันธ์เชิงเวลา (temporal dependency) ที่ซับซ้อน โดย MA-LSTM ถูกออกแบบมาโดยเฉพาะเพื่อจัดการข้อมูลลำดับ (sequential data) และสามารถจดจำความสัมพันธ์ระยะยาวได้ดีกว่าโมเดล ARIMA หรือ Prophet ที่เหมาะกับข้อมูลที่มีแนวโน้ม (trend) และความเป็นฤดูกาล (seasonality) ชัดเจน นอกจากนี้ การเชื่อมโยงผลลัพธ์เข้ากับระบบ Dashboard ยังช่วยให้ผู้ใช้งานเข้าถึงข้อมูลเชิงลึกและคำแนะนำที่สามารถนำไปใช้ได้จริง ซึ่งช่วยลดความเสี่ยงและเพิ่มประสิทธิภาพในการบริหารจัดการภาคเกษตรอย่างมีระบบและยั่งยืน

4.2 การพยากรณ์แนวโน้มผลผลิตและราคาครึ่ง

การพยากรณ์แนวโน้มของปริมาณผลผลิตและราคาครึ่งเป็นปัจจัยสำคัญที่ช่วยให้เกษตรกรสามารถตัดสินใจเกี่ยวกับการขยายหรือชะลอการเลี้ยง และกำหนดช่วงเวลาที่เหมาะสมในการจำหน่ายได้อย่างแม่นยำยิ่งขึ้น ในการศึกษาได้ทำการวิเคราะห์ข้อมูลด้านปริมาณการส่งออก ราคาครึ่ง และดัชนี ONI (Oceanic Niño Index) ซึ่งเป็นตัวชี้วัดปรากฏการณ์เอลนีโญและลานีญาที่อาจส่งผลกระทบต่อผลผลิต นอกจากนี้ ยังได้ประยุกต์ใช้แบบจำลอง MA-LSTM เพื่อพยากรณ์แนวโน้มของราคาครึ่งและปริมาณการส่งออก เพื่อช่วยให้เกษตรกรสามารถวางแผนการผลิตและการตลาดได้อย่างมีประสิทธิภาพ

ก่อนที่จะเข้าสู่กระบวนการพยากรณ์ จำเป็นต้องทำ การวิเคราะห์ข้อมูลเชิงลึก (Exploratory Data Analysis – EDA) เพื่อหา รูปแบบซ่อนเร้น และ Logic ที่มีอยู่ในข้อมูล เพื่อใช้เป็นแนวทางในการพัฒนาแบบจำลองการศึกษวิเคราะห์ข้อมูลย้อนหลังพบว่า ปริมาณการส่งออกและราคาครึ่งมีความสัมพันธ์กันในเชิงอุปสงค์และอุปทาน โดยสามารถจำแนกแนวโน้มที่สำคัญได้ดังนี้


ช่วงปี 2013 – 2014 ปริมาณการส่งออกเพิ่มขึ้นสูงมาก ส่งผลให้ราคาครึ่งพุ่งสูงขึ้น

ช่วงปี 2015 – 2016 ปริมาณการส่งออกลดลง ราคาครึ่งลดลงตาม

ช่วงปี 2020 – 2021 ราคาครึ่งเพิ่มสูงขึ้น ขณะที่ปริมาณการส่งออกคงที่

ช่วงปี 2022 – 2023 ปริมาณการส่งออกเพิ่มขึ้นมาก ส่งผลให้ราคาครึ่งลดลง

จากการวิเคราะห์แนวโน้มของผลผลิตและราคาครึ่ง สามารถจำแนกแนวโน้มหลักออกเป็น 4 รูปแบบ ซึ่งใช้เป็นพื้นฐานในการพยากรณ์และกำหนดกลยุทธ์การตัดสินใจของเกษตรกรได้อย่างมีประสิทธิภาพ แนวโน้มเหล่านี้ช่วยให้เกษตรกรสามารถปรับแผนการเลี้ยง และการจำหน่ายให้เหมาะสมกับสถานการณ์ตลาดและปัจจัยแวดล้อมที่เปลี่ยนแปลง



ภาพ 33 วิเคราะห์แนวโน้มระหว่างผลผลิตและราคาครึ่ง

จากภาพ 33 พบว่ามีช่วงเวลา que แสดงให้เห็นถึงพฤติกรรมของตลาดที่แตกต่างกัน 4 ช่วง ซึ่งสามารถวิเคราะห์ได้ดังนี้

กรอบสีแดง จะเห็นได้ว่าราคาครึ่งปรับตัวสูงขึ้นอย่างรวดเร็ว และปริมาณการส่งออกเพิ่มขึ้นสูงในทิศทางเดียวกัน สามารถแปลความหมายได้ว่าราคาครึ่งเพิ่มขึ้นเนื่องจาก อุปสงค์ของตลาดเพิ่มขึ้นปริมาณการส่งออกสูงขึ้นสะท้อนให้เห็นว่า ผู้ผลิตเร่งจำหน่ายสินค้าในช่วงที่ราคาสูง แนวโน้มนี้เกิดขึ้นในช่วงที่ตลาดมีการขยายตัวและมีความต้องการครึ่งเพิ่มขึ้น

กรอบสีส้ม ในช่วงเวลานี้ ราคาครึ่งปรับตัวลดลงอย่างต่อเนื่อง พร้อมกับปริมาณการส่งออกที่ลดลง ซึ่งสามารถแปลความหมายได้ว่า ตลาดเข้าสู่ช่วง ปรับฐานหลังจากที่ราคาครึ่งสูงขึ้นในช่วงก่อนหน้านี้ การลดลงของปริมาณการส่งออกบ่งชี้ว่า อุปสงค์ของตลาดลดลง และอาจส่งผลให้ผู้ผลิตลดปริมาณการผลิตลงเพื่อลดความเสี่ยงด้านราคาที่ลดต่ำลง แนวโน้มนี้เป็นลักษณะของ ช่วงตลาดถดถอยชั่วคราว ซึ่งเกิดขึ้นหลังจากราคาพุ่งสูงไปแล้ว

กรอบสีเขียว ราคาครึ่งมีแนวโน้ม เพิ่มขึ้นอย่างต่อเนื่อง ขณะที่ปริมาณการส่งออกกลับลดลง ซึ่งเป็นสถานการณ์ที่แตกต่างจากแนวโน้มทั่วไปของตลาด สามารถแปลความหมายได้ว่า ราคาสูงขึ้นอาจเกิดจาก ข้อจำกัดด้านอุปทาน หรือการกักตุนสินค้าโดยผู้ผลิต การลดลงของปริมาณการส่งออก อาจเกิดจาก ข้อจำกัดด้านผลผลิต หรือความต้องการกักตุนครึ่งของเกษตรกรและผู้ค้า เพื่อรอจำหน่ายในราคาที่สูงขึ้น แนวโน้มนี้สะท้อนให้เห็นว่า ตลาดยังคงมีอุปสงค์ที่สูง แม้ว่าจะมีข้อจำกัดด้านอุปทาน

กรอบสีน้ำเงิน จากภาพจะเห็นได้ว่าปริมาณการส่งออกเพิ่มขึ้นอย่างมาก ขณะที่ราคาครั้งเริ่มลดลง ในช่วงปลายปี 2023 สามารถแปลความหมายได้ว่า การเร่งส่งออกปริมาณมาก อาจนำไปสู่ ภาวะอุปทานล้นตลาด ซึ่งเป็นปัจจัยที่ส่งผลให้ราคาลดลง แนวโน้มนี้บ่งบอกถึงการปรับตัวของตลาดที่เกิดขึ้นเมื่อ ราคาสูงขึ้นในช่วงก่อนหน้านี้ ทำให้มีการผลิตและจำหน่ายเพิ่มขึ้น และในที่สุดก็นำไปสู่ การปรับฐานของราคา ในช่วงถัดไป

การวิเคราะห์แนวโน้มของปริมาณการส่งออกและราคาครั้งในช่วงปี 2012 – 2023 พบว่ามี 4 รูปแบบหลัก ได้แก่ ราคาขึ้น – ปริมาณการส่งออกขึ้น, ราคาลง – ปริมาณการส่งออกลง ราคาขึ้น – ปริมาณการส่งออกลดลง และ ราคาลง – ปริมาณการส่งออกขึ้น ซึ่งสะท้อนถึงกลไกตลาดและพฤติกรรมของผู้ผลิต แนวโน้มเหล่านี้สามารถใช้เป็นแนวทางในการพยากรณ์ตลาดและวางแผนการผลิต รายละเอียดสรุปได้ในตารางที่ 3

ตาราง 4 สรุปแนวโน้มของปริมาณการส่งออกและราคาครั้ง

ช่วงเวลา	ราคาครั้ง	ปริมาณการส่งออก	สถานการณ์ตลาด	แนวทางการตัดสินใจ
สีแดง	ขึ้น	ขึ้น	ตลาดขยายตัว ราคาสูง	ควรทยอยขายเพื่อบริหารความเสี่ยงจากอุปทานล้นตลาด
สีส้ม	ลง	ลง	ตลาดปรับฐาน ราคาลดลง	ชะลอการขาย รอจังหวะตลาดฟื้นตัวก่อนจำหน่าย
สีเขียว	ขึ้น	ลง	ราคาสูงแม้ว่าปริมาณส่งออกลดลง	รีบขายให้หมดช่วงราคาสูง ไม่ควรเก็บไว้นาน
สีน้ำเงิน	ลง	ขึ้น	อุปทานล้นตลาด ราคาปรับฐาน	ระบายบางส่วน หลีกเลี่ยงการกักเก็บระยะยาว

ผลการศึกษาความสัมพันธ์ของ ปริมาณการส่งออก และค่า ONI ซึ่งเป็นตัวบ่งชี้ปรากฏการณ์ El Niño และ La Niña พบว่าแนวโน้มของ El Niño และ La Niña มีผลโดยตรงต่อปริมาณผลผลิตและการส่งออก สามารถแบ่งเป็น 4 กรณีหลัก และนำมาใช้เป็นแนวทางแนะนำสำหรับการตัดสินใจด้านการเพาะปลูกได้ดังนี้

กรณีที่ 1 ปริมาณการส่งออกเพิ่มขึ้นในช่วง La Niña

สถานการณ์ La Niña มักส่งผลให้ปริมาณฝนเพิ่มขึ้นและมีอุณหภูมิต่ำกว่าปกติ ซึ่งเหมาะกับการผลิตครั้ง ปริมาณการส่งออกที่เพิ่มขึ้น แสดงถึงผลผลิตที่ดีและการผลิตที่สามารถดำเนินไปได้อย่างต่อเนื่องคำแนะนำควรเพิ่มการเพาะปลูกภาวะ La Niña ช่วยเพิ่มผลผลิต จึงเป็นโอกาสในการขยายพื้นที่เพาะปลูก สามารถใช้ประโยชน์จากอุณหภูมิที่เหมาะสมและความชื้นที่เพียงพอ ควรวางแผนการจัดเก็บและแปรรูปผลิตภัณฑ์ล่วงหน้าเพื่อรองรับการผลิตที่เพิ่มขึ้น

กรณีที่ 2 ปริมาณการส่งออกลดลงในช่วง La Niña

แม้จะอยู่ในช่วง La Niña แต่ปริมาณการส่งออกกลับลดลง ซึ่งอาจเกิดจากอุปทานล้นตลาดหรือข้อจำกัดด้านการค้าอาจเป็นไปได้ว่าผู้ผลิตมีผลผลิตจำนวนมากแต่ตลาดไม่มีความต้องการเพิ่มคำแนะนำ: ควรชะลอการเพาะปลูก ลดพื้นที่การเพาะปลูกชั่วคราว เพื่อลดภาวะอุปทานล้นตลาด ปรับแผนการจัดเก็บและแปรรูปผลิตภัณฑ์แทนการขายในช่วงราคาต่ำ

กรณีที่ 3 ปริมาณการส่งออกเพิ่มขึ้น El Niño

El Niño มักทำให้สภาพอากาศแห้งแล้ง และส่งผลให้ปริมาณการผลิตลดลง หากปริมาณการส่งออกยังเพิ่มขึ้น อาจหมายถึงอุปทานในตลาดมีจำกัด แต่ความต้องการยังคงสูงคำแนะนำ ควรเพิ่มการเพาะปลูก แต่ต้องบริหารความเสี่ยง อาจเป็นโอกาสดีในการเพาะปลูกเพิ่มขึ้น แต่ต้องมีการจัดการแหล่งน้ำอย่างมีประสิทธิภาพ

กรณีที่ 4 ปริมาณการส่งออกลดลง El Niño

ในช่วง El Niño มักเกิดภาวะแห้งแล้ง ทำให้ผลผลิตลดลง และปริมาณการส่งออกต่ำสภาวะนี้อาจทำให้ราคาครั้งเพิ่มขึ้น เนื่องจากมีอุปทานต่ำ แต่ความเสี่ยงด้านการผลิตสูงคำแนะนำ ควรชะลอการเพาะปลูก และบริหารทรัพยากรอย่างรอบคอบ หลีกเลี่ยงการขยายพื้นที่เพาะปลูก เพราะอาจเผชิญกับผลผลิตต่ำ ใช้มาตรการอนุรักษ์น้ำ และวางแผนลดต้นทุนการผลิต พิจารณาเก็บเกี่ยวผลผลิตก่อนฤดูแล้งเพื่อหลีกเลี่ยงความเสียหายจากสภาพอากาศ

แนวทางดังกล่าวสามารถสรุปได้ใน ตารางที่ 4 ซึ่งแสดงความสัมพันธ์ระหว่างปริมาณการส่งออกและค่า ONI พร้อมคำแนะนำที่เหมาะสมสำหรับการวางแผนการเพาะปลูกครั้งอย่างมีประสิทธิภาพ

ตาราง 5 สรุปแนวโน้มของปริมาณการส่งออกและ ONI

ปริมาณการส่งออก	สภาวะภูมิอากาศ (ONI)	แนวทางการตัดสินใจ
เพิ่มขึ้น	La Niña	ขยายพื้นที่การเพาะปลูกได้เต็มที่ เพื่อใช้ประโยชน์จากสภาพอากาศที่เหมาะสม
ลดลง	La Niña	ขยายแบบระมัดระวัง ตรวจสอบแปลงเพาะปลูกก่อน
เพิ่มขึ้น	El Niño	ขยายบางส่วนเฉพาะพื้นที่ที่มีน้ำเพียงพอ
ลดลง	El Niño	ชะลอการขยาย หรือหยุดเพาะปลูกชั่วคราว

4.3 การนำแบบจำลอง MA-LSTM ไปใช้ในเชิงปฏิบัติ

หลังจากที่ได้ทำการพยากรณ์แนวโน้ม ปริมาณการส่งออก (Quantity) และราคาครึ่ง (Price) ด้วยแบบจำลอง MA-LSTM พบว่าแบบจำลองสามารถจับแนวโน้มและคาดการณ์การเปลี่ยนแปลงของตลาดได้อย่างแม่นยำ โดยมี ค่าความคลาดเคลื่อน (MAE และ RMSE) อยู่ในระดับต่ำ ได้อย่างชัดเจน

เพื่อให้ ผลลัพธ์ของแบบจำลอง MA-LSTM สามารถนำไปใช้ได้จริง ในการบริหารจัดการการผลิตและการตลาดของเกษตรกร การนำแบบจำลองนี้ไปใช้สามารถแบ่งออกเป็น 3 ด้านหลัก ได้แก่ การวางแผนการเพาะปลูก การตัดสินใจด้านการจำหน่าย และการปรับปรุงกระบวนการผลิต

โมเดลที่ใช้วิเคราะห์แนวโน้มราคาได้แม่นยำที่สุดคือ MA-LSTM ซึ่งมีความสามารถในการจับแนวโน้มของข้อมูลได้ดีกว่า RNN และ Random Forest เนื่องจากสามารถเรียนรู้จากค่าเฉลี่ยเคลื่อนที่แบบเอกซ์โพเนนเชียลซึ่งช่วยลดผลกระทบจากค่าผิดปกติในข้อมูล

ด้วยการพัฒนาตารางคำแนะนำเชิงปฏิบัติสำหรับเกษตรกร โดยอ้างอิงจากผลการพยากรณ์แนวโน้มที่ได้จากแบบจำลอง MA-LSTM ตารางดังกล่าวได้จัดกลุ่ม “สถานะตลาด” ตามทิศทางของราคา (Price) ปริมาณการส่งออก (Quantity) และสภาพอากาศ (ONI) ซึ่งแบ่งออกเป็น 8 สถานะหลัก เช่น ราคาขึ้น ปริมาณขึ้น La Niña, ราคาสูง ปริมาณลง El Niño

การจัดทำตารางคำแนะนำนี้ มีวัตถุประสงค์เพื่อช่วยให้เกษตรกรสามารถตีความผลการพยากรณ์เชิงเทคนิคได้อย่างง่ายดาย โดยเชื่อมโยงผลคาดการณ์กับการตัดสินใจ ได้แก่ การขยายหรือชะลอการเพาะปลูก การตัดสินใจขายทันทีหรือทยอยขาย รวมถึงการเตรียมตัวรับมือกับสภาพอากาศ

ตาราง 6 ตารางแสดงคำแนะนำเชิงปฏิบัติสำหรับเกษตรกร

ราคา	ปริมาณ	สภาพอากาศ	คำแนะนำ
ขึ้น	ขึ้น	La Niña	ราคาครั้งเพิ่มขึ้นพร้อมกับปริมาณการส่งออกที่สูงขึ้น สะท้อนตลาดที่แข็งแกร่ง ประกอบกับสภาพอากาศแบบ La Niña ที่เอื้อต่อการเพาะปลูก แนะนำให้เกษตรกรขยายพื้นที่การผลิต และทยอยขายเพื่อทำกำไรในช่วงราคาดี
ขึ้น	ลง	La Niña	ราคาครั้งสูงขึ้นแต่ปริมาณส่งออกลดลง สะท้อนภาวะสินค้าขาดตลาด ขณะเดียวกัน La Niña สนับสนุนสภาพเพาะปลูก แนะนำให้เกษตรกรควบคุมพื้นที่ให้เหมาะสม และรีบจำหน่ายสินค้าในช่วงราคาสูง
ลง	ขึ้น	La Niña	ราคาครั้งลดลงแม้ว่าปริมาณส่งออกจะเพิ่มขึ้น บ่งบอกถึงภาวะตลาดผัน แต่สภาพอากาศแบบ La Niña ยังคงเอื้อต่อการเพาะปลูก แนะนำให้เกษตรกรเร่งระบายสต็อกบางส่วน และไม่ขยายพื้นที่เพิ่มเติมในระยะนี้
ลง	ลง	La Niña	ราคาครั้งและปริมาณส่งออกต่างลดลง พร้อมกับสภาพอากาศขึ้นของ La Niña แนะนำให้เกษตรกรชะลอการเพาะปลูกชั่วคราว และเก็บผลผลิตระยะสั้นเพื่อรอจังหวะราคาฟื้นตัว
ขึ้น	ขึ้น	El Niño	ราคาครั้งและปริมาณการส่งออกเพิ่มขึ้น สะท้อนตลาดที่ดี แต่ El Niño ทำให้อากาศแห้งแล้ง เสี่ยงต่อการขาดน้ำ แนะนำให้ขยายพื้นที่เฉพาะบริเวณที่มีน้ำเพียงพอ และทยอยขายเมื่อราคายังอยู่ในเกณฑ์ดี
ขึ้น	ลง	El Niño	ราคาครั้งสูงขึ้นแต่ปริมาณส่งออกลดลงในภาวะ El Niño แสดงถึงสินค้ามีน้อย แต่เสี่ยงภัยแล้ง แนะนำให้เกษตรกรไม่ขยายพื้นที่เพาะปลูกเพิ่ม และรีบจำหน่ายผลผลิตในช่วงราคาสูงก่อนสภาพอากาศกระทบแรงขึ้น
ลง	ขึ้น	El Niño	ราคาครั้งลดลงแม้ว่าปริมาณส่งออกจะเพิ่มขึ้น ขณะที่ El Niño ทำให้เสี่ยงภัยแล้ง แนะนำให้เกษตรกรระบายสินค้าบางส่วนเพื่อลดความเสี่ยง และชะลอการขยายพื้นที่เพาะปลูก
ลง	ลง	El Niño	ราคาครั้งและปริมาณการส่งออกต่างลดลงท่ามกลางภาวะ El Niño ที่แห้งแล้งรุนแรง แนะนำให้เกษตรกรหยุดการขยายพื้นที่เพาะปลูก และติดตามสถานการณ์ตลาดอย่างใกล้ชิด พร้อมเก็บสต็อกอย่างระมัดระวัง

ตารางที่ 6 แสดงการสรุปคำแนะนำเชิงปฏิบัติที่ได้จากการวิเคราะห์ผลการพยากรณ์ โดยจำแนกตามทิศทางของราคา ปริมาณการส่งออก และสภาพอากาศ (ONI) ซึ่งแบ่งออกเป็น 8 สถานะหลัก ตารางนี้ถูกออกแบบมาเพื่อเชื่อมโยงผลการพยากรณ์เชิงตัวเลขกับแนวทางการตัดสินใจ โดยในแต่ละสถานะจะมีคำแนะนำเฉพาะที่เหมาะสมกับสถานการณ์ เช่น ในกรณีที่ราคาครั้งและปริมาณการส่งออกเพิ่มขึ้นในช่วงที่มีสภาพอากาศ La Niña ซึ่งเอื้อต่อการเพาะปลูก จะมีคำแนะนำให้เกษตรกรขยายพื้นที่การผลิตและทยอยขายผลผลิตเพื่อให้ได้ราคาที่เหมาะสม ในทางกลับกัน หากเป็นสถานะที่ราคาลดลงและอยู่ภายใต้ El Niño ที่มีความแห้งแล้งรุนแรง จะมีคำแนะนำให้ชะลอหรือหยุดการเพาะปลูก และติดตามสถานการณ์ตลาดอย่างใกล้ชิด

การนำเสนอในตารางนี้ทำให้สามารถถ่ายทอดผลการพยากรณ์ไปสู่การใช้งานจริงได้อย่างเป็นระบบ ช่วยให้เกษตรกรสามารถใช้ข้อมูลเพื่อวางแผนการผลิตและการจำหน่ายได้อย่างเหมาะสม ซึ่งถือเป็นการยกระดับแบบจำลอง MA-LSTM จากเพียงการพยากรณ์เชิงสถิติไปสู่การเป็นส่วนหนึ่งของระบบสนับสนุนการตัดสินใจ (Decision Support System) ที่สามารถเพิ่มประสิทธิภาพการบริหารจัดการและลดความเสี่ยงในภาคการเกษตรได้อย่างแท้จริง

เพื่อการนำแบบจำลอง MA-LSTM ไปใช้ในเชิงปฏิบัติ งานวิจัยนี้ได้พัฒนาระบบ Dashboard เว็บแอปพลิเคชันสำหรับแสดงผลการพยากรณ์ โดย Dashboard ดังกล่าวเชื่อมโยงผลการวิเคราะห์และการพยากรณ์แนวโน้มของราคาครั้ง ปริมาณการส่งออก และค่าดัชนี ONI (Oceanic Niño Index) ทั้งจากข้อมูลจริงย้อนหลังและค่าที่พยากรณ์ล่วงหน้า 6 เดือน เพื่อให้ผู้ใช้สามารถเข้าถึงข้อมูลสำคัญได้อย่างรวดเร็วและเข้าใจง่าย

ระบบนี้ทำหน้าที่เป็นเครื่องมือที่ช่วยแปลงผลการคำนวณเชิงสถิติให้อยู่ในรูปแบบภาพและคำแนะนำที่ตีความได้ทันที โดยผู้ใช้สามารถเห็นภาพรวมแนวโน้มตลาด และนำข้อมูลไปใช้ประกอบการวางแผนการผลิตและการตลาดได้อย่างเหมาะสม เช่น ช่วยให้ตัดสินใจได้ว่าควรขยายหรือชะลอการเพาะปลูก และควรทยอยขายหรือเก็บสต็อกในช่วงเวลาใดโดยการนำเสนอสถานะมาแสดงตามเงื่อนไขที่กำหนดไว้ดังแสดงในรูปที่ 34-41

Dashboard การคาดการณ์ราคารองและผลผลิต


ราคารอง (บาท)



ปริมาณการส่งออก (ตัน)



ค่า ONI (ดัชนีสภาพอากาศ)



บทวิเคราะห์และคำแนะนำ

ราคารองเพิ่มขึ้นพร้อมกับปริมาณการส่งออกที่สูงขึ้น สะท้อนตลาดที่แข็งแกร่ง ประกอบกับสภาพอากาศแบบ La Niña ที่เอื้อต่อการเพาะปลูก และนำไปให้เกษตรกรขยายพื้นที่การผลิต และทยอยขายเพื่อทำกำไรในช่วงราคาดี

ภาพ 34 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาขึ้น ปริมาณเพิ่มขึ้น ภายใต้สภาพอากาศ La Niña

Dashboard การคาดการณ์ราคารั้วและผลผลิต


ราคารั้ว (บาท)



ปริมาณการส่งออก (ตัน)



ค่า ONI (ดัชนีสภาพอากาศ)



บทวิเคราะห์และคำแนะนำ

ราคารั้วสูงขึ้นแต่ปริมาณส่งออกลดลง สอดคล้องกับสัญญาณของ La Niña สบับสนับสนุนสภาพปะทุ และทำให้เกษตรกรควบคุมพื้นที่ที่เหมาะสม และรับจำหน่ายสินค้าในช่วงราคาสูง

ภาพ 35 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาขึ้น ปริมาณลดลง ภายใต้สภาพ La Niña

Dashboard การคาดการณ์ราคาคุ้งและผลผลิต


ราคาคุ้ง (บาท)



ปริมาณการส่งออก (ตัน)



ค่า ONI (ดัชนีสภาพอากาศ)



บทวิเคราะห์และคำแนะนำ

ราคาคุ้งลดลงแม้ว่าปริมาณส่งออกจะเพิ่มขึ้น บ่งบอกถึงภาวะตลาดล้น แต่สภาพอากาศแบบ La Niña ยังคงเอื้อการเพาะปลูก แนะนำให้เกษตรกรเร่งระบายสต็อกบางส่วน และไม่ขยายพื้นที่เพิ่มเติมนะครับ

ภาพ 36 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาลดลง ปริมาณเพิ่มขึ้น สภาพอากาศ La Niña

Dashboard การคาดการณ์ราคารั้วและผลผลิต


ราคารั้ว (บาท)



ปริมาณการส่งออก (ตัน)



ค่า ONI (ดัชนีสภาพอากาศ)



บทวิเคราะห์และคำแนะนำ

ราคารั้วและปริมาณส่งออกต่างลดลง พร้อมกับสภาพอากาศขึ้นของ La Niña และนำไปสู่ผลกระทบของการเพาะปลูกข้าวขาว และเก็บผลผลิตระยะสั้นเพื่อรอจังหวะราคาฟื้นตัว

ภาพ 37 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาลดลง ปริมาณลดลง ภายใต้สภาพอากาศ La Niña

Dashboard การคาดการณ์ราคาล้างและผลผลิต

ราคาล้าง (บาท)



ปริมาณการส่งออก (ตัน)



ค่า ONI (ดัชนีสภาพอากาศ)



บทวิเคราะห์และคำแนะนำ

ราคาล้างเพิ่มขึ้นพร้อมกับปริมาณการส่งออกที่สูงขึ้น สะท้อนตลาดที่แข็งแกร่ง ประกอบกับสภาพอากาศแบบ La Niña ที่เอื้อต่อการเพาะปลูก และนำไปให้เกษตรกรขยายพื้นที่การผลิต และทยอยขายเพื่อทำกำไรในช่วงราคาดี

ภาพ 38 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาขึ้น ปริมาณเพิ่มขึ้น ภายใต้สภาพอากาศ El Niño

Dashboard การคาดการณ์ราคาร้างและผลผลิต


ราคาร้าง (บาท)



ปริมาณการส่งออก (ตัน)



ค่า ONI (ดัชนีสภาพอากาศ)



บทวิเคราะห์และคำแนะนำ

ราคาร้างสูงขึ้นแต่ปริมาณส่งออกลดลงในภาวะ El Niño แสดงถึงสินค้ามีน้อยแต่เสี่ยงภัยแล้ง แนะนำให้เกษตรกรไม่ขยายพื้นที่เพาะปลูกเพิ่ม และรับจำหน่ายผลผลิตในช่วงราคาสูงก่อนสภาพอากาศกระทบแรงขึ้น

ภาพ 39 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาขึ้น ปริมาณลดลง ภายใต้สภาพอากาศ El Niño

Dashboard การคาดการณ์ราคาร้างและผลผลิต


ราคาร้าง (บาท)



ปริมาณการส่งออก (ตัน)



ค่า ONI (ดัชนีสภาพอากาศ)




บทวิเคราะห์และคำแนะนำ

ราคาร้างลดลงแม้ว่าปริมาณส่งออกจะเพิ่มขึ้น บ่งบอกถึงภาวะตลาดล้น แต่สภาพอากาศแบบ La Niña ยังคงเอื้อการเพาะปลูก และทำให้เกษตรกรเร่งระบายสต็อกบางส่วน และไม่ขยายพื้นที่เพิ่มเติมในระยะนี้

ภาพ 40 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาลดลง ปริมาณเพิ่มขึ้น ภายใต้สภาพอากาศ El Niño

Dashboard การคาดการณ์ราคาคุ้งและผลผลิต



บทวิเคราะห์และคำแนะนำ

ราคาคุ้งและปริมาณส่งออกต่างลดลง พร้อมกับสภาพอากาศขึ้นของ La Niña และนำไปให้เกษตรกรชะลอการเพาะปลูกข้าวคราว และเก็บผลผลิตระยะสั้นเพื่อรอจังหวะราคาฟื้นตัว


ภาพ 41 กราฟคาดการณ์ทิศทางและคำแนะนำ
ช่วงราคาลดลง ปริมาณลดลง ภายใต้สภาพอากาศ El Niño

ภาพที่ 34-41 แสดงนี้เป็นตัวอย่าง Dashboard เว็บแอปพลิเคชัน เพื่อแสดงผลการวิเคราะห์และพยากรณ์ราคาคุ้ง ปริมาณการส่งออก และค่าดัชนี ONI (Oceanic Niño Index) ทั้งในรูปแบบของข้อมูลจริงย้อนหลังและค่าที่พยากรณ์ล่วงหน้า 6 เดือน

4.4 การทดสอบโมเดลกับข้อมูลจริงและการประเมินผล

ในการพัฒนาระบบคาดการณ์ สำหรับงานวิจัยนี้ได้ออกแบบให้โมเดลสามารถนำผลลัพธ์ไปแปลความหมายเชิงปฏิบัติ โดยเชื่อมโยงข้อมูลราคาครั้ง ปริมาณการส่งออก และค่าดัชนี ONI เข้ากับตารางคำแนะนำที่จัดทำขึ้นอย่างเป็นระบบ ซึ่งช่วยให้เกษตรกรและผู้เกี่ยวข้องสามารถตัดสินใจได้อย่างเหมาะสมในแต่ละสถานการณ์ ทั้งในด้านการวางแผนการเพาะปลูก การจำหน่ายผลผลิต และการบริหารจัดการความเสี่ยง

Dashboard การคาดการณ์ราคาครั้งและผลผลิต



บทวิเคราะห์และคำแนะนำ

ราคาครั้งเพิ่มขึ้นพร้อมกับปริมาณการส่งออกที่สูงขึ้น สะท้อนตลาดที่แข็งแกร่ง ประกอบกับสภาพอากาศแบบ La Niña ที่เอื้อต่อการเพาะปลูก และแนวโน้มค่า ONI ที่อยู่ในช่วงราคาดี

ภาพ 42 แสดงกราฟคาดการณ์ทิศทางและคำแนะนำ เพื่อเปรียบเทียบระหว่างข้อมูลจริง ผลลัพธ์จริง และผลลัพธ์จากการพยากรณ์

เพื่อประเมินความแม่นยำของโมเดลที่พัฒนา ที่วิจัยได้ทำการทดสอบกับข้อมูลจริง ดังแสดงในรูปที่ 42 พบว่าผลการคาดการณ์มีความใกล้เคียงกับข้อมูลจริง โดยเฉพาะในแง่ของ แนวโน้มราคาและปริมาณการส่งออก ส่งผลให้คำแนะนำของระบบสอดคล้องกับสถานการณ์จริง แสดงถึงศักยภาพในการนำไปใช้งานได้อย่างมีประสิทธิภาพ ผลการประเมินนี้ตอกย้ำความพร้อมของระบบในการเป็นเครื่องมือช่วยตัดสินใจเพื่อเพิ่มประสิทธิภาพในการบริหารจัดการของเกษตรกรและผู้ประกอบการในอุตสาหกรรมครึ่ง

เมื่อพิจารณาผลการทดลองในภาพรวม บทที่ 4 ได้นำเสนอผลการประเมินโมเดล MA-LSTM, Random Forest และ RNN โดยเปรียบเทียบค่าความแม่นยำ เช่น MAE และ RMSE ผลการประเมินพบว่า MA-LSTM ให้ค่าความแม่นยำสูงสุด เหมาะสมสำหรับการพยากรณ์ผลผลิตและราคาครั้ง การวิเคราะห์ยังชี้ถึงความสำคัญของปัจจัยเกี่ยวกับการเจริญเติบโต เช่น ฤดูกาลและอุณหภูมิ พร้อมทั้งการใช้ปัจจัยเสริม เช่น ราคาและดัชนี ONI เพื่อเพิ่มความสมบูรณ์ของการพยากรณ์ ทั้งนี้ การประยุกต์ผลลัพธ์สู่ระบบ Dashboard ช่วยให้เกษตรกรเข้าถึงข้อมูลเชิงลึกและคำแนะนำที่นำไปใช้ได้จริง ช่วยลดความเสี่ยงและเพิ่มประสิทธิภาพในการบริหารจัดการภาคเกษตรอย่างยั่งยืน

บทที่ 5

สรุปผลการศึกษา อภิปรายผล และข้อเสนอแนะ

5.1 สรุปผลการศึกษา

การศึกษานี้มุ่งเน้นการพัฒนาแบบจำลองการพยากรณ์ผลผลิตและทิศทางราคาขายของครึ่ง โดยใช้เทคนิค MA-LSTM ซึ่งออกแบบมาเพื่อรองรับข้อมูลเชิงลำดับที่มีความผันผวนสูง เช่น ปริมาณการส่งออก ราคา และดัชนีภูมิอากาศ (ONI) ที่เปลี่ยนแปลงตามฤดูกาลและสภาพภูมิอากาศโลก

ผลการทดลองแสดงให้เห็นว่า MA-LSTM เป็นแบบจำลองที่ให้ผลการทำนายแม่นยำสูงสุดเมื่อเปรียบเทียบกับโมเดลพื้นฐานอื่น ๆ เช่น Random Forest และ Recurrent Neural Network (RNN) โดย MA-LSTM ให้ค่า MAE ต่ำที่สุดที่ 2.13% และ RMSE ที่ 3.60% แสดงถึงความสามารถในการจับแนวโน้มของข้อมูลและลดความคลาดเคลื่อนได้อย่างมีนัยสำคัญ อีกทั้งยังสามารถรักษาความสม่ำเสมอของผลลัพธ์ในช่วงการคาดการณ์ล่วงหน้า 6 เดือน

การใช้เทคนิคค่าเฉลี่ยเคลื่อนที่แบบเอกซ์โพเนนเชียล (EMA) เพื่อปรับเรียบข้อมูลก่อนนำเข้าสู่โมเดล ยังมีส่วนช่วยเพิ่มเสถียรภาพของข้อมูล ลดผลกระทบจากค่าผิดปกติ และช่วยให้ MA-LSTM สามารถตรวจจับแนวโน้มที่ซ่อนอยู่ได้ชัดเจนยิ่งขึ้น

แม้ว่าการใช้หลายปัจจัยในการพยากรณ์จะช่วยให้เห็นมิติเพิ่มเติมของข้อมูล แต่ผลการทดลองพบว่า “ปริมาณการส่งออก” และ “ค่า ONI” เป็นสองปัจจัยที่มีอิทธิพลโดยตรงและสำคัญที่สุดต่อความแม่นยำของการพยากรณ์ ทั้งในด้านผลผลิตและราคา ทั้งนี้ การเพิ่มปัจจัยทางเศรษฐกิจและภูมิอากาศเพิ่มเติมในอนาคตจะช่วยเสริมศักยภาพของแบบจำลองให้มีความแม่นยำและประยุกต์ใช้ได้หลากหลายยิ่งขึ้น

นอกจากนี้ โมเดล MA-LSTM ยังถูกพัฒนาให้เชื่อมโยงกับระบบแสดงผลแบบ Dashboard ที่สามารถวิเคราะห์แนวโน้มและให้คำแนะนำอัตโนมัติในเชิงกลยุทธ์ เช่น “ขยายพื้นที่การผลิต” หรือ “ชะลอการเพาะปลูก” โดยอ้างอิงจากข้อมูลพยากรณ์ของปริมาณการส่งออก ราคาครึ่ง และค่า ONI เพื่อสนับสนุนการตัดสินใจของเกษตรกรให้แม่นยำยิ่งขึ้น ลดความเสี่ยงจากความผันผวนของตลาด และยกระดับประสิทธิภาพในการบริหารจัดการการผลิตครึ่งในเชิงปฏิบัติอย่างมีประสิทธิภาพ

5.2 อภิปรายผล

ผลการทดลองแสดงให้เห็นว่า MA-LSTM มีความแม่นยำสูงสุด โดยสามารถพยากรณ์แนวโน้มของปริมาณการส่งออกและราคาครั้งได้ใกล้เคียงกับข้อมูลจริง ค่า MAE และ RMSE ต่ำกว่าโมเดลอื่น ๆ ซึ่งสะท้อนถึงความสามารถของโครงสร้าง LSTM ในการจดจำลำดับเวลาและความสัมพันธ์ของข้อมูล ช่วยเพิ่มเสถียรภาพของการพยากรณ์

ผลการทดลองยืนยันว่า MA-LSTM เป็นโมเดลที่มีประสิทธิภาพในการพยากรณ์ผลผลิตและราคาครั้ง โดยให้ค่าความคลาดเคลื่อนต่ำที่สุดในกลุ่มโมเดลที่นำมาทดสอบ ทั้งนี้เป็นผลจากความสามารถของโครงสร้าง LSTM ที่สามารถจดจำลำดับข้อมูลในอดีตและวิเคราะห์ความสัมพันธ์ของข้อมูลเชิงเวลาได้อย่างแม่นยำ

เมื่อเปรียบเทียบกับโมเดลอื่น พบว่า Basic RNN มีผลลัพธ์ที่ผันผวนในบางช่วงเวลา ขณะที่ Random Forest แม้จะให้ผลที่ใกล้เคียงกับข้อมูลจริง แต่มีความคลาดเคลื่อนเพิ่มขึ้นในช่วงท้ายของการพยากรณ์ ทำให้ MA-LSTM เป็นตัวเลือกที่เหมาะสมที่สุดสำหรับบริบทของข้อมูลนี้

การทดสอบด้วยการเพิ่มหลายปัจจัยร่วม เช่น ฤดูกาลและอุณหภูมิ พบว่าไม่ได้ช่วยเพิ่มความแม่นยำของแบบจำลองอย่างมีนัยสำคัญ โดยปัจจัยที่ส่งผลกระทบชัดเจนต่อความแม่นยำได้แก่ ปริมาณการส่งออกและค่า ONI ซึ่งเป็นตัวแปรที่สัมพันธ์โดยตรงกับผลผลิตครั้ง

ประเด็นสำคัญที่ค้นพบจากงานวิจัยนี้:

1. โมเดล MA-LSTM ให้ผลการพยากรณ์ที่แม่นยำที่สุด (MAE 2.13%, RMSE 3.60%)
2. ปริมาณการส่งออกและค่า ONI เป็นปัจจัยสำคัญในการพยากรณ์แนวโน้ม
3. El Niño และ La Niña มีผลโดยตรงต่อแนวโน้มตลาดครั้ง
4. การใช้หลายปัจจัยพร้อมกันไม่ได้เพิ่มความแม่นยำมากกว่าการใช้ปัจจัยเดียว

ในส่วนของการนำข้อมูลนำเข้า งานวิจัยนี้เลือกใช้ "ปริมาณการส่งออก" รายเดือนย้อนหลังเป็นตัวแทนของข้อมูลผลผลิต เนื่องจากยังไม่มีการจัดเก็บข้อมูลผลผลิตครั้งโดยตรงอย่างเป็นทางการในระดับประเทศ

จากการสัมภาษณ์ผู้แทนของบริษัท นอร์ทเทิร์น สยาม ซีด แลค จำกัด ซึ่งเป็นหนึ่งในผู้ส่งออกครั้งรายสำคัญของประเทศ พบว่า ลักษณะการดำเนินงานของอุตสาหกรรมครั้งในประเทศไทยมีรูปแบบ "ผลิตแล้วส่งออกทันที" โดยไม่มีการเก็บสต็อกระยะยาว เนื่องจากความต้องการของโลกไม่เพียงพอต่อปริมาณผลผลิตในบางช่วง และการเก็บรักษาค้างไว้นานทำให้เกิดการสูญเสียน้ำหนักเฉลี่ย 20–30% ขณะที่ราคาจำหน่ายเพิ่มขึ้นเพียง 10% เท่านั้น จึงเกิดความไม่คุ้มค่าในการเก็บรอขาย

ภายใต้ข้อจำกัดนี้ เกษตรกรจึงเลือกจำหน่ายผลผลิตทันที ส่งผลให้ข้อมูลการส่งออกในแต่ละเดือนสามารถใช้แทนผลผลิตที่เกิดขึ้นจริงได้อย่างแม่นยำ การใช้ข้อมูลส่งออกมาเป็นตัวแทนของผลผลิตจึงถือเป็นแนวทางที่เหมาะสมทั้งในเชิงตรรกะและข้อเท็จจริงในภาคอุตสาหกรรม

5.3 ข้อเสนอแนะสำหรับงานวิจัยในอนาคต

แม้ว่าการศึกษาในครั้งนี้จะแสดงให้เห็นว่า โมเดล MA-LSTM สามารถใช้ในการพยากรณ์แนวโน้มผลผลิตและราคาครั้งได้อย่างแม่นยำ แต่ยังมีข้อจำกัดบางประการที่สามารถปรับปรุงได้ในงานวิจัยอนาคต

5.3.1 การเพิ่มปัจจัยด้านเศรษฐกิจและตลาด

ศึกษาผลกระทบของ อัตราแลกเปลี่ยน, ราคาครั้งในตลาดโลก หรือดัชนีสินค้าเกษตรอื่น ๆ ที่อาจส่งผลต่อราคาครั้ง

รวมข้อมูลจาก ประเทศที่นำเข้าครั้ง เพื่อวิเคราะห์ห่วงโซ่อุปสงค์ของตลาดโลก

5.3.2 การพัฒนาโมเดลที่ซับซ้อนขึ้น

ทดลองใช้โมเดล AI ขั้นสูง เช่น Transformer for Time Series Forecasting หรือ Hybrid Models เปรียบเทียบโมเดล MA-LSTM กับ XGBoost หรือ Attention-based LSTM เพื่อดูว่าโมเดลไหนให้ผลลัพธ์ที่ดีที่สุด

5.2.3 การนำโมเดลไปใช้งานจริง

พัฒนา Web Application หรือ Dashboard ที่ให้เกษตรกรสามารถติดตามแนวโน้มตลาดแบบเรียลไทม์สร้าง ระบบแจ้งเตือน (Alert System) ที่สามารถแนะนำช่วงเวลาที่เหมาะสมในการขายหรือชะลอการเพาะเลี้ยง

5.2.4 การปรับปรุงความละเอียดของข้อมูล

ศึกษาการใช้ข้อมูลที่มีความละเอียดสูงขึ้น เช่น รายสัปดาห์หรือรายวัน แทนข้อมูลรายเดือนผสานข้อมูลจากหลายแหล่ง เช่น ดาวเทียมตรวจสอบสภาพอากาศ หรือข้อมูลจากเซ็นเซอร์ของฟาร์มครั้ง เพื่อเพิ่มประสิทธิภาพของแบบจำลอง

5.4 ข้อเสนอแนะในการขยายขอบเขตของตัวแปรนำเข้าไปในแบบจำลอง

แม้แบบจำลอง MA-LSTM ที่พัฒนาขึ้นในงานวิจัยนี้จะสามารถพยากรณ์ผลผลิตและทิศทางราคาครั้งได้อย่างแม่นยำในระดับที่น่าพึงพอใจ แต่เพื่อเพิ่มประสิทธิภาพของโมเดลในอนาคต ผู้วิจัยเสนอให้มีการขยายขอบเขตของตัวแปรนำเข้าไปในแบบจำลองเพิ่มเติม โดยเฉพาะในมิติของปัจจัยเศรษฐกิจและข้อมูลเชิงพื้นที่

ในด้านเศรษฐกิจ ควรพิจารณานำข้อมูลที่มีความสัมพันธ์กับตลาดโลกและต้นทุนของเกษตรกร เช่น อัตราแลกเปลี่ยนเงินบาทต่อดอลลาร์สหรัฐ ราคาครั้งในตลาดต่างประเทศ ต้นทุนการผลิตเฉลี่ย และราคาน้ำมัน มาใช้เป็นปัจจัยร่วมในการพยากรณ์ ทั้งนี้ เนื่องจากตัวแปรเหล่านี้มีอิทธิพลต่อความสามารถในการแข่งขัน การตัดสินใจผลิต และพฤติกรรมการส่งออกในแต่ละช่วงเวลา

ในด้านข้อมูลเชิงพื้นที่ ควรพิจารณาการใช้ข้อมูลระดับจังหวัด เช่น พื้นที่เพาะปลูกครั้ง ปริมาณผลผลิตรายจังหวัด หรือข้อมูลด้านภูมิอากาศจำแนกรายภูมิภาค เพื่อพัฒนาแบบจำลองพยากรณ์แบบเฉพาะพื้นที่ (Localized Forecast) ซึ่งจะช่วยให้ผลการพยากรณ์มีความแม่นยำมากยิ่งขึ้น และสามารถตอบโต้เชิงปฏิบัติในแต่ละพื้นที่ได้ตรงจุดมากกว่าโมเดลภาพรวมระดับประเทศ

การขยายตัวแปรเหล่านี้จะช่วยยกระดับแบบจำลองจากระดับแนวโน้มทั่วไป ไปสู่การเป็นเครื่องมือที่ตอบสนองความต้องการของทั้งเกษตรกร ผู้ประกอบการ และหน่วยงานรัฐในระดับพื้นที่ได้อย่างแท้จริง



ภาคผนวก ก

ข้อมูลที่ใช้ในการวิเคราะห์

ก.1 วิธีใช้งานเว็บไซต์ดึงข้อมูลปริมาณการส่งออกครั้ง

ภาพที่ 44 แสดงวิธีการใช้งานเว็บไซต์กรมศุลกากร <https://www.customs.go.th/> เพื่อดึงข้อมูลการส่งออกครั้ง (HS Code: 13019040) โดยเริ่มจาก (1) เลือกประเภทข้อมูลเป็น Export (2) กรอกรหัส HS-Code 13019040 (3) เลือกประเทศ All Country (4) กำหนดช่วงเวลา เช่น March 2025 (5) คลิกปุ่ม Search เพื่อแสดงข้อมูล หรือ Export / Export CSV เพื่อบันทึกไฟล์ข้อมูล (6) ระบบจะแสดงข้อมูลผลลัพธ์ประกอบด้วยปริมาณการส่งออก (Quantity, KGM) และมูลค่า FOB (Baht) เช่น เดือนมีนาคม 2025 ปริมาณ 43,000 KGM มูลค่า 14,785,363 บาท และยอดรวมมกราคม-มีนาคม 2025 ปริมาณ 89,000 KGM มูลค่า 27,843,146 บาท ข้อมูลนี้ถูกนำมาใช้เป็นฐานสำหรับการวิเคราะห์และพัฒนาแบบจำลอง MA-LSTM ในการวิจัยข้อมูลราคา และปริมาณการส่งออกไฟล์ CSV

The screenshot shows the Thai Customs website interface. The search filters are as follows:

- Type*: Export (1)
- HS-Code: 13019040 (2)
- Country: All Country (3)
- Month*: March (4)
- Year*: 2025 (4)
- Latest released: March 2025
- Buttons: Search (5), Export, Export CSV (5)

Below the filters, there is a table showing the results for HS Code 13019040:

				Mar 2025		Jan - Mar 2025	
HS CODE				Quantity	FOB (Baht)	Quantity	FOB (Baht)
13019040	000	KGM	Lac (KGM)	43,000	14,785,363	89,000	27,843,146
SUM				43,000	14,785,363	89,000	27,843,146

ภาพ 43 วิธีใช้งานเว็บไซต์กรมศุลกากร

เมื่อผู้ใช้กดปุ่ม Export หรือ Export CSV จากหน้าเว็บไซต์ ตามภาพ 44 ระบบจะดาวน์โหลดไฟล์ Excel ภาพ 45 ซึ่งภายในจะแสดงผลข้อมูลการส่งออกครั้งตามรหัส HS-Code 13019040 โดยมีรายละเอียดแบ่งเป็นเดือน เช่น Feb 2024 และช่วงสะสม Jan-Feb 2024 ในแต่ละคอลัมน์จะระบุ Quantity (ปริมาณ, หน่วย KGM) และ FOB (BAHT) ซึ่งหมายถึงมูลค่า FOB เป็นเงินบาท ตัวอย่างเช่น ในเดือนกุมภาพันธ์ 2024 ปริมาณการส่งออกอยู่ที่ 30,000 KGM มูลค่า 10,717,419 บาท ส่วนช่วงมกราคม-กุมภาพันธ์ 2024 ปริมาณรวม 45,000 KGM มูลค่า 15,653,663 บาท นอกจากนี้ยังมีแถว SUM แสดงผลรวมของข้อมูลแต่ละช่วงเพื่อความสะดวกในการวิเคราะห์หรือสรุปผล

A	B	C	D	E	F	G	H
				Feb 2024		Jan - Feb 2024	
HS CODE				Quantity	FOB (BAHT)	Quantity	FOB (BAHT)
13019040	0	KGM	Lac (KGM)	30,000	10,717,419	45,000	15,653,663
SUM				30,000	10,717,419	45,000	15,653,663

ภาพ 44 ไฟล์ Excel ข้อมูลการส่งออกครั้ง

ก.2 วิธีดึงข้อมูลสภาพอากาศ

ในการดึงข้อมูลดัชนีสภาพอากาศ ONI (Oceanic Niño Index) ซึ่งใช้ในการวิเคราะห์ผลกระทบของปรากฏการณ์ El Niño และ La Niña ต่อการผลิตครั้ง สามารถเข้าถึงได้ผ่านเว็บไซต์ NOAA (National Oceanic and Atmospheric Administration) ที่ลิงก์

https://origin.cpc.ncep.noaa.gov/products/analysis_monitoring/ensostuff/detrend.nino34.ascii.txt โดยให้ผู้ใช้คัดลอกลิงก์นี้แล้วเปิดในเว็บเบราว์เซอร์ ข้อมูลที่แสดงเป็นไฟล์ข้อความ (ASCII

format) ซึ่งประกอบด้วยค่า ONI รายเดือนย้อนหลังหลายสิบปี โดยแสดงผลในรูปแบบตารางที่ระบุปีและเดือน พร้อมค่า anomaly ของอุณหภูมิผิวน้ำทะเลบริเวณเขต Niño 3.4 สามารถกดคลิกขวาที่หน้าเว็บเลือก Save As เพื่อบันทึกไฟล์ข้อความ หรือคัดลอกข้อมูลเพื่อนำไปจัดเก็บในไฟล์ CSV ตามภาพที่ 46 และนำเข้ามาใช้ในการประมวลผลเพิ่มเติม เช่น การเชื่อมโยงกับข้อมูลปริมาณการส่งออกเพื่อสร้างโมเดลทำนาย

2016	1	29.11	26.55	2.56
2016	2	29.00	26.76	2.24
2016	3	28.90	27.29	1.61
2016	4	28.73	27.83	0.90
2016	5	28.24	27.94	0.30
2016	6	27.70	27.73	-0.03
2016	7	26.82	27.29	-0.47
2016	8	26.28	26.86	-0.57
2016	9	26.15	26.72	-0.57
2016	10	25.98	26.72	-0.74
2016	11	25.95	26.70	-0.76
2016	12	26.10	26.60	-0.50

ภาพ 45 ข้อมูลดัชนีสภาพอากาศ ONI

ก.3 การเก็บข้อมูลราคาปริมาณการส่งออก และสภาพอากาศรูปแบบ CSV

ไฟล์ข้อมูลข้อมูลราคาปริมาณการส่งออก และสภาพอากาศรูปแบบ CSV เป็นไฟล์ที่รวมข้อมูลสำคัญจากหลายแหล่งเพื่อนำมาใช้ในการสร้างโมเดลพยากรณ์ผลผลิตและราคาครั้ง โดยมีทั้งข้อมูลเชิงปริมาณ เช่น ปริมาณการส่งออก และราคา รวมถึงข้อมูลเชิงสภาพแวดล้อม เช่น ค่า ONI และอุณหภูมิ ซึ่งจัดเก็บแบบเชิงเวลา รายเดือน-ปี การรวมข้อมูลเหล่านี้เข้าด้วยกันทำให้สามารถนำไปใช้เป็นข้อมูลนำเข้า (input) สำหรับการวิเคราะห์และสร้างโมเดล MA-LSTM ได้อย่างมีประสิทธิภาพ ดังแสดงในภาพ 47

```

factor_lasted.csv > data
1  month_year,quantity,price,noi,temp
2  Jan-55,37200,322.1379839,-0.87,23.68
3  Feb-55,146827,355.6953285,-0.67,23.68
4  Mar-55,107632,336.738823,-0.61,25.88
5  Apr-55,51954,167.7141125,-0.49,28.9
6  May-55,20114,25.00054688,-0.32,27.97
7  Jun-55,0,0,0.02,26.68
8  Jul-55,36252,126.0831678,0.25,26.37
9  Aug-55,36807,18.12698671,0.47,27.01
10 Sep-55,114803,217.5087672,0.38,26.73
11 Oct-55,578955,301.7365063,0.26,26.1
12 Nov-55,553400,324.6249223,0.15,25.24
13 Dec-55,545819,406.2946581,-0.25,22.86
14 Jan-56,616640,470.8153769,-0.53,22.36
15 Feb-56,440168,454.9734329,-0.51,25.29
16 Mar-56,279257,398.3522454,-0.25,26.1
17 Apr-56,53925,398.9659342,-0.25,29.7
18 May-56,45450,349.029681,-0.4,29.2
19 Jun-56,71262,449.0447644,-0.43,28

```

ภาพ 46 ข้อมูลราคา ปริมาณการส่งออก และสภาพอากาศ รูปแบบ CSV

ภาคผนวก ข

การวิเคราะห์ข้อมูล

ข.1 การจัดเตรียมข้อมูล

โค้ดนี้ทำหน้าที่เตรียมข้อมูลสำหรับการฝึกโมเดลตามภาพ 48 โดยเริ่มจากโหลดไฟล์ factor_lasted.csv และเลือกเฉพาะคอลัมน์ quantity, price, oni จากนั้นแบ่งข้อมูล 80% สำหรับ train และ 20% สำหรับ test ต่อมาคำนวณค่า Exponential Moving Average (EMA) 5 ช่วงจาก quantity เพื่อลดความผันผวนของข้อมูล และสุดท้ายเลือกเฉพาะคอลัมน์ EMA_5 และ ONI เพื่อใช้ในขั้นตอนการปรับสเกลและการสร้างโมเดลต่อไป

```
# Load data
data = pd.read_csv('factor_lasted.csv')
data_quantity = data[['quantity', 'price', 'noi']]

# Setting 80% data for training
training_data_len = math.ceil(len(data_quantity) * 0.8)
train_data = data_quantity[:training_data_len]
test_data = data_quantity[training_data_len - 1:]

# Compute EMA
train_data['EMA_5'] = train_data['quantity'].ewm(span=5, adjust=False).mean()
test_data['EMA_5'] = test_data['quantity'].ewm(span=5, adjust=False).mean()

# Select relevant columns for scaling
train_data_selected = train_data[['EMA_5', 'noi']]
test_data_selected = test_data[['EMA_5', 'noi']]
```

ภาพ 47 โค้ดการจัดเตรียมข้อมูล

ในส่วนถัดมา ตามภาพ 49 โค้ดทำการปรับสเกลข้อมูลด้วย MinMaxScaler เพื่อให้อยู่ในช่วง 0-1 จากนั้นเตรียมข้อมูล train/test โดยใช้ฟังก์ชัน prepare_data ซึ่งจัดรูปข้อมูลเป็นลำดับเวลา (time series) ตาม time_steps ที่กำหนด สุดท้าย reshaping ข้อมูลให้เป็นรูปแบบที่เหมาะสมกับ LSTM หรือ RNN โดยเพิ่มมิติสำหรับจำนวนฟีเจอร์ เพื่อให้โมเดลสามารถอ่านค่า input ได้อย่างถูกต้อง.

```

# Scale dataset
scaler = MinMaxScaler()
scaled_train = scaler.fit_transform(train_data_selected)
scaled_test = scaler.transform(test_data_selected)

# Prepare training and testing data
def prepare_data(data, time_steps=10):
    X, y = [], []
    for i in range(time_steps, len(data)):
        X.append(data[i - time_steps:i, :])
        y.append(data[i, 0])
    return np.array(X), np.array(y)

X_train, y_train = prepare_data(scaled_train)
X_test, y_test = prepare_data(scaled_test)

# Reshape for LSTM/RNN
X_train = np.reshape(X_train, (X_train.shape[0], X_train.shape[1], X_train.shape[2]))
X_test = np.reshape(X_test, (X_test.shape[0], X_test.shape[1], X_test.shape[2]))

```

ภาพ 48 โค้ดการปรับสเกลข้อมูล และจัดรูปแบบข้อมูล

ข.2 โค้ดการฝึกโมเดล LSTM สำหรับการทำนายผลผลิตครั้ง

สำหรับการสร้างและฝึกโมเดล LSTM ภาพที่ 50 แสดงให้เห็นถึงขั้นตอนการเขียนโค้ด โดยเริ่มจากการสร้างโมเดลด้วยฟังก์ชัน `build_lstm` ซึ่งประกอบด้วยเลเยอร์ LSTM 2 ชั้น และเลเยอร์ Dense อีก 2 ชั้นเพื่อสรุปผลการทำนาย จากนั้นใช้คำสั่ง `model.compile` เพื่อกำหนด optimizer และ loss function ก่อนที่จะนำโมเดลไปฝึก (training) ด้วยข้อมูลชุดฝึก (`X_train, y_train`) ผ่านคำสั่ง `model.fit` โดยกำหนดจำนวนรอบการฝึก (epochs) เท่ากับ 50 และ batch size เท่ากับ 64 ขั้นตอนนี้ช่วยให้โมเดลเรียนรู้รูปแบบเชิงเวลาในข้อมูลได้อย่างมีประสิทธิภาพ เพื่อใช้ในการพยากรณ์ผลผลิตและราคาครั้งในขั้นตอนต่อไป

```
# LSTM model
def build_lstm(input_shape):
    model = Sequential()
    model.add(LSTM(50, return_sequences=True, input_shape=input_shape))
    model.add(LSTM(50))
    model.add(Dense(25))
    model.add(Dense(1))
    model.compile(optimizer='adam', loss='mean_squared_error')
    return model

# Train LSTM
lstm_model = build_lstm((X_train.shape[1], X_train.shape[2]))
lstm_model.fit(X_train, y_train, epochs=50, batch_size=64)
```

ภาพ 49 การสร้างและฝึกโมเดล LSTM สำหรับการทำนายผลผลิตครั้ง

ข.3 การทำนายผล (Prediction)

ในขั้นตอนนี้ โมเดลที่ผ่านการฝึกอบรมแล้วจะถูกนำมาใช้ทำนายค่าผลลัพธ์จากข้อมูลทดสอบ (X_{test}) โดย `lstm_model.predict(X_test)` ใช้สำหรับทำนายด้วยโมเดล LSTM ส่วน `rf_model.predict(...)` ใช้สำหรับทำนายด้วยโมเดล Random Forest ซึ่งจะนำค่าจากชุดทดสอบที่จัดรูปแบบเป็นลำดับ (sequence) เพื่อให้โมเดลสามารถทำนายผลได้อย่างต่อเนื่อง การทำนายนี้เป็นขั้นตอนสำคัญที่นำไปสู่การประเมินและเปรียบเทียบความแม่นยำระหว่างโมเดลต่าง ๆ ทั้งนี้ สามารถดูตัวอย่างโค้ดได้ใน ภาพที่ 51 ขั้นตอนการทำนายผลลัพธ์จากโมเดล LSTM และ Random Forest ซึ่งแสดงให้เห็นการนำข้อมูลชุดทดสอบมาเข้าสู่โมเดลเพื่อคำนวณค่าทำนายที่ใช้ในการวิเคราะห์ผลลัพธ์ต่อไปในบทถัดไป.

```
# Make predictions
y_lstm_pred = lstm_model.predict(X_test)
y_rf_pred = rf_model.predict(np.array([scaled_test[i - 10:i, 0] for i in range(10, len(scaled_test))]))
```


ภาพ 50 ขั้นตอนการทำนายผลลัพธ์จากโมเดล LSTM และ Random Forest

ภาคผนวก ค

การใช้งาน Dashboard

Dashboard ที่พัฒนาขึ้นในงานวิจัยนี้ช่วยแสดงผลการพยากรณ์ราคาครั้ง ปริมาณการส่งออก และค่า ONI ในรูปแบบกราฟเพื่อความเข้าใจง่าย ภาพที่ 52 แสดงตัวอย่าง Dashboard ซึ่งประกอบด้วยกราฟสามส่วน ได้แก่ (1) กราฟราคาครั้งเปรียบเทียบระหว่างค่าจริงกับค่าทำนาย, (2) กราฟปริมาณการส่งออกเปรียบเทียบระหว่างค่าจริงกับค่าทำนาย, และ (3) กราฟค่า ONI แสดงค่าจริงและค่าทำนาย ผู้ใช้งานสามารถดูแนวโน้มในอดีตและการพยากรณ์ในอนาคตเพื่อประกอบการตัดสินใจ เช่น ช่วงราคาสูงที่ควรทยอยขาย หรือช่วง La Niña ที่เหมาะแก่การขยายพื้นที่การผลิต ข้อความสรุปด้านล่าง Dashboard ช่วยแปลความหมายของผลวิเคราะห์เพื่อให้เกษตรกรสามารถวางแผนได้อย่างเหมาะสมและลดความเสี่ยง

Dashboard การคาดการณ์ราคาครั้งและผลผลิต



บทวิเคราะห์และคำแนะนำ

ราคาครั้งเพิ่มขึ้นพร้อมกับปริมาณการส่งออกที่สูงขึ้น สะท้อนตลาดที่แข็งแกร่ง ประกอบกับสภาพอากาศแบบ La Niña ที่เอื้อต่อการเพาะปลูก และน้ำให้เกษตรกรขยายพื้นที่การผลิต และทยอยขายเพื่อทำกำไรช่วงราคาดี

ภาพ 51 ตัวอย่าง Dashboard แสดงการพยากรณ์ราคาครั้ง ปริมาณการส่งออก และค่า ONI

บรรณานุกรม

- Avanija, J., K. Ambati, L. Naraganti, S. S. Derangula and T. Nashina (2024). Crop Recommendation System using Antlion Optimization and Decision Tree Algorithm. 2024 3rd International Conference on Applied Artificial Intelligence and Computing (ICAAIC).
- Bali, N. and A. Singla (2021). An Analysis of Recurrent Neural Network variants to predict yield of Wheat crop in Punjab region. 2021 9th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions) (ICRITO).
- Bashir, N. H., H. Chen, S. Munir, W. Wang, H. Chen, Y.-K. Sima and J. An (2022). "Unraveling the Role of Lac Insects in Providing Natural Industrial Products." Insects **13** DOI: 10.3390/insects13121117.
- Chen, Z., L. Li, B. Wang, J. Fan, T. Lu and K. Lv (2024). "The impact of global warming on ENSO from the perspective of objective signals." Atmospheric Research **299**: 107176.
- Elavarasan, D. and P. M. D. Vincent (2020). "Crop Yield Prediction Using Deep Reinforcement Learning Model for Sustainable Agrarian Applications." IEEE Access **8**: 86886–86901.
- Gupta, M., H. Kodamana and S. Sandeep (2022). "Prediction of ENSO Beyond Spring Predictability Barrier Using Deep Convolutional LSTM Networks." IEEE Geoscience and Remote Sensing Letters **19**: 1–5.
- Jing, L. and M. Bingxiang (2024). Application of an Ensemble Method Based on XGBoost and Transformer in Predicting Sugarcane and Dragon Fruit Yields in Guangxi Region. 2024 IEEE 3rd International Conference on Electrical Engineering, Big Data and Algorithms (EEBDA).
- Kurumatani, K. (2018). Time Series Prediction of Agricultural Products Price Based on Time Alignment of Recurrent Neural Networks. 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA).
- Marsetič, A. and U. Kanjir (2024). "Forecasting Vegetation Behavior Based on PlanetScope Time Series Data Using RNN-Based Models." IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing **17**: 5015–5025.
- Mateo-Sanchis, A., J. E. Adsua, M. Piles, J. Munoz-Mari, A. Perez-Suay and G. Camps-Valls (2023). "Interpretable Long Short-Term Memory Networks for Crop Yield Estimation."

IEEE Geoscience and Remote Sensing Letters **20**: 1–5.

Saini, P. and B. Nagpal (2022). Deep-LSTM Model for Wheat Crop Yield Prediction in India. 2022 Fifth International Conference on Computational Intelligence and Communication Technologies (CCICT).

Sharma, K. (2017). Lac Insects and Host Plants: 157–180.

Sharma, K. (2019). Understanding the Diversity of Lac Insects of *Kerria* spp. in India and the Nature of Insect–Host Plant Interaction: 219–233.

Sharma, P., P. Dadheech, N. Aneja and S. Aneja (2023). "Predicting Agriculture Yields Based on Machine Learning Using Regression and Deep Learning." IEEE Access **11**: 111255–111264.

Verma, H., A. Singh and S. Avasthi (2023). Linear Regression–Based Prediction Model For Real Estate Properties in India. 2023 Seventh International Conference on Image Information Processing (ICIIP).

Yang, S., L. Hu, H. Wu, H. Ren, H. Qiao, P. Li and W. Fan (2021). "Integration of Crop Growth Model and Random Forest for Winter Wheat Yield Estimation From UAV Hyperspectral Imagery." IEEE Journal of Selected Topics in Applied Earth Observations and Remote Sensing **14**: 6253–6269.

Ye, F., J. Hu, T. Q. Huang, L. J. You, B. Weng and J. Y. Gao (2022). "Transformer for El Niño–Southern Oscillation Prediction." IEEE Geoscience and Remote Sensing Letters **19**: 1–5.

Zhang, R.–H., L. Zhou, C. Gao and L. Tao (2024). "A transformer–based coupled ocean–atmosphere model for ENSO studies." Science Bulletin.

สุบรรณเสณ, ว. (2014). การเพาะเลี้ยงครั้งและการใช้ประโยชน์ครั้ง.

ประวัติผู้วิจัย

ชื่อ-สกุล	ทศพร มาเนียม
วัน เดือน ปี เกิด	23 มกราคม 2538
สถานที่เกิด	พิษณุโลก
ที่อยู่ปัจจุบัน	172/2 หมู่ 1 ตำบลบ้านบึง อำเภอเมืองพิจิตร จังหวัด พิจิตร

