

การจำแนกประเภทของพลาสมาบับเบิลบริเวณเส้นศูนย์สูตรโดยใช้ข้อมูลจาก

เรดาร์ความถี่สูงมากด้วยปัญญาประดิษฐ์

CLASSIFICATION OF EQUATORIAL PLASMA BUBBLES USING VERY HIGH-  
FREQUENCY RADAR DATA WITH ARTIFICIAL INTELLIGENCE



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิศวกรรมศาสตรดุษฎีบัณฑิต  
สาขาวิชาวิศวกรรมไฟฟ้า

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2567

KMITL-2025-EN-D-018-091

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

CLASSIFICATION OF EQUATORIAL PLASMA BUBBLES USING VERY HIGH-  
FREQUENCY RADAR DATA WITH ARTIFICIAL INTELLIGENCE



THANANPHAT THANAKULKETSARAT

A THESIS SUBMITTED IN PARTIAL FULFILLMENT  
OF THE REQUIREMENT FOR THE DEGREE OF

DOCTOR OF ENGINEERING IN ELECTRICAL ENGINEERING

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

2024

KMITL-2025-EN-D-018-091

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่ออนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2024

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การจำแนกประเภทของพลาสมาบับเบิลบริเวณเส้นศูนย์สูตรโดยใช้ข้อมูลจากเรดาร์ความถี่สูงมากด้วยปัญญาประดิษฐ์
นักศึกษา	นางสาวธนันท์พัชญา ธนากุลเกษรรัตน์
รหัสประจำตัว	64601062
ปริญญา	วิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้า
พ.ศ.	2567
อาจารย์ที่ปรึกษา	ศาสตราจารย์ ดร. พรชัย ทรัพย์นิธิ

### บทคัดย่อ

พลาสมาบับเบิลบริเวณเส้นศูนย์สูตร (Equatorial plasma bubbles หรือ EPB) เกิดจากความผิดปกติที่เกิดขึ้นภายในของชั้นไอโอโนสเฟียร์ในช่วงหลังพระอาทิตย์ตกดิน โดยที่ความหนาแน่นของพลาสมาในชั้นไอโอโนสเฟียร์ลดลงอย่างรวดเร็วซึ่งปริมาณความหนาแน่นของพลาสมาบริเวณนั้นจะมีความหนาแน่นต่ำกว่าพื้นที่รอบข้าง ความผิดปกติที่เกิดขึ้นในชั้นบรรยากาศไอโอโนสเฟียร์อาจส่งผลกระทบต่อระบบวิทยุ ระบบนำทาง และการสื่อสารผ่านดาวเทียมในชั้นบรรยากาศไอโอโนสเฟียร์ซึ่งจะทำให้เกิดการหยุดชะงัก การตรวจจับและจำแนก EPB แบบเรียลไทม์มีความสำคัญต่อการตรวจจับ EPB ในรายวัน ซึ่งในปี ค.ศ. 2020 ได้มีการติดตั้งสถานีเรดาร์พระจอมเกล้า ซึ่งเป็นสถานีเรดาร์ความถี่สูงมาก (Very High Frequency radar หรือ VHF) ที่สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง วิทยาเขตชุมพร (พิกัดภูมิศาสตร์: 10.72° N, 99.73° E และพิกัดแม่เหล็ก: 1.33° N) และเริ่มผลิตภาพเรดาร์ตั้งแต่นั้นเป็นต้นมา ในงานวิจัยนี้ นำเสนอวิธีในการตรวจจับพลาสมาบับเบิลจำนวน 3 วิธี ได้แก่ 1) วิธีซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine) 2) วิธีการโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีน (CNN-SVM) และ 3) วิธีการแยกค่าเอกฐาน (Singular Value Decomposition) ร่วมกับซัพพอร์ตเวกเตอร์แมชชีน (SVD-SVM) โดยแบบจำลองที่นำเสนอ นั้นได้รับการฝึกอบรมโมเดลโดยใช้รูปภาพพล็อตแบบ Quick Look (QL) จากระบบเรดาร์ VHF และวิธีการที่ใช้ข้อมูลจากเรดาร์ VHF ร่วมกับไอโอแกรม (Ionograms) ซึ่งเป็นข้อมูลที่ได้รับจากระบบไอโอโนซอนด์ ผลการทดลองแสดงให้เห็นว่าแบบจำลอง CNN-SVM ของเคอร์เนล RBF โดยการใช้ข้อมูลเรดาร์ VHF ร่วมกับไอโอแกรมที่ถูกกลบสัญญาณรบกวน (Remove noise) ที่เกิดขึ้นบนรูปภาพให้ความแม่นยำสูงสุดที่ 97.83 เปอร์เซ็นต์ ในขณะที่แบบจำลองที่ใช้ข้อมูลเพียงข้อมูลของเรดาร์ VHF แบบจำลองมีความแม่นยำที่ 93.67 เปอร์เซ็นต์ ตามลำดับ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

**Thesis Title** Classification of equatorial plasma bubbles using very high-frequency radar data with artificial intelligence

**Student** Miss Thananphat Thanakulketsarat

**Student ID.** 64601062

**Degree** Doctor of Engineering

**Program** Electrical Engineering

**Year** 2024

**Thesis Advisor** Prof. Dr. Pornchai Supnithi

## ABSTRACT

Equatorial plasma bubbles (EPB) are a phenomenon in which density of plasma in the ionosphere decreases after sunset. Such anomalies in the ionosphere can disrupt ionospheric radio, navigation, and satellite communications systems. Real-time EPB detection and classification are of great importance to the space weather community. In 2020, the King Mongkut's Institute of Technology Ladkrabang's Very High Frequency (VHF) radar station was installed at King Mongkut's Institute of Technology Ladkrabang, Chumphon Campus (geographic coordinates: 10.72° N, 99.73° E; magnetic coordinates: 1.33° N) and has been producing radar images since then. In this research, we propose three methods for detecting plasma bubbles: the first method is to detect plasma bubbles using the Support Vector Machine (SVM) technique. The second method is to experiment with image feature extraction techniques to reduce the model training time by using image feature extraction techniques from a Convolutional Neural Network (CNN) and Singular Value Decomposition, which is connected to Support Vector Machine (SVM) method, the proposed model is trained using Quick Look (QL) plot images from VHF radar system, and the third method designs the model using VHF radar data together with ionograms, which are the data obtained from ionosondes. The experimental results show that the RBF kernel CNN-SVM model using VHF radar data together with the removed noise ionograms on the images achieves the highest

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

accuracy of 97.83 percent, while the model using only VHF radar data achieves the accuracy of 93.67 percent, respectively.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## กิตติกรรมประกาศ

วิทยานิพนธ์ระดับปริญญาเอกนี้สำเร็จลุล่วงไปได้ด้วยดีเนื่องจากได้รับความช่วยเหลือในด้านคำแนะนำที่ดีจากอาจารย์ที่ปรึกษาของผู้จัดทำวิทยานิพนธ์ ศ.ดร.พรชัย ทรัพย์นิธิ ซึ่งอาจารย์คือพลังขับเคลื่อนหลักในการผลักดันผู้จัดทำวิทยานิพนธ์ให้สำเร็จผลในการศึกษาระดับปริญญาเอกที่สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง (KMITL) ผู้จัดทำวิทยานิพนธ์ขอขอบพระคุณศูนย์ความเป็นเลิศด้านจีเอ็นเอสเอสและสภาวะอากาศประเทศไทยและโครงการ SEALION (Southeast Asia Low-latitude Ionospheric Network) ซึ่งบริหารงานโดยสถาบันเทคโนโลยีการสื่อสารแห่งชาติ (NICT) ประเทศญี่ปุ่น สำหรับการสนับสนุนด้านการวิจัยโดยการจัดหาและให้ข้อมูลเรดาร์ VHF และไอโอโนแกรม

สำหรับคุณงามความดีอันใดที่เกิดจากวิทยานิพนธ์ฉบับนี้ ข้าพเจ้าขอมอบให้กับบุคคลในครอบครัวของข้าพเจ้าทุกท่าน ตลอดจนครูอาจารย์ที่เคารพทุกท่านที่ได้มอบวิชาความรู้และถ่ายทอดประสบการณ์ที่ดีให้แก่ข้าพเจ้า หากวิทยานิพนธ์ฉบับนี้เกิดข้อบกพร่องประการใด ข้าพเจ้าน้อมรับผิดไว้แต่เพียงผู้เดียว

ท้ายที่สุดนี้ ข้าพเจ้าขอแสดงความขอบคุณคณะกรรมการทุกท่านในการปกป้องวิทยานิพนธ์ระดับปริญญาเอกของข้าพเจ้าสำหรับคำถามและความคิดเห็นอันมีค่าของทุกท่าน ซึ่งเป็นองค์ประกอบที่สำคัญที่ช่วยให้มั่นใจถึงด้านเทคนิคและวิทยาศาสตร์ขั้นสูงของวิทยานิพนธ์ระดับปริญญาเอกนี้

ธนนันท์ พิชญ์ ธนากุลเกษรรัตน์

# สารบัญ

	หน้า
บทคัดย่อ.....	I
บทคัดย่อภาษาอังกฤษ.....	II
กิตติกรรมประกาศ.....	IV
สารบัญ.....	V
สารบัญตาราง.....	IX
สารบัญรูป.....	X
รายการคำย่อและสัญลักษณ์.....	XIII
บทที่ 1 บทนำ.....	1
1.1 ที่มาและความสำคัญของวิทยานิพนธ์.....	1
1.2 วัตถุประสงค์ของวิทยานิพนธ์.....	3
1.3 ขอบเขตของการศึกษา.....	4
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	5
2.1 ชั้นบรรยากาศด้านบนของโลก.....	5
2.2 ปฏิกิริยาการแผ่รังสีของแก๊สเรือนกระจก.....	7
2.3 เรดาร์ความถี่สูงมาก.....	9
2.3.1 การบังคับทิศทางด้วยลำแสงของเรดาร์.....	11
2.3.2 เรดาร์มอดูเลตแบบพัลส์.....	12
2.4 ไอโอโนสเฟียร์.....	18

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
2.5 การเรียนรู้ของเครื่อง	23
2.5.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน	24
2.5.2 ซัพพอร์ตเวกเตอร์แมชชีน	29
2.5.3 การประเมินผลของโมเดล	39
บทที่ 3 วิธีในการจำแนกประเภทของพลาสมาบับเบิลบริเวณเส้นศูนย์สูตร.....	42
3.1 ทบทวนวรรณกรรมที่เกี่ยวข้อง	42
3.2 การเตรียมข้อมูลเพื่อใช้ในการฝึกอบรมโมเดล	45
3.2.1 การวิเคราะห์และจัดเตรียมข้อมูลของภาพเรดาร์ VHF	45
3.2.2 ข้อมูลภาพไอโอโนแกรม	47
3.3 วิธีการของซัพพอร์ตเวกเตอร์แมชชีนโดยใช้ข้อมูลจากเรดาร์ VHF	48
3.4 วิธีการแยกค่าเอกพจน์ร่วมกับวิธีการซัพพอร์ตเวกเตอร์แมชชีนด้วยข้อมูลจาก เรดาร์ VHF	49
3.5 วิธีการโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีน โดยใช้ข้อมูลจากเรดาร์ VHF	51
3.6 โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีน เพื่อจำแนกประเภทของพลาสมาบับเบิลโดยการใช้ข้อมูลจากเรดาร์ VHF ร่วมกับรูปภาพไอโอโนแกรม (Ionograms)	52

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
3.6.1 แบบจำลองโมเดล CNN-SVM โดยใช้ข้อมูลจากเรดาร์ VHF พร้อมกับไอโอโนแกรม	52
3.6.2 แบบจำลองโมเดล CNN-SVM โดยใช้ข้อมูลจากเรดาร์ VHF พร้อมกับไอโอโนแกรมโดยลบสัญญาณรบกวนบนรูปภาพไอโอโนแกรม	53
3.6.3 แบบจำลองโมเดล CNN-SVM โดยใช้ข้อมูลจากเรดาร์ VHF พร้อมกับไอโอโนแกรมโดยลบสัญญาณรบกวนบนรูปภาพไอโอโนแกรมโดยการใช้ชั้นจำนวนการคอนโวลูชัน 2 ชั้น (Multi-Convolutional)	54
3.7 การตรวจสอบความถูกต้องของข้อมูลเรดาร์ VHF และไอโอโนซอนด์	55
3.8 การวิเคราะห์ทิศทางการก่อตัว การเคลื่อนตัว รวมไปถึงจำนวนของพลาสมาบับเบิลด้วยข้อมูลจากเรดาร์ VHF	57
3.8.1 วิเคราะห์ทิศทางการเคลื่อนตัวของ EPB	57
3.8.2 วิเคราะห์จำนวนของ EPB ที่เกิดขึ้นด้วยข้อมูลจากเรดาร์ VHF	59
บทที่ 4 ผลการวิจัยและอภิปราย.....	60
4.1 ผลการวิเคราะห์ระดับความสูงและความเร็วในการเคลื่อนตัวของพลาสมาบับเบิลด้วยข้อมูลเรดาร์ VHF	61
4.1.1 ผลการคำนวณระดับความสูงและความเร็วในการเคลื่อนตัวของพลาสมาบับเบิลด้วยข้อมูลเรดาร์ VHF	61
4.1.2 ผลการวิเคราะห์ความเร็วการเคลื่อนตัวในแนวตั้ง	64

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญ (ต่อ)

	หน้า
4.2 ผลการจำลองการจำแนกประเภทของพลาสมาบับเบิลด้วย	67
4.2.1 ผลการจำลองด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF	67
4.2.2 ผลการจำลองด้วยวิธีการแยกค่าเอกฐานร่วมกับการซัพพอร์ตเวกเตอร์แมชชีน ด้วยข้อมูลจากเรดาร์ VHF	69
4.2.3 ผลการจำลองด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ต เวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF	71
4.2.4 ผลการจำลองด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ต เวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF ร่วมกับรูปภาพไอโอโนแกรม	74
4.2.5 ผลการเปรียบเทียบประสิทธิภาพของโมเดลการจำแนกประเภทของพลาสมา บับเบิลบริเวณเส้นศูนย์สูตรที่นำเสนอ	78
บทที่ 5 สรุปผลการวิจัยและข้อเสนอแนะ.....	84
5.1 สรุปผลการวิจัย	84
5.2 ข้อเสนอแนะสำหรับการวิจัยในอนาคต	84
เอกสารอ้างอิง.....	86
ประวัติผู้เขียน.....	92
ภาคผนวก.....	93

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญตาราง

ตารางที่	หน้า
ตารางที่ 2.1 ข้อมูลจำเพาะของเรดาร์ VHF ของสถานีชุมพร	11
ตารางที่ 2.2 ประเภทของเคอร์เนลฟังก์ชัน	39
ตารางที่ 3.1 วรรณกรรมเกี่ยวกับปัญญาประดิษฐ์ของพลาสมาบับเบิล	42
ตารางที่ 4.1 ความแม่นยำของโมเดล SVM โดยเคอร์เนล RBF สำหรับค่าแกมมาที่แตกต่างกัน	67
ตารางที่ 4.2 ความแม่นยำของโมเดล SVM โดยเคอร์เนลพหุนาม (Polynomial Kernel) ที่มีระดับ (Degree) แตกต่างกัน	68
ตารางที่ 4.3 ค่าความแม่นยำของโมเดล SVD-SVM สำหรับเคอร์เนลต่าง ๆ	70
ตารางที่ 4.4 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนล RBF) สำหรับขนาดตัวกรองต่าง ๆ	72
ตารางที่ 4.5 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนลพหุนาม) สำหรับขนาดตัวกรองต่าง ๆ	73
ตารางที่ 4.6 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนล RBF) ที่มีขนาดตัวกรอง 3x3 จากผลการทดสอบโมเดล	75
ตารางที่ 4.7 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนลพหุนาม) ที่มีขนาดตัวกรอง 3x3 จากผลการทดสอบโมเดล	75
ตารางที่ 4.8 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนล RBF) ที่ใช้เลเยอร์คอนโวลูชัน 2 ชั้น จากผลการทดสอบโมเดล	77
ตารางที่ 4.9 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนลพหุนาม) ที่ใช้เลเยอร์คอนโวลูชัน 2 ชั้น จากผลการทดสอบโมเดล	77
ตารางที่ 4.10 เปรียบเทียบค่าความแม่นยำ (Accuracy) ของแต่ละแบบจำลองสำหรับเคอร์เนล RBF	78

## สารบัญรูป

รูปที่	หน้า
รูปที่ 2.1 พฤติกรรมของคลื่นเมื่อมีมุมตกกระทบต่างกัน	6
รูปที่ 2.2 การแยกตัวของชั้นไอโอโนสเฟียร์ในช่วงกลางวันและกลางคืน	6
รูปที่ 2.3 ความหนาแน่นของอิเล็กตรอนทั้งกลางวันและกลางคืนในชั้นบรรยากาศไอโอโนสเฟียร์ [1]	7
รูปที่ 2.4 ความไม่แน่นอนของ Rayleigh-Taylor [2]	8
รูปที่ 2.5 ระบบเรดาร์ซุ่มพร VHF สำหรับตรวจสอบพลาสมาบับเบิล	10
รูปที่ 2.6 ทิศทางและจำนวนของลำแสง (Beams) สำหรับเรดาร์ VHF	10
รูปที่ 2.7 การบังคับทิศทางของลำแสง	12
รูปที่ 2.8 การมอดูเลตแบบพัลส์ของเรดาร์	12
รูปที่ 2.9 กระบวนการแปลงภาพข้อมูลแบบ QL จากเรดาร์ VHF	15
รูปที่ 2.10 ตัวอย่างรูปแบบไฟล์ข้อมูลดิบ (Raw Data)	15
รูปที่ 2.11 ตัวอย่างข้อมูล (QL) ที่เกิดพลาสมาบับเบิลในวันที่ 13 เดือนกุมภาพันธ์ ค.ศ. 2020 เวลา 15.00 น.	18
รูปที่ 2.12 ตัวอย่างข้อมูล (RATI) ที่เกิดพลาสมาบับเบิลในวันที่ 13 เดือนกุมภาพันธ์ ค.ศ. 2020	18
รูปที่ 2.13 ระบบไอโอโนซอนด์ที่สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง	19
รูปที่ 2.14 ข้อมูลไอโอโนแกรมจากไอโอโนซอนด์ที่มีการแพร่กระจาย F เกิดขึ้น	19
รูปที่ 2.15 ระบบเรดาร์ FMCW พร้อมความสัมพันธ์ความถี่และเวลา [3]	21
รูปที่ 2.16 ไอโอโนซอนด์ [3]	22
รูปที่ 2.17 แบบจำลองของโครงข่ายประสาทเทียมแบบคอนโวลูชัน	24
รูปที่ 2.18 ตัวอย่างวิธีการคอนโวลูชัน	25
รูปที่ 2.19 ตัวอย่างการก้าวของตัวกรอง	26
รูปที่ 2.20 ตัวอย่างการขยายพื้นที่รอบอินพุต	27
รูปที่ 2.21 วิธีการพูลลิงแบบเลือกค่าสูงสุด	27
รูปที่ 2.22 วิธีการพูลลิงแบบเลือกค่าเฉลี่ย	28
รูปที่ 2.23 วิธีการพูลลิงแบบเลือกค่าต่ำสุด	28
รูปที่ 2.24 การเปลี่ยนรูปของข้อมูลหรือ Flatten	29
รูปที่ 2.25 ชั้นเชื่อมโยงแบบสมบурณ์	29

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูป (ต่อ)

รูปที่	หน้า
รูปที่ 2.26 ระยะขอบของคลาสและไฮเปอร์เพลนที่ใช้ในการจัดประเภทข้อมูลของสองคลาสเวกเตอร์ สนับสนุนที่ใช้เพื่อให้มีระยะขอบสูงสุดจากแต่ละคลาสของข้อมูล	30
รูปที่ 2.27 ข้อมูลที่ไม่สามารถแยกได้เป็นเส้นตรงโดยมีตัวแปรยืดหยุ่น (Slack) ที่กำหนดเพื่อลด ข้อผิดพลาดจากการจำแนกประเภทที่ไม่ถูกต้อง	35
รูปที่ 2.28 การแมปปีงข้อมูล	37
รูปที่ 3.1 ตัวอย่างข้อมูลเรดาร์ VHF หลังจากการครอบตัดและปรับขนาด	46
รูปที่ 3.2 ตัวอย่างข้อมูลเรดาร์ VHF ในรูปแบบการพล็อตความเข้มของช่วงระดับความสูง - เวลา (RATI)	46
รูปที่ 3.3 ตัวอย่างข้อมูลไอโอโนแกรมหลังจากการครอบตัดและปรับขนาด	47
รูปที่ 3.4 ตัวอย่างข้อมูลเรดาร์ VHF และไอโอโนแกรมสำหรับแต่ละคลาส	48
รูปที่ 3.5 สถาปัตยกรรมของแบบจำลอง SVM ด้วยข้อมูลจากเรดาร์ VHF	49
รูปที่ 3.6 สถาปัตยกรรมของโมเดล SVD-SVM	50
รูปที่ 3.7 สถาปัตยกรรมของโมเดล CNN-SVM [4]	52
รูปที่ 3.8 สถาปัตยกรรมของแบบจำลอง CNN-SVM โดยใช้ VHF พร้อมข้อมูลไอโอโนแกรม	53
รูปที่ 3.9 ตัวอย่างการลบสัญญาณรบกวนบนรูปภาพข้อมูล	54
รูปที่ 3.10 สถาปัตยกรรมของแบบจำลอง CNN-SVM โดยการเพิ่มโครงสร้างเลเยอร์ Convolutional ของ CNN เพื่อค้นหาแผนที่คุณลักษณะ (Multi - Convolutional layer)	55
รูปที่ 3.11 สถิติการตรวจสอบข้อมูลเรดาร์ VHF และไอโอโนซอนด์ในเดือนมีนาคม	55
รูปที่ 3.12 ตัวอย่างข้อมูลจากเรดาร์ VHF และไอโอโนซอนด์ เมื่อตรวจพบความผิดปกติที่เกิดขึ้นใน ชั้นบรรยากาศ	56
รูปที่ 3.13 ตัวอย่างการวิเคราะห์ทิศทางการก่อตัวและการเคลื่อนที่ของ EPB	58
รูปที่ 3.14 ตัวอย่างการวิเคราะห์จำนวนของ EPB ด้วยข้อมูลจากเรดาร์ VHF และ GNSS	59
รูปที่ 4.1 ตัวอย่างการคำนวณความสูงของพลาสมาบับเบิล	61
รูปที่ 4.2 บล็อกไดอะแกรมของการคำนวณระดับความสูงของพลาสมาบับเบิล	62
รูปที่ 4.3 ผลการคำนวณระดับความสูงของพลาสมาบับเบิล	63
รูปที่ 4.4 ตัวอย่างวิธีการคำนวณการเคลื่อนตัวของ EPB ในแนวตั้ง	65

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## สารบัญรูป (ต่อ)

รูปที่	หน้า
รูปที่ 4.5 ผลลัพธ์ความเร็วการเคลื่อนตัวของ EPB ในแนวตั้งข้อมูลจากเรดาร์ VHF เทียบกับไอโอโนซอนด์	66
รูปที่ 4.6 ตัวอย่างคุณภาพของภาพจากจำนวนส่วนประกอบ (Components) ต่างกัน	70
รูปที่ 4.7 เมทริกซ์ความสับสนแต่ละเทคนิคโดยใช้ข้อมูลจากเรดาร์ VHF สำหรับเคอร์เนล RBF	79
รูปที่ 4.8 เส้นโค้ง ROC ของแต่ละเทคนิคที่นำเสนอสำหรับเคอร์เนล RBF	80
รูปที่ 4.9 เมทริกซ์สับสนแบบจำลองการเพิ่มจำนวนชั้นการคอนโวลูชันสำหรับเคอร์เนล RBF	81
รูปที่ 4.10 เส้นโค้ง ROC แบบจำลองการเพิ่มจำนวนชั้นการคอนโวลูชันสำหรับเคอร์เนล RBF	82
รูปที่ 4.11 ต้นแบบซอฟต์แวร์ที่ใช้ในการจำแนกประเภทของ EPB	83

## รายการคำย่อและสัญลักษณ์

คำย่อ	คำเต็ม
ANN	Artificial Neural Network
AI	Artificial Intelligence
CNN	Convolutional Neural Network
FP	False positive class
FN	False negative class
GNSS	Global Navigation Satellite System
GPS	Global Positioning System
HF	High Frequency
ML	Machine learning
MF	Medium frequency
MSE	Mean square error
MSID	Medium scale ionospheric disturbance
NASA	National Aeronautics and Space Administration
NICT	National Institute of Communications Technology
PRE	Pre-reversal enhancement
RATI	Range Altitude Time Intensity
RTI	Range time intensity
R-T	Rayleigh Taylor instability theory
SEALION	SouthEast Asia Low-latitude Ionospheric Network
SVD	Singular Value Decomposition
SVM	Support Vector Machines
TP	True positive class
TN	True negative class
UT	Universal time
VHF	Very high frequency

# บทที่ 1

## บทนำ

### 1.1 ที่มาและความสำคัญของวิทยานิพนธ์

บรรยากาศชั้นไอโอโนสเฟียร์ (Ionosphere) เป็นชั้นบรรยากาศที่มีความสำคัญอย่างยิ่งต่อการสื่อสารด้วยคลื่นวิทยุและระบบระบุตำแหน่งบนพื้นโลก เนื่องจากเป็นบริเวณที่มีการแตกตัวของอะตอมและโมเลกุลจนกลายเป็นพลาสมา โดยเฉพาะในบริเวณชั้น F ซึ่งมีความหนาแน่นของอิเล็กตรอนสูงที่สุด อย่างไรก็ตาม ความไม่สม่ำเสมอของพลาสมาในชั้นนี้อาจส่งผลกระทบต่อความถูกต้องและเสถียรของระบบสื่อสารและนำทางอย่างมีนัยสำคัญ

หนึ่งในปรากฏการณ์สำคัญที่เกิดขึ้นในชั้นไอโอโนสเฟียร์บริเวณเส้นศูนย์สูตร คือปรากฏการณ์พลาสมาบับเบิลบริเวณเส้นศูนย์สูตร (Equatorial Plasma Bubble หรือ EPB) ซึ่งเกิดจากการลดลงอย่างรวดเร็วของความหนาแน่นของพลาสมา ทำให้เกิดบริเวณที่มีค่าความหนาแน่นต่ำกว่าโดยรอบ โดยมักเกิดขึ้นในช่วงหลังพระอาทิตย์ตก และสามารถขยายตัวได้ในระยะทางหลายร้อยกิโลเมตร EPB ส่งผลกระทบต่อตรงต่อการแพร่กระจายของคลื่นวิทยุความถี่สูง (High Frequency หรือ HF) และความแม่นยำของสัญญาณจากระบบนำทางด้วยดาวเทียม (Global Navigation Satellite System หรือ GNSS) เช่น GPS การศึกษาพองพลาสมาดังกล่าวสามารถดำเนินการได้อย่างมีประสิทธิภาพด้วยเทคนิคเรดาร์ โดยเฉพาะเรดาร์แบบ Coherent Backscatter ซึ่งสามารถตรวจจับความไม่สม่ำเสมอของพลาสมาที่จัดเรียงตามแนวสนามแม่เหล็กโลก (Field-Aligned Irregularities หรือ FAI) ได้อย่างชัดเจน หนึ่งในเรดาร์ที่สำคัญคือ Equatorial Atmosphere Radar (EAR) ซึ่งติดตั้งอยู่ที่ประเทศอินโดนีเซีย เป็นเรดาร์ VHF ที่มีการใช้งานอย่างแพร่หลาย EAR สามารถแสดงถึงความสามารถในการตรวจวัดการเปลี่ยนแปลงของความเข้มการกระเจิงกลับจากพองพลาสมาในช่วงเวลาหลังพระอาทิตย์ตก ซึ่งเป็นช่วงที่ปรากฏการณ์ EPB มีแนวโน้มเกิดขึ้นสูง [5] [6] [7] [8] [9] เรดาร์ São Luís ในประเทศบราซิล ยังเป็นอีกระบบที่มีบทบาทสำคัญในการศึกษาพองพลาสมา โดยสามารถตรวจพบโครงสร้างการสะท้อนของสัญญาณที่ยึดตัวในแนวตั้งซึ่งสัมพันธ์กับการพองของพลาสมาขนาดใหญ่ นอกจากนี้ยังตรวจพบการสะท้อนในระดับความสูงต่ำกว่าบริเวณที่มีการกระเจิงซึ่งไม่สามารถแยกแยะรายละเอียดได้อย่างชัดเจน [10] เรดาร์ Low Latitude Long Range Ionospheric Radar (LARID) ซึ่งตั้งอยู่บนเกาะไห่หนาน ประเทศจีน เป็นเรดาร์ที่ออกแบบมาเพื่อการศึกษาความผิดปกติ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ของไอโอโนสเฟียร์ในระยะทางไกล โดยสามารถตรวจจับการกระเจิงกลับจาก EPB ได้ไกลถึงกว่า 4,000 กิโลเมตร ซึ่งแสดงถึงศักยภาพของระบบในการติดตามความผิดปกติในระดับทวีป [11] นอกจากนี้ยังมีการใช้งานเรดาร์ VHF และ UHF ในการศึกษาความไม่สม่ำเสมอของพลาสมา ระบบ Jicamarca Unattended Long-Term Investigations of the Ionosphere and Atmosphere (JULIA) ใช้เรดาร์ VHF ที่ความถี่ประมาณ 50 เมกะเฮิร์ต ในการตรวจวัดความไม่ปกติที่มีขนาดในระดับเมตร ขณะที่เรดาร์ UHF สามารถตรวจจับความไม่สม่ำเสมอในระดับย่อยเมตร ซึ่งช่วยเพิ่มความละเอียดในการวิเคราะห์โครงสร้างของ EPB ได้อย่างมีประสิทธิภาพ [4] ในบางกรณีมีการใช้เรดาร์ VHF เพื่อตรวจสอบปรากฏการณ์การเปลี่ยนแปลงแอมพลิจูดและเฟสที่รวดเร็ว (Scintillation) หรือการสั่นสะเทือนของสัญญาณจากระบบนำทางดาวเทียมที่เกิดจาก EPB รวมถึงการเปลี่ยนแปลงของค่าความหนาแน่นอิเล็กตรอนทั้งหมด (Total Electron Content หรือ TEC) ซึ่งเป็นตัวชี้วัดความไม่เสถียรในไอโอโนสเฟียร์ [10] เรดาร์ Hainan COherent Scatter Phased Array Radar (HCOPAR) ซึ่งเป็นระบบเรดาร์แบบ อาร์เรย์เฟส (Phased-Array) ที่ตั้งอยู่ ณ สถานีวิจัยฟูเค่อ บนเกาะไห่หนาน ประเทศจีน ถูกออกแบบมาเพื่อศึกษาความผิดปกติที่จัดเรียงตามแนวสนามแม่เหล็ก (FAI) ใน [12] ชั้นไอโอโนสเฟียร์บริเวณเส้นศูนย์สูตร โดยสามารถสังเกตพฤติกรรมที่มีความสอดคล้องกันของความผิดปกติ รวมถึงตรวจวัดการเปลี่ยนแปลงของอัตราส่วนสัญญาณต่อสัญญาณรบกวน (Signal-to-Noise Ratio หรือ SNR) ซึ่งเป็นข้อมูลที่สำคัญต่อการวิเคราะห์กลไกการพัฒนาและการเคลื่อนที่ของ EPBs [13] จากการศึกษาล่าสุด ยังมีการใช้งาน LARID เพื่อสังเกตการณ์ EPB ที่ขยายในแนวลองจิจูดตั้งแต่มหาสมุทรแปซิฟิกจนถึงทวีปแอฟริกา โดยมีพิสัยตรวจจับถึง 9,500 กิโลเมตร และสามารถแสดงผลได้แบบเรียลไทม์ [11] นอกจากนี้ยังมีการใช้ข้อมูลจาก Incoherent Scatter Radar (ISR) ณ สถานี Millstone Hill ในการวิเคราะห์ลักษณะของ EPB ที่เกิดขึ้นในระหว่างพายุแม่เหล็กโลก โดยสามารถสังเกตการเพิ่มขึ้นของความสูงของชั้น F และการเคลื่อนตัวของพลาสมาในแนวตั้ง [14] รวมถึงการวิเคราะห์ความเร็วของพลาสมาในทิศทางขึ้น (Upward Plasma Drift) ที่สัมพันธ์กับความผิดปกติของความหนาแน่นที่เกิดจากพายุแม่เหล็กโลก [12] สุดท้าย การวิเคราะห์การเคลื่อนที่ของพองพลาสมาบริเวณเส้นศูนย์สูตร ยังสามารถทำได้โดยใช้ข้อมูลจากเรดาร์ Jicamarca Radio Observatory เพื่อประเมินระยะทางและความเร็วของการเคลื่อนตัวของ EPB ซึ่งมีความสำคัญต่อการพัฒนาแบบจำลองการพยากรณ์ปรากฏการณ์ในอนาคต [15]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

แม้ว่าจะมีการศึกษาปรากฏการณ์นี้มาอย่างต่อเนื่อง แต่การตรวจจับและจำแนกปรากฏการณ์ EPB ยังคงเป็นความท้าทาย เนื่องจากโครงสร้างของพลาสมาบับเบิลมีความซับซ้อนและแปรผันตามปัจจัยหลายประการ เช่น สภาพแวดล้อมแม่เหล็กโลก กิจกรรมของดวงอาทิตย์ และช่วงเวลาของปี ด้วยเหตุนี้ การนำเทคโนโลยีสมัยใหม่อย่างปัญญาประดิษฐ์และการเรียนรู้ของเครื่อง (Machine Learning) เข้ามาประยุกต์ใช้จึงเป็นแนวทางที่ได้รับความนิยมเพิ่มขึ้นในงานวิจัยปัจจุบัน ความก้าวหน้าล่าสุดในเทคนิคการตรวจจับและการจำแนก โดยเฉพาะการใช้การเรียนรู้ของเครื่องจักร ทำให้ความสามารถในการตรวจสอบปรากฏการณ์เหล่านี้แบบเรียลไทม์เพิ่มขึ้น หัวข้อต่อไปนี้จะสรุปประเด็นสำคัญของการจำแนก EPB

ในวิทยานิพนธ์ฉบับนี้ ผู้วิจัยเสนอแนวทางการตรวจจับปรากฏการณ์ EPB โดยใช้เทคนิคทางด้านการเรียนรู้ของเครื่อง ได้แก่ อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine หรือ SVM) การวิเคราะห์คุณลักษณะของภาพด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNN) และการลดมิติด้วยการแยกค่าเอกฐาน (Singular Value Decomposition หรือ SVD) นอกจากนี้ยังได้ทดลองออกแบบโมเดลการตรวจจับโดยใช้ข้อมูลจากเรดาร์ VHF ร่วมกับข้อมูลจากไอโอโนแกรม (Ionogram) เพื่อเพิ่มความแม่นยำของการตรวจจับและลดระยะเวลาในการประมวลผล

การศึกษานี้ยังมีเป้าหมายเพื่อพัฒนาเครื่องมือที่มีประสิทธิภาพในการตรวจจับ EPB และส่งเสริมการประยุกต์ใช้เทคโนโลยีด้านปัญญาประดิษฐ์ในงานด้านฟิสิกส์อวกาศ ซึ่งจะเป็นประโยชน์ทั้งต่อการวิจัยพื้นฐานและการพัฒนาเทคโนโลยีสำหรับระบบสื่อสารและการนำทางในอนาคต

## 1.2 วัตถุประสงค์ของวิทยานิพนธ์

1.2.1 นำเสนอวิธีการวิเคราะห์ทิศทางและการเคลื่อนตัว ความเร็วการเคลื่อนตัวในแนวตั้ง และจำนวนพลาสมาบับเบิลบริเวณเส้นศูนย์สูตรที่เกิดขึ้นในแต่ละวัน โดยการใช้ข้อมูลรูปภาพจากเรดาร์ VHF

1.2.2 นำเสนอวิธีการในการจำแนกประเภทของพลาสมาบับเบิลบริเวณเส้นศูนย์สูตรโดยการใช้ข้อมูลรูปภาพจากเรดาร์ VHF

1.2.3 พัฒนาซอฟต์แวร์สำหรับการจำแนกประเภทของพลาสมาบับเบิลด้วยข้อมูลจากภาพเรดาร์ VHF

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 1.3 ขอบเขตของการศึกษา

การศึกษานี้มุ่งเน้นการตรวจนับและจำแนกประเภทของปรากฏการณ์ พลาสมาบับเบิลบริเวณเส้นศูนย์สูตร โดยใช้ข้อมูลจากรadar VHF และไอโอโนซอนด์ซึ่งตั้งอยู่ที่ สถานีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง วิทยาเขตชุมพร ประเทศไทย ช่วงเวลาของข้อมูลที่ใช้ประกอบการศึกษา ได้แก่ วันที่ 1 เดือนมีนาคม ค.ศ. 2020 ถึงวันที่ 30 เดือนมีนาคม ค.ศ. 2020 และวันที่ 1 เดือนพฤศจิกายน ค.ศ. 2022 ถึงวันที่ 30 เดือนพฤศจิกายน ค.ศ. 2022

สำหรับการพัฒนาแบบจำลองจำแนกประเภทของ EPB ใช้เทคนิคด้านการเรียนรู้ของเครื่อง ได้แก่ ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine หรือ SVM) และโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNN) ซึ่งแบบจำลองที่พัฒนาขึ้นนี้มีวัตถุประสงค์เพื่อเพิ่มประสิทธิภาพในการจำแนกประเภทของพลาสมาบับเบิล โดยอาศัยข้อมูลจากระบบเรดาร์ VHF และไอโอโนซอนด์เป็นหลัก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 2 ทฤษฎีที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงทฤษฎีที่เกี่ยวข้องและสำคัญสำหรับการจัดทำวิทยานิพนธ์ รวมไปถึงแนวโน้มของงานวิจัยต่าง ๆ มีรายละเอียดดังต่อไปนี้

### 2.1 ชั้นบรรยากาศด้านบนของโลก

โลกถูกห่อหุ้มด้วยชั้นบรรยากาศที่มีความหนาประมาณ 2,000 กิโลเมตร ประกอบด้วยก๊าซต่าง ๆ ซึ่งมีความสำคัญต่อการดำรงชีวิต โดยเฉพาะไนโตรเจน (78%) และออกซิเจน (21%) ส่วนที่เหลือประกอบด้วยก๊าซอื่น ๆ เช่น คาร์บอนไดออกไซด์ โอโซน และไอน้ำ แม้จะมีสัดส่วนน้อย แต่ก็มีบทบาทสำคัญในกระบวนการควบคุมสภาพภูมิอากาศ [16] [17] [18] [19] ชั้นบรรยากาศไม่มีกำหนดขอบเขตที่แน่ชัด แต่โดยทั่วไปถือว่าสิ้นสุดเมื่อความหนาแน่นของอากาศลดลงจนไม่มีนัยสำคัญ และค่อย ๆ เปลี่ยนผ่านเข้าสู่ห้วงอวกาศ [17] [18] ชั้นบรรยากาศเบื้องบน (Upper Atmosphere) ประกอบด้วย มีโซสเฟียร์ เทอร์โมสเฟียร์ เอ็กโซสเฟียร์ และไอโอโนสเฟียร์ ซึ่งมีความหนาแน่นของอากาศต่ำ มีอุณหภูมิเปลี่ยนแปลงตามระดับความสูง และมักมีอนุภาคประจุ (ion) อยู่หนาแน่น โดยมีบทบาทในการดูดซับรังสีจากดวงอาทิตย์และส่งผลกระทบต่อระบบการสื่อสารของโลก ดังนี้

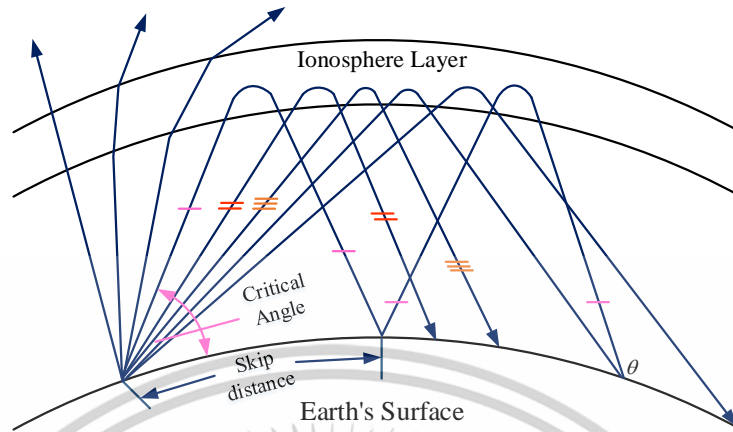
2.1.1 มีโซสเฟียร์ (Mesosphere) อยู่ที่ระดับความสูง 50–80 กิโลเมตร มีลมแรงและอุณหภูมิต่ำที่สุดในชั้นบรรยากาศ [18]

2.1.2 เทอร์โมสเฟียร์ (Thermosphere) อยู่ที่ระดับความสูง 80–700 กิโลเมตร อุณหภูมิสูงขึ้นมาจากการดูดซับรังสี UV และ X-ray [20]

2.1.3 เอ็กโซสเฟียร์ (Exosphere) เป็นชั้นนอกสุด เริ่มจาก 700 กิโลเมตรขึ้นไป โดยบรรยากาศจะเจือจางและค่อย ๆ แทรกซึมเข้าสู่ห้วงอวกาศ [20]

2.1.4 ไอโอโนสเฟียร์ (Ionosphere) อยู่ที่ความสูงประมาณ 85–1,000 กิโลเมตร เป็นบริเวณที่มีไอออนและอิเล็กตรอนอิสระหนาแน่น ส่งผลต่อการสะท้อนคลื่นวิทยุในย่านความถี่สูง (HF) ทำให้สามารถส่งสัญญาณในระยะไกลได้ ชั้นนี้จึงมีบทบาทสำคัญในการสื่อสารทางวิทยุ แม้ในยุคที่มีการใช้ดาวเทียมอย่างแพร่หลาย [20]


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.1 พฤติกรรมของคลื่นเมื่อมีมุมตกกระทบต่างกัน

ที่มา : [http://www.oocities.org/ten\\_2548/chapter8.html](http://www.oocities.org/ten_2548/chapter8.html)

จากรูปที่ 2.1 แสดงให้เห็นว่าคลื่นวิทยุที่ยิงเข้าสู่ชั้นไอโอโนสเฟียร์ในมุมต่ำกว่ามุมวิกฤตจะสะท้อนกลับมายังพื้นโลก ทำให้สามารถส่งสัญญาณได้ไกลขึ้น ในขณะที่คลื่นที่มีมุมยิงสูงกว่ามุมวิกฤตจะทะลุผ่านชั้นไอโอโนสเฟียร์ออกไปสู่อวกาศ การแพร่กระจายของคลื่นความถี่สูง (HF) ภายในไอโอโนสเฟียร์ขึ้นอยู่กับระดับการไอออไนซ์ของแต่ละบริเวณ ซึ่งมีความแตกต่างกันไปตามเวลาและพื้นที่ ส่งผลให้ชั้นไอโอโนสเฟียร์แบ่งออกเป็นหลายชั้น ได้แก่ ชั้น D, E และ F โดยเฉพาะชั้น F ซึ่งในเวลากลางวันจะแยกย่อยเป็นชั้น F1 และ F2 แต่ละชั้นมีผลต่อการสะท้อนและการดูดกลืนคลื่นวิทยุต่างกัน ส่งผลต่อคุณภาพและระยะทางการสื่อสารทางวิทยุ (ดังแสดงในรูปที่ 2.2)

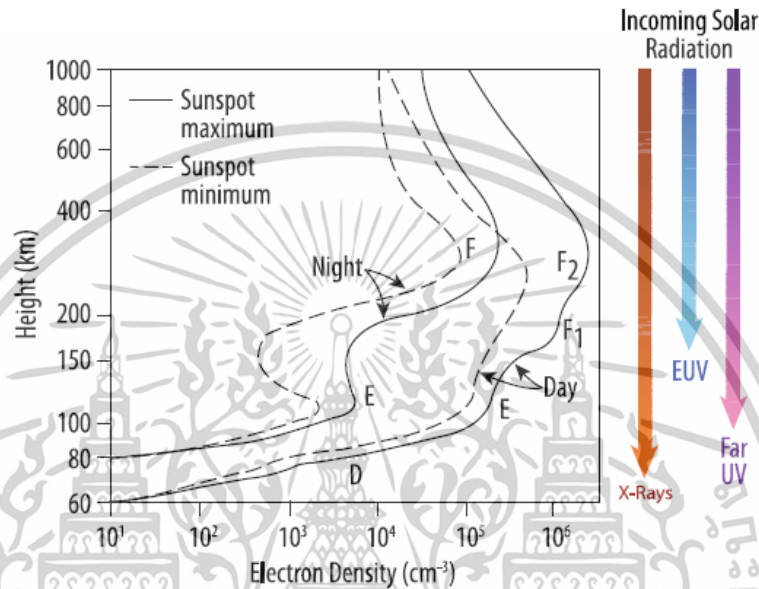


รูปที่ 2.2 การแยกตัวของชั้นไอโอโนสเฟียร์ในช่วงกลางวันและกลางคืน

ที่มา: <https://www.britannica.com/science/ionosphere-and-magnetosphere>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การค้นพบชั้นไอโอโนสเฟียร์ในช่วงแรก ๆ บ่งชี้ว่ามีชั้นอยู่หลายชั้น ไอออโนเซชันมีอยู่ทั่วทั้งชั้นบรรยากาศไอโอโนสเฟียร์ระดับแตกต่างกันไปตามระดับความสูง จุดสูงสุดในระดับอาจถือได้ว่าเป็นชั้นต่าง ๆ หรืออาจจะถูกต้องมากกว่าบริเวณ รูปที่ 2.3 เป็นรูปแบบการกระจายของอิเล็กตรอนโดยทั่วไปในบรรยากาศชั้นไอโอโนสเฟียร์



รูปที่ 2.3 ความหนาแน่นของอิเล็กตรอนทั้งกลางวันและกลางคืนในชั้นบรรยากาศไอโอโนสเฟียร์ [1]

## 2.2 ปรากฏการณ์พลาสมาบับเบิลบริเวณเส้นศูนย์สูตร


ปรากฏการณ์พลาสมาบับเบิล (Equatorial Plasma Bubble หรือ EPB) คือบริเวณในชั้นไอโอโนสเฟียร์ที่มีความหนาแน่นของอิเล็กตรอนลดลงผิดปกติ โดยมักเกิดบริเวณใกล้เส้นศูนย์สูตรแม่เหล็กโลก และมีผลกระทบต่อระบบสื่อสารและนำทาง โดยเฉพาะในช่วงเวลากลางคืน ระดับความสูงของปรากฏการณ์นี้อยู่ระหว่างประมาณ 200–1,200 กิโลเมตร การก่อตัวของพลาสมาบับเบิลเกิดจากความไม่เสถียรแบบ Rayleigh-Taylor instability ในชั้นบรรยากาศไอโอโนสเฟียร์ตอนล่าง ซึ่งขยายตัวขึ้นสู่ชั้นบน โดยความแตกต่างของความหนาแน่นอิเล็กตรอนที่รุนแรงสามารถทำให้เกิด “ฟองพลาสมา” ที่ลอยตัวขึ้นผ่านชั้น F ได้ภายในเวลาไม่กี่นาที

### 2.2.1 ความไม่เสถียรของ Rayleigh-Taylor

ความไม่เสถียรของเรย์ลีย์-เทย์เลอร์ (Rayleigh-Taylor Instability หรือ RTI) [2] เป็นกลไกพื้นฐานที่สำคัญในการก่อให้เกิดความไม่เสถียรของพลาสมาในชั้นไอโอโนสเฟียร์ โดยเฉพาะในบริเวณเส้นศูนย์สูตรช่วงเวลากลางคืน ปรากฏการณ์นี้เกิดขึ้นเมื่อพลาสมาที่มีความหนาแน่นสูงกว่าถูกจัดวาง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อยู่เหนือพลาสมาที่มีความหนาแน่นต่ำกว่าในสนามแรงโน้มถ่วง ทำให้เกิดสถานะไม่เสถียรซึ่งสามารถนำไปสู่การรบกวนที่ทวีความรุนแรงขึ้นเมื่อเวลาผ่านไป ในชั้น F ของไอโอโนสเฟียร์บริเวณเส้นศูนย์สูตร หลังช่วงพระอาทิตย์ตกดิน มักมีการไล่ระดับความหนาแน่นของอิเล็กตรอนอย่างรวดเร็ว ซึ่งเอื้อต่อการเกิด RTI การรบกวนเล็กน้อยที่เกิดขึ้นบริเวณด้านล่างของชั้น F อาจพัฒนาเป็นบริเวณพร่องพลาสมา (Plasma Depletion) หรือ “พลาสมาบับเบิล (Plasma Bubble)” ซึ่งสามารถลอยสูงขึ้นตามแนวเส้นสนามแม่เหล็กโลกและแผ่ขยายจากฐานขึ้นไปจนถึงด้านบนของชั้น F ดังแสดงในรูปที่ 2.4 เนื่องจากเส้นสนามแม่เหล็กมีแนวในแนวอนขบริเวณเส้นศูนย์สูตร และพลาสมามีการกระจายสม่ำเสมอไปตามแนวดังกล่าว ระบบพลาสมาจึงสามารถจำลองได้อย่างเหมาะสมด้วยแบบจำลองสองมิติในแนวตั้งบนระนาบตะวันออก-ตะวันตก (East - West) ที่ผ่านเส้นศูนย์สูตร นอกจากนี้ยังสามารถสังเกตกระแสไฟฟ้าในแนวตะวันออกที่เกิดจากความแตกต่างของแรงโน้มถ่วงที่กระทำต่ออิเล็กตรอนและไอออน เมื่อเกิดการผันผวนเล็กน้อยของความหนาแน่น ณ ด้านล่างของชั้นบรรยากาศไอโอโนสเฟียร์จะนำไปสู่การเปลี่ยนรูปของพื้นผิวความหนาแน่น (Isodensity Surface) ซึ่งเป็นจุดเริ่มต้นของการพัฒนาโครงสร้างไม่เสถียรของพลาสมา



รูปที่ 2.4 ความไม่แน่นอนของ Rayleigh-Taylor [2]

การเคลื่อนที่ของไอออนในพลาสมาทำให้เกิดการแยกตัวระหว่างพื้นผิวความหนาแน่นของอิเล็กตรอนและไอออน ส่งผลให้เกิดการสะสมของประจุไฟฟ้าในบางบริเวณ ซึ่งทำให้เกิดสนามไฟฟ้าโพลาไรเซชัน (Polarization Electric Field) ที่มีทิศทางสอดคล้องกับความหนาแน่นของพลาสมา กล่าวคือ สนามไฟฟ้ามีแนวโน้มชี้ไปทางทิศตะวันตกในบริเวณที่มีความหนาแน่นของอิเล็กตรอนสูง และชี้ไปทางทิศตะวันออกในบริเวณที่มีความหนาแน่นต่ำ สนามไฟฟ้านี้ก่อให้เกิดการล่องลอยของพลาสมาในแนวตั้งตามกลไก  $\vec{E} \times \vec{B}$  ซึ่งทำให้เกิดการเคลื่อนที่ของพลาสมาขึ้นในบริเวณที่มีความหนาแน่นต่ำ และลงในบริเวณที่มีความหนาแน่นสูง ส่งผลให้การไล่ระดับของความหนาแน่นรุนแรงขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และก่อให้เกิดความไม่เสถียรของพลาสมา (Plasma Instability) แม้รายละเอียดของกลไกการเกิด สunami ไฟฟ้าโพลาริเซชันจะไม่ได้กล่าวถึงในที่นี้ แต่ความไม่เสถียรของพลาสมาสามารถวิเคราะห์ได้ใน กรอบของพลศาสตร์เชิงเส้น (Linear Regime) โดยอัตราการเติบโตของความไม่เสถียร ( $\gamma$ ) สามารถ แสดงได้ดังสมการที่ (2.1)

$$\gamma = \left( \frac{E_x}{B} - W_y + \frac{g}{v_{in}} \right) \frac{1}{L} \quad (2.1)$$

โดยที่  $E_x$  คือสนามไฟฟ้าทางทิศตะวันออก (โวลต์ต่อเมตร)

$W_y$  คือลมที่เป็นกลางในแนวตั้ง (เมตร/วินาที)

$B$  คือสนามแม่เหล็กโลก (เทสลา)

$g$  คือความเร่งของแรงโน้มถ่วง (เมตรต่อวินาทีกำลังสอง)

$v_{in}$  คือความถี่การชนกันของไอออนที่เป็นกลาง

$L$  คือความยาวสเกลของการไล่ระดับตามแนวตั้งของความหนาแน่นของ พลาสมาในบริเวณชั้น F

จากสมการที่ (2.1) เมื่อแรงโน้มถ่วงและการไล่ระดับของความหนาแน่นของอิเล็กตรอนไม่ขนาน กัน กล่าวคือที่บริเวณด้านล่างอัตราการเติบโตจะเป็นบวกและขนาดจะแปรผันตรงกับความหนาแน่น ของการไล่ระดับ

## 2.3 เรดาร์ความถี่สูงมาก

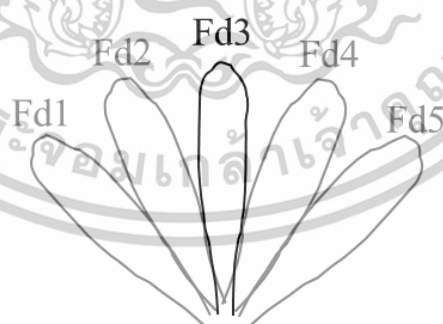
เรดาร์ VHF (Very High Frequency) เป็นระบบเรดาร์ที่ทำงานในช่วงความถี่ระหว่าง 30–300 เมกะเฮิร์ตซ์ โดยมีการใช้งานอย่างแพร่หลายในการควบคุมการจราจรทางอากาศ การเฝ้าระวังทาง ทะเล และการตรวจอากาศ ตัวระบบประกอบด้วยเครื่องส่งสัญญาณ เสาอากาศ เครื่องรับ และหน่วย ประมวลผลสัญญาณ โดยเครื่องส่งจะผลิตคลื่นแม่เหล็กไฟฟ้าความถี่สูงและส่งผ่านเสาอากาศออกไป เมื่อคลื่นเหล่านี้สะท้อนจากวัตถุ เช่น อากาศยาน หรือโครงสร้างของพลาสมาในชั้นบรรยากาศ สัญญาณสะท้อนจะถูกรับและแปลงผลเป็นข้อมูลตำแหน่ง ความเร็ว และทิศทางการเคลื่อนที่ของ เป้าหมาย ในงานวิจัยนี้ ได้ใช้ระบบเรดาร์ VHF สำหรับการสังเกตการณ์พลาสมาบับเบิลในชั้นไอโอ โนสเฟียร์ โดยใช้เสาอากาศยาก็ 3 องค์ประกอบ จำนวน 18 เสา จัดเรียงในแนวตะวันออก-ตะวันตก โดยมีระยะห่างระหว่างเสา 5 เมตร ใช้ความถี่ในการส่งประมาณ 39.65 เมกะเฮิร์ตซ์ เพื่อยิงคลื่นวิทยุ เข้าสู่ชั้นไอโอโนสเฟียร์ คลื่นที่ส่งจากเรดาร์จะสะท้อนกลับจากโครงสร้างไม่สม่ำเสมอของพลาสมา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บับเบิล ซึ่งทำให้สามารถตรวจวัดตำแหน่งและความเร็วของพลาสมาได้ การติดตั้งระบบเรดาร์นี้เป็นความร่วมมือระหว่างสถาบัน NICT (National Institute of Information and Communications Technology) ประเทศญี่ปุ่น และสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง วิทยาเขตชุมพร โดยเริ่มดำเนินการเมื่อวันที่ 17 เดือนมกราคม ค.ศ. 2020 ณ จังหวัดชุมพร ซึ่งตั้งอยู่ใกล้เส้นศูนย์สูตรแม่เหล็ก ทำให้เหมาะสมต่อการศึกษพลาสมาบับเบิลในระยะเริ่มต้นหลังการเกิดปรากฏการณ์รยะละเอียดของระบบเรดาร์แสดงไว้ในตารางที่ 2.1 และภาพรวมของระบบแสดงในรูปแบบที่ 2.5



รูปที่ 2.5 ระบบเรดาร์ชุมพร VHF สำหรับตรวจสอบพลาสมาบับเบิล



VHFR @ CPN  
West ↔ East

รูปที่ 2.6 ทิศทางและจำนวนของลำแสง (Beams) สำหรับเรดาร์ VHF

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.1 ข้อมูลจำเพาะของเรดาร์ VHF ของสถานีชุมพร

ที่ตั้ง	10.72°N, 99.37°E
คลื่นความถี่ในการทำงาน	39.65 เมกะเฮิรตซ์
ประเภทเสาอากาศ	เสาอากาศ Yagi 3 องค์ประกอบ 18 เสา
อัตราขยาย	22 เดซิเบล
ทิศราบของลำแสง (s)	-60, -48, -36, -24, -12, 0, 12, 24, 36, 48, 60
Inter Pulse Period (IPP)	6 มิลลิวินาที
การส่งพัลส์	รหัสเสริม 32 ไมโครวินาที x 8 บิต
การบังคับทิศทางด้วยลำแสง	ทุก ๆ 2 IPP
ความละเอียดของช่วง	4.8 กิโลเมตร
จำนวนครั้งที่ระบบรวมสัญญาณที่มีเฟสตรงกัน	2
จำนวนของ FFT	256
จำนวนครั้งที่ระบบรวมสัญญาณที่มีเฟสไม่ตรงกัน	1
ช่วง	140 - 855.2 กิโลเมตร
จำนวนช่วง	150
ระยะเวลาการสังเกต	33.792 วินาที

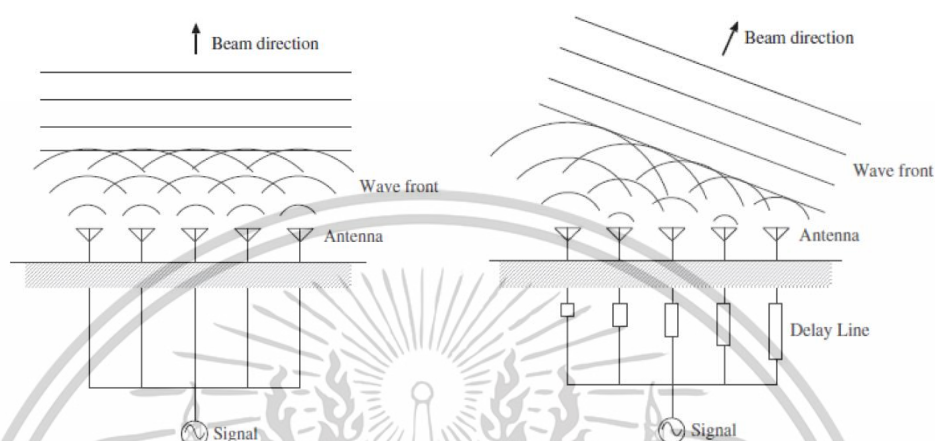
ระบบเรดาร์ VHF สำหรับการตรวจสอบพลาสมาบับเบิลมีรายละเอียดดังต่อไปนี้

### 2.3.1 การบังคับทิศทางด้วยลำแสงของเรดาร์

การบังคับทิศทางลำแสงเรดาร์ (Radar Beam Steering) คือความสามารถในการควบคุมทิศทางและรูปร่างของลำแสง (Beam) แม่เหล็กไฟฟ้าให้มุ่งไปยังตำแหน่งหรือเป้าหมายเฉพาะ ซึ่งเป็นคุณลักษณะสำคัญของระบบเรดาร์สมัยใหม่ การควบคุมดังกล่าวมักทำผ่านระบบเสาอากาศแบบอาร์เรย์ (Antenna Array) ซึ่งประกอบด้วยองค์ประกอบแผ่รังสีจำนวนมาก การบังคับทิศทางลำแสงสามารถทำได้โดยการปรับเปลี่ยนเฟสและแอมพลิจูดของสัญญาณที่ป้อนเข้าสู่แต่ละองค์ประกอบใน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


อาร์เรย์ ส่งผลให้เกิดการรวมคลื่นแบบเสริมกันในทิศทางที่ต้องการและหักล้างกันในทิศทางอื่น กระบวนการนี้เรียกว่า Phased Array Beamforming ซึ่งแสดงให้เห็นโดยภาพรวมในรูปที่ 2.7



รูปที่ 2.7 การบังคับทิศทางของลำแสง

### 2.3.2 เรดาร์มอดูเลตแบบพัลส์

การมอดูเลตแบบพัลส์ (Pulse Modulation) เป็นเทคนิคพื้นฐานที่ใช้ในระบบเรดาร์ VHF สำหรับการส่งและรับสัญญาณแม่เหล็กไฟฟ้าเพื่อตรวจจับและระบุตำแหน่งของวัตถุในบริเวณโดยรอบ โดยระบบจะทำการส่งพัลส์สัญญาณพลังงานสูงในช่วงเวลาสั้น ๆ ออกไปเป็นระยะ จากนั้นรับสัญญาณสะท้อนกลับจากวัตถุเป้าหมาย หลักการทำงานแสดงดังรูปที่ 2.8 การคำนวณระยะทางระหว่างเรดาร์กับวัตถุสามารถทำได้โดยการวัดเวลาหน่วง ( $\Delta t$ ) ระหว่างการส่งและรับสัญญาณ แล้วใช้สมการที่ (2.2)



รูปที่ 2.8 การมอดูเลตแบบพัลส์ของเรดาร์

จากรูปที่ 2.8 การคำนวณความละเอียดของช่วง ( $\Delta R$ ) ผลคูณระหว่างความเร็วของแสง ( $c$ ) และเวลา ( $t$ ) หาดด้วย 2 ซึ่งคำนวณได้ดังสมการที่ (2.2)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$\Delta R = \frac{ct}{2} \quad (2.2)$$

โดยที่  $c$  คือความเร็วของแสง (Speed of light) และ  $t$  คือเวลา (Time)

สเปกตรัมดอปเปลอร์ (Doppler spectrum หรือ  $f(v)$ ) เป็นเครื่องมือสำคัญในการวิเคราะห์พลวัตของพลาสมาในบรรยากาศไอโอโนสเฟียร์ โดยเฉพาะในบริเวณเส้นศูนย์สูตรที่มักพบการเกิดพลาสมาบับเบิล (Plasma Bubble) หรือบริเวณที่ความหนาแน่นของพลาสมาลดลงอย่างมีนัยสำคัญ ในช่วงเวลากลางคืน ระบบเรดาร์ VHF สามารถตรวจจับการเปลี่ยนแปลงความถี่ของคลื่นสะท้อนซึ่งเกิดจากปรากฏการณ์ดอปเปลอร์ (Doppler Effect) อันเนื่องมาจากการเคลื่อนที่สัมพัทธ์ของความไม่ปกติในชั้นไอโอโนสเฟียร์ โดยการเปลี่ยนแปลงความถี่ดอปเปลอร์ ( $f_D$ ) สามารถหาได้จากความเร็วสัมพัทธ์ ( $v$ ) จำนวน 2 เท่าหารด้วยความยาวคลื่นของเรดาร์ ( $\lambda$ ) ซึ่งแสดงได้ด้วยสมการที่ (2.3)

$$f_D = \frac{2v}{\lambda} \quad (2.3)$$

โดยที่  $f_D$  คือความถี่ดอปเปลอร์ (เฮิร์ต)

$v$  คือความเร็วสัมพัทธ์ของวัตถุเป้าหมายในแนวทิศทางของลำแสงเรดาร์ (เมตรต่อวินาที)

$\lambda$  คือความยาวคลื่นของคลื่นเรดาร์ (เมตร)

พลังงานทั้งหมด (Total Power หรือ  $\bar{p}$ ) หมายถึงปริมาณพลังงานรวมของสัญญาณที่ถูกรับโดยระบบตรวจวัด ซึ่งรวมถึงทั้งพลังงานของสัญญาณที่ต้องการ (Desired Signal) และพลังงานของสัญญาณรบกวน (Noise หรือ Interference) ที่แทรกเข้ามาในระบบ การประเมินค่าพลังงานทั้งหมดนี้มีความสำคัญอย่างยิ่ง โดยเฉพาะในบริบทของการศึกษาปรากฏการณ์ที่มีผลกระทบต่อการแพร่กระจายของสัญญาณ เช่น การกระเจิง (Scattering) ที่เกิดจากความแปรปรวนของไอโอโนสเฟียร์ ในการคำนวณค่าพลังงานรวมของสัญญาณ ( $\bar{p}$ ) นิยมใช้การอินทิเกรตฟังก์ชันความหนาแน่นของสัญญาณ  $f(v)$  บนช่วงความถี่ดอปเปลอร์ระหว่าง  $-v_D$  ถึง  $+v_D$  ซึ่งครอบคลุมบริเวณความถี่ที่คาดว่า จะมีการกระเจิงของสัญญาณ โดยสามารถแสดงได้ด้วยสมการที่ (2.4)

$$\bar{p} = \int_{-v_D}^{+v_D} f(v) dv \quad (2.4)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่  $\bar{p}$  คือค่าพลังงานรวมของสัญญาณในช่วงเวลาที่กำหนด

$f(v)$  คือฟังก์ชันความหนาแน่นของสัญญาณหรือกำลังสเปกตรัมของสัญญาณ ณ ความเร็วโดปเปลอร์

$v_D$  คือค่าขอบเขตของความเร็วโดปเปลอร์ที่พิจารณา

ในการสังเกตการณ์ EPB ด้วยระบบเรดาร์ VHF ประสิทธิภาพในการตรวจจับความไม่ปกติในชั้นไอโอโนสเฟียร์ขึ้นอยู่กับความสามารถในการแยกแยะสัญญาณสะท้อนจากเป้าหมายออกจากสัญญาณรบกวนพื้นหลัง ซึ่งสามารถวัดได้โดยใช้อัตราส่วนสัญญาณต่อสัญญาณรบกวน (SNR) (Signal-to-Noise Ratio หรือ SNR) ที่หาได้จากกำลังของสัญญาณที่ได้รับ ( $P_s$ ) ทหารด้วยกำลังของสัญญาณรบกวน ( $P_n$ ) ซึ่งคำนวณจากสมการที่ (2.5)

$$SNR = \frac{P_s}{P_n} \quad (2.5)$$

โดยที่  $P_s$  คือกำลังของสัญญาณที่ได้รับ (วัตต์)

$P_n$  คือกำลังของสัญญาณรบกวน (วัตต์)

SNR ที่มีค่าสูงกว่าหมายถึงความชัดเจนของสัญญาณที่สะท้อนกลับจากพลาสมาบับเบิลมีความเด่นชัดเมื่อเทียบกับระดับรบกวนของพื้นหลัง ทำให้สามารถระบุตำแหน่ง ความเร็ว หรือพลวัตของ EPB ได้อย่างแม่นยำยิ่งขึ้น ในทางปฏิบัติค่าของ  $SNR_{dB}$  มักแสดงในหน่วยเดซิเบล โดยสามารถคำนวณได้จากสมการที่ (2.6)

$$SNR_{dB} = 10 \log_{10} \left( \frac{P_s}{P_n} \right) \quad (2.6)$$

รูปภาพข้อมูลจากเรดาร์แบ่งได้เป็น 2 ประเภท คือ ภาพดูอย่างรวดเร็ว (Quick Look หรือ QL) และความเข้มของช่วงระดับความสูง-เวลา (Range-Altitude-Time Intensity หรือ RATI)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



1. ข้อมูลดิบอินพุต UD3 (UD3 Raw Data Input) แสดงตัวอย่างไฟล์ข้อมูลดังรูปที่ 2.10
  - รูปแบบไฟล์ raw.<sitename>.<timestamp> ชื่อไฟล์ประกอบด้วยชื่อไซต์ (Sitename) และ timestamp ของ UNIX epoch ในรูปแบบเลขฐานสิบหก (ยาว 8 อักขระ)
2. อ่านส่วนหัว (Read Header)
 

ส่วนหัวของไฟล์จะถูกอ่านเพื่อแยกข้อมูลเมตาที่สำคัญ:

  - ช่วง (Range) คือระยะทางที่ครอบคลุม
  - ความละเอียด (Resolution) คือระดับความละเอียดของข้อมูล
  - ช่วงเวลา (Interval) คือเวลาระหว่างการสุ่มตัวอย่าง
  - ความถี่การทำซ้ำของพัลส์ (Pulse Repetition Frequency หรือ PRF) คือความถี่ที่พัลส์เรดาร์ถูกปล่อยออกมา
  - การผสานรวม (Integrations) คือจำนวนสัญญาณที่ผสานรวม
  - เวลาเริ่มต้น (Start time) เมื่อการรวบรวมข้อมูลเริ่มต้นขึ้น
3. ตรวจสอบเวลาการรับข้อมูลและขนาดตัวอย่าง
  - ระยะเวลาการรับข้อมูลทั้งหมด
  - จำนวนจุดข้อมูล (ตัวอย่าง) ที่บันทึกไว้
4. คำนวณระยะต่ำสุดและสูงสุด (เป็นเมตร)
  - คำนวณระยะที่ใกล้และไกลที่สุดที่เรดาร์ครอบคลุมโดยอิงตามข้อมูลเมตา (Metadata)
5. ลบข้อมูลอาร์เรย์ 2 มิติ
  - ข้อมูลเรดาร์ดิบอยู่ในเมทริกซ์ 2 มิติที่มีขนาด  $M \times N$  (เช่น ช่องระยะ (Range bins)  $\times$  ช่องเวลา (Time bins) หรือช่องความถี่ (Frequency bins))
  - ตัวเลข 0 ทั้งหมดจะถูกแทนที่ด้วยตัวเลข "tiny" เล็ก ๆ เพื่อหลีกเลี่ยงปัญหา  $\log(0)$  ในการประมวลผลในภายหลัง (โดยเฉพาะอย่างยิ่งในระหว่างการปรับขนาดลอการิทึมหรือการแปลงเดซิเบล)
6. สร้างรายการลำแสงหรือ빔 (Beam)
  - แต่ละลำแสงถูกกำหนดโดยมุมราบ (Azimuth angles) และมุมเซนนิธ (Zenith angles) เป็นองศา รวมถึงข้อมูลความถี่ (Frequency) และความเข้มของเรดาร์ (Intensity data) ด้วย
7. ผลลัพธ์
 

การแสดงผลสองแบบในขั้นตอนสุดท้ายจะแสดงผลสองเส้นทางโดยใช้ Fd3 (น่าจะเป็นรูปแบบไฟล์/ข้อมูลสำหรับการสร้างกราฟ)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

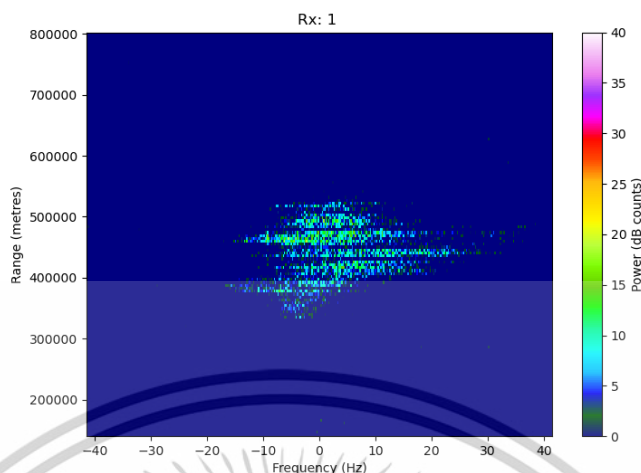
- กราฟกำลัง (Power Plot) โดยที่แกน X คือเวลา (วินาที) และแกน Y คือพิสัย (เมตร) รวมไปถึงสี/ความเข้ม (Color/Intensity) คือกำลังเรดาร์เป็นหน่วยเดซิเบล เพื่อแสดงให้เห็นว่าการส่งคืนเรดาร์เปลี่ยนแปลงไปอย่างไรเมื่อเวลาผ่านไป

- กราฟสเปกตรัม (Spectra Plot) ในแกน X คือความถี่ (เฮิรตซ์), แกน Y คือพิสัย (เมตร) และสี/ความเข้ม คือกำลังเรดาร์เป็นหน่วยเดซิเบล ใช้สำหรับการวิเคราะห์การเปลี่ยนแปลงดอปเปลอร์ (Doppler shifts) หรือพฤติกรรมโดเมนความถี่ (Frequency-domain)


ข้อมูลภาพทั้งสองแบบ (กำลังและสเปกตรัม) จะปรากฏบนเว็บไซต์ SEALION (<https://aer-nc-web.nict.go.jp/sealion/CPNVR/index.html>) ซึ่งผู้ใช้สามารถตรวจสอบข้อมูลเรดาร์ได้อย่างรวดเร็ว

จากรูปที่ 2.11 เมื่อค่าความเข้มของสัญญาณเรดาร์ (หรือกำลัง) ถูกพล็อตเทียบกับเวลาและระดับความสูง จะได้ภาพพล็อตที่แสดงมุมมองเชิงเวลาของการสะท้อนสัญญาณ ซึ่งสามารถนำมาใช้วิเคราะห์โครงสร้างของพลาสมาบับเบิลได้อย่างมีประสิทธิภาพ โดยทั่วไป ระยะทางระหว่างเสาอากาศเรดาร์และจุดที่เกิดการสะท้อนเรียกว่า “ช่วง (Range)” ซึ่งในทางปฏิบัติจะอ้างอิงถึงระดับความสูงของจุดสะท้อน แกนนอนของภาพพล็อตแสดงถึงเวลาที่ผ่านไปตั้งแต่ส่งพัลส์เรดาร์จนถึงการรับสัญญาณสะท้อน ขณะที่แกนตั้งแสดงถึงระดับความสูงที่สัญญาณสะท้อนกลับมาถึง ซึ่งสามารถแปลผลเป็นภาพลักษณ์ของความผิดปกติในชั้นบรรยากาศไอโอโนสเฟียร์ เช่น พลาสมาบับเบิล ภาพพล็อตในลักษณะนี้มักเรียกว่า “Quick Look Plot (QL Plot)” ซึ่งเป็นการแสดงข้อมูลแบบเรียลไทม์ที่รวบรวมจากเรดาร์ VHF โดยในพล็อตดังกล่าว แกน X แสดงความถี่ของสัญญาณ หรือเวลาในลักษณะของการสแกนต่อเนื่อง ส่วนแกน Y แสดงระดับความสูงของชั้นบรรยากาศที่ตรวจวัดได้ ข้อมูลภาพเรดาร์จะถูกรวบรวมในช่วงเวลาที่สม่ำเสมอทุก ๆ 2-3 นาที ทำให้สามารถติดตามการเปลี่ยนแปลงของพลาสมาบับเบิลในเชิงพลวัตได้อย่างแม่นยำ ทั้งนี้ การแปลความหมายของพล็อตในลักษณะนี้ต้องพิจารณาร่วมกับพารามิเตอร์ของระบบเรดาร์ เช่น ความละเอียดเชิงเวลา ความละเอียดเชิงระยะทาง และระดับของสัญญาณรบกวน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.11 ตัวอย่างข้อมูล (QL) ที่เกิดพลาสมาบับเบิลในวันที่ 13 เดือนกุมภาพันธ์ ค.ศ. 2020 เวลา 15.00 น.



รูปที่ 2.12 ตัวอย่างข้อมูล (RATI) ที่เกิดพลาสมาบับเบิลในวันที่ 13 เดือนกุมภาพันธ์ ค.ศ. 2020

เรดาร์ VHF มีความไวสูงต่อความผิดปกติขนาดเล็ก (Small-Scale Irregularities) ในชั้นบรรยากาศไอโอโนสเฟียร์ จึงเหมาะอย่างยิ่งสำหรับการศึกษาปรากฏการณ์ต่าง ๆ

## 2.4 ไอโอโนซอนด์

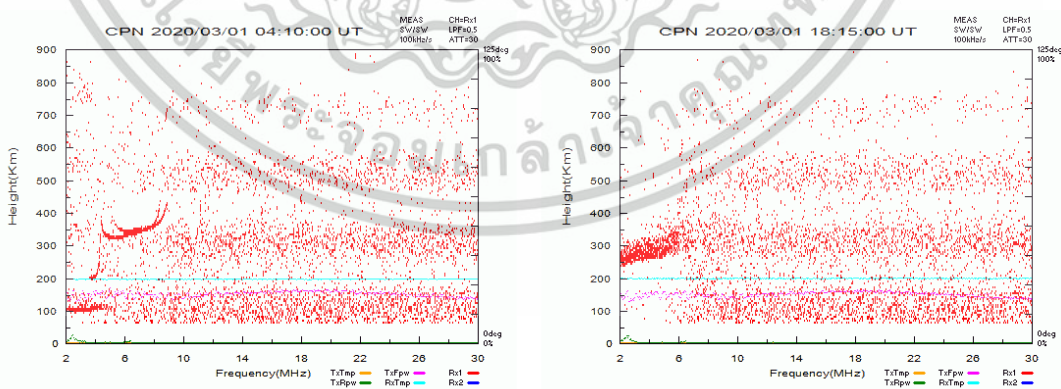
ไอโอซอนด์ (Ionosondes) เป็นอุปกรณ์ที่มีการทำงานคล้ายกับเรดาร์ และส่งพัลส์วิทยุเข้าไปในชั้นบรรยากาศไอโอโนสเฟียร์ จากนั้นจึงรับสัญญาณที่สะท้อนกลับมาเพื่อตรวจสอบความผิดปกติของชั้นบรรยากาศไอโอโนสเฟียร์ ความผิดปกติเหล่านี้ได้แก่ ชินทิลเลชัน พลาสมาบับเบิล และชั้น E ที่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เกิดขึ้นเป็นระยะ ๆ (Sporadic E) ไอโอโนแกรม (Ionograms) เกิดขึ้นจากไอโอโนซอนด์โดย กระบวนการกวาดผ่านความถี่ต่าง ๆ ไอโอโนแกรมเหล่านี้มีความสามารถในการแสดงภาพรวมของ โครงสร้างและโปรไฟล์ความหนาแน่นของอิเล็กตรอน (Electron Density Profiles) ของไอโอโนสเฟียร์ การวัดเหล่านี้ไม่เพียงแต่จำเป็นต่อการได้รับความรู้ถึงความผิดปกติของชั้นบรรยากาศไอโอโนสเฟียร์ส่งผลต่อการแพร่กระจายของคลื่นวิทยุ ระบบการสื่อสาร และสัญญาณ GNSS อย่างไร แต่ยัง จำเป็นต่อการตรวจสอบผลกระทบของสภาพอากาศในอวกาศต่อชั้นบรรยากาศด้านบนของโลกด้วย ตัวอย่างข้อมูลไอโอโนสเฟียร์แสดงอยู่ในรูปที่ 2.14 เรียกว่าข้อมูล "ไอโอโนแกรม"



รูปที่ 2.13 ระบบไอโอโนซอนด์ที่สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง วิทยาเขตชุมพร



(ก) เวลาสงบ

(ข) การแพร่กระจายชั้น F

รูปที่ 2.14 ข้อมูลไอโอโนแกรมจากไอโอโนซอนด์ที่มีการแพร่กระจาย F เกิดขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลักการของเครื่องตรวจวัดไอโอโนสเฟียร์ FMCW และ CADI ทำงานในลักษณะเดียวกันกับระบบเรดาร์ โดยระบบ FMCW ทำงานบนระบบแอนะล็อก ดังที่แสดงในตารางที่ 2.2 ช่วงความถี่การทำงานของไอโอโนซอนด์ FMCW อยู่ในแถบความถี่กลาง (Medium Frequency หรือ MF) – ความถี่สูง (High Frequency หรือ HF) ไอโอโนซอนด์ FMCW ให้ประโยชน์ที่โดดเด่นในการสังเกตการณ์แบบสองสถิต (bi-static observation) ด้วยตำแหน่งที่เพียงพอของเสาอากาศส่งและรับสัญญาณที่ติดตั้งแยกจากกันดังแสดงในรูปที่ 2.13 การสังเกตการณ์ไอโอโนซอนด์ FMCW ได้รับการควบคุมด้วยความถี่ที่เปลี่ยนแปลงเป็นเส้นตรง (2 เมกะเฮิร์ต – 30 เมกะเฮิร์ต โดยอัตราการกวาด (Sweep Rate) 9 ที่ 100 กิกะเฮิร์ตต่อวินาที) และเวลาบนเป้าหมายที่เคลื่อนที่ เสาอากาศและระบบ FMCW ที่สถานี CPN แสดงไว้ในรูปที่ 2.15 การสังเกตไอโอโนซอนด์ FMCW แสดงลำดับภาพไอโอโนแกรมที่มีปรากฏการณ์การแพร่กระจาย F ซึ่งกวาดขึ้นทุก ๆ 20 นาที สำหรับ 3 เมกะเฮิร์ต – 9 เมกะเฮิร์ต ดังแสดงในรูปที่ 2.15 ความสัมพันธ์ของความถี่และเวลาจะดำเนินการกับสัญญาณที่ส่งและสัญญาณที่ได้รับ ความถี่ (Frequency)  $f_b$  ที่ต่างกันจะได้มาจากสัญญาณส่งและรับสัญญาณที่อยู่ในช่วง (Range) ของเป้าหมายที่เคลื่อนที่  $r$  และความเร็วของการมองเห็นแนวสายตา (Line of sight velocity)  $v$  ตามสมการที่ (2.7)

การสังเกตการณ์ชั้นบรรยากาศไอโอโนสเฟียร์ด้วยระบบ Frequency Modulated Continuous Wave (FMCW) Ionosonde เป็นเทคนิคที่ใช้คลื่นความถี่วิทยุซึ่งมีความถี่เปลี่ยนแปลงอย่างต่อเนื่องเป็นเส้นตรง (linear frequency sweep) ในช่วงความถี่ 2 เมกะเฮิร์ต ถึง 30 เมกะเฮิร์ต โดยมีอัตราการกวาดความถี่ (Sweep Rate) ที่ 100 กิกะเฮิร์ตต่อวินาที เพื่อสร้างภาพไอโอโนแกรม (ionogram) ซึ่งแสดงผลสะท้อนของคลื่นจากชั้นไอโอโนสเฟียร์ในช่วงความถี่ต่าง ๆ การทดลองในวิจัยนี้ใช้ระบบ FMCW ที่ติดตั้ง ณ สถานีชุมพร (Chumphon Station หรือ CPN) โดยมีการแสดงรายละเอียดของเสาอากาศและระบบทั้งหมดไว้ในรูปที่ 2.15 ภาพไอโอโนแกรมถูกกวาดขึ้นทุก ๆ 20 นาที ในช่วงความถี่ระหว่าง 3–9 เมกะเฮิร์ต เพื่อสังเกตปรากฏการณ์การแพร่กระจายคลื่นในชั้น F ของชั้นไอโอโนสเฟียร์ ซึ่งมักเกี่ยวข้องกับพลาสมาบับเบิลและความไม่สม่ำเสมอของพลาสมาในแนวตั้ง ความถี่ที่ได้รับหลังการสะท้อนจะมีความแตกต่างจากความถี่ส่งเดิม เนื่องจากการเคลื่อนที่ของเป้าหมาย (หรือความไม่สม่ำเสมอของพลาสมา) ในแนวสายตา ซึ่งทำให้เกิดความถี่เบี่ยงเบน (Beat Frequency หรือ  $f_b$ ) ที่สามารถนำมาใช้คำนวณระยะทาง ( $r$ ) หรือความเร็วเชิงเส้นในแนวสายตา ( $v$ ) ได้ โดยความสัมพันธ์นี้สามารถแสดงได้ด้วยสมการที่ (2.7)

$$f_b(r, v) = \frac{2}{c}(r \cdot f - v \cdot f_0) \quad (2.7)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$r = r_0 + v \cdot t \quad (2.8)$$

โดยที่  $f_b$  คือความถี่เบี่ยงเบน (Beat Frequency) (เฮิร์ต)


$v$  คือความเร็วของเป้าหมายในแนวสายตา (Line-of-sight velocity) (เมตรต่อวินาที)

$c$  คือความเร็วแสงในสุญญากาศ (Velocity of light) ( $\approx 3 \times 10^8$  เมตรต่อวินาที)

$f'$  คืออัตราการกวาดความถี่ (Frequency sweep rate) (100 กิโลเฮิร์ตซ์/วินาที)

$f_0$  คือความถี่เริ่มต้น (Initial Frequency)

ทั้งสองเทอมในวงเล็บของสมการที่ (2.7) แสดงถึงการเลื่อนความถี่ (Frequency shift) เนื่องจากช่วงและการเลื่อนดอปเปลอร์ (Doppler Shift) สมการนี้อยู่ภายใต้เงื่อนไขของ  $v \ll c$  เวลาที่สะท้อนจากเป้าหมายเคลื่อนที่แสดงด้วย  $t$  ระยะเริ่มต้นที่เป้าหมายเคลื่อนที่จะแสดงด้วย  $r_0$




รูปที่ 2.15 ระบบเรดาร์ FMCW พร้อมความสัมพันธ์ความถี่และเวลา [3]

ไอโอโนแกรม (Ionogram) เป็นภาพพล็อตจากการวัดคลื่นวิทยุความถี่สูง (HF) ที่สะท้อนกลับจากชั้นไอโอโนสเฟียร์ โดยสร้างขึ้นจากอุปกรณ์ที่เรียกว่าไอโอโนซอนด์ (Ionosonde) ซึ่งทำงานโดยการส่งพัลส์ของคลื่นวิทยุในแนวตั้ง และบันทึกสัญญาณสะท้อนกลับในช่วงเวลาต่าง ๆ เพื่อวิเคราะห์คุณสมบัติของบรรยากาศในแนวตั้ง ไอโอโนแกรมโดยทั่วไปมีช่วงความถี่ตั้งแต่ 1–20 เมกะเฮิร์ต และแสดงระดับความสูงเสมือน (Virtual Height) ที่ได้จากการคำนวณเวลาหน่วงของคลื่นสะท้อน การสะท้อนของสัญญาณปรากฏเป็นร่องรอย (Traces) บนไอโอโนแกรม ซึ่งจำแนกได้เป็นร่องรอยแบบธรรมดา (Ordinary) และแบบพิเศษ (Extraordinary) ความสูงเสมือนที่แสดงมิใช่ความสูงจริง แต่ใช้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในการเปรียบเทียบโครงสร้างของชั้นบรรยากาศได้อย่างมีประสิทธิภาพ ขณะที่ความถี่ที่สูงที่สุดซึ่งยังสามารถสะท้อนกลับจากชั้นไอโอโนสเฟียร์ได้จะเรียกว่า ความถี่วิกฤต (Critical Frequency) ซึ่งเป็นค่าที่ใช้ระบุขอบเขตความสามารถในการสะท้อนของแต่ละชั้น



รูปที่ 2.16 ไอโอโนซอนด์ [3]

จากรูปที่ 2.16 แสดงหลักการทำงานของระบบไอโอโนซอนด์ ซึ่งทำหน้าที่ส่งคลื่นวิทยุขึ้นไปยังชั้นบรรยากาศไอโอโนสเฟียร์ และตรวจวัดสัญญาณสะท้อนกลับเพื่อนำมาคำนวณความสูงของชั้นบรรยากาศที่สะท้อนสัญญาณ โดยอาศัยการหน่วงเวลาระหว่างการส่งและการรับสัญญาณ และความเร็วของคลื่นวิทยุที่ทราบแน่นอน หนึ่งในปรากฏการณ์สำคัญที่ตรวจพบได้จากข้อมูลไอโอโนแกรม คือปรากฏการณ์ Equatorial Spread F (ESF) ซึ่งเกิดจากความไม่เสถียรของพลาสมาในชั้น F ของไอโอโนสเฟียร์ โดยเฉพาะบริเวณเส้นศูนย์สูตรแม่เหล็กโลกในช่วงเวลากลางคืน ลักษณะเฉพาะของ ESF คือความไม่สม่ำเสมอของความหนาแน่นพลาสมา ซึ่งส่งผลกระทบต่อ การแพร่กระจายของคลื่นวิทยุ รวมถึงสัญญาณจากระบบ GNSS และการสื่อสารด้วยคลื่น HF โดยสามารถสังเกตการเกิด ESF ได้จากรูปแบบการกระจายของสัญญาณสะท้อนในไอโอโนแกรมที่ผิดปกติไปจากสภาพปกติ ปรากฏการณ์ ESF สามารถจำแนกออกเป็น 4 ประเภทหลักตามลักษณะของการกระจายบนไอโอโนแกรม ได้แก่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- Frequency Spread-F (FSF) – แสดงการกระจายของคลื่นสะท้อนตามแกนความถี่
- Range Spread-F (RSF) – แสดงการกระจายของคลื่นสะท้อนตามแกนระยะความสูง
- Mixed Spread-F (MSF) – เป็นการรวมกันของการกระจายทั้งในแกนความถี่และความสูง
- Branch Spread-F (BSF) – แสดงการกระจายของร่องรอยคลื่นสะท้อนในลักษณะหลายแขนง

## 2.5 การเรียนรู้ของเครื่อง

ในยุคที่เทคโนโลยีสารสนเทศและปัญญาประดิษฐ์มีการพัฒนาอย่างรวดเร็ว การประมวลผลข้อมูลขนาดใหญ่และซับซ้อนเพื่อให้เกิดการเรียนรู้และการตัดสินใจอย่างชาญฉลาดจึงกลายเป็นหัวใจสำคัญของระบบคอมพิวเตอร์สมัยใหม่ หนึ่งในเครื่องมือที่มีบทบาทสำคัญในการดำเนินการดังกล่าวคือ โครงข่ายประสาทเทียม (Artificial Neural Networks หรือ ANN) ซึ่งเป็นแบบจำลองทางคณิตศาสตร์ที่ได้รับแรงบันดาลใจจากโครงสร้างและหน้าที่การทำงานของระบบประสาทในสมองมนุษย์

โครงข่ายประสาทเทียมถูกออกแบบให้สามารถเลียนแบบกระบวนการเรียนรู้ การประมวลผลข้อมูล และการตัดสินใจ โดยมีหน่วยพื้นฐานที่เรียกว่า นิวรอน (Neuron) ซึ่งทำหน้าที่คล้ายเซลล์ประสาทจริงในร่างกายมนุษย์ โดยมีส่วนประกอบที่สำคัญ ได้แก่ เดนไดรต์ (Dendrite) สำหรับรับข้อมูลนำเข้า, นิวรอนสำหรับประมวลผลข้อมูล, แอกซอน (Axon) สำหรับส่งผลลัพธ์ออก และไซแนปส์ (Synapse) ซึ่งทำหน้าที่เป็นจุดเชื่อมต่อในการถ่ายทอดสัญญาณระหว่างนิวรอน

การทำงานของโครงข่ายประสาทเทียมเริ่มต้นจากการรับข้อมูลนำเข้าผ่านเดนไดรต์ จากนั้นระบบจะทำการคำนวณค่ารวมแบบถ่วงน้ำหนักและประมวลผลด้วยฟังก์ชันกระตุ้น (Activation Function) หากค่าผลลัพธ์ผ่านเกณฑ์ที่กำหนด สัญญาณจะถูกส่งต่อไปยังนิวรอนถัดไป กระบวนการเรียนรู้ของระบบเกิดจากการปรับค่าน้ำหนักของไซแนปส์อย่างต่อเนื่องตามข้อมูลที่ได้รับ ซึ่งช่วยให้ระบบสามารถเรียนรู้รูปแบบของข้อมูลและปรับตัวได้อย่างมีประสิทธิภาพ

จากคุณลักษณะดังกล่าว โครงข่ายประสาทเทียมจึงถูกนำมาใช้ในหลากหลายสาขา เช่น การรู้จำภาพ การวิเคราะห์เสียงพูด การพยากรณ์ข้อมูล และการจำแนกประเภท ซึ่งล้วนแต่มีเป้าหมายเพื่อเพิ่มศักยภาพในการตัดสินใจของระบบคอมพิวเตอร์ให้ใกล้เคียงกับความสามารถของมนุษย์มากยิ่งขึ้น

ANN มีความสามารถในการเรียนรู้จากข้อมูลผ่านการปรับค่าพารามิเตอร์ที่เรียกว่า "ค่าน้ำหนัก" (Weight) ซึ่งเป็นตัวแทนของความรู้ที่สั่งสมไว้ในระบบ ยิ่งระบบได้รับข้อมูลมากและผ่านการเรียนรู้


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หลายรอบ ความแม่นยำในการวิเคราะห์และตัดสินใจจะยิ่งสูงขึ้น องค์ประกอบหลักของโครงข่ายประสาทเทียมสามารถแบ่งออกได้เป็น 5 ส่วนสำคัญ ได้แก่

- ข้อมูลนำเข้า (Input) คือตัวแปรต้นที่ถูกป้อนเข้าสู่โครงข่าย ซึ่งอาจต้องแปลงให้อยู่ในรูปแบบที่เหมาะสมต่อการประมวลผล เช่น การเข้ารหัสหรือปรับสเกล
- ค่าน้ำหนัก (Weight) คือพารามิเตอร์ที่สะท้อนความสัมพันธ์ระหว่างโหนด และเป็นหัวใจหลักของกระบวนการเรียนรู้ โดยมีการปรับเปลี่ยนค่าเมื่อเกิดการเรียนรู้ใหม่
- ข้อมูลส่งออก (Output) คือผลลัพธ์สุดท้ายที่ได้จากกระบวนการประมวลผลภายในโครงข่าย ซึ่งสามารถนำไปใช้ในการจำแนกหรือทำนาย
- ฟังก์ชันการรวม (Summation Function) ทำหน้าที่รวมค่าข้อมูลนำเข้าที่ถ่วงด้วยค่าน้ำหนัก เพื่อเตรียมเข้าสู่ขั้นตอนการกระตุ้น
- ฟังก์ชันกระตุ้น (Activation Function) ทำหน้าที่เปลี่ยนผลรวมถ่วงน้ำหนักให้เป็นผลลัพธ์ที่มีความหมาย โดยฟังก์ชันที่นิยมใช้ เช่น Sigmoid, Tanh และ ReLU

### 2.5.1 โครงข่ายประสาทเทียมแบบคอนโวลูชัน

ในปี ค.ศ. 1990 LeCun et al. [21] ได้เสนอการผสมผสานกระบวนการคำนวณแบบคอนโวลูชันเข้ากับโครงข่ายประสาทเทียม เพื่อใช้ในการสกัดคุณลักษณะเด่นจากภาพ โดยผลลัพธ์ที่ได้จากการคำนวณนี้จะอยู่ในรูปของ แผนที่คุณลักษณะ (Feature Map) ซึ่งเป็นตัวแทนของคุณลักษณะเด่นในแต่ละพื้นที่ของภาพ ต่อมาในปี ค.ศ. 1998 LeCun และคณะ [22] ได้พัฒนาโครงข่ายประสาทเทียมแบบคอนโวลูชันที่มีชื่อว่า LeNet-5 ซึ่งมีการเพิ่มชั้นที่เรียกว่า Fully Connected Layer (FC) เข้ามาในโครงสร้าง โดยชั้นนี้ทำหน้าที่เชื่อมต่อคุณลักษณะที่สกัดได้เข้ากับกระบวนการตัดสินใจของระบบ เหมือนกับชั้นของโครงข่ายประสาทเทียมแบบหลายชั้นทั่วไป โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network หรือ CNN) จึงสามารถทำหน้าที่ได้ทั้งในการ สกัดคุณลักษณะเด่น (Feature Extraction) และจำแนกประเภท (Classification)



รูปที่ 2.17 แบบจำลองของโครงข่ายประสาทเทียมแบบคอนโวลูชัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 2.17 เป็นแบบจำลองโครงข่ายประสาทเทียมแบบคอนโวลูชัน มีชั้นที่สำคัญ 3 ชั้น ได้แก่

### 2.5.1.1 ชั้นคอนโวลูชัน (Convolutional Layer)

ชั้นคอนโวลูชันเป็นองค์ประกอบพื้นฐานของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ที่มีหน้าที่สกัดคุณลักษณะสำคัญจากข้อมูลภาพอินพุต โดยใช้ตัวกรอง (Filter หรือ Kernel) ขนาดเล็ก เช่น  $3 \times 3$  หรือ  $5 \times 5$  พิกเซล ทำการเลื่อนผ่านภาพในลักษณะของการคอนโวลูชัน (Convolution) เพื่อดึงลักษณะเฉพาะ เช่น ขอบเส้น การไล่ระดับสี และ รูปร่างพื้นฐาน ออกมาในรูปของแผนที่คุณลักษณะ (Feature Map หรือ  $G$ ) การคำนวณภายในชั้นนี้จะดำเนินการโดยการหาผลคูณเชิงสเกลาร์ระหว่างค่าพิกเซล ( $h$ ) ในพื้นที่ย่อยของภาพ (Sub-region) กับค่าน้ำหนักในคอร์เนล ( $F$ ) จากนั้นนำผลรวมเหล่านี้มาจัดเรียงเป็นค่าของแต่ละตำแหน่งในแผนที่คุณลักษณะ โดยสามารถแสดงการดำเนินการในรูปสมการทางคณิตศาสตร์ได้ดังสมการที่ (2.9)

$$G = h * F \quad (2.9)$$

โดยที่  $G$  คือแผนที่คุณลักษณะที่ได้จากการคอนโวลูชันของภาพต้นฉบับ  $F$  กับคอร์เนล  $F$  และสามารถแจกแจงเป็นนิพจน์แบบไม่ต่อเนื่องได้ดังนี้

$$G[i, j] = \sum_{u=-k}^k \sum_{v=-k}^k h[u, v] F[i - u, j - v] \quad (2.10)$$


สมการที่ (2.10) แสดงถึงการรวมผลคูณของค่าพิกเซลในภาพกับค่าของคอร์เนลในพื้นที่ขนาด  $(2k + 1) \times (2k + 1)$  รอบตำแหน่ง  $(i, j)$  เพื่อให้ได้ค่าผลลัพธ์ใหม่ในแผนที่คุณลักษณะ  $G[i, j]$  ซึ่งชั้นคอนโวลูชันนี้จะเป็พื้นฐานในการแยกแยะข้อมูลจากภาพอย่างมีประสิทธิภาพสำหรับการเรียนรู้ในขั้นต่อไป

Subregion					Kernel						
1	1	1	0	0	1	0	1	=	4		
0	1	1	1	0	0	1	0	*			
0	0	1	1	1	1	0	1				
0	0	1	1	0							
0	1	1	0	0							


รูปที่ 2.18 ตัวอย่างวิธีการคอนโวลูชัน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


1) การก้าว (Stride) เป็นตัวกำหนดว่าจะเลื่อนตัวกรอง (Filter) ไปด้วยสเตป (Step) เท่าไร จากรูปที่ 2.19 จะแสดงตัวอย่างในการกำหนดการก้าวเท่ากับ 1



(ก) สเตปการก้าวที่ 1



(ข) สเตปการก้าวที่ 2




(ค) สเตปการก้าวที่ 3

รูปที่ 2.19 ตัวอย่างการก้าวของตัวกรอง

2) การขยาย (Padding) เป็นการเพิ่มพื้นที่รอบ ๆ อินพุต ซึ่งพื้นที่เหล่านี้เป็นพื้นที่ที่มักจะเติมเข้าไป โดยอาจจะเป็นการเติม 0 หรือค่าต่าง ๆ เพื่อให้แผนผังคุณลักษณะจากการทำงานของโครงข่ายประสาทเทียมแบบคอนโวลูชันที่ได้ยังคงมีขนาดเท่ากับอินพุต ในบางอินพุตตามขอบของข้อมูลอาจมีความสำคัญที่ส่งผลต่อการตัดสินใจบางอย่าง จึงจำเป็นต้องเก็บลักษณะตามขอบของข้อมูลไว้ด้วย ตัวอย่างการขยายพื้นที่รอบอินพุตแสดงดังรูปที่ 2.20 โดยส่วนบริเวณขอบสีขาวในรูปคือพื้นที่ที่ถูกเพิ่มเข้ามา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.20 ตัวอย่างการขยายพื้นที่รอบอินพุต

### 2.5.1.2 ชั้นพูลลิ่ง (Pooling Layer)

ชั้นพูลลิ่ง (Pooling Layer) เป็นส่วนประกอบสำคัญของโครงข่ายคอนโวลูชันแนลนิวรัลเน็ตเวิร์ก (CNN) โดยทำหน้าที่ลดขนาดของแผนผังคุณลักษณะ (Feature Map) ผ่านกระบวนการ Downsampling ซึ่งช่วยลดจำนวนพารามิเตอร์และภาระในการประมวลผล ทั้งยังคงรักษาคุณลักษณะที่สำคัญของข้อมูลเอาไว้ ชั้นพูลลิ่งยังมีบทบาทในการเพิ่มความไม่แปรผันต่อการหมุนและการเลื่อนตำแหน่งภายในภาพ ส่งผลให้โมเดลมีความสามารถในการทำนายที่เสถียรและแม่นยำยิ่งขึ้น โดยทั่วไป แผนผังคุณลักษณะจะถูกแบ่งออกเป็นพื้นที่ย่อยก่อนนำเข้าสู่กระบวนการพูลลิ่ง ซึ่งรูปแบบที่นิยมใช้งานคือ


1) การพูลลิ่งแบบเลือกค่าสูงสุด (Max Pooling) ซึ่งทำการเลือกค่ามากที่สุดในแต่ละพื้นที่ย่อย ผลลัพธ์ที่ได้คือเมทริกซ์ใหม่ที่เล็กลงแต่ยังคงลักษณะเด่นของข้อมูลไว้ โดยมีข้อดีสองประการหลักคือ (1) ช่วยลดจำนวนพารามิเตอร์และเวลาในการคำนวณ และ (2) รักษาคุณลักษณะที่สำคัญผ่านพิกเซลที่มีค่าสูงสุดในแต่ละบริเวณ ตัวอย่างแสดงดังรูปที่ 2.21 - รูปที่ 2.23

12	25	40	0	Max Pooling →	25	40
6	12	1	0		115	35
35	75	35	2			
115	25	20	10			

รูปที่ 2.21 วิธีการพูลลิ่งแบบเลือกค่าสูงสุด


2) การพูลลิ่งแบบใช้ค่าเฉลี่ย (Average Pooling) จะเป็นการเลื่อนหน้าต่างเพื่อคำนวณค่าเฉลี่ยของแต่ละบล็อกของแผนผังคุณลักษณะ แสดงตัวอย่างดังรูปที่ 2.22

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.22 วิธีการพูลลิ่งแบบเลือกค่าเฉลี่ย

3) การพูลลิ่งแบบเลือกค่าต่ำสุด (Min Pooling) จะเป็นการเลื่อนหน้าต่างเพื่อหาค่าที่ต่ำหรือค่าที่น้อยที่สุดของแต่ละบล็อกของแผนที่คุณลักษณะแสดงตัวอย่างดังรูปที่ 2.23



รูปที่ 2.23 วิธีการพูลลิ่งแบบเลือกค่าต่ำสุด


### 2.5.1.3 ชั้นเชื่อมโยงแบบสมบูรณ์ (Fully Connected Layer)

ในกระบวนการของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ชั้นเชื่อมต่อแบบสมบูรณ์ (Fully Connected Layer) ทำหน้าที่เป็นตัวเชื่อมระหว่างแผนผังคุณลักษณะ (Feature Map) ที่ได้จากชั้นคอนโวลูชันและชั้นพูลลิ่ง กับผลลัพธ์สุดท้ายของโมเดล โดยจะเริ่มจากการแปลงข้อมูลในแผนผังคุณลักษณะให้กลายเป็นเวกเตอร์หนึ่งมิติ (Flatten) ซึ่งเป็นการจัดเรียงข้อมูลใหม่จากหลายแถวหลายคอลัมน์ให้กลายเป็นคอลัมน์เดียว เพื่อให้อยู่ในรูปที่เหมาะสมสำหรับการประมวลผลในขั้นถัดไป จากนั้น ข้อมูลเวกเตอร์ที่ได้จะถูกส่งเข้าสู่ ชั้นซ่อน (Hidden Layer) ซึ่งในแต่ละนิวรอนจะรับอินพุตที่คูณกับค่าน้ำหนัก (Weight) และอาจรวมกับค่าไบแอส (Bias) ก่อนที่จะนำผลลัพธ์ผ่านฟังก์ชันการกระตุ้น (Activation Function) เพื่อสร้างค่าเอาต์พุตของแต่ละนิวรอนตามสมการที่ (2.11) จำนวนชั้นซ่อนสามารถกำหนดได้ตามความเหมาะสมของปัญหาหรือรูปแบบข้อมูล และจากชั้นซ่อนสุดท้าย จะได้ผลลัพธ์เข้าสู่ ชั้นเอาต์พุต (Output Layer) ซึ่งค่าที่ได้จากนิวรอนในชั้นนี้จะถูกแทนลงในฟังก์ชันซอฟต์แวร์แมกซ์ (Softmax Function) เพื่อแปลงให้อยู่ในรูปของค่าความน่าจะเป็นสำหรับการจำแนกประเภทของเอาต์พุตชั้นสุดท้าย ( $S$ ) เราจะนำค่าข้อมูลของอินพุตแต่ละนิวรอน ( $p_i$ ) คูณกับค่าน้ำหนักของแต่ละนิวรอน ( $w_i$ ) การคำนวณแสดงดังสมการที่ (2.11)

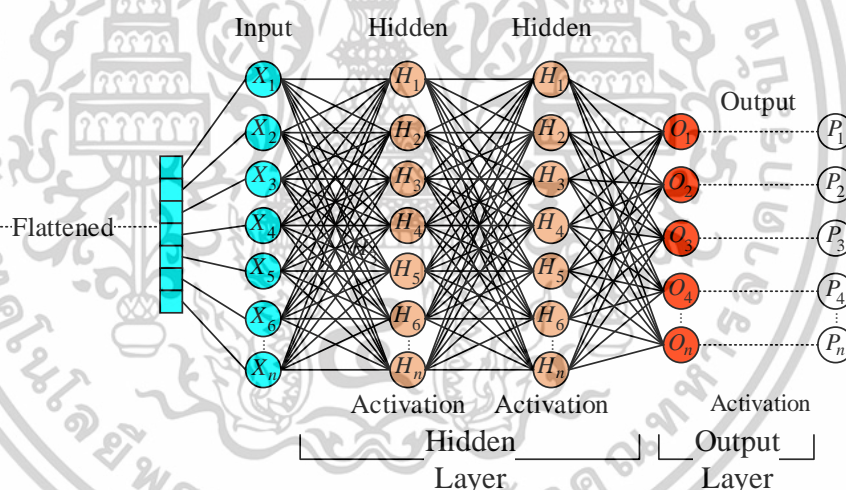
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$S = \sum_{i=1}^n p_i w_i \quad (2.11)$$

โดยที่  $p_i$  คือข้อมูลอินพุต  
 $w_i$  คือค่าน้ำหนัก



รูปที่ 2.24 การเปลี่ยนรูปของข้อมูลหรือ Flatten



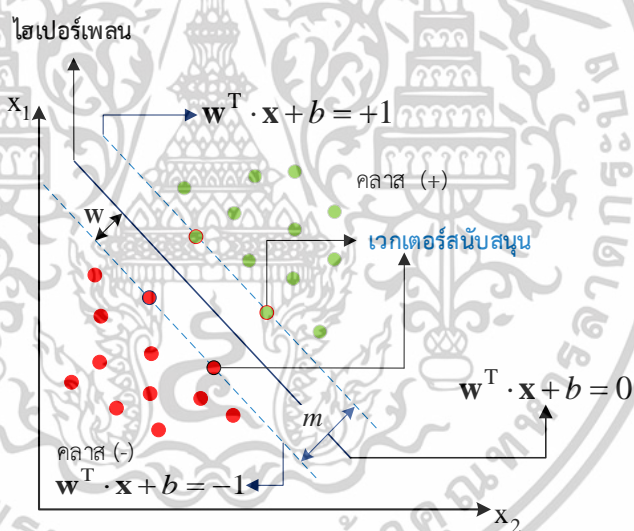
รูปที่ 2.25 ชั้นเชื่อมโยงแบบสมบูรณ์

## 2.5.2 ซัพพอร์ตเวกเตอร์แมชชีน

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) พัฒนาขึ้นครั้งแรกโดย Vapnik และ Lerner ในปี 1992 [23] ซึ่งเป็นโมเดลเชิงเส้นสำหรับการจำแนกประเภทและการถดถอยที่ใช้ทฤษฎีการเรียนรู้ของเครื่องเพื่อเพิ่มความแม่นยำในการทำนาย ให้สามารถแก้ปัญหาได้ทั้งแบบเชิงเส้นและไม่เชิงเส้น โดยทั่วไป SVM จะถูกแบ่งออกเป็นสองประเภท คือ Support Vector Classification (SVC) และการถดถอยของเวกเตอร์สนับสนุน (Support Vector Regression หรือ SVR) อัลกอริทึม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

การเรียนรู้ของเครื่องที่มีการควบคุมดูแล (Supervised Machine Learning) ซึ่งใช้สำหรับงานการจำแนกประเภทเป็นหลัก วัตถุประสงค์หลักคือค้นหาไฮเปอร์เพลนที่เหมาะสมที่สุด (Optimal Hyperplane) ที่แยกจุดข้อมูลของคลาสต่าง ๆ ด้วยระยะขอบ (Margin) สูงสุดที่เป็นไปได้ ซัพพอร์ตเวกเตอร์แมชชีนมีแนวคิดหลัก 3 แนวคิด คือไฮเปอร์เพลน (Hyperplane) ในปริภูมิ  $n$  มิติ ไฮเปอร์เพลนคือปริภูมีย่อยแบบแบนที่มีมิติ  $(n - 1)$  ที่แบ่งปริภูมิออกเป็นปริภูมิครึ่งหนึ่งสองปริภูมิ (Two Half-Spaces) สำหรับชุดข้อมูลสองมิติ ไฮเปอร์เพลนคือเส้นตรง สำหรับชุดข้อมูลสามมิติ ไฮเปอร์เพลนคือ ระนาบ (Plane) และระยะขอบ (Margin) คือระยะห่างระหว่างไฮเปอร์เพลนและจุดข้อมูลที่ใกล้ที่สุดจากคลาสใดคลาสหนึ่ง SVM มุ่งหวังที่จะเพิ่มระยะขอบนี้ให้สูงสุดเพื่อให้แน่ใจว่าแบบจำลองสามารถสรุปผลได้ดีกับข้อมูลที่ยังมองไม่เห็น ในส่วนของเวกเตอร์สนับสนุน (Support Vectors) คือจุดข้อมูลที่อยู่ใกล้กับไฮเปอร์เพลนมากที่สุด และกำหนดตำแหน่งและทิศทางของไฮเปอร์เพลนซึ่งมีความสำคัญในการสร้างไฮเปอร์เพลนที่เหมาะสมที่สุด



รูปที่ 2.26 ระยะขอบของคลาสและไฮเปอร์เพลนที่ใช้ในการจัดประเภทข้อมูลของสองคลาสเวกเตอร์สนับสนุนที่ใช้เพื่อให้มีระยะขอบสูงสุดจากแต่ละคลาสของข้อมูล

#### 2.5.2.1 กรณีแยกเป็นเส้นตรง (Hard Margin)

ซัพพอร์ตเวกเตอร์แมชชีนที่ใช้สำหรับการจำแนกประเภทเรียกว่า SVC (Support Vector Classification) โดยมีวัตถุประสงค์หลักในการค้นหา ฟังก์ชันการตัดสินใจ (Decision Function) ที่สามารถแบ่งแยกข้อมูลออกเป็นคลาสต่าง ๆ ได้อย่างมีประสิทธิภาพ พร้อมทั้งมีความสามารถในการสรุปทั่วไป (Generalization) ที่ดีในขั้นตอนการทดสอบ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับกรณีการจำแนกข้อมูลสองคลาส SVC จะพยายามหาขอบเขตการจำแนกที่เหมาะสมที่สุดในรูปของเส้นตรงหรือระนาบ ซึ่งเรียกว่า ไฮเปอร์เพลนที่เหมาะสม (Optimal Hyperplane) โดยเป็นเส้นที่สามารถแบ่งกลุ่มข้อมูลออกเป็นสองคลาสอย่างชัดเจน พร้อมทั้งมีระยะห่าง (Margin) ระหว่างเส้นกับจุดข้อมูลของแต่ละคลาสมากที่สุด ซึ่งช่วยให้การจำแนกมีความแม่นยำและต้านทานต่อข้อมูลรบกวน (Noise) ได้ดี [24] สำหรับชุดข้อมูลฝึกอบรม  $x_i$  ( $i = 1, 2, 3, \dots, n$ ) สามารถนิยามได้ด้วยสมการที่ (2.12) ซึ่งเส้นนี้ทำหน้าที่เป็นเส้นแบ่งข้อมูลระหว่างสองคลาส ดังที่แสดงในรูปที่ 2.26 เส้นตรงนี้ซึ่งเรียกอีกอย่างหนึ่งว่า ไฮเปอร์เพลนเชิงเส้น ค่าเวกเตอร์ของค่าน้ำหนัก ( $w$ ) (weight vector) มีมิติเท่ากับจำนวนพีเจอร์ของข้อมูลถูกคูณเชิงดอท (Dot product) ด้วยชุดข้อมูลฝึกอบรม ( $x$ ) ซึ่งจะใช้ในการกำหนดทิศทางของไฮเปอร์เพลน การคำนวณแสดงดังสมการที่ (2.12)

$$w^T x + b = 0 \quad (2.12)$$

โดยที่  $w$  คือเวกเตอร์น้ำหนักขนาด  $n$  มิติ

$b$  คือค่าไบอัส

ไฮเปอร์เพลนที่เหมาะสมต้องมีคุณสมบัติสำคัญสองประการ คือ การลดข้อผิดพลาดในการจำแนกข้อมูลให้น้อยที่สุด และการเพิ่มระยะห่าง (Margin) จากข้อมูลตัวอย่างที่ใกล้ไฮเปอร์เพลนของแต่ละคลาสให้สูงสุด ภายใต้เงื่อนไขนี้ ข้อมูลแต่ละจุดจะถูกจัดให้อยู่ฝั่งใดฝั่งหนึ่งของไฮเปอร์เพลนเท่านั้น โดยฝั่งหนึ่งแทนคลาส  $y = 1$  และอีกฝั่งแทนคลาส  $y = -1$  ซึ่งระยะขอบทั้งสองด้านนี้ถูกกำหนดขึ้นเพื่อควบคุมการแยกข้อมูลให้ชัดเจนและแม่นยำมากขึ้น ดังที่แสดงในรูปที่ 2.26

$$w^T x + b \begin{cases} \geq 1 & \text{for } y_i = 1 \\ \leq -1 & \text{for } y_i = -1 \end{cases} \quad (2.13)$$

โดยที่  $w$  คือเวกเตอร์น้ำหนักขนาด  $n$  มิติ

$x$  คือเวกเตอร์ของข้อมูลอินพุต (Input vector)

$b$  คือค่าไบอัส (Bias) หรือค่าคงที่ที่ใช้ในการเลื่อนไฮเปอร์เพลน

$y_i$  คือป้ายกำกับหรือคลาสของข้อมูล

อย่างไรก็ตาม ขอบเขตทั่วไปสำหรับไฮเปอร์เพลนอาจอยู่ที่ใดก็ได้ระหว่าง 1 ถึง -1 และมีระยะขอบมากมายที่สามารถถือเป็นขอบเขตของแต่ละคลาสได้

ดังนั้นเพื่อให้สามารถกำหนดไฮเปอร์เพลนที่เหมาะสมที่สุด (Optimal Hyperplane) สำหรับการจำแนกข้อมูลได้อย่างมีประสิทธิภาพ ควรพิจารณาการเพิ่มระยะห่างระหว่างข้อมูลของแต่ละคลาสกับไฮเปอร์เพลนให้มากที่สุด ซึ่งระยะห่างดังกล่าวเรียกว่า Margin โดยคำนวณได้จากสมการของระยะห่าง ( $d$ ) ซึ่งหาได้จากการหาค่าของเวกเตอร์น้ำหนักของไฮเปอร์เพลนจากทั้งคลาส ( $w$ ) และหารด้วยค่าความยาวของเวกเตอร์น้ำหนัก ( $\|w\|$ ) ซึ่งคำนวณได้จาก  $\sqrt{w_1^2 + w_2^2 + \dots + w_n^2}$  สมการในการคำนวณหาได้จาก (2.14)

$$d(w, b; x) = \frac{|(w^T x + b - 1) - (w^T x + b + 1)|}{\|w\|} = \frac{2}{\|w\|} \quad (2.14)$$

เมื่อ  $w$  คือเวกเตอร์น้ำหนักของไฮเปอร์เพลน  
 $\|w\|$  คือค่าความยาวของเวกเตอร์น้ำหนัก (Norm)

ดังนั้นการเพิ่มระยะขอบสูงสุดจะเท่ากับการลดเวกเตอร์มิติ  $w$  ซึ่งสามารถเขียนเป็น  $\frac{1}{2} w^T w$  ได้เช่นกัน ปัญหาความนูน (Convex Problem) ทัวไปในการกำหนดไฮเปอร์เพลนที่เหมาะสมที่สุดจะได้รับการกล่าวถึงดังสมการที่ (2.15) โดยมีเงื่อนไขว่าค่าฉลากของข้อมูลตัวอย่างที่  $y_i$  ต้องมากกว่าหรือเท่ากับ 1

$$\begin{aligned} \text{Max}_{w,b} &= \frac{1}{2} w^T w \\ \text{ขึ้นอยู่กั} & y_i (w^T x + b) \geq 1 \end{aligned} \quad (2.15)$$

การใช้ตัวคูณลาเกรนจ์ (Lagrange multiplier หรือ  $\alpha$ ) ช่วยให้สามารถเปลี่ยนปัญหา constrained optimization ให้อยู่ในรูปแบบที่สามารถคำนวณได้ง่ายขึ้นในรูปแบบของ dual problem ซึ่งมีประสิทธิภาพสูงในการคำนวณโดยเฉพาะเมื่อรวมกับ kernel trick ในกรณีที่ข้อมูลไม่สามารถแยกเชิงเส้นได้ซึ่งหาได้จากการลดเวกเตอร์มิติ  $w$  ลบด้วยค่าผลรวมของตัวคูณลาเกรนจ์ ( $\alpha_i$ ) ของค่าฉลากของข้อมูลตัวอย่างที่  $y_i$  ดังสมการที่ (2.16)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$L_p(w, b, \alpha) = \frac{1}{2} w^T w - \sum_{i=1}^N \alpha_i \{y_i [w^T x + b] - 1\} \quad (2.16)$$

ในการหาจุดคงที่ (Saddle) ของสมการข้างต้นนั้นจะต้องเป็นไปตามเงื่อนไขของ Karush–Kuhn–Tucker (KKT) ต่อไปนี้

$$\frac{\partial L}{\partial w} = 0 \quad (2.17)$$

$$w_0 = \sum_{i=1}^N \alpha_i x_i y_i$$

$$\frac{\partial L}{\partial b} = 0 \quad (2.18)$$

$$\sum_{i=1}^N \alpha_i y_i = 0$$

จากสมการที่ (2.17) จะสังเกตได้ว่า  $\alpha_i$  จะไม่เท่ากับศูนย์ก็ต่อเมื่อข้อมูลอินพุตที่สอดคล้องกัน ( $x_i$ ) เป็นเวกเตอร์สนับสนุน เวกเตอร์สนับสนุน คือข้อมูลที่เลือกให้เป็นขอบเขตของแต่ละคลาสซึ่งสามารถพบระยะขอบของคลาสได้

ในที่สุด การแทนที่สมการที่ (2.17) และสมการที่ (2.18) ในสมการที่ (2.16) จะได้สมการทั่วไปของ SVC สำหรับกรณีที่แยกได้เชิงเส้น ซึ่งจะต้องอยู่ภายใต้ข้อจำกัดสองประการดังสมการที่ (2.19)

$$\text{Max } L_d(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (2.19)$$

ขึ้นอยู่กับ

$$\begin{cases} \alpha_i \geq 0 \\ \sum_{i=1}^N \alpha_i y_i = 0 \end{cases}$$

ข้อจำกัดที่ได้จากการแก้ปัญหาในรูปแบบ Dual จะถูกนำมาใช้โดยอัลกอริทึมของเครื่องเวกเตอร์สนับสนุน (Support Vector Classifier หรือ SVC) เพื่อระบุเวกเตอร์รองรับ (Support Vectors) และชุดข้อมูลอินพุตที่มีความสอดคล้องกับแนวการแบ่งข้อมูลอย่างเหมาะสม จากนั้นพารามิเตอร์เวกเตอร์น้ำหนัก  $w$  ของไฮเปอร์เพลน ซึ่งทำหน้าที่เป็นฟังก์ชันการตัดสินใจ สามารถคำนวณได้จาก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สมการที่ (2.19) ขณะที่พารามิเตอร์ไบอัส  $b$  สามารถประเมินได้จากสมการที่ (2.20) โดยนิยามเขียนในรูปของค่าเฉลี่ยจากชุดของเวกเตอร์รองรับ

$$b_0 = \frac{1}{N} \sum_{s=1}^N (y_s - w^T x_s) \quad (2.20)$$

### 2.5.2.2 กรณีที่ไม่สามารถแยกเป็นเส้นตรงได้ (Soft Margin)

มีบางกรณีที่ข้อมูลไม่สามารถแยกออกจากกันได้เชิงเส้นเนื่องจากคุณลักษณะบางประการในฐานข้อมูลมีความคล้ายคลึงกัน อย่างไรก็ตาม SVM เชิงเส้นอาจยังสามารถให้แนวทางแก้ปัญหาที่ดีแก่ปัญหานี้ได้โดยสามารถกำหนดฟังก์ชันค่าปรับ (Penalty Function) ( $F(\xi)$ ) เพื่อให้สามารถวัดและลดระยะห่าง ( $\xi_i$ ) ระหว่างข้อมูลที่จัดประเภทไม่ถูกต้องของแต่ละคลาสจากขอบของคลาสนั้นได้ ฟังก์ชันค่าปรับในกรณีนี้ ( $F(\xi)$ ) หาได้จากผลรวมของระยะห่าง ( $\xi_i$ ) สามารถกำหนดได้สมการที่ (2.21)

$$F(\xi) = \sum_{i=1}^N \xi_i \quad (2.21)$$

ผลลัพธ์คือฟังก์ชันการเพิ่มประสิทธิภาพที่นำเสนอไว้ก่อนหน้านี้ในสมการที่ (2.22) สำหรับกรณีที่แยกจากกันไม่ได้เชิงเส้นจะมีเทอมใหม่ที่อิงตามฟังก์ชันค่าปรับที่กล่าวถึงดังนี้

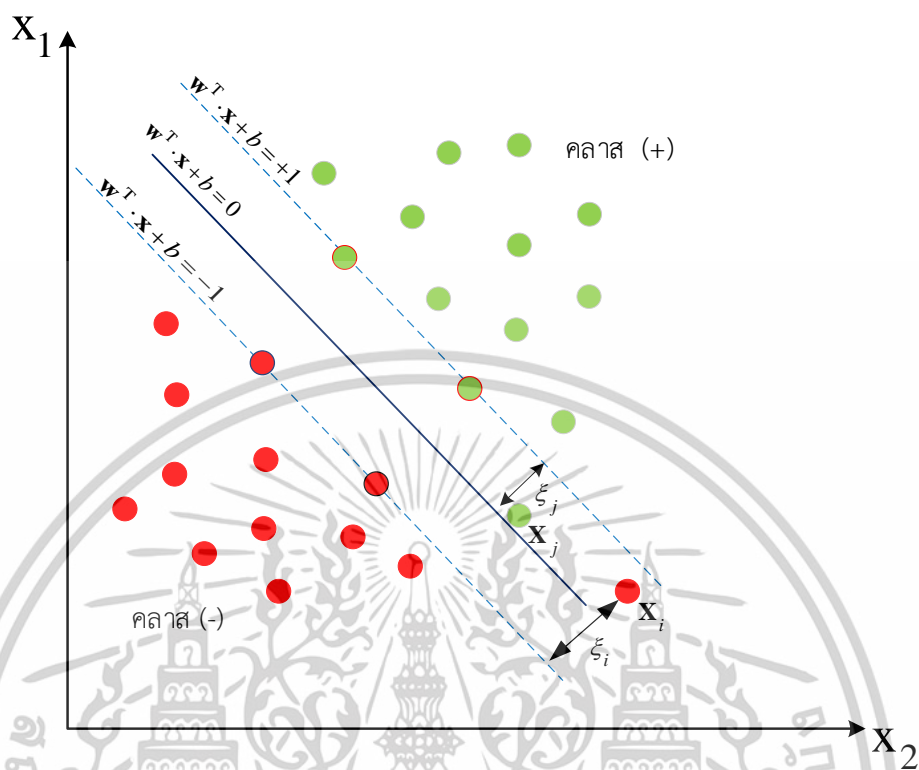
$$\text{Min}_{w,b} = \frac{1}{2} w^T w + C \sum_{i=1}^N \xi_i \quad (2.22)$$

ขึ้นอยู่กับ

$$y_i(w^T x + b) \geq 1 - \xi_i$$

พารามิเตอร์  $C$  ในสมการที่ (2.22) เรียกว่าพารามิเตอร์ “การแลกเปลี่ยน (Trade-Off)” ที่เพิ่มเข้ามาเพื่อเพิ่มระยะขอบให้สูงสุดและลดข้อผิดพลาดในการจำแนกให้เหลือน้อยที่สุด

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.27 ข้อมูลที่ไม่สามารถแยกได้เป็นเส้นตรงโดยมีตัวแปรยืดหยุ่น (Slack) ที่กำหนดเพื่อลดข้อผิดพลาดจากการจำแนกประเภทที่ไม่ถูกต้อง

เพื่อแก้ไขปัญหการเพิ่มประสิทธิภาพข้างต้น ซึ่งอยู่ภายใต้ข้อจำกัดของระยะขอบจึงใช้ตัวคูณ Lagrange ( $\alpha$  ( $\alpha_i \geq 0$ ),  $\beta$  ( $\beta_i \geq 0$ )) รูปแบบที่ไม่มีข้อจำกัดของสมการที่ (2.23) สามารถหาได้ดังต่อไปนี้

$$L_p(w, b, \xi, \alpha, \beta) = \frac{1}{2} w^T w - C \sum_{i=1}^N \xi_i - \sum_{i=1}^N \alpha_i [y_i [w^T x + b] - 1 + \xi_i] + \sum_{i=1}^N \beta_i \xi_i \quad (2.23)$$

วิธีแก้ปัญหที่เหมาะสมที่สุดสำหรับสมการที่ (2.24) สามารถหาได้โดยการตอบสนองเงื่อนไข KKT ต่อไปนี้

$$\frac{\partial L}{\partial w} = 0 \quad (2.24)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$w_0 = \sum_{i=1}^N \alpha_i x_i y_i$$

$$\frac{\partial L}{\partial b} = 0 \quad (2.25)$$

$$\sum_{i=1}^N \alpha_i y_i = 0$$

$$\frac{\partial L}{\partial \xi} = 0 \quad (2.26)$$

$$\alpha_i + \beta_i = C$$

การแทนที่สมการที่ (2.24) – (2.26) ในสมการที่ (2.23) จะสร้างปัญหาคู่ต่อไปสำหรับ SVC ระยะเวลาขอบนุ่มนวล (Soft margin)

$$\text{Max } L_a(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j x_i^T x_j \quad (2.27)$$


ขึ้นอยู่กับ  $\begin{cases} 0 \leq \alpha_i \leq C \\ \sum_{i=1}^N \alpha_i y_i = 0 \end{cases}$

ความแตกต่างระหว่างสมการที่ (2.27) และสมการที่นำเสนอไว้ก่อนหน้านี้เป็นสมการที่ (2.12) คือ ข้อจำกัดที่ตั้งไว้สำหรับตัวคูณ Lagrange  $\alpha$  ซึ่งบังคับให้ต้องเท่ากับหรือต่ำกว่าพารามิเตอร์แลกเปลี่ยน  $C$

### 2.5.2.3 กรณีแบบไม่เชิงเส้น (เคอร์เนล)

จุดประสงค์ของการใช้ไฮเปอร์เพลนที่เหมาะสมคือเพื่อเพิ่มความสามารถในการสรุปทั่วไปของโมเดล อย่างไรก็ตาม หากข้อมูลไม่สามารถแยกเป็นเส้นตรงได้ โมเดลจะไม่มีความสามารถในการสรุปทั่วไปที่ดี แม้ว่าจะพบไฮเปอร์เพลนที่เหมาะสมแล้วก็ตาม เพื่อแก้ไขปัญหานี้ ข้อมูลอินพุตจะถูกแมปลงในสเปซผลคูณจุดที่มีมิติสูงกว่า ซึ่งเรียกอีกอย่างว่าสเปซคุณลักษณะหรือสเปซฮิลเบิร์ตที่เสนอโดย [25] เมื่อคำนึงถึงทฤษฎีนี้ ข้อมูลจะยังคงไม่เป็นเชิงเส้นในสเปซอินพุตในขณะที่สามารถสร้าง SVC แบบเชิงเส้นในสเปซคุณลักษณะเพื่อแยกข้อมูลเหล่านี้ออกจากกัน รูปที่ 27.4 แสดงให้เห็นว่าสเปซคุณลักษณะสามารถใช้เพื่อแยกข้อมูลในมิติที่สูงกว่าได้อย่างไร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.28 การแมปฝังข้อมูล

ผลคูณภายใน (Inner Product)  $\varphi(x_i, x_j)$  สามารถคำนวณได้โดยการเลือกฟังก์ชันเคอร์เนล  $K(x_i, x_j)$  ที่ซับซ้อนดังที่เขียนดังสมการที่ (2.28)

$$\varphi(x_i, x_j) = K(x_i, x_j) \quad (2.28)$$

เมื่อพิจารณาถึงการประยุกต์ใช้ฟังก์ชันเคอร์เนลในการกำหนดผลคูณภายในของข้อมูลอินพุตที่นำมาในพื้นที่ที่เฟอรัสมการคู่ (Dual) ทัวไปที่นำเสนอไว้ก่อนหน้านี้สำหรับการจำแนกประเภทข้อมูลที่ไม่สามารถแยกจากกันเชิงเส้นได้ ดังสมการที่ (2.29) สามารถเขียนใหม่สำหรับกรณีการจำแนกประเภทแบบไม่เชิงเส้นดังนี้

$$\text{Max } L_d(\alpha) = \sum_{i=1}^N \alpha_i - \frac{1}{2} \sum_{i,j=1}^N y_i y_j \alpha_i \alpha_j K(x_i, x_j) \quad (2.29)$$

ขึ้นอยู่กับ  $\begin{cases} 0 \leq \alpha_i \leq C \\ \sum_{i=1}^N \alpha_i y_i = 0 \end{cases}$

อย่างไรก็ตาม การหาไฮเปอร์เพลนที่เหมาะสมที่สุดในโอกาสเหล่านี้อาจไม่ใช่เรื่องง่ายและไม่ตรงไปตรงมา เนื่องจากค่าที่ไม่ทราบของเวกเตอร์ถ่วงน้ำหนัก  $w$  จากผลรวมของผลคูณระหว่างค่าป้ายกำกับ ( $y$ ) และตัวคูณลากรางจ์  $\alpha$  ของอินพุตที่ตำแหน่งที่  $i$  ซึ่งเขียนเป็นสมการที่ (2.30)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$w = \sum_{i,j=1}^N y_i \alpha_i(x_i) \quad (2.30)$$

ภายใต้สถานการณ์ที่ไม่สามารถแยกคลาสข้อมูลได้สามารถใช้เทคนิคเคอร์เนลซึ่งไม่จำเป็นต้องมีการกำหนดพารามิเตอร์  $w$  โดยตรงสามารถใช้พารามิเตอร์ไบอัส  $b$  สามารถหาได้การนำค่าของป้ายกำกับ ( $y_i$ ) ลบด้วยผลรวมของผลคูณระหว่างค่าของป้ายกำกับและตัวคุณลักษณะ ( $\alpha_i$ ) โดยใช้ฟังก์ชันเคอร์เนลดังสมการที่ (2.31)

$$b = y_i - \sum_{i,j=1}^{N_{SV}} \alpha_i y_i K(x_i, x_j) \quad (2.31)$$

ดังนั้น ไฮเปอร์เพลนจะถูกกำหนดเป็น

$$d(x) = w^T \phi(x) + b \quad (2.32)$$

ฟังก์ชันการตัดสินใจที่เหมาะสมที่สุดจะได้รับการแทนที่สมการที่ (2.33) ในสมการที่ (2.32) และพิจารณาฟังก์ชันเคอร์เนลที่เหมาะสม ดังนั้นสมการทั่วไปของไฮเปอร์เพลน  $d(x)$  จึงสามารถกล่าวได้ดังสมการที่ (2.33)

$$d(x) = \sum_{i,j=1}^N y_i \alpha_i K(x_i, x_j) + b \quad (2.33)$$

ในอัลกอริธึม SVM ฟังก์ชันเคอร์เนล (Kernel Function) มีบทบาทสำคัญในการเพิ่มศักยภาพของโมเดลสำหรับการจำแนกข้อมูลที่ไม่สามารถแยกได้ด้วยเส้นตรงในพื้นที่ดั้งเดิม รวมถึงการประยุกต์ใช้ในปัญหาการถดถอย (Regression) ฟังก์ชันเคอร์เนลทำหน้าที่แปลงข้อมูลจากพื้นที่อินพุตเดิมไปยังพื้นที่คุณลักษณะที่มีมิติสูงกว่า (Higher-dimensional Feature Space) โดยไม่จำเป็นต้องคำนวณค่าพิกัดใหม่โดยตรง ซึ่งกระบวนการนี้เรียกว่า เทคนิคเคอร์เนล (Kernel Trick)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 2.2 ประเภทของเคอร์เนลฟังก์ชัน

1	เคอร์เนลเชิงเส้น	$K(\mathbf{x}_i, \mathbf{x}_j) = \mathbf{x}_i^T \cdot \mathbf{x}_j + C$
2	เคอร์เนลพหุนาม	$K(\mathbf{x}_i, \mathbf{x}_j) = (\gamma(\mathbf{x}_i^T \cdot \mathbf{x}_j) + C)^d$
3	เคอร์เนล RBF	$K(\mathbf{x}_i, \mathbf{x}_j) = \exp^{-\gamma\ \mathbf{x}_i^T \cdot \mathbf{x}_j\ ^2}$
4	เคอร์เนลซิกมอยด์	$K(\mathbf{x}_i, \mathbf{x}_j) = \tanh(\gamma(\mathbf{x}_i^T \cdot \mathbf{x}_j) + C)$

### 2.5.3 การประเมินผลของโมเดล

การประเมินผลความแม่นยำของโมเดลในงานด้านการเรียนรู้เชิงลึก (Deep Learning) มีบทบาทสำคัญในการปรับแต่งและเลือกตัวจำแนกประเภท (Classifier) ที่มีประสิทธิภาพสูงสุด โดยกระบวนการประเมินจะดำเนินผ่านสองขั้นตอนหลัก คือการฝึกอบรม (Training) และการทดสอบ (Testing) โดยมีเป้าหมายเพื่อปรับปรุงสมรรถนะของอัลกอริธึมการจำแนกประเภทให้สามารถสร้างแบบจำลองที่มีความแม่นยำสูง ในระหว่างการฝึกอบรม เมตริกการประเมิน (Evaluation Metrics) ถูกนำมาใช้เพื่อติดตามและเลือกโซลูชันที่ดีที่สุด ในขณะที่ในขั้นตอนการทดสอบ เมตริกเหล่านี้ทำหน้าที่ประเมินความสามารถของโมเดลบนข้อมูลที่ไม่เคยเห็นมาก่อน เพื่อสะท้อนศักยภาพในการสรุปทั่วไป (Generalization) หนึ่งในวิธีการประเมินพื้นฐานคือการพิจารณาผลลัพธ์จากค่าทางสถิติต่าง ๆ ได้แก่

- True Positive (TP) คือจำนวนข้อมูลคลาสบวกที่จำแนกได้ถูกต้อง
- True Negative (TN) คือจำนวนข้อมูลคลาสลบที่จำแนกได้ถูกต้อง
- False Positive (FP) คือจำนวนข้อมูลคลาสลบที่ถูกจำแนกผิดว่าเป็นคลาสบวก
- False Negative (FN) คือจำนวนข้อมูลคลาสบวกที่ถูกจำแนกผิดว่าเป็นคลาสลบ

ตัวชี้วัดเหล่านี้เป็นพื้นฐานในการคำนวณเมตริกต่าง ๆ ที่ใช้วัดประสิทธิภาพของโมเดล เช่น Accuracy, Precision, Recall และ F1-Score ดังที่แสดงในสมการที่ (2.34) - (2.39) ซึ่งเป็นส่วนสำคัญในการประเมินและเปรียบเทียบโมเดลจำแนกประเภทในงานวิจัย

1) ความแม่นยำ (Accuracy) คำนวณอัตราส่วนของคลาสที่คาดการณ์ถูกต้องต่อจำนวนตัวอย่างทั้งหมดที่ประเมิน สามารถคำนวณได้โดยสมการที่ (2.34)

$$\text{Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}} \quad (2.34)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2) ความไวหรือการเรียกคืน (Sensitivity or Recall) ใช้ในการคำนวณเศษส่วนของรูปแบบการบวกที่จัดประเภทอย่างถูกต้อง สามารถหาได้จากสมการที่ (2.35)

$$\text{Sensitivity} = \frac{TP}{TP + FN} \quad (2.35)$$

3) Specificity ใช้ในการคำนวณเศษส่วนของรูปแบบเชิงลบที่จัดประเภทอย่างถูกต้อง สามารถหาได้จากสมการที่ (2.36)

$$\text{Specificity} = \frac{TN}{FP + TN} \quad (2.36)$$

4) Precision ใช้ในการคำนวณรูปแบบเชิงบวกที่คาดการณ์ได้อย่างถูกต้องจากรูปแบบที่คาดการณ์ทั้งหมดในคลาสเชิงบวก สามารถหาได้จากสมการที่ (2.37)

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.37)$$

5) F1-Score คำนวณค่าเฉลี่ยฮาร์โมนิกระหว่างอัตราการเรียกคืนและความแม่นยำ สามารถหาได้จากสมการที่ (2.38)

$$F1_{score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.38)$$

6) พื้นที่ใต้เส้นโค้ง ROC (Area Under the ROC Curve) AUC เป็นเมตริกประเภทการจัดอันดับทั่วไป ใช้เพื่อทำการเปรียบเทียบระหว่างอัลกอริทึมการเรียนรู้ตลอดจนสร้างรูปแบบการเรียนรู้ที่เหมาะสมที่สุด ตรงกันข้ามกับเมตริกความน่าจะเป็นและเกณฑ์ ค่า AUC จะแสดงประสิทธิภาพการจัดอันดับของตัวแยกประเภททั้งหมด สมการที่ (2.39) ใช้เพื่อคำนวณค่า AUC สำหรับปัญหาสองคลาส โดยการหาจากผลรวมของตัวอย่างอันดับที่เป็นบวกทั้งหมด ( $S_p$ ) หารด้วยจำนวนของตัวอย่างทั้งเชิงบวกและเชิงลบ ( $n_p$ )

$$AUC = \frac{S_p - n_p(n_n + 1)/2}{n_p n_n} \quad (2.39)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยที่  $S_p$  แสดงผลรวมของตัวอย่างอันดับบวกทั้งหมด จำนวนตัวอย่างเชิงลบและบวกแสดงเป็น  $n_n$  และ  $n_p$  ตามลำดับ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 3

# วิธีการจำแนกประเภทของพลาสมาบับเบิลบริเวณเส้นศูนย์สูตรที่นำเสนอ

ในบทนี้นำเสนอวิธีการวิเคราะห์ระดับความสูง ทิศทางการเคลื่อนตัว และจำนวนพลาสมาบับเบิลที่เกิดขึ้นในแต่ละวัน และนำเสนอการออกแบบโมเดลในการจำแนกประเภทของพลาสมาบับเบิลบริเวณเส้นศูนย์สูตรโดยใช้โครงข่ายประสาทเทียมแบบคอนโวลูชัน และวิธีการของซัพพอร์ตเวกเตอร์แมชชีน โดยมีรายละเอียดดังต่อไปนี้

### 3.1 ทบทวนวรรณกรรมที่เกี่ยวข้อง

พลาสมาบริเวณเส้นศูนย์สูตร (Equatorial Plasma Bubbles หรือ EPBs) เป็นปรากฏการณ์ความไม่สม่ำเสมอของความหนาแน่นอิเล็กตรอนในชั้นบรรยากาศไอโอโนสเฟียร์ ซึ่งมีผลกระทบต่อสภาพอากาศในอวกาศและการทำงานของระบบสื่อสารผ่านดาวเทียม รวมถึงระบบกำหนดตำแหน่งบนพื้นโลก (GNSS) การตรวจจับและจำแนก EPBs อย่างแม่นยำจึงเป็นปัจจัยสำคัญต่อการพัฒนาแบบจำลองการพยากรณ์และระบบแจ้งเตือนล่วงหน้า ในช่วงทศวรรษที่ผ่านมา ความก้าวหน้าของเทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะเทคนิคการเรียนรู้ของเครื่อง (Machine Learning หรือ ML) และการเรียนรู้เชิงลึก (Deep Learning หรือ DL) ได้รับความสนใจอย่างแพร่หลายในวงการฟิสิกส์อวกาศ และถูกนำมาประยุกต์ใช้ในการวิเคราะห์และจำแนก EPBs ผู้วิจัยได้ทบทวนวรรณกรรมเกี่ยวกับการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกที่ใช้ในการทำนาย ตรวจจับ และจำแนกประเภทของพลาสมาบับเบิลแสดงดังตารางที่ 3.1

ตารางที่ 3.1 วรรณกรรมเกี่ยวกับปัญญาประดิษฐ์ของพลาสมาบับเบิล

ลำดับ	ผู้เขียน/ปี	วิธีการที่นำเสนอ
1	Reddy S. A. และคณะ (2023) [26]	การคาดการณ์ (Prediction) ความแปรปรวนรายวันของ EPB แบบจำลอง APE คาดการณ์ EPB ได้ดี โดยเฉพาะหลังพระอาทิตย์ตกดินและกิจกรรมสุริยะสูง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2	Carvalho O. และคณะ (2022) [27]	ทำนายค่าดัชนี $S_4$ ล่วงหน้า 30 นาที โดยใช้โมเดล 6 แบบ โดยอัลกอริทึม 3 ตัว ได้แก่ โครงข่ายประสาทเทียม (ANN), extreme gradient boosting และ random forest
3	Luwanga C. และคณะ (2022) [28]	ทดสอบแนวทางการเรียนรู้ของ 3 แนวทาง ได้แก่ SVM, autoencoder และการเรียนรู้การถ่ายโอนด้วย ResNet50 ในการตรวจจับ Spread F
4	Chakrabarti S. และคณะ (2024) [29]	อัลกอริทึมการเพิ่มประสิทธิภาพแบบใหม่ที่ผสานกลไกการค้นหาแบบสุ่มและแบบกริดเป็นการเรียกใช้ฟังก์ชัน เช่น Inception-v3, DenseNet169, VGG16 และ VGG19
5	Priyadarshi S. และคณะ (2024) [30]	การคาดการณ์ค่า ROTI โดยใช้โครงข่ายประสาทเทียมแบบย้อนกลับ (feedforward backpropagation Neural Network)
6	Maheswaran V. และคณะ (2024) [31]	แบบจำลองหน่วยความจำระยะยาวระยะสั้นแบบสองทิศทาง (Bi-LSTM) ในการทำนายปริมาณอิเล็กทรอนิกส์รวมแนวตั้ง (VTEC)
7	Lan T., Hu H. และคณะ (2020) [32]	การระบุ Spread F อัตโนมัติ 3 วิธีโดยอาศัยการเรียนรู้ของเครื่อง ได้แก่ ต้นไม้ตัดสินใจ (Decision Tree) ป่าสุ่ม (Random Forest) และ CNN
8	Rao T. และคณะ (2022) [33]	การทำนายพารามิเตอร์ของชั้นบรรยากาศไอโอโนสเฟียร์ เช่น foF2 และ hmF2 โดยใช้แบบจำลองหน่วยความจำระยะสั้นแบบสองทิศทาง (Bi-LSTM)
9	Shidler S. และคณะ (2020) [34]	สร้างแบบจำลองการเคลื่อนตัวของพลาสมาในแนวตั้ง (vertical plasma drifts) โดยใช้เทคนิคการเรียนรู้ของเครื่องจักรแบบป่าสุ่ม
10	Breuilhard H. และคณะ (2020) [35]	อัลกอริทึมการเรียนรู้เชิงลึกของเครื่องจักรแบบมัลติเลเยอร์เพอร์เซพตรอน (MLP) และโครงข่ายประสาทเทียมแบบคอนโวลูชันเต็มรูปแบบ (FCN) เพื่อจำแนกบริเวณพลาสมาที่สำคัญ
11	Thammavongsy P. และคณะ (2023) [36]	ใช้เทคนิคการเรียนรู้เชิงลึก โมเดล LSTM และ ANN เพื่อคาดการณ์การเกิดการแพร่กระจาย F บริเวณเส้นศูนย์สูตร

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

12	Atabati A. และคณะ (2021) [37]	การคาดการณ์ปรากฏการณ์ซินทิลเลชันด้วยพารามิเตอร์ S4 และ ROTI โดยโครงข่ายประสาทเทียม (ANN) และอัลกอริทึมทางพันธุกรรม (Genetic Algorithm)
13	Wang Z. และคณะ (2023) [38]	วิธีการตรวจจับและจำแนกภาพของ Spread F โดยโมเดล VGG, ResNet, EfficientNet, ViT และ MobileNet
14	Zhao X. และคณะ (2021) [39]	การคาดการณ์การเกิดซินทิลเลชัน โดยอาศัยอัลกอริทึม (XGBoost) , LightGBM และ CatBoost
15	Tang J. และคณะ (2023) [40]	การพยากรณ์ปริมาณอิเล็กตรอนทั้งหมดในชั้นบรรยากาศไอโอโนสเฟียร์ (TEC) โดยใช้แบบจำลอง BiConvGRU
16	Tang J. และคณะ (2022) [41]	การใช้ค่าสัมประสิทธิ์ที่คาดการณ์ไว้เพื่อสร้างแผนที่พยากรณ์ TEC โดยรากที่สองของค่าความผิดพลาดเฉลี่ย (RMSE) ข้อผิดพลาดสัมบูรณ์เฉลี่ย (MAE) และค่าสัมประสิทธิ์สหสัมพันธ์ (R)
17	Salles L. และคณะ (2023) [42]	การประมาณค่าโปรไฟล์แนวตั้งความหนาแน่นของอิเล็กตรอนในบริเวณชั้น F โดยใช้โครงข่ายประสาทเทียม LSTM
18	Seba E. และคณะ (2024) [43]	การสร้างแบบจำลองความผิดปกติของพลาสมาไอโอโนสเฟียร์ โดยใช้ Random Forest (RF) และโมเดล Convolutional Neural Network แบบมิติเดียว (1D-CNN)
19	Bi C. และคณะ (2022) [44]	การคาดการณ์การแปรผันของ foF2 ในชั้นบรรยากาศไอโอโนสเฟียร์โดยใช้โครงข่ายประสาทเทียมแบบผสมผสานระหว่าง CNN และ BiLSTM

ดังที่ได้กล่าวมา มีความก้าวหน้าในการศึกษาวิธีการทำนาย คาดการณ์ หรือจำแนกปรากฏการณ์ของพลาสมาบับเบิลบริเวณเส้นศูนย์สูตร แต่ยังคงมีช่องว่างของงานวิจัยที่ใช้การเรียนรู้ของเครื่องในการทำงานหรือจำแนกประเภทของ EPB โดยการใช้อุปกรณ์เรดาร์ VHF ดังนั้นผู้วิจัยจึงนำโมเดลโครงข่ายคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีนที่มีจุดเด่นในการหาคุณลักษณะของรูปภาพมาใช้จำแนกประเภทของพลาสมาบับเบิลโดยใช้อุปกรณ์เรดาร์ VHF

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 3.2 การเตรียมข้อมูลเพื่อใช้ในการฝึกอบรมโมเดล

ในงานวิทยานิพนธ์ฉบับนี้มีการใช้ข้อมูลจากสองระบบ ได้แก่ ข้อมูลจากเรดาร์ VHF และข้อมูลจากระบบไอโอโนซอนด์ โดยข้อมูลจากเรดาร์ VHF ที่นำมาใช้ครอบคลุมช่วงวันที่ 1 เดือนมีนาคม ค.ศ. 2020 ถึงวันที่ 30 เดือนมีนาคม ค.ศ. 2020 ซึ่งเรดาร์ VHF มีความสามารถในการรับสัญญาณในทุก ๆ 2-3 นาที สำหรับการวิจัยในครั้งนี้ ได้เลือกช่วงเวลาของข้อมูลระหว่างเวลา 07.00 น. ถึง 12.00 น. ตามเวลาสากลโลก (UTC) ซึ่งหากแปลงเป็นเวลาท้องถิ่นจะต้องเพิ่มเวลาอีก 7 ชั่วโมง ทั้งนี้ รูปภาพจากข้อมูลเรดาร์ VHF จำนวน 13,650 ภาพ ถูกนำมาใช้สำหรับการฝึกอบรมโมเดล ขณะที่ข้อมูลสำหรับการทดสอบโมเดลประกอบด้วยรูปภาพจำนวน 6,814 ภาพ ซึ่งครอบคลุมช่วงวันที่ 1 เดือนพฤศจิกายน ค.ศ. 2022 ถึงวันที่ 15 เดือนพฤศจิกายน ค.ศ. 2022

สำหรับข้อมูลจากเครื่องไอโอโนซอนด์นั้น มีการบันทึกข้อมูลในทุก ๆ 5 นาที โดยข้อมูลไอโอโนแกรมที่ใช้ในการฝึกอบรมโมเดลครอบคลุมช่วงเวลาเดียวกันกับข้อมูลเรดาร์ VHF คือระหว่างวันที่ 1 เดือนมีนาคม ค.ศ. 2020 ถึงวันที่ 30 เดือนมีนาคม ค.ศ. 2020 โดยมีจำนวนทั้งสิ้น 6,000 ภาพ สำหรับการทดสอบโมเดล ใช้ข้อมูลไอโอโนแกรมจำนวน 3,000 ภาพ ซึ่งได้จากช่วงวันที่ 1 เดือนพฤศจิกายน ค.ศ. 2022 ถึงวันที่ 15 เดือนพฤศจิกายน ค.ศ. 2022


### 3.2.1 การวิเคราะห์และจัดเตรียมข้อมูลของภาพเรดาร์ VHF

เรดาร์ความถี่สูงมาก (VHF) ถือเป็นเครื่องมือที่มีประสิทธิภาพสูงในการตรวจจับและศึกษาฟองพลาสมาบริเวณเส้นศูนย์สูตรในชั้นบรรยากาศไอโอโนสเฟียร์ ด้วยความสามารถในการวัดที่มีความละเอียดสูงทั้งในด้านพื้นที่และเวลา ทำให้สามารถติดตามการเปลี่ยนแปลงและวิวัฒนาการของฟองพลาสมา (EPB) รวมถึงตรวจสอบโครงสร้างขนาดใหญ่ได้อย่างชัดเจน นอกจากนี้ เรดาร์ VHF ยังสามารถตรวจวัดข้อมูลได้แบบเรียลไทม์ ซึ่งเป็นประโยชน์อย่างยิ่งต่อการพยากรณ์สภาพอากาศในอวกาศ เรดาร์ชนิดนี้จะปล่อยคลื่นวิทยุเข้าสู่ชั้นไอโอโนสเฟียร์ และเมื่อคลื่นเดินทางผ่านบริเวณที่มีความแปรปรวนของความหนาแน่นพลาสมา เช่น บริเวณที่เกิด EPB คลื่นจะเกิดการกระเจิง โดยลักษณะของสัญญาณที่สะท้อนกลับ เช่น ความเข้มและเวลาที่สัญญาณมาถึง สามารถนำมาวิเคราะห์เพื่อระบุการมีอยู่และลักษณะของฟองพลาสมาได้อย่างแม่นยำ เรดาร์ VHF ยังสามารถตรวจวัดได้ในระดับความละเอียดเชิงพื้นที่ในหน่วยเมตร และความละเอียดเชิงเวลาในระดับวินาที ช่วยให้เข้าใจพฤติกรรมพลวัตของ EPB ได้อย่างละเอียดลึกซึ้ง อีกทั้งยังสามารถครอบคลุมพื้นที่กว้างของชั้นไอโอ

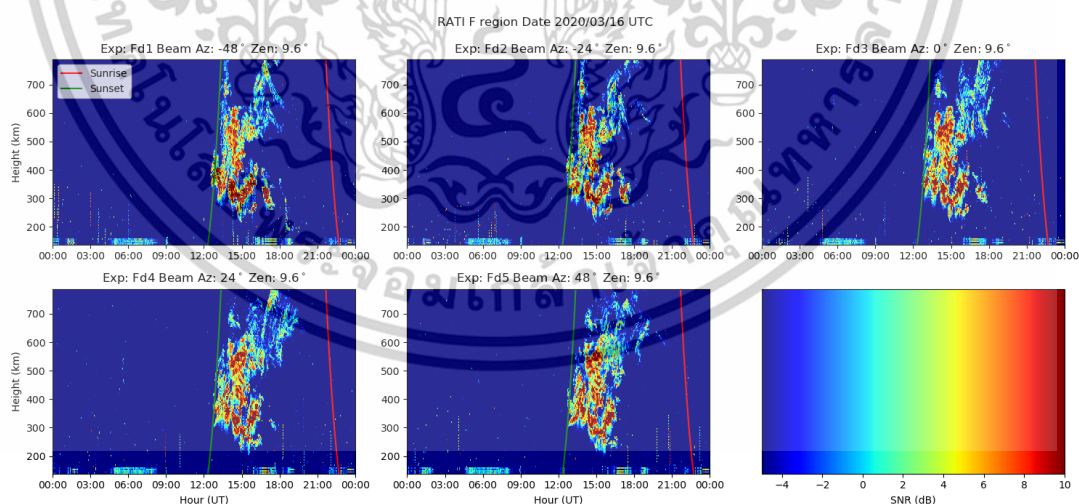
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โนสเฟียร์ ทำให้สามารถศึกษาทั้งโครงสร้างและการเปลี่ยนแปลงของ EPB ได้ในมิติที่กว้างและครบถ้วน

หลังจากที่ได้รับข้อมูลจากรีดาร์ VHF แล้วนั้นขั้นตอนถัดไปจะเป็นการประมวลผลข้อมูลเบื้องต้นของภาพเรดาร์ VHF โดยรูปภาพจะถูกครอบตัดข้อมูลออกบางส่วน โดยที่รูปภาพดั้งเดิม (Original Image) จะมีขนาด 500x830x3 จากนั้นจะทำการครอบตัดรูปภาพโดยจะเลือกช่วงที่มีเพียงข้อมูลที่สำคัญที่แสดงบนรูปและจะปรับขนาดให้เป็น 360x360x3 ทุก ๆ รูปภาพ ในรูปที่ 3.1 แสดงถึงตัวอย่างของรูปภาพดั้งเดิมและรูปภาพที่ทำการครอบตัดและปรับขนาด ตามลำดับ



รูปที่ 3.1 ตัวอย่างข้อมูลเรดาร์ VHF หลังจากการครอบตัดและปรับขนาด




รูปที่ 3.2 ตัวอย่างข้อมูลเรดาร์ VHF ในรูปแบบการพล็อตความเข้มของช่วงระดับความสูง - เวลา (RATI)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในรูปที่ 3.2 แสดงตัวอย่างข้อมูลจากการพล็อตแบบ RATI ซึ่งแสดงลักษณะการเปลี่ยนแปลงของช่วงเวลาและระดับความสูงของพลาสมาบับเบิลที่เกิดขึ้นภายในหนึ่งวัน โดยข้อมูลประกอบด้วยทั้งหมด 5 ลำแสง จากภาพจะเห็นได้ว่าเรดาร์ VHF สามารถตรวจจับการเกิดขึ้นของพลาสมาบับเบิลเริ่มแรกได้ในช่วงเวลาประมาณ 12:00–13:00 น. ตามเวลาสากล (UTC) โดยเริ่มปรากฏที่ระดับความสูงประมาณ 320 กิโลเมตรจากพื้นดิน จากนั้นพลาสมาบับเบิลมีการขยายตัวขึ้นไปยังระดับความสูงมากกว่า 800 กิโลเมตร ในช่วงเวลาประมาณ 18:00 น. และสลายตัวไปหลังเวลา 19:00 น. ตามเวลาสากล


### 3.2.2 ข้อมูลภาพไอโอโนแกรม

สำหรับข้อมูลไอโอโนแกรม ก่อนที่จะทำการนำข้อมูลไปใช้ในการฝึกอบรมโมเดลนั้น รูปภาพจะถูกครอบตัดและปรับขนาดของรูปภาพด้วยเช่นกัน และจะทำการแก้ไขรูปภาพโดยการลบเส้นสีฟ้าบนรูปภาพออก เพื่อให้โมเดลมีประสิทธิภาพในการคุณลักษณะของรูปภาพ โดยในขั้นตอนแรก เราจะครอบตัดจากภาพต้นฉบับและปรับขนาดภาพเป็น 230x230x3 พิกเซล ตัวอย่างกระบวนการแสดงไว้ในรูปที่ 3.3



รูปที่ 3.3 ตัวอย่างข้อมูลไอโอโนแกรมหลังจากการครอบตัดและปรับขนาด

จากนั้นจะได้ข้อมูลจากเรดาร์แต่ละตัวและจะแบ่งข้อมูลออกเป็น 3 คลาส ได้แก่ ไม่มีพลาสมาบับเบิล ไม่แน่ใจ และพลาสมาบับเบิล ตามที่แสดงในรูปที่ 3.4




รูปที่ 3.4 ตัวอย่างข้อมูลเรดาร์ VHF และไอโอโนแกรมสำหรับแต่ละคลาส

### 3.3 วิธีการของซัพพอร์ตเวกเตอร์แมชชีนโดยใช้ข้อมูลจากเรดาร์ VHF

ในงานวิจัยได้ดำเนินการออกแบบและพัฒนาโมเดลการจำแนกประเภทโดยใช้ Support Vector Machine (SVM) ร่วมกับฟังก์ชันเคอร์เนลจำนวนทั้งหมด 4 รูปแบบ ได้แก่ เคอร์เนลเชิงเส้น (Linear Kernel), เคอร์เนลพื้นฐานเชิงรัศมี (Radial Basis Function), เคอร์เนลพหุนาม (Polynomial Kernel) และเคอร์เนลซิกมอยด์ (Sigmoid Kernel) สำหรับการใช้งานเคอร์เนลแต่ละประเภทจำเป็นต้องกำหนดค่าพารามิเตอร์หลักจำนวนสองค่าคือ พารามิเตอร์  $C$  และพารามิเตอร์แกมมา ( $\gamma$ ) เพื่อให้ได้ประสิทธิภาพของโมเดลสูงสุด

พารามิเตอร์  $C$  ทำหน้าที่เป็นไฮเปอร์พารามิเตอร์ในการควบคุมการแลกเปลี่ยนระหว่างการเพิ่มระยะขอบของขอบเขตการตัดสินใจ (Decision Boundary) กับการลดข้อผิดพลาดในการจำแนกประเภทของข้อมูลฝึก ส่วนพารามิเตอร์  $\gamma$  มีหน้าที่กำหนดอิทธิพลของแต่ละจุดข้อมูลฝึกที่มีต่อการสร้างขอบเขตการตัดสินใจ โดยเฉพาะในกรณีที่ใช้ RBF Kernel ซึ่งเป็นฟังก์ชันที่อาศัยหลักการของระยะห่างระหว่างอินสแตนซ์ (instance) เพื่อคำนวณค่าความคล้ายคลึงกัน เพื่อเปรียบเทียบประสิทธิภาพของเคอร์เนลแต่ละประเภท จึงได้ทำการตั้งค่าพารามิเตอร์  $C$  และ  $\gamma$  โดยใช้ค่าชุด  $\{0.01, 1, 10, 100\}$  สำหรับทั้งสองพารามิเตอร์ในการทดลองฝึกอบรมโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.5 สถาปัตยกรรมของแบบจำลอง SVM ด้วยข้อมูลจากเรดาร์ VHF

### 3.4 วิธีการแยกค่าเอกพจน์ร่วมกับวิธีการซัพพอร์ตเวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF

การแยกค่าเอกพจน์ (Singular Value Decomposition หรือ SVD) เป็นเทคนิคทางคณิตศาสตร์ที่ใช้ในพีชคณิตเชิงเส้นและการเรียนรู้ของเครื่องเพื่อแยกเมทริกซ์ออกเป็นสามองค์ประกอบ ในการแยกคุณลักษณะ SVD ช่วยลดมิติของข้อมูล ในขณะที่ยังคงสามารถรักษาข้อมูลที่สำคัญที่สุดไว้ โดยที่ SVD จะทำการขยายการแยกตัวประกอบ (Factorization) หรือการสลายตัว (Decomposition) ไปยังเมทริกซ์ใด ๆ ซึ่งจะแยกตัวประกอบของเมทริกซ์  $A$  โดยที่  $A$  คือ  $m \times n$  และ  $m \geq n$  ผลลัพธ์ในส่วนนี้ก็เป็นจริงเช่นกันถ้า  $m < n$  แต่เลือก  $m \geq n$  เพื่อความง่าย โปรดทราบว่าผลลัพธ์ในส่วนนี้ใช้ได้กับเมทริกซ์  $A$  ใด ๆ สามารถแยกเมทริกซ์  $A$  ใด ๆ ที่มีขนาด  $m \times n$  ที่มีค่าเอกพจน์ (Singular Values) เป็นบวกได้  $\sigma_1 \geq \sigma_2 \geq \dots \geq \sigma_k > 0$  โดยที่  $k \leq n$  สมการของ SVD แสดงดังต่อไปนี้

$$A = U \sum V^T \quad (3.1)$$

โดยที่  $A$  คือขนาดของเมทริกซ์  $A$  ที่กำหนดค่าของ  $m$  (แถว) และ  $n$  (คอลัมน์)

$U$  คือเมทริกซ์มุมฉาก (Orthogonal Matrix) ขนาด  $m \times m$  ซึ่งจะเป็นเมทริกซ์เชิงตั้งฉากปกติ (Orthonormal Matrix)

$\sum$  คือเมทริกซ์แนวทแยง (Diagonal Matrix) มีขนาด  $m \times n$

$V^T$  คือทรานสโพสของเมทริกซ์มุมฉาก (The Right Angle Matrix) มีขนาด  $n \times n$


การแยกค่าเอกพจน์สามารถนำมาใช้ร่วมกับอัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน เพื่อเพิ่มประสิทธิภาพของการจำแนกประเภท โดยเฉพาะอย่างยิ่งในการลดมิติของข้อมูลอินพุตขณะที่ยังคงรักษาคุณลักษณะที่สำคัญที่สุดไว้ รวมไปถึงลดระยะเวลาในการฝึกอบรมโมเดล ในการทดลองนี้ได้ใช้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

SVD เพื่อแยกคุณลักษณะจากภาพ โดยเลือกเฉพาะค่าสเปกตรัมเอกพจน์ (Singular Values) ที่สำคัญ 4 อันดับแรก ตามแนวทางการลดมิติแบบแยกส่วน ซึ่งถูกนำไปใช้ทั้งในกระบวนการฝึกอบรมและทดสอบของแบบจำลอง

ในกระบวนการแยกคุณลักษณะ ขั้นแรกจะทำการแปลงภาพสีเป็นภาพระดับสีเทาโดยเฉลี่ยค่าของช่องสัญญาณสี RGB จากนั้นแปลงภาพระดับสีเทาให้เป็นเมทริกซ์ความเข้มแสง ซึ่งมีขนาดเท่ากับ ความสูงและความกว้างของภาพอินพุต จากเมทริกซ์ดังกล่าว SVD จะประมวลผลเพื่อสร้างค่าหลัก (Singular Values) และเวกเตอร์เอกพจน์ (Singular Vectors) ซึ่งสะท้อนถึงลักษณะเชิงโครงสร้างของภาพ

เพื่อให้การประมวลผลมีประสิทธิภาพและลดความซับซ้อนของข้อมูล จะเลือกใช้เฉพาะค่าสเปกตรัมเอกพจน์ที่มีค่าสูงสุด ซึ่งถือเป็นตัวแทนของคุณลักษณะที่สำคัญจากภาพโดยไม่ทำให้ข้อมูลสูญหายอย่างมีนัยสำคัญ คุณลักษณะที่ได้จากกระบวนการ SVD จะถูกส่งต่อเป็นข้อมูลอินพุตให้กับ SVM สำหรับกระบวนการจำแนกประเภท เพื่อแยกแยะภาพที่มีหรือไม่มีปรากฏการณ์พลาสมาบับเบิล ทั้งในขั้นตอนการฝึกอบรมและการทดสอบในแบบจำลอง เราพิจารณาขนาดของค่าเอกพจน์  $N = \{5,100,200,360\}$  สำหรับ SVD และเราตั้งค่าเคอร์เนลแต่ละอันโดยใช้  $C = \{0.01,1,10,100\}$  สำหรับ SVM



รูปที่ 3.6 สถาปัตยกรรมของโมเดล SVD-SVM


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.5 วิธีการโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีนโดยใช้ข้อมูลจากเรดาร์ VHF

การผสมผสานการทำงานระหว่างโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) กับอัลกอริธึมซัพพอร์ตเวกเตอร์แมชชีน (SVM) ถือเป็นแนวทางที่มีประสิทธิภาพสูง โดยอาศัยจุดเด่นของแต่ละโมเดลร่วมกัน กล่าวคือ CNN มีความสามารถในการเรียนรู้และสกัดคุณลักษณะเชิงลึกที่จำเพาะจากข้อมูลภาพ ในขณะที่ SVM มีจุดแข็งด้านการจำแนกประเภทข้อมูลที่มีขอบเขตการแบ่งแยกที่ชัดเจนและแม่นยำ ในการออกแบบสถาปัตยกรรมของ CNN สำหรับงานวิจัยนี้ ได้กำหนดจำนวนชั้นคอนโวลูชัน (Convolutional Layers) และชั้นการรวมกลุ่ม (Pooling Layers) พร้อมทั้งกำหนดขนาดของตัวกรองไว้ 3 ขนาด ได้แก่  $3 \times 3$ ,  $5 \times 5$  และ  $7 \times 7$  โดยใช้ฟังก์ชันการเปิดใช้งานแบบเรอูลู (Rectified Linear Unit หรือ ReLU) เพื่อเพิ่มความไม่เชิงเส้นให้กับโมเดล และใช้การรวมกลุ่มแบบแมกซ์พูลลิง (Max Pooling) สำหรับลดขนาดภาพและลดมิติของคุณลักษณะที่ได้ เพื่อให้เหมาะสมกับการประมวลผลในขั้นตอนถัดไป นอกจากนี้ ในแต่ละชั้นคอนโวลูชันยังได้กำหนดค่าก้าวของหน้าต่างกรอง (Stride) เป็น  $1 \times 1$  เพื่อรักษารายละเอียดของคุณลักษณะจากภาพต้นฉบับให้ได้มากที่สุด

คุณลักษณะที่ได้จากเลเยอร์สุดท้ายของ CNN จะถูกส่งต่อไปยังโมเดล SVM สำหรับทำหน้าที่จำแนกประเภท โดยในงานวิจัยนี้ได้เลือกใช้เคอร์เนล 2 ประเภท ได้แก่ เคอร์เนลพื้นฐานเชิงรัศมี (Radial Basis Function หรือ RBF) และเคอร์เนลพหุนาม (Polynomial Kernel) โดยมีการกำหนดพารามิเตอร์สำคัญ ได้แก่ ค่าคงที่การปรับ ( $C$ ), ค่าพารามิเตอร์แกมมา ( $\gamma$ ) สำหรับเคอร์เนล RBF และระดับของพหุนาม ( $d$ ) สำหรับเคอร์เนลพหุนาม เพื่อให้เหมาะสมกับลักษณะของข้อมูลที่ใช้ในการจำแนกประเภท

เพื่อเพิ่มประสิทธิภาพของโมเดลให้สูงที่สุด ได้ดำเนินการค้นหาพารามิเตอร์ที่เหมาะสมด้วยเทคนิคการค้นหากริด (Grid Search) ซึ่งช่วยในการเลือกค่าที่เหมาะสมที่สุดของ  $C$  และ  $\gamma$  สำหรับแต่ละเคอร์เนล ส่งผลให้ระบบสามารถจำแนกข้อมูลได้อย่างแม่นยำมากยิ่งขึ้น โดยภาพรวมสถาปัตยกรรมที่นำเสนอในงานวิจัยนี้แสดงให้เห็นถึงศักยภาพของการรวมโมเดล CNN และ SVM ในการวิเคราะห์และจำแนกภาพได้อย่างมีประสิทธิภาพ โดยรายละเอียดของสถาปัตยกรรมระบบดังกล่าวจะแสดงไว้ในรูปที่ 3.7



รูปที่ 3.7 สถาปัตยกรรมของโมเดล CNN-SVM [4]

### 3.6 โมเดลโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีน เพื่อจำแนกประเภทของพลาสมาบับเบิลโดยการใช้ข้อมูลจากเรดาร์ VHF ร่วมกับรูปภาพไอโอโนแกรม (Ionograms)


#### 3.6.1 แบบจำลองโมเดล CNN-SVM โดยใช้ข้อมูลจากเรดาร์ VHF พร้อมกับไอโอโนแกรม

ในการศึกษานี้ ได้ทำการตรวจสอบผลของจำนวนชั้นในการสกัดคุณลักษณะ (Feature Extraction Layers) และขนาดของตัวกรอง  $3 \times 3$  ที่มีต่อประสิทธิภาพของแบบจำลอง ซึ่งประกอบด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ร่วมกับซัพพอร์ตเวกเตอร์แมชชีน (SVM) โดยโมเดล SVM ได้รับการฝึกจากคุณลักษณะที่ได้จากเลเยอร์สุดท้ายของ CNN ในขณะที่ชั้นการรวมกลุ่ม (Pooling Layer) ถูกนำมาใช้ในรูปแบบการรวมกลุ่มสูงสุด (Max Pooling) ขนาด  $2 \times 2$  เพื่อย่อขนาดและลดมิติของข้อมูล

ในส่วนของโมเดล SVM ได้ทดลองใช้เคอร์เนล 2 ประเภท ได้แก่ เคอร์เนลเชิงรัศมี (RBF) และเคอร์เนลพหุนาม (Polynomial Kernel) สำหรับการจำแนกประเภท ขณะที่โครงสร้างของ CNN ประกอบด้วยชั้นคอนโวลูชันจำนวนตั้งแต่ 1 ถึง 7 ชั้น โดยใช้ตัวกรองขนาด  $3 \times 3$  และกำหนดสไตรด์ (Stride) ของฟิลเตอร์เท่ากับ  $1 \times 1$  เพื่อรักษาความละเอียดของภาพให้มากที่สุด

สุดท้าย คุณลักษณะที่ได้จากภาพจะถูกปรับแต่งเพิ่มเติมผ่านชั้น Max Pooling ขนาด  $2 \times 2$  ก่อนนำไปประมวลผลด้วยโมเดล SVM การออกแบบสถาปัตยกรรมโครงข่าย CNN และ SVM ดังกล่าว มีวัตถุประสงค์เพื่อประเมินผลกระทบของจำนวนชั้นและพารามิเตอร์ต่าง ๆ ที่มีต่อความแม่นยำในการจำแนกประเภทของระบบ สถาปัตยกรรมของแบบจำลอง CNN-SVM โดยใช้ VHF พร้อมข้อมูลไอโอโนแกรมแสดงไว้ในรูปที่ 3.8

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



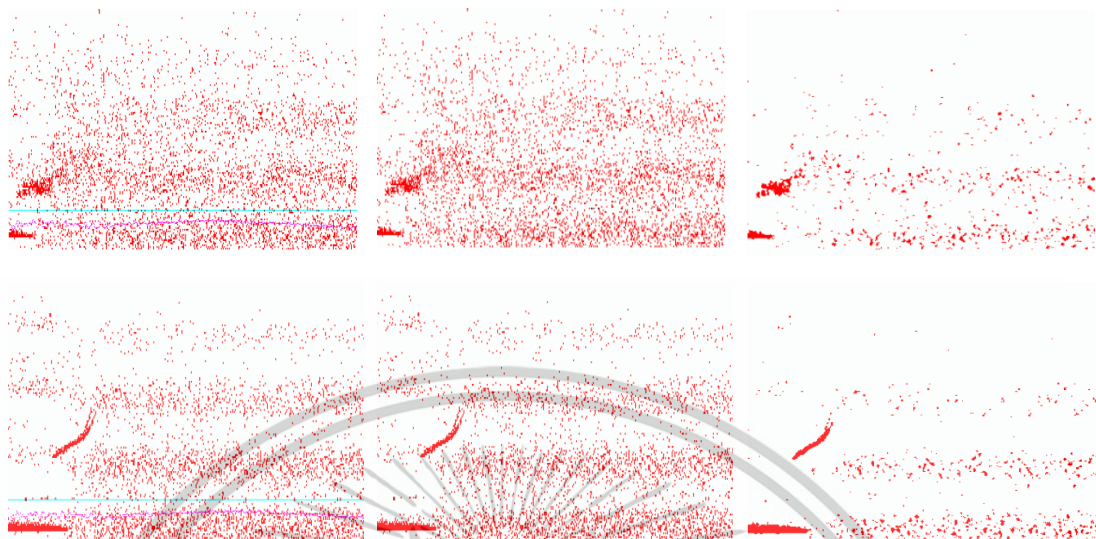
รูปที่ 3.8 สถาปัตยกรรมของแบบจำลอง CNN-SVM โดยใช้ VHF พร้อมข้อมูลไอโอโนแกรม

### 3.6.2 แบบจำลองโมเดล CNN-SVM โดยใช้ข้อมูลจากเรดาร์ VHF พร้อมกับไอโอโนแกรม โดยลดสัญญาณรบกวนบนรูปภาพไอโอโนแกรม

ในส่วนนี้ได้ดำเนินการลดสัญญาณรบกวนจากข้อมูลไอโอโนแกรมโดยใช้เทคนิคมัธยฐานฟิลเตอร์ (Median Blur Filter) เพื่อปรับปรุงคุณภาพของภาพสำหรับการประมวลผลในขั้นตอนถัดไป โดยผลลัพธ์ของกระบวนการแสดงไว้ในรูปที่ 3.9 ซึ่งรูปที่ 3.9(ก) แสดงภาพไอโอโนแกรมต้นฉบับ ซึ่งยังคงปรากฏสัญญาณรบกวนจากข้อมูลที่ไม่เกี่ยวข้อง ในขั้นตอนถัดมา (รูปที่ 3.9(ข)) ได้ทำการปรับแต่งภาพเบื้องต้น โดยเปลี่ยนพิกเซลที่มีค่าสีน้ำเงินและม่วงให้เป็นสีขาว เพื่อเตรียมภาพให้เหมาะสมสำหรับกระบวนการกรอง ขั้นตอนสุดท้ายคือการประยุกต์ใช้มัธยฐานฟิลเตอร์ขนาด  $3 \times 3$  โดยใช้หน้าต่างเลื่อน (Sliding Window) ขนาด  $1 \times 1$  เพื่อจัดสัญญาณรบกวนในระดับพิกเซล โดยไม่กระทบต่อคุณลักษณะที่สำคัญของภาพ ผลลัพธ์ของภาพหลังการกรองแสดงในรูปที่ 3.9(ค)

อย่างไรก็ตาม จากการทดลองใช้ฟิลเตอร์ขนาดใหญ่ขึ้น เช่น  $5 \times 5$  และ  $7 \times 7$  พบว่าข้อมูลเชิงโครงสร้างบางส่วนในภาพถูกลบออกไป ส่งผลให้รายละเอียดสำคัญบางประการสูญหาย จึงเลือกใช้ขนาด  $3 \times 3$  เป็นค่าที่เหมาะสมที่สุดในการลดสัญญาณรบกวนโดยยังคงรักษาข้อมูลสำคัญไว้ได้อย่างครบถ้วน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ก) ภาพต้นฉบับ                      ข) การแก้ไขข้อมูล                      ค) ลบสัญญาณรบกวนด้วยการ  
(ทำการลบเส้นสีฟ้าและสีม่วง                      ใช้ฟิลเตอร์ Median Blur  
บนรูปภาพ)

รูปที่ 3.9 ตัวอย่างการลบสัญญาณรบกวนบนรูปภาพข้อมูล


### 3.6.3 แบบจำลองโมเดล CNN-SVM โดยใช้ข้อมูลจากเรดาร์ VHF พร้อมกับไอโอโนแกรม โดยลบสัญญาณรบกวนบนรูปภาพไอโอโนแกรมโดยการใช้ชั้นจำนวนการคอนโวลูชัน 2 ชั้น (Multi-Convolutional)

ในแบบจำลองการจำแนกประเภทข้อมูลที่พัฒนาโดยใช้โครงข่ายประสาทเทียมเชิงคอนโวลูชัน ร่วมกับเครื่องเวกเตอร์สนับสนุน (CNN-SVM) ซึ่งใช้ข้อมูลจากเรดาร์ VHF ร่วมกับข้อมูลไอโอโนแกรม โครงสร้างของ CNN ถูกออกแบบมาเพื่อดึงและสกัดคุณลักษณะสำคัญของข้อมูลภาพผ่านเลเยอร์คอนโวลูชันแบบลำดับต่อเนื่อง โดยแผนผังของโครงสร้างดังกล่าวแสดงไว้ในรูปที่ 3.10

ในกระบวนการสกัดคุณลักษณะ เริ่มต้นด้วยเลเยอร์คอนโวลูชันจำนวนสองชั้น ซึ่งแต่ละชั้นใช้ตัวกรองขนาด  $3 \times 3$  และกำหนดสไตรด์ (Stride) เท่ากับ  $1 \times 1$  เพื่อรักษาความละเอียดของแผนที่คุณลักษณะ (Feature Map) ให้สูงที่สุด จากนั้นจะมีการเพิ่มจำนวนเลเยอร์คอนโวลูชันเพื่อเพิ่มความลึกและความซับซ้อนในการเรียนรู้คุณลักษณะ โดยทุกเลเยอร์จะใช้ฟังก์ชันการเปิดใช้งานแบบ ReLU เพื่อเพิ่มความไม่เชิงเส้นให้กับแบบจำลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ภายหลังการประมวลผลผ่านเลเยอร์คอนโวลูชัน จะมีการใช้กระบวนการรวมกลุ่มแบบ Max Pooling โดยใช้ตัวกรองขนาด  $2 \times 2$  เพื่อลดขนาดของแผนที่คุณลักษณะ ลดความซับซ้อนของข้อมูล และช่วยประหยัดทรัพยากรในการประมวลผล จากนั้นแผนที่คุณลักษณะจะถูกแปลงเป็นเวกเตอร์แบบแบน (Flattened Vector) เพื่อเตรียมสำหรับการป้อนเข้าสู่โมเดล SVM สำหรับขั้นตอนการจำแนกประเภท โมเดล SVM ที่ใช้จะมีการกำหนดชนิดของเคอร์เนล (Kernel) เป็นประเภท  $C$  พร้อมทั้งระบุพารามิเตอร์  $\gamma$  โดยอิงตามค่าที่ได้รับการปรับแต่ง (Tuned Parameters) จากการทดลองก่อนหน้า เพื่อเพิ่มประสิทธิภาพในการจำแนกข้อมูลในมิติสูง และช่วยให้แบบจำลองสามารถแยกแยะกลุ่มข้อมูลได้อย่างแม่นยำยิ่งขึ้น



รูปที่ 3.10 สถาปัตยกรรมของแบบจำลอง CNN-SVM โดยการเพิ่มโครงสร้างเลเยอร์ Convolutional ของ CNN เพื่อค้นหาแผนที่คุณลักษณะ (Multi – Convolutional layer)

### 3.7 การตรวจสอบความถูกต้องของข้อมูลเรดาร์ VHF และไอโอโนซอนด์

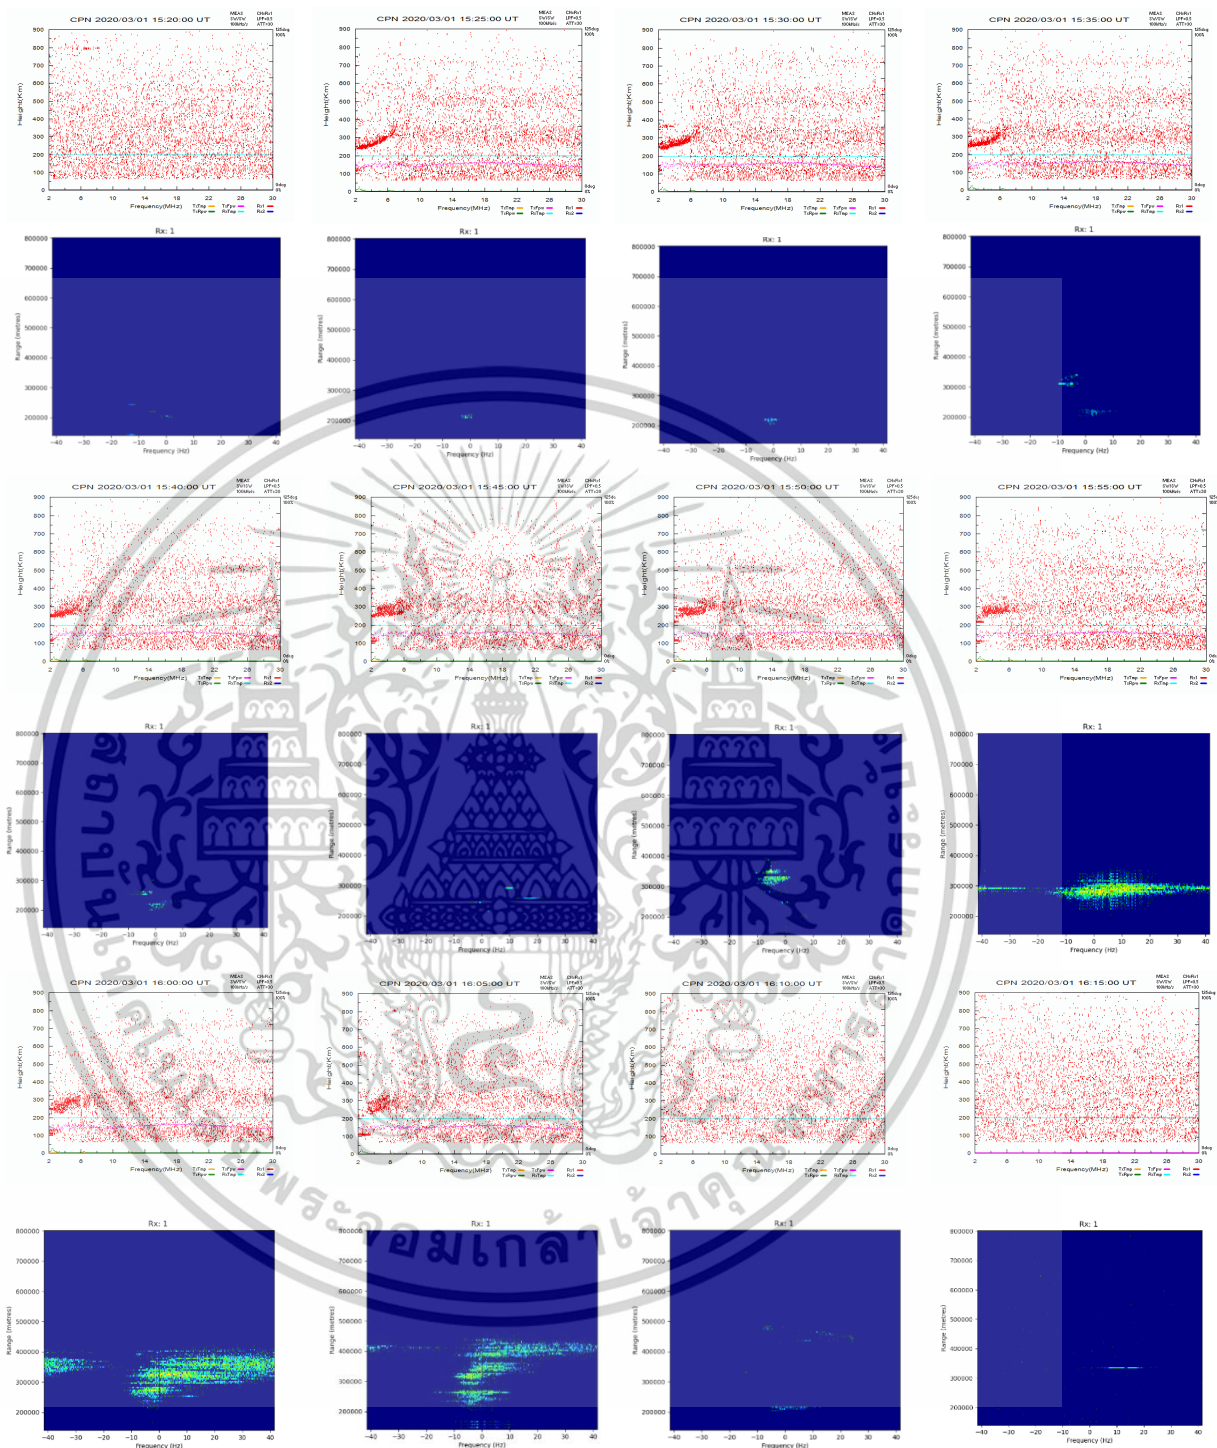
ก่อนการนำข้อมูลของไอโอโนซอนด์มาใช้ เราได้ทำการวิเคราะห์ข้อมูลจากเรดาร์ VHF และไอโอโนซอนด์ในเชิงสถิติเพื่อตรวจสอบความถูกต้องของข้อมูลที่เลือกในการศึกษานี้ จะใช้ข้อมูลเดือนมีนาคม ปี ค.ศ. 2020



รูปที่ 3.11 สถิติการตรวจสอบข้อมูลเรดาร์ VHF และไอโอโนซอนด์ในเดือนมีนาคม ปีค.ศ. 2020

หลังจากการตรวจสอบสถิติของข้อมูลแล้วจะแสดงตัวอย่างข้อมูลจากอุปกรณ์ทั้งสองเมื่อสามารถตรวจจับความไม่ปกติบนชั้นบรรยากาศไอโอโนสเฟียร์ได้ โดยแสดงข้อมูลในรูปที่ 3.12

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.12 ตัวอย่างข้อมูลจากเรดาร์ VHF และไอโอโนซอนด์ เมื่อตรวจพบความผิดปกติที่เกิดขึ้นในชั้นบรรยากาศไอโอโนสเฟียร์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.8 การวิเคราะห์ทิศทางการก่อตัว การเคลื่อนตัว รวมไปถึงจำนวนของพลาสมา บับเบิลด้วยข้อมูลจากเรดาร์ VHF

#### 3.8.1 วิเคราะห์ทิศทางการเคลื่อนตัวของ EPB


ทิศทางการเคลื่อนที่ของพลาสมาบริเวณเส้นศูนย์สูตร โดยทั่วไปมีลักษณะดังนี้ ในแนวราบ (Eastward) โดยปกติ EPB จะเคลื่อนที่ไปทางทิศตะวันออกตามแนวเส้นศูนย์สูตรแม่เหล็ก หลังช่วงพระอาทิตย์ตก ด้วยความเร็วประมาณ 50–200 เมตรต่อวินาที การเคลื่อนที่นี้ขับเคลื่อนโดยสนามไฟฟ้าโซนที่มีการเพิ่มค่าก่อนการกลับทิศของสนามไฟฟ้าทิศตะวันออก และได้รับอิทธิพลจากความไม่เสถียรของเรย์ลี-เทย์เลอร์ในชั้น F ของบรรยากาศไอโอโนสเฟียร์ ถัดมา คือแนวตั้ง (Vertical Motion) EPB สามารถเคลื่อนที่ในแนวตั้งขึ้น (Upward) โดยเฉพาะในช่วงก่อนรุ่งสาง ระหว่างพายุแม่เหล็กโลก หรือภายใต้สภาวะที่สนามไฟฟ้ามีความแปรปรวน และแนวกลับทิศ (Westward Drift) ในบางกรณี EPB อาจเคลื่อนที่ไปทางทิศตะวันตก ซึ่งสามารถเกิดขึ้นได้จากลมพายุที่พัดไปทางทิศตะวันตก หรือการเปลี่ยนแปลงในพลวัตของสนามไฟฟ้าในชั้นบรรยากาศไอโอโนสเฟียร์

ในงานวิจัยก่อนหน้านี้มีการใช้อุปกรณ์หลากหลายชนิดในการวิเคราะห์ทิศทางการเคลื่อนตัวของพลาสมาบับเบิล เช่น จากการวิเคราะห์ความผันผวนของ TEC ในตัวรับ GNSS หลายตัว (อย่างน้อยสามตัว) ซึ่งสามารถระบุความล่าช้าของเวลาในการผ่านพลาสมาบับเบิลได้ ทำให้สามารถคำนวณทั้งความเร็วและทิศทาง (มุมราบ) ของการเคลื่อนที่ EPB [45] [46] [47] โดยการซ้อนชั้นละติจูดแคบ ๆ จากภาพท้องฟ้าทั้งหมด 630 นาโนเมตร ทำให้ EPB ปรากฏเป็นแถบสีเข้มเอียง ความลาดชันจะให้ความเร็วการเคลื่อนที่ในแนวโซน (ตะวันออก-ตะวันตก) [48] [49]

การศึกษาปรากฏการณ์พลาสมาบับเบิลโดยใช้ข้อมูลจากเรดาร์ VHF นั้นสามารถใช้เพื่อบ่งชี้ถึงทิศทางการเคลื่อนตัวของ EPB ในการทดลองนั้นเราได้ใช้ข้อมูลทั้งหมด 12 วัน โดยจะแบ่งออกเป็นในปีค.ศ. 2020 DOY = { 20, 33, 44, 65, 67, 68, 69, 70, 71, 72} สำหรับการวิเคราะห์ทิศทางการเคลื่อนตัวของไปยังทิศตะวันออก และข้อมูลในปีค.ศ. 2022 DOY 15 (Hunga Tonga) จากเหตุการณ์ที่ภูเขาไฟฮังกา ตองกา ปะทุ และในปี ค.ศ. 2024 DOY 132 หลังจากการเกิดพายุแม่เหล็กโลก (Mother's Day, Geomagnetic Storm) สำหรับการวิเคราะห์ทิศทางการเคลื่อนตัวของไปยังทิศตะวันตก (Reverse direction) จากตัวอย่างดังรูปที่ 3.13 จะเห็นได้ว่าโดยปกติแล้ว EPB จะเริ่มเกิดจากทางด้านทิศตะวันตกและจะค่อย ๆ เคลื่อนที่ไปยังทิศตะวันออก ซึ่งจะสังเกตได้จาก Fd 1 ก่อน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อเทียบที่ ณ เวลาเดียวกัน แต่ถ้า EPB เริ่มก่อตัวขึ้นจากทางทิศตะวันออกก่อนแล้วเคลื่อนตัวกลับทิศทางมายังทิศตะวันตก จะสามารถสังเกตได้จากปริม Fd 5



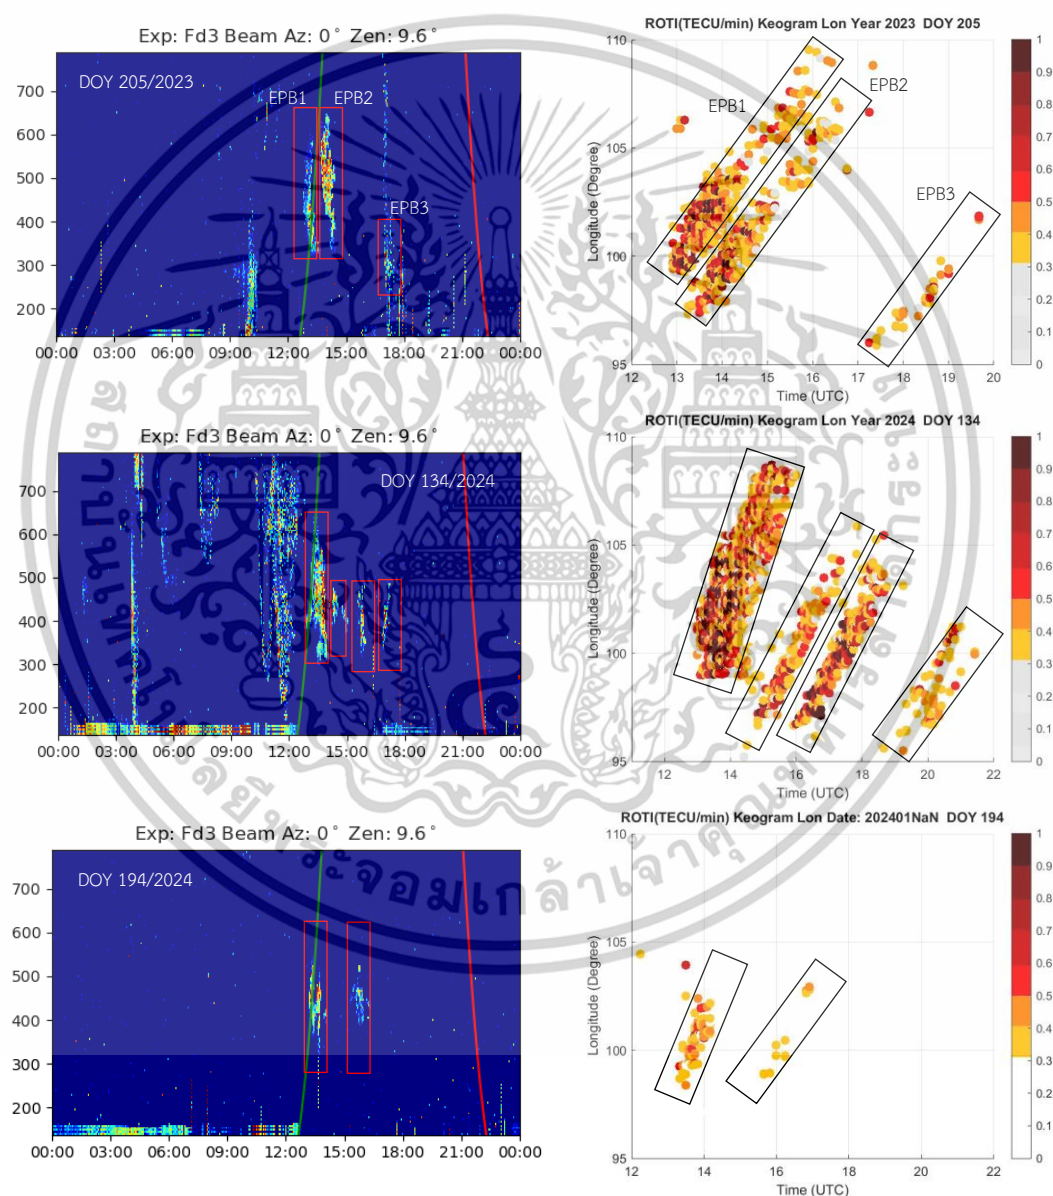
- ก) EPB เริ่มก่อตัวจากทางด้านทิศตะวันตกและเคลื่อนตัวไปยังทิศตะวันออก
- ข) EPB เริ่มก่อตัวจากทางด้านทิศตะวันออกและเคลื่อนตัวไปยังทิศตะวันตก

รูปที่ 3.13 ตัวอย่างการวิเคราะห์ทิศทางการก่อตัวและการเคลื่อนที่ของ EPB

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

### 3.8.2 วิเคราะห์จำนวนของ EPB ที่เกิดขึ้นด้วยข้อมูลจากเรดาร์ VHF

ในแต่ละเหตุการณ์ที่เกิด EPB นั้นเราสามารถวิเคราะห์จำนวนของ EPB ที่เกิดขึ้นในแต่ละวันโดยการใช้ข้อมูลจากเรดาร์ VHF ตัวอย่างการวิเคราะห์จำนวน EPB จะแสดงดังรูปที่ 3.14 และเปรียบเทียบกับข้อมูลจาก TEC Keogram ซึ่งแสดงให้เห็นถึงความสัมพันธ์ระหว่าง 2 อุปกรณ์ ในการตรวจพบ EPB



ก) ข้อมูลจากเรดาร์ VHF

ข) ข้อมูลจาก GNSS

รูปที่ 3.14 ตัวอย่างการวิเคราะห์จำนวนของ EPB ด้วยข้อมูลจากเรดาร์ VHF และ GNSS

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 4

### ผลการวิจัยและอภิปราย

ในบทนี้ได้นำเสนอหน้าตาต่างอินเทอร์เฟซของซอฟต์แวร์ที่พัฒนาขึ้นสำหรับการจำแนกประเภทของฟองพลาสมา รวมถึงผลการทดลองของโมเดลที่ได้ออกแบบและพัฒนา โดยใช้ชุดข้อมูลจากสถานีตรวจวัดของสถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง วิทยาเขตชุมพร ประเทศไทย

ข้อมูลที่ใช้สำหรับการฝึกอบรมโมเดลประกอบด้วยภาพจากวันที่ 1 เดือนมีนาคม ค.ศ. 2020 ถึงวันที่ 30 เดือนมีนาคม ค.ศ. 2020 รวมทั้งสิ้น 13,650 ภาพ ส่วนข้อมูลที่ใช้สำหรับการทดสอบโมเดลประกอบด้วยภาพจากวันที่ 1 เดือนพฤศจิกายน ค.ศ. 2022 ถึงวันที่ 30 เดือนพฤศจิกายน ค.ศ. 2022 จำนวน 6,814 ภาพ คิดเป็นประมาณร้อยละ 30 ของข้อมูลทั้งหมด โดยข้อมูลภาพทั้งหมดถูกจัดแบ่งออกเป็น 3 คลาส ได้แก่ คลาส 0 (ไม่มีฟองพลาสมา), คลาส 1 (ไม่แน่ใจ) และคลาส 2 (มีฟองพลาสมา)

เนื่องจาก SVM ถูกออกแบบมาเพื่อการจำแนกประเภทแบบไบนารี จึงได้มีการประยุกต์เทคนิค ‘หนึ่งต่อทั้งหมด’ (One-vs-All: OvA) หรือที่เรียกว่า ‘หนึ่งต่อที่เหลือ’ (One-vs-Rest: OvR) เพื่อให้สามารถรองรับการจำแนกประเภทแบบหลายคลาสได้ โดยวิธีนี้จะเปลี่ยนปัญหาการจำแนกแบบหลายคลาสให้เป็นชุดของปัญหาไบนารีหลายชุด โดยในแต่ละชุดจะทำการฝึกโมเดลแยกกันระหว่างหนึ่งคลาสกับกลุ่มของคลาสอื่น ๆ การฝึกแยกเช่นนี้มีข้อดีคือสามารถเพิ่มประสิทธิภาพของแบบจำลองและเพิ่มความแม่นยำในการจำแนกประเภทในกรณีที่มีหลายคลาส ซึ่งในงานวิจัยนี้ได้ใช้วิธีการของหนึ่งต่อทั้งหมด


ส่วนถัดไปของบทนี้จะนำเสนอผลการทดลองที่ได้จากการเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกประเภท 3 รูปแบบ ได้แก่ โมเดล SVM, โมเดลที่ผสมผสานการลดมิติด้วย SVD (SVD-SVM) และโมเดลที่ใช้โครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับ SVM (CNN-SVM)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.1 ผลการวิเคราะห์ระดับความสูงและความเร็วในการเคลื่อนตัวของพลาสมาบับเป็ลด้วยข้อมูลเรดาร์ VHF

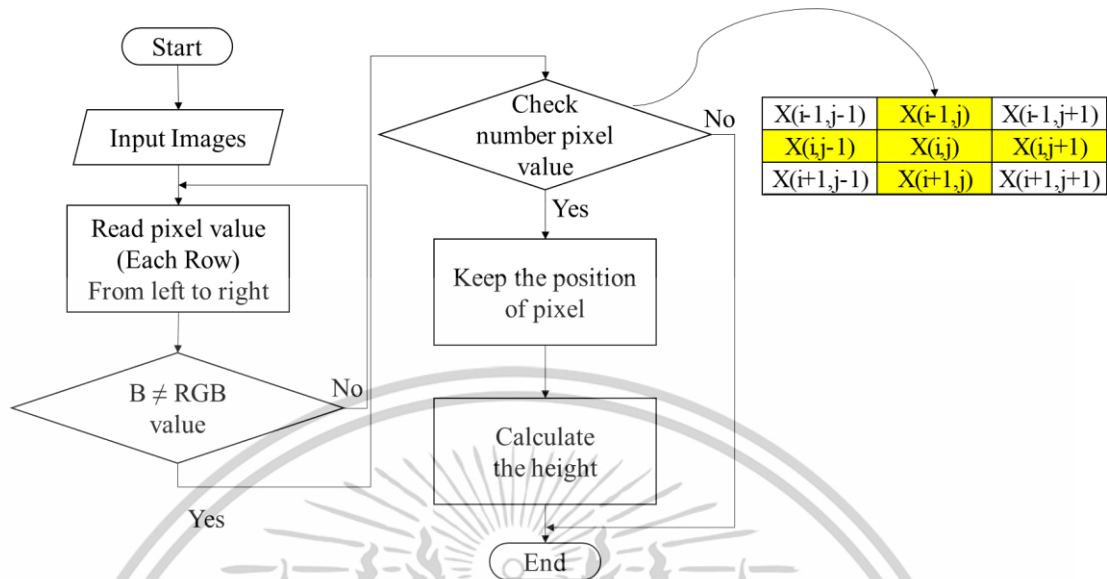
### 4.1.1 ผลการคำนวณระดับความสูงและความเร็วในการเคลื่อนตัวของพลาสมาบับเป็ลด้วยข้อมูลเรดาร์ VHF

การคำนวณระดับความสูงของพลาสมาบับเป็ลด้วยข้อมูลเรดาร์ VHF นั้นแสดงดังรูปที่ 4.1 โดยจะทำการแปลงค่าตำแหน่งพิกเซลไปเป็นระดับความสูง ซึ่งรูปภาพข้อมูลจากเรดาร์ VHF นั้นมีขนาดเท่ากับ  $500 \times 830 \times 3$  ในระดับความสูงของพลาสมาบับเป็ลจากข้อมูลเรดาร์ VHF นั้น 100 กิโลเมตรจากพื้นผิวโลกที่จำนวนค่าพิกเซลจากรูปภาพอยู่ที่ 60 พิกเซล ดังนั้นใน 1 พิกเซลนั้นจะมีค่าความสูงอยู่ที่ 1.6667 กิโลเมตร ซึ่งจะสามารถคำนวณระดับความสูงของพลาสมาบับเป็ลเพื่อทำการวิเคราะห์ความเร็วในการเคลื่อนตัวขึ้นในแนวตั้งของพลาสมาบับเป็ลได้ โดยแอมพลิจูดของการคำนวณระดับความสูงของพลาสมาจะแสดงดังรูปที่ 4.2




รูปที่ 4.1 ตัวอย่างการคำนวณความสูงของพลาสมาบับเป็ล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 4.2 บล็อกไดอะแกรมของการคำนวณระดับความสูงของพลาสติกเบิ้ล

จากภาพที่แสดงในรูปที่ 4.2 เป็นกระบวนการในการคำนวณระดับความสูงของพลาสติกเบิ้ล โดยอัลกอริธึมที่ใช้ในโปรแกรมจะดำเนินการผ่านการเลื่อนหน้าต่างวินโดว์ (Window) ไปบนข้อมูลภาพ เพื่อค้นหาตำแหน่งพิกเซลที่มีค่าตรงกับค่าที่กำหนดไว้ล่วงหน้า เมื่อโปรแกรมตรวจพบพิกเซลที่มีค่าเท่ากับค่าที่กำหนด วินโดว์จะทำการตรวจสอบค่าพิกเซลในบริเวณโดยรอบตำแหน่งพิกเซลหลักนั้น หากพบว่ามีพิกเซลที่มีค่าคล้ายกันในบริเวณใกล้เคียงมากกว่า 3 ตำแหน่ง โปรแกรมจะพิจารณาว่าตำแหน่งดังกล่าวมีความน่าเชื่อถือเพียงพอ และจะทำการบันทึกตำแหน่งพิกเซลดังกล่าวไว้เพื่อใช้ในการคำนวณระดับความสูงของพลาสติกเบิ้ล โดยค่าตำแหน่งพิกเซลที่ได้จะถูกแปลงเป็นค่าระดับความสูงผ่านการคูณกับอัตราส่วนความสูงต่อพิกเซล (Height-Per-Pixel Ratio) ซึ่งได้อธิบายไว้ในส่วนก่อนหน้านี้ ผลลัพธ์ที่ได้จากกระบวนการดังกล่าวจะให้ค่าประมาณของระดับความสูงของพลาสติกเบิ้ล และสามารถพิจารณาได้จากตัวอย่างผลการคำนวณที่แสดงในรูปที่ 4.3



รูปที่ 4.3 ผลการคำนวณระดับความสูงของพลาสมาบับเบิล

เมื่อได้ทำการคำนวณระดับความสูง ( $R_a$ ) ของพลาสมาบับเบิลแล้ว โดยการนำค่าระดับความสูงสูงสุด ณ เวลาสุดท้ายที่พลาสมาหายไปลบกับค่าระดับความสูงสูงสุดของพลาสมาบับเบิล ณ เวลาเริ่มต้น ขั้นตอนถัดไปจะทำการคำนวณความเร็ว ( $V$ ) ในการเคลื่อนตัวของพลาสมาบับเบิลในแต่ละช่วงเวลา ( $T$ ) ที่เกิดความผิดปกตินี้ โดยวิธีการคำนวณความเร็ว ( $V$ ) จะคำนวณจากระดับความสูง  $R_a$  ของแต่ละลูกหารด้วยระยะเวลา ( $T$ ) ทั้งหมดที่เกิดปรากฏการณ์ EPB จะแสดงดังสมการที่ (4.1)

$$R_a = Max_{Hn+1} - Max_{Hn} \quad (4.1)$$

$$T = t_{stop} - t_{start}$$

$$V = \frac{R_a}{T}$$

โดยที่  $R_a$  คือระดับของความสูงของพลาสมาบับเบิล (กิโลเมตร)

$T$  คือระยะเวลาที่เกิดพลาสมาบับเบิล (วินาที)

$V$  คือความเร็วที่พลาสมาบับเบิลเคลื่อนตัว (เมตรต่อวินาที)

$Max_{Hn}$  คือระดับความสูงสูงสุดของพลาสมาบับเบิลเกิดขึ้น ณ ช่วงเริ่มต้น และช่วงก่อนที่จะหายไปตามลำดับ (กิโลเมตร)

$t$  คือเวลาเริ่มต้นที่พลาสมาบับเบิลเกิดขึ้นและหายไป (วินาที)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผลลัพธ์และตัวอย่างการคำนวณความเร็วโดยในการคำนวณนั้นจะใช้ระดับความของพลาสมา บับเบิลบริเวณด้านล่างของความผิดปกติ (Bottom Side) ซึ่งจากสมการที่ (4.1) จะได้ค่าความเร็วดังนี้

$$\begin{aligned} R_a &= Max_{H2} - Max_{H1} \\ &= 605.50 \text{ กิโลเมตร} - 400.55 \text{ กิโลเมตร} \\ &= 204.95 \text{ กิโลเมตร (204,950 เมตร)} \end{aligned}$$


$$\begin{aligned} T &= t_{stop} - t_{start} \\ &= 15.40 \text{ UTC} - 13.11 \text{ UTC} \\ &= 2.29 \text{ ชั่วโมง} \\ &= (2 \times 60 \times 60) + (29 \times 60) \\ &= 7200 + 1740 \\ &= 8940 \text{ วินาที} \end{aligned}$$

$$\begin{aligned} V &= \frac{R_a}{T} \\ &= \frac{204950}{8940} \\ &= 22.93 \text{ เมตร/วินาที} \end{aligned}$$

ดังนั้นความเร็วในการเคลื่อนตัวของพลาสมาบับเบิลมีความเร็วที่ 22.93 เมตรต่อวินาที

#### 4.1.2 ผลการวิเคราะห์ความเร็วการเคลื่อนตัวในแนวตั้ง

ในวิเคราะห์ความเร็วการเคลื่อนตัวในแนวตั้ง (Vertical drift velocity) ของพลาสมาบับเบิลนั้น ผู้วิจัยได้ทำการออกแบบอัลกอริทึมในการคำนวณความเร็วโดยจะใช้ระดับความสูงด้านบน (Topside) และระดับความสูงด้านล่าง (Bottomside) จากนั้นจะทำการหารระดับความสูงค่ากึ่งกลาง (Centroid) ทุก ๆ รูปภาพที่ได้รับจากเรดาร์ VHF สมการในการคำนวณหาได้จากสมการที่ (4.2)



รูปที่ 4.4 ตัวอย่างวิธีการคำนวณการเคลื่อนตัวของ EPB ในแนวตั้ง

$$Al_{Centroid(n)} = \frac{\left[ \frac{Al_{top} + Al_{bott}}{2} \right] + \left[ \frac{Al_{left} + Al_{right}}{2} \right]}{2} \quad (4.2)$$

$$V_{drift} = \frac{Al_{Centroid(n)}}{T_{n+1} - T_n}$$

$$Mean_{V_{e(drift)}} = \frac{V_{drift(n)} + V_{drift(n+1)} + \dots}{N_{V_{drift}}}$$

โดยที่  $Al_{Centroid(n)}$  คือระดับความสูงของ EPB (เมตร) ของแต่ละภาพ QL

$V_{drift}$  คือความเร็วการเคลื่อนตัวของ EPB ในแนวตั้ง (เมตรต่อวินาที)

$T$  คือเวลาของรูปภาพ QL ที่ตรวจพบ EPB (วินาที)

$Mean_{V_{e(drift)}}$  คือความเร็วในการเคลื่อนตัวของ EPB ในแนวตั้ง (เมตรต่อวินาที)

$n$  คือลำดับของจำนวนรูปภาพ QL ที่ตรวจพบ EPB

การคำนวณหาจุดกึ่งกลางของระดับความสูง  $Al_{Centroid(n)}$  ทั้งลูกของ EPB จะคำนวณได้จาก ระดับความสูงด้านบน ( $Al_{top}$ ) ลบด้วยระดับความสูงด้านล่าง ( $Al_{bott}$ ) หาค่าเฉลี่ยสอง จากนั้นนำไปบวกกับความสูงด้านซ้าย ( $Al_{left}$ ) และด้านขวา ( $Al_{right}$ ) เช่นเดียวกัน จึงจะได้ค่ากึ่งกลางของระดับความสูงแต่ละลูก จากนั้นทำการคำนวณค่าความเร็วในการเคลื่อนตัวในแนวตั้ง ( $V_{drift}$ ) ด้วยค่า


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

กึ่งกลางของระดับความสูง ( $Al_{Centroid(n)}$ ) ทหารด้วยระยะเวลาที่เกิดปรากฏการณ์ EPB ( $T_n$ ) ค่าความเร็วในการเคลื่อนตัวแนวตั้งเฉลี่ยสามารถหาได้จากการนำค่ากึ่งกลางของระดับความสูง ( $Ve_{drift(n)}$ ) แต่ละลูกมาบวกกันแล้วหารด้วยจำนวนความเร็วทั้งหมด ( $N_{Ve_{drift}}$ )

จากนั้นเปรียบเทียบความเร็วในการเคลื่อนตัวของ EPB ในแนวตั้ง ( $Ve_{drift}$ ) ที่คำนวณจากไอโอโนแกรมโดยใช้พารามิเตอร์ความสูงบริเวณด้านล่าง ( $h'F$ ) เทียบกับเวลา สมการในการคำนวณหาได้จากสมการที่ (4.3)

$$Ve_{drift} = \frac{dh'F}{dt} \quad (4.3)$$

ผลลัพธ์จากการคำนวณแสดงไว้ในรูปที่ 4.5 ซึ่งแสดงการเปรียบเทียบความเร็วในการเคลื่อนที่ของปรากฏการณ์ที่ตรวจวัดได้จากอุปกรณ์ทั้งสองชนิด โดยผลการวิเคราะห์พบว่าค่าความเร็วจากการคำนวณของทั้งสองอุปกรณ์มีความสอดคล้องกันอย่างมีนัยสำคัญ รูปดังกล่าวนำเสนอข้อมูลจากการสังเกตการณ์จำนวน 10 วัน ได้แก่ วันที่ 1, 3, 4, 9, 12, 14, 16, 17, 20 และ 21 เดือนพฤศจิกายน พ.ศ. 2565 ซึ่งในช่วงเวลาดังกล่าว อุปกรณ์ทั้งสองสามารถตรวจพบความผิดปกติที่เกิดขึ้นในชั้นไอโอโนสเฟียร์ได้ตรงกัน แสดงให้เห็นถึงความน่าเชื่อถือและความสัมพันธ์ของผลการตรวจวัดระหว่างอุปกรณ์ทั้งสองประเภท



รูปที่ 4.5 ผลลัพธ์ความเร็วการเคลื่อนตัวของ EPB ในแนวตั้งข้อมูลจากเรดาร์ VHF เทียบกับไอโอโนซอนด์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## 4.2 ผลการจำลองการจำแนกประเภทของพลาสมาบับเป็ลด้วยวิธีการที่นำเสนอ

### 4.2.1 ผลการจำลองด้วยวิธีการซัพพอร์ตเวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF

ในแบบจำลองการจำแนกภาพครั้งนี้ รูปภาพจากเรดาร์ VHF ถูกป้อนเข้าสู่แบบจำลอง SVM โดยตรง ซึ่งถูกออกแบบให้เป็นแนวทางพื้นฐานในการประเมินประสิทธิภาพเบื้องต้น โดยเลือกใช้ฟังก์ชันเคอร์เนลจำนวน 2 ชนิด ได้แก่ เคอร์เนลแบบ RBF และเคอร์เนลพหุนาม (Polynomial Kernel) เพื่อใช้ในการจำแนกปรากฏการณ์พลาสมาบับเป็ล

ตารางที่ 4.1 แสดงผลการทดสอบความแม่นยำของแบบจำลอง SVM เมื่อใช้เคอร์เนล RBF โดยมีการปรับค่าพารามิเตอร์  $C$  และ  $\gamma$  (แกมมา) ในหลายค่าร่วมกัน ผลการทดลองแสดงให้เห็นว่า ความแม่นยำสูงสุดในการจำแนกอยู่ที่ร้อยละ 86.67 ซึ่งได้จากการตั้งค่าพารามิเตอร์  $C = 10$  และ  $C = 100$  ร่วมกับค่า  $\gamma = 0.01$  แม้ว่าค่าความแม่นยำจะเท่ากันในทั้งสองกรณีข้างต้น แต่พบว่าแบบจำลองที่ใช้  $C = 10$  มีระยะเวลาในการประมวลผลน้อยกว่าแบบจำลองที่ใช้  $C = 100$  จึงสามารถสรุปได้ว่า การเลือกใช้ค่าพารามิเตอร์ที่เหมาะสมไม่เพียงแต่ส่งผลต่อความแม่นยำของแบบจำลองเท่านั้น แต่ยังส่งผลต่อประสิทธิภาพในการประมวลผลอีกด้วย ซึ่งเป็นปัจจัยสำคัญในการนำแบบจำลองไปใช้งานในระบบตรวจจับจริงที่ต้องการความรวดเร็วและแม่นยำในเวลาเดียวกัน

ตารางที่ 4.1 ความแม่นยำของโมเดล SVM โดยเคอร์เนล RBF สำหรับค่าแกมมาที่แตกต่างกัน

พารามิเตอร์	ค่าความแม่นยำ (เปอร์เซ็นต์)			
	$C = 0.01$	$C = 1$	$C = 10$	$C = 100$
$\gamma = 0.01$	85.89	86.52	86.67	86.67
$\gamma = 1$	85.64	85.73	85.81	85.91
$\gamma = 10$	85.12	85.33	85.56	85.79
$\gamma = 100$	84.92	85.11	85.47	85.47

ในส่วนของการทดลองด้วยเคอร์เนลพหุนาม (Polynomial kernel) ได้ทำการประเมินประสิทธิภาพของแบบจำลอง SVM ภายใต้การกำหนดระดับเป็น  $d = \{0.01, 1, 10, 100\}$  และใช้ชุดพารามิเตอร์  $C$  ชุดเดียวกัน ค่าระดับของพหุนาม ( $d$ ) และค่าคงที่  $C$  ซึ่งเป็นตัวควบคุมสมดุลระหว่างความแม่นยำในการจำแนกและความสามารถในการเรียนรู้ของแบบจำลอง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.2 แสดงผลการจำแนกที่ได้จากการใช้ Polynomial kernel ซึ่งผลลัพธ์แสดงให้เห็นว่าความแม่นยำสูงสุดอยู่ที่ร้อยละ 82.33 เมื่อกำหนดค่าพารามิเตอร์  $C = 0.01$  และ  $d = 1$

**ตารางที่ 4.2** ความแม่นยำของโมเดล SVM โดยเคอร์เนลพหุนาม (Polynomial Kernel) ที่มีระดับ (Degree) แตกต่างกัน

พารามิเตอร์	ค่าความแม่นยำ (เปอร์เซ็นต์)			
	$C = 0.01$	$C = 1$	$C = 10$	$C = 100$
$d = 0.01$	81.96	81.74	80.53	80.88
$d = 1$	<b>82.33</b>	82.15	82.07	81.96
$d = 10$	82.14	82.02	81.91	81.82
$d = 100$	82.02	81.94	81.73	81.64

เมื่อทำการเปรียบเทียบระหว่างผลลัพธ์ของเคอร์เนล RBF และเคอร์เนลพหุนาม จะพบว่าแบบจำลองที่ใช้เคอร์เนล RBF ให้ความแม่นยำสูงกว่าทุกกรณีของเคอร์เนล polynomial อย่างสม่ำเสมอ นอกจากนี้ เคอร์เนล RBF ยังมีความสามารถในการจัดการกับข้อมูลที่ไม่เป็นเส้นตรงได้ดีกว่า เนื่องจากสามารถสร้างขอบเขตการแยกข้อมูลในลักษณะที่ยืดหยุ่นและมีความโค้งในมิติลักษณะเฉพาะ (Feature Space) ได้ดีกว่าเคอร์เนลพหุนาม

ในเชิงประสิทธิภาพการประมวลผล แบบจำลองที่ใช้เคอร์เนลพหุนามมีแนวโน้มใช้เวลามากกว่าในการประมวลผลเมื่อเพิ่มค่าระดับของเนลพหุนาม โดยเฉพาะในระดับที่สูงขึ้น ซึ่งส่งผลกระทบต่อความเร็วในการจำแนก ทั้งนี้เนื่องจากลักษณะของเคอร์เนลพหุนาม ที่มีความซับซ้อนทางคณิตศาสตร์มากกว่าเคอร์เนล RBF

จากผลการวิเคราะห์ข้างต้น สามารถสรุปได้ว่าเคอร์เนล RBF มีความเหมาะสมมากกว่าในบริบทของการจำแนกภาพจากเรดาร์ VHF เพื่อระบุพลาสมาบับเบิล เนื่องจากให้ค่าความแม่นยำสูงกว่า และยังมีประสิทธิภาพด้านเวลาในการประมวลผลที่ดีกว่า โดยเฉพาะเมื่อกำหนดค่าพารามิเตอร์อย่างเหมาะสม

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


#### 4.2.2 ผลการจำลองด้วยวิธีการแยกค่าเอกฐานร่วมกับการซัพพอร์ตเวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF

การแยกค่าเอกพจน์ (SVD) เมื่อประยุกต์ร่วมกับแบบจำลอง SVM สามารถช่วยเพิ่มประสิทธิภาพในการประมวลผลข้อมูลที่มีมิติสูงและมีจำนวนคุณลักษณะจำนวนมากได้อย่างมีนัยสำคัญ โดยปกติแล้วการใช้ SVM เพียงอย่างเดียวกับข้อมูลที่มีมิติสูง อาจทำให้เกิดปัญหาโอเวอร์ฟิตติ้ง (Overfitting) และมีความสามารถในการสรุปผล (Generalization) ที่จำกัด ซึ่งส่งผลให้ประสิทธิภาพของแบบจำลองในการจำแนกหรือทำนายข้อมูลใหม่ลดลง

SVD มีบทบาทสำคัญในการลดมิติของข้อมูลโดยการคัดเลือกเฉพาะคุณลักษณะที่มีความสำคัญเชิงข้อมูลมากที่สุด ซึ่งช่วยลดความซับซ้อนของข้อมูลต้นฉบับ และลดความเสี่ยงของการเกิดโอเวอร์ฟิต โดยยังคงรักษาคุณลักษณะสำคัญไว้ในระดับที่เพียงพอต่อการเรียนรู้ของแบบจำลอง ผลที่ตามมาคือแบบจำลองสามารถเรียนรู้ข้อมูลได้อย่างมีประสิทธิภาพมากขึ้น และมีความสามารถในการจำแนกที่ดีขึ้น

จากผลการทดลองซึ่งแสดงไว้ในรูปที่ 4.7 พบว่า เมื่อเพิ่มจำนวนค่าเอกพจน์ที่ใช้ในการสร้างเมทริกซ์ของภาพ ความชัดเจนของภาพที่ได้จะเพิ่มขึ้นตามลำดับ โดยภาพต้นฉบับมีค่าเอกพจน์ที่ไม่เป็นศูนย์ทั้งหมดประมาณ 360 ค่า อย่างไรก็ตาม พบว่าสามารถสร้างภาพที่มีลักษณะใกล้เคียงกับภาพต้นฉบับได้โดยใช้เพียงค่าเอกพจน์จำนวน 200 ค่า ซึ่งบ่งชี้ว่า SVD มีความสามารถในการลดมิติของข้อมูลอย่างมีประสิทธิภาพ ในขณะที่ยังสามารถรักษาข้อมูลสำคัญที่มีผลต่อการจำแนกไว้ได้อย่างเพียงพอ

ผลการวิเคราะห์ข้างต้นสะท้อนให้เห็นถึงศักยภาพของการรวม SVD เข้ากับ SVM ในการปรับปรุงประสิทธิภาพของแบบจำลอง โดยเฉพาะในกรณีที่ต้องประมวลผลข้อมูลภาพหรือข้อมูลเชิงพื้นที่ที่มีมิติสูงและซับซ้อน



รูปที่ 4.6 ตัวอย่างคุณภาพของภาพจากจำนวนส่วนประกอบ (Components) ต่างกัน

ผลการทดลองในการแยกส่วนประกอบของภาพเพื่อการจำแนกประเภทแสดงไว้ในตารางที่ 4.3 โดยในการศึกษานี้ได้ทำการเปรียบเทียบประสิทธิภาพของ SVM ที่ใช้เคอร์เนลสองประเภท ได้แก่ เคอร์เนลแบบฟังก์ชันฐานรัศมี (Radial Basis Function: RBF) และเคอร์เนลพหุนาม (Polynomial Kernel) สำหรับเคอร์เนล RBF ได้กำหนดค่าพารามิเตอร์  $C = 10$  และ  $\gamma = 0.1$  ขณะที่เคอร์เนลพหุนามใช้ค่าพารามิเตอร์ดีกรี  $d = 1$  และ  $C = 0.01$  ตามลำดับ

ผลลัพธ์ที่ได้แสดงให้เห็นประสิทธิภาพของแต่ละวิธีการภายใต้จำนวนค่าเอกพจน์ที่แตกต่างกัน โดยในตารางค่า  $N$  หมายถึงจำนวนค่าเอกพจน์ที่ถูกนำมาใช้ในการลดมิติข้อมูลก่อนการจำแนกประเภท ซึ่งมีผลโดยตรงต่อความแม่นยำของแบบจำลอง

ตารางที่ 4.3 ค่าความแม่นยำของโมเดล SVD-SVM สำหรับเคอร์เนลต่าง ๆ

เคอร์เนล	ค่าความแม่นยำ (เปอร์เซ็นต์)			
	$N = 5$	$N = 100$	$N = 200$	$N = 360$
RBF	86.94	87.58	87.79	88.33
Polynomial	83.32	84.51	84.73	85.00

จากผลลัพธ์ในตารางที่ 4.3 จะเห็นได้ว่าเวลาประมวลผลที่จำเป็นสำหรับโมเดลจะแตกต่างกันไป ขึ้นอยู่กับเทคนิคการแยกส่วนภาพที่ใช้ ในขณะที่ความแม่นยำที่เพิ่มขึ้นนั้นไม่สำคัญนักเมื่อขนาดของ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ส่วนประกอบเพิ่มขึ้น โมเดลที่ใช้เคอร์เนล RBF ที่มีค่า  $N = 360$  จะให้ความแม่นยำสูงสุด โมเดล SVD-SVM สามารถปรับจำนวนส่วนประกอบที่ใช้ในการประมวลผลได้โดยใช้ค่าเอกพจน์ที่ได้จาก SVD

เมื่อเปรียบเทียบประสิทธิภาพของแบบจำลอง SVM และ SVD-SVM ในการจำแนกปรากฏการณ์พลาสมาบับเบิลจากภาพเรดาร์ VHF พบว่าแบบจำลองแต่ละประเภทมีจุดเด่นและข้อจำกัดที่แตกต่างกัน

สำหรับแบบจำลอง SVM เพียงอย่างเดียว แม้จะมีข้อดีในด้านโครงสร้างที่เรียบง่ายและไม่ต้องการปริมาณข้อมูลจำนวนมากในการฝึก แต่เมื่อประยุกต์ใช้กับข้อมูลภาพที่มีมิติสูงและมีความซับซ้อน มักประสบปัญหาเรื่องโอเวอร์ฟิตติ้งและมีประสิทธิภาพในการจำแนกที่จำกัด เนื่องจากแบบจำลองไม่สามารถสกัดคุณลักษณะเชิงพื้นที่ (Spatial Features) ได้อย่างมีประสิทธิภาพ

เมื่อมีการประยุกต์ใช้ SVD ร่วมกับ SVM (SVD-SVM) เพื่อทำการลดมิติของข้อมูลก่อนป้อนเข้าสู่แบบจำลอง พบว่าแบบจำลองมีความสามารถในการเรียนรู้และจำแนกข้อมูลได้ดีขึ้นอย่างมีนัยสำคัญ เนื่องจาก SVD ช่วยคัดเลือกเฉพาะคุณลักษณะที่มีความสำคัญสูง ซึ่งลดภาระของ SVM ในการจัดการกับข้อมูลมิติสูง และลดความเสี่ยงของการเกิดโอเวอร์ฟิต อย่างไรก็ตาม ประสิทธิภาพของแบบจำลองยังคงมีขอบเขตจำกัดเมื่อเปรียบเทียบกับแบบจำลองที่สามารถเรียนรู้คุณลักษณะจากข้อมูลดิบได้โดยตรง

#### 4.2.3 ผลการจำลองด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF

การผสมผสานระหว่างโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ซึ่งมีจุดเด่นในการสกัดคุณลักษณะเชิงลึกจากข้อมูลภาพ ร่วมกับซัพพอร์ตเวกเตอร์แมชชีน (SVM) ที่มีประสิทธิภาพในการจำแนกข้อมูล ส่งผลให้แบบจำลองแบบผสม CNN-SVM สามารถจำแนกปรากฏการณ์พลาสมาบับเบิลได้อย่างมีประสิทธิภาพสูงกว่าการใช้ SVM เพียงอย่างเดียวอย่างมีนัยสำคัญ ผลการทดลองในงานวิจัยนี้แสดงให้เห็นว่าแบบจำลอง CNN-SVM ให้ค่าความแม่นยำในการจำแนกสูงกว่า ทั้งในแง่ของการเรียนรู้คุณลักษณะเฉพาะจากภาพเรดาร์ VHF และการจำแนกประเภทของข้อมูลของพลาสมาบับเบิลในขั้นสุดท้าย

ในการศึกษานี้ ได้ทำการวิเคราะห์ผลกระทบของพารามิเตอร์ที่เกี่ยวข้องกับโครงสร้างของ CNN ที่ใช้ร่วมกับ SVM ได้แก่ ขนาดของตัวกรอง (Kernel size) ซึ่งทดลองใช้ขนาด  $3 \times 3$ ,  $5 \times 5$  และ  $7 \times 7$  รวมถึงจำนวนเลเยอร์ของการสกัดคุณลักษณะ (Feature extraction layers) ตั้งแต่ 1 ถึง 7 เลเยอร์ โดยมีการกำหนดค่าขนาดสไตรด์ (stride) ของตัวกรองไว้ที่  $1 \times 1$  เพื่อให้การเคลื่อนที่ของฟิลเตอร์มีความละเอียด และใช้เลเยอร์การรวม (Pooling layer) ขนาด  $2 \times 2$  ในการลดมิติข้อมูลเชิงพื้นที่หลังการคอนโวลูชัน เลเยอร์สุดท้ายของ CNN ที่ทำหน้าที่สกัดคุณลักษณะของภาพจะถูกนำมาใช้เป็นอินพุตสำหรับการฝึก SVM ซึ่งในงานวิจัยนี้ได้ทดลองใช้เคอร์เนล SVM สองประเภท ได้แก่ เคอร์เนล RBF และเคอร์เนลพหุนาม เพื่อประเมินประสิทธิภาพของกระบวนการจำแนกที่ส่วนท้ายของแบบจำลองแบบผสม

ผลการทดลองชี้ให้เห็นว่าขนาดของตัวกรอง  $3 \times 3$  และจำนวนเลเยอร์ของ CNN ทั้งหมด 7 ชั้น ที่มีความแม่นยำของโมเดลถึง 93.67 เปอร์เซ็นต์ ซึ่งขนาดและจำนวนเลเยอร์ของ CNN มีผลต่อคุณภาพของคุณลักษณะที่ถูกสกัด และส่งผลกระทบต่อประสิทธิภาพโดยรวมของ SVM ในการจำแนกมีแนวโน้มให้ผลการจำแนกที่ดีกว่า เนื่องจากสามารถจับลักษณะเฉพาะของภาพได้ละเอียดขึ้น ขณะที่การใช้เลเยอร์รวมแบบสูงสุด (Max Pooling) ช่วยลดมิติข้อมูลโดยยังคงรักษาข้อมูลที่มีความสำคัญต่อการจำแนกไว้ได้อย่างมีประสิทธิภาพ

กล่าวโดยสรุป แบบจำลอง CNN-SVM ที่ได้รับการออกแบบอย่างเหมาะสมในแง่ของโครงสร้าง CNN และการเลือกใช้เคอร์เนล SVM สามารถปรับปรุงประสิทธิภาพในการจำแนกพลาสติกแบบบับเบิลได้อย่างชัดเจน และแสดงให้เห็นถึงความสามารถในการเรียนรู้และประมวลผลข้อมูลภาพเรดาร์ที่มีความซับซ้อนได้ดีกว่าแบบจำลอง SVM แบบเดิม

**ตารางที่ 4.4** ความแม่นยำของโมเดล CNN-SVM (เคอร์เนล RBF) สำหรับขนาดตัวกรองต่าง ๆ

จำนวนชั้น ขนาดตัวกรอง	ชั้นการคอนโวลูชัน			
	1	3	5	7
3x3	91.37	92.02	92.64	<b>93.67</b>
5x5	90.11	90.73	91.08	<b>91.53</b>
7x7	89.33	89.92	90.24	<b>90.67</b>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากตารางที่ 4.4 ผลการทดลองของแบบจำลอง CNN-SVM ซึ่งประเมินประสิทธิภาพของการจำแนกโดยการเปลี่ยนแปลงขนาดของตัวกรอง (Filter size) และจำนวนชั้นของเลเยอร์คอนโวลูชัน (convolutional layers) โดยใช้เคอร์เนลสองประเภท ได้แก่ เคอร์เนล (RBF) และเคอร์เนลพหุนาม (Polynomial kernel) ใน SVM ที่อยู่ในส่วนท้ายของแบบจำลอง

จากผลการทดลอง พบว่าเมื่อกำหนดขนาดตัวกรองเป็น  $3 \times 3$  และใช้จำนวนเลเยอร์คอนโวลูชันเท่ากับ 7 ชั้น แบบจำลองที่ใช้ SVM เคอร์เนล RBF สามารถบรรลุค่าความแม่นยำสูงสุดที่ร้อยละ 93.67 ซึ่งเป็นค่าที่สูงที่สุดในกลุ่มของแบบจำลองทั้งหมดที่ทำการทดสอบ แสดงให้เห็นว่าโครงสร้างของ CNN ที่มีการสกัดคุณลักษณะเชิงลึกในระดับหลายเลเยอร์ร่วมกับขนาดฟิลเตอร์ที่เล็กสามารถจับรายละเอียดเชิงพื้นที่ของภาพได้อย่างมีประสิทธิภาพ และเมื่อจับคู่กับ SVM ที่ใช้เคอร์เนล RBF ซึ่งมีความสามารถในการจำแนกข้อมูลที่ไม่เป็นเชิงเส้นสูง จึงส่งผลให้แบบจำลองสามารถแยกประเภทของข้อมูลได้อย่างแม่นยำยิ่งขึ้น

ในทำนองเดียวกัน ตารางที่ 4.5 แสดงผลการทดลองโดยใช้ SVM เคอร์เนลพหุนามร่วมกับโครงสร้าง CNN เดียวกัน (ขนาดตัวกรอง  $3 \times 3$  และจำนวนชั้นคอนโวลูชัน 7 ชั้น) พบว่าแบบจำลองสามารถบรรลุค่าความแม่นยำสูงสุดที่ร้อยละ 92.33 ซึ่งแม้จะต่ำกว่าเคอร์เนล RBF เล็กน้อย แต่ก็ยังอยู่ในระดับที่ถือว่ามีประสิทธิภาพสูง

ตารางที่ 4.5 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนลพหุนาม) สำหรับขนาดตัวกรองต่าง ๆ

ขนาดตัวกรอง \ จำนวนชั้น	ชั้นการคอนโวลูชัน			
	1	3	5	7
3x3	90.67	91.10	91.88	92.33
5x5	89.68	89.93	90.24	90.67
7x7	88.02	88.64	88.95	89.13

แม้ว่าตารางที่ 4.4 และตารางที่ 4.5 จะแสดงผลลัพธ์ตามเลเยอร์คอนโวลูชันสูงสุด 7 เลเยอร์ ในโมเดล CNN แต่เราได้สำรวจโมเดลที่มีเลเยอร์มากกว่านี้ อย่างไรก็ตาม เราพบว่าความแม่นยำดีขึ้นเพียงเล็กน้อยเท่านั้น โดยแลกมากับความล่าช้าที่เพิ่มขึ้นอย่างมาก โดยเฉพาะอย่างยิ่ง เมื่อจำนวนเลเยอร์เพิ่มขึ้นเป็น 9 เลเยอร์ ความแม่นยำของโมเดลจะดีขึ้นประมาณ 0.02 ถึง 0.05 เปอร์เซ็นต์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ผลการทดลองดังกล่าวชี้ให้เห็นว่า โครงสร้างของ CNN ที่ใช้ขนาดตัวกรองขนาดเล็กและจำนวนเลเยอร์หลายชั้นช่วยเพิ่มความสามารถในการเรียนรู้คุณลักษณะที่สำคัญจากภาพอย่างลึกซึ้ง ขณะเดียวกัน การเลือกใช้คอร์เนลของ SVM ที่เหมาะสมมีผลโดยตรงต่อประสิทธิภาพของแบบจำลอง โดยที่คอร์เนล RBF ให้ประสิทธิภาพสูงสุดในบริบทของงานวิจัยนี้

จากผลการทดลองในบทนี้ สรุปได้ว่าแบบจำลอง SVM เพียงอย่างเดียว เหมาะสำหรับข้อมูลที่มีมิติไม่สูงมากและมีลักษณะเชิงเส้น แบบจำลอง SVD-SVM ให้ประสิทธิภาพที่ดีขึ้นในการจัดการข้อมูลมิติสูง โดยลด noise และลดมิติที่ไม่จำเป็น แบบจำลอง CNN-SVM ให้ผลลัพธ์ที่ดีที่สุดในภาพรวม โดยเฉพาะในกรณีที่ข้อมูลมีโครงสร้างเชิงพื้นที่ซับซ้อน เช่น ข้อมูลรูปภาพ

ดังนั้น การเลือกใช้แบบจำลองจึงควรพิจารณาตามลักษณะของข้อมูลและข้อจำกัดของระบบ โดยในบริบทของการจำแนกปรากฏการณ์พลาสมาบับเบิลจากภาพเรดาร์ VHF แบบจำลอง CNN-SVM จึงเป็นแนวทางที่มีศักยภาพสูงสุด

#### 4.2.4 ผลการจำลองด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับซัพพอร์ตเวกเตอร์แมชชีนด้วยข้อมูลจากเรดาร์ VHF ร่วมกับรูปภาพไอโอโนแกรม

ในการสรุปผลการศึกษา ได้ทำการประเมินและเปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 4 แบบ ได้แก่ SVM, SVD-SVM, CNN-SVM (RBF kernel) และ CNN-SVM (Polynomial kernel) โดยสรุปผลลัพธ์ไว้ในตารางที่ 4.6 และตารางที่ 4.7 ซึ่งแสดงค่าความแม่นยำที่ได้จากแต่ละแบบจำลองภายใต้เงื่อนไขและชุดข้อมูลเดียวกัน

จากผลลัพธ์พบว่าแบบจำลอง CNN-SVM ที่ใช้คอร์เนล RBF ให้ค่าความแม่นยำสูงสุดที่ร้อยละ 95.10 ซึ่งมากกว่าแบบจำลองของคอร์เนล Polynomial ร้อยละ 93.14 เมื่อใช้งานร่วมกับข้อมูลจากเรดาร์ VHF และไอโอโนแกรม ซึ่งเป็นชุดข้อมูลที่มีลักษณะเชิงพื้นที่และเชิงเวลาอย่างซับซ้อน

ตารางที่ 4.6 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนล RBF) ที่มีขนาดตัวกรอง 3x3 จากผลการทดสอบโมเดล

จำนวนชั้น ประเภทข้อมูล	ชั้นการคอนโวลูชันแบบชั้นเดียว				
	1	3	5	7	9
VHF	91.85	92.02	92.54	<b>92.79</b>	93.02
VHF + Ionograms	93.14	93.35	93.69	<b>93.93</b>	94.15
VHF + Ionograms (Remove noise)	94.32	94.56	94.97	<b>95.10</b>	95.34

ผลการทดลองนี้สะท้อนให้เห็นถึงความสามารถของโครงสร้างแบบผสม CNN-SVM ในการเรียนรู้คุณลักษณะที่ซับซ้อนจากข้อมูลภาพและข้อมูลเชิงเวลา พร้อมทั้งสามารถจำแนกปรากฏการณ์พลาสมาบับเบิลได้อย่างมีประสิทธิภาพสูง โดยเฉพาะเมื่อจับคู่กับเคอร์เนล RBF ซึ่งมีความยืดหยุ่นในการจำแนกข้อมูลที่ไม่เป็นเชิงเส้น และสามารถปรับเส้นแบ่งเขตการจำแนกได้ตามโครงสร้างของข้อมูลจริง

กล่าวโดยสรุป แบบจำลอง CNN-SVM ที่ใช้เคอร์เนล RBF เป็นทางเลือกที่เหมาะสมที่สุดสำหรับการประมวลผลและจำแนกปรากฏการณ์พลาสมาบับเบิลในบริบทของงานวิจัยนี้ ทั้งในแง่ของความแม่นยำและความสามารถในการประมวลผลข้อมูลจากหลายแหล่งอย่างมีประสิทธิภาพ

เมื่อทำการฝึกอบโมเดลโดยใช้เลเยอร์ Convolutional จำนวน 8-9 เลเยอร์ ความแม่นยำของโมเดลจะเพิ่มขึ้น 0.2-0.5 เปอร์เซ็นต์ แต่เวลาในการฝึกโมเดลใช้เวลานาน ดังนั้นในงานนี้เราจะใช้เลเยอร์ Convolutional จำนวน 7 เลเยอร์

ตารางที่ 4.7 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนลพหุนาม) ที่มีขนาดตัวกรอง 3x3 จากผลการทดสอบโมเดล

จำนวนชั้น ประเภทข้อมูล	ชั้นการคอนโวลูชันแบบชั้นเดียว				
	1	3	5	7	9
VHF	89.86	90.03	90.27	<b>90.51</b>	90.74
VHF + Ionograms	91.15	91.21	91.54	<b>91.87</b>	91.93
VHF + Ionograms (Remove noise)	92.83	92.94	93.07	<b>93.14</b>	93.48

จากผลการทดลองเบื้องต้น พบว่าแบบจำลอง CNN-SVM ที่ใช้โครงสร้างเลเยอร์คอนโวลูชันเพียงชั้นเดียว ยังไม่สามารถจำแนกรูปภาพของคลาสที่ไม่แน่ชัด (Unsure class) ได้อย่างถูกต้องทั้งหมด โดยมีบางกรณีที่เกิดข้อผิดพลาดในการจำแนก ซึ่งแสดงให้เห็นถึงข้อจำกัดของการสกัดคุณลักษณะจากข้อมูลภาพที่มีความซับซ้อนผ่านโครงสร้างคอนโวลูชันเพียงชั้นเดียว

เพื่อแก้ไขข้อจำกัดดังกล่าว งานวิจัยนี้จึงได้นำเสนอแนวทางการพัฒนาแบบจำลองโดยเพิ่มจำนวนเลเยอร์คอนโวลูชันเป็นสองชั้น (Multi-convolution layers) เพื่อเพิ่มความลึกในการสกัดคุณลักษณะเชิงลำดับชั้น (Hierarchical features) จากข้อมูลภาพ โดยคาดหวังว่าจะสามารถระบุรายละเอียดเชิงโครงสร้างของภาพได้หลากหลายและลึกซึ้งยิ่งขึ้น ส่งผลให้แบบจำลองสามารถจำแนกข้อมูลได้แม่นยำยิ่งขึ้น โดยเฉพาะในกรณีของคลาสที่มีความไม่แน่นอนสูง

ผลการทดลองของแบบจำลองที่ใช้เลเยอร์คอนโวลูชันสองชั้น แสดงไว้ในตารางที่ 4.8 ซึ่งเปรียบเทียบความแม่นยำของแบบจำลองกับโครงสร้างเลเยอร์เดี่ยวสำหรับเคอร์เนล RBF และตารางที่ 4.9 สำหรับเคอร์เนลพหุนาม พบว่าการเพิ่มชั้นคอนโวลูชันช่วยเพิ่มประสิทธิภาพในการจำแนกได้อย่างชัดเจน โดยเฉพาะในกลุ่มคลาสที่มีลักษณะคลุมเครือ (Ambiguous or unsure class)

จากผลการทดลองดังกล่าว สามารถสรุปได้ว่าการออกแบบโครงสร้างของ CNN ให้มีความลึกมากขึ้นในกระบวนการสกัดคุณลักษณะ ส่งผลโดยตรงต่อประสิทธิภาพของแบบจำลองโดยรวม และเป็น

แนวทางที่เหมาะสมสำหรับการจำแนกปรากฏการณ์หรือข้อมูลภาพที่มีความซับซ้อนสูงในบริบทของงานวิจัยนี้

ตารางที่ 4.8 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนล RBF) ที่ใช้เลเยอร์คอนโวลูชัน 2 ชั้น จากการทดสอบโมเดล

จำนวนชั้น ประเภทข้อมูล	ชั้นการคอนโวลูชัน (Multi-Convolutional)				
	1	3	5	7	9
VHF	95.08	95.27	95.36	<b>95.54</b>	95.60
VHF + Ionograms	95.45	95.61	95.93	<b>96.02</b>	96.12
VHF + Ionograms (Remove noise)	97.32	97.54	97.75	<b>97.83</b>	97.90

ตารางที่ 4.9 ความแม่นยำของโมเดล CNN-SVM (เคอร์เนลพหุนาม) ที่ใช้เลเยอร์คอนโวลูชัน 2 ชั้น จากการทดสอบโมเดล

จำนวนชั้น ประเภทข้อมูล	ชั้นการคอนโวลูชัน (Multi-Convolutional)				
	1	3	5	7	9
VHF	93.98	94.12	94.21	<b>94.32</b>	94.47
VHF + Ionograms	95.46	95.61	95.72	<b>95.87</b>	95.91
VHF + Ionograms (Remove noise)	95.53	95.69	95.86	<b>96.04</b>	96.13

จากตารางที่ 4.8 ซึ่งเป็นผลการใช้เคอร์เนล RBF พบว่าแบบจำลองที่ใช้โครงสร้างแบบหลายชั้น และข้อมูลจาก VHF ร่วมกับไอโอโนแกรมที่ผ่านการลบ noise แล้ว แสดงให้เห็นว่าเคอร์ RBF มีความยืดหยุ่นและประสิทธิภาพสูงในการจัดการกับข้อมูลที่มีความซับซ้อนและไม่เป็นเชิงเส้น ประกอบกับ CNN ที่มีหลายเลเยอร์สามารถสกัดลักษณะเฉพาะจากข้อมูลภาพได้อย่างแม่นยำมากยิ่งขึ้น

ตารางที่ 4.9 ซึ่งใช้เคอร์เนลพหุนาม พบว่าแบบจำลองที่ใช้โครงสร้างแบบหลายชั้นสามารถให้ความแม่นยำได้ดีกว่าแบบชั้นเดียวในทุกประเภทของข้อมูล โดยเฉพาะกรณีที่ใช้ข้อมูล VHF ร่วมกับไอ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ไอโนแกรมและผ่านการลบสัญญาณรบกวนแล้ว แบบจำลองสามารถบรรลุค่าความแม่นยำสูงสุดที่ 96.04% แสดงให้เห็นว่าการใช้ข้อมูลจากหลายแหล่งร่วมกันช่วยเพิ่มความสามารถในการแยกแยะคุณลักษณะของพลาสมาได้ดียิ่งขึ้น ขณะที่โครงสร้างแบบหลายชั้นช่วยเพิ่มประสิทธิภาพในการเรียนรู้ลักษณะเชิงลึกของภาพ

#### 4.2.5 ผลการเปรียบเทียบประสิทธิภาพของโมเดลการจำแนกประเภทของพลาสมาแบบเปิด บริเวณเส้นศูนย์สูตรที่นำเสนอ

ในส่วนสุดท้ายของการทดลอง ได้ทำการวิเคราะห์เปรียบเทียบประสิทธิภาพของแบบจำลองทั้ง 4 แบบ ได้แก่ SVM, SVD-SVM, CNN-SVM (Single-convolution layer) และ CNN-SVM (Multi-convolution layer) สำหรับเคอร์เนล RBF โดยใช้ข้อมูลประเภทต่าง ๆ ที่ผ่านการประมวลผลผลลัพธ์สรุปรวมไว้ในตารางที่ 4.10 ซึ่งเปรียบเทียบค่าความแม่นยำ (Accuracy) ของแต่ละแบบจำลองภายใต้เงื่อนไขเดียวกัน


ตารางที่ 4.10 เปรียบเทียบค่าความแม่นยำ (Accuracy) ของแต่ละแบบจำลองสำหรับเคอร์เนล RBF

ประเภทของโมเดล	ค่าความแม่นยำ	ความแม่นยำของโมเดล (เปอร์เซ็นต์)
SVM		86.67
SVD-SVM		88.33
CNN-SVM (ข้อมูล VHF)		93.67
CNN-SVM (ข้อมูล VHF + Ionograms) แบบชั้นเดียว		95.10
CNN-SVM (ข้อมูล VHF + Ionograms) แบบหลายชั้น		97.83

สรุปผลจากการเปรียบเทียบแบบจำลอง CNN-SVM ที่ใช้โครงสร้างแบบหลายชั้นมีความแม่นยำสูงกว่าโครงสร้างแบบชั้นเดียวในทุกกรณีของข้อมูลและเคอร์เนลที่ใช้ การใช้ข้อมูลจากหลายแหล่ง (VHF + Iono) และการลบ noise มีผลต่อการเพิ่มประสิทธิภาพของแบบจำลองอย่างชัดเจนการใช้เคอร์เนล RBF ให้ค่าความแม่นยำสูงกว่าเคอร์เนลพหุนามอย่างสม่ำเสมอในทุกประเภทข้อมูล โดยเฉพาะเมื่อใช้โครงสร้าง CNN ที่ลึกขึ้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ผลการศึกษาดังกล่าวแสดงให้เห็นว่า การออกแบบโครงสร้างแบบจำลองที่เหมาะสมร่วมกับการเลือกข้อมูลและการประมวลผลที่เหมาะสมมีผลอย่างมีนัยสำคัญต่อประสิทธิภาพของการจำแนกปรากฏการณ์พลาสมาบับเบิล




รูปที่ 4.7 เมทริกซ์ความสับสนแต่ละเทคนิคโดยใช้ข้อมูลจากเรดาร์ VHF สำหรับคอร์เนล RBF

จากรูปที่ 4.7 แสดงผลเมทริกซ์ความสับสนที่ได้จากแบบจำลองที่เสนอแต่ละแบบ โดยเรียกคลาสต่างๆ ดังต่อไปนี้ คลาส 0 (ไม่ใช่พลาสมา) คลาส 1 (ไม่แน่ใจ) และคลาส 2 (พลาสมาบับเบิล) แบบจำลอง CNN-SVM ให้ความแม่นยำสูงกว่าที่ 28.67% เมื่อเปรียบเทียบกับแบบจำลอง SVM และแบบจำลอง SVD-SVM ตามลำดับ

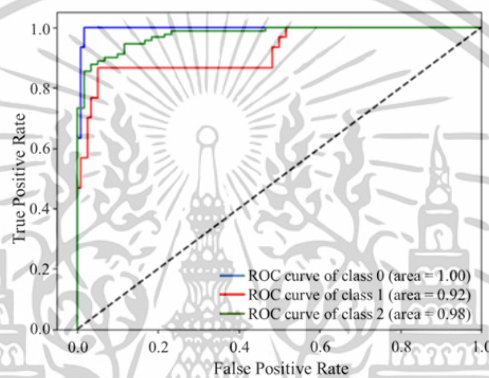
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ก) สำหรับแบบจำลอง SVM



ข) สำหรับแบบจำลอง SVD-SVM




ค) สำหรับแบบจำลอง CNN-SVM

#### รูปที่ 4.8 เส้นโค้ง ROC ของแต่ละเทคนิคที่นำเสนอสำหรับคอร์เนล RBF

ในรูปที่ 4.8 แสดงกราฟลักษณะการทำงานของตัวรับ (ROC) สำหรับแต่ละแบบ โดยแต่ละจุดบนกราฟคือค่าอัตราผลบวกที่แท้จริง (TPR) และอัตราผลบวกปลอม (FPR) สำหรับจุดเกณฑ์เฉพาะ ดังนั้น พื้นที่ใต้กราฟ ROC (AUC-ROC) จึงแสดงถึงความแตกต่างในการจำแนกพลาสมาบับเบิล ผลลัพธ์บ่งชี้ว่าแบบจำลอง CNN-SVM มีประสิทธิภาพเหนือกว่าแบบจำลอง SVM ในแง่ของ AUC-ROC สำหรับทั้งสามคลาส โดยเฉพาะอย่างยิ่ง โมเดล CNN-SVM สามารถเพิ่มค่า AUC-ROC ได้ 1% สำหรับคลาส 0, 14% สำหรับคลาส 1 และ 12% สำหรับคลาส 2 เมื่อเปรียบเทียบกับโมเดล SVM AUC-ROC เป็นเมตริกที่ใช้กันทั่วไปในการประเมินโมเดลการจำแนกแบบไบนารี ในขณะที่ SVM และ CNN เป็นโมเดลการเรียนรู้ของเครื่องที่นิยมใช้สองแบบสำหรับงานการจำแนก

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ก) แบบจำลอง CNN-SVM โดยใช้ VHF พร้อม ข้อมูลไอโอโนแกรม (ชั้นคอนไวลูลชั้น 1 ชั้น)      ข) แบบจำลอง CNN-SVM โดยใช้ VHF พร้อม ข้อมูลไอโอโนแกรม (ชั้นคอนไวลูลชั้นหลายชั้น)

รูปที่ 4.9 เมตริกซ์สับสนแบบจำลองการเพิ่มจำนวนชั้นการคอนไวลูลชั้นสำหรับเคอร์เนล RBF


จากการเปรียบเทียบแบบจำลองต่าง ๆ พบว่าการรวมเทคนิคการเรียนรู้เชิงลึก (CNN) และการเรียนรู้ของเครื่อง (SVM) สามารถเสริมจุดแข็งซึ่งกันและกันได้อย่างมีประสิทธิภาพ โดย CNN มีความสามารถในการเรียนรู้คุณลักษณะเชิงพื้นที่จากภาพเรดาร์ได้อย่างลึกซึ้ง ขณะที่ SVM มีความแม่นยำในการจำแนกกลุ่มข้อมูล โดยเฉพาะเมื่อใช้ร่วมกับเคอร์เนลที่เหมาะสม

การทดลองพบว่า การใช้โครงสร้างชั้นการคอนไวลูลชั้นแบบหลายชั้นส่งผลให้แบบจำลองสามารถเรียนรู้คุณลักษณะของพลาสมาบับเบิลที่มีความหลากหลายและซับซ้อนมากขึ้น โดยเฉพาะในกรณีของข้อมูลที่มีสัญญาณรบกวนหรือคลาสที่ไม่แน่ชัด (Unsure class) แบบจำลองสามารถจำแนกได้แม่นยำยิ่งขึ้นเมื่อโครงสร้างมีความลึก

ด้านฟังก์ชันเคอร์เนลนั้น เคอร์เนล RBF ให้ผลดีกว่าเคอร์เนลพหุนามในทุกกรณี ซึ่งสอดคล้องกับคุณสมบัติของ RBF ที่สามารถจำแนกข้อมูลที่ไม่เป็นเชิงเส้นได้ดีกว่าเคอร์เนลอื่น ๆ โดยเฉพาะในบริบทของข้อมูลภาพจากเรดาร์ที่มักมีลักษณะซับซ้อน

นอกจากนี้ การใช้ข้อมูลจากหลายแหล่ง โดยเฉพาะข้อมูลที่ผ่านมาการเตรียมการประมวลผล เช่น การลบสัญญาณรบกวน มีผลโดยตรงต่อการเพิ่มประสิทธิภาพของแบบจำลอง ซึ่งแสดงให้เห็นถึงความสำคัญของการเตรียมข้อมูลให้เหมาะสมก่อนนำเข้าสู่กระบวนการเรียนรู้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



ก) แบบจำลอง CNN - SVM โดยใช้ VHF พร้อม ข้อมูลไอโอโนแกรม (ชั้นคอนโวลูชัน 1 ชั้น) รูปที่ 4.10 เส้นโค้ง ROC แบบจำลองการเพิ่มจำนวนชั้นการคอนโวลูชันสำหรับคอร์เนล RBF

ข) แบบจำลอง CNN - SVM โดยใช้ VHF พร้อม ข้อมูลไอโอโนแกรม (ชั้นคอนโวลูชันหลายชั้น)

จากรูปที่ 4.10 แสดงเส้นโค้งลักษณะการทำงานของตัวรับ (Receiver Operating Characteristic) สำหรับการจำแนกประเภทแบบหลายคลาส ซึ่งได้ประเมินผลลัพธ์จากโมเดลทั้งสองบนคลาสที่แตกต่างกันจำนวนสามคลาส ได้แก่ คลาส 0 (ไม่มีพลาสมา), คลาส 1 (ไม่แน่ใจ) และคลาส 2 (พลาสมาบับเบิล) โดยแยกวิเคราะห์ประสิทธิภาพของแต่ละคลาสเป็นรายการ

จากผลการประเมิน พบว่าโมเดลสามารถจำแนกแต่ละคลาสได้อย่างมีประสิทธิภาพ โดยมีค่าพื้นที่ใต้เส้นโค้งลักษณะการทำงานของตัวรับ (Area Under the Curve หรือ AUC) มากกว่า 0.95 สำหรับทุกคลาส โดยเฉพาะในคลาสที่ 1 ซึ่งเป็นคลาสที่ไม่สามารถจำแนกได้อย่างแน่ชัด (ไม่แน่ใจ) มีค่า AUC สูงสุดที่ 0.99 แสดงถึงความสามารถในการจำแนกประเภทที่แม่นยำที่สุด รองลงมาคือคลาสที่ 2 (พลาสมาบับเบิล) และคลาสที่ 0 (ไม่มีพลาสมา) ซึ่งมีค่า AUC เท่ากับ 0.97 และ 0.96 ตามลำดับ ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่าโมเดลที่พัฒนาขึ้นมีความเหมาะสมและมีศักยภาพสูงสำหรับการประยุกต์ใช้ในการจำแนกประเภทข้อมูลพลาสมาในบริบทของปัญหานี้


แม้ว่างานวิจัยนี้จะประสบความสำเร็จในการพัฒนาแบบจำลองที่มีประสิทธิภาพสูงในการจำแนกพลาสมาบับเบิล แต่ยังมีข้อจำกัดบางประการ ได้แก่

- 1) ขนาดของชุดข้อมูลที่ใช้ฝึกแบบจำลองยังค่อนข้างจำกัด โดยเฉพาะในบางคลาสที่พบได้น้อย อาจทำให้โมเดลเกิดการเรียนรู้ที่ไม่สมดุล (Data Imbalance)
- 2) การทดลองในครั้งนี้จำกัดเฉพาะข้อมูลจากบางช่วงเวลาและพื้นที่ หากต้องการขยายผลไปยังบริบทอื่น อาจต้องมีการฝึกแบบจำลองใหม่

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3) ยังไม่ได้ทดลองเปรียบเทียบกับแบบจำลองลักษณะอื่น เช่น LSTM, Transformer หรือแบบ end-to-end CNN ที่ไม่ใช่ SVM

ต่อจากนั้น ได้มีการพัฒนาต้นแบบซอฟต์แวร์สำหรับการจำแนกประเภทของพลาสมาบับเบิล (EPB) แบบเรียลไทม์ ซึ่งแสดงไว้ในรูปที่ 4.11 โดยซอฟต์แวร์ต้นแบบดังกล่าวสามารถแสดงผลข้อมูลประกอบของภาพ ได้แก่ ตำแหน่งทางภูมิศาสตร์ วัน เดือน ปี และเวลา ของแต่ละภาพที่นำเข้าสู่ระบบ พร้อมทั้งแสดงผลลัพธ์ของการจำแนกประเภทในแต่ละภาพแบบเรียลไทม์อย่างชัดเจน



รูปที่ 4.11 ต้นแบบซอฟต์แวร์ที่ใช้ในการจำแนกประเภทของ EPB

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## บทที่ 5

# สรุปผลการวิจัยและข้อเสนอแนะ

### 5.1 สรุปผลการวิจัย

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการเรียนรู้ของเครื่องสำหรับการจำแนกปรากฏการณ์พองพลาสมา (EPB) โดยอาศัยข้อมูลจากเรดาร์ VHF และไอโอโนแกรม ซึ่งเป็นข้อมูลที่มีความซับซ้อนและมีลักษณะเชิงภาพ โดยมีการเปรียบเทียบแบบจำลองทั้งหมด 4 แบบ ได้แก่ แบบจำลอง SVM พื้นฐาน, แบบจำลอง SVD-SVM ที่ใช้การลดมิติโดยการแยกค่าเอกพจน์, แบบจำลอง CNN-SVM ที่ใช้ CNN ในการสกัดคุณลักษณะและใช้ SVM เป็นตัวจำแนก โดยใช้ทั้งเคอร์เนลพหุนามและเคอร์เนล RBF การเปรียบเทียบผลลัพธ์ระหว่างโครงสร้างชั้นการคอนโวลูชันแบบชั้นเดียว และแบบหลายชั้น (Multi-Convolution Layers) ใน CNN

จากผลการทดลองสามารถสรุปได้ว่าแบบจำลอง CNN-SVM ที่ใช้โครงสร้างชั้นการคอนโวลูชันแบบหลายชั้นร่วมกับเคอร์เนล RBF ให้ผลลัพธ์ที่ดีที่สุด โดยสามารถจำแนกปรากฏการณ์ EPB ได้ด้วยความแม่นยำสูงสุดที่ 97.83% เมื่อใช้ข้อมูล VHF ร่วมกับไอโอโนแกรมที่ผ่านการลบสัญญาณรบกวน การใช้โครงสร้างชั้นการคอนโวลูชันแบบหลายชั้นช่วยเพิ่มความสามารถในการสกัดคุณลักษณะเชิงลึกของภาพ ทำให้ผลลัพธ์ดีกว่าแบบโครงสร้างชั้นการคอนโวลูชันแบบชั้นเดียวอย่างมีนัยสำคัญ เคอร์เนล RBF ให้ผลลัพธ์โดยรวมดีกว่าเคอร์เนลพหุนามในทุกชุดข้อมูล โดยเฉพาะในกรณีที่มีลักษณะข้อมูลไม่เชิงเส้น การรวมข้อมูลจากหลายแหล่ง (VHF + Ionosonde) และการลบสัญญาณรบกวน (Noise removal) ส่งผลดีต่อประสิทธิภาพของแบบจำลอง

### 5.2 ข้อเสนอแนะสำหรับการวิจัยในอนาคต

จากข้อจำกัดที่กล่าวมา และผลการวิจัยที่ได้ ขอนำเสนอแนวทางการวิจัยต่อไปในอนาคตดังนี้

1) ขยายขอบเขตของชุดข้อมูล โดยควรเก็บข้อมูลจากหลายช่วงเวลา หลายฤดูกาล และจากหลายพื้นที่ เพื่อเพิ่มความสามารถในการ generalize ของแบบจำลอง

2. พัฒนาโมเดลเชิงลึกแบบ end-to-end โดยควรทดลองพัฒนาแบบจำลองการเรียนรู้เชิงลึก (Deep learning) ที่สามารถเรียนรู้และจำแนกข้อมูลได้ในกระบวนการเดียว เช่น CNN-LSTM หรือ Vision Transformer

3) ปรับแต่งพารามิเตอร์อัตโนมัติ ควรใช้เทคนิคอย่าง Bayesian Optimization หรือ AutoML ในการปรับค่าพารามิเตอร์เพื่อให้ได้ผลลัพธ์ที่ดีที่สุดโดยไม่ต้องใช้การทดลองซ้ำมาก

4) เปรียบเทียบกับแบบจำลองอื่น เช่น Random Forest, XGBoost, หรือเทคนิค ensemble เพื่อวัดความสามารถของโมเดลในบริบทอื่น



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## เอกสารอ้างอิง

- [1] G. Haerendel and J. V. Eccles, "The role of the equatorial electrojet in the evening ionosphere," *J Geophys Res Space Phys*, vol. 97, no. A2, 1992, doi: 10.1029/91ja02227.
- [2] M. C. Kelley, *The Earth's ionosphere: plasma physics and electrodynamics (Vol. 96)*. 2009.
- [3] K. Nozaki, "FMCW ionosonde for the SEALION project," *Journal of the National Institute of Information and Communications Technology*, vol. 56, no. 1-4, 2009.
- [4] T. Thanakulketsarat, P. Supnithi, L. M. M. Myint, K. Hozumi, and M. Nishioka, "Classification of the equatorial plasma bubbles using convolutional neural network and support vector machine techniques," *Earth, Planets and Space*, vol. 75, no. 1, 2023, doi: 10.1186/s40623-023-01903-7.
- [5] Y. Otsuka, K. Shiokawa, T. Ogawa, T. Yokoyama, M. Yamamoto, and S. Fukao, "Spatial relationship of equatorial plasma bubbles and field-aligned irregularities observed with an all-sky airglow imager and the Equatorial Atmosphere Radar," *Geophys Res Lett*, vol. 31, no. 20, 2004, doi: 10.1029/2004GL020869.
- [6] T. Yokoyama, S. Y. Su, and S. Fukao, "Plasma blobs and irregularities concurrently observed by ROCSAT-1 and Equatorial Atmosphere Radar," *J Geophys Res Space Phys*, vol. 112, no. 5, 2007, doi: 10.1029/2006JA012044.
- [7] A. Bumrungrit, P. Supnithi, S. Saito, and L. M. M. Myint, "A study of equatorial plasma bubble structure using VHF radar and GNSS scintillations over the low-latitude regions," *GPS Solutions*, vol. 26, no. 4, 2022, doi: 10.1007/s10291-022-01321-4.
- [8] S. Sharma, P. Galav, N. Dashora, and R. Pandey, "Longitudinal study of the ionospheric response to the geomagnetic storm of 15 May 2005 and manifestation of TADs," *Ann Geophys*, vol. 29, no. 6, 2011, doi: 10.5194/angeo-29-1063-2011.
- [9] K. K. Ajith *et al.*, "Explicit characteristics of evolutionary-type plasma bubbles observed from Equatorial Atmosphere Radar during the low to moderate solar

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- activity years 2010-2012,” *J Geophys Res Space Phys*, vol. 120, no. 2, 2015, doi: 10.1002/2014JA020878.
- [10] F. S. Rodrigues, E. B. Shume, E. R. De Paula, and M. Milla, “Equatorial 150 km echoes and daytime F region vertical plasma drifts in the Brazilian longitude sector,” *Ann Geophys*, vol. 31, no. 10, 2013, doi: 10.5194/angeo-31-1867-2013.
- [11] L. Hu *et al.*, “Development of Low Latitude Long Range Ionospheric Radar for Observing Plasma Bubble Irregularities and Preliminary Results,” *J Geophys Res Space Phys*, vol. 129, no. 3, 2024, doi: 10.1029/2023JA032099.
- [12] T. Sori, A. Shinbori, Y. Otsuka, T. Tsugawa, M. Nishioka, and A. Yoshikawa, “Generation Mechanisms of Plasma Density Irregularity in the Equatorial Ionosphere During a Geomagnetic Storm on 21–22 December 2014,” *J Geophys Res Space Phys*, vol. 127, no. 5, 2022, doi: 10.1029/2021JA030240.
- [13] W. Jia *et al.*, “Observations on the Variations of the Field-Aligned Irregularities in the Plasma Bubbles at Low-Latitudes of China,” *J Geophys Res Space Phys*, vol. 128, no. 11, 2023, doi: 10.1029/2023JA031890.
- [14] E. Aa *et al.*, “Merging of Storm Time Midlatitude Traveling Ionospheric Disturbances and Equatorial Plasma Bubbles,” *Space Weather*, vol. 17, no. 2, 2019, doi: 10.1029/2018SW002101.
- [15] S. A. Shidler, F. S. Rodrigues, B. G. Fejer, and M. A. Milla, “Radar Studies of Height-Dependent Equatorial F region Vertical and Zonal Plasma Drifts,” *J Geophys Res Space Phys*, vol. 124, no. 3, 2019, doi: 10.1029/2019JA026476.
- [16] S. R. Samundi D., “A Review on Various Aspects of Earth’s Atmosphere,” in *Handbook of Research on Aspects and Applications of Incompressible and Compressible Aerodynamics*, 2022. doi: 10.4018/978-1-6684-4230-2.ch002.
- [17] A. Brekke, “The atmosphere of the Earth,” 2013. doi: 10.1007/978-3-642-27401-5\_2.
- [18] Katja Matthes, T. Dudok de Wit, and J. Liliensten, “1.1 The Earth’s atmosphere: an introduction,” in *Earth’s climate response to a changing Sun*, 2021. doi: 10.1051/978-2-7598-1849-5.c003.

- [19] G. T. Farmer and J. Cook, "Introduction to Earth's Atmosphere," in *Climate Change Science: A Modern Synthesis*, 2013. doi: 10.1007/978-94-007-5757-8\_8.
- [20] C. F. Bohren and B. A. Albrecht, *Atmospheric thermodynamics*. 2023. doi: 10.1093/oso/9780198872702.001.0001.
- [21] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, 1998, doi: 10.1109/5.726791.
- [22] Y. Le Cun *et al.*, "Handwritten zip code recognition with multilayer networks," in *Proceedings - International Conference on Pattern Recognition*, 1990. doi: 10.1109/icpr.1990.119325.
- [23] V. Vapnik and a. Lerner, "Pattern recognition using generalized portrait method," *Automat. Remont Contr.*, vol. 24, 1963, doi: 10.1162/neco.1992.4.6.888.
- [24] C. Cortes and V. Vapnik, "Support-Vector Networks," *Mach Learn*, vol. 20, no. 3, 1995, doi: 10.1023/A:1022627411411.
- [25] D. Wilimitis, "The Kernel Trick in Support Vector Classification," Medium.com.
- [26] C. Kapil and G. K. Seemala, "Machine learning approach for detection of plasma depletions from TEC," *Advances in Space Research*, vol. 73, no. 7, 2024, doi: 10.1016/j.asr.2023.04.042.
- [27] O. Carvalho, P. A. A. Da Silva De Almeida Nava Alves, R. Y. De La Cruz Cueva, and A. O. B. Filho, "Nowcasting of Amplitude Ionospheric Scintillation Based on Machine Learning Techniques," *IEEE Trans Aerosp Electron Syst*, vol. 58, no. 6, 2022, doi: 10.1109/TAES.2022.3188741.
- [28] C. Luwanga, T. W. Fang, A. Chandran, and Y. J. Lee, "Automatic Spread-F Detection Using Deep Learning," *Radio Sci*, vol. 57, no. 5, 2022, doi: 10.1029/2021RS007419.
- [29] S. Chakrabarti, D. Patgiri, R. Rathi, G. Dixit, M. V. Sunil Krishna, and S. Sarkhel, "Optimizing a deep learning framework for accurate detection of the Earth's ionospheric plasma structures from all-sky airglow images," *Advances in Space Research*, vol. 73, no. 12, 2024, doi: 10.1016/j.asr.2024.03.014.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [30] S. Priyadarshi *et al.*, “Machine Learning-based ionospheric modelling performance during high ionospheric activity,” in *Proceedings of the International Technical Meeting of The Institute of Navigation, ITM*, 2023. doi: 10.33012/2023/18618.
- [31] V. K. Maheswaran *et al.*, “Bi-LSTM based vertical total electron content prediction at low-latitude equatorial ionization anomaly region of South India,” *Advances in Space Research*, vol. 73, no. 7, 2024, doi: 10.1016/j.asr.2023.08.054.
- [32] T. Lan, H. Hu, C. Jiang, G. Yang, and Z. Zhao, “A comparative study of decision tree, random forest, and convolutional neural network for spread-F identification,” *Advances in Space Research*, vol. 65, no. 8, 2020, doi: 10.1016/j.asr.2020.01.036.
- [33] T. V. Rao, M. Sridhar, D. V. Ratnam, P. B. S. Harsha, and I. Srivani, “A Bidirectional Long Short-Term Memory-Based Ionospheric foF2 and hmF2 Models for a Single Station in the Low Latitude Region,” *IEEE Geoscience and Remote Sensing Letters*, vol. 19, 2022, doi: 10.1109/LGRS.2020.3045702.
- [34] S. A. Shidler and F. S. Rodrigues, “Modeling equatorial ionospheric vertical plasma drifts using machine learning,” *Earth, Planets and Space*, vol. 72, no. 1, 2020, doi: 10.1186/s40623-020-01227-w.
- [35] H. Breuillard, R. Dupuis, A. Retino, O. Le Contel, J. Amaya, and G. Lapenta, “Automatic Classification of Plasma Regions in Near-Earth Space With Supervised Machine Learning: Application to Magnetospheric Multi Scale 2016–2019 Observations,” *Frontiers in Astronomy and Space Sciences*, vol. 7, 2020, doi: 10.3389/fspas.2020.00055.
- [36] P. Thammavongsy, P. Supnithi, L. M. M. Myint, K. Hozumi, and D. Lakanhanh, “Equatorial spread-F forecasting model with local factors using the long short-term memory network,” *Earth, Planets and Space*, vol. 75, no. 1, 2023, doi: 10.1186/s40623-023-01868-7.
- [37] A. Atabati, M. Alizadeh, H. Schuh, and L. C. Tsai, “Ionospheric scintillation prediction on s4 and roti parameters using artificial neural network and genetic algorithm,” *Remote Sens (Basel)*, vol. 13, no. 11, 2021, doi: 10.3390/rs13112092.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [38] Z. Wang *et al.*, “Automatic Detection and Classification of Spread-F From Ionosonde at Hainan With Image-Based Deep Learning Method,” *Space Weather*, vol. 21, no. 11, 2023, doi: 10.1029/2023SW003498.
- [39] X. Zhao *et al.*, “The Prediction of Day-to-Day Occurrence of Low Latitude Ionospheric Strong Scintillation Using Gradient Boosting Algorithm,” *Space Weather*, vol. 19, no. 12, 2021, doi: 10.1029/2021SW002884.
- [40] J. Tang, Z. Zhong, J. Hu, and X. Wu, “Forecasting Regional Ionospheric TEC Maps over China Using BiConvGRU Deep Learning,” *Remote Sens (Basel)*, vol. 15, no. 13, 2023, doi: 10.3390/rs15133405.
- [41] J. Tang, Y. Li, D. Yang, and M. Ding, “An Approach for Predicting Global Ionospheric TEC Using Machine Learning,” *Remote Sens (Basel)*, vol. 14, no. 7, 2022, doi: 10.3390/rs14071585.
- [42] L. A. Salles, P. R. Pereira Silva, G. Schwinn Fagundes, J. Sousasantos, and A. Moraes, “Estimation of dusk time F-region electron density vertical profiles using LSTM neural networks: A preliminary investigation,” *Artificial Intelligence in Geosciences*, vol. 4, 2023, doi: 10.1016/j.aiig.2023.12.001.
- [43] E. B. Seba and G. Lapenta, “Modeling Equatorial to Mid-Latitudinal Global Night Time Ionospheric Plasma Irregularities Using Machine Learning,” *Space Weather*, vol. 22, no. 3, 2024, doi: 10.1029/2023SW003754.
- [44] C. Bi, P. Ren, T. Yin, Z. Xiang, and Y. Zhang, “Modeling and Forecasting Ionospheric foF2 Variation in the Low Latitude Region during Low and High Solar Activity Years,” *Remote Sens (Basel)*, vol. 14, no. 21, 2022, doi: 10.3390/rs14215418.
- [45] D. K. Karan *et al.*, “First Zonal Drift Velocity Measurement of Equatorial Plasma Bubbles (EPBs) From a Geostationary Orbit Using GOLD Data,” *J Geophys Res Space Phys*, vol. 125, no. 9, 2020, doi: 10.1029/2020JA028173.
- [46] D. Barros, H. Takahashi, C. M. Wrasse, and C. A. O. B. Figueiredo, “Characteristics of equatorial plasma bubbles observed by TEC map based on ground-based GNSS receivers over South America,” *Ann Geophys*, vol. 36, no. 1, 2018, doi: 10.5194/angeo-36-91-2018.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

- [47] A. L. C. Souza, P. O. Camargo, M. T. A. H. Muella, and F. Tardelli-Coelho, "Drift Velocity Estimation of Ionospheric Bubbles Using GNSS Observations," *Radio Sci*, vol. 56, no. 8, 2021, doi: 10.1029/2020RS007220.
- [48] T. Yu, M. Li, C. Xia, X. Zuo, Z. Liu, and B. Zhao, "A New Method for Deriving Equatorial Plasma Bubble Velocity by Tracing OI 630 nm All-Sky Images," *J Geophys Res Space Phys*, vol. 123, no. 11, 2018, doi: 10.1029/2018JA025332.
- [49] N. P. Chapagain, M. J. Taylor, J. J. Makela, and T. M. Duly, "Equatorial plasma bubble zonal velocity using 630.0 nm airglow observations and plasma drift modeling over Ascension Island," *J Geophys Res Space Phys*, vol. 117, no. 6, 2012, doi: 10.1029/2012JA017750.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ประวัติผู้เขียน

ชื่อ-นามสกุล: นางสาวธันนพัชญ์ ธนากุลเกษรัตน์

วัน เดือน ปีเกิด: 3 เดือนมีนาคม พ.ศ. 2538

ที่อยู่: บ้านเลขที่ 38 หมู่ที่ 3 ตำบลจอม่วง อำเภอศิลาลาด จังหวัดศรีสะเกษ รหัสไปรษณีย์ 33160

ประวัติการศึกษา: 2561 วิศวกรรมศาสตรบัณฑิต ภาควิชาวิศวกรรมอิเล็กทรอนิกส์

มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน ศูนย์กลางนครราชสีมา

2563 วิศวกรรมศาสตรมหาบัณฑิต ภาควิชาวิศวกรรมไฟฟ้า

มหาวิทยาลัยเทคโนโลยีราชมงคลอีสาน ศูนย์กลางนครราชสีมา



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

## ภาคผนวก

### บทความทางวิชาการที่ได้รับการตีพิมพ์ระหว่างการศึกษา

#### 1. บทความทางวิชาการที่ได้รับการตีพิมพ์

1. Thanakulketsarat, T., Supnithi, P., Myint, L.M.M. et al. Classification of the equatorial plasma bubbles using convolutional neural network and support vector machine techniques. *Earth Planets Space* 75, 161 (2023). <https://doi.org/10.1186/s40623-023-01903-7>

#### 2. ผลงานวิจัยที่ได้นำเสนอในงานประชุมวิชาการ

1. Thanakulketsarat, T., Supnithi, P., Myint, L.M.M. et al, "Equatorial Plasma Bubble Detection by Support Vector Machine at Chumphon Station, Thailand," 2022 37th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC), Phuket, Thailand, 2022, pp. 697-700, doi: 10.1109/ITC-CSCC55581.2022.9894989.

2. Thanakulketsarat, T., Supnithi, P., Myint, L.M.M. et al. "Equatorial Plasma Bubble Detection using the Convolutional Neural Network (CNN) and Support Vector Machine (SVM)", 2023 XXXVth General Assembly and Scientific Symposium of the International Union of Radio Science (URSI GASS), DOI: 10.23919/URSIGASS57860.2023.10265497

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า  
ไม่ว่ากรณีใดๆทั้งสิ้น อีกทั้งห้ามมิให้ตัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้