

การวิเคราะห์เปรียบเทียบแบบจำลองสำหรับการคาดการณ์ปริมาณการปล่อย  
ก๊าซคาร์บอนไดออกไซด์จากภาคขนส่งในประเทศไทย



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต  
สาขาวิศวกรรมโยธา ขนส่ง และทรัพยากรธรณี  
มหาวิทยาลัยเทคโนโลยีสุรนารี  
ปีการศึกษา 2566

A COMPARATIVE STUDY OF MODELS FOR PREDICTING  
CARBON DIOXIDE EMISSIONS FROM THAILAND'S  
TRANSPORTATION SECTOR



THANANYA JANHUATON

A Thesis Submitted in Partial Fulfillment of the Requirements for the  
Degree of Master of Engineering in Civil, Transportation and  
Geo-Resources Engineering  
Suranaree University of Technology  
Academic Year 2023

การวิเคราะห์เปรียบเทียบแบบจำลองสำหรับการคาดการณ์ปริมาณการปล่อยก๊าซ  
คาร์บอนไดออกไซด์จากภาคขนส่งในประเทศไทย

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษาตาม  
หลักสูตรปริญญาโทบริหารธุรกิจ

คณะกรรมการสอบวิทยานิพนธ์

(ศ. ดร. วัฒนวงศ์ รัตนวราห)

ประธานกรรมการ

(รศ. ดร. สัจจจากาจ จอมโนนเขวา)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)

(ผศ. ดร. ธนพงษ์ จำปาหอม)

กรรมการ

(รศ. ดร. ยุพาพร รักสกุลพิวัฒน์)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ

(รศ. ดร. พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

ธัญญา จันทรหัตโตน: การวิเคราะห์เปรียบเทียบแบบจำลองสำหรับการคาดการณ์ปริมาณ  
การปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคขนส่งในประเทศไทย (A COMPARATIVE  
STUDY OF MODELS FOR PREDICTING CARBON DIOXIDE EMISSIONS FROM  
THAILAND'S TRANSPORTATION SECTOR)

อาจารย์ที่ปรึกษา: รองศาสตราจารย์ ดร.สัจจกาจ จอมโนนขวา, 52 หน้า

คำสำคัญ: การปล่อยก๊าซ CO<sub>2</sub>/การคาดการณ์/การขนส่ง/การเรียนรู้ของเครื่อง/ARIMAX/โครงข่าย  
ประสาทเทียม/ซัพพอร์ตเวกเตอร์รีเกรสชัน

การขนส่งมีอิทธิพลอย่างมากต่อการขับเคลื่อนการลดก๊าซเรือนกระจก โดยเฉพาะก๊าซ  
คาร์บอนไดออกไซด์ เนื่องจากการคมนาคมขนส่งเป็นพื้นฐานในหลาย ๆ เรื่อง เช่น การพัฒนา  
อุตสาหกรรมและบริการที่ปล่อยคาร์บอนต่ำ การปรับเปลี่ยนโครงสร้างเศรษฐกิจให้เป็นมิตรกับ  
สิ่งแวดล้อม รวมไปถึงการพัฒนาเมืองคาร์บอนต่ำที่มีความยั่งยืน นอกจากนี้โครงสร้างพื้นฐานดังกล่าว  
หากมีการพัฒนาขึ้นแล้ว อายุการใช้งานนั้นจะส่งผลกระทบต่อรูปแบบของการปล่อยก๊าซเรือนกระจกของ  
ประเทศเป็นเวลานาน ดังนั้น การพัฒนาแบบจำลองการคาดการณ์ที่แม่นยำมีความสำคัญอย่างยิ่งต่อ  
การกำหนดนโยบายที่มีประสิทธิภาพ

การศึกษานี้เปรียบเทียบประสิทธิภาพของแบบจำลอง ANN SVR และ ARIMAX ในการ  
คาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์จากภาคการขนส่งในประเทศไทย โดยใช้ชุดข้อมูล  
ครอบคลุมช่วงปีพ.ศ. 2536 ถึง 2565 แบบจำลองถูกประเมินประสิทธิภาพโดยเมตริกวัดผล 3 เมตริก  
ได้แก่ MAE, RMSE และ MAPE ผู้วิจัยตั้งเป้าที่จะระบุแบบจำลองที่แม่นยำและเชื่อถือได้มากที่สุด  
สำหรับการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในอนาคตจากภาคการขนส่งในประเทศไทย  
ผลจากการศึกษานี้สามารถให้ข้อมูลที่มีประโยชน์ต่อผู้กำหนดนโยบาย และผู้มีส่วนได้ส่วนเสียอื่น ๆ  
ในการพัฒนามาตรการเชิงรุกเพื่อลดการปล่อยมลพิษ ปรับปรุงคุณภาพอากาศ และส่งเสริมการสัญจร  
ที่ยั่งยืนในประเทศไทยและในประเทศอื่น ๆ ที่บริบทคล้ายคลึงกัน

สาขาวิชา วิศวกรรมขนส่ง

ปีการศึกษา 2566

ลายมือชื่อนักศึกษา.....

ลายมือชื่ออาจารย์ที่ปรึกษา.....



THANANYA JANHUATON: A COMPARATIVE STUDY OF MODELS FOR PREDICTING  
CARBON DIOXIDE EMISSIONS FROM THAILAND'S TRANSPORTATION SECTOR  
THESIS ADVISOR: ASSOC. PROF. SAJJAKAJ JOMNONKWAO, Ph.D., 52 PP.

Keyword: CO<sub>2</sub> emissions/Predicting/Transportation/Machine learning/ARIMAX/ANN/SVR

Transportation holds a crucial role in driving reductions in greenhouse gas emissions, particularly carbon dioxide. This is due to transportation serving as the foundation for various sectors, such as the development of low-carbon industries and services, the transition of the economic structure to be environmentally friendly, and the development of sustainable low-carbon cities. Moreover, once such infrastructure is developed, its lifespan will impact the country's greenhouse gas emission patterns for an extended period. Therefore, developing accurate prediction models is of paramount importance for effective policymaking.

This study conducts a comparative analysis of the performance of ANN, SVR, and ARIMAX models in predicting carbon dioxide emissions from the transportation sector in Thailand. The analysis utilizes a dataset spanning the period from 1993 to 2022. The models' performances were evaluated using three key metrics: MAE, RMSE, and MAPE. The objective of this study was to identify the most accurate and reliable model for forecasting future carbon dioxide emissions from Thailand's transportation sector. The findings from this study are intended to provide valuable insights to policymakers and other stakeholders, aiding in the development of proactive measures to reduce emissions, enhance air quality, and promote sustainable mobility both in Thailand and in other countries with similar contexts.

School of Transportation Engineering  
Academic Year 2023

Student's Signature.....  
Advisor's Signature.....

## กิตติกรรมประกาศ

วิทยานิพนธ์เล่มนี้สำเร็จลุล่วงได้ด้วยความช่วยเหลือและการสนับสนุนจากหลายฝ่าย ข้าพเจ้าขอแสดงความขอบคุณอย่างสุดซึ้งต่อทุกท่านที่มีส่วนร่วมในการทำงานครั้งนี้

ขอขอบคุณอาจารย์ที่ปรึกษาวิทยานิพนธ์ รองศาสตราจารย์ ดร.สัจจากาจ จอมโนนเขวา สำหรับคำแนะนำ ข้อเสนอแนะ และแนวทางแก้ไขปัญหาตลอดการทำวิทยานิพนธ์ ความรู้และความเชี่ยวชาญของอาจารย์เป็นแรงสนับสนุนสำคัญที่ทำให้สามารถดำเนินงานวิจัยนี้จนสำเร็จลุล่วงได้

ขอขอบคุณ ศาสตราจารย์ ดร.วิวัฒน์วงศ์ รัตนวราห และ ผู้ช่วยศาสตราจารย์ ดร.ธนพงษ์ จำปาหอม คณะกรรมการสอบวิทยานิพนธ์ สำหรับข้อแนะนำอันมีค่าในการปรับปรุงและพัฒนา วิทยานิพนธ์ฉบับนี้ให้มีความครบถ้วนสมบูรณ์ ตลอดจนแนวทางการนำไปใช้ประโยชน์

ขอขอบคุณ คุณปิยธิดา ปัญหาราช เลขานุการสาขาวิศวกรรมขนส่ง สำหรับความรู้ คำแนะนำ และความช่วยเหลือในด้านการดำเนินเอกสารและกระบวนการต่าง ๆ ระหว่างการศึกษา

ขอขอบคุณครอบครัวที่เป็นกำลังใจและสนับสนุนในทุกด้าน โดยเฉพาะการให้กำลังใจและความเข้าใจจากครอบครัวเป็นแรงผลักดันสำคัญที่ทำให้สามารถทำวิทยานิพนธ์นี้จนเสร็จสมบูรณ์

ธัญญา จันทร์หัวโทน

มหาวิทยาลัยเทคโนโลยีสุรนารี



# สารบัญ

หน้า

บทคัดย่อ.....	ก
Abstract.....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ฉ
สารบัญรูป.....	ช
<b>บทที่</b>	
<b>1 บทนำ.....</b>	<b>1</b>
1.1 ที่มาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	3
1.3 ขอบเขตการวิจัย.....	3
1.4 คำถามงานวิจัย.....	3
1.5 ประโยชน์ที่คาดว่าจะได้รับ.....	3
1.6 กรอบแนวคิดการวิจัย.....	4
<b>2 ปรัชญาวรรณกรรมและงานวิจัยที่เกี่ยวข้อง.....</b>	<b>5</b>
2.1 ทฤษฎีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN).....	5
2.2 ทฤษฎีซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR).....	7
2.3 ทฤษฎี Autoregressive Integrated Moving Average with Exogenous Variables (ARIMAX).....	10
2.4 งานวิจัยที่เกี่ยวข้อง.....	12
2.4.1 การคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์.....	12
2.4.2 การวิเคราะห์สถานการณ์ (Scenarios analysis).....	16
2.4.3 การหาค่าที่เหมาะสมที่สุดแบบเบย์.....	16
<b>3 วิธีดำเนินการวิจัย.....</b>	<b>24</b>
3.1 ขั้นตอนการดำเนินการศึกษา.....	24

## สารบัญ (ต่อ)

	หน้า
3.2 เครื่องมือที่ใช้ในการศึกษา.....	25
3.3 การเก็บรวบรวมข้อมูล.....	26
3.4 การวิเคราะห์ข้อมูล.....	27
<b>4 ผลการวิเคราะห์ข้อมูลและการอภิปรายผล.....</b>	<b>29</b>
4.1 สถิติเชิงบรรยาย.....	29
4.2 แบบจำลอง ANN.....	30
4.3 แบบจำลอง SVR.....	31
4.4 แบบจำลอง ARIMAX.....	32
4.5 ผลการทดสอบ HLN.....	35
4.6 การเปรียบเทียบประสิทธิภาพแบบจำลอง.....	36
4.7 การคาดการณ์และการวิเคราะห์สถานการณ์.....	38
<b>5 สรุปและข้อเสนอแนะ.....</b>	<b>41</b>
รายการอ้างอิง.....	43
ภาคผนวก.....	50
ประวัติผู้เขียน.....	52



## สารบัญตาราง

ตารางที่	หน้า
2.1	สรุปรงานวิจัยที่เกี่ยวกับการใช้พลังงานและการปล่อยก๊าซคาร์บอนไดออกไซด์.....19
3.1	แนวทางการแปรผลเมตริก MAPE.....26
3.2	แหล่งที่มาและคำอธิบายตัวแปร.....27
4.1	แสดงค่าสถิติเชิงบรรยายของชุดข้อมูล.....29
4.2	ช่วงการค้นหาไฮเปอร์พารามิเตอร์สำหรับ ANN.....31
4.3	ช่วงการค้นหาไฮเปอร์พารามิเตอร์สำหรับ SVR.....31
4.4	ผลการทดสอบ ADF.....33
4.5	ผลการทดสอบ HLN.....35
4.6	ผลการประเมินประสิทธิภาพแบบจำลอง.....37
4.7	การประเมินความแม่นยำของแบบจำลอง ARIMA ในการคาดการณ์ตัวแปรอิสระ.....38
4.8	ผลการคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ 15 ปีข้างหน้า.....40

## สารบัญรูป

รูปที่	หน้า
1.1	การปล่อยก๊าซเรือนกระจกของประเทศไทยในภาคพลังงาน พ.ศ. 2562.....2
1.2	กรอบแนวคิดวิจัย.....4
2.1	แบบจำลองโครงข่ายประสาทเทียมหลายชั้น (multilayer perceptron: MLP).....6
2.2	รูปแบบทางคณิตศาสตร์ของทฤษฎีโครงข่ายประสาทเทียม.....7
2.3	แผนผังขั้นตอนการดำเนินงานของแบบจำลองโครงข่ายประสาทเทียม.....7
2.4	แนวคิดของแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน.....9
2.5	แนวทางการสร้างแบบจำลองซัพพอร์ตเวกเตอร์รีเกรสชัน.....9
2.7	แนวทางการสร้างแบบจำลอง ARIMAX.....10
2.6	กระบวนการปรับไฮเปอร์พารามิเตอร์ให้เหมาะสมโดยใช้การหาค่าที่เหมาะสมที่สุดแบบเบย์.....18
3.1	แผนผังการดำเนินงาน.....25
4.1	แผนภาพการหาค่าที่เหมาะสมที่สุดสำหรับ ANN.....30
4.2	แผนภาพการหาค่าที่เหมาะสมที่สุดสำหรับ SVR.....32
4.3	แผนภาพ ACF ของข้อมูลที่มีลักษณะนิ่งแล้ว.....33
4.4	แผนภาพ PACF ของข้อมูลที่มีลักษณะนิ่งแล้ว.....34
4.5	แผนภาพ ACF ของค่าคงเหลือของแบบจำลอง ARIMAX (1,1,1).....34
4.6	แผนภาพ Q-Q ของค่าคงเหลือของแบบจำลอง ARIMAX (1,1,1).....35
4.7	แผนภาพเรดาร์ผลการประเมินประสิทธิภาพ.....36
4.8	การเปรียบเทียบค่าจริงและค่าที่คาดการณ์ไว้สำหรับการปล่อย CO <sub>2</sub> .....38

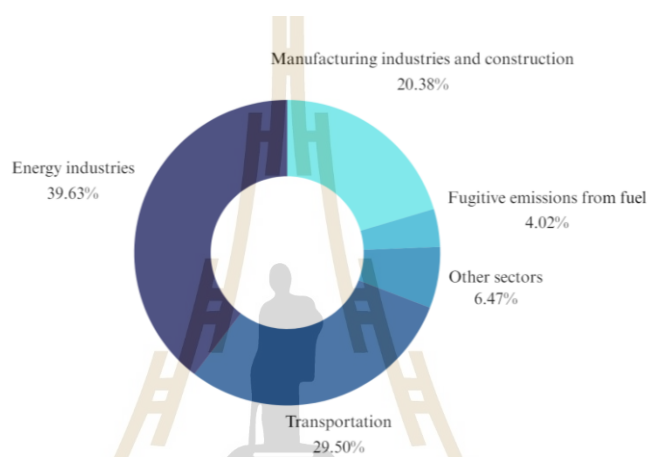
# บทที่ 1

## บทนำ

### 1.1 ที่มาและความสำคัญของปัญหา

ก๊าซเรือนกระจก (GHGs) เป็นกลุ่มของก๊าซที่ดักจับความร้อนในชั้นบรรยากาศของโลก ซึ่งนำไปสู่สิ่งที่เรียกว่าปรากฏการณ์เรือนกระจก และมีส่วนทำให้เกิดภาวะโลกร้อนและการเปลี่ยนแปลงสภาพภูมิอากาศ ในกลุ่มก๊าซเรือนกระจก ก๊าซคาร์บอนไดออกไซด์ (CO<sub>2</sub>) ถือเป็นสาเหตุหลักของภาวะโลกร้อน ในช่วงปีพ.ศ. 2554-2563 ระดับ CO<sub>2</sub> เพิ่มขึ้นในอัตราที่สูงเป็นประวัติการณ์ โดยเพิ่มขึ้นมากกว่า 2 ppm ต่อปี (NOAA, 2022) ปริมาณการปล่อยก๊าซคาร์บอนที่เพิ่มขึ้นนี้มีผลกระทบต่อสิ่งแวดล้อมหลายประการ เช่น อุณหภูมิของโลกที่สูงขึ้น ความแห้งแล้ง น้ำท่วม พายุ และเหตุการณ์สภาพอากาศที่รุนแรง (Bolan et al., 2024) ผลกระทบดังกล่าวนำไปสู่ความตระหนักถึงการบรรเทาการเปลี่ยนแปลงสภาพภูมิอากาศโลกและความยั่งยืนด้านสิ่งแวดล้อม (IPCC, 2018) ข้อตกลงปารีสซึ่งอยู่ภายใต้อนุสัญญากรอบสหประชาชาติว่าด้วยการเปลี่ยนแปลงสภาพภูมิอากาศ เป็นข้อตกลงระหว่างประเทศที่สำคัญที่สะท้อนถึงความพยายามระดับโลกในการจัดการกับการเปลี่ยนแปลงสภาพภูมิอากาศ ซึ่งประเทศไทยเป็นหนึ่งในภาคีของข้อตกลงปารีส โดยในประเทศไทยตั้งแต่ปีพ.ศ. 2554 - 2564 อุณหภูมิเฉลี่ยเพิ่มขึ้น 0.09 องศาต่อปี ซึ่งการปล่อยก๊าซเรือนกระจกส่วนใหญ่ในภาคพลังงานเป็นผลมาจากการเผาไหม้เชื้อเพลิง (ONEP, 2020) รูปที่ 1.1 บ่งชี้ว่าภาคการขนส่งของไทยมีบทบาทสำคัญในการปล่อยก๊าซคาร์บอนไดออกไซด์ โดยคิดเป็นสัดส่วน 29.50% ของการปล่อยก๊าซเรือนกระจกในภาคพลังงาน รองจากอุตสาหกรรมพลังงานซึ่งมีสัดส่วน 39.63% (ONEP, 2022) ภาคการขนส่งมีส่วนสำคัญในการปล่อยก๊าซคาร์บอนไดออกไซด์ทั้งในระดับโลกและในประเทศไทย ทำให้การพัฒนาแบบจำลองการคาดการณ์ที่แม่นยำมีความสำคัญอย่างยิ่งต่อการกำหนดนโยบายที่มีประสิทธิภาพ การศึกษาทบทวนก่อนหน้าเกี่ยวกับการคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ในภาคการขนส่งของประเทศไทย พบว่า Ratanavaraha and Jomnonkwo (2015) เปรียบเทียบแบบจำลองการถดถอยเชิงเส้นลอการิทึม (Log-linear regression) แบบจำลองการวิเคราะห์เส้นทาง (Path analysis) แบบจำลอง ARIMA (Autoregressive Integrated Moving Average) และแบบจำลองการประมาณเส้นโค้ง (Curve estimation) โดยพิจารณาปัจจัยที่เกี่ยวข้อง เช่น GDP ประชากร และจำนวนรถยนต์ที่จดทะเบียน ผลการศึกษาระบุว่าแบบจำลอง ARIMA มีประสิทธิภาพ

มากที่สุด Salangam (2022) เปรียบเทียบการแบบจำลองการถดถอยเชิงเส้น (Linear regression) และ แบบจำลองโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) โดยพิจารณาตัวแปร GDP ประชากร การใช้พลังงาน และจำนวนรถยนต์ที่จดทะเบียน ผลการศึกษาระบุว่าการคาดการณ์ CO<sub>2</sub> ของ ANN มีประสิทธิภาพและแม่นยำมากกว่าถึงหกเท่า นอกจากนี้ Sutthichaimethee and Ariyasajjakorn (2018) คาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์จากการใช้พลังงานภาคอุตสาหกรรมในประเทศไทยโดยใช้แบบจำลอง Autoregressive Integrated Moving Average with Exogenous Variables (ARIMAX) ซึ่งใช้ข้อมูล GDP และประชากรในการวิเคราะห์



รูปที่ 1.1 การปล่อยก๊าซเรือนกระจกของประเทศไทยในภาคพลังงาน พ.ศ. 2562 (ONEP, 2022).

การคาดการณ์ CO<sub>2</sub> ต้องเผชิญกับความซับซ้อน ความแปรปรวนของการปล่อยก๊าซเรือนกระจก และผลกระทบจากภายนอก เช่น นโยบาย เทคโนโลยี ภัยพิบัติทางธรรมชาติ การแพร่ระบาดของโควิด-19 และเหตุการณ์ทางภูมิรัฐศาสตร์อื่นๆ วิธีการคาดการณ์ CO<sub>2</sub> ที่ได้พบบ่อย คือ ANN ARIMA และ SVR ซึ่งมีจุดแข็งและจุดอ่อนที่แตกต่างกัน โดย ANN มีความยืดหยุ่นสูงและสามารถปรับให้เข้ากับรูปแบบข้อมูลประเภทต่าง ๆ ได้ รวมถึงรูปแบบความสัมพันธ์แบบไม่เชิงเส้น (Yun & Zanetti, 2021) หรือข้อมูลที่มีการกระจายตัวไม่ปกติ (Guh, 2002) SVR สามารถจับความสัมพันธ์แบบไม่เชิงเส้น (Shen et al., 2023) และได้รับผลกระทบจากค่าผิดปกติน้อยกว่าทางสถิติแบบดั้งเดิม ARIMAX หรือ ARIMA ร่วมกับตัวแปรภายนอก ช่วยให้สามารถพิจารณาปัจจัยภายนอกหรือเหตุการณ์แทรกแซงที่อาจส่งผลกระทบต่อข้อมูลอนุกรมเวลา ซึ่งจะช่วยให้ปรับปรุงความแม่นยำในการคาดการณ์ล่วงหน้า (Kongcharoen & Kruangpradit, 2013; Ling et al., 2019; Peter & Silvia, 2012) ปัจจุบัน ยังไม่มีการศึกษาใดเปรียบเทียบประสิทธิภาพของวิธีการทั้ง 3 นี้ในบริบทการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ที่เกี่ยวข้องกับการขนส่งในประเทศไทย ดังนั้น การศึกษาในปัจจุบันจึงมีจุดมุ่งหมายเพื่อเติมเต็มช่องว่างนี้ด้วยการเปรียบเทียบประสิทธิภาพของแบบจำลอง ANN ARIMAX

และ SVR ผู้วิจัยตั้งเป้าที่จะระบุแบบจำลองที่แม่นยำและเชื่อถือได้มากที่สุดสำหรับการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในอนาคตจากภาคการขนส่งในประเทศไทย ผลจากการศึกษานี้สามารถให้ข้อมูลที่มีประโยชน์ต่อผู้กำหนดนโยบาย และผู้มีส่วนได้ส่วนเสียอื่น ๆ ในการพัฒนามาตรการเชิงรุกเพื่อลดการปล่อยมลพิษ ปรับปรุงคุณภาพอากาศ และส่งเสริมการสัญจรที่ยั่งยืนในประเทศไทยและในประเทศอื่น ๆ ที่บริบทคล้ายคลึงกัน

## 1.2 วัตถุประสงค์ของการวิจัย

- 1) เพื่อระบุแบบจำลองที่เหมาะสมสำหรับการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคการขนส่งในประเทศไทย
- 2) เพื่อระบุแนวโน้มและรูปแบบการปล่อยก๊าซคาร์บอนไดออกไซด์ในภาคการขนส่ง

## 1.3 ขอบเขตการวิจัย

- 1) ศึกษาปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์เฉพาะภาคการขนส่งในประเทศไทย
- 2) การศึกษานี้ใช้ข้อมูลในช่วงปีพ.ศ. 2536 – 2565 ในการสร้างแบบจำลองคาดการณ์

## 1.4 คำถามงานวิจัย

แบบจำลองใดมีความเหมาะสมมากที่สุดในการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคขนส่งในประเทศไทยในอนาคต

## 1.5 ประโยชน์ที่คาดว่าจะได้รับ

- 1) ทราบถึงแนวโน้มการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคการขนส่งในอนาคต
- 2) องค์กรภาครัฐ นักวิจัย และหน่วยงานที่เกี่ยวข้องอื่น ๆ สามารถนำข้อมูลไปประยุกต์ใช้ในการตัดสินใจอย่างรอบรู้และดำเนินการนโยบายเพื่อลดผลกระทบจากการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคการขนส่ง

## 1.6 กรอบแนวคิดการวิจัย



รูปที่ 1.2 กรอบแนวคิดวิจัย



## บทที่ 2

### ปริทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

ในบทนี้เป็นการทบทวนวรรณกรรมที่เกี่ยวข้องอันได้แก่ แนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้องเพื่อให้เกิดความรู้ ความเข้าใจในเนื้อหา หรือประเด็นต่าง ๆ ที่เกี่ยวข้องกับงานวิจัยครั้งนี้ โดยหัวข้อการนำเสนอประกอบด้วย

1. ทฤษฎีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)
2. ทฤษฎีซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR)
3. ทฤษฎี Autoregressive Integrated Moving Average with Exogenous Variables (ARIMAX)
4. งานวิจัยที่เกี่ยวข้อง

#### 2.1 ทฤษฎีโครงข่ายประสาทเทียม (Artificial Neural Network: ANN)

โครงข่ายประสาทเทียม (Artificial neural networks: ANN) เป็นวิธีการเรียนรู้ของเครื่องที่ได้รับแรงบันดาลใจจากโครงสร้างและการทำงานของสมองมนุษย์ ประกอบด้วยหน่วยประมวลผลหลายหน่วยที่เรียกว่าเซลล์ประสาท (neurons) ซึ่งทำงานร่วมกันเพื่อประมวลผลข้อมูลและจดจำรูปแบบ กระบวนการเรียนรู้ของโครงข่ายประสาทเทียมเกี่ยวข้องกับการปรับน้ำหนักผ่านวิธีการที่เรียกว่าการย้อนกลับของการแพร่กระจาย (backpropagation) ข้อมูลเริ่มต้นจะถูกป้อนเข้าสู่เครือข่ายและผ่านหลายชั้น ซึ่งแต่ละชั้นจะใช้น้ำหนัก (weight) และฟังก์ชันการกระตุ้น (activation function) เพื่อแปลงข้อมูลจนกระทั่งได้ผลลัพธ์สุดท้าย สถาปัตยกรรมของโครงข่ายประสาทเทียมหลายชั้น (multilayer perceptron: MLP) แสดงใน Error! Reference source not found. รูปที่ 2.1 ซึ่งประกอบด้วยชั้นอินพุต (input layer) ชั้นซ่อนตัว (hidden layer) และชั้นเอาต์พุต (output layer) ผลลัพธ์ของเครือข่ายจะถูกเปรียบเทียบกับค่าจริงโดยใช้ฟังก์ชันการสูญเสีย (loss function) ซึ่งเป็นการวัดความแตกต่างระหว่างค่าที่คาดการณ์และค่าจริง ฟังก์ชันการสูญเสียที่พบบ่อยสำหรับงานคาดการณ์ ได้แก่ ค่าเฉลี่ยกำลังสองของความผิดพลาด (mean squared error: MSE) ความผิดพลาดจากฟังก์ชันการสูญเสียจะถูกส่งย้อนกลับผ่านเครือข่าย และน้ำหนักจะถูกปรับเพื่อให้ลดความผิดพลาดนี้โดยใช้อัลกอริทึมการปรับให้เหมาะสม เช่น การปรับน้ำหนักแบบเบย์ การคำนวณการสูญเสีย และ

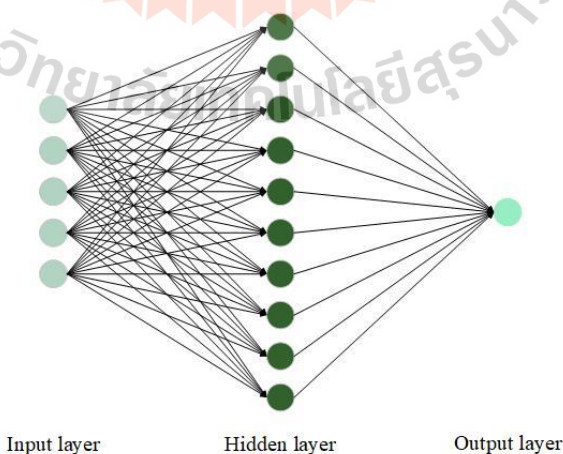


การแพร่กระจายย้อนกลับนี้จะดำเนินไปซ้ำ ๆ จนกว่าความผิดพลาดจะลดลงถึงระดับที่ยอมรับได้ ทำให้โครงข่ายประสาทเทียมสามารถเรียนรู้รูปแบบพื้นฐานในข้อมูลที่กำลังวิเคราะห์ได้


วิธีโครงข่ายประสาทเทียมมีความสามารถในการปรับตัวสูงเพื่อรองรับข้อมูลรูปแบบต่าง ๆ รวมถึงความสัมพันธ์ที่ไม่เป็นเชิงเส้น (Yun & Zanetti, 2021) และสามารถจัดการกับโครงสร้างข้อมูลที่ซับซ้อนได้ดี ซึ่งวิธีการทางสถิติแบบดั้งเดิมอาจประสบปัญหา เช่น การละเมิดสมมติฐานของการแจกแจงแบบปกติ (Guh, 2002) อย่างไรก็ตาม วิธีโครงข่ายประสาทเทียมยังมีความซับซ้อนในตัวเองและมักขาดความสามารถในการตีความ (Zhang et al., 2018) ทำให้ยากที่จะเข้าใจการคาดการณ์ของแบบจำลอง รูปแบบทางคณิตศาสตร์ของแบบจำลองแสดงดังรูปที่ 2.2 ซึ่งนิพจน์ทางคณิตศาสตร์สำหรับการคำนวณผลการคาดการณ์สำหรับตัวอย่าง  $j^{\text{th}}$  สามารถคำนวณได้โดยใช้สมการ 2.1 (Junhuathon & Chayakulkheeree, 2022) แนวทางการสร้างแบบจำลอง ANN ในการศึกษานี้แสดงดังรูปที่ 2.3

$$y_j = \sum_{i=1}^n \omega_{ki,j} f(h_k) + \beta_j \quad (2.1)$$

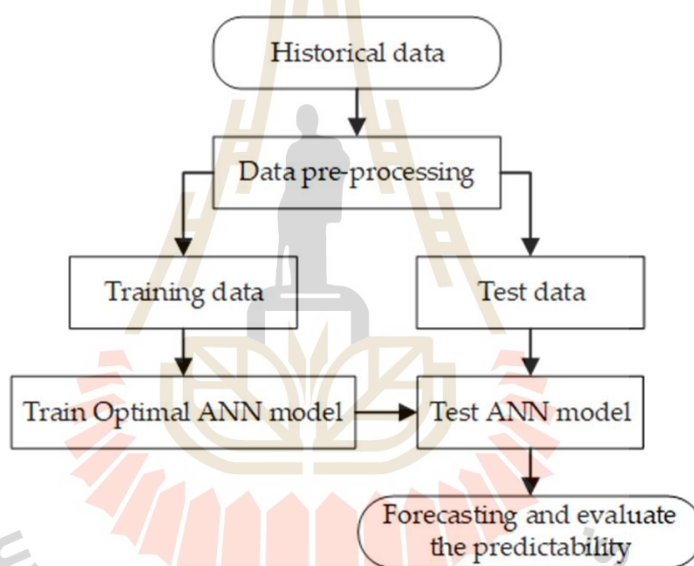
โดยที่  $\omega_{ki,j}$  คือ น้ำหนักจากโหนดซ่อนตัวที่  $k^{\text{th}}$  ไปยังโหนดเอาต์พุตในรอบที่  $i^{\text{th}}$   
 $\beta_j$  คือ แสดงถึงอคติของโหนดเอาต์พุตที่  $j^{\text{th}}$   
 $f(h_k)$  คือ เป็นผลลัพธ์ของโหนดซ่อนตัว  $h_k$  หลังจากที่ได้ใช้ฟังก์ชันการกระตุ้นแล้ว  
 $y_j$  คือ หมายถึงผลลัพธ์ของตัวอย่างที่  $j^{\text{th}}$



รูปที่ 2.1 แบบจำลองโครงข่ายประสาทเทียมหลายชั้น (multilayer perceptron: MLP)



รูปที่ 2.2 รูปแบบทางคณิตศาสตร์ของทฤษฎีโครงข่ายประสาทเทียม (Saber et al., 2019)



รูปที่ 2.3 แผนผังขั้นตอนการดำเนินงานของแบบจำลองโครงข่ายประสาทเทียม

## 2.2 ทฤษฎีซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR)

วิธีซัพพอร์ตเวกเตอร์รีเกรสชัน (Support Vector Regression: SVR) ถูกพัฒนามาจากแนวคิดของ วิธีซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) ซึ่งเป็นเทคนิคสำหรับการจำแนกประเภท (classification) โดยซัพพอร์ตเวกเตอร์รีเกรสชันได้ถูกออกแบบมาสำหรับการวิเคราะห์ถดถอย (regression) รวมถึงการคาดการณ์อนุกรมเวลา (Hao & Yu, 2006)

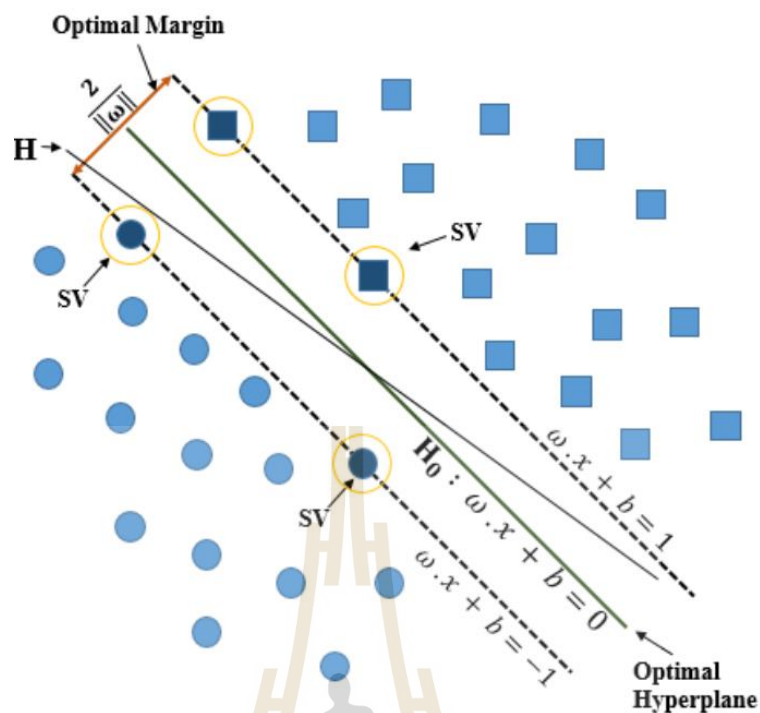
หลักการของ SVR มีองค์ประกอบแสดงดังรูปที่ 2.4 ซึ่งเกี่ยวข้องกับการปรับไฮเปอร์เพลน (hyperplane) หรือเส้นถดถอยถูกสร้างขึ้นจากแบบจำลอง SVR โดยพยายามให้เส้นใกล้เคียงกับค่า

จริงมากที่สุดภายใต้ระยะขอบ (margin) ซึ่งถูกกำหนดโดยค่าเอปซิลอน (Epsilon:  $\epsilon$ ) ระยะขอบดังกล่าวหมายถึงท่อเอปซิลอน (Epsilon tube) ที่ถูกสร้างขึ้นรอบเส้นถดถอย โดยมีระยะ  $\epsilon$  ที่กำหนดขอบเขตความคลาดเคลื่อนที่ยอมรับได้ โดยข้อผิดพลาดจากการคาดการณ์ภายในท่อเอปซิลอนจะไม่ถูกลงโทษ ซัพพอร์ตเวกเตอร์ (support vectors) คือจุดข้อมูลที่อยู่บนขอบเขตหรือด้านนอกของท่อเอปซิลอน ซึ่งมีบทบาทสำคัญในการกำหนดฟังก์ชันการถดถอย (Cortes & Vapnik, 1995) SVR ได้รับการออกแบบมาเพื่อเพิ่มระยะขอบสำหรับการถดถอย เพื่อให้มั่นใจถึงประสิทธิภาพที่แข็งแกร่งในการประมาณค่าฟังก์ชัน ทำให้ SVR โดยทั่วไปมีความทนทานต่อค่าผิดปกติ (Schölkopf et al., 2000) ซึ่งแนวคิดของ SVR มีพื้นฐานอยู่บนการลดความเสี่ยงเชิงโครงสร้างให้เหลือน้อยที่สุด (Hendayanti et al., 2022) ฟังก์ชันเคอร์เนลใช้ในการจับคู่ข้อมูลอินพุตกับพื้นที่มิติที่ (High dimension data) บนพื้นที่ข้อมูลคุณลักษณะ (Feature space) ช่วยให้ SVR สามารถจัดการความสัมพันธ์แบบไม่เชิงเส้นได้ (Cortes & Vapnik, 1995; Smola & Schölkopf, 2004) รูปที่ 2.5 แสดงแนวทางการสร้างแบบจำลอง SVR โดยนิพจน์ทางคณิตศาสตร์ของแบบจำลอง SVR ที่ใช้เคอร์เนลเชิงเส้น แสดงสมการ 2.2 (Kao et al., 2020; Liu et al., 2017; Sutthison, 2019; Sutthison & Thepchim, 2020) :

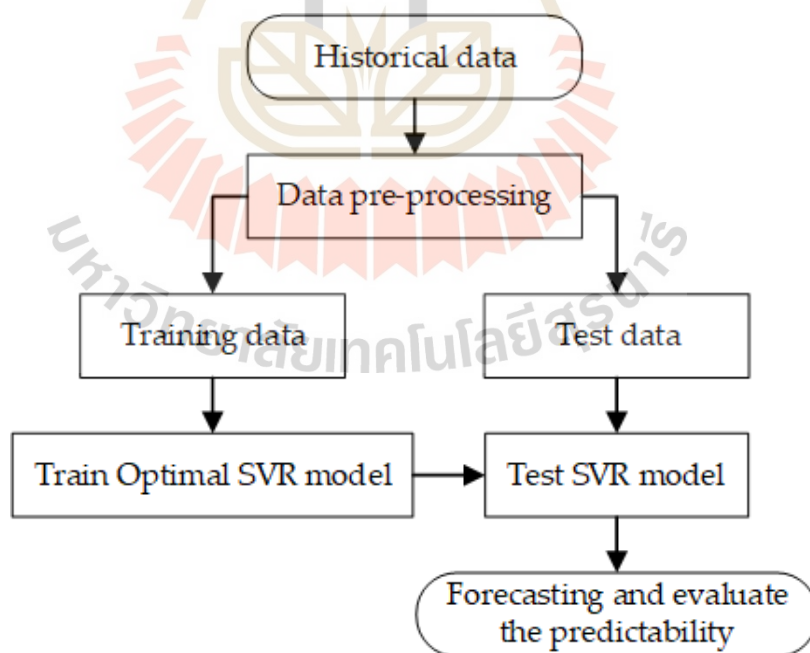
$$\hat{y}^{SVR} = \sum_{i=1}^m (\alpha_i - \alpha_i^*) K(x_i, x_j) + b \quad (2.2)$$

โดยที่  $\hat{y}^{SVR}$  ( $\alpha_i - \alpha_i^*$ ) และ  $b$  หมายถึง ค่าผลลัพธ์ (output), ความแตกต่างระหว่างตัวคูณลากรางจ์ (Lagrange multipliers), และ ค่าคงที่ (bias) ตามลำดับ. ฟังก์ชัน kernel สำหรับ SVR แบบเชิงเส้น แสดงด้วย  $K(x_i, x_j)$  เป็นผลคูณของเวกเตอร์  $x_i$  และ  $x_j$  ซึ่งเป็นข้อมูลอินพุต แสดงดังสมการต่อไปนี้ (Sutthison, 2019)

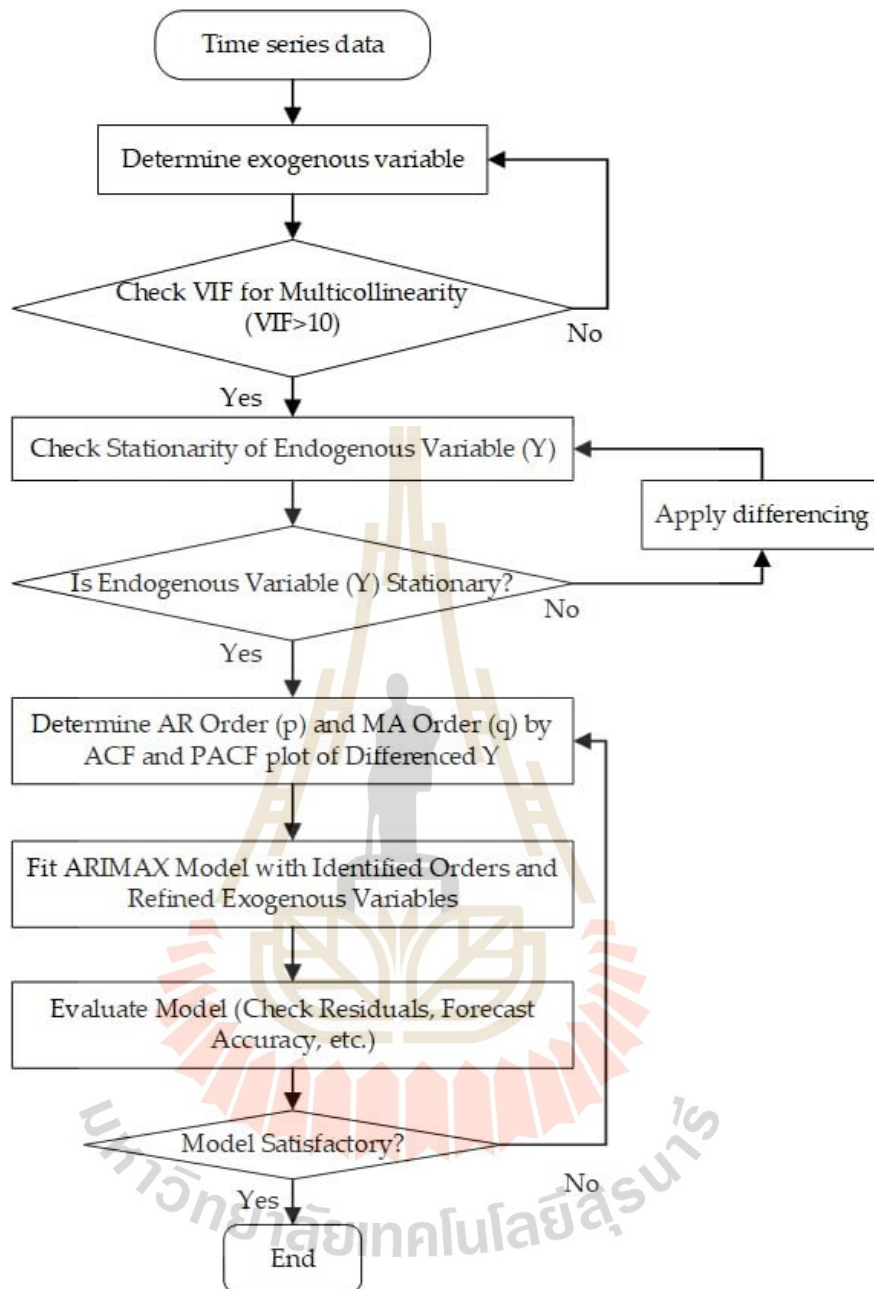
$$K(x_i, x_j) = x_i \cdot x_j \quad (2.3)$$



รูปที่ 2.4 แนวคิดของแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน (Saber et al., 2019)



รูปที่ 2.5 แนวทางการสร้างแบบจำลองซัพพอร์ตเวกเตอร์รีเกรสชัน



รูปที่ 2.6 แนวทางการสร้างแบบจำลอง ARIMAX

### 2.3 ทฤษฎี Autoregressive Integrated Moving Average with Exogenous Variables (ARIMAX)

Autoregressive Integrated Moving Average (ARIMA) เป็นแบบจำลองทางสถิติที่ใช้ในการวิเคราะห์อนุกรมเวลาเพื่อคาดการณ์ค่าในอนาคตจากค่าในอดีต (Box et al., 2015) แบบจำลองนี้

แยกย่อยข้อมูลออกเป็น 3 กระบวนการ ได้แก่ Autoregressive (AR) การคาดการณ์ตัวแปรตามจากค่าในอดีต Integrated (I) ซึ่งทำหน้าที่รักษาเสถียรภาพหรือทำให้ข้อมูลมีความ stationary กระบวนการสุดท้าย Moving Average (MA) ค่าคาดการณ์ตัวแปรตามพิจารณาเกี่ยวกับข้อผิดพลาดในที่อยู่ก่อนหน้า (Pankratz, 2009) องค์ประกอบของแบบจำลองประกอบด้วยพารามิเตอร์ 3 ตัว แทนค่าด้วยจำนวนเต็มเขียนอยู่ในรูป ARIMA(p,d,q) โดย AR(p) แสดงถึง Lag order หรือ Autoregressive ที่มีอันดับที่ p, I(d) แสดงถึงจำนวนครั้งในกระบวนการ Integrated ข้อมูลเพื่อให้ข้อมูลมีคุณสมบัติ stationary, MA(q) แสดงถึง Lag order หรือ Moving average ที่มีอันดับที่ q ข้อมูลอนุกรมเวลามักได้รับอิทธิพลจากเหตุการณ์ที่สำคัญต่าง ๆ เช่น การเปลี่ยนแปลงนโยบายกฎหมาย กฎระเบียบด้านสิ่งแวดล้อม และเหตุการณ์อื่นๆ ที่คล้ายคลึงกัน เหตุการณ์ดังกล่าวเรียกว่า เหตุการณ์การแทรกแซง (intervention events) การรวมตัวแปรภายนอกที่เหมาะสมเข้ากับแบบจำลอง ARIMA ซึ่งถูกเรียกว่าแบบจำลอง ARIMAX ช่วยให้สามารถจับผลกระทบของเหตุการณ์การแทรกแซงดังกล่าว จึงสามารถปรับปรุงประสิทธิภาพการคาดการณ์ได้อย่างมีนัยสำคัญ (Kongcharoen & Kruangpradit, 2013; Ling et al., 2019; Peter & Silvia, 2012) วิธีการนี้มีประโยชน์อย่างยิ่งในบริบทที่ทราบว่าปัจจัยภายนอกมีอิทธิพลต่อข้อมูลอนุกรมเวลา ในขณะเดียวกัน นิพจน์ทางคณิตศาสตร์สำหรับ ARIMAX แสดงดังสมการ 2.4 ซึ่งได้มาจากการรวมนิพจน์ทางคณิตศาสตร์ขององค์ประกอบทั้ง 4 องค์ประกอบเข้าด้วยกัน ได้แก่ AR ซึ่งแสดงด้วยสมการที่ 2.5 I แทนด้วยสมการที่ 2.6 MA แสดงโดยสมการที่ 2.7 และตัวแปรภายนอก (X) แสดงโดยสมการที่ 2.8 (Box et al., 2015; Chodakowska et al., 2021; Ling et al., 2019; Williams, 2001)

$$\Delta^d Y_t = \sum_{i=1}^p \phi_i \Delta^d Y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \beta_k X_{tk} + \varepsilon_t, \quad (2.4)$$

$$Y_t = \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t, \quad (2.5)$$

$$\Delta^d Y_t = (1-B)^d Y_t, \quad (2.6)$$

$$Y_t = \theta_1 \varepsilon_{t-1} + \theta_2 \varepsilon_{t-2} + \dots + \theta_q \varepsilon_{t-q} + \varepsilon_t, \quad (2.7)$$

$$Y_t = \beta_1 X_{t1} + \beta_2 X_{t2} + \dots + \beta_k X_{tk} \quad (2.8)$$

โดยที่  $Y_t$  คือ ค่าของผลลัพธ์ในช่วงเวลาที่  $t^{\text{th}}$   
 $\phi$  คือ ค่าสัมประสิทธิ์ของ AR



$\Delta^d$	คือ	การทำ differencing จำนวน $d$ ครั้ง
$B$	คือ	backshift operator
$\theta$	คือ	ค่าสัมประสิทธิ์ของ MA
$\beta_k$	คือ	ค่าสัมประสิทธิ์ของตัวแปรภายนอก $X_{it}$
$\varepsilon$	คือ	ค่า white noise error term

กรอบแนวคิดของ ARIMAX แสดงในรูปที่ 2.6 หลังจากประมวลผลและเตรียมข้อมูลแล้ว ขั้นตอนถัดไปประกอบด้วย การตรวจสอบความสัมพันธ์เชิงเส้นแบบพหุ (Multicollinearity) ระหว่างตัวแปรภายนอกโดยใช้ VIF หากพบความสัมพันธ์เชิงเส้น ตัวแปรจะถูกลบออกหรือรวมเข้าด้วยกัน จากนั้นจะมีการตรวจสอบความนิ่ง (Stationary) ของตัวแปรภายนอก (Y) โดยใช้การทดสอบ Augmented Dickey–Fuller (ADF) หากผลการทดสอบไม่มีนัยสำคัญทางสถิติแสดงว่าข้อมูลอนุกรมเวลาชุดนั้นมีลักษณะไม่คงที่ ต้องทำการแปลงข้อมูลให้มีลักษณะคงที่ โดยการหาผลต่างของข้อมูล (Differencing) หลังจากข้อมูลมีความนิ่ง พารามิเตอร์ AR (p) และ MA (q) ของแบบจำลอง ARIMAX จะถูกกำหนดจากแผนภาพ Autocorrelation Function (ACF) และ Partial Autocorrelation Function (PACF) ของข้อมูลอนุกรมเวลาที่แปลงแล้ว จากนั้นจะประเมินแบบจำลองโดยดูที่ค่าคลาดเคลื่อนและความแม่นยำในการคาดการณ์

## 2.4 งานวิจัยที่เกี่ยวข้อง

### 2.4.1 การคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์

Ratanavaraha and Jomnonkwao (2015) คาดการณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์จากการใช้พลังงานในภาคการขนส่งของประเทศไทยรวมถึงปัจจัยที่เกี่ยวข้อง โดยเปรียบเทียบ 4 แบบจำลอง ได้แก่ log-linear regression, path analysis, ARIMA, และ curve estimation ซึ่งในการศึกษานี้ใช้ตัวแปรอิสระ 5 ตัวเพื่อคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ที่ปล่อยออกมาจากการใช้พลังงานในการขนส่งประกอบด้วย ขนาดประชากร ผลิตภัณฑ์มวลรวมภายในประเทศ (GDP) และจำนวนยานพาหนะจดทะเบียนขนาดเล็ก ขนาดกลาง และขนาดใหญ่ จากผลการศึกษาพบว่าแบบจำลอง ARIMA มีค่า MAPE น้อยที่สุด ผลการวิเคราะห์ path analysis บ่งชี้ว่า ผลิตภัณฑ์มวลรวมภายในประเทศ (GDP) และจำนวนยานพาหนะจดทะเบียนขนาดใหญ่ ส่งผลกระทบต่อการปล่อยก๊าซคาร์บอนไดออกไซด์

Sutthichaimethee and Ariyasajjakorn (2018) คาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์จากการใช้พลังงานในภาคอุตสาหกรรมในประเทศไทย ในช่วงปีพ.ศ. 2559 - 2573 และ พ.ศ. 2559 - 2588 โดยใช้ข้อมูลประชากรและ GDP ในช่วงปี พ.ศ. 2543 ถึง พ.ศ. 2558



กับแบบจำลอง Autoregressive Integrated Moving Average with Explanatory Variable (ARIMAX) ผลการวิจัยบ่งชี้ว่าประเทศไทยจะมีก๊าซคาร์บอนไดออกไซด์โดยเฉลี่ยสูงขึ้น 14.3541% ในช่วงระยะเวลา 15 ปี และ 31.153 % ในช่วงระยะเวลา 30 ปี โดยใช้ R-Squared ในการวัดประสิทธิภาพโมเดล

Salangam (2022) ได้ศึกษาแนวทางในการคาดการณ์ ปริมาณ ก๊าซคาร์บอนไดออกไซด์ โดยเฉพาะในภาคส่วนอุตสาหกรรมขนส่ง และภาคเศรษฐกิจในประเทศไทย โดยประยุกต์ใช้วิธีการวิเคราะห์การถดถอย (Regression Analysis) และโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) ผู้วิจัยได้เก็บข้อมูล ปริมาณการใช้เชื้อเพลิงของยานพาหนะ จำนวนการถือครองยานพาหนะสะสม จำนวนประชากร GDP รวมถึงปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ จากภาคการขนส่งของประเทศไทยปีพ.ศ. 2552 ถึงปีพ.ศ. 2561 ผลการวิจัยพบว่าตัวแบบการคาดการณ์ด้วยวิธีโครงข่ายประสาทเทียมสามารถคาดการณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ ได้แม่นยำและมีประสิทธิภาพกว่าการวิเคราะห์การถดถอย

Kamoljitprapa and Sookkhee (2022) เสนอแบบจำลอง ARIMA สำหรับการคาดการณ์ก๊าซคาร์บอนไดออกไซด์ซึ่งจำแนกตามภาคเศรษฐกิจในประเทศไทย ประกอบด้วย ภาคการผลิตไฟฟ้า ภาคการขนส่ง ภาคอุตสาหกรรม และภาคเศรษฐกิจอื่น ๆ โดยใช้ข้อมูลการปล่อยก๊าซคาร์บอนไดออกไซด์รายเดือน ตั้งแต่ปีพ.ศ. 2544 ถึงปีพ.ศ. 2563 การสร้างแบบจำลอง และใช้แบบจำลองคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ ในปีพ.ศ. 2564 เพื่อเปรียบเทียบกับข้อมูลจริง โดยใช้ R-square, Adjusted R-square และ AIC ในการประเมินประสิทธิภาพแบบจำลองจากการคาดการณ์ดังกล่าว จากนั้นได้คาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ 10 ปี ข้างหน้า

Ağbulut (2022) ได้ทำการเปรียบเทียบแบบจำลองในการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์และความต้องการพลังงานของภาคการขนส่งในตุรกี โดยใช้ machine learning algorithms 3 เทคนิค ได้แก่ Deep Learning (DL), Support Vector Machine (SVM), และ Artificial Neural Network (ANN) พิจารณาจากค่า R-square, RMSE, MAPE, MBE, RMSE และ MABE โดยมีตัวแปรอินพุต ได้แก่ GDP จำนวนประชากร จำนวนรถจดทะเบียน ระหว่างปีพ.ศ. 2513-2553 ผลการวิจัยพบว่าทั้ง 3 เทคนิคได้ให้ผลลัพธ์ที่น่าพอใจอย่างมากในการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ จากการขนส่งในตุรกี โดยเฉพาะวิธี ANN

Ning et al. (2021) ได้พยายามหาวิธีการที่มีประสิทธิภาพในการคาดการณ์การปล่อยคาร์บอนและนำเสนอมาตรการที่ตรงจุดและมีประสิทธิภาพเพื่อลดการปล่อยก๊าซคาร์บอนไดออกไซด์ โดยวิเคราะห์ข้อมูลการปล่อยก๊าซคาร์บอนไดออกไซด์ในมณฑลและเมือง 4 แห่งของจีน ได้แก่ ปักกิ่ง เหอหนาน กวางตุ้ง และเจ้อเจียง ในแง่ของข้อมูลการปล่อยก๊าซคาร์บอนระหว่าง

ปีพ.ศ. 2540 - 2560 โดยใช้วิธี ARIMA ในการคาดการณ์การปล่อยคาร์บอนและวิเคราะห์แนวโน้มการปล่อยคาร์บอนในอีก 3 ปีข้างหน้าของแต่ละภูมิภาค ซึ่งผลลัพธ์ สามารถให้คำแนะนำสำหรับผู้มีอำนาจตัดสินใจในการกำหนดเป้าหมายการลดการปล่อยคาร์บอนที่เหมาะสม และใช้มาตรการอนุรักษ์พลังงานและลดการปล่อยก๊าซอย่างเหมาะสม

Fatima et al. (2019) ได้ศึกษาความสัมพันธ์ของข้อมูลการก๊าซคาร์บอนไดออกไซด์ในเอเชีย 9 ประเทศได้แก่ ญี่ปุ่น บังคลาเทศ จีน ปากีสถาน อินเดีย ศรีลังกา อิหร่าน สิงคโปร์ และเนปาล กับปัจจัยเชิงประจักษ์ ได้แก่ ความร้อนและการใช้ไฟฟ้า อุตสาหกรรมการผลิต อาคารที่พักอาศัยและอาคารพาณิชย์ การขนส่ง และปัจจัยอื่นๆ ตั้งแต่พ.ศ. 2514 - 2557 จากการตรวจสอบค่าสัมประสิทธิ์สหสัมพันธ์ และได้พยายามหาวิธีคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ ของแต่ละประเทศ โดยเปรียบเทียบแบบจำลอง Simple exponential smoothing (SES) และแบบจำลอง ARIMA ซึ่งข้อมูลตั้งแต่ปี พ.ศ. 2515-2553 ใช้สำหรับการสร้างแบบจำลองและข้อมูลปี พ.ศ. 2554-2557 เพื่อประเมินความถูกต้องของแบบจำลอง พิจารณาความเหมาะสมของแบบจำลองจากค่า FMAE ผลการศึกษาพบว่า ญี่ปุ่น จีน อินเดีย อิหร่าน และสิงคโปร์ เหมาะสมกับแบบจำลอง ARIMA และแบบจำลอง Simple exponential smoothing (SES) เหมาะสมสำหรับปากีสถานและศรีลังกา ในขณะที่เนปาลและบังคลาเทศ ค่า FMAE ของทั้ง 2 แบบจำลองมีค่าใกล้เคียงกัน ดังนั้นแบบจำลองใดแบบจำลองหนึ่งจึงสามารถใช้สำหรับการคาดการณ์ได้

Xu et al. (2019) ได้พยายามตรวจสอบการปล่อยก๊าซคาร์บอนไดออกไซด์ของจีนด้วยแบบจำลอง โครงข่ายประสาทเทียมแบบถดถอยอัตโนมัติไม่เป็นเชิงเส้นร่วมกับข้อมูลอินพุตภายนอก (NARX) โดยใช้ข้อมูลตั้งแต่ปี พ.ศ. 2521 - 2559 ทำการพยากรณ์ไปอีก 33 ปีข้างหน้า โดยการคาดการณ์ผล 3 สถานการณ์ ได้ผลการคาดการณ์ว่าจุดสูงสุดของการปล่อยก๊าซคาร์บอนไดออกไซด์ ของจีนจะเกิดขึ้นในปี พ.ศ. 2572, พ.ศ. 2574 หรือ พ.ศ. 2578 ในระดับ 10.08, 10.78 และ 11.63 พันล้านตัน ผู้วิจัยให้คำแนะนำว่าควรลดการปล่อยก๊าซคาร์บอนไดออกไซด์ที่ได้รับอิทธิพลจาก GDP อย่างเช่น การลดการปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคอุตสาหกรรม ลดการใช้ถ่านหินและเลือกใช้พลังงานที่ปล่อยก๊าซคาร์บอนไดออกไซด์น้อยกว่า

Sahraei et al. (2021) ใช้เทคนิค Multivariate Adaptive Regression Splines (MARS) เพื่อคาดการณ์ความต้องการพลังงานในภาคการขนส่งในตุรกี โดยใช้ชุดข้อมูลในปีพ.ศ. 2543 - 2562 ประกอบด้วยตัวแปร 5 ตัว ได้แก่ GDP, ราคาน้ำมัน, จำนวนประชากร, Ton-Km (หน่วยของการจราจรที่ได้มาจากการบรรทุกน้ำหนักหนึ่งตันในระยะทาง 1 กม.), Vehicle-Km (หน่วยของการจราจรที่ได้มาจากการเคลื่อนที่ของรถยนต์หนึ่งคันตลอด 1 กม.), Passenger-Km (หน่วยการวัดที่แสดงถึงการขนส่งของนักเดินทาง 1 คนโดยโหมดการขนส่งที่ระบุ (ทางอากาศ รถไฟ ถนน ทะเล ทาง

น้ำภายใน ฯลฯ) ประมาณ 1 กม.) คาดการณ์ในช่วงปีพ.ศ. 2563 – 2573 โดยใช้ GR-square, R-square, Adjust R-square, RMSE และ AIC ในการประเมินแบบจำลอง โดยแบบจำลองที่ใช้ตัวแปรอินพุตเป็น Ton-Km และราคาน้ำมันมีประสิทธิภาพในการคาดการณ์สูงสุด

Tawiah et al. (2023) ได้สร้างแบบจำลองเพื่อคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในปากีสถาน โดยวิเคราะห์เปรียบเทียบแบบจำลองอนุกรมเวลาแบบไม่เชิงเส้น ได้แก่ NAR กับแบบจำลองอนุกรมเวลาเชิงเส้น ได้แก่ ARIMA, Exponential Smoothing (ETS), Naïve Approach และ ANN ใช้ข้อมูลปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ในช่วงปีพ.ศ. 2503 – 2561 ในการพัฒนาแบบจำลอง เพื่อคาดการณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ปีพ.ศ. 2562 ถึงปีพ.ศ. 2571 ใช้ RMSE และ MAE ในการวัดประสิทธิภาพของแบบจำลอง ผลการศึกษาแสดงให้เห็นว่าแบบจำลอง NAR เหมาะสมที่สุด

Liu et al. (2017) ใช้ข้อมูลผลิตภัณฑ์มวลรวมภายในประเทศ (GDP) จำนวนประชากร ปริมาณนำเข้าสินค้า ปริมาณส่งออกสินค้า และการใช้พลังงาน ในช่วงปีพ.ศ. 2508 – 2558 ในการพัฒนาแบบจำลองถดถอยเชิงเส้นพหุคูณ (Multiple Linear Regression: MLR), support vector regression (SVR) และ Gated Recurrent Unit Artificial Neural Network (GRU ANN) เพื่อคาดการณ์การใช้พลังงานในจีน ในช่วงปี พ.ศ. 2558 – 2564 โดยใช้ MAPE และ RMSE ในการวัดประสิทธิภาพของแบบจำลอง ผลการวิจัยบ่งชี้ว่าแบบจำลอง Gated Recurrent Unit Artificial Neural Network (GRU ANN) เหมาะสมที่สุด

Thabani and Bonga (2019) พยายามสร้างแบบจำลองและคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในอินเดียโดยใช้แบบจำลอง ARIMA งานวิจัยนี้ใช้ข้อมูลการปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ตั้งแต่พ.ศ. 2503 – 2560 ในการพัฒนาแบบจำลอง โดยใช้ AIC, MAE, RMSE และ MAPE ในการวัดประสิทธิภาพของแบบจำลอง จากนั้นใช้แบบจำลองที่ดีที่สุดคาดการณ์ปริมาณการปล่อยก๊าซคาร์บอนไดออกไซด์ 13 ปีถัดไป หรือช่วงพ.ศ. 2561 – 2573 ผลการวิจัยบ่งชี้ว่าภายในปีพ.ศ. 2573 การปล่อยก๊าซคาร์บอนไดออกไซด์ของอินเดียจะสูงถึง 4.77 ล้านตัน หมายความว่าอินเดียจะยังคงเผชิญกับปัญหาจากภาวะโลกร้อน การเปลี่ยนแปลงของสภาพอากาศ และสิ่งแวดล้อม ผลการศึกษานี้จึงมีความสำคัญต่อรัฐบาลอินเดียสำหรับของวางแผนรับมือระยะกลางและระยะยาว

Faruque et al. (2022) ใช้วิธี Fully modified ordinary least square (FMOLS) ตรวจสอบความสัมพันธ์ระหว่างการปล่อยก๊าซคาร์บอนไดออกไซด์ การใช้พลังงานไฟฟ้า และผลิตภัณฑ์มวลรวมในประเทศ (GDP) ในบังกลาเทศตั้งแต่ปีพ.ศ. 2515 ถึง ปีพ.ศ. 2562 พบว่ามีความสัมพันธ์กันอย่างมีนัยสำคัญทางสถิติ จากนั้นเปรียบเทียบแบบจำลอง convolution neural

network (CNN), CNN long short-term memory (CNN-LSTM), long short-term memory (LSTM), and dense neural network (DNN) ในการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ และประเมินประสิทธิภาพของแบบจำลองโดยใช้ RMSE MAE และ MAPE พบว่า แบบจำลอง DNN มีค่าเมตริกประเมินประสิทธิภาพแบบจำลองต่ำที่สุด

Sun and Liu (2016) เสนอวิธีการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ จาก 3 อุตสาหกรรมหลักและภาคครัวเรือนในประเทศจีนในช่วงปีพ.ศ. 2552 - 2555 โดยอุตสาหกรรมขั้นต้น คือ อุตสาหกรรมทางการเกษตร อุตสาหกรรมหัตถกรรม คือ อุตสาหกรรมเหมืองถ่านหิน อุตสาหกรรมน้ำมัน และอุตสาหกรรมซีเมนต์ อุตสาหกรรมหัตถกรรม คือ อุตสาหกรรมที่เกี่ยวข้องกับการขนส่ง คลังสินค้า และบริการไปรษณีย์ ซึ่งในการศึกษานี้ใช้ข้อมูลการปล่อยก๊าซคาร์บอนไดออกไซด์ และปัจจัยที่เกี่ยวข้องตั้งแต่ปีพ.ศ. 2521 - 2551 ในการพัฒนา 3 แบบจำลอง ได้แก่ แบบจำลองซัพพอร์ตเวกเตอร์แมชชีน (SVM) แบบจำลองเกรย์ (GM) และแบบจำลองโครงข่ายประสาทเทียม (ANN) และเปรียบเทียบโมเดลโดยใช้ค่า MAPE, MaxAPE, MdAPE และ RMSE ผลการวิจัยบ่งชี้ว่าแบบจำลองซัพพอร์ตเวกเตอร์แมชชีน (SVM) มีความแม่นยำในการคาดการณ์มากที่สุด จากนั้นคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์

Ghalandari et al. (2021) ใช้แบบจำลองโครงข่ายประสาทเทียม 2 ประเภท ได้แก่ group method of data handling (GMDH) และ multi-layer perceptron (MLP) ในการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ของประเทศในยุโรป 4 ประเทศ ได้แก่ สหราชอาณาจักร เยอรมนี อิตาลี และฝรั่งเศส ซึ่งใช้ปริมาณการใช้พลังงานชนิดต่าง ๆ เช่น ปริมาณการใช้น้ำมัน ถ่านหิน , ก๊าซธรรมชาติ พลังงานนิวเคลียร์ การใช้พลังงานทดแทน และ ผลิตภัณฑ์มวลรวม ในปีพ.ศ. 2533 ถึงปีพ.ศ. 2561 โดยใช้ พบว่าแบบจำลอง MLP มีค่า R-squared ต่ำกว่า

เพื่อนำเสนอการวิจัยที่เกี่ยวข้องเพิ่มเติม โดยให้มุมมองที่ครอบคลุมเกี่ยวกับวิธีการวิเคราะห์ ผู้วิจัยได้จัดหมวดหมู่ตามผู้เขียน วิธีการที่ใช้ ตัวแปรอิสระ ตัวแปรตาม และภูมิภาคที่แต่ละการศึกษาเกี่ยวข้องสามารถดูภาพรวมได้จากตารางที่ 2.1

#### 2.4.2 การวิเคราะห์สถานการณ์ (Scenarios analysis)

การวิเคราะห์สถานการณ์ หรือ Scenarios analysis เป็นการตรวจสอบและประเมินเหตุการณ์ในอนาคตที่เป็นไปได้โดยการพิจารณาผลลัพธ์ทางเลือก (สถานการณ์) วิธีการนี้ใช้ในการคาดการณ์และทำความเข้าใจผลกระทบของตัวแปรและการตัดสินใจต่าง ๆ ที่มีต่อผลลัพธ์ ซึ่งมักใช้ในการวางแผนเชิงกลยุทธ์ และช่วยในกระบวนการตัดสินใจ วัตถุประสงค์หลักคือการสำรวจผลกระทบของสมมติฐานที่สร้างขึ้นและการตัดสินใจที่แตกต่างกันในแต่ละสถานการณ์ สมมติฐานอาจเป็นอัตรา

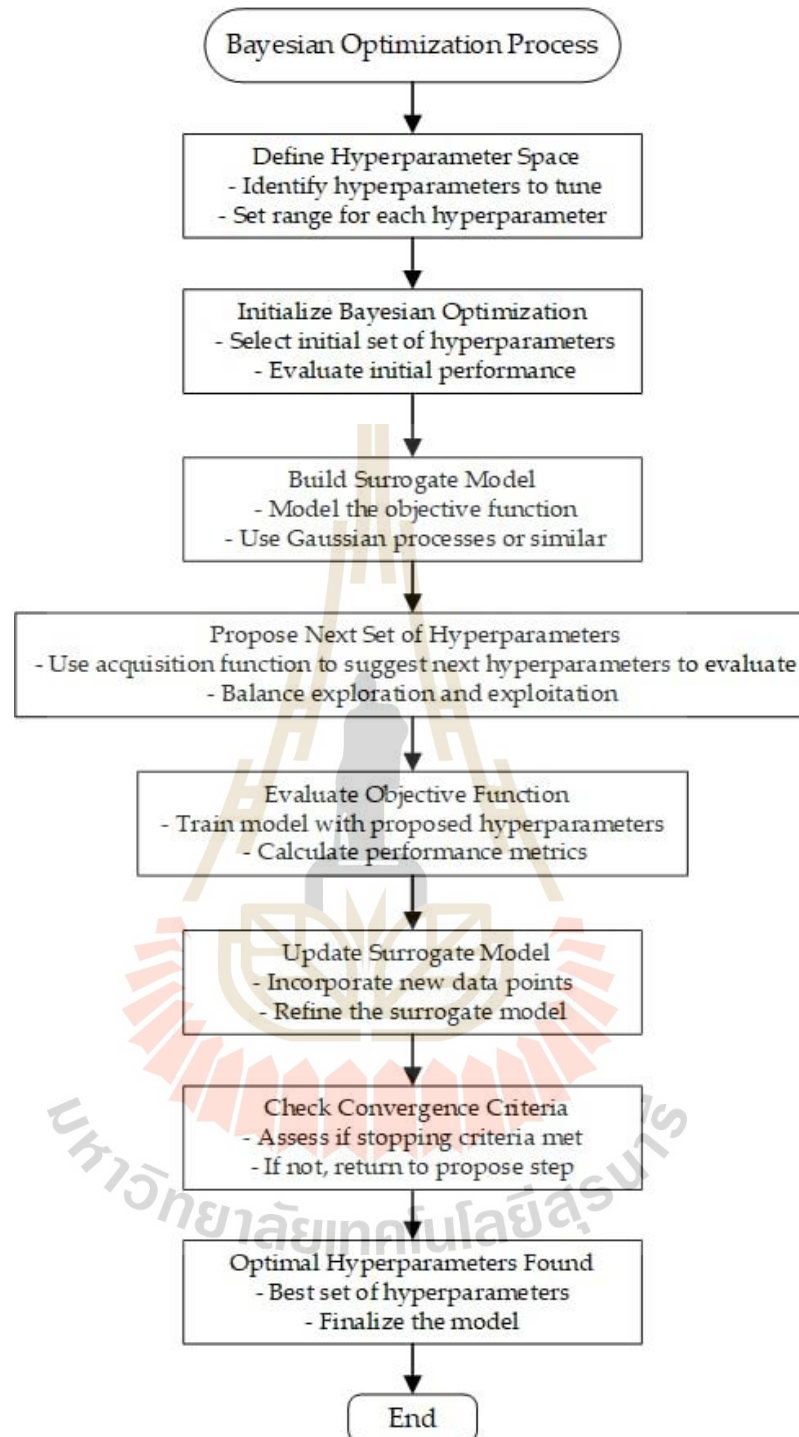
การเติบโตทางเศรษฐกิจ ความก้าวหน้าทางเทคโนโลยี การเปลี่ยนแปลงนโยบาย และปัจจัยที่เกี่ยวข้องอื่นๆ (Kosow & Gaßner, 2007)

Xu et al. (2019) สร้างแบบจำลองโครงข่ายประสาทเทียมแบบถดถอยอัตโนมัติไม่เป็นเชิงเส้นร่วมกับตัวแปรอินพุตภายนอก (Nonlinear Auto Regressive model with exogenous inputs: NARX) ในการคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ จากนั้นได้กำหนดสถานการณ์ 3 สถานการณ์ ประกอบด้วย สถานการณ์ที่ GDP มีการเติบโตสูง และสถานการณ์ที่ GDP มีการเติบโตต่ำซึ่งถูกพัฒนามาจากสถานการณ์มาตรฐาน โดยมีการปรับอัตราการเติบโตของ GDP เพื่อตรวจสอบอิทธิพลจากการเปลี่ยนแปลงดังกล่าว

#### 2.4.3 การหาค่าที่เหมาะสมที่สุดแบบเบย์

ในการศึกษานี้ใช้การหาค่าที่เหมาะสมที่สุดแบบเบย์เป็นวิธีการสำหรับการปรับแต่งไฮเปอร์พารามิเตอร์ของแบบจำลองการเรียนรู้ของเครื่อง (Cho et al., 2021; Dabboor et al., 2023) การหาค่าที่เหมาะสมที่สุดแบบเบย์เป็นวิธีที่มีประสิทธิภาพในการปรับพารามิเตอร์ของแบบจำลองที่ซับซ้อน เช่น ANN และ SVR ให้เหมาะสม สามารถค้นหาพื้นที่ไฮเปอร์พารามิเตอร์ได้อย่างมีประสิทธิภาพโดยการสร้างแบบจำลองความน่าจะเป็น (แบบจำลองตัวแทน: surrogate model) ซึ่งมีประสิทธิภาพมากกว่าการค้นหาตาราง (Grid search) หรือการค้นหาแบบสุ่ม (Random search) (Snoek et al., 2012) กระบวนการปรับไฮเปอร์พารามิเตอร์ให้เหมาะสมโดยใช้การหาค่าที่เหมาะสมที่สุดแบบเบย์ ผู้วิจัยจะต้องกำหนดช่วงการค้นหาไฮเปอร์พารามิเตอร์ของแบบจำลอง และฟังก์ชันวัตถุประสงค์ของแบบจำลองแสดงดังรูปที่ 2.7





รูปที่ 2.7 กระบวนการปรับไฮเปอร์พารามิเตอร์ให้เหมาะสมโดยใช้การหาค่าที่เหมาะสมที่สุดแบบเบย์

ตาราง 2.1 สรุปงานวิจัยที่เกี่ยวข้องกับการใช้พลังงานและการปล่อยก๊าซคาร์บอนไดออกไซด์

ผู้แต่ง	แบบจำลอง	ประเทศ	ตัวแปรอินพุต	ตัวแปรเอาต์พุต	เมตริกวัดประสิทธิภาพ
Ratanavaraha and Jomnonkwao (2015)	log-linear regression, path analysis, ARIMA, curve stimation	ไทย	GDP, จำนวนประชากร, จำนวนรถจดทะเบียนขนาดเล็ก, จำนวนรถจดทะเบียนขนาดกลาง, จำนวนรถจดทะเบียนขนาดใหญ่	CO <sub>2</sub>	R <sup>2</sup> , MSE, MAPE
Sutthichaimethee and Ariyasajjakorn (2018)	ARIMAX	ไทย	จำนวนประชากรและ GDP	CO <sub>2</sub>	R <sup>2</sup>
Salangam (2022)	Regression, ANN	ไทย	GDP, จำนวนประชากร, ปริมาณการใช้น้ำมัน, จำนวนรถจดทะเบียน	CO <sub>2</sub>	MAD, R <sup>2</sup>
Kamoljitprapa and Sookkhee (2022)	ARIMA	ไทย	ข้อมูล CO <sub>2</sub> ในอดีต	CO <sub>2</sub>	R <sup>2</sup> , Adjust R <sup>2</sup> , AIC
Ağbulut (2022)	DL, SVM, ANN	ตุรกี	GDP, จำนวนประชากร, จำนวนรถจดทะเบียน	CO <sub>2</sub>	R <sup>2</sup> , RMSE, MAPE, MBE, MABE



ตารางที่ 2.1 สรุปงานวิจัยที่เกี่ยวข้องกับการใช้พลังงานและการปล่อยก๊าซคาร์บอนไดออกไซด์ (ต่อ)

ผู้แต่ง	แบบจำลอง	ประเทศ	ตัวแปรอินพุต	ตัวแปรเอาต์พุต	เมตริกวัดประสิทธิภาพ
Xu et al. (2019)	NARX	จีน	Industrialization rate, Urbanization rate, GDP, proportions of industry and service sectors, proportions of tertiary sector, จำนวนประชากร, ปริมาณการใช้พลังงาน	CO <sub>2</sub>	MAE
Ning et al. (2021)	ARIMA	จีน	ข้อมูล CO <sub>2</sub> ในอดีต	CO <sub>2</sub>	R <sup>2</sup> , AIC, SC
Sahraei et al. (2021)	MARS	ตุรกี	GDP, ราคาน้ำมัน, จำนวนประชากร, Ton-Km, Vehicle-Km, Passenger-Km	ปริมาณการใช้น้ำมันในภาคการขนส่ง	GR-square R <sup>2</sup> , Adjust R <sup>2</sup> , RMSE, AIC
Tawiah et al. (2023)	ARIMA, ETS, Naïve Approach, MLP, NAR	ปากีสถาน	ข้อมูล CO <sub>2</sub> ในอดีต	CO <sub>2</sub>	RMSE, MAE

ตารางที่ 2.1 สรุปงานวิจัยที่เกี่ยวข้องกับการใช้พลังงานและการปล่อยก๊าซคาร์บอนไดออกไซด์ (ต่อ)

ผู้แต่ง	แบบจำลอง	ประเทศ	ตัวแปรอินพุต	ตัวแปรเอาต์พุต	เมตริกวัดประสิทธิภาพ
Fatima et al. (2019)	SES, ARIMA	ญี่ปุ่น, อิหร่าน, บังคลาเทศ, จีน, ปากีสถาน, อินเดีย, ศรีลังกา, สิงคโปร์, เนปาล	ข้อมูล CO <sub>2</sub> ในอดีต	CO <sub>2</sub>	FMAE
Liu et al. (2017)	MLR, SVR, GRU ANN	จีน	GDP, จำนวนประชากร, ปริมาณนำเข้าสินค้า และปริมาณการส่งออกสินค้า	CO <sub>2</sub>	MAPE, RMSE
Thabani and Bonga (2019)	ARIMA	อินเดีย	ข้อมูล CO <sub>2</sub> ในอดีต	CO <sub>2</sub>	AIC, MAE, RMSE, MAPE
Faruque et al. (2022)	LSTM, CNN, CNN-LSTM, DNN*	บังกลาเทศ	GDP และ การใช้พลังงานไฟฟ้า	CO <sub>2</sub>	MAPE, RMSE, MAE

ตารางที่ 2.1 สรุปงานวิจัยที่เกี่ยวข้องกับการใช้พลังงานและการปล่อยก๊าซคาร์บอนไดออกไซด์ (ต่อ)

ผู้แต่ง	แบบจำลอง	ประเทศ	ตัวแปรอินพุต	ตัวแปรเอาต์พุต	เมตริกวัดประสิทธิภาพ
Sun and Liu (2016)	SVM, GM, ANN	จีน	ปัจจัยที่เกี่ยวกับอุตสาหกรรมหลักและการบริโภคครัวเรือน เช่น GDP, ปริมาณผู้โดยสาร, จำนวนประชากรในเขตเมือง และยอดขายปลีกสินค้าอุปโภคบริโภคทั้งหมด	CO <sub>2</sub>	MAPE, RMSE, MaxAPE, MdAPE
Ghalandari et al. (2021)	GMDH, ANN*	อังกฤษ, เยอรมันนี, อิตาลี และฝรั่งเศส	GDP, ปริมาณการใช้น้ำมัน, ถ่านหิน, ก๊าซธรรมชาติ, พลังงานนิวเคลียร์ และการใช้พลังงานทดแทน	CO <sub>2</sub>	R <sup>2</sup> , MSE
Kour (2023)	ARIMA	แอฟริกาใต้	ข้อมูล CO <sub>2</sub> ในอดีต	CO <sub>2</sub>	RMSE
Rahman and Hasan (2017)	ARIMA	บังกลาเทศ	ข้อมูล CO <sub>2</sub> ในอดีต	CO <sub>2</sub>	RMSE MAE, MPE, MAPE, MASE, AIC, BIC

ตารางที่ 2.1 สรุปงานวิจัยที่เกี่ยวข้องกับการใช้พลังงานและการปล่อยก๊าซคาร์บอนไดออกไซด์ (ต่อ)

ผู้แต่ง	แบบจำลอง	ประเทศ	ตัวแปรอินพุต	ตัวแปรเอาต์พุต	เมตริกวัดประสิทธิภาพ
Li et al. (2020)	GM, DGM, RDGM ARIMA*	China	ข้อมูล CO <sub>2</sub> ในอดีต และ GDP	CO <sub>2</sub>	MAPE
Yang et al. (2018)	SVR	จีน	GDP, ปริมาณการใช้จ่ายเงิน, ถ่านโค้ก, น้ำมันเบนซิน, น้ำมันดีเซล, น้ำมันดิบ, น้ำมันก๊าด, น้ำมันเชื้อเพลิง และปริมาณการใช้ก๊าซธรรมชาติ	CO <sub>2</sub>	MAPE



## บทที่ 3


### วิธีดำเนินการวิจัย

วิธีดำเนินการวิจัยประกอบด้วย 4 องค์ประกอบหลัก ได้แก่ ขั้นตอนการดำเนินการศึกษา เครื่องมือที่ใช้ในการศึกษา การเก็บรวบรวมข้อมูลและการวิเคราะห์ข้อมูล

#### 3.1 ขั้นตอนการดำเนินการศึกษา

การศึกษาครั้งนี้ทำการศึกษาคาดการณ์ปริมาณคาร์บอนไดออกไซด์จากภาคการขนส่งในประเทศไทย มีขั้นตอนการดำเนินการศึกษาแสดงดังรูปที่ 3.1 ซึ่งมีรายละเอียดดังนี้

- 1) ทบทวนวรรณกรรมและงานวิจัยที่เกี่ยวข้องกับการคาดการณ์ปริมาณคาร์บอนไดออกไซด์
- 2) รวบรวมข้อมูลจากหน่วยงานที่เกี่ยวข้อง
- 3) การเตรียมข้อมูล (Data Pre-processing) ให้พร้อมนำเข้าสู่ฐานข้อมูลและนำไปวิเคราะห์
- 4) พัฒนาแบบจำลองซึ่งเกี่ยวข้องกับการปรับพารามิเตอร์และการเลือกคุณสมบัติเพื่อปรับปรุงความแม่นยำและประสิทธิภาพของแบบจำลอง
- 5) ประเมินประสิทธิภาพของแต่ละแบบจำลอง โดยใช้เครื่องมือที่เหมาะสม
- 6) เปรียบเทียบแบบจำลอง เพื่อระบุแบบจำลองที่ดีที่สุด
- 7) ใช้แบบจำลองที่ดีที่สุดในการคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์จากภาคการขนส่งในประเทศไทย
- 8) สรุปผลการวิจัยและเสนอแนะ



### 3.2 เครื่องมือที่ใช้ในการศึกษา

เพื่อระบุแบบจำลองที่ดีที่สุดจากหลายแบบจำลอง จำเป็นต้องมีเครื่องมือวัดประสิทธิภาพของแบบจำลองเพื่อใช้ประกอบการตัดสินใจ ในการศึกษาครั้งนี้เลือกใช้เครื่องมือวัดทางสถิติวิธีค่าคลาดเคลื่อนสัมบูรณ์เฉลี่ย (Mean Absolute Error: MAE) เป็นเมตริกที่วัดขนาดความแตกต่างสัมบูรณ์ระหว่างค่าจริงและค่าคาดการณ์ เขียนได้ดังสมการที่ 3.1 ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Root Mean Squared Error: RMSE) โดยเมตริกนี้วัดขนาดเฉลี่ยของข้อผิดพลาดในการคาดการณ์ที่ทำโดยแบบจำลอง เขียนได้ดังสมการที่ 3.2 และวิธีค่าเฉลี่ยของเปอร์เซ็นต์ความผิดพลาดสัมบูรณ์ (Mean Absolute Percentage Error: MAPE) เป็นเครื่องมือวัด

ทางสถิติที่ประเมินความแม่นยำของการคาดการณ์ของแบบจำลอง โดยการวัดความแตกต่างของเปอร์เซ็นต์เฉลี่ยระหว่างค่าที่คาดการณ์และค่าจริงในชุดข้อมูล MAPE เขียนได้ดังสมการที่ 3.3

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3.1)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (3.2)$$

$$MAPE = \left( \frac{1}{n} \sum_{i=1}^n \frac{|y_i - \hat{y}_i|}{|y_i|} \right) \times 100 \quad (3.3)$$

โดยที่  $y_i$  คือ ค่าจริงที่ลำดับที่  $i$ ,  $\hat{y}_i$  แสดงถึงค่าคาดการณ์ที่ลำดับ  $i$  และ  $n$  คือ จำนวนค่าสังเกต นอกจากนี้ ในการศึกษาก่อนหน้านี้ การประเมินความแม่นยำโดย MAPE ได้ถูกแบ่งออกเป็น 4 ระดับ (Ağbulut, 2022; Bakay & Ağbulut, 2021; Emang et al., 2010) แสดงดังตารางที่ 3.1

ตารางที่ 3.1 แนวทางการแปรผลเมตริก MAPE

ช่วงของค่า MAPE	ความแม่นยำของการคาดการณ์
$\leq 10\%$	มีความแม่นยำในการคาดการณ์สูง
$> 10\%$ และ $\leq 20\%$	มีความแม่นยำในการคาดการณ์ที่ดี
$> 20\%$ และ $\leq 50\%$	ความแม่นยำในการคาดการณ์ที่สมเหตุสมผล
$> 50\%$	ความแม่นยำในการคาดการณ์ที่ไม่ถูกต้อง

นอกจากประเมินประสิทธิภาพด้วยเมตริกดังกล่าว การทดสอบ Harvey, Leybourne Newbold (HLN) ถูกนำมาใช้เพื่อยืนยันว่าความสามารถในการคาดการณ์ของแบบจำลองมีความแตกต่างกันทางสถิติ (Harvey et al., 1997) ซึ่งถูกพัฒนามาจากแบบจำลอง Diebold-Mariano (DM) เหมาะสำหรับข้อมูลขนาดเล็ก (Bianchi et al., 2021; Mizen & Tsoukas, 2012) สมมติฐานว่าง ( $H_0$ ) ของการทดสอบ HLN ระบุว่าไม่มีความแตกต่างในความแม่นยำของการคาดการณ์ระหว่างสองแบบจำลอง ( $E(d_i) = 0$ ) โดยที่  $d_i$  แสดงถึงความแตกต่างของข้อผิดพลาดในการคาดการณ์ระหว่างแบบจำลอง สมมติฐานทางเลือก ( $H_1$ ) ระบุว่าความแม่นยำของการคาดการณ์ระหว่างสองแบบจำลองมีความแตกต่างกันอย่างมีนัยสำคัญทางสถิติ ( $E(d_i) \neq 0$ )



### 3.3 การเก็บรวบรวมข้อมูล

ในการศึกษาครั้งนี้ได้ทำการเปรียบเทียบวิธีคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคการขนส่งในประเทศไทย โดยใช้ชุดข้อมูลระหว่างปีพ.ศ. 2536 ถึง พ.ศ.2565 โดยข้อมูลที่รวบรวมเพื่อการศึกษาครั้งนี้เป็นข้อมูลประเภททุติยภูมิทั้งหมด ชุดข้อมูลประกอบด้วย 6 ตัวแปรรายละเอียดแสดงในตารางที่ 3.2

ตารางที่ 3.2 แหล่งที่มาและคำอธิบายตัวแปร

ข้อมูล	แหล่งข้อมูล	คำอธิบาย
CO <sub>2</sub> (พันตัน)	สำนักงานนโยบายและแผนพลังงาน (EPPO)	การปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคขนส่ง
Population (จำนวนประชากร) (พันคน)	ธนาคารโลก (World Bank)	ประชากรทั้งหมดขึ้นอยู่กับคำจำกัดความของประชากรโดยพหุคูณ ซึ่งนับผู้อยู่อาศัยทั้งหมดโดยไม่คำนึงถึงสถานะทางกฎหมายหรือสัญชาติ ค่าที่แสดงเป็นค่าประมาณกลางปี
GDP (ผลิตภัณฑ์มวลรวม ของประเทศ) (พันล้านบาท)	ธนาคารแห่งประเทศไทย (BOT)	ผลิตภัณฑ์มวลรวมในประเทศแบบปริมาณลูกโซ่ (Gross Domestic Product-Chain Volume Measures)
VK-Passenger (ล้านคัน-กิโลเมตร)		ปริมาณการเดินทางตามการโดยสาร ประกอบด้วยยานพาหนะ 5 ประเภท ได้แก่ รถยนต์นั่งไม่เกิน 7 คน รถยนต์นั่งเกิน 7 คน รถโดยสารขนาดเล็ก รถโดยสารขนาดกลาง และรถโดยสารขนาดใหญ่
VK-Freight (ล้านคัน-กิโลเมตร)	สำนักอำนวยความสะดวก ปลอดภัย กรมทางหลวง	ปริมาณการเดินทางตามการบรรทุก ประกอบด้วยยานพาหนะ 5 ประเภท ได้แก่ รถบรรทุกขนาดเล็ก รถบรรทุก 6 ล้อ รถบรรทุก 10 ล้อ รถบรรทุกพ่วง และรถบรรทุกกึ่งพ่วง
VK-Motorcycle (ล้านคัน-กิโลเมตร)		ปริมาณการเดินทางด้วยรถจักรยานยนต์

### 3.4 การวิเคราะห์ข้อมูล

เมื่อทำการรวบรวมข้อมูลตามเป้าหมายครบแล้ว จากนั้นทำการนำข้อมูลเข้าสู่ฐานข้อมูลทางระบบคอมพิวเตอร์ เพื่อหาแบบจำลองที่เหมาะสมที่สุดในการคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์จากภาคการขนส่งในประเทศไทย ผู้วิจัยได้วิเคราะห์เปรียบเทียบแบบจำลอง 3 แบบจำลอง ได้แก่ ANN SVR และ ARIMAX โดยใช้ MAPE RMSE และ MAE ในการประเมิน



## บทที่ 4

### ผลการวิเคราะห์ข้อมูลและการอภิปรายผล

#### 4.1 สถิติเชิงบรรยาย

ชุดข้อมูลสำหรับคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ในประเทศไทยครอบคลุมช่วงปี พ.ศ. 2536-2565 โดยในการศึกษานี้ใช้ข้อมูลระหว่างปีพ.ศ. 2536 - 2556 เพื่อสร้างแบบจำลอง และใช้ข้อมูลระหว่างปีพ.ศ. 2557 - 2565 เพื่อประเมินประสิทธิภาพของแบบจำลอง จากตารางที่ 4.1 พบว่าตัวแปรทั้งหมดมีค่าความเบ้ (Skewness: SK) อยู่ระหว่าง -0.457 ถึง 0.401 ค่าความโด่ง (Kurtosis: KU) อยู่ระหว่าง -1.460 ถึง -0.283 ซึ่งค่า SK อยู่ในช่วง -2 ถึง 2 และ KU อยู่ในช่วง -7 ถึง 7 บ่งชี้ว่าทุกตัวแปรมีการกระจายตัวแบบปกติ (Byrne, 2010; Garson, 2012; Hair, 2010)


ตารางที่ 4.1 แสดงค่าสถิติเชิงบรรยายของชุดข้อมูล

ตัวแปร	Min	Max	Mean	SD	SK	KU
VK Passenger	32,707.100	135,054.600	84,653.190	31,986.107	0.294	-1.333
VK Freight	37,246.000	104,044.300	70,715.600	20,148.667	0.377	-1.237
VK Motorcycle	2,826.600	43,957.900	33,480.952	5,996.299	0.364	-1.250
Population	57,776.082	71,697.030	66,367.487	4,238.109	-0.457	-0.969
GDP	4,341.000	10,923.300	7,569.903	2,132.466	0.082	-1.460
CO <sub>2</sub>	36,534.390	79,572.550	57,435.830	10,654.976	0.401	-0.283

ในขั้นตอนการเตรียมข้อมูล การตรวจสอบข้อมูลสูญหาย (Missing data) ในทุกตัวแปรได้รับการดำเนินการและไม่พบข้อมูลที่สูญหาย จากนั้นใช้วิธี Z-score ตรวจสอบค่าผิดปกติ (Outlier) โดยการคำนวณค่า Z-score สำหรับทุกตัวแปร และพิจารณาว่าข้อมูลใดที่มีค่า Z-score เกินกว่าขีดจำกัด  $\pm 3$  อาจเป็นค่าผิดปกติ ผลการวิเคราะห์พบว่าไม่มีค่าผิดปกติในชุดข้อมูลนี้ ผลลัพธ์เหล่านี้แสดงให้เห็นว่าข้อมูลครบถ้วนและไม่มีค่าผิดปกติ ซึ่งทำให้ชุดข้อมูลนี้เหมาะสมสำหรับการวิเคราะห์ต่อไป

## 4.2 แบบจำลอง ANN

การเลือกไฮเปอร์พารามิเตอร์สำหรับแบบจำลอง ANN ได้รับการปรับให้เหมาะสมโดยใช้การหาค่าเหมาะที่สุดแบบเบย์ (Bayesian optimization) โดยกำหนดฟังก์ชันวัตถุประสงค์เพื่อลดค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE) ให้เหลือน้อยที่สุด โดยใช้ช่วงการค้นหาไฮเปอร์พารามิเตอร์ที่



รูปที่ 4.1 แผนภาพการหาค่าที่เหมาะสมที่สุดสำหรับ ANN

กำหนดไว้ล่วงหน้าดังที่ระบุไว้ในตารางที่ 4.2 เมื่อดำเนินการปรับแต่งไฮเปอร์พารามิเตอร์โดยใช้การหาค่าเหมาะที่สุดแบบเบย์ อัลกอริทึมจะเลือกชุดของค่าไฮเปอร์พารามิเตอร์ที่ลดช่วงความเชื่อมั่นด้านบนของแบบจำลองวัตถุประสงค์ MSE แทนที่จะเป็นชุดที่ลด MSE ให้เหลือน้อยที่สุด กระบวนการหาค่าเหมาะที่สุดแสดงดังรูปที่ 4.1 โดยในการวนซ้ำครั้งที่ 20 แสดงถึงชุดของไฮเปอร์พารามิเตอร์ที่มี MSE น้อยที่สุด ในขณะที่การวนซ้ำครั้งที่ 16 แสดงถึงชุดของไฮเปอร์พารามิเตอร์ที่ดีที่สุด ซึ่งมีค่า MSE ที่  $12.320 \times 10^7$  สถาปัตยกรรม ANN ที่ได้รับการปรับปรุงให้เหมาะสมนั้นประกอบด้วย ชั้นซ่อนตัว 1 ชั้นขนาด 7 นิวรอน โดยใช้ฟังก์ชัน ReLU เป็นฟังก์ชันกระตุ้น (Activation function) และค่าสัมประสิทธิ์ regularization ที่ 826.227 การกำหนดไฮเปอร์พารามิเตอร์ดังกล่าว ส่งผลให้แบบจำลองมีประสิทธิภาพการคาดการณ์ MAPE, RMSE และ MAE เป็น 6.395, 5054.005 และ 4259.170 ตามลำดับ

ตารางที่ 4.2 ช่วงการค้นหาไฮเปอร์พารามิเตอร์สำหรับ ANN

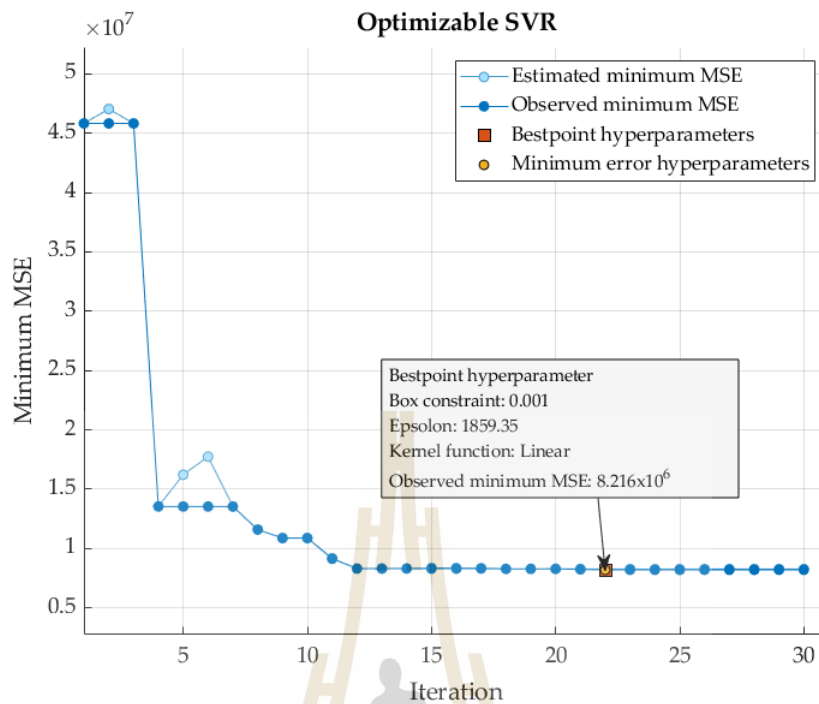
ไฮเปอร์พารามิเตอร์	ช่วงการค้นหา
จำนวนชั้น	1-3
ขนาดของชั้นที่ 1	1-300
ขนาดของชั้นที่ 2	1-300
ขนาดของชั้นที่ 3	1-300
ฟังก์ชันกระตุ้น	ReLU, Tanh, Sigmoid, None
ค่าสัมประสิทธิ์ regularization	$4.7619 \times 10^{-7}$ -4761.9048

### 4.3 แบบจำลอง SVR

การเลือกไฮเปอร์พารามิเตอร์สำหรับแบบจำลอง SVR ได้รับการปรับให้เหมาะสมโดยใช้การหาค่าเหมาะที่สุดแบบเบส โดยมีฟังก์ชันวัตถุประสงค์เพื่อลด MSE ให้เหลือน้อยที่สุด เช่นเดียวกับแบบจำลอง ANN ตารางที่ 4.3 แสดงช่วงการค้นหาไฮเปอร์พารามิเตอร์สำหรับแบบจำลอง SVR โดยในการวนซ้ำครั้งที่ 22 แสดงถึงจุดที่ดีที่สุดและจุดที่มีค่า MSE น้อยที่สุด แสดงดังรูปที่ 4.2 โดยมีค่า MSE  $8.216 \times 10^6$  จากการหาค่าที่เหมาะสมที่สุดแบบเบส ไฮเปอร์พารามิเตอร์ที่ถูกเลือกสำหรับแบบจำลอง SVR ได้แก่ ฟังก์ชันเคอร์เนลเชิงเส้น box constraint (C) ที่ 0.001 และ ค่าเอปไซลอน 1859.835 การประเมินประสิทธิภาพแบบจำลอง SVR พบว่ามีค่า MAPE, RMSE และ MAE ที่ 7.628%, 6193.925 และ 4865.085 ตามลำดับ

ตารางที่ 4.3 ช่วงการค้นหาไฮเปอร์พารามิเตอร์สำหรับ SVR

ไฮเปอร์พารามิเตอร์	ช่วงการค้นหา
Box constraint (C)	0.001-1000
เอปไซลอน (epsilon: $\epsilon$ )	7.3489-734887.3239
ฟังก์ชันเคอร์เนล (Kernel function)	Gaussian, linear, quadratic, cubic



รูปที่ 4.2 แผนภาพการหาค่าที่เหมาะสมที่สุดสำหรับ SVR

#### 4.4 แบบจำลอง ARIMAX

ตัวแปรภายนอกทั้งหมดในชุดข้อมูลสำหรับสร้างแบบจำลองมีค่า VIF มากกว่า 10 ซึ่งบ่งบอกถึงความสัมพันธ์เชิงเส้นแบบพหุ เพื่อแก้ไขปัญหานี้ จึงมีการใช้การถดถอยแบบขั้นตอน (Stepwise regression) สำหรับการเลือกตัวแปรเพื่อลดความสัมพันธ์เชิงเส้นแบบพหุ พบว่ามีเพียงตัวแปร VK—Freight ถูกเลือกเป็นตัวแปรภายนอก จากนั้นทำการทดสอบความนิ่งของข้อมูลโดยใช้การทดสอบ Augmented Dickey–Fuller (ADF) ผลการทดสอบในตารางที่ 4.4 แสดงให้เห็นว่าหลังจากการหาผลต่าง 1 ครั้ง ค่า p-value น้อยกว่า 0.05 ปฏิเสธสมมติฐานว่างว่าข้อมูลมีลักษณะไม่นิ่ง บ่งชี้ว่าพารามิเตอร์  $d$  มีค่า 1 สำหรับการกำหนดพารามิเตอร์  $p$  และ  $q$  ถูกพิจารณาจากแผนภาพคอเรลโรแกรม (Correlogram) ของค่าสหสัมพันธ์ในตัวเอง (Autocorrelation function : ACF) และ สหสัมพันธ์ในตัวเองบางส่วน (Partial autocorrelation function : PACF) ของข้อมูลที่มีลักษณะนิ่งแล้ว แสดงดังรูปที่ 4.4 แผนภาพ PACF แสดง spike ที่ lag 1 เช่นเดียวกับ แผนภาพ ACF ในรูปที่ 4.3 ซึ่งบ่งชี้ว่าพารามิเตอร์  $p$  และ  $q$  มีค่าเท่ากับ 1 เมื่อรวมองค์ประกอบที่ได้จากการสังเกตซึ่งประกอบด้วย AR(1) I(1) และ MA(1) แบบจำลองที่ได้คือ ARIMA(1,1,1) การตรวจสอบความเหมาะสมของแบบจำลอง (Diagnostic checking) เมื่อพิจารณาแผนภาพ ACF ของค่าคงเหลือจากรูปที่ 4.5 ไม่พบค่าใดอยู่นอกขอบเขตความเชื่อมั่น บ่งชี้ว่าค่าคลาดเคลื่อนมีลักษณะสุ่ม ไม่แสดงความสัมพันธ์อัตโนมัติที่มีนัยสำคัญ ในขณะเดียวกัน แผนภาพ Q-Q ในรูปที่ 4.6 แสดงให้เห็นว่าค่าคลาดเคลื่อนมีการแจกแจงใกล้เคียงกับ

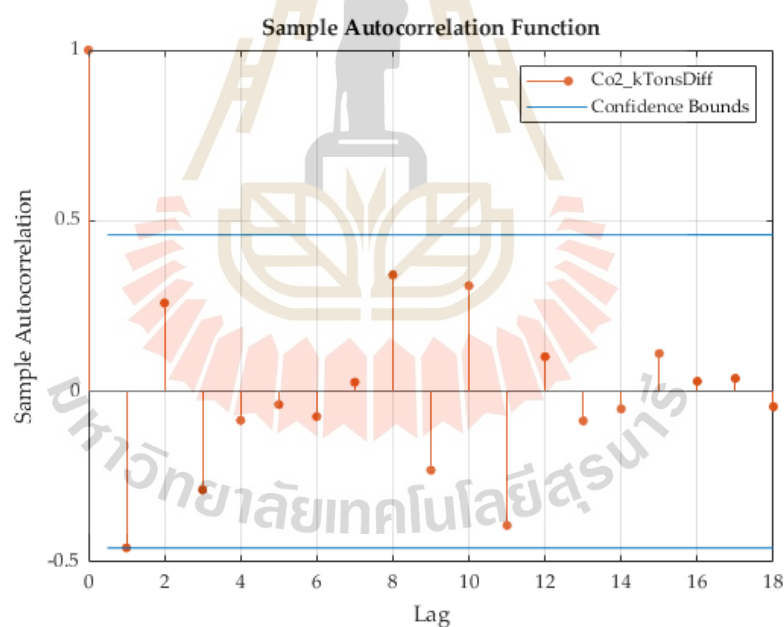


การแจกแจงปกติ การตรวจสอบดังกล่าว บ่งชี้ว่าแบบจำลองมีความน่าเชื่อถือ นอกจากนี้ ผลการประเมินประสิทธิภาพของแบบจำลอง ARIMAX มีค่า MAPE, RMSE และ MAE เท่ากับ 9.286, 7916.483 และ 6775.431 ตามลำดับ

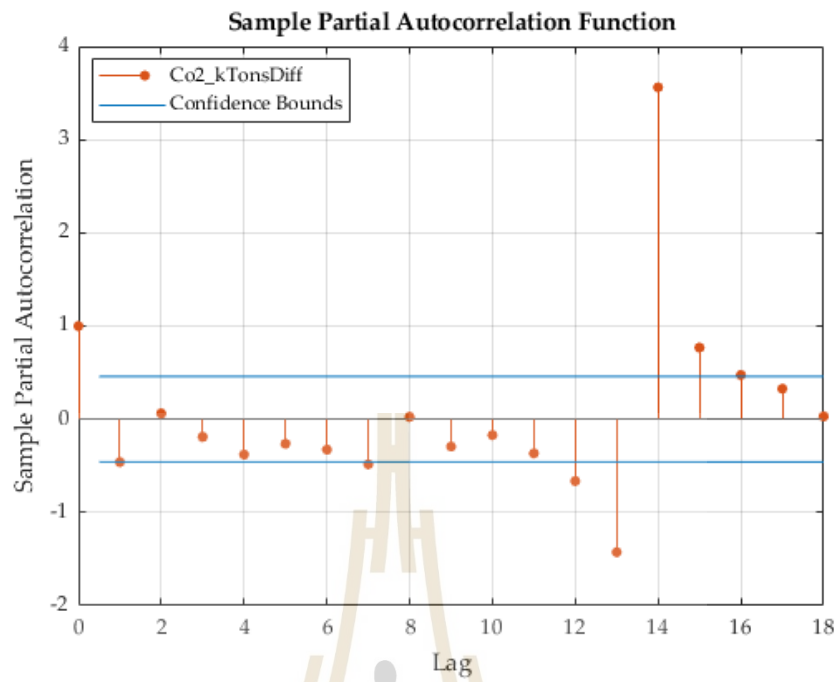
ตารางที่ 4.4 ผลการทดสอบ ADF

ADF test	No difference	1 <sup>st</sup> difference
Null rejected	False	True
P-Value	0.9220	0.0031
Test statistic	1.0927	-3.2928
Critical value	-1.9524	-1.9531
Significance level	0.05	0.05

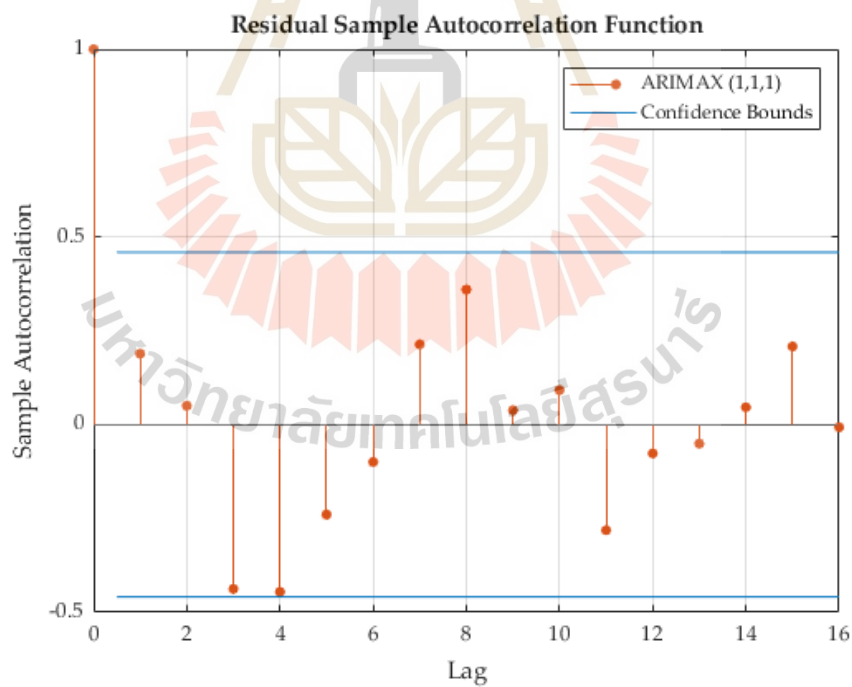
หมายเหตุ สมมติฐานว่าง: ข้อมูลอนุกรมเวลามีลักษณะไม่นิ่ง



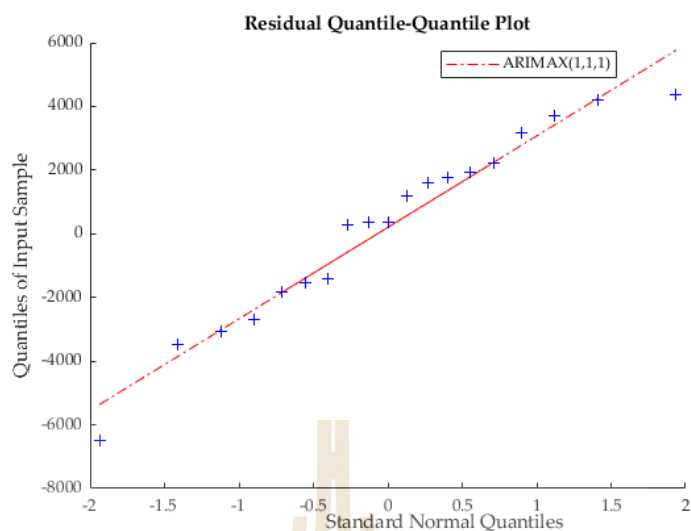
รูปที่ 4.3 แผนภาพ ACF ของข้อมูลที่มีลักษณะนิ่งแล้ว



รูปที่ 4.4 แผนภาพ PACF ของข้อมูลที่มีลักษณะนิ่งแล้ว



รูปที่ 4.5 แผนภาพ ACF ของค่าคงเหลือของแบบจำลอง ARIMAX (1,1,1)



รูปที่ 4.6 แผนภาพ Q-Q ของค่าคงเหลือของแบบจำลอง ARIMAX (1,1,1)

#### 4.5 ผลการทดสอบ HLN

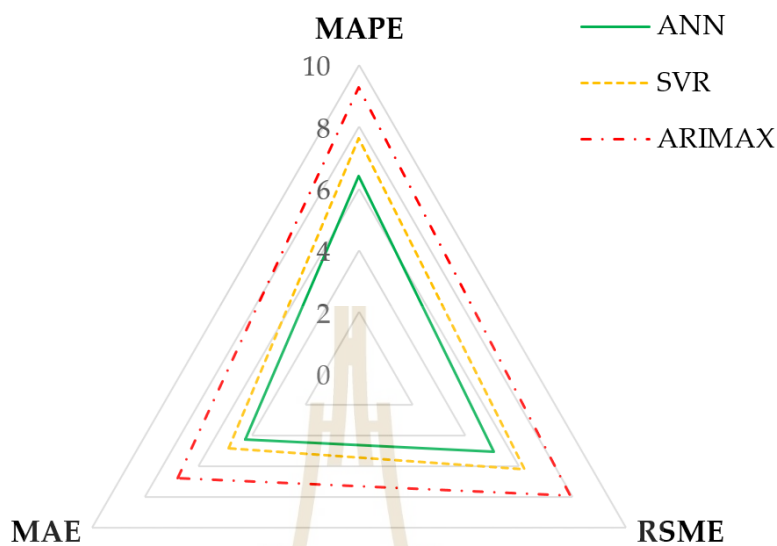
ผลการทดสอบ HLN ในตารางที่ 4.5 แสดงถึงการปฏิเสธสมมติฐานว่างที่กำหนดว่าความแม่นยำในการคาดการณ์ระหว่างแบบจำลองไม่แตกต่างกัน อย่างมีนัยสำคัญทางสถิติในทุกคู่เปรียบเทียบ สำหรับการเปรียบเทียบระหว่าง ANN และ SVR สมมติฐานว่างถูกปฏิเสธที่ระดับนัยสำคัญ 5% (ค่าสถิติ HLN = 4.182\*\*) ซึ่งบ่งบอกถึงความแตกต่างที่มีนัยสำคัญในความแม่นยำในการคาดการณ์ ในทำนองเดียวกัน สำหรับการเปรียบเทียบระหว่าง ANN และ ARIMAX สมมติฐานว่างจะถูกปฏิเสธที่ระดับนัยสำคัญ 1% (ค่าสถิติ HLN = 12.221\*\*\*) ซึ่งแสดงให้เห็นความแตกต่างที่มีนัยสำคัญ นอกจากนี้ การเปรียบเทียบระหว่าง SVR และ ARIMAX ยังนำไปสู่การปฏิเสธสมมติฐานว่างที่ระดับนัยสำคัญ 5% (ค่าสถิติ HLN = 3.692\*\*) ผลลัพธ์ดังกล่าว บ่งชี้ว่าความแม่นยำในการคาดการณ์ของแบบจำลอง ANN, SVR และ ARIMAX นั้นแตกต่างกันอย่างมีนัยสำคัญทางสถิติ

ตารางที่ 4.5 ผลการทดสอบ HLN

แบบจำลอง	ANN	SVR	ARIMAX
ANN	—	4.182**	12.221***
SVR	4.182**	—	3.692**
ARIMAX	12.221***	3.692**	—

หมายเหตุ \*, \*\*, และ \*\*\* แสดงถึงนัยสำคัญที่ระดับ 10%, 5% และ 1% ตามลำดับ

#### 4.6 การเปรียบเทียบประสิทธิภาพแบบจำลอง



รูปที่ 4.7 แผนภาพเรดาร์ผลการประเมินประสิทธิภาพ

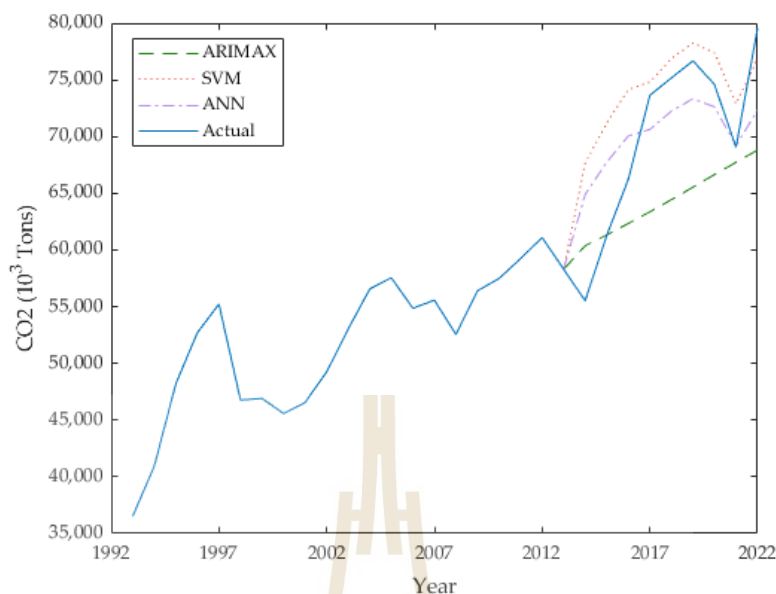
ผลการประเมินประสิทธิภาพแบบจำลองในตารางที่ .6 แสดงให้เห็นถึงค่า MAPE ที่ต่ำกว่า 10% ซึ่งบ่งชี้ถึงความแม่นยำสูงในการคาดการณ์สูงตามที่ระบุในตารางที่ 3.1 แผนภาพเรดาร์แสดงภาพรวมผลการประเมินประสิทธิภาพแบบจำลอง แสดงดังรูปที่ 4.7 โดย RMSE และ MAE จะถูกปรับเป็นหน่วยล้านตัน เพื่อให้เมตริกทั้งหมดมีค่าอยู่ในช่วงเดียวกัน แผนภาพเรดาร์แสดงให้เห็นว่าแบบจำลอง ANN แสดงข้อผิดพลาดน้อยที่สุด โดยมีค่า MAE เท่ากับ 4.259, RMSE เท่ากับ 5.054 และ MAPE เท่ากับ 6.395 ซึ่งบ่งชี้ถึงประสิทธิภาพที่เหนือกว่าในการจับผลกระทบภายนอก ต่อการปล่อยก๊าซคาร์บอนไดออกไซด์ แบบจำลอง SVR จะมีความแม่นยำน้อยกว่าเล็กน้อย โดยมีค่า MAE อยู่ที่ 4.865, RMSE เท่ากับ 6.194 และ MAPE อยู่ที่ 7.628 แต่ยังคงมีประสิทธิภาพที่ดีกว่าแบบจำลอง ARIMAX ซึ่งมีข้อผิดพลาดสูงสุด โดยมีค่า MAE 6.775, RMSE 7.916 และ MAPE 9.286 ซึ่งสะท้อนให้เห็นถึงข้อจำกัดในการปรับตัวให้เข้ากับการเปลี่ยนแปลงกะทันหันที่เกิดจากโรคระบาด ซึ่งสอดคล้องกับรูปที่ 4.8 ผลคาดการณ์จากแบบจำลอง ANN และ SVR มีค่าใกล้เคียงกับค่าจริงมากกว่าแบบจำลอง ARIMAX อย่างเห็นได้ชัด ซึ่งผลการทดสอบ HLN ในตารางที่ 4.5 บ่งชี้ว่าความแม่นยำในการคาดการณ์ของแบบจำลอง ANN SVR และ ARIMAX นั้นแตกต่างกันอย่างมีนัยสำคัญทางสถิติซึ่งเน้นย้ำถึงประสิทธิภาพของแบบจำลอง ANN ในการศึกษาครั้งนี้

ตารางที่ 4.6 ผลการประเมินประสิทธิภาพแบบจำลอง

แบบจำลอง	เมตริกประเมินประสิทธิภาพ		
	MAPE (%)	RSME (พินตัน)	MAE (พินตัน)
ANN	6.395	5054.005	4259.170
SVR	7.628	6193.925	4865.085
ARIMAX	9.286	7,916.483	6,775.431

ประสิทธิภาพของแบบจำลอง ARIMAX ต่ำกว่าแบบจำลองการเรียนรู้ของเครื่อง ซึ่งอาจเป็นอิทธิพลมาจากข้อจำกัดของวิธีวิเคราะห์ เช่น ความสัมพันธ์เชิงเส้นแบบพหุ (Multicollinearity) เป็นผลให้ตัวแปรที่มีความสัมพันธ์กันสูงถูกลบออกจากแบบจำลอง ซึ่งอาจทำให้ไม่สามารถจับความสัมพันธ์ทั้งหมดของข้อมูลที่วิเคราะห์ได้ เช่น ปัจจัยภายนอกหรือการเปลี่ยนแปลงกะทันหันอันเนื่องมาจากตัวแปร เนื่องจากชุดข้อมูลที่ถูกใช้ในการประเมินแบบจำลองครอบคลุมช่วงเวลาที่มีการระบาดของโควิด-19 ซึ่งส่งผลกระทบต่อผลการประเมินโดยเฉพาะอย่างยิ่ง มาตรการล็อกดาวน์ของรัฐบาลแห่งประเทศไทยส่งผลให้การจราจรบนถนนลดลงอย่างมาก สาเหตุหลักมาจากการเปลี่ยนแปลงพฤติกรรมการเดินทาง มีผู้คนจำนวนมากขึ้นที่เปลี่ยนมาทำงานทางไกลหรือเรียนออนไลน์ นอกจากนี้ภาคการขนส่งและโลจิสติกส์ประสบปัญหาการหยุดชะงักอย่างมากอันเนื่องมาจากการปิดชายแดนโดยรวมแล้วสถานการณ์เหล่านี้ถือเป็นเหตุการณ์สำคัญที่ส่งผลกระทบต่อ การปล่อยก๊าซคาร์บอนไดออกไซด์ในภาคการขนส่ง

ในขณะที่แบบจำลอง ANN และ SVR มีประสิทธิภาพที่ใกล้เคียงกัน และมีประสิทธิภาพที่ดีกว่าแบบจำลอง ARIMAX แสดงดังรูปที่ 4.7 เนื่องจากความสามารถในการรับมือกับความซับซ้อนของข้อมูล และความสามารถในการพิจารณาตัวแปรอิสระที่มากกว่า ช่วยให้แบบจำลองการเรียนรู้ของเครื่องสามารถอธิบายผลกระทบเมื่อเกิดเหตุการณ์วิกฤติได้ดีกว่า แบบจำลอง SVR ทนทานต่อค่าคลาดเคลื่อนกว่าวิธีการถดถอยแบบดั้งเดิม มีความสามารถในการจับความสัมพันธ์แบบไม่เชิงเส้นได้โดยใช้ฟังก์ชันเคอร์เนล แบบจำลอง ANN ซึ่งมีจุดแข็งในการจับความสัมพันธ์ที่ซ่อนอยู่ระหว่างตัวแปรอิสระและตัวแปรตาม ส่งผลให้เกิดความซับซ้อนที่เข้าใจได้ยาก ซึ่งมีวิธีการทำงานเหมือนกล่องดำ (Black box) ทำให้ตีความได้ยาก แต่มีการประมาณที่แม่นยำสูง



รูปที่ 4.8 การเปรียบเทียบค่าจริงและค่าที่คาดการณ์ไว้สำหรับการปล่อย CO<sub>2</sub>

ตารางที่ 4.7 การประเมินความแม่นยำของแบบจำลอง ARIMA ในการคาดการณ์ตัวแปรอิสระ

ตัวแปร	แบบจำลอง ARIMA(p,d,q)	MAPE (%)
Populations	(0,2,1)	0.376
GDP	(0,1,0)	3.165
VK—passenger	(0,1,0)	6.024
VK—freight	(0,1,0)	5.692
VK—motorcycle	(0,1,0)	3.210

#### 4.7 การคาดการณ์และการวิเคราะห์สถานการณ์

นโยบาย 30@30 ของประเทศไทยส่งเสริมอุตสาหกรรมการผลิตและการใช้ยานยนต์ไฟฟ้า โดยตั้งเป้าการผลิตยานยนต์ที่ปล่อยมลพิษเป็นศูนย์ ให้ได้อย่างน้อย 30% ของการผลิตยานยนต์ทั้งหมดในปีพ.ศ. 2573 นอกจากนี้ นโยบายดังกล่าวยังให้ความสำคัญกับการส่งเสริมการใช้รถยนต์ไฟฟ้าในรูปแบบการขนส่งต่าง ๆ รวมถึงรถยนต์โดยสาร การขนส่งสินค้า และรถจักรยานยนต์ โดยมีจุดมุ่งหมายเพื่อเปลี่ยนการใช้พลังงานในภาคการขนส่งไปสู่แหล่งพลังงานสีเขียว ซึ่งจะช่วยเพิ่มประสิทธิภาพการใช้พลังงานและลดการปล่อยก๊าซเรือนกระจก (GHG) จากการเผาไหม้เชื้อเพลิงในภาคการขนส่ง เมื่ออ้างอิงแนวคิดจากนโยบายนี้ ผู้วิจัยได้ตั้งสมมติฐานว่าภายในปีพ.ศ. 2573 ปริมาณการเดินทางจากรถสันดาปจะลดลง 3 สถานการณ์เพื่อเปรียบเทียบกับสถานการณ์มาตรฐาน ดังนี้

1. สถานการณ์มาตรฐาน หมายถึง สถานการณ์นี้สันนิษฐานถึงความต่อเนื่องของรูปแบบการใช้งานพาหนะในปัจจุบัน และการพึ่งพาแหล่งพลังงานแบบดั้งเดิม
2. สถานการณ์นโยบาย 1 หมายถึง สถานการณ์ที่คำนึงถึงผลกระทบของนโยบาย 30@30 โดยตั้งสมมติฐานว่า 10% ของปริมาณการเดินทางจะเปลี่ยนไปใช้ยานพาหนะไฟฟ้าภายในปีพ.ศ. 2573
3. สถานการณ์นโยบาย 2 หมายถึง สถานการณ์ที่คำนึงถึงผลกระทบของนโยบาย 30@30 โดยตั้งสมมติฐานว่า 20% ของปริมาณการเดินทางจะเปลี่ยนไปใช้ยานพาหนะไฟฟ้าภายในปีพ.ศ. 2573
4. สถานการณ์นโยบาย 3 หมายถึง สถานการณ์ที่คำนึงถึงผลกระทบของนโยบาย 30@30 โดยตั้งสมมติฐานว่า 30% ของปริมาณการเดินทางจะเปลี่ยนไปใช้ยานพาหนะไฟฟ้าภายในปีพ.ศ. 2573

สำหรับสถานการณ์นโยบายตัวแปร VK—passenger VK—freight และ VK—motorcycle จะถูกปรับเพื่อสะท้อนถึงการเปลี่ยนแปลง ในขณะที่ GDP และจำนวนประชากรยังคงเท่ากับสถานการณ์เกณฑ์มาตรฐาน

ในการศึกษานี้ได้ทำการคาดการณ์ผลลัพธ์ 15 ปีข้างหน้าเพื่อประเมินแนวโน้มระยะยาวของการปล่อยก๊าซคาร์บอนไดออกไซด์ ซึ่งสอดคล้องกับการศึกษาก่อนหน้า ซึ่งใช้ชุดข้อมูล 24 ปีในการคาดการณ์ผลลัพธ์ในช่วง 15 ปีข้างหน้า (Ratanavaraha & Jomnonkwao, 2015) นอกจากนี้ ยังสอดคล้องกับยุทธศาสตร์ระยะยาวในการพัฒนาแบบปล่อยก๊าซเรือนกระจกต่ำของประเทศ (Thailand's Long-Term Low Greenhouse Gas Emission Development Strategy: LT-LEDs) ที่เกี่ยวกับภาคพลังงาน และยังคงครอบคลุมเป้าหมายของแผนที่น่าทางการลดก๊าซเรือนกระจกของประเทศ ปีพ.ศ. 2564 ถึง พ.ศ. 2573 (ONEP, 2022)

แบบจำลอง ANN ถูกนำมาใช้เพื่อคาดการณ์การปล่อยก๊าซคาร์บอนไดออกไซด์ โดยใช้ตัวแปรอิสระที่คาดการณ์จากข้อมูลที่มีอยู่ผ่านแบบจำลอง ARIMA ชุดข้อมูลถูกแบ่งเป็น 70% สำหรับการสร้างแบบจำลอง ในขณะที่อีก 30% ที่เหลือใช้สำหรับการประเมินประสิทธิภาพโดยใช้ MAPE ผลลัพธ์ในตารางที่ 4.7 แสดงให้เห็นถึงค่า MAPE ที่ยอมรับได้สำหรับแบบจำลอง ตามที่กล่าวไว้ก่อนหน้านี้ ผลลัพธ์เหล่านี้บ่งชี้ถึงความเหมาะสมของแบบจำลองดังกล่าวในการคาดการณ์ตัวแปรอิสระที่ใช้สำหรับการคาดการณ์ CO<sub>2</sub> ในอนาคต

จากการวิเคราะห์สถานการณ์ สำหรับสถานการณ์มาตรฐาน ในปีพ.ศ. 2573 คาดการณ์ว่าการปล่อยก๊าซคาร์บอนไดออกไซด์จะสูงถึง 78,514.470 พันตัน ในทางตรงกันข้าม สถานการณ์นโยบาย ซึ่งได้รับอิทธิพลจากนโยบาย 30@30 คาดการณ์ว่าหากสามารถลดการเดินทางจากรถส่วนตัวได้ 10% การปล่อยก๊าซคาร์บอนไดออกไซด์จะลดลงเหลือ 73,515.508 พันตัน หากลดลงไป 20% การปล่อย



ก๊าซคาร์บอนไดออกไซด์จะลดลงเหลือ 68,516.545 และการปล่อยก๊าซคาร์บอนไดออกไซด์จะลดลงถึง 63,517.583 พันตัน หากสามารถลดการเดินทางจากรถส่วนตัวได้ 30% ผลการศึกษาพบว่า การลดปริมาณการเดินทางจากรถส่วนตัวมีผลต่อการลดลงของการปล่อยก๊าซคาร์บอนไดออกไซด์จากเผาไหม้เชื้อเพลิงในภาคการขนส่งอย่างมาก การลดลงนี้เน้นย้ำถึงประสิทธิผลของนโยบายนี้ในการลดการปล่อยก๊าซเรือนกระจกผ่านการเพิ่มประสิทธิภาพการใช้พลังงานและการใช้แหล่งพลังงานหมุนเวียนที่เพิ่มขึ้น ที่สำคัญ การเปลี่ยนไปใช้ยานพาหนะไฟฟ้าที่คาดการณ์ไว้จะช่วยลดการปล่อยก๊าซเรือนกระจกจากการเผาไหม้เชื้อเพลิงได้อย่างมาก โดยเน้นย้ำถึงศักยภาพของนโยบายนี้ในการส่งเสริมความยั่งยืนด้านสิ่งแวดล้อม

ตารางที่ 4.8 ผลการคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ 15 ปีข้างหน้า

ปี พ.ศ.	ค่าคาดการณ์ (พันตัน)
2570	76,339.847
2575	79,864.493
2580	82,880.635

ตารางที่ 4.8 แสดงให้เห็นถึงแนวโน้มการปล่อยก๊าซคาร์บอนไดออกไซด์ที่เพิ่มขึ้น ซึ่งสะท้อนถึงความต่อเนื่องของรูปแบบการใช้ยานพาหนะในปัจจุบัน และการพึ่งพาแหล่งพลังงานแบบดั้งเดิม ผลลัพธ์ของการคาดการณ์ 15 ปีระบุว่าหากไม่มีการแทรกแซงการปล่อยก๊าซคาร์บอนไดออกไซด์จะยังคงเพิ่มขึ้นไปถึง 82,880.635 กิโลตันภายในปีพ.ศ. 2580

## บทที่ 5

### สรุปและข้อเสนอแนะ

การศึกษานี้มุ่งเน้นไปที่ความแม่นยำในการคาดการณ์ปริมาณก๊าซคาร์บอนไดออกไซด์ (CO<sub>2</sub>) จากภาคการขนส่งในประเทศไทย โดยใช้ข้อมูลในช่วงปีพ.ศ. 2536 – 2565 ในการสร้างและประเมินแบบจำลอง ANN SVR และ ARIMAX ซึ่งแบบจำลองการเรียนรู้ของเครื่องแสดงประสิทธิภาพการคาดการณ์ที่เหนือกว่าแบบจำลองสถิติดั้งเดิมอย่าง ARIMAX โดยเฉพาะในช่วงเวลาที่ปริมาณ CO<sub>2</sub> มีแนวโน้มที่ผันผวน ซึ่งแบบจำลอง ML ดังกล่าวได้รวมอินพุตเพิ่มเติม เช่น ประชากร GDP VK passenger VK freight และ VK motorcycle ดังนั้นจึงแสดงผลกระทบที่ลดลงจากการระบาดของ COVID-19 เมื่อเทียบกับ ARIMAX ซึ่งใช้เพียงข้อมูลการปล่อย CO<sub>2</sub> ในอดีต และ VK freight ในการคาดการณ์ อย่างไรก็ตาม แบบจำลองทั้งหมดแสดงความแม่นยำในการคาดการณ์สูง โดยเห็นได้จากค่า MAPE ที่น้อยกว่าหรือเท่ากับ 10% (Ağbulut, 2022; Bakay & Ağbulut, 2021; Emang et al., 2010) เมื่อพิจารณาตัวชี้วัดประสิทธิภาพทั้งหมดซึ่งประกอบด้วย RMSE MAE และ MAPE แบบจำลอง ANN เป็นแบบจำลองที่เหมาะสมที่สุดในบริบทการคาดการณ์ CO<sub>2</sub> ในประเทศไทย อย่างไรก็ตาม การแบ่งข้อมูลสำหรับการสร้างแบบจำลอง การทดสอบเพื่อประเมินประสิทธิภาพของแบบจำลอง และการปรับพารามิเตอร์ให้เหมาะสมกับแบบจำลองมีส่วนสำคัญในการพัฒนาและปรับปรุงความแม่นยำของแบบจำลองในอนาคต แม้ว่าการศึกษาที่ศึกษาเกี่ยวกับการปล่อย CO<sub>2</sub> ที่เกี่ยวข้องกับการขนส่งของประเทศไทยเป็นหลัก แต่วิธีการและข้อค้นพบของการศึกษานี้สามารถนำไปประยุกต์ใช้ในประเทศอื่น ๆ ที่มีบริบทที่คล้ายคลึงกันจากปัจจัยต่าง ๆ เช่น การเติบโตของประชากรผลิตภัณฑ์มวลรวม และปริมาณการเดินทาง ประเทศอื่น ๆ สามารถใช้การศึกษานี้เป็นแนวทางการดำเนินการวิเคราะห์ที่คล้ายกัน ซึ่งต้องปรับให้เหมาะสมกับบริบทเฉพาะของประเทศนั้นๆ แม้ว่าผลลัพธ์จะแตกต่างกันไปขึ้นอยู่กับปัจจัยต่างๆ เช่น ความพร้อมใช้งานของข้อมูลและคุณภาพของข้อมูล การวิเคราะห์สถานการณ์แสดงให้เห็นว่าแนวทางของนโยบาย 30@30 มีศักยภาพที่จะสร้างผลกระทบต่อการลดลงของการปล่อยก๊าซคาร์บอนไดออกไซด์จากการเผาไหม้เชื้อเพลิงในภาคการขนส่ง โดยนโยบายได้สนับสนุนให้มีการนำรถยนต์ไฟฟ้ามาใช้อย่างกว้างขวางและปรับปรุงประสิทธิภาพการใช้พลังงานในภาคการขนส่ง จากการเปรียบเทียบสถานการณ์นโยบายกับสถานการณ์มาตรฐาน ผลการคาดการณ์บ่งชี้ว่าการปล่อยก๊าซคาร์บอนไดออกไซด์ลดลงอย่างมาก นโยบายนี้ไม่เพียงส่งเสริมความยั่งยืนด้านสิ่งแวดล้อมโดยการ

ลดการปล่อยก๊าซเรือนกระจก แต่ยังคงกระตุ้นการเติบโตทางเศรษฐกิจและความก้าวหน้าทางเทคโนโลยี โดยเน้นย้ำถึงบทบาทที่สำคัญของนโยบายในการพัฒนาความยั่งยืนด้านสิ่งแวดล้อมและเศรษฐกิจ ผลการศึกษานี้เป็นเครื่องมือที่มีประโยชน์ในการกำหนดนโยบายที่มีประสิทธิภาพในการลดการปล่อย CO<sub>2</sub> ในภาคการขนส่ง นอกจากนี้ ผลการศึกษายังช่วยให้รู้ถึงความสำคัญของการปรับปรุงแบบจำลองที่มีความแม่นยำในการคาดการณ์ปริมาณ CO<sub>2</sub> ในสถานการณ์ที่มีการผันผวนของปริมาณ CO<sub>2</sub> ตลอดเวลา ทำให้สามารถกำหนดแนวทางในการพัฒนานโยบายที่มีประสิทธิภาพอย่างยั่งยืน และช่วยลดผลกระทบต่อสิ่งแวดล้อมในอนาคต



## รายการอ้างอิง

- Ağbulut, Ü. (2022). Forecasting of transportation-related energy demand and CO<sub>2</sub> emissions in Turkey with different machine learning algorithms. *Sustainable Production and Consumption*, 29, 141-157. doi.org/10.1016/j.spc.2021.10.001
- Bakay, M. S., & Ağbulut, Ü. (2021). Electricity production based forecasting of greenhouse gas emissions in Turkey with deep learning, support vector machine and artificial neural network algorithms. *Journal of Cleaner Production*, 285, 125324. https://doi.org/10.1016/j.jclepro.2020.125324
- Bianchi, D., Büchner, M., & Tamoni, A. (2021). Bond risk premiums with machine learning. *The Review of Financial Studies*, 34(2), 1046-1089.
- Bolan, S., Padhye, L. P., Jasemizad, T., Govarthanam, M., Karmegam, N., Wijesekara, H., . . . Bolan, N. (2024). Impacts of climate change on the fate of contaminants through extreme weather events. *Science of The Total Environment*, 909, 168388. https://doi.org/10.1016/j.scitotenv.2023.168388
- Box, G. E., Jenkins, G. M., Reinsel, G. C., & Ljung, G. M. (2015). *Time series analysis: forecasting and control*. John Wiley & Sons.
- Byrne, B. M. (2010). *Structural equation modeling with AMOS: Basic concepts, applications and programming*. Pearson Education Limited.
- Cho, H. U., Nam, Y., Choi, E. J., Choi, Y. J., Kim, H., Bae, S., & Moon, J. W. (2021). Comparative analysis of the optimized ANN, SVM, and tree ensemble models using Bayesian optimization for predicting GSHP COP. *Journal of Building Engineering*, 44, 103411. https://doi.org/10.1016/j.job.2021.103411
- Chodakowska, E., Nazarko, J., & Nazarko, E. (2021). ARIMA Models in Electrical Load Forecasting and Their Robustness to Noise. *Energies*, 14(23), 7952.
- Cortes, C., & Vapnik, V. (1995). Support-Vector Networks. *Machine learning*, 20(3), 273-297. https://doi.org/10.1007/bf00994018

## รายการอ้างอิง (ต่อ)

- Dabboor, M., Atteia, G., Meshoul, S., & Alayed, W. (2023). Deep Learning-Based Framework for Soil Moisture Content Retrieval of Bare Soil from Satellite Data. *Remote Sensing*, 15(7).
- Emang, D., Shitan, M., Abd Ghani, A. N., & Noor, K. M. (2010). Forecasting with univariate time series models: A case of export demand for peninsular Malaysia's moulding and chipboard. *Journal of Sustainable Development*, 3(3), 157.
- Faruque, M. O., Rabby, M. A. J., Hossain, M. A., Islam, M. R., Rashid, M. M. U., & Muyeen, S. M. (2022). A comparative analysis to forecast carbon dioxide emissions. *Energy Reports*, 8, 8046-8060.  
<https://doi.org/10.1016/j.egy.2022.06.025>
- Fatima, S., Saad, S., Zia, S., Hussain, E., Fraz, T., Mehwish, S., & Khan. (2019). Forecasting Carbon Dioxide Emission of Asian Countries Using ARIMA and Simple Exponential Smoothing Models. *International Journal of Economic and Environment Geology*, 10. <https://doi.org/10.46660/ojs.v10i1.219>
- Garson, D. (2012). *Partial least squares: Regression and path modeling*.
- Ghalandari, M., Forootan Fard, H., Komeili Birjandi, A., & Mahariq, I. (2021). Energy-related carbon dioxide emission forecasting of four European countries by employing data-driven methods. *Journal of Thermal Analysis and Calorimetry*, 144(5), 1999-2008. <https://doi.org/10.1007/s10973-020-10400-y>
- Guh, R.-S. (2002). EFFECTS OF NON-NORMALITY ON ARTIFICIAL NEURAL NETWORK BASED CONTROL CHART PATTERN RECOGNIZER. *Journal of the Chinese Institute of Industrial Engineers*, 19(6), 13-22.  
<https://doi.org/10.1080/10170660209509363>
- Hair, J. F., Black, W. C., Babin, B. J., & Anderson, R. E. (2010). *Multivariate Data Analysis: A Global Perspective: Pearson Education International*. Pearson Education Limited.

## รายการอ้างอิง (ต่อ)

- Hao, W., & Yu, S. (2006). Support vector regression for financial time series forecasting. Knowledge Enterprise: Intelligent Strategies in Product Design, Manufacturing, and Management: Proceedings of PROLAMAT 2006, IFIP TC5 International Conference, June 15–17, 2006, Shanghai, China,
- Harvey, D., Leybourne, S., & Newbold, P. (1997). Testing the equality of prediction mean squared errors. *International Journal of Forecasting*, 13(2), 281-291. [https://doi.org/10.1016/S0169-2070\(96\)00719-4](https://doi.org/10.1016/S0169-2070(96)00719-4)
- Hendayanti, N. P. N., Nurhidayati, M., Soraya, S., & Negara, H. R. P. (2022). Community Purchase Decision Modeling in Bali With Non-Linear Methods. *Matrik Jurnal Manajemen Teknik Informatika Dan Rekayasa Komputer*, 21(3), 721-734. <https://doi.org/10.30812/matrik.v21i3.1740>
- IPCC. (2018). *Global Warming of 1.5°C: Summary for Policymakers*. Retrieved 21 December 2023 from <https://www.ipcc.ch/sr15/chapter/spm/>
- Junhuathon, N., & Chayakulkheeree, K. (2022). Deep-learning-based short-term photovoltaic power generation forecasting using improved self-organization map neural network. *Journal of Renewable and Sustainable Energy*, 14(4).
- Kamoljitprapa, P., & Sookkhee, S. (2022). Forecasting models for carbon dioxide emissions in major economic sectors of Thailand. *Journal of Physics: Conference Series*,
- Kao, Y.-S., Nawata, K., & Huang, C.-Y. (2020). Predicting Primary Energy Consumption Using Hybrid ARIMA and GA-SVR Based on EEMD Decomposition. *Mathematics*, 8(10), 1722.
- Kongcharoen, C., & Kruangpradit, T. (2013). Autoregressive integrated moving average with explanatory variable (ARIMAX) model for Thailand export. 33rd International Symposium on Forecasting, South Korea,
- Kosow, H., & Gaßner, R. (2007). *Methods of future and scenario analysis: overview, assessment, and selection criteria* (Vol. 39). Deutsches Institut für Entwicklungspolitik.

## รายการอ้างอิง (ต่อ)

- Kour, M. (2023). Modelling and forecasting of carbon-dioxide emissions in South Africa by using ARIMA model. *International Journal of Environmental Science and Technology*, 20(10), 11267-11274. <https://doi.org/10.1007/s13762-022-04609-7>
- Li, Y., Wei, Y., & Dong, Z. (2020). Will China Achieve Its Ambitious Goal?—Forecasting the CO<sub>2</sub> Emission Intensity of China towards 2030. *Energies*, 13(11).
- Ling, A., Darmesah, G., Chong, K., & Ho, C. (2019). Application of ARIMAX model to forecast weekly cocoa black pod disease incidence. *Mathematics and Statistics*, 7(4A), 29-40.
- Liu, B., Fu, C., Bielefield, A., & Liu, Y. Q. (2017). Forecasting of Chinese Primary Energy Consumption in 2021 with GRU Artificial Neural Network. *Energies*, 10(10).
- Mizen, P., & Tsoukas, S. (2012). Forecasting US bond default ratings allowing for previous and initial state dependence in an ordered probit model. *International Journal of Forecasting*, 28(1), 273-287. <https://doi.org/10.1016/j.ijforecast.2011.07.005>
- Ning, L., Pei, L., & Li, F. (2021). Forecast of China's Carbon Emissions Based on ARIMA Method. *Discrete Dynamics in Nature and Society*, 2021, 1441942. <https://doi.org/10.1155/2021/1441942>
- NOAA. (2022). *Increase in atmospheric methane set another record during 2021*. Retrieved 21 December 2023 from <https://www.noaa.gov/news-release/increase-in-atmospheric-methane-set-another-record-during-2021>
- ONEP. (2020). *Thailand's Nationally Determined Contribution Roadmap on Mitigation 2021-2030*. Office of Natural Resources and Environmental Policy and Planning.
- ONEP. (2022). *Thailand's fourth biennial update report (BUR4)*. Office of Natural Resources and Environmental Policy and Planning.



## รายการอ้างอิง (ต่อ)

- Peter, Ď., & Silvia, P. (2012). ARIMA vs. ARIMAX—which approach is better to analyze and forecast macroeconomic time series. Proceedings of 30th international conference mathematical methods in economics,
- Rahman, A., & Hasan, M. M. (2017). Modeling and forecasting of carbon dioxide emissions in Bangladesh using Autoregressive Integrated Moving Average (ARIMA) models. *Open Journal of Statistics*, 7(4), 560-566.
- Ratanavaraha, V., & Jomnonkwao, S. (2015). Trends in Thailand CO2 emissions in the transportation sector and Policy Mitigation. *Transport Policy*, 41, 136-146. <https://doi.org/10.1016/j.tranpol.2015.01.007>
- Saber, M., El Rharras, A., Saadane, R., Aroussi, H. K., & Wahbi, M. (2019). Artificial neural networks, support vector machine and energy detection for spectrum sensing based on real signals. *International Journal of Communication Networks and Information Security*, 11(1), 52-60.
- Sahraei, M. A., Duman, H., Çodur, M. Y., & Eyduran, E. (2021). Prediction of transportation energy demand: Multivariate Adaptive Regression Splines. *Energy*, 224, 120090. <https://doi.org/10.1016/j.energy.2021.120090>
- Salangam, S. (2022). Towards a predictor for CO2 emission using regression analysis and an artificial neural network. *The Journal of Industrial Technology : Suan SunandhaRajabhat University*, 10(2), 54-65.
- Schölkopf, B., Smola, A., Williamson, R. C., & Bartlett, P. L. (2000). New Support Vector Algorithms. *Neural computation*, 12(5), 1207-1245. <https://doi.org/10.1162/089976600300015565>
- Shen, S., Du, Y., Xu, Z., Qin, X., & Chen, J. (2023). Temperature Prediction Based on STOA-SVR Rolling Adaptive Optimization Model. *Sustainability*, 15(14).
- Smola, A., & Schölkopf, B. (2004). A Tutorial on Support Vector Regression. *Statistics and Computing*, 14(3), 199-222. <https://doi.org/10.1023/b:stco.0000035301.49549.88>


## รายการอ้างอิง (ต่อ)

- Snoek, J., Larochelle, H., & Adams, R. P. (2012). Practical bayesian optimization of machine learning algorithms. *Advances in neural information processing systems*, 25.
- Sun, W., & Liu, M. (2016). Prediction and analysis of the three major industries and residential consumption CO<sub>2</sub> emissions based on least squares support vector machine in China. *Journal of Cleaner Production*, 122, 144-153.  
<https://doi.org/10.1016/j.jclepro.2016.02.053>
- Sutthichaimethee, P., & Ariyasajakorn, D. (2018). Forecast of Carbon Dioxide Emissions from Energy Consumption in Industry Sectors in Thailand. *Environmental and Climate Technologies*, 22(1), 107-117. <https://doi.org/10.2478/rtuct-2018-0007>
- Sutthison, T. (2019). Application of the Forecasting Technique by hybrid model for Forecasting the Electricity Demands of Rajabhat Universities. *Naresuan University Journal: Science and Technology (NUJST)*, 27(1), 18-31.
- Sutthison, T., & Thepchim, S. (2020). Application of Empirical Mode Decomposition with Box –Jankins and Support Vector Regression for Time Series Forecasting. *Journal of Science and Technology : Ubon Ratchathani University*, 22(1), 59-74.
- Tawiah, K., Daniyal, M., & Qureshi, M. (2023). Pakistan CO<sub>2</sub> Emission Modelling and Forecasting: A Linear and Nonlinear Time Series Approach. *Journal of Environmental and Public Health*, 2023, 5903362.  
<https://doi.org/10.1155/2023/5903362>
- Thabani, N., & Bonga. (2019). Prediction of Emissions in India using ARIMA Models 1.
- Williams, B. M. (2001). Multivariate vehicular traffic flow prediction: Evaluation of ARIMAX modeling. *Transportation Research Record*, 1776(1), 194-200.
- Xu, G., Schwarz, P., & Yang, H. (2019). Determining China's CO<sub>2</sub> emissions peak with a dynamic nonlinear artificial neural network approach and scenario analysis. *Energy Policy*, 128, 752-762. <https://doi.org/10.1016/j.enpol.2019.01.058>

## รายการอ้างอิง (ต่อ)

- Yang, S., Wang, Y., Ao, W., Bai, Y., & Li, C. (2018). Prediction and analysis of CO2 emission in Chongqing for the protection of environment and public health. *International journal of environmental research and public health*, 15(3), 53
- Yun, S., & Zanetti, R. (2021, 1-4 Nov. 2021). Bayesian Estimation with Artificial Neural Network. 2021 IEEE 24th International Conference on Information Fusion (FUSION),
- Zhang, Z., Beck, M. W., Winkler, D. A., Huang, B., Sibanda, W., & Goyal, H. (2018). Opening the black box of neural networks: methods for interpreting neural network models in clinical applications. *Ann Transl Med*, 6(11), 216. <https://doi.org/10.21037/atm.2018.05.32>





ภาคผนวก

## รายชื่อบทความทางวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

ศุภนิดา, น., ธัญญา, จ., วัฒนวงศ์, ร., สัจจกาจ, จ., & อักษรสวรรค์, บ. (2023, 07/08). การวิเคราะห์องค์ประกอบเชิงยืนยันความคาดหวังของผู้ปกครองเกี่ยวกับความปลอดภัยของรถโดยสารสาธารณะสำหรับการเดินทางไปโรงเรียน. การประชุมวิศวกรรมโยธาแห่งชาติ ครั้งที่ 28, 28(0).

Jomnonkwao, S., Banyong, C., Nanthawong, S., Janhuaton, T., Ratanavaraha, V., Champahom, T., & Jongkol, P. (2022). Perceptions of Parents of the Quality of the Public Transport Services Used by Children to Commute to School. *Sustainability*, 14(20).

Janhuaton, T., Ratanavaraha, V., & Jomnonkwao, S. (2024). Forecasting Thailand's Transportation CO2 Emissions: A Comparison among Artificial Intelligent Models. *Forecasting*, 6(2), 462-484.

## ประวัติผู้เขียน

นางสาวธัญญา จันท์หัวโทน เกิดเมื่อวันที่ 4 เดือนพฤษภาคม .ศ. 2542 จังหวัดนครราชสีมา สำเร็จการศึกษาระดับชั้นมัธยมศึกษาจากโรงเรียนห้วยแถลงพิทยาคม ในปีการศึกษา 2559 และสำเร็จการศึกษาระดับปริญญาตรีจากสำนักวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่ง มหาวิทยาลัยเทคโนโลยีสุรนารี ในปีการศึกษา 2563 และในปีการศึกษา 2564 ได้เข้าศึกษาต่อในระดับปริญญาโท สำนักวิชาวิศวกรรมศาสตร์ สาขาวิชาวิศวกรรมขนส่ง หลักสูตรวิศวกรรมโยธา ขนส่ง และทรัพยากรธรณี (พ.ศ. 2563)

