

การแยกแยะท่าทางของบุคคลผ่านกำแพงหรือผนังด้วยคลื่น
ความถี่กว้างยิ่งโดยการเรียนรู้เชิงลึก

POSTURE CLASSIFICATION BY UWB RADAR SYSTEM THROUGH THE WALL
USING DEEP LEARNING



วิทยานิพนธ์นี้สำหรับการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชาวิศวกรรมชีวการแพทย์
คณะวิศวกรรมศาสตร์
สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
พ.ศ.2564

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

POSTURE CLASSIFICATION BY UWB RADAR SYSTEM THROUGH THE WALL
USING DEEP LEARNING



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

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



COPYRIGHT 2021

SCHOOL OF ENGINEERING

KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า

ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

หัวข้อวิทยานิพนธ์	การแยกแยะท่าทางของบุคคลผ่านท่าทางหรือผนังด้วยคลื่นความถี่กว้างยิ่งโดยการเรียนรู้เชิงลึก
นักศึกษา	นายสมพล ชื่นตระกูลวิทยา
รหัสประจำตัว	59601122
ปริญญา	วิศวกรรมศาสตรมหาบัณฑิต
สาขาวิชา	วิศวกรรมชีวการแพทย์
พ.ศ.	2564
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.ดร.ภัทรพงษ์ ผาสุขกิจ

บทคัดย่อ

วิทยานิพนธ์นี้นำเสนอการแยกแยะท่าทางของบุคคลผ่านท่าทางหรือผนัง ผลิตสัญญาณด้วยการใช้คลื่นความถี่แถบกว้าง เรดาร์ โดยเลือกใช้สัญญาณความถี่แถบกว้างแบบอิมพัลส์ซึ่งเป็นพัลส์แบบสั้น สัญญาณที่ถูกสะท้อนกลับจะให้ความละเอียดที่สูง และยังสามารถใช้ทดสอบกับมนุษย์ได้อีกด้วย สัญญาณความถี่แถบกว้างแบบอิมพัลส์อยู่ที่ 3 GHz โดยข้อมูลที่ได้จากเก็บผลผ่านท่าทาง จะถูกนำไปแยกแยะลักษณะท่าทางการเรียนรู้ข้อมูลเชิงลึกออกเป็น 5 ท่าทาง ซึ่งงานวิจัยนี้ได้แยกแยะออกเป็น ทำยืน ทำเดิน ทำนอน ทำนั่ง และไม่มีบุคคล ซึ่งการแยกท่าทางยังมีประสิทธิภาพสูงถึง 96.64 เปอร์เซ็นต์ ซึ่งในอนาคตหากมีการพัฒนาต่อเนื่อง อาจเป็นประโยชน์ในการช่วยเหลือ ดูแลคนชรา ผู้ป่วยติดเตียง และช่วยแพทย์หรือพยาบาลต่อไป

Thesis	POSTURE CLASSIFICATION BY UWB RADAR SYSTEM THROUGH THE WALL USING DEEP LEARNNG
Student	Mr. Sompon Chuentrakulwittaya
Student ID.	59601122
Degree	Master of Engineering
Program	Biomedical Engineering
Year	2021
Thesis Advisor	Assoc. Prof. Dr. Pattarapong Phasukkit

ABSTRACT

This thesis presents the distinction of a person's posture through a wall. The signal is produced Ultra-wide-band radar, using a wide-band impulse signal, which is a short pulse. The reflected signal produces a high resolution. it allows not only detect presence of a human being, but also its position. The IR Ultra-wide-band frequency is at 3 GHz. The posture data is collected, next I applied signal data with the Deep Neural Network model to classify 5 classes, which in this research can be divided into standing, walking, lying, sitting, and no person. Which the separation of postures is still effective up to 96.64 %, which in the future if there is continuous development May be useful in helping to take care of the elderly, bedridden patients. and help the doctor or nurse continue

กิตติกรรมประกาศ

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

ข้าพเจ้าขอขอบพระคุณ บิดา มารดา พี่ชาย และเพื่อนสนิทของข้าพเจ้า ผู้ส่ง แรงกาย แรงใจ แรงผลักดัน ขอขอบพระคุณเป็นอย่างสูง มา ณ โอกาสนี้ด้วย

ข้าพเจ้าขอขอบคุณพี่น้องสมาชิกห้องปฏิบัติการ Burn Lab ที่คอยอำนวยความสะดวกช่วยเหลือและคอยเป็นผู้แลกเปลี่ยนความรู้กับข้าพเจ้า ทำให้ข้าพเจ้าได้เข้าใจในหลายสิ่งมากขึ้น รวมทั้งคอยเป็นแรงผลักดันซึ่งกันและกันมาโดยตลอด

ข้าพเจ้าคาดหวังว่าวิทยานิพนธ์ฉบับนี้อาจเป็นประโยชน์แก่บุคลากรในวงการการศึกษา นักเรียนนักศึกษาและผู้สนใจทั่วไป เพื่อนำไปพัฒนาและปรับใช้เป็นผลประโยชน์ต่อสังคมต่อไปในอนาคต หากวิทยานิพนธ์เล่มนี้มีข้อผิดพลาดประการใด ข้าพเจ้าขอกราบขออภัยไว้ ณ ที่นี้

สมพล ชื่นตระกูลวิทยา

สารบัญ

	หน้า
บทคัดย่อ.....	I
ABSTRACT.....	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VI
สารบัญรูป.....	VII
บทที่ 1 บทนำ.....	1
1.1 ความสำคัญของวิทยานิพนธ์.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	5
1.3 สมมติฐานของการศึกษา.....	5
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	7
2.1 ประวัติความเป็นมา.....	7
2.2 พื้นฐานของระบบ UWB เรดาร์.....	12
2.3 ทฤษฎีที่เกี่ยวข้อง.....	16
2.3.1 นิยามของ UWB เรดาร์.....	17
2.4 เทคโนโลยีในกลุ่มของปัญญาประดิษฐ์.....	21
2.4.1 Machine Learning.....	21
2.4.2 Deep Learning.....	21
2.5 ทฤษฎีความน่าจะเป็นของเบย์.....	22
2.5.1 Bayesian Neural Network.....	23
2.5.2 Artificial Neural Network.....	23
2.5.3 Activation Function.....	24
2.6 วัดประสิทธิภาพ Model จาก Confusion Matrix.....	28
บทที่ 3 วิธีการวิจัย.....	30
3.1 วิธีการวิจัย.....	30
3.2 สมการของสัญญาณที่ใช้ในการประมวลผล (Raw Data).....	32
3.3 การตัดสัญญาณที่ไม่มีการเปลี่ยนแปลง (Clutter Reduction).....	35
3.4 การใช้ตัวกรองสัญญาณชนิดเรียบ (Smooth Filter).....	37

สารบัญ (ต่อ)

	หน้า
3.5 การแปลงฟูเรียร์.....	38
3.6 เสออากาศ UWB สำหรับการตรวจจ็ับวัตถุหลังกำแพง.....	39
3.7 การประยุกต์ใช้ UWB เรดาร์ในการตรวจจ็ับมนุษย์หลังกำแพง.....	42
3.8 โค้ดการเก็บและใช้ข้อมูล	43
3.9 ออกแบบการเรียนรู้ข้อมูลเชิงลึก	45
3.9.1 การเตรียมข้อมูล.....	45
3.9.2 ออกแบบการเรียนรู้ข้อมูลเชิงลึก.....	45
3.10 จำแนกแยกแยะลักษณะท่าทางโดยใช้การเรียนรู้ข้อมูลเชิงลึก	47
บทที่ 4 ผลการทดลอง.....	51
4.1 การตรวจวัดบุคคลในลักษณะต่างๆแล้วนำไปเรียนรู้ข้อมูลเชิงลึก.....	52
4.2 ตาราง Confusion Matrix.....	63
บทที่ 5 ผลการทดลอง.....	65
5.1 สรุปผลการทดลอง.....	65
เอกสารอ้างอิง.....	66
ประวัติผู้เขียน.....	68

สารบัญตาราง

	หน้า
ตารางที่ 2.1 การเปรียบเทียบคุณสมบัติของคลื่นที่ย่านความถี่ต่างๆ.....	17
ตารางที่ 3.1 คุณสมบัติทางสายอากาศ Vivaldi และอุปกรณ์การทดลอง.....	31
ตารางที่ 4.1 คะแนน F1 และ ค่าความแม่นยำของทำยีนสำหรับการ training.....	53
ตารางที่ 4.2 คะแนน F1 และ ค่าความแม่นยำของทำยีนสำหรับการ test	53
ตารางที่ 4.3 คะแนน F1 และ ค่าความแม่นยำของทำเดินสำหรับการ training	55
ตารางที่ 4.4 คะแนน F1 และ ค่าความแม่นยำของทำเดินสำหรับการ test.....	55
ตารางที่ 4.5 คะแนน F1 และ ค่าความแม่นยำของทำนั่งสำหรับการ training.....	57
ตารางที่ 4.6 คะแนน F1 และ ค่าความแม่นยำของทำนั่งสำหรับการ test.....	57
ตารางที่ 4.7 คะแนน F1 และ ค่าความแม่นยำของทำนอนสำหรับการ training	59
ตารางที่ 4.8 คะแนน F1 และ ค่าความแม่นยำของทำนอนสำหรับการ test.....	59
ตารางที่ 4.9 คะแนน F1 และ ค่าความแม่นยำของการทดสอบแบบไม่มีบุคคลสำหรับการ training.....	61
ตารางที่ 4.10 คะแนน F1 และ ค่าความแม่นยำของการทดสอบแบบไม่มีบุคคลสำหรับการ test.....	61
ตารางที่ 4.11 คะแนน F1 และ ค่าความแม่นยำทั้งหมดสำหรับการ training.....	64
ตารางที่ 4.12 คะแนน F1 และ ค่าความแม่นยำทั้งหมดสำหรับการ test	64

สารบัญรูป

หน้า

รูปที่ 1.1 ระบบพัลส์เรดาร์ (pulse radar system) ชนิดตัวส่งและตัวรับเดียวกัน(Monostatic radar).....	2
รูปที่ 1.2 สัญญาณรบกวนที่ส่งผลกระทบต่อเรดาร์	3
รูปที่ 1.3 การเปรียบเทียบ SNR กับระยะทางของเป้าหมายที่มี RCS แตกต่างกัน.....	4
รูปที่ 1.4 การประยุกต์ใช้เรดาร์ทางการแพทย์	5
รูปที่ 1.5 การประยุกต์คลื่นแม่เหล็กไฟฟ้า.....	6
รูปที่ 2.1 ผู้ประดิษฐ์เจ้าของสิทธิบัตร นายคริสเตียน ฮัลซ์เมเยอร์.....	8
รูปที่ 2.2 เรดาร์ภาคพื้นดิน	9
รูปที่ 2.3 เรดาร์ซีทัก ได้ถูกติดตั้งบนเรือรบของกองทัพเยอรมนี [13]	10
รูปที่ 2.4 เรดาร์เนปจูน ได้ถูกติดตั้งบนเครื่องบินรบของกองทัพเยอรมนี [13].....	10
รูปที่ 2.5 ระบบ UWB เรดาร์พื้นฐาน [1]	12
รูปที่ 2.6 วิธี SAR สำหรับเครื่องบิน [1]	13
รูปที่ 2.7 FMCW พัลส์เรดาร์สามารถจำแนกเป้าหมายได้ดีกว่า CW พัลส์เรดาร์	13
รูปที่ 2.8 ภาพสองมิติที่ได้จากอัลกอริทึม Range Doppler สำหรับ SAR ของระบบเครื่องบิน.....	14
รูปที่ 2.9 ระบบ Synthetic Aperture Radar (SAR).....	15
รูปที่ 2.10 ระบบ Synthetic Aperture Radar (SAR).....	15
รูปที่ 2.11 การประยุกต์ UWB เรดาร์ในการตรวจจับคนหลังกำแพง [16] - [19].....	16
รูปที่ 2.12 รูปคลื่น UWB ที่มี $B_r > 0.25$ ตามเงื่อนไข FCC.....	18
รูปที่ 2.13 ชนิดของคลื่น UWB	20
รูปที่ 2.14 รูปของนายโทมัส เบย์ผู้คิดค้นทฤษฎีความน่าจะเป็นของเบย์	22
รูปที่ 2.15 ตัวอย่าง Neural Network ภาพจาก https://towardsdatascience.com/machine-learning-fundamentals-ii-neural-networks-f1e7b2cb3eef	23
รูปที่ 2.16 กราฟของ Relu.....	25
รูปที่ 2.17 การแก้ปัญหาของ ReLu โดยใช้ Leaky ReLu	26
รูปที่ 2.18 รูป N ของ sigmoid.....	27
รูปที่ 2.19 รูปที่ N ฟังก์ชัน sigmoid และ tanh.....	27
รูปที่ 2.20 แสดงความสัมพันธ์ระหว่าง Actual values กับ Predicted values.....	29
รูปที่ 3.1 การตรวจจับการเคลื่อนไหวของมนุษย์ขณะมีโลหะที่ระยะ 2 เมตร	30

สารบัญรูป (ต่อ)

	หน้า
รูปที่ 3.2 สัญญาณภาคส่งจากการทดลองของรูปที่ 3.1	31
รูปที่ 3.3 แผนผังวิธีการตรวจจับการเคลื่อนที่ของมนุษย์จากการวัดความถี่ดอปเพลอร์.....	32
รูปที่ 3.4 สัญญาณภาครับที่เกิดจากการแกว่งแขนของมนุษย์	33
รูปที่ 3.5 สัญญาณข้อมูลดิบที่ได้จากการทดลอง (Raw Data) ของรูปที่ 3.2.....	35
รูปที่ 3.6 สัญญาณภาครับจากการตัดสัญญาณที่ไม่เคลื่อนที่ออก (Clutter Reduction).....	36
รูปที่ 3.7 การใช้ตัวกรองสัญญาณชนิดเรียบ (Smooth Filter).....	38
รูปที่ 3.8 การแปลงฟูเรียร์แต่ละแถวของตารางเพื่อหาความถี่ดอปเพลอร์.....	38
รูปที่ 3.9 การจำลองเสาอากาศด้วยโปรแกรม CST.....	39
รูปที่ 3.10 ค่าสัมประสิทธิ์การสะท้อน S_{11}	40
รูปที่ 3.11 ภาพการจำลองอัตราขยายสัญญาณและมุมการส่ง	41
รูปที่ 3.12 เสาอากาศที่ได้จากชิ้นงานจริง	41
รูปที่ 3.13 การเซตระบบของการประมวลผลสัญญาณของการตรวจจับการเคลื่อนที่ของมนุษย์.....	42
รูปที่ 3.14 โค้ดการตั้งค่าการเชื่อมต่อ.....	43
รูปที่ 3.15 โค้ดตั้งค่าสเกลข้อมูล.....	43
รูปที่ 3.16 โค้ดเก็บข้อมูลตัวส่งสัญญาณ.....	44
รูปที่ 3.17 โค้ดเก็บข้อมูลตัวรับสัญญาณ	44
รูปที่ 3.18 โครงสร้าง Deep Nueral Network	46
รูปที่ 3.19 โครงสร้าง Deep Nueral Network ของทุกท่าทาง	46
รูปที่ 3.20 โค้ดไว้สำหรับคำนวณ Matrix	47
รูปที่ 3.21 เรียกฟังก์ชันไว้ใช้งาน	47
รูปที่ 3.22 โค้ทอ่านค่าไฟล์ที่ได้ทำการบันทึกเพื่อแปลงเป็น Matrix.....	48
รูปที่ 3.23 Normalization ค่าแกน X และแกน Y.....	48
รูปที่ 3.24 โค้ทสร้าง weight และ bias เริ่มต้น.....	48
รูปที่ 3.25 โค้ทคำนวณ leaning rate	49
รูปที่ 3.26 โค้ท Feed forward	49
รูปที่ 3.27 โค้ท Backpropagation	49
รูปที่ 4.1 การเซตระบบของการตรวจจับมนุษย์ยืนที่ระยะ 2 เมตรจากสายอากาศ.....	52

สารบัญรูป (ต่อ)

	หน้า
รูปที่ 4.2 โครงสร้าง Deep Nueral Network.....	52
รูปที่ 4.3 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset	53
รูปที่ 4.4 การเซตระบบของการตรวจจับมนุษย์เดิน 0 – 4 เมตรไปยังสายอากาศ	54
รูปที่ 4.5 โครงสร้าง Deep Nueral Network.....	54
รูปที่ 4.6 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset	55
รูปที่ 4.7 การเซตระบบของการตรวจจับการนอนของมนุษย์ที่ ระยะ 2 เมตร	56
รูปที่ 4.8 โครงสร้าง Deep Nueral Network.....	56
รูปที่ 4.9 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset	57
รูปที่ 4.10 การเซตระบบของการตรวจจับมนุษย์ในทำนองที่ระยะ 2 เมตรจากสายอากาศ	58
รูปที่ 4.11 โครงสร้าง Deep Nueral Network	58
รูปที่ 4.12 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset	59
รูปที่ 4.13 การเซตระบบของการตรวจจับโดยไม่มีมนุษย์	60
รูปที่ 4.14 โครงสร้าง Deep Nueral Network	60
รูปที่ 4.15 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset	61
รูปที่ 4.16 โครงสร้าง Deep Nueral Network ของทุกท่าทาง	62
รูปที่ 4.17 ตารางสำคัญในการวัดความสามารถของ machine learning ในการแก้ปัญหา classification ระบบ train	63
รูปที่ 4.18 ตารางสำคัญในการวัดความสามารถของ machine learning ในการแก้ปัญหา classification ระบบ test.....	63

บทที่ 1

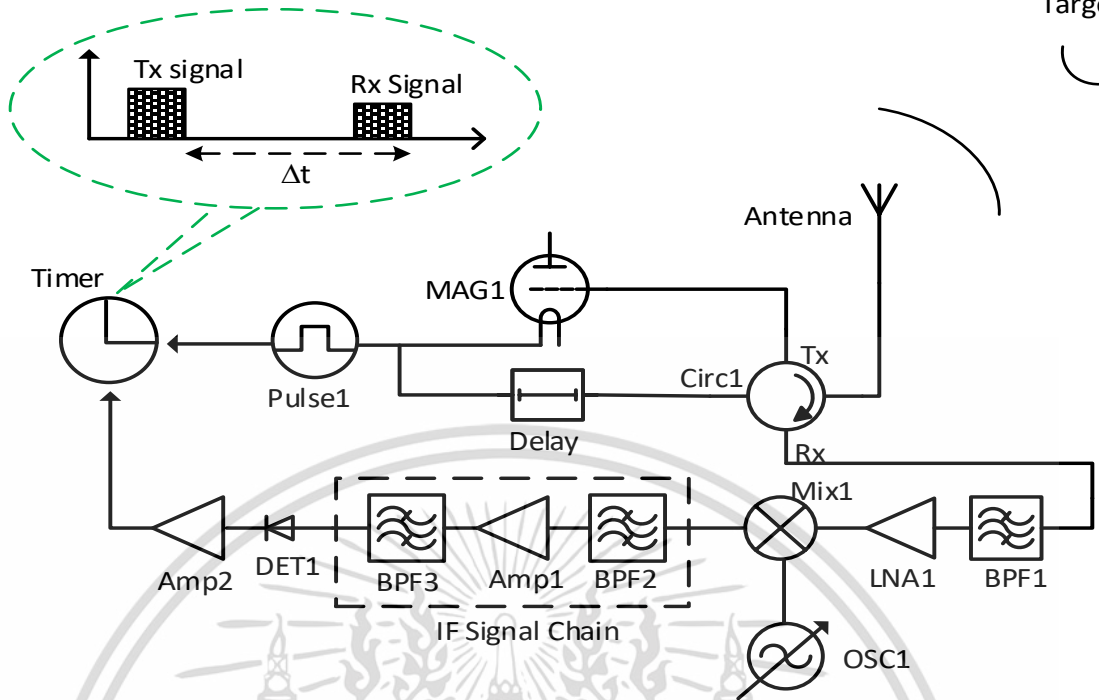
บทนำ

1.1 ความสำคัญของวิทยานิพนธ์

ในปัจจุบันเรดาร์ (Radar) เริ่มถูกวิจัยและประยุกต์ใช้อย่างเข้มข้นในช่วงสงครามโลกครั้งที่สองเพื่อตรวจจับเครื่องบินฝ่ายตรงข้ามให้ได้แม่นยำและรวดเร็วที่สุดในเตรียมการและวางแผนล่วงหน้า นอกจากนี้เรดาร์สามารถตรวจจับเป้าหมายได้อย่างรวดเร็วและมีประสิทธิภาพทุกภาคสนามและสภาพอากาศมาก เนื่องจากคลื่นแม่เหล็กไฟฟ้าที่เรดาร์ส่งนั้นเป็นคลื่นที่มีความเร็วแสงและเป็นคลื่นที่ไม่อาศัยตัวกลางในการส่ง ในปัจจุบันเรดาร์ที่ใช้ตรวจจับเป้าหมายทางอากาศใช้ระบบพัลส์เรดาร์ (pulse radar system) คือการส่งสัญญาณคลื่นสั้น (short pulse) เพื่อตรวจสอบสัญญาณภาครับได้แม่นยำมากขึ้น ดังรูปที่แสดง 1.1 คือพัลส์เรดาร์ชนิดตัวส่งและตัวรับเดียวกัน (Monostatic radar)



(ก) ASR-9 เรดาร์ใช้สำหรับการจราจรทางอากาศ (ข) TPS-59 3D เรดาร์ตรวจจับทางอากาศแบบเคลื่อนที่ได้ [1]



(ค) ไดอะแกรมการทำงานของระบบพัลส์เรดาร์


รูปที่ 1.1 ระบบพัลส์เรดาร์ (pulse radar system) ชนิดตัวส่งและตัวรับเดียวกัน (Monostatic radar)

จากรูปที่ 1.1(ค) เครื่องกำหนดสัญญาณพัลส์ (pulse1) ถูกใช้กระตุ้นแมกนีตรอน (mag1) ให้เกิดคลื่นแม่เหล็กไฟฟ้ากำลังสูงในย่านความถี่ไมโครเวฟและมีรูปคลื่นพัลส์ สัญญาณพัลส์ถูกใช้กระตุ้น (trigger) เพื่อปรับ Circ1 ให้เป็นโหมดการรับและกำหนดเวลาเริ่มรับสัญญาณภาครับที่ timer เมื่อได้รับสัญญาณภาครับแล้วทำการกรองสัญญาณรบกวนออก (BPF1) แล้วใช้ตัวขยายกำลังสัญญาณต่ำ (LNA1) ขั้นตอนต่อไปนำสัญญาณออสซิลเลต (OSC1) และสัญญาณที่ออกจาก LNA1 มาทำการดีมอดูเลต (demodulate) ผ่านตัวคูณสัญญาณ (MIX1) จากนั้นผ่านตัวกรองความถี่กลาง (IF signal chain) สุดท้ายใช้อุปกรณ์ตรวจจับแบบไดโอดเพื่อหาสัญญาณภาครับมาหยุดเวลาที่ timer เพื่อคำนวณหาระยะเวลาเลื่อน (Δt) เมื่อทราบเวลาเลื่อนแล้วสามารถคำนวณหาระยะทางของเป้าหมายได้จากสมการดังต่อไปนี้

$$R = \frac{c\Delta t}{2} \tag{1.1}$$

นอกจากนี้ประสิทธิภาพของระบบเรดาร์ในการตรวจจับระยะเป้าหมายมากที่สุด (maximum range detection) รูปที่ 1.2 สามารถถูกคำนวณได้จากสมการ (1.2)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 1.2 สัญญาณรบกวนที่ส่งผลกระทบต่อเรดาร์

สมการระยะทางสูงสุดของเป้าหมายที่เรดาร์จะตรวจจับได้ [2]

$$R_{max}^4 = \frac{P_t \cdot G^2 \cdot \lambda^2 \cdot \sigma}{(4\pi)^3 \cdot \text{SNR} \cdot k \cdot T_0 \cdot F_n \cdot L \cdot B_n} \quad (1.2)$$

โดยที่

R_{max} คือ ระยะมากที่สุดที่จะตรวจจับเป้าหมายได้ (maximum range, m)

P_t คือ พีคของกำลังไฟฟ้าภาคส่ง (peak transmit power, W)

G คือ อัตราขยายของเสาอากาศ (antenna gain, dB)

λ คือ ความยาวคลื่น (wave length, m)

σ คือ พื้นผิวของเป้าหมายที่คลื่นภาคส่งตกกระทบ Radar Cross Section (RCS), m^2

SNR คือ อัตราส่วนของกำลังสัญญาณภาครับเทียบกับกำลังสัญญาณรบกวน (signal to noise ratio, dB)

B_n คือ ความกว้างของความถี่สัญญาณรบกวน (system noise bandwidth, Hz)

k คือ ค่าคงที่ของ Boltzmann, $1.381 \cdot 10^{-23}$ (jou/deg)


T_0 คือ ค่าอุณหภูมิมาตรฐาน 290^0K

F_n คือ สัญญาณรบกวนจากระบบภาครับทั้งหมด (noise figure, dB)

L คือ ค่ากำลังสูญเสียทั้งหมดของระบบเรดาร์ (radar losses, dB)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

พารามิเตอร์
 $P_t = 1.5 \text{ MW}$
 $G = 45 \text{ dB}$
 $f_0 = 5.6 \text{ GHz}$
 $(\text{SNR})_{\min} = 20 \text{ dB}$
 $\text{RCS} = 0.1 \text{ m}^2$
 $\tau = 0.2 \text{ } \mu\text{s}$
 $L = 6 \text{ dB}$
 $F = 3 \text{ dB}$
 $T_0 = 290 \text{ K}$




รูปที่ 1.3 การเปรียบเทียบ SNR กับระยะทางของเป้าหมายที่มี RCS ต่างกัน

จากรูปที่ 1.3 อธิบายว่าระบบเรดาร์ที่มีประสิทธิภาพที่ดีควรมีค่า SNR น้อย ทำให้ระบบสามารถตรวจจับเป้าหมายขนาดเล็กได้ไกลขึ้น

อย่างไรก็ตามสมการที่ 1.2 ไม่สามารถถูกนำมาประยุกต์ใช้ในการตรวจจับมนุษย์หรือเป้าหมายสเกลระดับน้อยกว่าเซนติเมตรได้ (small and short range radar systems) เนื่องจากความกว้างของสัญญาณภาคส่งในแกนเวลา (τ) ต้องมีขนาดน้อยกว่าหรือเท่ากับนาโนวินาทีเรียกว่า Ultra-wideband (UWB pulse radar) เพื่อให้ความละเอียดในการจำแนกเป้าหมายตั้งแต่หนึ่งขึ้นไปได้อย่างชัดเจน ซึ่งรายละเอียดข้อดีและข้อเสียของ UWB เรดาร์จะถูกอธิบายตามตารางดังนี้

ต่อมาทฤษฎีนี้ได้รับการประยุกต์ใช้และพัฒนาอย่างกว้างขวาง เช่น การประยุกต์ใช้ทางการแพทย์ (bio-radiolocation)



(ก)



(ข)

รูปที่ 1.4 การประยุกต์ใช้เรดาร์ทางการแพทย์ (ก) การตรวจจับการหายใจ [2] (ข) การตรวจจับการเต้นของหัวใจ [3]

1.2 วัตถุประสงค์ของการวิจัย

- 1.2.1 ศึกษาความรู้เกี่ยวกับเกี่ยวกับองค์ประกอบ UWB เรดาร์
- 1.2.2 นำ UWB เรดาร์หาประยุกต์ใช้ในการตรวจสอบลักษณะท่าทางการเคลื่อนไหวของมนุษย์
- 1.2.3 นำข้อมูลที่ได้จากการบันทึกผล มาทำการใช้การเรียนรู้ข้อมูลเชิงลึกเพื่อแยกแยะลักษณะท่าทางต่าง

1.3 สมมุติฐานของการศึกษา



ในปัจจุบัน UWB เรดาร์ถูกใช้อย่างกว้างขวางในการตรวจจับและแสดงภาพสองมิติของเป้าหมายจากระยะไกลและใกล้ได้อย่างมีประสิทธิภาพ เพื่อตอบสนองความต้องการที่จะเข้าใจและทราบพฤติกรรมของเป้าหมายและตรวจสอบลักษณะท่าทางการเคลื่อนไหว โดยข้อได้เปรียบของ UWB เรดาร์นี้สามารถนำไปใช้ในการตรวจจับ ลักษณะท่าทางการเคลื่อนไหวของมนุษย์ในกิจกรรมต่างๆดังที่แสดงในรูป 1.5

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(ก)

(ข)



(ค)

(ง)

รูปที่ 1.5 การประยุกต์คลื่นแม่เหล็กไฟฟ้า UWB เพื่อตรวจจับและขึ้นภาพคนหลังกำแพง [4], [5], [6]

นอกจากนี้คลื่น UWB สามารถตรวจจับและแสดงความละเอียดในการจำแนกวัตถุในระดับเล็กกว่าสเกลเซนติเมตรได้มากกว่าคลื่นลักษณะอื่น นอกจากนี้ยังสามารถประยุกต์ใช้ในทางการแพทย์ในการวัดอัตราการหายใจและอัตราการเต้นของหัวใจโดยไม่ใช้การสัมผัสของผิวหนัง (non-contact sensor) เพื่อลดการระคายเคืองของผิวหนังในกรณีที่มีคนไข้จำนวนมากหรือคนไข้เป็นโรคผิวหนังชนิดติดต่อผู้อื่นตามรูปที่ 1.5 (ง)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2


ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงประวัติและความเป็นมาทฤษฎีต่าง ๆ ที่เกี่ยวข้องกับ UWB เรดาร์ในการตรวจจับการเคลื่อนไหวของมนุษย์พร้อมประมวลผลภาพสองมิติ และอธิบายการออกแบบระบบในการทดลองตลอดจนขบวนการประมวลผลสัญญาณภาครับ (Radar Signal Processing)

2.1 ประวัติความเป็นมา

ความเป็นมาของเรดาร์นั้นเริ่มต้นในช่วงปลายศตวรรษที่ 19 เมื่อมีการค้นพบคลื่นแม่เหล็กไฟฟ้าโดย ในปี ค.ศ. 1864 นักฟิสิกส์ชาวสกอตแลนด์ นายเจมส์ เคลิร์ก แมกซ์เวลล์ (James Clerk Maxwell) ได้ทำการค้นคว้าทฤษฎีและสมการอธิบายพฤติกรรมคลื่นแม่เหล็กไฟฟ้าขึ้น ซึ่งต่อมาในปี ค.ศ. 1886 นักฟิสิกส์ชาวเยอรมัน นายไฮน์ริช เฮิร์ตซ์ (Heinrich Hertz) ได้แสดงการทดลองเพื่อยืนยันทฤษฎีคลื่นแม่เหล็กไฟฟ้าของแมกซ์เวลล์ (Maxwell's equation) ทั้งนี้ยังได้ค้นพบว่าคลื่นแม่เหล็กไฟฟ้ามีคุณสมบัติสามารถสะท้อนกับวัตถุที่เป็นโลหะได้ [7] ในปี ค.ศ. 1900 นายนิโคลาส เทสลา (Nikola Tesla) วิศวกรชาวสหรัฐฯ ได้เสนอแนวความคิดเรื่องการใช้คลื่นแม่เหล็กไฟฟ้าเพื่อการตรวจจับและวัดความเร็วของเป้าหมายโดยมีหลักการเกี่ยวกับการสะท้อนก้องของเสียง (echo) [8]


ในช่วงศตวรรษที่ 20 ตอนต้น ได้มีพัฒนาการนำมาใช้อย่างเป็นทางการ ในปี ค.ศ. 1904 นายคริสเตียน ฮัลส์เมเยอร์ (Christian Huelsmeyer) นักฟิสิกส์ชาวเยอรมัน ทำการประดิษฐ์อุปกรณ์ที่เรียกว่า “เทเลเอ็นโมบิโลสโคป (Telemobiloscope)” ซึ่งใช้สำหรับการตรวจจับเรือในทะเลท่ามกลางหมอกหนาภายในระยะ 2 ไมล์ ด้วยการส่งคลื่นแม่เหล็กไฟฟ้าแบบต่อเนื่อง (Continuous wave; CW) ที่ความถี่ 650 MHz แต่อย่างไรก็ตามอุปกรณ์ยังไม่สามารถบอกระยะห่างของเป้าหมายได้ เพื่อป้องกันปัญหาเรือชนกัน เป็นครั้งแรกที่มีการใช้คลื่นแม่เหล็กไฟฟ้าในการตรวจจับวัตถุที่เป็นโลหะที่ระบบมีทั้งภาคส่งและภาครับ [9], [10]



รูปที่ 2.1 สิทธิบัตรของอุปกรณ์ “เทเลเอ็นโมบิโลสโคป (Telemobiloscope)” ที่จดทะเบียนในปี ค.ศ. 1905 และผู้ประดิษฐ์เจ้าของสิทธิบัตร นายคริสเตียน ฮัลซ์เมเยอร์ (Christian Huelsmeyer) [15]

จนกระทั่งในปี ค.ศ.1924 มีการทดลองเพื่อระบุความสูงของชั้นบรรยากาศไอโอโนสเฟียร์ด้วยหลักการสะท้อนของคลื่นแม่เหล็กไฟฟ้าย่านความถี่วิทยุ (radio echoes) โดยนักฟิสิกส์ชาวอังกฤษ เซอร์ เอ็ดเวิร์ด วิกเตอร์ แอปเปิ้ลตัน (Sir Edward Victor Appleton) ซึ่งประสบความสำเร็จและถือเป็นครั้งแรกที่มีการใช้คลื่นแม่เหล็กไฟฟ้าในการวัดระยะทาง ต่อมาในปี ค.ศ. 1935 นายโรเบิร์ต วัตสัน วัตต์ (Robert Watson-Watt) ได้เสนอวิธีการตรวจจับอากาศยานโดยใช้คลื่นแม่เหล็กไฟฟ้าและมีการทดลองสาธิตในงานวิจัยหัวข้อ “The Detection of Aircraft by Radio Methods” ซึ่งใช้ตั้งอยู่บนหลักการส่งคลื่นแม่เหล็กไฟฟ้าไปกระทบวัตถุ (radio wave bouncing) แล้ววัดข้อมูลจากการเดินทางของคลื่นในขณะเดียวกันทางฝั่งสหรัฐอเมริกา นายโรเบิร์ต เอ็ม เพจ (Robert M. Page) ได้ทำการทดลองส่งคลื่นแม่เหล็กไฟฟ้าเป็นสัญญาณพัลส์ความถี่ 60 MHz สามารถตรวจจับเครื่องบินที่อยู่ห่างออกไป 1.6 กิโลเมตร และในปี ค.ศ. 1936 สามารถพัฒนาเป็นการใช้สัญญาณความถี่ 28.6 MHz ตรวจจับเครื่องบินที่อยู่ห่างออกไป 40 กิโลเมตร ซึ่งนายเพจเป็นบุคลากรคนสำคัญในการพัฒนาเทคโนโลยีทางการตรวจจับโดยคลื่นแม่เหล็กไฟฟ้าของห้องปฏิบัติการวิจัยกองทัพเรือสหรัฐอเมริกา จนต่อมาในปี ค.ศ.1940 กองทัพเรือสหรัฐอเมริกาได้ให้ชื่อเรียกเทคโนโลยีนี้ว่า “เรดาร์ (Radar)” [9], [11]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(ก)

(ข)


รูปที่ 2.2 เรดาร์ภาคพื้นดิน (ก) เรดาร์เซนโฮม [12] (ข) เรดาร์เอส ซี อาร์-270[9]

ในยุคสงครามโลกครั้งที่ 2 (World war II) เรดาร์ได้มีวิวัฒนาการอย่างต่อเนื่องและเริ่มมีบทบาทเป็นอย่างมากโดยชาติมหาอำนาจในยุคนั้นที่มีการศึกษาระบบเรดาร์ เช่น สหรัฐอเมริกา สหราชอาณาจักร เยอรมนี เป็นต้น โดยเมื่อปี ค.ศ. 1937 ประเทศสหราชอาณาจักรได้นำผลงานที่นายโรเบิร์ต วัตสัน วัตต์ ได้พัฒนาขึ้นและจดสิทธิบัตรไปเมื่อปี ค.ศ. 1935 มาเป็นต้นแบบในการพัฒนาระบบเรดาร์สำหรับการเตือนภัยคุกคาม เรียกว่า “เซนโฮม (Chain Home; CH)” ซึ่งมีความถี่สัญญาณที่ใช้งาน 22 MHz สามารถตรวจจับอากาศยานได้ที่ความสูง 3,000 เมตร และระยะทางการตรวจจับที่ 150 กิโลเมตร [12] ภายใต้ความเกรงกลัวที่ว่าทางประเทศเยอรมนีจะสามารถพัฒนาอาวุธที่เรียกว่า “รังสีแห่งความตาย (death-ray)” ซึ่งเกรงว่าจะเป็นภัยคุกคามต่อทางสหราชอาณาจักร ต่อมาระบบเรดาร์เตือนภัยคุกคามนี้ได้ถูกนำมาติดตั้งเป็นระบบเตือนภัยชายฝั่งในบริเวณทางตะวันออกเฉียงและตอนใต้ของเกาะอังกฤษในปี ค.ศ. 1939 และมีบทบาทสำคัญในยุทธการบริเตน (Battle of Britain) ที่เพิ่มความแม่นยำในการค้นหาและโจมตีข้าศึก [9], [11]

ในทางฝั่งสหรัฐอเมริกาได้มีการพัฒนาเรดาร์ภาคพื้นดินชื่อว่า “เอส ซี อาร์-270 (SCR-270)” ซึ่งเตือนภัยคุกคามก่อนการโจมตีของกองทัพญี่ปุ่นเป็นเวลาประมาณชั่วโมงก่อนเกิดเหตุการณ์โจมตีเพิร์ลฮาร์เบอร์ (Attack on Pearl Harbor) เมื่อปี ค.ศ. 1941 นอกจากนี้ยังได้มีการโครงการร่วมระหว่างสหราชอาณาจักรและสหรัฐอเมริกา เพื่อการพัฒนาเครื่องแมกนีตรอนกำลังสูงสำหรับเรดาร์ (magnetron for high-power microwave radar) ซึ่งประสบผลสำเร็จและประดิษฐ์ “แมกนีตรอนเรโซแนนซ์ คิววิตตี้ (Resonant cavity magnetron)” สามารถผลิตสัญญาณพัลส์ความถี่สูงที่มีกำลังสูง ถูกนำไปใช้เป็นส่วนหนึ่งของระบบตรวจจับ “ลิดาร์ (Light detection and ranging)” ที่สามารถ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตรวจจับในสภาพอากาศทุกรูปแบบโดยปัจจุบันได้ถูกนำมาใช้ในการสื่อสารและวัดคุณภาพอากาศ [9], [11]



รูปที่ 2.3 เรดาร์ซีทัก ได้ถูกติดตั้งบนเรือรบของกองทัพเยอรมนี [13]



รูปที่ 2.4 เรดาร์เนปจูน ได้ถูกติดตั้งบนเครื่องบินรบของกองทัพเยอรมนี [13]

ประเทศเยอรมนีเป็นอีกชาติมหาอำนาจที่มีความเชี่ยวชาญทางด้านการพัฒนาเทคโนโลยีเรดาร์ซึ่งได้พัฒนาระบบปฏิบัติการเรดาร์อีกหลายแบบในระหว่างยุคสงครามโลกครั้งที่ 2 จุดเริ่มต้นในการพัฒนาเริ่มขึ้นในปี ค.ศ. 1933 นายรูดอล์ฟ कुโนด์ (Rudolph Kuhnold) หัวหน้าโครงการวิจัยทางด้านการวิเคราะห์สัญญาณของกองทัพเรือเยอรมัน ได้ทำการค้นคว้าวิธีการตรวจจับเป้าหมายใต้น้ำโดยใช้คลื่นเสียง ที่เรียกว่า “โซนาร์ (sonar)” หลังจากนั้นเขาได้ทำการพัฒนาเรดาร์สำหรับการตรวจจับเรือในทะเลด้วยตนเองมาจนถึงปี ค.ศ. 1935 มีการทดลองระบบซึ่งสามารถระบุตำแหน่งเรือที่จอดอยู่ห่างจากฝั่งได้ไกล 12 ไมล์ และเรือที่เคลื่อนที่ได้ไกล 5 ไมล์ หลังจากนั้นบริษัทเจมา (Gema company) ได้ดำเนินการพัฒนาโดยเพิ่มความถี่การใช้งานเป็น 600 MHz และสูงกว่า พบว่าสามารถตรวจจับเป้าหมายได้ไกลขึ้นและละเอียดมากขึ้น ต่อมาในปี ค.ศ. 1936 มีการพัฒนาระบบเรดาร์เตือนภัยคุกคามที่สำคัญของเยอรมนีในช่วงแรกของวิวัฒนาการเรดาร์เยอรมัน สามารถตรวจจับอากาศยานที่อยู่ไกลได้ 50 ไมล์ มีชื่อเรียกว่า “เรดาร์เฟรย่า (Freya radar)” ต่อมาในปี ค.ศ. 1937 ได้มีการประดิษฐ์ระบบเรดาร์ปฏิบัติการบนเรือสำเร็จเป็นครั้งแรกของโลก เรียกว่า “เรดาร์ซีทัก (Seetakt radar)” มีความถี่ปฏิบัติการที่ 375 MHz ตรวจจับได้ในระยะสั้นภายใน 9 ไมล์ เรดาร์ทั้งเอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

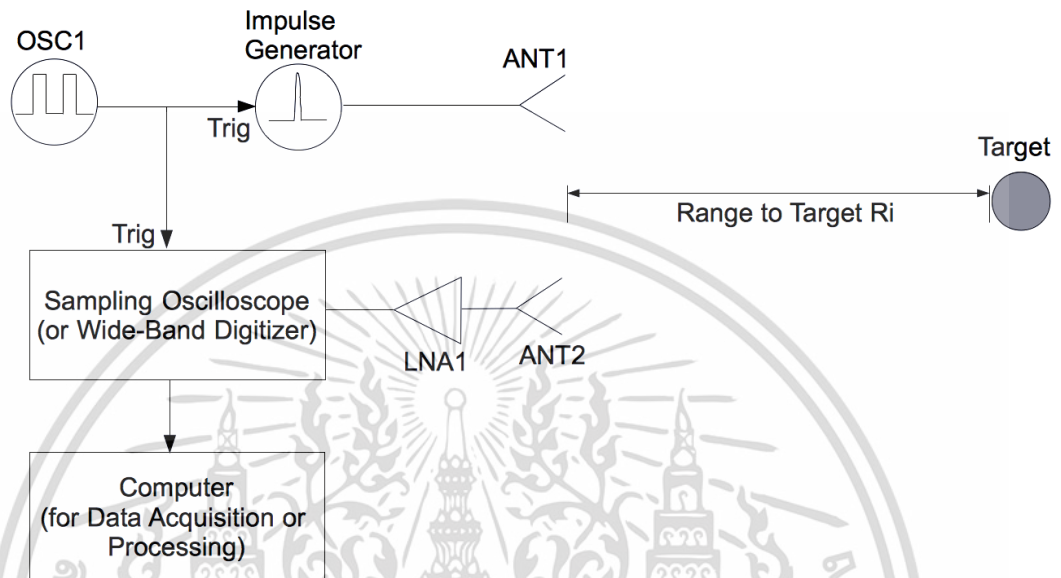
สองถูกนำมาใช้โดยกองทัพเรือเยอรมนี ในปี ค.ศ. 1938 [38] นอกจากนี้ยังมีการพัฒนาระบบเรดาร์ปฏิบัติการบนอากาศยาน เช่น เรดาร์เนปจูน (Neptun radar) และเรดาร์ลิกเตนสไตน์ (Lichtenstein radar) [9], [13]

จากรายละเอียดที่กล่าวมาสามารถระบุได้ว่าในยุคสงครามโลกครั้งที่ 2 เป็นยุคที่มีการพัฒนาระบบการตรวจจับเรดาร์และนำไปใช้งานอย่างกว้างขวางมาก โดยเฉพาะการตรวจจับทางไกล (remote sensing) เพื่อการสังเกตการณ์ข้าศึก การเตือนภัยก่อนการจู่โจมแก่พลเรือน ช่วยระบุตำแหน่งเพื่อการโจมตีทั้งในภาคพื้นดิน ทางน้ำ และอากาศ ในสภาพแวดล้อมทั้งกลางวัน กลางคืน และสภาพอากาศทุกแบบ ซึ่งบางครั้งเป็นการยากที่มนุษย์จะสังเกตการณ์ด้วยตนเอง

หลังจากสงครามโลกครั้งที่ 2 สิ้นสุดลง ได้มีการพัฒนาเทคนิคสำหรับระบบการตรวจจับเรดาร์ในยุคใหม่ เช่น ระบบช่องเปิดสังเคราะห์ (Synthetic aperture radar; SAR) ระบบเรดาร์เฟสอาร์เรย์ (phase array radar) ระบบระบุเป้าหมายเคลื่อนที่ (Moving target indication; MTI) ระบบเรดาร์ตรวจตราอันดับสอง (Secondary surveillance radar; SSR) และระบบเรดาร์พัลส์ดอปเปลอร์ (Pulse-doppler radar) เป็นต้น ซึ่งนำมาสู่การพัฒนาเทคโนโลยีที่เป็นประโยชน์ต่อการนำมาใช้ประโยชน์ในชีวิตประจำวันด้านอื่นมาจนถึงปัจจุบัน เช่น เรดาร์ตรวจสอบสภาพอากาศเพื่อใช้ในการพยากรณ์อากาศ เรดาร์ตรวจจับความเร็วยานพาหนะสำหรับการปฏิบัติหน้าที่ของเจ้าหน้าที่ตำรวจ เรดาร์ในระบบรถยนต์ [14], [15] เป็นต้น

2.2 พื้นฐานของระบบ UWB เรดาร์

ระบบเรดาร์พื้นฐานนี้ถูกนำเสนอโดยใช้อุปกรณ์ห้องทดลองขั้นพื้นฐานในการสร้างตามรูปที่แสดงด้านล่าง




รูปที่ 2.5 ระบบ UWB เรดาร์พื้นฐาน [1]

โดยที่สัญญาณสี่เหลี่ยมจาก OSC1 100kHz-500kHz เป็นตัวกำหนดการทำงานของเครื่องกำหนดพัลส์ (impulse generator) รุ่น HP 8133A 3GHz พร้อมกับเครื่องรับสัญญาณออสซิลโลสโคป (sampling oscilloscope) รุ่น Agilent DSO80604B 6GHz 40GSa/s เมื่อสัญญาณออกจากเครื่องกำหนดพัลส์ ผ่านเสาอากาศ (Vivaldi antenna) จะส่งคลื่นไปตกกระทบเป้าหมายและสะท้อนกับมายังภาครับ โดยมีตัวขยายกำลังสัญญาณต่ำ (Low Noise Amplifier, LNA) รุ่น R&K-AA260-OS Small signal amplifier 2GHz-5GHz ทำหน้าที่ขยายสัญญาณต่ำเพื่อให้เครื่องรับตรวจจับเป้าหมาย

ในปัจจุบันวิธีการระบุตำแหน่งในสองมิติและสามมิติของเป้าหมายมีอยู่สองหลักการ คือ

- 1) Synthetic Aperture Radar (SAR)
- 2) Inverse Synthetic Aperture Radar (ISAR) ในงานวิจัยนี้จะกล่าวถึงระบบ SAR ซึ่งระบบ SAR ถือกำเนิดและถูกใช้สำหรับระบบเครื่องบินตามรูปที่แสดง 2.6




รูปที่ 2.6 วิธี SAR สำหรับเครื่องบิน [1]

และสัญญาณภาคส่งโดยมากนิยมใช้เป็น FMCW ตามสมการด้านล่าง

$$s(t) = \begin{cases} \cos\left(2\pi f_c t + \pi \frac{f_{sw}}{\tau} t^2\right), & t < \tau \\ 0, & t \geq \tau \end{cases} \quad (2.6)$$


เนื่องจากสามารถจำแนกเป้าหมายได้ดีกว่าคลื่นสัญญาณ Sine ขณะคลื่นเกิดการทับซ้อนกันดังรูปที่แสดง 2.7 (ก) แต่คลื่นทับซ้อนที่มาจาก FMCW มีมูฟเฟสที่แตกต่างกันซึ่งสามารถแยกวัตถุได้ชัดเจนกว่าดังรูป 2.7 (ข)



รูปที่ 2.7 FMCW พัลส์เรดาร์สามารถจำแนกเป้าหมายได้ดีกว่า CW พัลส์เรดาร์

จากรูปที่ 2.6 ระบบ SAR ของเครื่องบินคือการบินเป็นเส้นตรงเพื่อเก็บค่าสัญญาณภาครับหลายตำแหน่งและได้ข้อมูลสัญญาณดังรูปที่แสดง 2.8 (ก)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.8 ภาพสองมิติที่ได้จากอัลกอริทึม Range Doppler สำหรับ SAR ของระบบเครื่องบิน (ก)


ข้อมูลดิบ (ข) บีบอัดระยะทางด้วย Matched Filter (ค) บีบอัดมุมด้วย Matched Filter

จากรูปที่แสดง 2.8 (ก) สัญญาณภาครับมีหลายตำแหน่งจะทำให้ภาพที่ได้มีความคมชัดมากขึ้นโดยใช้วิธีการ matched filter ตามสมการด้านล่าง


$$y(t_s) = F^{-1}\{F\{s_{ref}(t)\} \cdot F\{s_{rx}(t)\}^*\} \quad (2.7)$$

ผลลัพธ์ที่ได้ถูกแสดงดังรูป 2.6(ข) และ 2.6(ค) โดยเรียกกระบวนการนี้ว่าการบีบอัดในแนวระยะทาง (range compression) และการบีบอัดในแนวมุม (azimuth compression) และเรียกหลักการขึ้นภาพนี้ว่า Range and Doppler algorithm (RD)

อย่างไรก็ตามวิธีการเหล่านี้ไม่เหมาะสมกับ UWB เรดาร์ตรวจจับมนุษย์หลังกำแพงเพราะมีพื้นที่สแกนที่จำกัด ดังนั้นจึงเป็นที่มาของวิธี back projection เพื่อใช้กับระบบ SAR ตามรูปที่ 2.9 หรือระบบเสาอากาศอาร์เรย์ตามรูปที่แสดง 2.10 โดยใช้ข้อมูลไม่ต้องมากก็สามารถขึ้นภาพสองมิติได้ จึงเป็นข้อได้เปรียบของวิธีนี้ซึ่งจะกล่าวต่อไป



รูปที่ 2.9 ระบบ Synthetic Aperture Radar (SAR)




รูปที่ 2.10 ระบบ Synthetic Aperture Radar (SAR)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.3 ทฤษฎีที่เกี่ยวข้อง

ในปัจจุบัน Ultra-wideband (UWB) เรดาร์ถูกใช้อย่างกว้างขวางในการตรวจจับและแสดงภาพสองมิติของเป้าหมายจากระยะไกลและใกล้ได้อย่างมีประสิทธิภาพ เพื่อตอบสนองความต้องการที่จะเข้าใจและทราบพฤติกรรมของเป้าหมายและวัตถุโดยรอบจากระยะที่ไม่สามารถมองเห็นด้วยตาเปล่า ซึ่งนำไปสู่การประยุกต์ทางทหารและการช่วยเหลือมนุษย์ติดใต้ซากอาคารดังที่แสดงในรูป 2.9



รูปที่ 2.11 การประยุกต์ UWB เรดาร์ในการตรวจจับคนหลังกำแพง [16] - [19]

อย่างไรก็ตามในการประยุกต์ใช้คลื่นแม่เหล็กไฟฟ้าแต่ละชนิดล้วนแต่มีข้อได้เปรียบและเสียเปรียบในการประยุกต์ใช้ที่ต่างกันไปดังตารางที่ 2.1

ตารางที่ 2.1 การเปรียบเทียบคุณสมบัติของคลื่นที่ย่านความถี่ต่างๆ

	CW	FMCW	UWB	Infrared	X-ray
Detecting multiple targets	Low resolution	High resolution	Very high resolution	Very high resolution	Very high resolution
Through the Concrete wall	low attenuation in wall	low attenuation in wall	Middle attenuation in wall	Can't through wall	high attenuation in wall
Range detection	Difficult	Short and long ranges	Short and middle ranges	Short range	Short range
Dangerous to user	low	low	Very low (short pulse)	Cause heat to skin	Effect to DNA
Setup	Easy	Easy	Easy	Medium	Difficult
Cost	low	low	low	Medium	high

จากข้อที่หนึ่งของตาราง 2.1 จะเห็นได้ว่า UWB มีความละเอียดสูงที่สุดในการจำแนกหลายเป้าหมายพร้อมกับส่งผลอันตรายต่อผู้ใช้น้อยที่สุดเมื่อเทียบกับคลื่นชนิดต่างๆ ดังนั้น UWB พัลส์เรดาร์จึงมีความเหมาะสมในการตรวจจับและขึ้นภาพมนุษย์หรือวัตถุที่มีขนาดเล็กและต้องการความละเอียดสูง


2.3.1 นิยามของ UWB เรดาร์

นิยามและสมการของสัญญาณ Ultra-wideband (UWB) เป็นสิ่งแรกที่ต้องรู้ในการออกแบบระบบเรดาร์ ซึ่งนิยามของสัญญาณ UWB ถูกกำหนดโดยสมาคม Federal Communications Commission (FCC) ตามนิยามดังต่อไปนี้ แบนด์วิธแคบ (Narrowband) ถ้า $0 < B_f \leq 0.01$ แบนด์วิธกว้าง (Wideband) ถ้า $0.01 < B_f \leq 0.25$ แบนด์วิธกว้างพิเศษ (Ultra-Wideband) ถ้า $0.25 < B_f$ โดยที่ B_f อธิบายตามสมการดังต่อไปนี้

$$B_f = \frac{B}{f_c} = 2 \frac{f_H - f_L}{f_H + f_L} \quad (2.8)$$

โดยที่ f_H คือความถี่สูงสุดและ f_L คือความถี่ต่ำสุดวัดที่ตำแหน่งแอมพลิจูด -10 dB ตามรูปที่ 2.2

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.12 รูปคลื่น UWB ที่มี $B_f > 0.25$ ตามเงื่อนไข FCC

จากฟังก์ชันเกาส์เซียนทั่วไป (Gaussian Distribution Function) สามารถอธิบายดังสมการ (2.9) โดยที่ σ คือค่าเบี่ยงเบนมาตรฐาน (standard deviation) และ x คือชุดข้อมูล (Data) [19]

$$p(x) = \frac{1}{\sigma\sqrt{2\pi}} e^{-\left(\frac{x}{\sqrt{2}\sigma}\right)^2} \quad (2.9)$$

จากสมการเกาส์เซียนนี้สามารถนำมาประยุกต์ใช้อธิบายสัญญาณ UWB เนื่องจากสัญญาณ UWB มีลักษณะเป็นคลื่นสั้น (pulse signal) ตามที่แสดงในสมการที่ (2.10) [5]

$$G(t, a) = A_0 e^{-\left(\frac{t}{a}\right)^2} \quad (2.10)$$

จากสมการที่ (2.10) ตัวแปร

$$a = \sqrt{2}\sigma = \frac{t_{au}}{\sqrt{2}} = \frac{\sqrt{2}}{6} \tau$$

τ คือความกว้างสัญญาณ (pulse width) และอนุพันธ์ของฟังก์ชันอันดับ n สามารถอธิบายตามสมการด้านล่าง เพื่อใช้ในการอธิบายลักษณะคลื่น UWB อันดับต่างๆ

$$G_n(t, a) = \frac{d^n G(t, a)}{dx^n} = (-1)^n \frac{1}{a^n} H_n\left(\frac{t}{a}\right) G(t, a) \quad (2.11)$$


โดยที่ H_n คือสมการพหุนามของเฮอริไมท์ (Hermite polynomials)

$$H_n\left(\frac{t}{a}\right) = (-1)^n e^{\left(\frac{t}{a}\right)^2} \frac{d^n}{dx^n} e^{-\left(\frac{t}{a}\right)^2} \quad (2.12)$$

ตารางที่ 2.2 สมการพหุนามของเฮอริไมท์ที่ $H_n(x)$

$H_0(x) = 1$
$H_1(x) = 2x$
$H_2(x) = 4x^2 - 2$
$H_3(x) = 8x^3 - 12x$
$H_4(x) = 16x^4 - 48x^2 + 12$
$H_5(x) = 32x^5 - 160x^3 + 120x$

จากสมการที่ (2.11) และ (2.12) นำมาอธิบายคลื่น UWB ลักษณะต่างๆ ตามที่แสดงรูปที่ 2.11



รูปที่ 2.13 ชนิดของคลื่น UWB

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4 เทคโนโลยีในกลุ่มของปัญญาประดิษฐ์

เทคโนโลยีในกลุ่มของปัญญาประดิษฐ์ (Artificial Intelligence – AI) ได้กลายเป็นเทคโนโลยีที่สามารถพบเห็นและใช้งานได้ในชีวิตประจำวัน โดยเฉพาะในสมาร์ตโฟนที่หลายต่อหลายคนใช้กัน ปัญญาประดิษฐ์สามารถแบ่งเป็นสองประเภท คือ การเรียนรู้ด้วยจักรกล หรือ Machine Learning และที่กำลังเป็นที่สนใจในปัจจุบันอย่างการเรียนรู้เชิงลึกหรือ Deep Learning

2.4.1 Machine Learning

Machine learning คือ เทคนิคที่เกิดขึ้นจากการที่มนุษย์ทำการสอนและบันทึกข้อมูลให้คอมพิวเตอร์เรียนรู้ข้อมูลที่มีอยู่ (จากอดีตที่เกิดขึ้นแล้ว) และสามารถที่จะช่วยในการตัดสินใจในอนาคต หรือสามารถตอบคำถาม ชนิดของข้อมูลที่ยังไม่เกิดขึ้นได้ โดยแบ่งออกเป็น 3 ประเภท ดังนี้

1. Supervised Learning คือการเรียนรู้แบบมีการบอกโมเดลว่า คำตอบที่ถูกต้องคืออะไร แล้วให้โมเดลพยายามเรียนรู้ที่จะตอบให้ถูก เช่น สอนโมเดลให้เมื่อรับภาพเข้าไปแล้ว บอกได้ว่าในภาพนั้นมีวัตถุอะไรอยู่ โดยเราก็จะต้องเตรียมคำตอบของแต่ละภาพเอาไว้ด้วย ซึ่งแน่นอนว่าไม่ใช่เรื่องง่ายๆ เลยที่จะเตรียมข้อมูลเหล่านี้เอาไว้ในปริมาณมาก ซึ่งก็เป็นข้อเสียของการเรียนรู้ประเภทนี้

2. Unsupervised Learning คือการเรียนรู้แบบที่ไม่ต้องมีการเตรียมคำตอบที่ถูกต้องมาให้ล่วงหน้า โมเดลจะทำการเรียนรู้จากรูปแบบของข้อมูลเอง ว่าข้อมูลแบบไหนคล้ายกัน อยู่ใกล้กัน อะไรทำนองนั้น ฟังดูแล้วก็เหมือนจะง่ายนะครับ ดูจะแก้ปัญหาของ Supervised Learning ได้เลย แต่พอเอาเข้าจริง มันก็ยังมีจุดอ่อนอยู่มาก ในเรื่องของ ประสิทธิภาพและการนำไปใช้จริง เช่น ในบางครั้งเราไม่รู้ว่่าสิ่งที่โมเดลมันแบ่งออกมาแล้วเนี่ย มันแบ่งด้วยอะไรกันแน่ ซึ่ง Unsupervised Learning เนี่ย ที่ยังเห็นคนนำมาใช้บ่อยๆ ในปัจจุบันก็คือ Autoencoder (ซึ่งบางอย่างอาจมีการใช้ Autoencoder แบบ Supervised แต่ในที่นี้ขอพูดถึงแบบ Unsupervised) ซึ่งเป็นการเรียนรู้แบบที่ให้ Input ผ่านเข้าไปในโมเดล เพื่อสร้าง Output ที่หน้าตาเหมือนกับ Input แล้วนำเอาคุณสมบัติตรงกลางของโมเดลมาใช้

3. Semi-Supervised Learning คือ ข้อมูลที่ใช้สอนและบันทึกข้อมูลในคอมพิวเตอร์ บางส่วน ซึ่งมีการบอก Output ควรเป็นอย่างไร และข้อมูลบางส่วนไม่มีการบอกคำตอบที่ถูกต้อง

2.4.2 Deep Learning

Deep Learning คือ การจำลองรูปแบบการประมวลผลของสมองมนุษย์ โดยใช้โครงข่ายคล้ายเซลล์ประสาทในการประมวลผล เมื่อได้รับข้อมูลมา Deep Learning จะทำการแบ่งแยกข้อมูล และรายละเอียดต่างๆ ที่ได้รับมาทั้งหมด แล้วนำมาประมวลผลหาจุดเด่นและจุดแตกต่างของข้อมูลใน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เชิงลึก คล้ายกับการกรองข้อมูลเป็นชั้นๆ แล้วสรุปผลข้อมูลออกมาเป็น Output และตรวจสอบว่าข้อมูลนั้นส่งผลอย่างไร ผิด หรือถูก เช่น มีข้อมูลสัตว์ 1 ตัวที่ไม่ทราบว่าจะเป็นอะไร Deep Learning จะทำการตรวจสอบและคาดการณ์ ว่า ‘อาจจะเป็น’ สัตว์ชนิดนี้ โดยไม่จำเป็นต้องระบุว่ามีปีกหรือมีหาง Deep Learning แค่ ‘คาดการณ์’ เอาไว้ก่อน

หาก Deep Learning คาดการณ์ผิด ตัวมันจะเรียนรู้และปรับเปลี่ยนการประมวลผล เพื่อให้ Output ที่ออกมามีความถูกต้องมากขึ้น และยังเรียนรู้มาก Deep Learning ก็จะเข้าใจได้มากขึ้น และลงลึกในรายละเอียดยิบย่อยได้มากขึ้น จนสามารถสังเกตความแตกต่างของข้อมูลได้แม้เพียงเล็กน้อยก็ตาม โดยที่มนุษย์ไม่จำเป็นต้องแนะนำ

2.5 ทฤษฎีความน่าจะเป็นของเบย์



รูปที่ 2.14 รูปของนายโทมัส เบย์ผู้คิดค้นทฤษฎีความน่าจะเป็นของเบย์

ทฤษฎีความน่าจะเป็นของเบย์ ความน่าจะเป็นของเบย์ เป็นทฤษฎีที่พูดถึงความน่าจะเป็นในการเกิดสิ่งหนึ่ง ก็ต่อเมื่ออีกสิ่งที่ได้เกิดขึ้น หรือที่เรียกกันว่า “Given” ซึ่งถ้าใครได้เรียนมา ลักษณะของการเขียนสัญลักษณ์ ยกตัวอย่างเช่น $P(A|B)$ อ่านว่า ความน่าจะเป็นของเหตุการณ์ A เมื่อเกิดเหตุการณ์ B แล้ว ซึ่งกรณีที่จะพูดถึงต่อไปนี้ ึ่งความน่าจะเป็นแบบต่อเนื่อง (Continuous Probability) ก็เปลี่ยน Summation เป็น Integration

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


2.5.1 Bayesian Neural Network

Bayesian Neural Network เป็นเครื่องมือหนึ่งที่ใช้ในการพยากรณ์อนาคต โดยเรียนรู้จากเรื่องต่างๆ ในอดีต หรือบางครั้งก็ถูกเรียกว่า Pattern Recognition เพราะเกิดจากการเรียนรู้ที่จะหา Output จากรูปแบบของการเกิดสิ่งต่างๆ จากข้อมูล ซึ่งเจ้า Bayesian Neural Network นี้สามารถเรียกได้ว่าเป็นเครื่องมือชนิดหนึ่งในหลายประเภทของกระบวนการทำ Machine Learning (การเรียนรู้ของเครื่อง)

Bayesian Neural Network คือ การเลิกใช้ Weight และ Bias ที่เป็นตัวกำหนดแล้วเปลี่ยนมาใช้ในการแพร่กระจายแทน แล้วทุกครั้งที่ทำการทำนายก็สุ่ม Weight และ Bias มาจากการแพร่กระจายของข้อมูลนั้นๆ โดยวิธีการเรียนรู้ และการอนุมาน จากนั้นก็เปลี่ยนไป โดยการใช้วิธี Kullback-Leibler divergence และ Variational Inference

2.5.2 Artificial Neural Network

ต่อไปนี้จะกล่าวถึง Neural Network หรือเรียกอีกอย่างหนึ่งว่า โครงข่ายประสาทเทียม คือ การที่เราเอาเทคนิคการพยากรณ์ด้วยสมการเชิงเส้น มาใช้ต่อกับหลายๆ ตัว และหลายๆ ชั้น



รูปที่ 2.15 ตัวอย่าง Neural Network ภาพจาก <https://towardsdatascience.com/machine-learning-fundamentals-ii-neural-networks-f1e7b2cb3eef>

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ส่วนประกอบของ Neural Network จากรูปที่ 2.13 จะเห็นว่าส่วนประกอบของ Neural Network มีอยู่ด้วยกัน 3 ส่วน คือ

1. Input Layer ที่ชั้นนี้จะเป็นข้อมูล input ของเรานั้นเองครับ จำนวนของโหนดขึ้นอยู่กับจำนวนของ input ของเรา ว่ามีข้อมูลอะไรบ้างที่เรานำเข้ามามีคิดในโมเดล เช่น ถ้าข้อมูลของลูกค้าเป็น input ของเรา ซึ่งประกอบด้วย ยกตัวอย่างเช่น อายุ เพศ จังหวัดที่อาศัย รวมทั้งสิ้น 4 อย่าง input layer ก็จะมี 4 โหนด (ปกติแล้วใน Machine Learning เราจะเรียกปัจจัยที่นำมาวิเคราะห์เหล่านี้ว่า feature)

2. Hidden Layer เป็นชั้นที่อยู่ระหว่างกลาง ซึ่งจะมีผลอย่างมากต่อประสิทธิภาพในการเรียนรู้ของโมเดล ซึ่ง hidden layer นั้นจะมีกี่ชั้นก็ได้ แล้วแต่ผู้สร้าง ซึ่งแต่ละชั้นจะมีจำนวนของ Neuron เท่าไหร่ก็ได้เช่นกัน ซึ่งการเพิ่มชั้นและจำนวน neuron ก็จะมีผลต่อการทำงานของโมเดล ในส่วนของ hidden layer มีการทำงานเปรียบเสมือนส่วนที่เรียนรู้ข้อมูลเชิงลึก หรือ deep learning นั้นแหละครับ โดยสิ่งสำคัญใน hidden layer อีกอย่างหนึ่งคือ ทุกๆ โหนดต้องประกอบด้วย nonlinearity function ด้วย ซึ่งจะมาพูดถึงภายหลังต่อไป

3. Output Layer ชั้นที่เราจะนำเอาข้อมูลจากการคำนวณไปใช้ จำนวนของโหนดในชั้นนี้ขึ้นอยู่กับรูปแบบของ output ที่เราจะเอาไปใช้ ซึ่งถ้ายกตัวอย่างง่ายๆ เช่น ถ้างานที่เราทำเป็น Regression ก็กำหนดให้ output layer เป็นแบบ 1 โหนด เพราะต้องการคำตอบค่าเดียว ถ้าเป็นหลายค่าก็เพิ่มไปตามที่ต้องการ เช่น ในบางงานเราอาจจะ predict หาตำแหน่งของภาพในแกน x และ y พร้อมๆ กัน ในกรณีนี้เราก็ใส่ output layer เป็น 2 โหนด เป็นต้น

Prediction ที่คำนวณจาก Neural Network (Forward Propagation) เราจะกล่าวถึงเรื่อง Linear Regression ซึ่งหลักการของมันก็คือ การเอาข้อมูลไปคูณกับ weight แล้วบวกกับ bias และ bias คือ ตัวเลขที่บวกเข้าไปเพื่อปรับให้ค่าที่คำนวณออกมาถูกต้องมากขึ้น โดยค่านี้จะไม่ขึ้นอยู่กับตัวแปรใดๆ เป็นตัวแทนของ “ธรรมชาติของข้อมูล”

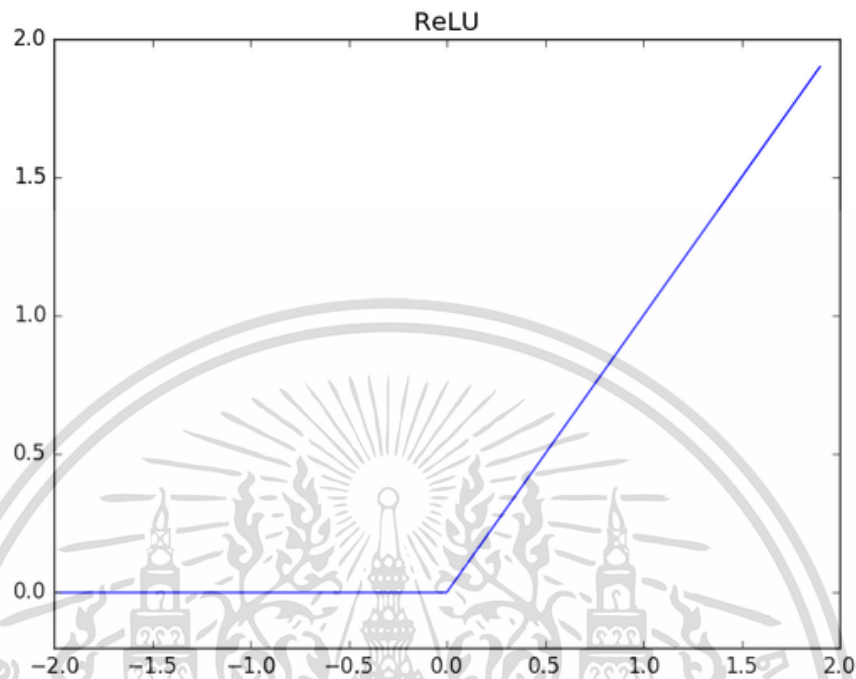
2.5.3 Activation Function

Activation Function คือ ฟังก์ชันที่ใช้เพื่อหา output ของ node หรือรู้จักอีกชื่อว่า Transfer Function ใน Neural Networks ใช้ในการกำหนด output ของ Neural Network ว่าเป็นจริงหรือไม่ โดยการนำไป maps กับผลลัพธ์ตั้งแต่ 0 จนถึง 1 หรือ -1 จนถึง 1 ฯลฯ (ขึ้นอยู่กับฟังก์ชันที่เราเลือก) แบ่งได้ 2 แบบ

- 1 ฟังก์ชันแบบเชิงเส้น
- 2 ฟังก์ชันแบบไม่ใช่เชิงเส้น

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในที่นี้เราจะเลือกใช้ฟังก์ชันแบบไม่เชิงเส้นเนื่องจากสามารถแก้ไขได้ เมื่อเราได้ผลลัพธ์มาแล้วเราจะนำค่านั้นไปเพื่อสร้างข้อมูลขึ้นมา ส่งเป็นชั้นถัดไปฟังก์ชัน




รูปที่ 2.16 กราฟของ Relu

เป็นฟังก์ชันที่ได้รับความนิยมสูงสุดในโลกขณะนี้ นิยมใช้ใน Convolutional Neural Network หรือ Deep Learning

ถ้าเราดูจากกราฟ ReLU จะมีแค่ครึ่งเดียว โดยที่ถ้าค่าต่ำกว่า 0 จะได้ output เป็น 0 โดยทันที หากค่ามากกว่าหรือเท่ากับ 0 ก็จะได้ output ที่มากกว่า 0 นั้นเอง แต่ปัญหาของคือการแปลงค่าลบเป็น 0 ทั้งหมดนั้นจะลดความสามารถของโมเดลในการเทรนจากข้อมูล หมายความว่าไม่ว่าค่าจะเป็นค่าเท่าใดก็ตามหากติดลบแล้ว เข้าสู่ ReLU function ก็จะกลายเป็น 0 ทันที ทำให้ส่งกระทบที่กราฟของเราไม่สามารถ map ค่าติดลบอะไรได้เลย


เมื่อเราได้ผลลัพธ์มาแล้ว เราจะนำค่านั้นไปผ่านฟังก์ชันแบบไม่เชิงเส้น เพื่อสร้างเป็นข้อมูลส่งไปให้ layer ถัดไป function นี้เราเรียกว่า ในตัวอย่างนี้เลือกใช้ nonlinearity function ที่ชื่อว่า

นอกจาก ReLU แล้ว ยังมีอีกหลายฟังก์ชันที่เราสามารถใช้ได้ตรงตำแหน่งนี้ แต่ที่ได้รับความนิยมที่สุดในปัจจุบันก็คือ ReLU เพราะว่าได้เปรียบในเชิงแคลคูลัส ในตอนที่โมเดลเรียนรู้เพื่อปรับค่า weight จะทำได้เร็วกว่าแบบอื่นๆ แต่ก็ขอแนะนำเสนอฟังก์ชันอื่นๆ ที่เคยได้รับความนิยม และยังมีอยู่บ้าง



รูป 2.17 การแก้ปัญหาของ ReLU โดยใช้ Leaky ReLU

ถูกออกแบบมาเพื่อแก้ปัญหาของ ReLU นั่นคือการรั่ว (Leaky) นั่นเองการรั่วนี้จะช่วยเพิ่ม range ของ ReLU ออกไปกลายเป็น (-infinity ถึง infinity) นั่นเอง โดยการใช้ค่า a โดยค่า a จะเป็น 0.01 หากเมื่อใดก็ตามค่า $a \neq 0.01$ เราจะเรียกว่า Randomized ReLU วิธีการที่ Neural Network ใช้ในการเรียนรู้ข้อมูล (Back Propagation) การเรียนรู้ของโมเดลเกิดขึ้นเมื่อเราเอาค่าที่ได้จากการคำนวณในส่วน forward propagation มาเทียบกับค่าของ output ที่เกิดขึ้นจริง (Ground Truth) ค่าความผิดพลาดที่เกิดขึ้นเราเรียกได้หลายชื่อ ไม่ว่าจะเป็น Loss, Error หรือ Residual มาถึงตรงนี้ โมเดลก็เหมือนกับคนเลยครับ เมื่อ loss แล้วจึงเรียนรู้ ก็คือเรียนรู้เอาจากความผิดพลาดวิธีการก็เหมือนกับโมเดล linear regression ครับ ที่โมเดลของเราจะปรับ weight เพื่อให้คำนวณผลลัพธ์ได้แม่นยำมากขึ้น โดยดูจากการ differentiation ค่า loss เทียบกับค่า weight แต่ละตัว วิธีการตรงนี้ ฟังดูยากและซับซ้อนครับ แต่จริงๆ ก็ไม่ได้มีอะไร แค่เรา diff แล้วก็ diff ไปเรื่อยๆ ครับ องค์ความรู้ที่โมเดลได้รับสุดท้ายแล้วองค์ความรู้ที่โมเดลของเราได้รับมานั้นก็คือ weight ที่ทำการปรับเรียบร้อยแล้ว ซึ่งเป็น weight ที่เมื่อใช้คำนวณ forward propagation แล้วจะเกิด loss น้อยที่สุด (ก็คือมีความคลาดเคลื่อนไปจากความจริงน้อยที่สุด)

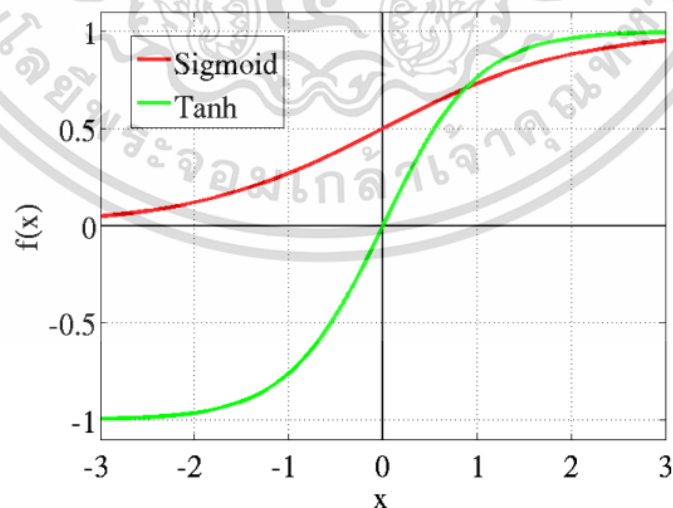


รูปที่ 2.18 รูป N ของ sigmoid

Sigmoid เป็นฟังก์ชันที่เปลี่ยนค่าทั้งหมดบนเส้นจำนวนให้กลายเป็นช่วง (0, 1) สมการคือ

$$\text{Sigmoid}(z) = 1/(1 + e^{(-x)}) \quad (2.13)$$

เป็นฟังก์ชันที่ S curve สาเหตุที่เป็นที่นิยมเพราะค่า output ของมัน (0-1) ดังนั้นมันจึงเหมาะสมมากหากเราต้องการหาค่าความน่าจะเป็น (probability) ของ output โดยค่า prob จะมีตั้งแต่ 0 จนถึง 1 แต่มันยังมีข้อเสียตรงที่ Sigmoid function อาจจะส่งผลให้ neural network ติดขัดได้ขณะเวลาที่เทรนโมเดล ดังนั้น softmax function จึงใช้งานได้มากกว่า sigmoid function ในกรณีที่เราต้องการทำ multiclass classification นั้นเอง



รูปที่ 2.19 รูปที่ N ฟังก์ชัน sigmoid และ tanh

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Tanh ทำงานคล้าย sigmoid แต่เปลี่ยนช่วงของ output เป็น (-1, 1) สมการคือ

$$\tanh(z) = \left(\frac{2}{1 + e^{-2z}} \right) - 1 \quad (2.14)$$

หน้าตาของมันจะคล้ายกับ Sigmoid แต่ output ของมันคือ (-1 จนถึง 1) ซึ่ง sigmoid คือ (0 จนถึง 1) จุดเด่นของฟังก์ชันนี้คือถ้าค่าที่ได้ออกมาเป็นค่าติดลบก็จะมีแนวโน้มไป maps กับค่าที่เป็นลบสูง โดยถ้าค่าเป็น 0 ก็จะมีแนวโน้มไป maps กับค่าใกล้ๆ 0 ในกราฟสูงมาก tanh function ถูกนิยมนำไปใช้กับ classification ที่มี 2 คลาส

เป็นฟังก์ชันที่ได้รับความนิยมสูงสุดในโลกขณะนี้ นิยมใช้ใน Convolutional Neural Network หรือ Deep Learning

Softmax Function หรือ SoftArgMax Function หรือ Normalized Exponential Function คือ ฟังก์ชันที่รับ Input เป็น Vector ของ Logit จำนวนจริง แล้ว Normalize ออกมาเป็นความน่าจะเป็น Probability ที่ผลรวมเท่ากับ 1 หรือเข้าใจง่าย ๆ ว่า Softmax รับตัวเลขเข้าไป แล้วแปลงออกมาเป็น Probability เรามาดูตัวอย่างกันจะเข้าใจง่ายขึ้น

$$\text{softmax}_j(z) = \left(\frac{e^{z_j}}{\sum_{k=1}^K e^{z_k}} \right) \quad (2.15)$$

Softmax มักถูกนำไปไว้ Layer สุดท้าย ของ Neural Network เพื่อให้ Output ออกมาเป็น Probability ไปคำนวณ Negative Log Likelihood เป็น Cross Entropy Loss เช่น ในงาน Single Class Classification Softmax ถูกนำไปใช้บ่อย ในงาน Classification จนถึงขนาดมีคนเรียกว่า Softmax Classifier หรือ Softmax Loss

2.6 วัดประสิทธิภาพ Model จาก Confusion Matrix

Confusion Matrix คือตารางสำคัญในการวัดความสามารถของ machine learning ในการแก้ปัญหา classification

การที่จะนำโมเดลใช้งานจริงได้นั้น จำเป็นต้องมีการวัดประสิทธิภาพโมเดล ก่อนว่าโมเดลนั้นมีประสิทธิภาพเพียงพอที่จะนำมาพัฒนา หรือ นำไปใช้งานด้านต่างๆ ซึ่งการวัดประสิทธิภาพนั้นส่วนใหญ่จะวัดค่าจากใน Table ข้อมูลที่มี (Confusion Matrix)

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

รูปที่ 2.20 แสดงความสัมพันธ์ระหว่าง Actual values กับ Predicted values

True Positive (TP) คือ สิ่งที่โปรแกรมทำนายว่า “จริง” และมีค่าเป็น “จริง”

True Negative (TN) คือ สิ่งที่โปรแกรมทำนายว่า “ไม่จริง” และมีค่า “ไม่จริง”

False Positive (FP) คือ สิ่งที่โปรแกรมทำนายว่า “จริง” แต่มีค่าเป็น “ไม่จริง”

False Negative (FN) คือ สิ่งที่โปรแกรมทำนายว่า “ไม่จริง” แต่มีค่าเป็น “จริง”

โดยทั่วไปแล้วจะมีตัววัดที่นิยมใช้กันในงานวิจัยและการทำงานต่างๆ อยู่ 3 ค่า และสมการ คือ

1. Precision เป็นการวัดความแม่นยำของข้อมูล โดยพิจารณาแยกที่ละคลาส

$$\frac{TP}{TP+FP} \quad (2.16)$$

2. Recall เป็นการวัดความถูกต้องของ Model โดยพิจารณาแยกที่ละคลาส

$$\frac{TP}{TP+FN} \quad (2.17)$$

F1-Score คือค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall สร้าง F1 ขึ้นมาเพื่อเป็น single metric ที่วัดความสามารถของโมเดล (ไม่ต้องเลือกระหว่าง precision, recall เพราะเฉลี่ยให้แล้ว)


$$F1 = 2 * \left(\frac{precision*recall}{precision+recall} \right) \quad (2.18)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 3 วิธีการวิจัย

3.1 วิธีการวิจัย

อ้างอิงข้อมูลได้นำการศึกษาการประมวลผลสัญญาณของการตรวจจับการเคลื่อนที่ของมนุษย์ในลักษณะท่าทางต่างๆ จากการทดลองจริงที่ระยะต่างๆ ซึ่งให้ผลที่ดีที่สุดโดยไม่เกิน 4 เมตร



(ก) การเซตระบบของการประมวลผลสัญญาณของการตรวจจับการเคลื่อนที่ของมนุษย์



(ข) การทดลองจริง

รูปที่ 3.1 การตรวจจับการเคลื่อนไหวของมนุษย์ขณะมีโลหะที่ระยะ 2 เมตร

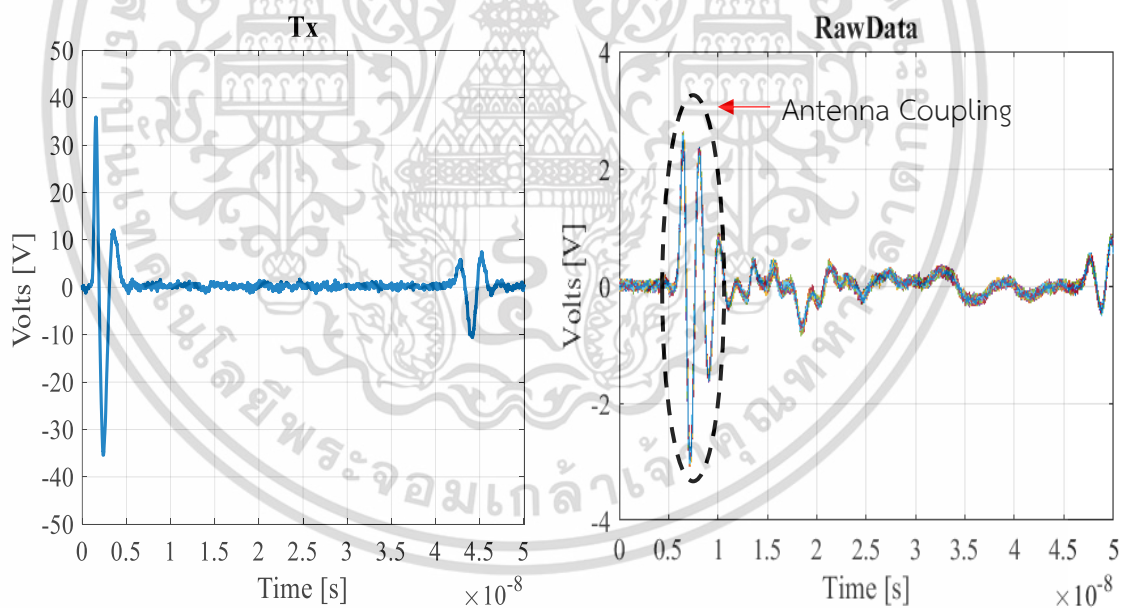
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 3.1 คุณสมบัติทางสายอากาศ Vivaldi และอุปกรณ์การทดลอง

ความถี่กลางของเสาอากาศแบบ Vivaldi	2 - 5 GHz, 11 dBi
ตัวขยายกำลังสัญญาณของภาคส่ง Mini-Circuits Amplifier ZVE-8G	2 GHz-8 GHz, 30 dBm
ตัวขยายกำลังสัญญาณของภาครับ R&K-AA260-OS Small Signal Amplifier	2 GHz-5 GHz, 26 dBm
ระยะห่างระหว่างสายอากาศทั้งสอง	25 cm
เครื่องกำเนิดสัญญาณ UWB ยี่ห้อ Picosecond Pulse Labs, Model-2600	$V_{out} = 1V$ ค่าความถี่กลางอยู่ที่ 3 GHz
อุปกรณ์รับสัญญาณ Agilent Oscilloscope, DSO80604B	ย่านความถี่ 6 GHz 40 GSa/s

จากนั้นทำการปล่อยคลื่นสัญญาณที่ภาคส่งแล้วทำการเก็บสัญญาณที่ภาครับแสดงดังรูปที่

3.2

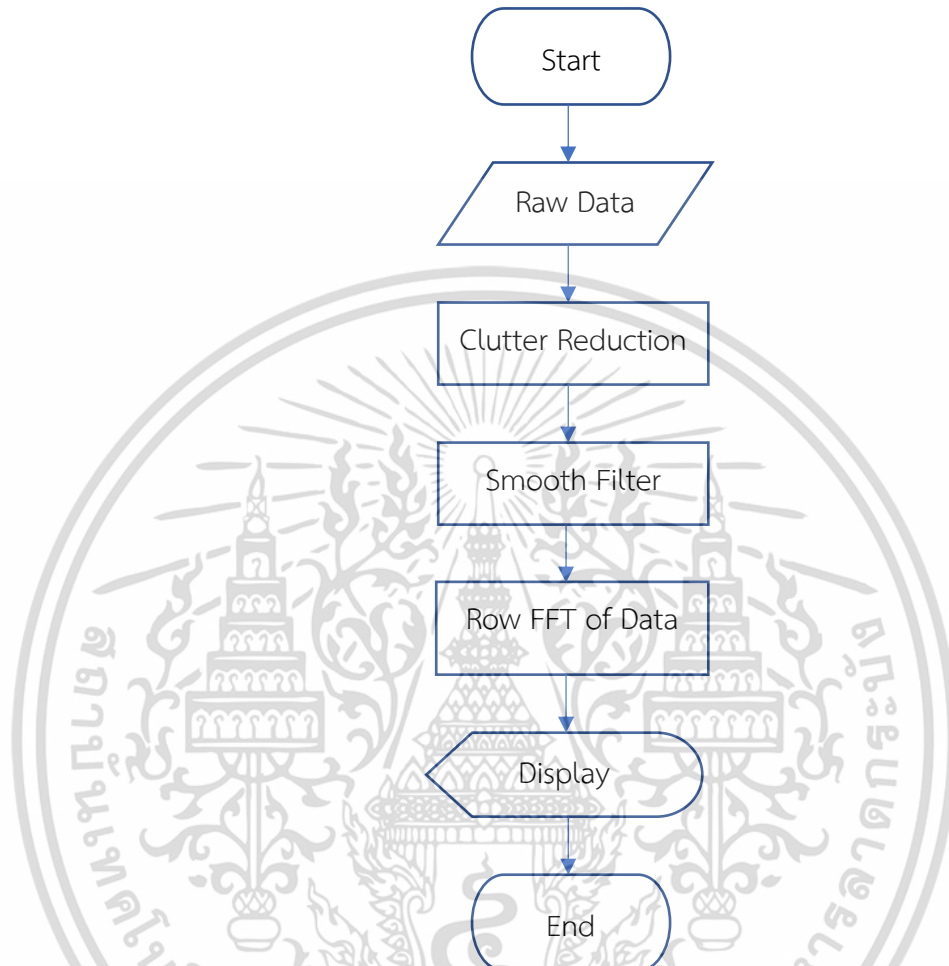


รูปที่ 3.2 สัญญาณภาคส่งจากการทดลองของรูปที่ 3.1

จากรูปที่ 3.2 จะเห็นได้ว่าสัญญาณภาครับมีความเพี้ยนมากเนื่องพลังงานภาคส่งแพร่มายังภาครับมาก (Antenna Coupling, Mutual Inductance) ส่งผลให้สัญญาณที่สะท้อนจากมนุษย์เห็นค่าได้น้อยมาก สาเหตุเกิดจากความถี่กลางของเสาอากาศ 1 GHz ไม่เข้ากัน (Impedance Mismatch) กับความถี่กลางของเครื่องกำเนิดสัญญาณ ปัญหานี้สามารถถูกแก้โดยออกแบบเสาอากาศใหม่ให้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เหมาะกับความถี่ของเครื่องกำเนิด อย่างไรก็ตามในหัวข้อนี้จะนำเสนอวิธีการตรวจจับสัญญาณของมนุษย์จากการวิธีการตรวจจับความถี่ต่อเพลอร์ของมนุษย์ตามแผนผังที่แสดงด้านล่าง (Signal Processing Flowchart) ดังต่อไปนี้



รูปที่ 3.3 แผนผังวิธีการตรวจจับการเคลื่อนที่ของมนุษย์จากการวัดความถี่ต่อเพลอร์


จากรูปที่ 3.3 แสดงวิธีการประมวลผลสัญญาณขั้นพื้นฐานของสัญญาณ UWB ในการตรวจจับการเคลื่อนที่ของมนุษย์หรือวัตถุอื่นๆ จากการวัดความถี่ต่อเพลอร์ โดยขั้นตอนแรกคือการเก็บข้อมูลของสัญญาณ

3.2 สมการของสัญญาณที่ใช้ในการประมวลผล (Raw Data)

สัญญาณที่ภาครับ (Received Signal) มีความถี่ของสัญญาณภาคส่งบวกกับความถี่ต่อเพลอร์ของมนุษย์ ($f_0 + f_d$) จึงเป็นการยากที่จะหาความถี่ต่อเพลอร์ด้วยวิธี demodulation ทั่วไป ดังนั้นในการหาความถี่ต่อเพลอร์นั้นสามารถหาได้จากการเปลี่ยนแปลงของมุมเฟสของสัญญาณที่

สะท้อนจากมนุษย์ ($df/d\tau = 2\pi f_d$) ดังรูปที่ 3.4

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 3.4 สัญญาณภาครับที่เกิดจากการแกว่งแขนของมนุษย์

โดยที่

แกนตั้ง t คือแกนเวลาของสัญญาณภาครับเรียกว่า time range หรือ fast time
แกนนอน τ คือเวลาที่ใช้ในการเก็บข้อมูลเรียกว่า scan time หรือ slow time

นอกจากนี้สัญญาณภาครับ $R(t, \tau)$ สามารถถูกอธิบายได้ตามสมการด้านล่างดังต่อไปนี้

$$R(t, \tau) = \sum_p \sigma_p s(t - t_p) + \sum_h \sigma_h s(t - t_h(\tau)) \quad (3.1)$$

โดยที่

$s(t)$ คือสัญญาณ UWB ภาคส่งถูกอธิบายในสมการ (1.13)

$\sum_p \sigma_p s(t - t_p)$ คือจำนวนสัญญาณที่ได้จากวัตถุที่ไม่เคลื่อนที่ (static target signals) โดย σ_p คือขนาดของสัญญาณสะท้อน (Reflection amplitude)

$\sum_h \sigma_h s(t - t_h(\tau))$ คือจำนวนสัญญาณที่ได้จากมนุษย์ (human motion) โดย σ_h คือขนาดของสัญญาณสะท้อนของมนุษย์ (Reflection human amplitude) นอกจากนี้ $t_h(\tau)$ คือเวลาที่เลื่อน (Time Shift) เนื่องจากการเคลื่อนที่ของวัตถุตั้งสมการที่ (3.2) โดยที่ c คือความเร็วแสงค่า ส่วนค่า “2” ในสมการนั้นหมายถึงการประมาณระยะทางขาไปบวกกับระยะทางขากลับของสัญญาณ เนื่องจากการว่างเสาอากาศทั้งสองมีระยะใกล้กันเมื่อเทียบกับตำแหน่งของมนุษย์

$$t_h(\tau) = \frac{2d(\tau)}{c} \quad (3.2)$$

และ $d(\tau)$ คือระยะห่างระหว่างมนุษย์และเสาอากาศถูกอธิบายสมการที่ (3.3)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

$$d(\tau) = d_0 + A_w \sin(2\pi f_w \tau) + A_r \sin(2\pi f_r \tau) + A_h \sin(2\pi f_h \tau) \quad (3.3)$$

โดยที่ d_0 คือตำแหน่งของมนุษย์ที่ไม่เคลื่อนที่ (nominal distance) และ $A_w \sin(2\pi f_w \tau)$, $A_r \sin(2\pi f_r \tau)$, $A_h \sin(2\pi f_h \tau)$ คือระยะทางแบบฮาร์โมนิกอย่างง่าย (simple harmonic motion) ที่เกิดจากการแกว่งแขน การหายใจ และการเต้นของหัวใจตามลำดับ โดยที่ A_w, A_r, A_h คือขนาดของสัญญาณ และ f_w, f_r, f_h คือความถี่ต่อเพลอร์

จากสมการ $R(t, \tau)$ เป็นฟังก์ชันเวลาต่อเนื่อง (continuous time signal) ถูกอธิบายเป็นฟังก์ชันเวลาไม่ต่อเนื่อง (Discrete Time Signal) เนื่องจากค่าที่ได้จากการวัดสัญญาณเป็นข้อมูลแบบดิจิทัล

$$R[n, m] = \sum_p \sigma_p s[n\Delta t - t_p] + \sum_h \sigma_h s[n\Delta t - t_h[m\Delta\tau]] = c[n] + h[n, m] \quad (3.4)$$

ในทางปฏิบัติจริงสัญญาณภาครับเกิดความเพี้ยนและสามารถถูกอธิบายได้ดังต่อไปนี้

$$R[n, m] = h[n, m] + c[n] + l[n, m] + w[n, m] + q[n, m] \quad (3.5)$$

โดยที่

$h[n, m]$ คือสัญญาณการเคลื่อนไหวของมนุษย์ (human micro-motion signal)


$c[n]$ คือสัญญาณรบกวนที่ไม่มีการเปลี่ยนแปลง (static clutter) เกิดจากสัญญาณที่ส่งนั้นตกกระทบกับวัตถุที่ไม่เคลื่อนที่ เช่น กำแพงและวัตถุรอบๆ ของสนามทดสอบ

$l[n, m]$ คือความเพี้ยนของสัญญาณเชิงเส้นตรง (linear trend) เกิดจากระบบการทริกเกอร์ของเรดาร์ (Radar Trigger) เช่น อุปกรณ์ A/D ที่ถูกรบกวนเป็นต้น

$w[n, m]$ คือสัญญาณรบกวนแบบเกาส์เซียน (Add White Gaussian Noise, AWGN) โดยมากเกิดจากความร้อนของตัวอุปกรณ์ในระบบ

$q[n, m]$ คือสัญญาณรบกวนที่มีการเปลี่ยนแปลง (non-static clutter) เช่นวัตถุรอบข้างมีการเคลื่อนไหวที่ไม่ใช่มนุษย์

สุดท้ายการทดลองจริงของรูป 3.2 สามารถอธิบายในรูปสมการ (3.5) ได้ดังรูปที่ 3.5



รูปที่ 3.5 สัญญาณข้อมูลดิบที่ได้จากการทดลอง (Raw Data) ของรูปที่ 3.2

ในหัวข้อต่อไป จะกล่าวถึงวิธีการลดสัญญาณ $c[n]$, $l[n, m]$, $w[n, m]$ และ $q[n, m]$ ตามลำดับ ส่งผลให้สัญญาณ $h[n, m]$ มีความชัดเจนมากขึ้น เพื่อตรวจจับตำแหน่งของมนุษย์จากความถี่ตอบเพลอร์


3.3 การตัดสัญญาณที่ไม่มีการเปลี่ยนแปลง (Clutter Reduction)

สัญญาณที่ไม่มีการเปลี่ยนแปลง $c[n]$ สามารถถูกพิจารณาเป็นสัญญาณไฟฟ้ากระแสตรงหรือ ฟังก์ชันค่าเฉลี่ยได้ดังสมการด้านล่าง

$$c[n] = \sum_p \sigma_p s[n\Delta t - t_p] = \frac{1}{M} \sum_{m=1}^M R[n, m] \quad (3.6)$$

ดังนั้นสัญญาณภาคีที่ถูกรับปรุงคือ

$$\Omega[n, m] = R[n, m] - \frac{1}{M} \sum_{m=1}^M R[n, m] \quad (3.7)$$



รูปที่ 3.6 สัญญาณภาครับจากการตัดสัญญาณที่ไม่เคลื่อนที่ออก (Clutter Reduction)

จากรูปที่ 3.6 สามารถระบุตำแหน่งของมนุษย์ได้จากการเคลื่อนไหวเล็กน้อย ในกรณีการทดลองสัญญาณของ antenna coupling มีขนาดสัญญาณที่มากและมีการเปลี่ยนแปลงของเวลาเล็กน้อยเนื่องจากความคลาดเคลื่อนอุปกรณ์ความถี่สูงภาครับภาคส่งและสิ่งแวดล้อมรอบข้าง อย่างไรก็ตามปัญหานี้หรือปัญหาเกี่ยวกับสัญญาณของกำแพงสามารถถูกแก้โดยการกำหนดให้เป็นศูนย์เพราะเรารู้อยู่แล้วว่าขนาดสัญญาณเหล่านี้มีค่ามากกว่าสัญญาณของมนุษย์ เพราะกำลังภาครับแปรผกผันกับตำแหน่งของมนุษย์แบบยกกำลังสี่ $P_r \propto 1/d^4$ โดยกระบวนการทางโปรแกรมถูกนำเสนอที่อัลกอริทึม 3.1

Algorithm 3.1 Clutter Reduction

Require: we need to reduce the clutter environment

- 1: $s_{dc}[n, 1] = \frac{1}{M} \sum_{m=1}^M R[n, m]$
- 2: for $m = 1$ to M do
- 3: $R[n, m] = R[n, m] - s_{dc}[t, 1]$
- 4: end for

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.4 การใช้ตัวกรองสัญญาณชนิดเรียบ (Smooth Filter)

เมื่อทำการตัดสัญญาณชนิดคงที่แล้ว ต่อมาทำการลดสัญญาณรบกวนเพื่อเพิ่ม Signal to Noise Ratio (SNR) โดยอัลกอริทึมตามด้านล่าง

Algorithm 3.1 Clutter Reduction

Require: we need to reduce the clutter environment

$$1: s_{dc}[n, 1] = \frac{1}{M} \sum_{m=1}^M R[n, m]$$

2: for $m = 1$ to M do

$$3: R[n, m] = R[n, m] - s_{dc}[t, 1]$$

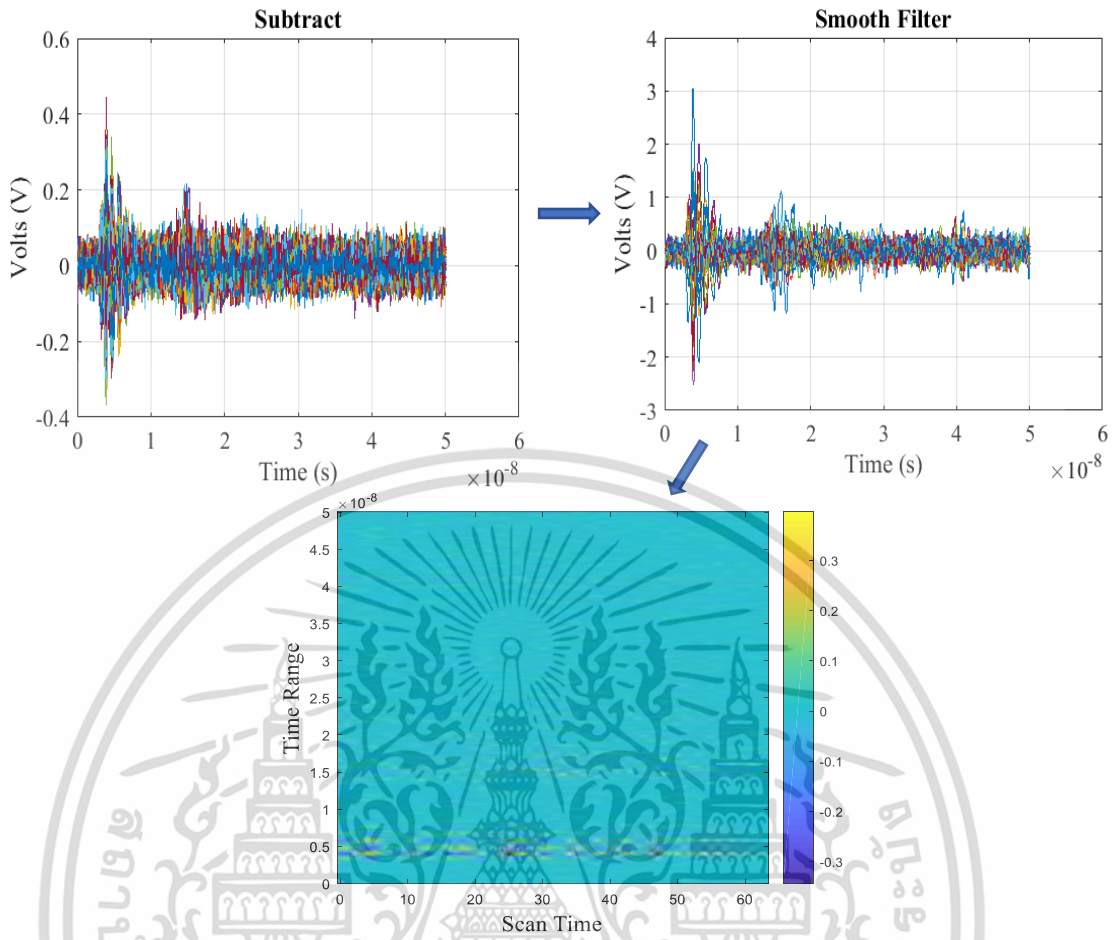
4: end for

for $\tau = 1$ to M do

$$R[t, \tau] = \frac{1}{2\lambda + 1} (R[t + \lambda, \tau] + R[t + \lambda - 1, \tau] + \dots + R[t - \lambda, \tau])$$

end for

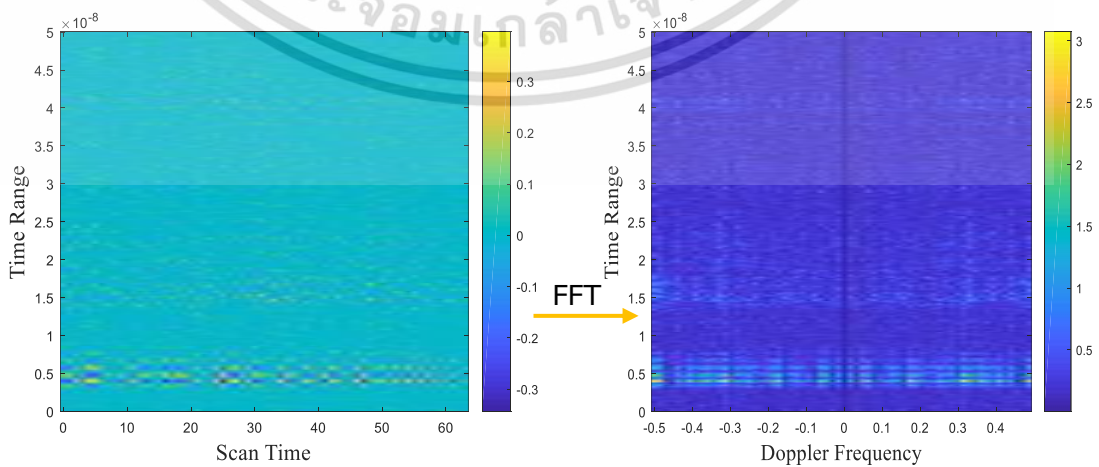
โดย λ คือจำนวนค่าที่ใช้ในการเฉลี่ย



รูปที่ 3.7 การใช้ตัวกรองสัญญาณชนิดเรียบ (Smooth Filter)

3.5 การแปลงฟูเรียร์

สุดท้ายใช้การแปลงฟูเรียร์ในแนวนอนของข้อมูล (FFT of Row Data) เพื่อหาความถี่ดอปเพลอร์ของเป้าหมายที่เคลื่อนที่



รูปที่ 3.8 การแปลงฟูเรียร์แต่ละแถวของตารางเพื่อหาความถี่ดอปเพลอร์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น เมื่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คำนวณระยะห่างระหว่างมนุษย์อย่างง่ายที่ได้จากการทดลอง โดยระยะจริงคือ 2.1 เมตร


$$R \approx \frac{ct}{2} = \frac{3 * 10^8 * 1.5 * 10^{-8}}{2}$$

$$R = 2.25 \text{ m}$$

ค่าความคลาดเคลื่อนโดยมากเกิดจากเสาอากาศตัวส่งและตัวรับอยู่ห่างกัน แต่มีความจำเป็นต้องวางระยะห่างถึง 15 cm เนื่องจากระยะใกล้กันมากขึ้นทำให้ความเหนี่ยวนำร่วมของเสาอากาศ (antenna coupling) มากขึ้น ส่งผลให้เกิดแรงดันที่ช่องสัญญาณของเครื่อง oscilloscope เกินพิกัน 5V

3.6 เสาอากาศ UWB สำหรับการตรวจจับวัตถุหลังกำแพง


เสาอากาศเป็นอุปกรณ์ที่สำคัญมากเป็นอันดับต้นๆของระบบเรดาร์ เพราะถ้าออกแบบเสาอากาศเหมาะสมกับความถี่ (matching impedance, $s_{11} < -10 \text{ dB}$) ที่ใช้ที่มีอัตราขยายสัญญาณสูง (high gain) และมีมุมที่แคบ (angular width) ก็สามารถส่งกำลังได้ระยะไกลและรับสัญญาณได้อย่างชัดเจน ทำให้ระบบเรดาร์สามารถตรวจจับตำแหน่งวัตถุหลังกำแพงได้อย่างชัดเจนและรวดเร็วมากขึ้น โดยพารามิเตอร์ของเสาอากาศ มีหน่วยเป็นมิลลิเมตร (mm)



รูปที่ 3.9 การจำลองเสาอากาศด้วยโปรแกรม CST


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ความหนาของ FR-4 substrate คือ 1.575 mm ความหนาทองแดง 0.035 mm ค่าความเป็นฉนวน $\epsilon_r = 4.33$ สูตรท้ายสมการเอกซ์โพเนนเชียลใช้สร้างกราฟเส้นโค้งของเสาอากาศคือ $y = 0.25e^{0.024t}$ จากนั้นคำนวณหาค่าสัมประสิทธิ์การสะท้อน S_{11} ผลลัพธ์ที่ได้ดังรูป 3.9




รูปที่ 3.10 ค่าสัมประสิทธิ์การสะท้อน S_{11}

จากรูปที่ 3.9 จะเห็นได้ว่าความกว้างของสัญญาณที่น้อยกว่า -10 dB อยู่ในช่วงประมาณ 2.4 GHz-4.5 GHz เนื่องจากออกแบบความกว้างอยู่ 130 mm จากนั้นคำนวณค่าอัตราขยายสัญญาณและความกว้างของสัญญาณที่ความถี่กลาง 3 GHz ตามรูปที่แสดง 3.10



(ก) ภาพสามมิติ


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้าไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(ข) ภาพสองมิติ

รูปที่ 3.11 ภาพการจำลองอัตราขยายสัญญาณและมุมการส่ง

จากรูปที่ 3.10 จะเห็นได้ว่ามีอัตราขยายสัญญาณสูงสุดที่ 10.1 dBi เนื่องจากการออกแบบความยาวเสาอากาศที่มากถึง 230 mm และมีความกว้างของคลื่นในการส่งรับอยู่ที่ 45.2 องศาสุดท้ายเสาอากาศชิ้นงานจริงแสดงดังรูปที่ 3.11



(ก) ด้านกราวด์ของชิ้นงานจริง


(ข) ด้านท่อนของชิ้นงานจริง

รูปที่ 3.12 เสาอากาศที่ได้จากชิ้นงานจริง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.7 การประยุกต์ใช้ UWB เรดาร์ในการตรวจจับมนุษย์หลังกำแพง

หัวข้อนี้ได้อธิบายวิธีการตรวจจับมนุษย์หลังกำแพงโดยทดสอบ 5 ท่าทางโดยทดสอบยืน เดิน นั่ง นอน ไม่ไม่มีบุคคล สัญญาณภาคส่งเป็น UWB ตามที่แสดงในรูป 3.13



รูปที่ 3.13 การเซตระบบของการประมวลผลสัญญาณของการตรวจจับการเคลื่อนที่ของมนุษย์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.8 โค้ดการเก็บและใช้ข้อมูล

```

##### GPIB #####
clear all; close all; clc;
c = physconst('LightSpeed'); % Speed of Light
waveform.nScan = 128; % Scan Number
nScan = waveform.nScan;
pause(6)

%% Start VISA and Open File
visaObj = visa('agilent','GPIB1::7::INSTR');
% Set the buffer size
visaObj.InputBufferSize = 2e5;
% Set the timeout value
visaObj.Timeout = 20;
% Set the Byte order
visaObj.ByteOrder = 'littleEndian';
% Open the connection
fopen(visaObj);

```

รูปที่ 3.14 โค้ดการตั้งค่าการเชื่อมต่อ

เป็นการตั้งค่าช่อง GPIB จากสโคปไปยังคอมพิวเตอร์และเปิดการเชื่อมต่อกับตัวอุปกรณ์ โดยที่ทำให้ตัวคอมพิวเตอร์ สามารถเก็บถึงข้อมูลที่แสดงผลเหมือนสโคป

```

%% Determining Channel #####
fprintf(visaObj,':SYSTEM:HEADER OFF');
fprintf(visaObj,':ACQUIRE:MODE RTIM');
fprintf(visaObj,':WAVEFORM:FORMAT WORD');
fprintf(visaObj,':WAVEFORM:BYTEORDER LSBfirst');
waveform.Points = str2double(query(visaObj,':WAVEFORM:Points?'));
waveform.Xincrement = str2double(query(visaObj,':WAVEFORM:Xincrement?'));
waveform.Xorigin = str2double(query(visaObj,':WAVEFORM:Xorigin?'));
waveform.Xreference = str2double(query(visaObj,':WAVEFORM:Xreference?'));
waveform.Yincrement = str2double(query(visaObj,':WAVEFORM:Yincrement?'));
waveform.Yorigin = str2double(query(visaObj,':WAVEFORM:Yorigin?'));
waveform.Yreference = str2double(query(visaObj,':WAVEFORM:Yreference?'));
waveform.Yrange = str2double(query(visaObj,':WAVEFORM:Yrange?'));
waveform.VoltsPerDivTx = waveform.Yrange/8;
waveform.SecPerDiv = waveform.Points * waveform.Xincrement/10 ;
% X-Y axis
Xmin = 0;
Xmax = waveform.Points*waveform.Xincrement;
N = waveform.Points; % Number of Range bins
t = Xmin: waveform.Xincrement: Xmax -waveform.Xincrement; % time domain
dt = (max(t) - min(t))/N;
% t = 0: dt: 45e-9;
% N = floor((max(t) - min(t))/dt)+1;

```

รูปที่ 3.15 โค้ดตั้งค่าสเกลข้อมูล

ตั้งค่าการตั้งสเกลข้อมูลทางแกน x และแกน y, จำนวนความละเอียด และแกนเวลา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```

%% Tx
h_fig1 = figure('units','normalized','outerposition',[0 0 1 1]);
subplot(2,2,1)
fprintf(visaObj,':WAVEFORM:SOURCE_CHAN3');
fprintf(visaObj,':DIGITIZE:CHANNEL3');
fprintf(visaObj,':WAV:DATA?');
waveform.TxSignal = binblockread(visaObj,'int16');
waveform.TxSignal = (waveform.Yincrement.*(waveform.TxSignal -...
waveform.Yreference)) + waveform.Yorigin;
waveform.TxSignal = waveform.TxSignal(1:N,1);
plot(t,waveform.TxSignal)
title('Tx','Fontname','Times New Roman','FontSize',16);
xticks([0:0.5e-8:max(t)])
% axis([min(t) max(t) -5 5])
xlabel('Time [s]','Fontname','Times New Roman','FontSize',16);
ylabel('Volts [V]','Fontname','Times New Roman','FontSize',16);
set(gca,'Fontname','Times New Roman','FontSize',16);
grid on

```

รูปที่ 3.16 โค้ดเก็บข้อมูลตัวส่งสัญญาณ

เป็นการเลือกช่องทาง CH3 ในการแสดงการส่งข้อมูล เก็บค่าไว้ใน Waveform.TXSignal

```

%% Capture Data
fprintf(visaObj,':WAVEFORM:SOURCE_CHAN4');
fprintf(visaObj,':DIGITIZE:CHANNEL4');
fprintf(visaObj,':WAV:DATA?');
Data = binblockread(visaObj,'int16');
Data = (waveform.Yincrement.*(Data - waveform.Yreference)) +
waveform.Yorigin;
index_want = 3500:12000; % good 3500:12000
N = length(index_want);
waveform.RawData = zeros(N,nScan);
for m = 1:nScan
tic;
fprintf(visaObj,':WAV:DATA?');
pause(0.05)
Data = binblockread(visaObj,'int16');
Data = Data(index_want);
% Data = (waveform.Yincrement.*(Data - waveform.Yreference)) +
waveform.Yorigin;
subplot(2,2,2)
plot(Data)
drawnow;
waveform.RawData(:,m) = Data;
waveform.Toc = toc;
end
for m = 1:nScan
waveform.RawData(:,m) = (waveform.Yincrement.*(waveform.RawData(:,m)...
- waveform.Yreference)) + waveform.Yorigin;
end
fprintf(visaObj,'*CLS'); % clear display by SCPI
fclose(visaObj);delete(visaObj); clear visaObj;

```

รูปที่ 3.17 โค้ดเก็บข้อมูลตัวรับสัญญาณ

เป็นการเลือกช่องทาง CH4 และรับข้อมูลจากตัวรับสัญญาณเมื่อเราได้ข้อมูลของสัญญาณใน

ภาครับมาเราจะนำไปเข้าสู่กระบวนการเรียนรู้เชิงลึก
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.9 ออกแบบการเรียนรู้ข้อมูลเชิงลึก

3.9.1 การเตรียมข้อมูล

เทคนิค Normalization ถูกนำมาใช้เพื่อเปลี่ยนคุณสมบัติให้อยู่ในระดับใกล้เคียงกันปรับปรุงประสิทธิภาพและความเสถียรในการฝึกอบรมของแบบจำลอง Deep Neural Network ในงานวิจัยนี้ใช้ค่าเฉลี่ย Normalization สำหรับฟังก์ชันที่แสดงในสมการ (3.8) จากนั้นนำข้อมูล 2,400 ตัวอย่าง แบ่งออกเป็น 2 ชุดตัวอย่าง ได้แก่ ชุดฝึก 2,040 ตัวอย่างและชุดทดสอบ 360 ตัวอย่าง

$$x_{new} = \frac{x - x_{min}}{x_{max} - x_{min}} \quad (3.8)$$

3.9.2 ออกแบบการเรียนรู้ข้อมูลเชิงลึก

ในงานวิจัยนี้เราออกแบบ Deep Neural Network โดยใช้ชั้นอินพุต 1 ชั้นที่มี 212,525 โหนด 4 ชั้นซ่อนที่มี 100-80-60-30 โหนดตามลำดับและชั้นเอาต์พุต 1 ชั้น จากการยื่น


ในงานวิจัยนี้เราออกแบบ Deep Neural Network โดยใช้ชั้นอินพุต 1 ชั้นที่มี 212,525 โหนด 4 ชั้นซ่อนที่มี 100-80-60-30 โหนดตามลำดับและชั้นเอาต์พุต 1 ชั้น จากการเดิน

ในงานวิจัยนี้เราออกแบบ Deep Neural Network โดยใช้ชั้นอินพุต 1 ชั้นที่มี 212,525 โหนด 4 ชั้นซ่อนที่มี 100-80-60-30 โหนดตามลำดับและชั้นเอาต์พุต 1 ชั้น จากการนอน

ในงานวิจัยนี้เราออกแบบ Deep Neural Network โดยใช้ชั้นอินพุต 1 ชั้นที่มี 212,525 โหนด 4 ชั้นซ่อนที่มี 100-80-60-30 โหนดตามลำดับและชั้นเอาต์พุต 1 ชั้น จากการนั่ง


ในงานวิจัยนี้เราออกแบบ Deep Neural Network โดยใช้ชั้นอินพุต 1 ชั้นที่มี 212,525 โหนด 4 ชั้นซ่อนที่มี 100-80-60-30 โหนดตามลำดับและชั้นเอาต์พุต 1 ชั้น จากการไม่มีผู้คน

โดยทั้ง 5 ท่าทางจะถูกนำไปทดสอบเพื่อบอกว่าเป็นท่าทางยืน เดิน นั่ง นอน และไม่มีบุคคลโดยใช้ฟังก์ชัน sigmoid ในการทดสอบ และหลังจากนั้นจะนำข้อมูลของทั้ง 5 ท่าทางไปรวมกันเพื่อจะแยกแยะท่าทางต่างๆ



รูปที่ 3.18 โครงสร้าง Deep Neural Network

ในงานวิจัยนี้เราออกแบบ Deep Neural Network โดยใช้ชั้นอินพุต 1 ชั้นที่มี 212,525 โหนด 4 ชั้นซ่อนที่มี 100-80-60-30 โหนดตามลำดับและชั้นเอาต์พุต 1 ชั้น ด้วย 5 โหนด โดยการนำผลเพื่อมาแยกแยะลักษณะท่าทางออกเป็นห้าท่าทาง



รูปที่ 3.19 โครงสร้าง Deep Neural Network ของทุกท่าทาง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ฟังก์ชันการเปิดใช้งานถูกใช้ในกระบวนการ feed forward ของ hidden layer คือ ฟังก์ชันการเปิดใช้งาน Tanh ซึ่งในขณะที่ในกระบวนการไปยังด้านหลังไข่อนุพันธ์ของฟังก์ชันการเปิดใช้งาน Tanh ต่อมาในกระบวนการ feed forward ของ output layer โดยใช้ ฟังก์ชันการเปิดใช้งาน Softmax เพื่อเป็นการจำแนกให้เป็นหลายคลาส

3.10 จำแนกแยกแยะลักษณะท่าทางโดยใช้การเรียนรู้ข้อมูลเชิงลึก

```
import numpy as np
import pandas as pd

import matplotlib.pyplot as plt
%matplotlib inline
```

รูปที่ 3.20 โค้ดไว้สำหรับคำนวณ Matrix

เราจะทำการเรียก Numpy ไว้สำหรับคำนวณเมทริก จากนั้นเราจะเรียก Pandas เอาไว้ใช้ในการอ่านไฟล์ สร้างไฟล์ในการสร้างกราฟ

```
def Relu(Z):
    A_i=Z*(Z>0)
    return A_i

def df_Relu(A_i):
    df_ai=(A_i>0)
    return df_ai

def tanh(Z):
    A_i=np.tanh(Z)
    return A_i

def df_tanh(A_i):
    df_ai=1-A_i**2
    return df_ai

def sigmoid(Z):
    A_i=1/(1+np.exp(-Z))
    return A_i

def softmax(Z):
    A_i=np.exp(Z)/np.exp(Z).sum(axis=1,keepdims=True)
    return A_i
```

รูปที่ 3.21 เรียกฟังก์ชันไว้ใช้งาน

ทำการสร้างฟังก์ชันออกมาเพื่อเรียกใช้งานประกอบด้วย Relu , Tanh ,Sigmoid และ Softmax

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
data=pd.read_excel('activity.xlsx')
data=pd.read_excel('Posture_classification.xlsx')
```

```
DataM=data.values
```

```
type(DataM)
```

```
numpy.ndarray
```

```
N>DataM.shape[0]
```

```
D>DataM.shape[1]-1
D>DataM.shape[1]-5
```

```
X>DataM[:,D]
```

```
Y>DataM[:,D:]
```

รูปที่ 3.22 โค้ชอ่านค่าไฟล์ที่ได้ทำการบันทึกเพื่อแปลงเป็น Matrix

นำเอาข้อมูลที่ได้จากการทดสอบทั้งหมด 5 ตำแหน่ง จากนั้นแปลงข้อมูลให้กลายเป็นเมทริก โดยแยกค่า X และค่า Y

```
X_min=X.min(axis=0)
X_max=X.max(axis=0)
```

```
Y_min=Y.min(axis=0)
Y_max=Y.max(axis=0)
```

```
X_norm=(X-X_min)/(X_max-X_min)
```

```
Y_norm=(Y-Y_min)/(Y_max-Y_min)
```

รูปที่ 3.23 Normalization ค่าแกน X และแกน Y

นำค่า X และ Y ที่ได้มาทำการ Normalization

```
A0=X_norm
```

```
W1=np.random.randn(212525,100)
B1=np.random.randn(1,100)
```

```
W2=np.random.randn(100,80)
B2=np.random.randn(1,80)
```

```
W3=np.random.randn(80,60)
B3=np.random.randn(1,60)
```

```
W4=np.random.randn(60,30)
B4=np.random.randn(1,30)
```

```
W5=np.random.randn(30,1)
B5=np.random.randn(1,1)
```

```
#W4=np.random.randn(3,1)
#B4=np.random.randn(1,1)
```

```
W5=np.random.randn(30,5)
B5=np.random.randn(1,5)
```

รูปที่ 3.24 โค้ชสร้าง weight และ bias เริ่มต้น

ทำการสร้าง weight และ bias โดย weight ตัวแรกจะมีขนาดเป็น input และ ออกเป็นตาม จำนวนของ input ของสัญญาณเพื่อส่งต่อไป layer ต่อไปและที่ layer ชั้นสุดท้ายจะออกขนาดตาม ท่าทางคือ 5 ท่าทาง ซึ่งทุก weight จะมีการทำ Normalization เพื่อให้การสุ่มค่าไม่กระจายค่าเกินไป

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

```
error_list=[]
epoch=2500
lr=0.1
```

รูปที่ 3.25 โค้ทคำนวณ learning rate

กำหนดค่าเริ่มต้นในกระบวนการคิดข้อมูลเชิงลึก เพื่อที่จะส่งต่อไปยังกระบวนการ feed forward ต่อไป

```
for i in range(epoch):
    #network 1
    Z1=np.dot(A0,W1)+B1
    A1=tanh(Z1)
    df_A1=df_tanh(A1)

    #network 2
    Z2=np.dot(A1,W2)+B2
    A2=tanh(Z2)
    df_A2=df_tanh(A2)

    #network 3
    Z3=np.dot(A2,W3)+B3
    A3=tanh(Z3)
    df_A3=df_tanh(A3)

    #Network 4
    Z4=np.dot(A3,W4)+B4
    A4=tanh(Z4)
    df_A4=df_tanh(A4)

    #Network 5
    Z5=np.dot(A4,W5)+B5

    #A5=Z5
    #A5=sigmoid(Z5)
    A5=softmax(Z5)
```

รูปที่ 3.26 โค้ท Feed forward

ทำการนำข้อมูลสัญญาณในแต่ละเสาไปผ่านทุกชั้นและออกเป็น output 5 ตำแหน่ง

```
#network 5
Error5=Y_norm-A5
W5=W5+(lr/N)*np.dot(A4.T,Error5)
B5=B5+(lr/N)*np.dot(1,Error5).sum(axis=0,keepdims=True)

#network 4
Error4=np.dot(Error5,W5.T)*df_A4
W4=W4+(lr/N)*np.dot(A3.T,Error4)
B4=B4+(lr/N)*np.dot(1,Error4).sum(axis=0,keepdims=True)

#network 3
Error3=np.dot(Error4,W4.T)*df_A3
W3=W3+(lr/N)*np.dot(A2.T,Error3)
B3=B3+(lr/N)*np.dot(1,Error3).sum(axis=0,keepdims=True)

#network 2
Error2=np.dot(Error3,W3.T)*df_A2
W2=W2+(lr/N)*np.dot(A1.T,Error2)
B2=B2+(lr/N)*np.dot(1,Error2).sum(axis=0,keepdims=True)

#network 1
Error1=np.dot(Error2,W2.T)*df_A1
W1=W1+(lr/N)*np.dot(A0.T,Error1)
B1=B1+(lr/N)*np.dot(1,Error1).sum(axis=0,keepdims=True)

#error=((Y_norm-A5)**2).sum()/N

#error=(-Y_norm*np.log(A5)-(1-Y_norm)*np.log(1-A5)).sum()/N

error=(-Y_norm*np.log(A5)).sum()/N

error_list.append(error)
```

รูปที่ 3.27 โค้ท Backpropagation

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

นำค่าของข้อผิดพลาดระหว่าง ค่า output ที่แท้จริง - ค่า output ที่ออกมาจาก Feed forward เพื่อนำค่าของข้อผิดพลาดไปหา weight และ bias ใหม่ทุกตัว ขั้นตอนนี้จะทำให้โมเดลมีความแม่นยำเพิ่มขึ้น



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 4

ผลการทดลอง

ในการทดลองของหัวข้อนี้ใช้เสาอากาศภาครับสองต้นเพื่อประยุกต์ใช้ในกรณีที่มีเนื้อที่จำกัด โดยแต่ละต้นมีระยะห่าง 25 เซนติเมตรจากตัวส่ง โดยใช้อุปกรณ์ดังต่อไปนี้

- 1). Agilent DSO80604B Oscilloscope 6 GHz 40 GSa/s (OSC) เป็นตัวรับสัญญาณภาครับและส่งข้อมูลเวลาจริง (real time) ผ่าน GPIB ไปยังโปรแกรม MATLAB
- 2). HP Pulse Generator 8133A 3GHz (UWB Source) ใช้สร้างสัญญาณ UWB เรดาร์โดยกำหนดความกว้างของคลื่นเท่ากับ 200 psec เมื่ออ่านค่าจาก OSC
- 3). Mini-Circuits Amplifier ZVE-8G 2 GHz – 8 GHz (PA) ใช้ขยายกำลังสัญญาณของภาคส่ง
- 4). R&K-AA260-OS Small Signal Amplifier 2GHz – 5 GHz (LNA) ใช้ขยายกำลังสัญญาณของภาครับ
- 5). Agilent Multifunction Switch 34980A (RF Switch) ใช้สวิตช์เสาอากาศภาครับแต่ละต้นในการรับสัญญาณ โดยชุดควบคุมต่อขนานกับ OSC ผ่าน GPIB ซึ่งถูกควบคุมผ่านโปรแกรมที่เขียนขึ้นเองใน MATLAB
- 6). นำข้อมูลที่ได้หลังจากผ่านข้อมูลกิจกรรมมนุษย์ของอาสาสมัคร 8 คนที่มีอายุ 20 ถึง 30 ปีที่รวบรวมจากเรดาร์ UWB ผ่าน Deep Neural Networks ขั้นตอนการประเมินแบบจำลองได้ตั้งตารางสำคัญในการวัดความสามารถของ machine learning ในการแก้ปัญหา classification ระบบ train ตามคะแนน F1 ของชุดฝึกและชุดทดสอบของแต่ละท่าทาง


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.1 การตรวจวัดบุคคลในลักษณะต่างๆแล้วนำไปเรียนรู้ข้อมูลเชิงลึก



รูปที่ 4.1 การเซตระบบของการตรวจจับมนุษย์ยืนที่ระยะ 2 เมตรจากสายอากาศ

โดยรูปที่ 4.1 ได้ทำการวัดการยืนที่ระยะ 2 เมตรโดยได้ทำการวัดบุคคล 5 บุคคลอายุระหว่าง 20-30 ปีเป็นชาย 4 หญิง 1 รวมสัญญาณที่ได้ทำการบันทึกทั้งหมด 2400 สัญญาณโดยแบ่งออกเป็น โดยแบ่งไปใช้ในการทำ training set ที่ 2040 สัญญาณ และ test set ที่ 360 สัญญาณ แล้ว Model ตอบถูกจริงๆกลับมาเท่าไร่ รวมไปถึง การคำนวณเทียบกับคำตอบที่ผิดข้างเคียง ว่าตัวเองถูกมากน้อยแค่ไหน รูปที่ 4.2 ทำการออกแบบ deep neural network โดยที่ input ของเราอยู่ที่ 212,525 nodes โดยมี 4 hidden layer 1 output ในท่าทางของการยืน



รูปที่ 4.2 โครงสร้าง Deep Neural Network

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

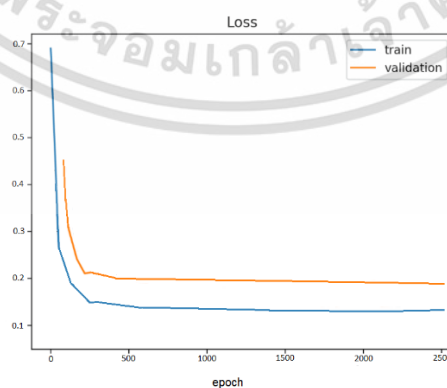
ตารางที่ 4.1 คะแนน F1 และ ค่าความแม่นยำของทำยีนสำหรับการ training

Evaluation	Human Activity Classes
	Stand
Precision(%)	100
Recall(%)	96
F1-score(%)	98

ตารางที่ 4.2 คะแนน F1 และ ค่าความแม่นยำของทำยีนสำหรับการ test

Evaluation	Human Activity Classes
	Stand
Precision(%)	100
Recall(%)	86
F1-score(%)	98

ค่า F1-Score ของการ train และ test ในทำยีน โดยค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall นักวิจัยสร้าง F1 ขึ้นมาเพื่อที่วัดความสามารถของโมเดล ดังตารางที่ 4.1 และ 4.2



lr = 0.01

รูปที่ 4.3 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และ Learning Curve เป็นสิ่งที่แสดงถึงประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset ซึ่งแกน x ของกราฟจะเป็น Epoch และแกน y จะเป็นประสิทธิภาพของ Model โดยประสิทธิภาพของ Model จะถูกวัดหลังจากการปรับปรุง Weight และ Bias ด้วยข้อมูล 2 ชนิด ได้แก่ "Training Dataset ที่ Model กำลังเรียนรู้" และ "Validation Dataset ที่ไม่เคยถูกใช้สอน Model มาก่อน" ดังรูปที่ 4.3



รูปที่ 4.4 การเซตระบบของการตรวจจับมนุษย์เดิน 0 – 4 เมตรไปยังสายสายอากาศ

โดยรูปที่ 4.4 ได้ทำการวัดการเดินที่จาก 0- 4 เมตรจนถึงสายอากาศโดยได้ทำการวัดบุคคล 5 บุคคลอายุระหว่าง 20-30 ปีเป็นชาย 4 หญิง 1 รวมสัญญาณที่ได้ทำการบันทึกทั้งหมด 2400 สัญญาณโดยแบ่งออกเป็น โดยแบ่งไปใช้ในการทำ training set ที่ 2040 สัญญาณ และ test set ที่ 360 สัญญาณ แล้ว Model ตอบถูกจริงๆกลับมาเท่าไร รวมไปถึง การคำนวณเทียบกับคำตอบที่ผิดข้างเคียง ว่าตัวเองถูกมากน้อยแค่ไหน รูปที่ 4.5 ทำการออกแบบ deep neural network โดยที่ input ของเราอยู่ที่ 212,525 nodes โดยมี 4 hidden layer 1 output ในทิศทางของการยื่น



รูปที่ 4.5 โครงสร้าง Deep Neural Network

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

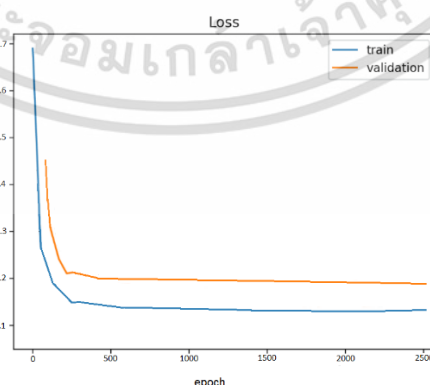
ตารางที่ 4.3 คะแนน F1 และ ค่าความแม่นยำของการเดินสำหรับการ training

Evaluation	Human Activity Classes
	Walk
Precision(%)	96
Recall(%)	100
F1-score(%)	98

ตารางที่ 4.4 คะแนน F1 และ ค่าความแม่นยำของการเดินโดยการ test

Evaluation	Human Activity Classes
	Walk
Precision(%)	86
Recall(%)	100
F1-score(%)	92

ค่า F1-Score ของการ train และ test ในทำนอง โดยค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall นักวิจัยสร้าง F1 ขึ้นมาเพื่อที่วัดความสามารถของโมเดล ดังตารางที่ 4.3 และ 4.4



รูปที่ 4.6 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และ Learning Curve เป็นสิ่งที่แสดงถึงประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset ซึ่งแกน x ของกราฟจะเป็น Epoch และแกน y จะเป็นประสิทธิภาพของ Model โดยประสิทธิภาพของ Model จะถูกวัดหลังจากการปรับปรุง Weight และ Bias ด้วยข้อมูล 2 ชนิด ได้แก่ "Training Dataset ที่ Model กำลังเรียนรู้" และ "Validation Dataset ที่ไม่เคยถูกใช้สอน Model มาก่อน" ดังรูปที่ 4.6



รูปที่ 4.7 การเซตระบบของการตรวจจับการนอนของมนุษย์ที่ ระยะ 2 เมตร

โดยรูปที่ 4.7 ได้ทำการวัดการนอนที่ระยะ 2 เมตรโดยได้ทำการวัดบุคคล 5 บุคคลอายุระหว่าง 20-30 ปีเป็นชาย 4 หญิง 1 รวมสัญญาณที่ได้ทำการบันทึกทั้งหมด 2400 สัญญาณโดยแบ่งออกเป็น โดยแบ่งไปใช้ในการทำ training set ที่ 2040 สัญญาณ และ test set ที่ 360 สัญญาณ แล้ว Model ตอบถูกจริงๆกลับมาเท่าไร รวมไปถึง การคำนวณเทียบกับคำตอบที่ผิดข้างเคียง ว่าตัวเองถูกมากน้อยแค่ไหน รูปที่ 4.8 ทำการออกแบบ deep neural network โดยที่ input ของเราอยู่ที่ 212,525 nodes โดยมี 4 hidden layer 1 output ในทำทางของการอื่น



รูปที่ 4.8 โครงสร้าง Deep Neural Network

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 4.5 คะแนน F1 และ ค่าความแม่นยำของการนั่งสำหรับการ training

Evaluation	Human Activity Classes
	Sit
Precision(%)	100
Recall(%)	100
F1-score(%)	100

ตารางที่ 4.6 คะแนน F1 และ ค่าความแม่นยำของการนั่งเดินโดย test

Evaluation	Human Activity Classes
	Sit
Precision(%)	100
Recall(%)	100
F1-score(%)	100


ค่า F1-Score ของการ train และ test ในทำยีน โดยค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall นักวิจัยสร้าง F1 ขึ้นมาเพื่อที่วัดความสามารถของโมเดล ดังตารางที่ 4.5 และ 4.6



รูปที่ 4.9 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และ Learning Curve เป็นสิ่งที่แสดงถึงประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset ซึ่งแกน x ของกราฟจะเป็น Epoch และแกน y จะเป็นประสิทธิภาพของ Model โดยประสิทธิภาพของ Model จะถูกวัดหลังจากการปรับปรุง Weight และ Bias ด้วยข้อมูล 2 ชนิด ได้แก่ "Training Dataset ที่ Model กำลังเรียนรู้" และ "Validation Dataset ที่ไม่เคยถูกใช้สอน Model มาก่อน" ดังรูปที่ 4.9



รูปที่ 4.10 การเซตระบบของการตรวจจับมนุษย์ในท่านั่งที่ระยะ 2 เมตรจากสายอากาศ

โดยรูปที่ 4.10 ได้ทำการวัดการนั่งที่ระยะ 2 เมตรโดยได้ทำการวัดบุคคล 5 บุคคลอายุระหว่าง 20-30 ปีเป็นชาย 4 หญิง 1 รวมสัญญาณที่ได้ทำการบันทึกทั้งหมด 2400 สัญญาณโดยแบ่งออกเป็น โดยแบ่งไปใช้ในการทำ training set ที่ 2040 สัญญาณ และ test set ที่ 360 สัญญาณ แล้ว Model ตอบถูกจริงๆกลับมาเท่าไร รวมไปถึง การคำนวณเทียบกับคำตอบที่ผิดข้างเคียง ว่าตัวเองถูกมากน้อยแค่ไหน รูปที่ 4.11 ทำการออกแบบ deep neural network โดยที่ input ของเราอยู่ที่ 212,525 nodes โดยมี 4 hidden layer 1 output ในท่าทางของการยืน



รูปที่ 4.11 โครงสร้าง Deep Neural Network

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ตารางที่ 4.7 คะแนน F1 และ ค่าความแม่นยำของการนอนสำหรับการ training

Evaluation	Human Activity Classes
	Lay
Precision(%)	100
Recall(%)	100
F1-score(%)	100

ตารางที่ 4.8 คะแนน F1 และ ค่าความแม่นยำของการนอนโดยการ test

Evaluation	Human Activity Classes
	Lay
Precision(%)	100
Recall(%)	100
F1-score(%)	100


ค่า F1-Score ของการ train และ test ในทำยี่น โดยค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall นักวิจัยสร้าง F1 ขึ้นมาเพื่อที่วัดความสามารถของโมเดล ดังตารางที่ 4.7 และ 4.8



รูปที่ 4.12 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset

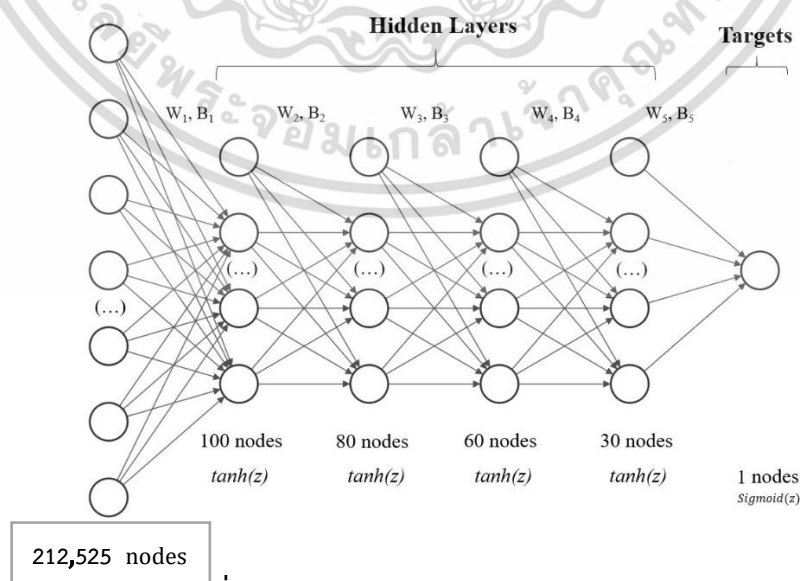
เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

และ Learning Curve เป็นสิ่งที่แสดงถึงประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset ซึ่งแกน x ของกราฟจะเป็น Epoch และแกน y จะเป็นประสิทธิภาพของ Model โดยประสิทธิภาพของ Model จะถูกวัดหลังจากการปรับปรุง Weight และ Bias ด้วยข้อมูล 2 ชนิด ได้แก่ "Training Dataset ที่ Model กำลังเรียนรู้" และ "Validation Dataset ที่ไม่เคยถูกใช้สอน Model มาก่อน" ดังรูปที่ 4.12



รูปที่ 4.13 การเซตระบบของการตรวจจ็บโดยไม่มีมนุษย์

โดยรูปที่ 4.13 ได้ทำการวัดการโดยไม่มีบุคคล ได้ทำการวัดทั้งหมด 5 รอบ รวมสัญญาณที่ได้ทำการบันทึกทั้งหมด 2400 สัญญาณโดยแบ่งออกเป็น โดยแบ่งไปใช้ในการทำ training set ที่ 2040 สัญญาณ และ test set ที่ 360 สัญญาณ แล้ว Model ตอบถูกจริงๆกลับมาเท่าไร รวมไปถึง การคำนวณเทียบกับคำตอบที่ผิดข้างเคียง ว่าตัวเองถูกมากน้อยแค่ไหน รูปที่ 4.14 ทำการออกแบบ deep neral network โดยที่ input ของเราอยู่ที่ 212,525 nodes โดยมี 4 hidden layer 1 output ในท่าทางของการอื่น



รูปที่ 4.14 โครงสร้าง Deep Neral Network

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

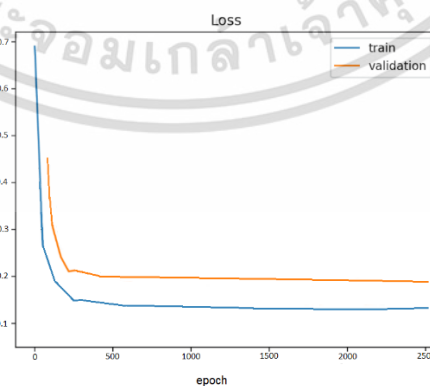
ตารางที่ 4.9 คะแนน F1 และ ค่าความแม่นยำของการทดสอบแบบไม่มีบุคคลสำหรับการ training

Evaluation	Human Activity Classes
	No Human
Precision(%)	100
Recall(%)	100
F1-score(%)	100

ตารางที่ 4.10 คะแนน F1 และ ค่าความแม่นยำของการทดสอบแบบไม่มีบุคคลสำหรับการ test

Evaluation	Human Activity Classes
	No Human
Precision(%)	100
Recall(%)	100
F1-score(%)	100


ค่า F1-Score ของการ train และ test ในทำนองเดียวกัน โดยค่าเฉลี่ยแบบ harmonic mean ระหว่าง precision และ recall นักวิจัยสร้าง F1 ขึ้นมาเพื่อที่วัดความสามารถของโมเดล ดังตารางที่ 4.9 และ 4.10



รูปที่ 4.15 ประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


และ Learning Curve เป็นสิ่งที่แสดงถึงประสิทธิภาพการเรียนรู้ของ Model จาก Training Dataset ซึ่งแกน x ของกราฟจะเป็น Epoch และแกน y จะเป็นประสิทธิภาพของ Model โดยประสิทธิภาพของ Model จะถูกวัดหลังจากการปรับปรุง Weight และ Bias ด้วยข้อมูล 2 ชนิด ได้แก่ "Training Dataset ที่ Model กำลังเรียนรู้" และ "Validation Dataset ที่ไม่เคยถูกใช้สอน Model มาก่อน" ดังรูปที่ 4.13




รูปที่ 4.16 โครงสร้าง Deep Neural Network ของทุกท่าทาง

เรานำผลที่วัดจากทุกท่าทาง ยืน เดิน นั่ง นอน และไม่มีบุคคล โดยให้โมเดล Classification จำแนก ว่าแต่ละท่าทางที่เราจะทำนาย เราสามารถนำผลลัพธ์ที่โมเดลทำนาย มาใส่เป็นตารางได้ โดยแนวตั้งคือ ความจริง Ground Truth แนวนอนคือ สิ่งที่โมเดลทำนาย ตารางนี้เรียกว่า Confusion Matrix ดังด้านล่าง โดยได้แบ่งออกเป็น Confusion ของการ train และ Confusion ของการ test ดังรูปที่ 4.15 และ 4.16

4.2 ตาราง Confusion Matrix



รูปที่ 4.17 ตารางสำคัญในการวัดความสามารถของ machine learning ในการแก้ปัญหา classification ระบบ train



รูปที่ 4.18 ตารางสำคัญในการวัดความสามารถของ machine learning ในการแก้ปัญหา classification ระบบ test

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตารางที่ 4.11 คะแนน F1 และ ค่าความแม่นยำทั้งหมดสำหรับการ training

Evaluation	Human Activity Classes				
	Stand	Walk	Sit	Lay	No human
Precision(%)	100	96	100	100	100
Recall(%)	96	100	100	100	100
F1-score(%)	98	100	100	100	100
Average F1-score(%)	99.21				

ตารางที่ 4.12 คะแนน F1 และ ค่าความแม่นยำทั้งหมดสำหรับการ test

Evaluation	Human Activity Classes				
	Stand	Walk	Sit	Lay	No human
Precision(%)	100	86	100	100	100
Recall(%)	86	100	100	100	100
F1-score(%)	92	92	100	100	100
Average F1-score(%)	96.94				

F1-score ได้จำแนกแยกแยะ Classification ของการ train และ การ test เหนือ โดยที่ นักวิจัยสร้าง F1-score ขึ้นมาเพื่อเป็นวัดความสามารถของโมเดล ดังตารางที่ 4.11 และ 4.12

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5

สรุปผลการดำเนินงาน

5.1 สรุปผลการทดลอง

โครงการวิจัยฉบับนี้นำเสนอการพัฒนาระบบเรดาร์สำหรับประยุกต์ใช้ในการตรวจจับบุคคลหลังกำแพง จากการศึกษาและทดลองนี้เราพบว่าข้อมูลที่รวบรวมจาก UWB เรดาร์จะไม่สามารถแยกแยะท่าทางของบุคคลคลอบอกได้เพียงแต่เฉพาะตำแหน่งเท่านั้น จึงทำการนำข้อมูลที่ได้จากการวัดจากบุคคลทั้งหมดนำไปสู่การเรียนรู้ข้อมูลเชิงลึก ซึ่งได้ทำการออกแบบอัลกอริทึม Deep Neural Network ที่ให้ผลลัพธ์ที่ดีที่สุด เพื่อจำแนกกิจกรรมของมนุษย์ออกมาเป็น 5 ท่าทางและยังได้ผลลัพธ์อย่างชัดเจนอีกด้วย โดยคะแนนเฉลี่ยของ(F1-score) ชุดฝึกของการทดสอบที่ 1 และชุดผลทดสอบที่ 2 คือ 99.21% และ 96.94% ตามลำดับ ซึ่งในอนาคตอาจทำการเพิ่มจำนวนคลาสกิจกรรมของมนุษย์และตัวอย่างข้อมูลเพื่อเพิ่ม ความแม่นยำและประสิทธิภาพการทำงาน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] Schlutz, Matthew. "Synthetic Aperture Radar Imaging Simulated in MATLAB." (2009).
- [2] J. Nabelek, W.-P. Chen and H. Ye, "The Tangshan Earthquake Sequence and its implications for the evolution of the North China Basin," *Journal of Geophysical Research*, vol. 92, no. B12, pp. 12615-12628, 1987.
- [3] "September 11 Attacks," History. com, 25 August 2018. [Online] . Available: https://www.history.com/topics/21st-century/9-11-attacks#section_1. [Accessed 6 September 2020].
- [4] Chuanwei Ding, Jiaming Yan, Li Zhang, Heng Zhao, Hong Hong, and Xiaohua Zhu, "Noncontact Multiple Targets Vital Sign Detection Based on VMD Algorithm," 2017 IEEE Radar Conference
- [5] Artit Rittiplang and Pattarapong Phasukkit, "Human Movement Detection behind the Wall based on Doppler Frequency and Standard Deviation," 2018 International Symposium on Multimedia and Communication Technology (ISMAT), August 29-31, 2018, Tottori Prefectural Lifelong Learning Center, Tottori, Japan.
- [6] Greg Barrie, "Ultra-Wideband Synthetic Aperture Data and Image Processing," Defence R&D Canada-Ottawa.
- [7] H. Rahman, *Fundamental Principles of Radar*, Boca Raton, FL: CRC Press Taylor&Francis Group, 2019, pp. 1-10..
- [8] T. K. Sarkar, M. S. Palma and E. L. Mokole, "Echoing Across the Years: A History of Early Radar Evolution," *IEEE Microwave Magazine*, vol. 17, no. 10, pp. 46 - 60, 2016.
- [9] M. Guarnieri, "The Early History of Radar[Historical]," *IEEE Industrial Electronics Magazine*, vol. IV, no. 3, pp. 36-42, 2010.
- [10] S. Swords, *Technical History of the Beginnings of Radar*, London, UK: Peter Peregrinus, 1986.
- [11] H. Rahman, *Fundamental Principles of Radar*, Boca Raton, FL: CRC Press Taylor&Francis Group, 2019, pp. 1-10.

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง (ต่อ)

- [12] T. K. Sarkar, M. S. Palma and E. L. Mokole, "Echoing Across the Years: A History of Early Radar Evolution," IEEE Microwave Magazine, vol. 17, no. 10, pp. 46 - 60, 2016..
- [13] H. Rohling, "From Huelsmeyer's telemobiloskop to the digital radar," in 2014 11th European Radar Conference, Rome, Italy, 2014.
- [14] Z. Xu, C. J. Baker and S. Pooni, "Range and Doppler Cell Migration in Wideband Automotive Radar," IEEE Transactions on Vehicular Technology, vol. 68 , no. 6, pp. 5527 - 5536, 2019..
- [15] Z. Feng, M. Li, M. Stolz, M. Kunert and W. Wiesbeck, "Lane Detection With a High-Resolution Automotive Radar by Introducing a New Type of Road Marking," IEEE Transactions on Intelligent Transportation Systems, vol. 20, no. 7, pp. 2430 - 2447, 2019 .
- [16] Artit Rittiplang and Pattarapong Phasukkit, 2018 "Human Movement Detection behind the Wall based on Doppler Frequency and Standard Deviation," 2018 International Symposium on Multimedia and Communication Technology (ISMAC), August 29-31, 2018, pp. 85-88.

ประวัติผู้เขียน

ชื่อ-นามสกุล	นายสมพล ชื่นตระกูลวิทยา
วัน เดือน ปีเกิด	22 กันยายน 2531
ที่อยู่	170/192 ถนนร่มเกล้า แขวงคลองสามประเวศ เขตลาดกระบัง กรุงเทพมหานคร 10520 โทร.0-6230-0765
ประวัติการศึกษา	พ.ศ. 2549 มัธยมศึกษาตอนปลาย โรงเรียนอัครพิทยานุกูล พ.ศ. 2552 อนุปริญญา สาขาบำรุงรักษาเครื่องมือสื่อสารการบิน สถาบันการบินพลเรือน พ.ศ. 2555 วิศวกรรมศาสตรบัณฑิต สาขาวิชาอิเล็กทรอนิกส์และ โทรคมนาคม (เกียรตินิยมอันดับ2) มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี
ประสบการณ์การทำงานและผลงานวิจัย	
พ.ศ.2555-2560	ตำแหน่งวิศวกรซ่อมบำรุงรักษาเครื่องจำลองการบิน บริษัท Asian Aviation Training Centre Ltd.
พ.ศ.2560-ปัจจุบัน	ตำแหน่งผู้ควบคุมวิศวกรซ่อมบำรุงรักษาเครื่องจำลองการบิน ชนิด AIRBUS A320 บริษัท Asian Aviation Training Centre Ltd.
พ.ศ. 2561	ตีพิมพ์หัวข้อวิจัย “Experiment of human riding detection by UWB Pulse-Dopper Radar” ในงาน Proceeding of ISMAC 2018

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้