

การประยุกต์ใช้ตัวแบบซัพพอร์ตเวกเตอร์แมชชีนและตัวแบบโครงข่ายประสาทเทียมร่วมกับวิธีการทำ
ให้เรียบแบบเอ็กซ์โปเนนเชียล



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต
สาขาวิชาสถิติ ภาควิชาสถิติ
คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2563
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

APPLICATION OF SUPPORT VECTOR MACHINE AND ARTIFICIAL NEURAL NETWORK ON
EXPONENTIAL SMOOTHING



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science in Statistics
Department of Statistics
FACULTY OF COMMERCE AND ACCOUNTANCY
Chulalongkorn University
Academic Year 2020
Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การประยุกต์ใช้ตัวแบบซัพพอร์ตเวกเตอร์แมชชีนและตัวแบบโครงข่ายประสาทเทียมร่วมกับวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียล
โดย	น.ส.แซนนี่ ชั่ว
สาขาวิชา	สถิติ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.นัท กุลวานิช

คณะพาณิชย์ศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้รับวิทยานิพนธ์ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

..... คณะบดีคณะพาณิชย์ศาสตร์และการ
บัญชี

(รองศาสตราจารย์ ดร.วิเลิศ ภูริวัชร)

คณะกรรมการสอบวิทยานิพนธ์

..... ประธานกรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.อักรินทร์ ไพบูลย์พานิช)

..... อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก

(ผู้ช่วยศาสตราจารย์ ดร.นัท กุลวานิช)

..... กรรมการ

(รองศาสตราจารย์ ดร.เสกสรร เกียรติสุไพบูลย์)

..... กรรมการภายนอกมหาวิทยาลัย

(ดร.อรุณี กำลั้ง)

แขนงนี้ ชื่อ : การประยุกต์ใช้ตัวแบบซัพพอร์ตเวกเตอร์แมชชีนและตัวแบบโครงข่ายประสาทเทียมร่วมกับวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียล. (APPLICATION OF SUPPORT VECTOR MACHINE AND ARTIFICIAL NEURAL NETWORK ON EXPONENTIAL SMOOTHING) อ.ที่ปรึกษาหลัก : ผศ. ดร.นัท กุลวานิช

การพยากรณ์อนุกรมเวลาเป็นการคาดคะเนผลลัพธ์จากข้อมูลในอดีต เพื่อเป็นแนวทางในการวางแผนการดำเนินงานด้านต่าง ๆ ในอนาคต งานวิจัยฉบับนี้ได้รวบรวมข้อมูลอนุกรมเวลาจากแหล่งข้อมูลต่าง ๆ ในประเทศไทยจำนวน 40 ชุด ทั้งปริมาณการผลิตสินค้า มูลค่าการจำหน่ายสินค้า ปริมาณเชื้อเพลิง ปริมาณน้ำในเขื่อน และจำนวนผู้ใช้บริการรถไฟฟ้า ซึ่งมีรูปแบบแนวโน้มและฤดูกาลของข้อมูลอนุกรมเวลาที่หลากหลาย สำหรับศึกษาการประยุกต์วิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) ในการพยากรณ์ และเปรียบเทียบความแม่นยำของผลการพยากรณ์อนุกรมเวลาที่ได้จาก 3 ตัวแบบ คือ วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสมระหว่างตัวแบบ ES ร่วมกับตัวแบบโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างตัวแบบ ES ร่วมกับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) โดยมีเกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error : RMSE) เป็นเกณฑ์ในการเปรียบเทียบความแม่นยำของตัวแบบ ผลการศึกษาพบว่าตัวแบบผสมระหว่างตัวแบบ ES ร่วมกับตัวแบบโครงข่ายประสาทเทียม (ES+ANN) มีความแม่นยำในการพยากรณ์อนุกรมเวลามากที่สุดสำหรับข้อมูลทั้ง 40 ชุด

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สาขาวิชา สถิติ
ปีการศึกษา 2563

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6081530226 : MAJOR STATISTICS

KEYWORD: Time-series data, Exponential Smoothing, Hybrid model

Sanny Chua : APPLICATION OF SUPPORT VECTOR MACHINE AND ARTIFICIAL NEURAL NETWORK ON EXPONENTIAL SMOOTHING. Advisor: Asst. Prof. NAT KULVANICH

Time-series forecasting is useful for the future strategic planning in many sectors by estimating future from previous values. This research has been gathering 40 time-series datasets from various data sources in Thailand such as production volumes, the volume of sales, amount of fuel, amount of water in the dam and number of BTS users which have different kinds of trend and seasonality patterns of time-series data. For studying the application of Exponential Smoothing (ES) and comparing time-series forecasting accuracy results from three models: ES, hybrid ES and Artificial Neural Network model (ES+ANN), hybrid ES and Support Vector Machine model (ES+SVM). The root mean square error (RMSE) is used as a criterion for comparing the predictive accuracy of three models. The results suggest that the hybrid ES+ANN model provides the most accurate forecast for all datasets.



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Field of Study: Statistics

Student's Signature

Academic Year: 2020

Advisor's Signature

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยความรู้ ความอนุเคราะห์ และความช่วยเหลืออย่างดียิ่งจาก ผู้ช่วยศาสตราจารย์ ดร.นันท กุลวานิช อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้มอบความรู้ โอกาส คำแนะนำและคำปรึกษาชี้แนะแนวทางในการทำวิจัย ทั้งยังช่วยชี้ข้อบกพร่องเพื่อปรับปรุงแก้ไข ตลอดจนให้คำแนะนำเมื่อพบปัญหาต่าง ๆ ที่เกิดขึ้นระหว่างการทำนิพนธ์ จนกระทั่งวิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงไปได้ด้วยดี ผู้วิจัยขอกราบขอบพระคุณท่านอาจารย์เป็นอย่างสูงไว้ ณ ที่นี้

ขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.อัครินทร์ ไพบูลย์พานิช ประธานกรรมการสอบวิทยานิพนธ์ รองศาสตราจารย์ ดร. เสกสรร เกียรติสุไพบูลย์ กรรมการสอบวิทยานิพนธ์ และ อ.อรุณี กำลั้ง กรรมการผู้ทรงคุณวุฒิภายนอก ที่ได้กรุณาสละเวลาเพื่อตรวจสอบข้อบกพร่อง ตลอดจนให้คำแนะนำที่เป็นประโยชน์แก่ผู้วิจัย เพื่อให้วิทยานิพนธ์ฉบับนี้สมบูรณ์มากยิ่งขึ้น อีกทั้งคณาจารย์ประจำภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัยทุกท่านที่ได้ให้โอกาสทางการศึกษา และถ่ายทอดวิชาความรู้ ทางด้านสถิติและการดำรงชีวิตให้แก่ผู้วิจัยจนกระทั่งสำเร็จการศึกษาในครั้งนี้

สุดท้ายนี้ผู้วิจัยขอกราบขอบพระคุณบิดา มารดา และครอบครัว ที่คอยสนับสนุน ช่วยเหลือ เป็นทั้งกำลังใจและแรงผลักดันที่ดีให้กับผู้วิจัยในการศึกษาจนสำเร็จลุล่วง และขอขอบคุณเพื่อน ๆ ที่คอยช่วยเหลือและให้คำแนะนำที่ดีกับผู้วิจัยตลอดมา

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญภาพ.....	ฉ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของการวิจัย.....	3
1.3 สมมติฐานของการวิจัย.....	3
1.4 ขอบเขตของการวิจัย.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	6
บทที่ 2 ทฤษฎี และกรอบแนวคิดที่เกี่ยวข้อง	7
2.1 วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Exponential Smoothing: ES)	7
2.1.1 วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Single Exponential Smoothing; SES)	8
2.1.2 วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double Exponential Smoothing).....	9
2.1.3 วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสามครั้ง (Triple Exponential Smoothing).....	9

2.2 โครงข่ายประสาทเทียม (Artificial neuron network: ANN)	15
2.2.1 หลักการทำงานของตัวแบบโครงข่ายประสาทเทียม	16
2.2.2 โครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้น (Multi-layer perceptron: MLP) .	17
2.2.3 การเรียนรู้แบบแพร่ย้อนกลับ (Back-propagation: BP).....	20
2.2.4 การเรียนรู้แบบ Resilient back propagation (Rprop).....	21
2.3 ตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (Support vector machine model: SVM).....	22
2.3.1 ตัวแบบซัพพอร์ทเวกเตอร์แมชชีนแบบเชิงเส้น	23
2.3.2 ตัวแบบซัพพอร์ทเวกเตอร์แมชชีนแบบไม่เป็นเชิงเส้น	25
2.3.3 การกำหนดขอบเขต SVM ในงานวิจัย	26
2.4 ตัวแบบผสม (Hybrid Model).....	27
2.5 การตรวจสอบความแม่นยำของการพยากรณ์.....	27
บทที่ 3 วิธีดำเนินงานวิจัย	28
3.1 ขั้นตอนในการดำเนินงานวิจัย	28
3.2 แผนผังการดำเนินงานวิจัย	33
บทที่ 4 ผลการวิจัย	36
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ	44
5.1 สรุปผลการวิจัย.....	44
5.2 ข้อเสนอแนะ.....	46
บรรณานุกรม.....	48
ภาคผนวก ก.....	50
ภาคผนวก ข.....	67
ประวัติผู้เขียน.....	76

สารบัญตาราง

	หน้า
ตารางที่ 1.1 แสดงรายชื่อชุดข้อมูลที่ใช้ในงานวิจัย	4
ตารางที่ 2.1 ตารางแสดงการจัดกลุ่มวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Gardner, 1987).....	12
ตารางที่ 2.2 ตารางแสดงสมการวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลตามลักษณะแนวโน้มและฤดูกาล	13
ตารางที่ 3.1 ชนิดของ ES Model, ชุดข้อมูล และตัวอย่างกราฟอนุกรมเวลาของ ES Model.....	28
ตารางที่ 4.1 ค่า RMSE ของชุดข้อมูลทดสอบจำนวน 40 ชุด.....	37
ตารางที่ 4.2 ผลการจัดอันดับความแม่นยำของวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสม ES+ANN และตัวแบบผสม ES+SVM สำหรับข้อมูลจำนวน 40 ชุด	42
ตารางที่ 4.3 ผลความแม่นยำในการพยากรณ์เมื่อแบ่งตามประเภท ES MODEL	43

สารบัญภาพ

หน้า

ภาพที่ 2.1 ตัวอย่างกราฟพยากรณ์ข้อมูลการผลิตน้ำมันประเทศซาอุดีอาระเบีย ปีค.ศ. 1996–2013 โดยวิธี SES.....	8
ภาพที่ 2.2 กราฟพยากรณ์ข้อมูลจำนวนผู้โดยสารเครื่องบิน ปีค.ศ. 1990–2016 โดยวิธี Holt.....	9
ภาพที่ 2.3 กราฟพยากรณ์ข้อมูลชาวต่างชาติที่มาเยือนประเทศออสเตรเลีย โดยวิธี Holt-Winters' additive method และ Holt-Winters' multiplicative	11
ภาพที่ 2.4 เซลล์ประสาทในสมองมนุษย์.....	16
ภาพที่ 2.5 การทำงานของโครงข่ายประสาทเทียม	17
ภาพที่ 2.6 โครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้น.....	17
ภาพที่ 2.7 การทำงานของโหนดในชั้นข้อมูลนำเข้า ชั้นซ่อน และชั้นผลลัพธ์	18
ภาพที่ 2.8 เทคนิคการแพร่แบบย้อนกลับ	20
ภาพที่ 2.9 ความกว้างของเส้นขอบเมื่อค่า C เปลี่ยนแปลง.....	24
ภาพที่ 2.10 (ซ้าย) ค่าที่อยู่นอก ϵ -intensive zone เป็นระยะ ξ_i และ ξ_i^* (ขวา) ภาพแสดง ϵ -intensive loss function.....	24
ภาพที่ 2.11 การแปลงลักษณะข้อมูลโดยใช้ kernel function	26
ภาพที่ 4.1 กราฟผลการพยากรณ์ข้อมูลชุดที่ 12 มีลักษณะข้อมูลแบบ ETS(A,N,N).....	39
ภาพที่ 4.2 กราฟผลการพยากรณ์ข้อมูลชุดที่ 4 มีลักษณะข้อมูลแบบ ETS(A,N,A).....	40
ภาพที่ 4.3 กราฟผลการพยากรณ์ข้อมูลชุดที่ 7 มีลักษณะข้อมูลแบบ ETS(A,N,M)	40
ภาพที่ 4.4 กราฟผลการพยากรณ์ข้อมูลชุดที่ 29 มีลักษณะข้อมูลแบบ ETS(A,A,N).....	40
ภาพที่ 4.5 กราฟผลการพยากรณ์ข้อมูลชุดที่ 1 มีลักษณะข้อมูลแบบ ETS(A,A,A)	41
ภาพที่ 4.6 กราฟผลการพยากรณ์ข้อมูลชุดที่ 11 มีลักษณะข้อมูลแบบ ETS(A,A,M)	41
ภาพที่ 4.7 กราฟผลการพยากรณ์ข้อมูลชุดที่ 23 มีลักษณะข้อมูลแบบ ETS(A,M,A)	41
ภาพที่ 4.8 กราฟผลการพยากรณ์ข้อมูลชุดที่ 2 มีลักษณะข้อมูลแบบ ETS(A,M,M).....	42



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

การพยากรณ์เป็นการคาดคะเนผลลัพธ์และแนวโน้มที่เกิดขึ้นในอนาคต เพื่อการวางแผนการดำเนินงานต่าง ๆ ทั้งในด้านการคมนาคม การผลิต การตลาดและธุรกิจการเงิน เป็นต้น โดยการพยากรณ์อนุกรมเวลาเป็นหนึ่งในวิธีทางสถิติที่มักใช้ในการพยากรณ์ โดยวิธีการนี้ใช้ข้อมูลที่ทราบในอดีตศึกษาหารูปแบบของข้อมูล เพื่อใช้ในการสร้างตัวแบบพยากรณ์ที่เหมาะสม และนำตัวแบบนั้นพยากรณ์ข้อมูลในอนาคต ดังนั้นจึงมีงานวิจัยที่สร้างและพัฒนาตัวแบบพยากรณ์อนุกรมเวลาในแบบต่าง ๆ เพื่อให้ตัวแบบมีความแม่นยำในการพยากรณ์ข้อมูลนั้น ๆ มากที่สุด

วิธีการหนึ่งที่นิยมใช้ในการพยากรณ์อนุกรมเวลา คือ วิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Exponential Smoothing: ES) ถูกคิดค้นในปีค.ศ. 1950 เป็นวิธีที่ให้ความสำคัญกับข้อมูลล่าสุดและลดความสำคัญของข้อมูลที่ระยะเวลาที่ไกลออกไป โดยสามารถแบ่งเป็นวิธีย่อยตามลักษณะข้อมูล ดังนี้ วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Single Exponential Smoothing) ใช้สำหรับข้อมูลที่มีการเคลื่อนไหวที่มีแนวโน้มไม่ชัดเจนและไม่มีรูปแบบฤดูกาล ในปีค.ศ. 1957 Holt ได้พัฒนาวิธีการพยากรณ์เพื่อใช้สำหรับข้อมูลที่มีการเคลื่อนไหวแบบมีแนวโน้มและไม่มีรูปแบบฤดูกาล ได้แก่ วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double Exponential Smoothing) และในปีค.ศ. 1960 Holt และ Winters ได้พัฒนาวิธีการพยากรณ์เป็นวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสามครั้ง (Triple Exponential Smoothing) สำหรับข้อมูลที่มีการเคลื่อนไหวแบบมีแนวโน้มและมีฤดูกาล

ซึ่งวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียลที่กล่าวมานั้นมีความสามารถในการอธิบายข้อมูลที่มีองค์ประกอบที่เป็นเส้นตรง (linear component) ได้ดี แต่โดยทั่วไปแล้วลักษณะข้อมูลที่พบส่วนใหญ่ นั้นมักประกอบด้วยข้อมูลทั้งแบบที่มีองค์ประกอบที่เป็นเส้นตรงและข้อมูลที่มีองค์ประกอบไม่เป็นเชิงเส้น (nonlinear component) โครงข่ายประสาทเทียม (Artificial neural network model: ANN) เป็นหนึ่งในวิธีที่นิยมใช้ในการพยากรณ์ข้อมูลที่ไม่เป็นเชิงเส้น ในปีค.ศ. 1943 McCulloch และ Pitts ได้มีการนำเสนอแนวคิดสร้างตัวแบบโดยเลียนแบบการทำงานของเครือข่ายประสาทในสมองมนุษย์ ยุคแรกๆของโครงข่ายประสาทโดย Rosenblatt ปี 1957 จะมีเพียงแค่ 1 ชั้น ไม่สามารถรับมือกับรูปแบบที่ซับซ้อนได้จึงไม่เป็นที่นิยม ต่อมาได้ถูกพัฒนาอย่างต่อเนื่องจนมี

กระบวนการคิดคำนวณ สามารถเรียนรู้รูปแบบข้อมูลที่มีความซับซ้อน และไม่จำเป็นต้องมีเงื่อนไขในการสร้างตัวแบบ ต่อมาในปี ค.ศ. 1995 Cortes และ Vapnik ได้มีการพัฒนาตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (Support vector machine model: SVM) โดยอาศัยหลักการหาสมการเส้นตรงสำหรับจำแนกข้อมูล ซึ่งทั้งโครงข่ายประสาทเทียมและตัวแบบซัพพอร์ทเวกเตอร์แมชชีนเป็นวิธีที่นิยมใช้ในการพยากรณ์ข้อมูลที่มีความซับซ้อน

วิธีการพยากรณ์ที่ได้กล่าวถึงข้างต้นนั้น แต่ละวิธีมีความเหมาะสมกับข้อมูลที่แตกต่างกัน โดย (ZHANG, 2003) ได้พัฒนาตัวแบบผสมเพื่อเป็นตัวแบบทางเลือกในการพยากรณ์อนุกรมเวลา โดยนำข้อดีของแต่ละตัวแบบมาใช้ในการอธิบายข้อมูล กล่าวคือ ข้อมูลที่มีองค์ประกอบเชิงเส้นตรง (linear component) จะใช้ตัวแบบ ARIMA (Autoregressive Integrated Moving Average) และในการอธิบายข้อมูลที่มีองค์ประกอบไม่เป็นเชิงเส้น (nonlinear component) จะใช้ตัวแบบโครงข่ายประสาทเทียมในการอธิบายข้อมูล จากนั้นนำค่าพยากรณ์ที่ได้จากตัวแบบทั้งสองส่วนมารวมกัน เพื่อพยากรณ์ข้อมูลที่ต้องการในอนาคต โดยพบว่าการใช้ตัวแบบผสมนี้ให้ความแม่นยำในการพยากรณ์ได้ดีกว่าตัวแบบเดี่ยว หลังจากนั้นจึงมีงานวิจัยที่ได้ศึกษาความแม่นยำในการพยากรณ์ของตัวแบบผสมแบบต่าง ๆ เพื่อเปรียบเทียบกับตัวแบบเดี่ยว เช่น ตัวแบบผสม ARIMA+SVM (ชญาสินี บุญมานะ, 2560), ตัวแบบผสม SARIMA+ANN และ SARIMA+SVM (อนันต์ทรัพย์สุข, 2560) ในงานวิจัยของอนุธิดาได้พัฒนาจากชญาสินีโดยใช้ตัวแบบ SARIMA ในการพยากรณ์อนุกรมเวลาที่มีฤดูกาลแทนการใช้ตัวแบบ ARIMA ทั้งสองงานวิจัยได้มีการใช้ข้อมูลจำลองและข้อมูลจริงเพียง 1 ชุดในการเปรียบเทียบความแม่นยำของตัวแบบ ซึ่งต่างได้ข้อสรุปเดียวกันว่าตัวแบบผสมให้ความแม่นยำในการพยากรณ์ได้ดีกว่าตัวแบบเดี่ยว

การศึกษาตัวแบบผสมโดยใช้วิธีการอื่นในการอธิบายข้อมูลที่เป็นเชิงเส้น เช่น ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบโครงข่ายประสาทเทียม (ES+ANN) Panigrahi และ Behera (Sibarama Panigrahi, 2017) เลือกใช้วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลในการอธิบายและพยากรณ์ข้อมูลเชิงเส้น อีกทั้งยังมีการเปรียบเทียบความแม่นยำของตัวแบบดังกล่าวกับตัวแบบผสมของ Zhang และตัวแบบอื่น โดยใช้ชุดข้อมูลอนุกรมเวลา 16 ชุดจากงานวิจัยของ Hyndman, R.J. (R. J. a. K. Hyndman, 2008) ผลการวิจัยพบว่าตัวแบบผสมของ Panigrahi ให้ความแม่นยำในการพยากรณ์มากที่สุดสำหรับชุดข้อมูล 7 ชุด จากข้อมูล 16 ชุด ส่วนตัวแบบของ Zhang มีความแม่นยำในการพยากรณ์มากที่สุดสำหรับชุดข้อมูลเพียง 3 ชุด

การศึกษาตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (ES+SVM) (Jinjun Tang, 2013) เลือกใช้วิธีการพยากรณ์ส่วนของข้อมูลที่เป็นเชิงเส้นโดยใช้วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลชนิดซ้ำสองครั้ง ประกอบด้วยการใช้ซัพพอร์ทเวกเตอร์แมชชีนในส่วนของคุณค่าที่ไม่เป็นเชิงเส้น ซึ่งในงานวิจัยนี้ใช้พยากรณ์ของสภาพคล่องของการจราจร

จากข้อมูลจริงเพียง 1 ชุดเท่านั้น ได้ข้อสรุปว่าตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้งและตัวแบบซัพพอร์ทเวกเตอร์แมชชีนนั้นสามารถลดความผิดพลาดในการพยากรณ์ เมื่อเทียบกับตัวแบบ ARIMA และวิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง

ดังนั้น ในงานวิจัยครั้งนี้ผู้วิจัยจึงสนใจที่จะศึกษาและเปรียบเทียบความแม่นยำของตัวแบบการพยากรณ์ข้อมูลอนุกรมเวลา โดยใช้ข้อมูลจริงที่มีลักษณะข้อมูลแบบต่างๆ ในการเปรียบเทียบความแม่นยำของตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล, ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (ES+SVM) โดยตรวจสอบความแม่นยำของค่าพยากรณ์จากการพิจารณารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) ซึ่งตัวแบบที่ดีที่สุดของแต่ละชุดข้อมูลจะมีค่า RMSE ต่ำที่สุด

1.2 วัตถุประสงค์ของการวิจัย

เพื่อเปรียบเทียบความแม่นยำของค่าพยากรณ์ในชุดข้อมูลจริงจำนวน 40 ชุด ที่ได้จากวิธีการวิเคราะห์อนุกรมเวลา 3 แบบคือ

- วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)
- ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN)
- ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (ES+SVM)

1.3 สมมติฐานของการวิจัย

การพยากรณ์ด้วยตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN), ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (ES+SVM) มีความแม่นยำในการพยากรณ์ข้อมูลสูงกว่าการพยากรณ์โดยใช้วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)

1.4 ขอบเขตของการวิจัย

ใช้ชุดข้อมูลจริงรายเดือนจำนวน 40 ชุดที่ได้จากรวบรวมข้อมูลจากแหล่งข้อมูลในประเทศไทย ได้แก่ เว็บไซต์กรมการค้าภายใน การไฟฟ้าฝ่ายผลิตแห่งประเทศไทย สำนักงานเศรษฐกิจอุตสาหกรรม และบริษัทระบบขนส่งมวลชนกรุงเทพจำกัด(มหาชน) เพื่อใช้ในการศึกษาและเปรียบเทียบความแม่นยำของตัวแบบ โดยมีชุดข้อมูลดังนี้

ตารางที่ 1.1 แสดงรายชื่อชุดข้อมูลที่ใช้ในงานวิจัย

ชุดที่	ข้อมูล	หน่วย	จำนวนจุดเวลา
1	จำนวนผู้ใช้รถไฟฟ้า BTS ตั้งแต่ปีพ.ศ. 2552-2561	ล้านคน	120
2	ปริมาณการใช้ NATURAL GAS ตั้งแต่ปีพ.ศ. 2543-2554	MMSCF	144
3	ปริมาณการใช้ไฟฟ้า ตั้งแต่ปีพ.ศ. 2552-2561	unit(GWh)	120
4	ปริมาณการผลิต PE ตั้งแต่ปีพ.ศ. 2549-2558	พันตัน	120
5	ปริมาณการผลิต Propylene ตั้งแต่ปีพ.ศ. 2551-2558	พันตัน	96
6	ปริมาณการผลิตกระจกแผ่น ตั้งแต่ปีพ.ศ. 2547-2558	พันตัน	144
7	ปริมาณการผลิตกากน้ำตาล ตั้งแต่ปีพ.ศ. 2543-2558	พันตัน	192
8	ปริมาณการผลิตก๊าซหุงต้ม ตั้งแต่ปีพ.ศ. 2547-2558	ล้านลิตร	144
9	ปริมาณการผลิตเครื่องเรือนที่ทำด้วยไม้ ตั้งแต่ปีพ.ศ. 2543-2558	พันชิ้น	192
10	ปริมาณการผลิตน้ำตาลทรายดิบ ตั้งแต่ปีพ.ศ. 2543-2558	พันตัน	192
11	ปริมาณการผลิตน้ำมันดีเซลหมุนเร็ว ตั้งแต่ปีพ.ศ. 2543-2558	ล้านลิตร	192
12	ปริมาณการผลิตน้ำมันหล่อลื่น ตั้งแต่ปีพ.ศ. 2547-2558	ล้านลิตร	144
13	ปริมาณการผลิตน้ำอัดลม ตั้งแต่ปีพ.ศ. 2547-2558	ล้านลิตร	144
14	ปริมาณการผลิตแบตเตอรี่สำหรับรถยนต์ และ จักรยานยนต์ ตั้งแต่ปีพ.ศ. 2543-2558	พันหม้อ	192

ชุดที่	ข้อมูล	หน่วย	จำนวนจุดเวลา
15	ปริมาณการผลิตสับประรดกระป๋อง ตั้งแต่ปีพ.ศ. 2544-2558	พันตัน	180
16	ปริมาณการผลิตสายไฟฟ้า ตั้งแต่ปีพ.ศ. 2543-2558	พันตัน	192
17	ปริมาณการผลิตเหล็กเส้นกลม ตั้งแต่ปีพ.ศ. 2543-2558	พันตัน	192
18	ปริมาณการผลิตแอม ตั้งแต่ปีพ.ศ. 2547-2558	ตัน	144
19	ปริมาณน้ำไหลเข้าเขื่อนภูมิพล ตั้งแต่ปีพ.ศ. 2540-2561	ล้านลบ.ม.	264
20	มูลค่าการจำหน่ายกระดาษพิมพ์เขียน ตั้งแต่ปีพ.ศ. 2547-2558	ล้านบาท	144
21	มูลค่าการจำหน่ายกระเบื้องปูพื้น-บุผนัง ตั้งแต่ปีพ.ศ. 2547-2558	ล้านบาท	144
22	มูลค่าการจำหน่ายกึ่งแข็งแข็ง ตั้งแต่ปีพ.ศ. 2543-2558	ล้านบาท	192
23	มูลค่าการจำหน่ายถุงพลาสติก ตั้งแต่ปีพ.ศ. 2547-2558	ล้านบาท	144
24	มูลค่าการจำหน่ายนมพร้อมดื่ม ตั้งแต่ปีพ.ศ. 2544-2558	ล้านบาท	180
25	มูลค่าการจำหน่ายขนมปังสำเร็จรูป ตั้งแต่ปีพ.ศ. 2544-2558	ล้านบาท	180
26	มูลค่าการจำหน่ายผ้าทอฝ้าย ตั้งแต่ปีพ.ศ. 2543-2558	ล้านบาท	192
27	มูลค่าการจำหน่ายอิฐทนไฟ ตั้งแต่ปีพ.ศ. 2549-2558	ล้านบาท	120
28	มูลค่าการจำหน่ายไอศกรีม ตั้งแต่ปีพ.ศ. 2543-2558	ล้านบาท	192

ชุดที่	ข้อมูล	หน่วย	จำนวนจุดเวลา
29	มูลค่าการนำเข้า ตั้งแต่ปีพ.ศ. 2554-2560	ล้านบาท	84
30	มูลค่าการส่งออก ตั้งแต่ปีพ.ศ. 2554-2560	ล้านบาท	84
31	ราคากะหล่ำดอกคละ ตั้งแต่ปีพ.ศ. 2551-2561	บาท/กก.	132
32	ราคาไก่สดชำแหละ น่อง ตะโพก ตั้งแต่ปีพ.ศ. 2551-2561	บาท/กก.	132
33	ราคาไข่ไก่เบอร์ 1 ตั้งแต่ปีพ.ศ. 2551-2561	บาท/ฟอง	132
34	ราคาพริกสดชี้ฟ้า ตั้งแต่ปีพ.ศ. 2551-2561	บาท/ขีด	132
35	ราคามะนาวเบอร์ 3-4 ตั้งแต่ปีพ.ศ. 2552-2561	บาท/ผล	120
36	ราคามันฝรั่งเกรดเอ ตั้งแต่ปีพ.ศ. 2551-2561	บาท/กก.	132
37	ราคาส้มเขียวหวานรังสิตเบอร์ 5 ตั้งแต่ปีพ.ศ. 2551-2561	บาท/กก.	132
38	ราคาสุกรชำแหละ เนื้อสัน สันใน ตั้งแต่ปีพ.ศ. 2551-2561	บาท/กก.	132
39	ราคาหอมแดงภาคเหนือ ตัดจุก หัวใหญ่ ตั้งแต่ปีพ.ศ. 2551-2561	บาท/กก.	132
40	ราคาหัวผักกาดคละ ตั้งแต่ปีพ.ศ. 2551-2561	บาท/กก.	132

1.5 ประโยชน์ที่คาดว่าจะได้รับ

งานวิจัยนี้สามารถเปรียบเทียบความแม่นยำของการพยากรณ์ของวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลเพียงอย่างเดียว, ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม(ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ตเวกเตอร์แมชชีน(ES+SVM) จากการพยากรณ์โดยใช้ข้อมูลจริง เพื่อเป็นแนวทางสำหรับนักวิเคราะห์ในการเลือกเทคนิคการพยากรณ์ข้อมูลอนุกรมเวลาต่อไปในอนาคตได้

บทที่ 2

ทฤษฎี และกรอบแนวคิดที่เกี่ยวข้อง

ทฤษฎีพื้นฐานและแนวคิดที่เกี่ยวข้องในการศึกษางานวิจัยนี้ ผู้วิจัยได้แบ่งออกเป็น 5 หัวข้อหลัก ได้แก่ วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบโครงข่ายประสาทเทียม (ANN), ตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM), ตัวแบบผสม (Hybrid Model) และเกณฑ์ที่ใช้ในการตัดสินใจ โดยมีรายละเอียดดังต่อไปนี้

2.1 วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Exponential Smoothing: ES)

(R. J. Hyndman, & Athanasopoulos, G., 2018) จากวิธีการพยากรณ์อนุกรมเวลาโดยวิธีของนาอิวฟ์ (Naïve Method) คือ ค่าในอนาคตทั้งหมดจะมีค่าเท่ากับค่าข้อมูลที่เก็บมาล่าสุด โดยวิธีการนี้เป็นวิธีที่ให้ความสำคัญกับข้อมูลล่าสุดเพียงข้อมูลเดียวและไม่ได้ใช้ข้อมูลในอดีต ณ จุดเวลาอื่นในการพยากรณ์ข้อมูลในอนาคต ดังสมการ

$$\hat{y}_{t+h} = \hat{y}_t$$

และจาก Average Method ซึ่งเป็นวิธีที่ให้ความสำคัญกับข้อมูลในอดีตเท่า ๆ กัน ซึ่งก็คือเป็นการพยากรณ์ที่ให้น้ำหนักแก่ข้อมูลในอดีตเท่ากันทุกข้อมูล เพื่อหาข้อมูลในอนาคต ดังสมการ

$$\hat{y}_{t+h} = \frac{1}{T} \sum_{t=1}^T y_t$$

ดังนั้นจากทั้งสองวิธีจึงต้องการหาวิธีที่สมเหตุสมผลสำหรับการพยากรณ์ คือ ต้องการการพยากรณ์ที่ให้ความสำคัญกับข้อมูลล่าสุดและลดความสำคัญของข้อมูลที่ระยะเวลาที่ไกลออกไป เรียกอีกอย่างว่าการหาค่าเฉลี่ยแบบถ่วงน้ำหนัก ซึ่งเป็นหลักการของวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล คือ การให้น้ำหนักลดลงแบบเอ็กซ์โปเนนเชียล องค์ประกอบของตัวแบบประกอบด้วย 3 องค์ประกอบ คือ ส่วนที่เป็นความคลาดเคลื่อน (error), ประเภทของแนวโน้ม (trend) และประเภทของฤดูกาล (seasonal)

โดยวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลมีหลายวิธี (ดุรงค์วัฒนา, 2537) เช่น

2.1.1 วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Single Exponential Smoothing; SES)

เหมาะสำหรับข้อมูลที่มีการเคลื่อนไหวอยู่ในระดับคงที่ (Horizontal data) มีแนวโน้มและฤดูกาลที่ไม่ชัดเจน วิธีนี้มีค่าถ่วงน้ำหนักหรือค่าคงที่ปรับเรียบ (smoothing constant) คือ α ซึ่งมีค่าอยู่ระหว่าง 0 ถึง 1 มีค่า l_t เป็นค่า Level equation ซึ่งให้ค่าประมาณของระดับของอนุกรมเวลาแต่ละจุด และสมการพยากรณ์จะมีค่าเท่ากับ Level equation ซึ่งองค์ประกอบของวิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียล (SES) นี้ นำไปใช้ประโยชน์ในการพยากรณ์ได้น้อย แต่เป็นรูปแบบที่ง่ายที่สุดและสามารถเพิ่มองค์ประกอบอื่น ๆ ในตัวแบบได้

$$\text{Level equation: } l_t = \alpha y_{t-1} + (1-\alpha)l_{t-1}$$

$$\text{สมการพยากรณ์: } \hat{y}_{t+h} = l_t$$

การประมาณค่าพารามิเตอร์ α ของตัวแบบหาได้จากการค่าที่น้อยที่สุดของผลบวกกำลังสองของค่าคลาดเคลื่อน (Sum of Squared Errors; SSE) ดังสมการ

$$\text{SSE} = \sum_{t=1}^T (\hat{y}_t - y_{t+1})^2 = \sum_{t=1}^T e_t^2$$



ภาพที่ 2.1 ตัวอย่างกราฟพยากรณ์ข้อมูลการผลิตน้ำมันประเทศซาอุดีอาระเบีย
ปีค.ศ. 1996-2013 โดยวิธี SES

(ที่มา: https://otexts.com/fpp2/fpp_files/figure-html/ses-1.png)

2.1.2 วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง (Double Exponential Smoothing)


เป็นวิธีที่ถูกพัฒนาจากวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล โดย Holt ในปีค.ศ.1957 เพื่อใช้ในการพยากรณ์หาแนวโน้มของผลผลิต สินค้าคงคลังและกำลังแรงงาน ซึ่งตัวแบบนี้เหมาะสำหรับข้อมูลที่มีการเคลื่อนไหวแบบมีแนวโน้มและไม่มีการเคลื่อนไหวแบบฤดูกาล มีค่าคงที่ปรับเรียบ (α) และค่าปรับเรียบแนวโน้ม (β) โดยแต่ละค่ามีค่าอยู่ระหว่าง 0 ถึง 1

$$\text{Level equation: } l_t = \alpha y_t + (1-\alpha)(l_{t-1} + b_{t-1})$$

$$\text{Trend equation: } b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1}$$

$$\text{สมการพยากรณ์: } \hat{y}_{t+h} = l_t + hb_t$$

โดย h คือ จำนวนจุดเวลาที่ต้องการพยากรณ์



ภาพที่ 2.2 กราฟพยากรณ์ข้อมูลจำนวนผู้โดยสารเครื่องบิน ปีค.ศ. 1990–2016 โดยวิธี Holt (ที่มา: https://otexts.com/fpp2/fpp_files/figure-html/dampedtrend-1.png)

2.1.3 วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสามครั้ง (Triple Exponential Smoothing)

เป็นวิธีที่ถูกคิดค้นโดย Holt และ Winters ในปีค.ศ. 1960 ซึ่งเป็นการต่อยอดวิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียลซ้ำสองครั้ง เพื่อให้วิธีการพยากรณ์เหมาะสำหรับข้อมูลที่มี

การเคลื่อนไหวแบบมีแนวโน้มและมีฤดูกาล โดยมีค่าปรับเรียบข้อมูล (α) , ค่าปรับเรียบแนวโน้ม (β) และค่าปรับเรียบฤดูกาล (γ) โดยแต่ละค่ามีค่าอยู่ระหว่าง 0 ถึง 1

- Holt-Winters' additive method ใช้เมื่อลักษณะการเคลื่อนไหวฤดูกาลมีแนวโน้มคงที่

$$\text{Level equation: } l_t = \alpha(y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1})$$

$$\text{Trend equation: } b_t = \beta^*(l_t - l_{t-1}) + (1-\beta^*)b_{t-1}$$

$$\text{Seasonal equation: } s_t = \gamma(y_t - l_{t-1} + b_{t-1}) + (1-\gamma)s_{t-m}$$

$$\text{สมการพยากรณ์: } \hat{y}_{t+h} = l_t + hb_t + s_{t+h-m(k+1)}$$

โดย h คือ จำนวนจุดเวลาที่ต้องการพยากรณ์

m คือ จำนวนฤดูกาลของข้อมูล เช่น ค่า m=4 สำหรับข้อมูลที่เป็นรายไตรมาส, m=12 สำหรับข้อมูลชนิดรายเดือน

k คือ จำนวนเต็มที่ได้จาก (h-1)/m

- Holt-Winters' multiplicative method ใช้เมื่อลักษณะการเคลื่อนไหวฤดูกาลมีแนวโน้มเชิงพหุ

$$\text{Level equation: } l_t = \alpha \frac{y_t}{s_{t-m}} + (1-\alpha)(l_{t-1} + b_{t-1})$$

$$\text{Trend equation: } b_t = \beta^*(l_t - l_{t-1}) + (1-\beta^*)b_{t-1}$$


$$\text{Seasonal equations: } s_t = \gamma \frac{y_t}{l_{t-1} + b_{t-1}} + (1-\gamma)s_{t-m}$$

$$\text{สมการพยากรณ์: } \hat{y}_{t+h} = (l_t + hb_t)s_{t+h-m(k+1)}$$

โดย h คือ จำนวนจุดเวลาที่ต้องการพยากรณ์

m คือ จำนวนฤดูกาลของข้อมูล เช่น ค่า m=4 สำหรับข้อมูลที่เป็นรายไตรมาส, m=12 สำหรับข้อมูลชนิดรายเดือน










k คือ จำนวนเต็มที่ได้จาก (h-1)/m



ภาพที่ 2.3 กราฟการพยากรณ์ข้อมูลชาวต่างชาติที่มาเยือนประเทศออสเตรเลีย
โดยวิธี Holt-Winters' additive method และ Holt-Winters' multiplicative
(ที่มา: https://otexts.com/fpp2/fpp_files/figure-html/7-HW-1.png)

(Pegels, 1969) มีการจัดกลุ่มวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลออกเป็น 9 แบบตามองค์ประกอบของข้อมูล โดยส่วนที่เป็นแนวโน้ม (Trend Component) สามารถแบ่งออกเป็นตัวแบบที่ไม่มีแนวโน้ม (None trend), แนวโน้มเป็นเชิงบวก (Additive trend) และแนวโน้มเป็นเชิงพหุ (Multiplicative trend) ในส่วนที่เป็นฤดูกาล (Seasonal Component) สามารถแบ่งออกเป็นตัวแบบที่ไม่มีแนวโน้ม (None seasonal), ฤดูกาลที่เป็นเชิงบวก (Additive seasonal) และฤดูกาลที่เป็นเชิงพหุ (Multiplicative seasonal) ดังตารางที่ 2.1 ที่ได้แสดงลักษณะกราฟของแต่ละตัวแบบ และตารางที่ 2.2 แสดงสมการของตัวแบบแบ่งตามลักษณะแนวโน้มและฤดูกาล ซึ่งถูกเรียบเรียงอีกครั้งโดย Hydeman ในปี 2008 โดยแต่ละตัวแบบมี Error model ที่เป็นแบบ Additive error

ตารางที่ 2.1 ตารางแสดงการจัดกลุ่มวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (Gardner, 1987)

Trend Component	Seasonal Component		
	N (None)	A (Additive)	M (Multiplicative)
N (None)	N,N 	N,A 	N,M 
A (Additive)	A,N 	A,A 	A,M 
M (Multiplicative)	M,N 	M,A 	M,M 

ตารางที่ 2.2 ตารางแสดงสมการวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลตามลักษณะแนวโน้มและฤดูกาล

Trend Component	Seasonal Component		
	N (None)	A (Additive)	M (Multiplicative)
N (None)	$l_t = \alpha y_{t-1} + (1-\alpha)l_{t-1}$ $\hat{y}_{t+h} = l_t$	$l_t = \alpha y_{t-1} + (1-\alpha)l_{t-1}$ $s_t = \gamma(y_t - l_{t-1}) + (1-\gamma)s_{t-m}$ $\hat{y}_{t+h} = l_t + s_{t+h-m}$	$l_t = \alpha y_{t-1} + (1-\alpha)l_{t-1}$ $s_t = \gamma \left(\frac{y_t}{l_{t-1}} \right) + (1-\gamma)s_{t-m}$ $\hat{y}_{t+h} = l_t s_{t+h-m}$
A (Additive)	$l_t = \alpha y_t + (1-\alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta(l_t - l_{t-1}) + (1-\beta)b_{t-1}$ $s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1-\gamma)s_{t-m}$ $\hat{y}_{t+h} = l_t + hb_t$	$l_t = \alpha(y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1-\beta^*)b_{t-1}$ $s_t = \gamma(y_t - l_{t-1} - b_{t-1}) + (1-\gamma)s_{t-m}$ $\hat{y}_{t+h} = l_t + hb_t + s_{t+h-m}$	$l_t = \alpha \frac{y_t}{s_{t-m}} + (1-\alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta^*(l_t - l_{t-1}) + (1-\beta^*)b_{t-1}$ $s_t = \gamma \frac{y_t}{l_{t-1} + b_{t-1}} + (1-\gamma)s_{t-m}$ $\hat{y}_{t+h} = (l_t + hb_t)s_{t+h-m}$
M (Multiplicative)	$l_t = \alpha y_t + (1-\alpha)(l_{t-1}b_{t-1})$ $b_t = \beta^*(l_t/l_{t-1}) + (1-\beta^*)b_{t-1}$ $\hat{y}_{t+h} = l_t b_t$	$l_t = \alpha(y_t - s_{t-m}) + (1-\alpha)(l_{t-1} + b_{t-1})$ $b_t = \beta^*(l_t/l_{t-1}) + (1-\beta^*)b_{t-1}$ $s_t = \gamma(y_t - l_{t-1}b_{t-1}) + (1-\gamma)s_{t-m}$ $\hat{y}_{t+h} = l_t b_t^h + s_{t+h-m}$	$l_t = \alpha \frac{y_t}{s_{t-m}} + (1-\alpha)(l_{t-1}b_{t-1})$ $b_t = \beta^*(l_t/l_{t-1}) + (1-\beta^*)b_{t-1}$ $s_t = \gamma \frac{y_t}{l_{t-1}b_{t-1}} + (1-\gamma)s_{t-m}$ $\hat{y}_{t+h} = l_t b_t^h s_{t+h-m}$

ตัวแบบของวิธีทำเรียบแบบเอ็กซ์โปเนนเชียล มักถูกเรียกชื่อตัวแบบตามลักษณะของข้อมูล ซึ่งมักมีการเขียนเป็นสัญลักษณ์อย่างย่อ 3 ตัว โดยตัวแรกแสดงถึงลักษณะองค์ประกอบที่เป็น Error ได้แก่แบบ Additive(A), ตัวที่สองแสดงถึงลักษณะของแนวโน้ม (Trend) ได้แก่แบบ None(N), Additive(A) และ Multiplicative(M) ตัวที่สามแสดงถึงลักษณะของฤดูกาล (Seasonal) ได้แก่แบบ None(N), Additive(A), Multiplicative(M) ตามลำดับ ตัวอย่างการเขียนในรูปสัญลักษณ์ เช่น

- ตัวแบบ ETS(A,N,N) หมายถึงตัวแบบวิธีทำเรียบแบบเอ็กซ์โปเนนเชียลที่มี Additive error, None trend, None seasonal ซึ่งตัวแบบนี้เป็นที่รู้จักในชื่อ วิธีการพยากรณ์ทำให้เรียบแบบเอ็กซ์โปเนนเชียล (SES)

- ตัวแบบ ETS(A,A,N) ในชื่อ Holt's method
- ตัวแบบ ETS(A,A,A) ในชื่อ Holt's-Winters additive method
- ตัวแบบ ETS(A,A,M) ในชื่อ Holt's-Winters multiplicative method

การใช้วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลในการพยากรณ์ข้อมูลอนุกรมเวลา อาจพบว่าสามารถใช้ตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลได้หลายตัวแบบ จึงต้องมีเกณฑ์ในการพิจารณาว่าตัวแบบใดคือตัวแบบที่เหมาะสมมากที่สุด เช่น

1. เกณฑ์ข้อสนเทศของอาไคเคะ (Akaike's Information Criterion; AIC) คิดค้นโดย Akaike (1973: 267) มีเกณฑ์ในการเลือกตัวแบบคือตัวแบบที่ให้ค่า AIC น้อยกว่าจะเป็นตัวแบบที่เหมาะสมกว่า เกณฑ์นี้สามารถคัดเลือกตัวแบบได้ดีเมื่อตัวอย่างมีขนาดใหญ่ หากขนาดตัวอย่างใหญ่ไม่พออาจทำให้เกิดความผิดพลาดในการคัดเลือกตัวแบบสูง (McQuarrie et al., 1997: 285) มีสูตรการคำนวณดังนี้

$$AIC = -2 \log \left(\frac{SSE}{n} \right) + 2p$$

หรือ

$$AIC = -2 \log L + 2p$$

เมื่อ SSE คือ ผลบวกกำลังสองของค่าคลาดเคลื่อน

n คือ จำนวนข้อมูลที่พิจารณา

p คือ จำนวนพารามิเตอร์ในตัวแบบ

L คือ ฟังก์ชันภาวะน่าจะเป็นสูงสุด

2. เกณฑ์ข้อสนเทศของอาไคเคะปรับปรุง (Corrected for Akaike's Information Criterion; AICc) Hurvich and Tsai (1989: 297-307) ได้เสนอเกณฑ์ข้อสนเทศนี้เพื่อปรับแก้ความผิดพลาดจากการใช้เกณฑ์ AIC เมื่อตัวอย่างมีขนาดเล็ก โดยการปรับปรุงจากเกณฑ์ AIC ด้วยการเพิ่มตัวปรับแก้ความเอนเอียงคือ $\frac{2p(p+1)}{n-p-1}$ จึงได้สูตรคำนวณดังนี้

$$AICc = AIC + \frac{2p(p+1)}{n-p-1}$$

เมื่อ n คือ จำนวนข้อมูลที่พิจารณา

p คือ จำนวนพารามิเตอร์ในตัวแบบ

3. เกณฑ์ข้อสนเทศของเบส์ (Bayesian information criterion: BIC) เป็นเกณฑ์ที่ปรับจากเกณฑ์ AIC โดยพิจารณาขนาดตัวอย่างด้วย โดยมีเกณฑ์คือตัวแบบที่เหมาะสมกว่า คือตัวแบบที่มีค่า BIC ต่ำกว่า มีสูตรการคำนวณดังนี้

$$BIC = n \log \left(\frac{MSE}{n} \right) + \frac{2(p+2)n\sigma^2}{MSE} - \frac{2n^2\sigma^4}{MSE}$$

เมื่อ MSE คือ ค่าคลาดเคลื่อนกำลังสองเฉลี่ยของตัวแบบเต็มรูป (Full model)

n คือ จำนวนข้อมูลที่พิจารณา

p คือ จำนวนพารามิเตอร์ในตัวแบบ


σ คือ ค่าเบี่ยงเบนมาตรฐานของค่าคลาดเคลื่อน

โดยในงานวิจัยนี้เลือกใช้เกณฑ์ข้อสนเทศของอาไคเคะ (Akaike's Information Criterion; AIC) ในการเลือกตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล เนื่องจากข้อมูลอนุกรมเวลาที่ศึกษาส่วนใหญ่เป็นอนุกรมเวลาแบบระยะกลาง

2.2 โครงข่ายประสาทเทียม (Artificial neuron network: ANN)

แนวคิดเริ่มต้นของโครงข่ายประสาทเทียมได้มาจากการศึกษาความสามารถในการรับรู้ การตอบสนอง การคิดคำนวณที่ซับซ้อน การจดจำรูปแบบ และการสร้างความรู้ใหม่ของโครงข่ายไฟฟ้าชีวภาพในเซลล์สมองมนุษย์ ซึ่งโครงข่ายประสาทของมนุษย์นั้นเกิดจากการเชื่อมต่อระหว่างเซลล์ประสาทหรือนิวรอน (Neuron) จำนวนมากจนเกิดเป็นเครือข่ายที่ทำงานร่วมกันของเซลล์ประสาทในสมอง มีหลักการทำงาน คือ เมื่อเซลล์ประสาทได้รับการกระตุ้นจากสิ่งเร้าทั้งภายในและภายนอก กระแสประสาทนั้นจะส่งเข้าสู่เดนไดรต์ (Dendrite) ซึ่งเป็นใยประสาทที่นำกระแสประสาทเข้าสู่ตัวเซลล์ทำหน้าที่เป็นตัวรับข้อมูล และส่งต่อเข้าสู่นิวเคลียส (Nucleus) หากมีกระแสประสาทมากพอ นิวเคลียสจะกระตุ้นเซลล์อื่นผ่านทางใยประสาทที่ทำหน้าที่นำกระแสประสาทออกจากตัวเซลล์ เรียกว่า

แอกซอน (Axon) ต่อไป หรือก็คือหากกระแสประสาทที่ได้รับมีน้ำหนักมากกว่าค่าที่กำหนดแล้ว นิวรอนก็จะส่งกระแสประสาทออกไปยังนิวรอนอื่น ๆ ในโครงข่าย แต่หากกระแสประสาทนั้นมี น้ำหนักน้อยกว่าค่าที่กำหนดก็จะไม่เกิดการส่งกระแสต่อ



ภาพที่ 2.4 เซลล์ประสาทในสมองมนุษย์


(ที่มา: <https://simple.wikipedia.org/wiki/Neuron>)

ตัวแบบทางคณิตศาสตร์โครงข่ายประสาทเทียม ได้ถูกคิดค้นขึ้นโดย McCulloch และ Pitts ในปี ค.ศ. 1943 เพื่อเป็นเครื่องมือที่มีความสามารถในการเรียนรู้ที่ซับซ้อน มีการประมวลผลโดยมีความพยายามเลียนแบบกระบวนการทำงานของโครงข่ายประสาทในสมองมนุษย์ในด้านการเรียนรู้ การจดจำรูปแบบและการสร้างความรู้ใหม่ ทำให้ตัวแบบโครงข่ายประสาทเทียมเป็นที่นิยมในการพยากรณ์ข้อมูลที่ไม่เป็นเชิงเส้นตรง โดยโครงข่ายประสาทเทียมจะรวบรวมความรู้ผ่านกระบวนการเรียนรู้ (Learning process) และถูกจัดเก็บในรูปแบบค่าถ่วงน้ำหนัก (weight) อีกทั้งโครงข่ายประสาทเทียมมีข้อดี คือ เมื่อมีข้อมูลรบกวน โครงข่ายประสาทเทียมจะยังมีความแกร่ง (Robust) แต่มีข้อเสีย คือ การฝึกหัดโครงข่ายใช้ระยะเวลาานาน อีกทั้งมีความยากในการแปลความหมาย (ชญาณิน บุญมานะ, 2560: 43-44)

2.2.1 หลักการทำงานของตัวแบบโครงข่ายประสาทเทียม

หลักการทำงานของตัวแบบโครงข่ายประสาทเทียมเกิดขึ้นในหน่วยประมวลผลย่อย (node) เมื่อป้อนข้อมูลนำเข้าเข้าสู่โครงข่ายประสาทเทียม ข้อมูลนำเข้าแต่ละค่าจะถูกคูณด้วยค่าถ่วงน้ำหนัก ซึ่งได้มาจากการสุ่มสำหรับแต่ละค่าข้อมูลนำเข้า แล้วนำมารวมกัน จากนั้นส่งผ่านไปยังฟังก์ชันการกระตุ้น (Activation function) หรืออีกชื่อเรียกหนึ่งว่า ฟังก์ชันการแปลง (Transfer function) เพื่อให้

ได้มาซึ่งข้อมูลผลลัพธ์ที่ต้องการ ซึ่งในยุคแรกของโครงข่ายประสาทโดย Rosenblatt ปี 1957 จะเป็นเพียงแค่ 1 layer ไม่มีความซับซ้อน ดังรูป




ภาพที่ 2.5 การทำงานของโครงข่ายประสาทเทียม

(ที่มา: <http://www.theprojectspot.com/tutorial-post/introduction-to-artificial-neural-networks-part-1/7>)


2.2.2 โครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้น (Multi-layer perceptron: MLP)

จากการค้นพบวิธีโครงข่ายประสาทเทียมในยุคแรกได้เลิกนิยมไปช่วงหนึ่ง เนื่องจากโครงข่ายชนิดนั้นทำนายผลลัพธ์ที่ไม่ซับซ้อน จากนั้นถูกพัฒนาโดยการใช้โครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้นหรือการเพิ่มจำนวนชั้นซ่อนและเชื่อมต่อด้วยชั้นผลลัพธ์ เพื่อสามารถทำงานแบบไม่เป็นเชิงเส้นได้



ภาพที่ 2.6 โครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้น

โครงข่ายประเภนี้เป็นประเภทหนึ่งของ โครงข่ายประสาทแบบไปข้างหน้า (Feedforward neural network) มักใช้สำหรับงานที่มีความซับซ้อนและให้ผลที่ดี อีกทั้งนิยมใช้ในการพยากรณ์ ข้อมูลอนุกรมเวลา ประกอบด้วยโครงสร้าง 3 ชั้น ดังรูป



ภาพที่ 2.7 การทำงานของโหนดในชั้นข้อมูลนำเข้า ชั้นซ่อน และชั้นผลลัพธ์
(ที่มา: อนุธิตา, 2560)

- 1) ชั้นข้อมูลนำเข้า (Input layer) มีจำนวน 1 ชั้น เป็นชั้นที่รับข้อมูลนำเข้าที่อยู่ในรูปเชิงปริมาณที่โครงข่ายประสาทเทียมยอมรับได้
- 2) ชั้นซ่อน (Hidden layer) มีจำนวน 1 ชั้นขึ้นไป โดยไม่มีข้อกำหนดในการเลือกจำนวน Hidden neurons ตัวอย่างเช่น กำหนดใช้ $2n+1$ หรือ $2n$ โดยที่ n คือจำนวนโหนดนำเข้า (Zhang, 1998:44) เป็นต้น ซึ่งต้องทำการทดลองหาจำนวนที่เหมาะสมสำหรับข้อมูลนั้น ๆ โดยชั้นซ่อน 1 ชั้น ประกอบด้วยฟังก์ชันการทำงานดังนี้

2.1) ฟังก์ชันการรวม (Summation function) เป็นการคำนวณหาผลรวมของโหนดข้อมูลนำเข้าแต่ละตัวคูณด้วยค่าถ่วงน้ำหนัก (weight) ที่ได้จากการสุ่มค่าเพื่อเชื่อมโยงระหว่างชั้นข้อมูลนำเข้าและ โหนด Hidden neurons ในชั้นซ่อน ดังสมการ

$$net_j = \sum_{i=1}^N x_i w_{ij} + bias$$

โดย x_i คือ ข้อมูลนำเข้าที่ i , $i=1, \dots, N$


w_{ij} คือ ค่าถ่วงน้ำหนักที่เชื่อมโยงจากข้อมูลนำเข้าที่ i ไปยังโหนดในชั้นซ่อนที่ j ,

$j=1, \dots, J$

2.2) ฟังก์ชันการแปลง (Transfer function) เป็นส่วนที่ทำหน้าที่ปรับค่าผลรวมข้อมูลที่ได้จากฟังก์ชันการรวมว่าจะส่งข้อมูลออกไปแบบใด โดยมีฟังก์ชันการแปลงองค์ประกอบที่ไม่เป็นเชิงเส้น


- Sigmoid function : เป็นฟังก์ชันที่ทำหน้าที่แปลงข้อมูลให้มีค่าอยู่ระหว่าง 0 ถึง 1 ดังสมการ

$$f(x) = \frac{1}{1+e^{-x}}$$



- Tan-Sigmoid function หรือ Hyperbolic tangent function (tanh) มีความคล้ายคลึงกับ Sigmoid function ซึ่งจาก Sigmoid function จะเห็นว่ามีช่วงการแปลงที่แคบ ทำให้แม้ค่าเริ่มต้นจะเปลี่ยนแปลงไปมากหรือน้อย แต่ค่า gradient มีความเปลี่ยนแปลงไปจากเดิมเพียงเล็กน้อย ซึ่งก็จะทำให้โครงข่ายประสาทเทียมไม่สามารถเรียนรู้ได้อย่างมีประสิทธิภาพเท่าที่ควร tanh จึงได้ทำการแก้ไขปัญหานั้นด้วยการปรับระยะใหม่ของ sigmoid ให้มีช่วงกว้างมากขึ้น ให้ค่าที่ได้จากการแปลงอยู่ระหว่าง -1 ถึง 1 มีสมการดังนี้

$$f(x) = \tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{e^x - e^{-x}}{e^x + e^{-x}}$$



ดังนั้น ในงานวิจัยนี้จึงเลือกใช้ฟังก์ชันการแปลง คือ Tan-Sigmoid function (tanh) ในการแปลงค่าข้อมูลในชั้นซ่อน

- 3) ชั้นผลลัพธ์ (Output layer) มีจำนวน 1 ชั้นขึ้นไป ประกอบด้วยฟังก์ชันการทำงานดังนี้

3.1) ฟังก์ชันการรวม (Summation function) โดยคำนวณจากค่าผลรวมของผลคูณระหว่างโหนดและค่าถ่วงน้ำหนักของเส้นเชื่อมโยงแต่ละหน่วยจากชั้นซ่อนมายังชั้นผลลัพธ์ ดังสมการ

$$net_k = \sum_{j=1}^J y_j w_{jk} + bias$$

โดย w_{jk} คือ ค่าถ่วงน้ำหนักที่เชื่อมโยงจากโหนดในชั้นซ่อนที่ j ไปยังโหนดชั้นผลลัพธ์ที่ k , $k=1, \dots, K$

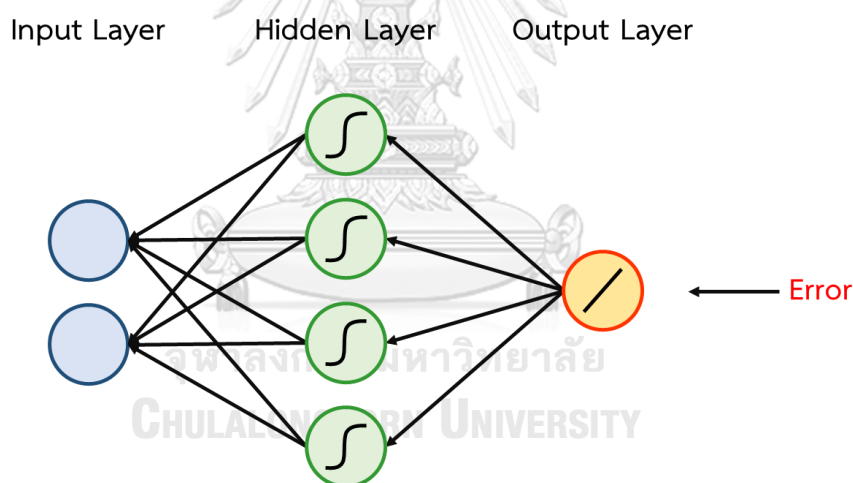
3.2) ฟังก์ชันการแปลง (Transfer function) ทำหน้าที่ในการปรับค่าผลรวมเป็นค่าพยากรณ์ที่ต้องการ การใช้ Sigmoid function หรือ Tan-Sigmoid function สามารถทำได้หากใช้

ในการพยากรณ์เชิงกลุ่ม หากเป็นการพยากรณ์ที่เป็นตัวเลขมักใช้ Linear Activation Function ซึ่งมีสมการดังนี้

$$y_k = f(\text{net}_k) = \text{net}_k$$

2.2.3 การเรียนรู้แบบแพร่ย้อนกลับ (Back-propagation: BP)

ในโครงข่ายประสาทเทียมแบบไปข้างหน้าหรือ Feed Forward จะรับข้อมูลจากชั้นข้อมูลนำเข้าสร้างค่าถ่วงน้ำหนัก แล้วประมวลผลผ่านชั้นซ่อนแล้วได้ผลลัพธ์ที่ชั้นผลลัพธ์ แต่เมื่อต้องการปรับค่าถ่วงน้ำหนักในแต่ละจุดเชื่อมโยง เพื่อให้ได้ค่าผลลัพธ์ที่แม่นยำมากยิ่งขึ้น Martin Riedmiller และ Heinrich Braun (Riedmiller, 1993) ได้กล่าวไว้ว่า การเรียนรู้แบบแพร่ย้อนกลับ (BP) เป็นการเรียนรู้ที่นิยมใช้ในการฝึกสอนโครงข่ายประสาทเทียมแบบเพอร์เซ็ปตรอนหลายชั้น (MLP) โดยมีกระบวนการในการปรับปรุงค่าถ่วงน้ำหนัก (weight) เพื่อให้ได้ข้อมูลผลลัพธ์ที่ใกล้เคียงกับข้อมูลเป้าหมาย



ภาพที่ 2.8 เทคนิคการแพร่แบบย้อนกลับ

หลักการของการเรียนรู้แบบแพร่ย้อนกลับ คือ นำข้อมูลผลลัพธ์ที่ได้จากโครงข่ายเปรียบเทียบกับข้อมูลเป้าหมาย (Target Data) เพื่อหาค่าความผิดพลาดหรือความคลาดเคลื่อนของข้อมูล สำหรับการใช้ในการแก้ไขค่าน้ำหนักที่เชื่อมโยงระหว่างโหนด โดยนำค่าความคลาดเคลื่อนนั้น ๆ กลับเข้าสู่โครงข่ายในชั้นผลลัพธ์ย้อนกลับมายังชั้นข้อมูลนำเข้า โดยกระบวนการนี้จะเป็นกระบวนการวนซ้ำ และจะหยุดเมื่อได้ค่าน้ำหนักที่ทำให้ฟังก์ชันความคลาดเคลื่อนมีค่าน้อยที่สุด (Zhang, 1988:38) เมื่อค่าถ่วงน้ำหนักเริ่มต้นที่ใช้ในโครงข่ายเข้าสู่กระบวนการฝึกสอนโครงข่าย ค่าถ่วงน้ำหนักใหม่จะถูกปรับดังสมการ ดังนี้

$$w_{ij}(t+1) = w_{ij}(t) - \eta \frac{\partial E}{\partial w_{jk}}(t)$$

โดย w_{jk} คือ ค่าถ่วงน้ำหนักจาก k ไปยัง j

η คือ อัตราการเรียนรู้ (learning rate)

$\frac{\partial E}{\partial w_{jk}}(t)$ คือ partial derivative ของฟังก์ชันค่าความคลาดเคลื่อนเทียบกับค่าถ่วงน้ำหนักที่เชื่อมโยงระหว่างโหนด k และ j

ในการตรวจสอบเพื่อหาค่าถ่วงน้ำหนักโครงข่ายประสาทเทียมที่เหมาะสมสำหรับข้อมูล สามารถคำนวณได้จากค่าคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) ของข้อมูลที่ได้การทำงานแต่ละรอบ หากค่า MSE นั้นสามารถยอมรับได้ให้จบการเรียนรู้ แต่ถ้าค่ามันยังไม่สามารถยอมรับได้ โครงข่ายจะทำการเรียนรู้ไปเรื่อยๆ หรือทำงานตามจำนวนรอบการทำงานที่ได้กำหนดไว้จนจบ โดยผลลัพธ์จากรอบการทำงานที่ให้ค่า MSE น้อยที่สุด คือค่าถ่วงน้ำหนักที่เหมาะสมที่สุด

จากสมการการปรับค่าถ่วงน้ำหนักที่ได้จากขนาดของ partial derivative และอัตราการเรียนรู้ ซึ่งอัตราการเรียนรู้เป็นค่าที่ส่งผลกระทบต่อประสิทธิภาพของการเรียนรู้แบบ BP หากกำหนดอัตราการเรียนรู้ที่มากเกินไปอาจทำให้ไม่ได้ค่าน้ำหนักที่ทำให้ค่าคลาดเคลื่อนของกระบวนการที่ต่ำสุด (Martin Riedmiller and Heinrich Braun, 1993) ดังนั้น หากต้องการให้การฝึกสอนมีประสิทธิภาพมากขึ้น มักจะกำหนดค่าอัตราการเรียนรู้ให้มิต่ำน้อย เพื่อให้มีความละเอียดในการหาค่าถ่วงน้ำหนักที่ทำให้ค่าคลาดเคลื่อนน้อยที่สุด ซึ่งทำให้ใช้ระยะเวลาเพิ่มขึ้นเพื่อหาค่าน้ำหนักที่เหมาะสม

2.2.4 การเรียนรู้แบบ Resilient back propagation (Rprop)

การเรียนรู้แบบ Rprop ได้ถูกพัฒนามาจากการเรียนรู้แบบ Back-Propagation (BP) โดย Martin Riedmiller และ Heinrich Braun ในปี 1993 ซึ่งมีความแตกต่างจากการเรียนรู้แบบ BP คือ การเรียนรู้ชนิดนี้ไม่ใช้ขนาดของ partial derivative ในการปรับค่าถ่วงน้ำหนัก แต่จะใช้เพียงเครื่องหมายในการปรับค่า ซึ่งทำให้การเรียนรู้แบบ Rprop ใช้เวลาน้อยกว่า BP และมีความแม่นยำมากกว่า (Navneel Prasad, 2013)

ขั้นตอนของการเรียนรู้แบบ Rprop คือ ในขั้นเริ่มต้นจะมีค่าเปลี่ยนแปลง (Δ_{jk}) สำหรับแต่ละค่าถ่วงน้ำหนัก จากนั้นจะถูกปรับค่าเปลี่ยนแปลงใหม่ ($\Delta_{jk}^{(t)}$) โดยจะถูกปรับค่าเพิ่มขึ้นด้วย η^+ หรือลดลง η^- โดยสังเกตจากการเปลี่ยนเครื่องหมายที่ได้จากการทำ partial derivative ของค่าคลาดเคลื่อนเก่าและค่าถ่วงน้ำหนัก ($\frac{\partial E^{(t-1)}}{\partial w_{jk}}$) และ partial derivative ของค่าคลาดเคลื่อนปัจจุบัน

และค่าถ่วงน้ำหนัก ($\frac{\partial E^{(t)}}{\partial w_{jk}}$) หากไม่มีการเปลี่ยนแปลงเครื่องหมาย ค่าเปลี่ยนแปลงเก่านั้นจะปรับด้วย η^+ แต่หากมีการเปลี่ยนเครื่องหมายค่าเปลี่ยนแปลงเก่านั้นจะถูกปรับด้วย η^- ดังนี้

$$\Delta_{jk}^{(t)} = \begin{cases} \eta^+ \cdot \Delta_{jk}^{(t-1)} & , \text{ ถ้า } \frac{\partial E^{(t-1)}}{\partial w_{jk}} \cdot \frac{\partial E^{(t)}}{\partial w_{jk}} > 0 \\ \eta^- \cdot \Delta_{jk}^{(t-1)} & , \text{ ถ้า } \frac{\partial E^{(t-1)}}{\partial w_{jk}} \cdot \frac{\partial E^{(t)}}{\partial w_{jk}} < 0 \\ \Delta_{jk}^{(t-1)} & , \text{ กรณีอื่นๆ} \end{cases}$$

โดย $0 < \eta^- < 1 < \eta^+$

จากนั้นกำหนดเครื่องหมายของค่าเปลี่ยนแปลงใหม่ $\Delta_{jk}^{(t)}$ เพื่อปรับทิศทางสำหรับค่าเปลี่ยนแปลงค่าถ่วงน้ำหนักใหม่ ($\Delta w_{jk}^{(t)}$) โดยสังเกตจากขนาด partial derivative ของค่าคลาดเคลื่อนปัจจุบันและค่าถ่วงน้ำหนัก กำหนดเครื่องหมายลบเมื่อไม่มีการเปลี่ยนแปลงเครื่องหมาย และกำหนดเครื่องหมายบวกเมื่อเครื่องหมายเปลี่ยนแปลง ดังสมการ

$$\Delta w_{jk}^{(t)} = \begin{cases} -\Delta_{jk}^{(t)} & , \text{ ถ้า } \frac{\partial E^{(t)}}{\partial w_{jk}} > 0 \\ +\Delta_{jk}^{(t)} & , \text{ ถ้า } \frac{\partial E^{(t)}}{\partial w_{jk}} < 0 \\ 0 & , \text{ กรณีอื่นๆ} \end{cases}$$

โดยค่าถ่วงน้ำหนักใหม่นั้นจะสามารถหาได้การค่าถ่วงน้ำหนักเดิมรวมกับค่าเปลี่ยนแปลงค่าถ่วงน้ำหนักใหม่ ดังสมการ

$$w_{jk}^{(t+1)} = w_{jk}^{(t)} + \Delta w_{jk}^{(t)}$$

งานวิจัยนี้ใช้โปรแกรม R ในการวิเคราะห์ข้อมูล ซึ่งได้มีการกำหนดค่าเริ่มต้น คือ $\eta^- = 0.5$ และ $\eta^+ = 1.2$ (Martin Riedmiller ,Heinrich Braun :1993, 588) ผู้วิจัยจึงเลือกใช้ตามค่าเริ่มต้นในโปรแกรม

2.3 ตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (Support vector machine model: SVM)

ตัวแบบซัพพอร์ตเวกเตอร์แมชชีนมีแนวคิดมาจากตัวแบบโครงข่ายประสาทเทียม ถูกพัฒนาโดย Vapnik เมื่อปี ค.ศ. 1995 โดยมีหลักการ คือ การหาเส้นที่ทำให้ค่าความกว้างของเส้นขอบที่มากที่สุด (Maximum Margin) เพื่อใช้แบ่งกลุ่มข้อมูลออกเป็น 2 กลุ่ม ซึ่งเป็นวิธีที่สามารถแยกข้อมูล

ได้โดยมีความผิดพลาดน้อย โดยมีซัพพอร์ตเวกเตอร์ (Support vector) เป็นตัวกำหนดขนาดของเส้นขอบระหว่างข้อมูลสองกลุ่ม หากข้อมูลมีการเปลี่ยนแปลงใด ๆ เส้นจำแนกก็ยังขึ้นอยู่กับซัพพอร์ตเวกเตอร์ซึ่งเป็นค่าความกว้างของเส้นขอบที่มากที่สุด และมีกระบวนการแปลงข้อมูลบนพื้นที่ข้อมูลนำเข้า (Input space) จากข้อมูลที่มีมิติต่ำ (Low dimension dataset) ให้อยู่ในรูปแบบของข้อมูลที่มีมิติสูง (High dimension dataset) เพื่อแบ่งกลุ่มข้อมูล

2.3.1 ตัวแบบซัพพอร์ตเวกเตอร์แมชชีนแบบเชิงเส้น

การหาฟังก์ชันเชิงเส้นตรง (linear function : $f(x)$) บนพื้นที่ข้อมูลคุณลักษณะ (Feature space) ที่มีระยะ ϵ มากที่สุด และมีค่าคลาดเคลื่อนน้อยที่สุด (Minimize error) การสร้างตัวแบบซัพพอร์ตเวกเตอร์แมชชีนสามารถใช้ในการวิเคราะห์การถดถอย (Regression analysis) และยังสามารถใช้สร้างตัวแบบในการพยากรณ์ข้อมูลอนุกรมเวลาได้ (Thissena, 2003) หาได้จากสมการ

$$f(x) = \langle w, x \rangle + b, \quad w \in \mathbb{R}^d, b \in \mathbb{R}$$

โดย w คือ เวกเตอร์ค่าถ่วงน้ำหนัก (weight)

b คือ bias

ซึ่งการคำนวณค่าที่ดีที่สุดสามารถหาได้จากสมการเส้นตรงที่ minimize cost function : $R_{SVM}(C)$ ดังสมการต่อไปนี้


$$\text{Minimize} \quad R_{SVM}(C) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n L_{\epsilon}(y_i - f(x_i, w))$$

$$L_{\epsilon}(y_i, f(x_i, w)) = \begin{cases} 0 & , |y_i - f(x_i, w)| \leq \epsilon \\ |y_i - f(x_i, w)| - \epsilon & , \text{otherwise} \end{cases}$$

$$\text{Subject to} \begin{cases} y_i - \langle w, x \rangle - b \leq \epsilon \\ \langle w, x \rangle + b - y_i \leq \epsilon \end{cases}$$

สมการข้างต้นประกอบด้วย


- Regularization term $\left(\frac{1}{2} \|w\|^2\right)$ ทำหน้าที่เป็นตัวกำหนด flatness of solution
- ค่า C หรือ regularized constant ($C \geq 0$) เป็นค่าที่ปรับสมดุลระหว่างค่าผิดพลาดจากการเรียนรู้และความซับซ้อนของตัวแบบ มีส่วนในการกำหนดความกว้างของเส้นขอบและความผิดพลาดในการจำแนกกลุ่ม ซึ่งหากกำหนดค่า C ขนาดใหญ่จะทำให้ความกว้างของเส้นขอบแคบ และถ้ากำหนดค่า C ขนาดเล็กจะทำให้ความกว้างของเส้นขอบกว้าง ดังภาพที่ 2.9 หากค่า C มีค่าเป็น infinity จะทำให้เป็นการหาค่าต่ำสุดของเทอมจาก empirical risk term เพียงอย่างเดียว (อนันต์ทรัพย์สุข, 2560)



ภาพที่ 2.9 ความกว้างของเส้นขอบเมื่อค่า C เปลี่ยนแปลง

(ที่มา: <https://medium.com/@pushkarmandot/what-is-the-significance-of-c-value-in-support-vector-machine-28224e852c5a>)

- Empirical risk term ประกอบด้วยฟังก์ชัน L หรือ \mathcal{E} -intensive loss function โดย \mathcal{E} คือ ค่าที่ยอมรับให้มีความผิดพลาดได้ จะมีค่าเท่ากับ 0 เมื่อระยะห่างระหว่างค่าจริงและเส้นสมการถดถอยอยู่ในช่วง $\pm \mathcal{E}$ แสดงถึงระยะห่างระหว่างค่าจริงที่อยู่นอก \mathcal{E} -intensive zone โดย ξ_i คือระยะที่อยู่เหนือ $+\mathcal{E}$ และ ξ_i^* คือระยะที่ต่ำกว่า $-\mathcal{E}$ ดังภาพที่ 2.10



ภาพที่ 2.10 (ซ้าย) ค่าที่อยู่นอก \mathcal{E} -intensive zone เป็นระยะ ξ_i และ ξ_i^*

(ขวา) ภาพแสดง \mathcal{E} -intensive loss function

(ที่มา : Using support vector machines for time series prediction, 2003: 37)

ดังนั้นสมการ minimize ข้างต้นจึงถูกเปลี่ยนดังนี้

$$\text{Minimize} \quad \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n (\xi_i + \xi_i^*)$$

$$\text{Subject to } \begin{cases} y_i - \langle w, x \rangle - b \leq \varepsilon + \zeta_i, & \zeta_i \geq 0, \quad i=1, 2, \dots, n \\ \langle w, x \rangle + b - y_i \leq \varepsilon + \zeta_i^*, & \zeta_i^* \geq 0, \quad i=1, 2, \dots, n \end{cases}$$

จากสมการข้างต้นเมื่อใช้ Lagrangian method ในการจำกัดค่าที่เหมาะสม จะสามารถหาเวกเตอร์ค่าถ่วงน้ำหนัก (weight) คือ

$$w = \sum_{i=1}^n (\alpha_i - \alpha_i^*)$$

เมื่อ α_i และ α_i^* แทนตัวคูณลากรางจ์ที่อยู่เหนือและใต้เส้นสมการถดถอยตามลำดับ โดย $\alpha_i \times \alpha_i^* = 0$, $\alpha_i \geq 0$, $\alpha_i^* \geq 0$, $i=1, 2, \dots, n$ หากมีตัวคูณลากรางจ์ที่ไม่เท่ากับศูนย์จึงจะถูกเรียกว่า ซัพพอร์ตเวกเตอร์

จากการหาค่าถ่วงข้างต้นจึงได้สมการถดถอย ดังนี้

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \cdot \langle x_i, x \rangle + b$$


2.3.2 ตัวแบบซัพพอร์ตเวกเตอร์แมชชีนแบบไม่เป็นเชิงเส้น

ในกรณีที่ไม่สามารถแบ่งกลุ่มข้อมูลด้วยเส้นตรง จึงต้องหาสมการถดถอยที่ใช้แบ่งข้อมูล โดยแทนค่าด้วยฟังก์ชันเคอร์เนล (Kernel function) เพื่อสร้างสมการถดถอย ดังสมการ

$$f(x) = \sum_{i=1}^n (\alpha_i - \alpha_i^*) \cdot K(x_i, x) + b$$

โดย $K(x_i, x) = \langle \phi(x_i), \phi(x) \rangle$

วิธีนี้เป็นวิธีที่นิยมใช้ในการพยากรณ์อนุกรมเวลา เนื่องจากข้อมูล 2 กลุ่มโดยทั่วไปแล้ว มักจะไม่ได้วางตัวในพิกัดที่คุณลักษณะ (Feature space) ทำให้ไม่สามารถที่จะใช้สมการของซัพพอร์ตเวกเตอร์แมชชีนแบบเชิงเส้นตรงเพื่อหาเส้นแบ่งกลุ่มได้ จึงต้องมีกระบวนการแปลงข้อมูลที่มีลักษณะไม่เป็นเชิงเส้นตรงบนพื้นที่ข้อมูลนำเข้า (Input space) จากข้อมูลที่มีมิติต่ำ (Low dimension dataset) ให้อยู่ในรูปแบบของข้อมูลที่มีมิติสูง (High dimension dataset) บนพื้นที่ข้อมูลคุณลักษณะ โดยใช้ฟังก์ชันเคอร์เนล (Kernel function) ในการปรับรูปแบบข้อมูล ดังภาพที่ 2.11



ภาพที่ 2.11 การแปลงลักษณะข้อมูลโดยใช้ kernel function

(ที่มา : Application of Supervised Machine Learning to Predict the Mortality Risk in Elderly Using Biomarkers, 2017: 34)

ฟังก์ชันเคอร์เนลมีหลายประเภท เช่น

1. Linear kernel: $k(x, x') = x^T x' + c$
2. Polynomial kernel: $k(x, x') = (\alpha x^T x' + c)^d$
3. Gaussian radial basis function (RBF): $k(x, x') = \exp\left(-\frac{\|x-x'\|^2}{2\sigma^2}\right)$
4. Laplace RBF kernel: $k(x, x') = \exp\left(-\frac{\|x-x'\|}{\sigma}\right)$
5. Sigmoid kernel: $k(x, x') = \tanh(s\langle x, x' \rangle + c)$
6. Log kernel: $k(x, x') = -\log\|x - x'\|^d + 1$

2.3.3 การกำหนดขอบเขต SVM ในงานวิจัย

- การกำหนดค่าพารามิเตอร์ เนื่องจากการเลือกใช้ค่า C ไม่ได้มีการกำหนดอย่างตายตัว ผู้วิจัยจึงเลือกใช้ช่วงค่า C คือ 2^0 ถึง 2^{10} และค่า ϵ อยู่ในช่วง 10^{-4} - 10^0 จากนั้นทำการวนซ้ำเพื่อหาค่า C และ ϵ เพื่อสร้างตัวแบบซัพพอร์ตเวกเตอร์แมชชีนจากข้อมูลทดลองที่ดีที่สุดสำหรับข้อมูลแต่ละชุด

- ในงานวิจัยชิ้นนี้เลือกใช้ kernel function ชนิด Gaussian radial basis function เนื่องจากฟังก์ชันนี้ประกอบด้วยพารามิเตอร์ σ ที่ต้องหาค่าเพียงตัวเดียว อีกทั้งยังมีประสิทธิภาพในการแปลง Nonlinear mapping จากพื้นที่ข้อมูลนำเข้าไปสู่พื้นที่ข้อมูลที่มีมิติสูง (Chen and Wang, 2007: 257)

2.4 ตัวแบบผสม (Hybrid Model)

หลักการสร้างตัวแบบผสม (Zhang 2003) โดยเลือกตัวแบบจากองค์ประกอบของข้อมูลที่น่ามาวิเคราะห์ซึ่งแบ่งเป็น 2 องค์ประกอบ ได้แก่ องค์ประกอบที่เป็นเชิงเส้น และองค์ประกอบที่ไม่เป็นเชิงเส้น จากนั้นคำนวณค่าพยากรณ์รวม (Total Forecasting) ซึ่งมีสมการดังนี้

$$y_t = \hat{L}_t + \hat{N}_t$$

โดย \hat{L}_t แทนองค์ประกอบที่เป็นเชิงเส้น (linear component)

\hat{N}_t แทนองค์ประกอบที่ไม่เป็นเชิงเส้น (nonlinear component)

ขั้นตอนการสร้างตัวแบบผสมมีดังนี้

1. วิเคราะห์ข้อมูลอนุกรมเวลาด้วยตัวแบบที่เหมาะสมสำหรับการพยากรณ์ข้อมูลในส่วนที่เป็นเชิงเส้น (\hat{L}_t) โดย Zhang ได้เลือกใช้ตัวแบบ ARIMA
2. คำนวณค่าส่วนเหลือ (residual; e_t) จากการพยากรณ์ด้วยตัวแบบในขั้นตอนที่ 1 โดยค่าส่วนเหลือนั้นจะจัดเป็นข้อมูลที่มีองค์ประกอบที่ไม่เป็นเชิงเส้น ซึ่งหาได้จากสมการดังนี้

$$e_t = y_t - \hat{L}_t$$
3. พยากรณ์ข้อมูลจากค่าส่วนเหลือที่มีองค์ประกอบที่ไม่เป็นเชิงเส้น (\hat{N}_t) ด้วยตัวแบบที่เหมาะสมสำหรับการพยากรณ์ข้อมูลที่มีองค์ประกอบไม่เป็นเชิงเส้น เช่น โครงข่ายประสาทเทียม หรือ ตัวแบบซัพพอร์ตเวกเตอร์แมชชีน
4. คำนวณค่าพยากรณ์รวม

2.5 การตรวจสอบความแม่นยำของการพยากรณ์

เกณฑ์ที่ใช้ในการคัดเลือกตัวแบบในการพยากรณ์ที่ดีที่สุดมีอยู่หลายเกณฑ์ ดังต่อไปนี้

2.5.1 ค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Square Error: MSE) เป็นค่าที่วัดจากกำลังสองของค่าคลาดเคลื่อนของการพยากรณ์

$$MSE = \frac{\sum_{i=1}^n e_i^2}{n}$$

2.5.2 รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) เป็นค่าที่คำนวณจากการหารากที่สองของค่าเฉลี่ยของค่าคลาดเคลื่อนของการพยากรณ์กำลังสอง ซึ่งมีหน่วยวัดเดียวกับค่าสังเกต

$$RMSE = \sqrt{\frac{\sum_{i=1}^n e_i^2}{n}}$$

บทที่ 3

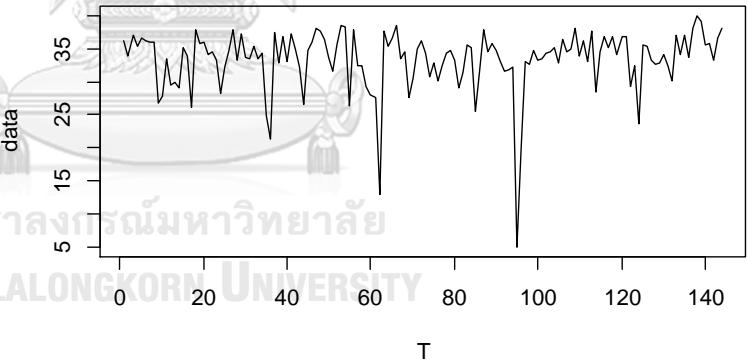
วิธีดำเนินงานวิจัย

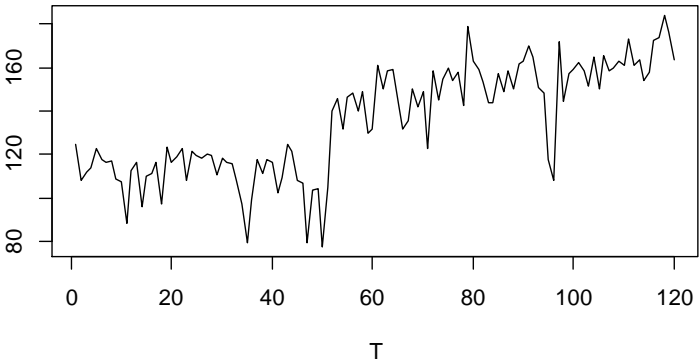
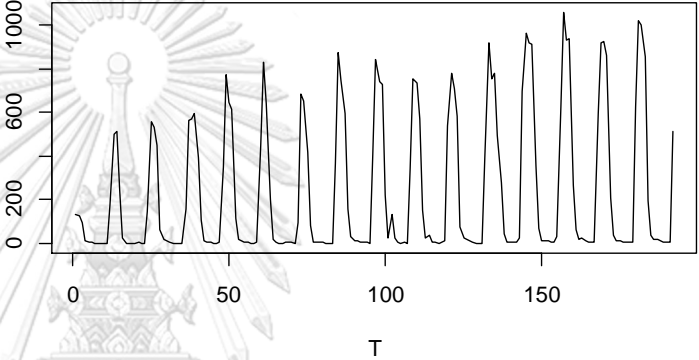
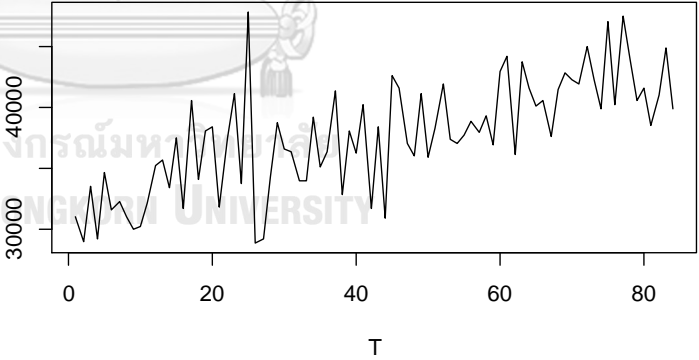
3.1 ขั้นตอนในการดำเนินงานวิจัย

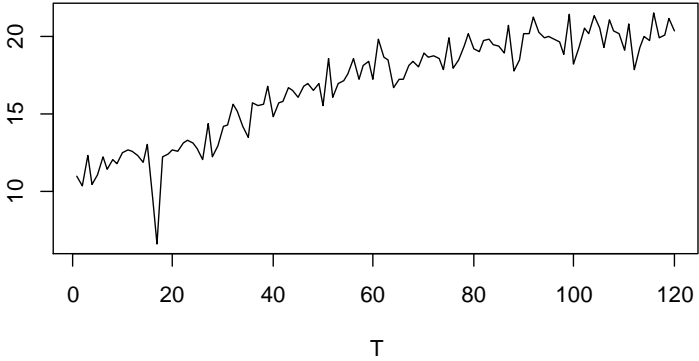
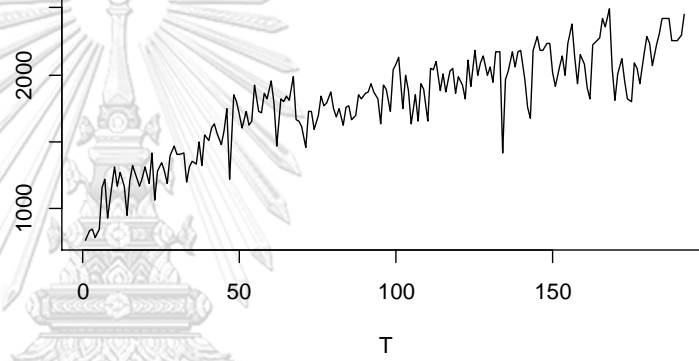
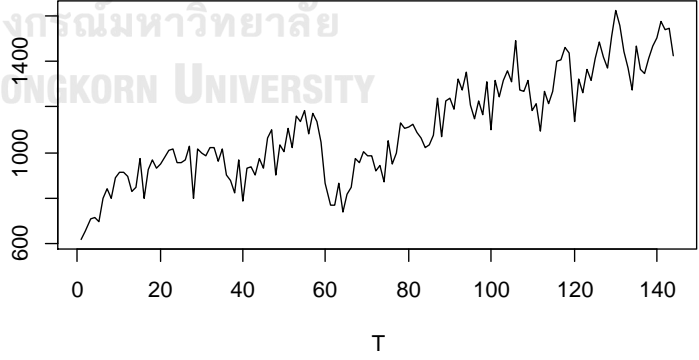
3.1.1 ศึกษาตัวแบบ ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

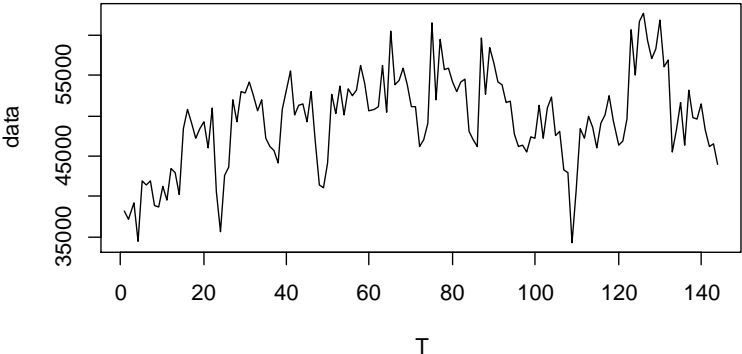
3.1.2 เก็บรวบรวมข้อมูลสำหรับการวิเคราะห์ข้อมูลจากแหล่งข้อมูลในประเทศไทย จำนวน 40 ชุดข้อมูล เพื่อให้มีลักษณะข้อมูลที่หลากหลาย โดยมีตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) ที่เหมาะสมสำหรับข้อมูลแต่ละชุดดังตารางที่ 3.1 ในที่นี้ได้ยกตัวอย่างรูปภาพอนุกรมเวลาของข้อมูล 8 ชุดให้เห็นถึงลักษณะเบื้องต้นของกราฟเวลาของข้อมูลแต่ละชุดที่ใช้ตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลแตกต่างกัน 8 ตัวแบบ

ตารางที่ 3.1 ชนิดของ ES Model, ชุดข้อมูล และตัวอย่างกราฟอนุกรมเวลาของ ES Model

ES Model	ชุดข้อมูลที่	ตัวอย่างกราฟอนุกรมเวลา
ETS(A,N,N)	12, 17, 27, 32	 <p>ข้อมูลชุดที่ 12: ปริมาณการผลิตน้ำอ้อยต้ม ตั้งแต่ปีพ.ศ. 2547-2558</p>

ES Model	ชุดข้อมูลที่	ตัวอย่างกราฟอนุกรมเวลา
ETS(A,N,A)	4, 5, 6, 8, 15, 20, 21, 22, 26, 36	 <p data-bbox="678 728 1380 772">ข้อมูลชุดที่ 4: ปริมาณการผลิต PE ตั้งแต่ปีพ.ศ. 2549-2558</p>
ETS(A,N,M)	7, 13, 19, 30, 31, 34, 35, 39, 40	 <p data-bbox="678 1169 1380 1214">ข้อมูลชุดที่ 7: ปริมาณการผลิตกากน้ำตาล ตั้งแต่ปีพ.ศ. 2543-2558</p>
ETS(A,A,N)	29	 <p data-bbox="678 1610 1380 1655">ข้อมูลชุดที่ 29: มูลค่าการนำเข้า ตั้งแต่ปีพ.ศ. 2554-2560</p>

ES Model	ชุดข้อมูลที่	ตัวอย่างกราฟอนุกรมเวลา
ETS(A,A,A)	ชุดข้อมูลที่ 1, 3, 18, 28, 33, 38	 <p data-bbox="730 734 1294 837">ข้อมูลชุดที่ 1: ข้อมูลจำนวนผู้โดยสารรถไฟฟ้า BTS ตั้งแต่ปีพ.ศ. 2552-2561</p>
ETS(A,A,M)	ชุดข้อมูลที่ 11, 14, 16, 24	 <p data-bbox="730 1238 1294 1341">ข้อมูลชุดที่ 11: ปริมาณการผลิตน้ำมันดีเซลหมุนเร็ว ตั้งแต่ปีพ.ศ. 2543-2558</p>
ETS(A,M,A)	ชุดข้อมูลที่ 23	 <p data-bbox="730 1731 1294 1834">ข้อมูลชุดที่ 23: มูลค่าการจำหน่ายถุงพลาสติก ตั้งแต่ปีพ.ศ. 2547-2558</p>

ES Model	ชุดข้อมูลที่	ตัวอย่างกราฟอนุกรมเวลา
ETS(A,M,M)	2, 9, 10, 25, 37	 <p>ข้อมูลชุดที่ 2: ปริมาณการใช้ NATURAL GAS ตั้งแต่ปีพ.ศ. 2543-2554</p>

3.1.3 จากนั้นแบ่งข้อมูลแต่ละชุดออกเป็นข้อมูลฝึกหัดร้อยละ 80 ของข้อมูลทั้งหมด และข้อมูลทดสอบร้อยละ 20 ของข้อมูลทั้งหมด

3.1.4 นำข้อมูลฝึกหัดแต่ละชุดสร้างตัวแบบด้วยวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) โดยพิจารณาใช้วิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียลตัวแบบที่เหมาะสมกับลักษณะข้อมูลแต่ละชุด โดยใช้เกณฑ์อาไคเคะ (Akaike's Information Criterion) หรือ เกณฑ์ AIC ตัวแบบวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียลที่เหมาะสมที่สุดคือตัวแบบที่ให้ค่า AIC ต่ำที่สุด จากนั้นนำตัวแบบที่เหมาะสมมาพยากรณ์ชุดข้อมูล โดยใช้ข้อมูลฝึกหัดและข้อมูลทดสอบ และคำนวณรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean square error: RMSE) ของข้อมูลทดสอบ


3.1.5 คำนวณหาค่าส่วนเหลือ (Residuals) ที่ได้จากการพยากรณ์ด้วยวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียลในชุดข้อมูลฝึกสอน จากนั้นนำค่าส่วนเหลือซึ่งเป็นข้อมูลที่ไม่เป็นเชิงเส้นมาสร้างตัวแบบโครงข่ายประสาทเทียม (ANN) ชนิดโครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้น (MLP) โดยใช้เทคนิค Resilient back propagation (Rprop) ตัวแบบโครงข่ายประสาทเทียมประกอบด้วยชั้นข้อมูลนำเข้า (Input layer) 1 ชั้นภายใต้จำนวนโหนด 1 โหนด ชั้นซ่อน (Hidden layer) 1 ชั้นมีโหนดจำนวน 1 ถึง 5 โหนดโดยใช้ Tan-Sigmoid logistic function เป็น Activate function และชั้นผลลัพธ์ (Output layer) 1 ชั้นจำนวน 1 โหนดโดยใช้ Linear function เป็น Activate function ซึ่งให้ค่าผลลัพธ์ 1 ค่า และกำหนดจำนวนรอบการทำซ้ำเท่ากับ 100 รอบ จากนั้นเลือกตัวแบบโครงข่ายประสาทเทียมที่เหมาะสมที่ให้ค่า RMSE ต่ำที่สุด สำหรับใช้พยากรณ์ชุดข้อมูลทดสอบ หลังจากนั้นคำนวณหาค่าพยากรณ์รวม (Total Forecasting) ซึ่งเป็นการรวมข้อมูลส่วนที่เป็นองค์ประกอบที่เป็นเชิงเส้น ที่ได้จากการพยากรณ์ด้วยวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล และข้อมูลส่วนที่องค์ประกอบที่ไม่เป็นเชิงเส้น ที่ได้จากการพยากรณ์ด้วยตัวแบบโครงข่ายประสาทเทียม (ANN)


และทำการคำนวณหารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean square error: RMSE) ของตัวแบบผสม

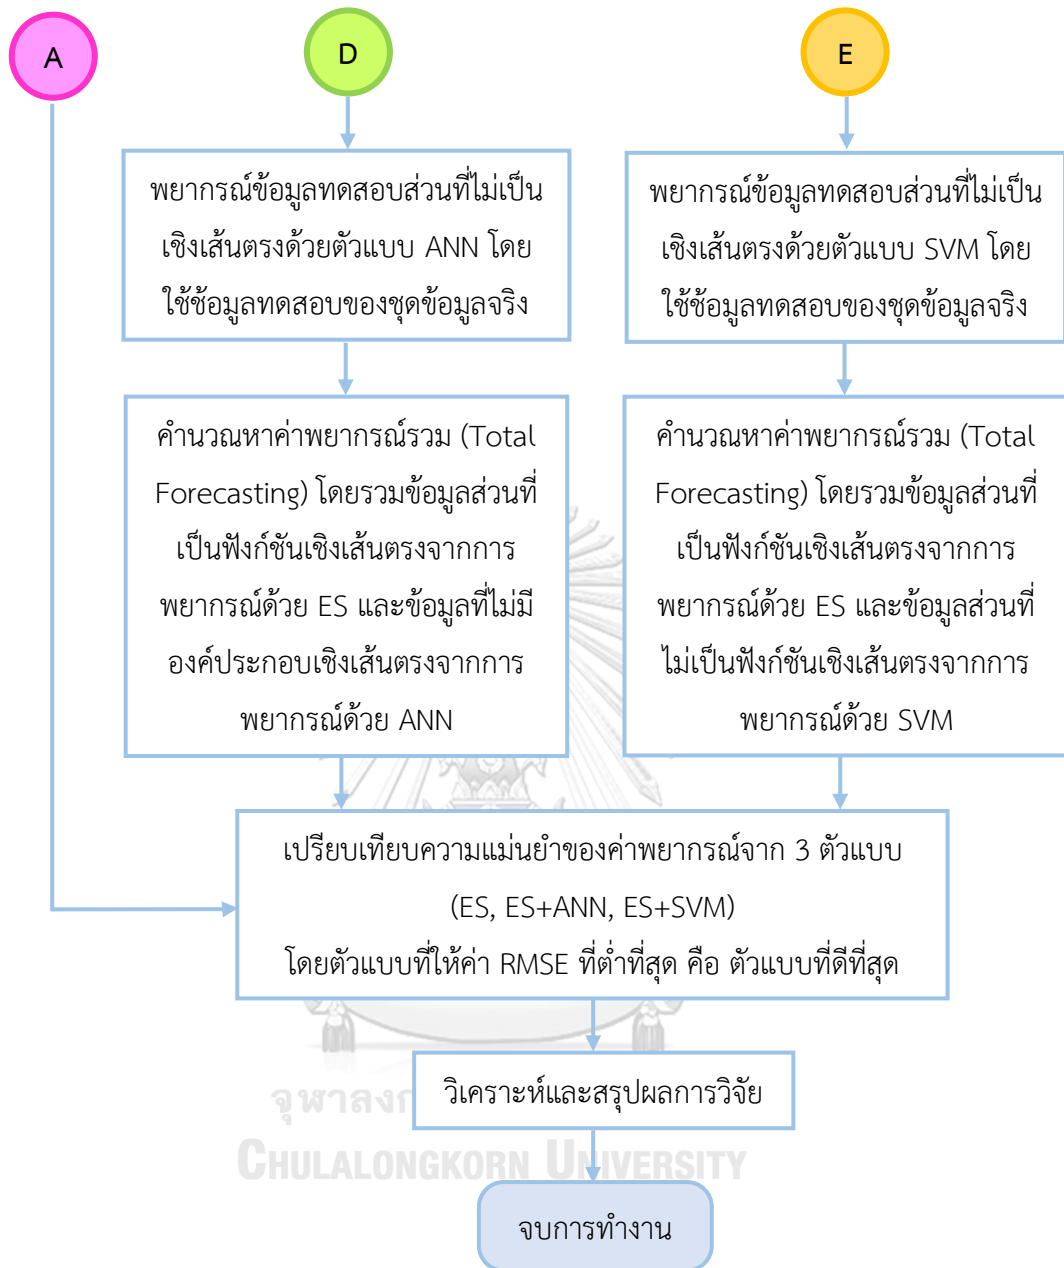
3.1.6 นำค่าส่วนเหลือ (Residuals) ที่ได้จากการพยากรณ์ด้วยวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียลในชุดข้อมูลฝึกสอน มาสร้างตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) โดยใช้ Gaussian radial basis function (RBF) เป็น Kernel function และกำหนดองค์ประกอบตัวแบบคือ ค่า cost (C) อยู่ในช่วงขอบเขต (2^0 , 2^{10}) และค่า epsilon (ϵ) อยู่ในช่วงขอบเขต (10^{-4} , 10^0) จากนั้นทำการสร้างตัวแบบ SVM ภายใต้งैอนไขโดยมีจำนวนรอบการทำซ้ำเท่ากับ 100 รอบ จากนั้นเลือกตัวแบบซัพพอร์ตเวกเตอร์แมชชีนที่เหมาะสมจากตัวแบบที่ให้ค่า RMSE ต่ำที่สุดในชุดข้อมูลฝึกสอน เพื่อใช้ตัวแบบนั้น ๆ พยากรณ์ชุดข้อมูลสำหรับทดสอบ หลังจากนั้นรวมข้อมูลส่วนที่ได้จากการพยากรณ์ด้วยวิธีการทำให้เรียบแบบเอ็กซ์โปเนนเชียลซึ่งเป็นองค์ประกอบเชิงเส้น และข้อมูลที่พยากรณ์ด้วยตัวแบบซัพพอร์ตเวกเตอร์แมชชีนซึ่งเป็นองค์ประกอบที่ไม่เป็นเชิงเส้น โดยการคำนวณหาค่าพยากรณ์รวม (Total Forecasting) ขั้นตอนสุดท้ายคือการคำนวณหารากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean square error: RMSE) ของตัวแบบผสม

3.1.7 เปรียบเทียบความแม่นยำของผลการพยากรณ์ชุดข้อมูลจากตัวแบบทั้ง 3 ตัวแบบ ซึ่งได้แก่วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) โดยตัวแบบที่มีรากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE) ต่ำสุดคือตัวแบบที่มีความแม่นยำมากที่สุด

3.2 แผนผังการดำเนินงานวิจัย







บทที่ 4

ผลการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อเปรียบเทียบความแม่นยำในการพยากรณ์ชุดข้อมูลจำนวน 40 ชุดจากการรวมรวมข้อมูลอนุกรมเวลาในประเทศไทย ซึ่งพยากรณ์โดยใช้ตัวแบบ 3 ตัวแบบ ได้แก่ วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล และโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล และตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) โดยข้อมูลแต่ละชุดจะถูกแบ่งข้อมูลจำนวนร้อยละ 80 สำหรับใช้เป็นชุดข้อมูลฝึกสอน (Training data) เพื่อใช้ในการสร้างตัวแบบ และร้อยละ 20 ของข้อมูล สำหรับสร้างชุดข้อมูลทดสอบ (Testing Data) เพื่อใช้ตรวจสอบความแม่นยำของตัวแบบ จากนั้นในขั้นตอนสุดท้ายจะทำการเปรียบเทียบความแม่นยำในการพยากรณ์ โดยเกณฑ์ที่ใช้ในการเปรียบเทียบตัวแบบ คือ เกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE)

ในขั้นต้นจะทำการพิจารณากราฟ และวิเคราะห์ลักษณะเบื้องต้นของชุดข้อมูลแต่ละชุด จากนั้นนำเสนอผลการเปรียบเทียบความแม่นยำของค่าพยากรณ์ของตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลทั้ง 9 ตัวแบบ โดยใช้เกณฑ์อาไคเคะ (Akaike's Information Criterion: AIC) ในการเลือกตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล ซึ่งได้แสดงผลการใช้เกณฑ์ AIC ของข้อมูลทั้ง 40 ชุดในภาคผนวก ก. โดยตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลที่ให้ค่า AIC น้อยที่สุด คือ ตัวแบบที่เหมาะสมที่สุด ซึ่งได้ตัวแบบที่แตกต่างกัน 8 ตัวแบบ

จากการศึกษาตัวแบบผสมซึ่งตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) พบว่าการสร้างตัวแบบโครงข่ายประสาทเทียมจากค่าส่วนเหลือจากตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล โดยใช้เทคนิคการฝึกสอนโครงข่ายแบบ Resilient back propagation (Rprop) โดยมีการใช้ข้อมูลฝึกหัดทำการวนซ้ำ 100 รอบสำหรับข้อมูลแต่ละชุด เพื่อหาตัวแบบโครงข่าย พบว่าข้อมูลแต่ละชุดใช้ระยะเวลาหนึ่งในการประมวลผล ได้ผลว่าตัวแบบโครงข่ายประสาทเทียมที่ประกอบด้วยชั้นข้อมูลนำเข้าซึ่งมีจำนวนโหนด 1 โหนด, ชั้นซ่อนมีโหนดจำนวน 3-5 โหนด ดังตารางแสดงจำนวนชั้นซ่อนของตัวแบบโครงข่ายประสาทเทียม (ANN) ที่ให้ค่า RMSE ต่ำที่สุดของรอบการวนซ้ำของชุดข้อมูล 40 ชุดในภาคผนวก ก. และชั้นผลลัพธ์ที่มีจำนวน

โหนด 1 โหนดเป็นตัวแทนที่ให้ค่า RMSE ต่ำที่สุด โดยโหนดในชั้นซ่อนนั้นมีความแตกต่างกันขึ้นกับ ครั้งการวนซ้ำและชุดข้อมูลที่ใช้สร้างตัวแทน

การศึกษาตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ตเวกเตอร์แมชชีนพบว่า เมื่อนำค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล สร้างตัวแบบซัพพอร์ตเวกเตอร์แมชชีนจากการวนซ้ำจำนวน 100 รอบ สามารถประมวลผลได้เร็วกว่าตัวแบบโครงข่ายประสาทเทียม โดยได้ค่าพารามิเตอร์ที่ดีที่สุดของข้อมูลแต่ละชุด ซึ่งทำให้ค่า RMSE ของตัวแบบซัพพอร์ตเวกเตอร์แมชชีนในส่วนข้อมูลสำหรับฝึกหัดมีค่าต่ำที่สุด โดยทั้ง 40 ชุดมีค่า epsilon (ϵ) เท่ากับ 0.0001 เท่ากันทุกชุด จากการตั้งช่วงขอบเขตค่า ϵ สำหรับตัวแบบให้อยู่ในช่วง 0.0001 ถึง 1 ในส่วนค่า cost (C) นั้นได้มีการตั้งช่วงขอบเขต คือ 2^0 ถึง 2^{10} ซึ่งในชุดข้อมูลทั้ง 40 ชุด ใช้ค่า C เท่ากับ 1 จำนวน 27 ชุด, ค่า C เท่ากับ 2 จำนวน 9 ชุด และค่า C เท่ากับ 4, 16, 128, 256 อย่างละ 1 ชุด และค่า sigma (σ) จะมีค่าแตกต่างกันตามแต่ละชุดข้อมูล ซึ่งได้แสดงในตารางในภาคผนวก ก

จากการนำตัวแบบที่ดีที่สุดจากการสร้างโครงข่ายประสาทเทียมและตัวแบบซัพพอร์ตเวกเตอร์แมชชีนในการพยากรณ์ส่วนที่ไม่เป็นเชิงเส้น ร่วมกับตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลที่ใช้สร้างตัวแบบเชิงเส้นตรง คำนวณค่า RMSE ของตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) ดังตารางที่ 4.1

ตารางที่ 4.1 ค่า RMSE ของชุดข้อมูลทดสอบจำนวน 40 ชุด


ข้อมูลชุดที่	ES Model	ค่า RMSE		
		ES	ES+ANN	ES+SVM
1	AAA	1.4378	0.7673	1.2379
2	AAM	8188.125	2207.618	9424.3861
3	AAA	521.2550	283.1961	532.2873
4	ANA	43.1506	14.0717	42.7693
5	ANA	10.9276	8.4223	10.6086
6	ANA	2.1040	1.5525	1.9590
7	ANM	49.1221	43.5416	49.3410
8	ANA	45.7958	37.8887	44.6458

ข้อมูลชุดที่	ES Model	ค่า RMSE		
		ES	ES+ANN	ES+SVM
9	AMM	62.8280	51.7066	60.1278
10	AMM	218.2676	170.1556	105.1795
11	AAM	208.0202	159.8867	202.1584
12	ANN	3.6910	3.0933	3.5147
13	ANM	18.3655	13.4802	17.9766
14	AAM	178.0292	103.6777	179.9461
15	ANA	14.8705	5.8793	14.8452
16	AAM	1.8234	0.5982	1.7387
17	ANA	4.4251	3.6329	4.2311
18	AAA	15.6146	13.9782	15.6152
19	ANM	360.7297	274.8936	363.2336
20	AAM	82.8885	27.9249	83.8952
21	ANA	93.8491	70.9604	95.1555
22	ANA	774.6048	200.9396	784.4228
23	AMA	139.1297	66.8405	118.2827
24	AAM	300.4732	139.8744	304.4506
25	AMM	144.3475	72.4092	79.6034
26	ANA	57.4398	56.6052	57.8403
27	ANN	26.2926	22.5066	24.1590
28	AAA	73.3231	58.9109	73.8745
29	AAN	2662.4939	2632.0670	2741.8749
30	ANM	15133.7455	7375.4160	15599.4026
31	ANM	4.5602	4.0024	4.1450
32	ANN	6.4828	1.5135	6.0722
33	AAA	0.4662	0.1343	0.7780
34	ANM	0.8574	0.6233	0.7134

ข้อมูลชุดที่	ES Model	ค่า RMSE		
		ES	ES+ANN	ES+SVM
35	ANM	0.9748	0.5816	0.6970
36	ANA	1.7652	1.3747	1.4097
37	AMM	21.2545	9.0179	22.1691
38	AAA	14.8289	4.7455	14.9950
39	ANM	13.4420	7.4956	13.4030
40	ANM	2.5413	1.9838	2.1888


กราฟผลการพยากรณ์อนุกรมเวลาของตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) ในที่นี้ ได้นำเสนอตัวอย่างกราฟที่มีตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลแตกต่างกันจำนวน 8 ชุดจากชุดข้อมูล 40 ชุด ได้แก่ข้อมูลชุดที่ 12, 4, 7, 29, 1, 11, 23 และ 2

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)




ภาพที่ 4.1 กราฟผลการพยากรณ์ข้อมูลชุดที่ 12 มีลักษณะข้อมูลแบบ ETS(A,N,N)

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)




ภาพที่ 4.2 กราฟผลการพยากรณ์ข้อมูลชุดที่ 4 มีลักษณะข้อมูลแบบ ETS(A,N,A)

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)




ภาพที่ 4.3 กราฟผลการพยากรณ์ข้อมูลชุดที่ 7 มีลักษณะข้อมูลแบบ ETS(A,N,M)

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)



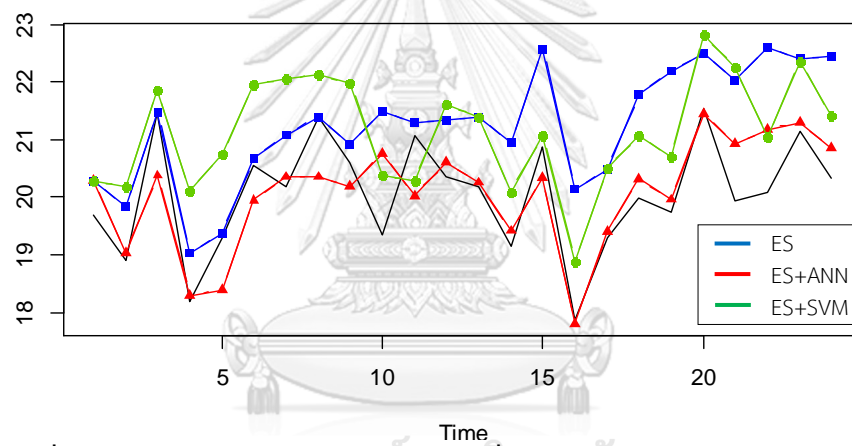
ภาพที่ 4.4 กราฟผลการพยากรณ์ข้อมูลชุดที่ 29 มีลักษณะข้อมูลแบบ ETS(A,A,N)

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)




ภาพที่ 4.5 กราฟผลการพยากรณ์ข้อมูลชุดที่ 1 มีลักษณะข้อมูลแบบ ETS(A,A,A)

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)




ภาพที่ 4.6 กราฟผลการพยากรณ์ข้อมูลชุดที่ 11 มีลักษณะข้อมูลแบบ ETS(A,A,M)

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)



ภาพที่ 4.7 กราฟผลการพยากรณ์ข้อมูลชุดที่ 23 มีลักษณะข้อมูลแบบ ETS(A,M,A)

Real testing data VS Fitted values(ES vs ES+ANN vs ES+SVM)



ภาพที่ 4.8 กราฟผลการพยากรณ์ข้อมูลชุดที่ 2 มีลักษณะข้อมูลแบบ ETS(A,M,M)

ในการพยากรณ์ความแม่นยำของตัวแบบโดยใช้ชุดข้อมูลอนุกรมเวลาจริงจำนวน 40 ชุด โดยใช้รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) เป็นเกณฑ์ในการเปรียบเทียบตัวแบบระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) ตัวแบบผสมวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) โดยตัวแบบที่มีค่า RMSE น้อยที่สุดคือตัวแบบที่มีความแม่นยำมากที่สุด พบว่าตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) มีความแม่นยำในการพยากรณ์ข้อมูลมากที่สุดสำหรับข้อมูลจำนวน 40 ชุด ซึ่งตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) และวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) มีความแม่นยำในการพยากรณ์ข้อมูลต่ำกว่าทุกชุดข้อมูล โดยการใช้ตัวแบบ ES มีความแม่นยำเป็นอันดับสองสำหรับข้อมูล 17 ชุด อันดับสามสำหรับข้อมูล 23 ชุด และตัวแบบ ES+SVM มีความแม่นยำอันดับสองสำหรับข้อมูล 23 ชุด อันดับสามสำหรับข้อมูล 17 ชุด มีรายละเอียดชุดข้อมูลดังตารางที่ 4.2

ตารางที่ 4.2 ผลการจัดอันดับความแม่นยำของวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสม ES+ANN และตัวแบบผสม ES+SVM สำหรับข้อมูลจำนวน 40 ชุด

อันดับความแม่นยำของตัวแบบ	จำนวนชุดข้อมูล	ข้อมูลชุดที่
1. ตัวแบบผสม ES+ANN	23	1, 4, 5, 6, 8, 9, 11, 12,
2. ตัวแบบผสม ES+SVM		13, 15, 16, 17, 23, 25,
3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)		27, 31, 32, 34, 35, 36,
		37, 39, 40

อันดับความแม่นยำของตัวแบบ	จำนวนชุดข้อมูล	ข้อมูลชุดที่
1. ตัวแบบผสม ES+ANN	17	2, 3, 7, 10, 14, 18, 19,
2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)		20, 21, 22, 24, 26, 28,
3. ตัวแบบผสม ES+SVM		29, 30, 33, 38

จากผลการวิจัยข้างต้นเมื่อนำผลการวิจัยมาแบ่งตามประเภทวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลพบว่า ตัวแบบผสมวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) มีความแม่นยำในการพยากรณ์ข้อมูลมากกว่า วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) เมื่อข้อมูลมีลักษณะแนวโน้มที่ไม่แน่นอน และแนวโน้มที่เป็นเชิงพหุ วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) จะมีความแม่นยำในการพยากรณ์ข้อมูลมากกว่าตัวแบบผสมวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) เมื่อข้อมูลมีลักษณะแนวโน้มเป็นเชิงบวก ดังตารางที่ 4.3

ตารางที่ 4.3 ผลความแม่นยำในการพยากรณ์เมื่อแบ่งตามประเภท ES MODEL

ES MODEL	จำนวนชุดข้อมูลเมื่อเรียงลำดับความแม่นยำความแม่นยำในการพยากรณ์	
	ES+ANN>ES+SVM>ES	ES+ANN>ES>ES+SVM
ETS(A,N,N)	4	0
ETS(A,N,A)	6	4
ETS(A,N,M)	6	3
ETS(A,A,N)	0	1
ETS(A,A,A)	1	5
ETS(A,A,M)	2	2
ETS(A,M,A)	1	0
ETS(A,M,M)	3	2

บทที่ 5

สรุปผลการวิจัยและข้อเสนอแนะ

การศึกษาความแม่นยำในการพยากรณ์ชุดข้อมูลจริงซึ่งเก็บข้อมูลจากแหล่งข้อมูลในประเทศไทยจำนวน 40 ชุด ซึ่งพยากรณ์โดยใช้ตัวแบบ 3 ตัวแบบ ได้แก่ วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) โดยลักษณะชุดข้อมูลที่เลือกใช้นั้นมีความหลากหลายของลักษณะข้อมูล โดยต้องการทำการเปรียบเทียบความแม่นยำในการพยากรณ์ตัวแบบทั้ง 3 ตัวแบบ โดยเกณฑ์ที่ใช้ในการเปรียบเทียบตัวแบบ คือ เกณฑ์รากของค่าคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Square Error: RMSE) สรุปผลการวิจัย ดังนี้

5.1 สรุปผลการวิจัย

จากการศึกษาพบว่าผลการพิจารณาตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลในงานวิจัยนี้เลือกใช้เกณฑ์ อาโคเคะ (AIC) ในการคัดเลือกตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล โดยตัวแบบที่ให้ค่า AIC น้อยที่สุดเป็นตัวแบบที่เหมาะสมที่สุด ได้ผลสรุปตัวแบบ ES ที่เหมาะสมสำหรับข้อมูล 8 ตัวแบบ โดยการใช้ตัวแบบ ES พยากรณ์ข้อมูลอนุกรมเวลานั้นมีความแม่นยำเป็นอันดับสองสำหรับข้อมูล 17 ชุด และอันดับสามสำหรับข้อมูล 23 ชุด โดยวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) จะมีความแม่นยำในการพยากรณ์ข้อมูลมากกว่าตัวแบบผสมวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) เมื่อข้อมูลมีลักษณะแนวโน้มเป็นเชิงบวก

จากการศึกษาตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) ที่ใช้เทคนิคการฝึกสอนโครงข่ายแบบ Resilient back propagation (Rprop) ประกอบด้วยชั้นข้อมูลนำเข้าจำนวน 1 โหนด, ชั้นซ่อนมีโหนดจำนวน 3-5 โหนดขึ้นอยู่กับรอบการวนซ้ำและชุดข้อมูลที่ใช้สร้างตัวแบบ และชั้นผลลัพธ์จำนวน 1 โหนด เป็นตัวแบบที่ให้ค่า RMSE ต่ำที่สุด เมื่อนำมาสร้างตัวแบบผสมผลการคำนวณหาค่าพยากรณ์รวม (Total forecasting) พบว่าตัวแบบ ES+ANN ให้ค่า RMSE ต่ำที่สุดสำหรับข้อมูลทั้ง 40 ชุด จากชุดข้อมูลที่ใช้ในการศึกษาจำนวน 40 ชุด

การศึกษาตัวแบบซัพพอร์ทเวกเตอร์แมชชีนพบว่า เมื่อนำค่าส่วนเหลือที่ได้จากการพยากรณ์ด้วยตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล สร้างตัวแบบซัพพอร์ทเวกเตอร์แมชชีนที่ให้ค่า RMSE ของตัวแบบของข้อมูลทดสอบต่ำที่สุด โดยทั้ง 40 ชุดมีค่า epsilon (ϵ) เท่ากับ 0.0001 เท่ากัน ในส่วนค่าพารามิเตอร์ sigma (σ) และ cost (C) จะมีค่าแตกต่างกันตามแต่ละชุดข้อมูล เมื่อนำตัวแบบซัพพอร์ทเวกเตอร์แมชชีนที่ดีที่สุดสำหรับข้อมูลแต่ละชุดรวมกับวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล ผลการคำนวณหาค่าพยากรณ์รวม (Total forecasting) พบว่าตัวแบบ ES+SVM มีความแม่นยำอันดับสองรองจากตัวแบบ ES+ANN สำหรับข้อมูลจำนวน 23 ชุด และมีความแม่นยำเป็นอันดับสามสำหรับข้อมูล 17 ชุด โดยตัวแบบผสมวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (ES+SVM) มีความแม่นยำในการพยากรณ์ข้อมูลมากกว่า วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) เมื่อข้อมูลมีลักษณะแนวโน้มที่ไม่แน่นอน และแนวโน้มที่เป็นเชิงพหุ

สรุปได้ว่า งานวิจัยนี้ได้ศึกษาตัวแบบโดยข้อมูลจริงจำนวน 40 ชุด ซึ่งพบว่าตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) มีความแม่นยำในการพยากรณ์ข้อมูลมากที่สุดสำหรับชุดข้อมูล 40 ชุด ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ทเวกเตอร์แมชชีน (ES+SVM) มีความแม่นยำในการพยากรณ์ข้อมูลเป็นอันดับสองสำหรับข้อมูล 23 ชุด เมื่อข้อมูลมีลักษณะแนวโน้มที่ไม่แน่นอน และแนวโน้มที่เป็นเชิงพหุจะมีความแม่นยำในการพยากรณ์มากกว่าวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) ดังนั้นการพยากรณ์ข้อมูลอนุกรมเวลาโดยใช้ตัวแบบผสมวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลร่วมกับตัวแบบโครงข่ายประสาทเทียมเป็นอีกทางเลือกหนึ่งที่น่าสนใจและสามารถเพิ่มประสิทธิภาพในการพยากรณ์ข้อมูลจากการใช้ตัวแบบเดียวได้มากขึ้น

ข้อจำกัดในงานวิจัยคือจำนวนข้อมูลที่ใช้ในการศึกษา โดยข้อมูลที่ใช้อาจน้อยเกินไปทำให้เกิดความไม่ชัดเจนในการแบ่งกลุ่ม และระยะเวลาที่ใช้ในการประมวลผล เนื่องการใช้ตัวแบบโครงข่ายประสาทเทียมและตัวแบบซัพพอร์ทเวกเตอร์แมชชีน มีการกำหนดขอบเขตจำนวนโหนดชั้นซ่อนค่าพารามิเตอร์ของตัวแบบเป็นช่วงขอบเขต และการวนซ้ำเพื่อหาตัวแบบแต่ละครั้งจะให้ผลลัพธ์ที่แตกต่างกันบ้างเล็กน้อย ทั้งนี้ขึ้นกับขอบเขตของข้อมูลและวัตถุประสงค์ของงานนั้น ๆ

5.2 ข้อเสนอแนะ

1. เพิ่มจำนวนชุดข้อมูลเพื่อความชัดเจนในการเปรียบเทียบความแม่นยำของตัวแบบ
2. ในงานวิจัยนี้เปรียบเทียบความแม่นยำของตัวแบบเพียง 3 ตัวแบบ คือ วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) ซึ่งผู้ที่สนใจอาจนำตัวแบบเดี่ยวหรือตัวแบบผสมแบบอื่นเปรียบเทียบความแม่นยำในการพยากรณ์ข้อมูล เพื่อหาตัวแบบที่มีประสิทธิภาพในการพยากรณ์ข้อมูลมากขึ้น เช่น ตัวแบบผสมระหว่าง Variational Mode Decomposition (VMD) ร่วมกับ Extreme Learning Machine (ELM), ตัวแบบผสมระหว่างตัวแบบ Pegels ร่วมกับตัวแบบ ARIMA หรือ ตัวแบบผสมระหว่างตัวแบบ ARIMA ร่วมกับตัวแบบ Exponential smoothing เป็นต้น
3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลในงานวิจัยนี้เลือกขอบเขตโดยใช้ตัวแบบเพียง 9 ตัวแบบ ซึ่งเป็นตัวแบบสำหรับลักษณะข้อมูลที่แนวโน้มไม่มีการ damped ได้แก่ ตัวแบบ ES ที่เป็น Additive Damped Trend หรือ Multiplicative Damped Trend ซึ่งผู้ที่สนใจอาจศึกษาโดยเพิ่มตัวแบบสำหรับลักษณะข้อมูลที่แนวโน้มมีการ damped และในส่วนของ Error term ของตัวแบบในงานวิจัยชิ้นนี้ได้มีข้อจำกัดคือ ให้องค์ประกอบของ error เป็นแบบ Additive เท่านั้น ซึ่งสามารถใช้ศึกษาเพิ่มเติมโดยให้องค์ประกอบของ error เป็นได้ทั้งแบบ Additive และ Multiplicative เพื่อให้ตัวแบบครอบคลุมลักษณะข้อมูลที่มีความหลากหลายมากยิ่งขึ้น
4. การสร้างตัวแบบโครงข่ายประสาทเทียมเพื่อใช้ในการสร้างตัวแบบผสม ในงานวิจัยนี้ใช้ตัวแบบโครงข่ายประสาทเทียมแบบส่งสัญญาณไปข้างหน้า (Feed-forward artificial neural network) ชนิดโครงข่ายประสาทเทียมเพอร์เซ็ปตรอนหลายชั้น (Multi-layer perceptron: MLP) และใช้เทคนิค Resilient back propagation (Rprop) ซึ่งตัวแบบโครงข่ายประสาทเทียมมีอีกหลายชนิดให้ศึกษาเพิ่มเติมและใช้เปรียบเทียบ เช่น Convolutional neural network (CNN), Recurrent neural network (RNN), Long Short-Term Memory (LSTM) เป็นต้น เพื่อเพิ่มประสิทธิภาพของตัวแบบที่ใช้ในการพยากรณ์ อีกทั้งกระบวนการในชั้นซ่อนซึ่งมีการใช้ Activation function สามารถเลือกใช้ Sigmoid logistic function แทนการใช้ Hyperbolic tangent function หรือในชั้นผลลัพธ์เลือกใช้ Activation function แบบ Sigmoid logistic function หรือ Hyperbolic tangent function แทนการใช้ Linear function
5. การสร้างตัวแบบซัพพอร์ตเวกเตอร์แมชชีน งานวิจัยนี้เลือกใช้ Kernel function ประเภท Gaussian radial basis function (RBF) และสร้างตัวแบบโดยใช้พารามิเตอร์คือ ค่า C อยู่ในช่วง (2^0-2^{10}) และค่า ϵ อยู่ในช่วง $(10^{-4}-10^0)$ โดยสามารถเลือกใช้ Kernel function ประเภทอื่น

เช่น Linear Kernel, Polynomial Kernel และ Exponential radial basis ในการสร้างตัวแบบซัพพอร์ทเวกเตอร์แมชชีน อีกทั้งยังสามารถเลือกปรับเปลี่ยนค่าพารามิเตอร์ C และค่า ϵ ในช่วงอื่นในการปรับปรุงตัวแบบ ซึ่งอาจทำให้ตัวแบบซัพพอร์ทเวกเตอร์แมชชีนที่ได้มีความแม่นยำมากขึ้น



บรรณานุกรม

- Hyndman, R. J., & Athanasopoulos, G. (Producer). (2018). Forecasting: principles and practice.
- Hyndman, R. J. a. K. (2008). Automatic Time Series Forecasting: The forecast Package for R. *Journal of Statistical Software*, 27(3).
- Jinjun Tang, G. X., Yinhai Wang, Hua Wang, Shen Zhang, Fang Liu. (2013). Traffic flow prediction based on hybrid model using double exponential smoothing and support vector machine. *16th International IEEE Conference on Intelligent Transportation Systems*.
- Navneel Prasad, R. S., Sunil Pranit Lal. (2013). *Comparison of Back Propagation and Resilient Propagation Algorithm for Spam Classification*. Paper presented at the 2013 Fifth International Conference on Computational Intelligence, Modelling and Simulation, Seoul.
- Pegels, C. C. (1969). Exponential forecasting: Some new variations. *Management Science*, 15(5).
- Riedmiller, M. a. H. B. (1993). A Direct Adaptive Method for Faster Backpropagation Learning :The RPROP Algorithm. *Proceedings of the IEEE International Conference on Neural Networks(ICNN)*, 586-591.
- Sibarama Panigrahi, H. S. B. (2017). A hybrid ETS-ANN model for time series forecasting. *Engineering Applications of Artificial Intelligence*, 66, 49-59.
- Thissen, U., R. v. Brakela, A. P. d. Weijerb, W. J. Melssena and L. M. C. Buydensa (2003). Using support vector machines for time series prediction. *Chemometrics and Intelligent Laboratory Systems*, 69, 35-49.
- ZHANG, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- ชญาสิน บัญมานะ, น. ก. (2560). การเปรียบเทียบความแม่นยำของการ พยากรณ์ด้วยตัวแบบอนุกรมเวลาแบบผสม. วารสารวิชาการด้านวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยธรรมศาสตร์, 25(2), 177-190.
- ดุรงค์วัฒนา, ส. (2537). การพยากรณ์ทางธุรกิจ. กรุงเทพฯ: สำนักพิมพ์แห่งจุฬาลงกรณ์มหาวิทยาลัย.

อนันต์ทรัพย์สุข, อ. (2560). การเปรียบเทียบตัวแบบอนุกรมเวลาแบบผสมสำหรับการพยากรณ์ข้อมูล
อนุกรมเวลาที่มีปัจจัยเชิงฤดูกาล. จุฬาลงกรณ์มหาวิทยาลัย,





ผลลัพธ์การวิเคราะห์ชุดข้อมูลจริง

ตารางที่แสดงค่า AIC ของวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) ทั้ง 9 ตัวแบบ สำหรับชุดข้อมูล 40 ชุด

ข้อมูลชุดที่	ค่า AIC ของ ES Model											
	ETS(A,N,N)	ETS(A,N,A)	ETS(A,N,M)	ETS(A,A,N)	ETS(A,A,A)	ETS(A,A,M)	ETS(A,M,N)	ETS(A,M,A)	ETS(A,M,M)			
1	463.6250	425.1202	445.4658	458.0861	419.8844	437.2538	445.4658	420.7668	438.6642			
2	2460.1120	2386.5760	2392.9320	2465.9870	2386.7740	2383.1910	2392.9320	2384.5180	2381.0250			
3	1721.0670	1620.2340	1644.8050	1729.8230	1587.7460	1593.4750	1644.8050	1590.7230	1636.6370			
4	938.3507	904.9104	929.8744	942.4065	910.1975	943.1563	929.8744	910.1879	945.6301			
5	764.1469	733.5226	741.0961	768.1674	738.6771	743.3780	741.0961	737.0260	745.7336			
6	923.1872	916.8976	925.8052	927.1429	926.8654	926.9198	925.8052	926.1561	934.1319			
7	2425.3220	2214.0490	2166.9080	2429.1820	2203.3320	2175.2810	2166.9080	-	2200.5530			
8	1440.4480	1433.2930	1443.0680	1444.3500	1435.9490	1449.2070	1443.0680	1436.4970	1448.2490			
9	2264.5780	2257.7680	2254.6510	2269.2070	2256.7700	2246.2380	2254.6510	2253.5350	2245.3190			
10	2517.2100	2325.9010	2280.2600	2521.2630	2356.2450	2264.7030	2280.2600	-	2253.1900			
11	2333.3320	2308.8900	2325.5310	2331.5800	2295.5960	2293.2190	2325.5310	2298.0180	2306.1770			
12	913.2781	918.9644	918.8520	927.1713	921.5176	922.6594	918.8520	921.5684	921.8094			
13	1274.6940	1188.9860	1187.1930	1279.5860	1191.6610	1189.5430	1187.1930	1191.7540	1198.3040			

ข้อมูลชุดที่	ค่า AIC ของ ES Model									
	ETS(A,N,N)	ETS(A,N,A)	ETS(A,N,M)	ETS(A,A,N)	ETS(A,A,A)	ETS(A,A,M)	ETS(A,M,N)	ETS(A,M,A)	ETS(A,M,M)	
14	2238.1360	2172.6080	2174.9470	2241.1490	2176.2130	2172.3760	2174.9470	2176.7530	2206.6980	
15	1386.5570	1276.4120	1281.5880	1393.8450	1280.4160	1286.2350	1281.5880	1280.1060	1290.3430	
16	708.2295	690.5878	689.3775	710.7741	690.6025	683.5256	689.3775	691.6871	688.2507	
17	1307.0230	1320.7200	1318.7850	1311.4150	1323.5500	1324.2090	1318.7850	1324.1040	1324.8970	
18	1160.1710	1101.0930	1114.1110	1161.3800	1098.4490	1107.6760	1114.1110	1100.1490	1112.1880	
19	3764.4590	3600.5510	3574.8070	3773.6010	3604.6290	3582.4540	3574.8070	3610.2070	3579.7800	
20	1826.3230	1815.2970	1818.2270	1836.1620	1819.9390	1839.7810	1818.2270	1820.0220	1827.2730	
21	1753.9260	1625.8340	1626.9370	1756.8300	1628.4410	1634.9950	1626.9370	1628.6600	1646.9120	
22	2635.7940	2536.4950	2544.9450	2652.9660	2539.3930	2544.8220	2544.9450	2540.9840	2559.9350	
23	1570.7210	1527.8040	1540.3470	1573.2650	1514.4450	1516.5440	1540.3470	1513.3070	1518.8560	
24	2177.0220	2125.4410	2106.3580	2174.9880	2125.5820	2088.4050	2106.3580	2129.4140	2104.2400	
25	1986.4280	1945.5540	1939.0150	1980.1470	1937.3800	1931.1150	1939.0150	1934.3530	1930.4260	
26	2046.8000	2026.3920	2037.9500	2050.7310	2032.7970	2030.7210	2037.9500	2033.4560	2039.3610	
27	1016.5440	1034.5370	1034.1550	1022.9390	1038.9240	1038.8210	1034.1550	1038.9850	1041.3940	
28	1950.6390	1909.9160	1942.6420	1953.7120	1909.0390	1919.2090	1942.6420	1916.5250	1922.0180	

ข้อมูลชุดที่	ค่า AIC ของ ES Model									
	ETS(A,N,N)	ETS(A,N,A)	ETS(A,N,M)	ETS(A,A,N)	ETS(A,A,A)	ETS(A,A,M)	ETS(A,M,N)	ETS(A,M,A)	ETS(A,M,M)	ETS(A,M,M)
29	1386.7670	1391.2200	1390.5960	1380.4320	1387.2600	1385.7720	1390.5960	1381.2830	1388.1090	1388.1090
30	1500.9810	1486.4130	1485.1490	1510.5270	1488.6300	1488.0490	1485.1490	1488.1690	1487.2330	1487.2330
31	893.9938	788.9547	782.5960	898.2146	793.0488	786.0237	782.5960	794.0385	793.9845	793.9845
32	764.6317	767.9660	836.8279	769.7107	772.2462	783.3369	836.8279	772.0999	790.9103	790.9103
33	169.7502	171.7664	173.2321	173.1165	165.5212	166.1259	173.2321	165.9000	166.6158	166.6158
34	512.0325	491.5195	485.1323	516.0207	495.7705	488.6416	485.1323	495.6306	489.0745	489.0745
35	423.0552	365.8517	347.6788	428.3057	369.7410	353.5626	347.6788	368.0836	354.5124	354.5124
36	670.3102	655.2817	680.6722	675.1890	659.3773	679.5466	680.6722	659.4511	695.0586	695.0586
37	1035.2730	963.3917	958.3623	1038.8815	969.2850	971.3610	958.3623	972.3348	942.5501	942.5501
38	891.2611	884.3500	893.0711	902.0650	875.1768	900.0373	893.0711	875.7881	879.6535	879.6535
39	993.0778	927.7209	923.8266	997.4017	933.4759	943.1651	923.8266	935.5906	951.8499	951.8499
40	804.6562	787.1553	781.0828	813.3086	792.3668	786.0017	781.0828	791.9181	785.9159	785.9159

ตารางแสดงค่าพารามิเตอร์ของวิธีทำใหเรียบแบบเอ็กซ์โปเนนเชียล (ES) และตัวแบบที่เหมาะสมที่สุดของข้อมูล 40 ชุด

no.	Smoothing parameters			Initial states:			sigma	Model
	alpha	beta	gamma	l	b	s		
1	0.2611	0.0001	0.0001	11.3188	0.0924	0.1435, 0.1905, 0.4911, 0.0082, 0.5736, 0.352, 0.0461, -1.1781, -1.4169, 1.1025, -0.4262, 0.1139	0.8343	AAA
2	0.4669	0.0001	0.0001	41960	1.0009	0.9037, 0.9539, 1.0327, 1.0071, 1.0494, 1.0518, 1.037, 1.0982, 1.0026, 1.0639, 0.9076, 0.8921	2715.9	AMM
3	0.9276	0.0001	0.0001	11286.5986	54.2457	-960.0371, -416.5078, 67.8752, 57.3472, 370.1497, 545.0302, 529.8133, 1309.634, 45.4287, 724.8741, -1154.117, -1119.491	365.554	AAA
4	0.6898	-	0.0001	121.4133	-	-4.6156, -19.5469, 0.0103, 0.2749, 7.7685, 9.0641, -2.968, 3.7972, 5.4341, 4.1437, -6.4366, 3.0742	10.522	ANA
5	0.7047	-	0.0001	174.7828	-	-11.4758, -24.5383, -3.4523, -3.2138, 3.052, 6.0971, 1.4695, 11.2145, 4.6257, 14.2502, -5.733, 7.7042	12.1431	ANA
6	0.6875	-	0.0001	58.5055	-	-2.1151, -1.8857, 1.5687, -0.4748, 0.5604, 2.1477, -1.1174, 2.3124, -0.83, 1.9083, -4.3944, 2.3199	4.7045	ANA
7	0.0206	-	0.1851	61.1659	-	1.5397, 0.0353, 0.0017, 0.0035, 0.0083, 3e-04, 0.5006, 0.3819, 0.7379, 2.8261, 2.9988, 2.9658	87.1117	ANM
8	0.4700	-	0.0001	490.0658	-	9.1342, -16.0171, 15.5524, -3.0339, 14.1408, 26.0515, -23.5291, 3.3652, -8.9024, 4.3667, -47.0267, 25.8983	44.4211	ANA

no.	Smoothing parameters			Initial states:				sigma	Model
	alpha	beta	gamma	l	b	s			
9	0.541	0.0001	0.0074	651.05	0.9975	0.9649, 1.008, 1.1302, 1.1177, 1.0465, 1.0571, 0.9671, 0.9882, 0.8091, 1.0531, 0.9466, 0.9115	111.7183	AMM	
10	0.0084	0.0001	0.0511	68.167	0.9943	1.9849, 0.0174, 2e-04, 0.0175, 8e-04, 0.0142, 2e-04, 0.0658, 0.7722, 2.1799, 3.3921, 3.5547	114.6099	AMM	
11	0.1757	0.0103	0.0001	961.1178	19.7012	1.0468, 0.9035, 0.989, 0.9762, 1.004, 1.0634, 1.0049, 1.0616, 1.0253, 0.9999, 0.909, 1.0164	130.5164	AAM	
12	0.0001	-	-	32.9826	-	-	4.8598	ANN	
13	0.2827	-	0.0028	143.6253	-	1.005, 0.9797, 0.8488, 0.8561, 0.8993, 0.8819, 0.9565, 1.1072, 1.2533, 1.2709, 0.9623, 0.9789	15.2368	ANM	
14	0.7535	0.0020	0.0002	734.1245	2.5978	0.8881, 0.9983, 0.9772, 1.0013, 1.0212, 1.0491, 1.0841, 1.0626, 0.8934, 1.0906, 0.9844, 0.9498	88.1601	AAM	
15	0.4995	-	0.0001	21.5569	-	9.9601, 10.5121, 5.9697, -10.8013, -19.4499, -15.5847, -2.5527, 4.709, 2.4395, 7.3181, 3.7534, 3.7267	6.6463	ANA	
16	0.4895	0.0001	0.0001	2.5435	0.0381	0.903, 1.0374, 1.0469, 1.0633, 1.0204, 1.0104, 0.9624, 1.038, 0.861, 1.1248, 0.9737, 0.9589	0.7013	AAM	
17	0.1269	-	0.0001	38.3719	-	-2.0083, -1.78, -2.7754, -1.9683, -1.8417, -0.241, -1.0416, 5.2691, 2.4092, 4.6856, -0.508, -0.1995	5.4969	ANA	

no.	Smoothing parameters			Initial states:				sigma	Model
	alpha	beta	gamma	l	b	s			
18	0.3877	0.0001	0.0001	88.1403	0.6339	23.2869, -1.5126, -8.3681, -4.6565, 2.2475, 1.2579, -13.7057, -9.2049, -2.2182, 11.8845, -1.1417, 2.1308		10.2829	AAA
19	0.5172	-	0.0208	336.4203	-	0.4164, 1.0851, 2.5952, 3.1819, 1.8658, 0.7126, 0.8845, 0.4269, 0.2325, 0.1652, 0.1652, 0.2687		316.8459	ANM
20	0.6038	0.0075	0.0068	229.3915	5.0131	0.8427, 0.9629, 1.0086, 1.0593, 1.0328, 1.0627, 1.0447, 0.8842, 1.0683, 0.9817, 0.9834		30.2952	AAM
21	0.4127	-	0.0010	1920.6113	-	-273.4803, -141.6134, -37.172, -14.992, -9.4806, -43.2033, 47.5027, 130.1836, -56.6451, 358.7742, 41.099, -0.9727		102.6012	ANA
22	0.6689	-	0.0001	2771.2646	-	-151.7659, 393.4481, 833.1343, 637.6501, 490.9756, -311.0078, -23.642, -254.5695, -599.38, -443.7608, -592.8113, -600.2863		289.2088	ANA
23	0.5724	0.0001	0.0019	771.4742	1.0033	-55.3116, 32.0191, 79.9177, 49.825, 40.0644, 30.8968, 19.7475, 11.5179, -122.8972, 41.8782, -79.397, -48.2608		62.4403	AMA
24	0.7390	0.0025	0.0001	145.2900	19.0750	0.922, 0.9291, 0.9028, 1.0654, 1.0708, 1.0489, 1.0302, 1.0188, 0.9103, 1.1253, 1.0033, 0.9732		110.7565	AAM
25	0.0317	0.0001	0.0002	117.2891	1.0021	1.0085, 1.0724, 0.9202, 0.9618, 0.9025, 1.0288, 1.0211, 0.9796, 1.0276, 1.0623, 0.9979, 1.0174		21.2388	AMM

no.	Smoothing parameters			Initial states:				sigma	Model
	alpha	beta	gamma	l	b	s			
26	0.6546	-	0.0002	405.2536	-	9.4386, -10.9408, -1.3842, 16.9627, 1.5341, -16.4107, 17.021, 19.6091, -17.3926, 51.7709, -39.2909, -30.9173	55.2005	ANA	
27	0.1414	-	-	123.7313	-	-	19.9176	ANN	
28	0.4773	0.0001	0.0001	171.0937	2.7844	-11.4613, -33.237, -32.8839, -38.3926, -5.5538, 4.7137, -9.3665, 26.3949, 60.3802, 43.7592, -4.27, -0.0828	37.4933	AAA	
29	0.0001	0.0001	-	31541.3545	139.7643	-	3482.62	AAN	
30	0.2990	-	0.0001	116079.4082	-	1.0268, 0.9643, 1.0603, 0.9636, 1.0221, 0.9993, 0.9936, 1.0632, 0.9217, 1.0791, 0.9823, 0.9235	7145.048	ANIM	
31	0.3618	-	0.0001	33.3116	-	0.8625, 1.1213, 1.3321, 1.1744, 1.0519, 1.1244, 1.1632, 1.1221, 0.8759, 0.7781, 0.6561, 0.7381	3.6295	ANIM	
32	0.9999	-	-	61.4808	-	-	3.5122	ANN	
33	0.7483	0.0005	0.0001	2.7266	0.0003	-0.13, 0.059, -0.0369, 0.1425, 0.1857, 0.0305, 0.0955, 0.0799, -0.0978, -0.0877, -0.0672, -0.1735	0.196	AAA	
34	0.7222	-	0.0001	3.5276	-	0.9481, 1.0705, 0.9646, 0.9939, 0.9995, 1.0195, 1.2754, 1.1988, 0.9421, 0.8884, 0.8358, 0.8633	0.8922	ANIM	
35	0.3352	-	0.0001	1.6033	-	0.6943, 0.7185, 0.8898, 0.9352, 0.724, 0.5955, 0.7438, 1.3395, 1.7995, 1.59, 1.101, 0.869	0.5777	ANIM	

no.	Smoothing parameters			Initial states:					sigma	Model
	alpha	beta	gamma	l	b	s				
36	0.9999	-	0.0001	29.1247	-	0.8627, -0.2423, -0.3812, -1.0708, -0.1265, 0.4522, 0.6141, -0.3275, -1.8083, -1.7561, 1.7479, 2.0357	1.9908	ANA		
37	0.9823	0.0001	0.014	28.998	0.9982	0.6851, 0.698, 0.9602, 1.2241, 1.3274, 1.1466, 1.0062, 1.0249, 1.1175, 1.0841, 0.9357, 0.7902	7.6577	AMM		
38	0.9999	0.0001	0.0001	115.4740	0.2319	-7.4427, -7.2439, -6.4113, 0.9648, 5.485, 4.084, 6.3912, 7.5983, 6.1313, -2.387, -1.427, -5.7427	5.5729	AAA		
39	0.9976	-	0.0003	65.7868	-	1.1548, 1.2916, 1.2155, 1.2092, 1.2325, 1.1489, 0.9133, 0.7855, 0.7115, 0.7145, 0.7504, 0.8722	7.0658	ANM		
40	0.2808	-	0.0002	15.2088	-	0.8569, 1.0661, 1.2253, 1.0293, 0.8232, 1.0171, 1.2491, 1.1393, 0.8982, 0.9371, 0.9191, 0.8394	3.6037	ANM		

ตารางแสดงจำนวนชั้นซ่อนของตัวแบบโครงข่ายประสาทเทียม (ANN) ที่ให้ค่า RMSE ต่ำที่สุด
ของรอบการวนซ้ำ ของชุดข้อมูล 40 ชุด

no.	best hidden layer	RMSE
1	4	0.7673
2	5	2172.8460
3	5	283.1961
4	4	14.0717
5	5	8.4223
6	4	1.5525
7	4	43.5416
8	4	37.8887
9	5	46.3159
10	4	101.7248
11	3	159.8867
12	4	3.0933
13	4	13.4802
14	4	103.6777
15	5	5.8793
16	4	0.5982
17	4	0.1760
18	4	13.9782
19	5	274.8936
20	4	0.1149
21	3	70.9604
22	5	200.9396
23	5	64.2721
24	5	139.8744
25	5	69.4676
26	5	56.6052
27	5	22.5066

no.	best hidden layer	RMSE
28	4	58.9109
29	5	2632.0670
30	3	7375.4160
31	5	4.0024
32	5	1.5135
33	4	0.1343
34	5	0.6233
35	5	0.5816
36	4	1.3747
37	5	9.6056
38	5	4.7455
39	5	7.4956
40	4	1.9838

ตารางแสดงค่าพารามิเตอร์ sigma (σ), epsilon (ϵ) และ cost (C) ของตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) ที่ดีที่สุดและค่า RMSE ของตัวแบบ สำหรับข้อมูลจำนวน 40 ชุด

ข้อมูลชุดที่	sigma (σ)	epsilon (ϵ)	cost (C)	RMSE
1	3.7513	0.0001	1	0.7312
2	2.5353	0.0001	128	2554.7092
3	3.1232	0.0001	1	324.3155
4	4.7063	0.0001	2	9.6204
5	3.8846	0.0001	1	10.9434
6	0.9600	0.0001	1	4.3767
7	6.5487	0.0001	2	83.0407
8	3.4829	0.0001	1	41.3658
9	2.7417	0.0001	1	104.9183
10	25.2302	0.0001	2	112.4292
11	2.1861	0.0001	1	122.4194

ข้อมูลชุดที่	sigma (σ)	epsilon (ϵ)	cost (C)	RMSE
12	2.4629	0.0001	1	4.7530
13	2.0608	0.0001	1	14.1873
14	2.9774	0.0001	256	83.6109
15	2.0720	0.0001	1	6.2533
16	2.2335	0.0001	1	0.6480
17	1.1448	0.0001	1	5.1995
18	3.3773	0.0001	1	9.4663
19	3.0186	0.0001	1	306.7744
20	2.7288	0.0001	16	0.1149
21	3.5059	0.0001	1	93.0855
22	3.0116	0.0001	2	272.8531
23	2.8670	0.0001	2	57.0278
24	2.4308	0.0001	1	104.6361
25	3.5111	0.0001	2	60.3207
26	3.4063	0.0001	1	52.6728
27	0.8156	0.0001	2	19.6683
28	2.9365	0.0001	2	35.4907
29	11.1377	0.0001	1	3401.4086
30	4.9065	0.0001	1	6389.6850
31	2.3773	0.0001	1	3.3612
32	3.7302	0.0001	1	3.3266
33	0.8153	0.0001	1	0.1885
34	2.9397	0.0001	1	0.8093
35	1.8327	0.0001	2	0.5385
36	4.8879	0.0001	4	1.7800
37	2.9811	0.0001	1	7.5839
38	3.4580	0.0001	1	4.9569
39	0.7307	0.0001	1	6.4312
40	0.6781	0.0001	1	3.2940

ตารางแสดงการจัดอันดับความแม่นยำของตัวแบบวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES), ตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและโครงข่ายประสาทเทียม (ES+ANN) และตัวแบบผสมระหว่างวิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียลและตัวแบบซัพพอร์ตเวกเตอร์แมชชีน (ES+SVM) พร้อมทั้งค่า RMSE ของแต่ละตัวแบบสำหรับข้อมูลจำนวน 40 ชุด

ข้อมูลชุดที่	อันดับความแม่นยำของตัวแบบ	ค่า RMSE
1	1. ตัวแบบผสม ES+ANN	0.7673
	2. ตัวแบบผสม ES+SVM	1.2379
	3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	1.4378
2	1. ตัวแบบผสม ES+ANN	2172.8460
	2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	9268.6018
	3. ตัวแบบผสม ES+SVM	9424.3861
3	1. ตัวแบบผสม ES+ANN	283.1961
	2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	521.2550
	3. ตัวแบบผสม ES+SVM	532.2873
4	1. ตัวแบบผสม ES+ANN	14.0717
	2. ตัวแบบผสม ES+SVM	42.7693
	3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	43.1506
5	1. ตัวแบบผสม ES+ANN	8.4223
	2. ตัวแบบผสม ES+SVM	10.6086
	3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	10.9276
6	1. ตัวแบบผสม ES+ANN	1.5525
	2. ตัวแบบผสม ES+SVM	1.9590
	3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	2.1040
7	1. ตัวแบบผสม ES+ANN	43.5416
	2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	49.1221
	3. ตัวแบบผสม ES+SVM	49.3410
8	1. ตัวแบบผสม ES+ANN	37.8887
	2. ตัวแบบผสม ES+SVM	44.6458
	3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	45.7958
9	1. ตัวแบบผสม ES+ANN	46.3159

ข้อมูลชุดที่	อันดับความแม่นยำของตัวแบบ	ค่า RMSE
	2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	60.1278 60.3246
10	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	101.7248 104.4008 105.1795
11	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	159.8867 202.1584 208.0202
12	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	3.0933 3.5147 3.6910
13	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	13.4802 17.9766 18.3655
14	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	103.6777 178.0292 179.9461
15	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	5.8793 14.8452 14.8705
16	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	0.5982 1.7387 1.8234
17	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	3.63286 4.23110 4.42507

ข้อมูลชุดที่	อันดับความแม่นยำของตัวแบบ	ค่า RMSE
18	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	13.9782 15.6146 15.6152
19	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	274.8936 360.7297 363.2336
20	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	27.9249 82.8885 83.8952
21	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	70.9604 93.8491 95.1555
22	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	200.9396 774.6048 784.4228
23	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	64.2721 118.2827 118.4373
24	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	139.8744 300.4732 304.4506
25	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	69.4676 79.6034 81.8962
26	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	56.6052 57.4398 57.8403

ข้อมูลชุดที่	อันดับความแม่นยำของตัวแบบ	ค่า RMSE
27	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	22.5066 24.1590 26.2926
28	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	58.9109 73.3231 73.8745
29	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	2632.0670 2662.4939 2741.8749
30	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	7375.4160 15133.7455 15599.4026
31	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	4.0024 4.1450 4.5602
32	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	1.5135 6.0722 6.4828
33	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	0.1343 0.4662 0.7780
34	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	0.6233 0.7134 0.8574
35	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	0.5816 0.6970 0.9748

ข้อมูลชุดที่	อันดับความแม่นยำของตัวแบบ	ค่า RMSE
36	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	1.3747 1.4097 1.7652
37	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	9.6056 22.1691 22.2000
38	1. ตัวแบบผสม ES+ANN 2. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES) 3. ตัวแบบผสม ES+SVM	4.7455 14.8289 14.9950
39	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	7.4956 13.4030 13.4420
40	1. ตัวแบบผสม ES+ANN 2. ตัวแบบผสม ES+SVM 3. วิธีทำให้เรียบแบบเอ็กซ์โปเนนเชียล (ES)	1.9838 2.1888 2.5413



คำสั่งการวิเคราะห์ข้อมูลด้วยโปรแกรม R เวอร์ชัน 3.6.1

Library used in analysis

```
library(smooth)
library(forecast)
library(DMwR)
library(neuralnet)
library(e1071)
library(kernlab)
library(Metrics)
```

```
a <- read.csv("E:\\dataset.csv",header=T)
t <- read.csv("E:\\t.csv",header=T)
#head(a)
```

Select dataset (data no.25)

```
no.dataset<- 25
dat<- as.numeric(as.character(a[,no.dataset]))
T<-t[no.dataset,]
data<- dat[1:T]
plot(data,type="l")
#plot(decompose(ts(data,frequency=12)))
abline(v=c(round(length(data)*0.8)),col="red",lty=5,lwd=2)
```

Data set splitting 80:20

```
no.train<- round(length(data)*0.8)
no.test<- length(data) - no.train
train_data<- ts(data[1: no.train], frequency=12)
test_data<- ts(data[no.train+1 : no.test])
```

```
#####
```

```
##### 1) Exponential Smoothing (ES) #####
```

```
#####
```

```
train_data_es<- ets(train_data,ic="aic",model="AZZ", damped= FALSE, restrict=FALSE)
```

```
train_data_es
```

```
#forecast data by using train_data_es model
```

```
test_dat_es<- forecast(train_data_es,h= no.test)
```

```
plot(test_dat_es)
```

```
res_train_es<- data.frame(resid(train_data_es))
```

```
test_data_es<- data.frame(test_dat_es)[,1]
```

```
forecast_es_test<- test_data_es
```

```
res_test_es<- test_data - forecast_es_test
```

```
plot(forecast_es_test, type="l")
```

```
### Computing MSE and RMSE from ES testing data set ###
```

```
crite.es.test<-regr.eval(test_data, forecast_es_test, stat=c("mse","rmse"))
```

```
crite.es.test
```

```
#####
```

```
##### 2) Hybrid ES+ANN #####
```

```
#####
```

```
### _____ 2.1 ES+ANN (TRAINING) _____ ###
```

```
### Transform the residuals by Min-Max normalization ###
```

```
norm_train_res<- (res_train_es-min(res_train_es))/(max(res_train_es)-min(res_train_es))
```



```

X<- data.frame(X= norm_train_res[1:(no.train-1),])
Y<- data.frame(Y= norm_train_res[2:no.train,])
norm_res_train_dat<- data.frame(X,Y)

no.input <- 1
no.hidden <- 5
no.output <- 1
no.iteration<- 100
J<- c()
I<- c()
Weight<- c()
RMSE<- c()

for(i in 1:no.iteration){
  for(j in 1:no.hidden){

ann_train<- neuralnet(Y~X, data= norm_res_train_dat, hidden=j, algorithm = "rprop+",
  learningrate.factor = list(minus = 0.5, plus = 1.2), act.fct="tanh",
  linear.output=TRUE)
weight<- ann_train$startweights
Weight<- c(Weight, weight)
predict_ann_train<- ann_train$net.result[[1]]
rmse <- rmse(as.numeric(Y[[1]]), predict_ann_train)
J<- c(J,j)
I<- c(I,i)
RMSE<- c(RMSE, rmse)

}
}

all_ann_train<- data.frame(hidden_neuron=J, iteration=I, RMSE=RMSE)

```

Choose the best hidden neuron & weight by using RMSE

```
minrms_ann<- which.min(all_ann_train$RMSE)
best_ann<- all_ann_train[minrms_ann,]
best_weight<- Weight[minrms_ann]
best_hidden<- all_ann_train[minrms_ann,1]
```

2.2 ES+ANN(TESTING)

Normalization residuals from the best testing ES model

```
norm_test_res<- (res_test_es - min(res_test_es))/(max(res_test_es) - min(res_test_es))
norm_test_res<- data.frame(norm_test_res)
```

Forecasting by the best ANN model

```
X<- data.frame(X= norm_test_res[1:(no.test-1),])
Y<- data.frame(Y= norm_test_res[2:no.test,])
norm_res_test_dat<- data.frame(X,Y)
```

```
best_ann_test<- neuralnet(Y~X, data=norm_res_test_dat, startweights=best_weight,
  hidden=best_hidden, algorithm="rprop+", learningrate.factor = list(minus = 0.5,
  plus = 1.2), act.fct="tanh", linear.output=TRUE)
```

```
norm_res_test_forecast<- best_ann_test$net.result[[1]]
```

Denormalize forecasting value

```
res_test_forecast<- (norm_res_test_forecast*(max(res_test_es)-
  min(res_test_es)))+min(res_test_es)
```

Calculate Total forecasting (ES+ANN) in testing data set

```
real_test_data<- test_data
forecast_ann_test <- c(rep(0,1),res_test_forecast)
total_forecast_es_ann_test<- as.numeric(forecast_es_test + forecast_ann_test)
total_es_ann_test<- cbind(real_test_data, forecast_es_test, forecast_ann_test,
  total_forecast_es_ann_test)
```

**### Compare real data VS fitted values from the best Hybrid ES+ANN models
in testing data ###**

```
plot(test_data, col=" blue", type="l", ylab="", main="Real testing data VS Fitted
  values(ES vs ES+ANN)")
lines(forecast_es_test, col="red")
lines(total_forecast_es_ann_test, col="green")
```

Compute MSE and RMSE from Hybrid ES+ANN models testing data set

```
crite.es.ann.test<- regr.eval(real_test_data, total_forecast_es_ann_test,
  stat=c("mse","rmse"))
crite.es.ann.test
```

#####

3) Hybrid ES+SVM models

#####

_____ 3.1 ES+SVM(TRAINING) _____

```
svm_train_dat<- data.frame(res_train_es)
```

Find the best C and epsilon for SVM

```
X<- data.frame(X= res_train_es[1: (no.train-1),])
```

```
Y<- data.frame(Y= res_train_es[2: no.train,])
```

```
svm_train_dat1<- data.frame(X,Y)
```

```
obj<- tune.svm(Y~X, data=svm_train_dat1, cost=c(2^(0:10)), epsilon=c(10^(-4):1),
  kernel='radial')
```

```
best_c<- obj$best.parameters[1]
```

```
best_epsilon<- obj$best.parameters[2]
```

```
no.iterations<- 100
```

```
Forecast_svm_train<- c()
```

```

J<- c()
RMSE<- c()
SIGMA<- c()

for(j in 1:no.iterations){
  ## estimate sigma for the kernel ##
  srange.train<- sigest(res_train_es[2:no.train,]~res_train_es[1:(no.train-1)],
    data=svm_train_dat)
  svm_train<- ksvm(res_train_es[2:no.train,]~ res_train_es[1:(no.train-1)],
    data=svm_train_dat, kernel="rbfdot", C=best_c, epsilon = best_epsilon,
    kpar=list(sigma=srange.train[2]))
  rmse<- rmse(res_train_es[2:no.train,], predict(svm_train))
  J<- c(J,j)
  RMSE<- c(RMSE, rmse)
  SIGMA<-c(SIGMA, srange.train[2])
}
all_svm_train<- data.frame(sigma.value=SIGMA, iteration=J, RMSE=RMSE)
### Choose the best sigma by using RMSE ###
i<- which.min(all_svm_train[,3])
#best_svm<- all_svm_train[i,]
best_sigma<- SIGMA[i]

### _____ 3.2 ES+SVM(TESTING) _____ #####

### Using residuals from testing data by the ES model to bulid SVM model
###
svm_test_dat<- data.frame(res_test_es)
### Forecasting by the best SVM model ###
best_svm_test<- ksvm(res_test_es[2:no.test]~res_test_es[1:(no.test-1)],
  data=svm_test_dat, kernel="rbfdot", C=best_c, epsilon=best_epsilon,
  kpar=list(sigma=best_sigma))

```

Calculate Total forecasting (ES + SVM) in testing data set

```
forecast_svm_test <- c(rep(0,1), predict(best_svm_test))
total_forecast_es_svm_test<- forecast_es_test + forecast_svm_test
total_es_svm_test<- cbind(test_data, forecast_es_test, forecast_svm_test,
  total_forecast_es_svm_test)
```

Compute MSE and RMSE from ES+SVM models in testing data set

```
crite.es.svm.test<- regr.eval(test_data[2:no.test], total_forecast_es_svm_test[2:no.test],
  stat=c("mse","rmse"))
```

```
crite.es.svm.test
```

#####

Compare real data VS ES models VS Hybrid ES+ANN models VS Hybrid ES+SVM models in testing data set

#####

Plot graph

```
y.min<- min(test_data, forecast_es_test, total_forecast_es_ann_test,
  total_forecast_es_svm_test)
y.max<- max(test_data, forecast_es_test, total_forecast_es_ann_test,
  total_forecast_es_svm_test)
plot(test_data, col="black", type="l", ylab="", ylim=c(y.min, y.max), main="Real testing
  data VS Fitted values(ES vs ES+ANN vs ES+SVM)")
lines(forecast_es_test, col="blue", type="l", pch=15, lwd=1)
lines(forecast_es_test, col="blue",type="b",pch=15, lwd=1, cex=0.8)
lines(total_forecast_es_ann_test, col="red",type="l", pch=17, lwd=1)
lines(total_forecast_es_ann_test, col="red",type="b", pch=17, lwd=1, cex=0.8)
lines(total_forecast_es_svm_test, col="chartreuse3", type="l", pch=16, lwd=1)
lines(total_forecast_es_svm_test, col="chartreuse3", type="b", pch=16, lwd=1)
```

Compute MSE and RMSE from ES models, Hybrid ES+ANN models and Hybrid ES+SVM models in testing data set

```
crite.test<- matrix(c(crite.es.test, crite.es.ann.test, crite.es.svm.test), nrow=3, ncol=2,  
  byrow=T)  
colnames(crite.test)<- c("mse", "rmse")  
rownames(crite.test)<- c("ES", "ES+ANN", "ES+SVM")  
crite.test
```



ประวัติผู้เขียน

ชื่อ-สกุล	นางสาวแซนนี่ ชั่ว
วัน เดือน ปี เกิด	3 ตุลาคม 2537
วุฒิการศึกษา	สำเร็จการศึกษาคณะวิศวกรรมศาสตร์ สาขาวิศวกรรมไฟฟ้า (วศ.บ.) สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง ในปีการศึกษา 2559 และเข้าศึกษาต่อในหลักสูตรวิทยาศาสตรมหาบัณฑิต (วท.ม.) สาขาวิชาสถิติ ภาควิชาสถิติ คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย ในปีการศึกษา 2560



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY