

การพยากรณ์จำนวนนักท่องเที่ยวต่างชาติที่มาจากประเทศไทยโดยใช้ข้อมูลเวลาและโครงข่ายประสาทเทียม



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมอุตสาหการ ภาควิชาวิศวกรรมอุตสาหการ
คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ปีการศึกษา 2563
ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

Forecasting International Tourist Arrivals to Thailand using Time Series and Artificial
Neuron Network



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

Department of Industrial Engineering

FACULTY OF ENGINEERING

Chulalongkorn University

Academic Year 2020

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพยากรณ์จำนวนนักท่องเที่ยวต่างชาติที่มาจากประเทศไทย
	โดยใช้ข้อมูลระยะเวลาและโครงข่ายประสาทเทียม
โดย	นายภณพล อเนกคุณวุฒิ
สาขาวิชา	วิศวกรรมอุตสาหการ
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	รองศาสตราจารย์ ดร.นระเกณท์ พุ่มชูศรี

คณะวิศวกรรมศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต

.....	คณบดีคณะวิศวกรรมศาสตร์
(ศาสตราจารย์ ดร.สุพจน์ เตชวรสินสกุล)	
คณะกรรมการสอบวิทยานิพนธ์	
.....	ประธานกรรมการ
(รองศาสตราจารย์ ดร.ดาริชา สุธีวงศ์)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(รองศาสตราจารย์ ดร.นระเกณท์ พุ่มชูศรี)	
.....	กรรมการ
(ดร.นันทชัย กานตานันทะ)	
.....	กรรมการภายนอกมหาวิทยาลัย
(ผู้ช่วยศาสตราจารย์ ดร.มานพ เรียวเดชะ)	

ภณพล อเนกคุณวุฒิ : การพยากรณ์จำนวนนักท่องเที่ยวต่างชาติที่มาประเทศไทยโดยใช้
อนุกรมเวลาและโครงข่ายประสาทเทียม. (Forecasting International Tourist
Arrivals to Thailand using Time Series and Artificial Neuron Network) อ.ที่
ปรึกษาหลัก : รศ. ดร.นระเกณท์ พุ่มชูศรี

อุตสาหกรรมการท่องเที่ยวเป็นหนึ่งในอุตสาหกรรมที่ใหญ่ที่สุดในโลกและส่งผลโดยตรง
ต่อเศรษฐกิจของประเทศไทย การพยากรณ์จำนวนนักท่องเที่ยวต่างชาติที่เข้ามาท่องเที่ยวแต่ละ
เดือนมีประโยชน์ในการนำไปใช้วางแผนรับมือกับความต้องการท่องเที่ยวของชาวต่างชาติแต่ละ
ประเทศ เนื่องจากรูปแบบการพยากรณ์ที่เฉพาะเจาะจงสามารถบ่งบอกถึงลักษณะของการ
ท่องเที่ยวของแต่ละประเทศได้ งานวิจัยนี้มีวัตถุประสงค์เพื่อนำเสนอและเปรียบเทียบรูปแบบการ
พยากรณ์สำหรับนักท่องเที่ยวต่างชาติที่เข้ามาในประเทศไทย ประเทศที่จะทำการวิเคราะห์ ได้แก่
ประเทศจีน ญี่ปุ่น เกาหลี มาเลเซีย รัสเซีย อังกฤษ สหรัฐอเมริกา สิงคโปร์ อินเดีย ออสเตรเลีย
ลาว ฮองกง และเยอรมัน ข้อมูลที่ใช้ในการวิจัยนี้คือจำนวนนักท่องเที่ยวต่างชาติซึ่งถูกบันทึก
เป็นข้อมูลรายเดือนตั้งแต่ เดือนมกราคม พ.ศ. 2556 ถึงตุลาคม พ.ศ. 2562 รูปแบบการพยากรณ์ที่
นำมาใช้ ได้แก่ รูปแบบ ค่าเฉลี่ยเคลื่อนที่ตามฤดูกาลอัตโนมัติ (SARIMA) ตรรกอนมิติตามฤดูกาลการ
แปลงบ็อกซ์ค็อกซ์ ค่าเฉลี่ยเคลื่อนที่แบบเคลื่อนไหวอัตโนมัติแนวโน้มและฤดูกาล (TBATS) และ
โครงข่ายประสาทเทียม (ANN) จากนั้นวัดผลความแม่นยำโดยค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาด
แบบสัมบูรณ์ (MAPE) ผลการศึกษาพบว่า ประเทศส่วนใหญ่ที่ศึกษา SARIMA เป็นวิธีที่ให้ค่าความ
คลาดเคลื่อนน้อยที่สุด อย่างไรก็ตามประเทศไทยการพยากรณ์แบบอนุกรมเวลายังไม่ให้ผลเป็นที่น่า
พอใจ (MAPE เกิน 8%) ได้แก่ ประเทศจีน อินเดีย และรัสเซีย และได้ใช้วิธี ANN ในการพยากรณ์
เปรียบเทียบเพิ่มเติม ซึ่งมีเพียงประเทศจีนเท่านั้นที่ ANN ได้ผลแม่นยำกว่าวิธีอื่น

สาขาวิชา วิศวกรรมอุตสาหการ
ปีการศึกษา 2563

ลายมือชื่อนิสิต
ลายมือชื่อ อ.ที่ปรึกษาหลัก

6170236021 : MAJOR INDUSTRIAL ENGINEERING

KEYWORD: Forecasting, Tourism Industry, Tourists, SARIMA, TBATS, ANN

Panapol Anekkunnawut : Forecasting International Tourist Arrivals to Thailand using Time Series and Artificial Neuron Network. Advisor: Assoc. Prof. NARAGAIN PHUMCHUSRI, Ph.D.

Tourism industry is one of the largest industry in the world and it directly impacts Thai economy. Forecasting the monthly number of foreign tourists visiting Thailand is useful for planning the tourism needs from each country because the specific forecasting patterns can indicate the nature each country's tourists. This research objective is to present and compare forecasting models for foreign tourists visiting Thailand. Countries to be analyzed include China, Japan, Korea, Malaysia, Russia, the United Kingdom, the United States of America, Singapore, India, Australia, Laos, Hong Kong, and Germany. The data used in this research is the number of foreign tourists visiting Thailand from these countries recorded monthly from January 2013 to October 2019. The forecasting models considered are the Seasonal Autoregressive Integrated Moving Average model (SARIMA), Trigonometric Seasonal, Box-Cox Transformation, ARMA residuals, Trend and Seasonality (TBATS), and Artificial Neural Network (ANN). The performances of these methods are evaluated by the mean absolute percentage error (MAPE). From the results, MAPE from SARIMA is the least for most counties. However, the considered time series methods are not satisfactory for China, India and Russia (MAPE $\geq 8\%$). ANN method is tested in these three countries and it can help reducing errors only for China.

Field of Study: Industrial Engineering

Student's Signature

Academic Year: 2020

Advisor's Signature

กิตติกรรมประกาศ

การที่วิทยานิพนธ์ฉบับนี้สามารถสำเร็จลุล่วงไปได้ด้วยดี ข้าพเจ้าขอขอบพระคุณ รองศาสตราจารย์ ดร.นระเกณท์ พุ่มชูศรี อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้มอบความรู้ คำแนะนำอันมีค่า และความช่วยเหลือต่าง ๆ ตลอดการจัดทำวิทยานิพนธ์ ขอขอบพระคุณรองศาสตราจารย์ ดร. ดาริชา สุธีวงศ์ ดร. นันทชัย กานตาทันตะ และ ผู้ช่วยศาสตราจารย์ ดร. มานพ เรียวเดชะ กรรมการสอบวิทยานิพนธ์ที่ช่วยให้คำแนะนำและชี้จุดบกพร่องให้วิทยานิพนธ์ฉบับนี้ ขอขอบคุณ นายธารินทร์ โชติวณิช นายพรภวิชัย เนียมจ้อย และนายอาทิตย์ โคตรแสนลี ที่คอยให้คำปรึกษา และให้ความช่วยเหลือต่าง ๆ อันเป็นประโยชน์ต่อการทำวิทยานิพนธ์ฉบับนี้

สุดท้ายนี้ ข้าพเจ้าขอกราบขอบพระคุณ บิดา มารดา ผู้ให้กำเนิด ที่คอยเป็นกำลังใจ และแรงสนับสนุนอันดีให้กับข้าพเจ้าตลอดมา

ภณพล อเนกคุณวุฒิ



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

สารบัญ

	หน้า
.....	ค
บทคัดย่อภาษาไทย.....	ค
.....	ง
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญรูปภาพ.....	ฎ
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาของอุตสาหกรรมการท่องเที่ยว.....	1
1.2 จำนวนของนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทยในปี 2561 และ แนวโน้มจำนวนของนักท่องเที่ยวต่างชาติของปี 2562.....	3
1.3 วัตถุประสงค์ของการวิจัย.....	9
1.4 ขอบเขตของงานวิจัย.....	10
1.5 ผลลัพธ์ของงานวิจัย.....	10
1.6 ประโยชน์ของงานวิจัย.....	10
บทที่ 2 การศึกษาวรรณกรรมที่เกี่ยวข้อง.....	12
2.1 วิธีการและทฤษฎีที่เกี่ยวข้อง.....	12
2.2 การประเมินประสิทธิภาพของแบบจำลอง.....	18
2.3 ตัวอย่างงานวิจัยที่เกี่ยวข้องกับการนำเสนอเปรียบเทียบหรือสร้างแบบจำลองการพยากรณ์ อุตสาหกรรมการท่องเที่ยว.....	19
บทที่ 3 วิธีการดำเนินงาน.....	25

3.1	ระเบียบของการวิจัย.....	25
3.2	ข้อมูลของงานวิจัยนี้.....	30
3.3	แบบจำลองการพยากรณ์.....	33
3.4	การเปรียบเทียบแบบจำลองการพยากรณ์.....	42
บทที่ 4	ผลการดำเนินงาน.....	43
4.1	วิธีอนุกรมเวลา (Time Series Method).....	43
4.2	วิธีเชิงสาเหตุ (Causal Method).....	50
บทที่ 5	บทสรุปงานวิจัยและข้อเสนอแนะ.....	66
5.1	สรุปผลงานวิจัย.....	66
5.2	ข้อจำกัดที่เกิดขึ้นในการสร้างแบบจำลอง ANN.....	68
5.3	แนวทางการต่อยอดงานวิจัยในอนาคตของการพัฒนาแบบจำลอง ANN.....	68
5.4	แนวทางการนำแบบจำลองไปใช้ในอนาคต.....	69
บรรณานุกรม.....		70
ประวัติผู้เขียน.....		93

สารบัญตาราง

หน้า

ตารางที่ 1: ลำดับของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวที่เข้ามาท่องเที่ยวในประเทศไทยมากที่สุดของแต่ละแหล่งที่มา (ปี 2561).....	4
ตารางที่ 2: ลำดับของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวที่เข้ามาท่องเที่ยวในประเทศไทยมากที่สุดของแต่ละแหล่งที่มา (ปี 2562).....	6
ตารางที่ 3: เปรียบเทียบ 16 ลำดับประเทศที่มีจำนวนนักท่องเที่ยวและรายได้มากที่สุด (ปี 2562)....	8
ตารางที่ 4: สรุปงานวิจัยที่เกี่ยวข้องกับอุตสาหกรรมการท่องเที่ยว แบบจำลองการพยากรณ์ที่ใช้ในการศึกษา และการประเมินความถูกต้องของแต่ละงานวิจัยเพิ่มเติม	21
ตารางที่ 5: ลำดับของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวมาท่องเที่ยวและสร้างรายได้สูงที่สุด	25
ตารางที่ 6: ลำดับคะแนนของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวมาท่องเที่ยวและสร้างรายได้สูงที่สุด	26
ตารางที่ 7: เลือกประเทศที่จะนำมาสร้างแบบจำลองการพยากรณ์จากคะแนนรวมของแต่ละประเทศ	27
ตารางที่ 8: ลำดับของ 13 ประเทศที่ได้เลือกนำจำนวนนักท่องเที่ยวต่างชาติที่เข้ามาท่องเที่ยวที่ประเทศไทยมาวิเคราะห์ในงานวิจัย	29
ตารางที่ 9: ความถูกต้องแม่นยำของการพยากรณ์	42
ตารางที่ 10: ผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 5 ปี เป็นชุดข้อมูลฝึกอบรม (Training) (เดือนพฤศจิกายน ปี 2556 ถึง ตุลาคม ปี 2561) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562).....	43
ตารางที่ 11: ผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 3 ปี เป็นชุดข้อมูลฝึกอบรม (Training) (เดือนพฤศจิกายน ปี 2558 ถึง ตุลาคม ปี 2561) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562).....	44
ตารางที่ 12: ผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 4 ปี เป็นชุดข้อมูลฝึกอบรม (Training) (เดือนพฤศจิกายน ปี 2557 ถึง ตุลาคม ปี 2561) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562).....	45

ตารางที่ 13: เปรียบเทียบผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 3, 4 และ 5 ปี เป็นชุดข้อมูลฝึกอบรม (Training) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562)..... 46

ตารางที่ 14: ผลจากการทดสอบแบบจำลอง (Testing model) ของ TBATS กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562) เปรียบเทียบกับการทดสอบแบบจำลอง (Testing model) SARIMA..... 47

ตารางที่ 15: Coefficients ของปัจจัยจากที่เลือกใช้กับแต่ละประเทศเพื่อนำมาสร้างแบบจำลอง ANN โดยการนำปัจจัยมาวิเคราะห์ค่าความ significant ด้วยวิธีการถดถอย (Regression) (ประเทศจีน). 50

ตารางที่ 16: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศจีน (Non-Stepwise)..... 51

ตารางที่ 17: ค่า R-sq และ R-sq (adj) ของแต่ละประเทศที่เลือกมาสร้างแบบจำลอง ANN แบบ Non-Stepwise (จีน อินเดีย และ รัสเซีย)..... 52

ตารางที่ 18: Coefficients ของปัจจัยจากที่เลือกใช้กับประเทศจีนเพื่อนำมาสร้างแบบจำลอง ANN โดยการนำปัจจัยมาวิเคราะห์ค่าความ significant ด้วยวิธีการถดถอย (Regression) (Stepwise)..... 52

ตารางที่ 19: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศจีน (Stepwise)..... 52

ตารางที่ 20: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศอินเดีย (Stepwise)..... 53

ตารางที่ 21: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศรัสเซีย (Stepwise)..... 54

ตารางที่ 22: ค่า R-sq และ R-sq (adj) ของแต่ละประเทศที่เลือกมาสร้างแบบจำลอง ANN แบบ Stepwise (จีน อินเดีย และ รัสเซีย)..... 55

ตารางที่ 23: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ ReLU function เป็น Activation function 56

ตารางที่ 24: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ ReLU function เป็น Activation function (Stepwise)	56
ตารางที่ 25: เปรียบเทียบค่า MAPE ระหว่างข้อมูลปัจจัยที่ Non-Stepwise และ Stepwise ในแต่ละจำนวนชั้นของ Hidden layer nodes (ReLU function) ของการทดสอบแบบจำลอง (Testing model) ANN	57
ตารางที่ 26: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ Sigmoid function เป็น Activation function	58
ตารางที่ 27: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ Sigmoid function เป็น Activation function (Stepwise)	59
ตารางที่ 28: เปรียบเทียบค่า MAPE ระหว่างข้อมูลปัจจัยที่ Non-Stepwise และ Stepwise ในแต่ละจำนวนชั้นของ Hidden layer nodes (Sigmoid function) ของการทดสอบแบบจำลอง (Testing model) ANN	59
ตารางที่ 29: เปรียบเทียบเวลาที่ใช้ในการฝึกอบรมแบบจำลอง (Training model) ANN ของประเทศจีนโดยเฉลี่ย จากการใช้ ReLU function และ Sigmoid function เป็น Activation function	60
ตารางที่ 30: ค่า Absolute Percentage forecasting Error values (APE) ของประเทศจีน	61
ตารางที่ 31: จัดกลุ่มโดยใช้ Tukey Method ค่าของความเชื่อมั่น 95 เปอร์เซ็นต์ (95% confidence interval).....	61
ตารางที่ 32: หาความแตกต่างของแต่ละแบบจำลองด้วยความต่างของค่าเฉลี่ย (Tukey Simultaneous Tests for Differences of Means).....	61
ตารางที่ 33: เปรียบเทียบ MAPE ที่มาจากการทดสอบแบบจำลอง (Testing model) กับข้อมูลจริงของแบบจำลอง SARIMA, TBATS และ ANN	63
ตารางที่ 34: การแนะนำการเลือกแบบจำลอง SARIMA, TBATS และ ANN จากการวิเคราะห์ของ Tukey Simultaneous 95% CIs ของทุกประเทศ	63

สารบัญรูปภาพ

หน้า

รูปที่ 1: จำนวนนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทยในแต่ละปี (2545-2561)	2
รูปที่ 2: จำนวนนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2561)	5
รูปที่ 3: จำนวนรายได้ที่ได้จากนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2561)	5
รูปที่ 4: จำนวนนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2562)	7
รูปที่ 5: จำนวนรายได้ที่ได้จากนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2562)	7
รูปที่ 6: เปรียบเทียบรูปแบบข้อมูลอนุกรมเวลาของจำนวนนักท่องเที่ยวจากประเทศมาเลเซีย เยอรมัน และ จีน (พฤศจิกายน ปี 2556 ถึง ตุลาคม ปี 2561)	9
รูปที่ 7: ลักษณะของแบบจำลอง ANN	14
รูปที่ 8: รูปแบบการป้อนข้อมูลแบบ Feed-Forward neural network	16
รูปที่ 9: รูปแบบการป้อนข้อมูลแบบ Recurrent Neural Network	16
รูปที่ 10: รูปแบบกราฟการคำนวณโดย ReLU function	17
รูปที่ 11: รูปแบบกราฟการคำนวณโดย Sigmoid function	18
รูปที่ 12: จำนวนนักท่องเที่ยวต่างชาติแต่ละประเทศที่ทำการคัดเลือกเพื่อนำมาทำการวิเคราะห์และสร้างแบบจำลอง (ปี 2562)	28
รูปที่ 13: จำนวนนักท่องเที่ยวจากประเทศเยอรมันในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561	30
รูปที่ 14: จำนวนนักท่องเที่ยวจากประเทศสหรัฐอเมริกาในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561	31

รูปที่ 15: จำนวนนักท่องเที่ยวจากประเทศสิงคโปร์ในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561.....	31
รูปที่ 16: จำนวนนักท่องเที่ยวจากประเทศลาวในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561.....	32
รูปที่ 17: จำนวนนักท่องเที่ยวจากประเทศจีนในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561	32
รูปที่ 18: จำนวนนักท่องเที่ยวจากประเทศมาเลเซียในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561.....	33
รูปที่ 19: ACF และ PACF ของประเทศสิงคโปร์ (พฤศจิกายน ปี 2556 ถึง ตุลาคม ปี 2561)	34
รูปที่ 20: จำนวนนักท่องเที่ยวจากประเทศสิงคโปร์หลังจากทำการจัดการกับฤดูกาลแล้ว (Seasonal differencing)	35
รูปที่ 21: ACF และ PACF ของประเทศสิงคโปร์หลังจากทำการจัดการกับฤดูกาลแล้ว (Seasonal differencing)	35
รูปที่ 22: ตรวจสอบแบบจำลอง SARIMA(p, d, q)(P, D, Q) _s ที่เลือก	36
รูปที่ 23: ข้อมูลที่เกี่ยวข้องกับแบบจำลอง ARIMA(1,0,0)(0,1,0) ₁₂ หรือ SARIMA(1,0,0) (0,1,0) ₁₂	36
รูปที่ 24: Flow chart ของการสร้างแบบจำลอง ANN ในงานวิจัยนี้	41
รูปที่ 25: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศมาเลเซียด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562.....	48
รูปที่ 26: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศเยอรมันด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562.....	48
รูปที่ 27: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศญี่ปุ่นด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562.....	49
รูปที่ 28: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศเกาหลีด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562.....	49
รูปที่ 29: สมการที่ได้จากการนำปัจจัยที่เลือกมาทำวิธีการถดถอย (Regression) (ประเทศจีน)	51

รูปที่ 30: สมการจากวิธีการถดถอย (Regression) ที่ได้จากการนำปัจจัยที่เลือกมาทำ Stepwise (ประเทศจีน)..... 53

รูปที่ 31: สมการจากวิธีการถดถอย (Regression) ที่ได้จากการนำปัจจัยที่เลือกมาทำ Stepwise (ประเทศอินเดีย)..... 54

รูปที่ 32: สมการจากวิธีการถดถอย (Regression) ที่ได้จากการนำปัจจัยที่เลือกมาทำ Stepwise (ประเทศรัสเซีย) 54

รูปที่ 33: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ ReLU function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 1 ชั้น 55

รูปที่ 34: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ ReLU function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 2 ชั้น 55

รูปที่ 35: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ Sigmoid function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 1 ชั้น 57

รูปที่ 36: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ Sigmoid function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 2 ชั้น 58

รูปที่ 37: เปรียบแบบจำลองแบบ Tukey Simultaneous 95% CIs 62

รูปที่ 38: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศจีนด้วยแบบจำลอง SARIMA, TBATS และ ANN..... 64

รูปที่ 39: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศอินเดียด้วยแบบจำลอง SARIMA, TBATS และ ANN..... 65

รูปที่ 40: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศจีนด้วยแบบจำลอง SARIMA, TBATS และ ANN..... 65

รูปที่ 41: ตัวอย่างข้อมูลอนุกรมเวลา (Time series data) ของประเทศอินเดียเดือน พฤศจิกายน ปี พ.ศ. 2560 ถึง เดือนตุลาคมปี พ.ศ. 2562..... 67

รูปที่ 42: ตัวอย่างข้อมูลอนุกรมเวลา (Time series data) ของประเทศรัสเซียเดือน พฤศจิกายน ปี พ.ศ. 2556 ถึง เดือนตุลาคมปี พ.ศ. 2562..... 67

บทที่ 1 บทนำ

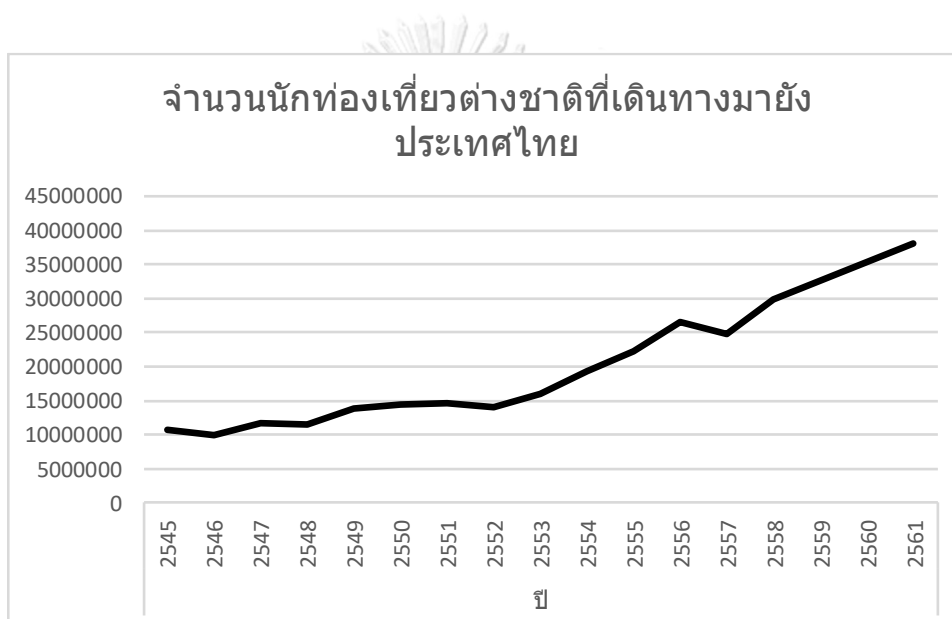
1.1 ความเป็นมาของอุตสาหกรรมการท่องเที่ยว

อุตสาหกรรมการท่องเที่ยวเป็นหนึ่งในอุตสาหกรรมที่ใหญ่ที่สุดในโลก ไม่ว่าจะประเทศใด จำเป็นที่จะต้องใช้การเดินทางระหว่างประเทศ อาจกล่าวได้ว่าการรู้ถึงลักษณะการท่องเที่ยวของประเทศต่าง ๆ จะส่งผลทำให้สามารถคาดการณ์ได้ว่าจะเกิดอะไรขึ้นในเวลานั้น เพื่อเตรียมความพร้อมสำหรับการรับมืออย่างถูกต้อง

ประเทศไทยเป็นประเทศที่มีผลิตภัณฑ์ด้านการท่องเที่ยวทางธรรมชาติ วัฒนธรรม หลากหลาย และแหล่งท่องเที่ยวชายหาดที่สวยงาม องค์ประกอบทั้งหมดเหล่านี้เป็นสิ่งที่ดึงดูดให้นักท่องเที่ยวจากทั่วโลกอยากมาท่องเที่ยวที่ประเทศไทยเป็นอย่างมาก โดยเฉพาะประเทศจากฝั่งยุโรป อเมริกา เอเชียใต้ โอเชียเนีย (Oceania) ตะวันออกกลาง และแอฟริกา นอกจากการที่มาท่องเที่ยวแล้วชาวต่างชาติบางกลุ่มได้เข้ามาที่ประเทศไทยเพื่อที่จะดูเส้นทางในการทำธุรกิจที่ประเทศไทยอีกด้วย ในนิตยสารการท่องเที่ยวและการสำรวจวิถีชีวิตหลายฉบับประเทศไทยได้รับการจัดอันดับให้ติดอันดับหนึ่งในสิบของชายหาด แหล่งบันเทิง และร้านอาหาร โดยที่กล่าวมานี้มาจากการสำรวจของนิตยสารการท่องเที่ยวชื่อว่า “โลนลี่ แพลนเน็ต (Lonely Planet)” ซึ่งเป็นนิตยสารการท่องเที่ยวที่มีคนนิยมมากโดยเฉพาะในหมู่นักท่องเที่ยวอายุน้อย ทั้งนี้แสดงให้เห็นว่าประเทศไทยเป็นจุดหมายที่ยอดนิยมในแง่ของสถานที่ท่องเที่ยว และอาหาร

เมื่อก้าวถึงวัฒนธรรมแล้วคงต้องบอกว่าประเทศไทยมีอารยธรรมเก่าแก่ที่ยังคงรักษาไว้ให้ได้ดูชมกันมากมาย โดยโบราณสถานของไทยที่เป็นแหล่งอารยธรรมโบราณที่สามารถบอกเล่าความเป็นมาของประเทศไทยยกตัวอย่าง เช่น อุทยานประวัติศาสตร์กำแพงเพชร จังหวัดกำแพงเพชร อุทยานประวัติศาสตร์สุโขทัย จังหวัดสุโขทัย อุทยานประวัติศาสตร์พระนครศรีอยุธยา จังหวัดพระนครศรีอยุธยา และ อื่น ๆ เป็นต้น

จากรูปที่ 1 แสดงให้เห็นได้ว่าจำนวนนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวในประเทศไทยมีแนวโน้มเติบโตอย่างต่อเนื่อง ซึ่งในปี 2557 เท่านั้นที่มีการลดลงของจำนวนนักท่องเที่ยวเนื่องจากมีเหตุการณ์ภายในประเทศบางอย่างจึงอาจส่งผลกระทบต่อจำนวนนักท่องเที่ยวที่ลดลงนี้ แต่หลังจากปี 2557 จำนวนนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวในประเทศไทยมีจำนวนที่เพิ่มขึ้นอย่างต่อเนื่อง หากจำนวนนักท่องเที่ยวเพิ่มขึ้นอย่างต่อเนื่องเช่นนี้จะส่งผลให้รายได้จากการท่องเที่ยวในประเทศไทยเพิ่มสูงขึ้นเช่นกัน ดังนั้นจึงมีความจำเป็นที่จะต้องคาดการณ์จำนวนนักท่องเที่ยวที่เดินทางมาท่องเที่ยวในประเทศไทยเพื่อรับมือกับสถานการณ์ต่าง ๆ ที่จะเกิดขึ้นในวันข้างหน้า



รูปที่ 1: จำนวนนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทยในแต่ละปี (2545-2561)
ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

ภาพรวมของจำนวนนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทยที่ได้เห็นจากรูปที่ 1 เป็นการนำเสนอจำนวนของนักท่องเที่ยวต่างชาติโดยรวมของหลากหลายประเทศ โดยงานวิจัยนี้จะนำข้อมูลของประเทศที่มีความสำคัญกับการท่องเที่ยวของประเทศไทยมาทำการวิเคราะห์ และสร้างแบบจำลองการพยากรณ์ที่เหมาะสมกับแต่ละประเทศ เพื่อรองรับกับความเป็นไปได้ของจำนวนนักท่องเที่ยวต่างชาติจากประเทศที่มีความสำคัญต่อการท่องเที่ยวของประเทศไทย

โดยในแต่ละประเทศจะมีลักษณะของการเดินทางมาท่องเที่ยวที่บ่งบอกถึงรูปแบบของการท่องเที่ยวของประเทศนั้น ซึ่งเหตุผลที่ใช้ในการเลือกประเทศที่จะนำข้อมูลจำนวนนักท่องเที่ยวที่เดินทางมาท่องเที่ยวที่ประเทศไทยจากประเทศเหล่านั้นมาทำการวิเคราะห์ข้อมูลและสร้างแบบจำลอง คือ จำนวนของนักท่องเที่ยวต่างชาติที่มาจากประเทศเหล่านั้นมีจำนวนมาก โดยจะมีการ

กระจายการวิเคราะห์ข้อมูลจำนวนนักท่องเที่ยวของประเทศที่สนใจในแต่ละทวีปเพื่อเน้นความหลากหลายจากแหล่งที่มาของนักท่องเที่ยวต่างชาติแต่ละประเทศเช่นกัน

1.2 จำนวนของนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทยในปี 2561 และแนวโน้มจำนวนของนักท่องเที่ยวต่างชาติของปี 2562

ในปี 2561 นักท่องเที่ยวต่างชาติที่มาเยือนประเทศไทยบรรลุเป้าหมายด้านรายได้อยู่ในอันดับที่ 4 ของโลก ประเทศไทยถือเป็นประเทศการท่องเที่ยวที่มีชื่อเสียงระดับโลกในขณะที่ยุทธศาสตร์การท่องเที่ยวของไทยเป็นส่วนสำคัญในการขับเคลื่อนเศรษฐกิจของประเทศ จากการเปิดเผยสถานการณ์การท่องเที่ยวในปี 2561 โดยกระทรวงการท่องเที่ยวและกีฬา เนื่องจากประเทศไทยมีโอกาสต้อนรับนักท่องเที่ยวชาวต่างชาติจำนวน 38,277,300 คน เพิ่มขึ้น 7.54% จากปี 2560 มีรายได้ 2,007,503 ล้านบาทเพิ่มขึ้น 9.63% รวมถึงรายได้จากการท่องเที่ยวมูลค่ากว่า 3,075,683 ล้านบาท

ในปี 2562 เป้าหมายของนักท่องเที่ยวต่างชาติอยู่ที่ 41 ล้านคน สำหรับแนวโน้มการท่องเที่ยวในปี 2562 คาดว่าจะมีโอกาสเพิ่มขึ้นที่จะได้ต้อนรับนักท่องเที่ยวต่างชาติจากปีที่แล้ว ที่มีจำนวนนักท่องเที่ยวต่างชาติอยู่ที่ 38.28 ล้านคนเพิ่มขึ้น 7.5% ซึ่งจะสามารถสร้างรายได้มากกว่า 2.21 ล้านล้านบาท เดิมโตสูงถึง 10% โดยนักท่องเที่ยวชาวจีนมีจำนวนนักท่องเที่ยวกว่า 11.69 ล้านคนจะเดินทางมาประเทศไทย และอีก 11% นักท่องเที่ยวจากประเทศอาเซียน 11.31 ล้านคนเพิ่มขึ้น 10% และ 6.9 ล้านคนจากยุโรปเพิ่มขึ้น 2%


กลุ่มของประเทศที่มีนักท่องเที่ยวต่างชาติเข้ามาท่องเที่ยวที่ประเทศไทยมากที่สุดจากทั่วโลกคือ กลุ่มประเทศที่มาจากเอเชียตะวันออก โดยประเทศที่มีจำนวนของนักท่องเที่ยวมาท่องเที่ยวที่ประเทศไทยเป็นจำนวนมากที่มาจากเอเชียตะวันออก ได้แก่ ประเทศจีน เกาหลี ลาว และญี่ปุ่น เป็นต้น

ตารางที่ 1: ลำดับของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวที่เข้ามาท่องเที่ยวในประเทศไทยมากที่สุดของแต่ละแหล่งที่มา (ปี 2561)


ลำดับที่	ประเทศ	จำนวนของนักท่องเที่ยว (2561)	รายได้ที่ได้จากนักท่องเที่ยว (ล้านบาท)
1	จีน	10,535,241	518,911.67
2	มาเลเซีย	4,020,526	105,031.60
3	เกาหลี	1,796,426	103,499.04
4	ลาว	1,664,630	80,617.59
5	ญี่ปุ่น	1,656,101	80,504.15
6	อินเดีย	1,598,346	74,487.51
7	รัสเซีย	1,472,789	71,240.05
8.	สหรัฐอเมริกา	1,122,270	67,767.18
9	สิงคโปร์	1,069,867	59,840.62
10	เวียดนาม	1,028,150	55,053.63
11	ฮ่องกง	1,015,749	49,547.94
12	อังกฤษ	986,854	45,885.74
13	เยอรมัน	886,523	38,894.23
14	กัมพูชา	948,824	38,346.73
15	ออสเตรเลีย	801,203	36,426.55
16	ฝรั่งเศส	749,556	34,031.78

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากตารางที่ 1 ทำให้ทราบถึงจำนวนนักท่องเที่ยวของประเทศสำคัญที่มีจำนวนของนักท่องเที่ยวที่เข้ามาในประเทศไทยมากที่สุด 16 ลำดับ และได้ทราบถึงรายได้ที่ได้รับจากการมาท่องเที่ยวของคนจากแต่ละประเทศของปี 2561



รูปที่ 2: จำนวนนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2561)
ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย



รูปที่ 3: จำนวนรายได้ที่ได้จากนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2561)

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

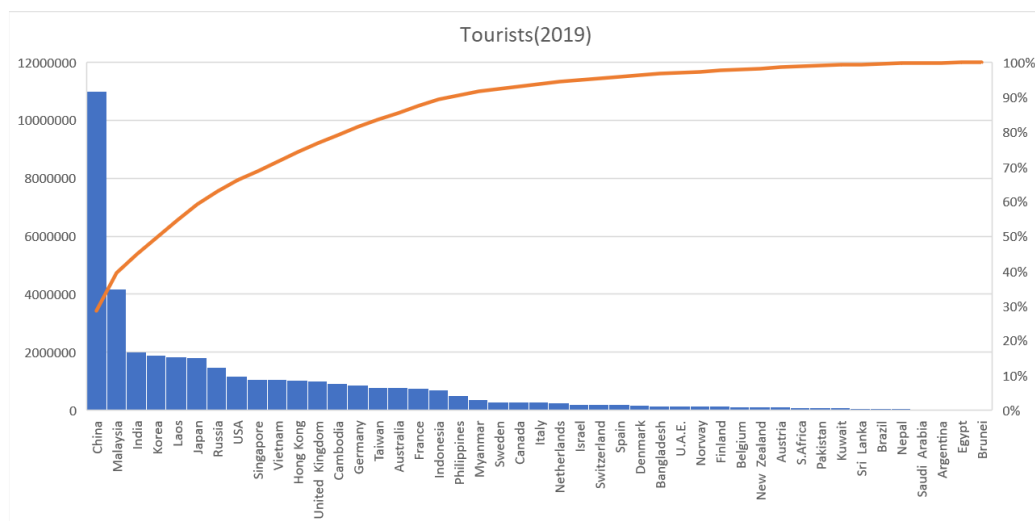
จากรูปที่ 2 และ 3 จะเห็นได้ว่าประเทศที่มีจำนวนของนักท่องเที่ยวที่เข้ามาท่องเที่ยวในประเทศไทยและจำนวนของรายได้มากที่สุด คือ ประเทศจีน มีจำนวนของนักท่องเที่ยวมากถึง 10.5 ล้านคน คิดเป็น 27.6% และรายได้กว่า 5.2 แสนล้านบาท คิดเป็น 28.98% ของชาวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทยทั้งหมด โดยประเทศจีนเป็นประเทศที่มีจำนวนนักท่องเที่ยวเป็นอันดับหนึ่งมาตลอดมากกว่า 10 ปี และมีแนวโน้มที่จะมีจำนวนเพิ่มขึ้นในทุกปี

ตารางที่ 2: ลำดับของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวที่เข้ามาท่องเที่ยวในประเทศไทยมากที่สุดของแต่ละแหล่งที่มา (ปี 2562)


ลำดับที่	ประเทศ	จำนวนของนักท่องเที่ยว (2562)	รายได้ที่ได้จากนักท่องเที่ยว (ล้านบาท)
1	จีน	10,994,721	543,707.33
2	มาเลเซีย	4,166,868	106,728.72
3	อินเดีย	1,995,516	103,784.23
4	เกาหลี	1,887,853	89,807.95
5	ญี่ปุ่น	1,806,340	86,372.01
6	ลาว	1,845,375	83,276.12
7	รัสเซีย	1,483,453	74,367.38
8.	สหรัฐอเมริกา	1,167,845	74,164.38
9	สิงคโปร์	1,056,836	56,227.85
10	เวียดนาม	1,047,629	54,881.26
11	ฮ่องกง	1,045,198	52,319.70
12	อังกฤษ	994,018	44,524.02
13	กัมพูชา	907,506	40,320.69
14	เยอรมัน	857,487	37,729.01
15	ไต้หวัน	789,923	35,766.51
16	ออสเตรเลีย	768,668	35,552.61

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากตารางที่ 2 ทำให้ทราบถึงจำนวนนักท่องเที่ยวในประเทศสำคัญที่มีจำนวนของนักท่องเที่ยวที่เข้ามาในประเทศไทยมากที่สุด 16 ลำดับ และได้ทราบถึงรายได้ที่ได้รับจากการมาท่องเที่ยวของนักท่องเที่ยวจากแต่ละประเทศของปี 2562



รูปที่ 4: จำนวนนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2562)
ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย



รูปที่ 5: จำนวนรายได้ที่ได้จากนักท่องเที่ยวต่างชาติทั้งหมดแต่ละประเทศที่เข้ามาท่องเที่ยวในประเทศไทย (ปี 2562)

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

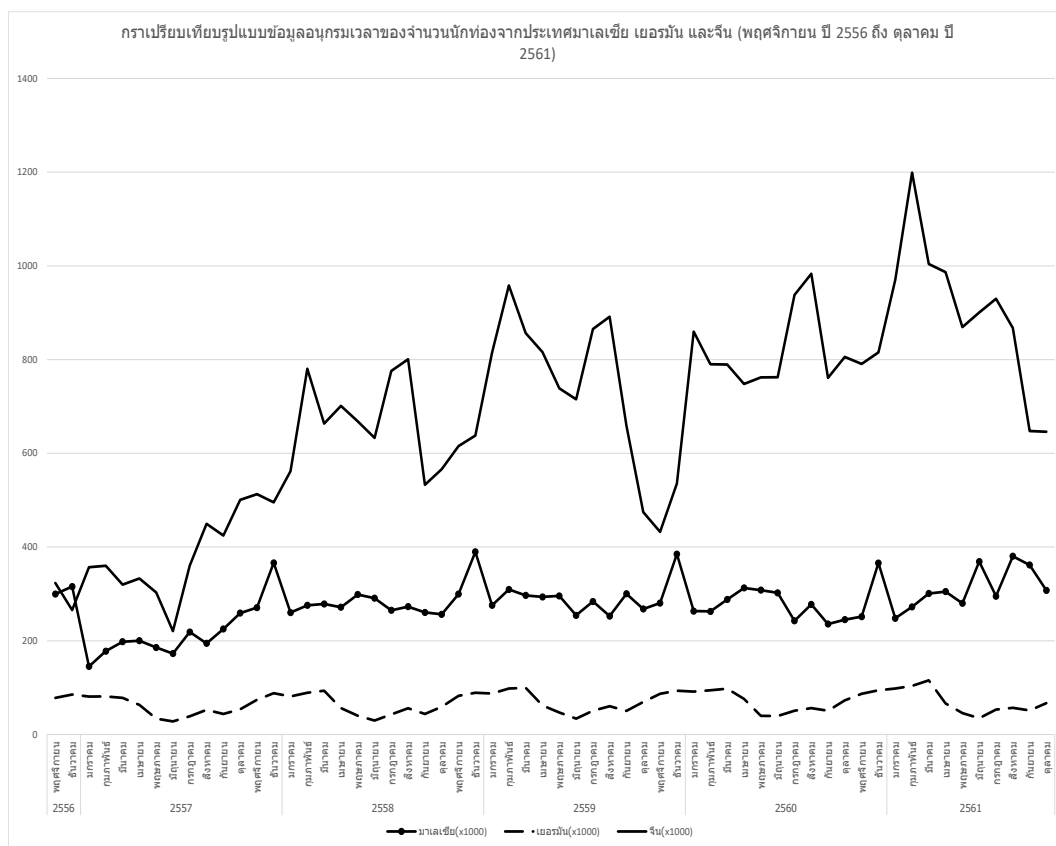
จากรูปที่ 4 และ 5 จะเห็นได้ว่ามีหลากหลายประเทศที่มีจำนวนของนักท่องเที่ยวที่เข้ามาท่องเที่ยวที่ประเทศไทยและจำนวนของรายได้ที่มาก ซึ่งในจำนวนนักท่องเที่ยวต่างชาติจากประเทศเหล่านั้นส่งผลกระทบต่อรายได้และเศรษฐกิจของประเทศไทยเป็นอย่างมาก จึงได้ทำการเรียงลำดับประเทศตามจำนวนของนักท่องเที่ยวและรายได้เพื่อทำการเลือกประเทศที่จะทำการศึกษาและสร้างแบบจำลองการพยากรณ์ที่แม่นยำมาเพื่อใช้ในการรองรับสถานการณ์ที่จะเกิดขึ้นได้อย่างเหมาะสม

ตารางที่ 3: เปรียบเทียบ 16 ลำดับประเทศที่มีจำนวนนักท่องเที่ยวและรายได้มากที่สุด (ปี 2562)

ลำดับ ที่	ประเทศ	จำนวนของ นักท่องเที่ยว (2562)	ลำดับ ที่	ประเทศ	รายได้ที่ได้จาก นักท่องเที่ยว (ล้านบาท)
1	จีน	10,994,721	1	จีน	543,707.33
2	มาเลเซีย	4,166,868	2	มาเลเซีย	106,728.72
3	อินเดีย	1,995,516	3	รัสเซีย	103,784.23
4	เกาหลี	1,887,853	4	ญี่ปุ่น	89,807.95
5	ญี่ปุ่น	1,806,340	5	อินเดีย	86,372.01
6	ลาว	1,845,375	6	สหรัฐอเมริกา	83,276.12
7	รัสเซีย	1,483,453	7	เกาหลี	74,367.38
8.	สหรัฐอเมริกา	1,167,845	8	อังกฤษ	74,164.38
9	สิงคโปร์	1,056,836	9	ออสเตรเลีย	56,227.85
10	เวียดนาม	1,047,629	10	ลาว	54,881.26
11	ฮ่องกง	1,045,198	11	เยอรมัน	52,319.70
12	อังกฤษ	994,018	12	ฝรั่งเศส	44,524.02
13	กัมพูชา	907,506	13	ฮ่องกง	40,320.69
14	เยอรมัน	857,487	14	สิงคโปร์	37,729.01
15	ไต้หวัน	789,923	15	กัมพูชา	35,766.51
16	ออสเตรเลีย	768,668	16	ไต้หวัน	35,552.61

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากตารางที่ 3 เมื่อทำการเปรียบเทียบข้อมูลจำนวนนักท่องเที่ยวต่างชาติและรายได้ที่ได้จากนักท่องเที่ยวต่างชาติปี 2562 จะทำให้เห็นว่าลำดับของจำนวนนักท่องเที่ยวต่างชาติกับรายได้ที่ได้รับบางประเทศอยู่ในลำดับที่ต่างกัน เช่น ประเทศกัมพูชาและไต้หวัน มีจำนวนของนักท่องเที่ยวสูงกว่าออสเตรเลียกับเยอรมันก็จริงแต่รายได้ต่ำกว่ามากหรือบางประเทศไม่อยู่ในลำดับดังกล่าว เช่น ประเทศเวียดนามและฝรั่งเศส จึงได้ทำการคัดเลือกประเทศโดยเลือกประเทศที่จะนำมาทำการวิเคราะห์จะต้องมีจำนวนนักท่องเที่ยวและรายได้ติดอันดับจากที่ได้ทำการจัดลำดับไว้



รูปที่ 6: เปรียบเทียบรูปแบบข้อมูลอนุกรมเวลาของจำนวนนักท่องเที่ยวจากประเทศมาเลเซีย เยอรมัน และจีน (พฤศจิกายน ปี 2556 ถึง ตุลาคม ปี 2561)

จากรูปที่ 6 จะเห็นได้ว่าแต่ละประเทศมีลักษณะของฤดูกาล (Seasonal) การท่องเที่ยวที่แตกต่างกัน ประเทศจีนจะมีจำนวนนักท่องเที่ยวสูงสุดที่เดือนกุมภาพันธ์ และสิงหาคม ประเทศมาเลเซียจะมีจำนวนนักท่องเที่ยวสูงสุดที่เดือนธันวาคม และประเทศเยอรมันจะมีจำนวนนักท่องเที่ยวสูงสุดที่เดือนมีนาคม

จากที่กล่าวมาข้างต้นทำให้รู้ถึงลักษณะการท่องเที่ยวของแต่ละประเทศนั้นมีความแตกต่างกัน จึงจำเป็นที่จะต้องมีการสร้างแบบจำลองการพยากรณ์จำนวนนักท่องเที่ยวแยกแต่ละประเทศ เพื่อวางแผนรับมือและคาดการณ์เหตุการณ์ที่จะเกิดขึ้นในแต่ละเดือนของนักท่องเที่ยวจากในแต่ละประเทศนั้นได้อย่างถูกต้องและเหมาะสม

1.3 วัตถุประสงค์ของการวิจัย

เพื่อนำเสนอแบบจำลองที่เหมาะสมในการพยากรณ์จำนวนนักท่องเที่ยวต่างชาติจากประเทศที่สำคัญที่เดินทางมาท่องเที่ยวที่ประเทศไทยแบบรายเดือน

1.4 ขอบเขตของงานวิจัย

1. ข้อมูลจำนวนนักท่องเที่ยวต่างชาติที่เดินทางเข้ามาท่องเที่ยวในประเทศไทยที่จะนำมาวิเคราะห์ คือ ข้อมูลสถิติจำนวนนักท่องเที่ยวจากกระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย โดยข้อมูลถูกบันทึกเป็นข้อมูลแบบรายเดือน ตั้งแต่เดือนมกราคม ปี 2556 ถึง ตุลาคม ปี 2562 โดยจะทำการแบ่งข้อมูลออกเป็น 2 ส่วน คือ ในส่วนแรก 80% (พฤศจิกายน 2556 ถึง ตุลาคม ปี 2561) ของข้อมูลทั้งหมดจะใช้สำหรับการสร้างแบบจำลองการพยากรณ์ และ ส่วนที่สอง 20% (พฤศจิกายน 2561 ถึง ตุลาคม ปี 2562) ที่เหลือจะนำมาใช้ทดสอบความแม่นยำของการพยากรณ์ของแบบจำลองที่ถูกสร้างขึ้น

2. ประเทศสำคัญที่ทำการเลือกมาเพื่อที่จะทำการวิเคราะห์ข้อมูลเพื่อนำไปสร้างแบบจำลองมีอยู่ทั้งหมด 13 ประเทศ คือ จีน มาเลเซีย เกาหลี ลาว ญี่ปุ่น อินเดีย รัสเซีย สหรัฐอเมริกา สิงคโปร์ ฮังการี อังกฤษ เยอรมัน และออสเตรเลีย โดยการคัดเลือกประเทศจะเลือกจากประเทศที่มีจำนวนนักท่องเที่ยวเข้ามาท่องเที่ยวที่ประเทศไทยเป็นจำนวนมาก และ สร้างรายได้ให้กับประเทศไทยจำนวนมาก สามารถดูรายละเอียดและเหตุผลในการเลือกประเทศเพิ่มเติมได้จากตารางที่ 5 ถึง 8

3. แบบจำลองที่เลือกใช้ในการพยากรณ์จำนวนนักท่องเที่ยวต่างชาติ

3.1 แบบจำลองค่าเฉลี่ยเคลื่อนที่ตามฤดูกาลอัตโนมัติ (Seasonal Autoregressive Integrated Moving Average model: SARIMA)

3.2 แบบจำลองตรีโกณมิติตามฤดูกาลการแปลงบ็อกซ์ค็อกซ์ค่าเฉลี่ยเคลื่อนที่แบบเคลื่อนไหวอัตโนมัติแนวโน้มและฤดูกาล (Trigonometric Seasonal, Box-Cox Transformation, ARMA residuals, Trend and Seasonality: TBATS)

3.3 แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

4. การประเมินความแม่นยำของแบบจำลองการพยากรณ์ใช้วิธีการค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

1.5 ผลลัพธ์ของงานวิจัย

สามารถนำเสนอแบบจำลองการพยากรณ์จำนวนนักท่องเที่ยวที่เหมาะสมในการที่จะนำมาใช้ในพยากรณ์จำนวนนักท่องเที่ยวต่างชาติในแต่ละประเทศที่เดินทางเข้ามาท่องเที่ยวที่ประเทศไทยที่ได้ทำการคัดเลือกไว้

1.6 ประโยชน์ของงานวิจัย

1. สามารถช่วยบริษัทที่เกี่ยวข้องกับการท่องเที่ยวในเรื่องของการวางแผนรองรับความต้องการที่จะท่องเที่ยวของนักท่องเที่ยวต่างชาติอย่างแม่นยำ เพื่อลดการสูญเสียที่ไม่จำเป็นที่เกิดจากความผิดพลาดในการคาดการณ์จำนวนนักท่องเที่ยวที่จะเข้ามาท่องเที่ยวที่ประเทศไทย

2. สามารถช่วยเป็นตัวอย่างของการเรียนรู้รูปแบบของแบบจำลองการพยากรณ์เพื่อนำไปต่อยอดในด้านธุรกิจหรือการวิจัยที่เกี่ยวกับการพยากรณ์ได้

3. ผลการศึกษาจากงานวิจัยนี้สามารถนำไปทำการวิเคราะห์ต่อในเรื่องของความเป็นไปได้ในการทำทัวร์ หรือ โปรโมชันพิเศษสำหรับประเทศที่มีจำนวนนักท่องเที่ยวที่เข้ามาท่องเที่ยวที่ประเทศไทยเป็นจำนวนมากเพื่อเพิ่มรายได้ที่จะได้รับจากนักท่องเที่ยวจากประเทศเหล่านี้



บทที่ 2 การศึกษาวรรณกรรมที่เกี่ยวข้อง

เมื่อกล่าวถึงความต้องการของนักท่องเที่ยวต่างชาติที่ต้องการจะเข้ามาท่องเที่ยวที่ประเทศไทย การพยากรณ์จำนวนนักท่องเที่ยวต่างชาติมีความสำคัญต่อการวางแผนการจัดการกับจำนวนนักท่องเที่ยว จึงทำให้เกิดงานวิจัยที่เกี่ยวข้องกับการพยากรณ์จำนวนนักท่องเที่ยวเกิดขึ้นหลากหลายรูปแบบงานวิจัย ไม่ว่าจะเป็นในแง่ของอุตสาหกรรมการท่องเที่ยวหรือบริษัทที่เกี่ยวกับการขนส่งมวลชน รูปแบบของงานวิจัยที่เกี่ยวข้องกับวิธีการที่ใช้ศึกษาหรือแบบจำลองการพยากรณ์ จะมีทั้งงานวิจัยเพื่อการพัฒนาแบบจำลองการพยากรณ์หรืองานวิจัยที่นำเสนอวิธีการและแบบจำลองการพยากรณ์ที่เหมาะสมกับข้อมูลในแต่ละรูปแบบ

งานวิจัยที่เกี่ยวข้องกับการพยากรณ์จำนวนนักท่องเที่ยวในปัจจุบันมีอยู่หลากหลายลักษณะในแต่ละลักษณะจะมีการใช้งานแบบจำลองตามความชำนาญและประสบการณ์ของผู้ที่ทำการพยากรณ์ โดยการพยากรณ์นั้นจะทำการแบ่งรูปแบบของการพยากรณ์ข้อมูลออกเป็น 2 ประเภท คือ การพยากรณ์ข้อมูลที่เป็นอนุกรมเวลา (Time series data) และ การพยากรณ์ข้อมูลที่เป็นเชิงสาเหตุ (Causal method) จะทำการยกตัวอย่างทฤษฎีที่เกี่ยวข้องกับแบบจำลองการพยากรณ์ทั้งสองประเภทรวมถึงรูปแบบการพยากรณ์ที่งานวิจัยนี้จะนำมาใช้ในการพยากรณ์จำนวนนักท่องเที่ยวต่างชาติที่เดินทางเข้ามาท่องเที่ยวในประเทศไทย

2.1 วิธีการและทฤษฎีที่เกี่ยวข้อง

2.1.1 แบบจำลองของอนุกรมเวลา (Time series method)

2.1.1.1 SARIMA (Seasonal Autoregressive Integrated Moving Average model)

งานวิจัยของ (Box, Jenkins, & Reinsel, 2011) ได้อธิบายถึงแบบจำลองการพยากรณ์ข้อมูลอนุกรมเวลา (Time series data) หนึ่งในแบบจำลองการพยากรณ์ที่ได้รับความนิยมที่สุดในการนำมาใช้เป็นมาตรฐานการพยากรณ์ข้อมูลประเภทอนุกรมเวลา (Time series method) คือแบบจำลองค่าเฉลี่ยเคลื่อนที่ตามฤดูกาลอัตโนมัติ (Seasonal Autoregressive Integrated Moving Average model: SARIMA) โดยมีการประเมินด้วยวิธีค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) ซึ่งในงานวิจัยนี้ได้มีการเปรียบเทียบให้เห็นถึงความสามารถในการพยากรณ์ที่แม่นยำในการพยากรณ์ข้อมูลอนุกรมเวลา

แบบจำลอง ARIMA เป็นแบบจำลองยอดนิยมที่นำมาใช้ในการพยากรณ์ข้อมูลอนุกรมเวลา (Time series data) เนื่องจากให้ค่าการพยากรณ์ที่ค่อนข้างแม่นยำและสามารถจัดการกับปัญหาของข้อมูลที่มีได้หลากหลาย ซึ่งแบบจำลอง ARIMA นี้จะถูกเรียกว่า แบบจำลอง ARIMA (p, d, q) โดยที่ d แทนจำนวนครั้งที่ต้องนำข้อมูลอนุกรมเวลามาทำการจัดการกับแนวโน้ม (Trend) เรียกวิธีการนี้ว่าการทำ Differencing เพื่อที่จะให้ข้อมูลอนุกรมเวลานั้นไม่มีแนวโน้มเหลืออยู่ เรียกว่า การทำให้ข้อมูลคงที่ (Stationary) สำหรับข้อมูลอนุกรมเวลาที่มีฤดูกาล (Seasonal data) แนะนำให้ใช้แบบจำลองค่าเฉลี่ยเคลื่อนที่ตามฤดูกาลอัตโนมัติเป็นที่รู้จักกันในชื่อ SARIMA (p, d, q) (P, D, Q) แบบจำลองในงานวิจัยนี้มุ่งเน้นไปที่แบบจำลอง SARIMA ซึ่งสามารถแสดงเป็น:

$$\Phi(L^s) \varphi(L) \Delta^d \Delta_s^D y_t = \vartheta_0 \Theta(L^s) \vartheta(L) \varepsilon_t \quad (1)$$

ที่มา: (Box et al., 2011)

โดยที่ s คือ ระยะเวลาของฤดูกาล (Seasonal length) ตัวอย่างเช่นถ้า s = 12 สำหรับข้อมูลอนุกรมเวลา (Time series data) ที่เป็นแบบรายเดือน หรือ s = 4 สำหรับข้อมูลอนุกรมเวลาที่เป็นไตรมาส L คือ ตัวดำเนินการล่าช้า (Lag operators) และ Δ_t ถือว่าเป็นกระบวนการที่มีการรบกวน (Noisy) ซึ่งมีค่าเฉลี่ยเป็นศูนย์ และ ความแปรปรวน σ^2 ตัวดำเนินการกำจัดแนวโน้ม (Differencing) คือ Δ_d โดย d คือ จำนวนของการกำจัดแนวโน้ม (Number of Differencing) และ ตัวดำเนินการกำจัดแนวโน้มของข้อมูลที่มีฤดูกาล (Difference for seasonal data) คือ Δ_s^D โดย D คือ จำนวนการกำจัดแนวโน้มของข้อมูลที่มีฤดูกาล (Number of Differencing for seasonal data) ตัวดำเนินการกำจัดแนวโน้มจะใช้ในการแปลงข้อมูลอนุกรมเวลา y_t ที่เป็นข้อมูลอนุกรมเวลาแบบไม่คงที่ (Non-stationary data) ให้เป็นข้อมูลอนุกรมเวลาแบบคงที่ (Stationary data)

2.1.1.2 TBATS (Trigonometric Seasonal, Box-Cox Transformation, ARMA residuals, Trend and Seasonality)

ต้นแบบของวิธีการพยากรณ์ถูกนำเสนอโดย (De Livera, 2010) และ (De Livera, Hyndman, & Snyder, 2011) โดยเริ่มจากแบบจำลองบ็อกซ์-ค็อกซ์ค่าเฉลี่ยเคลื่อนที่แบบเคลื่อนไหวอัตโนมัติแนวโน้มและฤดูกาล (Box-Cox transformation, ARMA errors, Trend and Seasonal components: BATS model) ได้ขยายมาจากแบบจำลองฤดูกาลสองชั้นกับบ็อกซ์ - ค็อกซ์ (Double seasonal Holt-Winters, integrated with Box-Cox) และ ค่าเฉลี่ยเคลื่อนที่อัตโนมัติ (ARMA model) (De Livera, 2010) ได้แสดงให้เห็นว่าแบบจำลอง BATS สามารถพยากรณ์ข้อมูลอนุกรมเวลาแบบพื้นฐานได้ค่อนข้างแม่นยำ

อย่างไรก็ตามแบบจำลอง BATS ยังคงไม่สามารถทำงานได้ดีนักเมื่อเจอกับข้อมูลที่มีความซับซ้อนและมีจำนวนของฤดูกาล (Seasonal) ที่มากหรือซับซ้อนเกินไป (De Livera et al., 2011)

จึงได้เสนอแบบจำลอง TBATS นี้ขึ้นมา โดยการที่นำฟังก์ชันตรีโกณมิติเข้ามาใช้กับแบบจำลอง BATS แบบจำลอง TBATS นั้นสามารถลดจำนวนพารามิเตอร์ของแบบจำลองลงได้และยังมีความยืดหยุ่นในการใช้งานกับข้อมูลอนุกรมเวลาที่มีความซับซ้อนหรือมีจำนวนของฤดูกาลที่มาก ซึ่งสามารถทำงานได้สะดวกแบบจำลอง BATS ดังนั้นจึงสามารถบอกได้ว่าแบบจำลอง TBATS สามารถนำไปใช้กับข้อมูลที่หลากหลาย มีความยืดหยุ่นในการใช้งานมากกว่าแบบจำลอง BATS

สมการต่อไปนี้จะแสดงให้เห็นการนำฟังก์ชันตรีโกณมิติมาใช้กับแบบจำลอง BATS

$$y_t^{(\omega)} = l_{t-1} + \varphi b_{t-1} + \sum_{i=1}^T s_{t-1}^{(i)} + d_t \quad (2)$$

$$s_t^{(i)} = \sum_{j=1}^{k_i} s_{j,t}^{(i)} \quad (3)$$

$$s_{j,t}^{(i)} = s_{j,t-1}^{(i)} \cos \lambda_j^{(i)} + s_{j,t-1}^{*(i)} \sin \lambda_j^{(i)} + \gamma_1^{(i)} d_t \quad (4)$$

$$s_{j,t}^{*(i)} = -s_{j,t-1}^{(i)} \sin \lambda_j^{(i)} + s_{j,t-1}^{*(i)} \cos \lambda_j^{(i)} + \gamma_2^{(i)} d_t \quad (5)$$


โดยที่ k_i คือ จำนวนฮาร์โมนิกส์ (Harmonics) ที่จำเป็นสำหรับ i^{th} องค์ประกอบฤดูกาล $\gamma_1^{(i)}$, $\gamma_2^{(i)}$ คือ พารามิเตอร์ที่ปรับให้เรียบ และ $\lambda_j^{(i)} = 2\pi j/m_i$

ที่มา: (De Livera et al., 2011)

2.1.2 แบบจำลองเชิงสาเหตุ (Causal method)

2.1.2.1 ANN (Artificial Neural Network)

แบบจำลอง ANN เป็นแบบจำลองที่ได้รับความนิยมมากที่สุดในการเรียนรู้ของเครื่อง (Machine learning) ที่ถูกสร้างเพื่อจัดจำรูปแบบของข้อมูลที่มีจำนวนมากและซับซ้อน ซึ่งแบบจำลอง ANN จะถูกสร้างขึ้นโดยจำลองการคำนวณเป็นเหมือนโครงข่ายประสาทของระบบสมองของมนุษย์ ในงานวิจัยของ (McCulloch & Pitts, 1943) เสนอและอธิบายการทำงานของแบบจำลอง ANN ปัจจุบัน แบบจำลอง ANN ได้ถูกนำมาใช้กันอย่างแพร่หลายไม่ว่าจะในการพยากรณ์หรือการจัดจำข้อมูลเพื่อนำไปวิเคราะห์ผล รูปที่ 7 จะแสดงตัวอย่างการทำงานของแบบจำลอง ANN ที่จำลองระบบโครงข่ายประสาทของสมอง



รูปที่ 7: ลักษณะของแบบจำลอง ANN

แบบจำลอง ANN หรือ โครงข่ายประสาทเทียม หรือ ข่ายงานประสาทเทียม (Connectionist systems) คือ ระบบคอมพิวเตอร์จากแบบจำลองทางคณิตศาสตร์เพื่อที่จะนำมาทำการจำลองการทำงานของโครงข่ายประสาทที่อยู่ในสมองของสัตว์ โครงข่ายประสาทเทียมสามารถเรียนรู้ที่จะทำงานที่มอบหมายได้จากการเรียนรู้ผ่านตัวอย่างของข้อมูลโดยไม่ถูกโปรแกรมด้วยกฎเกณฑ์ตายตัวแบบระบบอัตโนมัติทั่วไป

สมการของแบบจำลอง ANN คือ

$$a_j^i = \sigma\left(\sum_m w_{jk}^i a_k^{i-1}\right) + b_j^i \quad (6)$$

โดย a_j^i คือ ค่า Output ที่ได้จาก activation function ของ neuron j ในชั้นของ i^{th}

σ คือ the activation function

w_{jk}^i คือ น้ำหนักของ neuron k^{th} จากเชื่อมต่อระหว่าง node j^{th} และ ในชั้นที่ $(i - 1)^{\text{th}}$ กับชั้นที่ i^{th}


b_j^i คือ ค่า bias ของ neuron j^{th} ในชั้นที่ i^{th}

การป้อนข้อมูลการเรียนรู้ให้กับแบบจำลอง ANN สามารถแบ่งออกเป็น 2 รูปแบบ คือ แบบเรียนรู้ไปข้างหน้า (Feed-Forward Neural Network) และ แบบป้อนย้อนกลับ (Recurrent Neural Network) โดยจะสามารถอธิบายลักษณะการป้อนข้อมูลได้ดังนี้

2.1.2.1.1 ลักษณะการป้อนค่าของข้อมูลของแบบจำลอง ANN

2.1.2.1.1.1 แบบป้อนไปข้างหน้า (Feed-Forward Neural Network)

แบบจำลอง ANN แบบ Feed-Forward จะประกอบด้วยเซตของบัพ (Node) ซึ่งอาจจะถูกกำหนดให้เป็นบัพของอินพุต (Input nodes) และบัพของเอาต์พุต (Output nodes) หรือ บัพอยู่ระหว่างกลางซึ่งเรียกว่า บัพฮิดเดน (Hidden nodes) โดยกำหนดค่าน้ำหนัก (Weight) กำกับอยู่ที่เส้นเชื่อมทุกเส้น เมื่อข่ายงานเริ่มทำงานจะมีการกำหนดค่าให้แก่ input nodes โดยค่าเหล่านี้ อาจจะได้มาจากการกำหนดโดยมนุษย์ จากตัววัดค่าต่าง ๆ หรือผลจากโปรแกรมอื่น ๆ ที่กำหนด จากนั้น input nodes จะส่งค่าของข้อมูลที่ได้รับไปตามเส้นเชื่อมขาออก (รูปที่ 8) โดยค่าของข้อมูลที่ส่งออกไปจะถูกนำมาคูณกับค่าน้ำหนัก (Weight) ของเส้นเชื่อมในชั้นถัดไป ซึ่งจะรับค่าที่เป็นผลรวมจากบัพต่าง ๆ แล้วจึงจะทำการคำนวณผลด้วย Activation function ของ ANN แล้วจึงจะส่งค่าไปยังชั้นถัดไป การคำนวณเช่นนี้จะเกิดขึ้นไปที่ละชั้น จนถึง Output nodes และจะทำให้ได้ค่าของข้อมูลที่ต้องการจากการที่ได้ทำการป้อนข้อมูลให้แบบจำลอง ANN เรียนรู้




รูปที่ 8: รูปแบบการป้อนข้อมูลแบบ Feed-Forward neural network

2.1.2.1.1.2 แบบป้อนย้อนกลับ (Recurrent Neural Network)

แบบจำลอง ANN แบบ Recurrent จะประกอบด้วยเซตของบัพ (Node) ซึ่งอาจจะถูกกำหนดให้เป็นบัพของอินพุต (Input nodes) และบัพของเอาต์พุต (Output nodes) หรือ บัพอยู่ระหว่างกลางซึ่งเรียกว่า บัพฮิดเดน (Hidden nodes) โดยกำหนดค่าน้ำหนัก (Weight) กำกับอยู่ที่เส้นเชื่อมทุกเส้น ซึ่งมีความคล้ายกันกับแบบ Feed-Forward แต่จะแตกต่างกันตรงที่เวลาส่งค่าของข้อมูลจาก Output nodes จะมีการนำค่าของข้อมูลที่ได้นั้นย้อนกลับมาที่ Hidden nodes เพื่อทำการคำนวณหาค่าของข้อมูลที่ดีที่สุดใหม่แล้วจึงส่งค่าข้อมูลที่ได้ทำการหาออกไปที่ Output nodes อีกที (รูปที่ 9) โดยจะมีการทำงานเป็นระบบแบบนี้จนกว่าจะครบการทำซ้ำ (Iteration) ที่เรที่ตั้งคำสั่งให้คอมพิวเตอร์นั้นเรียนรู้และหาค่าที่ดีที่สุดของข้อมูลที่ต้องการได้ (Convergence)

CHULALONGKORN UNIVERSITY



รูปที่ 9: รูปแบบการป้อนข้อมูลแบบ Recurrent Neural Network


2.1.2.1.2 Activation Function ของแบบจำลอง ANN ที่ได้เลือกนำมาใช้ในงานวิจัยนี้ (Agostinelli, Hoffman, Sadowski, & Baldi, 2014)

2.1.2.1.2.1 ReLU (Rectified Linear Unit)

ReLU function คือ ฟังก์ชันเส้นตรง เนื่องจากหาค่าของข้อมูล Input เป็นค่าบวก ค่าของความชัน (Slope) จะมีค่าเท่ากับ 1 เสมอ (รูปที่ 10) ทำให้ Gradient ไม่หาย (ไม่เกิด Vanishing Gradient) ส่งผลทำให้สามารถฝึกอบรมแบบจำลอง (Training model) ได้รวดเร็วขึ้น (Sibi, Jones, & Siddarth, 2013)

สมการ

$$f(x) = \max(0, x) = \begin{cases} 0 & \text{for } x \leq 0 \\ x & \text{for } x > 0 \end{cases} \quad (7)$$




รูปที่ 10: รูปแบบกราฟการคำนวณโดย ReLU function

2.1.2.1.2.2 Sigmoid

Sigmoid function คือ ฟังก์ชันที่จะมี Curve เป็นรูปตัว S (รูปที่ 11) สามารถทำความเข้าใจกับลักษณะของกราฟได้ง่าย โดย Output ที่ได้จาก ฟังก์ชัน Sigmoid จะมีค่าอยู่ระหว่าง 0 ถึง 1 เสมอ

สมการ

$$S(x) = \frac{1}{1+e^{-x}} = \frac{e^x}{e^x+1} \quad (8)$$



รูปที่ 11: รูปแบบกราฟการคำนวณโดย Sigmoid function

2.2 การประเมินประสิทธิภาพของแบบจำลอง

การประเมินประสิทธิภาพแบบจำลองทำได้โดยการตรวจวัดข้อผิดพลาดต่าง ๆ 2 รูปแบบ เพื่อการประเมินประสิทธิภาพของรูปแบบในการพยากรณ์ที่แตกต่างกัน โดย

1. A_t คือ ค่าจริงของข้อมูลที่นำมาทดสอบเปรียบเทียบในเวลา t ต่าง ๆ
2. F_t คือ ค่าพยากรณ์ของข้อมูลที่นำมาทดสอบเปรียบเทียบในเวลา t ต่าง ๆ
3. n คือ จำนวนของข้อมูลอนุกรมเวลา (Time series data) ที่ใช้ในการทดสอบแบบจำลอง

วิธีการคำนวณการประเมินความผิดพลาดสามารถทำได้ดังนี้:

I. ค่าเฉลี่ยความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Error: MAE): วัดค่าเฉลี่ยความผิดพลาดแบบสัมบูรณ์ของข้อมูลจริงกับข้อมูลที่ได้จากการพยากรณ์

$$MAE = \frac{1}{n} \sum_{t=1}^n |A_t - F_t| \quad (9)$$

II. ค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE): วัดค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ของข้อมูลจริงกับข้อมูลที่ได้จากการพยากรณ์ โดยจะสามารถบ่งบอกความแม่นยำของแบบจำลองด้วยค่าเปอร์เซ็นต์ที่ได้จากการคำนวณ

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{A_t - F_t}{A_t} \right| \quad (10)$$

2.3 ตัวอย่างงานวิจัยที่เกี่ยวข้องกับการนำเสนอเปรียบเทียบหรือสร้างแบบจำลองการพยากรณ์ อุตสาหกรรมการท่องเที่ยว

งานวิจัยของ (Mamula, 2015) ได้ทำการตรวจสอบความแม่นยำในการพยากรณ์ของรูปแบบการพยากรณ์ที่แตกต่างกัน โดยให้ความสำคัญในการพยากรณ์ความต้องการของนักท่องเที่ยวต่างชาติที่จะเข้ามาท่องเที่ยวที่ประเทศโครเอเชีย (Croatia) ซึ่งนักท่องเที่ยวจากประเทศที่งานวิจัยนี้สนใจ คือนักท่องเที่ยวจากประเทศเยอรมัน โดยแบบจำลองที่งานวิจัยนี้เลือกใช้ของอนุกรมเวลา (Time series method) ได้แก่ แบบจำลอง Holt-Winters triple exponential smoothing (HW) แบบจำลอง Seasonal Autoregressive Integrated Moving Average (SARIMA) และ แบบจำลอง Naive S (Seasonal Naive) ในส่วนของแบบจำลองของเชิงสาเหตุ (Causal method) ได้แก่ Multiple regression model (MR) แบบจำลองการพยากรณ์ทั้ง 4 แบบจำลองได้นำมาทำการประเมินโดยวิธีค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) ซึ่งค่าผลลัพธ์ที่ได้ของทั้ง 4 แบบจำลองไม่ได้ต่างกันอย่างมีนัยสำคัญ และทั้ง 4 แบบจำลองสามารถใช้ในการพยากรณ์จำนวนนักท่องเที่ยวจากประเทศเยอรมันที่จะเข้ามาท่องเที่ยวที่ประเทศโครเอเชีย (Croatia) ได้

งานวิจัยของ (Lin & Lee, 2013) เป็นงานวิจัยที่เกี่ยวกับการพยากรณ์ข้อมูลที่เป็นเชิงสาเหตุ (Causal Method) ซึ่งข้อมูลของงานวิจัยนี้เป็นข้อมูลที่ว่าด้วยปัจจัยที่มีผลต่อการพยากรณ์รายได้และความเป็นไปได้ทางเศรษฐกิจที่มาจากอุตสาหกรรมการท่องเที่ยวแบบรายเดือน โดยสนใจไปในทางการพัฒนาแบบจำลองการพยากรณ์แบบสมการถดถอย (Regression models) คือ แบบจำลอง Multivariate Adaptive Regression Splines (MARS) แบบจำลอง Artificial Neural Network (ANN) และ แบบจำลอง Support Vector Regression (SVR) โดยแบบจำลองการพยากรณ์ทั้ง 3 แบบจำลองได้นำมาทำการประเมินโดยวิธีค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) ซึ่งค่าผลลัพธ์ที่ได้แบบจำลอง SVR แม่นยำที่สุด

งานวิจัยของ (Phumchusri & Ungtrakul, 2020) เป็นงานวิจัยแบบจำลองการพยากรณ์ที่เหมาะสมที่จะนำมาใช้ในการพยากรณ์การเข้าพักโรงแรมแห่งหนึ่งซึ่งมีการบันทึกข้อมูลเป็นรายวัน โดยในงานวิจัยนี้แบ่งแบบจำลองการพยากรณ์กับข้อมูล 2 ประเภท คือ แบบอนุกรมเวลา (Time series method) และ แบบปัจจัยเชิงสาเหตุ (Causal method) แบบจำลองการพยากรณ์ข้อมูลอนุกรมเวลา (Time series method) ที่งานวิจัยนี้เลือกใช้ ได้แก่ แบบจำลอง Seasonal Autoregressive Integrated Moving Average (SARIMA) และ แบบจำลอง Trigonometric Seasonal, Box-Cox Transformation, ARMA residuals, Trend, and Seasonality (TBATS) โดยปัจจัยเชิงสาเหตุนี้ได้นำข้อมูลอนุกรมเวลา (Time series data) ของการเข้าพักโรงแรมแห่งนี้มาเป็นปัจจัยในการสร้างแบบจำลองการพยากรณ์เชิงสาเหตุ (Causal method) ในส่วนของ

แบบจำลองการพยากรณ์ข้อมูลเชิงสาเหตุ (Causal method) ที่งานวิจัยนี้เลือกใช้ คือ แบบจำลอง Back-Propagation Neural Network (BPNN) และ Support Vector Regression (SVR) ในการประเมินความถูกต้องของแบบจำลองโดยวิธีค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) ซึ่งค่าผลลัพธ์ที่ได้ในส่วนของการพยากรณ์ข้อมูลอนุกรมเวลา (Time series method) คือ แบบจำลอง TBATS ดีที่สุด สุดท้ายส่วนของการพยากรณ์ข้อมูลเชิงสาเหตุ (Causal method) คือ BRNN ดีที่สุด

งานวิจัยของ (Chinnakum & Boonyasana, 2016) เป็นงานวิจัยที่อธิบายถึงการพยากรณ์ความต้องการของอุตสาหกรรมการท่องเที่ยวระหว่างประเทศของประเทศไทยซึ่งข้อมูลถูกบันทึกไว้เป็นข้อมูลแบบรายเดือน โดยในงานวิจัยได้นำเสนอแบบจำลองการพยากรณ์ทางคณิตศาสตร์ คือ Autoregressive with generalized autoregressive conditionally heteroskedastic (AR(m)-GARCH (p, q)) สามารถนำแบบจำลอง AR(m)- GARCH (p, q) มาช่วยในการพยากรณ์ได้ดี ส่วนของการประเมินโดยวิธีค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

งานวิจัยของ (Sookmark, 2011) เป็นงานวิจัยที่อธิบายถึงการวิเคราะห์ข้อมูลความต้องการที่จะเข้ามาท่องเที่ยวในประเทศไทยของชาวต่างชาติที่มีความสำคัญต่ออุตสาหกรรมการท่องเที่ยวของประเทศไทยที่ถูกบันทึกไว้เป็นข้อมูลแบบรายเดือน งานวิจัยนี้ได้แนะนำเสนอและเปรียบเทียบแบบจำลองของอนุกรมเวลา (Time series method) ได้แก่ Seasonal autoregressive integrated moving average (SARIMA) และ แบบจำลองของเชิงสาเหตุ (Causal method) ได้แก่ Multiple regression model (MR) ในส่วนของการประเมินโดยวิธีค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

งานวิจัยของ (Law & Au, 1999) ว่าด้วยการสร้างแบบจำลองการพยากรณ์จำนวนนักท่องเที่ยวชาวญี่ปุ่นที่เดินทางเข้ามาท่องเที่ยวที่ประเทศฮ่องกง เนื่องจากในช่วงเวลาดังกล่าวนักท่องเที่ยวจากทางประเทศญี่ปุ่นเดินทางเพื่อที่จะมาท่องเที่ยวที่ประเทศฮ่องกงเป็นจำนวนมาก ในการสร้างแบบจำลองการพยากรณ์จะใช้ข้อมูลของจำนวนนักท่องเที่ยวชาวญี่ปุ่นที่ถูกบันทึกไว้เป็นข้อมูลรายปี โดยงานวิจัยนี้ได้แนะนำเสนอแบบจำลอง Artificial Neural Network (ANN) ในการช่วยวิเคราะห์และพยากรณ์จำนวนนักท่องเที่ยวชาวญี่ปุ่น

งานวิจัยของ (Hwande & Phumchusri, 2020) เป็นงานวิจัยที่อธิบายถึงการพยากรณ์จำนวนนักท่องเที่ยวต่างชาติจากประเทศที่สำคัญที่เดินทางมาท่องเที่ยวในประเทศไทย คือ ประเทศจีน มาเลเซีย เกาหลี ญี่ปุ่น รัสเซีย อังกฤษ และสหรัฐอเมริกา ทั้งนี้ข้อมูลจำนวนนักท่องเที่ยวต่างชาติถูกบันทึกไว้เป็นข้อมูลแบบรายเดือน โดยงานวิจัยนี้ได้แนะนำเสนอและเปรียบเทียบแบบจำลองของอนุกรมเวลา (Time series method) และ แบบจำลองของเชิงสาเหตุ (Causal method) ซึ่ง

แบบจำลองของอนุกรมเวลา (Time series method) ที่งานวิจัยนี้เลือกใช้ ได้แก่ Seasonal autoregressive integrated moving average (SARIMA) และ Holt-Winters method (HW) แบบจำลองของเชิงสาเหตุ (Causal method) ได้แก่ Multiple regression model (MR) และ Artificial Neural Network (ANN) ในส่วนของการประเมินโดยวิธีค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (Mean Absolute Percentage Error: MAPE)

งานวิจัยก่อนหน้าล่าสุดที่มีความใกล้เคียงกับงานวิจัยนี้ คือ งานวิจัยของ (Hwande & Phumchusri, 2020) ซึ่งได้ทำการเปรียบเทียบรูปแบบของการพยากรณ์ที่ใช้ระหว่างแบบจำลองของอนุกรมเวลา (Time series method) ได้แก่ Seasonal autoregressive integrated moving average (SARIMA) และ แบบจำลองของเชิงสาเหตุ (Causal method) ได้แก่ แบบจำลอง Artificial Neural Network (ANN) ที่มีข้อมูลจำนวนนักท่องเที่ยวต่างชาติที่มาท่องเที่ยวในประเทศไทยและปัจจัยต่าง ๆ ที่มีผลต่อการพยากรณ์ถูกบันทึกไว้เป็นข้อมูลแบบรายเดือน โดยรูปแบบการพยากรณ์ที่งานวิจัยนี้ให้ความสนใจ คือ แบบจำลอง SARIMA และ แบบจำลอง ANN

ตารางที่ 4 จะนำเสนองานวิจัยที่เกี่ยวข้องกับการพยากรณ์จำนวนนักท่องเที่ยวในแบบจำลองของอนุกรมเวลา (Time series method) และแบบจำลองของเชิงสาเหตุ (Causal method) ตามลำดับ โดยจะสรุปแบบจำลองที่เลือกนำมาศึกษาในแต่ละงานวิจัย ความถี่ของข้อมูลที่ใช้สร้างแบบจำลอง การประเมินความถูกต้องของแบบจำลองการพยากรณ์ และ ลักษณะของงานวิจัย จากการรวบรวมงานวิจัยต่าง ๆ ที่เกี่ยวข้องมารวมสรุปจะทำให้เห็นทฤษฎีที่เกี่ยวข้อง และ แบบจำลองการพยากรณ์ที่นำมาใช้กับข้อมูลในแต่ละลักษณะ เพื่อนำเสนอและเปรียบเทียบ เพื่อความเหมาะสมของแบบจำลองการพยากรณ์และข้อมูลที่จะทำการวิเคราะห์หรือการพยากรณ์

จุฬาลงกรณ์มหาวิทยาลัย

ตารางที่ 4: สรุปงานวิจัยที่เกี่ยวข้องกับอุตสาหกรรมการท่องเที่ยว แบบจำลองการพยากรณ์ที่ใช้ในการศึกษา และการประเมินความถูกต้องของแต่ละงานวิจัยเพิ่มเติม

ผู้วิจัย	ความถี่ของข้อมูล	แบบจำลองที่เลือกศึกษา		การประเมินความถูกต้อง	ลักษณะงานวิจัย
		Time series method	Causal method		
(Baldigara, 2013)	เดือน	DEST Naive T AR	LR	MAPE	นำเสนอและเปรียบเทียบแบบจำลอง

(Song, Witt, & Li, 2003)	ปี	ADLM	MR	MAPE	เปรียบเทียบ แบบจำลอง
(Hao, Var, & Chon, 2003)	ปี		MR	MAPE	นำเสนอ แบบจำลอง
(Mamula, 2015)	ไตรมาส	Naïve S HW SARIMA	MR	MAPE	นำเสนอและ เปรียบเทียบ แบบจำลอง
(Lin & Lee, 2013)	เดือน		SVR MARS ANN	MAPE	นำเสนอและ เปรียบเทียบ แบบจำลอง
(Sookmark, 2011)	เดือน	SARIMA	MR	MAPE	เปรียบเทียบ แบบจำลอง
(BROŻYNA, Mentel, Szetela, & Strielkowski, 2018)	ชั่วโมง วัน เดือน	TBATS		MAPE	นำเสนอ แบบจำลอง
(De Livera et al., 2011)	สัปดาห์	BATS TBATS		MAPE	นำเสนอ แบบจำลอง
Álvarez-Díaz, M., González-Gómez, M., & Otero-Giráldez, M. S. (2019)	เดือน	SARIMA	NAR	MAPE	นำเสนอและ เปรียบเทียบ แบบจำลอง
(Law & Au, 1999)	ปี		ANN	MAPE	นำเสนอ แบบจำลอง
(Phumchusri & Ungtrakul, 2020)	วัน	SARIMA BATS TBATS	BPNN SVR	MAPE	นำเสนอและ เปรียบเทียบ แบบจำลอง

(Hwandee & Phumchusri, 2020)	เดือน	SARIMA	ANN MR	MAPE	นำเสนอและเปรียบเทียบแบบจำลอง
งานวิจัยนี้	เดือน	SARIMA TBATS	ANN	MAPE	นำเสนอและเปรียบเทียบแบบจำลองการพยากรณ์

หมายเหตุ:

AR: Autoregressive method

ADLM: Autoregressive distributed lag model

ARIMA: Autoregressive integrated moving average

ANN: Artificial Neural Network

BPNN: Back-Propagation Neural Network

AR(m)- GARCH (p, q): Autoregressive with generalized autoregressive conditionally heteroskedastic

BSM: non-causal basic structural model

BATS: Box-Cox Transformation, ARMA residuals, Trend and Seasonality

DEST: Double exponential smoothing with trend

ES: Exponential smoothing

Naïve T: naïve with trend

Naïve S: seasonal naïve model

LR: linear regression

MARS: Multivariate Adaptive Regression Splines

MR: multiple regression model

SVR: Support Vector Regression

SARIMA: Seasonal autoregressive integrated moving average

TBATS: Trigonometric Seasonal, Box-Cox Transformation, ARMA residuals, Trend and Seasonality

MS-VAR: Markov-switching vector autoregressive

HW: Holt-Winters method

PR: Poisson regression

NAR: Non-linear autoregressive neural network

จากตารางที่ 4 งานวิจัยนี้แตกต่างจากงานวิจัยที่กล่าวมาข้างต้นเนื่องจากงานวิจัยนี้เลือกใช้แบบจำลองของอนุกรมเวลา (Time series method) คือ แบบจำลอง TBATS (Trigonometric Seasonal, Box-Cox Transformation, ARMA residuals, Trend and Seasonality) ในการนำมาเป็นแบบจำลองการพยากรณ์จำนวนนักท่องเที่ยวชาวต่างชาติที่มีความถี่ของข้อมูลเป็นแบบรายเดือน จะเห็นได้ว่าในลักษณะความถี่ของข้อมูลที่ถูกบันทึกไว้เป็นรายเดือนนั้น ยังไม่มีผู้ทำการวิจัยแบบจำลองการพยากรณ์ TBATS โดยงานวิจัยล่าสุดที่เกี่ยวข้องกับการพยากรณ์จำนวนนักท่องเที่ยวชาวต่างชาติที่ถูกบันทึกความถี่ของข้อมูลไว้เป็นแบบรายเดือน คือ งานวิจัยของ (Hwande & Phumchusri, 2020) แบบจำลองการพยากรณ์ที่เป็นแบบจำลองของแบบอนุกรมเวลา (Time series method) จะยังเลือกใช้แบบจำลอง SARIMA ในการศึกษาอยู่

โดยในงานวิจัยนี้ได้เลือกนำแบบจำลอง TBATS (De Livera et al., 2011) มานำเสนอและเปรียบเทียบในรูปแบบของการพยากรณ์ของอนุกรมเวลา (Time series method) ซึ่งในงานวิจัยของ De Livera ได้กล่าวว่าแบบจำลอง TBATS นี้ สามารถนำมาใช้พยากรณ์ข้อมูลที่เป็นแบบอนุกรมเวลา (Time series method) ได้ดี โดยแบบจำลอง TBATS นี้ถูกสร้างขึ้นโดยการนำฟังก์ชันตรีโกณมิติมาใช้เพื่อลดจำนวนพารามิเตอร์ และ ขจัดปัญหาของข้อมูลที่มีความถี่ของฤดูกาล (Seasonal data) สูง เพื่อให้การพยากรณ์ได้ค่าที่แม่นยำยิ่งขึ้น และ แบบจำลอง ANN ที่สามารถนำมาใช้พยากรณ์ข้อมูลที่เป็นแบบเชิงสาเหตุ (Causal method) ได้ดี โดยในความเหมาะสมนี้จึงจะทำการทดลองนำแบบจำลองทั้งสองมาทำการทดลองพยากรณ์จำนวนนักท่องเที่ยวชาวต่างชาติของงานวิจัยนี้

ในงานวิจัยนี้ จะทำการเปรียบเทียบข้อมูลการพยากรณ์จำนวนนักท่องเที่ยวชาวต่างชาติที่มาจากนักท่องเที่ยวที่ประเทศไทยของแบบจำลอง SARIMA, TBATS และ ANN กับข้อมูลจริงของจำนวนนักท่องเที่ยวต่างชาติ เพื่อเปรียบเทียบแบบจำลองการพยากรณ์ TBATS และ ANN นั้นว่าสามารถให้ค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE) ได้แม่นยำกว่า แบบจำลอง SARIMA หรือไม่ เพื่อให้ได้แบบจำลองที่เหมาะสมและแม่นยำสำหรับการพยากรณ์จำนวนนักท่องเที่ยวแต่ละประเทศ

บทที่ 3วิธีการดำเนินงาน

3.1 ระเบียบของการวิจัย

3.1.1 การเตรียมข้อมูล

ในบทนี้มีวัตถุประสงค์เพื่อนำเสนอและเปรียบเทียบรูปแบบการพยากรณ์ที่สามารถพยากรณ์จำนวนนักท่องเที่ยวต่างชาติที่ต้องการเดินทางมาท่องเที่ยวในประเทศไทยได้อย่างแม่นยำ เพื่อจัดการกับความหลากหลายของลักษณะการท่องเที่ยวของแต่ละประเทศและปัญหาการพยากรณ์ การใช้เทคนิคหรือแบบจำลองที่แตกต่างกันขึ้นอยู่กับประสบการณ์ของผู้ทำการพยากรณ์ โดยการเลือกวิธีการจะขึ้นอยู่กับหลายปัจจัยและจำเป็นต้องนำมาพิจารณาเพื่อทำการวิเคราะห์ข้อมูล

ตารางที่ 5: ลำดับของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวมาท่องเที่ยวและสร้างรายได้สูงที่สุด

ลำดับที่	ประเทศ	จำนวนของนักท่องเที่ยว (ปี 2562)	ลำดับที่	ประเทศ	รายได้ที่ได้จากนักท่องเที่ยว (ล้านบาท)
1	จีน	10,994,721	1	จีน	543,707.33
2	มาเลเซีย	4,166,868	2	มาเลเซีย	106,728.72
3	อินเดีย	1,995,516	3	รัสเซีย	103,784.23
4	เกาหลี	1,887,853	4	ญี่ปุ่น	89,807.95
5	ญี่ปุ่น	1,806,340	5	อินเดีย	86,372.01
6	ลาว	1,845,375	6	สหรัฐอเมริกา	83,276.12
7	รัสเซีย	1,483,453	7	เกาหลี	74,367.38
8	สหรัฐอเมริกา	1,167,845	8	อังกฤษ	74,164.38
9	สิงคโปร์	1,056,836	9	ออสเตรเลีย	56,227.85
10	เวียดนาม	1,047,629	10	ลาว	54,881.26
11	ฮ่องกง	1,045,198	11	เยอรมัน	52,319.70
12	อังกฤษ	994,018	12	ฝรั่งเศส	44,524.02
13	กัมพูชา	907,506	13	ฮ่องกง	40,320.69
14	เยอรมัน	857,487	14	สิงคโปร์	37,729.01
15	ไต้หวัน	789,923	15	กัมพูชา	35,766.51
16	ออสเตรเลีย	768,668	16	ไต้หวัน	35,552.61

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

ตารางที่ 6: ลำดับคะแนนของ 16 ประเทศที่มีจำนวนนักท่องเที่ยวมาท่องเที่ยวและสร้างรายได้สูงสุด

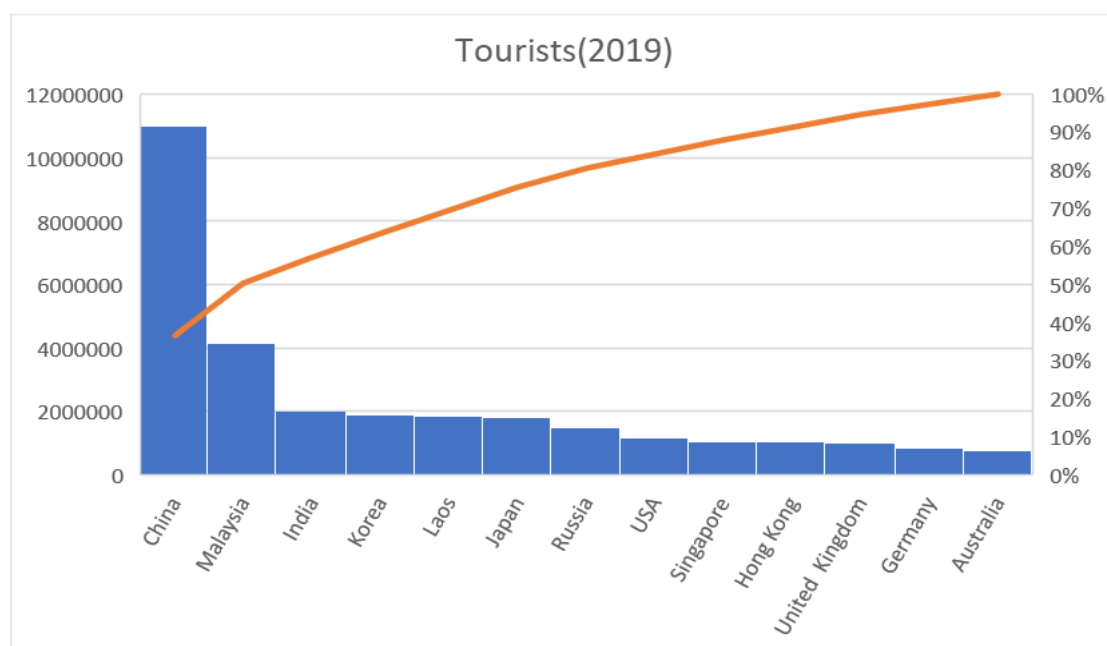
ลำดับ ที่	ประเทศ	คะแนน จำนวนของนักท่องเที่ยว (ปี 2562)	ลำดับ ที่	ประเทศ	คะแนน รายได้ที่ได้จาก นักท่องเที่ยว
1	จีน	16	1	จีน	16
2	มาเลเซีย	15	2	มาเลเซีย	15
3	อินเดีย	14	3	รัสเซีย	14
4	เกาหลี	13	4	ญี่ปุ่น	13
5	ญี่ปุ่น	12	5	อินเดีย	12
6	ลาว	11	6	สหรัฐอเมริกา	11
7	รัสเซีย	10	7	เกาหลี	10
8	สหรัฐอเมริกา	9	8	อังกฤษ	9
9	สิงคโปร์	8	9	ออสเตรเลีย	8
10	เวียดนาม	7	10	ลาว	7
11	ฮ่องกง	6	11	เยอรมัน	6
12	อังกฤษ	5	12	ฝรั่งเศส	5
13	กัมพูชา	4	13	ฮ่องกง	4
14	เยอรมัน	3	14	สิงคโปร์	3
15	ไต้หวัน	2	15	กัมพูชา	2
16	ออสเตรเลีย	1	16	ไต้หวัน	1

ในตารางที่ 6 ทางผู้วิจัยได้ทำการให้คะแนนแต่ละประเทศตามลำดับที่มีจำนวนนักท่องเที่ยวและรายได้สูงสุดจากลำดับที่ 1 ถึง 16 โดยคะแนนที่ให้จะเรียงจากประเทศที่มีลำดับสูงสุดเป็น 16 คะแนน แล้วลดลงไปจนถึงลำดับต่ำสุด คือ 1 คะแนนตามลำดับ ซึ่งคะแนนเหล่านี้จะถูกนำมารวมเพื่อเลือกประเทศที่จะนำมาสร้างแบบจำลองการพยากรณ์ต่อไป

ตารางที่ 7: เลือกประเทศที่จะนำมาสร้างแบบจำลองการพยากรณ์จากคะแนนรวมของแต่ละประเทศ

ประเทศ	คะแนนของลำดับ จำนวนนักท่องเที่ยว	คะแนนลำดับจำนวน รายได้	คะแนนรวม	ลำดับ ที่	เลือก/ ไม่เลือก
จีน	16	16	32	1	เลือก
มาเลเซีย	15	15	30	2	เลือก
อินเดีย	14	12	26	3	เลือก
เกาหลี	13	10	23	6	เลือก
ญี่ปุ่น	12	13	25	4	เลือก
ลาว	11	7	18	8	เลือก
รัสเซีย	10	14	24	5	เลือก
สหรัฐอเมริกา	9	11	20	7	เลือก
สิงคโปร์	8	3	11	10	เลือก
เวียดนาม	7	-	-	-	ไม่เลือก
ฮ่องกง	6	4	10	11	เลือก
อังกฤษ	5	9	14	9	เลือก
กัมพูชา	4	2	6	-	ไม่เลือก
เยอรมัน	3	6	9	12	เลือก
ไต้หวัน	2	1	3	-	ไม่เลือก
ออสเตรเลีย	1	8	9	13	เลือก

จากตารางที่ 7 ประเทศที่จะนำมาทำการวิเคราะห์ข้อมูลอนุกรมเวลา (Time series data) ของข้อมูลจำนวนนักท่องเที่ยวต่างชาติ มีทั้งหมด 13 ประเทศ ได้แก่ จีน มาเลเซีย เกาหลี ลาว ญี่ปุ่น อินเดีย รัสเซีย สหรัฐอเมริกา สิงคโปร์ ฮ่องกง อังกฤษ เยอรมัน และออสเตรเลีย ในส่วนของประเทศที่ไม่เลือก 3 ประเทศ ได้แก่ เวียดนาม กัมพูชา และ ไต้หวัน เหตุผลเนื่องจากประเทศเวียดนามติดอันดับจำนวนนักท่องเที่ยวแต่ไม่ติดอันดับของจำนวนรายได้จึงไม่ถูกเลือก เหตุผลที่ไม่เลือกประเทศกัมพูชาและไต้หวันเนื่องจากคะแนนต่ำ ซึ่งข้อมูลอนุกรมเวลาของจำนวนนักท่องเที่ยวทั้ง 13 ประเทศ จะถูกบันทึกไว้เป็นข้อมูลแบบรายเดือน



รูปที่ 12: จำนวนนักท่องเที่ยวต่างชาติแต่ละประเทศที่ทำการคัดเลือกเพื่อนำมาทำการวิเคราะห์และสร้างแบบจำลอง (ปี 2562)

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

ในรูปที่ 12 จะแสดงชื่อประเทศและจำนวนนักท่องเที่ยวของ 13 ประเทศที่ได้ทำการคัดเลือกจากการให้คะแนนตามลำดับความสำคัญของจำนวนนักท่องเที่ยวและจำนวนรายได้ (ตารางที่ 7) เพื่อที่จะนำประเทศที่เลือกดังกล่าวมาสร้างแบบจำลองการพยากรณ์แยกแต่ละประเทศ

ตารางที่ 8: ลำดับของ 13 ประเทศที่ได้เลือกนำจำนวนนักท่องเที่ยวต่างชาติที่เข้ามาท่องเที่ยวที่ประเทศไทยมาวิเคราะห์ในงานวิจัย

ลำดับ ที่	ประเทศ	จำนวนของ นักท่องเที่ยว (2562)	จำนวนของ นักท่องเที่ยว (2561)	การ เปลี่ยนแปลง ของจำนวน นักท่องเที่ยว (%)	การ เปลี่ยนแปลง ของรายได้ (%)
1	จีน	10,994,721	10,535,241	4.36	4.78
2	มาเลเซีย	4,166,868	4,020,526	3.64	3.12
3	เกาหลี	1,887,853	1,796,426	5.09	4.39
4	ลาว	1,845,375	1,664,630	10.86	10.76
5	ญี่ปุ่น	1,806,340	1,656,101	9.07	11.40
6	อินเดีย	1,995,516	1,598,346	24.85	27.45
7	รัสเซีย	1,483,453	1,472,789	0.72	-1.19
8	สหรัฐอเมริกา	1,167,845	1,122,270	4.06	3.44
9.	สิงคโปร์	1,056,836	1,069,867	-1.22	-1.61
10	ฮ่องกง	1,045,198	1,015,749	2.90	3.67
11	อังกฤษ	994,018	986,854	0.73	-0.43
12	เยอรมัน	857,487	886,523	-3.28	-4.97
13	ออสเตรเลีย	768,668	801,203	-4.06	-6.04

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากตารางที่ 8 ได้ทำการอธิบายถึงการเปลี่ยนแปลงของจำนวนนักท่องเที่ยวและรายได้ที่ได้รับจากนักท่องเที่ยวต่างชาติที่เดินทางเข้ามาท่องเที่ยวในประเทศไทยว่าแต่ละประเทศนั้นมีความเปลี่ยนแปลงอย่างไร ประเทศที่มีความเปลี่ยนแปลงของจำนวนนักท่องเที่ยวและรายได้ที่เปลี่ยนแปลงในทางบวกมากที่สุด คือ ประเทศอินเดีย โดยจำนวนนักท่องเที่ยวในปี 2562 มีจำนวนเพิ่มขึ้นถึง 24.85% และรายได้เพิ่มขึ้นถึง 27.45% ซึ่งถือว่าการเปลี่ยนแปลงที่มาก ในส่วนของประเทศที่มีการเปลี่ยนแปลงในทางลบมากที่สุด คือ ประเทศออสเตรเลีย โดยจำนวนนักท่องเที่ยวในปี 2562 มีจำนวนลดลง 4.06% และ รายได้ลดลง 6.04%

3.1.2 การแบ่งข้อมูล


ข้อมูลจำนวนนักท่องเที่ยวต่างชาติที่เดินทางเข้ามาท่องเที่ยวในประเทศไทยที่นำมาวิเคราะห์ คือ ข้อมูลสถิติจำนวนนักท่องเที่ยวจากกระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย โดยข้อมูลถูกบันทึกเป็นข้อมูลรายเดือน ตั้งแต่เดือนมกราคม ปี 2556 ถึง ตุลาคม ปี 2562 โดยจะทำการแบ่งข้อมูลออกเป็น 2 ส่วน คือ ในส่วนแรก 80% (พฤศจิกายน 2556 ถึง ตุลาคม ปี 2561) ของข้อมูลทั้งหมดจะใช้สำหรับการสร้างแบบจำลองการพยากรณ์ และ ส่วนที่สอง 20% (พฤศจิกายน 2561 ถึง ตุลาคม ปี 2562) ที่เหลือจะนำมาใช้ทดสอบความแม่นยำของการพยากรณ์ของแบบจำลองการพยากรณ์ที่ถูกสร้างขึ้น

****หมายเหตุ:** เนื่องจากในเดือนพฤศจิกายน ปี 2562 เริ่มเข้าสู่ช่วง Covid-19 และได้เริ่มมีการปิดประเทศทำให้นักท่องเที่ยวไม่สามารถมาท่องเที่ยวที่ประเทศไทย จึงทำให้ไม่สามารถนำข้อมูลนักท่องเที่ยวต่างชาติในช่วงเดือนดังกล่าวจนถึงปัจจุบัน ทั้งนี้งานวิจัยนี้จึงเลือกใช้การแบ่งข้อมูลเป็น 2 ส่วน อย่างที่กล่าวมาข้างต้น**

3.2 ข้อมูลของงานวิจัยนี้

กราฟอนุกรมเวลา (Time series plot) ของข้อมูลอนุกรมเวลาของนักท่องเที่ยวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทยตั้งแต่เดือนพฤศจิกายน 2556 ถึงตุลาคม 2562 โดยรูปแบบของข้อมูลอนุกรมเวลาจะมีเดือนที่มีคนมามากที่สุดหรือน้อยที่สุดเหมือนกันในแต่ละปี และหากข้อมูลอนุกรมเวลาของจำนวนนักท่องเที่ยวมีแนวโน้มที่จะเพิ่มขึ้นแสดงให้เห็นว่าข้อมูลจำนวนนักท่องเที่ยวมีองค์ประกอบตามฤดูกาล (Seasonal) และ แนวโน้ม (Trend) ตามลำดับ

ตัวอย่างกราฟอนุกรมเวลา (Time series plot) ของประเทศที่แสดงในรูปที่ 13, 14 และ 15 เป็นตัวอย่างของข้อมูลอนุกรมเวลา (Time series data) ของจำนวนนักท่องเที่ยวต่างชาติที่มีรูปแบบของฤดูกาล (Seasonal) ที่ชัดเจน เนื่องจากจะมีเดือนที่มีจำนวนนักท่องเที่ยวต่างชาติจำนวนมากที่สุดและน้อยที่สุดเหมือนกันในเดือนนั้น ๆ ของแต่ละปี




รูปที่ 13: จำนวนนักท่องเที่ยวจากประเทศเยอรมันในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ.

2561

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย


จากรูปที่ 13 จำนวนนักท่องเที่ยวจากประเทศเยอรมันมีจำนวนสูงสุดที่เดือนมีนาคมแล้วลดลงที่เดือนเมษายนและต่ำสุดเดือนมิถุนายนของในแต่ละปี แสดงให้เห็นถึงความเป็นฤดูกาล (Seasonal) ของข้อมูลอนุกรมเวลา (Time series data)



รูปที่ 14: จำนวนนักท่องเที่ยวจากประเทศสหรัฐอเมริกาในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากรูปที่ 14 จำนวนนักท่องเที่ยวจากประเทศสหรัฐอเมริกามีจำนวนสูงสุดที่เดือนธันวาคมและต่ำสุดเดือนกันยายนของแต่ละปี แสดงให้เห็นถึงความเป็นฤดูกาล (Seasonal) ของข้อมูลอนุกรมเวลา (Time series data)




รูปที่ 15: จำนวนนักท่องเที่ยวจากประเทศสิงคโปร์ในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ.

2561

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากรูปที่ 15 จำนวนนักท่องเที่ยวจากประเทศสิงคโปร์มีจำนวนสูงสุดที่เดือนธันวาคมแล้วลดลงที่เดือนมกราคมและต่ำสุดที่เดือนกุมภาพันธ์ของในแต่ละปี แสดงให้เห็นถึงความเป็นฤดูกาล (Seasonal) ของข้อมูลอนุกรมเวลา (Time series data)

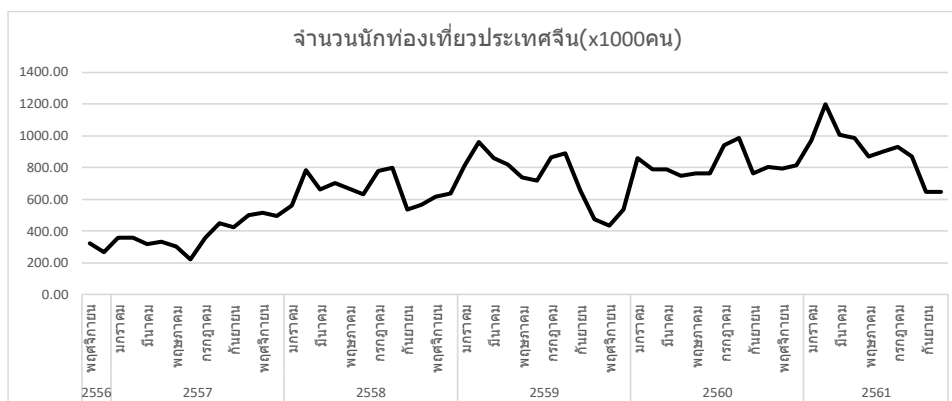
ตัวอย่างกราฟอนุกรมเวลา (Time series plot) ของประเทศที่แสดงในรูปที่ 16, 17 และ 18 เป็นตัวอย่างของข้อมูลอนุกรมเวลา (Time series data) ของจำนวนนักท่องเที่ยวต่างชาติที่มีรูปแบบของฤดูกาล (Seasonal) ที่ไม่ชัดเจน แต่สามารถเห็นรูปแบบของแนวโน้ม (Trend) ได้



รูปที่ 16: จำนวนนักท่องเที่ยวจากประเทศลาวในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย


จากรูปที่ 16 จำนวนนักท่องเที่ยวจากประเทศลาวมีจำนวนสูงสุดที่เดือนสิงหาคมและต่ำสุดที่เดือนกุมภาพันธ์ของในแต่ละปี แสดงให้เห็นถึงความเป็นฤดูกาล (Seasonal) ของข้อมูลอนุกรมเวลา (Time series data) และมีแนวโน้ม (Trend) ของจำนวนนักท่องเที่ยวที่จะเพิ่มขึ้นอย่างต่อเนื่อง



รูปที่ 17: จำนวนนักท่องเที่ยวจากประเทศจีนในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากรูปที่ 17 ข้อมูลอนุกรมเวลา (Time series data) ของจำนวนนักท่องเที่ยวจากประเทศจีนมีรูปแบบรูปแบบของฤดูกาล (Seasonal) ที่ไม่ชัดเจน แต่สามารถบอกได้ว่าจำนวนนักท่องเที่ยวจากประเทศจีนมีแนวโน้ม (Trend) ของจำนวนนักท่องเที่ยวที่จะเพิ่มขึ้นอย่างต่อเนื่อง



รูปที่ 18: จำนวนนักท่องเที่ยวจากประเทศไทยในเดือนพฤศจิกายน พ.ศ. 2556 ถึง ตุลาคม พ.ศ. 2561

ที่มา: กระทรวงการท่องเที่ยวและกีฬาแห่งประเทศไทย

จากรูปที่ 18 นักท่องเที่ยวจากประเทศไทยมีจำนวนสูงสุดที่เดือนธันวาคมแล้วลดลงในเดือนมกราคมของในแต่ละปี แสดงให้เห็นถึงความเป็นฤดูกาล (Seasonal) ของข้อมูลอนุกรมเวลา (Time series data) และมีแนวโน้ม (Trend) ของจำนวนนักท่องเที่ยวในปี 2561

3.3 แบบจำลองการพยากรณ์

3.3.1 การสร้างแบบจำลองค่าเฉลี่ยเคลื่อนที่ตามฤดูกาลอัตโนมัติ (SARIMA)

แบบจำลอง SARIMA สามารถสร้างได้ตามขั้นตอนดังต่อไปนี้

ขั้นตอนที่ 1: ตรวจสอบข้อมูลอนุกรมเวลา (Time series data) ด้วยการสร้างกราฟของข้อมูลอนุกรมเวลา (Time series plot) เพื่อดูว่าข้อมูลมีแนวโน้ม (Trend) และมีฤดูกาล (Seasonal) หรือไม่ เพื่อให้รู้ว่าข้อมูลอนุกรมเวลา (Time series data) นี้เป็นแบบคงที่ (Stationary data) หรือแบบไม่คงที่ (Non-Stationary data)

ขั้นตอนที่ 2: ถ้าข้อมูลอนุกรมเวลา (Time series data) มีแนวโน้ม (Trend) และมีฤดูกาล (Seasonal) ให้นำข้อมูลมาทำการกำจัดแนวโน้มและฤดูกาล (Differencing) เพื่อให้ข้อมูลอนุกรมเวลา (Time series data) เป็นแบบคงที่ (Stationary data)

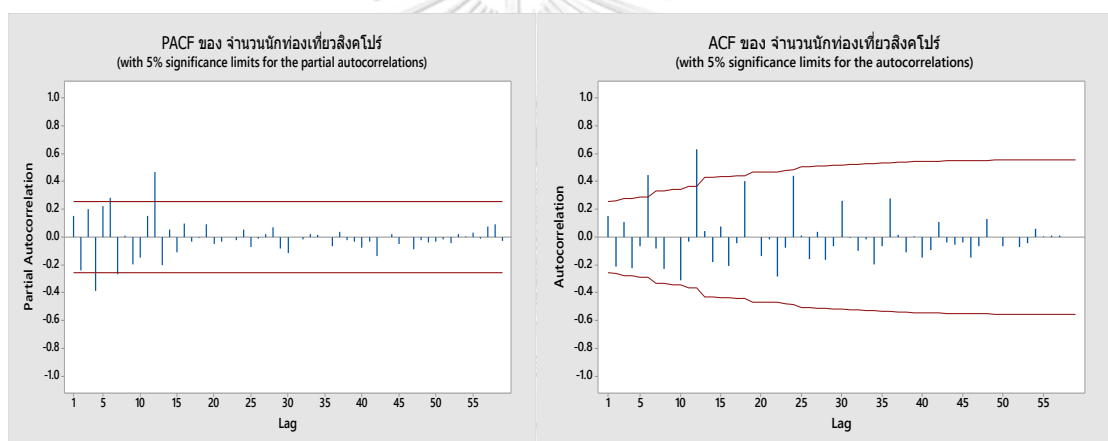
ขั้นตอนที่ 3: ตรวจสอบฟังก์ชันความสัมพันธ์อัตโนมัติ (Autocorrelation Function: ACF) และฟังก์ชันความสัมพันธ์อัตโนมัติบางส่วน (Partial Autocorrelation Function: PACF) เพื่อดูว่าข้อมูล

อนุกรมเวลา (Time series data) นั้นอยู่ในเงื่อนไขของ (Autoregressive: AR) หรือ (Moving average: MA) แบบจำลอง SARIMA ที่ดีจะถูกเลือกเมื่อมีค่าทดสอบสมมติฐานน้อยกว่า 0.05 ($p\text{-value} < 0.05$)

ขั้นตอนที่ 4: เมื่อเลือกแบบจำลอง SARIMA แล้ว ค่าพารามิเตอร์ (Parameter) ของแบบจำลองจะสามารถประมาณได้โดยวิธีกำลังสองน้อยที่สุด (The least-squares method)


ขั้นตอนที่ 5: ทดสอบส่วนที่เหลือ (Residual) เพื่อตรวจสอบว่าแบบจำลองนั้นเพียงพอสำหรับข้อมูลหรือไม่ มีความจำเป็นต้องตรวจสอบสมมติฐานของส่วนที่เหลือว่ามีภาวะปกติ (Normal) และความสัมพันธ์อัตโนมัติ (Autocorrelation) กันหรือไม่

ขั้นตอนสุดท้าย: นำแบบจำลอง SARIMA ที่เลือกมาทดสอบความแม่นยำของแบบจำลอง (Testing model)



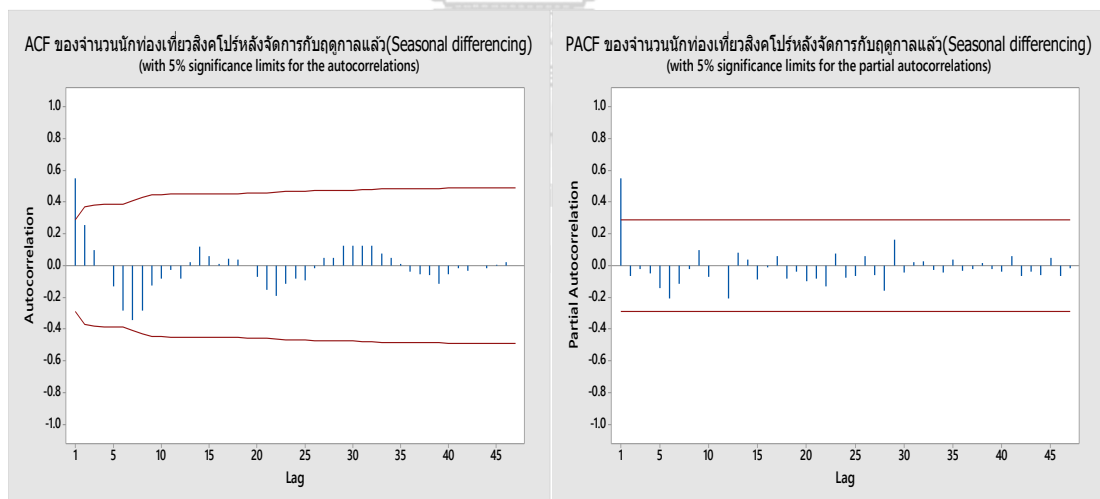
รูปที่ 19: ACF และ PACF ของประเทศสิงคโปร์ (พฤศจิกายน ปี 2556 ถึง ตุลาคม ปี 2561)

จากรูปที่ 19 จะเห็นได้ว่าชุดข้อมูลอนุกรมเวลา (Time series data) ของประเทศสิงคโปร์ ACF มีรูปแบบของฤดูกาล (Seasonal) เนื่องจากมีความ significant ของข้อมูลใน Lag ที่ 6,12,...,k ทำให้สามารถบอกได้ว่าข้อมูลอนุกรมเวลานี้ไม่ได้เป็นข้อมูลที่คงที่ (Stationary Data) ต้องทำการจัดการกับฤดูกาล (Seasonal) ของข้อมูลอนุกรมเวลา (Time series data) นี้ก่อนที่จะนำมาสร้างแบบจำลอง SARIMA



รูปที่ 20: จำนวนนักท่องเที่ยวจากประเทศสิงคโปร์หลังจากทำการจัดการกับฤดูกาลแล้ว (Seasonal differencing)

จากรูปที่ 20 จะแสดงรูปแบบของข้อมูลอนุกรมเวลา (Time series data) ของจำนวนนักท่องเที่ยวจากประเทศสิงคโปร์หลังจากทำการจัดการกับฤดูกาล (Seasonal) แล้วว่ามีรูปแบบของข้อมูลเปลี่ยนแปลงอย่างไร จะเห็นได้ว่าความเป็นฤดูกาล (Seasonal) ของข้อมูลอนุกรมเวลา (Time series data) จำนวนนักท่องเที่ยวจากประเทศสิงคโปร์ (รูปที่ 15) นั้นได้ถูกจัดการแล้ว



รูปที่ 21: ACF และ PACF ของประเทศสิงคโปร์หลังทำการจัดการกับฤดูกาลแล้ว (Seasonal differencing)

จากรูปที่ 21 ACF ของข้อมูลอนุกรมเวลา (Time series data) จำนวนนักท่องเที่ยวที่มาจากประเทศสิงคโปร์มีความ significant ใน Lag ที่ 1 แล้วค่อย ๆ ลดลง และ PACF มีความ significant

ที่ Lag 1 ที่เดียวแล้วไม่มีความ significant ที่ Lag อื่น ทำให้สรุปได้ว่าข้อมูลนี้เหมาะกับแบบจำลอง AR(1) หรือ SARIMA(1,0,0) (0,1,0)₁₂

```
> fit.arima <- auto.arima(Datats,trace = TRUE ,test = "kpss", ic="aic")
```

```
ARIMA(2,0,2)(1,1,1)[12] with drift      : Inf
ARIMA(0,0,0)(0,1,0)[12] with drift      : 347.3134
ARIMA(1,0,0)(1,1,0)[12] with drift      : 332.0062
ARIMA(0,0,1)(0,1,1)[12] with drift      : 335.0789
ARIMA(0,0,0)(0,1,0)[12]                 : 355.5071
ARIMA(1,0,0)(0,1,0)[12] with drift      : 331.311
ARIMA(1,0,0)(0,1,1)[12] with drift      : 331.9456
ARIMA(1,0,0)(1,1,1)[12] with drift      : 333.934
ARIMA(2,0,0)(0,1,0)[12] with drift      : 332.9972
ARIMA(1,0,1)(0,1,0)[12] with drift      : 333.0631
ARIMA(0,0,1)(0,1,0)[12] with drift      : 334.5905
ARIMA(2,0,1)(0,1,0)[12] with drift      : Inf
ARIMA(1,0,0)(0,1,0)[12]                 : 331.6127
```

```
Best model: ARIMA(1,0,0)(0,1,0)[12] with drift
```

รูปที่ 22: ตรวจสอบแบบจำลอง SARIMA(p, d, q)(P, D, Q)_s ที่เลือก

รูปที่ 22 ได้ทำการตรวจสอบแบบจำลอง SARIMA(p, d, q)(P, D, Q)_s ที่เลือกกว่าเป็นแบบจำลองที่เหมาะสมที่สุดแล้วหรือไม่ด้วยชุดคำสั่ง auto.arima ของ โปรแกรม R หลังจากที่ได้ทำการตรวจสอบโปรแกรม R ได้หาแบบจำลอง SARIMA(p, d, q)(P, D, Q)_s ที่เหมาะสมที่สุดมาให้ คือ ARIMA(1,0,0)(0,1,0)[12] หรือ SARIMA(1,0,0) (0,1,0)₁₂ ซึ่งตรงกับได้วิเคราะห์ไว้ข้างต้น

```
Coefficients:
  ar1  drift
  0.5637 0.3284
s.e.  0.1191 0.1920

sigma^2 estimated as 53.2: log likelihood=-162.66
AIC=331.31 AICc=331.86 BIC=336.92
> coefest(fit.arima)

> summary(fit.arima)
Series: Datats
ARIMA(1,0,0)(0,1,0)[12] with drift

Coefficients:
  ar1  drift
  0.5637 0.3284
s.e.  0.1191 0.1920

sigma^2 estimated as 53.2: log likelihood=-162.66
AIC=331.31 AICc=331.86 BIC=336.92

z test of coefficients:

      Estimate Std. Error z value Pr(>|z|)
ar1    0.56368    0.11913  4.7317 2.227e-06 ***
drift  0.32838    0.19201  1.7102  0.08722 .
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Training set error measures:
              ME      RMSE      MAE      MPE      MAPE
Training set 0.1561564 6.386437 4.446309 -0.07337796 5.836181
              MASE      ACF1
Training set 0.6338438 0.03262741
```

รูปที่ 23: ข้อมูลที่เกี่ยวข้องกับแบบจำลอง ARIMA(1,0,0)(0,1,0)[12] หรือ SARIMA(1,0,0) (0,1,0)₁₂

ในส่วนของรูปที่ 23 จะแสดงข้อมูลในส่วนของ AIC, BIC, z test, และ ค่าเฉลี่ยความผิดพลาดของแบบจำลอง (Measures error) จากข้อมูลข้างต้นสามารถอธิบายได้ว่าแบบจำลอง ARIMA(1,0,0)(0,1,0)[12] หรือ SARIMA(1,0,0) (0,1,0)₁₂ มีค่า significant ที่ยอมรับได้น้อยกว่า 0.05 (p-value < 0.05) และ มีความแม่นยำในการพยากรณ์ของแบบจำลองที่ MAPE = 5.84% โดยประมาณ

3.3.2 แบบจำลอง BATS และ TBATS มีขั้นตอนดังต่อไปนี้

ขั้นตอนที่ 1: ข้อมูลจำเพาะของชุดรูปแบบที่มีทั้งหมดซึ่งจะต้องพิจารณาสำหรับแต่ละชุดในกรอบการสร้างแบบจำลอง BATS มีทั้งหมด 24 แบบสำหรับการพิจารณาของแต่ละชุดเฟรมเวิร์ก (Framework) นี้ประกอบด้วยชุดค่าผสม 16 แบบที่พิจารณาส่วนประกอบ B, A, T, S และ 8 แบบที่พิจารณาองค์ประกอบของแนวโน้มแบบหน่วง (Damped trend component) ตัวอย่าง $\omega=1$ ถือว่าไม่มีการแปลงบ็อกซ์ - คอกซ์ (Box-Cox transformation), $\phi=1$ แสดงว่าไม่มีส่วนประกอบแบบหน่วง (Damping component), $p = q = 0$ เนื่องจากไม่มีการปรับ ARMA ที่เหลือในแบบจำลองการสร้างแบบจำลอง TBATS ค่อนข้างตรงไปตรงมาโดยหลักการคล้ายคลึงกับเวกเตอร์แบบสุ่มเนื่องจากค่าการทดลองของพารามิเตอร์ (Parameter) ที่ไม่รู้จักทำให้การแจกแจงความคงตัวร่วมของสถานะคงที่ที่ได้รับแล้วมอบหมายให้ขั้นตอนที่เกี่ยวข้องต่อไป

ขั้นตอนที่ 2: การประเมินแบบจำลอง สถานะเริ่มต้น x_0 พารามิเตอร์การปรับให้เรียบ (The smoothing parameters) พารามิเตอร์บ็อกซ์ - คอกซ์ (The Box-Cox parameter) พารามิเตอร์แบบหน่วง (the damping parameter) และค่าสัมประสิทธิ์สำหรับองค์ประกอบ ARMA จะถูกประเมินโดยใช้เกณฑ์การประเมินที่เหมาะสม

เกณฑ์การประเมินที่แตกต่างกันสามข้อจะพิจารณาสำหรับการปรับให้เหมาะสมแบบไม่เชิงเส้น (Non-linear) ดังนี้

แบบที่ 1: ค่าสูงสุดบันทึกความน่าจะเป็นของการประมาณการ (Maximize the log-likelihood of the estimates: MLE)

แบบที่ 2: ค่าต่ำสุดรากที่สองของค่าเฉลี่ยข้อผิดพลาดของข้อมูลดั้งเดิม (Minimize the Root Mean Square Error of the original data: RMSE)

แบบที่ 3: ค่าต่ำสุดรากที่สองของค่าเฉลี่ยข้อผิดพลาดของข้อมูลที่เปลี่ยนแปลงแล้ว (Minimize the Root Mean Square Error of The transformed data: RMSE_T)

ขั้นตอนที่ 3: เลือกแบบจำลองที่ดีที่สุด เกณฑ์ในการเลือกใช้การดู Akaike information criterion (AIC) เปรียบเทียบผลที่ได้ของแบบจำลอง การตรวจสอบแบบจำลอง ARMA ทำดังต่อไปนี้

- 1) ตั้งให้ $\{p = 0, q = 0\}$ สันนิษฐานว่าไม่จำเป็นต้องทำการปรับแบบจำลอง ARMA
- 2) หาค่าของ p และ q ในชุดค่าผสมของแบบจำลอง ARMA ที่เป็นไปได้ทั้งหมดจนถึง $p = q = 5$ แล้วพิจารณา และ การเลือกแบบจำลอง ARMA (p, q) เลือกแบบจำลองที่มี AIC น้อยที่สุด หรือ ดึงค่า p และ q จากการทำแบบขั้นตอน (Stepwise) สำหรับแบบจำลอง TBATS จำนวนของฮาร์มอนิกส์ (Harmonics) ถูกเลือกใช้โดยการเพิ่มขึ้นอย่างคงที่ของฮาร์มอนิกส์ (Harmonics) และ การทดสอบความสำคัญ (Significant) ของแต่ละแบบให้ใช้ F-test ในการทดสอบ

ขั้นตอนที่ 4: สร้างการกระจายการพยากรณ์โดยใช้แบบจำลองที่ดีที่สุดที่ได้จากการทำ 3 ขั้นตอน

3.3.3 ขั้นตอนการฝึกอบรมแบบจำลอง ANN (Training ANN model) มีดังนี้

ขั้นตอนที่ 1: สุ่มค่าน้ำหนัก (Weight) เริ่มต้นและค่าของข้อมูลเริ่มต้น (เพื่อทำให้สามารถคำนวณหาผลลัพธ์ของข้อมูลในครั้งแรกได้)

ขั้นตอนที่ 2: นำค่าข้อมูลที่จะทำการเรียนรู้เข้าสู่ Input nodes (Forward propagation)

ขั้นตอนที่ 3: เลือก Activation function ที่จะใช้ในการคำนวณ

ขั้นตอนที่ 4: ใช้ Backpropagation ในการคืนค่าของข้อมูลเพื่อทำการเรียนรู้ค่าของข้อมูลจนกว่าค่าจะลู่เข้า (Convergence) ค่าที่ดีที่สุด

ขั้นตอนที่ 5: ใช้ algorithm “adam” เพื่อหาค่าของข้อมูลที่ดีที่สุด (adam คือ algorithm ประเภท Optimization ที่ถูกสร้างขึ้นมาเพื่อหาค่าของข้อมูลที่ดีที่สุด สามารถเพิ่มประสิทธิภาพการทำงานของฟังก์ชันโดยที่ต้องการหน่วยความจำในการใช้งานเพียงเล็กน้อย และสามารถใช้สำหรับการแก้ปัญหาของข้อมูลที่มีจำนวนมากได้เป็นอย่างดี) (Kingma & Ba, 2014)

ขั้นตอนที่ 6: สร้างแบบจำลอง ANN ที่ได้จากการนำค่าข้อมูลมาเรียนรู้ (Training) เพื่อนำไปใช้ในการทดสอบ (Testing)

3.3.3.1 ปัจจัยที่นำมาใช้ในการเรียนรู้ (Training) กับแบบจำลอง ANN

งานวิจัยนี้จะเลือกปัจจัยที่มีความสำคัญต่ออุตสาหกรรมการท่องเที่ยวจากข้อเสนอแนะจากงานวิจัยก่อนหน้าที่เกี่ยวข้องกับความต้องการด้านการท่องเที่ยว (Hwandee & Phumchusri, 2020)

งานวิจัยนี้ได้ทำการศึกษาความต้องการการมาท่องเที่ยวในประเทศไทยของชาวต่างชาติจากประเทศที่มีความสำคัญเกี่ยวกับความต้องการที่จะเดินทางมาท่องเที่ยวที่ประเทศไทย โดยประเทศที่มีความสำคัญมากที่สุด 13 ประเทศจากทั้งหมด ได้แก่ จีน, รัสเซีย, อินเดีย, เกาหลี, มาเลเซีย, อังกฤษ, สหรัฐอเมริกา, ญี่ปุ่น, สิงคโปร์, ออสเตรเลีย, ลาว, เยอรมัน และ ฮังการี

ปัจจัยที่ได้มีการแนะนำจากงานวิจัยก่อนหน้าที่เกี่ยวข้องกับความต้องการด้านการท่องเที่ยว ได้แก่ รายได้ในรูปของ Gross Domestic Product (GDP) ต่อหัวเฉลี่ย ราคาสัมพัทธ์ (relative price) อัตราแลกเปลี่ยนค่าเงิน (exchange rate) ตัวแปรจำลองผลกระทบของการเกิดฤดูกาล (dummy variable of seasonal effect) และ ตัวแปรจำลองผลกระทบของการเกิดข่าวไม่ดีหรือสถานการณ์ภายในประเทศ (dummy variable of news shock effect)

- GDP ต่อหัว หมายถึง รายได้ของประชากรจากประเทศที่เดินทางเข้ามาท่องเที่ยวที่ประเทศไทย โดยหน่วยของ GDP ต่อหัว คือ ดอลลาร์ต่อหัวรายปี

- Relative Price หมายถึง ตัวเลขทางสถิติที่ใช้วัดการเปลี่ยนแปลงของราคาสินค้าและบริการที่ครอบครัวหรือผู้บริโภคซื้อหามาบริโภคเป็นประจำ ในปัจจุบันจะถูกนำมาใช้เปรียบเทียบกับราคาในปีที่กำหนดไว้เป็นปีฐาน

$$\text{Relative Prices} = \frac{\text{CPI(Destination)}}{\text{CPI (Origin)}} \quad (11)$$

โดยที่

CPI (Destination) คือ ดัชนีราคาผู้บริโภคของประเทศที่เดินทางเข้ามาท่องเที่ยวที่ประเทศไทย

ไทย

CPI (Origin) คือ ดัชนีราคาผู้บริโภคของประเทศไทย

- Exchange Rate หมายถึง จำนวนหน่วยของการแลกเปลี่ยนระหว่างสกุลเงินของแต่ละประเทศที่เข้ามาท่องเที่ยวที่ประเทศไทย ซึ่งมีมูลค่าเพิ่มขึ้นหรือลดลงตามปริมาณการซื้อขายเงินในตลาด
- Dummy variable of seasonal effect คือ ตัวแปรจำลองของผลกระทบความเป็นฤดูกาล (Seasonal) ของแต่ละเดือน
- Dummy variable of news shock effect คือ ตัวแปรจำลองของการเกิดข่าวไม่ดีหรือสถานการณ์ภายในประเทศ ที่ส่งผลกระทบต่อการท่องเที่ยวที่ประเทศไทย

ในช่วงเวลาที่ผ่านมาตั้งแต่ปี พ.ศ. 2556 ถึง พ.ศ. 2562 ประเทศไทยได้มีข่าวหรือสถานการณ์จำนวนมากที่ส่งผลกระทบต่อการท่องเที่ยวของประเทศไทย เนื่องจากว่าข่าวหรือสถานการณ์ที่เกิดขึ้นสร้างความเสียหายต่อการคมนาคมและความไม่ปลอดภัยสำหรับชาวต่างชาติที่ต้องการจะเข้ามาท่องเที่ยวที่ประเทศไทยในช่วงเวลาดังกล่าว แต่ข่าวหรือสถานการณ์ดังกล่าวจะเกิดขึ้นในระยะเวลาประมาณ 1 ถึง 3 เดือนโดยส่วนใหญ่ และสูงสุดอยู่ที่ 9 เดือน โดยจะมีสถานการณ์ดังต่อไปนี้

- การต่อต้านรัฐบาล (Anti-Government)

สถานการณ์การต่อต้านรัฐบาลที่เกิดขึ้นภายในประเทศ ซึ่งส่งผลกระทบต่อค่าตัวแปรจำลองผลกระทบเป็น 1 ในเดือนที่มีการต่อต้านรัฐบาล และ จะแทนเป็น 0 ในตอนที่สถานการณ์ปกติ ซึ่งในเดือนที่ได้รับผลกระทบ คือ เดือนพฤศจิกายน ปี พ.ศ. 2556 ถึง กรกฎาคม ปี พ.ศ. 2557 ในการเรียนรู้ของแบบจำลอง ANN (Training ANN model)

- การลอบวางระเบิดในกรุงเทพมหานคร (Bomb in Bangkok)

การลอบวางระเบิดที่เกิดขึ้นในกรุงเทพมหานคร ทำให้เกิดความวุ่นวายการท่องเที่ยวชะงักงันเนื่องจากความไม่ปลอดภัยที่เกิดขึ้นถือเป็นผลกระทบด้านลบต่อการท่องเที่ยว โดยจะทำการแทนค่าตัวแปรจำลองผลกระทบเป็น 1 ในเดือนที่มีการผลกระทบของการวางระเบิด และ

จะแทนเป็น 0 ในตอนที่สถานการณ์ปกติ ซึ่งในเดือนที่ได้รับผลกระทบคือ เดือนสิงหาคม ถึง ตุลาคม ปี 2558 ในการเรียนรู้ของแบบจำลอง ANN (Training ANN model)

- อุทกภัย (Floods)

การเกิดอุทกภัยในประเทศไทยสร้างความเสียหายแก่ที่พักอาศัยและสถานที่ท่องเที่ยวต่าง ๆ ทำให้ส่งผลกระทบต่อปริมาณนักท่องเที่ยวที่ประเทศไทยในช่วงเวลาที่เกิดอุทกภัยขึ้น ซึ่งจะทำให้การแทนค่าตัวแปรจำลองผลกระทบเป็น 1 ในเดือนที่มีการเกิดอุทกภัย และ จะแทนเป็น 0 ในตอนที่สถานการณ์ปกติ ซึ่งเดือนที่ได้รับผลกระทบคือ เดือนมีนาคม ถึง มิถุนายน ปี 2560 และ เดือนสิงหาคม ถึง พฤศจิกายน ปี 2561 ในการเรียนรู้ของแบบจำลอง ANN (Training ANN model)

- การสิ้นพระชนม์ของในหลวงรัชกาลที่ 9 (Thai King Rama9 Passed Away)

การสิ้นพระชนม์ของในหลวงรัชกาลที่ 9 ถือเป็นเหตุการณ์ที่มีผลกระทบทางจิตใจของประชาชนชาวไทยและการท่องเที่ยวภายในประเทศเนื่องจากได้มีนโยบายข้อกำหนดจากทางรัฐบาลว่าในช่วงที่ไว้อาลัย ห้ามมีการจัดงานแสดงรื่นเริงใด ๆ สถานที่ท่องเที่ยวหลายแห่งถูกจำกัดการให้บริการจึงส่งผลกระทบต่อปริมาณนักท่องเที่ยวชะลอตัวลง โดยจะทำการแทนค่าตัวแปรจำลองผลกระทบเป็น 1 ในเดือนที่ในหลวงรัชกาลที่ 9 สิ้นพระชนม์ และ จะแทนเป็น 0 ในตอนที่สถานการณ์ปกติ ซึ่งเดือนที่ได้รับผลกระทบคือ เดือนตุลาคม ถึง พฤศจิกายน ปี 2559 ในการเรียนรู้ของแบบจำลอง ANN (Training ANN model)


- เรือล่มที่ภูเก็ต (Boat Accident in Phuket)

เรือล่มที่ภูเก็ตทำให้เกิดความเสียหายต่อการท่องเที่ยวที่ประเทศไทย เนื่องจากนักท่องเที่ยวส่วนใหญ่เป็นนักท่องเที่ยวจากประเทศจีน ซึ่งมีความสำคัญกับอุตสาหกรรมการท่องเที่ยวของไทยมากที่สุดจากทุกประเทศ โดยจะทำการแทนค่าตัวแปรจำลองผลกระทบเป็น 1 ในเดือนที่เรือล่ม และ จะแทนเป็น 0 ในตอนที่สถานการณ์ปกติ ซึ่งเดือนที่ได้รับผลกระทบคือ เดือน กันยายน ถึง พฤศจิกายน ปี 2561 ในการเรียนรู้ของแบบจำลอง ANN (Training ANN model)

จากปัจจัยที่กล่าวมาข้างต้นงานวิจัยนี้จะเพิ่มเติมปัจจัยที่มีความสำคัญต่อความต้องการการท่องเที่ยวของชาวต่างชาติ ได้แก่

- ข้อมูลอนุกรมเวลาของจำนวนนักท่องเที่ยวแต่ละประเทศ (Time Series Data)

ข้อมูลอนุกรมเวลา (Time Series Data) ของจำนวนนักท่องเที่ยวแต่ละประเทศที่นำมาทำการวิเคราะห์ เพื่อช่วยให้แบบการพยากรณ์ของแบบจำลอง ANN ได้เรียนรู้ถึงลักษณะของการท่องเที่ยวของแต่ละประเทศที่จะทำการพยากรณ์ เพื่อให้ได้ข้อมูลจำนวนนักท่องเที่ยวของแต่ละประเทศจากการพยากรณ์มีความถูกต้องแม่นยำมากขึ้น จากคำแนะนำของงานวิจัยที่เกี่ยวข้องกับการจัดเตรียมห้องพักให้กับชาวต่างชาติที่เดินทางมาท่องเที่ยวที่ประเทศไทย (Phumchusri & Ungtrakul, 2020)



รูปที่ 24: Flow chart ของการสร้างแบบจำลอง ANN ในงานวิจัยนี้

3.4 การเปรียบเทียบแบบจำลองการพยากรณ์

ตารางที่ 9: ความถูกต้องแม่นยำของการพยากรณ์

MAPE value	Interpretation
<10%	Highly accurate
10-20%	Good
20-50%	Reasonable
>50%	Bad

ที่มา: (Klimberg, Sillup, Boyle, & Tawva, 2010)

ในการเปรียบเทียบระหว่างแบบจำลองในงานวิจัยนี้จะใช้วิธี Randomized Complete Block Design (RCBD) โดยใช้ค่า p-value < 0.05 เพื่อแบ่งกลุ่ม และ ใช้ Tukey method ในการวิเคราะห์และเปรียบเทียบแบบจำลองว่ามีความแตกต่างกันอย่างมีนัยสำคัญหรือไม่

บทที่ 4 ผลการดำเนินงาน

4.1 วิธีอนุกรมเวลา (Time Series Method)

4.1.1 Seasonal ARIMA Method

ตารางที่ 10: ผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 5 ปี เป็นชุดข้อมูลฝึกอบรม (Training) (เดือนพฤศจิกายน ปี 2556 ถึง ตุลาคม ปี 2561) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562)

ประเทศ	แบบจำลอง	ค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE)	
		การฝึกอบรมแบบจำลอง (Training model)	การทดสอบแบบจำลอง (Testing model)
จีน	(0,1,0) (1,1,0) ₁₂	7.94	8.99
มาเลเซีย	(1,1,0) (1,1,0) ₁₂	7.03	10.58
เกาหลี	(1,0,0) (1,1,0) ₁₂	4.92	6.69
ญี่ปุ่น	(1,0,0) (0,1,0) ₁₂	3.44	4.21
รัสเซีย	(2,1,1) (0,1,1) ₁₂	9.78	11.31
อังกฤษ	(4,1,0) (1,1,1) ₁₂	3.04	3.59
สหรัฐอเมริกา	(2,0,0) (0,1,0) ₁₂	2.92	2.85
สิงคโปร์	(1,0,0) (0,1,0) ₁₂	5.84	5.48
อินเดีย	(0,1,1) (0,1,0) ₁₂	3.48	16.35
ออสเตรเลีย	(0,1,1) (0,1,1) ₁₂	3.52	3.99
ลาว	(0,0,1) (1,1,0) ₁₂	3.96	4.55
ฮ่องกง	(1,0,0) (0,1,1) ₁₂	10.38	7.57
เยอรมัน	(0,0,0) (0,1,1) ₁₂	4.88	11.30

ตารางที่ 10 บอกถึงรายละเอียดของ SARIMA (p, d, q) (P, D, Q) ที่นำมาใช้ในการพยากรณ์ข้อมูล และค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE) ระหว่างการฝึกอบรมแบบจำลอง (Training model) และ การทดสอบแบบจำลอง (Testing model) นั้นมีความแตกต่างกันเล็กน้อย แต่มีประเทศที่มี MAPE ของการทดสอบที่สูงกว่าการฝึกอบรมมาก คือ อินเดีย และเยอรมัน

ตารางที่ 11: ผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 3 ปี เป็นชุดข้อมูลฝึกอบรม (Training) (เดือนพฤศจิกายน ปี 2558 ถึง ตุลาคม ปี 2561) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562)

ประเทศ	แบบจำลอง	ค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE)	
		การฝึกอบรมแบบจำลอง (Training model)	การทดสอบแบบจำลอง (Testing model)
		จีน	(1,0,0) (1,1,0) ₁₂
มาเลเซีย	(1,1,0) (0,1,0) ₁₂	6.58	17.79
เกาหลี	(2,0,0) (1,1,0) ₁₂	2.96	3.80
ญี่ปุ่น	(0,0,0) (0,1,0) ₁₂	1.87	3.87
รัสเซีย	(2,0,0) (0,1,1) ₁₂	4.70	13.09
อังกฤษ	(0,0,1) (1,1,0) ₁₂	1.61	2.56
สหรัฐอเมริกา	(1,1,1) (0,1,0) ₁₂	1.98	2.29
สิงคโปร์	(0,0,0) (0,1,0) ₁₂	3.04	5.01
อินเดีย	(1,0,0) (1,1,0) ₁₂	2.02	11.44
ออสเตรเลีย	(0,0,0) (1,1,0) ₁₂	1.99	5.12
ลาว	(0,0,1) (0,1,1) ₁₂	2.92	3.80
ฮ่องกง	(3,1,0) (1,1,0) ₁₂	6.58	10.94
เยอรมัน	(0,0,0) (1,1,0) ₁₂	3.75	7.77

ตารางที่ 11 บอกถึงรายละเอียดของ SARIMA (p, d, q) (P, D, Q) ที่นำมาใช้ในการพยากรณ์ข้อมูล และค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE) ระหว่างการฝึกอบรมแบบจำลอง (Training model) และ การทดสอบแบบจำลอง (Testing model) นั้นมีความแตกต่างกันมาก แต่มีประเทศที่มี MAPE ของการทดสอบที่สูงกว่าการฝึกอบรมน้อย คือ เกาหลี อังกฤษ สหรัฐอเมริกา และ ลาว

ตารางที่ 12: ผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 4 ปี เป็นชุดข้อมูลฝึกอบรม (Training) (เดือนพฤศจิกายน ปี 2557 ถึง ตุลาคม ปี 2561) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562)

ประเทศ	แบบจำลอง	ค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE)	
		การฝึกอบรมแบบจำลอง	การทดสอบแบบจำลอง
		(Training model)	(Testing model)
จีน	(1,0,1) (1,1,0) ₁₂	6.85	9.80
มาเลเซีย	(1,0,2) (0,1,1) ₁₂	4.90	12.46
เกาหลี	(0,0,0) (1,1,0) ₁₂	3.85	4.71
ญี่ปุ่น	(0,1,1) (0,1,0) ₁₂	2.40	3.57
รัสเซีย	(2,0,0) (0,1,0) ₁₂	6.80	16.74
อังกฤษ	(0,1,1) (1,1,0) ₁₂	2.56	2.45
สหรัฐอเมริกา	(0,1,1) (0,1,0) ₁₂	2.34	2.23
สิงคโปร์	(0,0,0) (0,1,0) ₁₂	3.61	4.72
อินเดีย	(1,0,0) (1,1,0) ₁₂	2.62	12.74
ออสเตรเลีย	(0,0,0) (0,1,1) ₁₂	2.03	5.04
ลาว	(2,0,0) (1,1,0) ₁₂	3.71	4.71
ฮ่องกง	(3,1,0) (1,1,0) ₁₂	8.04	12.09
เยอรมัน	(0,1,1) (0,1,1) ₁₂	4.03	9.54

ตารางที่ 12 บอกถึงรายละเอียดของ SARIMA (p, d, q) (P, D, Q) ที่นำมาใช้ในการพยากรณ์ข้อมูล และค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE) ระหว่างการฝึกอบรมแบบจำลอง (Training model) และ การทดสอบแบบจำลอง (Testing model) มีประเทศที่มี MAPE ของการทดสอบที่สูงกว่าการฝึกอบรมมาก คือ มาเลเซีย รัสเซีย อินเดีย ฮ่องกง และ เยอรมัน

ตารางที่ 13: เปรียบเทียบผลจากการทดสอบแบบจำลอง (Testing model) ของ SARIMA โดยใช้ข้อมูลย้อนหลัง 3, 4 และ 5 ปี เป็นชุดข้อมูลฝึกอบ (Training) กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562)

ประเทศ	ค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE)		
	3 ปี	4 ปี	5 ปี
จีน	9.27	9.80	8.99
มาเลเซีย	17.79	12.46	10.58
เกาหลี	3.80	4.71	6.69
ญี่ปุ่น	3.87	3.57	4.21
รัสเซีย	13.09	16.74	11.31
อังกฤษ	2.56	2.45	3.59
สหรัฐอเมริกา	2.29	2.23	2.85
สิงคโปร์	5.01	4.72	5.48
อินเดีย	11.44	12.74	16.35
ออสเตรเลีย	5.12	5.04	3.99
ลาว	3.80	4.71	4.55
ฮ่องกง	10.94	12.09	7.57
เยอรมัน	7.77	9.54	11.30

ตารางที่ 13 ทางผู้วิจัยได้ทำการเปรียบเทียบผลการทดสอบแบบจำลอง (Testing model) SARIMA ที่มีการฝึกอบแบบจำลอง (Training model) ด้วยข้อมูลจำนวนนักท่องเที่ยวต่างชาติย้อนหลัง 3, 4 และ 5 ปี โดยประเทศที่แบบจำลอง SARIMA ของ 3 ปี ได้แก่ เกาหลี ลาว และเยอรมัน ของ 4 ปี ได้แก่ ญี่ปุ่น อังกฤษ สหรัฐอเมริกา และ สิงคโปร์ ของ 5 ปี ได้แก่ จีน รัสเซีย ออสเตรเลีย และ ฮ่องกง

4.1.2 TBATS

ตารางที่ 14: ผลจากการทดสอบแบบจำลอง (Testing model) ของ TBATS กับข้อมูลจำนวนนักท่องเที่ยวจริง (เดือนพฤศจิกายน ปี 2561 ถึง ตุลาคม ปี 2562) เปรียบเทียบกับการทดสอบแบบจำลอง (Testing model) SARIMA

ประเทศ	ค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE)	
	การทดสอบแบบจำลอง (SARIMA)	การทดสอบแบบจำลอง (TBATS)
	จีน	8.99
มาเลเซีย	10.58	7.74
เกาหลี	6.69	7.54
ญี่ปุ่น	4.21	6.59
รัสเซีย	11.31	12.04
อังกฤษ	3.59	4.59
สหรัฐอเมริกา	2.85	6.93
สิงคโปร์	5.48	5.14
อินเดีย	16.35	23.67
ออสเตรเลีย	3.99	4.46
ลาว	4.55	3.48
ฮ่องกง	7.57	7.97
เยอรมัน	11.30	7.62


ในตารางที่ 14 ได้ทำการเปรียบเทียบค่าเฉลี่ยเปอร์เซ็นต์ความผิดพลาดแบบสัมบูรณ์ (MAPE) ของแบบจำลอง SARIMA และ TBATS โดยการเปรียบเทียบจะใช้ข้อมูลจำนวนนักท่องเที่ยวต่างชาติย้อนหลัง 5 ปี ในการฝึกอบรมแบบจำลอง (Training model)

เนื่องจากการฝึกอบรมแบบจำลอง (Training model) ถ้ามีจำนวนของข้อมูลทีมากจะทำให้สามารถสร้างแบบจำลองการพยากรณ์ได้ดี สามารถเปรียบเทียบได้จากความแตกต่างของ MAPE ระหว่างการฝึกอบรมแบบจำลอง (Training model) กับ การทดสอบแบบจำลอง (Testing model) (ตารางที่ 10, 11 และ 12) ซึ่งผลลัพธ์ที่ได้คือ แบบจำลอง TBATS สามารถให้ค่า MAPE ที่ดีกว่าแบบจำลอง SARIMA อยู่ 4 ประเทศ คือ ประเทศมาเลเซีย สิงคโปร์ ลาว และเยอรมัน จากการ


ทดสอบแบบจำลอง TBATS แล้ว จะเห็นได้ว่ามีประเทศที่ให้ค่า MAPE สูงสุด 3 ประเทศ (มากถึง 8 เปอร์เซ็นต์) คือ ประเทศจีน รัสเซีย และ อินเดีย

ประเทศที่น่าแบบจำลอง TBATS มาทำการทดสอบ (Testing) แล้วให้ค่า MAPE มากกว่า 8 เปอร์เซ็นต์อาจเนื่องมาจากมีรูปแบบของข้อมูลในปัจจุบันบางส่วนที่เปลี่ยนแปลงไป จึงทำให้มีโอกาสที่จะเกิดความผิดพลาดในการพยากรณ์

ในรูปที่ 25 และ 26 แสดงกราฟตัวอย่างของการเปรียบเทียบข้อมูลจำนวนนักท่องเที่ยวจริงกับข้อมูลที่ได้จากการพยากรณ์ของแบบจำลอง SARIMA และ TBATS โดยจะนำเสนอตัวอย่างของประเทศที่การพยากรณ์ของแบบจำลอง TBATS ให้ผลลัพธ์ของค่า MAPE ที่ดีกว่า ได้แก่ ประเทศ มาเลเซียและเยอรมัน




รูปที่ 25: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศมาเลเซียด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562




รูปที่ 26: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศเยอรมันด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562

ในรูปที่ 27 และ 28 แสดงกราฟตัวอย่างของการเปรียบเทียบข้อมูลจำนวนนักท่องเที่ยวจริงกับข้อมูลที่ได้จากการพยากรณ์ของแบบจำลอง SARIMA และ TBATS โดยจะนำเสนอตัวอย่างของประเทศที่การพยากรณ์ของแบบจำลอง SARIMA ให้ผลลัพธ์ของค่า MAPE ที่ดีกว่า ได้แก่ ประเทศญี่ปุ่น และ เกาหลี



รูปที่ 27: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศญี่ปุ่นด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562



รูปที่ 28: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศเกาหลีด้วยแบบจำลอง SARIMA และ TBATS เดือนพฤศจิกายน พ.ศ. 2561 ถึง ตุลาคม พ.ศ. 2562

4.2 วิธีเชิงสาเหตุ (Causal Method)

ประเทศที่ได้เลือกมาสร้างแบบจำลอง ANN มีจำนวน 3 ประเทศ คือ จีน, อินเดีย และ รัสเซีย เนื่องจากแบบจำลอง SARIMA และ TBATS ให้ค่า MAPE ในการทดสอบแบบจำลอง (Testing model) ของทั้ง 3 ประเทศมากกว่า 8 เปอร์เซ็นต์ จึงได้เลือกทั้ง 3 ประเทศมาทำการสร้างแบบจำลอง ANN และ เพิ่มเติมปัจจัยในส่วนข้อมูลอนุกรมเวลา (Time series data) ของจำนวนนักท่องเที่ยวต่างชาติแต่ละประเทศที่ถูกบันทึกไว้เป็นข้อมูลรายเดือน โดย Activation Function ที่ใช้ในการหาคำนวณค่า Output ของแบบจำลอง ANN ที่เลือกนำมาใช้ในงานวิจัยนี้ คือ ReLU function (Rectified Linear Unit) (หัวข้อที่ 2.1.2.1.2.1) และ Sigmoid function (หัวข้อที่ 2.1.2.1.2.2) ในการหาพารามิเตอร์ (Parameter) ของการฝึกอบรมแบบจำลอง (Training model) จะใช้จำนวนของ Hidden layer nodes เป็นแบบ 1 ชั้น และ 2 ชั้น ซึ่งในการคำนวณและค้นหาจำนวนของ node ที่จะนำมาใช้ในแต่ละชั้นของ Hidden layer nodes จะใช้ Library ชื่อว่า GridSearchCV ของภาษา python ในการคำนวณและค้นหาว่าจำนวนของ node ที่ดีที่สุดของการนำมาสร้างแบบจำลอง ANN นั้นว่ามีจำนวนเป็นเท่าไร เพื่อที่จะนำมาทำการทดสอบแบบจำลอง (Testing model) กับข้อมูลจริงของจำนวนนักท่องเที่ยวต่างชาติแต่ละประเทศ

ตารางที่ 15: Coefficients ของปัจจัยจากที่เลือกใช้กับแต่ละประเทศเพื่อนำมาสร้างแบบจำลอง ANN โดยการนำปัจจัยมาวิเคราะห์ค่าความ significant ด้วยวิธีการถดถอย (Regression) (ประเทศจีน)

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	4319	1581	2.73	0.008	
GDP	-0.0190	0.0222	-0.85	0.396	7.73
relative CPI	-2038	1002	-2.03	0.046	8.26
exchange rate	-342.1	78.8	-4.34	0.000	5.44
China(x1000)(1)	0.5288	0.0755	7.01	0.000	2.58
Seasonal	94.5	22.2	4.26	0.000	1.17
Anti(GV)	-104.1	38.2	-2.72	0.008	2.18
Bomb	152.1	43.5	3.50	0.001	1.16
Flood	-18.3	38.8	-0.47	0.639	1.99
King passed away	-132.1	72.5	-1.82	0.073	1.35
Boat Accident in Phuket	-84.0	67.3	-1.25	0.217	1.72

จากตารางที่ 15 จะเห็นได้ว่ามีปัจจัยที่มีค่า p-value ที่สูง ยกตัวอย่างปัจจัยรายได้ประชากรต่อหัวเฉลี่ย (GDP) มีค่า p-value คือ 0.396 และ อุทกภัย (Floods) มีค่า p-value คือ 0.639 งานวิจัยนี้จึงได้ทำการสร้างแบบจำลอง ANN ทั้ง 3 ประเทศ ได้แก่ ประเทศจีน อินเดีย และ รัสเซีย จากลักษณะของข้อมูล 2 รูปแบบกับ คือ แบบ Non-Stepwise และ Stepwise เพื่อเปรียบเทียบ

ความแตกต่างของค่า MAPE ที่ได้จากการทดสอบแบบจำลอง (Testing model) ANN จากข้อมูลทั้ง 2 รูปแบบกับทั้ง 3 ประเทศ

**หมายเหตุ: ดู Coefficients ของประเทศอินเดียและรัสเซียได้ที่บรรณานุกรม

4.2.1 Non-Stepwise

ตารางที่ 16: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศจีน (Non-Stepwise)

Analysis of Variance						Model Summary			
Source	DF	Adj SS	Adj MS	F-Value	P-Value	S	R-sq	R-sq(adj)	R-sq(pred)
Regression	10	3106312	310631	41.06	0.000	86.9743	87.07%	84.95%	82.45%
GDP	1	5516	5516	0.73	0.396				
relative CPI	1	31318	31318	4.14	0.046				
exchange rate	1	142765	142765	18.87	0.000				
China(x1000)(1)	1	371378	371378	49.09	0.000				
Seasonal	1	137007	137007	18.11	0.000				
Anti(GV)	1	56070	56070	7.41	0.008				
Bomb	1	92577	92577	12.24	0.001				
Flood	1	1682	1682	0.22	0.639				
King passed away	1	25148	25148	3.32	0.073				
Boat Accident in Phuket	1	11795	11795	1.56	0.217				
Error	61	461436	7565						
Total	71	3567748							

ตารางที่ 16 แสดงให้เห็นถึงความ significant ของปัจจัยที่เลือกมาใช้ พร้อมค่า R-sq = 87.07% และค่า R-sq (adj) = 84.95% ในการสร้างแบบจำลอง ANN ของประเทศจีน (หัวข้อที่ 3.3.3.1) ***หมายเหตุ China(x1000)(1) คือ ข้อมูลอนุกรมเวลา (Time series data) ของประเทศจีน(x1000คน)***

Regression Equation

$$\begin{aligned} \text{China}(x1000) = & 4319 - 0.0190 \text{ GDP} - 2038 \text{ relative CPI} - 342.1 \text{ exchange rate} \\ & + 0.5288 \text{ China}(x1000)(1) + 94.5 \text{ Seasonal} - 104.1 \text{ Anti}(GV) + 152.1 \text{ Bomb} \\ & - 18.3 \text{ Flood} - 132.1 \text{ King passed away} - 84.0 \text{ Boat Accident in Phuket} \end{aligned}$$

รูปที่ 29: สมการที่ได้จากการนำปัจจัยที่เลือกมาทำวิธีการถดถอย (Regression) (ประเทศจีน)

ตารางที่ 17: ค่า R-sq และ R-sq (adj) ของแต่ละประเทศที่เลือกมาสร้างแบบจำลอง ANN แบบ Non-Stepwise (จีน อินเดีย และ รัสเซีย)

ประเทศ	R-sq	R-sq (adj)
จีน	87.07%	84.95%
อินเดีย	88.15%	86.21%
รัสเซีย	88.48%	86.59%

4.2.2 Stepwise (p-value < 0.1)

ตารางที่ 18: Coefficients ของปัจจัยจากที่เลือกใช้กับประเทศจีนเพื่อมาสร้างแบบจำลอง ANN โดยการนำปัจจัยมาวิเคราะห์ค่าความ significant ด้วยวิธีการถดถอย (Regression) (Stepwise)

Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	2770	638	4.34	0.000	
relative CPI	-1146	469	-2.44	0.017	1.80
exchange rate	-266.7	48.6	-5.48	0.000	2.06
China(x1000)(1)	0.5808	0.0695	8.36	0.000	2.18
Seasonal	99.4	22.0	4.52	0.000	1.15
Anti(GV)	-82.4	36.1	-2.28	0.026	1.93
Bomb	144.7	41.7	3.47	0.001	1.06
Boat Accident in Phuket	-102.6	57.1	-1.80	0.077	1.23

**หมายเหตุ: ดู Coefficients ของปัจจัยหลังจากนำมาทำ Stepwise ของประเทศอินเดียและรัสเซียได้ที่บรรณานุกรม

ตารางที่ 19: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศจีน (Stepwise)

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	7	3080228	440033	57.77	0.000
relative CPI	1	45440	45440	5.97	0.017
exchange rate	1	229044	229044	30.07	0.000
China(x1000)(1)	1	531827	531827	69.82	0.000
Seasonal	1	155401	155401	20.40	0.000
Anti(GV)	1	39611	39611	5.20	0.026
Bomb	1	91787	91787	12.05	0.001
Boat Accident in Phuket	1	24618	24618	3.23	0.077
Error	64	487520	7617		
Total	71	3567748			

Model Summary

S	R-sq	R-sq(adj)	R-sq(pred)
87.2783	86.34%	84.84%	83.43%

ตารางที่ 19 หลังจากทำการ stepwise ที่ p-value < 0.1 แล้ว ปัจจัยที่จะเลือกไปสร้างแบบจำลอง ANN ของประเทศจีน ได้แก่ ราคาสัมพัทธ์ (relative CPI) อัตราแลกเปลี่ยนค่าเงิน (exchange rate) ข้อมูลอนุกรมเวลา (Time series data) ของประเทศจีน (China(x1000)(1)) ผลกระทบของฤดูกาล (Seasonal) การต่อต้านรัฐบาล (Anti(GV)) การลอบวางระเบิด (Bomb) และ เรือล่มที่ภูเก็ต (Boat Accident in Phuket) พร้อมค่า R-sq = 86.34% และ ค่า R-sq (adj) = 84.84%

Regression Equation

$$\text{China}(x1000) = 2770 - 1146 \text{ relative CPI} - 266.7 \text{ exchange rate} + 0.5808 \text{ China}(x1000)(1) + 99.4 \text{ Seasonal} - 82.4 \text{ Anti}(GV) + 144.7 \text{ Bomb} - 102.6 \text{ Boat Accident in Phuket}$$

รูปที่ 30: สมการจากวิธีการถดถอย (Regression) ที่ได้จากการนำปัจจัยที่เลือกมาทำ Stepwise (ประเทศจีน)

ตารางที่ 20: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศอินเดีย (Stepwise)

Analysis of Variance

Source	DF	Adj SS	Adj MS	F-Value	P-Value
Regression	6	59541.0	9923.5	75.24	0.000
GDP	1	3770.6	3770.6	28.59	0.000
relative CPI	1	468.4	468.4	3.55	0.064
India(x1000)(1)	1	389.8	389.8	2.96	0.090
Seasonal	1	2932.8	2932.8	22.24	0.000
Anti(GV)	1	1406.3	1406.3	10.66	0.002
Boat Accident in Phuket	1	1035.6	1035.6	7.85	0.007
Error	65	8573.1	131.9		
Total	71	68114.0			

Model Summary

S	R-sq	R-sq(adj)	R-sq(pred)
11.4845	87.41%	86.25%	83.80%

ตารางที่ 20 หลังจากทำการ stepwise ด้วยวิธีการถดถอย (Regression) ที่ p-value < 0.1 แล้ว ปัจจัยที่จะเลือกไปสร้างแบบจำลอง ANN ของประเทศอินเดีย ได้แก่ รายได้ประชากรต่อหัวเฉลี่ย (GDP) ราคาสัมพัทธ์ (relative CPI) ข้อมูลอนุกรมเวลาของประเทศอินเดีย (India(x1000)(1)) ผลกระทบของฤดูกาล (Seasonal) การต่อต้านรัฐบาล (Anti(GV)) และ เรือล่มที่ภูเก็ต (Boat Accident in Phuket) พร้อมค่า R-sq = 87.41% และ ค่า R-sq (adj) = 86.25%

Regression Equation

$$\text{India}(x1000) = -182.6 + 0.0933 \text{ GDP} + 79.7 \text{ relative CPI} + 0.196 \text{ India}(x1000)(1) + 14.39 \text{ Seasonal} + 12.73 \text{ Anti}(GV) - 20.89 \text{ Boat Accident in Phuket}$$

รูปที่ 31: สมการจากวิธีการถดถอย (Regression) ที่ได้จากการนำปัจจัยที่เลือกมาทำ Stepwise (ประเทศอินเดีย)

ตารางที่ 21: ANOVA (Analysis of Variance) ของปัจจัยที่เลือกมาใช้ในการสร้างแบบจำลอง ANN และ ค่า R-sq ของประเทศรัสเซีย (Stepwise)

Analysis of Variance						Model Summary			
Source	DF	Adj SS	Adj MS	F-Value	P-Value	S	R-sq	R-sq(adj)	R-sq(pred)
Regression	4	259857	64964.2	112.59	0.000	24.0206	87.05%	86.28%	85.22%
GDP	1	4068	4067.8	7.05	0.010				
Russia(x1000)(1)	1	43899	43898.5	76.08	0.000				
Seasonal	1	20041	20040.8	34.73	0.000				
King passed away	1	1903	1903.2	3.30	0.074				
Error	67	38658	577.0						
Total	71	298515							

ตารางที่ 21 หลังจากทำการ stepwise ที่ p-value < 0.1 แล้ว ปัจจัยที่จะเลือกไปสร้างแบบจำลอง ANN ของประเทศรัสเซีย ได้แก่ รายได้ประชากรต่อหัวเฉลี่ย (GDP) ข้อมูลอนุกรมเวลาของประเทศจีน (Russia(x1000)(1)), ผลกระทบของฤดูกาล (Seasonal) และ การสิ้นพระชนม์ของในหลวงรัชกาลที่ 9 (King passed away) พร้อมค่า R-sq = 87.05% และค่า R-sq (adj) = 86.28%

Regression Equation

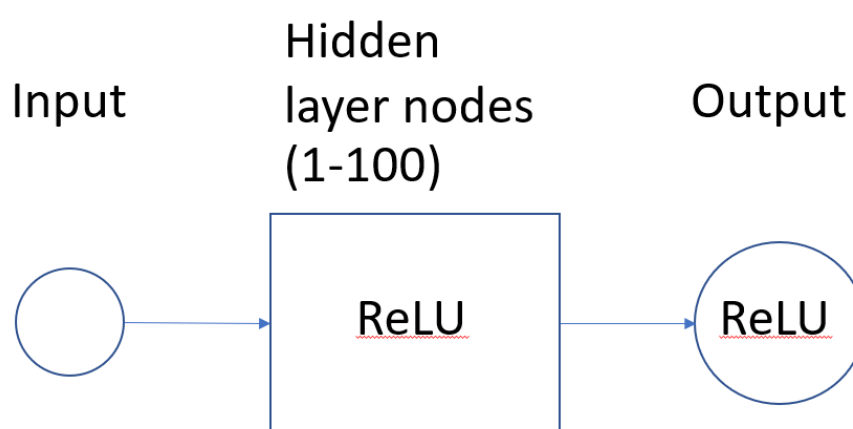
$$\text{Russia}(x1000) = -33.8 + 0.00454 \text{ GDP} + 0.6123 \text{ Russia}(x1000)(1) + 48.54 \text{ Seasonal} - 32.6 \text{ King passed away}$$

รูปที่ 32: สมการจากวิธีการถดถอย (Regression) ที่ได้จากการนำปัจจัยที่เลือกมาทำ Stepwise (ประเทศรัสเซีย)


ตารางที่ 22: ค่า R-sq และ R-sq (adj) ของแต่ละประเทศที่เลือกมาสร้างแบบจำลอง ANN แบบ Stepwise (จีน อินเดีย และ รัสเซีย)

ประเทศ	R-sq	R-sq (adj)
จีน	86.34%	84.84%
อินเดีย	87.41%	86.25%
รัสเซีย	87.05%	86.28%

4.2.3 ReLU function



รูปที่ 33: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ ReLU function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 1 ชั้น



รูปที่ 34: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ ReLU function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 2 ชั้น

ตารางที่ 23: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ ReLU function เป็น Activation function

ประเทศ	Hidden layer nodes			
	1 ชั้น (1-100)	MAPE (Testing)	2 ชั้น (1-100)(1-100)	MAPE (Testing)
จีน	52	12.07	(68, 45)	6.64
อินเดีย	3	19.53	(9, 10)	16.45
รัสเซีย	18	17.07	(12, 22)	13.76

ตารางที่ 23 แสดงถึงจำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ ค่า MAPE ที่ได้จากการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ ReLU function เป็น Activation function จะเห็นได้ว่าทั้ง 3 ประเทศที่จำนวนของ hidden layer nodes เป็น 2 ชั้น จะให้ค่า MAPE ที่ดีกว่าที่เป็น 1 ชั้น

ตารางที่ 24: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ ReLU function เป็น Activation function (Stepwise)

ประเทศ	Hidden layer nodes			
	1 ชั้น (1-100)	MAPE (Testing)	2 ชั้น (1-100)(1-100)	MAPE (Testing)
จีน	13	12.98	(19, 11)	10.86
อินเดีย	5	21.29	(3, 35)	17.26
รัสเซีย	3	14.35	(5, 3)	13.14

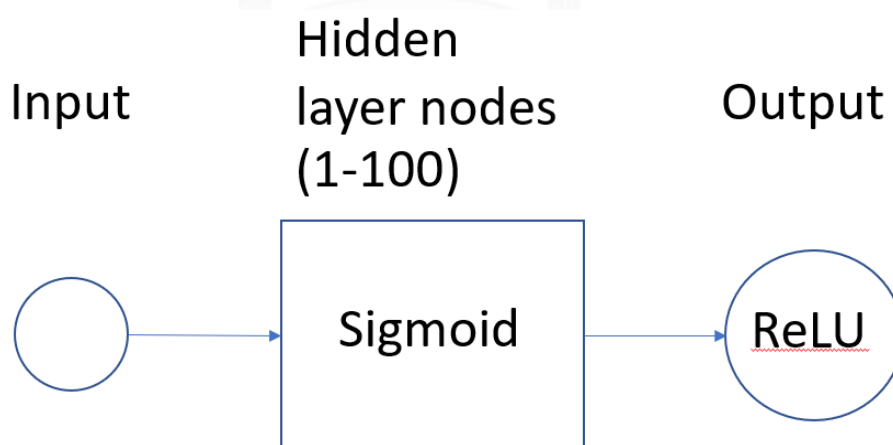
ตารางที่ 24 แสดงถึงจำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ ค่า MAPE ที่ได้จากการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ ReLU function เป็น Activation function และ ทำการ Stepwise จะเห็นได้ว่าทั้ง 3 ประเทศที่จำนวนของ hidden layer nodes เป็น 2 ชั้น จะให้ค่า MAPE ที่ดีกว่าที่เป็น 1 ชั้น

ตารางที่ 25: เปรียบเทียบค่า MAPE ระหว่างข้อมูลปัจจัยที่ Non-Stepwise และ Stepwise ในแต่ละจำนวนชั้นของ Hidden layer nodes (ReLU function) ของการทดสอบแบบจำลอง (Testing model) ANN

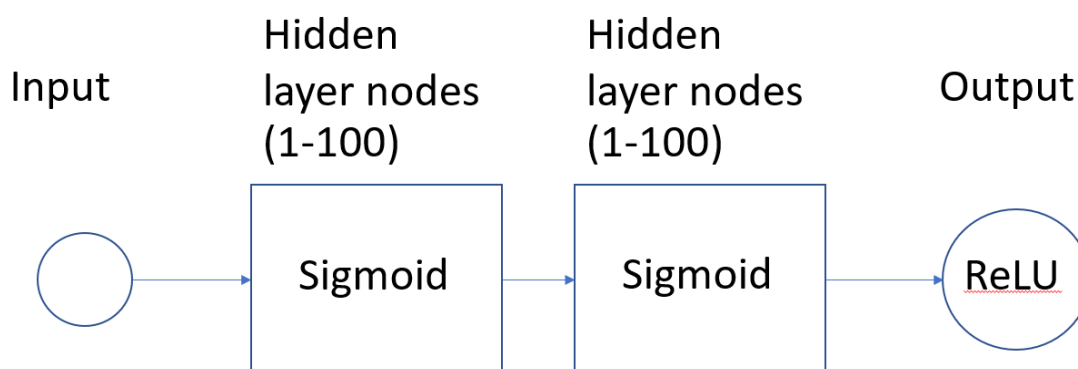
ประเทศ	Hidden layer nodes							
	MAPE(Testing)							
	Non-Stepwise				Stepwise			
	1 ชั้น		2 ชั้น		1 ชั้น		2 ชั้น	
จีน	52	12.07	(68, 45)	6.64	13	12.98	(19, 11)	10.86
อินเดีย	3	19.53	(9, 10)	16.45	5	21.29	(3, 35)	17.26
รัสเซีย	18	17.07	(12, 22)	13.76	3	14.35	(5, 3)	13.14

ตารางที่ 25 แสดงการเปรียบเทียบค่า MAPE การทดสอบแบบจำลอง (Testing model) ANN ระหว่างปัจจัยที่ทำการ Stepwise และ Non-stepwise ในแต่ละประเทศ โดยประเทศที่ทำการ Stepwise ที่จำนวนของ hidden layer nodes เป็น 1 ชั้น และ 2 ชั้น แล้วให้ค่า MAPE ที่ได้ดีกว่า ได้แก่ ประเทศรัสเซีย ทั้งนี้จะเห็นได้ว่าค่า MAPE ของการทำ Stepwise หรือ Non-stepwise ทั้งในแบบที่จำนวนของ hidden layer nodes เป็น 1 ชั้น หรือ 2 ชั้น แต่ละประเทศจะมีค่าต่างกันไม่มากนัก เว้นแต่ประเทศรัสเซียของ 1 ชั้น และ ประเทศจีนของ 2 ชั้น ที่มีค่าแตกต่างกันมากอย่างเห็นได้ชัด แต่ในงานวิจัยนี้จะให้ความสำคัญกับค่า MAPE ในแบบของ Non-stepwise

4.2.4 Sigmoid function



รูปที่ 35: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ Sigmoid function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 1 ชั้น



รูปที่ 36: ลักษณะของการฝึกอบรมแบบจำลอง (Training model) ANN โดยใช้ Sigmoid function เป็น Activation function แบบที่จำนวนชั้นของ Hidden layer nodes เป็น 2 ชั้น

ตารางที่ 26: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ Sigmoid function เป็น Activation function

ประเทศ	Hidden layer nodes			
	1 ชั้น (1-100)	MAPE (Testing)	2 ชั้น (1-100)(1-100)	MAPE (Testing)
จีน	72	12.23	(9, 100)	13.04
อินเดีย	11	21.35	(8, 100)	17.86
รัสเซีย	9	16.41	(19, 28)	16.64

ตารางที่ 26 แสดงถึงจำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ ค่า MAPE ที่ได้จากการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ Sigmoid function เป็น Activation function จะเห็นได้ว่าประเทศที่จำนวนของ hidden layer nodes ที่เป็น 1 ชั้น จะให้ค่า MAPE ที่ดีกว่า ได้แก่ ประเทศจีน และ รัสเซีย ในส่วนที่เป็น 2 ชั้น ได้แก่ ประเทศอินเดีย

ตารางที่ 27: จำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ MAPE ของแต่ละประเทศที่ทำการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ Sigmoid function เป็น Activation function (Stepwise))

ประเทศ	Hidden layer nodes			
	1 ชั้น (1-100)	MAPE (Testing)	2 ชั้น (1-100)(1-100)	MAPE (Testing)
จีน	97	14.34	(5, 100)	11.25
อินเดีย	73	23.55	(15, 97)	17.73
รัสเซีย	81	14.60	(18, 21)	13.25

ตารางที่ 27 แสดงถึงจำนวนของ node ในแต่ละชั้นของ hidden layer nodes และ ค่า MAPE ที่ได้จากการทดสอบแบบจำลอง (Testing model) ANN โดยใช้ Sigmoid function เป็น Activation function และ ทำการ Stepwise จะเห็นได้ว่าทั้ง 3 ประเทศที่ hidden layer nodes เป็น 2 ชั้น จะให้ค่า MAPE ที่ดีกว่าที่เป็น 1 ชั้น

ตารางที่ 28: เปรียบเทียบค่า MAPE ระหว่างข้อมูลปัจจัยที่ Non-Stepwise และ Stepwise ในแต่ละจำนวนชั้นของ Hidden layer nodes (Sigmoid function) ของการทดสอบแบบจำลอง (Testing model) ANN

ประเทศ	Hidden layer nodes							
	MAPE(Testing)							
	Non-Stepwise				Stepwise			
	1 ชั้น	2 ชั้น	1 ชั้น	2 ชั้น	1 ชั้น	2 ชั้น	1 ชั้น	2 ชั้น
จีน	72	12.23	(9, 100)	13.04	97	14.34	(5, 100)	11.25
อินเดีย	11	21.35	(8, 100)	17.86	73	23.55	(15, 97)	17.73
รัสเซีย	9	16.41	(19, 28)	16.64	81	14.60	(18, 21)	13.25

ตารางที่ 28 แสดงการเปรียบเทียบค่า MAPE การทดสอบแบบจำลอง (Testing model) ANN ระหว่างปัจจัยที่ทำการ Stepwise และ Non-stepwise ในแต่ละประเทศ โดยประเทศที่ข้อมูลปัจจัยทำการ Stepwise ที่จำนวนของ hidden layer nodes เป็น 1 ชั้น แล้วค่า MAPE ที่ได้ดีกว่า ได้แก่ ประเทศรัสเซีย ในส่วนของประเทศที่ทำการ Stepwise ที่จำนวนของ hidden layer nodes เป็น 2 ชั้น แล้วทุกประเทศได้ค่า MAPE ที่ได้ดีกว่า ทั้งนี้จะเห็นได้ว่าค่า MAPE ของการทำ Stepwise

หรือ Non-stepwise ทั้งในแบบที่จำนวนของ hidden layer nodes เป็น 1 ชั้น หรือ 2 ชั้น แต่ละประเทศจะมีค่าต่างกันไม่มาก ยกเว้นประเทศรัสเซียของแบบ 1 ชั้น และ 2 ชั้น ที่มีค่าแตกต่างกันมากอย่างเห็นได้ชัด แต่ในงานวิจัยนี้จะให้ความสำคัญค่า MAPE ในแบบ Non-stepwise

จากตารางที่ 25 และ ตารางที่ 28 ค่า MAPE จาก ReLU function และ Sigmoid function มีความแตกต่างกันไม่มาก แต่เวลาในการ Training model แตกต่างกันอย่างพอสมควร

ตารางที่ 29: เปรียบเทียบเวลาที่ใช้ในการฝึกอบรมแบบจำลอง (Training model) ANN ของประเทศจีนโดยเฉลี่ย จากการใช้ ReLU function และ Sigmoid function เป็น Activation function

Activation function	Hidden layer nodes	
	1 ชั้น (วินาที)	2 ชั้น (วินาที)
ReLU	0.50	1.40
Sigmoid	25.42	17.96

ตารางที่ 29 แสดงการเปรียบเทียบเวลาที่ใช้ในการฝึกอบรมแบบจำลอง (Training model) ANN โดยเฉลี่ย ระหว่างการใช้ ReLU function และ Sigmoid function เป็น Activation function ที่จำนวนชั้นของ Hidden layer nodes แบบที่เป็น 1 ชั้น และ 2 ชั้น จะเห็นได้ว่าเวลาที่ใช้ในการฝึกอบรมแบบจำลอง (Training model) ANN ของ ReLU function น้อยกว่า Sigmoid function งานวิจัยนี้จึงได้จะให้ความสนใจที่ ReLU function เป็นสำคัญ

4.2.5 การเปรียบเทียบแบบจำลองและการเลือกแบบจำลอง

ในส่วนนี้จะทำการเปรียบเทียบแบบจำลอง SARIMA, TBATS และ ANN โดยใช้ค่า Absolute Percentage forecasting Error values (APE) เพื่อนำมาทำ RCBD (Randomized Complete Block Designs) แสดงในตารางที่ 30 และ Turkey method ที่ค่าของความเชื่อมั่น 95 เปอร์เซ็นต์ (95% confidence interval) แสดงในตารางที่ 31 และ ตารางที่ 32

ตารางที่ 30: ค่า Absolute Percentage forecasting Error values (APE) ของประเทศไทย

ประเทศไทย	Absolute Percentage forecasting Error values		
	SARIMA	TBATS	ANN(68, 45)
พ.ย. 61	8.42	1.64	7.78
ธ.ค. 61	18.83	21.04	3.16
ม.ค. 62	14.29	22.68	7.16
ก.พ. 62	5.89	13.78	6.37
มี.ค. 62	8.58	15.92	11.03
เม.ย. 62	3.02	10.61	8.02
พ.ค. 62	2.87	4.55	12.48
มิ.ย. 62	0.31	14.16	8.28
ก.ค. 62	5.09	13.26	5.04
ส.ค. 62	10.51	16.99	3.84
ก.ย. 62	17.59	21.18	3.57
ต.ค. 62	12.52	21.99	2.98

ตารางที่ 31: จัดกลุ่มโดยใช้ Tukey Method ค่าของความเชื่อมั่น 95 เปอร์เซ็นต์ (95% confidence interval)

Grouping Information Using the Tukey Method and 95% Confidence


Method	N	Mean	Grouping
TBATS	12	14.82	A
SARIMA	12	8.99	B
ANN(68, 45)	12	6.642	B

ตารางที่ 32: หาความแตกต่างของแต่ละแบบจำลองด้วยวิธี Tukey (Tukey Simultaneous Tests for Differences of Means)

Tukey Simultaneous Tests for Differences of Means

Difference of Levels	Difference of Means	SE of Difference	95% CI	T-Value	Adjusted P-Value
SARIMA - ANN(68, 45)	2.35	2.24	(-3.14, 7.84)	1.05	0.551
TBATS - ANN(68, 45)	8.17	2.24	(2.68, 13.66)	3.65	0.003
TBATS - SARIMA	5.83	2.24	(0.34, 11.32)	2.60	0.036

จากรูปที่ 37 จะเป็นกราฟแสดงการเปรียบเทียบความแตกต่างของแต่ละแบบจำลองด้วยค่าความต่างของค่าเฉลี่ยที่ค่าของความเชื่อมั่น 95 เปอร์เซ็นต์ (95% confidence interval) โดยวิธีดูว่าแตกต่างกันอย่างมีนัยสำคัญหรือไม่ดูได้จากเส้นประ หากส่วนของกราฟของค่าความแตกต่างของค่าเฉลี่ยสัมผัสกับเส้นประแสดงว่าแบบจำลองทั้งสองแบบจำลองนั้นไม่แตกต่างกันอย่างมีนัยสำคัญ จะเห็นได้ว่าสำหรับประเทศจีนแบบจำลอง SARIMA เทียบกับแบบจำลอง ANN(68, 45) ไม่แตกต่างกันอย่างมีนัยสำคัญ แบบจำลอง TBATS เทียบกับแบบจำลอง ANN(68, 45) แตกต่างกันอย่างมีนัยสำคัญ สุดท้ายแบบจำลอง TBATS เทียบกับแบบจำลอง SARIMA แตกต่างกันอย่างมีนัยสำคัญ ในกรณีของการเลือกแบบจำลองที่ไม่แตกต่างกันอย่างมีนัยสำคัญให้เลือกแบบจำลองที่มีความง่ายในการใช้งานและการความเข้าใจ เช่น แบบจำลอง SARIMA และ แบบจำลอง ANN(68, 45) ไม่แตกต่างกันอย่างมีนัยสำคัญ ทางผู้วิจัยจึงแนะนำให้เลือกใช้แบบจำลอง SARIMA แต่ถ้าแตกต่างกันอย่างมีนัยสำคัญเช่นแบบจำลอง TBATS เทียบกับ แบบจำลอง ANN(68, 45) ทางผู้วิจัยแนะนำแบบจำลอง ANN(68, 45) เนื่องจากให้ค่า MAPE ที่ดีกว่า (ตารางที่ 33)



รูปที่ 37: เปรียบแบบจำลองแบบ Tukey Simultaneous 95% CIs

**หมายเหตุ: ดู Tukey Simultaneous 95% CIs ของประเทศอินเดียและรัสเซียได้ที่บรรณานุกรม

ตารางที่ 33: เปรียบเทียบ MAPE ที่มาจากการทดสอบแบบจำลอง (Testing model) กับข้อมูลจริงของแบบจำลอง SARIMA, TBATS และ ANN

ประเทศ	แบบจำลอง (MAPE)		
	SARIMA	TBATS	ANN
จีน	8.99*	14.82	7.47** (68, 45)
อินเดีย	16.35**	23.67	17.34* (9, 10)
รัสเซีย	11.31**	12.04*	13.76 (12, 22)

**หมายเหตุ 1: ตัวเลขใน () หมายถึง จำนวนของ node ใน hidden layer nodes แต่ละชั้น

**หมายเหตุ 2: ค่า MAPE ที่มีสัญลักษณ์ ** และ * อยู่ หมายถึง ค่านั้นมีความถูกต้องของการพยากรณ์สูงสุด และ รองลงมาตามลำดับ

**หมายเหตุ 3:

SARIMA: Seasonal Autoregressive integrated moving average

TBATS: Trigonometric Seasonal, Box-Cox Transformation, ARMA residuals, Trend and Seasonality

ANN: Artificial Neural Network

จากตารางที่ 33 ประเทศที่แบบจำลอง ANN สามารถให้ค่า MAPE ที่ดีกว่า คือ ประเทศจีน

ตารางที่ 34: การแนะนำการเลือกแบบจำลอง SARIMA, TBATS และ ANN จากการวิเคราะห์ของ Tukey Simultaneous 95% CIs ของทุกประเทศ


ประเทศ	แบบจำลอง		
	SARIMA	TBATS	ANN
จีน	**		*
อินเดีย	**		*
รัสเซีย	**	*	

**หมายเหตุ : ในช่องที่มีสัญลักษณ์ ** อยู่ หมายถึง แบบจำลองการพยากรณ์นั้นถูกแนะนำให้เลือกใช้ก่อน และ สัญลักษณ์ * คือ แนะนำถัดไป


จากตาราง 34 แสดงการแนะนำการเลือกใช้แบบจำลองการพยากรณ์ที่ได้จากการวิเคราะห์ด้วย Tukey Simultaneous 95% CIs ของทุกประเทศ ในทางสถิติจะแนะนำให้ทำ SARIMA กับทั้ง 3 ประเทศ เนื่องจากผลต่างของค่าเฉลี่ย Absolute Percentage forecasting Error values (APE) หลังจากทำการวิเคราะห์ด้วย Tukey Simultaneous tests 95% CIs ไม่แตกต่างกันมีนัยสำคัญ จึงแนะนำให้ใช้วิธีที่ง่ายต่อการทำความเข้าใจและใช้งาน

อย่างไรก็ดีจากการทดสอบแบบจำลอง SARIMA, TBATS และ ANN แล้วประเทศที่แบบจำลอง ANN สามารถให้ค่า MAPE ที่ดีกว่า คือ ประเทศจีน ประเทศที่ TBATS สามารถให้ค่า MAPE ที่ดีกว่า คือ ประเทศมาเลเซีย สิงคโปร์ ลาว และ เยอรมัน ในส่วนของประเทศที่ SARIMA สามารถให้ค่า MAPE ที่ดีกว่า คือ ประเทศเกาหลี เกาหลี ญี่ปุ่น รัสเซีย อังกฤษ และ สหรัฐอเมริกา


จากรูปที่ 38 ถึง รูปที่ 40 จะเป็นกราฟเปรียบเทียบระหว่างข้อมูลจำนวนนักท่องเที่ยวต่างชาติแต่ละประเทศที่เป็นข้อมูลจริงกับข้อมูลที่ได้จากการพยากรณ์ของแบบจำลอง SARIMA, TBATS และ ANN ของประเทศจีน อินเดีย และ รัสเซีย ที่ได้เลือกนำมาสร้างแบบจำลอง ANN เนื่องจากแบบจำลอง SARIMA และ TBATS ให้ค่า MAPE ของทั้ง 3 ประเทศ สูงกว่า 8 เปอร์เซ็นต์ (ตารางที่ 14)



รูปที่ 38: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศจีนด้วยแบบจำลอง SARIMA, TBATS และ ANN



รูปที่ 39: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศไทยด้วยแบบจำลอง SARIMA, TBATS และ ANN




รูปที่ 40: เปรียบเทียบข้อมูลจริงกับค่าพยากรณ์ของประเทศไทยด้วยแบบจำลอง SARIMA, TBATS และ ANN

บทที่ 5 บทสรุปงานวิจัยและข้อเสนอแนะ


5.1 สรุปผลงานวิจัย

งานวิจัยนี้ได้ทำการเปรียบเทียบและนำเสนอแบบจำลองการพยากรณ์ทั้งในรูปแบบของข้อมูลที่เป็นอนุกรมเวลา (Time series method) และ ข้อมูลที่เป็นเชิงสาเหตุ (Causal method) เพื่อเป็นทางเลือกในการใช้งานวิธีการดังกล่าวกับประเทศที่เหมาะสม ช่วยให้ผู้สามารถพยากรณ์จำนวนนักท่องเที่ยวต่างชาติที่เดินทางเข้ามาท่องเที่ยวของแต่ละประเทศที่มีความสำคัญต่ออุตสาหกรรมการท่องเที่ยวของประเทศไทยได้อย่างถูกต้องแม่นยำ

หลังจากที่ได้ผลลัพธ์บทสรุปของการทดสอบแบบจำลอง SARIMA และ TBATS ที่เป็นแบบจำลองการพยากรณ์จำพวกอนุกรมเวลา (Time series method) กับข้อมูลจำนวนนักท่องเที่ยวจริงของแต่ละประเทศ ซึ่งประเทศที่แบบจำลอง TBATS สามารถให้ค่า MAPE ที่ดีกว่า คือ ประเทศมาเลเซีย สิงคโปร์ ลาว และ เยอรมัน โดยแต่ละประเทศที่แบบจำลอง TBATS ให้ค่า MAPE สูงกว่า 8 เปอร์เซ็นต์ คือ ประเทศจีน อินเดีย และ รัสเซีย (ตารางที่ 14) จะนำมาสร้างแบบจำลอง ANN โดยมีปัจจัยที่เกี่ยวข้องซึ่งประยุกต์มาจากงานวิจัยอุตสาหกรรมการท่องเที่ยว (Hwandee & Phumchusri, 2020) ได้แก่ รายได้ในรูปของ Gross Domestic Product (GDP) ต่อหัว ราคาสัมพัทธ์ (relative price) อัตราแลกเปลี่ยนค่าเงิน (exchange rate) ตัวแปรจำลองผลกระทบของการเกิดฤดูกาล (dummy variable of seasonal effect) ตัวแปรจำลองผลกระทบของการเกิดข่าวไม่ดีภายในประเทศ (dummy variable of news shock effect) และ ในงานวิจัยนี้ได้เพิ่มข้อมูลอนุกรมเวลา (Time series data) ของประเทศที่ได้ทำการสร้างแบบจำลอง ANN เป็นปัจจัยเพิ่มเติมจากผลงานวิจัยการพยากรณ์ยอดจองห้องพักของโรงแรมแห่งหนึ่ง (Phumchusri & Ungtrakul, 2020) ซึ่งในงานวิจัยนี้ได้ทำการสร้างแบบจำลอง ANN โดยใช้ Activation function 2 แบบ คือ ReLU function (Rectified Linear Unit function) และ Sigmoid function เป็นเครื่องมือในการคำนวณหาค่า Output ในแต่จำนวนชั้นของ Hidden layer nodes เพื่อให้ได้ค่าของข้อมูลจากการพยากรณ์ของแบบจำลอง ANN แต่ในงานวิจัยนี้จะให้ความสำคัญกับ ReLU function เนื่องจากสามารถทำความเข้าใจในการใช้งานได้ง่ายกว่าและใช้เวลาในการฝึกอบรมแบบจำลอง (Training model) น้อยกว่า Sigmoid function โดยประเทศที่หลังจากสร้างแบบจำลอง ANN แล้ว ค่า MAPE ดีขึ้น คือ ประเทศจีน (ประเทศอินเดียและรัสเซียใกล้เคียงกับค่า MAPE เดิม)



รูปที่ 41: ตัวอย่างข้อมูลอนุกรมเวลา (Time series data) ของประเทศไทยเดือน พฤศจิกายน ปี พ.ศ. 2560 ถึง เดือนตุลาคมปี พ.ศ. 2562



รูปที่ 42: ตัวอย่างข้อมูลอนุกรมเวลา (Time series data) ของประเทศไทยเดือน พฤศจิกายน ปี พ.ศ. 2556 ถึง เดือนตุลาคมปี พ.ศ. 2562

จากรูปที่ 41 จำนวนของนักท่องเที่ยวจากประเทศไทยในช่วงปี พ.ศ. 2561 กับ พ.ศ. 2562 มีความแตกต่างกันมากถึง 24.85% (ตารางที่ 8) อาจส่งผลให้การพยากรณ์มีความผิดพลาดสูง ในส่วนของรูปที่ 42 จะเป็นรูปแบบของข้อมูลอนุกรมเวลา (Time series data) ของประเทศไทย จะเห็นได้ว่าในปี พ.ศ. 2561 กับ พ.ศ. 2562 มีความใกล้เคียงกัน แต่ในปี พ.ศ. 2556 ถึง ปี พ.ศ. 2559 จะมีแนวโน้ม (Trend) ของจำนวนนักท่องเที่ยวลดลงอย่างต่อเนื่องและมีลักษณะของฤดูกาล (Seasonal) ของการท่องเที่ยวที่แตกต่างกัน จึงอาจส่งผลให้การพยากรณ์ของแบบจำลองมีความผิดพลาด

อย่างไรก็ดีงานวิจัยนี้ได้ทำการเปรียบเทียบแบบจำลองการพยากรณ์ SARIMA, TBATS และ ANN ว่าด้วยเรื่องของการเปรียบเทียบค่า MAPE ที่จะทำให้เห็นว่าในแต่ละแบบจำลองการพยากรณ์สามารถพยากรณ์ได้ถูกต้องแม่นยำแตกต่างกันมากหรือไม่ และได้ทำการเปรียบเทียบแบบจำลองโดยใช้วิธีในทางสถิติด้วยวิธี RCBD (Randomized Complete Block Designs) และ Turkey method ที่ค่าของความเชื่อมั่น 95 เปอร์เซ็นต์ (95% confidence interval) เพื่อวิเคราะห์หาค่า Absolute Percentage forecasting Error values (APE) ของข้อมูลจำนวนนักท่องเที่ยวจริงในแต่ละประเทศเทียบกับข้อมูลที่ใช้แบบจำลองพยากรณ์ของแต่ละแบบจำลองว่ามีความแตกต่างกันอย่างมีนัยสำคัญหรือไม่ เพื่อแนะนำแบบจำลองการพยากรณ์ที่สามารถทำความเข้าใจและใช้งานได้ง่ายกว่า

5.2 ข้อจำกัดที่เกิดขึ้นในการสร้างแบบจำลอง ANN

ข้อมูลปัจจัยและข้อมูลอนุกรมเวลา (Time series data) ของงานวิจัยนี้ถูกจำกัดด้วยข้อมูลรายเดือนของจำนวนนักท่องเที่ยวต่างชาติที่เดินทางเข้ามาที่ประเทศไทย ณ ปัจจุบันสามารถหาข้อมูลจำนวนนักท่องเที่ยวต่างชาติรายเดือนย้อนหลังได้เก่าที่สุดที่ ปี พ.ศ. 2556 (รายปี พ.ศ. 2545) จึงทำให้มีจำนวนข้อมูลที่ใช้ในการเรียนรู้ค่อนข้างน้อย อาจส่งผลให้แบบจำลอง ANN ไม่สามารถทำการเรียนรู้และความสามารถในการพยากรณ์ได้ดังที่ควรจะเป็น

เนื่องจากสถานการณ์ของ Covid-19 จึงไม่สามารถนำข้อมูลในช่วงตั้งแต่เดือนพฤศจิกายนปี พ.ศ. 2562 จนถึงวันปัจจุบันมาใช้กับแบบจำลองได้ ส่งผลให้ในงานวิจัยนี้จำเป็นต้องแบ่งข้อมูลเป็น 2 ส่วน ดังที่กล่าวในขั้นตอนการแบ่งข้อมูล

5.3 แนวทางการต่อยอดงานวิจัยในอนาคตของการพัฒนาแบบจำลอง ANN

- ทดลองใช้ Activation function อื่น ของแบบจำลอง ANN เนื่องจาก ณ เวลาที่ทำงานวิจัยนี้ได้มี ReLU function ที่สามารถนำมาช่วยในการ Training ANN model ได้ดี ซึ่งในอนาคตอาจจะมี Activation function อื่นที่สามารถให้ผลลัพธ์ที่ดีกว่าได้
- ทดลองกับจำนวน node ที่มีจำนวนมากกว่า 100 ของ hidden layer nodes ในงานวิจัยนี้ได้ทดลองจำนวน node ที่ 1-100 ซึ่งหากมีการเพิ่มจำนวนขอบเขตของ node ให้มากยิ่งขึ้น อาจส่งผลให้ แบบจำลอง ANN สามารถทำการคำนวณหรือค้นหาตัว Training model ที่ดียิ่งขึ้นได้
- ค้นหาปัจจัยที่มีผลอื่น ๆ เพื่อเพิ่มการเรียนรู้ให้กับแบบจำลอง ANN ที่อาจจะส่งผลให้แบบจำลอง ANN สามารถเรียนรู้ได้ดีขึ้นและพยากรณ์ได้ถูกต้องแม่นยำยิ่งขึ้นในอนาคต
- เนื่องจากมีข้อจำกัดของจำนวนข้อมูลจึงจำเป็นต้องแบ่งข้อมูลเป็น 2 ส่วน คือ ข้อมูล 80% เป็นข้อมูลในการเรียนรู้ (Training) และ 20% เป็นข้อมูลในการทดสอบ (Testing) อย่างไรก็ตามหากมีจำนวนของข้อมูลเพิ่มขึ้นควรทำการแบ่งข้อมูลออกเป็น 3 ส่วน โดยอาจจะเลือก

70% เป็นข้อมูลในการเรียนรู้ (Training) 20% เป็นข้อมูลในการตรวจสอบความถูกต้อง (Validating) และ 10% สุดท้ายควรเป็นข้อมูลใหม่ที่แบบจำลองไม่เคยได้เรียนรู้มาก่อน ไว้ใช้สำหรับทดสอบ (Testing) เพื่อให้สามารถบอกได้ว่าแบบจำลองของเรามีความถูกต้องแม่นยำและเหมาะสม

5.4 แนวทางการนำแบบจำลองไปใช้ในอนาคต

งานวิจัยนี้ได้เปรียบเทียบและนำเสนอแบบจำลองการพยากรณ์ทั้ง 2 รูปแบบ คือ แบบของอนุกรมเวลา (Time series method) และ แบบของเชิงสาเหตุ (Causal method) โดยการนำแบบจำลองในแต่ละรูปแบบไปใช้งานหรือใช้ในการศึกษาในอนาคตจำเป็นต้องดูว่าในเรื่องของความผิดพลาดที่เกิดจากการพยากรณ์เทียบจากค่า Mean absolute Percentage Error (MAPE) ในงานวิจัยนี้ว่าเพิ่มขึ้นหรือไม่ หากเพิ่มขึ้นควรทำการหาพารามิเตอร์ (Parameter) ชุดใหม่ของแบบจำลองที่จะเลือกนำไปใช้ตามขั้นตอนการสร้างแบบจำลองที่งานวิจัยนี้ได้เขียนขั้นตอนอธิบายไว้ เนื่องจากการมีข้อมูลชุดใหม่ที่แบบจำลองไม่เคยได้เรียนรู้ อาจส่งผลให้การพยากรณ์ของแบบจำลองที่ใช้พารามิเตอร์เดิมในการเรียนรู้นั้นไม่สามารถพยากรณ์ได้อย่างเต็มประสิทธิภาพ จึงแนะนำให้พิจารณาเรื่องดังกล่าวก่อนที่จะนำแบบจำลองที่งานวิจัยนี้ได้ทำการสรุปของแต่ละประเทศไปใช้งานหรือศึกษาต่อในอนาคต เพื่อความถูกต้องแม่นยำและเหมาะสมของการเลือกใช้แบบจำลองการพยากรณ์

บรรณานุกรม

- Agostinelli, F., Hoffman, M., Sadowski, P., & Baldi, P. (2014). Learning activation functions to improve deep neural networks. *arXiv preprint arXiv:1412.6830*.
- Baldigara, T. (2013). Forecasting Tourism Demand in Croatia: A Comparison of Different Extrapolative Methods. *Journal of Business Administration Research, 2*(1), 84.
- Box, G. E., Jenkins, G. M., & Reinsel, G. C. (2011). *Time series analysis: forecasting and control* (Vol. 734): John Wiley & Sons.
- BROŻYNA, J., Mentel, G., Szetela, B., & Strielkowski, W. (2018). MULTI-SEASONALITY IN THE TBATS MODEL USING DEMAND FOR ELECTRIC ENERGY AS A CASE STUDY. *Economic Computation & Economic Cybernetics Studies & Research, 52*(1).
- Chinnakum, W., & Boonyasana, P. (2016). Forecasting International Tourism Demand in Thailand. *Thai Journal of Mathematics, 231-244*.
- De Livera, A. M. (2010). *Modeling time series with complex seasonal patterns using exponential smoothing*. Monash University,
- De Livera, A. M., Hyndman, R. J., & Snyder, R. D. (2011). Forecasting time series with complex seasonal patterns using exponential smoothing. *Journal of the American statistical association, 106*(496), 1513-1527.
- Hao, J., Var, T., & Chon, J. (2003). A forecasting model of tourist arrivals from major markets to Thailand. *Tourism Analysis, 8*(1), 33-45.
- Hwandee, O., & Phumchusri, N. (2020). Forecasting International Tourist Arrivals from Major Countries to Thailand. In *Advances in Electronics Engineering* (pp. 115-125): Springer.
- Kingma, D. P., & Ba, J. (2014). Adam: A method for stochastic optimization.

arXiv preprint arXiv:1412.6980.

- Klimberg, R. K., Sillup, G. P., Boyle, K. J., & Tavva, V. (2010). Forecasting performance measures—What are their practical meaning? *Advances in business and management forecasting*, 7, 137-147.
- Law, R., & Au, N. (1999). A neural network model to forecast Japanese demand for travel to Hong Kong. *Tourism Management*, 20(1), 89-97.
- Lin, C.-J., & Lee, T.-S. (2013). Tourism demand forecasting: Econometric model based on multivariate adaptive regression splines, artificial neural network and support vector regression. *Advances in Management and Applied Economics*, 3(6), 1.
- Mamula, M. (2015). Modelling and forecasting international tourism demand-evaluation of forecasting performance. *International Journal of Business Administration*, 6(3), 102.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, 5(4), 115-133.
- Phumchusri, N., & Ungtrakul, P. (2020). Hotel daily demand forecasting for high-frequency and complex seasonality data: a case study in Thailand. *Journal of Revenue and Pricing Management*, 19(1), 8-25.
- Sibi, P., Jones, S. A., & Siddarth, P. (2013). Analysis of different activation functions using back propagation neural networks. *Journal of theoretical and applied information technology*, 47(3), 1264-1268.
- Song, H., Witt, S. F., & Li, G. (2003). Modelling and forecasting the demand for Thai tourism. *Tourism Economics*, 9(4), 363-387.
- Sookmark, S. (2011). An analysis of international tourism demand in Thailand.

ข้อมูลอนุกรมเวลาประเทศไทย

ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	323.22
	ธันวาคม	265.43
2557	มกราคม	357.03
	กุมภาพันธ์	360.02
	มีนาคม	319.88
	เมษายน	332.82
	พฤษภาคม	302.82
	มิถุนายน	220.50
	กรกฎาคม	360.23
	สิงหาคม	449.67
	กันยายน	424.46
	ตุลาคม	500.67
	พฤศจิกายน	512.86
	ธันวาคม	495.34
2558	มกราคม	561.92
	กุมภาพันธ์	780.55
	มีนาคม	663.57
	เมษายน	701.17
	พฤษภาคม	668.08
	มิถุนายน	632.89
	กรกฎาคม	775.90
	สิงหาคม	800.60
	กันยายน	532.70
	ตุลาคม	566.16
	พฤศจิกายน	615.41
	ธันวาคม	637.86
2559	มกราคม	814.69
	กุมภาพันธ์	958.20
	มีนาคม	856.68
	เมษายน	816.03
	พฤษภาคม	738.60
	มิถุนายน	715.41
	กรกฎาคม	865.36
	สิงหาคม	891.38
	กันยายน	658.90
	ตุลาคม	474.36
	พฤศจิกายน	432.47
	ธันวาคม	535.57
2560	มกราคม	859.62
	กุมภาพันธ์	790.05
	มีนาคม	789.41
	เมษายน	748.09
	พฤษภาคม	762.18
	มิถุนายน	762.50
	กรกฎาคม	937.90
	สิงหาคม	983.21
	กันยายน	760.97
	ตุลาคม	805.57
	พฤศจิกายน	790.75
	ธันวาคม	815.49
2561	มกราคม	970.00
	กุมภาพันธ์	1198.971
	มีนาคม	1004.025
	เมษายน	986.703
	พฤษภาคม	869.206
	มิถุนายน	900.652
	กรกฎาคม	929.738
	สิงหาคม	867.481
	กันยายน	647.664
	ตุลาคม	646.141
	พฤศจิกายน	675.129
	ธันวาคม	838.634
2562	มกราคม	1069.787
	กุมภาพันธ์	1064.806
	มีนาคม	985.232
	เมษายน	898.994
	พฤษภาคม	794.913
	มิถุนายน	836.742
	กรกฎาคม	983.752
	สิงหาคม	1031.675
	กันยายน	852.13
	ตุลาคม	826.392

ข้อมูลอนุกรมเวลาประเทศไทย

ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	299.596
	ธันวาคม	315.707
2557	มกราคม	145.15
	กุมภาพันธ์	177.851
	มีนาคม	197.945
	เมษายน	200.124
	พฤษภาคม	185.547
	มิถุนายน	172.567
	กรกฎาคม	218.588
	สิงหาคม	194.505
	กันยายน	225.083
	ตุลาคม	259.045
	พฤศจิกายน	270.783
	ธันวาคม	366.23
2558	มกราคม	260.055
	กุมภาพันธ์	275.576
	มีนาคม	278.509
	เมษายน	271.568
	พฤษภาคม	298.671
	มิถุนายน	290.79
	กรกฎาคม	264.897
	สิงหาคม	272.767
	กันยายน	260.359
	ตุลาคม	256.399
	พฤศจิกายน	299.588
	ธันวาคม	389.676
2559	มกราคม	275.589
	กุมภาพันธ์	309.458
	มีนาคม	296.774
	เมษายน	293.519
	พฤษภาคม	295.72
	มิถุนายน	254.142
	กรกฎาคม	283.868
	สิงหาคม	252.563
	กันยายน	300.141
	ตุลาคม	267.736
	พฤศจิกายน	280.424
	ธันวาคม	384.956
2560	มกราคม	263.253
	กุมภาพันธ์	262.608
	มีนาคม	288.004
	เมษายน	312.73
	พฤษภาคม	307.927
	มิถุนายน	302.285
	กรกฎาคม	242.526
	สิงหาคม	277.606
	กันยายน	235.654
	ตุลาคม	244.999
	พฤศจิกายน	251.412
	ธันวาคม	365.796
2561	มกราคม	247.936
	กุมภาพันธ์	272.351
	มีนาคม	300.793
	เมษายน	304.891
	พฤษภาคม	279.91
	มิถุนายน	368.935
	กรกฎาคม	294.981
	สิงหาคม	380.318
	กันยายน	361.692
	ตุลาคม	307.518
	พฤศจิกายน	390.91
	ธันวาคม	521.904
2562	มกราคม	272.36
	กุมภาพันธ์	324.724
	มีนาคม	318.613
	เมษายน	329.013
	พฤษภาคม	336.127
	มิถุนายน	349.19
	กรกฎาคม	314.981
	สิงหาคม	384.245
	กันยายน	331.643
	ตุลาคม	327.068

ข้อมูลอนุกรมเวลาประเทศเกาหลี

ปี	เดือน	จำนวนนักท่องเที่ยว(×1000คน)
2556	พฤศจิกายน	113.658
	ธันวาคม	114.468
2557	มกราคม	135.598
	กุมภาพันธ์	100.65
	มีนาคม	79.481
	เมษายน	77.026
	พฤษภาคม	74.905
	มิถุนายน	65.534
	กรกฎาคม	89.189
	สิงหาคม	114.123
	กันยายน	81.366
	ตุลาคม	95.413
	พฤศจิกายน	91.16
	ธันวาคม	118.121
2558	มกราคม	153.075
	กุมภาพันธ์	117.339
	มีนาคม	100.236
	เมษายน	86.3
	พฤษภาคม	89.582
	มิถุนายน	91.77
	กรกฎาคม	121.496
	สิงหาคม	137.404
	กันยายน	94.244
	ตุลาคม	108.969
	พฤศจิกายน	123.315
	ธันวาคม	149.315
2559	มกราคม	174.971
	กุมภาพันธ์	147.69
	มีนาคม	103.28
	เมษายน	95.762
	พฤษภาคม	96.294
	มิถุนายน	107.498
	กรกฎาคม	134.306
	สิงหาคม	140.751
	กันยายน	107.884
	ตุลาคม	99.452
	พฤศจิกายน	114.746
	ธันวาคม	141.566
2560	มกราคม	171.485
	กุมภาพันธ์	163.559
	มีนาคม	128.234
	เมษายน	116.421
	พฤษภาคม	112.22
	มิถุนายน	133.734
	กรกฎาคม	152.515
	สิงหาคม	164.001
	กันยายน	134.458
	ตุลาคม	123.234
	พฤศจิกายน	147.762
	ธันวาคม	161.447
2561	มกราคม	197.62
	กุมภาพันธ์	159.983
	มีนาคม	143.644
	เมษายน	115.859
	พฤษภาคม	122.68
	มิถุนายน	141.555
	กรกฎาคม	153.523
	สิงหาคม	164.135
	กันยายน	135.47
	ตุลาคม	132.012
	พฤศจิกายน	154.561
	ธันวาคม	175.359
2562	มกราคม	208.158
	กุมภาพันธ์	184.406
	มีนาคม	144.524
	เมษายน	118.145
	พฤษภาคม	111.911
	มิถุนายน	140.243
	กรกฎาคม	166.107
	สิงหาคม	180.418
	กันยายน	145.528
	ตุลาคม	151.047

ข้อมูลอนุกรมเวลาประเทศญี่ปุ่น

ปี	เดือน	จำนวนนักท่องเที่ยว(×1000คน)
2556	พฤศจิกายน	133.502
	ธันวาคม	137.063
2557	มกราคม	115.643
	กุมภาพันธ์	97.639
	มีนาคม	101.317
	เมษายน	97.006
	พฤษภาคม	88.678
	มิถุนายน	78.306
	กรกฎาคม	95.553
	สิงหาคม	131.367
	กันยายน	109.342
	ตุลาคม	102.863
	พฤศจิกายน	117.841
	ธันวาคม	132.331
2558	มกราคม	121.828
	กุมภาพันธ์	129.35
	มีนาคม	118.198
	เมษายน	102.218
	พฤษภาคม	103.601
	มิถุนายน	100.572
	กรกฎาคม	111.371
	สิงหาคม	141.672
	กันยายน	115.137
	ตุลาคม	97.054
	พฤศจิกายน	115.538
	ธันวาคม	125.163
2559	มกราคม	122.445
	กุมภาพันธ์	133.585
	มีนาคม	124.237
	เมษายน	107.009
	พฤษภาคม	100.833
	มิถุนายน	101.291
	กรกฎาคม	117.38
	สิงหาคม	154.912
	กันยายน	127.643
	ตุลาคม	99.493
	พฤศจิกายน	121.766
	ธันวาคม	128.916
2560	มกราคม	129.505
	กุมภาพันธ์	137.051
	มีนาคม	141.708
	เมษายน	111.49
	พฤษภาคม	108.298
	มิถุนายน	111.426
	กรกฎาคม	120.232
	สิงหาคม	162.703
	กันยายน	132.926
	ตุลาคม	110.65
	พฤศจิกายน	140.15
	ธันวาคม	138.189
2561	มกราคม	143.809
	กุมภาพันธ์	144.884
	มีนาคม	144.482
	เมษายน	119.053
	พฤษภาคม	109.084
	มิถุนายน	118.508
	กรกฎาคม	128.134
	สิงหาคม	181.534
	กันยายน	141.678
	ตุลาคม	122.032
	พฤศจิกายน	148.809
	ธันวาคม	153.989
2562	มกราคม	154.948
	กุมภาพันธ์	161.839
	มีนาคม	157.89
	เมษายน	149.597
	พฤษภาคม	116.44
	มิถุนายน	123.665
	กรกฎาคม	134.395
	สิงหาคม	198.399
	กันยายน	154.514
	ตุลาคม	136.174

ข้อมูลอนุกรมเวลาประเทศไทย

ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	230.867
	ธันวาคม	253.622
2557	มกราคม	269.479
	กุมภาพันธ์	223.1
	มีนาคม	207.241
	เมษายน	114.925
	พฤษภาคม	65.989
	มิถุนายน	58.775
	กรกฎาคม	61.642
	สิงหาคม	59.597
	กันยายน	59.017
	ตุลาคม	116.039
	พฤศจิกายน	183.773
	ธันวาคม	186.853
2558	มกราคม	145.538
	กุมภาพันธ์	96.367
	มีนาคม	84.485
	เมษายน	58.312
	พฤษภาคม	43.302
	มิถุนายน	38.475
	กรกฎาคม	39.613
	สิงหาคม	37.159
	กันยายน	36.232
	ตุลาคม	69.73
	พฤศจิกายน	106.742
	ธันวาคม	128.181
2559	มกราคม	138.866
	กุมภาพันธ์	110.143
	มีนาคม	109.161
	เมษายน	85.223
	พฤษภาคม	58.44
	มิถุนายน	49.418
	กรกฎาคม	47.932
	สิงหาคม	52.682
	กันยายน	52.849
	ตุลาคม	90.919
	พฤศจิกายน	132.615
	ธันวาคม	161.835
2560	มกราคม	176.881
	กุมภาพันธ์	155.175
	มีนาคม	156.931
	เมษายน	106.631
	พฤษภาคม	65.654
	มิถุนายน	57.872
	กรกฎาคม	55.721
	สิงหาคม	54.409
	กันยายน	50.832
	ตุลาคม	105.571
	พฤศจิกายน	163.334
	ธันวาคม	197.208
2561	มกราคม	226.649
	กุมภาพันธ์	195.171
	มีนาคม	197.022
	เมษายน	126.396
	พฤษภาคม	57.089
	มิถุนายน	48.488
	กรกฎาคม	49.72
	สิงหาคม	50.05
	กันยายน	49.637
	ตุลาคม	101.217
	พฤศจิกายน	166.245
	ธันวาคม	205.081
2562	มกราคม	229.518
	กุมภาพันธ์	191.559
	มีนาคม	194.471
	เมษายน	108.308
	พฤษภาคม	55.738
	มิถุนายน	45.962
	กรกฎาคม	46.737
	สิงหาคม	46.325
	กันยายน	52.078
	ตุลาคม	106.693

ข้อมูลอนุกรมเวลาประเทศไทย

ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	84.826
	ธันวาคม	100.529
2557	มกราคม	85.771
	กุมภาพันธ์	77.526
	มีนาคม	78.029
	เมษายน	89.495
	พฤษภาคม	59.93
	มิถุนายน	59.569
	กรกฎาคม	74.764
	สิงหาคม	70.53
	กันยายน	55.882
	ตุลาคม	71.137
	พฤศจิกายน	80.446
	ธันวาคม	104.798
2558	มกราคม	85.031
	กุมภาพันธ์	81.044
	มีนาคม	86.755
	เมษายน	82.864
	พฤษภาคม	62.141
	มิถุนายน	64.806
	กรกฎาคม	80.431
	สิงหาคม	74.094
	กันยายน	58.788
	ตุลาคม	73.362
	พฤศจิกายน	86.563
	ธันวาคม	111.689
2559	มกราคม	94.268
	กุมภาพันธ์	91.972
	มีนาคม	102.434
	เมษายน	81.415
	พฤษภาคม	64.761
	มิถุนายน	67.692
	กรกฎาคม	86.091
	สิงหาคม	79.479
	กันยายน	62.245
	ตุลาคม	73.979
	พฤศจิกายน	86.887
	ธันวาคม	113.122
2560	มกราคม	94.087
	กุมภาพันธ์	87.082
	มีนาคม	88.826
	เมษายน	99.445
	พฤษภาคม	62.646
	มิถุนายน	67.255
	กรกฎาคม	84.057
	สิงหาคม	79.841
	กันยายน	60.199
	ตุลาคม	75.339
	พฤศจิกายน	87.799
	ธันวาคม	107.892
2561	มกราคม	93.464
	กุมภาพันธ์	88.843
	มีนาคม	101.460
	เมษายน	86.529
	พฤษภาคม	61.732
	มิถุนายน	65.075
	กรกฎาคม	79.751
	สิงหาคม	77.879
	กันยายน	58.768
	ตุลาคม	74.075
	พฤศจิกายน	89.136
	ธันวาคม	109.954
2562	มกราคม	97.241
	กุมภาพันธ์	92.111
	มีนาคม	91.686
	เมษายน	97.362
	พฤษภาคม	61.653
	มิถุนายน	64.701
	กรกฎาคม	79.872
	สิงหาคม	77.167
	กันยายน	57.806
	ตุลาคม	75.728

ข้อมูลอนุกรมเวลาประเทศสหรัฐอเมริกา

ปี	เดือน	จำนวนนักท่องเที่ยว(×1000คน)
2556	พฤศจิกายน	81.997
	ธันวาคม	90.113
2557	มกราคม	81.552
	กุมภาพันธ์	64.290
	มีนาคม	68.622
	เมษายน	60.930
	พฤษภาคม	52.716
	มิถุนายน	52.370
	กรกฎาคม	57.611
	สิงหาคม	49.712
	กันยายน	47.373
	ตุลาคม	64.309
	พฤศจิกายน	73.340
	ธันวาคม	90.695
2558	มกราคม	81.179
	กุมภาพันธ์	71.953
	มีนาคม	74.675
	เมษายน	67.137
	พฤษภาคม	63.906
	มิถุนายน	67.891
	กรกฎาคม	70.264
	สิงหาคม	56.090
	กันยายน	53.057
	ตุลาคม	70.667
	พฤศจิกายน	88.725
	ธันวาคม	101.961
2559	มกราคม	93.149
	กุมภาพันธ์	82.406
	มีนาคม	87.171
	เมษายน	74.761
	พฤษภาคม	72.047
	มิถุนายน	78.120
	กรกฎาคม	81.007
	สิงหาคม	61.234
	กันยายน	58.956
	ตุลาคม	73.760
	พฤศจิกายน	98.031
	ธันวาคม	115.001
2560	มกราคม	101.785
	กุมภาพันธ์	87.687
	มีนาคม	93.768
	เมษายน	87.147
	พฤษภาคม	76.500
	มิถุนายน	86.997
	กรกฎาคม	86.319
	สิงหาคม	67.917
	กันยายน	62.942
	ตุลาคม	77.810
	พฤศจิกายน	105.149
	ธันวาคม	122.103
2561	มกราคม	109.577
	กุมภาพันธ์	90.388
	มีนาคม	106.562
	เมษายน	88.698
	พฤษภาคม	81.146
	มิถุนายน	90.468
	กรกฎาคม	88.351
	สิงหาคม	71.161
	กันยายน	65.009
	ตุลาคม	82.986
	พฤศจิกายน	118.125
	ธันวาคม	129.617
2562	มกราคม	116.908
	กุมภาพันธ์	96.064
	มีนาคม	109.604
	เมษายน	94.254
	พฤษภาคม	82.815
	มิถุนายน	95.581
	กรกฎาคม	92.634
	สิงหาคม	73.574
	กันยายน	67.43
	ตุลาคม	86.527

ข้อมูลอนุกรมเวลาประเทศสิงคโปร์

ปี	เดือน	จำนวนนักท่องเที่ยว(×1000คน)
2556	พฤศจิกายน	101.368
	ธันวาคม	123.743
2557	มกราคม	46.163
	กุมภาพันธ์	40.974
	มีนาคม	58.39
	เมษายน	56.113
	พฤษภาคม	62.005
	มิถุนายน	73.308
	กรกฎาคม	61.975
	สิงหาคม	69.061
	กันยายน	78.265
	ตุลาคม	79.495
	พฤศจิกายน	93.728
	ธันวาคม	124.656
2558	มกราคม	69.413
	กุมภาพันธ์	63.788
	มีนาคม	80.422
	เมษายน	68.101
	พฤษภาคม	79.264
	มิถุนายน	99.331
	กรกฎาคม	71.558
	สิงหาคม	65.226
	กันยายน	63.704
	ตุลาคม	66.615
	พฤศจิกายน	88.316
	ธันวาคม	122.647
2559	มกราคม	65.603
	กุมภาพันธ์	70.369
	มีนาคม	87.183
	เมษายน	69.965
	พฤษภาคม	78.419
	มิถุนายน	101.122
	กรกฎาคม	73.135
	สิงหาคม	67.136
	กันยายน	80.168
	ตุลาคม	67.501
	พฤศจิกายน	86.672
	ธันวาคม	120.277
2560	มกราคม	72.625
	กุมภาพันธ์	63.046
	มีนาคม	89.263
	เมษายน	72.32
	พฤษภาคม	82.795
	มิถุนายน	107.582
	กรกฎาคม	75.35
	สิงหาคม	81.366
	กันยายน	84.26
	ตุลาคม	72.709
	พฤศจิกายน	97.649
	ธันวาคม	129.112
2561	มกราคม	74.741
	กุมภาพันธ์	70.815
	มีนาคม	93.737
	เมษายน	69.967
	พฤษภาคม	85.264
	มิถุนายน	108.478
	กรกฎาคม	75.505
	สิงหาคม	87.591
	กันยายน	81.535
	ตุลาคม	78.364
	พฤศจิกายน	107.417
	ธันวาคม	132.805
2562	มกราคม	74.668
	กุมภาพันธ์	70.649
	มีนาคม	85.402
	เมษายน	70.913
	พฤษภาคม	77.978
	มิถุนายน	111.191
	กรกฎาคม	76.652
	สิงหาคม	84.342
	กันยายน	85.417
	ตุลาคม	80.576

ข้อมูลอนุกรมเวลาประเทศอินเดีย

ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	84.999
	ธันวาคม	91.656
2557	มกราคม	70.072
	กุมภาพันธ์	59.927
	มีนาคม	73.126
	เมษายน	71.65
	พฤษภาคม	94.105
	มิถุนายน	80.751
	กรกฎาคม	71.63
	สิงหาคม	74.983
	กันยายน	75.895
	ตุลาคม	86.461
	พฤศจิกายน	83.495
	ธันวาคม	90.508
2558	มกราคม	79.764
	กุมภาพันธ์	72.34
	มีนาคม	78.706
	เมษายน	85.653
	พฤษภาคม	110.211
	มิถุนายน	99.524
	กรกฎาคม	90.032
	สิงหาคม	84.61
	กันยายน	89.164
	ตุลาคม	89.339
	พฤศจิกายน	90.053
	ธันวาคม	100.026
2559	มกราคม	91.526
	กุมภาพันธ์	75.876
	มีนาคม	90.74
	เมษายน	94.01
	พฤษภาคม	128.856
	มิถุนายน	111.506
	กรกฎาคม	104.758
	สิงหาคม	101.401
	กันยายน	97.806
	ตุลาคม	90.268
	พฤศจิกายน	94.056
	ธันวาคม	113.705
2560	มกราคม	107.227
	กุมภาพันธ์	93.618
	มีนาคม	103.634
	เมษายน	107.451
	พฤษภาคม	139.541
	มิถุนายน	138.278
	กรกฎาคม	121.895
	สิงหาคม	116.376
	กันยายน	115.551
	ตุลาคม	112.241
	พฤศจิกายน	117.446
	ธันวาคม	138.684
2561	มกราคม	131.048
	กุมภาพันธ์	107.448
	มีนาคม	121.157
	เมษายน	121.284
	พฤษภาคม	156.075
	มิถุนายน	150.587
	กรกฎาคม	130.417
	สิงหาคม	129.576
	กันยายน	122.371
	ตุลาคม	116.997
	พฤศจิกายน	141.1
	ธันวาคม	167.694
2562	มกราคม	163.794
	กุมภาพันธ์	123.272
	มีนาคม	163.158
	เมษายน	163.938
	พฤษภาคม	173.033
	มิถุนายน	191.59
	กรกฎาคม	164.159
	สิงหาคม	172.276
	กันยายน	155.998
	ตุลาคม	161.961

ข้อมูลอนุกรมเวลาประเทศออสเตรเลีย

ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	73.596
	ธันวาคม	89.673
2557	มกราคม	78.488
	กุมภาพันธ์	54.521
	มีนาคม	60.514
	เมษายน	83.237
	พฤษภาคม	58.427
	มิถุนายน	69.42
	กรกฎาคม	74.22
	สิงหาคม	61.676
	กันยายน	73.462
	ตุลาคม	75.549
	พฤศจิกายน	63.563
	ธันวาคม	78.777
2558	มกราคม	72.352
	กุมภาพันธ์	53.292
	มีนาคม	63.717
	เมษายน	70.318
	พฤษภาคม	56.684
	มิถุนายน	73.099
	กรกฎาคม	75.381
	สิงหาคม	61.339
	กันยายน	70.321
	ตุลาคม	72.248
	พฤศจิกายน	64.948
	ธันวาคม	73.751
2559	มกราคม	69.391
	กุมภาพันธ์	52.971
	มีนาคม	63.439
	เมษายน	67.449
	พฤษภาคม	56.531
	มิถุนายน	71.159
	กรกฎาคม	77.843
	สิงหาคม	62.72
	กันยายน	70.188
	ตุลาคม	69.362
	พฤศจิกายน	60.688
	ธันวาคม	74.629
2560	มกราคม	68.131
	กุมภาพันธ์	54.28
	มีนาคม	60.244
	เมษายน	78.772
	พฤษภาคม	60.249
	มิถุนายน	70.76
	กรกฎาคม	79.304
	สิงหาคม	62.81
	กันยายน	73.069
	ตุลาคม	71.11
	พฤศจิกายน	61.976
	ธันวาคม	76.386
2561	มกราคม	71.628
	กุมภาพันธ์	51.372
	มีนาคม	64.567
	เมษายน	73.324
	พฤษภาคม	57.396
	มิถุนายน	65.752
	กรกฎาคม	78.52
	สิงหาคม	61.054
	กันยายน	69.513
	ตุลาคม	71.58
	พฤศจิกายน	63.391
	ธันวาคม	72.917
2562	มกราคม	70.799
	กุมภาพันธ์	51.483
	มีนาคม	55.492
	เมษายน	75.202
	พฤษภาคม	59.366
	มิถุนายน	64.918
	กรกฎาคม	73.069
	สิงหาคม	58.53
	กันยายน	65.903
	ตุลาคม	67.857

ข้อมูลอนุกรมเวลาประเทศสลาว


ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	77.389
	ธันวาคม	79.986
2557	มกราคม	78.806
	กุมภาพันธ์	72.414
	มีนาคม	73.387
	เมษายน	86.503
	พฤษภาคม	80.606
	มิถุนายน	76.775
	กรกฎาคม	103.946
	สิงหาคม	114.859
	กันยายน	92.767
	ตุลาคม	89.34
	พฤศจิกายน	85.491
	ธันวาคม	99.089
2558	มกราคม	91.251
	กุมภาพันธ์	78.043
	มีนาคม	90.066
	เมษายน	98.512
	พฤษภาคม	102.04
	มิถุนายน	96.613
	กรกฎาคม	106.962
	สิงหาคม	113.207
	กันยายน	106.132
	ตุลาคม	109.378
	พฤศจิกายน	103.845
	ธันวาคม	124.473
2559	มกราคม	118.008
	กุมภาพันธ์	96.852
	มีนาคม	100.531
	เมษายน	103.049
	พฤษภาคม	103.709
	มิถุนายน	99.713
	กรกฎาคม	125.64
	สิงหาคม	152.021
	กันยายน	124.491
	ตุลาคม	120.219
	พฤศจิกายน	111.94
	ธันวาคม	131.847
2560	มกราคม	121.401
	กุมภาพันธ์	122.518
	มีนาคม	122.457
	เมษายน	120.398
	พฤษภาคม	130.204
	มิถุนายน	132.866
	กรกฎาคม	157.409
	สิงหาคม	158.377
	กันยายน	125.06
	ตุลาคม	131.779
	พฤศจิกายน	136.171
	ธันวาคม	154.007
2561	มกราคม	133.334
	กุมภาพันธ์	125.89
	มีนาคม	135.321
	เมษายน	138.376
	พฤษภาคม	127.418
	มิถุนายน	137.627
	กรกฎาคม	146.068
	สิงหาคม	151.232
	กันยายน	138.005
	ตุลาคม	143.974
	พฤศจิกายน	136.053
	ธันวาคม	151.158
2562	มกราคม	149.196
	กุมภาพันธ์	137.264
	มีนาคม	138.662
	เมษายน	145.484
	พฤษภาคม	147.804
	มิถุนายน	167.931
	กรกฎาคม	169.872
	สิงหาคม	165.902
	กันยายน	161.295
	ตุลาคม	154.272

ข้อมูลอนุกรมเวลาประเทศฮ่องกง


ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	46.312
	ธันวาคม	31.511
2557	มกราคม	19.499
	กุมภาพันธ์	18.778
	มีนาคม	21.007
	เมษายน	38.817
	พฤษภาคม	38.851
	มิถุนายน	32.508
	กรกฎาคม	48.06
	สิงหาคม	58.269
	กันยายน	50.862
	ตุลาคม	48.179
	พฤศจิกายน	48.538
	ธันวาคม	59.763
2558	มกราคม	35.99
	กุมภาพันธ์	57.86
	มีนาคม	54.306
	เมษายน	63.254
	พฤษภาคม	59.402
	มิถุนายน	67.087
	กรกฎาคม	79.674
	สิงหาคม	70.046
	กันยายน	38.711
	ตุลาคม	42.064
	พฤศจิกายน	44.712
	ธันวาคม	56.511
2559	มกราคม	38.539
	กุมภาพันธ์	62.585
	มีนาคม	71.834
	เมษายน	50.903
	พฤษภาคม	58.687
	มิถุนายน	78.124
	กรกฎาคม	86.011
	สิงหาคม	85.538
	กันยายน	59.296
	ตุลาคม	52.557
	พฤศจิกายน	44.221
	ธันวาคม	62.969
2560	มกราคม	56.259
	กุมภาพันธ์	46.942
	มีนาคม	57.526
	เมษายน	73.743
	พฤษภาคม	66.156
	มิถุนายน	75.431
	กรกฎาคม	82.997
	สิงหาคม	93.136
	กันยายน	69.66
	ตุลาคม	55.942
	พฤศจิกายน	62.611
	ธันวาคม	80.491
2561	มกราคม	60.464
	กุมภาพันธ์	80.543
	มีนาคม	74.295
	เมษายน	88.945
	พฤษภาคม	84.897
	มิถุนายน	102.546
	กรกฎาคม	108.027
	สิงหาคม	121.806
	กันยายน	77.951
	ตุลาคม	74.74
	พฤศจิกายน	75.823
	ธันวาคม	89.367
2562	มกราคม	60.464
	กุมภาพันธ์	80.543
	มีนาคม	74.295
	เมษายน	88.945
	พฤษภาคม	84.897
	มิถุนายน	102.546
	กรกฎาคม	108.027
	สิงหาคม	121.806
	กันยายน	77.951
	ตุลาคม	74.74

ข้อมูลอนุกรมเวลาประเทศไทย


ปี	เดือน	จำนวนนักท่องเที่ยว(x1000คน)
2556	พฤศจิกายน	78.14
	ธันวาคม	85.145
2557	มกราคม	80.835
	กุมภาพันธ์	81.056
	มีนาคม	78.008
	เมษายน	62.963
	พฤษภาคม	33.776
	มิถุนายน	27.902
	กรกฎาคม	38.622
	สิงหาคม	52.613
	กันยายน	43.69
	ตุลาคม	53.659
	พฤศจิกายน	73.994
	ธันวาคม	88.122
2558	มกราคม	81.104
	กุมภาพันธ์	88.821
	มีนาคม	93.219
	เมษายน	56.061
	พฤษภาคม	39.999
	มิถุนายน	29.733
	กรกฎาคม	42.72
	สิงหาคม	55.829
	กันยายน	43.795
	ตุลาคม	59.079
	พฤศจิกายน	82.528
	ธันวาคม	88.931
2559	มกราคม	87.293
	กุมภาพันธ์	98.041
	มีนาคม	99.562
	เมษายน	61.716
	พฤษภาคม	46.859
	มิถุนายน	33.646
	กรกฎาคม	50.621
	สิงหาคม	60.21
	กันยายน	50.439
	ตุลาคม	69.398
	พฤศจิกายน	86.658
	ธันวาคม	93.442
2560	มกราคม	91.346
	กุมภาพันธ์	94.227
	มีนาคม	97.701
	เมษายน	75.902
	พฤษภาคม	39.624
	มิถุนายน	39.281
	กรกฎาคม	50.541
	สิงหาคม	56.346
	กันยายน	50.573
	ตุลาคม	72.677
	พฤศจิกายน	86.74
	ธันวาคม	94.325
2561	มกราคม	97.969
	กุมภาพันธ์	103.746
	มีนาคม	115.581
	เมษายน	66.352
	พฤษภาคม	45.615
	มิถุนายน	34.6
	กรกฎาคม	53.149
	สิงหาคม	56.697
	กันยายน	51.239
	ตุลาคม	66.823
	พฤศจิกายน	94.052
	ธันวาคม	100.627
2562	มกราคม	97.002
	กุมภาพันธ์	101.915
	มีนาคม	103.476
	เมษายน	74.98
	พฤษภาคม	36.741
	มิถุนายน	37.741
	กรกฎาคม	52.191
	สิงหาคม	52.259
	กันยายน	45.611
	ตุลาคม	64.71




ACF และ PACF ของประเทศจีน




ACF และ PACF ของประเทศออสเตรเลีย




ACF และ PACF ของประเทศเยอรมัน




ACF และ PACF ของประเทศฮ่องกง




ACF และ PACF ของประเทศอินเดีย



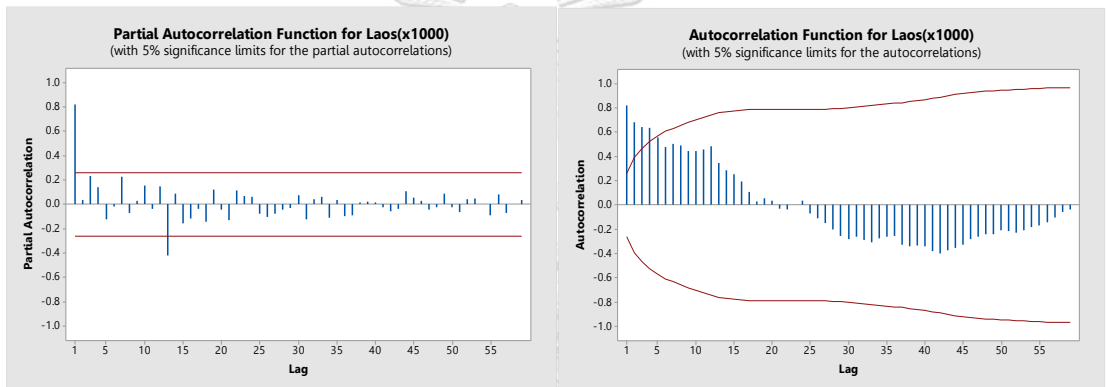
ACF และ PACF ของประเทศญี่ปุ่น



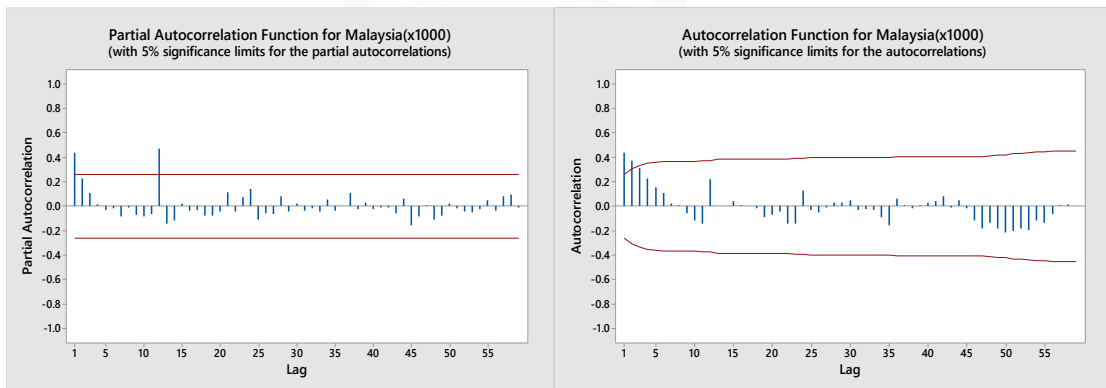
ACF และ PACF ของประเทศเกาหลี




ACF และ PACF ของประเทศลาว



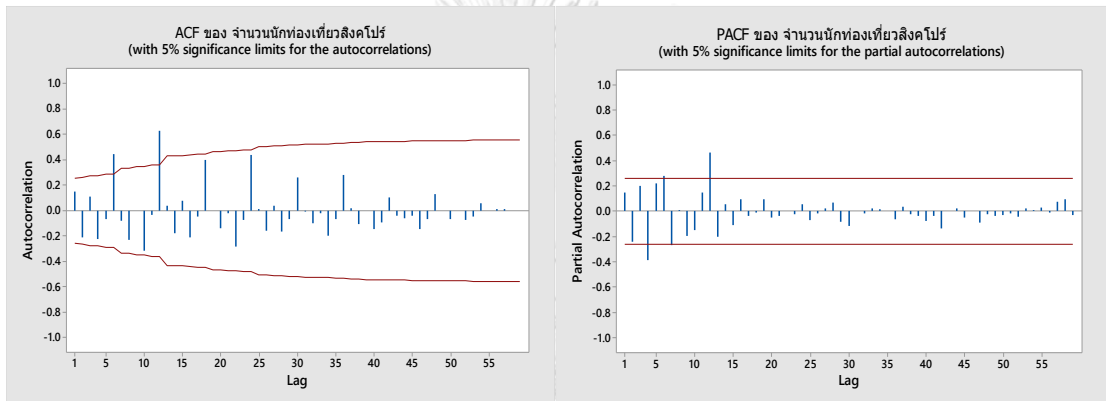
ACF และ PACF ของประเทศมาเลเซีย




ACF และ PACF ของประเทศรัสเซีย




ACF และ PACF ของประเทศสิงคโปร์



ACF และ PACF ของประเทศอังกฤษ



ACF และ PACF ของประเทศอเมริกา



Artificial Neural Network: ANN

Coefficients และ สมการของประเทศอินเดีย (Non-Stepwise)

Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	-59.3	95.0	-0.62	0.535	
GDP	0.0704	0.0239	2.95	0.005	13.34
relative CPI	74.4	46.6	1.60	0.115	8.03
exchange rate	-148	103	-1.44	0.155	6.96
India(x1000)(1)	0.236	0.120	1.97	0.053	4.09
Seasonal	14.50	3.19	4.55	0.000	1.35
Anti(GV)	9.04	4.71	1.92	0.060	1.79
Bomb	5.86	5.81	1.01	0.318	1.19
Flood	-2.07	4.52	-0.46	0.648	1.65
King passed away	-6.37	8.73	-0.73	0.468	1.12
Boat Accident in Phuket	-22.11	8.56	-2.58	0.012	1.59

Regression Equation

$$\begin{aligned} \text{India(x1000)} = & -59.3 + 0.0704 \text{ GDP} + 74.4 \text{ relative CPI} - 148 \text{ exchange rate} \\ & + 0.236 \text{ India(x1000)(1)} + 14.50 \text{ Seasonal} + 9.04 \text{ Anti(GV)} + 5.86 \text{ Bomb} \\ & - 2.07 \text{ Flood} - 6.37 \text{ King passed away} - 22.11 \text{ Boat Accident in Phuket} \end{aligned}$$

Coefficients และ สมการของประเทศรัสเซีย (Non-Stepwise)

Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	-25	107	-0.23	0.816	
GDP	0.00229	0.00281	0.82	0.418	3.74
relative CPI	2.8	14.9	0.19	0.851	7.66
exchange rate	-3.6	62.4	-0.06	0.954	11.01
Russia(x1000)(1)	0.6326	0.0777	8.14	0.000	3.02
Seasonal	48.38	8.87	5.45	0.000	2.44
Anti(GV)	18.0	10.2	1.76	0.083	2.08
Bomb	-21.0	12.6	-1.67	0.101	1.30
Flood	3.5	10.5	0.33	0.742	1.95
King passed away	-37.8	18.2	-2.08	0.042	1.14
Boat Accident in Phuket	-22.1	16.7	-1.32	0.193	1.43

Regression Equation

$$\begin{aligned} \text{Russia(x1000)} = & -25 + 0.00229 \text{ GDP} + 2.8 \text{ relative CPI} - 3.6 \text{ exchange rate} \\ & + 0.6326 \text{ Russia(x1000)(1)} + 48.38 \text{ Seasonal} + 18.0 \text{ Anti(GV)} - 21.0 \text{ Bomb} \\ & + 3.5 \text{ Flood} - 37.8 \text{ King passed away} - 22.1 \text{ Boat Accident in Phuket} \end{aligned}$$

Coefficients และ สมการของประเทศอินเดีย (Stepwise)

Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	-182.6	33.1	-5.51	0.000	
GDP	0.0933	0.0175	5.35	0.000	7.15
relative CPI	79.7	42.3	1.88	0.064	6.65
India(x1000)(1)	0.196	0.114	1.72	0.090	3.72
Seasonal	14.39	3.05	4.72	0.000	1.24
Anti(GV)	12.73	3.90	3.27	0.002	1.23
Boat Accident in Phuket	-20.89	7.46	-2.80	0.007	1.21

Regression Equation

$$\text{India(x1000)} = -182.6 + 0.0933 \text{ GDP} + 79.7 \text{ relative CPI} + 0.196 \text{ India(x1000)(1)} \\ + 14.39 \text{ Seasonal} + 12.73 \text{ Anti(GV)} - 20.89 \text{ Boat Accident in Phuket}$$

Coefficients และ สมการของประเทศรัสเซีย (Stepwise)

Coefficients

Term	Coef	SE Coef	T-Value	P-Value	VIF
Constant	-33.8	17.7	-1.90	0.061	
GDP	0.00454	0.00171	2.66	0.010	1.35
Russia(x1000)(1)	0.6123	0.0702	8.72	0.000	2.41
Seasonal	48.54	8.24	5.89	0.000	2.06
King passed away	-32.6	18.0	-1.82	0.074	1.09

Regression Equation

$$\text{Russia(x1000)} = -33.8 + 0.00454 \text{ GDP} + 0.6123 \text{ Russia(x1000)(1)} + 48.54 \text{ Seasonal} \\ - 32.6 \text{ King passed away}$$

Absolute Percentage forecasting Error values (APE) ของประเทศอินเดีย

ประเทศอินเดีย	Absolute Percentage forecasting Error values		
	SARIMA	TBATS	ANN (9, 10)
พ.ย. 61	12.19	16.20	9.36
ธ.ค. 61	13.45	19.11	13.84
ม.ค. 62	16.06	28.09	17.61
ก.พ. 62	7.61	16.13	3.02
มี.ค. 62	21.79	30.55	19.33
เม.ย. 62	22.09	27.61	19.69
พ.ค. 62	6.07	13.42	13.98
มิ.ย. 62	18.04	26.91	22.96
ก.ค. 62	16.63	25.42	20.63
ส.ค. 62	21.04	29.23	24.53
ก.ย. 62	17.42	24.95	18.21
ต.ค. 62	23.78	26.40	14.26

การจัดกลุ่มโดยใช้ Tukey Method ค่าของความเชื่อมั่น 95 เปอร์เซ็นต์ (95% confidence interval) และ หาความแตกต่างของแต่ละแบบจำลองด้วยความแตกต่างกันของค่าเฉลี่ย (Tukey Simultaneous Tests for Differences of Means) ของประเทศไทย

Grouping Information Using the Tukey Method and 95% Confidence


Method	N	Mean	Grouping
TBATS	12	23.67	A
ANN(9, 10)	12	16.45	B
SARIMA	12	16.35	B

Means that do not share a letter are significantly different.

Tukey Simultaneous Tests for Differences of Means

Difference of Levels	Difference of Means	SE of Difference	95% CI	T-Value	Adjusted P-Value
SARIMA - ANN(9, 10)	-0.10	2.38	(-5.95, 5.74)	-0.04	0.999
TBATS - ANN(9, 10)	7.22	2.38	(1.37, 13.06)	3.03	0.013
TBATS - SARIMA	7.32	2.38	(1.48, 13.16)	3.07	0.011

การเปรียบเทียบแบบจำลองแบบ Tukey Simultaneous 95% CIs ของประเทศไทย



Absolute Percentage forecasting Error values (APE) ของประเทศไทย

ประเทศไทย	Absolute Percentage forecasting Error values		
	SARIMA	TBATS	ANN (12, 22)
พ.ย. 61	5.86	9.15	4.14
ธ.ค. 61	11.69	13.18	9.66
ม.ค. 62	17.71	20.56	11.29
ก.พ. 62	19.92	20.88	3.75
มี.ค. 62	23.76	25.62	4.47
เม.ย. 62	12.78	10.93	22.23
พ.ค. 62	6.42	2.83	20.61
มิ.ย. 62	2.98	10.81	28.52
ก.ค. 62	3.72	4.65	27.69
ส.ค. 62	2.50	13.96	22.71
ก.ย. 62	14.77	5.62	8.43
ต.ค. 62	13.56	6.34	1.67

การจัดกลุ่มโดยใช้ Tukey Method ค่าของความเชื่อมั่น 95 เปอร์เซ็นต์ (95% confidence interval) และ ทหาความแตกต่างของแต่ละแบบจำลองด้วยแตกต่างกันของค่าเฉลี่ย (Tukey Simultaneous Tests for Differences of Means) ของประเทศรัสเซีย

Grouping Information Using the Tukey Method and 95% Confidence


Method	N	Mean	Grouping
ANN(12, 22)	12	13.76	A
TBATS	12	12.04	A
SARIMA	12	11.31	A

Means that do not share a letter are significantly different.

Tukey Simultaneous Tests for Differences of Means

Difference of Levels	Difference of Means	SE of Difference	95% CI	T-Value	Adjusted P-Value
SARIMA - ANN(12, 22)	-2.46	3.33	(-10.64, 5.72)	-0.74	0.743
TBATS - ANN(12, 22)	-1.72	3.33	(-9.90, 6.46)	-0.52	0.864
TBATS - SARIMA	0.74	3.33	(-7.44, 8.92)	0.22	0.973

การเปรียบเทียบแบบจำลองแบบ Tukey Simultaneous 95% CIs ของประเทศอินเดีย



ค่าของข้อมูลจำนวนนักท่องเที่ยวที่ได้จากการพยากรณ์ของแบบจำลอง SARIMA, TBATS และ ANN

เปรียบเทียบค่าของข้อมูลที่ได้จากการพยากรณ์และข้อมูลนักท่องเที่ยวจริงของประเทศไทย

ประเทศไทย	ข้อมูล นักท่องเที่ยว จริง	ค่าของข้อมูลที่ได้จากการพยากรณ์(คน)		
		SARIMA	TBATS	ANN (68, 45)
พ.ย. 61	675129	618287	664042	622604
ธ.ค. 61	838634	680757	662219	812140
ม.ค. 62	1069787	916899	827161	993220
ก.พ. 62	1064806	1002125	918046	996970
มี.ค. 62	985232	900736	828365	876593
เม.ย. 62	898994	871859	803638	826907
พ.ค. 62	794913	817720	758736	695727
มิ.ย. 62	836742	834179	718218	767428
ก.ค. 62	983752	933715	853319	934213
ส.ค. 62	1031675	923250	856434	992028
ก.ย. 62	852130	702267	671633	821676
ต.ค. 62	826392	722952	644702	801805

เปรียบเทียบค่าของข้อมูลที่ได้จากการพยากรณ์และข้อมูลนักท่องเที่ยวจริงของประเทศไทย

ประเทศไทย	ข้อมูล นักท่องเที่ยว จริง	ค่าของข้อมูลที่ได้จากการพยากรณ์(คน)		
		SARIMA	TBATS	ANN (9, 10)
พ.ย. 61	141100	123894	118243	127892
ธ.ค. 61	167694	145132	135651	144484
ม.ค. 62	163794	137496	117792	134953
ก.พ. 62	123272	113896	103383	126998
มี.ค. 62	163158	127605	113315	131616
เม.ย. 62	163938	127732	118669	131657
พ.ค. 62	173033	162523	149809	148837
มิ.ย. 62	191590	157035	140032	147600
ก.ค. 62	164159	136865	122435	130300
ส.ค. 62	172276	136024	121938	130020
ก.ย. 62	155998	128819	117074	127594
ต.ค. 62	161961	123445	119205	138861

เปรียบเทียบค่าของข้อมูลที่ได้จากการพยากรณ์และข้อมูลนักท่องเที่ยวจริงของประเทศไทย

ประเทศไทย	ข้อมูล นักท่องเที่ยว จริง	ค่าของข้อมูลที่ได้จากการพยากรณ์(คน)		
		SARIMA	TBATS	ANN (12, 22)
พ.ย. 61	166245	156506	151032	159357
ธ.ค. 61	205081	181112	178044	185271
ม.ค. 62	229518	188876	182330	203604
ก.พ. 62	191559	153393	151556	184380
มี.ค. 62	194471	148259	144652	185782
เม.ย. 62	108308	94469	96472	132385
พ.ค. 62	55738	52158	54160	67223
มิ.ย. 62	45962	44591	50932	59070
ก.ค. 62	46737	44999	48911	59681
ส.ค. 62	46325	45165	52793	56846
ก.ย. 62	52078	44388	49153	56470
ต.ค. 62	106693	92227	99928	108474

ประวัติผู้เขียน

ชื่อ-สกุล	นายภณพล อเนกคุณวุฒิ
วัน เดือน ปี เกิด	24 กรกฎาคม 2538
สถานที่เกิด	จังหวัดอุบลราชธานี
วุฒิการศึกษา	ปริญญาตรี สาขาวิชาวิศวกรรมการผลิต ภาควิชาวิศวกรรมการผลิต คณะวิศวกรรมศาสตร์ มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
ที่อยู่ปัจจุบัน	78-80 ถ.อุปราช ต.ในเมือง อ.เมือง จ.อุบลราชธานี 34000



จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY