

การพยากรณ์ปริมาณความต้องการเหล็กที่ร้อนภายในประเทศด้วยวิธีการเรียนรู้ของเครื่อง



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

สาขาวิชาวิศวกรรมอุตสาหการ ภาควิชาวิศวกรรมอุตสาหการ

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2563

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Domestic Hot Rolled Steel Demand Forecasting Using Machine Learning Methods



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Engineering in Industrial Engineering

Department of Industrial Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2020

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์

การพยากรณ์ปริมาณความต้องการเหล็กดีร์รอน
ภายในประเทศด้วยวิธีการเรียนรู้ของเครื่อง

โดย

นายชัยพฤกษ์ นิละนนท์

สาขาวิชา

วิศวกรรมอุตสาหการ

อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

อาจารย์ ดร.นันทชัย กานตานันทะ

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์

..... คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)

..... ประธานกรรมการ
(รองศาสตราจารย์ ดร.ดาริชา สุธีวงศ์)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(อาจารย์ ดร.นันทชัย กานตานันทะ)

..... กรรมการ
(รองศาสตราจารย์ ดร.นระเกณท์ พุ่มชูศรี)

..... กรรมการภายนอกมหาวิทยาลัย
(รองศาสตราจารย์ ดร.จันทร์ศิริ สิงห์เถื่อน)

ชัยพฤกษ์ นิละนนท์ : การพยากรณ์ปริมาณความต้องการเหล็กรีดร้อนภายในประเทศ
ด้วยวิธีการเรียนรู้ของเครื่อง. (Domestic Hot Rolled Steel Demand Forecasting
Using Machine Learning Methods) อ.ที่ปรึกษาหลัก : อ. ดร.นันทชัย กานตานันท์

เหล็กเป็นวัสดุที่สำคัญชนิดหนึ่งและมีปริมาณความต้องการใช้งานมากขึ้นทุกปี
ในอุตสาหกรรมเหล็ก การพยากรณ์เพื่อวางแผนการจัดซื้อวัตถุดิบ การจัดเตรียมการผลิต และ
แผนการขายจึงเป็นสิ่งที่สำคัญ การพยากรณ์ที่แม่นยำสามารถทำให้การวางแผนต่าง ๆ เป็นอย่าง
เหมาะสมและสามารถลดต้นทุนในการผลิตและการดำเนินการได้ งานวิจัยนี้จัดทำขึ้นเพื่อศึกษาการ
พยากรณ์และเปรียบเทียบความแม่นยำในการพยากรณ์ข้อมูลปริมาณความต้องการเหล็กรีดร้อน
ภายในประเทศ โดยใช้ข้อมูลตั้งแต่เดือนมกราคมปี ค.ศ. 2014 จนถึงเดือนธันวาคมปี ค.ศ. 2019
ตัวแบบการพยากรณ์ที่ใช้ในงานวิจัยนี้ประกอบไปด้วย ตัวแบบ Holt's Exponential Smoothing,
ARIMA, Multiple Regression, Artificial Neural Network, eXtreme Gradient Boosting,
Random Forest, Support Vector Regression และ Light Gradient Boosting Machine
และตัวแบบผสมที่คัดเลือกจากตัวแบบการเรียนรู้ของเครื่องที่มีความแม่นยำที่สุดสามอันดับแรกมา
ทำการผสม จากนั้นทำการเปรียบเทียบความแม่นยำด้วยค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย
(MAPE)

ผลการวิจัยพบว่าตัวแบบที่มีความแม่นยำมากที่สุดคือตัวแบบผสม Artificial
Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ
Artificial Neural Network เป็นตัวผสม มีค่า MAPE เท่ากับ 3.59% แม่นยำกว่าตัวแบบ
Artificial Neural Network ที่เป็นตัวแบบการเรียนรู้ของเครื่องที่แม่นยำที่สุดด้วยค่า MAPE
เท่ากับ 5.63% ถึง 36.23%

สาขาวิชา วิศวกรรมอุตสาหการ

ลายมือชื่อนิสิต

ปีการศึกษา 2563

ลายมือชื่อ อ.ที่ปรึกษาหลัก

6270062821 : MAJOR INDUSTRIAL ENGINEERING

KEYWORD: Forecasting, Steel consumption amount, Hot rolled steel, Steel industry, Machine Learning, Hybrid Model

Chaiyapruerk Nilanon : Domestic Hot Rolled Steel Demand Forecasting Using Machine Learning Methods. Advisor: Lect. NANTACHAI KANTANANTHA, Ph.D.

Steel is one of the most important materials and its demand is increasing every year. In the steel industry, forecasting is very important for the procurement planning of raw materials, production arrangement, and sales plan. The accurate forecast can optimize planning and reduce production and operating costs. This research was conducted to study the forecast and compare the forecasting accuracy of domestic hot-rolled steel demand volume data using data from January 2014 to December 2019. The forecasting models used in this study included Holt's Exponential Smoothing, ARIMA, Multiple Regression, Artificial Neural Network, eXtreme Gradient Boosting, Random Forest, Support Vector Regression, Light Gradient Boosting Machine, and hybrid models selected from the top three of machine learning models and evaluate the accuracy with mean absolute percentage error (MAPE).

The results showed that the most accurate model is the hybrid model of Artificial Neural Network, Random Forest, and eXtreme Gradient Boosting hybridized using Artificial Neural Network model with a MAPE of 3.59%. It has higher accuracy than the Artificial Neural Network model, the most accurate machine learning model, with a MAPE of 5.63% for 36.23%.

Field of Study: Industrial Engineering

Student's Signature

Academic Year: 2020

Advisor's Signature

กิตติกรรมประกาศ

ผู้วิจัยขอกราบขอบพระคุณอาจารย์ ดร. นันทชัย กานตานันทะ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ผู้กรุณาช่วยเหลือ ให้คำแนะนำ ให้ความรู้ และชี้ให้เห็นข้อบกพร่องต่าง ๆ ด้วยความเอาใจใส่อย่างดียิ่ง ตลอดการดำเนินงานวิจัย จนวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดี นอกจากนี้ยังทำให้ผู้วิจัยเข้าใจใน การทำงาน การหาความรู้ และประสบการณ์นอกตำราเรียน ซึ่งมีประโยชน์ต่อการดำเนินการวิจัย การ ทำงาน และการดำเนินชีวิตต่อไป และขอขอบพระคุณท่านประธานกรรมการ รองศาสตราจารย์ ดร. ดา ริชา สุธีวงศ์ ท่านกรรมการ รองศาสตราจารย์ ดร. นระเกณท์ พุ่มชูศรี และ รองศาสตราจารย์ ดร. จันทร์ ศิริ สิงห์เถื่อน ผู้ชี้แนะและให้คำแนะนำในการดำเนินการวิจัยและวิทยานิพนธ์นี้ให้สมบูรณ์ยิ่งขึ้น

ขอขอบพระคุณบิดา มารดา และครอบครัวของผู้วิจัยที่ให้การสนับสนุน ให้กำลังใจ และเป็น แรงผลักดันในการศึกษาและดำเนินการวิจัยจนสำเร็จการศึกษา และขอบคุณเพื่อน ๆ ในภาควิชาที่คอย ช่วยเหลือ ให้คำปรึกษา ให้กำลังใจ มอบประสบการณ์ในการศึกษาที่ดีแก่ผู้วิจัย

ชัยพลกษั นิละนนท์

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ฉ
สารบัญรูปภาพ.....	ฉ
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญ.....	1
1.2 ลักษณะปัญหา.....	5
1.3 วัตถุประสงค์ของงานวิจัย.....	5
1.4 ขอบเขตของงานวิจัย.....	6
1.4.1 การพยากรณ์.....	6
1.4.2 ขอบเขตของข้อมูล.....	6
1.4.3 ตัวแบบในการพยากรณ์ที่ใช้ในงานวิจัย.....	7
1.4.4 การเปรียบเทียบความแม่นยำ.....	8
1.5 ผลที่คาดว่าจะได้รับ.....	8
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	8
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	9
2.1 ข้อมูลพื้นฐานเกี่ยวกับอุตสาหกรรมเหล็กแผ่นรีดร้อน.....	9

2.2 การพยากรณ์แบบอนุกรมเวลา (Time Series Forecasting).....	13
2.2.1 ตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์ (Holt’s Exponential Smoothing Model)	13
2.2.2 ตัวแบบ Autoregressive Integrated Moving Average (ARIMA)	14
2.3 การพยากรณ์เชิงสาเหตุ (Causal Method Forecasting).....	16
2.3.1 ตัวแบบการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression).....	16
2.4 การเรียนรู้ของเครื่อง (Machine Learning: ML)	17
2.4.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning).....	19
2.4.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning).....	22
2.4.3 การเรียนรู้แบบเสริมแรง (Reinforcement Learning).....	23
2.4.4 Artificial Neural Network (ANN).....	25
2.4.5 Support Vector Machine (SVM) and Support Vector Regression (SVR).....	27
2.4.6 Random Forest (RF).....	29
2.4.7 eXtreme Gradient Boosting (XGboost)	31
2.4.8 Light Gradient Boosting Machine (LGBM).....	32
2.4.9 วิธีการพยากรณ์แบบผสม (Hybrid Method)	33
2.5 การประเมินผลการพยากรณ์	33
2.6 ทบทวนวรรณกรรม.....	35
2.6.1 Application of machine learning techniques for supply chain demand forecasting.....	35
2.6.2 Forecasting tourism demand to Catalonia: Neural networks vs. time series models.....	36
2.6.3 Forecasting of demand using ARIMA model	36
2.6.4 Short-term electricity demand forecasting using double seasonal exponential smoothing	37

2.6.5 Day-ahead load forecast using random forest and expert input selection	38
2.6.6 Stock index forecasting base on a hybrid model	39
2.6.7 Research on China's Steel Demand Using Combined Forecast	40
2.6.8 Forecasting for Steel Production using Artificial Neural Networks and Feasibility Analysis of Plant Regeneration Acid Development in PT. XYZ	41
2.6.9 Analyzing Structure and Driving Force of Steel Consumption in China	42
2.6.10 Modeling steel supply and demand functions using logarithmic multiple regression analysis (case study: Steel industry in Iran)	43
2.6.11 Polish steel consumption.....	44
2.6.12 Trends and development of steel demand in China: A bottom-up analysis	45
2.6.13 Forecasting iron ore import and consumption of China using grey model optimized by particle swarm optimization algorithm	47
บทที่ 3 วิธีการดำเนินการวิจัย	52
3.1 การรวบรวมข้อมูล	52
3.2 การจัดการและวิเคราะห์ข้อมูล	52
3.3 การปรับข้อมูล (Data Normalization).....	55
3.4 ตัวแบบการพยากรณ์	56
3.4.1 ตัวแบบการพยากรณ์อนุกรมเวลา.....	56
3.4.2 ตัวแบบการพยากรณ์เชิงสาเหตุ.....	58
3.4.3 ตัวแบบการพยากรณ์ด้วยการเรียนรู้ของเครื่อง.....	58
3.4.4 ตัวแบบการพยากรณ์ผสม.....	58
3.5 การประเมินผลการพยากรณ์	59
บทที่ 4 ผลการดำเนินการ	60

4.1 การพยากรณ์ด้วยตัวแบบอนุกรมเวลา	60
4.1.1 ตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์	60
4.1.2 ตัวแบบ Autoregressive Integrated Moving Average (ARIMA)	63
4.2 การพยากรณ์ด้วยตัวแบบเชิงสาเหตุ.....	66
4.2.1 ตัวแบบการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression).....	66
4.3 การพยากรณ์ด้วยตัวแบบการเรียนรู้ของเครื่อง	79
4.3.1 ตัวแบบ Artificial Neural Network (ANN).....	79
4.3.2 ตัวแบบ Support Vector Regression (SVR).....	85
4.3.3 ตัวแบบ Random Forest (RF)	90
4.3.4 ตัวแบบ eXtreme Gradient Boosting (XGboost).....	94
4.3.5 ตัวแบบ Light Gradient Boosting Machine (LGBM).....	97
4.4 การพยากรณ์ด้วยตัวแบบผสม.....	100
4.4.1 ตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	103
4.4.2 ตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ ตัวแบบ Artificial Neural Network เป็นตัวผสม	107
4.4.3 ตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	111
4.4.4 ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	115
4.4.5 ตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม.....	119
4.4.6 ตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ ตัวแบบ Random Forest เป็นตัวผสม	124
4.4.7 ตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม.....	129

4.4.8	ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม.....	134
4.4.9	ตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม.....	139
4.4.10	ตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม.....	142
4.4.11	ตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม.....	145
4.4.12	ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม...	148
4.5	การประเมินผลการพยากรณ์.....	150
4.5.1	กลุ่มตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุ.....	150
4.5.2	กลุ่มตัวแบบการเรียนรู้ของเครื่อง.....	152
4.5.3	กลุ่มตัวแบบผสม.....	153
4.5.4	ความแม่นยำและเวลา.....	156
4.6	ผลการพยากรณ์สำหรับทดสอบตัวแบบ.....	158
บทที่ 5	สรุปผลการวิจัยและข้อเสนอแนะ.....	161
5.1	สรุปผล.....	161
5.2	ข้อเสนอแนะ.....	165
บรรณานุกรม.....		167
ภาคผนวก ก.....		172
ประวัติผู้เขียน.....		191

สารบัญตาราง

	หน้า
ตารางที่ 2-1 A Scale of Judgment of Forecast Accuracy (Lewis, 1982).....	34
ตารางที่ 2-2 ผลการพยากรณ์ปี ค.ศ. 2010 ของตัวแบบที่มีความคลาดเคลื่อนน้อยที่สุด 3 ตัวแบบ	41
ตารางที่ 2-3 ผลการวิเคราะห์เชิงสถิติของตัวแบบ (Mehmanpazir et al., 2019).....	44
ตารางที่ 2-4 สรุปและเปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ความต้องการเหล็ก.....	49
ตารางที่ 3-1 ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ.....	53
ตารางที่ 4-1 AICc ของตัวแบบการ ARIMA.....	64
ตารางที่ 4-2 การเปรียบเทียบค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยของตัวแบบการพยากรณ์การ ถดถอยเชิงเส้นพหุคูณ.....	79
ตารางที่ 4-3 ข้อเสนอแนะการกำหนดจำนวนชั้นซ่อน (Heaton, 2017)	81
ตารางที่ 4-4 การเปรียบเทียบความแม่นยำสำหรับตัวแบบเดี่ยว.....	100
ตารางที่ 4-5 การเปรียบเทียบ MAPE ของตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุสำหรับข้อมูล ตรวจสอบตัวแบบ.....	151
ตารางที่ 4-6 การเปรียบเทียบ MAPE ของตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุสำหรับข้อมูล ตรวจสอบตัวแบบ.....	153
ตารางที่ 4-7 การเปรียบเทียบ MAPE ของตัวแบบผสมสำหรับข้อมูลตรวจสอบตัวแบบ.....	155
ตารางที่ 4-8 เวลาที่ใช้ในการสร้างตัวแบบของตัวแบบการเรียนรู้ของเครื่องและตัวแบบผสม.....	157

สารบัญรูปภาพ

	หน้า
รูปที่ 1-1 ปริมาณการผลิตเหล็กดิบทั่วโลก.....	2
รูปที่ 1-2 ปริมาณการผลิต ปริมาณการนำเข้า ปริมาณการส่งออก และปริมาณความต้องการ ของเหล็กแผ่นรีดร้อน.....	2
รูปที่ 1-3 โครงสร้างต้นทุนของอุตสาหกรรมผลิตเหล็ก	3
รูปที่ 1-4 ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศไทย พ.ศ. 2556 – 2562.....	6
รูปที่ 2-1 ลำดับของอุตสาหกรรมเหล็กกล้า	9
รูปที่ 2-2 องค์ประกอบของโรงถลุงแบบเตาถลุงพ่นลม	10
รูปที่ 2-3 องค์ประกอบของเตาพ่นออกซิเจน	11
รูปที่ 2-4 องค์ประกอบของเตาอาร์คไฟฟ้า	11
รูปที่ 2-5 องค์ประกอบกระบวนการผลิตเหล็กแผ่นรีดร้อนชนิดม้วน	12
รูปที่ 2-6 กระบวนการทำงานของโปรแกรมทั่วไป	17
รูปที่ 2-7 กระบวนการทำงานของการเรียนรู้ของเครื่อง	18
รูปที่ 2-8 ประเภทของการเรียนรู้ของเครื่องจักร จำแนกตามตัวแบบการเรียนรู้	19
รูปที่ 2-9 การทำนายเพื่อระบุว่าข้อมูลภาพนำเข้าระบบเป็นสิ่งใด.....	20
รูปที่ 2-10 การหาสมการพยากรณ์ด้วยวิธี Regression จากความสัมพันธ์ระหว่างราคาและ ทำเลของที่ดิน	21
รูปที่ 2-11 ตัวอย่างการทำงานของ การเรียนรู้ของเครื่องแบบมีผู้สอน	23
รูปที่ 2-12 ตัวอย่างการทำงานของ การเรียนรู้ของเครื่องแบบไม่มีผู้สอน	23
รูปที่ 2-13 ตัวอย่างการทำงานของ การเรียนรู้ของเครื่องแบบเสริมแรง	24
รูปที่ 2-14 ส่วนประกอบของเซลล์ประสาท	25
รูปที่ 2-15 แบบจำลองการทำงานของประสาทเทียมใน Artificial Neural Network	26
รูปที่ 2-16 แบบจำลองการทำงานของ Artificial Neural Network	27

รูปที่ 2-17 แบบจำลองการทำงานของ Support Vector Machine.....	28
รูปที่ 2-18 ตัวแบบ Support Vector Machine (บน) และ Support Vector Regression (ล่าง). 29	
รูปที่ 2-19 แบบจำลอง Decision tree.....	30
รูปที่ 2-20 แบบจำลอง Random Forest.....	31
รูปที่ 2-21 ความแตกต่างระหว่าง Bagging และ Boosting	32
รูปที่ 2-22 Level-wise and Leaf-wise tree growth.....	33
รูปที่ 2-23 Half-hourly electricity demand in England and Wales from Monday 5 June 2000 to Sunday 18 June 2000 (Taylor, 2003).....	37
รูปที่ 2-24 Regression tree	38
รูปที่ 2-25 The flow chart of the PHM	40
รูปที่ 2-26 ผลการพยากรณ์จากตัวแบบการพยากรณ์ 4 วิธี.....	42
รูปที่ 2-27 ความต้องการเหล็กจริงและผลการพยากรณ์ความต้องการเหล็ก	43
รูปที่ 2-28 ความต้องการเหล็กจริงและผลการพยากรณ์ความต้องการเหล็กในประเทศโปแลนด์.....	45
รูปที่ 2-29 Bottom-up analysis model of steel demand.....	46
รูปที่ 2-30 Future steel consumption in China, 2010-2050.....	46
รูปที่ 2-31 PSO-based GM(1,1) prediction model	47
รูปที่ 2-32 The comparison of the actual and forecast import volume	48
รูปที่ 3-1 ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ ตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560	54
รูปที่ 3-2 ปริมาณความต้องการเหล็กแผ่นรีดร้อนแยกเป็นรายปีตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560	55
รูปที่ 3-3 ACF ของปริมาณความต้องการเหล็กแผ่นรีดร้อนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560	57
รูปที่ 3-4 PACF ของปริมาณความต้องการเหล็กแผ่นรีดร้อน ตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560..	57
รูปที่ 4-1 ผลการปรับปรุงการพยากรณ์ระหว่างค่าระดับและค่าแนวโน้ม.....	60

รูปที่ 4-2 ผลการพยากรณ์ผลการพยากรณ์สำหรับตรวจสอบตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์.....	61
รูปที่ 4-3 ACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์.....	62
รูปที่ 4-4 PACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์.....	62
รูปที่ 4-5 ผลการพยากรณ์ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Autoregressive Integrated Moving Average	65
รูปที่ 4-6 ACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบ ARIMA(2,1,0)	65
รูปที่ 4-7 PACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบ ARIMA(2,1,0)	66
รูปที่ 4-8 ปริมาณความต้องการเหล็กแบ่งตามกลุ่มอุตสาหกรรม ข้อมูลปี 2560	67
รูปที่ 4-9 ผลการพยากรณ์ผลการพยากรณ์สำหรับตรวจสอบตัวแบบการพยากรณ์แบบถดถอยพหุคูณโดยใช้ปัจจัยที่ผ่านกระบวนการ Stepwise.....	70
รูปที่ 4-10 ค่า Residual ของตัวแบบการถดถอยเชิงเส้นพหุคูณปริมาณความต้องการเหล็กแผ่นรีดร้อน.....	70
รูปที่ 4-11 ปริมาณการจำหน่ายซีเมนต์พอร์ตแลนด์เทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อน....	71
รูปที่ 4-12 ปริมาณการจำหน่ายรถยนต์รวมทุกประเภทเทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อน	72
รูปที่ 4-13 ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้าเทียบกับปริมาณความต้องการเหล็กแผ่นรีดร้อน.....	73
รูปที่ 4-14 ผลิตภัณฑ์มวลรวมในประเทศเทียบกับปริมาณความต้องการเหล็กแผ่นรีดร้อน	74
รูปที่ 4-15 ปริมาณการนำเข้าเทียบกับปริมาณความต้องการเหล็กแผ่นรีดร้อน.....	75
รูปที่ 4-16 ผลการพยากรณ์ด้วยตัวแบบการพยากรณ์แบบถดถอยพหุคูณโดยใช้ปัจจัยที่ผ่านเงื่อนไข	78
รูปที่ 4-17 ค่า Residual ของตัวแบบการถดถอยเชิงเส้นพหุคูณโดยใช้ปัจจัยที่ผ่านเงื่อนไข	78
รูปที่ 4-18 ลักษณะของ Activation function แบบ ReLU	82
รูปที่ 4-19 ลักษณะของ Activation function แบบ Sigmoid.....	82
รูปที่ 4-20 ผลของ Epoch และ Batch size ต่อ MAPE	83

รูปที่ 4-21 ผลของ Activation function ต่อ MAPE.....	84
รูปที่ 4-22 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Artificial Neural Network	85
รูปที่ 4-23 ผลจากการปรับค่า Hyperparameter C.....	86
รูปที่ 4-24 การพิจารณาข้อมูลเมื่อกำหนดค่า Gamma สูงและต่ำ.....	87
รูปที่ 4-25 ลักษณะของ Hyperplane เมื่อกำหนดค่า Gamma ที่ 0 10 และ 100.....	87
รูปที่ 4-26 ลักษณะการทำงานของ Kernel ที่ต่างกันบนข้อมูลชุดเดียวกัน	88
รูปที่ 4-27 ผลของ C และ Kernel ต่อ MAPE.....	89
รูปที่ 4-28 ผลของ Gamma และ Kernel ต่อ MAPE	89
รูปที่ 4-29 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Support Vector Regression	90
รูปที่ 4-30 ตัวอย่างการกำหนด max_depth = 3.....	91
รูปที่ 4-31 ตัวอย่างการกำหนด min_samples_leaf = 2 (ช่าย) และ 6 (ขวา)	92
รูปที่ 4-32 ผลของ min_samples_leaf และ n_estimators ต่อ MAPE	93
รูปที่ 4-33 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Random Forest	94
รูปที่ 4-34 ผลของ learning_rate และ n_estimators ต่อ MAPE.....	96
รูปที่ 4-35 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ eXtreme Gradient Boosting	97
รูปที่ 4-36 ผลของ learning_rate และ n_estimators ต่อ MAPE.....	99
รูปที่ 4-37 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Light Gradient Boosting Machine.....	100
รูปที่ 4-38 วิธีการผสมตัวแบบ Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม.....	103
รูปที่ 4-39 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE.....	104
รูปที่ 4-40 ผลของ Activation function ต่อค่าเฉลี่ย MAPE	105
รูปที่ 4-41 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	106
รูปที่ 4-42 วิธีการผสมตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	107

รูปที่ 4-43 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE.....	108
รูปที่ 4-44 ผลของ Activation function ต่อค่าเฉลี่ย MAPE	109
รูปที่ 4-45 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	110
รูปที่ 4-46 วิธีการผสมตัวแบบ Random Forest และ eXtreme Gradient Boosting โดยใช้ตัว แบบ Artificial Neural Network เป็นตัวผสม.....	111
รูปที่ 4-47 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE.....	112
รูปที่ 4-48 ผลของ Activation function ต่อค่าเฉลี่ย MAPE	113
รูปที่ 4-49 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	114
รูปที่ 4-50 วิธีการผสมตัวแบบ Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	115
รูปที่ 4-51 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE.....	116
รูปที่ 4-52 ผลของ Activation function ต่อค่าเฉลี่ย MAPE	117
รูปที่ 4-53 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม	118
รูปที่ 4-54 วิธีการผสมตัวแบบ Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม.....	119
รูปที่ 4-55 ผลของ min_samples_leaf และ n_estimators ต่อค่าเฉลี่ย MAPE.....	120
รูปที่ 4-56 ผลของ n_estimators ต่อค่าเฉลี่ย MAPE	121
รูปที่ 4-57 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE	122
รูปที่ 4-58 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม.....	123
รูปที่ 4-59 วิธีการผสมตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม.....	124

รูปที่ 4-60 ผลของ min_samples_leaf และ n_estimators ต่อค่าเฉลี่ย MAPE.....	125
รูปที่ 4-61 ผลของ n_estimators ต่อค่าเฉลี่ย MAPE	126
รูปที่ 4-62 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE	127
รูปที่ 4-63 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม	128
รูปที่ 4-64 วิธีการผสมตัวแบบ Random Forest และ eXtreme Gradient Boosting โดยใช้ตัว แบบ Random Forest เป็นตัวผสม.....	129
รูปที่ 4-65 ผลของ min_samples_leaf และ n_estimators ต่อค่าเฉลี่ย MAPE.....	130
รูปที่ 4-66 ผลของ n_estimators ต่อค่าเฉลี่ย MAPE	131
รูปที่ 4-67 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE	132
รูปที่ 4-68 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม	133
รูปที่ 4-69 วิธีการผสมตัวแบบ Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม	134
รูปที่ 4-70 ผลของ min_samples_leaf และ n_estimators ต่อ MAPE	135
รูปที่ 4-71 ผลของ n_estimators ต่อค่าเฉลี่ย MAPE	136
รูปที่ 4-72 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE	137
รูปที่ 4-73 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม.....	138
รูปที่ 4-74 วิธีการผสมตัวแบบ Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม	139
รูปที่ 4-75 ผลของ min_child_weight และ n_estimators ต่อ MAPE	140
รูปที่ 4-76 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม	141
รูปที่ 4-77 วิธีการผสมตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม	142

รูปที่ 4-78 ผลของ min_child_weight และ n_estimators ต่อ MAPE	143
รูปที่ 4-79 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม	144
รูปที่ 4-80 วิธีการผสมตัวแบบ Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม.....	145
รูปที่ 4-81 ผลของ min_child_weight และ n_estimators ต่อ MAPE	146
รูปที่ 4-82 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม	147
รูปที่ 4-83 วิธีการผสมตัวแบบ Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม	148
รูปที่ 4-84 ผลของ min_child_weight และ n_estimators ต่อ MAPE	149
รูปที่ 4-85 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม.....	150
รูปที่ 4-86 ผลการพยากรณ์สำหรับตรวจสอบของกลุ่มตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุ.	151
รูปที่ 4-87 ผลการพยากรณ์สำหรับตรวจสอบของกลุ่มตัวแบบการเรียนรู้ของเครื่อง.....	152
รูปที่ 4-88 ผลการพยากรณ์สำหรับตรวจสอบของกลุ่มตัวแบบผสม	154
รูปที่ 4-89 เวลาที่ใช้ในการสร้างตัวแบบของตัวแบบการเรียนรู้ของเครื่องและตัวแบบผสม กับค่า MAPE จากผลการพยากรณ์สำหรับตรวจสอบตัวแบบ	156
รูปที่ 4-90 การใช้ข้อมูลในการสร้างตัวแบบและการพยากรณ์	158
รูปที่ 4-91 ผลการพยากรณ์สำหรับทดสอบตัวแบบผสม โดยใช้ข้อมูลสร้างตัวแบบ 48 ข้อมูล	159
รูปที่ 4-92 ผลการพยากรณ์สำหรับทดสอบตัวแบบผสม โดยใช้ข้อมูลสร้างตัวแบบ 60 ข้อมูล	160
รูปที่ 5-1 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest ที่ใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม เปรียบเทียบกับตัวแบบการเรียนรู้ของเครื่องที่เกี่ยวข้อง.....	164

บทที่ 1


บทนำ

1.1 ที่มาและความสำคัญ


เหล็กเป็นวัสดุชนิดหนึ่งที่สำคัญ เนื่องจากสามารถใช้งานได้หลากหลาย มีความแข็งแรง และทำการขึ้นรูปได้หลากหลาย ตั้งแต่อดีตจนถึงปัจจุบันมนุษย์เริ่มใช้เหล็กตั้งแต่ขณะยังไม่สามารถแปรรูปได้โดยใช้แร่เหล็กโดยนำมาทำเป็นอาวุธ จนมีการพัฒนาการแปรรูปมนุษย์สามารถนำมาขึ้นรูปเป็นอาวุธ เครื่องใช้โลหะ จนไปถึงสิ่งก่อสร้าง ปัจจุบันเหล็กเป็นส่วนประกอบในสิ่งต่างรอบตัวเรามากมาย เช่นเครื่องใช้ไฟฟ้า รถยนต์ อาคาร และสิ่งก่อสร้าง การผลิตเหล็กมีกระบวนการที่ซับซ้อนมากมาย ตั้งแต่การทำเหมืองเพื่อขุดหาแร่เหล็ก จากนั้นขนส่งแร่เหล็กมาทำการการถลุงแยกสิ่งเจือปน กลายเป็นก้อนหรือแท่งขนาดใหญ่ของเหล็กและเหล็กกล้าสำหรับนำไปแปรรูปต่อไปจนเป็นชิ้นส่วนสำเร็จที่นำมาใช้งานตามวัตถุประสงค์

อุตสาหกรรมเหล็กเป็นอุตสาหกรรมสำคัญของโลก และมีปริมาณการใช้งานมากขึ้นอย่างต่อเนื่องทุกปี ตั้งแต่ พ.ศ. 2547 การผลิตเหล็กดิบมีปริมาณสูงกว่า 1,000 ล้านตัน และยังเพิ่มขึ้นอย่างต่อเนื่องเป็น 1,433.4 ล้านตันใน พ.ศ. 2553 และ 1,869 ล้านตันใน พ.ศ. 2562 การเติบโตของการผลิตเหล็กดิบทั่วโลกแสดง ดังรูปที่ 1-1 จากปริมาณการผลิตเหล็กดิบทั่วโลกในแต่ละปี (World Steel Association, 2020) ซึ่งสามารถสะท้อนให้เห็นความต้องการและการใช้งานเหล็กโดยรวมได้

อุตสาหกรรมเหล็กแผ่นรีดร้อน เป็นหนึ่งในอุตสาหกรรมเหล็กที่สำคัญและมีความสามารถในการเติบโตได้ในประเทศ สังเกตได้จากปริมาณการผลิต (Production) ปริมาณการนำเข้า (Import) ปริมาณการส่งออก (Export) และปริมาณความต้องการ (Demand) ดังรูปที่ 1-2 ข้อมูลสถิติจากสถาบันเหล็กและเหล็กกล้าแห่งประเทศไทย (Iron and Steel Institute of Thailand, 2020) แสดงให้เห็นว่า สำหรับการผลิตเหล็กแผ่นรีดร้อนภายในประเทศคิดเป็น 52% ของความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ ยังคงต้องมีการนำเข้าสูงถึง 48% ซึ่งหมายถึงช่วง (Gap) ที่ยังสามารถขยายตัวเพิ่มได้ในอุตสาหกรรมเหล็กแผ่นรีดร้อนหากเพิ่มความสามารถในการแข่งขันในอุตสาหกรรมนี้ได้




รูปที่ 1-1 ปริมาณการผลิตเหล็กดิบทั่วโลก
(World Steel Association, 2020)



รูปที่ 1-2 ปริมาณการผลิต ปริมาณการนำเข้า ปริมาณการส่งออก และปริมาณความต้องการ ของ
เหล็กแผ่นรีดร้อน
(Iron and Steel Institute of Thailand, 2020)

ต้นทุน เป็นปัจจัยสำคัญในการแข่งขันในอุตสาหกรรมเหล็กแผ่นรีดร้อน เนื่องจากเกี่ยวข้องกับการกำหนดราคาจำหน่ายของเหล็กรีดร้อน โครงสร้างต้นทุนของเหล็ก วัตถุดิบ (Raw materials) 66% ของต้นทุนการผลิตทั้งหมด ต้นทุนพลังงานและเชื้อเพลิง (Energy) 13% ค่าจ้างแรงงาน (Labor) 7% และค่าใช้จ่ายอื่น (Other) 14% (Toomwongsa, 2018) ดังแสดงในรูปที่ 1-3 หากสามารถปรับปรุงต้นทุนในส่วน of วัตถุดิบรวมถึงการวางแผนการผลิตที่สามารถจัดการต้นทุนด้านแรงงานและพลังงานให้น้อยลงได้ จะเพิ่มความสามารถในการแข่งขันได้



รูปที่ 1-3 โครงสร้างต้นทุนของอุตสาหกรรมผลิตเหล็ก

ปริมาณความต้องการเหล็กแผ่นรีดร้อนเป็นข้อมูลสำคัญที่ใช้ในกำหนดนโยบายการดำเนินงาน กลยุทธ์ การวางแผนผลิต การวางแผนการจัดการวัตถุดิบตั้งแต่การคำนวณเวลานำ (Lead time) เพื่อกำหนดเวลาที่ต้องสั่งซื้อ ปริมาณการสั่งซื้อ ปริมาณการจัดเก็บจนถึงการนำวัตถุดิบเข้าทำ

การผลิต ซึ่งจะสามารถลดต้นทุนการจัดเก็บ เงินทุนจม และต้นทุนของเงินทุน ไปจนถึงการป้องกันการจัดเก็บเกินความต้องการหรือการเสียโอกาสในการทำกำไรจากความผันผวนของราคา

ข้อมูลจากสถาบันเหล็กและเหล็กกล้าแห่งประเทศไทยแสดงถึงปริมาณและมูลค่าของอุตสาหกรรมเหล็กแผ่นรีดร้อนในประเทศไทยมีปริมาณการซื้อขายเฉลี่ย 422,175.52 ตันต่อเดือน (ปริมาณความต้องการเหล็กแผ่นรีดร้อนเฉลี่ยต่อเดือนใน พ.ศ. 2562) และมีมูลค่าสูงถึง 8,345 ล้านบาทต่อเดือน (ราคาเฉลี่ยต่อตันใน พ.ศ. 2562 เท่ากับ 19,767 บาทต่อตัน) (Iron and Steel Institute of Thailand, 2020) การพยากรณ์ที่แม่นยำจึงมีความสำคัญมาก การคลาดเคลื่อนเพียง 1% หมายถึงมูลค่าที่สูงในหลักล้านบาท ทุกครั้งที่เราพัฒนาแผนใดก็ตามเราต้องทำการคาดการณ์ผลที่จะได้ หรือสิ่งที่จะเกิดขึ้นในแผนที่จัดทำ (Mentzer & Moon, 2004) การพยากรณ์ไม่เพียงส่งผลกระทบทั้งทางตรงและทางอ้อมต่อเกือบทุกกิจกรรมภายใน (Klimberg, Sillup, Boyle, & Tavva, 2010) การพยากรณ์ที่แม่นยำจะทำให้การกำหนดนโยบายการดำเนินงาน กลยุทธ์ การวางแผนผลิต และการวางแผนการจัดการ สามารถทำได้เหมาะสมกับสถานการณ์ที่พยากรณ์ไว้ได้ดีกว่าการพยากรณ์ที่ไม่แม่นยำ

นอกจากวิธีแบบดั้งเดิม เช่น การพยากรณ์แบบปรับเรียบเอกซ์โพเนนเชียล (Exponential Smoothing) และ การพยากรณ์แบบ Autoregressive Integrated Moving Average (ARIMA) ที่เป็นตัวแบบการพยากรณ์จากข้อมูลในอดีต หรือที่เรียกว่า อนุกรมเวลา (Time Series) หรือการพยากรณ์แบบถดถอย (Regression) ที่เป็นตัวแบบการพยากรณ์จากข้อมูลที่มีความสัมพันธ์ ในปัจจุบันตัวแบบการพยากรณ์โดยอาศัยการเรียนรู้ของเครื่อง (Machine Learning) เป็นอีกตัวแบบหนึ่งที่ทำให้ความแม่นยำสูง และมีความหลากหลายของการสร้างตัวแบบไปจนถึงการใช้ตัวแบบผสมที่สามารถนำจุดเด่นของแต่ละตัวแบบการพยากรณ์เพื่อให้การพยากรณ์มีความแม่นยำมากขึ้น การพยากรณ์โดยอาศัยการเรียนรู้ของเครื่องจะทำการเรียนรู้และสร้างตัวแบบในการพยากรณ์จากข้อมูลที่นำเข้า (Input) และผลลัพธ์ (Output) ที่เกิดขึ้นจากข้อมูลนั้น และนำตัวแบบในการพยากรณ์ที่สร้างขึ้นจากการเรียนรู้ มาทำการพยากรณ์เมื่อมีการนำเข้าข้อมูลใหม่

เพื่อค้นหาตัวแบบการพยากรณ์ที่ให้ผลการพยากรณ์ที่แม่นยำที่สุดในการพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนในประเทศไทย จึงจัดทำงานวิจัยนี้เพื่อศึกษาการพยากรณ์ปริมาณ


ความต้องการเหล็กแผ่นรีดร้อนด้วยตัวแบบการเรียนรู้ของเครื่องและเปรียบเทียบความแม่นยำกับตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุ โดยเมื่อสามารถค้นหาตัวแบบที่แม่นยำและทำการพยากรณ์แล้ว บริษัทในอุตสาหกรรมเหล็กแผ่นรีดร้อนที่ทราบถึงส่วนแบ่งตลาด (Market share) ของตนเองจะสามารถนำข้อมูลการพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศไปคำนวณเป็นปริมาณความต้องการโดยรวมของลูกค้าตนเองได้

1.2 ลักษณะปัญหา

จากการสำรวจบริษัทในอุตสาหกรรมเหล็กแผ่นรีดร้อนภายในประเทศจำนวนหนึ่งพบว่า บริษัทส่วนใหญ่ใช้วิธีการพยากรณ์ล่วงหน้าด้วยการสอบถามปริมาณจากแผนการจัดซื้อ แผนการผลิต หรือปริมาณการขายจากลูกค้าของตนล่วงหน้าเป็นจำนวน 3-6 เดือนแตกต่างกันตามลูกค้า ซึ่งไม่ทราบวิธีการที่ได้มาของปริมาณดังกล่าวและมีความแม่นยำเฉลี่ยเพียง 60-70% เท่านั้น เมื่อประกอบกับเวลานำในการผลิต เวลานำในการนำเข้าวัตถุดิบจากต่างประเทศที่ใช้เวลานาน รวมไปถึงมูลค่าที่สูงของอุตสาหกรรมเหล็กแผ่นรีดร้อน การพยากรณ์ดังกล่าวทำให้เกิดปัญหาในสองลักษณะคือ การขาดแคลนวัตถุดิบสำหรับการผลิตซึ่งทำให้บริษัทขาดความน่าเชื่อถือและอาจถูกเก็บค่าปรับจากการผิดสัญญา หรือเสียโอกาสการขาย และการจัดเก็บวัตถุดิบเกินความต้องการซึ่งทำให้เสียต้นทุนการจัดเก็บและขาดสภาพคล่องทางการเงิน

1.3 วัตถุประสงค์ของงานวิจัย

เพื่อค้นหาตัวแบบการพยากรณ์ที่แม่นยำในการพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ สำหรับใช้ในการวางแผนการดำเนินการจัดซื้อวัตถุดิบ การเตรียมการผลิต และการขาย



รูปที่ 1-4 ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศไทย พ.ศ. 2556 – 2562

1.4 ขอบเขตของงานวิจัย

1.4.1 การพยากรณ์

การพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศรายเดือน ตั้งแต่เดือนมกราคม พ.ศ. 2562 จนถึงเดือนธันวาคม พ.ศ. 2562

1.4.2 ขอบเขตของข้อมูล

ปริมาณความต้องการเหล็กแผ่นรีดร้อนและข้อมูลปัจจัยที่ใช้ในการศึกษาเป็นข้อมูลทุติยภูมิจากหน่วยงานที่เชื่อถือได้

- ปริมาณความต้องการเหล็กแผ่นรีดร้อน ข้อมูลรายเดือนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2562 จากศูนย์ข้อมูลเชิงลึกอุตสาหกรรมเหล็กไทย (Iron and Steel Institute of Thailand, 2020)

- ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน ข้อมูลรายเดือนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2562 จาก สถาบันเหล็กและเหล็กกล้าแห่งประเทศไทย (Iron and Steel Institute of Thailand, 2020)
- ผลิตภัณฑ์มวลรวมของประเทศ (GDP) ข้อมูลรายไตรมาสตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2562 จาก ธนาคารแห่งประเทศไทย (Bank of Thailand, 2020)
- ปริมาณการจำหน่ายรถยนต์ ข้อมูลรายเดือนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2562 จาก สำนักงานเศรษฐกิจอุตสาหกรรม (The Office of Industrial Economics, 2020)
- ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า ข้อมูลรายเดือนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2562 จากสำนักงานเศรษฐกิจอุตสาหกรรม (The Office of Industrial Economics, 2020)
- ปริมาณการจำหน่ายซีเมนต์ปอร์ตแลนด์ ข้อมูลรายเดือนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2562 จากสำนักงานเศรษฐกิจอุตสาหกรรม (The Office of Industrial Economics, 2020)

1.4.3 ตัวแบบในการพยากรณ์ที่ใช้ในงานวิจัย

- ตัวแบบการพยากรณ์การปรับเรียบเอกซ์โพเนนเชียลของโฮลท์ (Holt's Exponential Smoothing Model)
- ตัวแบบ Autoregressive Integrated Moving Average (ARIMA)
- ตัวแบบการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression : MLR)
- ตัวแบบ Artificial Neural Network (ANN)
- ตัวแบบ Support Vector Regression (SVR)
- ตัวแบบ Random Forest (RF)
- ตัวแบบ eXtreme Gradient Boosting (XGboost)
- ตัวแบบ Light Gradient Boosted Machine (LGBM)
- ตัวแบบผสม (Hybrid Method)

1.4.4 การเปรียบเทียบความแม่นยำ

การเปรียบเทียบความแม่นยำจะใช้ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error: MAPE)

1.5 ผลที่คาดว่าจะได้รับ

- ทราบถึงประสิทธิภาพของตัวแบบการพยากรณ์ในแต่ละตัวแบบต่อการพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศไทย
- ทราบถึงตัวแบบการพยากรณ์ที่เหมาะสมสำหรับการพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศไทยในระดับการพยากรณ์เป็นรายเดือน
- ทราบถึงปัจจัยที่ส่งผลกระทบต่อปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศไทย

1.6 ประโยชน์ที่คาดว่าจะได้รับ

- ผลการพยากรณ์ที่แม่นยำสามารถนำไปใช้ในการวางแผนการวางแผนการผลิต ที่เหมาะสม ส่งผลให้สามารถลดต้นทุนในการดำเนินการและการผลิต ทำให้ความสามารถในการแข่งขันในอุตสาหกรรมเหล็กแผ่นรีดร้อนสูงขึ้น
- ทราบถึงปัจจัยที่ควรพิจารณา ซึ่งจะสามารถนำไปวิเคราะห์และคาดคะเนผลกระทบต่อปัจจัยได้
- องค์กรที่เกี่ยวข้องกับอุตสาหกรรมเหล็กในประเทศไทยทั้งภาครัฐและเอกชนสามารถนำข้อมูลจากงานวิจัยนี้ไปใช้การพัฒนาการพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อน เพื่อพัฒนาอุตสาหกรรมเหล็กแผ่นรีดร้อนในประเทศให้สามารถแข่งขันกับสินค้านำเข้าได้

บทที่ 2

ทฤษฎีที่เกี่ยวข้อง

2.1 ข้อมูลพื้นฐานเกี่ยวกับอุตสาหกรรมเหล็กแผ่นรีดร้อน


อุตสาหกรรมเหล็กแผ่นรีดร้อนแบ่งออกเป็น 3 ลำดับประกอบไปด้วย อุตสาหกรรมเหล็กขั้นต้น อุตสาหกรรมเหล็กชั้นกลาง และอุตสาหกรรมเหล็กชั้นปลาย โดยแต่ละลำดับจะมีหน้าที่ วัตถุดิบ และผลผลิตที่แตกต่างกันดังแสดงในรูปที่ 2-1



รูปที่ 2-1 ลำดับของอุตสาหกรรมเหล็กกล้า

อุตสาหกรรมเหล็กขั้นต้นเป็นการถลุงเพื่อแปรสภาพสินแร่เหล็กซึ่งมีองค์ประกอบเป็นเหล็กออกไซด์เช่น Fe_2O_3 Fe_3O_4 FeS_2 และรูปแบบอื่น ทำการลด (Reduce) ออกซิเจน (O) ให้กลายเป็นเหล็กหรือ Fe กระบวนการถลุงที่ใช้ในปัจจุบันมี 2 กระบวนการคือ

- Indirection reaction โดยส่วนมากใช้เตาถลุงแบบพ่นลม (Blast furnace) ดังรูปที่ 2-2 โดยพ่นลมร้อนและออกซิเจนทำให้เกิดการเผาไหม้ของถ่านหินเกิดความร้อนที่หลอมเหลวสินแร่เหล็กและก๊าซคาร์บอนมอนอกไซด์ (CO) ซึ่งจะไปจับตัวกับออกซิเจนในสินแร่เหล็กทำให้ได้เหล็กที่บริสุทธิ์ขึ้นรวมไปถึงการแยกธาตุเจือปนอื่นด้วยการเติมฟลักซ์ (Flux) ผลผลิตที่ได้จากกระบวนการนี้คือเหล็กดิบถลุง
- Direction reaction โดยส่วนมากใช้เตาถลุงแบบหมุน (Rotary kiln) จะต้องทำการเตรียมสินแร่เหล็กที่ผ่านการบดละเอียดเพื่อให้สามารถทำปฏิกิริยากับก๊าซร้อนได้ดีขึ้น จากนั้นบรรจุสินแร่เหล็กที่ผ่านการบดแล้วเข้าไปในเตาถลุงแบบหมุน และปล่อยก๊าซสำหรับทำปฏิกิริยา เช่น ก๊าซมีเทน ก๊าซไฮโดรเจน หรือก๊าซคาร์บอนมอนอกไซด์ จากหอความร้อน (Heating tower) เพื่อทำปฏิกิริยารีดักชัน (Reduction) เพื่อลดออกซิเจนในสินแร่เหล็กโดยไม่หลอมเหลว ผลผลิตที่ได้จากกระบวนการนี้คือเหล็กดิบพูน




รูปที่ 2-2 องค์ประกอบของโรงถลุงแบบเตาถลุงพ่นลม

(<http://ironandsteelmaking00.blogspot.com/2017/07/all-about-blast-furnace.html>)

อุตสาหกรรมเหล็กชั้นกลางเป็นการหลอมเหล็กดิบทั้งในแบบถลุงและเหล็กพูนจากอุตสาหกรรมเหล็กขั้นต้น หรืออาจใช้เศษเหล็กมาทำการผลิต เพื่อทำการปรับปรุงส่วนผสมทางเคมีให้ได้ตามความเหมาะสมกับการใช้งานโดยนำเหล็กวัตถุดิบมาทำการหลอมภายในเตาหลอม ปัจจุบันวิธีการผลิตที่นิยมใช้เป็นหลักมีสองวิธีซึ่งจะใช้วัตถุดิบและให้ผลผลิตที่มีคุณภาพต่างกัน


- วิธีการผลิตโดยใช้เตาฟ่อนอกซิเจน (Basic Oxygen Furnace: BOF) ดังรูปที่ 2-3 จะใช้เหล็กดิบเป็นวัตถุดิบหลัก ทำให้ได้ผลิตภัณฑ์ที่มีคุณภาพสูง สามารถนำไปใช้งานในกลุ่มงานคุณภาพสูงเช่นชิ้นส่วนรถยนต์หรือเครื่องใช้ไฟฟ้าได้



รูปที่ 2-3 องค์ประกอบของเตาฟ่อนอกซิเจน

(<https://www.cliftonsteel.com/knowledge-center/how-is-steel-made>)

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY



รูปที่ 2-4 องค์ประกอบของเตาอาร์คไฟฟ้า


(<https://teara.govt.nz/en/diagram/5885/electric-arc-furnace>)

- วิธีการผลิตโดยใช้เตาอาร์คไฟฟ้า (Electric Arc Furnace: EAF) ดังรูปที่ 2-4 จะใช้เศษเหล็กเป็นวัตถุดิบหลักและได้ผลิตภัณฑ์คุณภาพดีต่อยกกว่ามักจะใช้ผลิตกลุ่มเหล็กสำหรับงานก่อสร้าง

โดยทั้งสองวิธีจะทำการผลิตเป็นเหล็กแท่งโดยสามารถผลิตได้ทั้ง 3 รูปแบบคือ เหล็กแท่งแบน เหล็กแท่งใหญ่ และเหล็กแท่งยาว เพื่อนำไปทำการแปรรูปในอุตสาหกรรมขั้นต่อไป

อุตสาหกรรมเหล็กขั้นปลายจะนำผลผลิตจากอุตสาหกรรมเหล็กขั้นกลางมาทำการแปรรูปเป็นรูปแบบที่เหมาะสมต่อการใช้งานโดยและมีกระบวนการที่หลากหลาย เช่น

- กระบวนการรีดร้อน (Hot Rolled) : นำเหล็กแท่งมาทำการรีดให้เป็นเหล็กแผ่น เหล็กเส้น เหล็กโครงสร้าง และเหล็กทรงยาวรูปแบบอื่น ดังรูปที่ 2-5
- กระบวนการรีดเย็น (Cold Rolled) : นำเหล็กแผ่นรีดร้อน มาทำการรีดขึ้นรูปที่อุณหภูมิต่ำ อาศัยแรงดึงและแรงกดในการรีด
- การหล่อ (Casting) : การหลอมเหล็กวัตถุดิบและเทลงแม่พิมพ์ที่เตรียมไว้สามารถทำการขึ้นรูปได้หลากหลายและทำได้ง่าย



รูปที่ 2-5 องค์ประกอบกระบวนการผลิตเหล็กแผ่นรีดร้อนชนิดม้วน

(https://www.researchgate.net/figure/Schematic-illustration-of-hot-rolling-process_fig1_283849153)

ในบางครั้งเรียกผลิตภัณฑ์จากอุตสาหกรรมเหล็กขั้นปลายว่าผลิตภัณฑ์กึ่งสำเร็จรูป (Semi-finish Product) ซึ่งยังสามารถนำไปแปรรูปต่อไปเป็นชิ้นงานสำเร็จตามทีออกแบบไว้

2.2 การพยากรณ์แบบอนุกรมเวลา (Time Series Forecasting)

ข้อมูลอนุกรมเวลา (Time series data) หมายถึงข้อมูลที่ถูกจัดเก็บหรือสามารถเรียบเรียงเป็นลำดับ ตามช่วงเวลาที่ต้องการ เช่น ข้อมูลราคาขายของหุ้นเป็นรายวัน ปริมาณความต้องการสินค้าเป็นรายสัปดาห์ หรือปริมาณการผลิตของสินค้าเป็นรายเดือน ซึ่งจะสามารถบอกถึงความเปลี่ยนแปลงในอดีตจนถึงปัจจุบันเท่าที่การเก็บข้อมูลจะทำได้ การพยากรณ์แบบอนุกรมเวลาเป็นการนำข้อมูลในอดีตมาใช้พยากรณ์ข้อมูลในอนาคต (Chatfield, 2000) มีวิธีการที่ถูกคิดค้นขึ้นมามากมาย ทั้งวิธีที่สามารถใช้งานได้อย่างครอบคลุมและวิธีเฉพาะของแต่ละข้อมูล ในงานวิจัยนี้จะนำวิธีการที่มีการใช้อย่างแพร่หลายและได้รับการยอมรับ

2.2.1 ตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์ (Holt's Exponential Smoothing Model)

จากตัวแบบพยากรณ์ปรับเรียบเอกซ์โพเนนเชียลอย่างง่ายที่มีข้อจำกัดที่ไม่สามารถการพยากรณ์ข้อมูลที่มีแนวโน้มได้อย่างแม่นยำโดยมีการให้ค่าถ่วงน้ำหนักข้อมูล α เพียงอย่างเดียว ได้มีการพัฒนาต่อโดยเพิ่มการคำนวณที่เกี่ยวกับแนวโน้มของข้อมูล ด้วยการเพิ่มตัวแปรแนวโน้ม และสัมประสิทธิ์การปรับเรียบของข้อมูลแนวโน้ม β (Kalekar, 2004) ในงานวิจัยนี้สัมประสิทธิ์การปรับเรียบจะถูกคำนวณขึ้นโดยกำหนดให้เป็นค่าที่ทำให้ค่าความคลาดเคลื่อน (Error) น้อยที่สุด โดยค่าถ่วงน้ำหนักจะมีค่าตั้งแต่ 0 ถึง 1 หาก α เข้าใกล้ 1 จะหมายถึงการพยากรณ์โดยให้น้ำหนักข้อมูลใหม่มากกว่าข้อมูลเก่า หรือ α เข้าใกล้ 0 จะหมายถึงการพยากรณ์โดยให้น้ำหนักข้อมูลเก่ามากกว่าข้อมูลใหม่

สมการสำหรับการพยากรณ์ด้วยตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์แสดงดังสมการที่ (1)–(3)

$$\hat{Y}_{t+p} = L_t + pT_t \quad (1)$$

$$L_t = \alpha Y_t + (1 - \alpha)(L_{t-1} + T_{t-1}) \quad (2)$$

$$T_t = \beta(L_t - L_{t-1}) + (1 - \beta)T_{t-1} \quad (3)$$

เมื่อ

$$\hat{Y}_{t+p} = \text{ค่าพยากรณ์ของสิ่งที่สนใจใน ณ เวลา } t + p$$

$$Y_t = \text{ค่าสังเกตของสิ่งที่สนใจ ณ เวลา } t$$

$$L_t = \text{ค่าระดับของข้อมูล (Level) ที่สนใจ ณ เวลา } t$$

$$L_{t-1} = \text{ค่าระดับของข้อมูลที่สนใจ ณ เวลา } t - 1$$

$$T_t = \text{ค่าแนวโน้มของข้อมูล (Trend) ที่สนใจ ณ เวลา } t$$

$$T_{t-1} = \text{ค่าแนวโน้มของข้อมูลที่สนใจ ณ เวลา } t - 1$$

$$p = \text{ช่วงเวลาที่ต้องการพยากรณ์ล่วงหน้านับจากเวลา } t$$

$$\alpha = \text{ค่าถ่วงน้ำหนัก หรือ สัมประสิทธิ์การปรับเรียงของค่าระดับของข้อมูล}$$

$$\beta = \text{ค่าถ่วงน้ำหนัก หรือ สัมประสิทธิ์การปรับเรียงของค่าแนวโน้มของข้อมูล}$$

2.2.2 ตัวแบบ Autoregressive Integrated Moving Average (ARIMA)

ตัวแบบพยากรณ์ ARIMA หรือ Box-Jenkins' Method เป็นตัวแบบที่สามารถใช้กับข้อมูลได้ทุกรูปแบบ (Chatfield, 2000) และให้ความแม่นยำสูง โดยควรมีข้อมูลมากกว่า 50 ข้อมูลขึ้นไป ตัวแบบ ARIMA ต้องอาศัยความรู้และความชำนาญในการวิเคราะห์ข้อมูล และลักษณะของข้อมูลในแต่ละขั้นตอนการพยากรณ์เพื่อทำการกำหนดตัวแบบที่จะใช้ในการพยากรณ์

สมการสำหรับการพยากรณ์ด้วยตัวแบบ Autoregressive Integrated Moving Average แสดงดังสมการที่ (4) และ (5)

เมื่อข้อมูลอยู่ในรูปปรกติ ($d = 0$)

$$\hat{Y}_t = \alpha_0 + \sum_{i=1}^p \phi_i Y_{t-1} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (4)$$

เมื่อ \hat{Y}_t = ค่าพยากรณ์ของสิ่งที่สนใจใน ณ เวลา t

Y_{t-1} = ค่าสังเกตของสิ่งที่สนใจใน ณ เวลา $t - 1$

α = ค่าคงที่ถ่วงน้ำหนัก

ϕ = สัมประสิทธิ์ของ AR

θ = สัมประสิทธิ์ของ MA

ε = ค่าความคลาดเคลื่อน

เมื่อข้อมูลอยู่ในรูปผลต่างลำดับที่ 1 ($d = 1$)

$$\Delta \hat{Y}_t = \alpha_0 + \sum_{i=1}^p \phi_i \Delta Y_{t-1} + \sum_{i=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (5)$$

เมื่อ $\Delta \hat{Y}_t$ = ผลต่างของค่าพยากรณ์ของสิ่งที่สนใจใน ณ เวลา t

ΔY_{t-j} = ผลต่างของค่าสังเกตของสิ่งที่สนใจใน ณ เวลา $t - j$

α = ค่าคงที่ถ่วงน้ำหนัก

ϕ = สัมประสิทธิ์ของ AR

θ = สัมประสิทธิ์ของ MA

ε = ค่าความคลาดเคลื่อน

ARIMA ประกอบขึ้นจากสองตัวแบบคือ Auto Regressive (AR) และ Moving Average (MA) โดยเมื่อทำการพยากรณ์ด้วย ARIMA จะต้องทำการวิเคราะห์ความคงที่ของข้อมูล (Stationary data) หากข้อมูลมีความคงที่แล้ว จะทำการวิเคราะห์ลักษณะของข้อมูลเพื่อเลือกลำดับของแต่ละตัว

แบบทั้ง AR(p) และ MA(q) และนำมาทำการพยากรณ์ด้วย ARMA(p,q) หากวิเคราะห์ข้อมูลแล้ว ยังไม่สามารถเลือกตัวแบบได้เนื่องจากมีความไม่คงที่ของข้อมูล (Non-stationary data) ต้องทำการหาผลต่าง (Differencing) เป็นลำดับขั้น d และนำมาทำการพยากรณ์ด้วย ARIMA(p,d,q) (Box, Jenkins, Reinsel, & Ljung, 2015)

2.3 การพยากรณ์เชิงสาเหตุ (Causal Method Forecasting)

2.3.1 ตัวแบบการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression)

ตัวแบบพยากรณ์ถดถอยเชิงเส้นพหุคูณเป็นตัวแบบการพยากรณ์ที่พัฒนาต่อจากตัวแบบการถดถอยเชิงเส้น โดยสามารถพยากรณ์ผ่านตัวแปรหลายตัวแปรที่มีความสัมพันธ์กัน (Eberly, 2007) ตัวแปรที่นำมาวิเคราะห์เพื่อทำการพยากรณ์เรียกว่าตัวแปรอิสระ (Independent variable) ตัวแปรที่เป็นผลจากการวิเคราะห์หรือผลการพยากรณ์เรียกว่าตัวแปรตาม (Dependent variable) (Uyanik & Güler, 2013)

สมการสำหรับการพยากรณ์ประชากร (Population) ด้วยตัวแบบการถดถอยเชิงเส้นพหุคูณ แสดงดังสมการที่ (6)

$$Y = \beta_0 + \beta_1 X_1 + \beta_2 X_2 + \dots + \beta_k X_k + \varepsilon \quad (6)$$

สมการสำหรับการพยากรณ์ตัวอย่าง (Sample) ด้วยตัวแบบการถดถอยเชิงเส้นพหุคูณ แสดงดังสมการที่ (7)

$$\hat{Y} = b_0 + b_1 X_1 + b_2 X_2 + \dots + b_k X_k + e \quad (7)$$

เมื่อ Y = ค่าสังเกตของสิ่งที่สนใจ ณ เวลา t

\hat{Y} = ค่าพยากรณ์ของสิ่งที่สนใจ ณ เวลา t

β_0 = จุดตัดแกน Y

b_0 = ค่าประมาณของจุดตัดแกน Y

β_1, \dots, β_k = สัมประสิทธิ์ของตัวแปรอิสระ

b_1, \dots, b_k = ค่าประมาณของสัมประสิทธิ์ของตัวแปรอิสระ


X_1, \dots, X_k = ตัวแปรอิสระ

\mathcal{E} = ค่าความคลาดเคลื่อน

e = ค่าประมาณของค่าความคลาดเคลื่อน

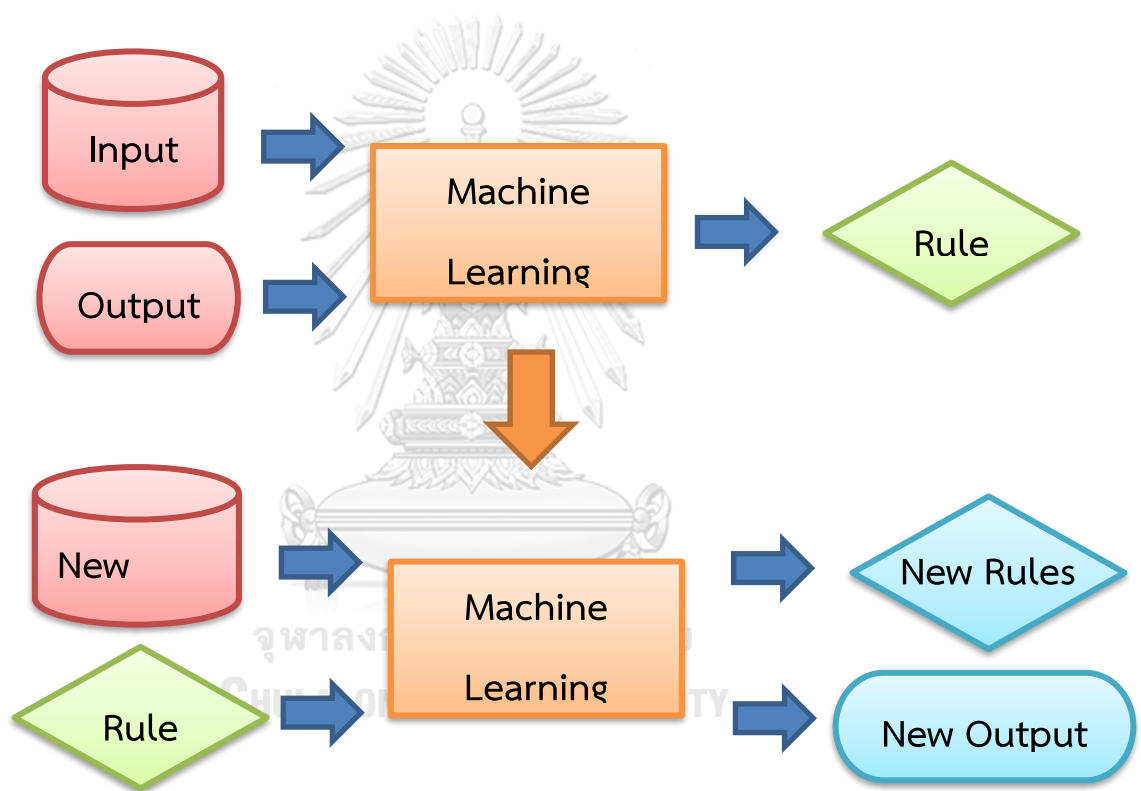
2.4 การเรียนรู้ของเครื่อง (Machine Learning: ML)

การเรียนรู้ของเครื่องเป็นส่วนหนึ่งของการศึกษาและพัฒนาระบบปัญญาประดิษฐ์ (Artificial Intelligent: AI) โดยการเรียนรู้ของเครื่องเป็นการศึกษาและพัฒนาระบบที่สามารถทำการเรียนรู้ จดจำ และการปรับปรุงตัวแบบในการคำนวณและสถิติด้วยตัวเอง (Zhang, 2020) เพื่อให้ได้ผลลัพธ์ของการกระทำเป็นไปตามวัตถุประสงค์ที่ต้องการ ซึ่งจะแตกต่างจากการเขียนโปรแกรมทั่วไป ที่จำเป็นต้องกำหนดตัวแบบการทำงาน วิธีคำนวณ และตรรกะ (Logic) ในการทำงานของโปรแกรมที่เหมาะสมต่อข้อมูลและให้ได้ผลลัพธ์ที่ต้องการ และเมื่อมีการเปลี่ยนแปลงของข้อมูลเกิดขึ้นก็จำเป็นต้องแก้ไข หรือกำหนดตัวแบบการทำงานใหม่ ดังรูปที่ 2-6 แต่การเรียนรู้ของเครื่องจะทำงานด้วยการสร้างระบบที่เรียนรู้ความสัมพันธ์ระหว่างข้อมูลนำเข้าและผลลัพธ์ เพื่อหาตัวแบบการคำนวณที่เหมาะสมต่อจุดประสงค์ที่ต้องการ ดังรูปที่ 2-7




รูปที่ 2-6 กระบวนการทำงานของโปรแกรมทั่วไป

เราจะเรียกคอมพิวเตอร์โปรแกรมว่าได้เรียนรู้จากประสบการณ์ E เพื่อทำงาน T ได้โดยมีประสิทธิผล P เมื่อโปรแกรมนั้นสามารถทำงาน T ที่วัดผลด้วย P แล้วพัฒนาขึ้นจากประสบการณ์ (Mitchell, 1997) หมายถึงระบบการทำงานของการเรียนรู้ของเครื่องที่มีการพัฒนาตัวแบบการทำงานเมื่อมีการเปลี่ยนแปลงของข้อมูลในระบบได้เรียนรู้ และประมวลผลหาวิธีการทำงานใหม่ที่ดีกว่าเดิม



รูปที่ 2-7 กระบวนการทำงานของการเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่องสามารถแบ่งเป็น 3 ตัวแบบตามการเรียนรู้ดังรูปที่ 2-8 ได้แก่ การเรียนรู้แบบมีผู้สอน (Supervised Learning) การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) และการเรียนรู้แบบเสริมแรง (Reinforcement Learning) ซึ่งจะมีกระบวนการเรียนรู้ที่และการนำไปใช้งานที่แตกต่างกัน




รูปที่ 2-8 ประเภทของการเรียนรู้ของเครื่องจักร จำแนกตามตัวแบบการเรียนรู้
 (<https://medium.com/investic/machine-learning-คืออะไร-fa8bf6663c07>)

2.4.1 การเรียนรู้แบบมีผู้สอน (Supervised Learning)

การเรียนรู้แบบมีผู้สอนเป็นวิธีการเรียนรู้ของเครื่อง โดยที่ผู้สอนหรือผู้ใช้งานนำข้อมูลนำเข้า และผลลัพธ์เข้าสู่ระบบของเครื่อง (Zhang, 2020) เครื่องจะทำการเรียนรู้โดยหาความสัมพันธ์ของข้อมูลนำเข้าและผลลัพธ์ จากนั้นจะเก็บบันทึกรูปแบบความสัมพันธ์ในรูปแบบที่เหมาะสม เช่น สมการทางคณิตศาสตร์ เพื่อนำมาใช้ในการทำงานครั้งต่อไป เมื่อมีการทำงานและนำเข้าข้อมูลใหม่ จะมีทำการประเมินการทำงานจากผลลัพธ์ และทำการปรับปรุงรูปแบบการทำงานเพื่อให้ได้ผลลัพธ์ที่ดีขึ้น การเรียนแบบมีผู้สอนแบ่งเป็นประเภทหลักสองประเภท คือ การจำแนก (Classification) และการถดถอย (Regression)

การจำแนก (Classification)

การจำแนกใช้ในการแบ่งประเภทข้อมูลหรือทำนายข้อมูลที่มีความไม่ต่อเนื่องกัน (Discrete) เช่น การทำนาย (Predict) ข้อมูลว่าเป็นเพศชายหรือหญิง สีแดงหรือสีฟ้า หรือการทำนายว่าเป็นวัตถุชนิดใด เช่น ระบบการประเมินวัตถุของกล้องถ่ายรูปในโทรศัพท์มือถือ (Smart phone) การจำแนกทำงานโดยอาศัยข้อมูลปัจจัย (Feature) เช่น การทำนายว่าบุคคลตัวอย่างเป็นเพศใดจากฐานข้อมูลที่มีอย่าง ส่วนสูง น้ำหนัก การเดินทาง ปริมาณความต้องการ หรืออาชีพ พร้อมข้อมูลเฉลย (Label) ของแต่ละชุดข้อมูลว่าเป็นชายหรือหญิง ระบบจะคำนวณจากสถิติและความน่าจะเป็นเพื่อใช้เป็นรูปแบบในการประมวลผลและให้ผลลัพธ์เมื่อมีการป้อนข้อมูลนำเข้าใหม่ หากผลลัพธ์ผิดพลาด ระบบจะทำการเรียนรู้เพิ่มเติมจากข้อมูลนำเข้าใหม่เพื่อทำการปรับปรุงรูปแบบ ดังรูปที่ 2-9



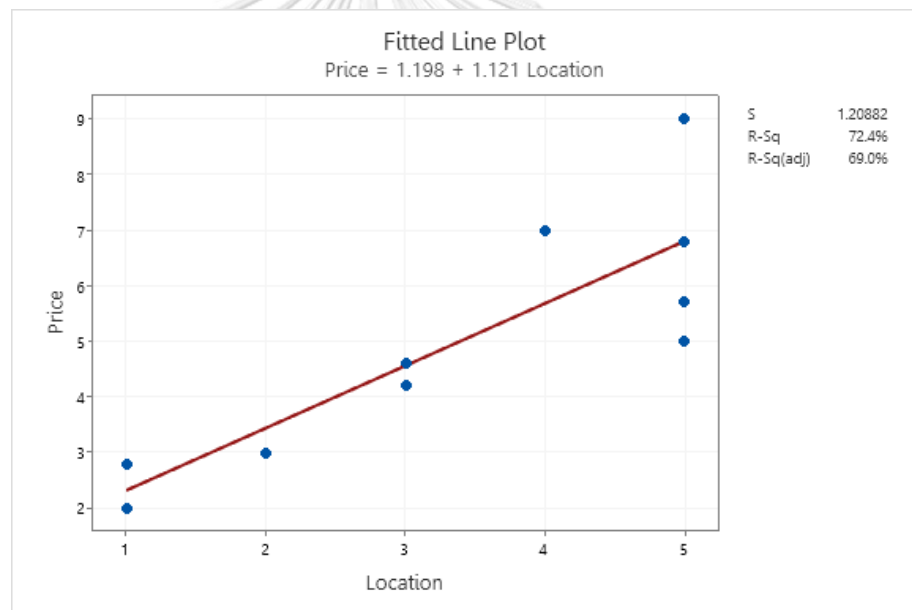
รูปที่ 2-9 การทำนายเพื่อระบุว่าข้อมูลภาพนำเข้าสู่ระบบเป็นสิ่งใด

(<https://www.thaiprogrammer.org/2018/12/การเรียนรู้ของเครื่องmachine-le/>)

การจำแนกยังสามารถนำไปใช้งานได้อย่างหลากหลายโดยอาศัยหลักการคล้ายกัน เช่น การจำแนกรูปภาพ (Image Classification) การรักษาลูกค้า (Customer retention) การตรวจจับความผิดปกติ (Identity Fraud Detection) และการวินิจฉัย (Diagnostics)

การถดถอย (Regression)

การถดถอยนิยมใช้ในการพยากรณ์ค่าของข้อมูลที่ต่อเนื่องกัน (Continuous) ที่สนใจในช่วงเวลาถัดไป เช่น การพยากรณ์อัตราแลกเปลี่ยนค่าเงิน (Exchange rate) ในเดือนหน้า หรือปีหน้า การถดถอยจะหาความสัมพันธ์ระหว่างปัจจัยกับผลลัพธ์ที่เคยเกิดขึ้นดังรูปที่ 2-10 เช่น การหาความสัมพันธ์ระหว่างมูลค่าของที่ดิน (y) โดยมีข้อมูลปัจจัย (x) เป็นเขตที่อยู่ใกล้รถไฟฟ้าหรือไม่ ติดถนนหรือไม่ หรือใกล้ห้างสรรพสินค้าหรือไม่ ระบบจะสร้างตัวแบบการพยากรณ์พร้อมผลลัพธ์ เมื่อมีการป้อนข้อมูลใหม่ ระบบจะทำการพยากรณ์และเปรียบเทียบผลการพยากรณ์เดิม รวมไปถึงการปรับปรุงตัวแบบการพยากรณ์เพื่อให้ได้ความแม่นยำสูงที่สุดที่สามารถทำได้



รูปที่ 2-10 การหาสมการพยากรณ์ด้วยวิธี Regression จากความสัมพันธ์ระหว่างราคาและ ทำเลของที่ดิน


การถดถอยสามารถประยุกต์ใช้ในการพยากรณ์ได้หลายรูปแบบเช่น การพยากรณ์อากาศ (Weather Forecasting) การพยากรณ์ตลาด (Market Forecasting) หรือการพยากรณ์ปริมาณการ

เพิ่มขึ้นของประชากร (Population Forecasting) ซึ่งสามารถนำไปใช้ในการวางแผนการดำเนินการได้อย่างเหมาะสมยิ่งขึ้น

2.4.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning)

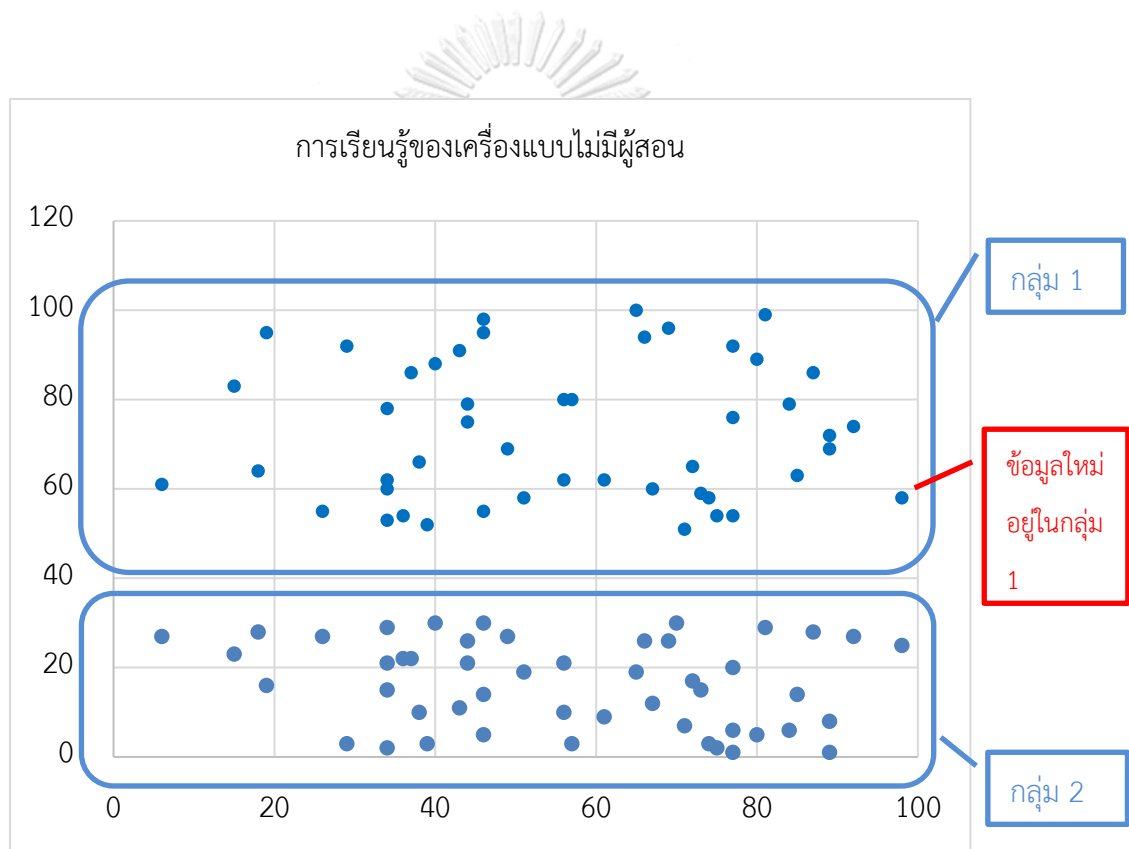
การเรียนรู้แบบไม่มีผู้สอนเป็นการเรียนรู้จากข้อมูลที่ป้อนเข้าสู่ระบบโดยที่ไม่มีการเฉลยให้ (Zhang, 2020) ระบบจะทำการจัดกลุ่มของข้อมูล (Cluster) ตามเกณฑ์การจัดกลุ่มที่ตั้งค่าไว้ เพื่อให้ผู้ใช้งานสามารถนำข้อมูลที่มีการจัดกลุ่มแล้วไปทำการวิเคราะห์หาคำตอบต่อไป การเรียนรู้แบบไม่มีผู้สอนจะแตกต่างกับการเรียนรู้แบบมีผู้สอนในส่วนของเฉลย หรือผลลัพธ์ในอดีตที่เกิดขึ้นจากข้อมูลนั้น นิยมใช้ในการจัดการข้อมูล

ความแตกต่างระหว่างการเรียนรู้แบบมีผู้สอนและแบบไม่มีผู้สอนคือ การเรียนรู้แบบมีผู้สอนระบบจะรู้ถึงคำตอบของสิ่งที่สนใจ และให้ผลลัพธ์เป็นคำตอบใหม่ที่ประมวลผลได้ แต่การเรียนรู้แบบไม่มีผู้สอน ระบบจะไม่รู้ถึงคำตอบของสิ่งที่สนใจ และให้ผลลัพธ์เป็นการจัดรูปแบบข้อมูลตามที่กำหนด ตัวอย่างดังรูปที่ 2-11 และ 2-12



รูปที่ 2-11 ตัวอย่างการทำงานของเครื่องแบบมีผู้สอน

เมื่อมีข้อมูลนำเข้าใหม่ ระบบที่มีการเรียนรู้แบบมีผู้สอนจะสามารถให้ผลลัพธ์ได้ว่า ข้อมูลนำเข้าใหม่อยู่ในกลุ่มสีอะไร และประเมินผลความแม่นยำของผลลัพธ์ แต่ระบบที่มีการเรียนรู้แบบไม่มีผู้สอนจะรับรู้ถึงสีของแต่ละกลุ่มแต่จะให้ผลลัพธ์ได้เพียง ข้อมูลนำเข้าใหม่อยู่กลุ่มใดจากกลุ่มข้อมูลที่จัดไว้ และประเมินผลจากความเหมาะสมของการจัดกลุ่มและการนำไปใช้งาน




รูปที่ 2-12 ตัวอย่างการทำงานของเครื่องแบบไม่มีผู้สอน

2.4.3 การเรียนรู้แบบเสริมแรง (Reinforcement Learning)

วิธีการเรียนรู้แบบเสริมแรงเป็นการเรียนรู้จากสิ่งแวดล้อม (Environment) ในขณะนั้นว่าถ้ากระทำ (Action) สิ่งใดระบบจะได้คะแนนหรือรางวัล (Reward) ในการเรียนรู้ ผู้เรียนรู้ (Agent)

(Zhang, 2020) จะทำการเรียนรู้แต่ละการกระทำทั้งหมดที่กำหนดให้ และทดลองกระทำแต่ละการกระทำ ผู้เรียนรู้จะทำการเรียนรู้และจดจำการกระทำนั้นๆ ที่ทำให้ได้รางวัลมากที่สุด และทำซ้ำเมื่อพบสิ่งแวดล้อมเดิมหรือใกล้เคียงเดิม ดังรูปที่ 2-13




รูปที่ 2-13 ตัวอย่างการทำงานของเครื่องแบบเสริมแรง
(<https://tupleblog.github.io/reinforcement-learning/>)

สำหรับการเรียนรู้แบบเสริมแรง ยกตัวอย่างเปรียบเทียบการฝึกสอนสัตว์เลี้ยง เช่น การสอนให้แมวกดกระดิ่งเพื่อขออาหาร ในตอนแรกแมวไม่รู้เลยว่า ทำอย่างไรจะได้อาหาร แมวก็จะเดินไปรอบบริเวณ ทำกิจกรรมที่อยากทำ แต่เมื่อวางกระดิ่งแล้วกดให้เป็นตัวอย่างพร้อมกับให้อาหาร แมวจะเริ่มเรียนรู้ว่าเมื่อมีเสียงกระดิ่งจะมีอาหาร หลังจากที่แมวกดกระดิ่งเองครั้งแรกแล้วได้ยินเสียง แมวจะเรียนรู้ว่าการกดกระดิ่งหรือการกระทำนี้ทำให้เกิดเสียงกระดิ่ง และเมื่อเกิดเสียงกระดิ่งจะมีอาหาร จากนั้นแมวจะทำการกดกระดิ่งเมื่อต้องการอาหาร

การเรียนรู้แบบเสริมแรง มักนำไปใช้ในระบบตอบสนองอัตโนมัติ (Real-time decisions) พบได้มากในรูแบบของตัวละครไร้ผู้เล่นในเกมส์ (Game artificial intelligent) หรือบอทเกมส์ (Game robot) เช่น อัลฟา โกะ (Alpha GO) ที่สามารถชนะผู้เล่นระดับโลกได้

2.4.4 Artificial Neural Network (ANN)

Artificial Neural Network คือรูปแบบที่จำลองมาจากการทำงานของเซลล์ประสาท (Neural) จากการทำงานของเซลล์ประสาทที่ทำหน้าที่ประมวลผลเมื่อได้รับการกระตุ้น (Threshold) ที่มากพอและส่งข้อมูลต่อเป็นกระแสไฟฟ้าไปยังเซลล์อื่น ดังรูปที่ 2-14



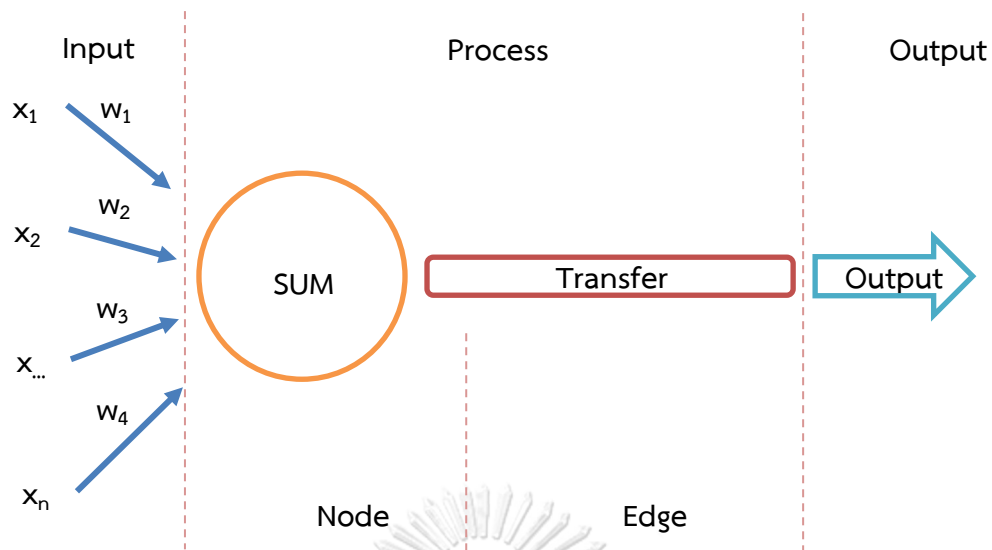
รูปที่ 2-14 ส่วนประกอบของเซลล์ประสาท

(http://www.freewebs.com/soaring_sphincter_travel_agency/nervoussystem.htm)

จุฬาลงกรณ์มหาวิทยาลัย

CHULALONGKORN UNIVERSITY


เซลล์ประสาทประกอบไปด้วย เส้นใยประสาท (Dendrite) ทำหน้าที่รับกระแสประสาท ตัวเซลล์ประสาท (Body) ทำหน้าที่ประมวลผลกระแสประสาท แกนประสาท (Axon) ทำหน้าที่แปลงกระแสประสาท และ ปลายประสาท (Axon tip) ทำหน้าที่ส่งต่อกระแสประสาท โดยที่บริเวณจุดเชื่อมต่อที่ปลายประสาทเรียกว่า จุดประสานประสาท (Synapses) เป็นตัวส่งกระแสประสาทระหว่างเส้นใยประสาทและปลายประสาท การไหลของข้อมูลเป็นไปดังรูปที่ 2-15



รูปที่ 2-15 แบบจำลองการทำงานของประสาทเทียมใน Artificial Neural Network

การจำลองกระบวนการการทำงานของเครือข่ายประสาท โดย 1 หน่วยการทำงานของ Artificial Neural Network เทียบเท่ากับ 1 เซลล์ประสาท เพื่อทำการประมวลผลและส่งต่อค่าที่ประมวลผลได้ 1 ค่า โดยจุดประสานประสาทเป็นส่วนรับข้อมูลเข้า ตัวเซลล์ประสาทหรือปม (Node) เป็นส่วนประมวลผล แกนประสาทหรือเส้นเชื่อมต่อ (Edge) เป็นส่วนแปลงค่าข้อมูล และปลายประสาทเป็นส่วนส่งต่อข้อมูลผลลัพธ์

การทำงานของเครือข่ายประสาทเทียมจะรวบรวมแต่ละหน่วยของประสาทเทียมมาทำงานประมวลผล ดังรูปที่ 2-16 โดยเมื่อยังมีข้อมูลป้อนเข้าหลายข้อมูลจำนวนของหน่วยประสาทเทียมและชั้นซ่อน (Hidden Layer) ควรจะมีจำนวนมากขึ้นไปด้วย




รูปที่ 2-16 แบบจำลองการทำงานของ Artificial Neural Network

การใช้งาน Artificial Neural Network สามารถใช้งานได้ครอบคลุมทุกรูปแบบ (S.-C. Wang, 2003) ทั้งรูปแบบการจำแนก และการถดถอย ทั้งรูปแบบการเรียนรู้แบบมีผู้สอนและไม่มีผู้สอน สามารถใช้ในการแก้ปัญหาที่ไม่อยู่ในเชิงเส้น (Nonlinear) ได้เนื่องจาก Artificial Neural Network ไม่จำเป็นต้องกำหนดเงื่อนไขการประมวลผล ใช้เพียงการปรับค่าน้ำหนักของข้อมูลแต่ละข้อมูลเพื่อให้เหมาะสมต่อเป้าหมายที่ต้องการ นอกจากนี้ Artificial Neural Network ยังสามารถนำไปพยากรณ์ข้อมูลแบบอนุกรมเวลาได้อย่างแม่นยำ

2.4.5 Support Vector Machine (SVM) and Support Vector Regression (SVR)

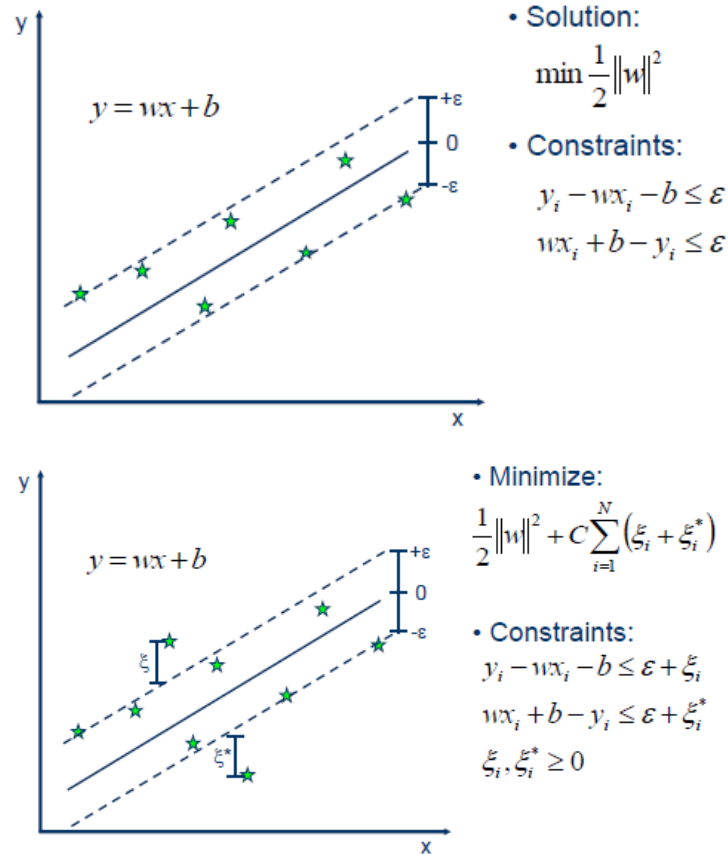
Support Vector Machine เป็นตัวแบบพัฒนาขึ้นโดย Vapnik ที่ห้องปฏิบัติการของ AT&T (V Vapnik, 1995) เป็นอัลกอริทึมที่สามารถเรียนรู้จากข้อมูลและเฉลยของข้อมูลนั้นเพื่อประมวลผลและพยากรณ์ผลลัพธ์ของข้อมูลใหม่ (Noble, 2006) Support Vector Machine เป็นหนึ่งในวิธีการที่นิยมใช้สำหรับงานจำแนกข้อมูล Support Vector Machine จะทำการหาเส้นแบ่งระหว่างข้อมูลโดยหาความสัมพัทธ์ระหว่างข้อมูลและกลุ่มข้อมูล และสร้างระนาบการตัดสินใจ (Decision Hyperplane) ที่เหมาะสมดังรูปที่ 2-17 ที่มาของชื่อมาจากเส้นเวกเตอร์ที่มีระยะห่างระหว่างสองชุดข้อมูลมากที่สุด (Maximum margin)



รูปที่ 2-17 แบบจำลองการทำงานของ Support Vector Machine
 (<https://codeinsane.wordpress.com/2018/12/08/support-vector-machine/>)

นอกจากนี้ Support Vector Machine ยังสามารถทำการจำแนกข้อมูลที่ซับซ้อน และไม่อยู่ในเชิงเส้นได้หลายวิธี เช่น การใช้เคอร์เนล (Kernel Function) (Vladimir Vapnik, Golowich, & Smola, 1997) จะสามารถสร้างระนาบการตัดสินใจที่ไม่ใช่เส้นตรงได้

ในขณะเดียวกันมีผู้ที่นำ Support Vector Machine ไปใช้ในการแก้ปัญหาแบบ Regression ซึ่ง Support Vector Machine เดิมเป็นตัวอย่างที่ให้ผลลัพธ์แบบ Binary เมื่อนำมาใช้งานกับค่าที่เป็นจำนวนจริงจึงให้ผลลัพธ์ที่ไม่ดีนัก ในปี 1996 จึงมีการพัฒนาตัวอย่าง Support Vector Machine ให้สามารถใช้แก้ปัญหา Regression ในชื่อของ Support Vector Regression (Drucker, Burges, Kaufman, Smola, & Vapnik, 1997) ซึ่งมีลักษณะการทำงานโดยใช้เส้น Support Vector เช่นเดิมแต่มีการเพิ่มการคำนวณค่า Epsilon insensitive (ϵ) ซึ่งเป็นระยะห่างระหว่าง Support Vector ที่ตัวแบบสร้างขึ้นกับจุดของข้อมูลที่อยู่นอก Support Vector นั้นและปรับปรุงการคำนวณผลลัพธ์ ดังรูปที่ 2-18 แสดงลักษณะความแตกต่างของการทำงานระหว่าง Support Vector Machine กับ Support Vector Regression



รูปที่ 2-18 ตัวแบบ Support Vector Machine (บน) และ Support Vector Regression (ล่าง)
(http://www.saedsayad.com/support_vector_machine_reg.htm)

จุฬาลงกรณ์มหาวิทยาลัย

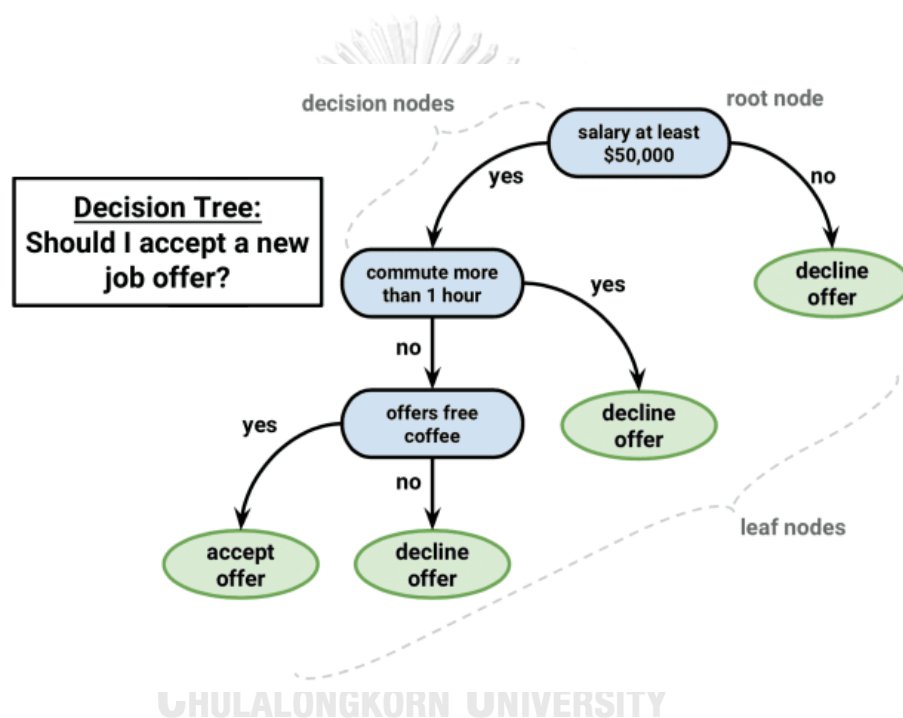
CHULALONGKORN UNIVERSITY

สำหรับงานวิจัยนี้จะใช้ตัวแบบ Support Vector Regression เนื่องจากลักษณะข้อมูลและผลลัพธ์ที่ต้องการอยู่ในรูปแบบของจำนวนจริง Support Vector Regression จึงมีความเหมาะสมมากกว่า Support Vector Machine

2.4.6 Random Forest (RF)

Random Forest เสนอโดย L.Breiman (Breiman, 2001) Random Forest มีความสามารถในการจำแนกและถดถอยได้เป็นอย่างดี สามารถปรับให้เข้ากับการเรียนรู้ข้อมูลเฉพาะได้ง่ายและให้ผลลัพธ์ที่แม่นยำ (Biau & Scornet, 2016) เป็นรูปแบบที่พัฒนาต่อจากวิธีการ Decision tree โดยการใช้ Decision tree จำนวนมาก (Breiman, 2001) เปรียบเสมือนป่าที่มีต้นไม้อยู่เป็นจำนวนมาก ซึ่งเป็นที่มาของชื่อวิธีการ พื้นฐานของ Decision tree มาจากการสร้างกฎ (Rule)

สำหรับการตัดสินใจจากข้อมูลใดก็ตามและข้อมูลจะไหลไปในทิศทางที่เหมาะสมกับกฎนั้น โดยโครงสร้างจะประกอบไปด้วย ปมราก (Root node) ปม (Node) กิ่ง (Branch) และ ใบ (Leaf) แต่ละส่วนจะทำหน้าที่แตกต่างกัน ปมรากและปมจะทำหน้าที่เป็นจุดทดสอบหรือหัวข้อที่ต้องทำการตัดสินใจตามทางเลือกที่กำหนดให้ในส่วนของกิ่ง และเมื่อตัดสินใจเลือกตามกิ่งแล้วก็การดำเนินการก็จะไหลไปตามกิ่งนั้นไปยังปมที่อยู่ถัดไปหรือใบที่เป็นการตัดสินใจสุดท้าย การทำงานของ Decision tree ใน Random Forest จะมีลักษณะการทำงานดังตัวอย่างในการตัดสินใจของปัญหาการรับข้อเสนอเข้าทำงานรูปที่ 2-19



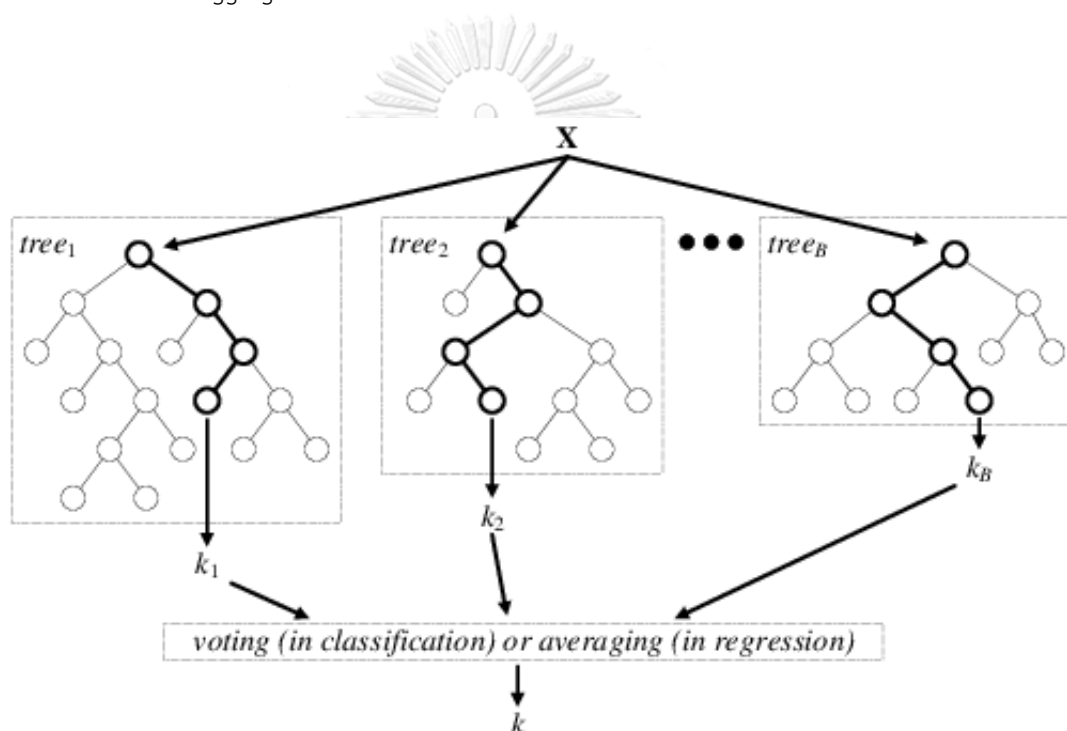
รูปที่ 2-19 แบบจำลอง Decision tree

(https://cway-quantlab.blogspot.com/2017/06/optimize-trading-system-with-gradient_21.html?view=mosaic)

แบบจำลองการตัดสินใจในหัวข้อการตัดสินใจรับข้อเสนออาชีพ กำหนดให้ปมรากเป็นการตัดสินใจในเรื่องของเงินเดือนโดยกำหนดให้อย่างน้อยมากกว่า \$50,000 ถึงจะรับพิจารณา หากข้อเสนอที่ได้รับมีเงินเดือนน้อยกว่า \$50,000 จะปฏิเสธข้อเสนอทันที สมมติว่าข้อเสนอที่ได้รับมีเงินเดือนมากกว่า \$50,000 ก็จะมีการตัดสินใจในปมต่อไปที่กำหนดว่าการเดินทางไปทำงานใช้เวลามากกว่า 1 ชั่วโมงหรือไม่ หากมากกว่า 1 ชั่วโมงก็จะไม่รับข้อเสนอ หากน้อยกว่า 1 ชั่วโมงก็จะรับ

ข้อเสนอและจะนำไปสู่การตัดสินใจต่อไปจนทางเลือกสุดท้ายที่เป็นใบ และไม่มีปมการตัดสินใจอีก และถือเป็นคำตอบสุดท้าย

Random Forest จะนำเอา Decision tree จำนวนมากมารวมกันเพื่อทำนายค่าโดยการเลือกค่าที่มีจำนวนต้นไม้ตัดสินใจเลือกมากที่สุด Decision tree ใน Random Forest จะถูกออกแบบให้มีรูปแบบหรือหัวข้อที่ต้องตัดสินใจไม่เหมือนกันและได้รับข้อมูลนำเข้าที่ไม่เท่ากันโดยการสุ่มเลือกให้ข้อมูลกับแต่ละต้นดังรูปที่ 2-20 เพื่อให้การตัดสินใจของแต่ละต้นเป็นอิสระต่อกัน เทคนิคลักษณะนี้เรียกว่า Bagging




รูปที่ 2-20 แบบจำลอง Random Forest

(<https://medium.com/mmp-li/random-forest-ทำนายว่าจักรยานจะขายได้กี่ต่อเมื่อ-c60080354380>)

2.4.7 eXtreme Gradient Boosting (XGboost)

(Chen & Guestrin, 2016) ได้พัฒนาตัวแบบ XGboost โดยใช้ตัวแบบ Decision tree คล้ายกับตัวแบบ Random Forest แตกต่างกันว่า XGboost ได้เปลี่ยนวิธีการหาคำตอบโดยใช้เทคนิค

Boosting ซึ่งเป็นการสร้าง Decision tree หรือ Weak Classifier มาเรียนรู้ข้อมูลและส่งต่อผลการเรียนรู้ให้ Weak Classifier ตัวต่อไปทำการเรียนรู้และปรับแก้ความคลาดเคลื่อน ความแตกต่างระหว่าง Bagging และ Boosting มีลักษณะดังรูปที่ 2-21




รูปที่ 2-21 ความแตกต่างระหว่าง Bagging และ Boosting


(<https://tupleblog.github.io/images/post/baggingboosting/schematic.png>)

2.4.8 Light Gradient Boosting Machine (LGBM)

LGBM พัฒนาขึ้นโดยทีมนักวิจัยของ Microsoft เพื่อลดเวลาในการใช้งานตัวแบบ โดย LGBM มีลักษณะในการสร้าง Decision tree ที่แตกต่างจาก XGboost ดังรูปที่ 2-22 LGBM มีลักษณะการสร้าง Decision tree ต่อจากจุดที่เลือกไว้และสร้างต่อจากผลที่ได้เป็นขั้น เรียกว่าเป็นการเติบโตแนวตั้ง โดยไม่ต้องคำนวณจาก Decision tree ทั้งหมดที่สร้างขึ้นพร้อมกันใน XGboost โดยมี Algorithm ในการใช้ Histogram ในการจัดกลุ่มข้อมูลช่วยให้ LGBM สามารถทำงานได้รวดเร็วขึ้น (Khandelwal, 2017)



Level-wise tree growth in XGBOOST.



Leaf wise tree growth in Light GBM.

รูปที่ 2-22 Level-wise and Leaf-wise tree growth

(<https://www.analyticsvidhya.com/blog/2017/06/which-algorithm-takes-the-crown-light-gbm-vs-xgboost/>)

2.4.9 วิธีการพยากรณ์แบบผสม (Hybrid Method)

วิธีการพยากรณ์แบบผสมเป็นรูปแบบที่พัฒนาขึ้นโดยเพื่อจุดเด่นของการพยากรณ์ในแต่ละรูปแบบมาผสมเข้าด้วยกันเพื่อให้ได้ความแม่นยำที่สูงขึ้น โดยหลักการแล้วจะนำตัวแบบการพยากรณ์ที่มีความสามารถในการพยากรณ์ข้อมูลที่อยู่ในรูปแบบเชิงเส้นมาผสมกับรูปแบบการพยากรณ์ที่มีความสามารถในการพยากรณ์ข้อมูลที่ไม่อยู่ในรูปแบบเชิงเส้นและให้น้ำหนักกับค่าการพยากรณ์แต่ละตัวที่ทำให้ค่าความคลาดเคลื่อนน้อยที่สุด (J.-J. Wang, Wang, Zhang, & Guo, 2012)

2.5 การประเมินผลการพยากรณ์

การประเมินผลการพยากรณ์เลือกใช้วิธีการหาค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error, MAPE) เป็นตัววัดผล โดยค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยหมายถึงความคลาดเคลื่อนคิดเป็นเปอร์เซ็นต์โดยไม่คำนึงถึงเครื่องหมาย บวก หรือ ลบ

สามารถสื่อความหมายแก่ผู้ใช้งาน สามารถนำไปเปรียบเทียบระหว่างวิธีการได้ง่ายกว่าการประเมินผล ด้วยวิธีการอื่น (Makridakis, 1993)

สมการสำหรับการคำนวณค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE) แสดงดังสมการ (8)

$$MAPE = \frac{1}{n} \sum_{i=1}^n \frac{|A_i - F_i|}{A_i} \times 100\% \quad (8)$$

เมื่อ

A_i = ค่าจริงของสิ่งที่สนใจ

F_i = ค่าพยากรณ์ของสิ่งที่สนใจ

n = จำนวนข้อมูล

ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยที่น้อยหมายถึงความแม่นยำที่มาก สามารถประเมินผลตัวแบบผ่านตารางการประเมินค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยของ Lewis ที่ได้รับการพัฒนาขึ้นเพื่อใช้ในการประเมินตัวแบบว่ามีความแม่นยำและสามารถใช้งานได้ในระดับใด (Lewis, 1982)

ตารางที่ 2-1 A Scale of Judgment of Forecast Accuracy (Lewis, 1982)

ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย	การตัดสินความแม่นยำในการพยากรณ์
น้อยกว่า 10%	มีความแม่นยำสูง
ตั้งแต่ 11% ถึง 20%	มีความแม่นยำที่ดี
ตั้งแต่ 21% ถึง 50%	มีความสมเหตุสมผล
ตั้งแต่ 51% ขึ้นไป	ไม่แม่นยำ

ตัวแบบที่สามารถยอมรับได้จะต้องมีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยกว่า 50% ตัวแบบที่ดีจะต้องมีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยกว่า 20% และตัวแบบที่มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยกว่า 10% ถือว่าเป็นตัวแบบที่มีความแม่นยำในการพยากรณ์สูง

2.6 ทบทวนวรรณกรรม

ดังที่กล่าวในข้างต้น การพยากรณ์มีการพัฒนาอย่างต่อเนื่องตั้งแต่อดีตจนถึงปัจจุบันและได้มีการพัฒนาตัวแบบการพยากรณ์ขึ้นมามากมายจากการศึกษาวิจัย สำหรับงานวิจัยนี้จะทำการศึกษาเกี่ยวกับการพยากรณ์ด้วยวิธีการพยากรณ์แบบอนุกรมเวลา การพยากรณ์เชิงสาเหตุ และการพยากรณ์ด้วยการเรียนรู้ของเครื่อง

2.6.1 Application of machine learning techniques for supply chain demand forecasting

งานวิจัยของ (Carbonneau, Laframboise, & Vahidov, 2008) ศึกษาการพยากรณ์ปริมาณอุปสงค์โดยใช้ชุดข้อมูล 2 ชุดคือ ข้อมูลจำลองจากโซ่อุปทานเป็นข้อมูลรายวันโดยจำลองข้อมูลจำนวน 1,200 วัน และข้อมูลคำสั่งซื้อที่ลูกค้าสั่งซื้อกับองค์กรเป็นข้อมูลรายเดือนของโรงงานตัวอย่างแห่งหนึ่งในประเทศแคนาดาตั้งแต่เดือนมกราคม ค.ศ. 1992 ถึง เมษายน ค.ศ. 2003 เมื่อผ่านการเตรียมข้อมูลแล้วเหลือข้อมูลจำนวน 130 เดือน เพื่อนำไปใช้งานในการจัดการภายในห่วงโซ่อุปทาน (Supply Chain) ทีมผู้วิจัยได้ใช้เทคนิคในการศึกษา 8 เทคนิค ประกอบไปด้วย การพยากรณ์อย่างง่าย วิธีค่าเฉลี่ย วิธีค่าเฉลี่ยเคลื่อนที่ วิธีแนวโน้ม การวิธีการถดถอยเชิงเส้นพหุคูณ วิธีโครงข่ายประสาทเทียม วิธีโครงข่ายประสาทเทียมแบบวนซ้ำ และวิธี Support Vector Regression แบบกำลังสองน้อยที่สุด ได้แบ่งชุดข้อมูลเพื่อทำการสอน (Train date) 600 ข้อมูลสำหรับข้อมูลจำลองจากโซ่อุปทาน 100 ข้อมูลสำหรับข้อมูลคำสั่งซื้อกับองค์กร และการทดสอบ (Test data) 600 ข้อมูลสำหรับข้อมูลจำลองจากโซ่อุปทาน 30 ข้อมูลสำหรับข้อมูลคำสั่งซื้อกับองค์กร และทำการพยากรณ์ข้อมูลล่วงหน้า 15 ชุดข้อมูล (15 วันสำหรับข้อมูลจำลองจากโซ่อุปทาน และ 15 เดือนสำหรับข้อมูลคำสั่งซื้อกับองค์กร) และวัดผลด้วย Mean Absolute Error (MAE) พบว่า วิธีการพยากรณ์ด้วยวิธีการถดถอยเชิงเส้นพหุคูณ วิธีโครงข่ายประสาทเทียม วิธีโครงข่ายประสาทเทียมแบบวนซ้ำ และ Support Vector Regression แบบกำลังสองน้อยที่สุด ให้ความแม่นยำที่ดีกว่าวิธีการทั่วไปอย่างการพยากรณ์อย่างง่าย การพยากรณ์ด้วยวิธีค่าเฉลี่ย การพยากรณ์ด้วยวิธีค่าเฉลี่ยเคลื่อนที่ และการพยากรณ์ด้วยวิธีแนวโน้ม อย่างมีนัยสำคัญ และพบว่า วิธีการพยากรณ์และการพยากรณ์ด้วยวิธี Support Vector Regression แบบกำลังสองน้อยที่สุด ให้ความแม่นยำมากที่สุดและแตกต่างอย่างจากวิธีการอื่นอย่างมากในชุดข้อมูลการสอนและให้ความแม่นยำในชุดข้อมูลทดสอบเป็นอันดับ

สองรองจาก วิธีการพยากรณ์ด้วยวิธีโครงข่ายประสาทเทียมแบบวนซ้ำเล็กน้อย สำหรับงานวิจัยนี้
สรุปว่าวิธีการพยากรณ์ด้วยวิธี Support Vector Regression แบบกำลังสองน้อยที่สุดเป็นวิธีที่ให้
ความแม่นยำมากที่สุด

2.6.2 Forecasting tourism demand to Catalonia: Neural networks vs. time series models

งานวิจัยของ (Claveria & Torra, 2014) ศึกษาการพยากรณ์ปริมาณความต้องการของ
นักท่องเที่ยวต่อการเดินทางท่องเที่ยวไปยังแคว้นคาตาลูญาประเทศสเปน ในการศึกษาที่ใช้ข้อมูล
ปริมาณนักท่องเที่ยวจากทุกประเทศต้นทางที่มีจุดหมายไปยังคาตาลูญาตั้งแต่ ค.ศ. 2001 จนถึง
ค.ศ. 2009 เพื่อเปรียบเทียบความแม่นยำของตัวแบบการพยากรณ์ระหว่างด้วยวิธี Artificial Neural
Network และด้วยวิธีอนุกรมเวลา โดยการพยากรณ์ด้วยวิธีอนุกรมเวลาเลือกใช้วิธีการ ARIMA และ
Self-exciting threshold autoregression models (SETAR) สำหรับการพยากรณ์ด้วยวิธีอนุกรม
เวลา ใช้ข้อมูลตั้งแต่ เดือนมกราคม ค.ศ. 2001 ถึง เดือนมกราคม ค.ศ. 2008 เพื่อทำการพยากรณ์ 1
2 3 6 และ 12 เดือนถัดไป จากนั้นเปรียบเทียบกับข้อมูลส่วนที่เหลือ สำหรับการพยากรณ์ด้วยวิธี
Artificial Neural Network ได้แบ่งข้อมูลออกเป็นสามส่วน ใช้สำหรับการสอน การตรวจสอบความ
ถูกต้อง และข้อมูลสำหรับการทดสอบความแม่นยำ จากนั้นวัดผลความแม่นยำของแต่ละวิธีการ
พยากรณ์ด้วยวิธี Root Mean Squared Forecast Error (RMSFE) พบว่าไม่สามารถสรุปได้ชัดเจน
ว่าการพยากรณ์ด้วยวิธีใดให้ความแม่นยำที่สูงกว่าอย่างชัดเจน เนื่องจากผลการพยากรณ์ ARIMA
SETAR และ Artificial Neural Network มีความแม่นยำในแต่ละชุดข้อมูลไม่เท่ากัน โดยรวมแล้ว
ARIMA สามารถทำการพยากรณ์ได้แม่นยำในหลายชุดข้อมูลมากกว่า SETAR และ Artificial Neural
Network

2.6.3 Forecasting of demand using ARIMA model


งานวิจัยของ (Fattah, Ezzine, Aman, El Moussami, & Lachhab, 2018) ศึกษาการ
พยากรณ์ปริมาณอุปสงค์ของบริษัทอาหารในโมร็อกโก เพื่อปรับปรุงการบริหารจัดการสินค้าคงคลัง
การพยากรณ์ที่มีความแม่นยำเพียงพอต่อเป้าหมายของบริษัทจะช่วยให้การบริหารจัดการมี
ประสิทธิภาพ ในการศึกษาที่ใช้ข้อมูลของอุปสงค์ในอดีตที่จัดเก็บในรูปแบบอนุกรมเวลาเป็นรายเดือน
ตั้งแต่เดือน มกราคม ค.ศ. 2010 จนถึงเดือน ธันวาคม ค.ศ. 2016 เป็นจำนวน 72 ข้อมูล ได้แบ่ง

ออกเป็นสองชุดข้อมูลโดยใช้ข้อมูลเดือน มกราคม ค.ศ. 2010 จนถึงเดือน ธันวาคม ค.ศ. 2015 เพื่อทำการสอนและทำการทดสอบโดยใช้ข้อมูลเดือน มกราคม ค.ศ. 2016 จนถึงเดือน ธันวาคม ค.ศ. 2016 และวัดผลด้วย 4 ตัวชี้วัดคือ Akaike Criterion (AIC). Schwarz Bayesian Criterion (SBC) Maximum Likelihood และ Standard Error จากการวิเคราะห์ข้อมูล Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) ตามขั้นตอนสามารถเลือกสำหรับทดสอบ ARIMA ได้ 6 ตัวแบบคือ ARIMA(1,0,2) ARIMA(2,0,2) ARIMA(1,0,1) ARIMA(1,0,0) ARIMA(0,0,1) with constant และ ARIMA(0,0,1) without constant พบว่า ARIMA(1,0,1) with constant ให้ค่า AIC และ SBC น้อยที่สุด และมีค่าความผิดพลาดเป็นอันดับที่สอง งานวิจัยนี้จึงสรุปว่า ARIMA(1,0,1) with constant มีความแม่นยำเพียงพอต่อการนำไปใช้งานในบริษัท

2.6.4 Short-term electricity demand forecasting using double seasonal exponential smoothing

งานวิจัยของ (Taylor, 2003) ศึกษาการพยากรณ์ปริมาณการใช้ไฟฟ้าในประเทศอังกฤษและเวลส์ โดยพิจารณาการพยากรณ์ข้อมูลอนุกรมเวลาแบบครึ่งชั่วโมงของการใช้ไฟฟ้าด้วยตัวแบบผสมของการพยากรณ์การปรับเรียบและการพยากรณ์แบบ ARMA จากการสังเกตข้อมูลหนึ่งสัปดาห์ในเดือนมิถุนายน ค.ศ. 2000 พบลักษณะของฤดูกาลตามรอบเวลา 48 ชั่วโมง และพบว่ามีรูปแบบฤดูกาลที่สองขึ้นในช่วงสองวันสุดท้ายของสัปดาห์เห็นชัดขึ้นเมื่อเทียบกับสัปดาห์ถัดไป ดังรูปที่ 2-23

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY




รูปที่ 2-23 Half-hourly electricity demand in England and Wales from Monday 5 June 2000 to Sunday 18 June 2000 (Taylor, 2003)

ผู้วิจัยได้ทำการพยากรณ์เปรียบเทียบโดยข้อมูลแบบครึ่งชั่วโมงจำนวน 12 สัปดาห์ ตั้งแต่ วันที่ 5 กรกฎาคม ค.ศ. 2000 จนถึง วันที่ 27 สิงหาคม ค.ศ. 2000 และใช้วิธีการพยากรณ์ 4 แบบคือ ตัวแบบผสม Holt-Winters for within-day seasonality with AR(1) adjustment ตัวแบบผสม Holt-Winters for within-week seasonality with AR(1) adjustment ตัวแบบผสม Double seasonal Holt-Winters with AR(1) adjustment และ Double Seasonal ARMA ผลการวิจัยนี้ พบว่าตัวแบบผสม Double seasonal Holt-Winters with AR(1) adjustment ให้ความแม่นยำมากที่สุด โดยมีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยที่ต่ำที่สุดเพียง 1.25%

2.6.5 Day-ahead load forecast using random forest and expert input selection

งานวิจัยของ (Lahouar & Slama, 2015) ศึกษาการพยากรณ์โหลด (Load) การใช้ไฟฟ้าในประเทศตูนิเซีย ด้วยวิธีการพยากรณ์แบบ Random forest การศึกษานี้ใช้ข้อมูลแบบรายชั่วโมงตั้งแต่วันที่ 1 มกราคม ค.ศ. 2009 ถึง 31 สิงหาคม ค.ศ. 2014 และทำการแทนที่ข้อมูลที่ขาดหายไปด้วยการใช้ข้อมูลก่อนหน้า รวมถึงการคงไว้ของข้อมูลจากเหตุการณ์ต่าง ๆ เช่น สถานการณ์ฉุกเฉิน ปัญหาทางการเมือง เพื่อให้เครื่องทำการเรียนรู้รูปแบบที่เกิดขึ้น ผู้วิจัยใช้จำนวน Tree เป็นจำนวน 500 ต้น ในตัวแบบ Random Forest ที่สร้างขึ้นโดยมีเงื่อนไขในการตัดสินใจดังรูปที่ 2-24




รูปที่ 2-24 Regression tree
(Lahouar & Slama, 2015)

การประเมินผลความแม่นยำใช้รูปแบบของ ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยในส่วนของผลการทำนายที่เกิดขึ้นเทียบกับข้อมูลจริง โดยในงานวิจัยนี้ทำการทดสอบด้วยข้อมูลครึ่งปี ตั้งแต่วันที่ 1 มกราคม ค.ศ. 2014 ถึง 30 กรกฎาคม ค.ศ. 2014 โดยแยกข้อมูลวันหยุดเพื่อทำการพยากรณ์แยกในตัวแบบที่แตกต่างกันและมีการปรับปรุงตัวแบบการพยากรณ์ในวันหยุด พบว่าค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยที่ได้อยู่ที่ 2.24% เท่านั้น

ผู้วิจัยได้ทำการเปรียบเทียบความแม่นยำกับตัวแบบการพยากรณ์อื่นเพิ่มเติม โดยการนำ Persistence model (PER) Artificial Neural Network และ Support Vector Machine มาทำการพยากรณ์เพื่อเปรียบเทียบ พบว่า โดยเฉลี่ยแล้วการพยากรณ์แบบ Random Forest ให้ความแม่นยำมากที่สุด ทั้งนี้การพยากรณ์ในตัวแบบอื่น เช่น Support Vector Machine ยังต้องอาศัยการศึกษาตัวแปรที่เหมาะสม

2.6.6 Stock index forecasting base on a hybrid model

งานวิจัยของ (J.-J. Wang et al., 2012) ศึกษาการพยากรณ์ดัชนีราคาหุ้น (Stock price index) Shenzhen Integrated Index (SZII-China) และ Jones Industrial Average Index (DJIAI-USA) ด้วยตัวแบบผสมที่สามารถจับข้อมูลทั้งในรูปแบบเชิงเส้น และไม่เชิงเส้นได้ โดยทำการผสมตัวแบบจากการปรับเรียบเอกซ์โพเนนเชียล ตัวแบบ ARIMA ตัวแบบโครงข่ายประสาทเทียมแบบแพร่ย้อนกลับ (Back Propagation Neural Network : BPNN) ซึ่งตัวแบบการปรับเรียบเอกซ์โพเนนเชียล และตัวแบบ ARIMA จะเป็นตัวแบบที่สามารถจับข้อมูลที่เป็นเชิงเส้น และตัวแบบ BPNN จะเป็นตัวแบบที่สามารถจับข้อมูลที่ไม่เป็นเชิงเส้น และทำการถ่วงน้ำหนักด้วย Genetic Algorithm (GA) แผนผังการทำงานของตัวแบบผสม แสดงดังรูปที่ 2-25



รูปที่ 2-25 The flow chart of the PHM
(J.-J. Wang et al., 2012)

ผลการศึกษาพบว่าตัวแบบผสมสามารถพยากรณ์ได้แม่นยำกว่าตัวแบบเดี่ยวอย่างตัวแบบการปรับเรียบเอกซ์โพเนนเชียล และตัวแบบ ARIMA อย่างมาก โดยตัวแบบผสม ตัวแบบการปรับเรียบเอกซ์โพเนนเชียล และตัวแบบ ARIMA มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย 32.25% 52.21% และ 42.88% ตามลำดับ

2.6.7 Research on China's Steel Demand Using Combined Forecast

งานวิจัยของ (Weng, Zhou, Zhou, & Qi, 2015) ศึกษาการพยากรณ์ปริมาณความต้องการเหล็กในประเทศจีนปี ค.ศ. 2010 เพื่อทำการพยากรณ์ปริมาณความต้องการเหล็กในประเทศจีนปี ค.ศ. 2015 ด้วยวิธีการผสมตัวแบบในรูปแบบ Combine โดยศึกษาต่อจากตัวแบบที่มีการศึกษาก่อนหน้าตามการทบทวนวรรณกรรมสามารถคัดเลือกมาได้ 8 ตัวแบบ จากนั้นทำการคำนวณค่าความคลาดเคลื่อน และเลือก 3 ตัวแบบดังตารางที่ 2-2 เป็นตัวแบบที่มีความคลาดเคลื่อนน้อยที่สุดมาทำการผสมตัวแบบ

ตารางที่ 2-2 ผลการพยากรณ์ปี ค.ศ. 2010 ของตัวแบบที่มีความคลาดเคลื่อนน้อยที่สุด 3 ตัวแบบ

ตัวแบบ	ผลการพยากรณ์ ค.ศ. 2010 (ร้อยละต้น)	ปริมาณความต้องการ จริง ค.ศ. 2010 (ร้อยละต้น)	ค่าร้อยละ ความคลาดเคลื่อน
Consumption intensity method	5.18	6.11	15.22
Regression method	5.10		16.53
Grey theory method	4.98		18.49

จากนั้นทำการหาค่าคงที่ถ่วงน้ำหนักของแต่ละตัวแบบและนำมาคำนวณเพื่อทำการพยากรณ์ ได้ผลการพยากรณ์ปริมาณความต้องการเหล็กในประเทศไทยปี ค.ศ. 2015 เท่ากับ 8.25 ร้อยล้านตัน ซึ่งเมื่อเทียบกับปริมาณความต้องการจริงที่เกิดขึ้นคือ 8.038 ร้อยล้านตัน คิดเป็นความคลาดเคลื่อนเพียงร้อยละ 2.637 ถือเป็นตัวแบบที่มีความแม่นยำสูง

2.6.8 Forecasting for Steel Production using Artificial Neural Networks and Feasibility Analysis of Plant Regeneration Acid Development in PT. XYZ

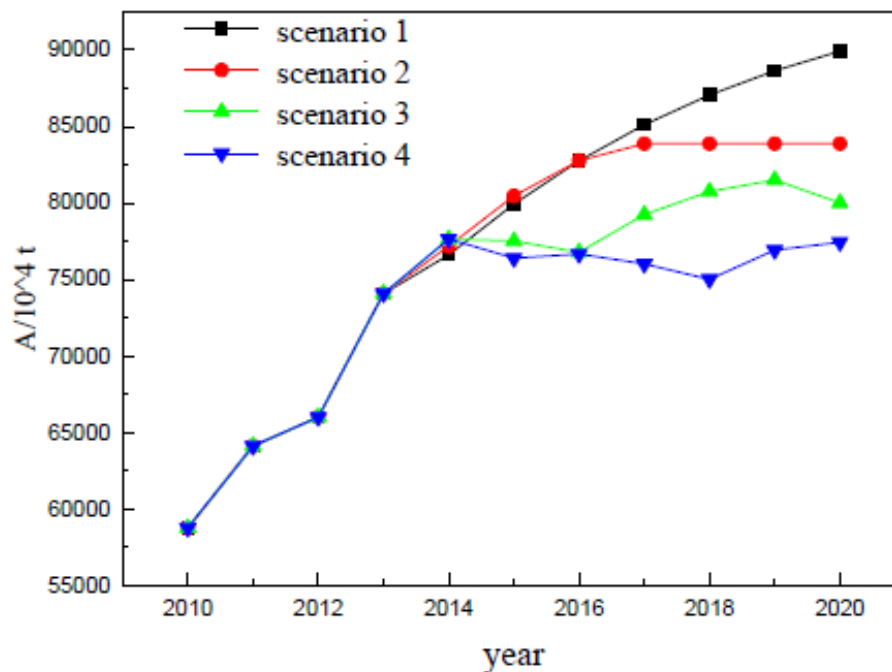
งานวิจัยของ (Sasongko, Marie, & Arifin, 2020) ศึกษาการพยากรณ์ปริมาณความต้องการเหล็กในประเทศอินโดนีเซียปี ค.ศ. 2019 ถึง ค.ศ. 2020 เพื่อทำการประเมินการลงทุนในเทคโนโลยีใหม่ของ Acid Regeneration Plant เพื่อทดแทนเทคโนโลยีเก่าที่ใช้อยู่ ด้วยตัวแบบโครงข่ายประสาทเทียม ตัวแบบการถดถอยเชิงเส้น และตัวแบบการแยกองค์ประกอบ โดยใช้ข้อมูลปริมาณความต้องการเหล็ก ค.ศ. 2015 ถึง ค.ศ. 2018 ในการสอนตัวแบบ และวัดผลการพยากรณ์ด้วยค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย

จากการศึกษาพบว่าตัวแบบโครงข่ายประสาทเทียม เป็นตัวแบบการพยากรณ์ที่มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยที่สุดซึ่งมีค่าเท่ากับร้อยละ 2.58 โดยที่ตัวแบบการแยกองค์ประกอบ และตัวแบบการถดถอยเชิงเส้น มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเพิ่มขึ้นเท่ากับร้อยละ 10.03 และ 15.23 ตามลำดับ จากนั้นทำการพยากรณ์ปริมาณความต้องการเหล็กและประเมินร่วมกับปัจจัยอื่น ๆ ในการประเมินการลงทุนเทคโนโลยีใหม่ของ Acid Regeneration Plant

โดยสรุปว่าการลงทุนในเทคโนโลยี Spray Roaster มีความเหมาะสมที่สุดโดยมีมูลค่าการลงทุนเป็นเงิน 5.292 ล้านดอลลาร์ และระยะเวลาคืนทุน 2 ปี 9 เดือน

2.6.9 Analyzing Structure and Driving Force of Steel Consumption in China

งานวิจัยของ (Gao, Na, Tian, Ye, & Qi, 2018) ศึกษาการปัจจัยที่ส่งผลต่อปริมาณการใช้เหล็กในประเทศจีนโดยศึกษา 6 ปัจจัยหลักคือ 1. Steel consumption 2. Service life-span 3. In-use stock of steel 4. Average service life-span 5. Productivity per in-use stock of steel 6. Steel output per unit GDP และทำการพยากรณ์ปริมาณความต้องการใช้เหล็กในประเทศจีนปี ค.ศ. 2010 ถึง ค.ศ. 2020 ได้ผลการพยากรณ์ดังรูปที่ 2-26



รูปที่ 2-26 ผลการพยากรณ์จากตัวแบบการพยากรณ์ 4 วิธี


(Gao et al., 2018)

จากรูปที่ 2-26 ได้มีการแบ่งการพยากรณ์เป็น 4 วิธี วิธีที่ 1 ใช้ตัวแบบ S-growth วิธีที่ 2 ใช้ตัวแบบ Polynomial growth วิธีที่ 3 และ 4 ใช้ตัวแบบ Back Propagation Neural Network (BPNN) แบบ 3 ชั้นซ้อนที่มีการปรับค่าปัจจัยแตกต่างกันและมีการจำลองสถานการณ์จำลองที่ปรับโครงสร้างอุตสาหกรรมเพื่อให้ผลผลิตเหล็กลดลง 3% และ 2% ทุกปี

2.6.10 Modeling steel supply and demand functions using logarithmic multiple regression analysis (case study: Steel industry in Iran)

งานวิจัยของ (Mehmanpazir, Khalili-Damghani, & Hafezalkotob, 2019) เสนอแนวทางในการวิเคราะห์และกำหนดฟังก์ชันอุปสงค์และการพยากรณ์อุปสงค์และอุปทานของเหล็กในประเทศไทยผ่านโดยวิเคราะห์ปัจจัยที่เกี่ยวข้องประกอบไปด้วย ปริมาณความต้องการ ปริมาณการนำเข้า ปริมาณการส่งออก ปริมาณอุปทาน ของเหล็กดิบ ผลผลิตเหล็กกล้า เหล็กแผ่นรีดร้อน และเหล็กเส้น ผู้วิจัยได้ทำการวิเคราะห์และสร้างฟังก์ชันของอุปสงค์และอุปทานด้วยวิธีการวิเคราะห์ Linear Logarithmic Function และ Logarithmic Regression และวิเคราะห์ความเหมาะสมด้วย ANOVA ซึ่งเป็นเครื่องมือทางสถิติ หลังจากทำการวิเคราะห์ปัจจัยที่เกี่ยวข้องแล้วจึงทำการพยากรณ์ด้วยตัวแบบ Least Squares Method โดยใช้ข้อมูลรายเดือน 48 เดือนตั้งแต่ปี ค.ศ. 2010 ถึง ค.ศ. 2013 เป็นข้อมูลในการสร้างตัวแบบและใช้การวิเคราะห์เชิงสถิติเป็นตัวชี้วัดได้ผลดังรูปที่ 2-27 และผลการวิเคราะห์ความเหมาะสมของตัวแบบและความแม่นยำของตัวแบบดังตารางที่ 2-3

จุฬาลงกรณ์มหาวิทยาลัย



รูปที่ 2-27 ความต้องการเหล็กจริงและผลการพยากรณ์ความต้องการเหล็ก

(Mehmanpazir et al., 2019)

ตารางที่ 2-3 ผลการวิเคราะห์เชิงสถิติของตัวแบบ (Mehmanpazir et al., 2019)

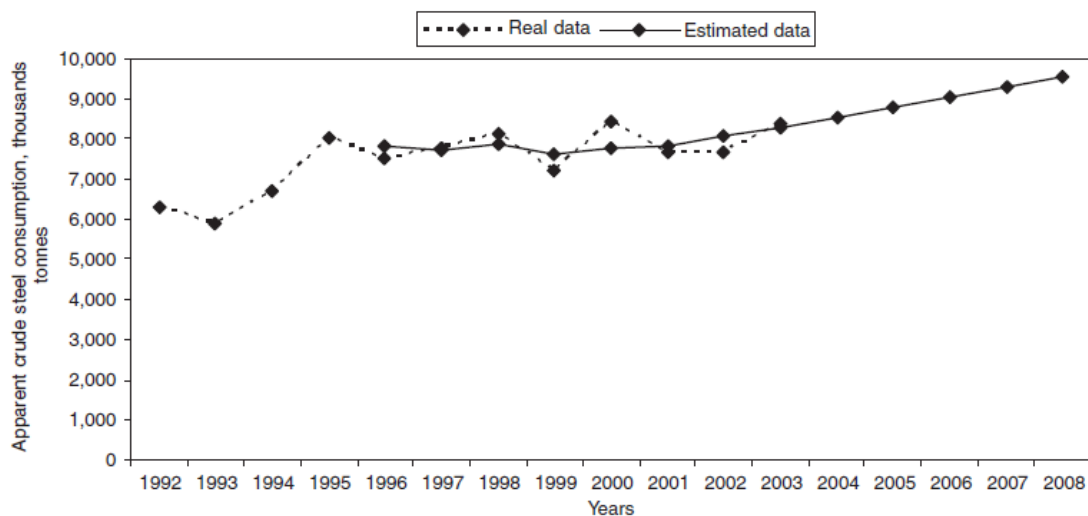
Endogenous attribute	l_ConsumptionSteel
Examples	44
R ²	0.890054
Adjusted-R ²	0.875587
Sigma error	0.033851
F-Test (5,38)	61.5247 (0.000000)

จากรูปที่ 2-27 ผลการสร้างตัวแบบการพยากรณ์สามารถทำการพยากรณ์ได้ใกล้เคียงค่าจริง และตารางที่ 2-3 จากค่า R² = 0.89 หมายถึงตัวแบบการพยากรณ์สามารถอธิบายผลการพยากรณ์ได้ถึง 89% และมีค่า Sigma error เพียง 0.34 เท่านั้น สามารถสรุปได้ว่าตัวแบบและผลการพยากรณ์เหมาะสมต่อการพยากรณ์ปริมาณความต้องการเหล็กในประเทศอิหร่าน

2.6.11 Polish steel consumption

งานวิจัยของ (Rebiasz, 2006) ศึกษาการเปลี่ยนแปลงการบริโภคเหล็กในประเทศโปแลนด์ที่เกิดขึ้นในช่วงปี ค.ศ. 1974 ถึง ค.ศ. 2003 โดยเชื่อมโยงกับความเปลี่ยนแปลงจากปัจจัยทางเศรษฐกิจอื่น ๆ ทำการวิเคราะห์ปริมาณการใช้เหล็กจากอุตสาหกรรมที่เกี่ยวข้องโดยคำนวณปริมาณสำหรับแต่ละภาคอุตสาหกรรมตามองค์ประกอบของผลิตภัณฑ์ รายได้ และองค์ประกอบวัสดุของผลิตภัณฑ์ในอุตสาหกรรม ประกอบไปด้วย 1. Metal containing products excluding machinery 2. Mechanical machinery and equipment 3. Electrical machinery and equipment 4. Motor vehicles and other transportation 5. Building

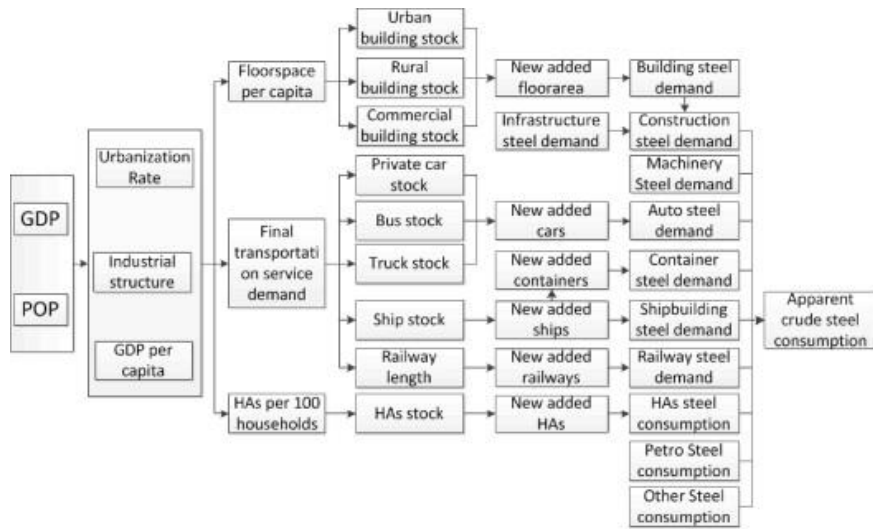
จากการพยากรณ์ได้ผลดังรูปที่ 2-28 โดยพยากรณ์เพิ่ม 5 ปีจนถึงปี ค.ศ. 2008 การบริโภคเหล็กในโปแลนด์เพิ่มขึ้นในปี ค.ศ. 2008 ปริมาณการใช้เหล็กที่ชัดเจนมีแนวโน้มที่จะสูงถึง 9,520,000 ตันเทียบกับ 8,350,000 ตันในปี ค.ศ. 2003



รูปที่ 2-28 ความต้องการเหล็กจริงและผลการพยากรณ์ความต้องการเหล็กในประเทศโปแลนด์
(Rebiasz, 2006)


2.6.12 Trends and development of steel demand in China: A bottom-up analysis

งานวิจัยของ (Yin & Chen, 2013) ศึกษาการเปลี่ยนแปลงการปริมาณการผลิตและการบริโภคที่เกิดขึ้นในช่วง ค.ศ. 1998 ถึง ค.ศ. 2010 โดยมีการบริโภคหลักจาก 9 อุตสาหกรรม ประกอบไปด้วยอุตสาหกรรมการก่อสร้าง อุตสาหกรรมเครื่องจักร อุตสาหกรรมรถยนต์ อุตสาหกรรมต่อเรือ อุตสาหกรรมทางรถไฟ อุตสาหกรรมปิโตรเลียม อุตสาหกรรมเครื่องใช้ในครัวเรือน และอุตสาหกรรมคอนเทนเนอร์ ซึ่งมีการวิเคราะห์ข้อมูลด้วย Stock based model และ Bottom-up analysis model ดังรูปที่ 2-29



รูปที่ 2-29 Bottom-up analysis model of steel demand (Yin & Chen, 2013)

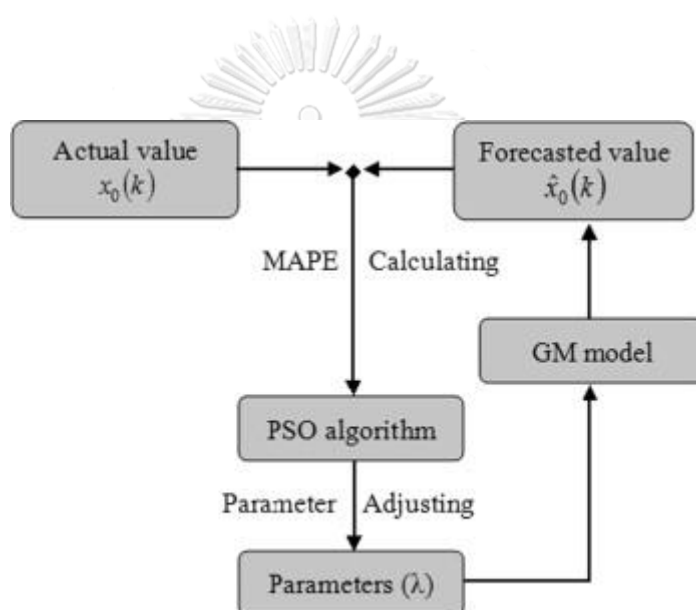
การพยากรณ์ปริมาณการบริโภคเหล็กของจีน ทำการพยากรณ์จากปัจจัยที่กล่าวถึงในส่วนก่อนหน้านี้ จากผลการพยากรณ์ความต้องการเหล็กในอุตสาหกรรมส่วนใหญ่เพิ่มขึ้นจนถึงจุดสูงสุดในช่วงก่อนปี ค.ศ. 2025 จากนั้นจะค่อย ๆ ลดลงดังรูปที่ 2-30



รูปที่ 2-30 Future steel consumption in China, 2010–2050 (Yin & Chen, 2013)

2.6.13 Forecasting iron ore import and consumption of China using grey model optimized by particle swarm optimization algorithm

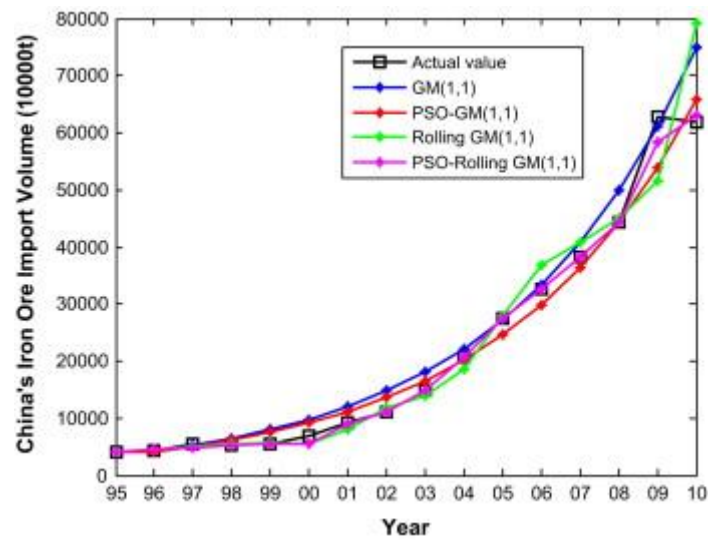
งานวิจัยของ (Ma, Zhu, & Wang, 2013) ศึกษาและพัฒนาตัวแบบผสมประเภท Hybrid ที่มีความแม่นยำสูงโดยผสมระหว่าง Grey theory และ Rolling mechanism optimized ที่ใช้ Particle swarm optimization algorithm ในการ Optimize ขั้นตอนการสร้างตัวแบบการพยากรณ์แสดงดังรูปที่ 2-31 โดยใช้ China Statistical Yearbook (ปี ค.ศ. 1996 ถึง ค.ศ. 2011) เป็นแหล่งข้อมูลเพื่อสร้างและทดสอบความแม่นยำของตัวแบบ



รูปที่ 2-31 PSO-based GM(1,1) prediction model
(Ma et al., 2013)

ตัวแบบการพยากรณ์ที่สร้างขึ้นมี 4 ตัวแบบคือ 1. ตัวแบบ Grey method (GM(1,1)) 2. ตัวแบบผสมระหว่าง Particle swarm optimization algorithm and Grey method (PSO-GM(1,1)) 3. ตัวแบบผสมระหว่าง Rolling mechanism และ Grey method (Rolling GM(1,1)) 4. ตัวแบบผสมระหว่าง Particle swarm optimization algorithm และ Rolling mechanism และ Grey method (PSO-rolling GM(1,1)) ได้ผลการพยากรณ์ดังรูปที่ 2-32 และการคำนวณค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเพื่อเปรียบเทียบตัวแบบพบว่า ตัวแบบที่ 4. PSO-rolling GM(1,1)) มีค่า

ร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยที่สุดโดยมีค่าเท่ากับ 2.3061 และตัวแบบที่ 3 2 และ 1 มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเพิ่มขึ้นเป็น 6.7015 14.4493 และ 16.8834 ตามลำดับ



รูปที่ 2-32 The comparison of the actual and forecast import volume
(Ma et al., 2013)

ตารางที่ 2-4 สรุปและเปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ความต้องการเหล็ก

ลำดับ	งานวิจัย	ชุดข้อมูล	ตัวแบบการพยากรณ์	ประเภทตัวชี้วัด	ผลลัพธ์
1	Research on China's Steel Demand Using Combined Forecast	ผลการพยากรณ์จากตัวแบบเดี่ยว	ตัวแบบผสมประเภท Combine	PE	ผลการพยากรณ์ความต้องการเหล็กในประเทศจีนปี พ.ศ. 2558
2	Forecasting for Steel Production using Artificial Neural Networks and Feasibility Analysis of Plant Regeneration Acid Development in PT. XYZ	ปริมาณความต้องการเหล็กในประเทศ ปริมาณการขายเหล็กของบริษัท	ANN Regression Decomposition	MAPE	MAPE ของ Artificial Neural Network เท่ากับ 2.58 การถดถอยเชิงเส้น เท่ากับ 15.23 และการแยกองค์ประกอบ เท่ากับ 10.03
3	Analyzing Structure and Driving Force of Steel Consumption in China	ปริมาณการบริโภคเหล็ก อายุการใช้งาน ปริมาณเหล็กในคลัง อายุการใช้งานเฉลี่ย ผลผลิตต่อปริมาณเหล็กในคลัง ผลผลิตต่อหน่วย GDP	1.S-growth 2.Polynomial growth 3.BPNN	ค่าพยากรณ์	ปัจจัยที่เกี่ยวข้องกับปริมาณความต้องการเหล็กและผลการพยากรณ์ ปริมาณความต้องการใช้เหล็กในประเทศจีน ปี พ.ศ. 2553-2563

ตารางที่ 2-4 สรุปและเปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ความต้องการเหล็ก (ต่อ)

ลำดับ	งานวิจัย	ชุดข้อมูล	ตัวแบบการพยากรณ์	ประเภทตัวชี้วัด	ผลลัพธ์
4	Modeling steel supply and demand functions using logarithmic multiple regression analysis (case study: Steel industry in Iran)	ข้อมูลการนำเข้าส่งออก และปริมาณการใช้งานของ เหล็กดิบผลิตภัณฑ์จาก เหล็ก และ เหล็กแผ่นรีดร้อน	Least Square Method (Regression)	Sigma Error	ปัจจัยที่เกี่ยวข้องกับปริมาณความต้องการเหล็กและผลการพยากรณ์ ปริมาณความต้องการใช้เหล็กในประเทศ อิหร่าน
5	Polish steel consumption	อุตสาหกรรมบรรจุภัณฑ์ เครื่องจักรกล เครื่องจักรไฟฟ้า ยานยนต์ ก่อสร้าง	Consumption intensity method	ค่าพยากรณ์	ปัจจัยที่เกี่ยวข้องกับปริมาณความต้องการเหล็กและผลการพยากรณ์ ปริมาณความต้องการใช้เหล็กในประเทศ โปแลนด์
6	Trends and development of steel demand in China: A bottom-up analysis	GDP อัตราการขยายตัวของเมือง ระดับความอิมิตัวอายุการใช้งาน ความเข้มของเหล็ก	Economic Demand Model	ค่าพยากรณ์	ผลการพยากรณ์ ปริมาณความต้องการใช้เหล็กในประเทศ จีน แยกตามอุตสาหกรรม

ตารางที่ 2-4 สรุปและเปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการพยากรณ์ความต้องการเหล็ก (ต่อ)

ลำดับ	งานวิจัย	ชุดข้อมูล	ตัวแบบการพยากรณ์	ประเภทตัวชี้วัด	ผลลัพธ์
7	Forecasting iron ore import and consumption of China using grey model optimized by particle swarm optimization algorithm	ปริมาณการบริโภคแร่เหล็กในประเทศจีน	1. Particle swarm optimization algorithm 2. Rolling Method 3. Grey Method	MAPE	ผลการพยากรณ์ปริมาณความต้องการใช้เหล็กในประเทศจีนโดยตัวแบบที่แม่นยำที่สุดมี MAPE เพียง 2.3061
8	งานวิจัยฉบับนี้	ปริมาณการจำหน่ายซีเมนต์ รถยนต์ เครื่องใช้ไฟฟ้า ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน และ GDP	1. Holt's 2. ARIMA 3. Regression 4. ANN 5. SVR 6. RF 7. XGBoost 8. LGBM 9. Hybrid	MAPE	ผลการพยากรณ์ปริมาณความต้องการใช้เหล็กในประเทศไทย

งานวิจัยนี้จะดำเนินการผสมตัวแบบโดยการใช้ตัวแบบการเรียนรู้ของเครื่องเป็นตัวผสมระหว่างตัวแบบที่มีความแม่นยำที่สุดสามอันดับแรก ซึ่งการผสมผลการพยากรณ์ด้วย ตัวแบบ ANN สามารถให้ผลการพยากรณ์ที่ดีขึ้นจากการพยากรณ์ในตัวแบบเดี่ยว (Omar, Hoang, & Liu, 2016) แต่ในงานวิจัยนี้จะศึกษาเพิ่มเติมด้วยการใช้ตัวแบบการเรียนรู้ของเครื่องที่แม่นยำที่สุดสามอันดับแรกมาเป็นตัวผสมและทำการเปรียบเทียบ

บทที่ 3

วิธีการดำเนินการวิจัย

เพื่อค้นหาตัวแบบการพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศที่แม่นยำ สามารถนำไปใช้งานได้จริงในการวางแผนการจัดการได้อย่างเหมาะสม ผู้วิจัยได้เลือกข้อมูลทุติยภูมิที่เป็นข้อมูลที่เชื่อถือได้ จากแหล่งข้อมูลที่เชื่อถือได้ในระดับประเทศ และเลือกตัวแบบการพยากรณ์ทั้งในตัวแบบอนุกรมเวลา ตัวแบบเชิงสาเหตุ และตัวแบบการเรียนรู้ของเครื่องเพื่อทำการเปรียบเทียบความแม่นยำ

3.1 การรวบรวมข้อมูล

การรวบรวมข้อมูลทำการรวบรวมจากแหล่งข้อมูลที่เชื่อถือได้ โดยเป็นหน่วยงานและองค์กรที่เป็นทางการ 3 แห่ง ประกอบไปด้วย

- ศูนย์ข้อมูลเชิงลึกอุตสาหกรรมเหล็กไทย สถาบันเหล็กและเหล็กกล้าแห่งประเทศไทย
- ธนาครแห่งประเทศไทย
- สำนักงานเศรษฐกิจอุตสาหกรรม กระทรวงอุตสาหกรรม

โดยทำการรวบรวมข้อมูลที่อยู่ในช่วงเวลาเดียวกันเพื่อให้ได้ข้อมูลที่มีความสัมพันธ์กันในช่วงเวลา ซึ่งจะมีผลต่อการสร้างตัวแบบการพยากรณ์ โดยเฉพาะตัวแบบการพยากรณ์เชิงสาเหตุ ซึ่งช่วงเวลาของข้อมูลที่รวบรวมคือ ตั้งแต่เดือน มกราคม พ.ศ. 2557 จนถึงเดือน ธันวาคม พ.ศ. 2562

3.2 การจัดการและวิเคราะห์ข้อมูล

ข้อมูลที่นำมาใช้ในการพยากรณ์ด้วยตัวแบบอนุกรมเวลาเป็นข้อมูลปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ รายเดือนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2562 จำนวน 72 ข้อมูลดังตาราง 3-1


ตารางที่ 3-1 ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ

ปี-เดือน	ปริมาณ (ตัน)	ปี - เดือน	ปริมาณ (ตัน)	ปี - เดือน	ปริมาณ (ตัน)
2557-1	356,358.2	2559-1	422,053.8	2561-1	422,054
2557-2	380,862.9	2559-2	408,482.8	2561-2	408,483
2557-3	414,206.0	2559-3	514,733.7	2561-3	514,734
2557-4	410,634.9	2559-4	488,154.5	2561-4	488,154
2557-5	432,377.6	2559-5	573,056.2	2561-5	573,056
2557-6	441,668.1	2559-6	430,619.5	2561-6	430,619
2557-7	423,289.9	2559-7	459,180.3	2561-7	459,180
2557-8	535,560.2	2559-8	486,836.6	2561-8	486,837
2557-9	433,581.5	2559-9	509,439.3	2561-9	509,439
2557-10	423,318.6	2559-10	401,155.7	2561-10	401,156
2557-11	446,306.1	2559-11	502,302.8	2561-11	502,303
2557-12	468,793.7	2559-12	557,935.8	2561-12	557,936
2558-1	403,564.1	2560-1	361,885.1	2562-1	361,885
2558-2	424,093.0	2560-2	462,232.7	2562-2	462,233
2558-3	387,587.2	2560-3	536,411.9	2562-3	536,412
2558-4	361,952.2	2560-4	389,057.4	2562-4	389,057
2558-5	410,860.1	2560-5	447,850.0	2562-5	447,850
2558-6	436,761.4	2560-6	434,361.1	2562-6	434,361
2558-7	441,276.6	2560-7	447,911.5	2562-7	447,911
2558-8	418,757.3	2560-8	461,230.1	2562-8	461,230
2558-9	483,459.2	2560-9	515,869.5	2562-9	515,870
2558-10	409,822.5	2560-10	432,541.4	2562-10	432,541
2558-11	350,591.7	2560-11	410,223.5	2562-11	410,223
2558-12	402,953.0	2560-12	486,148.5	2562-12	486,148

จากข้อมูลข้างต้นในการพยากรณ์ในงานวิจัยนี้จะแบ่งข้อมูลออกเป็นสามส่วน


- ส่วนแรก ใช้สำหรับสร้างตัวแบบการพยากรณ์ (Training data)
ใช้ข้อมูลตั้งแต่ เดือนมกราคม พ.ศ. 2557 จนถึง เดือนธันวาคม พ.ศ. 2560 เป็นจำนวน 48 ข้อมูล
- ส่วนที่สอง ใช้สำหรับการตรวจสอบตัวแบบ (Validation data)
ใช้ข้อมูลตั้งแต่ เดือนมกราคม พ.ศ. 2561 จนถึง เดือนธันวาคม พ.ศ. 2561 เป็นจำนวน 12 ข้อมูล
- ส่วนที่สาม ใช้สำหรับการทดสอบตัวแบบ (Testing data)
ใช้ข้อมูลตั้งแต่ เดือนมกราคม พ.ศ. 2562 จนถึง เดือนธันวาคม พ.ศ. 2562 เป็นจำนวน 12 ข้อมูล

จากข้อมูลอนุกรมเวลาในตารางที่ 3-1 นำมาทำเป็นแผนภูมิเส้นเพื่อสังเกตลักษณะแนวโน้มของข้อมูลได้ดังรูปที่ 3-1 สังเกตได้ว่ามีลักษณะของแนวโน้มตั้งเส้นแนวโน้มเชิงบวกดังภาพ



รูปที่ 3-1 ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ ตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560

จากข้อมูลอนุกรมเวลาในตารางที่ 3-1 นำมาทำเป็นแผนภูมิเส้นเพื่อสังเกตลักษณะฤดูกาลหรือรอบของข้อมูลได้ดังรูปที่ 3-2 ไม่สามารถสังเกตลักษณะของฤดูกาลหรือรอบได้อย่างแน่ชัด



รูปที่ 3-2 ปริมาณความต้องการเหล็กแผ่นรีดร้อนแยกเป็นรายปีตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560

CHULALONGKORN UNIVERSITY

3.3 การปรับข้อมูล (Data Normalization)

การปรับข้อมูลเป็นการปรับข้อมูลให้เหมาะสมกับการวิเคราะห์ข้อมูลด้วยกระบวนการของการเรียนรู้ของเครื่องโดยปรับข้อมูลจากข้อมูลที่มีค่ามากเช่น 1,000,000 ให้อยู่ในรูปของข้อมูลที่อยู่ในหลักหน่วย ซึ่งจะช่วยให้ตัวแบบการเรียนรู้ของเครื่องสามารถเรียนรู้จากข้อมูลได้รวดเร็วยิ่งขึ้นและมีความแม่นยำ ในงานวิจัยนี้จะใช้ Standard scaler จาก Library sklearn ในการปรับข้อมูลให้เหมาะสมกับตัวแบบการเรียนรู้ของเครื่อง ซึ่ง Standard scaler มีสมการในการคำนวณดังสมการที่

(9)

$$Z = \frac{(x - \bar{x})}{\sigma} \quad (9)$$

เมื่อ Z = ค่าของข้อมูลที่ผ่านการปรับข้อมูล

X = ค่าของข้อมูลก่อนการปรับข้อมูล

\bar{X} = ค่าเฉลี่ยของข้อมูล

σ = ส่วนเบี่ยงเบนมาตรฐาน

3.4 ตัวแบบการพยากรณ์


3.4.1 ตัวแบบการพยากรณ์อนุกรมเวลา

วิธีการพยากรณ์แบบอนุกรมเวลาถูกพัฒนาขึ้นมาหลายตัวแบบ ซึ่งแต่ละตัวแบบมีความเหมาะสมกับข้อมูลที่มีลักษณะแตกต่างกันออกไป เมื่อทำการวิเคราะห์ข้อมูลเบื้องต้นแล้ว การเลือกตัวแบบที่เหมาะสมกับข้อมูลจะสามารถให้ความแม่นยำที่ดีได้ จากการวิเคราะห์ข้อมูลเบื้องต้นในหัวข้อ 3.2 ผู้วิจัยพบว่า ข้อมูลมีจำนวนไม่มาก มีลักษณะของแนวโน้มที่ชัดเจน แต่ยังไม่ชัดเจนในลักษณะของฤดูกาล ผู้วิจัยได้เลือกตัวแบบการพยากรณ์ดังนี้


- ตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์ (Holt's Exponential Smoothing Model)

ตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์เหมาะกับข้อมูลที่มีแนวโน้ม พัฒนาต่อจากตัวแบบการปรับเรียบเอกซ์โพเนนเชียล เพื่อให้ตัวแบบสามารถจัดการเปลี่ยนแปลงของข้อมูลตามแนวโน้มได้ ดังรูปที่ 3-1 แสดงให้เห็นว่าข้อมูลสำหรับสร้างตัวแบบการพยากรณ์มีลักษณะของแนวโน้ม และจากการวิเคราะห์ ACF และ PACF เพื่อยืนยันการมีแนวโน้มและหาลักษณะของฤดูกาลของข้อมูลดังรูปที่ 3-3 และ รูปที่ 3-4 พบว่ามีลักษณะของแนวโน้มโดยสังเกตจากการลดลงตามเวลาของ ACF และ PACF แต่ไม่พบลักษณะของฤดูกาลในข้อมูลชุดนี้ การเลือกวิธีการพยากรณ์ด้วยตัวแบบการ

พยากรณ์การปรับเรียบเอกซ์โพเนนเชียลของโฮสต์ จึงเหมาะสมกว่าการเลือกตัวแบบอื่น
ในกลุ่มตัวแบบการปรับเรียบเอกซ์โพเนนเชียล



รูปที่ 3-3 ACF ของปริมาณความต้องการเหล็กแผ่นรีดร้อนตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560



รูปที่ 3-4 PACF ของปริมาณความต้องการเหล็กแผ่นรีดร้อน ตั้งแต่ พ.ศ. 2557 จนถึง พ.ศ. 2560

- ตัวแบบ Autoregressive Integrated Moving Average (ARIMA)

ตัวแบบการพยากรณ์แบบ ARIMA หรือ Box-Jenkins' model เป็นตัวแบบที่สามารถใช้กับข้อมูลทุกรูปแบบ ให้ความแม่นยำสูง แต่ตัวแบบ ARIMA ต้องอาศัยความรู้และความชำนาญในการวิเคราะห์ข้อมูล และลักษณะของข้อมูลในแต่ละขั้นตอนการพยากรณ์เพื่อทำการกำหนดตัวแบบที่จะใช้ในการพยากรณ์

3.4.2 ตัวแบบการพยากรณ์เชิงสาเหตุ

วิธีการพยากรณ์ด้วยตัวแบบเชิงสาเหตุ ผู้วิจัยเลือกใช้ตัวแบบการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression) เนื่องจากเป็นตัวแบบพื้นฐานของการพยากรณ์เชิงสาเหตุ สามารถเลือกใช้ตัวแปรอิสระที่จะนำมาเป็นปัจจัยในการพยากรณ์ได้หลายตัวแปร ซึ่งมีเป้าหมายในการทำให้ตัวแปรตามหรือผลการพยากรณ์มีค่าความคลาดเคลื่อนน้อยที่สุด

3.4.3 ตัวแบบการพยากรณ์ด้วยการเรียนรู้ของเครื่อง

วิธีการพยากรณ์ด้วยการเรียนรู้ของเครื่อง ผู้วิจัยใช้การเขียนโปรแกรมด้วยภาษา Python ผ่านโปรแกรม Jupyter Notebook ใน Anaconda Navigator และ Google Colaboratory ใน Google โดยเลือกตัวแบบการพยากรณ์ดังต่อไปนี้

- ตัวแบบ Artificial Neural Network
- ตัวแบบ Support Vector Regression
- ตัวแบบ Random Forest
- ตัวแบบ eXtreme gradient boosting
- ตัวแบบ Light Gradient Boosted Machine

3.4.4 ตัวแบบการพยากรณ์ผสม

จากการพยากรณ์ด้วยการเรียนรู้ของเครื่อง ผู้วิจัยจะทำการรวมตัวแบบการเรียนรู้ของเครื่องเข้าด้วยกันเพื่อศึกษาวิธีการ และค้นหาตัวแบบผสมที่สามารถทำการพยากรณ์ได้แม่นยำมากขึ้น โดยใช้การเขียนโปรแกรมด้วยภาษา Python ผ่านโปรแกรม Jupyter Notebook ใน Anaconda Navigator และ Google colaboratory ใน Google โดยเลือกตัวแบบการพยากรณ์จากหัวข้อ 3.3.3 ที่ให้คำร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยที่สุด 3 ตัวแบบมาทำการผสม

3.5 การประเมินผลการพยากรณ์

หลังจากทำการพยากรณ์แล้ว ผู้วิจัยจะทำการประเมินผลการพยากรณ์ด้วยการเปรียบเทียบค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Percentage Error, MAPE) เพื่อหารูปแบบการพยากรณ์ที่มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยที่สุด



บทที่ 4


ผลการดำเนินการ

4.1 การพยากรณ์ด้วยตัวแบบอนุกรมเวลา

การพยากรณ์ด้วยตัวแบบอนุกรมเวลาเป็นตัวแบบพื้นฐานในการพยากรณ์ สามารถพยากรณ์ได้ด้วยข้อมูลในอดีตของสิ่งที่สนใจ การดำเนินการวิจัยนี้จะทำการพยากรณ์ด้วยตัวแบบอนุกรมเวลาเพื่อเป็นข้อมูลสำหรับการเปรียบเทียบกับวิธีการอื่น


4.1.1 ตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์

ตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์ประกอบไปด้วยค่าคงที่ α (alpha) และ β (beta) แทนค่าการให้น้ำหนัก โดยค่าเหล่านี้จะคำนวณจากที่ให้ค่าความผิดพลาด (Error) น้อยที่สุดผ่านโปรแกรม R-studio จากข้อมูลอนุกรมเวลา เมื่อทำการปรับรูปการพยากรณ์ (Fitted) สังเกตค่าระดับ (Level) และค่าแนวโน้ม (Trend) ได้ผลดังรูปที่ 4-1




รูปที่ 4-1 ผลการปรับรูปการพยากรณ์ระหว่างค่าระดับและค่าแนวโน้ม


จากการคำนวณของโปรแกรม R-studio เพื่อหาค่าคงที่ปรับเรียบ α และ β ที่เหมาะสมที่สุด คำนวณได้ $\alpha = 0.332909$ และ $\beta = 0.2467024$ เมื่อนำไปแทนค่าในสมการเพื่อคำนวณค่าพยากรณ์จะได้ค่าพยากรณ์สำหรับตรวจสอบดังภาคผนวกตารางที่ ก-1 และ รูปที่ 4-2 หลังจากทำการพยากรณ์ ผู้วิจัยทำการตรวจสอบตัวแบบการพยากรณ์ด้วยการวิเคราะห์ลักษณะของ ACF และ PACF ของค่าความต่างระหว่างค่าพยากรณ์และค่าจริง เพื่อตรวจสอบความปกติของข้อมูลการพยากรณ์ เมื่อนำค่า Residual มาจัดให้อยู่ในรูปแบบ ACF และ PACF ได้ดังรูปที่ 4-3 และ รูปที่ 4-4 และพิจารณารูปแบบของ ACF และ PACF พบว่าการกระจายตัวของค่า Residual อยู่ภายในช่วงความเชื่อมั่น (Confident interval) และไม่มีรูปแบบการกระจายตัว แสดงให้เห็นว่าตัวแบบที่ใช้ทำการพยากรณ์มีความเหมาะสมกับข้อมูล



รูปที่ 4-2 ผลการพยากรณ์ผลการพยากรณ์สำหรับตรวจสอบตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์



รูปที่ 4-3 ACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์



รูปที่ 4-4 PACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์

4.1.2 ตัวแบบ Autoregressive Integrated Moving Average (ARIMA)

ผู้วิจัยเลือกใช้คำสั่ง `auto.arima` เพื่อให้โปรแกรมทำการคำนวณตัวแบบการพยากรณ์ที่เหมาะสม ผ่านการเปรียบเทียบค่า Corrected for Akaike's Information Criterion หรือ AICc โดยตัวแบบที่ให้ค่า AICc ต่ำที่สุดจะเป็นตัวแบบที่ถูกเลือก

การสร้างตัวแบบด้วยคำสั่ง `auto.arima` ในโปรแกรม R-studio ให้ผลการเปรียบเทียบ AICc ดังตารางที่ 4-1 เมื่อทำการเปรียบเทียบแล้วพบว่าตัวแบบ ARIMA(2,1,0) มีค่า AICc น้อยที่สุด โดยมีค่าเท่ากับ 1,160.86 จึงทำการเลือกตัวแบบการพยากรณ์ด้วย ARIMA(2,1,0) เพื่อทำการพยากรณ์ ตัวแบบ ARIMA(2,1,0) ให้ค่าพยากรณ์สำหรับตรวจสอบดังภาคผนวกตารางที่ ก-2 และรูปที่ 4-5 จากนั้นพิจารณาความเหมาะสมของการพยากรณ์จาก ACF และ PACF ของ Residual ดังรูปที่ 4-6 และ 4-7 รวมไปถึง z-test และ normality test ตรวจสอบค่า p-value = 0.7368 ซึ่งมากกว่า 0.05 สามารถสรุปได้ว่าตัวแบบ ARIMA(2,1,0) สามารถใช้ในการพยากรณ์ข้อมูลปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศได้

ข้อมูลตัวแบบ ARIMA(2,1,0)

Series: snseries

ARIMA(2,1,0)

Coefficients:

ar1 ar2

-0.6769 -0.5155

s.e. 0.1250 0.1223

sigma^2 estimated as 2.785e+09: log likelihood=-577.15

AIC=1160.3 AICc=1160.86 BIC=1165.85

z test of coefficients:

Estimate Std. Error z value Pr(>|z|)

ar1 -0.67693 0.12504 -5.4139 6.168e-08 ***

ar2 -0.51552 0.12230 -4.2151 2.497e-05 ***

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1


Shapiro-Wilk normality test

data: fitauto\$residuals


W = 0.9837, p-value = 0.7368

ตารางที่ 4-1 AICc ของตัวแบบการ ARIMA


ARIMA		AICc
ARIMA(2,1,2)(1,0,1)[12]	with drift	Inf
ARIMA(0,1,0)	with drift	1183.245
ARIMA(1,1,0)(1,0,0)[12]	with drift	1177.738
ARIMA(0,1,1)(0,0,1)[12]	with drift	Inf
ARIMA(0,1,0)		1181.139
ARIMA(1,1,0)	with drift	1175.366
ARIMA(1,1,0)(0,0,1)[12]	with drift	1177.747
ARIMA(1,1,0)(1,0,1)[12]	with drift	Inf
ARIMA(2,1,0)	with drift	1163.044
ARIMA(2,1,0)(1,0,0)[12]	with drift	1165.523
ARIMA(2,1,0)(0,0,1)[12]	with drift	1165.532
ARIMA(2,1,0)(1,0,1)[12]	with drift	Inf
ARIMA(3,1,0)	with drift	1165.064
ARIMA(2,1,1)	with drift	1165.148
ARIMA(1,1,1)	with drift	Inf
ARIMA(3,1,1)	with drift	Inf
ARIMA(2,1,0)		1160.86
ARIMA(2,1,0)(1,0,0)[12]		1163.24
ARIMA(2,1,0)(0,0,1)[12]		1163.244
ARIMA(2,1,0)(1,0,1)[12]		Inf
ARIMA(1,1,0)		1173.2
ARIMA(3,1,0)		1162.803
ARIMA(2,1,1)		1162.889
ARIMA(1,1,1)		1162.028
ARIMA(3,1,1)		1162.602



รูปที่ 4-5 ผลการพยากรณ์ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Autoregressive Integrated Moving Average



รูปที่ 4-6 ACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบ ARIMA(2,1,0)




รูปที่ 4-7 PACF ของค่า Residual จากผลการพยากรณ์ด้วยตัวแบบ ARIMA(2,1,0)

4.2 การพยากรณ์ด้วยตัวแบบเชิงสาเหตุ

4.2.1 ตัวแบบการถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression)

ข้อมูลจากสถาบันเหล็กและเหล็กกล้าแห่งประเทศไทย พบว่าปริมาณการใช้งานเหล็กกล้าภายในประเทศแบ่งตามการใช้งานในภาคธุรกิจเป็น ธุรกิจการก่อสร้าง 57.1% อุตสาหกรรมรถยนต์ 18.0% อุตสาหกรรมเครื่องจักร 11.1% เครื่องใช้ไฟฟ้า 9.2% บรรจุก๊าซ 3.9% และอุตสาหกรรมอื่น 0.7% (Toomwongsa, 2017) ดังรูปที่ 4-8 ผู้วิจัยจึงทำการค้นหาข้อมูลอนุกรมเวลาของยอดขายในอุตสาหกรรมที่เกี่ยวข้องกับความต้องการเหล็กแผ่นรีดร้อนรวมถึงข้อมูลที่เกี่ยวข้องภายในอุตสาหกรรมเหล็กแผ่นรีดร้อนเพื่อนำมาเป็นปัจจัยในการพยากรณ์

ปริมาณความต้องการเหล็กแบ่งตามกลุ่มอุตสาหกรรม ข้อมูลปี 2560



รูปที่ 4-8 ปริมาณความต้องการเหล็กแบ่งตามกลุ่มอุตสาหกรรม ข้อมูลปี 2560

(Toomwongsa, 2017)

จากการค้นหาข้อมูลยอดขายในอุตสาหกรรมที่เกี่ยวข้องกับความต้องการเหล็กแผ่นรีดร้อน ผู้วิจัยค้นหาข้อมูลที่เกี่ยวข้องได้ทั้งหมด 41 ปัจจัยประกอบไปด้วย ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน ปริมาณการส่งออกเหล็กแผ่นรีดร้อน ราคาเหล็กแผ่นรีดร้อนในประเทศ ราคานำเข้าเหล็กแท่งแบน (East Asia) ราคานำเข้าเหล็กแผ่นรีดร้อน (East Asia) ราคเหล็กแผ่นรีดร้อนในประเทศจีน อัตราแลกเปลี่ยนบาทไทยต่อดอลลาร์ ราคาทองคำต่ำสุด ราคาทองคำสูงสุด ราคาทองคำเฉลี่ย น้ำมันดิบ (WTI) น้ำมันดิบ (Brent) ราคาน้ำมันดีเซล ราคาเอ็นจีวี (1 กิโลกรัม) มูลค่าการซื้อขายที่ดิน และสิ่งปลูกสร้าง การออกใบอนุญาตจัดสรรที่ดิน พื้นที่ก่อสร้างที่ได้รับอนุญาต การขอจดทะเบียนอาคารชุด ที่อยู่อาศัยจดทะเบียนเพิ่ม GDP ยอดขายรถยนต์ทุกประเภท ยอดขายรถโดยสารส่วนบุคคล ยอดผลิตรถยนต์ทุกประเภท ยอดผลิตรถยนต์ (ขนาดเครื่องยนต์ 1,500 CC) ยอดผลิตรถยนต์ (ขนาดเครื่องยนต์ 1,800 CC) ยอดผลิตรถยนต์ (ขนาดเครื่องยนต์ 2,000 CC) ยอดผลิตรถยนต์ (ขนาดเครื่องยนต์ 2,500 CC) ราคาน้ำมันเตาซัลเฟอร์ต่ำพิเศษ ราคาน้ำมันเตาชั้นสอง ราคาน้ำมันดิบเฉลี่ย ราคาน้ำมันดิบเฉลี่ย (ราคาแบบ Spot) ราคาน้ำมันดิบ (UK) ราคาน้ำมันดิบ (Brent 38° API)

ราคาถ่านหิน (South Africa) ราคาถ่านหิน (Australia) ราคาสินแร่เหล็ก ปริมาณการจำหน่ายซีเมนต์
 ปอร์ตแลนด์ ปริมาณการจำหน่ายรถยนต์รวมทุกประเภท ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า ปริมาณ
 การจำหน่ายซีเมนต์ผสม และปริมาณการผลิตซีเมนต์ผสม

หลังจากรวบรวมข้อมูลปัจจัยที่ใช้ในการพยากรณ์แล้ว ผู้วิจัยได้ทำการพยากรณ์โดยใช้
 โปรแกรม Minitab ในการทำการจัดตัวแบบการพยากรณ์และให้โปรแกรมทำการคัดเลือกข้อมูลเพื่อ
 ทำการสร้างตัวแบบการพยากรณ์ด้วยกระบวนการ Stepwise ที่ค่าความเชื่อมั่น 95% การนำเข้า
 ข้อมูลจะนำเข้าสู่ข้อมูลสำหรับการสร้างตัวแบบการพยากรณ์โดยใช้ข้อมูลตั้งแต่ มกราคม พ.ศ. 2557
 ถึง ธันวาคม พ.ศ. 2560 ทำการพยากรณ์ข้อมูล ตั้งแต่ มกราคม พ.ศ. 2561 ถึง ธันวาคม พ.ศ. 2561
 ซึ่งเป็นข้อมูลตรวจสอบ จากนั้นทำการเปรียบเทียบกับข้อมูลจริงตั้งแต่ มกราคม พ.ศ. 2561 ถึง
 ธันวาคม พ.ศ. 2561

ผลการใช้การบวนการ Stepwise ของโปรแกรม Minitab ในการสร้างตัวแบบการถดถอยเชิงเส้น
 พหุคูณโดยใช้ปัจจัยทั้งหมด

Regression Equation

$$\begin{aligned} \text{HR Carbon} &= 169833 + 0.730 \text{ ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน} + 1.073 \text{ ยอดขาย} \\ \text{Consumption} & \text{รถยนต์ทุกประเภท} - 15.34 \text{ ยอดผลิตรถยนต์ (ขนาดเครื่องยนต์ 2,500} \\ & \text{CC)} + 0.01067 \text{ ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า} \end{aligned} \quad (10)$$

Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	169833	49270	3.45	0.001	
ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน	0.730	0.112	6.54	0.000	1.01
ยอดขายรถยนต์รวมทุกประเภท	1.073	0.455	2.36	0.023	1.01
ยอดผลิตรถยนต์ (ขนาดเครื่องยนต์ 2,500 CC)	-15.34	6.31	-2.43	0.019	1.13
ปริมาณการจำหน่าย เครื่องใช้ไฟฟ้า	0.01067	0.00359	2.97	0.005	1.13


Model Summary

S	R-sq	R-sq(adj)	R-sq(pred)
33946.6	61.26%	57.65%	53.10%


Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	4	78350225297	19587556324	17.00	0.000
ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน	1	49220112522	49220112522	42.71	0.000
ยอดขายรถรวมทุกประเภท	1	6406120565	6406120565	5.56	0.023
ยอดผลิตรถยนต์(ขนาดเครื่องยนต์ 2,500 CC)	1	6810476244	6810476244	5.91	0.019
ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า	1	10156819641	10156819641	8.81	0.005
Error	43	49552070725	1152373738		
Total	47	1.27902E+11			

จากการสร้างตัวแบบโดยใช้ปัจจัยข้างต้นทั้งหมดผ่านกระบวนการ Stepwise ที่ค่าความเชื่อมั่น 95% ตัวแบบทำการคัดเลือกเหลือ 4 ปัจจัยประกอบไปด้วย ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน ยอดขายรถรวมทุกประเภท ยอดผลิตรถยนต์(ขนาดเครื่องยนต์ 2,500 CC) และปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า จากสมการการพยากรณ์ที่สร้างขึ้นสามารถนำไปพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ ใน พ.ศ. 2561 จำนวน 12 เดือนได้ดังภาคผนวกตารางที่ ก-3 และรูปที่ 4-9 จากนั้นทำการตรวจสอบความปกติของค่า Residual เพื่อตรวจสอบว่าตัวแบบที่ใช้ในการพยากรณ์เหมาะสมกับข้อมูลหรือไม่ โดยการนำค่า Residual ของตัวแบบมาทำการทดสอบความปกติ (Normality) ดังรูปที่ 4-10 จากลักษณะการกระจายตัวรวมไปถึงค่า P-value ของการทดสอบ Anderson - Darling = 0.468 ซึ่งมากกว่าระดับนัยสำคัญที่ 0.05 สามารถสรุปได้ว่าตัวแบบที่ใช้ทำการพยากรณ์มีความเหมาะสมกับข้อมูล



รูปที่ 4-9 ผลการพยากรณ์ผลการพยากรณ์สำหรับตรวจสอบตัวแบบการพยากรณ์แบบถดถอยพหุคูณ
โดยใช้ปัจจัยที่ผ่านกระบวนการ Stepwise




รูปที่ 4-10 ค่า Residual ของตัวแบบการถดถอยเชิงเส้นพหุคูณปริมาณความต้องการเหล็กแผ่นรีดร้อน

แต่ในการใช้งานจริงมีหลายปัจจัยที่ไม่สามารถทราบข้อมูลล่วงหน้าได้ผู้วิจัยจึงทำการคัดเลือกข้อมูลที่สามารถทราบล่วงหน้าได้ อาจเป็นค่าจริง เช่น ยอดการจองรถหรือยอดสั่งซื้อรถจากผู้ผลิตแต่ละราย เป้าหมายยอดการผลิตในแต่ละเดือนซึ่งอุตสาหกรรมรถยนต์จะประกาศล่วงหน้าเสมอ หรือค่าที่ผู้เชี่ยวชาญในอุตสาหกรรมนั้น ๆ ทำการพยากรณ์ออกมา โดยที่ไม่ต้องทำการพยากรณ์ขึ้นมาเอง เพื่อนำมาเป็นข้อมูลสำหรับพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนล่วงหน้าที่สามารถใช้งานได้จริง โดยผู้วิจัยคัดเลือกได้ 5 ข้อมูลดังนี้

- ปริมาณการจำหน่ายซีเมนต์พอร์ตแลนด์

ปริมาณการจำหน่ายซีเมนต์พอร์ตแลนด์เป็นตัวแทนกลุ่มก่อสร้าง (Construction) เนื่องจากในการก่อสร้างอาคารหรือสิ่งก่อสร้างจะมีความต้องการใช้ปูนซีเมนต์เป็นพื้นฐาน และใช้เหล็กแผ่นร่วมในการก่อสร้าง เช่น การสร้างโครงสร้างเหล็ก หรือการทำแบบหล่อสำหรับเสาสะพาน




รูปที่ 4-11 ปริมาณการจำหน่ายซีเมนต์พอร์ตแลนด์เทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อน

ผู้วิจัยได้สร้างแผนภาพเพื่อสังเกตการเคลื่อนไหวของข้อมูลโดยเปรียบเทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อนดังรูปที่ 4-11 พบว่าข้อมูลมีการเคลื่อนไหวในลักษณะเดียวกันหลายเดือนแต่ยังมีแนวโน้มที่แตกต่างกันโดยปริมาณการจำหน่ายซีเมนต์พอร์ตแลนด์มีแนวโน้มลดลง แต่ปริมาณความต้องการเหล็กแผ่นรีดร้อนในประเทศมีแนวโน้มเพิ่มขึ้น ผู้วิจัยจะทำการคัดเลือกโดยใช้กระบวนการ Stepwise ในโปรแกรม Minitab ต่อไป

- ปริมาณการจำหน่ายรถยนต์รวมทุกประเภท

ปริมาณการจำหน่ายรถยนต์รวมทุกประเภทเป็นตัวแทนกลุ่ม Automotive โดยภายในรถยนต์มีการใช้เหล็กแผ่นรีดร้อนเป็นโครงสร้าง เช่น บางส่วนของตัวถัง (Body) โครงรถ (Chassis) หรือแผ่นรองผ้าเบรก (Break parts) ผู้วิจัยได้สร้างแผนภาพเพื่อสังเกตการเคลื่อนไหวของข้อมูลโดยเปรียบเทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อนดังรูปที่ 4-12




รูปที่ 4-12 ปริมาณการจำหน่ายรถยนต์รวมทุกประเภทเทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อน

จากรูปที่ 4-12 พบว่าข้อมูลมีการเคลื่อนไหวในลักษณะเดียวกันหลายเดือนและยังมีแนวโน้มไปในเชิงบวกเช่นเดียวกัน ผู้วิจัยจะทำการคัดเลือกโดยใช้กระบวนการ Stepwise ในโปรแกรม Minitab ต่อไป

- ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า

ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้าเป็นตัวแทนกลุ่ม Appliance หรือเครื่องใช้ไฟฟ้า โดยเครื่องใช้ไฟฟ้าจะมีส่วนประกอบของเหล็กแผ่นรีดร้อน เช่น คอมเพรสเซอร์ที่ใช้ในเครื่องปรับอากาศ ตู้เย็น ปั่นน้ำ โดยปริมาณการขายหลักของกลุ่มเครื่องใช้ไฟฟ้าคือเครื่องปรับอากาศ ผู้วิจัยได้สร้างแผนภาพเพื่อสังเกตการเคลื่อนไหวของข้อมูลโดยเปรียบเทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อนดังรูปที่ 4-13




รูปที่ 4-13 ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้าเทียบกับปริมาณความต้องการเหล็กแผ่นรีดร้อน

จากรูปที่ 4-13 พบว่าข้อมูลมีการเคลื่อนไหวในลักษณะเดียวกันหลายเดือนและยังมีแนวโน้มไปในเชิงบวกเช่นเดียวกัน ผู้วิจัยจะทำการคัดเลือกโดยใช้กระบวนการ Stepwise ในโปรแกรม Minitab ต่อไป

- **ผลิตภัณฑ์มวลรวมในประเทศ (Gross Domestic Product : GDP)**

ผลิตภัณฑ์มวลรวมในประเทศ เป็นข้อมูลเศรษฐกิจมหภาค (Macro-economic) เพื่อแทนในส่วนการใช้งานอื่น และการเปลี่ยนแปลงของภาคเศรษฐกิจโดยรวมของประเทศ ผู้วิจัยได้สร้างแผนภาพเพื่อสังเกตการเคลื่อนไหวของข้อมูลโดยเปรียบเทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อนดังรูปที่ 4-14



รูปที่ 4-14 ผลิตภัณฑ์มวลรวมในประเทศเทียบกับปริมาณความต้องการเหล็กแผ่นรีดร้อน


จากรูปที่ 4-14 พบว่าข้อมูลมีแนวโน้มไปในเชิงบวกเช่นเดียวกัน เนื่องจากข้อมูล GDP เป็นข้อมูลบ่งชี้เศรษฐกิจโดยรวมจึงมีการเคลื่อนไหวที่ไม่ตรงกับปริมาณความต้องการ

เหล็กแผ่นรีดร้อนในประเทศในระดับรายเดือน ผู้วิจัยจะทำการคัดเลือกโดยใช้กระบวนการ Stepwise ในโปรแกรม Minitab ต่อไป

- ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน (HRC Import)

จากภาพที่ 1-2 ปริมาณการนำเข้าแผ่นเหล็กรีดร้อนมีความสัมพันธ์กับปริมาณการใช้งานและเป็นข้อมูลที่สามารถทราบได้ก่อนจากพิกัดส่งออกหรือพิกัดนำเข้า ผู้วิจัยได้สร้างแผนภาพเพื่อสังเกตการเคลื่อนไหวของข้อมูลโดยเปรียบเทียบกับปริมาณการใช้งานเหล็กแผ่นรีดร้อนดังรูปที่ 4-15

ผู้วิจัยพบว่าข้อมูลมีการเคลื่อนไหวใกล้เคียงกันอย่างมากแต่ยังมีแนวโน้มที่แตกต่างกันโดยปริมาณการนำเข้าเหล็กแผ่นรีดร้อนมีแนวโน้มลดลงเล็กน้อยแต่ปริมาณความต้องการเหล็กแผ่นรีดร้อนในประเทศมีแนวโน้มเพิ่มขึ้น ผู้วิจัยจะทำการคัดเลือกโดยใช้กระบวนการ Stepwise ในโปรแกรม Minitab ต่อไป



รูปที่ 4-15 ปริมาณการนำเข้าเทียบกับปริมาณความต้องการเหล็กแผ่นรีดร้อน

หลังจากรวบรวมข้อมูลปัจจัยที่ใช้ในการพยากรณ์แล้ว ผู้วิจัยได้ทำการพยากรณ์โดยใช้โปรแกรม Minitab ในการทำการจัดตัวแบบการพยากรณ์และให้โปรแกรมทำการคัดเลือกข้อมูลเพื่อทำการสร้างตัวแบบการพยากรณ์ด้วยกระบวนการ Stepwise ที่ค่าความเชื่อมั่น 95% การนำเข้าข้อมูลจะนำเข้าสู่ข้อมูลสำหรับการสร้างตัวแบบการพยากรณ์โดยใช้ข้อมูลตั้งแต่ มกราคม พ.ศ. 2557 ถึง ธันวาคม พ.ศ. 2560 ทำการพยากรณ์ข้อมูล ตั้งแต่ มกราคม พ.ศ. 2561 ถึง ธันวาคม พ.ศ. 2561 ซึ่งเป็นข้อมูลตรวจสอบ จากนั้นทำการเปรียบเทียบกับข้อมูลจริงตั้งแต่ มกราคม พ.ศ. 2561 ถึง ธันวาคม พ.ศ. 2561

ผลการใช้โปรแกรม Minitab ในการสร้างตัวแบบการถดถอยเชิงเส้นพหุคูณ

Regression Equation

$$\begin{aligned} \text{HR Carbon} &= 125171 + 0.739 \text{ ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน} \\ \text{Consumption} &+ 1.115 \text{ ยอดขายรถยนต์ทุกประเภท} \\ &+ 0.01358 \text{ ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า} \end{aligned} \quad (11)$$

Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	125171	48200	2.60	0.013	
ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน	0.739	0.118	6.28	0.000	1.01
ยอดขายรถยนต์ทุกประเภท	1.115	0.480	2.33	0.025	1.01
ปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า	0.01358	0.00357	3.80	0.000	1.01

Model Summary


S	R-sq	R-sq(adj)	R-sq(pred)
35790.6	55.93%	52.93%	48.60%

Analysis of Variance


Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	3	71539749053	23846583018	18.62	0.000
ปริมาณการนำเข้าเหล็ก แผ่นรีดร้อน	1	50498677802	50498677802	39.42	0.000
ยอดขายรถยนต์ทุก ประเภท	1	6925978173	6925978173	5.41	0.025
ปริมาณการจำหน่าย เครื่องใช้ไฟฟ้า	1	18504911356	18504911356	14.45	0.000
Error	44	56362546970	1280966977		
Total	47	1.27902E+11			

จากสมการการพยากรณ์ที่สร้างขึ้นสามารถนำไปพยากรณ์ปริมาณความต้องการเหล็กแผ่นรีดร้อนภายในประเทศ ใน พ.ศ. 2561 จำนวน 12 เดือนได้ดังภาคผนวกตารางที่ ก-4 และรูปที่ 4-16

จากนั้นทำการตรวจสอบความปกติของค่า Residual เพื่อตรวจสอบว่าตัวแบบที่ใช้ในการพยากรณ์เหมาะสมกับข้อมูลหรือไม่ โดยการนำค่า Residual ของตัวแบบมาทำการทดสอบความปกติ (Normality) ดังรูปที่ 4-17 จากลักษณะการกระจายตัวรวมไปถึงค่า P-value ของการทดสอบ Anderson – Darling = 0.271 ซึ่งมากกว่าระดับนัยสำคัญที่ 0.05 สามารถสรุปได้ว่าตัวแบบที่ใช้ทำการพยากรณ์มีความเหมาะสมกับข้อมูล



รูปที่ 4-16 ผลการพยากรณ์ด้วยตัวแบบการพยากรณ์แบบถดถอยพหุคูณโดยใช้ปัจจัยที่ผ่านเงื่อนไข



รูปที่ 4-17 ค่า Residual ของตัวแบบการถดถอยเชิงเส้นพหุคูณโดยใช้ปัจจัยที่ผ่านเงื่อนไข

จากตัวแบบการถดถอยพหุคูณทั้งสองตัวแบบที่มีการใช้ข้อมูลที่แตกต่างกัน มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยดังตารางที่ 4-2 พบกว่ามีความแตกต่างกัน 0.4% แต่ตัวแบบที่ใช้ปัจจัยที่ผ่านเงื่อนไขที่สามารถทราบข้อมูลล่วงหน้าได้เป็นตัวแบบที่สามารถใช้งานได้จริง ผู้วิจัยจึงเลือกใช้ตัวแบบดังกล่าวเป็นตัวแทนของตัวแบบการถดถอยเชิงเส้นพหุคูณ

ตารางที่ 4-2 การเปรียบเทียบค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยของตัวแบบการพยากรณ์การถดถอยเชิงเส้นพหุคูณ

ตัวแบบการพยากรณ์	ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย
การถดถอยเชิงเส้นพหุคูณโดยใช้ปัจจัยทั้งหมด	6.9%
การถดถอยเชิงเส้นพหุคูณโดยใช้ปัจจัยที่ผ่านเงื่อนไข	7.3%

4.3 การพยากรณ์ด้วยตัวแบบการเรียนรู้ของเครื่อง

การพยากรณ์ด้วยตัวแบบการเรียนรู้ของเครื่องจะใช้ปัจจัยที่เกี่ยวข้องชุดเดียวกันกับตัวแบบการถดถอยเชิงเส้นพหุคูณในการพยากรณ์ด้วยตัวแบบเชิงสาเหตุ ที่ใช้ปัจจัยที่ผ่านเงื่อนไขที่สามารถทราบข้อมูลล่วงหน้าได้ เพื่อที่จะสามารถใช้งานได้จริงและสามารถประเมินผลความแม่นยำภายใต้ชุดข้อมูลที่ใช้ในการสร้างตัวแบบที่อยู่ในเงื่อนไขเดียวกัน

4.3.1 ตัวแบบ Artificial Neural Network (ANN)

การสร้างตัวแบบ Artificial Neural Network ผู้วิจัยใช้ชุดคำสั่งจาก Library tensorflow.keras ซึ่งเป็น Library ที่พัฒนา Artificial Neural Network ทั้งในด้านประสิทธิภาพที่สูงขึ้น (Abadi et al., 2016) และสามารถใช้งานได้ง่ายขึ้นกว่าการสร้าง Artificial Neural Network แบบเดิมที่ต้องทำการโปรแกรมการทำงานแต่ละขั้นตอนขึ้นมาเอง ในการสร้างตัวแบบ Artificial Neural Network จาก Library tensorflow.keras กำหนด Seed จำนวน 200 Seed ต่อการปรับค่า hyperparameter เพื่อบันทึกค่าในแต่ละตัวแบบ และดำเนินการโดยใช้วิธีการ Loop for เพื่อให้สามารถเก็บค่าได้ง่ายตามรูปแบบที่ต้องการลงในไฟล์แบบ Text หรือ Microsoft Excel และสามารถ

เรียกใช้โปรแกรมต่อเนื่องหากมีเหตุการณ์ที่ทำให้โปรแกรมหยุดทำงานโดยไม่ต้องเริ่มใหม่ทั้งหมด โดย Hyperparameter ที่ทำการปรับค่ามีดังนี้

Seed คือการบันทึกผลการสร้างตัวแบบพยากรณ์ เนื่องจากในการเรียกใช้ตัวแบบ Artificial Neural Network แต่ละครั้ง ตัวแบบจะมีการเริ่มต้นแบบสุ่ม ทำให้การเรียกใช้ตัวแบบในแต่ละครั้งจะได้ผลลัพธ์ที่แตกต่างกัน Seed จะทำการบันทึกค่าของตัวแบบทุกค่า สำหรับการเรียกใช้ซ้ำโดยตัวแบบไม่ถูกเปลี่ยนแปลงและให้ผลลัพธ์เช่นเดิม ในงานวิจัยนี้กำหนดจำนวนทั้งหมด 200 ค่า โดยเริ่มตั้งแต่ Seed ที่ 1 ถึง Seed ที่ 200

Epoch คือจำนวนรอบการทำซ้ำ หรือเรียกว่าจำนวนครั้งที่ทำการเรียนรู้เพื่อปรับปรุงการคำนวณของตัวแบบ ในงานวิจัยนี้ได้ทำการปรับค่า epoch จำนวน 11 ค่า ได้แก่ 50 100 200 300 400 500 600 700 800 900 และ 1000

Batch size คือจำนวนข้อมูลที่นำเข้าไปทำการเรียนรู้ในแต่ละครั้งในหนึ่งรอบของ Epoch เพื่อปรับปรุงการคำนวณของตัวแบบ เช่น มี Input data จำนวน 48 ข้อมูล หากทำการตั้งค่า Batch size เป็น 12 ข้อมูล ในหนึ่งรอบของ Epoch ตัวแบบจะทำการเรียนรู้ 4 ครั้งโดยเรียนรู้จากข้อมูลนำเข้าทีละ 12 ข้อมูลและทำการปรับปรุงการคำนวณทุกครั้งที่มีการเรียนรู้ ในงานวิจัยนี้ได้ทำการปรับค่า Batch size จำนวน 4 ค่า 12 24 36 และ 48 ตามจำนวนและลักษณะของ Input data


Number of hidden layers คือจำนวนของชั้นซ่อน แต่ละชั้นซ่อนจะทำการคำนวณค่าถ่วงน้ำหนักของแต่ละ Node ภายในชั้นซ่อนนั้นและส่งค่าไปยังชั้นถัดไป ในงานวิจัยนี้ได้ใช้จำนวนของชั้นซ่อน เป็น 1 ชั้นซ่อน และ 2 ชั้นซ่อนเพื่อเปรียบเทียบกัน เนื่องจากเมื่อเปรียบเทียบตามตารางข้อแนะนำการกำหนดจำนวนชั้นซ่อนของ Jeff Heaton ดังตารางที่ 4-3 ได้กล่าวไว้ว่าจำนวนชั้นซ่อน 1 ชั้นสามารถประมาณฟังก์ชันใด ๆ ได้ และจำนวนชั้นซ่อนไม่เกิน 2 ชั้นสามารถแสดงขอบเขตการตัดสินใจและให้ความแม่นยำได้ (Heaton, 2017)

ตารางที่ 4-3 ข้อเสนอแนะการกำหนดจำนวนชั้นซ่อน (Heaton, 2017)

จำนวนชั้นซ่อน	ผลลัพธ์
ไม่มีชั้นซ่อน	สามารถแสดงฟังก์ชันหรือการตัดสินใจที่แยกได้แบบเชิงเส้นเท่านั้น
1 ชั้นซ่อน	สามารถประมาณฟังก์ชันใด ๆ ที่มีความต่อเนื่องแต่จำกัด ฟังก์ชันหนึ่งไปยังอีกฟังก์ชันหนึ่ง
2 ชั้นซ่อน	สามารถแสดงขอบเขตการตัดสินใจที่มีความถูกต้องด้วย Activation function ได้อย่างมีประสิทธิภาพ และสามารถประมาณการได้อย่างราบรื่นและมีความแม่นยำ
มากกว่า 2 ชั้นซ่อน	ชั้นซ่อนเพิ่มเติมสามารถเรียนรู้ที่มีความซับซ้อนได้มากขึ้น


Number of nodes in hidden layers คือจำนวนของจุดที่ทำการคำนวณในแต่ละชั้นซ่อน การตั้งค่า Node ที่ต่ำเกินไปอาจทำให้ตัวแบบมีการเรียนรู้ที่ไม่เพียงพอ (Under fitting) หรือการตั้งค่าที่สูงเกินไปอาจทำให้ตัวแบบมีการเรียนรู้มากเกินไป (Over fitting) ได้เช่นกัน ในงานวิจัยนี้ได้ใช้จำนวนของ Node ในชั้นซ่อนเท่ากับ 10 20 30 40 50 Node สำหรับชั้นซ่อนที่หนึ่งและชั้นซ่อนที่สอง

Activation function เป็น Function สำหรับการแปลงค่าที่คำนวณได้ในแต่ละ Node ก่อนที่จะทำการส่งต่อไปยังชั้นถัดไปซึ่งมีหลายรูปแบบให้เลือกใช้ ตามความเหมาะสมของ Input และ Output ในงานวิจัยนี้เลือกใช้ Activation Function 2 แบบคือ ReLU เนื่องจากความเหมาะสมของ ReLU ต่อการพยากรณ์ข้อมูลแบบปริมาณและสามารถสร้างตัวแบบได้อย่างรวดเร็วโดยมีลักษณะของ Function ดังรูปที่ 4-18 และ Sigmoid ซึ่งเป็น Activation Function ที่นิยมใช้ในการพยากรณ์ที่เกี่ยวข้องกับความน่าจะเป็นเนื่องจาก Function จะคำนวณและแปลงค่าอยู่ระหว่าง 0 ถึง 1 ดังรูปที่ 4-19 โดยในงานวิจัยนี้จะกำหนดให้ Activation Function ของชั้นข้อมูลออก (Output layer) เป็น Activation Function แบบ ReLU เท่านั้นเนื่องจากผลลัพธ์เป็นค่าจำนวนที่มากกว่า 1



รูปที่ 4-18 ลักษณะของ Activation function แบบ ReLU


(<https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>)



รูปที่ 4-19 ลักษณะของ Activation function แบบ Sigmoid


(<https://towardsdatascience.com/activation-functions-neural-networks-1cbd9f8d91d6>)

ผลจากการสร้างตัวแบบ Artificial Neural Network ได้ตัวแบบทั้งหมด 968,000 ตัวแบบ โดย Hyperparameter ที่มีผลต่อการเปลี่ยนแปลงของค่า MAPE อย่างมากประกอบไปด้วย Epoch Batch size และ Activation function สามารถสังเกตได้จากรูปที่ 4-20 และ 4-21 ได้ดังนี้



รูปที่ 4-20 ผลของ Epoch และ Batch size ต่อ MAPE

จากรูปที่ 4-20 สามารถสรุปได้ว่าจำนวนของการทำซ้ำหรือ Epoch ที่มากขึ้นมีผลทำให้ค่า MAPE โดยเฉลี่ยลดลงในช่วง Epoch 50 ถึง 300 และกลับไปเพิ่มขึ้นอย่างต่อเนื่องและจำนวนของ Batch size มีผลอย่างมากในช่วงที่ Epoch น้อยเนื่องจากตัวแบบยังไม่สามารถเรียนรู้เองได้มากพอการกำหนดการเรียนรู้จากจำนวนของข้อมูลนำเข้าจึงมีผลมาก แต่เมื่อจำนวนของ Epoch มีจำนวนมากผลจากความแตกต่างระหว่าง Batch size จึงลดลงอย่างเห็นได้ชัดยกเว้น Batch size 12 อาจเกิดจากการเรียนรู้ที่มากเกินไปในหลาย Seed ส่งผลให้มีการ Overfitting มากจึงทำให้ค่าเฉลี่ย MAPE เพิ่มขึ้นสูง




รูปที่ 4-21 ผลของ Activation function ต่อ MAPE
(Hidden layer1 – Hidden layer2)

จากรูปที่ 4-21 สามารถสรุปได้ว่าตัวแบบทั้งแบบ 1 ชั้นซ่อน และ 2 ชั้นซ่อนที่มีการใช้ Activation function เป็น ReLU เพียงอย่างเดียว ให้ผลลัพธ์ที่ดีกว่าตัวแบบที่ใช้ Activation function แบบ Sigmoid ผสมอยู่

โดยตัวแบบที่ให้ค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Artificial Neural Network คือตัวแบบ Artificial Neural Network ที่มีค่า Seed = 192 Epoch = 1,000 Batch size = 12 Hidden layer = 2 โดยใช้ Activation function ใน Hidden layer เป็น ReLU ใน Hidden layer ที่ 1 และ ReLU ใน Hidden layer ที่ 2 และจำนวน Node = 10 ใน Hidden layer ทั้งสองชั้น มีค่า MAPE

เท่ากับ 5.63% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-5 และรูปที่ 4-22



รูปที่ 4-22 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Artificial Neural Network


จุฬาลงกรณ์มหาวิทยาลัย

4.3.2 ตัวแบบ Support Vector Regression (SVR)

การสร้างตัวแบบ Support Vector Regression ผู้วิจัยใช้ชุดคำสั่งจาก Library sklearn.svm ซึ่งเป็น Library ที่พัฒนาโดยทีม scikit-learn ซึ่ง sklearn.svm เป็นหนึ่งในชุดโปรแกรมที่ถูกพัฒนาขึ้น (Pedregosa et al., 2011) ทั้งในด้านประสิทธิภาพ และสามารถใช้งานได้ง่าย ในการสร้างตัวแบบ Support Vector Regression จาก Library sklearn.svm ผู้วิจัยได้การปรับค่า Hyperparameter และดำเนินการโดยใช้วิธีการ Loop for โดย Hyperparameter ที่ทำการปรับค่ามีดังนี้

C เป็น Regularization parameter ใน Support Vector Regression มีผลในการเรียนรู้ของตัวแบบ ค่า C จะเป็นการแลกเปลี่ยนระหว่างการจำแนกที่ถูกต้องกับขนาดของ Margin กล่าวคือ

การปรับค่า C ที่มากจะทำให้ตัวแบบให้น้ำหนักกับ Hyperplane ที่สามารถจำแนกข้อมูลได้ถูกต้องถึงแม้ว่าจะมี Margin น้อย มากกว่า Hyperplane ที่มี Margin มากแต่มีข้อมูลที่จำแนกผิดพลาดตั้งรูปตัวอย่างรูปที่ 4-23 ทั้งนี้ขึ้นอยู่กับลักษณะของข้อมูลที่นำเข้าไปสร้างตัวแบบ ในงานวิจัยนี้ได้ทำการปรับค่า C โดยใช้ค่า C ตั้งแต่ 0.01 และเพิ่มทีละ 0.01 จนถึง 1 ทั้งหมดเป็นจำนวน 100 ค่า




รูปที่ 4-23 ผลจากการปรับค่า Hyperparameter C


(<https://stats.stackexchange.com/questions/31066/what-is-the-influence-of-c-in-svms-with-linear-kernel>)

จุฬาลงกรณ์มหาวิทยาลัย

Γ เป็น Hyperparameter สำหรับการสร้างตัวแบบ Support Vector Regression ที่ไม่เป็นเชิงเส้น โดย Γ กำหนดว่าการพิจารณาเพื่อสร้าง Hyperplane จะพิจารณาจากข้อมูลที่ใกล้หรือไกลจาก Hyperplane ขนาดไหน ซึ่งหมายความว่า Γ สูงจะพิจารณาเฉพาะจุดที่ใกล้กับ Hyperplane ที่เป็นไปได้ และ Γ ต่ำจะพิจารณาจุดที่ไกลกว่าดังรูปที่ 4-24 Γ ต่ำจะมีผลต่อรูปร่างและความซับซ้อนในการจำแนกข้อมูลของตัวแบบ เมื่อตัวแบบมีค่า Γ ที่ต่ำ Hyperplane จะมีการโค้งน้อยหรือเกือบจะเป็นเส้นตรงหากมีค่าที่ต่ำมาก และเมื่อตัวแบบมีค่า Γ ที่สูง Hyperplane จะมีความโค้งมากและจะจำเพาะกับข้อมูลได้ดี ดังตัวอย่างรูปที่ 4-25 ในงานวิจัยนี้ได้ทำการปรับค่า Γ โดยใช้ค่า Γ ตั้งแต่ 0.1 และเพิ่มทีละ 0.1 จนถึง 5 ทั้งหมดเป็นจำนวน 50 ค่า




รูปที่ 4-24 การพิจารณาข้อมูลเมื่อกำหนดค่า Gamma สูงและต่ำ
 (<https://towardsdatascience.com/svm-and-kernel-svm-fed02bef1200>)



รูปที่ 4-25 ลักษณะของ Hyperplane เมื่อกำหนดค่า Gamma ที่ 0 10 และ 100
 (<https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/>)

Kernel คือชุดของฟังก์ชันทางคณิตศาสตร์ในรูปแบบต่าง ๆ ที่กำหนดเป็น Kernel มีความแตกต่างของการแปลงผลข้อมูล Kernel จะทำงานโดยการรับข้อมูลเป็นอินพุตและแปลงเป็นรูปแบบที่ต้องการดังรูปที่ 4-26



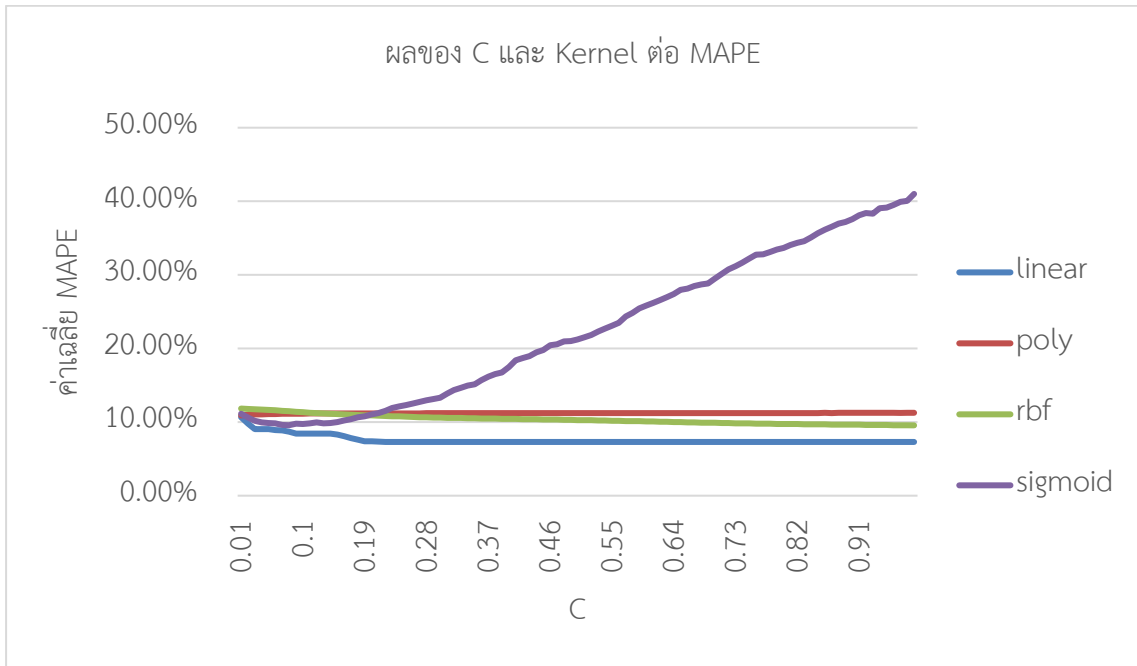
รูปที่ 4-26 ลักษณะการทำงานของ Kernel ที่ต่างกันบนข้อมูลชุดเดียวกัน
(<https://scikit-learn.org/stable/modules/svm.html>)

ในงานวิจัยนี้ได้ทำการปรับค่า Kernel จำนวน 4 แบบ ได้แก่ Linear, Polynomial, Radial Basis Function (RBF) และ Sigmoid


ผลจากการสร้างตัวแบบ Support Vector Regression ได้ตัวแบบทั้งหมด 20,000 ตัวแบบ โดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ Kernel สามารถสังเกตได้จากรูปที่ 4-27 และ 4-28 Hyperparameter C ส่งผลให้ตัวแบบที่ใช้ Kernel แบบ Linear และ RBF มีค่า MAPE ลดลงโดย Linear จะคงที่เมื่อ C มีค่าตั้งแต่ 0.22 ขึ้นไป แต่ C ส่งผลต่อ Kernel แบบ Poly และ Sigmoid มีค่า MAPE เพิ่มขึ้น โดยเฉพาะ Sigmoid มีค่า MAPE เพิ่มขึ้นอย่างมากเมื่อ C เพิ่มขึ้น สำหรับ Hyperparameter Gamma ส่งผลต่อตัวแบบที่ใช้ Kernel แบบ Poly RBF และ Sigmoid แต่ไม่ส่งผลต่อตัวแบบที่ใช้ Kernel แบบ Linear โดยส่งผลให้ตัวแบบที่ใช้ Kernel ทั้งสามมีค่า MAPE ลดลงในช่วง 0.2 และ 0.3 จากนั้นเพิ่มขึ้นอย่างรวดเร็วในตัวแบบที่ใช้ Kernel แบบ Sigmoid ส่วนตัวแบบที่ใช้ Kernel แบบ Poly และ RBF จะมีค่า MAPE เพิ่มขึ้นอย่างช้า ๆ จนใกล้จะคงที่

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Support Vector Regression คือตัวแบบ Support Vector Regression ที่ใช้ Kernel แบบ Linear ที่มีค่า C ตั้งแต่ 0.22 จนถึง 1.00 และใน

ทุกค่า Gamma มีค่า MAPE เท่ากับ 7.30% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังตารางที่ 4-9 และรูปที่ 4-29




รูปที่ 4-27 ผลของ C และ Kernel ต่อ MAPE



รูปที่ 4-28 ผลของ Gamma และ Kernel ต่อ MAPE

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Support Vector Regression คือตัวแบบ Support Vector Regression ที่ใช้ Kernel แบบ Linear ที่มีค่า C ตั้งแต่ 0.22 จนถึง 1.00 และในทุกค่า Gamma มีค่า MAPE เท่ากับ 7.30% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-6 และรูปที่ 4-29



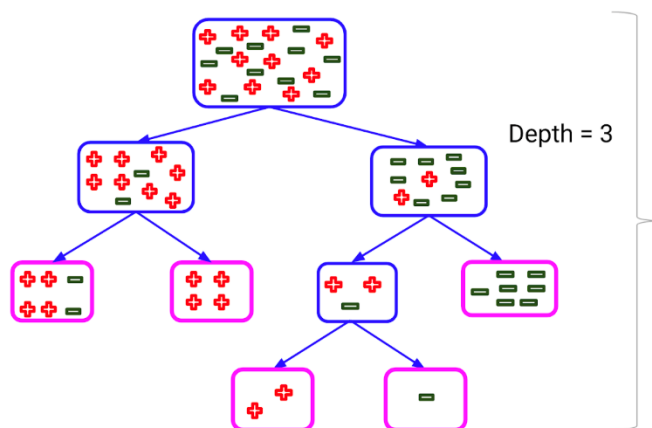
รูปที่ 4-29 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Support Vector Regression

4.3.3 ตัวแบบ Random Forest (RF)

การสร้างตัวแบบ Random Forest ผู้วิจัยใช้ชุดคำสั่งจาก Library sklearn.ensemble ซึ่ง เป็น Library ที่พัฒนาโดยทีม scikit-learn ในการสร้างตัวแบบ Random Forest จาก Library sklearn.ensemble ผู้วิจัยได้การปรับค่า Hyperparameter และดำเนินการโดยใช้วิธีการ Loop for โดย Hyperparameter ที่ทำการปรับค่ามีดังนี้

max_depth เป็นตัวกำหนดค่าความลึกของชั้น Leaf ที่ทำการตัดสินใจในแต่ละ Decision tree ดังรูปที่ 4-30 หากไม่กำหนด ตัวแบบจะทำการสร้างความลึกจนกว่าในแต่ละ Leaf จะมีตัวอย่าง

ข้อมูลนำเข้าที่น้อยกว่า `min_samples_split` ในงานวิจัยนี้ได้ทำการปรับค่า `max_depth` โดยใช้ค่า `max_depth` เท่ากับ 10 20 30 40 50 60 70 80 90 100 และ None



รูปที่ 4-30 ตัวอย่างการกำหนด `max_depth = 3`

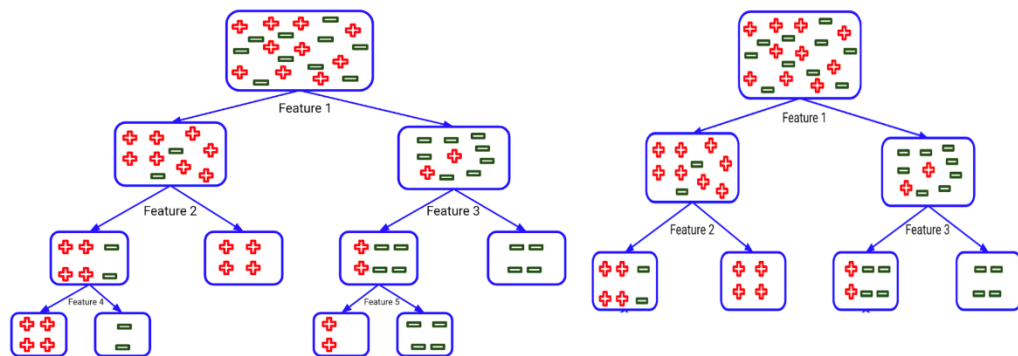
(<https://www.analyticsvidhya.com/blog/2020/03/beginners-guide-random-forest-hyperparameter-tuning/>)

`n_estimators` เป็นตัวกำหนดจำนวนของ Decision tree ภายในตัวแบบว่าจะใช้ Decision tree จำนวนเท่าไร ในงานวิจัยนี้ได้ทำการปรับค่า `n_estimators` โดยใช้ค่า `n_estimators` เท่ากับ 100 200 300 400 500 600 700 800 900 และ 1000

`max_features` เป็นตัวกำหนดจำนวนสูงสุดของปัจจัยที่จะนำไปทำการตัดสินใจในแต่ละ Decision tree เนื่องจากมีจำนวนของปัจจัยที่น้อยในงานวิจัยนี้ได้ทำการปรับค่า `max_features` โดยกำหนดให้ `max_features` ทำการตั้งค่าแบบ auto

`min_samples_leaf` เป็นตัวกำหนดจำนวนขั้นต่ำของปัจจัยที่ใช้พิจารณาในแต่ละ Leaf สำหรับปลายสุดของการแบ่ง Leaf หากมีการแบ่งแล้วมีปัจจัยต่ำกว่า `min_samples_leaf` จะถูกตัดออกจากการตัดสินใจ ในงานวิจัยนี้ได้ทำการปรับค่า `min_samples_leaf` โดยใช้ค่า `min_samples_leaf` เท่ากับ 1 2 3 4 5 6 7 8 9 และ 10

`min_samples_split` เป็นตัวกำหนดจำนวนขั้นต่ำของตัวอย่างที่ใช้ในการแบ่ง Node หาก Node นั้นมีจำนวนน้อยกว่า `min_samples_split` แล้วจะไม่ถูกแบ่งออกอีก ดังรูปที่ 4-31 ในงานวิจัยนี้ได้ทำการปรับค่า `min_samples_split` โดยใช้ค่า `min_samples_split` เท่ากับ 2 4 6 8 และ 10




รูปที่ 4-31 ตัวอย่างการกำหนด `min_samples_leaf = 2` (ซ้าย) และ 6 (ขวา)

(<https://www.analyticsvidhya.com/blog/2020/03/beginners-guide-random-forest-hyperparameter-tuning/>)

`random_state` เป็นตัวควบคุมการสุ่มตัวอย่างที่จะใช้ในแต่ละ Decision tree ในงานวิจัยนี้ได้ทำการปรับค่า `random_state` โดยใช้ค่า `random_state` เท่ากับ 10 20 30 40 50 60 70 80 90 และ 100


ผลจากการสร้างตัวแบบ Random Forest ได้ตัวแบบทั้งหมด 55,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ `min_samples_leaf` และ `n_estimators` สามารถสังเกตได้จากรูปที่ 4-32 ได้ดังนี้



รูปที่ 4-32 ผลของ min_samples_leaf และ n_estimators ต่อ MAPE

จากรูปที่ 4-32 Hyperparameter min_samples_leaf ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators โดยใน min_samples_leaf = 2 มีค่าเฉลี่ย MAPE ที่ต่ำที่สุดจากทุกตัวแบบ

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Random Forest คือตัวแบบ Random Forest ที่กำหนดค่า max_depth = 10, n_estimators = 100, max_features = auto, min_samples_leaf = 2, min_samples_split = 8 และ random_state = 60 มีค่า MAPE เท่ากับ 6.21% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-7 และรูปที่ 4-33



รูปที่ 4-33 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Random Forest

4.3.4 ตัวแบบ eXtreme Gradient Boosting (XGboost)

การสร้างตัวแบบ eXtreme Gradient Boosting ผู้วิจัยใช้ชุดคำสั่งจาก Library xgboost ซึ่งเป็น Library ที่พัฒนาขึ้นมาเพื่อใช้ในการสร้างตัวแบบโดยเฉพาะ ในการสร้างตัวแบบ eXtreme Gradient Boosting จาก Library xgboost ผู้วิจัยได้ทำการปรับค่า Hyperparameter และดำเนินการโดยใช้วิธีการ Loop for โดย Hyperparameter ที่ทำการปรับค่ามีดังนี้

learning_rate หรือ eta เป็นตัวกำหนดอัตราการเรียนรู้ของตัวแบบและป้องกันการ Overfitting จากการเรียนรู้ในแต่ละขั้นตอนด้วยการปรับค่าน้ำหนักของข้อมูลที่เรียนรู้มา ในงานวิจัยนี้ได้ทำการปรับค่า learning_rate โดยใช้ค่า learning_rate เท่ากับ 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9 และ 1.0

max_depth เป็นตัวกำหนดค่าความลึกของชั้น Leaf ที่ทำการตัดสินใจในแต่ละ Decision tree ในงานวิจัยนี้ได้ทำการปรับค่า max_depth โดยใช้ค่า max_depth เท่ากับ 1 2 3 4 5 6 7 8 9 และ 10


`min_child_weight` เป็นตัวกำหนดผลรวมน้ำหนักขั้นต่ำของการแบ่ง Node เมื่อผลรวมของน้ำหนักต่ำกว่าค่าที่กำหนด Node จะถูกยกเลิกและหยุดการแบ่ง คล้ายกับ `min_samples_leaf` ในตัวแบบ Random Forest แต่ใช้ผลรวมของน้ำหนักที่ตัวแบบให้กับ Node เป็นตัวกำหนดแทน ในงานวิจัยนี้ได้ทำการปรับค่า `min_child_weight` โดยใช้ค่า `min_child_weight` เท่ากับ 1 2 3 4 5 6 7 8 9 และ 10

`gamma` หรือ `min_split_loss` เป็นตัวกำหนดการลด Loss function ขั้นต่ำที่จะทำการแบ่ง Node ของ Decision tree หากการแบ่งนั้นมีการลด Loss ต่ำกว่าที่กำหนดตัวแบบจะหยุดการแบ่ง Node ในงานวิจัยนี้ได้ทำการปรับค่า `gamma` โดยใช้ค่า `gamma` เท่ากับ 0.0 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9 และ 1.0

`colsample_bytree` คืออัตราส่วนตัวอย่างย่อยของคอลัมน์เมื่อสร้าง Decision tree การสุ่มตัวอย่างจะทำเพียงครั้งเดียวสำหรับทุก Decision tree จากนั้นตัวแบบจะดำเนินการตามคำสั่งต่อไป ในงานวิจัยนี้ได้ทำการปรับค่า `colsample_bytree` โดยใช้ค่า `colsample_bytree` เท่ากับ 0.0 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9 และ 1.0

`n_estimators` เป็นตัวกำหนดจำนวนของ Decision tree ภายในตัวแบบว่าจะใช้ Decision tree จำนวนเท่าไร ในงานวิจัยนี้ได้ทำการปรับค่า `n_estimators` โดยใช้ค่า `n_estimators` เท่ากับ 100 200 300 400 500 600 700 800 900 และ 1000


ผลจากการสร้างตัวแบบ eXtreme Gradient Boosting ได้ตัวแบบทั้งหมด 1,210,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ `learning_rate` สามารถสังเกตได้จากรูปที่ 4-34 ได้ดังนี้



รูปที่ 4-34 ผลของ learning_rate และ n_estimators ต่อ MAPE

จากรูปที่ 4-34 Hyperparameter learning_rate ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators โดยค่าเฉลี่ยของ MAPE มีแนวโน้มลดลงจาก learning_rate 0.1 จนถึง 0.6 หลังจากนั้นจะเพิ่มขึ้นอย่างรวดเร็ว สามารถสรุปได้ว่าในช่วง learning_rate 0.1 ถึง 1.0 ค่าที่เหมาะสมจะอยู่ประมาณ 0.1 ถึง 0.6

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ eXtreme Gradient Boosting คือตัวแบบ eXtreme Gradient Boosting ที่กำหนดค่า learning_rate = 0.1, n_estimators = 200, max_depth = 5, min_child_weight = 9, gamma = 0.0 และ colsample_bytree = 0.1 มีค่า MAPE เท่ากับ 5.72% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-8 และรูปที่ 4-35



รูปที่ 4-35 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ eXtreme Gradient Boosting

4.3.5 ตัวแบบ Light Gradient Boosting Machine (LGBM)

การสร้างตัวแบบ Light Gradient Boosting Machine ผู้วิจัยใช้ชุดคำสั่งจาก Library lightgbm ซึ่งเป็น Library ที่พัฒนาขึ้นมาเพื่อใช้ในการสร้างตัวแบบโดยเฉพาะ ในการสร้างตัวแบบ Light Gradient Boosting Machine จาก Library lightgbm ผู้วิจัยได้ทำการปรับค่า Hyperparameter และดำเนินการโดยใช้วิธีการ Loop for โดย Hyperparameter ที่ทำการปรับค่ามีดังนี้

boosting_type เป็นประเภทของการ Boosting ของตัวแบบ Light Gradient Boosting Machine ประกอบไปด้วย gbd, dart, goss และ rf ซึ่งแต่ละประเภทมีการทำงานที่แตกต่างกัน โดยปรกติจะถูกตั้งค่าเป็น gbd ในงานวิจัยนี้ได้ทำการปรับค่า boosting_type โดยใช้ค่า boosting_type เป็น gbd และ dart

learning_rate หรือ eta เป็นตัวกำหนดอัตราการเรียนรู้ของตัวแบบและป้องกันการ Overfitting จากการเรียนรู้ในแต่ละขั้นตอนด้วยการปรับค่าน้ำหนักของข้อมูลที่เรียนรู้ออกมา ในงานวิจัย

นี้ได้ทำการปรับค่า `learning_rate` โดยใช้ค่า `learning_rate` เท่ากับ 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9 และ 1.0

`max_depth` เป็นตัวกำหนดค่าความลึกของชั้น Leaf ที่ทำการตัดสินใจในแต่ละ Decision tree ในงานวิจัยนี้ได้ทำการปรับค่า `max_depth` โดยใช้ค่า `max_depth` เท่ากับ -1 0 1 2 3 4 5 6 7 8 9 และ 10


`num_leaves` เนื่องจาก LightGBM ใช้อัลกอริธึมแบบ leaf-wise จึงใช้ `num_leaves` แทน `max_depth` เมื่อปรับความซับซ้อนของ Decision tree ในงานวิจัยนี้ได้ทำการปรับค่า `num_leaves` โดยใช้ค่า `num_leaves` เท่ากับ 10 20 30 40 50 60 70 80 90 และ 100

`colsample_bytree` คืออัตราส่วนตัวอย่างย่อยของคอลัมน์เมื่อสร้าง Decision tree การสุ่มตัวอย่างจะทำเพียงครั้งเดียวสำหรับทุก Decision tree จากนั้นตัวแบบจะดำเนินการตามคำสั่งต่อไป ในงานวิจัยนี้ได้ทำการปรับค่า `colsample_bytree` โดยใช้ค่า `colsample_bytree` เท่ากับ 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9 และ 1.0

`subsample` หรือ `bagging_fraction` เป็นตัวกำหนดเปอร์เซ็นต์ของแถวของข้อมูลที่ใช้ต่อกระบวนการสร้าง Decision tree หมายความว่า จะมีการสุ่มแถวบางแถวของข้อมูลเพื่อให้เหมาะสมกับ Decision tree ในงานวิจัยนี้ได้ทำการปรับค่า `subsample` โดยใช้ค่า `subsample` เท่ากับ 0.1 0.2 0.3 0.4 0.5 0.6 0.7 0.8 0.9 และ 1.0

`n_estimators` เป็นตัวกำหนดจำนวนของ Decision tree ภายในตัวแบบว่าจะใช้ Decision tree จำนวนเท่าไร ในงานวิจัยนี้ได้ทำการปรับค่า `n_estimators` โดยใช้ค่า `n_estimators` เท่ากับ 100 200 300 400 500 600 700 800 900 และ 1000


ผลจากการสร้างตัวแบบ Light Gradient Boosting Machine ได้ตัวแบบทั้งหมด 2,400,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ `learning_rate` และ `n_estimators` สามารถสังเกตได้จากรูปที่ 4-36 ได้ดังนี้



รูปที่ 4-36 ผลของ learning_rate และ n_estimators ต่อ MAPE

จากรูปที่ 4-36 Hyperparameter learning_rate ส่งผลที่แตกต่างกันในแต่ละช่วงของ n_estimators โดยในช่วง 100 ถึง 300 มีค่า MAPE ลดลงอย่างรวดเร็วและกลับมาเพิ่มขึ้นเล็กน้อยเมื่อ learning_rate มีค่ามากกว่า 0.2 0.3 และ 0.4 สำหรับ n_estimators = 100 200 และ 300 ตามลำดับ และในช่วง 400 ถึง 1,000 มีค่า MAPE เพิ่มขึ้นในช่วงอย่างรวดเร็วในช่วงแรกและเพิ่มขึ้นเล็กน้อย

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Light Gradient Boosting Machine คือตัวแบบ Light Gradient Boosting Machine ที่กำหนดค่า boosting_type = gbdt, learning_rate = 0.4, max_depth = 1, num_leaves = 10, colsample_bytree = 0.7, subsample = 0.1, n_estimators = 100 มีค่า MAPE เท่ากับ 7.33% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีการพยากรณ์ดังภาคผนวกตารางที่ ก-9 และรูปที่ 4-37



รูปที่ 4-37 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Light Gradient Boosting Machine

4.4 การพยากรณ์ด้วยตัวแบบผสม

จากการทำการพยากรณ์และเปรียบเทียบผลความแม่นยำแล้วผู้วิจัยได้เลือกตัวแบบเดี่ยวที่แม่นยำที่สุดสามตัวแบบเพื่อทำการผสมตัวแบบ ดังตารางที่ 4-4

ตารางที่ 4-4 การเปรียบเทียบความแม่นยำสำหรับตัวแบบเดี่ยว

ตัวแบบการพยากรณ์	Validation MAPE
Artificial Neural Network	5.63%
eXtreme Gradient Boosting	5.72%
Random Forest	6.21%
Support Vector Regression	7.30%
Multiple Linear Regression	7.32%
Light Gradient Boosting Machine	7.33%
Holt's Exponential Smoothing	8.87%
ARIMA (2,1,0)	9.82%

จากตารางที่ 4-4 ตัวแบบที่ผู้วิจัยเลือกที่เลือกได้แก่ Artificial Neural Network, eXtreme Gradient Boosting และ Random Forest ซึ่งจะนำผลการพยากรณ์ของทั้งสามตัวแบบมาทำการผสมการพยากรณ์โดยใช้กระบวนการของ Artificial Neural Network โดยการทำงานของ Artificial Neural Network เป็นการคำนวณการให้น้ำหนักกับแต่ละปัจจัยในแต่ละ Node ผ่าน Activation Function ดังรูปที่ 2-15 สามารถเรียนรู้และปรับปรุงการคำนวณจากการวัดผลความคลาดเคลื่อนในตัวแบบเพื่อให้ได้ผลลัพธ์ที่ดีที่สุดจึงเหมาะต่อการผสมตัวแบบ ซึ่งการผสมผลการพยากรณ์ด้วยวิธีการนี้ สามารถให้ผลการพยากรณ์ที่ดีขึ้นจากการพยากรณ์ในตัวแบบเดี่ยว (Omar, Hoang, & Liu, 2016) นอกจากนี้ผู้วิจัยได้เพิ่มการทดลองผสมการพยากรณ์โดยใช้กระบวนการของ eXtreme Gradient Boosting และ Random Forest ในการผสมตัวแบบเนื่องจากเป็นกระบวนการของตัวแบบที่ได้ค่าความแม่นยำที่สุดสามอันดับในการพยากรณ์ตัวแบบเดี่ยว ซึ่งถือมีความเหมาะสมต่อข้อมูลชุดนี้เช่นเดียวกับ Artificial Neural Network เพื่อเปรียบเทียบผลลัพธ์จากการผสมตัวแบบ


ขั้นตอนการผสมตัวแบบโดยใช้ Artificial Neural Network หรือ eXtreme Gradient Boosting หรือ Random Forest เป็นตัวผสมมีขั้นตอนการดำเนินการดังต่อไปนี้

1. จัดเตรียมข้อมูลนำเข้าซึ่งเป็นข้อมูลปัจจัยที่เลือกไว้ได้แก่ ปริมาณการนำเข้าเหล็กแผ่นรีดร้อน ยอดขายรถยนต์ทุกประเภท และปริมาณการจำหน่ายเครื่องใช้ไฟฟ้า ประกอบกับผลเฉลยของชุดข้อมูลคือปริมาณความต้องการเหล็กแผ่นรีดร้อนที่เกิดขึ้นจริง ทั้งหมด 72 เดือน โดยทำการแบ่งข้อมูลออกเป็น 3 ส่วน ประกอบไปด้วยชุดข้อมูลสำหรับสอนตัวแบบ 48 เดือน ชุดข้อมูลสำหรับตรวจสอบตัวแบบ 12 เดือน และชุดข้อมูลสำหรับทดสอบตัวแบบ 12 เดือน จากนั้นทำการ Normalize ข้อมูลด้วยชุดคำสั่ง StandardScaler
2. สร้างตัวแบบการเรียนรู้ของเครื่องด้วยข้อมูลสำหรับสอนตัวแบบ และปรับค่า Hyperparameter ตามที่กำหนดไว้ในหัวข้อที่ 4.3.1 สำหรับ Artificial Neural Network หัวข้อที่ 4.3.3 สำหรับ eXtreme Gradient Boosting และหัวข้อที่ 4.3.5 สำหรับ Random Forest

3. วัดผลการเรียนรู้ของแต่ละชุด Hyperparameter โดยการทำการพยากรณ์ด้วยชุดข้อมูล ตรวจสอบตัวแบบ และคำนวณค่า MAPE เพื่อเปรียบเทียบและค้นหาชุด Hyperparameter ที่ดีที่สุดของแต่ละตัวแบบเดี่ยวที่เลือกไว้
4. พยากรณ์ตัวแบบเดี่ยวด้วย Hyperparameter ที่ดีที่สุดของแต่ละตัวแบบเพื่อนำผลการพยากรณ์ไปใช้เป็นข้อมูลนำเข้าของตัวแบบผสมในขั้นตอนต่อไป
5. จัดเตรียมข้อมูลนำเข้าซึ่งเป็นข้อมูลผลการพยากรณ์ของตัวแบบเดี่ยวที่เลือกไว้นำมา ประกอบกับผลเฉลยของชุดข้อมูลคือปริมาณความต้องการเหล็กแผ่นรีดร้อนที่เกิดขึ้นจริง ทั้งหมด 72 เดือน โดยทำการแบ่งข้อมูลออกเป็น 3 ส่วน ประกอบไปด้วยชุดข้อมูล สำหรับสอนตัวแบบ 48 เดือน ชุดข้อมูลสำหรับตรวจสอบตัวแบบ 12 เดือน และชุด ข้อมูลสำหรับทดสอบตัวแบบ 12 เดือน จากนั้นทำการ Normalize ข้อมูลด้วยชุดคำสั่ง StandardScaler
6. สร้างตัวแบบการเรียนรู้ของเครื่องสำหรับผสมตัวแบบตามตัวแบบที่เลือกไว้ข้างต้น ด้วย ข้อมูลสำหรับสอนตัวแบบ และปรับค่า Hyperparameter ตามที่กำหนดไว้ในหัวข้อที่ 4.3.1 สำหรับ Artificial Neural Network หัวข้อที่ 4.3.3 สำหรับ eXtreme Gradient Boosting และหัวข้อที่ 4.3.5 สำหรับ Random Forest
7. วัดผลการเรียนรู้ของแต่ละชุด Hyperparameter โดยการทำการพยากรณ์ด้วยชุดข้อมูล ตรวจสอบตัวแบบ และคำนวณค่า MAPE เพื่อเปรียบเทียบและค้นหาชุด Hyperparameter ที่ดีที่สุด
8. ทำการพยากรณ์ตัวแบบผสมด้วย Hyperparameter ที่ดีที่สุดของแต่ละตัวแบบผสมเพื่อนำมาเปรียบเทียบความแม่นยำโดยใช้ MAPE ในการเปรียบเทียบ


เพื่อให้ง่ายต่อการทำความเข้าใจ ผู้วิจัยได้จัดทำ Flow Chart สำหรับแต่ละตัวแบบผสมไว้ในแต่ละหัวข้อของตัวแบบผสมดังต่อไปนี้

4.4.1 ตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม




รูปที่ 4-38 วิธีการผสมตัวแบบ Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

ผลจากการสร้างตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม ได้ตัวแบบทั้งหมด 968,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อการเปลี่ยนแปลงของค่า MAPE อย่างมากประกอบไปด้วย Epoch Batch size และ Activation function สามารถสังเกตได้จากรูปที่ 4-39 และ 4-40 ได้ดังนี้



รูปที่ 4-39 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-39 สามารถสรุปได้ว่าจำนวนของ Epoch ที่มากขึ้นมีผลทำให้ค่า MAPE โดยเฉลี่ยลดลงอย่างรวดเร็วในช่วง Epoch 50 ถึง 300 และกลับไปเพิ่มขึ้นเล็กน้อยตลอดช่วง Epoch 400 ถึง 1000 จำนวนของ Batch size มีผลอย่างมากในช่วงที่ Epoch น้อยเนื่องจากตัวแบบยังไม่สามารถเรียนรู้เองได้มากพอการกำหนดการเรียนรู้จากจำนวนของข้อมูลนำเข้าจึงมีผลมาก แต่เมื่อจำนวนของ Epoch มีจำนวนมากผลจากความแตกต่างระหว่าง Batch size จึงลดลง



รูปที่ 4-40 ผลของ Activation function ต่อค่าเฉลี่ย MAPE
(Hidden layer1 – Hidden layer2)


จากรูปที่ 4-40 สามารถสรุปได้ว่าตัวแบบที่มีการใช้ Activation function ผสมกันระหว่าง ReLU และ ReLU หรือ ReLU และ Sigmoid ให้ผลลัพธ์โดยเฉลี่ยดีกว่าตัวแบบที่มีชั้นซ่อนเดียว และตัวแบบที่ใช้ Activation function Sigmoid และ Sigmoid

โดยตัวแบบที่ให้ค่า MAPE น้อยที่สุดในกลุ่มผสมตัวแบบ Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า Seed = 191 Epoch = 50 Batch size = 12 Hidden layer = 2 โดยใช้ Activation function ใน Hidden layer เป็น ReLU ใน Hidden layer ที่ 1 และ ReLU ใน Hidden layer ที่ 2 และจำนวน Node = 10 ใน Hidden layer ทั้งสองชั้น มีค่า MAPE เท่ากับ 4.21% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-10 และรูปที่ 4-41




รูปที่ 4-41 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

4.4.2 ตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม




รูปที่ 4-42 วิธีการผสมตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

ผลจากการสร้างตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสมได้ตัวแบบทั้งหมด 968,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อการเปลี่ยนแปลงของค่า MAPE อย่างมากประกอบไปด้วย Epoch Batch size และ Activation function สามารถสังเกตได้จากรูปที่ 4-43 และ 4-44 ได้ดังนี้



รูปที่ 4-43 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-43 สามารถสรุปได้ว่าจำนวนของ Epoch ที่มากขึ้นมีผลทำให้ค่า MAPE โดยเฉลี่ยลดลงอย่างรวดเร็วในช่วง Epoch 50 ถึง 300 และกลับไปเพิ่มขึ้นเล็กน้อยถึงคงที่ในช่วง Epoch 400 ถึง 1000 จำนวนของ Batch size มีผลอย่างมากในช่วงที่ Epoch น้อย Batch size ที่มากจะมี MAPE ที่มากกว่า Batch size น้อยในเมื่อเปรียบเทียบที่ Epoch ที่เท่ากัน เนื่องจาก Batch size ที่น้อยกว่าจะทำการเรียนรู้ข้อมูลที่ละชุดซึ่งมีชุดย่อยที่มากกว่า MAPE มีค่าน้อยกว่า แต่เมื่อจำนวนของ Epoch มีจำนวนมากผลจากความแตกต่างระหว่าง Batch size จึงลดลง



รูปที่ 4-44 ผลของ Activation function ต่อค่าเฉลี่ย MAPE
(Hidden layer1 – Hidden layer2)


จากรูปที่ 4-44 สามารถสรุปได้ว่าตัวแบบที่มีการใช้ Activation function ผสมกันระหว่าง ReLU และ ReLU หรือ ReLU และ Sigmoid ให้ผลลัพธ์โดยเฉลี่ยดีกว่าตัวแบบที่มีชั้นซ่อนเดียว และตัวแบบที่ใช้ Activation function Sigmoid และ Sigmoid

โดยตัวแบบที่ให้ค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า Seed = 169 Epoch = 1000 Batch size = 12 Hidden layer = 1 โดยใช้ Activation function ใน Hidden layer เป็น ReLU ใน Hidden layer ที่ 1 และจำนวน Node = 10 ใน Hidden layer มีค่า MAPE เท่ากับ 4.04% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-11 และรูปที่ 4-45




รูปที่ 4-45 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

4.4.3 ตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม




รูปที่ 4-46 วิธีการผสมตัวแบบ Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

ผลจากการสร้างตัวแบบผสมด้วย Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม ได้ตัวแบบทั้งหมด 968,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อการเปลี่ยนแปลงของค่า MAPE อย่างมากประกอบไปด้วย Epoch Batch size และ Activation function สามารถสังเกตได้จากรูปที่ 4-47 และ 4-48 ได้ดังนี้



รูปที่ 4-47 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-47 สามารถสรุปได้ว่าจำนวนของ Epoch ที่มากขึ้นมีผลทำให้ค่า MAPE โดยเฉลี่ยลดลงอย่างรวดเร็วในช่วง Epoch 50 ถึง 300 และกลับไปเพิ่มขึ้นเล็กน้อยในช่วง Epoch 400 ถึง 1000 จำนวนของ Batch size จะมีผลอย่างมากในช่วงที่ Epoch น้อยเมื่อเปรียบเทียบที่ Epoch ที่เท่ากัน เนื่องจาก Batch size ที่น้อยกว่าจะทำการเรียนรู้ข้อมูลที่ละชุดซึ่งมีชุดย่อยที่มากกว่าทำให้ MAPE มีค่าน้อยกว่า แต่เมื่อจำนวนของ Epoch มีจำนวนมากผลจากความแตกต่างระหว่าง Batch size จึงลดลง



รูปที่ 4-48 ผลของ Activation function ต่อค่าเฉลี่ย MAPE
(Hidden layer1 – Hidden layer2)


จากรูปที่ 4-48 สามารถสรุปได้ว่าตัวแบบที่มีการใช้ Activation function Sigmoid ในชั้นซ่อนใดชั้นซ่อนหนึ่ง ให้ผลลัพธ์โดยเฉลี่ยดีกว่าตัวแบบที่ไม่ได้ใช้ Activation function Sigmoid

โดยตัวแบบที่ให้ค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม คือคือตัวแบบผสมที่กำหนดค่า Seed = 39 Epoch = 300 Batch size = 12 Hidden layer = 1 โดยใช้ Activation function ใน Hidden layer เป็น ReLU ใน Hidden layer ที่ 1 และจำนวน Node = 10 ใน Hidden layer มีค่า MAPE เท่ากับ 5.13% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-12 และรูปที่ 4-49 ซึ่งเมื่อสังเกตจากรูปที่ 4-48 ผลของ Activation function ต่อค่าเฉลี่ย MAPE จะแตกต่างกับตัวแบบที่มีค่า MAPE น้อยที่สุด เนื่องจากเป็นค่าเฉลี่ยจากชุด Hyperparameter ทั้งหมดที่มีการใช้ Activation function นั้น ๆ ซึ่งค่า MAPE ของกลุ่ม Activation function แบบ Sigmoid ตัวแบบส่วนใหญ่มีค่าใกล้เคียงกันในช่วง MAPE ที่ต่ำกว่าแบบ ReLU ซึ่งมีการกระจายตัวในช่วง MAPE ที่สูงกว่าและมีเพียงบางตัวแบบที่มีค่า MAPE ต่ำกว่าแบบ Sigmoid ดังตัวแบบนี้




รูปที่ 4-49 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

4.4.4 ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม




รูปที่ 4-50 วิธีการผสมตัวแบบ Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

ผลจากการสร้างตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสมได้ตัวแบบทั้งหมด 968,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อการเปลี่ยนแปลงของค่า MAPE อย่างมากประกอบไปด้วย Epoch Batch size และ Activation function สามารถสังเกตได้จากรูปที่ 4-51 และ 4-52 ได้ดังนี้



รูปที่ 4-51 ผลของ Epoch และ Batch size ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-51 สามารถสรุปได้ว่าจำนวนของ Epoch ที่มากขึ้นมีผลทำให้ค่า MAPE โดยเฉลี่ยลดลงอย่างรวดเร็วในช่วง Epoch 50 ถึง 500 และค่อนข้างคงที่ในช่วง Epoch 600 ถึง 1000 จำนวนของ Batch size จะมีผลอย่างมากในช่วงที่ Epoch น้อยเมื่อเปรียบเทียบที่ Epoch ที่เท่ากัน เนื่องจาก Batch size ที่น้อยกว่าจะทำการเรียนรู้ข้อมูลที่ละชุดซึ่งมีชุดย่อยที่มากกว่าทำให้ MAPE มีค่าน้อยกว่า แต่เมื่อจำนวนของ Epoch มีจำนวนมากผลจากความแตกต่างระหว่าง Batch size จึงลดลง



รูปที่ 4-52 ผลของ Activation function ต่อค่าเฉลี่ย MAPE
(Hidden layer1 – Hidden layer2)


จากรูปที่ 4-52 สามารถสรุปได้ว่าตัวแบบที่มีการใช้ Activation function ReLU กับ ReLU และ ReLU ผสมกับ Sigmoid ให้ผลลัพธ์โดยเฉลี่ยดีกว่าตัวแบบที่มีการใช้ Activation function เดี่ยวหรือมีชั้นซ่อนเดียว และตัวแบบที่ใช้ Activation function Sigmoid กับ Sigmoid ที่เกิดความคลาดเคลื่อนสูงกว่าตัวแบบอื่น

โดยตัวแบบที่ให้ค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม คือคือตัวแบบผสมที่กำหนดค่า Seed = 57 Epoch = 900 Batch size = 12 Hidden layer = 1 โดยใช้ Activation function ใน Hidden layer เป็น ReLU ใน Hidden layer ที่ 1 และจำนวน Node = 10 ใน Hidden layer มีค่า MAPE เท่ากับ 3.59% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังตารางที่ ก-13 และรูปที่ 4-53




รูปที่ 4-53 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

4.4.5 ตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม




รูปที่ 4-54 วิธีการผสมตัวแบบ Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

ผลจากการสร้างตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสมได้ตัวแบบทั้งหมด 55,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ min_samples_leaf, n_estimators และ min_samples_split สามารถสังเกตได้จากรูปที่ 4-55 4-56 และ 4-57 ได้ดังนี้




รูปที่ 4-55 ผลของ min_samples_leaf และ n_estimators ต่อค่าเฉลี่ย MAPE

จากรูปที่ 4-55 Hyperparameter min_samples_leaf ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators ตัวแบบจะมีค่าเฉลี่ย MAPE เพิ่มขึ้นเมื่อค่า min_samples_leaf เพิ่มขึ้นโดยเพิ่มขึ้นอย่างช้า ๆ ในช่วง min_samples_leaf = 1 ถึง 5 และเพิ่มขึ้นอย่างรวดเร็วในช่วง min_samples_leaf = 6 ถึง 10 สรุปได้ว่า min_samples_leaf ที่มีค่าน้อยจะทำให้ตัวแบบมีค่าเฉลี่ย MAPE ที่น้อยกว่าตัวแบบที่มีค่า min_samples_leaf มาก



รูปที่ 4-56 ผลของ $n_estimators$ ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-56 Hyperparameter $n_estimators$ ส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE เพิ่มขึ้น เมื่อค่า $n_estimators$ เพิ่มขึ้น ยกเว้นที่ $n_estimators = 200$ ที่ส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE ลดลง และที่ $n_estimators = 300$ ตัวแบบจะมีค่าเฉลี่ย MAPE จะเพิ่มขึ้นสูงกว่าปกติ สรุปได้ว่า $n_estimators$ ที่มีค่าน้อยจะทำให้ตัวแบบมีค่าเฉลี่ย MAPE ที่น้อยกว่าตัวแบบที่มีค่า $n_estimators$ มาก โดยเฉพาะที่ $n_estimators = 200$



รูปที่ 4-57 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-57 Hyperparameter min_samples_split ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators โดยส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE ลดลงเมื่อค่า min_samples_split เพิ่มขึ้น ตั้งแต่ min_samples_split = 2 ถึง 8 และกลับมาเพิ่มขึ้นที่ min_samples_split = 10 สรุปได้ว่า min_samples_split ค่ามากจะทำให้ตัวแบบมีค่าเฉลี่ย MAPE ที่น้อยกว่าตัวแบบที่มีค่า min_samples_split น้อย ยกเว้นที่ min_samples_split = 10

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า max_depth = 10, n_estimators = 100, max_features = auto, min_samples_leaf = 1, min_sample_split = 8 และ random_state = 30 มีค่า MAPE เท่ากับ 6.40% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-14 และรูปที่ 4-58




รูปที่ 4-58 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

4.4.6 ตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม




รูปที่ 4-59 วิธีการผสมตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

ผลจากการสร้างตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม ได้ตัวแบบทั้งหมด 55,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ `min_samples_leaf`, `n_estimators` และ `min_samples_split` สามารถสังเกตได้จากรูปที่ 4-60 4-61 และ 4-62 ได้ดังนี้




รูปที่ 4-60 ผลของ min_samples_leaf และ n_estimators ต่อค่าเฉลี่ย MAPE

จากรูปที่ 4-60 Hyperparameter min_samples_leaf ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators ตัวแบบจะมีค่าเฉลี่ย MAPE เพิ่มขึ้นตั้งแต่ช่วง min_samples_leaf = 1 ถึง 8 ซึ่งในช่วง min_samples_leaf = 3 ถึง 6 จะเพิ่มขึ้นอย่างรวดเร็ว หลังจากนั้นจะลดลงในช่วง min_samples_leaf = 8 จนถึง min_samples_leaf = 10 สรุปได้ว่าช่วงของ min_samples_leaf ที่เหมาะสมต่อข้อมูลชุดนี้อยู่ในช่วงที่ min_samples_leaf = 1 ถึง 3



รูปที่ 4-61 ผลของ $n_estimators$ ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-61 Hyperparameter $n_estimators$ ส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE เพิ่มขึ้นเมื่อค่า $n_estimators = 100$ ถึง 200 จากนั้นค่าเฉลี่ย MAPE จะลดลงเมื่อ $n_estimators = 300$ และกลับมาเพิ่มขึ้นจนถึง $n_estimators = 700$ และลดลงเล็กน้อยอีกครั้งสรุปได้ว่าโดยรวมแล้วส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE เพิ่มขึ้นเมื่อค่า $n_estimators$ เพิ่มขึ้น



รูปที่ 4-62 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-62 Hyperparameter min_samples_split ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators โดยส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE ลดลงเล็กน้อยเมื่อค่า min_samples_split เพิ่มขึ้นตั้งแต่ min_samples_split = 2 ถึง 6 และกลับมาเพิ่มขึ้นอย่างรวดเร็วในช่วง min_samples_split = 8 ถึง 10 สรุปได้ว่า min_samples_split ที่เหมาะสมจะอยู่ที่ min_samples_split = 6

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม คือตัวแบบ Random Forest ที่กำหนดค่า max_depth = 10, n_estimators = 100, max_features = auto, min_samples_leaf = 1, min_sample_spilt = 6 และ random_state = 10 มีค่า MAPE เท่ากับ 5.50% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-15 และรูปที่ 4-63




รูปที่ 4-63 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

4.4.7 ตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม




รูปที่ 4-64 วิธีการผสมตัวแบบ Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

ผลจากการสร้างตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสมได้ตัวแบบทั้งหมด 55,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ min_samples_leaf, n_estimators และ min_samples_split สามารถสังเกตได้จากรูปที่ 4-65 4-66 และ 4-67 ได้ดังนี้




รูปที่ 4-65 ผลของ min_samples_leaf และ n_estimators ต่อค่าเฉลี่ย MAPE

จากรูปที่ 4-65 Hyperparameter min_samples_leaf ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators ตัวแบบจะมีค่าเฉลี่ย MAPE ลดลงอย่างรวดเร็วตั้งแต่ช่วง min_samples_leaf = 1 ถึง 4 และเพิ่มขึ้นอย่างรวดเร็วตั้งแต่ min_samples_leaf = 5 จนถึง min_samples_leaf = 10 สรุปได้ว่าช่วงของ min_samples_leaf ที่เหมาะสมต่อข้อมูลชุดนี้อยู่ในช่วงที่ min_samples_leaf = 3 ถึง 4



รูปที่ 4-66 ผลของ $n_estimators$ ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-66 Hyperparameter $n_estimators$ ส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE เพิ่มขึ้น เมื่อค่า $n_estimators$ มีค่ามากขึ้นสรุปได้ว่าค่า $n_estimators$ ที่เหมาะสมต่อข้อมูลชุดนี้คือ $n_estimators = 100$



รูปที่ 4-67 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-67 Hyperparameter min_samples_split ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators โดยส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE ลดลงเล็กน้อยเมื่อค่า min_samples_split = 2 ถึง 4 จากนั้นลดลงในช่วง min_samples_split = 4 ถึง 8 และเพิ่มขึ้นอีกครั้งเมื่อ min_samples_split = 10 สรุปได้ว่าโดยรวมแล้วเมื่อ min_samples_split มากขึ้น ตัวแบบจะมีค่าเฉลี่ย MAPE ลดลง

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า $max_depth = 30$, $n_estimators = 100$, $max_features = auto$, $min_samples_leaf = 4$, $min_sample_split = 8$ และ $random_state = 30$ มีค่า MAPE เท่ากับ 6.12% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-16 และรูปที่ 4-68




รูปที่ 4-68 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

4.4.8 ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม




รูปที่ 4-69 วิธีการผสมตัวแบบ Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

ผลจากการสร้างตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสมได้ตัวแบบทั้งหมด 55,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ min_samples_leaf, n_estimators และ min_samples_split สามารถสังเกตได้จากรูปที่ 4-64 ได้ดังนี้




รูปที่ 4-70 ผลของ min_samples_leaf และ n_estimators ต่อ MAPE

จากรูปที่ 4-70 Hyperparameter min_samples_leaf ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators ตัวแบบจะมีค่าเฉลี่ย MAPE เพิ่มขึ้นในช่วง min_samples_leaf = 1 ถึง 2 จากนั้นลดลงที่ min_samples_leaf = 3 และเพิ่มขึ้นอย่างต่อเนื่องตั้งแต่ min_samples_leaf = 4 จนถึง min_samples_leaf = 10 สรุปว่า min_samples_leaf ที่เหมาะสมต่อข้อมูลชุดนี้คือ min_samples_leaf = 1 และช่วงที่ min_samples_leaf = 3 ถึง 4



รูปที่ 4-71 ผลของ $n_estimators$ ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-71 Hyperparameter $n_estimators$ ส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE เพิ่มขึ้นเมื่อค่า $n_estimators$ มีค่ามากขึ้นสรุปได้ค่า $n_estimators$ ที่เหมาะสมต่อข้อมูลชุดนี้คือ $n_estimators = 100$



รูปที่ 4-72 ผลของ min_samples_split และ n_estimators ต่อค่าเฉลี่ย MAPE


จากรูปที่ 4-72 Hyperparameter min_samples_split ส่งผลที่คล้ายกันให้กับทุกค่าของ n_estimators โดยส่งผลให้ตัวแบบมีค่าเฉลี่ย MAPE เพิ่มขึ้นเล็กน้อยในช่วง min_samples_split = 2 ถึง 4 จากนั้นลดลงในช่วง min_samples_split = 4 ถึง 8 และเพิ่มขึ้นอย่างมากเมื่อ min_samples_split = 10 สรุปได้ว่าช่วงของ min_samples_split ที่เหมาะสมกับข้อมูลนี้อยู่ในช่วง min_samples_split = 6 ถึง 8

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า max_depth = 10, n_estimators = 100, max_features = auto, min_samples_leaf = 1, min_sample_spilt = 6 และ random_state = 90 มีค่า MAPE เท่ากับ 5.93% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-17 และรูปที่ 4-73




รูปที่ 4-73 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

4.4.9 ตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม



รูปที่ 4-74 วิธีการผสมตัวแบบ Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม


ผลจากการสร้างตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสมได้ตัวแบบทั้งหมด 1,210,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ min_child_weight และ n_estimators สามารถสังเกตได้จากรูปที่ 4-75



รูปที่ 4-75 ผลของ min_child_weight และ n_estimators ต่อ MAPE


จากรูปที่ 4-75 Hyperparameter min_child_weight ส่งผลที่คล้ายกันให้กับทุกค่าของ min_child_weight โดยค่าเฉลี่ย MAPE เพิ่มขึ้นในช่วง min_child_weight 1 จนถึง 2 จากนั้นลดลงในช่วง min_child_weight 2 จนถึง 3 หลังจากนั้นค่าเฉลี่ย MAPE เพิ่มขึ้นอย่างรวดเร็ว ในช่วง min_child_weight 3 จนถึง 4 จากนั้นค่าเฉลี่ย MAPE เพิ่มขึ้นเล็กน้อยจนถึง min_child_weight = 9 และเพิ่มขึ้นมากที่ min_child_weight = 10 สามารถสรุปได้ว่าที่ min_child_weight = 1 เหมาะสมต่อข้อมูล เนื่องจากมีค่าเฉลี่ย MAPE ที่น้อยที่สุด

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า learning_rate = 0.08, max_depth = 3, min_child_weight = 1, gamma = 0.4, colsample_bytree = 0 และ n_estimators = 100 มีค่า MAPE เท่ากับ 5.46% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-18 และรูปที่ 4-76



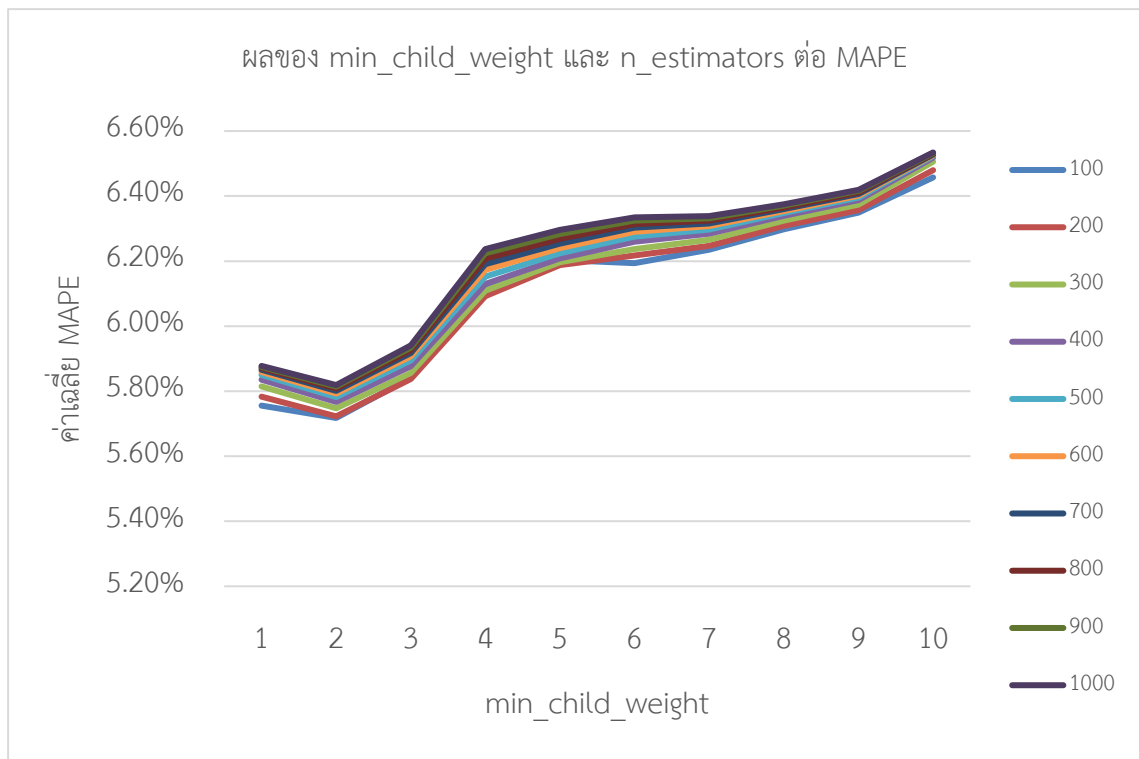
รูปที่ 4-76 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม

4.4.10 ตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม



รูปที่ 4-77 วิธีการผสมตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม


ผลจากการสร้างตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม ได้ตัวแบบทั้งหมด 1,210,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ min_child_weight และ n_estimators สามารถสังเกตได้จากรูปที่ 4-78



รูปที่ 4-78 ผลของ min_child_weight และ n_estimators ต่อ MAPE


จากรูปที่ 4-78 Hyperparameter min_child_weight ส่งผลที่คล้ายกันให้กับทุกค่าของ min_child_weight โดยค่าเฉลี่ย MAPE ลดลงในช่วง min_child_weight = 1 จนถึง 2 จากนั้นเพิ่มขึ้นอย่างรวดเร็วในช่วง min_child_weight = 2 จนถึง 4 หลังจากนั้นค่าเฉลี่ย MAPE เพิ่มขึ้นเล็กน้อยในช่วง min_child_weight = 4 จนถึง 10 สามารถสรุปได้ว่าช่วงของ min_child_weight ที่เหมาะสมต่อข้อมูลคือ min_child_weight = 1 ถึง 3 เนื่องจากมีค่าเฉลี่ย MAPE ที่น้อยที่สุด

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบ Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม คือตัวแบบผสม ที่กำหนดค่า learning_rate = 0.03, max_depth = 4, min_child_weight = 1, gamma = 0.2, colsample_bytree = 1 และ n_estimators = 300 มีค่า MAPE เท่ากับ 4.93% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังตารางที่ ก-19 และรูปที่ 4-79




รูปที่ 4-79 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม

4.4.11 ตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม



รูปที่ 4-80 วิธีการผสมตัวแบบ Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม


ผลจากการสร้างตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสมได้ตัวแบบทั้งหมด 1,210,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ min_child_weight และ n_estimators สามารถสังเกตได้จากรูปที่ 4-81



รูปที่ 4-81 ผลของ min_child_weight และ n_estimators ต่อ MAPE


จากรูปที่ 4-81 Hyperparameter min_child_weight ส่งผลที่คล้ายกันให้กับทุกค่าของ min_child_weight ซึ่งค่าเฉลี่ย MAPE มีการเปลี่ยนแปลงในทุกช่วงของ min_child_weight โดยลดลงเล็กน้อยในช่วง min_child_weight = 1 ถึง 2 จากนั้นเพิ่มขึ้นเล็กน้อยในช่วง min_child_weight = 2 ถึง 3 และลดลงอย่างรวดเร็วในช่วง min_child_weight = 3 ถึง 4 จากนั้นเพิ่มขึ้นเล็กน้อยในช่วง min_child_weight = 4 ถึง 5 และลดลงอย่างรวดเร็วอีกครั้งในช่วง min_child_weight = 5 ถึง 6 หลังจากนั้นค่าเฉลี่ย MAPE เพิ่มขึ้นเล็กน้อยในช่วง min_child_weight = 6 ถึง 7 และกลับเพิ่มขึ้นอย่างรวดเร็ว min_child_weight = 7 ถึง 8 ในช่วง min_child_weight = 8 ถึง 9 ค่าเฉลี่ย MAPE ลดลงเล็กน้อยและเพิ่มอีกครั้งที่ min_child_weight = 10 สามารถสรุปได้ว่าช่วงของ min_child_weight ที่เหมาะสมต่อข้อมูลคือ min_child_weight = 6 ถึง 7 เนื่องจากมีค่าเฉลี่ย MAPE ที่น้อยที่สุด

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า learning_rate = 0.02, max_depth = 3, min_child_weight = 6, gamma = 0 colsample_bytree = 1 และ n_estimators = 500 มีค่า MAPE เท่ากับ 6.21% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-20 และรูปที่ 4-82




รูปที่ 4-82 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม

4.4.12 ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม



รูปที่ 4-83 วิธีการผสมตัวแบบ Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม


ผลจากการสร้างตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสมได้ตัวแบบทั้งหมด 1,210,000 ตัวแบบโดย Hyperparameter ที่มีผลต่อค่า MAPE อย่างมากคือ min_child_weight และ n_estimators สามารถสังเกตได้จากรูปที่ 4-84



รูปที่ 4-84 ผลของ min_child_weight และ n_estimators ต่อ MAPE

จากรูปที่ 4-84 Hyperparameter min_child_weight ส่งผลที่คล้ายกันให้กับทุกค่าของ min_child_weight โดยเพิ่มขึ้นอย่างมากในช่วง min_child_weight = 1 ถึง 4 จากนั้นลดลงอย่างรวดเร็วเล็กน้อยในช่วง min_child_weight = 4 ถึง 7 และเพิ่มขึ้นอีกครั้งในช่วง min_child_weight = 7 ถึง 10 สามารถสรุปได้ว่าช่วงของ min_child_weight ที่เหมาะสมต่อข้อมูลคือ min_child_weight = 1 เนื่องจากมีค่าเฉลี่ย MAPE ที่น้อยที่สุด

ตัวแบบที่มีค่า MAPE น้อยที่สุดในกลุ่มตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม คือตัวแบบผสมที่กำหนดค่า learning_rate = 0.06, max_depth = 8, min_child_weight = 1, gamma = 0.1, colsample_bytree = 1 และ n_estimators = 200 มีค่า MAPE เท่ากับ 5.36% สำหรับการพยากรณ์ด้วยชุดข้อมูลตรวจสอบ โดยมีผลการพยากรณ์ดังภาคผนวกตารางที่ ก-21 และรูปที่ 4-85



รูปที่ 4-85 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัว

ผสม


4.5 การประเมินผลการพยากรณ์

สำหรับการประเมินผลการพยากรณ์ผู้วิจัยจะแบ่งเป็น 3 กลุ่มเพื่อง่ายต่อการสังเกตค่าและประเมินผล โดยแบ่งออกเป็น กลุ่มตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุ กลุ่มตัวแบบการเรียนรู้ของเครื่อง และกลุ่มตัวแบบผสม

4.5.1 กลุ่มตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุ

ผลการพยากรณ์จากตัวแบบในกลุ่มตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุเมื่อเปรียบเทียบกับค่าจริงที่เกิดขึ้นดังรูปที่ 4-86 และคำนวณค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยสำหรับเปรียบเทียบความแม่นยำได้ดังตารางที่ 4-5 ตัวแบบการถดถอยเชิงเส้นพหุคูณมีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยที่สุดในกลุ่มตัวแบบนี้ โดยมีค่าเท่ากับ 7.3% ผลการพยากรณ์ของ

ตัวแบบการถดถอยเชิงเส้นพหุคูณมีการเคลื่อนไหวใกล้เคียงกับปริมาณความต้องการเหล็กแผ่นรีดร้อนที่เกิดจริงโดยมีการเคลื่อนไหวที่แตกต่างกันในช่วงเดือน พฤษภาคม ถึง กรกฎาคม และ พฤศจิกายน ถึง ธันวาคม เท่านั้น ในขณะที่ตัวแบบอื่นมีผลการพยากรณ์เป็นเส้นตรงที่ใกล้เคียงกับค่าเฉลี่ยรวม



รูปที่ 4-86 ผลการพยากรณ์สำหรับตรวจสอบของกลุ่มตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุ


CHULALONGKORN UNIVERSITY

ตารางที่ 4-5 การเปรียบเทียบ MAPE ของตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุสำหรับข้อมูลตรวจสอบตัวแบบ

ตัวแบบการพยากรณ์	Validation MAPE
การถดถอยเชิงเส้นพหุคูณ	7.32%
การปรับเรียบเอกซ์โพเนนเชียลของโฮลท์	8.87%
ARIMA (2,1,0)	9.82%

4.5.2 กลุ่มตัวแบบการเรียนรู้ของเครื่อง

ผลการพยากรณ์จากตัวแบบในกลุ่มตัวแบบการเรียนรู้ของเครื่องเมื่อเปรียบเทียบกับค่าจริงที่เกิดขึ้นดังรูปที่ 4-87 ผลการพยากรณ์ของแต่ละตัวแบบในกลุ่มมีการเคลื่อนไหวใกล้เคียงกันสามารถจับช่วงข้อมูลขึ้นและลงได้ใกล้เคียงกับค่าจริงที่เกิดขึ้นและเมื่อทำการคำนวณค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเพื่อเปรียบเทียบตัวแบบดังตารางที่ 4-6 ตัวแบบ Artificial Neural Network มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยที่สุดในกลุ่มตัวแบบนี้ โดยมีค่าเท่ากับ 5.63%




รูปที่ 4-87 ผลการพยากรณ์สำหรับตรวจสอบของกลุ่มตัวแบบการเรียนรู้ของเครื่อง

ตารางที่ 4-6 การเปรียบเทียบ MAPE ของตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุสำหรับข้อมูล
ตรวจสอบตัวแบบ

ตัวแบบการพยากรณ์	Validation MAPE
Artificial Neural Network	5.63%
eXtreme Gradient Boosting	5.72%
Random Forest	6.21%
Support Vector Regression	7.30%
Light Gradient Boosting Machine	7.33%

4.5.3 กลุ่มตัวแบบผสม

ผลการพยากรณ์จากตัวแบบในกลุ่มตัวแบบผสมเมื่อเปรียบเทียบกับค่าจริงที่เกิดขึ้นดังรูปที่ 4-88 ผลการพยากรณ์ของกลุ่มตัวแบบผสมมีการเคลื่อนไหวใกล้เคียงผลการพยากรณ์ของกลุ่มตัวแบบการเรียนรู้ของเครื่อง เนื่องจากตัวแบบผสมใช้ผลการพยากรณ์ของตัวแบบการเรียนรู้ของเครื่องตั้งแต่ 2 ตัวแบบขึ้นไปมาเป็นปัจจัยในการผสมตัวแบบและทำการพยากรณ์ เมื่อทำการคำนวณค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยเพื่อเปรียบเทียบตัวแบบดังตารางที่ 4-7 ตัวแบบผสมที่ใช้ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม มีค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ยน้อยที่สุดในกลุ่มตัวแบบนี้ โดยมีค่าเท่ากับ 3.59%



รูปที่ 4-88 ผลการพยากรณ์สำหรับตรวจสอบของกลุ่มตัวแบบผสม




ตารางที่ 4-7 การเปรียบเทียบ MAPE ของตัวแบบผสมสำหรับข้อมูลตรวจสอบตัวแบบ

ตัวแบบการพยากรณ์	Validation MAPE
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting, Random Forest ด้วย Artificial Neural Network (ANN+XGB+RF (ANN))	3.59%
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting ด้วย Artificial Neural Network (ANN+XGB (ANN))	4.04%
ตัวแบบผสม Artificial Neural Network, Random Forest ด้วย Artificial Neural Network (ANN+RF (ANN))	4.21%
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting ด้วย eXtreme Gradient Boosting (ANN+XGB (XGB))	4.93%
ตัวแบบผสม eXtreme Gradient Boosting, Random Forest ด้วย Artificial Neural Network (XGB+RF (ANN))	5.13%
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting, Random Forest ด้วย eXtreme Gradient Boosting (ANN+XGB+RF (XGB))	5.36%
ตัวแบบผสม Artificial Neural Network, Random Forest ด้วย eXtreme Gradient Boosting (ANN+RF (XGB))	5.46%
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting ด้วย Random Forest (ANN+XGB (RF))	5.50%
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting, Random Forest ด้วย Random Forest (ANN+XGB+RF (RF))	5.93%
ตัวแบบผสม eXtreme Gradient Boosting, Random Forest ด้วย Random Forest (XGB+RF (RF))	6.12%
ตัวแบบผสม eXtreme Gradient Boosting, Random Forest ด้วย eXtreme Gradient Boosting (XGB+RF (XGB))	6.21%
ตัวแบบผสม Artificial Neural Network, Random Forest ด้วย Random Forest (ANN+RF (RF))	6.40%

4.5.4 ความแม่นยำและเวลา

จากการตัวแบบการพยากรณ์ที่สร้างขึ้นด้วย Google Colaboratory โดยเฉพาะในกลุ่มตัวแบบการเรียนรู้ของเครื่องและตัวแบบผสมที่ต้องใช้เวลาซึ่งเป็นทรัพยากรสำคัญในการสร้างตัวแบบค่อนข้างมาก เวลาจึงเป็นอีกปัจจัยสำคัญที่ควรต้องทำการพิจารณา ในการสร้างตัวแบบผู้วิจัยได้ทำการบันทึกเวลาที่ต้องใช้ด้วยชุดคำสั่ง time ด้วยการบันทึกเวลาในตอนเริ่มการสร้างตัวแบบจนได้ตัวแบบที่ Optimum ที่สุดในขอบเขตที่กำหนดไว้ ดังตารางที่ 4-8 และรูปที่ 4-89 โดยเรียงลำดับตามค่า MAPE



รูปที่ 4-89 เวลาที่ใช้ในการสร้างตัวแบบของตัวแบบการเรียนรู้ของเครื่องและตัวแบบผสม กับค่า MAPE จากผลการพยากรณ์สำหรับตรวจสอบตัวแบบ

ตารางที่ 4-8 เวลาที่ใช้ในการสร้างตัวของตัวแบบการเรียนรู้ของเครื่องและตัวแบบผสม

ตัวแบบการพยากรณ์	Number of models	CV MAPE	เวลา (ชั่วโมง)
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting, Random Forest ด้วย Artificial Neural Network	968,000	3.59%	43.68
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting ด้วย Artificial Neural Network	968,000	4.04%	42.66
ตัวแบบผสม Artificial Neural Network, Random Forest ด้วย Artificial Neural Network	968,000	4.21%	42.14
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting ด้วย eXtreme Gradient Boosting	1,210,000	4.93%	34.65
ตัวแบบผสม eXtreme Gradient Boosting, Random Forest ด้วย Artificial Neural Network	968,000	5.13%	20.75
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting, Random Forest ด้วย eXtreme Gradient Boosting	1,210,000	5.36%	34.53
ตัวแบบผสม Artificial Neural Network, Random Forest ด้วย eXtreme Gradient Boosting	1,210,000	5.46%	34.49
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting ด้วย Random Forest	55,000	5.50%	32.66
ตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting, Random Forest ด้วย Random Forest	55,000	5.63%	22.01
ตัวแบบผสม eXtreme Gradient Boosting, Random Forest ด้วย Random Forest	55,000	5.72%	13.19
ตัวแบบผสม eXtreme Gradient Boosting, Random Forest ด้วย eXtreme Gradient Boosting	1,210,000	5.93%	31.73
ตัวแบบผสม Artificial Neural Network, Random Forest ด้วย Random Forest	55,000	6.12%	23.38

จากตารางที่ 4-8 และรูปที่ 4-89 พบว่าตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting, Random Forest ด้วย Artificial Neural Network ที่มีค่า MAPE น้อยที่สุดเป็นตัวแบบที่ใช้เวลาในการสร้างตัวแบบมากที่สุดนับตั้งแต่การเริ่มสร้างจากตัวแบบเดี่ยวจนถึงตัวแบบผสม รวมเป็นเวลา 43.68 ชั่วโมง หรือ 43 ชั่วโมง 41 นาที และตัวแบบที่มีค่า MAPE ในลำดับที่ 2 คือตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting ด้วย Artificial Neural Network และลำดับที่ 3 คือตัวแบบผสม Artificial Neural Network, Random Forest ด้วย Artificial Neural Network ก็ใช้เวลาในการสร้างตัวแบบใกล้เคียงกัน โดยใช้เวลา 42.66 ชั่วโมงและ 42.14 ชั่วโมงตามลำดับ ทั้งสามตัวแบบนี้ใช้เวลาในการสร้างมากเนื่องจากเป็นตัวแบบที่มีการสร้างขึ้นด้วยตัวแบบ Artificial Neural Network ที่ใช้เวลามากที่สุดในกลุ่มตัวแบบเดี่ยวโดยใช้เวลาถึง 22.01 ชั่วโมงในการสร้างตัวแบบเดี่ยวและในการรวมเป็นตัวแบบผสมก็ใช้เวลาอีก 21.67 ชั่วโมง


4.6 ผลการพยากรณ์สำหรับทดสอบตัวแบบ

จากการเปรียบเทียบค่า MAPE และวัตถุประสงค์ของงานวิจัยในการค้นหาตัวแบบที่แม่นยำที่สุดผู้วิจัยเลือกตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสมซึ่งเป็นตัวแบบที่มีค่า MAPE น้อยที่สุดมาทำการพยากรณ์ด้วยข้อมูลทดสอบตัวแบบเพื่อวัดผลการพยากรณ์ โดยไม่มีการเปลี่ยนแปลงค่า Hyperparameter และเพื่อทดสอบความความแข็งแกร่ง (Robustness) ของตัวแบบ ผู้วิจัยได้ทำการเปรียบเทียบการพยากรณ์โดยใช้ตัวแบบที่ถูกสร้างจากข้อมูลสร้างตัวแบบ 48 เดือน สร้างจากข้อมูลสร้างตัวแบบ 60 เดือน ดังรูปที่ 4-90


ข้อมูลสร้างตัวแบบ 48 เดือน (พ.ศ. 2557 - 2560)	ข้อมูลตรวจสอบตัวแบบ 12 เดือน (พ.ศ. 2561)	ข้อมูลทดสอบตัวแบบ 12 เดือน (พ.ศ. 2562)
ข้อมูลสร้างตัวแบบ 60 เดือน (พ.ศ. 2557 - 2561)		ข้อมูลทดสอบตัวแบบ 12 เดือน (พ.ศ. 2562)

รูปที่ 4-90 การใช้ข้อมูลในการสร้างตัวแบบและการพยากรณ์

โดยตัวแบบที่สร้างจากข้อมูลสร้างตัวแบบ 48 เดือน ซึ่งเป็นข้อมูลปี พ.ศ. 2557 จนถึง พ.ศ. 2560 และทำการพยากรณ์ข้อมูลทดสอบในปี พ.ศ. 2562 จำนวน 12 เดือน ได้ผลดังตารางที่ ก-22 และรูปที่ 4-91 และคำนวณค่า MAPE ของการพยากรณ์ด้วยข้อมูลทดสอบได้เท่ากับ 14.22% และตัวแบบที่สร้างจากข้อมูลสร้างตัวแบบ 60 เดือน ซึ่งเป็นข้อมูลปี พ.ศ. 2557 จนถึง พ.ศ. 2561 และทำการพยากรณ์ข้อมูลทดสอบในปี พ.ศ. 2562 จำนวน 12 เดือน ได้ผลดังตารางที่ ก-23 และรูปที่ 4-92 และคำนวณค่า MAPE ของการพยากรณ์ด้วยข้อมูลทดสอบได้เท่ากับ 7.97% เมื่อประเมินผลตัวแบบผ่านตารางการประเมินค่า MAPE ของ Lewis ดังตารางที่ 2-1 พบว่าตัวแบบที่ใช้ข้อมูลสร้างตัวแบบ 48 เดือน ยังคงเป็นตัวแบบที่แม่นยำ และตัวแบบที่ใช้ข้อมูลสร้างตัวแบบ 60 เดือนถือได้ว่าเป็นตัวแบบที่มีความแม่นยำสูง



รูปที่ 4-91 ผลการพยากรณ์สำหรับทดสอบตัวแบบผสม โดยใช้ข้อมูลสร้างตัวแบบ 48 ข้อมูล



รูปที่ 4-92 ผลการพยากรณ์สำหรับทดสอบตัวแบบผสม โดยใช้ข้อมูลสร้างตัวแบบ 60 ข้อมูล



บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

การศึกษากการพยากรณ์ปริมาณความต้องการเหล็กคอร์ดร้อนภายในประเทศด้วยวิธีการเรียนรู้ของเครื่อง โดยมีวัตถุประสงค์เพื่อค้นหาตัวแบบที่มีความแม่นยำมากที่สุด ผู้วิจัยได้เลือกใช้ข้อมูลปัจจัยที่สามารถทราบได้ล่วงหน้าเพื่อให้ตัวแบบการพยากรณ์สามารถนำไปใช้งานได้จริง สำหรับตัวแบบการพยากรณ์ ผู้วิจัยได้เลือกตัวแบบจาก 4 ประเภทตัวแบบ ประกอบไปด้วยตัวแบบอนุกรมเวลา 2 ตัวแบบ ตัวแบบเชิงสาเหตุ 1 ตัวแบบ ตัวแบบการเรียนรู้ของเครื่อง 5 ตัวแบบ และตัวแบบผสม 12 ตัวแบบ รวมเป็น 20 ตัวแบบการพยากรณ์ หลังจากการทำการศึกษากการสร้างตัวแบบและการพยากรณ์ด้วยตัวแบบที่สร้างขึ้นแล้วผู้วิจัยได้คำนวณค่า MAPE เพื่อทำการเปรียบเทียบผลการพยากรณ์ดังตารางที่ 4-5 4-6 4-7 และการเปรียบเทียบความแม่นยำและเวลาดังตารางที่ 4-8 โดยสรุปผลการวิจัยได้ดังนี้

5.1 สรุปผล


จากการสร้างตัวแบบการพยากรณ์ทั้ง 20 ตัวแบบในการวิจัยนี้พบว่าตัวแบบการถดถอยเชิงเส้นพหุคูณที่มีค่า MAPE 7.32% ถือได้ว่ามีความแม่นยำเพียงพอต่อการใช้งาน แต่ดังที่กล่าวไว้ในข้างต้นมูลค่าในอุตสาหกรรมเหล็กแผ่นรีดร้อนมีมูลค่าสูงถึง 8,345 ล้านบาทต่อเดือน ดังนั้นการพัฒนาตัวแบบที่มีความแม่นยำขึ้นเพียง 1% ที่จะนำมาใช้ในการวางแผนการจัดการสามารถคิดเป็นมูลค่าได้หลักล้านบาทต่อเดือน ตัวแบบการเรียนรู้ของเครื่องและตัวแบบผสมที่ผู้วิจัยได้ทำการศึกษาและพัฒนาขึ้นสำหรับข้อมูลชุดนี้มีความแม่นยำมากกว่าตัวแบบการถดถอยเชิงเส้นพหุคูณ เมื่อเปรียบเทียบค่า MAPE กับตัวแบบ Artificial Neural Network ที่เป็นตัวแบบที่ดีที่สุดของตัวแบบการเรียนรู้ของเครื่องซึ่งมีค่า MAPE เท่ากับ 5.63% พบว่าค่า MAPE ลดลงถึง 1.69% หรือคิดเป็น 23.08% เมื่อเทียบกับตัวแบบการถดถอยเชิงเส้นพหุคูณ และเมื่อนำตัวแบบ Artificial Neural Network เปรียบเทียบกับตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม ที่เป็นตัวแบบที่ดีที่สุดของตัวผสมซึ่งมีค่า MAPE เท่ากับ 3.59% พบว่าค่า MAPE ลดลงถึง 2.04% หรือคิดเป็น 36.23% เมื่อเทียบกับตัวแบบ Artificial Neural Network

การที่ตัวแบบการเรียนรู้ของเครื่องสามารถทำการพยากรณ์ได้แม่นยำกว่าตัวแบบเชิงสาเหตุ เนื่องมาจากการคำนวณภายในของตัวแบบโดยตัวแบบเชิงสาเหตุจะคำนวณจากความสัมพันธ์ของปัจจัยกับผลเฉลยโดยตรงและหาค่าถ่วงน้ำหนักมาประกอบการคำนวณโดยจะได้สมการการพยากรณ์เพียงสมการเดียวและใช้ในการพยากรณ์ทุกช่วงเวลา แต่ตัวแบบการเรียนรู้ของเครื่อง ตัวแบบ Artificial Neural Network มีการแบ่งการคำนวณที่ละเอียดยิ่งกว่าตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุ โดยมีการรับข้อมูลนำเข้าในแต่ละ Node และทำการคำนวณให้ค่าถ่วงน้ำหนักใหม่ในแต่ละ Node ดังรูปที่ 2-15 และคำนวณทุก Node ในทุกชั้นซ่อน ที่ทำให้สามารถคำนวณข้อมูลได้ซับซ้อนยิ่งขึ้นดังรูปที่ 2-16 จึงทำให้ตัวแบบ Artificial Neural Network สามารถให้ค่าถ่วงน้ำหนักเฉพาะสำหรับแต่ละปัจจัยในแต่ละช่วงเวลาได้ตามที่กำหนดในข้อมูลนำเข้า ตัวแบบ Random Forest แม้จะเป็นตัวแบบที่อาศัยการตัดสินใจจาก Decision Tree แต่ด้วยความซับซ้อนในการตัดสินใจจาก Decision Tree ที่มีจำนวนมาก ตัวแบบจึงสามารถเลือกตัดสินใจค่าการพยากรณ์ตามความสัมพันธ์ของปัจจัยได้ดียิ่งขึ้น และตัวแบบ eXtreme Gradient Boosting ที่อาศัย Decision Tree เช่นเดียวกับตัวแบบ Random Forest แต่มีการปรับปรุงค่าจาก Weak Classifier เพิ่มเติม ตัวแบบการเรียนรู้ของเครื่องจึงให้ผลลัพธ์ที่แม่นยำกว่าตัวแบบตัวแบบอนุกรมเวลาและตัวแบบเชิงสาเหตุในชุดข้อมูลนี้

ตัวแบบผสมที่ใช้ Artificial Neural Network สามารถให้ค่าถ่วงน้ำหนักเฉพาะสำหรับแต่ละปัจจัยในแต่ละช่วงเวลาได้ตามที่กำหนดในข้อมูลนำเข้าซึ่งยังให้ผลลัพธ์ที่แม่นยำกว่าตัวแบบผสมที่ใช้ตัวแบบ Random Forest และ eXtreme Gradient Boosting เป็นตัวผสม เนื่องจากทั้งสองตัวแบบเป็นตัวแบบที่มีพื้นฐานจาก Decision Tree ที่อาศัยการตัดสินใจจากผลลัพธ์ที่ถูกเลือกในตัวแบบผสม Random Forest และผลลัพธ์ที่ถูกเลือกและปรับปรุงจาก Weak Classifier ในตัวแบบ eXtreme Gradient Boosting ซึ่งซึ่งอาจไม่ละเอียดเพียงพอต่อการผสมข้อมูล

การผสมตัวแบบโดยปรกติแล้วนิยมการผสมตัวแบบเชิงเส้นกับตัวแบบที่ไม่เป็นเชิงเส้นเข้าด้วยกัน ในงานวิจัยนี้ทำการศึกษาโดยใช้การผสมตัวแบบที่ไม่เป็นเชิงเส้นกับตัวแบบที่ไม่เป็นเชิงเส้น โดยการผสมตัวแบบด้วยตัวแบบการเรียนรู้ของเครื่องสองตัวแบบ และสามตัวแบบ โดยการนำผลลัพธ์ของตัวแบบการเรียนรู้ของเครื่องที่ดีที่สุดสามอันดับแรกมาทำการผสมทำให้ตัวแบบผสมสามารถดึงข้อดีของแต่ละตัวแบบเดี่ยวออกมาได้โดยเฉพาะตัวแบบผสม Artificial Neural Network, Random

Forest และ eXtreme Gradient Boosting ที่ใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม จะทำการให้ค่าถ่วงน้ำหนักแก่ผลลัพธ์ที่มีความสัมพันธ์กับผลเฉลยที่ดีกว่า เช่น ในผลลัพธ์ของตัวแบบ Artificial Neural Network ที่สามารถพยากรณ์ได้ดีในช่วงเดือน มีนาคม และ มิถุนายน ถึง ตุลาคม ผลลัพธ์ของตัวแบบ eXtreme Gradient Boosting ที่สามารถพยากรณ์ได้ดีในช่วงเดือน มกราคม ถึง กุมภาพันธ์ สิงหาคม และตุลาคม ถึง ธันวาคม และผลลัพธ์ของตัวแบบ Random Forest ที่สามารถพยากรณ์ได้ดีในช่วงเดือน มกราคม เมษายน ถึง พฤษภาคม และธันวาคม ตัวแบบ Artificial Neural Network จะปรับค่าถ่วงน้ำหนักของผลลัพธ์ในแต่ละเดือนให้ได้ใกล้เคียงกับผลเฉลยมากที่สุดดังรูปที่ 5-1 จะเห็นได้ว่าตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting ที่ใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม สามารถพยากรณ์ได้ดีในช่วงเดือน มกราคม ถึงกุมภาพันธ์ และ มิถุนายน จนถึงธันวาคม ซึ่งเป็นผลพยากรณ์ที่ใกล้เคียงกับค่าจริงถึง 8 เดือน จากเดิมที่ตัวแบบ Artificial Neural Network สามารถให้ผลการพยากรณ์ที่ใกล้เคียงกับค่าจริงได้เพียง 5 เดือน ทำให้ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting ที่ใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม มีความแม่นยำสูงขึ้นอย่างมากโดยมีค่า MAPE เหลือเพียง 3.59% เท่านั้น



รูปที่ 5-1 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest ที่ใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม เปรียบเทียบกับตัวแบบการเรียนรู้ของเครื่องที่เกี่ยวข้อง

สำหรับการพยากรณ์ด้วยข้อมูลทดสอบตัวแบบ จากการเปรียบเทียบระหว่างการพยากรณ์ด้วยตัวแบบที่มีการใช้ข้อมูลในการสร้างตัวแบบ 48 เดือน ที่มีค่า MAPE เท่ากับ 14.22% และตัวแบบที่มีการใช้ข้อมูลในการสร้างตัวแบบ 60 เดือน ที่มีค่า MAPE เท่ากับ 7.97% เนื่องจากการใช้ตัวแบบที่ใช้ข้อมูลในการสร้างตัวแบบ 48 เดือน มาทำการพยากรณ์ข้อมูล 12 เดือน ในปี พ.ศ.2562 จะต้องทำการพยากรณ์ล่วงหน้าถึง 24 เดือน ดังตารางที่ 4-9 ซึ่งทำให้ค่า MAPE สูงขึ้นจากความห่างของข้อมูลที่ใช้สร้างตัวแบบที่ไม่เป็นปัจจุบัน แต่เมื่อทำการปรับปรุงโดยการเพิ่มข้อมูลในปี พ.ศ.2561 ในข้อมูลการสร้างตัวแบบและทำการสร้างตัวแบบที่ใช้ข้อมูล 60 เดือน มาทำการพยากรณ์ทำให้ค่า MAPE ที่ได้ ลดลงเหลือเพียง 7.97% ซึ่งเป็นผลมาจากความเป็นปัจจุบันของข้อมูลสร้างตัวแบบซึ่งจะทำให้ประเมินผลรอบการปรับปรุงตัวแบบได้ว่า ตัวแบบที่สร้างขึ้นควรจะต้องมีการปรับปรุงข้อมูลในการสร้างตัวแบบทุกปี และยังคงแสดงให้เห็นว่าตัวแบบยังคงมีความแข็งแกร่ง และคงทนต่อการเพิ่มข้อมูล

เนื่องจากตัวแบบการเรียนรู้ของเครื่องเป็นแบบที่ไม่เป็นเชิงเส้น และมีความละเอียดของการประมวลผลในตัวแบบเพียงพอที่จะตอบสนองต่อข้อมูลลักษณะต่าง ๆ

อย่างไรก็ตามแม้ตัวแบบผสมจะมีความแม่นยำที่สูงมาก แต่ก็ต้องใช้ทรัพยากรมากเช่นกัน ในงานวิจัยนี้ได้ใช้เวลาในการสร้างตัวแบบมาเป็นตัวชี้วัดเพิ่มเติมเพื่อเปรียบเทียบเวลาที่ใช้ในการสร้างตัวแบบการพยากรณ์ในกลุ่มตัวแบบการเรียนรู้ของเครื่องและตัวแบบผสมซึ่งได้ผลดังตารางที่ 4-29 และนำมาสร้างเป็นแผนภูมิการกระจายดังรูปที่ 4-89 ตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting ที่ใช้ตัวแบบ Artificial Neural Network ที่มีความแม่นยำที่สุดจำเป็นต้องใช้ทรัพยากรหรือเวลาในการสร้างตัวแบบมากที่สุดเช่นกัน เนื่องจากตัวแบบ Artificial Neural Network ที่มีการกำหนดค่า Epoch ถึง 10 ค่าโดยค่าที่สูงที่สุดคือ 1,000 และ Batch size ที่มีขนาดเล็กตั้งแต่ 12 24 36 และ 48 การที่ตัวแบบ Artificial Neural Network จะนำเข้า Batch size จนครบและทำซ้ำเท่ากับค่า Epoch นั้นจึงใช้เวลานานและตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting ที่ใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม ทำการสร้างตัวแบบด้วยตัวแบบ Artificial Neural Network ถึงสองครั้ง สำหรับข้อมูลชุดนี้สามารถสรุปได้ว่า การสร้างตัวแบบด้วยตัวแบบ Artificial Neural Network จะใช้เวลาการสร้างตัวแบบมากกว่าตัวแบบการเรียนรู้ของเครื่องตัวแบบอื่น ประมาณ 2 เท่า

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

5.2 ข้อเสนอแนะ

สำหรับตัวแบบการเรียนรู้ของเครื่อง ยังมีวิธีที่สามารถปรับปรุงตัวแบบได้อีกมาก เช่น การปรับ Hyperparameter ในช่วงที่กว้างขึ้นเพื่อค้นหาจุดที่ดีที่สุดหรือที่เรียกว่า Global Optimum ที่สามารถให้ผลการพยากรณ์ที่แม่นยำยิ่งขึ้นได้ภายใต้ทรัพยากรที่มี การเลือกปรับ Hyperparameter อื่นเพิ่มเติมเพื่อการปรับการคำนวณของตัวแบบ การเพิ่ม Hidden Layer เพื่อเพิ่มการคำนวณในตัวแบบ Artificial Neural Network รวมไปถึงการเปลี่ยนหรือเพิ่มปัจจัยที่ใช้ในการพยากรณ์ในตัวแบบการเรียนรู้ของเครื่อง

สำหรับตัวแบบผสมที่เป็นตัวแบบหลักในงานวิจัยนี้ ยังสามารถปรับเปลี่ยนแนวคิด วิธีการผสมตัวแบบซึ่งสามารถทำได้โดยไม่จำกัดวิธีขึ้นอยู่กับความเหมาะสมต่อข้อมูล การนำค่าอนุกรมเวลาของสิ่งที่ต้องการพยากรณ์ในอดีตเพิ่มเข้ามาเป็นปัจจัยในการสร้างตัวแบบ หรือการนำค่าความคลาดเคลื่อนเพิ่มเข้ามาเป็นปัจจัยในการสร้างตัวแบบผสมซึ่งอาจทำให้ตัวแบบสามารถปรับปรุงผลการพยากรณ์และค่าที่เกิดขึ้นจริงได้ดียิ่งขึ้น

การเลือกใช้สำหรับตัวแบบผสมที่เหมาะสมต่อการใช้งานและข้อจำกัดด้านทรัพยากร สำหรับการพยากรณ์ที่มีชุดข้อมูลที่มีมากกว่าข้อมูลชุดนี้ การสร้างตัวแบบการเรียนรู้ของเครื่องอาจใช้เวลาเป็นวัน เป็นเดือน หรือมากกว่านั้น การที่จะสร้างตัวแบบผสมซึ่งใช้เวลาเพิ่มขึ้นเป็นเท่าตัวอาจทำให้ทรัพยากรที่มีอยู่ไม่เพียงพอหรือไม่ทันต่อการใช้งาน การเปรียบเทียบดังรูปที่ 4-89 สามารถช่วยในการตัดสินใจและวางแผนการสร้างตัวแบบได้ เช่น การเลือกใช้ตัวแบบที่เหมาะสมต่อเวลาหากมีข้อจำกัดด้านเวลาที่ต้องการผลลัพธ์ 24 ชั่วโมง อาจเลือกตัวแบบผสม Random Forest และ eXtreme Gradient Boosting ที่ใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม มีค่า MAPE เท่ากับ 5.13% โดยใช้เวลา 20.75 ชั่วโมง หรือในอีกแนวทางหนึ่งอาจทดลองใช้ชุดของ Hyperparameter ที่ดีที่สุดของตัวแบบเดี่ยวมาทำการผสมตัวแบบโดยไม่ต้องทำการหา Hyperparameter ที่ดีที่สุดของตัวแบบผสมใหม่จะช่วยลดเวลาในการสร้างตัวแบบได้อย่างมาก

บรรณานุกรม

- Abadi, M., Barham, P., Chen, J., Chen, Z., Davis, A., Dean, J., . . . Isard, M. (2016). *Tensorflow: A system for large-scale machine learning*. Paper presented at the 12th {USENIX} symposium on operating systems design and implementation ({OSDI} 16).
- Bank of Thailand. (2020). Thailand's Macro Economic Indicators. Retrieved from https://www.bot.or.th/App/BTWS_STAT/statistics/BOTWEBSTAT.aspx?reportID=409&language=ENG
- Biau, G., & Scornet, E. (2016). A random forest guided tour. *Test*, 25(2), 197-227.
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*: John Wiley & Sons.
- Breiman, L. (2001). Random forests. *Machine learning*, 45(1), 5-32.
- Carbonneau, R., Laframboise, K., & Vahidov, R. (2008). Application of machine learning techniques for supply chain demand forecasting. *European Journal of Operational Research*, 184(3), 1140-1154.
- Chatfield, C. (2000). *Time-series forecasting*: CRC press.
- Chen, T., & Guestrin, C. (2016). *Xgboost: A scalable tree boosting system*. Paper presented at the Proceedings of the 22nd acm sigkdd international conference on knowledge discovery and data mining.
- Claveria, O., & Torra, S. (2014). Forecasting tourism demand to Catalonia: Neural networks vs. time series models. *Economic Modelling*, 36, 220-228.
- Drucker, H., Burges, C. J., Kaufman, L., Smola, A., & Vapnik, V. (1997). Support vector regression machines. *Advances in neural information processing systems*, 9, 155-161.
- Eberly, L. E. (2007). Multiple linear regression. *Topics in Biostatistics*, 165-187.
- Fattah, J., Ezzine, L., Aman, Z., El Moussami, H., & Lachhab, A. (2018). Forecasting of demand using ARIMA model. *International Journal of Engineering Business Management*, 10, 1847979018808673.
- Gao, C., Na, H., Tian, M., Ye, Z., & Qi, Z. (2018). Analyzing Structure and Driving Force of

- Steel Consumption in China. *JOURNAL OF ENVIRONMENTAL ACCOUNTING AND MANAGEMENT*, 6(1), 33-45.
- Heaton, J. (2017, 01/06/2017). The Number of Hidden Layers. Retrieved from <https://www.heatonresearch.com/2017/06/01/hidden-layers.html>
- Iron and Steel Institute of Thailand. (2020). Thailand Steel Production and Consumption. Retrieved from <http://iiu.isit.or.th/>
- Kalekar, P. S. (2004). Time series forecasting using holt-winters exponential smoothing. *Kanwal Rekhi school of information Technology*, 4329008(13), 1-13.
- Khandelwal, P. (2017, June 12, 2017). Which algorithm takes the crown: Light GBM vs XGBOOST? Retrieved from <https://www.analyticsvidhya.com/blog/2017/06/which-algorithm-takes-the-crown-light-gbm-vs-xgboost/>
- Klimberg, R. K., Sillup, G. P., Boyle, K. J., & Tavva, V. (2010). Forecasting performance measures—what are their practical meaning? In *Advances in business and management forecasting*: Emerald Group Publishing Limited.
- Lahouar, A., & Slama, J. B. H. (2015). Day-ahead load forecast using random forest and expert input selection. *Energy Conversion and Management*, 103, 1040-1051.
- Lewis, C. D. (1982). *Industrial and business forecasting methods: A practical guide to exponential smoothing and curve fitting*: Butterworth-Heinemann.
- Ma, W., Zhu, X., & Wang, M. (2013). Forecasting iron ore import and consumption of China using grey model optimized by particle swarm optimization algorithm. *Resources Policy*, 38(4), 613-620.
- Makridakis, S. (1993). Accuracy measures: theoretical and practical concerns. *International journal of forecasting*, 9(4), 527-529.
- Mehmanpazir, F., Khalili-Damghani, K., & Hafezalkotob, A. (2019). Modeling steel supply and demand functions using logarithmic multiple regression analysis (case study: Steel industry in Iran). *Resources Policy*, 63, 101409.
- Mentzer, J. T., & Moon, M. A. (2004). *Sales forecasting management: a demand management approach*: Sage Publications.
- Mitchell, T. M. (1997). *Machine Learning*. Professional Book Group 11 West 19th Street New York, NY United States: McGraw-Hill Inc.

- Noble, W. S. (2006). What is a support vector machine? *Nature biotechnology*, 24(12), 1565-1567.
- Omar, H., Hoang, V. H., & Liu, D.-R. (2016). A hybrid neural network model for sales forecasting based on ARIMA and search popularity of article titles. *Computational intelligence and neuroscience*, 2016.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., . . . Dubourg, V. (2011). Scikit-learn: Machine learning in Python. *the Journal of machine Learning research*, 12, 2825-2830.
- Rebiasz, B. (2006). Polish steel consumption, 1974–2008. *Resources Policy*, 31(1), 37-49.
- Sasongko, A., Marie, I., & Arifin, F. (2020). *Forecasting for Steel Production using Artificial Neural Networks and Feasibility Analysis of Plant Regeneration Acid Development in PT. XYZ*. Paper presented at the IOP Conference Series: Materials Science and Engineering.
- Taylor, J. W. (2003). Short-term electricity demand forecasting using double seasonal exponential smoothing. *Journal of the Operational Research Society*, 54(8), 799-805.
- The Office of Industrial Economics. (2020). Industrial statistics. Retrieved from <https://indexes.oie.go.th/industrialStatistics1.aspx>
- Toomwongsa, N. (2017). *THAILAND INDUSTRY OUTLOOK 2018-20 (STEEL INDUSTRY)*. Retrieved from <https://www.krungsri.com/bank/th/Other/research/industry/industry-outlook.html>
- Toomwongsa, N. (2018). *THAILAND INDUSTRY OUTLOOK 2018-20 (STEEL INDUSTRY)*. Retrieved from <https://www.krungsri.com/bank/th/Other/research/industry/industry-outlook.html>
- Uyanik, G. K., & Güler, N. (2013). A study on multiple linear regression analysis. *Procedia-Social and Behavioral Sciences*, 106, 234-240.
- Vapnik, V. (1995). *The nature of statistical learning theory* springer new york google scholar. *New York*.
- Vapnik, V., Golowich, S. E., & Smola, A. (1997). Support vector method for function

- approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, 281-287.
- Wang, J.-J., Wang, J.-Z., Zhang, Z.-G., & Guo, S.-P. (2012). Stock index forecasting based on a hybrid model. *Omega*, 40(6), 758-766.
- Wang, S.-C. (2003). Artificial neural network. In *Interdisciplinary computing in java programming* (pp. 81-100): Springer.
- Weng, Y., Zhou, L., Zhou, S., & Qi, T. (2015). Research on China's Steel Demand Using Combined Forecast. *International Journal of u-and e-Service, Science and Technology*, 8(1), 189-200.
- World Steel Association. (2020). *Steel Statistical Yearbook 2020 concise version*. Retrieved from <https://www.worldsteel.org/steel-by-topic/statistics/steel-statistical-yearbook.html>
- Yin, X., & Chen, W. (2013). Trends and development of steel demand in China: A bottom-up analysis. *Resources Policy*, 38(4), 407-415.
- Zhang, X.-D. (2020). Machine learning. In *A Matrix Algebra Approach to Artificial Intelligence* (pp. 223-440): Springer.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

ภาคผนวก ก

ตารางที่ ก-1 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบการปรับเรียบเอกซ์โพเนนเชียลของโฮลท์

เดือน	ปี	ผลการพยากรณ์ (ต้น)	Lo 80	Hi 80	Lo 95	Hi 95
มกราคม	2561	454,747.4	379,069.3	530,425.5	339,007.7	570,487.1
กุมภาพันธ์	2561	455,465.6	373,528.3	537,402.9	330,153.3	580,777.9
มีนาคม	2561	456,183.8	366,020.9	546,346.7	318,291.6	594,076.0
เมษายน	2561	456,902	356,645.8	557,158.2	303,573.4	610,230.6
พฤษภาคม	2561	457,620.2	345,562.8	569,677.6	286,243.2	628,997.2
มิถุนายน	2561	458,338.4	332,945.9	583,730.9	266,567.1	650,109.7
กรกฎาคม	2561	459,056.6	318,957.2	599,155.9	244,793.1	673,320.0
สิงหาคม	2561	459,774.8	303,737.1	615,812.5	221,135.7	698,413.8
กันยายน	2561	460,493	287,402.4	633,583.5	195,773.8	725,212.1
ตุลาคม	2561	461,211.2	270,049.4	652,373.0	168,854.4	753,567.9
พฤศจิกายน	2561	461,929.4	251,756.8	672,101.9	140,498.2	783,360.5
ธันวาคม	2561	462,647.5	232,589.7	692,705.4	110,804.4	814,490.7



ตารางที่ ก-2 การพยากรณ์สำหรับตรวจสอบตัวแบบ ARIMA(2,1,0)

เดือน	ปี	ผลการพยากรณ์ (ต้น)	Lo 80	Hi 80	Lo 95	Hi 95
มกราคม	2561	446,258.2	378,632.8	513,883.7	342,834.0	549,682.5
กุมภาพันธ์	2561	434,119.8	363,052.6	505,186.9	325,432.0	542,807.6
มีนาคม	2561	462,901.0	389,596.3	536,205.7	350,791.1	575,010.9
เมษายน	2561	449,675.9	364,079.0	535,272.8	318,766.7	580,585.1
พฤษภาคม	2561	443,790.9	353,592.2	533,989.6	305,843.8	581,738.0
มิถุนายน	2561	454,592.5	360,834.5	548,350.5	311,202.0	597,983.0
กรกฎาคม	2561	450,314.5	350,010.6	550,618.4	296,912.9	603,716.0
สิงหาคม	2561	447,641.9	342,859.2	552,424.6	287,390.5	607,893.2
กันยายน	2561	451,656.5	343,005.0	560,307.9	285,488.4	617,824.6
ตุลาคม	2561	450,316.7	336,894.4	563,738.9	276,852.3	623,781.0
พฤศจิกายน	2561	449,154.0	331,630.0	566,678.0	269,416.5	628,891.5
ธันวาคม	2561	450,631.7	329,336.4	571,927.1	265,126.5	636,136.9

ตารางที่ ก-3 การพยากรณ์สำหรับตรวจสอบตัวแบบการถดถอยเชิงเส้นพหุคูณโดยใช้ปัจจัยที่ผ่านกระบวนการ Stepwise

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ต้น)
มกราคม	2561	467,772.7
กุมภาพันธ์	2561	445,356.9
มีนาคม	2561	528,882.4
เมษายน	2561	499,057.4
พฤษภาคม	2561	480,448.9
มิถุนายน	2561	460,203.8
กรกฎาคม	2561	438,307.6
สิงหาคม	2561	514,375.0
กันยายน	2561	494,880.3
ตุลาคม	2561	467,667.3
พฤศจิกายน	2561	505,634.8
ธันวาคม	2561	464,191.0

ตารางที่ ก-4 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบการถดถอยเชิงเส้นพหุคูณโดยใช้ปัจจัยที่ผ่าน
เงื่อนไข

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	464,031.3
กุมภาพันธ์	2561	442,713.5
มีนาคม	2561	528,726.7
เมษายน	2561	498,097.3
พฤษภาคม	2561	479,287.7
มิถุนายน	2561	458,990.6
กรกฎาคม	2561	436,533.9
สิงหาคม	2561	514,537.9
กันยายน	2561	497,516.0
ตุลาคม	2561	470,157.4
พฤศจิกายน	2561	509,191.8
ธันวาคม	2561	470,298.4

ตารางที่ ก-5 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Artificial Neural Network

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	446,308.1
กุมภาพันธ์	2561	451,089.9
มีนาคม	2561	532,636.1
เมษายน	2561	531,673.7
พฤษภาคม	2561	487,604.6
มิถุนายน	2561	482,816.2
กรกฎาคม	2561	481,953.4
สิงหาคม	2561	542,978.9
กันยายน	2561	532,503.4
ตุลาคม	2561	471,153.8
พฤศจิกายน	2561	512,679.4
ธันวาคม	2561	446,308.1

ตารางที่ ก-6 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Support Vector Regression

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	476,203.3
กุมภาพันธ์	2561	468,837.3
มีนาคม	2561	493,015.2
เมษายน	2561	492,635.1
พฤษภาคม	2561	480,238.2
มิถุนายน	2561	477,667.0
กรกฎาคม	2561	464,074.6
สิงหาคม	2561	493,322.5
กันยายน	2561	492,249.0
ตุลาคม	2561	460,370.3
พฤศจิกายน	2561	493,179.4
ธันวาคม	2561	405,499.6

ตารางที่ ก-7 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Random Forest

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	476,203.3
กุมภาพันธ์	2561	468,837.3
มีนาคม	2561	493,015.2
เมษายน	2561	492,635.1
พฤษภาคม	2561	480,238.2
มิถุนายน	2561	477,667.0
กรกฎาคม	2561	464,074.6
สิงหาคม	2561	493,322.5
กันยายน	2561	492,249.0
ตุลาคม	2561	460,370.3
พฤศจิกายน	2561	493,179.4
ธันวาคม	2561	405,499.6

ตารางที่ ก-8 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ eXtreme Gradient Boosting

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	472,078.2
กุมภาพันธ์	2561	470,553.6
มีนาคม	2561	494,342.9
เมษายน	2561	538,496.6
พฤษภาคม	2561	443,552.8
มิถุนายน	2561	442,029.6
กรกฎาคม	2561	447,774.3
สิงหาคม	2561	542,603.8
กันยายน	2561	495,373.7
ตุลาคม	2561	471,645.2
พฤศจิกายน	2561	495,373.7
ธันวาคม	2561	400,544.2

ตารางที่ ก-9 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบ Light Gradient Boosting Machine

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	472,736.9
กุมภาพันธ์	2561	451,117.0
มีนาคม	2561	507,369.5
เมษายน	2561	507,369.5
พฤษภาคม	2561	451,117.0
มิถุนายน	2561	451,117.0
กรกฎาคม	2561	451,117.0
สิงหาคม	2561	507,369.5
กันยายน	2561	507,369.5
ตุลาคม	2561	507,369.5
พฤศจิกายน	2561	507,369.5
ธันวาคม	2561	451,117.0

ตารางที่ ก-10 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	461,097.9
กุมภาพันธ์	2561	448,642.7
มีนาคม	2561	530,161.1
เมษายน	2561	520,045.0
พฤษภาคม	2561	486,746.3
มิถุนายน	2561	480,877.1
กรกฎาคม	2561	480,155.0
สิงหาคม	2561	539,766.8
กันยายน	2561	535,499.3
ตุลาคม	2561	464,165.6
พฤศจิกายน	2561	494,307.0
ธันวาคม	2561	398,548.3

ตารางที่ ก-11 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	467,894.9
กุมภาพันธ์	2561	469,884.7
มีนาคม	2561	534,249.3
เมษายน	2561	540,182.1
พฤษภาคม	2561	479,105.6
มิถุนายน	2561	477,049.0
กรกฎาคม	2561	478,299.2
สิงหาคม	2561	539,917.9
กันยายน	2561	535,026.2
ตุลาคม	2561	473,456.6
พฤศจิกายน	2561	486,365.6
ธันวาคม	2561	397,215.6

ตารางที่ ก-12 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	462,284.0
กุมภาพันธ์	2561	501,349.0
มีนาคม	2561	479,303.2
เมษายน	2561	521,383.8
พฤษภาคม	2561	445,317.0
มิถุนายน	2561	443,318.9
กรกฎาคม	2561	450,022.4
สิงหาคม	2561	521,383.8
กันยายน	2561	501,188.6
ตุลาคม	2561	455,690.7
พฤศจิกายน	2561	480,390.8
ธันวาคม	2561	398,932.0

ตารางที่ ก-13 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	464,871.8
กุมภาพันธ์	2561	495,788.7
มีนาคม	2561	513,932.0
เมษายน	2561	527,766.3
พฤษภาคม	2561	475,446.6
มิถุนายน	2561	471,538.0
กรกฎาคม	2561	472,619.7
สิงหาคม	2561	543,609.4
กันยายน	2561	522,539.1
ตุลาคม	2561	468,005.7
พฤศจิกายน	2561	465,951.1
ธันวาคม	2561	396,109.9

ตารางที่ ก-14 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	461,606.1
กุมภาพันธ์	2561	434,406.5
มีนาคม	2561	536,866.1
เมษายน	2561	534,202.2
พฤษภาคม	2561	456,141.6
มิถุนายน	2561	438,142.8
กรกฎาคม	2561	442,618.0
สิงหาคม	2561	538,571.9
กันยายน	2561	530,826.1
ตุลาคม	2561	498,777.0
พฤศจิกายน	2561	530,417.4
ธันวาคม	2561	407,281.7

ตารางที่ ก-15 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	471,328.8
กุมภาพันธ์	2561	453,165.5
มีนาคม	2561	529,835.9
เมษายน	2561	538,871.1
พฤษภาคม	2561	456,168.4
มิถุนายน	2561	458,194.2
กรกฎาคม	2561	459,702.6
สิงหาคม	2561	544,605.9
กันยายน	2561	529,835.9
ตุลาคม	2561	482,050.6
พฤศจิกายน	2561	521,949.7
ธันวาคม	2561	395,389.7

ตารางที่ ก-16 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	477,113.5
กุมภาพันธ์	2561	453,247.4
มีนาคม	2561	523,711.5
เมษายน	2561	525,940.6
พฤษภาคม	2561	443,506.5
มิถุนายน	2561	435,223.7
กรกฎาคม	2561	439,361.3
สิงหาคม	2561	525,940.6
กันยายน	2561	523,711.5
ตุลาคม	2561	478,761.2
พฤศจิกายน	2561	523,711.5
ธันวาคม	2561	402,331.1

ตารางที่ ก-17 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ Random Forest เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	469,522.3
กุมภาพันธ์	2561	447,495.7
มีนาคม	2561	531,996.1
เมษายน	2561	539,287.5
พฤษภาคม	2561	450,769.8
มิถุนายน	2561	446,892.4
กรกฎาคม	2561	447,823.2
สิงหาคม	2561	542,184.5
กันยายน	2561	526,177.4
ตุลาคม	2561	487,633.3
พฤศจิกายน	2561	524,958.5
ธันวาคม	2561	399,013.0

ตารางที่ ก-18 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ Random Forest โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	450,419.7
กุมภาพันธ์	2561	439,031.5
มีนาคม	2561	539,095.9
เมษายน	2561	539,095.9
พฤษภาคม	2561	445,042.0
มิถุนายน	2561	468,412.8
กรกฎาคม	2561	468,412.8
สิงหาคม	2561	545,180.6
กันยายน	2561	539,095.9
ตุลาคม	2561	500,918.1
พฤศจิกายน	2561	535,499.9
ธันวาคม	2561	412,256.7

ตารางที่ ก-19 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	478,188.1
กุมภาพันธ์	2561	443,587.8
มีนาคม	2561	531,109.1
เมษายน	2561	531,109.1
พฤษภาคม	2561	448,379.4
มิถุนายน	2561	465,863.0
กรกฎาคม	2561	465,863.0
สิงหาคม	2561	546,060.2
กันยายน	2561	531,109.1
ตุลาคม	2561	481,140.7
พฤศจิกายน	2561	516,440.9
ธันวาคม	2561	404,990.6

ตารางที่ ก-20 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	460,996.1
กุมภาพันธ์	2561	446,654.5
มีนาคม	2561	531,961.9
เมษายน	2561	531,961.9
พฤษภาคม	2561	457,524.3
มิถุนายน	2561	440,007.7
กรกฎาคม	2561	440,007.7
สิงหาคม	2561	531,961.9
กันยายน	2561	531,961.9
ตุลาคม	2561	486,672.8
พฤศจิกายน	2561	531,961.9
ธันวาคม	2561	409,208.6

ตารางที่ ก-21 ผลการพยากรณ์สำหรับตรวจสอบตัวแบบผสม Artificial Neural Network, Random Forest และ eXtreme Gradient Boosting โดยใช้ตัวแบบ eXtreme Gradient Boosting เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2561	485,926.7
กุมภาพันธ์	2561	436,659.6
มีนาคม	2561	535,323.8
เมษายน	2561	535,323.8
พฤษภาคม	2561	442,692.6
มิถุนายน	2561	467,544.8
กรกฎาคม	2561	467,544.8
สิงหาคม	2561	551,920.5
กันยายน	2561	535,323.8
ตุลาคม	2561	485,214.5
พฤศจิกายน	2561	528,082.8
ธันวาคม	2561	406,740.2

ตารางที่ ก-22 ผลการพยากรณ์สำหรับทดสอบตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2562	470,342.1
กุมภาพันธ์	2562	491,285.0
มีนาคม	2562	488,376.9
เมษายน	2562	540,899.2
พฤษภาคม	2562	447,538.2
มิถุนายน	2562	445,511.3
กรกฎาคม	2562	451,083.3
สิงหาคม	2562	543,727.5
กันยายน	2562	496,383.5
ตุลาคม	2562	465,049.4
พฤศจิกายน	2562	490,972.1
ธันวาคม	2562	398,398.8

ตารางที่ ก-23 ผลการพยากรณ์สำหรับทดสอบตัวแบบผสม Artificial Neural Network, eXtreme Gradient Boosting และ Random Forest โดยใช้ตัวแบบ Artificial Neural Network เป็นตัวผสม

เดือน	ปี พ.ศ.	ผลการพยากรณ์ (ตัน)
มกราคม	2562	467,782.7
กุมภาพันธ์	2562	453,307.6
มีนาคม	2562	418,222.9
เมษายน	2562	393,228.4
พฤษภาคม	2562	447,203.9
มิถุนายน	2562	436,821.5
กรกฎาคม	2562	485,804.8
สิงหาคม	2562	402,404.6
กันยายน	2562	356,316.5
ตุลาคม	2562	436,299.2
พฤศจิกายน	2562	371,366.9
ธันวาคม	2562	414,566.3

ประวัติผู้เขียน

ชื่อ-สกุล	ชัยพฤกษ์ นิละนนท์
วัน เดือน ปี เกิด	14 พฤษภาคม 2535
สถานที่เกิด	จังหวัดชลบุรี
วุฒิการศึกษา	ปริญญาตรีวิศวกรรมศาสตร์ สาขาวิศวกรรมวัสดุ มหาวิทยาลัยเกษตรศาสตร์
ที่อยู่ปัจจุบัน	47 หมู่ ๖ บ้านร่วมก่อ เขตทวีวัฒนา แขวงทวีวัฒนา จังหวัด กรุงเทพมหานคร 10170



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY