

การทำนายระดับความสูงสำหรับการบินขึ้นและลงจอดของเครื่องบินอย่างมีประสิทธิภาพโดยใช้โครงข่าย GRU

ALTITUDE PREDICTION FOR THE EFFICIENT TAKE-OFF AND LANDING OF AIRCRAFT USING GATED RECURRENT UNIT (GRU)



วิทยานิพนธ์นี้สำหรับการศึกษาดำเนินการตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต  
สาขาวิชาวิศวกรรมอิเล็กทรอนิกส์  
คณะวิศวกรรมศาสตร์  
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง  
พ.ศ. 2564

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ALTITUDE PREDICTION FOR THE EFFICIENT TAKE-OFF AND LANDING OF  
AIRCRAFT USING GATED RECURRENT UNIT (GRU)



A THESIS SUBMITTED IN FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF  
MASTER OF ENGINEERING IN ELECTRONICS ENGINEERING  
SCHOOL OF ENGINEERING  
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG  
2021

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2021

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การทำนายระดับความสูงสำหรับการบินขึ้นและลงจอดของเครื่องบินอย่างมีประสิทธิภาพโดยใช้โครงข่าย GRU
นักศึกษา	นายศิวกร ปวีตรปก
รหัสประจำตัว	62601078
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมอิเล็กทรอนิกส์
พ.ศ.	2564
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.ดร.ภัทรพงษ์ ผาสุขกิจ

### บทคัดย่อ

วิทยานิพนธ์นี้มีจุดมุ่งหมายเพื่อทำนายระดับความสูงในการบินขึ้นและลงจอดของเครื่องบินเฉพาะประเภท A320 ในสนามบินนานาชาติภูเก็ตโดยใช้โครงข่าย GRU ตามการเรียนรู้เชิงลึก ซึ่งสนามบินมีภูมิประเทศเป็นเกาะจึงต้องการความปลอดภัยสูง เนื่องจากปัจจัยต่างๆในลักษณะทางกายภาพของน่านฟ้าจะส่งผลต่อการบินขึ้นและลงจอดของเครื่องบิน ในการวิจัยนี้ได้รวบรวมปัจจัยต่างๆเพื่อการวิเคราะห์ซึ่งรวบรวมข้อมูลตัวอย่าง 1,095 ตัวอย่างเพื่อทำนายระดับความสูงใน 3 ช่วงเวลา ข้อมูลขาเข้าข้อมูลสำหรับการวิเคราะห์ประกอบด้วยคุณสมบัติ 10 อย่างเช่นความเร็วในแนวตั้ง ระดับความสูงของจีพีเอส ค่าความเร็วอากาศ ค่าความเร็วปรากฏบนพื้นโลก ค่าความเร็วอากาศที่รับจากเครื่องวัดโดยตรง อุณหภูมิ ลม ทิศทางลม ตำแหน่งละติจูด และตำแหน่งลองจิจูด โดยแบบจำลองได้รับการออกแบบให้มีการทำงาน 3 ไทม์สเต็ป ใน 1 ไทม์สเต็ป ประกอบด้วย 4 ชั้น: 1 ชั้นข้อมูลขาเข้า 2 ชั้นซ่อน และ 1 ชั้นข้อมูลส่งออก โดยให้ผลลัพธ์ของไทม์สเต็ปก่อนหน้านี้จะถูกอัปเดตเป็นอินพุตสำหรับไทม์สเต็ปถัดไป กำหนดให้การเรียนรู้ของแบบจำลองโครงข่าย GRU มีอัตราการเรียนรู้ (learning rate) 0.1 ดำเนินการ (Epochs) 2,000 รอบ ซึ่งจะได้รับความสำเร็จในการบินขึ้นของชุดฝึกและชุดทดสอบมากกว่า 96% และความสำเร็จในการลงจอดสำหรับชุดฝึกและชุดทดสอบมากกว่า 97%

<b>Thesis</b>	ALTITUDE PREDICTION FOR THE EFFICIENT TAKE-OFF AND LANDING OF AIRCRAFT USING GATED RECURRENT UNIT (GRU)
<b>Student</b>	Mr. Siwagorn Pavitpok
<b>Student ID.</b>	62601078
<b>Degree</b>	Master of Engineering
<b>Program</b>	Electronics Engineering
<b>Year</b>	2021
<b>Thesis Advisor</b>	Assoc. Prof. Dr. Pattarapong Phasukkit

## ABSTRACT

The aim of this research is to predict altitude for take-off and landing on specific aircraft type A320 in Phuket International Airport by using Gated recurrent unit based on deep learning. In which the airport has Island terrain, Therefore, it needs high security. due to various factors in the physical aspect of the airspace will affect the take-off and landing. In this research, various factors were gathered for analysis in which 1095 sample data was collected to predict elevation in 3 timesteps. The information input for analysis consists of 10 features such as vertical speed, GPS altitude, true airspeed, ground speed, indicated airspeed, temperature, wind speed, wind angle, latitude, and longitude. the output previous timestep will be updated to the input for the next timestep. Where the model is designed as a neural network model with 3 timesteps. 1 timestep consists of 4 layers: 1 input layer (neurons = 10), 2 hidden layers (neurons = 3), and 1 output layer (neurons = 1). The epoch = 2000, learning rate = 0.1, which will get the take-off accuracy for training set and test set more than 96% and the landing accuracy for training set and test set more than 97%.

## กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สามารถสำเร็จลุล่วงไปได้ด้วยดี จากความช่วยเหลือและให้คำปรึกษาจากอาจารย์ที่ปรึกษา รศ.ดร.ภัทรพงษ์ ผาสุขกิจ ในการให้คำปรึกษา เสนอแนะ ในการแนะแนวทางในการดำเนินงานวิจัยและวางแผนงาน รวมไปถึงจนถึงการแก้ปัญหาและจัดหาอุปกรณ์ สถานที่เพื่อทำการทดลองวิจัย ทำให้ข้าพเจ้ามีประสบการณ์ ความรู้ เพื่อนำไปใช้ในการทำงานที่ดีมากขึ้น จึงขอขอบพระคุณเป็นอย่างสูง

ข้าพเจ้าขอขอบพระคุณ บิดา มารดา ของข้าพเจ้า ผู้ส่งเสียกำลังทรัพย์ แรงกาย แรงใจ แรงผลักดัน รวมถึงการสนับสนุนในด้านการศึกษาและทุกด้านแก่ข้าพเจ้าเสมอมา ขอขอบพระคุณเป็นอย่างสูง มา ณ โอกาสนี้ด้วย

ข้าพเจ้าขอขอบคุณพี่น้องสมาชิกห้องปฏิบัติการ Burn Lab ที่คอยอำนวยความสะดวกช่วยเหลือและคอยเป็นผู้แลกเปลี่ยนความรู้กับข้าพเจ้า ทำให้ข้าพเจ้าได้เข้าใจในหลายสิ่งมากขึ้น รวมทั้งคอยเป็นแรงผลักดันซึ่งกันและกันมาโดยตลอด

ข้าพเจ้าคาดหวังว่าวิทยานิพนธ์ฉบับนี้อาจเป็นประโยชน์แก่บุคลากรในวงการการศึกษานักเรียนนักศึกษาและผู้สนใจทั่วไป เพื่อนำไปพัฒนาและปรับใช้เป็นผลประโยชน์ต่อสังคมต่อไปในอนาคต

ศิวกร ปวีตรปก

# สารบัญ


	หน้า
บทคัดย่อ .....	I
ABSTRACT .....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VII
สารบัญรูป .....	VIII
บทที่ 1 บทนำ .....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์และจุดมุ่งหมายของการศึกษา .....	2
1.3 ขอบเขตงานวิจัย .....	2
1.4 ประโยชน์ที่คาดว่าจะได้รับ .....	2
1.5 ขั้นตอนการดำเนินงานวิจัย .....	3
1.6 ผลงานวิจัยที่ตีพิมพ์.....	3
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง .....	4
2.1 ความรู้เบื้องต้นเกี่ยวกับการบินขึ้นและลงจอดของเครื่องบิน .....	4
2.1.1 ปัจจัยที่มีผลต่อการบิน.....	4
2.1.2 โมเดลเครื่องบินและพารามิเตอร์ .....	5
2.1.3 การบินขึ้น (Take off).....	7
2.1.4 การลงจอด (Landing).....	8
2.1.5 สถิติการเกิดอุบัติเหตุทางการบินขณะบินขึ้นและลงจอด.....	8
2.2 โครงข่ายประสาทเทียม (Artificial neural network: ANN).....	11
2.2.1 ฟังก์ชันกระตุ้น (Activation function).....	13
2.2.2 โครงสร้างของโครงข่ายประสาทเทียม.....	15
2.2.3 กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม .....	16
2.2.4 โครงข่ายประสาทเทียมแบบไปข้างหน้า (Feedforward neural network) .....	17
2.2.5 กระบวนการแพร่ย้อนกลับ (Backpropagation algorithm) .....	18
2.2.6 ฟังก์ชันการสูญเสีย (Loss function).....	19
2.3 การเรียนรู้เชิงลึก (Deep learning).....	20
2.3.1 โครงข่ายประสาทเชิงลึก (Deep neural network).....	20

## สารบัญ (ต่อ)

	หน้า
2.4 โครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network: RNN).....	21
2.4.1 ปัญหาการพึ่งพาระยะยาว (long term dependency).....	22
2.4.2 โครงข่ายความจำระยะสั้นระยะยาว (Long Short-Term Memory: LSTM).....	23
2.4.3 โครงข่าย GRU (Gated Recurrent Unit: GRU) .....	26
2.4.4 การเชื่อมต่อของชั้นในโครงข่าย GRU .....	29
2.4.5 ข้อดีและข้อเสียของโครงข่ายประสาทเทียมแบบวนกลับ .....	30
2.5 การประเมินประสิทธิภาพ (Performance Evaluation).....	31
บทที่ 3 ระเบียบวิธีวิจัย .....	33
3.1 บทนำ .....	33
3.2 ข้อมูลที่นำมาใช้ในงานวิจัยและแบบจำลอง .....	34
3.3 การเตรียมข้อมูลก่อนนำมาวิจัย(Data Preprocessing).....	35
3.4 การเรียนรู้ข้อมูลของแบบจำลองโครงข่าย GRU.....	37
3.4.1 การจัดเตรียมข้อมูลสำหรับการเรียนรู้ (Data Mining).....	37
3.4.2 การเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน .....	39
3.4.3 การเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน .....	40
3.4.4 ภาพรวมการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน .....	41
3.5 การทำนายผลของแบบจำลองโครงข่าย GRU .....	42
3.5.1 การจัดเตรียมข้อมูลสำหรับการทำนายผล (Post Processing).....	42
3.5.2 การทำนายผลระดับความสูงการบินขึ้นของเครื่องบิน .....	43
3.5.3 การทำนายผลระดับความสูงการลงจอดของเครื่องบิน .....	44
3.5.4 ภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน .....	45
3.6 ประเมินประสิทธิภาพการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน.....	46
บทที่ 4 ผลการดำเนินงาน .....	47
4.1 บทนำ .....	47
4.2 ฐานข้อมูลที่นำมาใช้ในงานวิจัย .....	47
4.3 ผลการเตรียมข้อมูลก่อนนำมาวิจัย.....	49
4.4 ผลการเรียนรู้ข้อมูลของแบบจำลองโครงข่าย GRU .....	50
4.4.1 ข้อมูลสำหรับการเรียนรู้.....	50
4.4.2 ผลการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน .....	50
4.4.3 ผลการเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน .....	52

## สารบัญ (ต่อ)

	หน้า
4.4.4 ภาพรวมผลการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน .....	54
4.5 ผลการทำนายของแบบจำลองโครงข่าย GRU .....	56
4.5.1 ข้อมูลสำหรับการทำนายผล.....	56
4.5.2 ผลการทำนายระดับความสูงการบินขึ้นของเครื่องบิน .....	56
4.5.3 ผลการทำนายระดับความสูงการลงจอดของเครื่องบิน .....	58
4.5.4 ภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน.....	60
บทที่ 5 สรุปผลการดำเนินงาน .....	64
5.1 สรุปผลการทดลอง.....	64
5.2 อภิปรายผลการดำเนินงาน.....	65
เอกสารอ้างอิง .....	66
ประวัติผู้เขียน.....	69



## สารบัญตาราง

	หน้า
ตารางที่ 2.1 ปัจจัยของมนุษย์ที่เป็นสาเหตุของการเกิดอุบัติเหตุ.....	10
ตารางที่ 4.1 ตารางแสดงพารามิเตอร์ของเครื่องบินแอร์บัส A320 ที่ใช้ในการทำนายการบินขึ้นและลง จอดของเครื่องบิน .....	48
ตารางที่ 4.2 แสดงผลการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน .....	52
ตารางที่ 4.3 แสดงผลการเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน .....	54
ตารางที่ 4.4 แสดงภาพรวมผลการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน .....	55
ตารางที่ 4.5 แสดงความน่าเชื่อถือของการทำนายระดับความสูงการบินขึ้นของเครื่องบิน .....	58
ตารางที่ 4.6 แสดงความน่าเชื่อถือของการทำนายระดับความสูงการลงจอดของเครื่องบิน .....	60
ตารางที่ 4.7 ภาพรวมแสดงความน่าเชื่อถือของการทำนายระดับความสูงการบินขึ้นและลงจอด .....	61
ตารางที่ 4.8 แสดงความน่าเชื่อถือของการเรียนรู้และผลการทำนายระดับความสูงการบินขึ้นและลง จอดของเครื่องบิน .....	62

## สารบัญรูป

	หน้า
รูปที่ 2.1 โมเดลเครื่องบิน.....	5
รูปที่ 2.2 กระบวนการบินขึ้นของเครื่องบิน.....	7
รูปที่ 2.3 กระบวนการลงจอดของเครื่องบิน.....	8
รูปที่ 2.4 สถิติการเกิดอุบัติเหตุ.....	9
รูปที่ 2.5 อัตราการรอดชีวิตสำหรับส่วนต่างๆของห้องโดยสาร.....	11
รูปที่ 2.6 แบบจำลองกับการทำงานของเซลล์ประสาทในสมองของมนุษย์.....	11
รูปที่ 2.7 โครงสร้างการทำงานของโครงข่ายประสาทเทียม.....	12
รูปที่ 2.8 ฟังก์ชันซิกมอยด์ (Sigmoid function).....	13
รูปที่ 2.9 ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์(Hyperbolic Tangent Function : Tanh).....	13
รูปที่ 2.10 ฟังก์ชันเรกติไฟต์เชิงเส้นหรือรีลู (Rectified Linear Unit : Relu function).....	14
รูปที่ 2.11 ฟังก์ชันซอฟต์แม็กซ์ (SoftMax Function).....	14
รูปที่ 2.12 โครงข่ายประสาทเทียมแบบชั้นเดียว.....	15
รูปที่ 2.13 โครงข่ายประสาทเทียมแบบหลายชั้น.....	16
รูปที่ 2.14 โครงสร้างของโครงข่ายประสาทเทียมแบบไปข้างหน้า.....	18
รูปที่ 2.15 กระบวนการแพร่ย้อนกลับ.....	18
รูปที่ 2.16 โครงสร้างโครงข่ายประสาทเชิงลึก.....	21
รูปที่ 2.17 โครงข่ายประสาทเทียมแบบวงกลับ.....	21
รูปที่ 2.18 โครงสร้างภายในโครงข่ายความจำระยะสั้นระยะยาว.....	25
รูปที่ 2.19 ตัวอย่างการทำงานภายในของโครงข่าย GRU.....	26
รูปที่ 2.20 โครงสร้างภายในโครงข่าย GRU.....	28
รูปที่ 2.21 การเชื่อมต่อของชั้นโครงข่าย GRU แบบย่อ.....	29
รูปที่ 2.22 การเชื่อมต่อของชั้นโครงข่าย GRU แบบละเอียด.....	30
รูปที่ 3.1 กระบวนการทำงานของงานวิจัย.....	33
รูปที่ 3.2 บริเวณช่วงการบินขึ้นของเครื่องบินจากสนามบินนานาชาติภูเก็ตที่ใช้ในการวิจัย.....	34
รูปที่ 3.3 บริเวณช่วงการลงจอดของเครื่องบินที่สนามบินนานาชาติภูเก็ตที่ใช้ในการวิจัย.....	34
รูปที่ 3.4 แบบจำลองทำนายระดับความสูงของเครื่องบิน.....	35
รูปที่ 3.5 ขั้นตอนการปรับปรุงคุณภาพของข้อมูลก่อนนำมาวิจัย.....	36
รูปที่ 3.6 การกำหนดข้อมูลเป้าหมายการเรียนรู้.....	37
รูปที่ 3.7 ขั้นตอนการจัดเตรียมข้อมูลของแบบจำลองโครงข่าย GRU.....	38
รูปที่ 3.8 การปรับช่วงขอบเขตของข้อมูลในการเรียนรู้.....	39

## สารบัญรูป (ต่อ)

	หน้า
รูปที่ 3.9 ขั้นตอนการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน.....	40
รูปที่ 3.10 ขั้นตอนการเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน.....	40
รูปที่ 3.11 ภาพรวมการเรียนรู้ระดับความสูงของการบินขึ้นและลงจอดของเครื่องบิน.....	41
รูปที่ 3.12 ขั้นตอนการจัดเตรียมข้อมูลสำหรับการทำนายผล.....	42
รูปที่ 3.13 ขั้นตอนการทำนายผลระดับความสูงการบินขึ้นของเครื่องบิน.....	43
รูปที่ 3.14 ขั้นตอนการทำนายผลระดับความสูงการลงจอดของเครื่องบิน.....	44
รูปที่ 3.15 ภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน.....	45
รูปที่ 4.1 ภาพแสดงผลการจัดเตรียมข้อมูลก่อนเข้าสู่แบบจำลอง.....	49
รูปที่ 4.2 กราฟความคลาดเคลื่อนการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบินแต่ละรอบ (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE).....	51
รูปที่ 4.3 กราฟความคลาดเคลื่อนการเรียนรู้ระดับความสูงการลงจอดของเครื่องบินแต่ละรอบ (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE).....	53
รูปที่ 4.4 ตัวอย่างรูปเปรียบเทียบระหว่างผลลัพธ์การทำนายระดับความสูงการบินขึ้นกับระดับความสูงการบินขึ้นที่เกิดขึ้นจริง (ก) ผลลัพธ์การทำนายด้วยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ผลลัพธ์การทำนายด้วยค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) ผลลัพธ์การทำนายด้วยรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE).....	57
รูปที่ 4.5 ตัวอย่างรูปเปรียบเทียบระหว่างผลลัพธ์การทำนายระดับความสูงการลงจอดกับระดับความสูงการลงจอดที่เกิดขึ้นจริง (ก) ผลลัพธ์การทำนายด้วยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ผลลัพธ์การทำนายด้วยค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) ผลลัพธ์การทำนายด้วยรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE).....	59

# บทที่ 1

## บทนำ

ในบทนี้จะกล่าวถึงความเป็นมาและความสำคัญของปัญหา วัตถุประสงค์และจุดมุ่งหมายของการศึกษา ขอบเขตงานวิจัย ประโยชน์ที่คาดว่าจะได้รับ ขั้นตอนการดำเนินงานวิจัย และผลงานวิจัยที่ตีพิมพ์

### 1.1 ความเป็นมาและความสำคัญของปัญหา

เหตุการณ์อุบัติเหตุทางการบินหรือปัจจัยภายนอกที่เกิดขึ้นขณะการบินขึ้นและลงจอดของเครื่องบินที่สนามบินอันเนื่องด้วยสาเหตุหลายประการ อาทิ ภูมิประเทศ ลม และสภาพถนนของสนามบิน สาเหตุเหล่านี้เป็นปัจจัยที่เป็นปัญหามากในปัจจุบัน [1], [2] ตัวอย่างเช่น เหตุการณ์วันที่ 16 กันยายน พ.ศ. 2550 เดินทางจากท่าอากาศยานดอนเมือง มุ่งหน้าสู่สนามบินนานาชาติภูเก็ต สายการบิน บินวัน-ทู-โก เที่ยวบินที่ 269 พร้อมผู้โดยสารและลูกเรือ 130 คน ขณะกำลังลงจอดบริเวณท่าอากาศยานนานาชาติภูเก็ต ทันทีที่แตะพื้นรันเวย์เครื่องเสียการทรงตัว ลื่นไถลออกนอกรันเวย์ ในเหตุการณ์นี้ทำให้มีผู้เสียชีวิต 89 คนและบาดเจ็บ 41 คน [3], [4] เหตุการณ์วันที่ 31 สิงหาคม พ.ศ. 2530 เครื่องบินโบอิง 737 (HS-TBC) ของสายการบินเดินอากาศไทย เที่ยวบินที่ 365 เดินทางจากหาดใหญ่ มุ่งหน้าสู่สนามบินนานาชาติภูเก็ต ได้ประสบอุบัติเหตุตกทะเลขณะกำลังลงจอด ที่บริเวณใกล้กับสนามบินนานาชาติภูเก็ต เหตุการณ์นี้ทำให้มีผู้เสียชีวิต 83 คน [5], [6] เหตุการณ์วันที่ 21 กรกฎาคม พ.ศ. 2540 เครื่องบิน Learjet 31 ทะเบียน 9V-ATD ของสายการบิน สิงคโปร์แอร์ไลน์ เดินทางจากท่าอากาศยานนานาชาติภูเก็ตมุ่งหน้าท่าอากาศยานระนองพร้อมนักบิน 2 ราย ได้ประสบอุบัติเหตุตก เหตุการณ์นี้ทำให้มีผู้เสียชีวิต 2 ราย [7] เหตุการณ์วันที่ 21 กันยายน พ.ศ. 2559 สายการบินไทย TG221 ทะเบียน HS-THB เป็นเครื่องบินชนิด Airbus 350-900 ได้เกิดอุบัติเหตุยางระเบิดเหตุการณ์นี้ไม่มีผู้ใดได้รับบาดเจ็บ [8] และเหตุการณ์วันที่ 10 มีนาคม พ.ศ. 2561 สายการบิน สมาคมการบินสยาม ทะเบียน HS-PMS เป็นเครื่องบิน ชนิด Jabiru J450 เกิดอุบัติเหตุตก ที่ตำบลปากคลอง เหตุการณ์นี้ทำให้มีผู้เสียชีวิต 2 ราย [9] จากเหตุการณ์ที่ยกตัวอย่างมานี้ สามารถอธิบายถึงความเสียหายที่เกิดขึ้นต่อชีวิตอันมีค่าของผู้คนมากมาย เพราะฉะนั้นการป้องกันปัญหาที่เป็นปัจจัยภายนอกที่ส่งผลต่อการบินขึ้นและลงจอดของเครื่องบิน จึงเป็นเรื่องสำคัญ และลดการเกิดอุบัติเหตุทางการบิน เพื่อเพิ่มโอกาสรอดชีวิตให้มากที่สุด ดังนั้นการพัฒนาเทคโนโลยีในการช่วยเหลือเพื่ออำนวยความสะดวกสำหรับการบินขึ้นและลงจอดของเครื่องบิน จึงมีความสำคัญอย่างยิ่งต่อความปลอดภัยของผู้โดยสาร และนักบิน

## 1.2 วัตถุประสงค์และจุดมุ่งหมายของการศึกษา

1. ในการศึกษานี้มีเป้าหมายเพื่อพัฒนาแบบจำลองการทำนายระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินโดยใช้การเรียนรู้เชิงลึก
2. ในการศึกษานี้มีเป้าหมายเพื่อลดอุบัติเหตุทางการบิน
3. ในการศึกษานี้มีเป้าหมายเพื่อต้องการเป็นส่วนหนึ่งในการนำไปพัฒนาต่อยอดในการช่วยเหลือนักบินขณะนำเครื่องบินขึ้นและลงจอด

## 1.3 ขอบเขตงานวิจัย

1. ข้อมูลในการวิจัยเป็นข้อมูลที่มาจากการบินขึ้นและลงจอดของเครื่องบินที่สนามบินนานาชาติภูเก็ต
2. ใช้โครงข่าย GRU (Gated recurrent unit: GRU) ที่พัฒนาจากโครงข่ายประสาทเทียม (neural network: NN) เป็นโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent neural network: RNN)
3. แบบจำลองสร้างด้วยโปรแกรม python (Jupyter Notebook)
4. ทำนายระดับความสูงของเครื่องบินและประเมินค่าความผิดพลาดด้วย ค่าเฉลี่ยกำลังสองสัมบูรณ์ (Mean Absolute Error: MAE), ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error: MSE), รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE)

## 1.4 ประโยชน์ที่คาดว่าจะได้รับ

1. สามารถประยุกต์ใช้เป็นแนวทางการตัดสินใจในการบินขึ้นและลงจอดของเครื่องบิน
2. สามารถนำแบบจำลองไปทำนายระดับความสูงการขึ้นและลงจอดของเครื่องบิน
3. สามารถสร้างแบบจำลองที่มีค่าความผิดพลาดน้อยที่สุด
4. เนื่องจากงานวิจัยเกี่ยวกับการทำนายระดับความสูงการขึ้นและลงจอดของเครื่องบินมีผู้วิจัยน้อย คาดว่าจะเป็นประโยชน์ต่อไปในอนาคต

## 1.5 ขั้นตอนการดำเนินงานวิจัย

การทำนายระดับความสูงสำหรับการขึ้น-ลงของเครื่องบินอย่างมีประสิทธิภาพโดยใช้โครงข่าย GRU (Gated Recurrent Unit : GRU) โดยมีขั้นตอนการดำเนินงานวิจัย ดังนี้

1. ศึกษาและค้นคว้างานวิจัยที่เกี่ยวข้องกับการทำนายระดับความสูงสำหรับการขึ้น-ลงของเครื่องบินโดยใช้โครงข่าย GRU
2. สร้างชุดข้อมูลและออกแบบจำลองเพื่อใช้ในการทำนายระดับความสูง
3. ประยุกต์ใช้แบบจำลองโครงข่าย GRU ในการทำนายระดับความสูงสำหรับการขึ้น-ลงของเครื่องบิน
4. ประเมินผลการทดลองในการทำนายระดับความสูงสำหรับการขึ้น-ลงของเครื่องบิน โดยใช้ประเมินประสิทธิภาพการวัดความผิดพลาดด้วย ค่าเฉลี่ยกำลังสองสัมบูรณ์ (Mean Absolute Error: MAE), ค่าเฉลี่ยความผิดพลาดกำลังสอง (Mean Square Error: MSE), รากที่สองของค่าเฉลี่ยความผิดพลาดกำลังสอง (Root Mean Square Error: RMSE)
5. สรุปผลการทดลองการทำนายระดับความสูงสำหรับการขึ้น-ลงของเครื่องบิน

## 1.6 ผลงานวิจัยที่ตีพิมพ์

Siwagorn Pavitpok and Pattarapong Phasukkit, "ALTITUDE PREDICTION FOR THE EFFICIENT TAKE-OFF AND LANDING OF AIRCRAFT USING GATED RECURRENT UNIT (GRU).", The 7th International Conference on Engineering, Applied Sciences and Technology, Thailand, April 1 – 3, 2021.

## บทที่ 2

### ทฤษฎีที่เกี่ยวข้อง

วิทยานิพนธ์ฉบับนี้มีการประยุกต์ความรู้ในหลายสาขาวิชา ประกอบด้วย ความรู้เบื้องต้นเกี่ยวกับการบินขึ้นและลงจอดของเครื่องบิน โครงข่ายประสาทเทียม (Artificial neural network: ANN) การเรียนรู้เชิงลึก (Deep learning) โครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network: RNN) การประเมินประสิทธิภาพ (Performance Evaluation) ซึ่งทั้งหมดเป็นส่วนหนึ่งของวิชาปัญญาประดิษฐ์ (Artificial Intelligence: AI) สำหรับวิธีการทำนายระดับความสูงสำหรับการบินขึ้นและลงจอดของเครื่องบิน

#### 2.1 ความรู้เบื้องต้นเกี่ยวกับการบินขึ้นและลงจอดของเครื่องบิน

การบินขึ้นและลงจอดของเครื่องบินเป็นขั้นตอนที่อันตรายที่สุดของการบิน ดังนั้นการศึกษาประสิทธิภาพการบินขึ้นและประสิทธิภาพการลงจอด จึงมีความสำคัญอย่างยิ่งสำหรับงานวิจัยนี้ โดยระหว่างกระบวนการบินขึ้นและลงจอดของเครื่องบินมีการพัฒนาอัลกอริทึมที่สามารถทำนายระดับความสูงที่มีความแม่นยำสูง วิธีที่นำเสนอในงานวิจัยนี้มีการวิเคราะห์ระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินทั้งหมดและสามารถคำนวณประสิทธิภาพการทำนายระดับความสูงของการบินขึ้นและลงจอดที่สนามบินนานาชาติภูเก็ตภายใต้สภาพแวดล้อมที่แตกต่างกัน และมีภูมิประเทศเป็นเกาะ โดยอัลกอริทึมของงานวิจัยนี้จะมีการวิเคราะห์โดยละเอียดเกี่ยวกับปัจจัยหลักที่มีผลต่อประสิทธิภาพการบินขึ้นและลงจอด

การบินขึ้นและลงจอดของเครื่องบิน โดยส่วนใหญ่คิดว่าการลงจอดนั้นมีความเสี่ยงสูงกว่าการบินขึ้น แต่ในทางทฤษฎีด้านการบินการบินขึ้นนั้นมีความเสี่ยงมากกว่า ในเชิงเปรียบเทียบการลงจอดสำหรับนักบินนั้นยากกว่าการบินขึ้นเพราะการลงจอดนักบินต้องใช้ทักษะในการบังคับเครื่องบินจากบนอากาศที่มีระดับความสูงลงสู่พื้นดินที่มีพื้นที่แคบ

##### 2.1.1 ปัจจัยที่มีผลต่อการบิน

ตัวอย่างปัจจัยภายนอกที่ส่งผลต่อการบินขึ้นและลงจอดของเครื่องบินล้วนเป็นปัจจัยที่ทำให้นักบินทำงานได้ยากขึ้น

1. สภาพภูมิอากาศ (Climate)
2. ความแรงลม (Wind)
3. สภาพพื้นผิวถนน (runway)

4. ทิศนวิสัย (Visibility)
5. ภูมิประเทศ (terrain)

### 2.1.2 โมเดลเครื่องบินและพารามิเตอร์

งานวิจัยนี้สนใจพารามิเตอร์ของเครื่องบิน A320 เนื่องจากเครื่องบินแอร์บัส A320 เป็นเครื่องบินพาณิชย์ขนาดกลาง ที่มีพิสัยระยะไกลถึงปานกลาง ซึ่งหลายๆสายการบินได้นำมาใช้เป็นเครื่องบินโดยสารในปัจจุบัน ดังแสดงในรูปที่ 2.1



รูปที่ 2.1 โมเดลเครื่องบิน [10]

พารามิเตอร์ของเครื่องบินแอร์บัส A320 ที่นำมาใช้ในงานวิจัยนี้เป็นพารามิเตอร์ที่สำคัญที่ใช้ในการทำนายการลดระดับของเครื่องบิน มีรายละเอียดดังต่อไปนี้

1. ความเร็วในแนวตั้ง (Vertical Speed) บางทีเรียกว่า Vertical velocity indicator (VVI) โดยเครื่องวัดนี้จะรับรู้การเปลี่ยนแปลง ของความกดอากาศ แล้วแสดงค่าออกมาให้ทราบถึงท่าทางของ เครื่องว่าขณะนี้กำลังอยู่ ท่าไต่ (climbs) หรือ ร่อน (ลดระดับ descend) โดยหน่วยที่แสดงออกมานี้จะมีหน่วยเป็น ฟุตต่อนาที
2. ระดับความสูงของจีพีเอส (GPS Altitude) คือ ระบบควบคุมความสูงของตัวเครื่องบินซึ่งจะทำหน้าที่ควบคุมเครื่องบินแต่ละลำตามที่นักบินกำหนดไว้ แต่ว่ามีเครื่องบินบางลำที่มีฟังก์ชันที่ตึกว่านั้นโดยมันสามารถไต่ระดับความสูงหรือลดลงได้เองตามความเหมาะสม

3. ค่าความเร็วอากาศ (True Air Speed: TAS) คือ เป็นค่าความเร็วอากาศที่ถูกต้องหลังจากการแก้ไขผลกระทบที่เกิดจากความสูง ความกดอากาศ อุณหภูมิ ความหนาแน่นของอากาศแล้ว
4. ค่าความเร็วปรากฏบนพื้นโลก (Ground Speed) คือ เป็นค่าความเร็ว ของเครื่องบินเมื่อเทียบเงาของเครื่องบินกับพื้นโลก โดยการปรับค่าความเร็วของลมที่มีผลต่อความเร็วที่เทียบกับพื้นโลกนี้ เช่น ถ้าเป็นลมตรงหน้าเครื่องก็จะช้าลง หากเป็นที่มาทางท้ายเครื่องบินก็จะทำให้ความเร็วนี้เพิ่มขึ้น เป็นต้น
5. ค่าความเร็วอากาศที่รับจากเครื่องวัดโดยตรง (Indicated Air Speed: IAS) คือ เป็นมาตรวัดความเร็วของเครื่องบิน บอกรวดเร็วของลมที่ผ่านเครื่องบิน ซึ่งก็จะมีค่าเท่ากับความเร็วของเครื่องบินที่เดินทางผ่านอากาศ ใช้หลักการของการเปลี่ยนแปลงความกดอากาศในการทำงาน กล่าวคือ เมื่อเครื่องบินทำการบินด้วยความเร็วที่สูงระบบกลไกก็จะไปขยับเข็มให้แสดงความเร็วที่สูงขึ้น
6. อุณหภูมิ (Temperature) คือ เครื่องวัดอุณหภูมิภายนอกเครื่องบิน หน่วยองศาเซลเซียส
7. ลม (Wind) คือ ความเร็วลมที่เคลื่อนที่ในแนวราบกับพื้นโลก ณ ตำแหน่งของเครื่องบินปัจจุบัน
8. ทิศทางลม (Wind Angle) คือ ทิศทางลมที่เคลื่อนที่เข้าหาเครื่องบิน ณ ตำแหน่งของเครื่องบินปัจจุบัน
9. ตำแหน่งละติจูด (Latitude) คือ เส้นละติจูด เป็นเส้นสมมติที่วางตามแนวนอนของโลก เส้นละติจูดที่อยู่บริเวณตรงกลางหรือเรียกว่าเส้น อีควเตอร์ (Equator) เส้นละติจูดนั้นเป็นเส้นที่ใช้วัดพิกัดในเชิงตัวเลขว่าทิศเหนือและทิศใต้นั้นห่างจากเส้นอีควเตอร์ซึ่งเป็นเส้นที่แบ่ง ณ จุดกึ่งกลางโลก โดยส่วนที่อยู่เหนือกว่าเส้นอีควเออร์นั้นคือซีกโลกเหนือ และส่วนที่อยู่ใต้เส้นอีควเตอร์คือซีกโลกใต้ โดยตำแหน่งของสนามบินนานาชาติภูเก็ตอยู่ที่ละติจูด 8.11056
10. ตำแหน่งลองจิจูด (Longitude) คือ เส้นลองจิจูด เป็นเส้นสมมติที่วางตามแนวตั้งของโลก หรือที่เรียกว่าเส้นเมอร์ริเดียน (Meridian) วิธีที่ง่ายที่สุดในการจินตนาการภาพสำหรับเส้นลองจิจูด ให้ลองนึกถึงวงรีที่ตัดแบ่งครึ่งวงตัวตามแนวตั้งของโลก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยปลายด้านหนึ่งของวงรีนั้นวางที่ตำแหน่งขั้วโลกเหนือ และปลายอีกด้านหนึ่งวางที่ขั้วโลกใต้ โดยตำแหน่งของสนามบินนานาชาติภูเก็ตอยู่ที่ลองจิจูด 98.3125

11. ระดับความสูงที่ปรับเทียบ (Calibrated altitude) ระดับความสูงที่ปรับเทียบจะได้รับการแก้ไขสำหรับสภาวะบรรยากาศที่ไม่เป็นมาตรฐาน คือความสูงที่แท้จริงเหนือระดับน้ำทะเลปานกลาง ราวกับวัดด้วยสายวัด ระดับความสูงของสนามบิน ยอตกูเขา หอคอย และสิ่งกีดขวางอื่นๆ ระบุไว้ในระดับความสูงที่แท้จริง

### 2.1.3 การบินขึ้น (Take off) [1], [11]

ขั้นตอนในการบินขึ้นของเครื่องบินนักบินจะคำนวณหาค่าความเร็ว ณ จุดที่ต้องยกหัวขึ้น ความเร็วนี้เรียกว่า  $V(r)$  เป็นความเร็วที่เพียงพอสำหรับการสร้างแรงยกเพื่อยกตัวขึ้น จะขึ้นอยู่กับน้ำหนักบรรทุกของเครื่องบินในเที่ยวบินนั้นๆ อุณหภูมิภายนอก ทิศทางลมและความสูงของรันเวย์จากระดับน้ำทะเลด้วย ซึ่งแน่นอนว่าเครื่องบินลำเดียวกันนี้ถ้ามีน้ำหนักบรรทุกต่างกัน ในสภาพอากาศของสนามบินที่ต่างกัน จะต้องใช้ความเร็วสำหรับยกหัวขึ้นต่างกัน ช่วงของการบินขึ้นจะเร่งคืบบังคับเครื่องยนต์จนสุด พอเครื่องบินเร่งความเร็วไปจนถึง  $V(r)$  นักบินจะยกหัวขึ้น ซึ่งกระบวนการบินขึ้นของเครื่องบินสามารถแบ่งออกเป็น 3 ส่วนในช่วงที่อยู่บนภาคพื้นดิน (Ground Roll) ได้แก่ ความเร็วในการตัดสินใจ (Decision speed) ความเร็วเริ่มยกหัว (Rotation speed) และ ความเร็วที่เครื่องบินเริ่มยกตัว (Lift-off Speed) ความเร็วต่ำสุดที่เครื่องบินอยู่สูง 35 ฟุต หรือ 10.7 เมตร (Take-off Safety Speed) ดังแสดงรูปในรูปที่ 2.2




รูปที่ 2.2 กระบวนการบินขึ้นของเครื่องบิน [12]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.1.4 การลงจอด (Landing) [1], [13]

ขั้นตอนในการลงจอดของเครื่องบินประกอบด้วย 2 ขั้นตอน ได้แก่ การลงจอดในช่วงที่เครื่องบินอยู่บนอากาศ (Air distance) และช่วงที่อยู่บนภาคพื้นดิน (Ground Roll Distance) การลงจอดของเครื่องบินขณะที่อยู่บนอากาศนักบินจะลดเพดานบินลงในระยะห่างจากสนามบินที่เหมาะสม ซึ่งประกอบไปด้วยระยะทางที่เครื่องบินกำลังลดความเร็วหลังจากผ่านระดับสิ่งกีดขวาง (Obstacle) และระยะเปลี่ยนผ่านการลงจอด (Transition) จากขั้นตอนการลงจอดในช่วงที่เครื่องบินอยู่บนอากาศกับอยู่บนภาคพื้นดิน ในส่วนระยะลงจอดของเครื่องบินช่วงที่อยู่บนภาคพื้นดินจะประกอบด้วยระยะที่ล้อของเครื่องบินกำลังเริ่มสัมผัสพื้น (Rotation) และระยะที่ล้อของเครื่องบินสัมผัสพื้น (Noise-wheel on the ground) โดยระยะทางในการลงจอดของเครื่องบินจะแบ่งเป็นระยะ ดังแสดงในรูปที่ 2.3

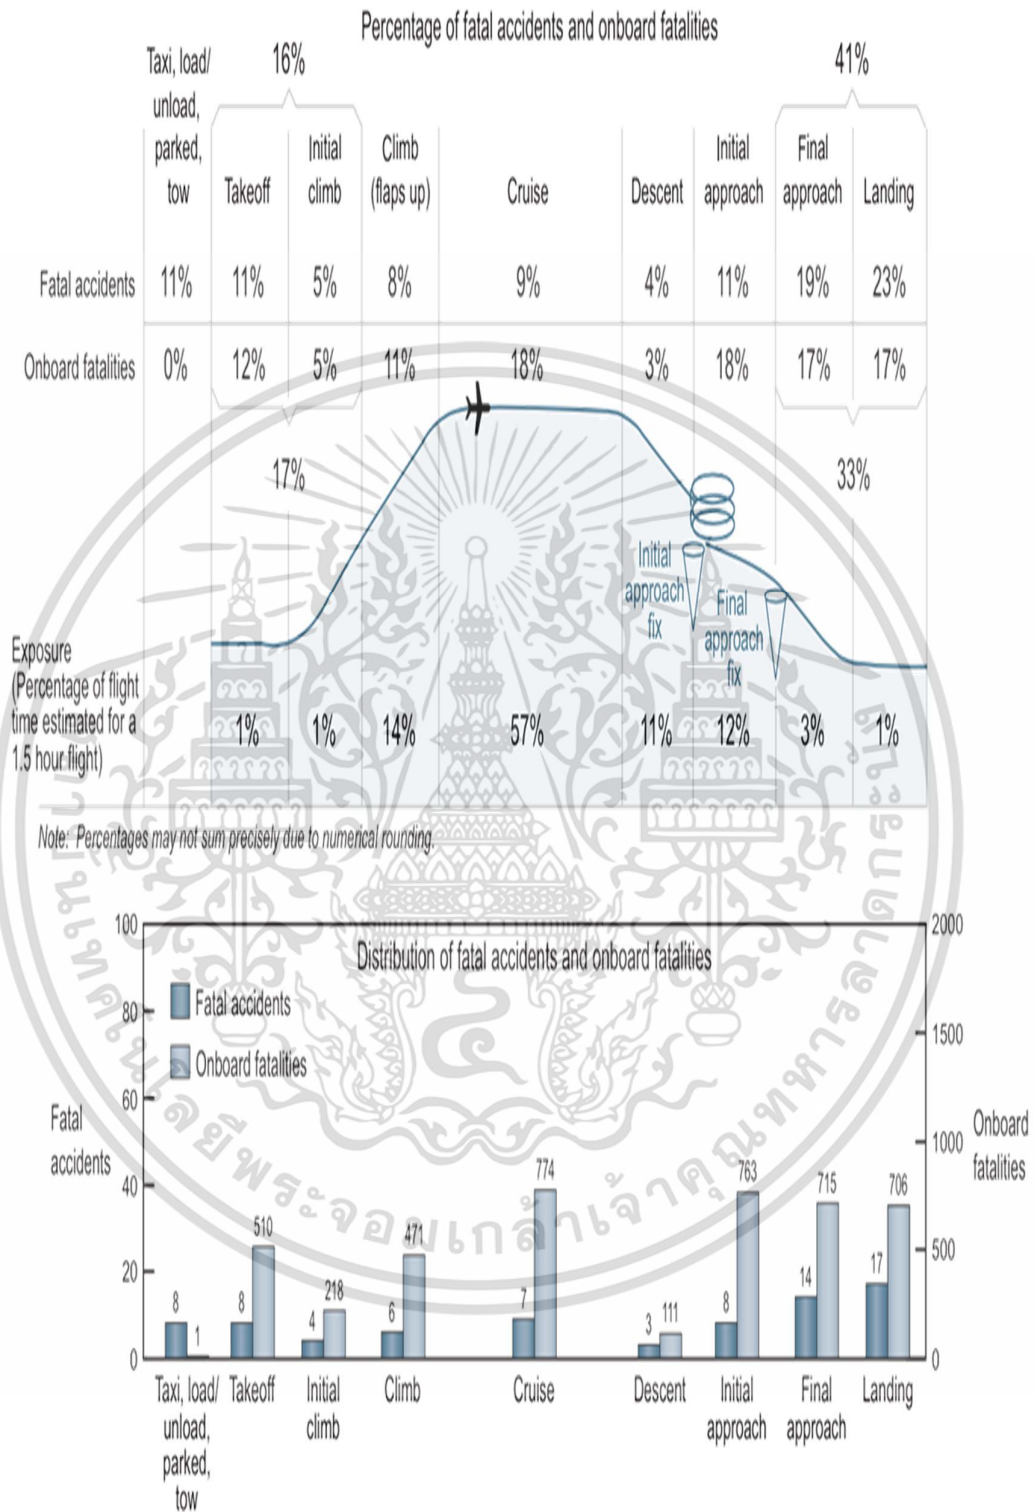


รูปที่ 2.3 กระบวนการลงจอดของเครื่องบิน [14]

### 2.1.5 สถิติการเกิดอุบัติเหตุทางการบินขณะบินขึ้นและลงจอด [15-16]

เที่ยวบินของเครื่องบินพาณิชย์ทั้งหมดเริ่มต้นด้วยการบินขึ้นและสิ้นสุดที่ปลายทางด้วยการนำเครื่องบินลงจอด เหตุการณ์และอุบัติเหตุจำนวนมากนั้นได้เกิดขึ้นในช่วงเวลาระหว่างนี้ โดยสถิติอุบัติเหตุที่น่าเสนาในหัวข้อนี้เป็นอุบัติเหตุเฉพาะเครื่องบินพาณิชย์ทั่วโลกที่มีน้ำหนักรวมสูงสุด 60,000 ปอนด์ ดังแสดงในรูปที่ 2.4

สัดส่วนของการเกิดอุบัติเหตุที่เกิดจากปัญหาทางกลไกได้ลดลง แต่สัดส่วนของอุบัติเหตุที่เกิดจากมนุษย์นั้นสูงขึ้น โดยงานวิจัยของคณะกรรมการความปลอดภัยในการขนส่งของออสเตรเลีย (ATSB) ระบุว่า ปัจจัยของมนุษย์เป็นสาเหตุที่เอื้อต่อเหตุการณ์และการเกิดอุบัติเหตุทั้งหมดประมาณ 70% แสดงปัจจัยของมนุษย์ที่เป็นสาเหตุของการเกิดอุบัติเหตุได้ดังตารางที่ 2.1



รูปที่ 2.4 สถิติการเกิดอุบัติเหตุ [15]


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.1 ปัจจัยของมนุษย์ที่เป็นสาเหตุของการเกิดอุบัติเหตุ

ปัจจัย	เปอร์เซ็นต์ของเหตุการณ์
การตัดสินใจไม่เพียงพอ	74%
การละเว้นการกระทำหรือการกระทำที่ไม่เหมาะสม	72%
การไม่ปฏิบัติตามเกณฑ์สำหรับแนวทางที่มีเสถียรภาพ	66%
การประสานงานของลูกเรือไม่เพียงพอการตรวจสอบและการสำรองข้อมูล	63%
การรับรู้สถานการณ์ในแนวนอนหรือแนวตั้งไม่เพียงพอ	52%
ความเข้าใจไม่เพียงพอหรือไม่เพียงพอเกี่ยวกับเงื่อนไขที่เกิดขึ้น	48%
การดำเนินการซ้ำหรือล่าช้า	45%
ปัญหาในการจัดการเที่ยวบิน	45%
ไม่ปฏิบัติตามขั้นตอนโดยเจตนา	40%
การฝึกอบรมไม่เพียงพอ	37%
การสื่อสารของนักบิน / คอนโทรลเลอร์ไม่ถูกต้องหรือไม่สมบูรณ์	33%
ปฏิสัมพันธ์กับระบบอัตโนมัติ	20%

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


อัตราการรอดชีวิตสำหรับส่วนต่างๆของห้องโดยสารอ้างอิงจากการวิเคราะห์การขัดข้องของเครื่องบินเชิงพาณิชย์ทั้งหมดในสหรัฐอเมริกาตั้งแต่ปี พ.ศ.2514 ดังแสดงในรูปที่ 2.5 โดยส่วนท้ายของเครื่องบินนั้นมีความปลอดภัยมากที่สุด ยิ่งนั่งใกล้ส่วนท้ายของเครื่องบินจะมีความปลอดภัยมากกว่าส่วนหน้าถึง 20% แต่ก็ขึ้นอยู่กับสถานการณ์การเกิดอุบัติเหตุแล้วแต่ว่าเป็นอุบัติเหตุแบบไหน



รูปที่ 2.5 อัตราการรอดชีวิตสำหรับส่วนต่างๆของห้องโดยสาร [16]

## 2.2 โครงข่ายประสาทเทียม (Artificial neural network: ANN) [17-20]

โครงข่ายประสาทเทียม (Artificial neural network: ANN) ถูกสร้างขึ้นด้วยแบบจำลองทางคณิตศาสตร์สำหรับประมวลผลข้อมูล (Mathematic model) ที่ถูกออกแบบมาให้เหมือนการทำงานของเซลล์ประสาทในสมองของมนุษย์ ดังแสดงในรูปที่ 2.6 เป็นหนึ่งในการเรียนรู้ของเครื่อง (Machine learning) วิธีการนี้ได้รับความนิยมอย่างมาก เพื่อให้ได้โครงข่ายการทำงานที่สามารถจดจำรูปแบบของข้อมูล (Pattern deduction) และการอนุมานความรู้ (Knowledge deduction) จากข้อมูลตัวอย่างที่ถูกมอบหมาย โดยจัดเก็บข้อมูลในรูปแบบค่าถ่วงน้ำหนักของโครงข่าย (Weight) ที่เปลี่ยนแปลงไปตามข้อมูลการเรียนรู้ที่ป้อนให้ ซึ่งมีความสามารถในการรวบรวมความรู้ผ่านกระบวนการเรียนรู้ (Learning process) จึงทำให้โครงข่ายประสาทเทียมถูกนำมาประยุกต์ใช้ในด้านต่างๆอย่างแพร่หลาย เช่น การวินิจฉัยโรคทางการแพทย์ การวางแผนและหุ่นยนต์ การให้เหตุผลและการพิสูจน์ทฤษฎีอย่างอัตโนมัติ



รูปที่ 2.6 แบบจำลองกับการทำงานของเซลล์ประสาทในสมองของมนุษย์ [17]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


การประมวลผลต่างๆ ของโครงข่ายประสาทเทียมเกิดขึ้นในหน่วยประมวลผลย่อยที่เรียกว่า โหนด (Node) ที่มีลักษณะการทำงานส่งสัญญาณระหว่างโหนดที่เชื่อมต่อกัน (Fully connected) เพื่อรับส่งข้อมูล โดยมีฟังก์ชันการกระตุ้น (Activation function) หรือ ฟังก์ชันการแปลง (Transfer function) เป็นตัวกำหนดสัญญาณส่งออกซึ่งทำหน้าที่เหมือนกระบวนการทำงานในสมองของมนุษย์ องค์ประกอบของโครงข่ายประสาทเทียมประกอบไปด้วย 5 ส่วน ได้แก่ ชั้นข้อมูลขาเข้า (Input layer) ชั้นข้อมูลขาออก (Output layer) ค่าน้ำหนัก (Weights) โดยมีฟังก์ชัน ผลรวม (Summation function) ในการคำนวณผลรวมของข้อมูลนำเข้า และฟังก์ชันการกระตุ้น (Activation function) กำหนดสัญญาณส่งออกข้อมูล ดังแสดงในรูปที่ 2.7 โดยองค์ประกอบการทำงานของโครงข่ายประสาทเทียม มีดังนี้

- 1.) ข้อมูลขาเข้า (Input) คือ ข้อมูลเชิงตัวเลขที่ใช้ป้อนให้กับโครงข่ายประสาทเทียม โดยหากเป็นข้อมูลเชิงคุณภาพต้องแปลงข้อมูลให้อยู่ในรูปเชิงปริมาณที่โครงข่ายประสาทเทียมยอมรับได้
- 2.) ข้อมูลส่งออก (Output) คือ ค่าของผลลัพธ์ที่เกิดขึ้นจริงจากกระบวนการเรียนรู้ (Actual output) ได้จากกระบวนการทำงานลำดับสุดท้ายของโครงข่ายประสาทเทียม
- 3.) ค่าน้ำหนัก (Weights) คือ สิ่งที่ได้จากการเรียนรู้ของโครงข่ายประสาทเทียม หรือค่าความรู้ (Knowledge) ซึ่งค่าน้ำหนักจะถูกเก็บเป็นทักษะการจดจำข้อมูลอื่นๆ ที่อยู่ในรูปแบบเดียวกัน
- 4.) ฟังก์ชันผลรวม (Summation function :S) เป็นความสัมพันธ์ทางคณิตศาสตร์โดยมีหน้าที่ คำนวณผลรวมของข้อมูลที่ได้จากชั้นข้อมูลนำเข้า แสดงได้ดังสมการที่ (2.1)

$$S = \sum_{i=1}^n a_i w_i \quad (2.1)$$

- 5.) ฟังก์ชันการกระตุ้น (Activation function) เป็นความสัมพันธ์ทางคณิตศาสตร์ซึ่งทำหน้าที่ปรับค่าของข้อมูลที่ได้รับจากฟังก์ชันผลรวมให้อยู่ในช่วงที่ต้องการ แสดงได้ดังสมการที่ (2.2)

$$Y = f \left[ \sum_{i=1}^n (x_i w_i) + bias \right] \quad (2.2)$$



รูปที่ 2.7 โครงสร้างการทำงานของโครงข่ายประสาทเทียม

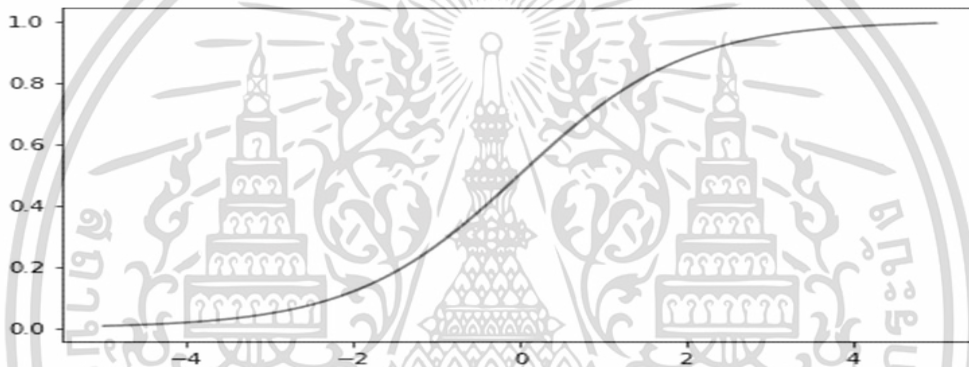
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 2.2.1 ฟังก์ชันกระตุ้น (Activation function)

ฟังก์ชันกระตุ้นคือฟังก์ชันที่ใช้เพื่อหาค่าผลลัพธ์ข้อมูล โดยตัดสินใจว่าถ้าผลลัพธ์ข้อมูลของโครงข่ายมีผลลัพธ์ที่ได้เป็นลักษณะเชิงเส้น ทำให้ไม่สามารถตอบปัญหาที่ซับซ้อนได้ ฟังก์ชันกระตุ้นจึงจำเป็นต่อโครงข่ายประสาทเทียมเพื่อแก้ปัญหาที่ซับซ้อน โดยฟังก์ชันกระตุ้นมีรายละเอียดดังต่อไปนี้

1. ฟังก์ชันซิกมอยด์ (Sigmoid function) ฟังก์ชันที่แปลงค่าจำนวนจริงให้ผลลัพธ์อยู่ในช่วงระหว่าง -1 ถึง 1 หรือ 0 ถึง 1 สามารถเขียนฟังก์ชันซิกมอยด์แทนด้วยสัญลักษณ์  $\sigma$  สามารถคำนวณได้ดังสมการที่ 2.3


$$\sigma(x) = \frac{1}{1 + e^{-x}} \quad (2.3)$$



รูปที่ 2.8 ฟังก์ชันซิกมอยด์ (Sigmoid function)

2. ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent Function : Tanh) ฟังก์ชันที่แปลงค่าจำนวนจริงให้อยู่ในช่วงระหว่าง -1 ถึง 1 คำนวณได้ดังสมการที่ 2.4

$$\tanh(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

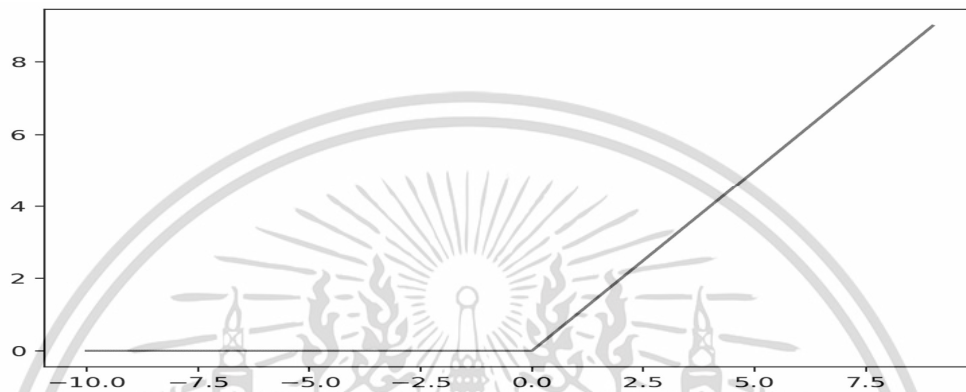


รูปที่ 2.9 ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent Function : Tanh)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. ฟังก์ชันเรกติไฟต์เชิงเส้นหรือรีลู (Rectified Linear Unit : Relu function) ฟังก์ชันที่ให้ค่าผลลัพธ์มากกว่าหรือเท่ากับ 0 สมการของฟังก์ชันเรกติไฟต์เชิงเส้นสามารถคำนวณได้ดังสมการที่ 2.5

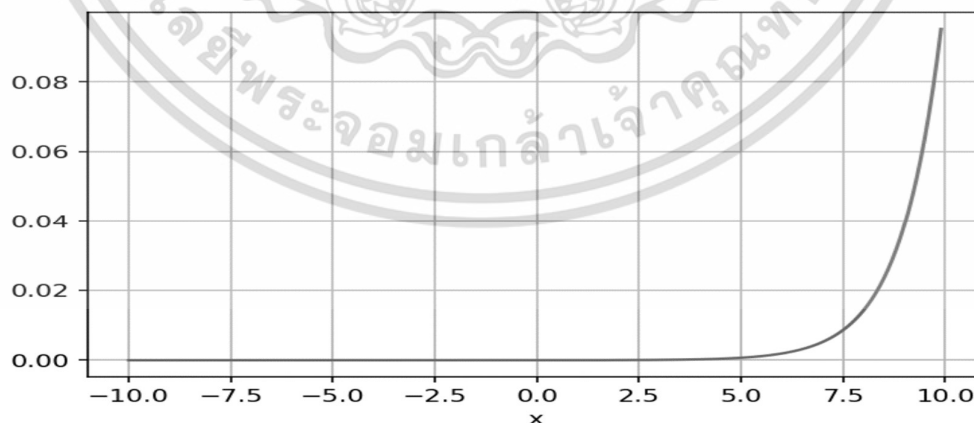
$$Relu(x) = \begin{cases} 0 & \text{if } z < 0 \\ z & \text{if } z \geq 0 \end{cases} \quad (2.5)$$



รูปที่ 2.10 ฟังก์ชันเรกติไฟต์เชิงเส้นหรือรีลู (Rectified Linear Unit : Relu function)

4. ฟังก์ชันซอฟต์แวร์แมกซ์ (SoftMax Function) ฟังก์ชันที่ให้ค่าผลลัพธ์อยู่ระหว่าง 0 ถึง 1 ซึ่งจะแปลงค่าทุกตัวของโหนดให้มีค่าระหว่าง 0 ถึง 1 โดยเมื่อนำผลลัพธ์มารวมกันแล้วทั้งหมดแล้ว จะได้ค่าเท่ากับ 1 พอดี สามารถคำนวณได้ดังสมการที่ 2.6

$$softmax(x)_j = \frac{e^{x_j}}{\sum_{i=1}^k e^{x_i}} \quad (2.6)$$

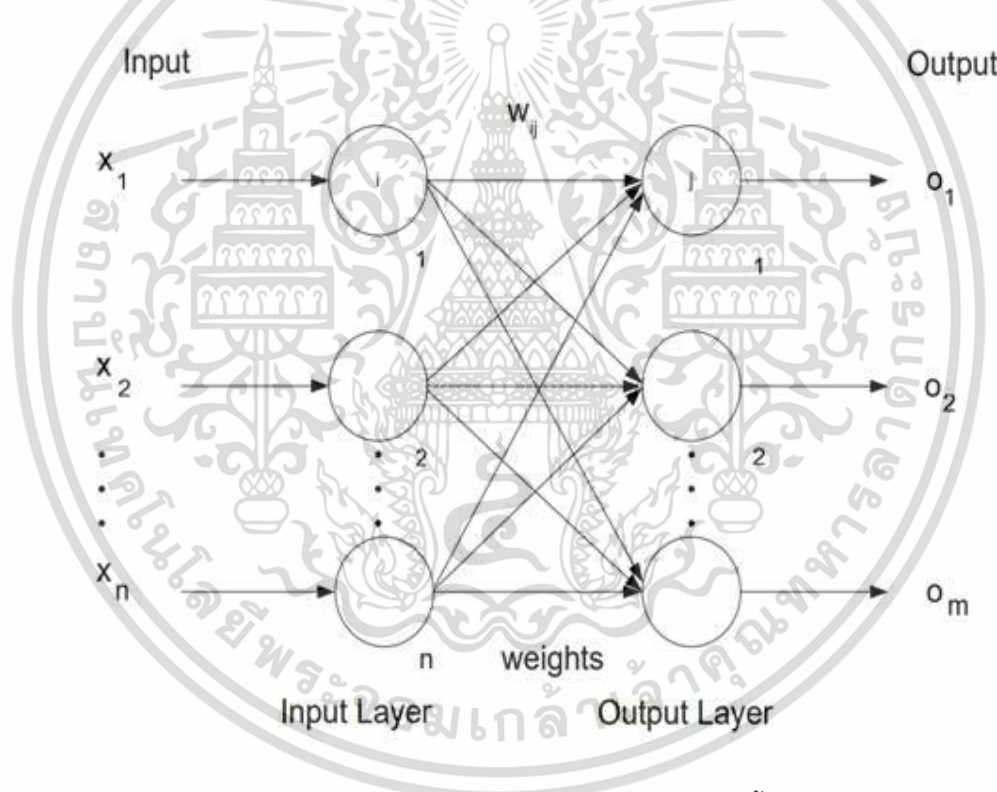


รูปที่ 2.11 ฟังก์ชันซอฟต์แวร์แมกซ์ (SoftMax Function)

### 2.2.2 โครงสร้างของโครงข่ายประสาทเทียม

โครงข่ายประสาทเทียมเชื่อมต่อกันด้วยนิวรอนจำนวนมาก โดยแบ่งออกเป็นกลุ่มย่อยดังนี้ ชั้นข้อมูลขาเข้า (Input layer) ชั้นซ่อน (Hidden layer) คือชั้นที่อยู่ระหว่างชั้นข้อมูลขาเข้าและชั้นข้อมูลส่งออก และชั้นสุดท้ายชั้นข้อมูลส่งออก (Output layer) โดยทั่วไปชั้นซ่อนอาจมีมากกว่า 1 ชั้นก็ได้ สามารถแบ่งประเภทตามโครงสร้างของโครงข่ายประสาทเทียมได้ 2 ประเภท ดังนี้

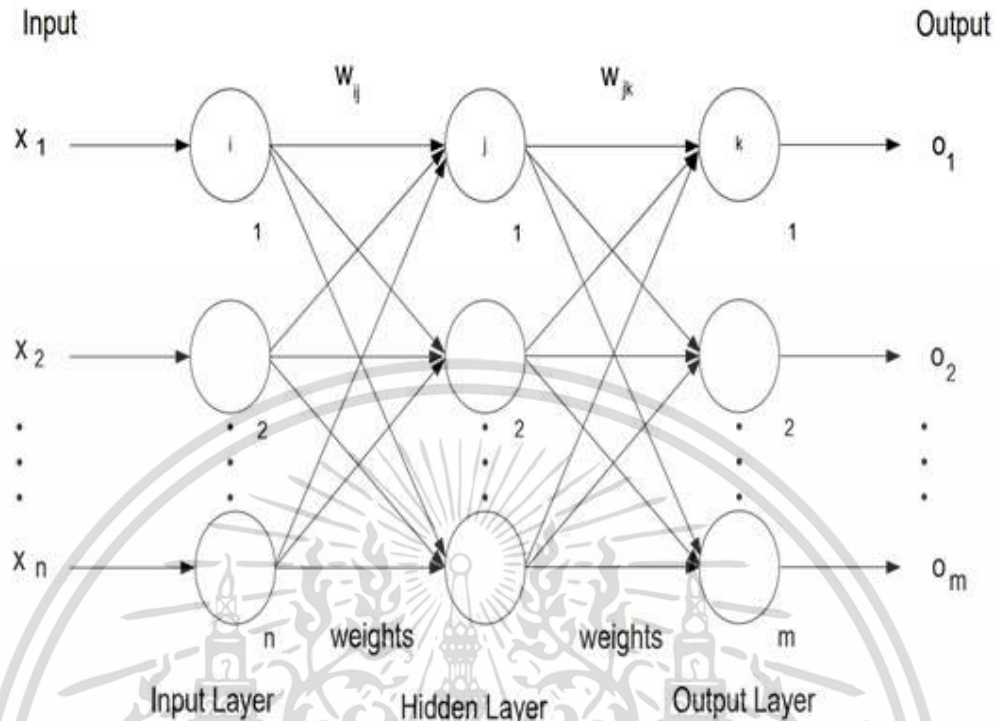
1. โครงข่ายประสาทเทียมแบบชั้นเดียว (Single Layer neural network) เป็นโครงข่ายที่มี ชั้นข้อมูลขาเข้าและชั้นข้อมูลส่งออก ซึ่งชั้นขาเข้ามีหน้าที่รับข้อมูลขาเข้าแล้วส่งข้อมูลผ่านเส้นเชื่อมโยงต่างๆโดยความเข้มของสัญญาณขึ้นอยู่กับค่าน้ำหนักที่อยู่บนเส้นเชื่อมโยง และนำข้อมูลที่รับมามีค่าแล้วมาใช้ฟังก์ชันกระตุ้นก่อนส่งข้อมูลไปยังชั้นขาออกของโครงข่ายประสาทเทียมแบบชั้นเดียว



รูปที่ 2.12 โครงข่ายประสาทเทียมแบบชั้นเดียว

2. โครงข่ายประสาทเทียมแบบหลายชั้น (Multi-Layer neural network) เป็นโครงข่ายประเภทการทำนาย (Networks for prediction) ประกอบด้วยชั้นข้อมูลขาเข้า ชั้นข้อมูลส่งออกและชั้นการประมวลผลที่เรียกว่า ชั้นซ่อน (Hidden layer) อย่างน้อย 1 ชั้นซ่อน โดยไม่มีข้อจำกัดทางทฤษฎีต่อจำนวนของชั้นซ่อน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.13 โครงข่ายประสาทเทียมแบบหลายชั้น

### 2.2.3 กระบวนการเรียนรู้ของโครงข่ายประสาทเทียม

การเรียนรู้ข้อมูลของโครงข่ายประสาทเทียม เป็นรูปแบบหนึ่งของโครงข่ายประสาทเทียมโดยการป้อนข้อมูลเพื่อให้โครงข่ายทำการเรียนรู้และหาค่าน้ำหนักที่เหมาะสม อาศัยกระบวนการทำซ้ำ (Iterative) ใช้สำหรับงานที่มีความซับซ้อนให้ผลลัพธ์ที่ได้เป็นอย่างดี สามารถแบ่งกระบวนการเรียนรู้ข้อมูลของโครงข่ายประสาทเทียมได้ 3 ประเภท ดังนี้

1. การเรียนรู้แบบมีผู้สอน (Supervised learning) คือ การเรียนรู้ที่โครงข่ายจะกำหนดค่าผลลัพธ์เป้าหมายให้กับข้อมูลป้อนเข้า โดยระหว่างการสอนโครงข่ายจะให้ค่าผลลัพธ์จริงซึ่งแตกต่างจากค่าผลลัพธ์เป้าหมายทำให้ได้ค่าความคลาดเคลื่อน และหาค่าความคลาดเคลื่อนจากผลลัพธ์การเรียนรู้เทียบกับค่าเป้าหมาย โดยโครงข่ายจะนำค่าผิดพลาดระหว่างผลลัพธ์ที่ได้กับค่าเป้าหมาย มาใช้ในการปรับค่าน้ำหนักของโครงข่ายด้วยกระบวนการทำซ้ำกับข้อมูล จนกระทั่งค่าน้ำหนักในโครงข่ายลู่เข้าเพื่อให้ได้ผลลัพธ์ที่ใกล้เคียงกับเป้าหมายมากที่สุด ทั้งหมดนี้เรียกว่า การเรียนรู้ จากนั้นเมื่อโครงข่ายทำการเรียนรู้แล้วก็จะป้อนข้อมูลขาเข้าที่เป็นชุดทดสอบให้โครงข่ายเพื่อที่จะหาค่าผลลัพธ์การทำงาน วิชยานิพนธ์นี้จะใช้การเรียนรู้แบบมีผู้สอนเท่านั้น

2. การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) คือ การเรียนรู้ที่โครงข่ายไม่มีการกำหนดค่าเป้าหมายผลลัพธ์ให้กับข้อมูลขาเข้า โดยการปรับค่าถ่วงน้ำหนักจะใช้การหาความสัมพันธ์ของข้อมูลป้อนเข้าที่มีรูปแบบคล้ายคลึงกัน เปรียบเทียบกับการจำแนกประเภทสิ่งต่างๆ ตามลักษณะของรูปร่างได้ด้วยตนเอง
3. การเรียนรู้เชิงบังคับ (Reinforcement learning) คือ การเรียนรู้จากสิ่งต่างๆด้วยการลองผิดลองถูก โดยในระหว่างการสอนที่มีเพียงชุดข้อมูลอินพุตจะใช้การเรียนรู้แบบไม่มีผู้สอน และใช้การเรียนรู้แบบมีผู้สอนเมื่อได้ค่าผลลัพธ์และทำการบอกว่าถูกหรือผิด แต่ไม่บอกค่าผลลัพธ์ที่ถูกต้องว่าคืออะไร

### 2.2.4 โครงข่ายประสาทเทียมแบบไปข้างหน้า (Feedforward neural network)

ในบางปัญหาเพอร์เซปตรอนเพียงตัวเดียวไม่สามารถแก้ปัญหาได้ ดังนั้น รูปแบบของโครงข่ายประสาทเทียมที่ง่ายที่สุดในการแก้ปัญหาจึงเป็นที่มาของโครงข่ายประสาทเทียมแบบไปข้างหน้า โครงข่ายประสาทเทียมแบบไปข้างหน้า คือ การส่งข้อมูลแบบไปข้างหน้าทางเดียว เป็นการคำนวณแบบไปข้างหน้า ซึ่งใช้ค่าจากชั้นก่อนหน้ามาคำนวณแล้วส่งผลลัพธ์ต่อไปยังชั้นถัดไปโดยที่ผลลัพธ์ของแต่ละชั้นจะไม่ย้อนกลับมาเป็นข้อมูลอินพุตของชั้นก่อนหน้าอีก โครงสร้างของโครงข่ายประสาทเทียมแบบไปข้างหน้าแบ่งออกเป็น 3 ชั้น พิจารณาได้จากรูปที่ 2.14

1. ชั้นข้อมูลขาเข้า (Input layer) ข้อมูลเชิงตัวเลขจำนวน  $n$  ค่าตั้งแต่  $x_1, \dots, x_n$
2. ชั้นซ่อน (Hidden layer) ข้อมูลจากชั้นข้อมูลขาเข้าจะคำนวณผลลัพธ์ด้วยค่าน้ำหนักที่แตกต่างกัน ผลลัพธ์ของทุกตัวในชั้นนี้จะถูกส่งไปยังชั้นถัดไป
3. ชั้นข้อมูลส่งออก (Output layer) ทำงานคล้ายชั้นซ่อน ซึ่งข้อมูลของชั้นส่งออกคือผลลัพธ์ของแต่ละตัวในชั้นซ่อน เนื่องจากโครงข่ายประสาทเทียมแบบไปข้างหน้าในชั้นส่งออกชั้นนี้จะให้ค่าผลลัพธ์ ดังนั้นรูปแบบลักษณะของโครงข่ายและการแก้ปัญหาจะขึ้นอยู่กับจำนวนของเพอร์เซปตรอนด้วย

สมการของโครงข่ายประสาทเทียมแบบไปข้างหน้า


$$h_i(x) = \begin{cases} 1 & \text{if } w_0 + \sum_{i=1}^n w_i x_i > 0 \\ -1 & \text{otherwise} \end{cases} \quad (2.7)$$

$$o_i(x) = \begin{cases} 1 & \text{if } w_0 + \sum_{i=1}^p w_i h_i > 0 \\ -1 & \text{otherwise} \end{cases} \quad (2.8)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดย,  $h_i$  เป็นสมการเพอร์เซปตรอนตัวที่  $i$  ในชั้นซ่อน  
 $p$  เป็นจำนวนเพอร์เซปตรอนในชั้นซ่อน  
 $o_i$  เป็นสมการเพอร์เซปตรอนตัวที่  $i$  ในชั้นผลลัพธ์

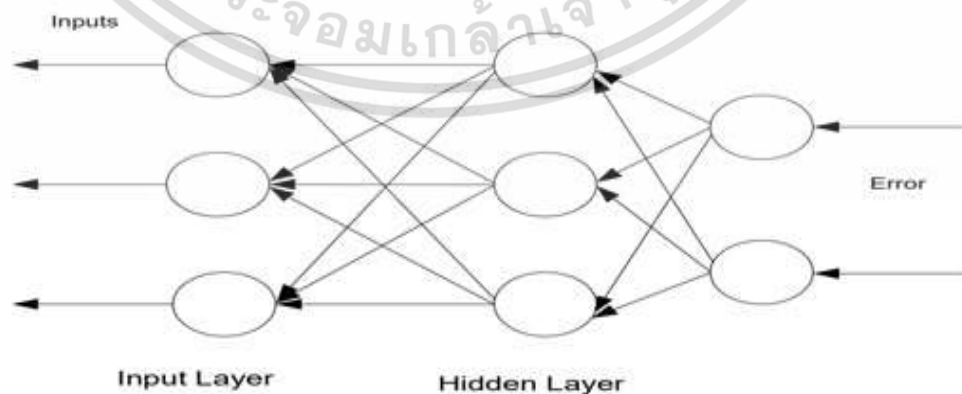
แต่ในปัจจุบันโครงข่ายประสาทเทียมแบบไปข้างหน้าไม่ค่อยได้รับความนิยมเพราะผลลัพธ์ที่ได้มีลักษณะเป็นเชิงเส้นและไม่สามารถตอบปัญหาที่ซับซ้อนได้



รูปที่ 2.14 โครงสร้างของโครงข่ายประสาทเทียมแบบไปข้างหน้า

### 2.2.5 กระบวนการแพร่ย้อนกลับ (Backpropagation algorithm)

กระบวนการแพร่ย้อนกลับ เป็นกระบวนการในการเรียนรู้แบบมีผู้สอน นิยมนำมาใช้เพื่อปรับค่าถ่วงน้ำหนักของการเรียนรู้แต่ละรอบให้มีความเหมาะสมมากขึ้น ซึ่งค่าถ่วงน้ำหนักที่ทำการปรับนั้นขึ้นอยู่กับความคลาดเคลื่อนระหว่างผลลัพธ์ที่ได้จากโครงข่ายกับค่าเป้าหมาย โดยมีหลักการคือ เมื่อโครงข่ายประสาทเทียมได้รับข้อมูลขาเข้า ชี้นำเข้าข้อมูลจะคำนวณค่าน้ำหนักของหน่วยรับข้อมูลไปยังชั้นซ่อน และจากชั้นซ่อนไปยังชั้นส่งออก โดยหากเกิดความคลาดเคลื่อนระหว่างผลลัพธ์ที่ได้กับค่าเป้าหมาย โครงข่ายจะปรับค่าความผิดพลาดจากชั้นส่งออก และแพร่ย้อนกลับไปยังชั้นซ่อน จากนั้นจึงแพร่ย้อนกลับไปยังชั้นข้อมูลขาเข้า ตามลำดับ



รูปที่ 2.15 กระบวนการแพร่ย้อนกลับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 2.2.6 ฟังก์ชันการสูญเสีย (Loss function)

ฟังก์ชันการสูญเสียเป็นวิธีการประเมินว่าแบบจำลองทำงานได้ดีเพียงใดในไฟล์ชุดข้อมูล หากแบบจำลองทำงานได้ดีบนชุดข้อมูลผลลัพธ์จากฟังก์ชันการสูญเสียของไฟล์ แบบจำลองควรอยู่ในระดับต่ำ เป็นส่วนที่สำคัญมากในขณะที่ปรับแต่งไฮเปอร์พารามิเตอร์

โครงข่ายประสาทเทียมแบบไปข้างหน้ามักจะต้องมีค่าความผิดพลาด (Error) เกิดขึ้นเสมอ ดังนั้น การลดค่าความผิดพลาดให้เหลือน้อยที่สุด คือ การเข้าใกล้ 0 ให้มากที่สุดโดยเราจะมองค่าความผิดพลาดเป็นฟังก์ชันการสูญเสีย

กำหนดให้  $E$  คือฟังก์ชันการสูญเสียหรือค่าความผิดพลาด

$N$  คือจำนวนข้อมูลฝึกสอนทั้งหมด

$t_i$  คือผลลัพธ์ที่ถูกต้องของข้อมูลฝึกสอนชุดที่  $i$

$o_i$  คือผลลัพธ์ปัจจุบันจากการของฝึกสอนข้อมูลชุดที่  $i$

สามารถเขียนสมการของฟังก์ชันการสูญเสียที่นิยมใช้ได้ดังต่อไปนี้

- 1) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE)

$$E = \frac{1}{2} \sum_{i=1}^N (t_i - o_i)^2 \quad (2.9)$$

- 2) ค่าเฉลี่ยครอส-เอนโทรปี (Binary Cross-Entropy: BCE)

$$E = -\frac{1}{N} \sum_{i=1}^N t_i \cdot \log(o_i) + (1 - t_i) \cdot \log(1 - o_i) \quad (2.10)$$

- 3) ค่าติดลบลอการิทึมของความเป็นไปได้ (Negative Log Likelihood: NLL)

$$E = -\frac{1}{C} \sum_{i=1}^c \log d_i \quad (2.11)$$

โดย  $C$  คือจำนวนประเภทของผลลัพธ์ทั้งหมดที่เป็นไปได้

$d_i$  คือผลต่างของความน่าจะเป็นระหว่างผลลัพธ์ที่ถูกต้องกับผลลัพธ์ทั้งหมดที่ทำนาย

จะมีการหาค่าเหมาะสมที่สุด (Optimization) ในการฝึกสอนโครงข่ายประสาทเทียมแบบไปข้างหน้า เพื่อลดค่าความผิดพลาดให้ได้มากที่สุดในการฝึกสอนข้อมูลแต่ละรอบคือ วิธีการเอสจิดี (Stochastic Gradient Descent) โดยการหาค่าผลลัพธ์จากฟังก์ชันการสูญเสียมาหาค่าเกรเดียนเทียบน้ำหนัก ซึ่งปรับน้ำหนักจากสมการที่ 2.12 สำหรับข้อมูลขาเข้าลำดับที่  $i$  ดังนี้

$$w_i = w_i + \Delta w_i \quad (2.12)$$

$$\Delta w_i = -\eta \frac{\partial E}{\partial w_i} \quad (2.13)$$

เนื่องจากค่าน้ำหนักที่ปรับจะมีผลกับชั้นผลลัพธ์ของโครงข่ายเท่านั้น ซึ่งชั้นอื่นภายในโครงข่ายไม่ได้ถูกปรับเปลี่ยน ดังนั้น จะต้องปรับค่าน้ำหนักทุกชั้นของโครงข่ายด้วยกระบวนการแพร่ย้อนกลับ (Backpropagation)

## 2.3 การเรียนรู้เชิงลึก (Deep learning) [21-22]


การเรียนรู้เชิงลึก (Deep Learning) เป็นอัลกอริทึมสำหรับการเรียนรู้และเป็นส่วนหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ที่สามารถทำให้เครื่องสามารถตัดสินใจได้เช่นเดียวกับมนุษย์ โดยการประยุกต์การเรียนรู้โดยใช้ข้อมูลทางด้านสถิติในการวิเคราะห์สร้างแบบจำลองและทำนายผลลัพธ์จากข้อมูล

การเรียนรู้เชิงลึกเป็นหนึ่งในอัลกอริทึมที่ถูกพัฒนามาจากโครงข่ายประสาทเทียมซึ่งเป็นการออกแบบมาให้เหมือนกับเซลล์ประสาทของมนุษย์ โดยพัฒนาด้วยการใช้โครงข่ายที่ซ้อนกันหลายชั้น ซึ่งเกิดจากการประยุกต์ใช้ความสามารถของแต่ละโครงข่ายเพื่อเพิ่มประสิทธิภาพในการวิเคราะห์ที่ดียิ่งขึ้น ในปัจจุบันการเรียนรู้เชิงลึกมีประสิทธิภาพในการวิเคราะห์และทำนายผลลัพธ์มากกว่าการเรียนรู้ของเครื่องเป็นอย่างมาก ทั้งในด้านจำนวนข้อมูลและการประมวลผลที่มีประสิทธิภาพสูงขึ้น ทำให้การเรียนรู้เชิงลึกมีจำนวนตัวแปรเพื่อเพิ่มประสิทธิภาพในการวิเคราะห์มากกว่าการเรียนรู้แบบเดิม และการเรียนรู้เชิงลึกไม่เพียงแต่เพิ่มจำนวนชั้นเท่านั้น ยังนำความสามารถในกระบวนการแพร่ย้อนกลับที่ใช้ฟังก์ชันการสูญเสียมาคำนวณค่าความผิดพลาดที่ได้จากการเปรียบเทียบระหว่างค่าของผลลัพธ์ที่ได้กับค่าจริง และสามารถปรับค่าพารามิเตอร์ของแบบจำลองด้วย Optimize Function ซึ่งเป็นฟังก์ชันในการปรับค่าพารามิเตอร์ของการเรียนรู้ในปัจจุบัน การเรียนรู้เชิงลึกมีอัลกอริทึมที่ได้รับความนิยมในปัจจุบัน ได้แก่ Deep neural network, Recurrent neural network, Long Short-Term Memory และ Gated Recurrent Units โดยความนิยมในการใช้งานการเรียนรู้เชิงลึกนั้น เนื่องจากมีประสิทธิภาพในการวิเคราะห์ที่สูง

### 2.3.1 โครงข่ายประสาทเชิงลึก (Deep neural network) [23]

โครงข่ายประสาทเชิงลึก (Deep Neural Network: DNN) เป็นการพัฒนาจากความรู้ด้านโครงข่ายประสาทเทียมจนเกิดเป็นเทคนิคของการเรียนรู้เชิงลึกขึ้น โดยให้โครงข่ายประสาทเทียมแบบหลายชั้นเรียนรู้ที่จะสร้างข้อมูลตัวแทนขึ้นมาเพื่อใช้ควบคู่กับอัลกอริทึมต่างๆ จากเดิมที่ต้องผ่านกระบวนการสกัดข้อมูลตัวแทน (Feature extraction) โดยมีหลักการคือเพิ่มจำนวนชั้นซ่อนเข้าไปจำนวนหนึ่งเพื่อวิเคราะห์ข้อมูล ซึ่งจำนวนที่มากขึ้นสามารถวิเคราะห์ข้อมูลได้ละเอียดขึ้น และใช้กระบวนการแพร่ย้อนกลับในการฝึกสอน ทำให้สามารถวิเคราะห์ได้อย่างแม่นยำและมีประสิทธิภาพสูง หลักการทำงานของโครงข่ายประสาทเชิงลึกแสดงในรูปที่ 2.16 ดังต่อไปนี้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.16 โครงสร้างโครงข่ายประสาทเชิงลึก

## 2.4 โครงข่ายประสาทเทียมแบบวนกลับ (Recurrent Neural Network: RNN) [21,24-26]

โครงข่ายประสาทเทียมแบบวนกลับ เป็นโครงข่ายประสาทเทียมที่มีความคล้ายกับโครงข่ายประสาทเทียมแบบไปข้างหน้า โดยประมวลผลข้อมูลขาเข้าตามลำดับ (Sequence) ข้อมูลในรูปแบบนี้จะมีลำดับการเกิดเหตุการณ์ที่ชัดเจนตัวอย่างข้อมูลลักษณะนี้ อาทิเช่น ดัชนีหุ้น ข้อมูลอนุกรมเวลา (Time-series) เป็นต้น โครงสร้างของโครงข่ายประสาทเทียมแบบวนกลับมีลักษณะเหมือนกับโครงข่ายประสาทเทียมทั่วไป แต่มีข้อมูลขาเข้าเพิ่มเติมนอกเหนือจากข้อมูล ณ ปัจจุบัน ซึ่งมีการนำผลลัพธ์จากช่วงเวลาก่อนหน้ากลับมาใช้ในการคำนวณเพิ่มเติมในรอบ ซึ่งทำให้โครงข่ายประสาทเทียมแบบวนกลับเปรียบเสมือนหน่วยความจำสั้นๆ โครงข่ายประสาทแบบวนกลับสามารถพิจารณาโครงสร้างตามรูปที่ 2.17 และสามารถอธิบายได้ดังสมการที่ 2.14



รูปที่ 2.17 โครงข่ายประสาทเทียมแบบวนกลับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กำหนดให้	$s_t$	คือ ผลลัพธ์ ณ ช่วงเวลา $t$
	$W$	คือ ค่าของน้ำหนักที่คูณกับข้อมูลที่ขึ้นก่อน ณ ช่วงเวลา $t - 1$
	$U$	คือ ค่าของน้ำหนักที่คูณกับข้อมูลขาเข้า ณ ช่วงเวลา $t$
	$x_t$	คือ ค่าของข้อมูลขาเข้า ณ ช่วงเวลา $t$
	$\sigma$	คือ ฟังก์ชันกระตุ้น
	$b$	คือ ไบแอส

สมการของโครงข่ายประสาทเทียมแบบวนกลับ

$$s_t = \sigma(Ws_{t-1} + Ux_t + b) \quad (2.14)$$

ในเรื่องของการเชื่อมโยงข้อมูล โครงข่ายประสาทเทียมแบบวนกลับจะได้เปรียบโครงข่ายประสาทเทียมแบบเดิม เมื่อ  $s_{t-1}$  คือค่าผลลัพธ์ของขั้นก่อนที่ถูกลำไปรวมกับข้อมูลขาเข้า  $x_t$  ณ ช่วงเวลา  $t$  โดยการเชื่อมโยงข้อมูลที่เคยเรียนรู้มาแล้วกับข้อมูลขาเข้า ณ ช่วงเวลาปัจจุบัน ซึ่งกล่าวได้ว่าโครงข่ายประสาทเทียมแบบวนกลับสามารถเชื่อมโยงการเรียนรู้ของข้อมูล ณ ช่วงเวลาปัจจุบันกับข้อมูลที่เคยเรียนรู้มาในอดีต แต่โครงข่ายประสาทเทียมแบบเดิมสนใจแต่ข้อมูล ณ ช่วงเวลาปัจจุบันเท่านั้น

#### 2.4.1 ปัญหาการพึ่งพาระยะยาว (long term dependency)

โครงข่ายประสาทเทียมแบบวนกลับอาจเกิดปัญหาในการประมวลผล เนื่องจากปัญหาการพึ่งพาระยะยาว คือ ถ้าข้อมูลที่มีจำนวนเยอะมากโครงข่ายประสาทเทียมแบบวนกลับจะไม่สามารถเก็บรักษาข้อมูลที่เคยเรียนรู้มาในอดีตทั้งหมดได้ เพราะเกิดปัญหาเกรเดียนต์เลือนหาย (Vanishing gradient problem) จากกระบวนการแพร่ย้อนกลับ เพราะค่าน้ำหนักที่ถูกปรับเปลี่ยนในหน่วยย่อยนั้นเปลี่ยนแปลงน้อยมาก แทบจะเรียกได้ว่าไม่มีการเปลี่ยนแปลงเลย หรือโครงข่ายประสาทเทียมแบบวนกลับนั้น “ลืม” ข้อมูลที่เคยเรียนรู้มาก่อนหน้า เปรียบกับสมองมนุษย์ที่เรียนรู้ข้อมูลบางอย่างต่อเนื่องเป็นเวลายาวนาน จนลืมบางเหตุการณ์ในก่อนหน้า

โครงข่ายประสาทเทียมแบบวนกลับถูกพัฒนาให้สามารถ “จดจำ” ข้อมูลที่เคยเรียนรู้มาในอดีต โดยใช้ “หน่วยความจำ” (Memory) ในวิทยานิพนธ์ฉบับนี้ขอยกตัวอย่างโครงข่ายประสาทเทียมแบบวนกลับที่เสริมหน่วยความจำ 2 โครงข่าย ดังต่อไปนี้

1. โครงข่ายความจำระยะสั้นระยะยาว (Long Short-Term Memory : LSTM)
2. โครงข่าย GRU (Gated Recurrent Unit : GRU)

## 2.4.2 โครงข่ายความจำระยะสั้นระยะยาว (Long Short-Term Memory: LSTM) [27-29]

วิธีการของโครงข่ายความจำระยะสั้นระยะยาวถูกนำเสนอครั้งแรกโดย S. Hochreiter โครงข่ายความจำระยะสั้นระยะยาว พัฒนามาจากโครงข่ายประสาทเทียมแบบวนกลับ เพื่อใช้แก้ปัญหาที่เป็นลำดับ (Sequence) โดยเรียนรู้จากข้อมูลในอดีตระยะยาว (Long-term dependency) เอกลักษณะของโครงข่ายนี้คือ เซลล์ความจำ (Memory cell) ทำหน้าที่เก็บข้อมูลที่สำคัญเพื่อให้รู้ว่าข้อมูลในอดีตเป็นมาอย่างไรและสามารถเลือกได้ว่าข้อมูลไหนควรจดจำข้อมูลไหนควรลบทิ้ง สำหรับการเลือกเก็บข้อมูลขาเข้าของโครงข่ายความจำระยะสั้นระยะยาวนั้น ขึ้นอยู่กับค่าที่ได้รับจากประตู (Gate) 3 ประตู ซึ่งประกอบไปด้วย

1. ประตูขาเข้า (Input gate) มีหน้าที่ประเมินความสำคัญของข้อมูลขาเข้าใหม่
2. ประตูลืม (Forget gate) มีหน้าที่ประเมินความสำคัญของข้อมูลที่ถูกรักษาไว้ในเซลล์ความจำและเลือกจะขจัดหรือลืมเพื่อแทนที่ด้วยข้อมูลใหม่
3. ประตูขาออก (Output gate) มีหน้าที่ควบคุมปริมาณผลลัพธ์โดยประเมินจากข้อมูลที่ถูกรักษาไว้ในเซลล์ความจำ

เขียนสมการของโครงข่ายความจำระยะสั้นระยะยาวได้ดังนี้

ประตูข้อมูลขาเข้า (Input gate)

$$i_t = \sigma(W_i s_{t-1} + U_i x_t + W_{ci} c_{t-1} + b_i) \quad (2.15)$$

กำหนดให้

$i_t$  คือผลลัพธ์ที่ได้จากประตูขาเข้า

$\sigma$  คือฟังก์ชันซิกมอยด์

$W_i$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลชั้นซ่อนในประตูขาเข้า

$S_{t-1}$  คือข้อมูลชั้นซ่อนที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$U_i$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลขาเข้าในประตูขาเข้า

$x_t$  คือข้อมูลขาเข้าที่นำเข้ามาคำนวณ

$W_{ci}$  คือค่าน้ำหนักสำหรับคำนวณเซลล์ความจำในประตูขาเข้า

$c_{t-1}$  คือเซลล์ความจำที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$b_i$  คือไบแอสที่นำมาคำนวณในประตูขาเข้า

ประตูลืม (Forget gate)

$$f_t = \sigma(W_f s_{t-1} + U_f x_t + W_{cf} c_{t-1} + b_f) \quad (2.16)$$

กำหนดให้

$f_t$  คือผลลัพธ์ที่ได้จากประตูลืม

$\sigma$  คือฟังก์ชันซิกมอยด์

$W_f$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลชั้นซ่อนในประตูลืม

$s_{t-1}$  คือข้อมูลชั้นซ่อนที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$U_f$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลขาเข้าในประตูลืม

$x_t$  คือข้อมูลขาเข้าที่นำเข้ามาคำนวณ

$W_{cf}$  คือค่าน้ำหนักสำหรับคำนวณเซลล์ความจำในประตูลืม

$c_{t-1}$  คือเซลล์ความจำที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$b_f$  คือไบแอสที่นำมาคำนวณในประตูลืม

ประตูขาออก (Output gate)

$$o_t = \sigma(W_o s_{t-1} + U_o x_t + W_{co} c_{t-1} + b_o) \quad (2.17)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (2.18)$$

กำหนดให้

$o_t$  คือผลลัพธ์ที่ได้จากประตูขาออก

$\sigma$  คือฟังก์ชันซิกมอยด์

$W_o$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลชั้นซ่อนในประตูขาออก

$s_{t-1}$  คือข้อมูลชั้นซ่อนที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$U_o$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลขาเข้าในประตูขาออก

$x_t$  คือข้อมูลขาเข้าที่นำเข้ามาคำนวณ

$W_{co}$  คือค่าน้ำหนักสำหรับคำนวณเซลล์ความจำในประตูขาออก

$c_{t-1}$  คือเซลล์ความจำที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$b_o$  คือไบแอสที่นำมาคำนวณในประตูขาออก

$h_t$  คือค่าของชั้นซ่อนจากการคำนวณ

ประตูเซลล์ความจำ (Memory Cell State Gate)

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c s_{t-1} + U_c x_t + b_c) \quad (2.19)$$

กำหนดให้

$c_t$  คือผลลัพธ์ที่ได้จากประตูเซลล์ความจำในช่วงหน่วยเวลา

$f_t$  คือค่าผลลัพธ์ที่ได้จากประตูลืม

$c_{t-1}$  คือเซลล์ความจำจากหน่วยเวลาก่อนหน้า

$i_t$  คือผลลัพธ์ที่ได้จากประตูขาเข้า

$\tanh$  คือฟังก์ชันไฮเพอร์โบลิกแทนเจนต์

$W_c$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลชั้นซ่อนในประตูเซลล์ความจำ

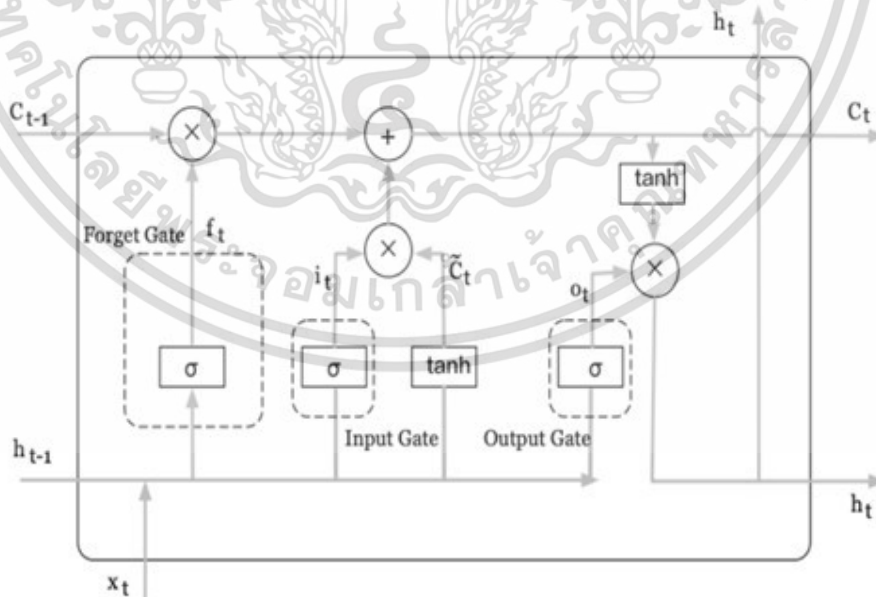
$S_{t-1}$  คือข้อมูลชั้นซ่อนที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$U_c$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลขาเข้าจากประตูเซลล์ความจำ

$x_t$  คือข้อมูลขาเข้าที่นำเข้ามาคำนวณ

$b_c$  คือไบแอสที่นำมาคำนวณในประตูลืม

โครงสร้างของโครงข่ายความจำระยะสั้นระยะยาวสามารถอธิบายได้ดังภาพต่อไปนี้



รูปที่ 2.18 โครงสร้างภายในโครงข่ายความจำระยะสั้นระยะยาว [27]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากสมการที่กล่าวมาข้างต้นจะพบว่ามีการเติมไบแอส  $b_i, b_f, b_o, b_c$  ค่าน้ำหนัก  $W_i, W_f, W_o, W_c$  และค่าน้ำหนักจากชั้นซ่อนที่ได้ในแต่ละตัวแปร  $U_i, U_f, U_o, U_c$  โดยนำน้ำหนักที่ได้มาคำนวณรวมกับผลลัพธ์ชั้นซ่อนในช่วงเวลาก่อนหน้า  $s_{t-1}$  เมื่อนำสมการข้างต้นมารวมกันเป็นโมเดลจะได้สมการดังนี้

ผลลัพธ์จากการทำนาย

$$C_t = f_t \cdot C_{t-1} + i_t \cdot c_t \quad (2.20)$$


ผลลัพธ์ของชั้นซ่อน

$$h_t = o_t \cdot \tanh(c_t) \quad (2.18)$$

สำหรับวิธีการของโครงข่ายความจำระยะสั้นระยะยาว (Long Short-Term Memory : LSTM) จะมีโครงสร้างภายในที่ต่างจากวิธีการของโครงข่ายแบบวนกลับ เพราะวิธีการของโครงข่ายความจำระยะสั้นระยะยาว ออกแบบเพื่อแก้ไขปัญหา Gradient Vanishing ที่เกิดขึ้นกับวิธีการของโครงข่ายแบบวนกลับ ถ้าเกิดการวนซ้ำรอบจำนวนมากจะมีการปรับเปลี่ยนค่าน้ำหนักที่น้อยจนแทบไม่เปลี่ยนแปลง

#### 2.4.3 โครงข่าย GRU (Gated Recurrent Unit: GRU) [30-31]

โครงข่าย GRU ถูกคิดค้นและพัฒนาขึ้นเมื่อปีค.ศ. 2014 โดยถูกพัฒนามาจากโครงข่ายความจำระยะสั้นระยะยาวและมีลักษณะการทำงานคล้ายกับโครงข่ายความจำระยะสั้นระยะยาวแต่มีขนาดเล็กลง โดยพัฒนาในส่วนของลดความซับซ้อนเนื่องจากจำนวนหน่วยย่อยมีจำนวนมาก ซึ่งมีผลต่อการใช้ทรัพยากรและทำให้การทำงานเร็วขึ้น ทั้งนี้โครงข่าย GRU ลดความซับซ้อนในการวิเคราะห์ของโครงข่ายด้วยการลดจำนวนประตู เหลือเพียง 2 ประตู ได้แก่ ประตูอัปเดต และประตูรีเซ็ต พิจารณาโครงสร้างของโครงข่าย GRU จากรูปที่ 2.19 ดังต่อไปนี้



รูปที่ 2.19 ตัวอย่างการทำงานภายในของโครงข่าย GRU [30]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

1. ประตูอัปเดต (Update gate) มีหน้าที่ช่วยกำหนดจำนวนข้อมูลในอดีตจากข้อมูลในขั้นตอนเวลาก่อนหน้า ที่จะส่งต่อไปยังขั้นตอนถัดไป ขั้นตอนนี้มีประสิทธิภาพอย่างมากเพราะสามารถตัดสินใจที่จะเลือกข้อมูลทั้งหมดจากอดีตและลดปัญหาการลืมข้อมูลที่เคยเรียนรู้มาก่อนหน้า
2. ประตูรีเซ็ต (Reset gate) มีหน้าที่ช่วยในการตัดสินใจว่าควรจะลืมข้อมูลในอดีตไปมากน้อยเพียงใด

เขียนสมการของโครงข่าย GRU ได้ดังนี้

กำหนดให้  $z$  คือประตูอัปเดต

$r$  คือประตูรีเซ็ต

ประตูอัปเดต(Update gate)

$$z_t = \sigma(W_z s_{t-1} + U_z x_t + b_z) \quad (2.21)$$

กำหนดให้  $z_t$  คือผลลัพธ์ที่ได้จากประตูอัปเดต

$\sigma$  คือฟังก์ชันซิกมอยด์

$W_z$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลชั้นซ่อนในประตูอัปเดต

$s_{t-1}$  คือข้อมูลชั้นซ่อนที่ได้มาจากการคำนวณในหน่วยเวลาก่อนหน้า

$U_z$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลขาเข้าในประตูอัปเดต

$x_t$  คือข้อมูลขาเข้าที่นำเข้ามาคำนวณ

$b_z$  คือไบแอสที่นำมาคำนวณในประตูอัปเดต

ประตูรีเซ็ต (Reset gate)

$$r_t = \sigma(W_r s_{t-1} + U_r x_t + b_r) \quad (2.22)$$

กำหนดให้  $r_t$  คือผลลัพธ์ที่ได้จากประตูอัปเดต

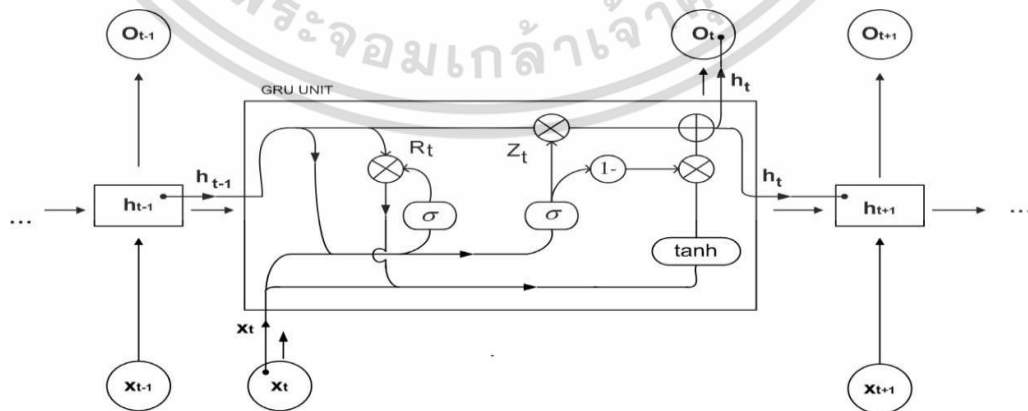
$\sigma$  คือฟังก์ชันซิกมอยด์

- $W_z$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลชั้นซ่อนในประตูลี้เซ้ท
- $S_{t-1}$  คือข้อมูลชั้นซ่อนที่ได้มาจากการคำนวณในหน่วยเวลาดก่อนหน้า
- $U_z$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลขาเข้าในประตูลี้เซ้ท
- $x_t$  คือข้อมูลขาเข้าที่นำเข้ามาคำนวณ
- $b_r$  คือไบแอสที่นำมาคำนวณในประตูลี้เซ้ท

สำหรับการคำนวณหาค่าผลลัพธ์และชั้นซ่อนของโครงข่าย GRU นั้น ทำได้โดยการนำผลลัพธ์ที่ได้จากประตูอัปเดตและประตูลี้เซ้ทมาทำการคำนวณด้วยฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ จากนั้นค่าที่ได้จากประตูลี้เซ้ทจะกำหนดว่าจะทำการล้มหรือทำการจำค่าเดิม หรือล้ค่าเดิมออกไป และทำการคุมปริมาณของข้อมูลด้วยประตูอัปเดต พิจารณาจากสมการ 2.23 ต่อไปนี้

$$h_t = (1 - z_t) \cdot \tanh(r_t \cdot W_h s_{t-1} + U_h x_t) + z_t s_{t-1} \tag{2.23}$$

- กำหนดให้
- $h_t$  คือผลลัพธ์ชั้นซ่อนที่ได้จากการคำนวณ
  - $z_t$  คือค่าที่ได้จากประตูอัปเดต
  - $\tanh$  คือฟังก์ชันไฮเพอร์โบลิกแทนเจนต์
  - $r_t$  คือค่าที่ได้จากประตูอัปเดต
  - $W_h$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลชั้นซ่อนจากหน่วยเวลาดก่อนหน้า
  - $S_{t-1}$  คือข้อมูลชั้นซ่อนที่ได้มาจากการคำนวณในหน่วยเวลาดก่อนหน้า
  - $U_h$  คือค่าน้ำหนักสำหรับคำนวณข้อมูลขาเข้า
  - $x_t$  คือข้อมูลขาเข้าที่นำเข้ามาคำนวณ




รูปที่ 2.20 โครงสร้างภายในโครงข่าย GRU

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

#### 2.4.4 การเชื่อมต่อของชั้นในโครงข่าย GRU

การเชื่อมโยงในแต่ละชั้นของโครงข่าย GRU จะมีการนำค่าผลลัพธ์ของสถานะก่อนหน้ามาเป็นข้อมูลขาเข้าให้กับสถานะปัจจุบัน โดยค่าเริ่มต้นของตัวอย่างนี้ คือ timestep  $t-1$  เนื่องจากเป็นค่าสถานะเริ่มต้นจึงไม่มีค่าผลลัพธ์ของสถานะก่อนหน้า พิจารณา timestep  $t-1$  แบ่งออกเป็น 4 ชั้น ดังต่อไปนี้

1. ชั้นขาเข้า ประกอบด้วย 2 ส่วน ได้แก่ ค่าผลลัพธ์ของสถานะก่อนหน้า (Initialize) และค่าผลลัพธ์ที่ time-step นี้คือ  $x_{t-1}$
2. ชั้นซ่อนที่ 1 เป็นชั้นของเซลล์โครงข่าย GRU ซึ่งมีค่าผลลัพธ์  $h_{t-1}$  เป็นผลรวมของเซลล์โครงข่าย GRU ในชั้นนี้ และมีการ initialize ค่าผลลัพธ์  $g_{t-1}$  ของ time-step ก่อนหน้านี้ด้วย
3. ชั้นซ่อนที่ 2 เป็นชั้นของเซลล์โครงข่าย GRU ซึ่งมีค่าผลลัพธ์  $g_{t-1}$  เป็นผลรวมของแต่ละเซลล์โครงข่าย GRU ในชั้นนี้
4. ชั้นส่งออก จะเป็นข้อมูลขาเข้าให้กับชั้นซ่อนที่ 1 ใน time-step ถัดไป

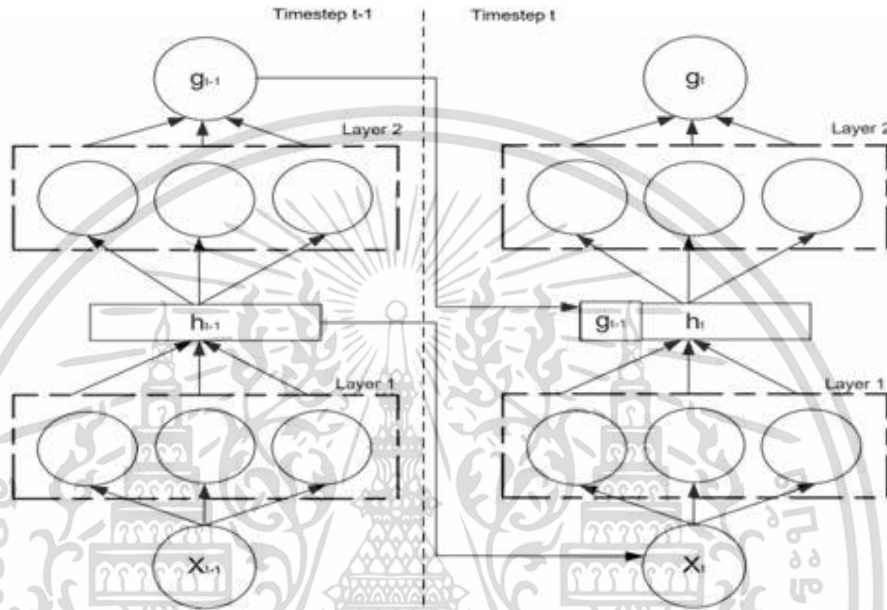


รูปที่ 2.21 การเชื่อมต่อของชั้นโครงข่าย GRU แบบย่อ

พิจารณา timestep  $t$  แบ่งออกเป็น 4 ชั้น ดังต่อไปนี้

1. ชั้นขาเข้า  $h_{t-1}$  คือค่าผลลัพธ์ของชั้นซ่อนที่ 2 ของ timestep  $t-1$  และ  $x_t$  คือข้อมูลขาเข้าที่ timestep ปัจจุบัน
2. ชั้นซ่อนที่ 1 เป็นชั้นของเซลล์โครงข่าย GRU

3. ชั้นซ่อนที่ 2  $g_{t-1}$  คือข้อมูลขาออกชั้นซ่อนที่ 2 ของ timestep ก่อนหน้า และค่า  $h_t$  คือข้อมูลขาออกของชั้นซ่อนที่ 1 ของ timestep ก่อนหน้า
4. ชั้นส่งออกจะเป็นข้อมูลขาเข้าให้ชั้นซ่อนที่ 1 ใน timestep ถัดไป



รูปที่ 2.22 การเชื่อมต่อของชั้นโครงข่าย GRU แบบละเอียด

#### 2.4.5 ข้อดีและข้อเสียของโครงข่ายประสาทเทียมแบบวนกลับ

โครงข่ายประสาทเทียมแบบวนกลับแต่ละประเภทมีข้อดีและข้อเสียที่แตกต่างกัน ดังนี้

ข้อดีของโครงข่ายประสาทเทียมแบบวนกลับแต่ละประเภท

1. แบบโครงข่ายประสาทเทียมแบบวนกลับ (Recurrent neural network: RNN) ใน ส่วนของข้อมูลที่เป็นลำดับเวลาโครงข่ายประสาทเทียมแบบวนกลับให้ประสิทธิภาพ ที่ดีกว่าโครงข่ายประสาทเชิงลึก (Deep neural network: DNN)
2. โครงข่ายความจำระยะสั้นระยะยาว (Long short-term memory) สำหรับข้อมูลที่มีความสัมพันธ์สถานะระยะยาว โครงข่ายความจำระยะสั้นระยะยาวให้ ประสิทธิภาพที่ดีกว่าโครงข่าย GRU เนื่องจากมีหน่วยความจำภายในทำให้สามารถ จำความสัมพันธ์ของสถานะระยะยาวได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. โครงข่าย GRU (Gated recurrent unit) มีโครงสร้างซับซ้อนน้อยกว่าโครงข่ายความจำระยะสั้นระยะยาว เพราะมีพารามิเตอร์น้อยกว่าทำให้ฝึกสอนได้เร็วและมีประสิทธิภาพมากกว่าหรือเทียบเท่าโครงข่ายความจำระยะสั้นระยะยาว

ข้อเสียของโครงข่ายประสาทเทียมแบบวนกลับแต่ละประเภท

1. โครงข่ายประสาทเทียมแบบวนกลับ (Recurrent neural network: RNN) ไม่สามารถลืมนสถานะก่อนหน้าได้
2. โครงข่ายความจำระยะสั้นระยะยาว (Long short-term memory) เนื่องจากมีพารามิเตอร์เยอะ ประกอบด้วย ประตูขาเข้า (Input gate) ประตูลืม (Forget gate) ประตูขาออก (Output gate) และ 1 หน่วยเซลล์ความจำ (Memory Cell) ทำให้การฝึกสอนข้อมูลของแบบจำลองจึงทำได้ช้า
3. โครงข่าย GRU (Gated recurrent unit) จะให้ประสิทธิภาพที่แย่กว่าโครงข่ายความจำระยะสั้นระยะยาว สำหรับข้อมูลที่มีความสัมพันธ์สถานะระยะยาว

## 2.5 การประเมินประสิทธิภาพ (Performance Evaluation)

ในการประเมินประสิทธิภาพของแบบจำลองในการทำนายผลลัพธ์ของข้อมูลที่อยู่ในรูปตัวเลข จะใช้ค่าความผิดพลาดที่เกิดขึ้นของการทำนายชุดข้อมูลทดสอบด้วยการเปรียบเทียบค่าของผลลัพธ์จากการทำนายกับค่าของผลลัพธ์ที่เกิดขึ้นจริง โดยในวิทยานิพนธ์นี้จะนำเสนอวิธีการประเมินประสิทธิภาพในแต่ละรอบ 3 วิธี ดังแสดงในสมการต่อไปนี้

1. ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าคลาดเคลื่อนสัมบูรณ์ หรือ MAE ย่อมาจาก “Mean Absolute Error” คำนวณโดยหาผลรวมของค่า absolute(error) แล้วคูณกับ  $1/n$  เพื่อเปลี่ยนเป็นค่าเฉลี่ย เขียนสมการได้ดังนี้

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (2.24)$$

กำหนดให้

$n$  คือจำนวนข้อมูลทั้งหมด

$y$  คือค่าของข้อมูลที่แท้จริง

$\hat{y}_i$  คือค่าของผลลัพธ์ที่ได้จากการทำนาย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง หรือ MSE จะมีการทำให้ค่า Error กลายเป็นบวกก่อนโดยการนำค่า Error มายกกำลังสองก่อนที่จะนำค่า Error มาหาค่าเฉลี่ย เขียนสมการได้ดังนี้

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.25)$$

กำหนดให้

$n$  คือจำนวนข้อมูลทั้งหมด

$y$  คือค่าของข้อมูลที่แท้จริง

$\hat{y}_i$  คือค่าของผลลัพธ์ที่ได้จากการทำนาย

3. รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เป็น Loss Function ที่จะนำค่าเฉลี่ยความผิดพลาดยกกำลังสองมาใส่รากที่สอง (Square Root) จึงทำให้มีคุณสมบัติที่คล้ายกับค่าเฉลี่ยความผิดพลาดยกกำลังสอง แต่ต่างกันตรงที่หน่วยของค่า Error จะไม่มีเลขยกกำลังสอง จึงให้อ่านค่าได้ง่ายกว่า เนื่องจากหน่วยของรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสองนั้นมีหน่วยเดียวกันกับค่าที่แบบจำลองทำนายไว้เขียนสมการได้ดังนี้

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{n}} \quad (2.26)$$

กำหนดให้

$n$  คือจำนวนข้อมูลทั้งหมด

$y$  คือค่าของข้อมูลที่แท้จริง

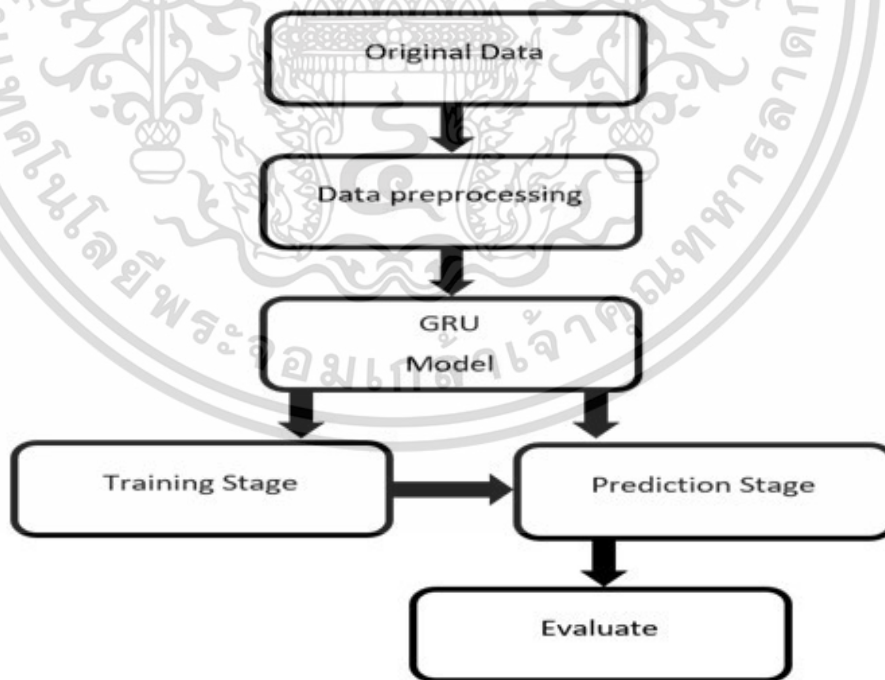
$\hat{y}_i$  คือค่าของผลลัพธ์ที่ได้จากการทำนาย

จากที่กล่าวมาข้างต้นนั้น เป็นทฤษฎีเกี่ยวกับงานวิจัยนี้โดยเทคนิคของโครงข่ายประสาทเทียม ซึ่งใช้หลักการเรียนรู้จากชุดข้อมูลตัวอย่างเพื่อทำนายผลลัพธ์กับข้อมูลชุดใหม่ และการประเมินประสิทธิภาพหรือการประเมินค่าความผิดพลาดที่ได้จากการทำนายเพื่อวัดประสิทธิภาพของการทำนาย ซึ่งในแต่ละตัวชี้วัดก็จะต้องเลือกใช้ให้เหมาะสมกับปัญหานั้นๆ

## บทที่ 3 ระเบียบวิธีวิจัย

### 3.1 บทนำ

งานวิจัยนี้มีวัตถุประสงค์เพื่อนำเสนอวิธีการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบินที่สนามบินนานาชาติภูเก็ตในประเทศไทยด้วยการใช้โครงข่าย GRU โดยกระบวนการทำงานของงานวิจัยนี้ประกอบด้วยการทำงานทั้งหมด 5 ส่วน ได้แก่ ข้อมูลที่นำมาใช้ในงานวิจัยและแบบจำลอง การเตรียมข้อมูลก่อนนำมาวิจัย (Data preprocessing) การเรียนรู้ข้อมูลของแบบจำลองโครงข่าย GRU การทำนายผลของแบบจำลองโครงข่าย GRU และการประเมินประสิทธิภาพการทำนายระดับความสูงของการบินขึ้นและลงจอดของเครื่องบิน ดังแสดงในรูปที่ 3.1 โดยเริ่มต้นจากการเตรียมข้อมูลการบินขึ้นและลงจอดของเครื่องบิน เพื่อความเป็นระเบียบและง่ายต่อการนำไปใช้ก่อนนำข้อมูลที่ผ่านการจัดระเบียบแล้วเข้าสู่แบบจำลองโครงข่าย GRU ทั้งในส่วนการเรียนรู้และทำนายผล ผลลัพธ์สุดท้ายที่ได้จากการทำนายผล คือ ระดับความสูงของการบินขึ้นและลงจอดของเครื่องบิน จากนั้นนำผลลัพธ์ที่ได้จากการทำนายระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินไปเปรียบเทียบกับระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินจริง เพื่อประเมินประสิทธิภาพของวิธีการทำนายทั้งการบินขึ้นและลงจอดของเครื่องบินที่สนามบินนานาชาติภูเก็ต




รูปที่ 3.1 กระบวนการทำงานของงานวิจัย


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.2 ข้อมูลที่นำมาใช้ในงานวิจัยและแบบจำลอง

เนื่องด้วยบริเวณของสนามบินนานาชาติภูเก็ตคือจุดที่มีภูมิประเทศเป็นเกาะ และมีลมพัดตลอดเวลาของข้อมูลที่ได้รับ และเป็นจุดที่น่าสนใจ (point of interest) จึงเป็นจุดเริ่มต้นของช่วงที่สนใจจะศึกษาการบินขึ้นของเครื่องบิน โดยการเลือกช่วงการบินขึ้นของเครื่องบินที่ใช้ในการวิจัยหลักจะเลือกช่วงระดับความสูงไม่เกิน 40,000 ft ที่กำลังบินขึ้นจากสนามบินนานาชาติภูเก็ต ดังแสดงในรูปที่ 3.2 และเลือกช่วงการบินลงจอดของเครื่องบินที่ใช้ในการวิจัยหลักจะเลือกช่วงระดับความสูงไม่เกิน 40,000 ft ที่กำลังลงจอดที่สนามบินนานาชาติภูเก็ต ดังแสดงในรูปที่ 3.3 จึงตั้งสมมุติฐานว่าถ้าหากใช้ข้อมูลระดับความสูงในช่วงดังกล่าวมาศึกษาจะส่งผลให้แบบจำลองโครงข่าย GRU สามารถใช้ในการทำนายระดับความสูงของการบินขึ้นและลงจอดได้ และโครงสร้างของแบบจำลองโครงข่าย GRU แสดงดังรูปที่ 3.4



รูปที่ 3.2 บริเวณช่วงการบินขึ้นของเครื่องบินจากสนามบินนานาชาติภูเก็ตที่ใช้ในการวิจัย



รูปที่ 3.3 บริเวณช่วงการลงจอดของเครื่องบินที่สนามบินนานาชาติภูเก็ตที่ใช้ในการวิจัย

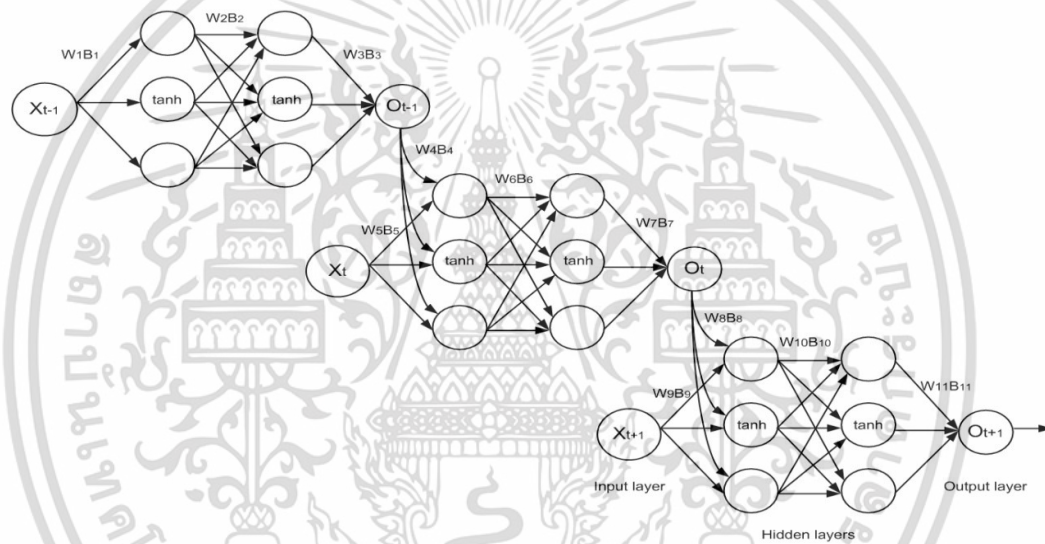
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แบบจำลองสำหรับการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน ได้ออกแบบแบบจำลองที่มีการทำงาน 3 โหมดสเต็ป ใน 1 โหมดสเต็ป ประกอบด้วย 3 ชั้น: 1 ชั้นข้อมูลขาเข้า 2 ชั้นซ่อน และ 1 ชั้นข้อมูลขาออก

โดยโหมดสเต็ป 1 ของการบินขึ้นใช้เวลาในการคำนวณประมาณ 5 วินาที, การบินลงใช้เวลาในการคำนวณประมาณ 5 วินาที

โดยโหมดสเต็ป 2 ของการบินขึ้นใช้เวลาในการคำนวณประมาณ 4 วินาที, การบินลงใช้เวลาในการคำนวณประมาณ 4 วินาที

โดยโหมดสเต็ป 3 ของการบินขึ้นใช้เวลาในการคำนวณประมาณ 2 วินาที, การบินลงใช้เวลาในการคำนวณประมาณ 2 วินาที



รูปที่ 3.4 แบบจำลองทำนายระดับความสูงของเครื่องบิน

โดยพื้นฐานแล้วหากเราต้องการความแม่นยำที่มากขึ้นเราจะเพิ่มจำนวนชั้นของ Hidden layer และจำนวนเซลล์ประสาท (Neural) ให้มากขึ้นก็จะช่วยได้ แต่ไม่เสมอไปไม่จำเป็นต้องเพิ่ม Hidden layer หรือจำนวนเซลล์ประสาท (Neural) ในบางครั้งค่าน้อยๆก็ให้ผลลัพธ์ที่ดีที่สุด

### 3.3 การเตรียมข้อมูลก่อนนำมาวิจัย (Data Preprocessing)

การเตรียมข้อมูลที่ได้จากการบินขึ้นและลงจอดของเครื่องบิน จะต้องทำการคัดข้อมูลที่ไมเกี่ยวข้องหรือข้อมูลเสีย (Noise data) เพื่อลดปัญหาที่จะเกิดขึ้นในการเรียนรู้ โดยมีขั้นตอนดังแสดงในรูปที่ 3.5 เป็นขั้นตอนที่สำคัญมากในกระบวนการทำงานด้านข้อมูล ซึ่งถ้าการเตรียมข้อมูลก่อนนำมาวิจัยไม่ดีย่อมจะส่งผลให้การทำงานในขั้นตอนอื่นๆ ไม่มีประสิทธิภาพตามไปด้วย โดยผลกระทบที่เกิดขึ้นอาจทำให้เสียเวลา และต้องทำใหม่ หรือผลกระทบที่ร้ายแรงกว่าอาจส่งผลให้การวิเคราะห์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หรือการทำนายจากการนำข้อมูลไปใช้ ผิดจากที่ควรจะเป็น ดังนั้นก่อนนำข้อมูลไปใช้ในงานวิจัยควรมีการตรวจสอบคุณภาพของข้อมูล ทำให้ข้อมูลอยู่ในรูปแบบที่ถูกต้อง เพื่อให้ข้อมูลอยู่ในรูปแบบที่สามารถนำไปใช้ในงานวิจัยต่อในขั้นตอนอื่นอย่างมีประสิทธิภาพ เริ่มจากการทำความสะอาดข้อมูล (Cleaning data) การทำความสะอาดข้อมูลเป็นการทำงานที่เกี่ยวกับการตรวจสอบและแก้ไขข้อมูล โดยขั้นตอนของการทำความสะอาดข้อมูลนับเป็นขั้นตอนแรกที่สำคัญของการเตรียมข้อมูลก่อนนำมาวิจัย ดังนั้นในการทำความสะอาดข้อมูลนั้นจึงต้องตรวจสอบว่ามีข้อผิดพลาดอะไรเกิดขึ้นกับข้อมูลบ้าง เช่น มีการจัดเก็บข้อมูลที่ซ้ำซ้อน (Duplicate data) ข้อมูลไม่ถูกต้อง (Incorrectly data) ข้อมูลเก่าล้าสมัย (Expired data) เกิดการสูญหายของข้อมูลในบางส่วน (Missing Value) มีค่าข้อมูลที่มีความผิดปกติหรือแตกต่างไปจากข้อมูลในกลุ่ม (Outliers) จากนั้นทำการปรับปรุงข้อมูล โดยวิธีการอาจใช้การแทนที่ด้วยการแก้ไขเป็นค่าที่ถูกต้องหรือแทนด้วยค่าใหม่ หรือทำการลบข้อมูลที่ไมถูกต้องเหล่านั้นออกไป เป็นต้น การรวบรวมข้อมูล (Data integration) ขั้นตอนในการรวบรวมข้อมูลทั้งหมดที่มีจากแหล่งข้อมูลต่างๆ มาไว้ด้วยกัน จากนั้นการเลือกข้อมูล (Data selection) คือการคัดเลือกข้อมูลที่เกี่ยวข้องกับข้อมูลที่จะใช้วิเคราะห์ เลือกข้อมูลที่มีความสัมพันธ์กัน ส่งผลต่อกันเป็นประโยชน์ต่อการทำนาย ขั้นตอนสุดท้าย การแปลงข้อมูล (Data Transformation) การแปลงข้อมูลเป็นอีกขั้นตอนหนึ่งที่สำคัญในกระบวนการเตรียมข้อมูลเพื่อนำไปวิเคราะห์ โดยวิธีการปรับช่วงขอบเขตของข้อมูล (Normalization) เนื่องจากลักษณะของข้อมูลการขึ้นและลงจอดของเครื่องบินมีมาตราส่วนของค่าที่ได้แตกต่างกัน รวมทั้งค่าของชุดข้อมูลที่เต็มลักษณะการกระจายตัวที่ไม่ใช่การแจกแจง (Normal distribution) จึงจำเป็นต้องปรับช่วงขอบเขตของข้อมูลทั้งหมดให้อยู่ในมาตราส่วนเดียวกัน โดยวิธีการปรับช่วงขอบเขตของข้อมูลด้วยค่าสูงสุดและต่ำสุด (Min-max Normalization) ซึ่งเป็น การปรับช่วงของข้อมูลให้อยู่ในช่วง 0 – 1 สามารถเขียนสมการ



รูปที่ 3.5 ขั้นตอนการปรับปรุงคุณภาพของข้อมูลก่อนนำมาวิจัย

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

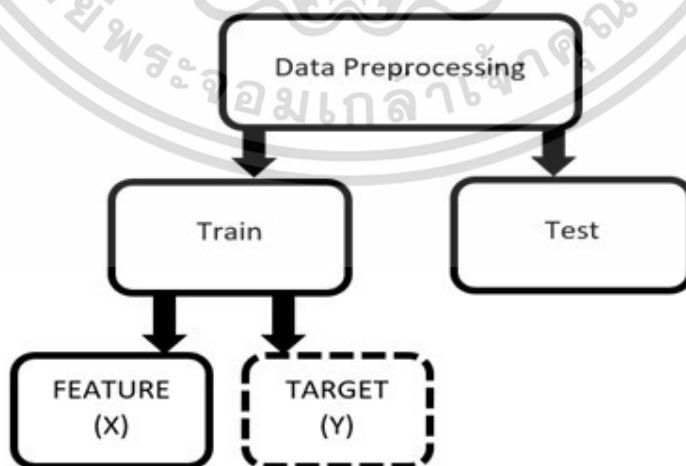
### 3.4 การเรียนรู้ข้อมูลของแบบจำลองโครงข่าย GRU

การเรียนรู้ข้อมูลการบินขึ้นและลงจอดของโครงข่าย GRU มีขั้นตอนการทำงานทั้งหมด 4 ขั้นตอน ได้แก่ การจัดเตรียมข้อมูลสำหรับการเรียนรู้ การเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน การเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน และภาพรวมการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน โดยกำหนดให้การเรียนรู้ของแบบจำลองโครงข่าย GRU มีอัตราการเรียนรู้ (learning rate) 0.1 ดำเนินการ (Epochs) 2,000 รอบ

#### 3.4.1 การจัดเตรียมข้อมูลสำหรับการเรียนรู้ (Data Mining)

การจัดเตรียมข้อมูลสำหรับการเรียนรู้ (Data Mining) เป็นขั้นตอนที่ใช้ในการนำข้อมูลที่พร้อมแล้วมาสร้างแบบจำลอง โดยเริ่มจากการเตรียมข้อมูลก่อนนำมาวิจัย (Data Preprocessing) และเลือกเทคนิคที่เหมาะสมกับชุดข้อมูล หลังจากนั้นจะทำการเรียนรู้ (Train) ให้แบบจำลองมีการเรียนรู้ลักษณะของข้อมูลว่าชุดข้อมูลทั้งหมดมีความสัมพันธ์กันอย่างไร โดยการเรียนรู้ของแบบจำลองจำเป็นต้องกำหนดพารามิเตอร์ (Parameter) ให้เหมาะสม ซึ่งในการพิจารณาค่าพารามิเตอร์นั้นขึ้นอยู่กับประสิทธิภาพในการวิเคราะห์ เทคนิคที่เลือกใช้ และการลองผิดลองถูก จากนั้นนำแบบจำลองที่ได้ไปทดสอบหาค่าความผิดพลาดของแบบจำลอง โดยการนำข้อมูลจริงที่เตรียมไว้สำหรับการทดสอบมาป้อนลงในแบบจำลองแล้วดูผลของการทำนายที่ได้ โดยแบ่งขั้นตอนการจัดเตรียมข้อมูลดังนี้


1.) กำหนดข้อมูลเป้าหมายการเรียนรู้ เป็นการเลือกเอาข้อมูลการบินขึ้นและลงจอดของเครื่องบินที่เป็นจริง มาสร้างเป็นข้อมูลเป้าหมายการเรียนรู้ระดับความสูงของแบบจำลองโครงข่าย GRU โดยแบ่งข้อมูลเป้าหมาย ดังแสดงในรูปที่ 3.6



รูปที่ 3.6 การกำหนดข้อมูลเป้าหมายการเรียนรู้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.) การแบ่งข้อมูลเพื่อการเรียนรู้ เป็นการเลือกเอาข้อมูลของการบินขึ้นและลงจอดที่เกิดขึ้นจริง มาจำแนกเป็นข้อมูลเพื่อการเรียนรู้และข้อมูลเป้าหมายในแต่ละไทม์สเต็ป (timestep) ของแบบจำลองโครงข่าย GRU โดยแบ่งข้อมูลออกเป็น 3 ไทม์สเต็ป ดังแสดงในรูปที่ 3.7

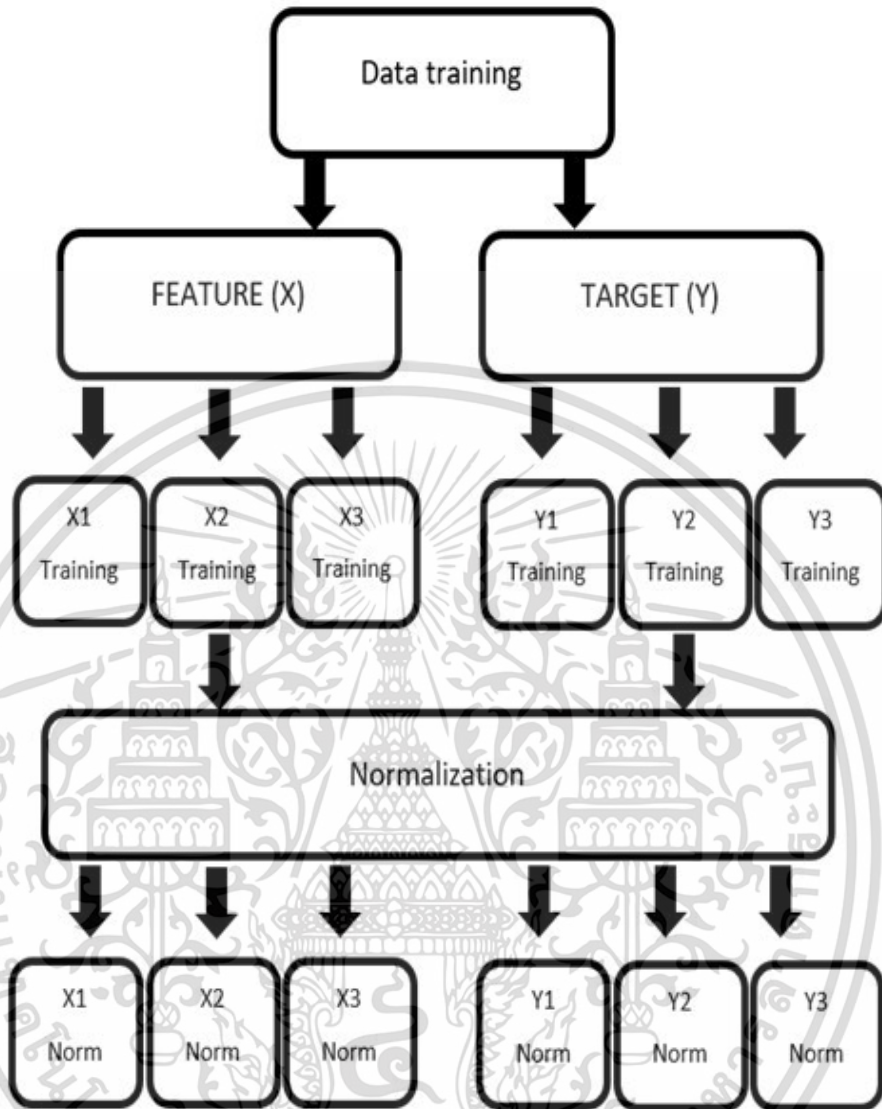


รูปที่ 3.7 ขั้นตอนการจัดเตรียมข้อมูลของแบบจำลองโครงข่าย GRU

โดยในแต่ละไทม์สเต็ป มีการแบ่งข้อมูลและนำไปใช้งาน ดังต่อไปนี้

- ไทม์สเต็ป1 เป็นการแบ่งข้อมูลเพื่อการเรียนรู้(X1) และข้อมูลเป้าหมายการเรียนรู้(Y1) ชุดที่ 1 ของข้อมูลจริงจากข้อมูลการบินขึ้นและลงจอดของเครื่องบินทั้งหมด เพื่อให้แบบจำลองเรียนรู้ข้อมูลสำหรับการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ระดับความสูงของเครื่องบิน
- ไทม์สเต็ป2 เป็นการแบ่งข้อมูลเพื่อการเรียนรู้(X2) และข้อมูลเป้าหมายการเรียนรู้(Y2) ชุดที่ 2 ของข้อมูลจริงจากข้อมูลการบินขึ้นและลงจอดของเครื่องบินทั้งหมด มาสร้างเป็นข้อมูลเพื่อการเรียนรู้สำหรับการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ระดับความสูงของเครื่องบิน โดยแบบจำลองจะเรียนรู้ข้อมูลไทม์สเต็ปปัจจุบัน(ไทม์สเต็ป2)และเรียนรู้ข้อมูลในอดีต(ไทม์สเต็ป1) เพื่อเลือกที่จะส่งข้อมูลต่อไปยังไทม์สเต็ปถัดไปเท่าไรและตัดสินใจว่าจะลิมข้อมูลในอดีตมากน้อยเท่าไร
- ไทม์สเต็ป3 เป็นการแบ่งข้อมูลเพื่อการเรียนรู้(X3) และข้อมูลเป้าหมายการเรียนรู้(Y3) ชุดที่ 3 ของข้อมูลจริงจากข้อมูลการบินขึ้นและลงจอดของเครื่องบินทั้งหมด มาสร้างเป็นข้อมูลเพื่อการเรียนรู้สำหรับการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ระดับความสูงของเครื่องบิน โดยแบบจำลองจะเรียนรู้ข้อมูลไทม์สเต็ปปัจจุบัน(ไทม์สเต็ป3)และเรียนรู้ข้อมูลในอดีต(ไทม์สเต็ป2) และทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

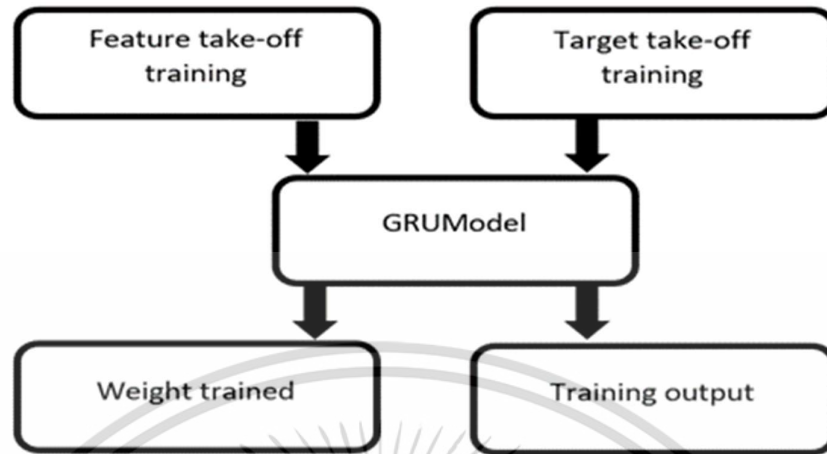
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.8 การปรับช่วงขอบเขตของข้อมูลในการเรียนรู้

#### 3.4.2 การเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน


การเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน เป็นกระบวนการป้อนข้อมูลเพื่อให้แบบจำลองทำการเรียนรู้คุณลักษณะของข้อมูลการบินขึ้นของเครื่องบิน โดยอาศัยการทำงานของแบบจำลองโครงข่าย GRU มีขั้นตอนดังรูปที่ 3.9 เริ่มจากการนำข้อมูลที่ปรับช่วงขอบเขตแล้ว (Normalization) ที่ผ่านการแบ่งส่วนข้อมูลออกเป็น 3 ส่วน จากขั้นตอนการจัดเตรียมข้อมูลสำหรับการเรียนรู้ เพื่อเข้าสู่กระบวนการเรียนรู้ของแบบจำลองโครงข่าย GRU โดยกำหนดให้ ข้อมูล ข้อมูลขาเข้าเป็นข้อมูลสำหรับการเรียนรู้ ข้อมูลเป้าหมายการเรียนรู้เป็นตัวกำหนดความถูกต้องในการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้แต่ละรอบ



รูปที่ 3.9 ขั้นตอนการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน

### 3.4.3 การเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน

การเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน เป็นกระบวนการป้อนข้อมูลเพื่อให้แบบจำลองทำการเรียนรู้คุณลักษณะของข้อมูลการบินขึ้นของเครื่องบิน โดยอาศัยการทำงานของแบบจำลองโครงข่าย GRU มีขั้นตอนดังรูปที่ 3.10 เริ่มจากการนำข้อมูลที่ปรับช่วงขอบเขตแล้ว (Normalization) ที่ผ่านการแบ่งส่วนข้อมูลออกเป็น 3 ส่วน จากขั้นตอนการจัดเตรียมข้อมูลสำหรับการเรียนรู้ เพื่อเข้าสู่กระบวนการเรียนรู้ของแบบจำลองโครงข่าย GRU โดยกำหนดให้ ข้อมูล ข้อมูลขาเข้าเป็นข้อมูลสำหรับการเรียนรู้ ข้อมูลเป้าหมายการเรียนรู้เป็นตัวกำหนดความถูกต้องในการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้แต่ละรอบ

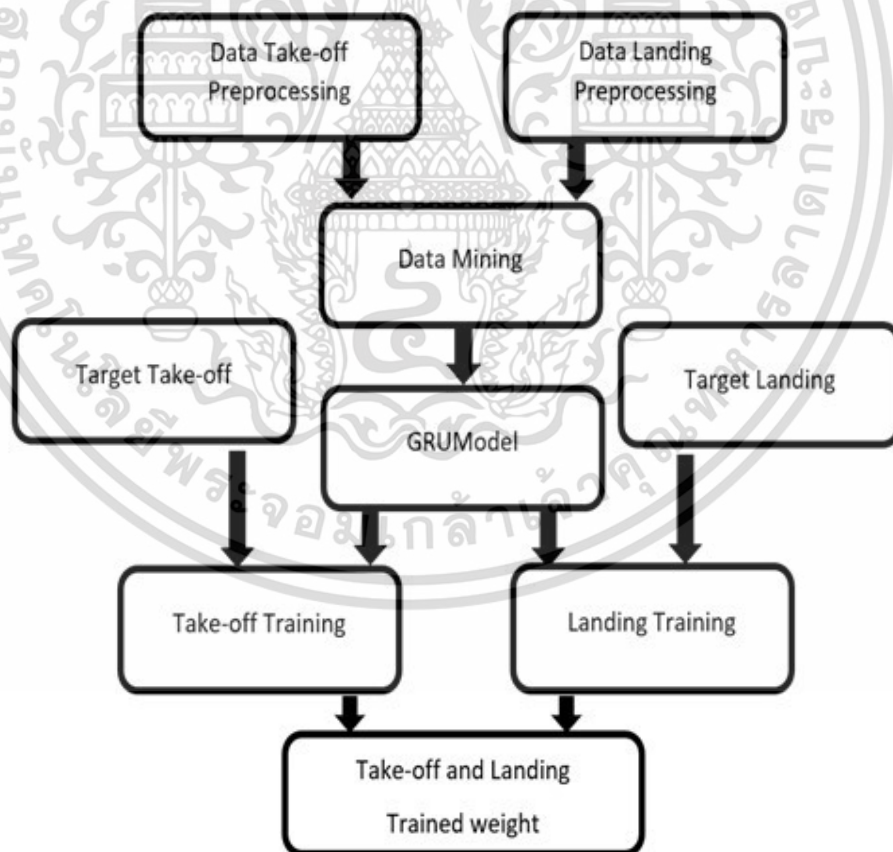


รูปที่ 3.10 ขั้นตอนการเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.4.4 ภาพรวมการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

ภาพรวมขั้นตอนการเรียนรู้ของโครงข่าย GRU เป็นกระบวนการป้อนข้อมูลเพื่อให้แบบจำลองได้มีการเรียนรู้คุณลักษณะต่างๆ ของข้อมูลการบินขึ้นและลงจอดของเครื่องบิน โดยอาศัยหลักการทำงานของแบบจำลองโครงข่าย GRU ซึ่งเป็นขั้นตอนต่อจากการเรียนรู้ข้อมูลของแบบจำลองโครงข่าย GRU มีขั้นตอนดังรูปที่ 3.11 เริ่มจากการนำข้อมูลที่ใช้เป็นข้อมูลขาเข้าในการเรียนรู้ข้อมูลของแบบจำลองโครงข่าย GRU มาจัดข้อมูลให้อยู่ในรูปแบบเมทริกซ์ (matrix) และปรับช่วงขอบเขตของข้อมูล (Normalization) เพื่อจำกัดช่วงขอบเขตของข้อมูลที่ต้องการให้แบบจำลองเรียนรู้ รวมถึงเพิ่มความแม่นยำของการเรียนรู้ของแบบจำลอง จากนั้นนำข้อมูลที่ได้จากการแบ่งไหมส์เต็ปและปรับช่วงขอบเขตของข้อมูล เข้าสู่กระบวนการทำงานของแบบจำลองโครงข่าย GRU ซึ่งใช้กระบวนการของโครงข่ายประสาทเทียมแบบไปข้างหน้า (Feedforward) ฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic Tangent Function : Tanh) และ กระบวนการแพร่กลับ (Backpropagation) โดยกำหนดให้ ข้อมูลเป้าหมายการเรียนรู้เป็นตัวกำหนดความถูกต้องในการคำนวณหาความคลาดเคลื่อนของผลลัพธ์การเรียนรู้คุณลักษณะระดับความสูงในแต่ละรอบ



รูปที่ 3.11 ภาพรวมการเรียนรู้ระดับความสูงของการบินขึ้นและลงจอดของเครื่องบิน

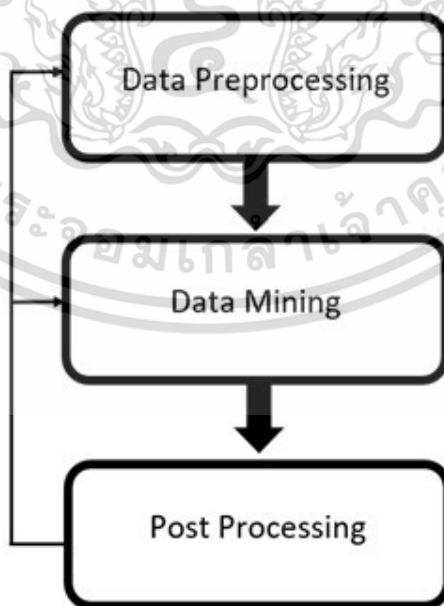
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5 การทำนายผลของแบบจำลองโครงข่าย GRU

การทำนายผลระดับความสูงของการบินขึ้นและลงจอดของเครื่องบิน เป็นการนำแบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้ข้อมูล มาใช้หาผลลัพธ์ต่างๆ โดยมีขั้นตอนการทำงานทั้งหมด 4 ขั้นตอน ได้แก่ การจัดเตรียมข้อมูลสำหรับการทำนายผล การทำนายผลระดับความสูงการบินขึ้นของเครื่องบิน การทำนายผลระดับความสูงการลงจอดของเครื่องบิน และภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน โดยกำหนดให้การทำนายผลของแบบจำลองโครงข่าย GRU มีอัตราการเรียนรู้ (learning rate) 0.1 ดำเนินการ (Epochs) 2,000 รอบ

#### 3.5.1 การจัดเตรียมข้อมูลสำหรับการทำนายผล (Post Processing)

การจัดเตรียมข้อมูลสำหรับการทำนายผล (Post Processing) ระดับความสูงการบินขึ้นและลงจอดของเครื่องบินโดยแบบจำลองโครงข่าย GRU มีขั้นตอนดังแสดงในรูปที่ 3.12 คือขั้นตอนสุดท้ายของการวิจัย เป็นขั้นตอนการนำผลลัพธ์ที่ได้มาประเมินผล ซึ่งในขั้นตอนนี้หากผลการทดสอบ (Test) ไม่เป็นที่น่าพอใจจะต้องทำการจัดข้อมูลใหม่ เพื่อให้ได้ค่าความถูกต้อง (Accuracy) มากที่สุด หรือค่าความคลาดเคลื่อนในการทำนายน้อยที่สุด (Error) เริ่มจากการเตรียมข้อมูลก่อนนำมาวิจัย (Data Preprocessing) ที่ผ่านกระบวนการเตรียมข้อมูล (Data Mining) ที่เป็นขั้นตอนการนำข้อมูลเข้าสู่แบบจำลองเพื่อให้แบบจำลองได้เรียนรู้ ก่อนนำข้อมูลสำหรับการทดสอบ (Test) มาประเมินผลของแบบจำลองที่ทำนายจากเหตุการณ์ที่เกิดขึ้นจริงว่ามีความผิดพลาดมากน้อยเพียงใด การทำนายที่ได้นั้นเป็นไปตามความต้องการหรือไม่

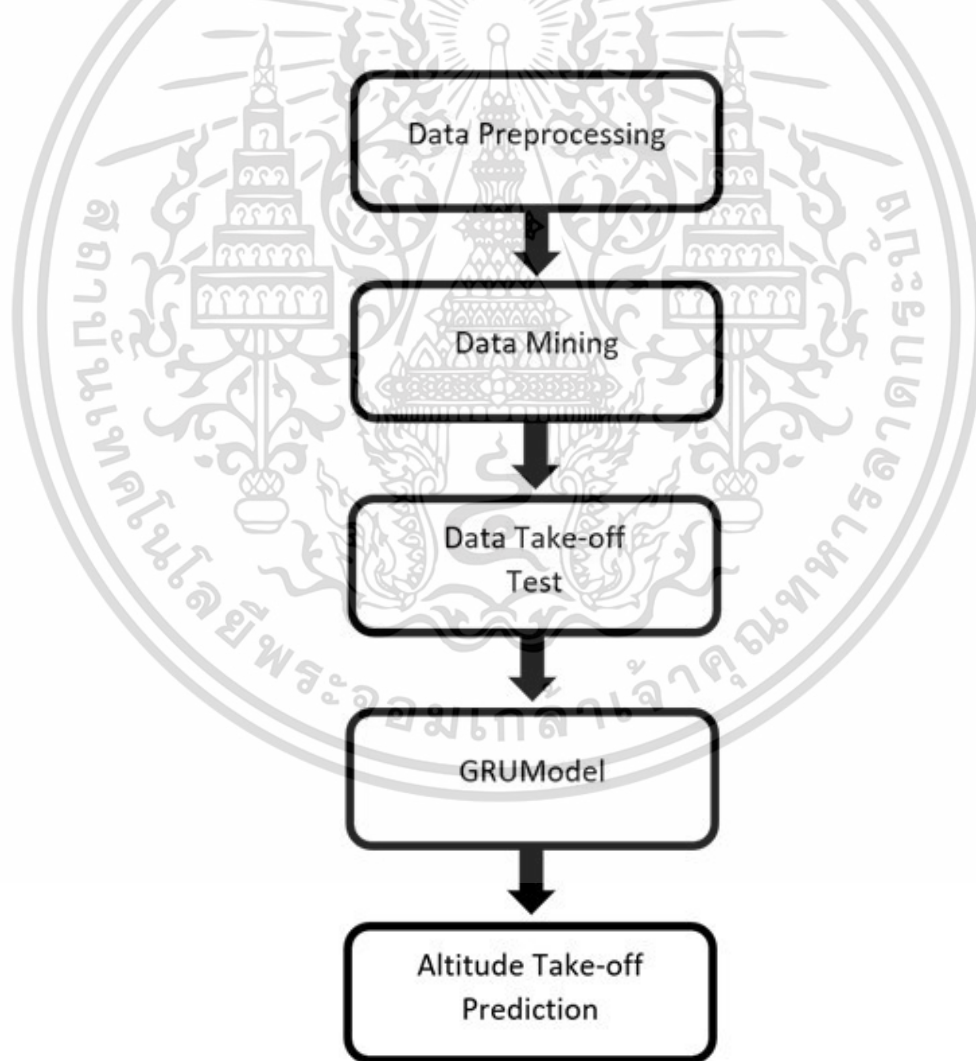


รูปที่ 3.12 ขั้นตอนการจัดเตรียมข้อมูลสำหรับการทำนายผล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5.2 การทำนายผลระดับความสูงการบินขึ้นของเครื่องบิน

การทำนายผลของแบบจำลองโครงข่าย GRU เป็นการกระบวนการหลังการเรียนรู้ของแบบจำลองที่เลือกเอาเฉพาะข้อมูลที่ต้องการทดสอบ (Test) เข้าสู่แบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้ข้อมูลแล้ว มีขั้นตอนดังแสดงในรูปที่ 3.13 เริ่มจากการนำข้อมูลสำหรับทดสอบที่ผ่านการแบ่งส่วนข้อมูล (Data Mining) และปรับช่วงขอบเขต (Normalization) แล้วจากขั้นตอนการจัดเตรียมข้อมูลก่อนนำมาวิจัย เพื่อเข้าสู่กระบวนการทำนายผลของแบบจำลองโครงข่าย GRU จากนั้นนำข้อมูลผลลัพธ์ที่ได้จากการทำนายผลมาเข้าสู่กระบวนการประเมินผลของแบบจำลองที่ทำนายจากเหตุการณ์ที่เกิดขึ้นจริงว่ามีความผิดพลาดมากน้อยเพียงใด การทำนายที่ได้นั้นเป็นไปตามความต้องการหรือไม่ โดยมีผลลัพธ์สุดท้ายเป็นการทำนายระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินที่มีขนาดข้อมูลเท่ากับระดับความสูงขาเข้า

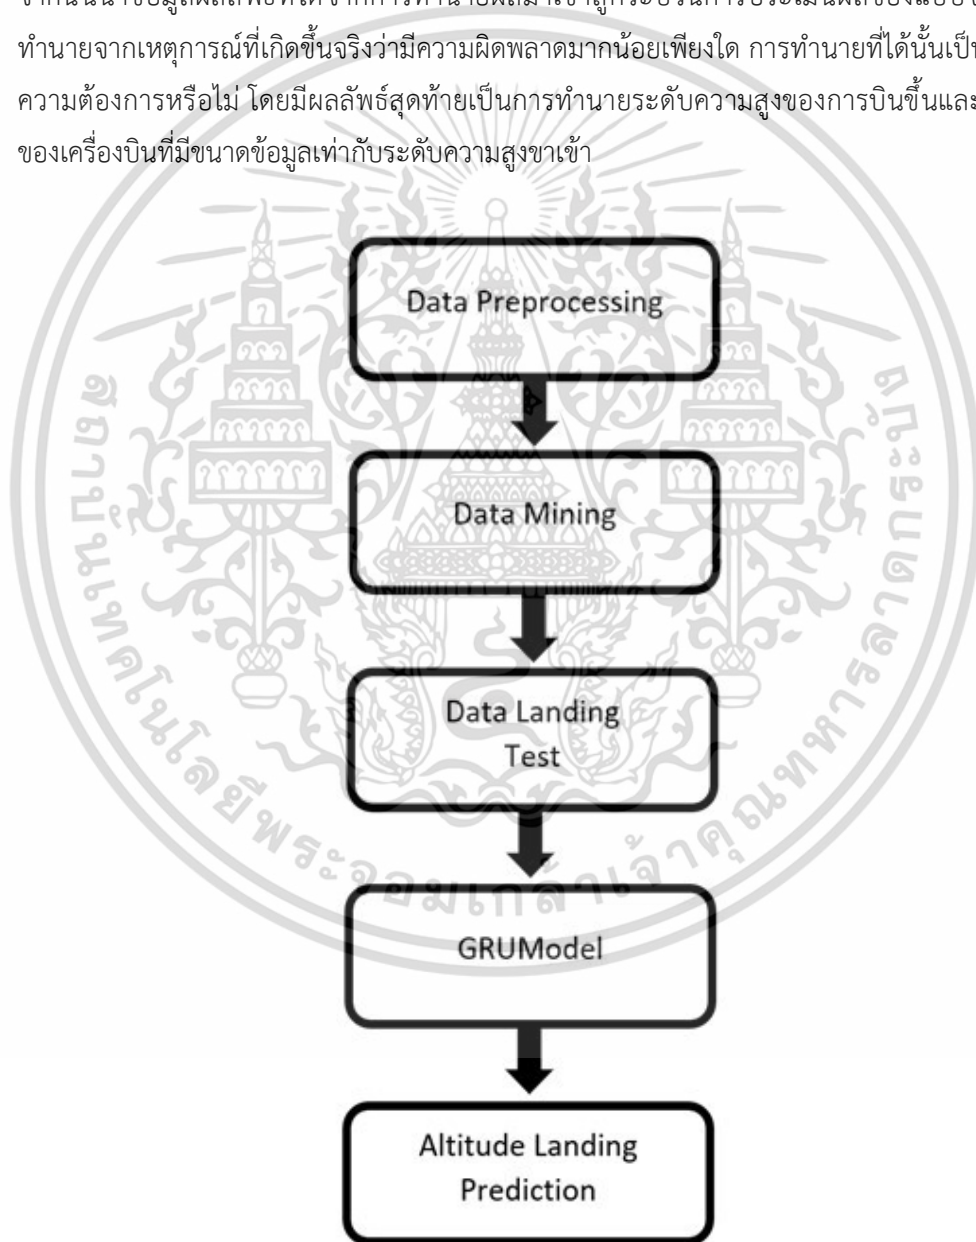


รูปที่ 3.13 ขั้นตอนการทำนายผลระดับความสูงการบินขึ้นของเครื่องบิน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5.3 การทำนายผลระดับความสูงการลงจอดของเครื่องบิน

การทำนายผลของแบบจำลองโครงข่าย GRU เป็นการกระบวนการหลังการเรียนรู้ของแบบจำลองที่เลือกเอาเฉพาะข้อมูลที่ต้องการทดสอบ (Test) เข้าสู่แบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้ข้อมูลแล้ว มีขั้นตอนดังแสดงในรูปที่ 3.14 เริ่มจากการนำข้อมูลสำหรับทดสอบที่ผ่านการแบ่งส่วนข้อมูล (Data Mining) และปรับช่วงขอบเขต (Normalization) แล้วจากขั้นตอนการจัดเตรียมข้อมูลก่อนนำมาวิจัย เพื่อเข้าสู่กระบวนการทำนายผลของแบบจำลองโครงข่าย GRU จากนั้นนำข้อมูลผลลัพธ์ที่ได้จากการทำนายผลมาเข้าสู่กระบวนการประเมินผลของแบบจำลองที่ทำนายจากเหตุการณ์ที่เกิดขึ้นจริงว่ามีความผิดพลาดมากน้อยเพียงใด การทำนายที่ได้นั้นเป็นไปตามความต้องการหรือไม่ โดยมีผลลัพธ์สุดท้ายเป็นการทำนายระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินที่มีขนาดข้อมูลเท่ากับระดับความสูงขาเข้า

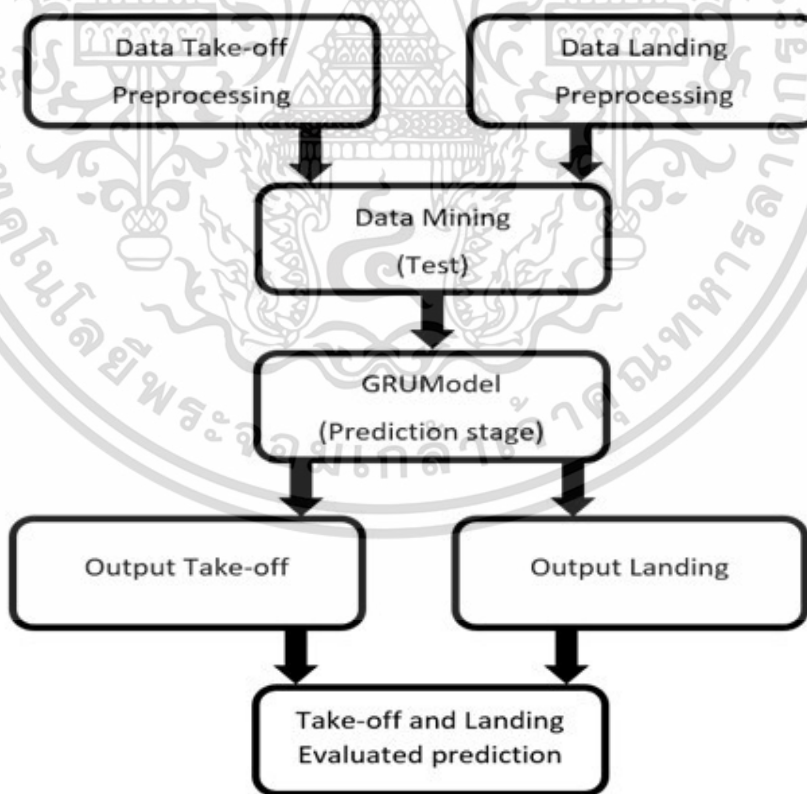


รูปที่ 3.14 ขั้นตอนการทำนายผลระดับความสูงการลงจอดของเครื่องบิน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5.4 ภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

ภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน เป็นการระบุระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินของผลลัพธ์ที่ได้จากขั้นตอนการทำนายผล โดยอาศัยการทำงานของแบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้ข้อมูล ซึ่งทำงานต่อจากการทำนายผลของแบบจำลองโครงข่าย GRU มีขั้นตอนแสดงในรูปที่ 3.15 เริ่มจากการจัดเตรียมข้อมูลสำหรับการทำนายผล (Post Processing) ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน เป็นขั้นตอนการนำข้อมูลทดสอบ (Test) ที่ได้จากการแบ่งข้อมูล (Data Mining) เข้าสู่แบบจำลองในส่วนของการทำนายระดับความสูงของการบินขึ้นและลงจอดของเครื่องบิน โดยข้อมูลทดสอบผ่านการปรับช่วงขอบเขตของข้อมูล (Normalization) เพื่อจำกัดขอบเขตของข้อมูลให้อยู่ในรูปแบบที่เหมาะสมก่อนนำมาใช้ทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบินด้วยแบบจำลองโครงข่าย GRU ซึ่งผลลัพธ์ที่ได้จากการทำนายประกอบไปด้วย ระดับความสูงการบินขึ้นของเครื่องบิน และระดับความสูงการลงจอดของเครื่องบิน จากนั้นนำผลลัพธ์การทำนายมาผ่านกระบวนการประเมินประสิทธิภาพเพื่อนำผลลัพธ์ที่ได้มาประเมินผลของแบบจำลองที่ทำนายจากเหตุการณ์ที่เกิดขึ้นจริงว่ามีความผิดพลาดมากน้อยเพียงใด



รูปที่ 3.15 ภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.6 ประเมินประสิทธิภาพการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

การประเมินประสิทธิภาพการทำนายระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินสามารถแบ่งออกได้เป็น 3 ส่วน คือ ไทม์สเต็ป (Timestep) ที่ 1, ไทม์สเต็ป (Timestep) ที่ 2, ไทม์สเต็ป (Timestep) ที่ 3 ซึ่งในแต่ละส่วนใช้วิธีการประเมินประสิทธิภาพ 3 วิธี ได้แก่ ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) ซึ่งได้จากการเปรียบเทียบระหว่างผลลัพธ์ของการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบินและข้อมูลระดับความสูงของการบินขึ้นและลงจอดของเครื่องบินที่เป็นจริง ซึ่งมีการเปรียบเทียบการประเมินประสิทธิภาพโดยการหาค่าเฉลี่ยของแต่ละตัวชี้วัด

โดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่านี้จะมีความอ่อนไหวกับข้อมูลที่มีความผิดปกติหรือแตกต่างไปจากข้อมูลในกลุ่มน้อยกว่าค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และ รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เนื่องจากการนำค่า Error มาใส่ Absolute เท่านั้น แต่ค่าเฉลี่ยความผิดพลาดยกกำลังสอง ค่านี้จะอ่อนไหวกับข้อมูลที่มีความผิดปกติหรือแตกต่างไปจากข้อมูลในกลุ่มมากเนื่องจากการนำค่า Error มายกกำลังสอง จึงต้องระวังข้อมูลที่มีความผิดปกติหรือแตกต่างไปจากข้อมูลในกลุ่ม รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง มีคุณสมบัติที่คล้ายกับค่าเฉลี่ยความผิดพลาดยกกำลังสองแต่นำค่าเฉลี่ยความผิดพลาดยกกำลังสอง มาใส่ Square Root ซึ่งอาจทำให้ตีความได้ง่ายกว่าเนื่องจากหน่วยของค่า Error จะไม่มีเลขยกกำลัง 2 เหมือนกับ ค่าเฉลี่ยความผิดพลาดยกกำลังสอง

## บทที่ 4

### ผลการดำเนินงาน

#### 4.1 บทนำ

ในบทนี้จะกล่าวถึงผลลัพธ์ในแต่ละขั้นตอนของการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบินด้วยแบบจำลองโครงข่าย GRU ในส่วนแรก คือ ฐานข้อมูลการบินขึ้นและลงจอดของเครื่องบินที่นำมาใช้ในงานวิจัย ในส่วนต่อมานี้จะเป็นผลการเตรียมข้อมูลก่อนนำมาวิจัย ต่อมาเป็นที่ทำการคัดข้อมูลที่ไม่เกี่ยวข้องหรือข้อมูลเสีย (Noise data) เพื่อลดปัญหาที่จะเกิดขึ้นในการเรียนรู้ ต่อมาเป็นการเป็นการกล่าวถึงการเตรียมข้อมูลสำหรับการเรียนรู้และผลของประสิทธิภาพการเรียนรู้ของแบบจำลองโครงข่าย GRU ทั้งการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบินและการเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน ในอันดับสุดท้ายเป็นการกล่าวถึงผลลัพธ์และค่าประสิทธิภาพวิธีการทำนายผลระดับความสูงการบินขึ้นของเครื่องบินและการทำนายผลระดับความสูงการลงจอดของเครื่องบินด้วยแบบจำลองโครงข่าย GRU รวมถึงเปรียบเทียบค่าประสิทธิภาพกับวิธีการวัดประสิทธิภาพแบบอื่น ๆ

#### 4.2 ฐานข้อมูลที่นำมาใช้ในงานวิจัย

ลักษณะของข้อมูลที่นำมาวิจัยเป็นข้อมูลที่เกิดขึ้นจริงจากการบินขึ้นและลงจอดของเครื่องบินที่สนามบินนานาชาติภูเก็ต ดังแสดงในตารางที่ 4.1 โดยข้อมูลที่นำมาวิจัยข้อมูลขาเข้าการทดลองประกอบด้วย ความเร็วในแนวตั้ง (Vertical Speed), ระดับความสูงของจีพีเอส (GPS Altitude), ค่าความเร็วอากาศ (True Air Speed: TAS), ค่าความเร็วปรากฏบนพื้นโลก (Ground Speed), ค่าความเร็วอากาศที่รับจากเครื่องวัดโดยตรง (Indicated Air Speed: IAS), อุณหภูมิ (Temperature), ลม (Wind), ทิศทางลม (Wind Angle), ตำแหน่งละติจูด (Latitude), ตำแหน่งลองจิจูด (Longitude), ระดับความสูงที่ปรับเทียบ (Calibrated altitude) การเก็บข้อมูลการบินขึ้นของเครื่องบินจะเก็บข้อมูลเฉพาะการบินขึ้นที่สนามบินนานาชาติภูเก็ตโดยไม่สนใจปลายทาง และการลงจอดของเครื่องบินจะเก็บข้อมูลเฉพาะการลงจอดที่สนามบินนานาชาติภูเก็ตไม่สนใจต้นทาง โดยสนใจแค่การบินขึ้นและลงจอดที่สนามบินนานาชาติภูเก็ตเท่านั้น ซึ่งช่วงการรวบรวมข้อมูลที่นำมาวิจัยขณะมีการบินขึ้นและลงจอดของเครื่องบินเป็นแบบเรียลไทม์ มีการเคลื่อนที่ทุกๆ 15 วินาที

ฐานข้อมูลที่นำมาใช้ในงานวิจัยการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน ใช้ฐานข้อมูลจาก flightradar24 ซึ่งเป็นเว็บไซต์เกี่ยวกับการแสดงข้อมูลการบินแบบเรียลไทม์

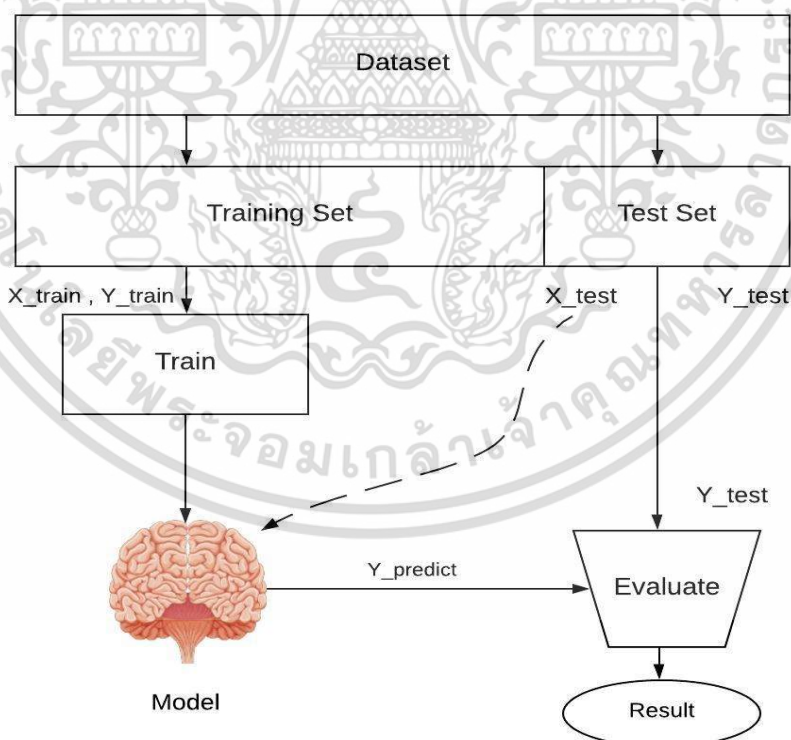
ตารางที่ 4.1 ตารางแสดงพารามิเตอร์ของเครื่องบินแอร์บัส A320 ที่ใช้ในการทำนายการบินขึ้นและลงจอดของเครื่องบิน

ความเร็วในแนวตั้ง (Vertical Speed)	หน่วยฟุตต่อนาที หรือ fpm.(Feet per minute)
ระดับความสูงของจีพีเอส (GPS Altitude)	หน่วยฟุต (ft) โดยมีขนาดเท่ากับ 0.3048 เมตร
ค่าความเร็วอากาศ (True Air Speed: TAS)	หน่วยน็อต(kts) 1 Knots = 1.852 กม./ชม.
ค่าความเร็วปรากฏบนพื้นโลก (Ground Speed)	หน่วยน็อต(kts) 1 Knots = 1.852 กม./ชม.
ค่าความเร็วอากาศที่รับจากเครื่องวัดโดยตรง (Indicated Air Speed: IAS)	หน่วยน็อต(kts) 1 Knots = 1.852 กม./ชม.
อุณหภูมิ (Temperature)	องศาเซลเซียส(°C)เป็นหน่วยวัดอุณหภูมิ
ลม (Wind)	หน่วยน็อต(kts) 1 Knots = 1.852 กม./ชม.
ทิศทางลม (Wind Angle)	หน่วยในการวัดมุมมีหน่วยเป็นองศาซึ่งเขียนในสัญลักษณ์ ("°")
ตำแหน่งละติจูด (Latitude)	8.1128
ตำแหน่งลองจิจูด (Longitude)	98.3117
ระดับความสูงที่ปรับเทียบ (Calibrated altitude)	หน่วยฟุต (ft) โดยมีขนาดเท่ากับ 0.3048 เมตร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 4.3 ผลการเตรียมข้อมูลก่อนนำมาวิจัย

ผลการเตรียมข้อมูลที่ได้จากการบินขึ้นและลงจอดของเครื่องบิน โดยทำการคัดข้อมูลที่ไมเกี่ยวข้องหรือข้อมูลเสีย (Noise data) เพื่อลดปัญหาที่จะเกิดขึ้นในการเรียนรู้ ก่อนนำไปเป็นข้อมูลขาเข้าทั้งในส่วนการเรียนรู้และทำนายผลของแบบจำลองโครงข่าย GRU เริ่มจากการทำความสะอาดข้อมูล (Cleaning data) การทำความสะอาดข้อมูลโดยขั้นตอนของการทำความสะอาดข้อมูลนับเป็นขั้นตอนแรกที่สำคัญของการเตรียมข้อมูลก่อนนำมาวิจัย หลังจากขั้นตอนการทำความสะอาดข้อมูลจะแบ่งข้อมูลออกเป็น 2 ส่วน ได้แก่ข้อมูลเพื่อการเรียนรู้ (Training) จะแบ่งข้อมูลออก 80% จากข้อมูลการบินขึ้นและลงจอดของเครื่องบินทั้งหมดและแบ่งข้อมูลเพื่อทดสอบ (Test) 20% จากข้อมูลการบินขึ้นและลงจอดทั้งหมด เพื่อตรวจสอบและประเมินประสิทธิภาพของแบบจำลอง ขั้นตอนสุดท้าย การแปลงข้อมูล (Data Transformation) โดยวิธีการปรับช่วงขอบเขตของข้อมูล (Normalization) เพื่อปรับช่วงขอบเขตของข้อมูลทั้งหมดให้อยู่ในมาตราส่วนเดียวกัน โดยวิธีการปรับช่วงขอบเขตของข้อมูลด้วยค่าสูงสุดและต่ำสุด (Min-max Normalization) ซึ่งเป็นการปรับช่วงของข้อมูลให้อยู่ในช่วง 0 – 1 ดังแสดงในรูปที่ 4.1



รูปที่ 4.1 ภาพแสดงผลการจัดเตรียมข้อมูลก่อนเข้าสู่แบบจำลอง

#### 4.4 ผลการเรียนรู้ข้อมูลของแบบจำลองโครงข่าย GRU

การเรียนรู้ข้อมูลการบินขึ้นและลงจอดของโครงข่าย GRU ใช้ข้อมูลเพื่อการเรียนรู้ 80% จากชุดข้อมูลที่ได้จากการเก็บข้อมูลการบินขึ้นและลงจอดของเครื่องบินทั้งหมด ที่ผ่านการเตรียมข้อมูลก่อนนำมาวิจัย (Data Preprocessing) โดยกำหนดให้การเรียนรู้ของแบบจำลองโครงข่าย GRU มีอัตราการเรียนรู้ (learning rate) 0.1 ดำเนินการ (Epochs) 2,000 รอบ

##### 4.4.1 ข้อมูลสำหรับการเรียนรู้

ข้อมูลที่ใช้ในการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบินของแบบจำลองโครงข่าย GRU ประกอบไปด้วย 2 ส่วน ได้แก่ กำหนดข้อมูลเป้าหมายการเรียนรู้ ทำหน้าที่เป็นตัวกำหนดความถูกต้องในการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้แต่ละรอบ ส่วนต่อมาเป็นการแบ่งข้อมูลเพื่อการเรียนรู้ โดยการเลือกเอาข้อมูลของการบินขึ้นและลงจอดที่เกิดขึ้นจริง มาจำแนกเป็นข้อมูลเพื่อการเรียนรู้และข้อมูลเป้าหมายในแต่ละไทม์สเต็ป (timestep) เพื่อให้แบบจำลองมีประสิทธิภาพมากขึ้น โดยมีรายละเอียดดังต่อไปนี้


- 1.) กำหนดข้อมูลเป้าหมายการเรียนรู้ เป็นข้อมูลที่ได้จากการเลือกจากข้อมูลการบินขึ้นและลงจอดของเครื่องบินที่เป็นจริง มาสร้างเป็นข้อมูลเป้าหมายการเรียนรู้ของแบบจำลองโครงข่าย GRU ได้แก่ ระดับความสูงที่ปรับเทียบ (Calibrated altitude) ซึ่งได้จากการเลือกจากข้อมูลทั้งหมดของการบินขึ้นและลงจอดของเครื่องบิน โดยข้อมูลเป้าหมายถูกนำมาใช้สำหรับคำนวณค่าความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ทั้งระดับความสูงการบินขึ้นของเครื่องบินและระดับความสูงการลงจอดของเครื่องบิน
- 2.) การแบ่งข้อมูลเพื่อการเรียนรู้ เริ่มจากการเลือกเอาข้อมูลของการบินขึ้นและลงจอดที่เกิดขึ้นจริง มาจำแนกเป็นข้อมูลเพื่อการเรียนรู้และข้อมูลเป้าหมายในแต่ละไทม์สเต็ป (timestep) ของแบบจำลองโครงข่าย GRU โดยแบ่งข้อมูลออกเป็น 3 ไทม์สเต็ป โดยข้อมูลเป้าหมายการเรียนรู้จะถูกนำมาใช้สำหรับคำนวณค่าความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ระดับความสูงการบินขึ้นและลงจอดในแต่ละไทม์สเต็ป

##### 4.4.2 ผลการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน

การเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน เป็นกระบวนการป้อนข้อมูลเพื่อให้แบบจำลองทำการเรียนรู้ข้อมูลการบินขึ้นของเครื่องบิน ซึ่งอาศัยการทำงานของแบบจำลองโครงข่าย GRU โดยมีการแบ่งข้อมูลเพื่อการเรียนรู้ และกำหนดข้อมูลเป้าหมายการเรียนรู้เพื่อเป็นตัวกำหนดความถูกต้องในการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ของระดับความสูงการบินขึ้นของ

เครื่องบินแต่ละรอบ แสดงดังรูปที่ 4.2 (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)

ผลการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบินที่ผ่านการเตรียมข้อมูลก่อนนำมาวิจัยของแบบจำลองโครงข่าย GRU โดยเมื่อผ่านกระบวนการเรียนรู้ของแบบจำลองโครงข่าย GRU ค่าความคลาดเคลื่อนการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบินแต่ละรอบ แสดงดังตารางที่ 4.2



รูปที่ 4.2 กราฟความคลาดเคลื่อนการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบินแต่ละรอบ (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)

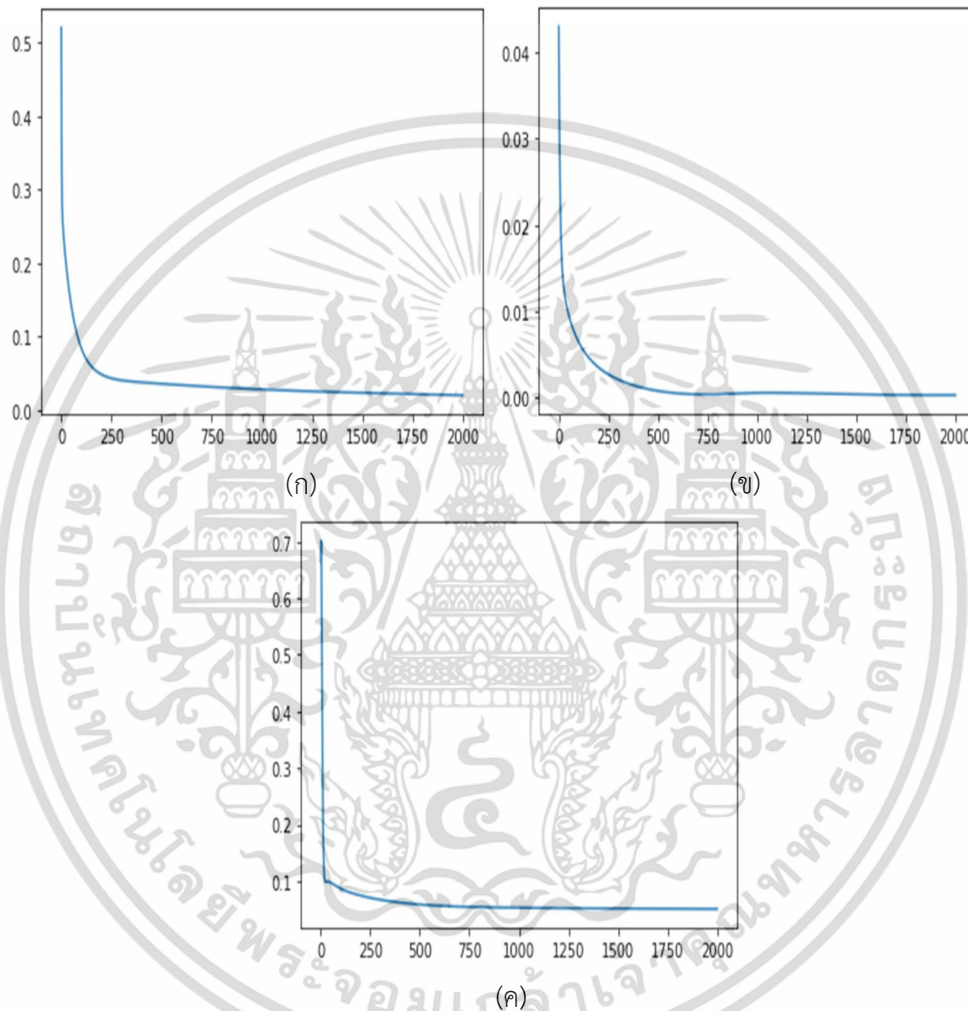
ตารางที่ 4.2 แสดงผลการเรียนรู้ระดับความสูงการบินขึ้นของเครื่องบิน

Timestep	TAKEOFF			
	TRAINING			
	Error	MAE	MSE	RMSE
1		0.642	0.955	0.694
2		0.550	0.247	0.545
3		0.057	0.003	0.044

#### 4.4.3 ผลการเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน

การเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน เป็นกระบวนการป้อนข้อมูลเพื่อให้งานแบบจำลองทำการเรียนรู้ข้อมูลการลงจอดของเครื่องบิน ซึ่งอาศัยการทำงานของแบบจำลองโครงข่าย GRU โดยมีการแบ่งข้อมูลเพื่อการเรียนรู้ และกำหนดข้อมูลเป้าหมายการเรียนรู้เพื่อเป็นตัวกำหนดความถูกต้องในการคำนวณความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ของระดับความสูงการลงจอดของเครื่องบินแต่ละรอบแสดงดังรูปที่ 4.3 (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)

ผลการเรียนรู้ระดับความสูงการลงจอดของเครื่องบินที่ผ่านการเตรียมข้อมูลก่อนนำมาวิจัยของแบบจำลองโครงข่าย GRU โดยเมื่อผ่านกระบวนการเรียนรู้ของแบบจำลองโครงข่าย GRU ค่าความคลาดเคลื่อนการเรียนรู้ระดับความสูงการลงจอดของเครื่องบินแต่ละรอบ แสดงดังตารางที่ 4.3



รูปที่ 4.3 กราฟความคลาดเคลื่อนการเรียนรู้ระดับความสูงการลงจอดของเครื่องบินแต่ละรอบ (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)

ตารางที่ 4.3 แสดงผลการเรียนรู้ระดับความสูงการลงจอดของเครื่องบิน

Timestep	LANDING		
	TRAINING		
Error	MAE	MSE	RMSE
1	0.923	0.508	0.680
2	0.294	0.493	0.510
3	0.046	0.003	0.052

#### 4.4.4 ภาพรวมผลการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

ภาพรวมผลการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบินประเมินด้วยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) แสดงดังตารางที่ 4.4 โดยระดับความสูงการบินขึ้นเมื่อผ่านกระบวนการเรียนรู้ ทั้ง 3 ไทม์สเต็ป แบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) เท่ากับ 0.642, 0.550 และ 0.057 ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) เท่ากับ 0.955, 0.247 และ 0.003 รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.694, 0.545, 0.044 ตามลำดับ

โดยระดับความสูงการลงจอดเมื่อผ่านกระบวนการเรียนรู้ ทั้ง 3 ไทม์สเต็ป แบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) เท่ากับ 0.923,

0.294 และ 0.046 ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) เท่ากับ 0.508, 0.493 และ 0.003 รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.680, 0.510, 0.052 ตามลำดับ

ตารางที่ 4.4 แสดงให้เห็นว่าค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และ รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) ในโหม้สเต็ปที่ 2 ค่าความคลาดเคลื่อนลดลงจากโหม้สเต็ปที่ 1 เนื่องจากแบบจำลองได้เรียนรู้ข้อมูลในอดีต และโหม้สเต็ปที่ 3 ค่าความคลาดเคลื่อนน้อยที่สุดเนื่องจากค่าความผิดพลาดเข้าใกล้ 0 มากที่สุด

ตารางที่ 4.4 แสดงภาพรวมผลการเรียนรู้ระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

Timestep	TAKEOFF			LANDING			
	TRAINING						
	Error	MAE	MSE	RMSE	MAE	MSE	RMSE
1		0.642	0.955	0.694	0.923	0.508	0.680
2		0.550	0.247	0.545	0.294	0.493	0.510
3		0.057	0.003	0.044	0.046	0.003	0.052

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.5 ผลการทำนายของแบบจำลองโครงข่าย GRU

การทำนายผลข้อมูลการบินขึ้นและลงจอดของโครงข่าย GRU ใช้ข้อมูลเพื่อการทำนายผล 20% จากชุดข้อมูลที่ได้จากการเก็บข้อมูลการบินขึ้นและลงจอดของเครื่องบินทั้งหมด ที่ผ่านการเตรียมข้อมูลก่อนนำมาวิจัย (Data Preprocessing) โดยกำหนดให้การเรียนรู้ของแบบจำลองโครงข่าย GRU มีอัตราการเรียนรู้ (learning rate) 0.1 ดำเนินการ (Epochs) 2,000 รอบ


### 4.5.1 ข้อมูลสำหรับการทำนายผล

ข้อมูลที่ใช้สำหรับการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบินด้วยแบบจำลองโครงข่าย GRU เป็นข้อมูลที่ได้จากขั้นตอนการเตรียมข้อมูลก่อนนำมาวิจัย ที่ผ่านการแปลงข้อมูลแล้ว (Data transformation) โดยนำข้อมูลทั้งหมดมาแบ่งเป็นข้อมูลที่ต้องการทำนายผล 20% กำหนดข้อมูลเป้าหมายการทำนายผล เป็นข้อมูลที่ได้จากการเลือกจากข้อมูลการบินขึ้นและลงจอดของเครื่องบินที่เป็นจริง มาสร้างเป็นข้อมูลเป้าหมายการเรียนรู้ของแบบจำลองโครงข่าย GRU ได้แก่ ระดับความสูงที่ปรับเทียบ (Calibrated altitude) โดยข้อมูลเป้าหมายถูกนำมาใช้สำหรับคำนวณค่าความคลาดเคลื่อนของผลลัพธ์การเรียนรู้ทั้งระดับความสูงการบินขึ้นของเครื่องบินและระดับความสูงการลงจอดของเครื่องบิน ก่อนนำไปแบ่งข้อมูลเพื่อการทำนายผล 3 ไทม์สเต็ป


### 4.5.2 ผลการทำนายระดับความสูงการบินขึ้นของเครื่องบิน

การทำนายผลระดับความสูงการบินขึ้นของเครื่องบิน เป็นกระบวนการป้อนข้อมูลทดสอบ (Test) เพื่อให้แบบจำลองทำการทำนายระดับความสูงการบินขึ้นของเครื่องบิน ซึ่งอาศัยการทำงานของแบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้แล้ว แสดงดังรูปที่ 4.4 (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)


ผลการทำนายระดับความสูงการบินขึ้นของเครื่องบินที่ผ่านการเตรียมข้อมูลก่อนนำมาวิจัยของแบบจำลองโครงข่าย GRU โดยกระบวนการทำนายของแบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้ค่าความคลาดเคลื่อนระดับความสูงการบินขึ้นของเครื่องบินแต่ละรอบ แสดงดังตารางที่ 4.5



(ก)



(ข)



(ค)

รูปที่ 4.4 ตัวอย่างรูปเปรียบเทียบระหว่างผลลัพธ์การทำนายระดับความสูงการบินขึ้นกับระดับความสูงการบินขึ้นที่เกิดขึ้นจริง (ก) ผลลัพธ์การทำนายด้วยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ผลลัพธ์การทำนายด้วยค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) ผลลัพธ์การทำนายด้วยรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 4.5 แสดงความน่าเชื่อถือของการทำนายระดับความสูงการบินขึ้นของเครื่องบิน

Timestep	TAKEOFF			
	TEST			
	Error	MAE	MSE	RMSE
1		0.156	0.215	0.690
2		0.135	0.062	0.488
3		0.014	0.001	0.040

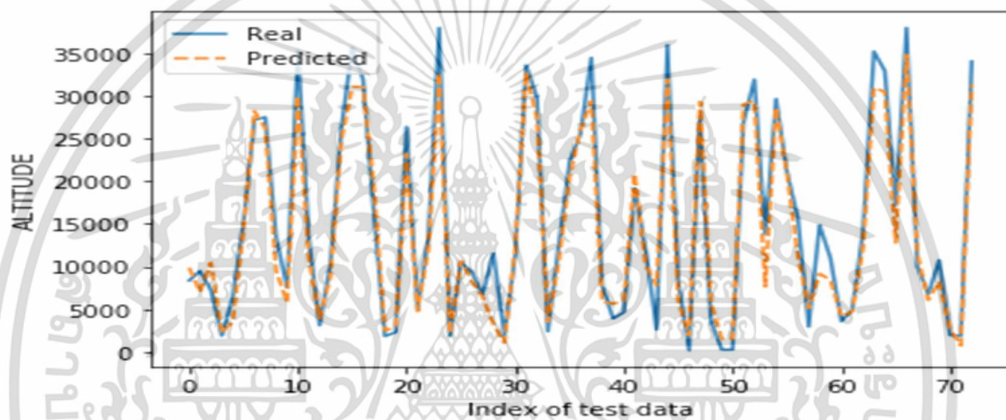
#### 4.5.3 ผลการทำนายระดับความสูงการลงจอดของเครื่องบิน

การทำนายผลระดับความสูงการลงจอดของเครื่องบิน เป็นกระบวนการป้อนข้อมูลทดสอบ (Test) เพื่อให้แบบจำลองทำการทำนายระดับความสูงการลงจอดของเครื่องบิน ซึ่งอาศัยการทำงานของแบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้แล้ว แสดงดังรูปที่ 4.5 (ก) ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)


ผลการทำนายระดับความสูงการลงจอดของเครื่องบินที่ผ่านการเตรียมข้อมูลก่อนนำมาวิจัยของแบบจำลองโครงข่าย GRU โดยกระบวนการทำนายของแบบจำลองโครงข่าย GRU ที่ผ่านการเรียนรู้ค่าความคลาดเคลื่อนระดับความสูงการลงจอดของเครื่องบินแต่ละรอบ แสดงดังตารางที่ 4.6



(ก)



(ข)



(ค)

รูปที่ 4.5 ตัวอย่างรูปเปรียบเทียบระหว่างผลลัพธ์การทำนายระดับความสูงการลงจอดกับระดับความสูงการลงจอดที่เกิดขึ้นจริง (ก) ผลลัพธ์การทำนายด้วยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) (ข) ผลลัพธ์การทำนายด้วยค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) (ค) ผลลัพธ์การทำนายด้วยรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.6 แสดงความน่าเชื่อถือของการทำนายระดับความสูงการลงจอดของเครื่องบิน

Timestep	LANDING		
	TEST		
	Error	MAE	MSE
1	0.231	0.116	0.671
2	0.076	0.111	0.506
3	0.018	0.001	0.042

#### 4.5.4 ภาพรวมการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

ภาพรวมผลการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบินประเมินด้วยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) แสดงดังตารางที่ 4.7 โดยระดับความสูงการบินขึ้นเมื่อผ่านกระบวนการทำนายผล ทั้ง 3 ไทม์สเต็ป แบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) เท่ากับ 0.156, 0.135 และ 0.014 ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) เท่ากับ 0.215, 0.062 และ 0.001 รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.690, 0.488, 0.040 ตามลำดับ

โดยระดับความสูงการลงจอดเมื่อผ่านกระบวนการทำนายผล ทั้ง 3 ไทม์สเต็ป แบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) เท่ากับ 0.231, 0.076 และ 0.018 ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) เท่ากับ

0.116, 0.111 และ 0.001 รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.671, 0.506, 0.042 ตามลำดับ

ตารางที่ 4.7 แสดงให้เห็นว่าค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และ รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) ในไทม์สเต็ปที่ 2 ค่าความคลาดเคลื่อนลดลงจากไทม์สเต็ปที่ 1 เนื่องจากแบบจำลองได้เรียนรู้ข้อมูลในอดีต และไทม์สเต็ปที่ 3 ค่าความคลาดเคลื่อนน้อยที่สุดเนื่องจากค่าความผิดพลาดเข้าใกล้ 0 มากที่สุด

ตารางที่ 4.7 ภาพรวมแสดงความน่าเชื่อถือของการทำนายระดับความสูงการบินขึ้นและลงจอด

Timestep	TAKEOFF			LANDING		
	TEST					
	MAE	MSE	RMSE	MAE	MSE	RMSE
1	0.156	0.215	0.690	0.231	0.116	0.671
2	0.135	0.062	0.488	0.076	0.111	0.506
3	0.014	0.001	0.040	0.018	0.001	0.042

การหาประสิทธิภาพของวิธีการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน เป็นการเปรียบเทียบระหว่างผลลัพธ์การทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน และระดับความสูงการบินขึ้นและลงจอดของเครื่องบินที่เป็นจริง เพื่อบ่งบอกความคลาดเคลื่อนของระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน โดยมีการเปรียบเทียบการประเมินประสิทธิภาพของความคลาดเคลื่อน ดังแสดงในตารางที่ 4.8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.8 แสดงความน่าเชื่อถือของการเรียนรู้และผลการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน

timestep	TAKEOFF						LANDING					
	TRAIN			TEST			TRAIN			TEST		
	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE	MAE	MSE	RMSE
1	0.642	0.955	0.694	0.156	0.215	0.690	0.923	0.508	0.680	0.231	0.116	0.671
2	0.550	0.247	0.545	0.135	0.062	0.488	0.294	0.493	0.510	0.076	0.111	0.506
3	0.057	0.003	0.044	0.014	0.001	0.040	0.046	0.003	0.052	0.018	0.001	0.042

จากตารางเปรียบเทียบความคลาดเคลื่อนโทมส์เต็ปที่ 1 กับโทมส์เต็ปที่ 3 ในส่วนการเรียนรู้ (Train) โทมส์เต็ปที่ 1 การบินขึ้นของเครื่องบิน แบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.642, 0.955 และ 0.694 ตามลำดับ โทมส์เต็ปที่ 3 การบินขึ้นของเครื่องบิน แบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.057, 0.003 และ 0.044 ตามลำดับ

จากตารางเปรียบเทียบความคลาดเคลื่อนโทมส์เต็ปที่ 1 กับโทมส์เต็ปที่ 3 ในส่วนการทดสอบ (Test) โทมส์เต็ปที่ 1 การบินขึ้นของเครื่องบิน แบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean

Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.156, 0.215 และ 0.690 ตามลำดับ ไทม์สเต็ปที่ 3 การบินขึ้นของเครื่องบินแบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.014, 0.001 และ 0.040 ตามลำดับ

จากตารางเปรียบเทียบความคลาดเคลื่อนไทม์สเต็ปที่ 1 กับไทม์สเต็ปที่ 3 ในส่วนการเรียนรู้ (Train) ไทม์สเต็ปที่ 1 การลงจอดของเครื่องบินแบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.923, 0.508 และ 0.680 ตามลำดับ ไทม์สเต็ปที่ 3 การลงจอดของเครื่องบินแบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.046, 0.003 และ 0.052 ตามลำดับ

จากตารางเปรียบเทียบความคลาดเคลื่อนไทม์สเต็ปที่ 1 กับไทม์สเต็ปที่ 3 ในส่วนการทดสอบ (Test) ไทม์สเต็ปที่ 1 การลงจอดของเครื่องบินแบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.231, 0.116 และ 0.671 ตามลำดับ ไทม์สเต็ปที่ 3 การลงจอดของเครื่องบินแบบจำลองมีค่าความคลาดเคลื่อนวัดโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) เท่ากับ 0.018, 0.001 และ 0.042 ตามลำดับ

จากตารางเปรียบเทียบความคลาดเคลื่อนไทม์สเต็ปที่ 1 กับไทม์สเต็ปที่ 3 แสดงให้เห็นว่า ทุกๆ 1 ไทม์สเต็ปมีผลในการลดข้อผิดพลาด ประสิทธิภาพของแบบจำลองโครงข่าย GRU ที่ประเมินโดยค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และ รากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) จะเห็นได้ว่าการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบินโดยใช้โครงข่าย GRU แบบเรียลไทม์ การทำนายผลระยะสั้นโดยอิงจากโครงข่าย GRU นั้นดีที่สุดสำหรับแบบจำลองการทำนายระดับความสูงสำหรับการบินขึ้นและลงจอดของเครื่องบินนั้นแม่นยำและมีประสิทธิภาพ

## บทที่ 5

### สรุปผลการดำเนินงาน

#### 5.1 สรุปผลการทดลอง

วิทยานิพนธ์ฉบับนี้นำเสนอการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบินที่สนามบินนานาชาติภูเก็ต ด้วยแบบจำลองโครงข่าย GRU ร่วมกับการใช้ข้อมูลการบินขึ้นและลงจอดของเครื่องบิน และการปรับปรุงคุณภาพของข้อมูลการบินขึ้นและลงจอดของเครื่องบินด้วยวิธีการเตรียมข้อมูล(Data preprocessing) เพื่อทำการคัดข้อมูลที่ไม่เกี่ยวข้องหรือข้อมูลเสีย (Noise data) เพื่อลดปัญหาที่จะเกิดขึ้นในการเรียนรู้ ประกอบไปด้วยการทำงาน 4 ส่วน โดยส่วนแรก คือ การทำความสะอาดข้อมูล (Cleaning data) ส่วนต่อมาคือการรวบรวมข้อมูล (Data integration) จากนั้นการเลือกข้อมูล (Data selection) และส่วนสุดท้ายคือการแปลงข้อมูล (Data Transformation) โดยวิธีการปรับช่วงขอบเขตของข้อมูลด้วยค่าสูงสุดและต่ำสุด (Min-max Normalization) ซึ่งผลลัพธ์ที่ได้จากการเตรียมข้อมูลจะถูกนำไปเข้าสู่กระบวนการ (Data mining) เพื่อผ่านกระบวนการจัดเตรียมข้อมูลสำหรับการเรียนรู้ ก่อนนำมาเข้าสู่แบบจำลองโครงข่าย GRU ทั้งในส่วนการเรียนรู้และการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน โดยมีผลลัพธ์สุดท้ายคือระดับความสูงการบินขึ้นและลงจอดของเครื่องบิน ผลลัพธ์ของประสิทธิภาพแบบจำลองเมื่อทดสอบด้วยชุดข้อมูลสำหรับการทำนายผล (Post Processing) โดยใช้การประเมินประสิทธิภาพทั้งหมด 3 ตัวชี้วัด คือ ค่าคลาดเคลื่อนสัมบูรณ์ (Mean Absolute Error: MAE) ค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Mean Squared Error: MSE) และรากที่สองของค่าเฉลี่ยความผิดพลาดยกกำลังสอง (Root Mean Square Error: RMSE) ทุกๆ 1 ไทม์สเต็ปมีผลในการลดข้อผิดพลาด ผลการวิจัยพบว่าแบบจำลองนี้ให้ประสิทธิภาพที่ดีและมีความแม่นยำ โดยในการทำนายผลระดับความสูงการบินขึ้นและลงจอดของเครื่องบินนั้น แบบจำลองให้ความแม่นยำมากกว่า 97%

อย่างไรก็ตามการทำนายระดับความสูงการบินขึ้นและลงจอดของเครื่องบินนั้นเป็นปัญหาที่ซับซ้อน ไม่ควรพิจารณาเฉพาะปัญหาของวิธีการทำนายเท่านั้น แต่ยังคงพิจารณาปัญหาอื่น ๆ ด้วย เช่น การบินขึ้นและลงจอดของเครื่องบินสามารถเปลี่ยนแปลงได้โดยมนุษย์เป็นหลัก และขึ้นอยู่กับปัจจัยภายนอกของเครื่องบิน แม้ว่าการทำนายผลของแบบจำลองจะมีความแม่นยำสูง แต่ก็ขึ้นอยู่กับปัจจัยข้างต้น ดังนั้นแบบจำลองจึงต้องได้รับการฝึกฝนหลายๆครั้งเพื่อปรับให้เข้ากับสถานการณ์ต่างๆ เพื่อให้แบบจำลองสมบูรณ์แบบ

## 5.2 อภิปรายผลการดำเนินงาน

เนื้อหาในวิทยานิพนธ์ฉบับนี้ได้ทำการพัฒนาแบบจำลองเพื่อทำการทำนายผลระดับความสูง การบินขึ้นและลงจอดของเครื่องบินโดยใช้แบบจำลองโครงข่าย GRU แม้ว่าจะมีปัญหาในการเก็บ ข้อมูลของการบินขึ้นและลงจอดของเครื่องบิน แต่ผลลัพธ์ที่ได้ถือว่ามีประสิทธิภาพและมีความแม่นยำ สูง สามารถนำไปใช้เพื่อสนับสนุนการตัดสินใจในการบินขึ้นและลงจอดของเครื่องบินได้ นอกจากนี้ใน ส่วนของการเก็บข้อมูลที่ไม่สามารถระบุส่วนที่มีความคลุมเครือของข้อมูลการบินขึ้นและลงจอด สามารถต่อยอดได้โดยเพิ่มกระบวนการปรับปรุงคุณภาพของข้อมูลด้วยเตรียมข้อมูล(Data preprocessing) เพื่อคัดข้อมูลที่ ไม่เกี่ยวข้อง เช่น ข้อมูลที่ซ้ำซ้อน ข้อมูลไม่ถูกต้อง เกิดการสูญหาย ของข้อมูลในบางส่วน ให้มีความชัดเจนของข้อมูลมากขึ้น



## เอกสารอ้างอิง

- [1] Jan Roskam, Chuan-Tau Edward Lan, Airplane Aerodynamics and Performance, DARcorporation, 1997.
- [2] X. Su, H. Li, Y. Zhang, H. Jiang and M. Zhao, "Research on Landing Environment System of Carrier-Based Aircraft," in *IEEE*, Nanchang, China, 2019.
- [3] "ONE TWO GO AIRLINES COMPANY LIMITED MCDONNELL DOUGLAS DC-9-82 (MD-82)," MINISTRY OF TRANSPORT, THAILAND, 2017.
- [4] "โศกนาฏกรรม'วันทุโก'," MGR Online, 17 กันยายน 2550. [Online]. Available: <https://mgronline.com/daily/detail/9500000109603>. [Accessed 5 เมษายน 2564].
- [5] "เครื่องบินเดินอากาศไทย ตกขณะร่อนลงจอดที่สนามบินภูเก็ต," trueID News, 29 สิงหาคม 2563. [Online]. Available: <https://news.trueid.net/detail/5vwdlP7bNYPM>. [Accessed 5 เมษายน 2564].
- [6] "เที่ยวบิน 365 ลวงสว่างตก ตายยกลำ!," komchadluek, 31 สิงหาคม 2561. [Online]. Available: <https://www.komchadluek.net/news/today-in-history/341589>. [Accessed 5 เมษายน 2564].
- [7] "ASN Aircraft accident Learjet 31 9V-ATD," flight safety foundation, 3 april 2021. [Online]. Available: <https://aviation-safety.net/database/record.php?id=19970721-1>. [Accessed 5 april 2021].
- [8] "ทำอากาศยานภูเก็ต," 3 เมษายน 2564. [Online]. Available: <https://th.wikipedia.org/wiki/ทำอากาศยานภูเก็ต>. [Accessed 5 เมษายน 2564].
- [9] "เครื่องบินเล็กบินพา 2 นักศึกษาดูงาน เสียการทรงตัวตกกระแทกพื้น กัปตันและครูดับ นักศึกษาเจ็บ 2 ราย," MATICHON ONLINE, 10 มีนาคม 2561. [Online]. Available: [https://www.matichon.co.th/news-monitor/news\\_870845](https://www.matichon.co.th/news-monitor/news_870845). [Accessed 5 เมษายน 2564].
- [10] "3dwarehouse,"[Online].Available: <https://3dwarehouse.sketchup.com/model/b0734335-2029-47cf-8278-d9034a5becd4/Airbus-A320-211212214215216WL-Template>.
- [11] Krenkel, A.R., Salzman, A., "Journal of Aircraft," *AEROSPACE RESEARCH CENTRAL*, vol. 5, no. 5, 1968.

- [12] "SHORT-FIELD TAKEOFF AND CLIMB," 12charlie, 2012. [Online]. Available: [http://www.12charlie.com/Chapter\\_12/Chap12Page021.htm](http://www.12charlie.com/Chapter_12/Chap12Page021.htm).
- [13] Yajuan zhu, Jiangfeng wang, Yongliang chen, Yizhao wu, "CALCULATION OF TAKEOFF AND LANDING PERFORMANCE UNDER," in *Sixth International Symposium on Physics of Fluids (ISPF6)*, 2016.
- [14] "flyinhighokc," Short-Field Approach and Landing, 1999. [Online]. Available: <http://www.flyinhighokc.com/flyinghandbook/pages/8-19.html>.
- [15] "Accident Reports," aviationchief, 2021. [Online]. Available: <http://www.aviationchief.com/accident-reports.html>.
- [16] "What Is the Safest Seat on a Plane?," popularmechanics, 18 jul 2007. [Online]. Available: <https://www.popularmechanics.com/flight/a1918/4219452/>.
- [17] ช. ประกอบผล, "โครงข่ายประสาทเทียม," *วารสาร มวก.วิชาการ* 12(24), pp. 73-87, 2552.
- [18] D. W. Patterson, *Artificial Neural Networks: Theory and Applications.*, Singapore: Prentice Hall., 1996.
- [19] L. Fausett, *Foundations of Neural Networks : Architectures Algorithms and Applications.*, London: Prentice-Hall International., 1994.
- [20] F. Limin, *Neural Networks in Computer Intelligence.*, New York: Mcgraw-Hill., 1994.
- [21] Y. Lecun, Y. Bengio, and G. Hinton., "Deep Learning,," *Nature*, vol. 521, no. 7553, pp. 436-444, May, 2015.
- [22] R. Hecht-Nielsen, "In Neural Networks for," in *Theory of the backpropagation neural network.*, Academic Press., 1992, pp. 65-93.
- [23] Han and etc., "EIE: Efficient Inference Engine on Compressed Deep Neural Network," in *2016 ACM/IEEE 43rd Annual International Symposium on Computer Architecture (ISCA)*, Seoul, Korea (South), 25 August 2016.
- [24] Mikolov, T., Karafiát, M., Burget, L., Černocký, J., & Khudanpur, S., "Recurrent neural network based language model,," in *In Proceeding of Eleventh Annual Conference of the International Speech Communication Association.*, 2010.
- [25] Duan, Y., Lv, Y., & Wang, F.-Y., "Travel time prediction with LSTM neural network,," in *IEEE 19th International Conference on Intelligent Transportation Systems (ITSC)*, Rio de Janeiro, Brazil., 2016.

- [26] Premjith, B., Soman, K. P., & Kumar, M. A., "A deep learning approach for Malayalam morphological analysis at character level," in *International Conference on Computational Intelligence and Data Science (ICCIDS 2018)*, 2018.
- [27] J. S. Sepp Hochreiter, "Long short-term memory.," in *Neural Computation*, 9(8), 1997, pp. 1735-1780.
- [28] F. A. Gers, J. Schmidhuber, and F. Cummins, "Learning to Forget: Continual Prediction with LSTM," in *Neural Computation*, 12(10), 2000, pp. 2451-2471.
- [29] Y. Liu, Y. Wang, X. Yang and L. Zhang, "Short-term travel time prediction by deep learning: A comparison of different LSTM-DNN models," in *IEEE 20th International Conference on Intelligent Transportation Systems (ITSC)*, Yokohama, Japan, 2017.
- [30] K. Cho et al., "Learning Phrase Representations using RNN Encoder-Decoder for Statistical," in *Conference on Empirical Methods in Natural Language Processing (EMNLP)*, 2014.
- [31] J. Chung, C. Gulcehre, K. Cho, and Y. Bengio, "Empirical Evaluation of Gated Recurrent Neural Networks on Sequence Modeling," in *NIPS 2014 Deep Learning and Representation Learning Workshop*, 2014.

## ประวัติผู้เขียน

ชื่อ-นามสกุล	นายศิวกร ปวีตรปก
วัน เดือน ปีเกิด	26 ธันวาคม 2539 ที่กรุงเทพมหานคร
ที่อยู่	562 ม.10 ต.ท่าตูม อ.ศรีมหาโพธิ ปราจีนบุรี 25140 โทร.084-3271038
ประวัติการศึกษา	พ.ศ. 2558 มัธยมศึกษาตอนปลาย โรงเรียนมาารีวิทยากบินทร์บุรี พ.ศ. 2562 วิศวกรรมศาสตรบัณฑิต สาขาวิชาอิเล็กทรอนิกส์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ประสบการณ์การทำงานและผลงานวิจัย	
พ.ศ.2563	ตีพิมพ์หัวข้อวิจัย “Intelligent air-traffic-management to predict altitude of aircraft for effective landing on island-landscape airport by using Deep learning approach” ในงานประชุมวิชาการ “Innovation Aviation & Aerospace Industry - International Conference 2020”
พ.ศ.2563	ตีพิมพ์หัวข้อวิจัย “Vertical speed prediction for the efficient landing of aircraft using GRU” ในงานประชุมวิชาการ “5th International STEM Education Conference”
พ.ศ.2564	ตีพิมพ์หัวข้อวิจัย “Altitude prediction for the efficient take-off and landing of aircraft using Gated recurrent unit (GRU).” ในงานประชุมวิชาการ “The 7th International Conference on Engineering, Applied Sciences and Technology”

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้