

วิธีอคูสติกอิมิชชันโดยหลักการเรียนรู้เชิงลึกเพื่อหาตำแหน่งรอยร้าว
โดยไม่ทำลายในรางรถไฟ

DEEP LEARNING-BASED ACOUSTIC EMISSION SCHEME FOR
NONDESTRUCTIVE LOCALIZATION OF CRACKS IN TRAIN RAILS



วิทยานิพนธ์นี้สำหรับการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต

สาขาวิชาวิศวกรรมไฟฟ้า

คณะวิศวกรรมศาสตร์

สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง

พ.ศ. 2564

KMITL-2021-EN-D-018-051

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

DEEP LEARNING-BASED ACOUSTIC EMISSION SCHEME FOR
NONDESTRUCTIVE LOCALIZATION OF CRACKS IN TRAIN RAILS



A THESIS SUBMITTED IN FULFILLMENT
OF THE REQUIREMENT FOR THE DEGREE OF
DOCTOR OF ENGINEERING IN ELECTRICAL ENGINEERING
SCHOOL OF ENGINEERING
KING MONGKUT'S INSTITUTE OF TECHNOLOGY LADKRABANG
2021
KMITL-2021-EN-D-018-051

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	วิธีอนุพัทธ์คอสติกอิมิตชันโดยหลักการเรียนรู้เชิงลึกเพื่อหาตำแหน่งรอยร้าวโดยไม่ทำลายในรางรถไฟ
นักศึกษา	นายวรา สุวรรณสินธุ์
รหัสประจำตัว	58601023
ปริญญา	วิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชา	วิศวกรรมไฟฟ้า
พ.ศ.	2564
อาจารย์ที่ปรึกษาวิทยานิพนธ์	รศ.ดร.ภัทรพงษ์ ผาสุขกิจ

บทคัดย่อ

วิทยานิพนธ์นี้นำเสนอรูปแบบการตรวจสอบสัญญาณอะคูสติกอิมิตชันโดยหัววัดสัญญาณอะคูสติกอิมิตชันหนึ่งตัว โดยการทดสอบแบบไม่ทำลายสำหรับการตรวจสอบรอยบกพร่องภายในรางรถไฟภายใต้ภาระ (Under load) ในการทำงานสัญญาณอะคูสติกอิมิตชันจะถูกจับโดยหัววัดสัญญาณอะคูสติกอิมิตชัน และแปลงสัญญาณอะคูสติกอิมิตชันเป็นข้อมูลสัญญาณดิจิทัลโดยโมดูลเก็บข้อมูลสัญญาณอะคูสติกอิมิตชัน (AE data acquisition module) ข้อมูลดิจิทัลได้รับการปรับปรุงเพื่อลดสัญญาณรบกวนเสียงรบกวนและเสียงสัมผัสของล้อและราง และข้อมูลที่ถูกลดสัญญาณรบกวนแล้ว (Denoised) ได้รับการเตรียมข้อมูลและจัดประเภทเพื่อระบุตำแหน่งรอยบกพร่องในรางรถไฟโดยการใช้แบบจำลองอัลกอริทึมการเรียนรู้เชิงลึก สัญญาณอะคูสติกอิมิตชันจำลองของการเกิดรอยบกพร่องสร้างจากการหักเสียดินสอที่ส่วนหัวราง (Rail head), เหวราง (Rail web) และ ฐานราง (Rail foot) จะถูกนำมาใช้ในการฝึกโมเดล (Training) และทดสอบโมเดล (Testing) ในแบบจำลองอัลกอริทึมในการฝึกและทดสอบอัลกอริทึมของสัญญาณอะคูสติกอิมิตชันจำลองของการเกิดรอยบกพร่องจะถูกแบ่งออกเป็นสองกลุ่ม (สัญญาณอะคูสติกอิมิตชันจำนวน 150 และ 300 ชุดข้อมูล) เพื่อเปรียบเทียบความแม่นยำในการจำแนกประเภท นอกจากนี้ยังมีการนำหลักการตรวจสอบอะคูสติกอิมิตชันที่ร่วมกับการเรียนรู้เชิงลึกมาใช้ในการทดสอบภาคสนามเพื่อตรวจหาตำแหน่งรอยบกพร่องในรางรถไฟ ความถูกต้องรวม (Total accuracy) ภายใต้การจัดกลุ่มแรกและกลุ่มสองคือ 86.6% และ 96.6% ในห้องปฏิบัติการและจากการทดสอบภาคสนามคือ 77.33% ความใหม่ของงานวิจัยนี้อยู่ที่การใช้นำหัววัดสัญญาณอะคูสติกอิมิตชันหนึ่งตัว (Single AE Sensor) และอัลกอริทึมการเรียนรู้เชิงลึกของสัญญาณอะคูสติกอิมิตชันเพื่อตรวจสอบและระบุตำแหน่งรอยบกพร่องในรางรถไฟได้อย่างมีประสิทธิภาพ ซึ่งแตกต่างจากเทคโนโลยีการตรวจสอบอะคูสติกอิมิตชันที่ใช้ในปัจจุบัน ซึ่งอาศัยหัววัดสัญญาณอะคูสติกอิมิตชันมากกว่าสองตัวขึ้นไป และการแปรผลการตรวจสอบโดยมนุษย์

Thesis	Deep Learning-based Acoustic Emission scheme for Nondestructive Localization of Cracks in Train Rails
Student	Mr. Wara Suwansin
Student ID.	58601023
Degree	Doctor of Engineering
Program	Electrical Engineering
Year	2021
Thesis Advisor	Assoc. Prof. Dr. Pattarapong Phasukkit

ABSTRACT

This research proposes a nondestructive single-sensor acoustic emission (AE) scheme for detection and localization of crack in steel rail under load. In the operation, AE signals were captured by the AE sensor and converted into digital signal data by AE data acquisition module. The digital data were denoised to remove ambient and wheel/rail contact noises, and the denoised data were processed to dataset prepared and classified to localize cracks in the steel rail using a deep learning algorithmic model. The artificial AE signals of pencil lead break at the head, web, and foot of steel rail were used to train and test the algorithmic model. In training and testing the algorithm, the artificial AE signals were divided into two groupings (150 and 300 AE signals) and the classification accuracy compared. The deep learning-based AE scheme was also implemented on-site to detect cracks in the steel rail. The total accuracy under the first and second groupings were 86.6 % and 96.6 % in laboratory, and that of the onsite experiment was 77.33 %. The novelty of this research lies in the use of single AE sensor and AE signal-based deep learning algorithm to efficiently detect and localize cracks in the steel rail, unlike existing AE crack-localization technology which relies on two or more sensors and human interpretation.

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สามารถสำเร็จลุล่วงไปได้ด้วยดี จากความช่วยเหลือและให้คำปรึกษาจากอาจารย์ที่ปรึกษา รองศาสตราจารย์ ดร.ภัทรพงษ์ ผาสุกกิจ ในการให้คำปรึกษา เสนอแนะแนวทางการดำเนินงานวิจัยและการวางแผนงานวิจัย รวมไปถึงจนถึงการแก้ปัญหาและจัดหาอุปกรณ์ สถานที่เพื่อทำการทดลองวิจัย ทำให้ข้าพเจ้ามีประสบการณ์ ความรู้เพื่อนำไปใช้ในการทำงานที่ดีมากขึ้น จึงขอขอบพระคุณเป็นอย่างสูง

ข้าพเจ้าขอขอบพระคุณบิดา มารดา และผู้มีอุปการคุณของข้าพเจ้า ผู้ส่งเสริมกำลังทรัพย์ แรงกาย แรงใจ แรงผลักดัน และการสนับสนุนในด้านการศึกษาและทุกด้านแก่ข้าพเจ้าเสมอมา ขอขอบพระคุณเป็นอย่างสูงมา ณ โอกาสนี้ด้วย

ข้าพเจ้าขอขอบคุณครอบครัวของข้าพเจ้าได้แก่ ภรรยาของข้าพเจ้าคือ นางสาวนุชญา เทียงตรง และลูกชายของข้าพเจ้าคือ เด็กชายนราวิชญ์ สุวรรณสินธุ์ รวมถึงสมาชิกครอบครัวใหญ่ (Big Family) ทุกท่านที่คอยดูแลเป็นห่วงและคอยให้กำลังใจซึ่งเป็นแรงผลักดันที่ยิ่งใหญ่มาโดยตลอด

ข้าพเจ้าขอขอบคุณ สมาชิกทุกท่านในห้องปฏิบัติการ Burn Lab ที่คอยอำนวยความสะดวกช่วยเหลือและคอยเป็นผู้แลกเปลี่ยนความรู้กับข้าพเจ้า และช่วยปฏิบัติการทดลองและเก็บผลการทดลองทั้งในห้องปฏิบัติการและนอกห้องปฏิบัติการ รวมทั้งคอยเป็นแรงผลักดันซึ่งกันและกันมาโดยตลอด

ข้าพเจ้าคาดหวังว่าวิทยานิพนธ์ฉบับนี้อาจเป็นประโยชน์แก่บุคลากรในวงการการศึกษานักเรียน นักศึกษาและผู้สนใจทั่วไป เพื่อนำไปพัฒนาและปรับใช้เป็นผลประโยชน์ต่อสังคมต่อไปในอนาคต

วรา สุวรรณสินธุ์

สารบัญ

บทคัดย่อ	I
ABSTRACT	II
กิตติกรรมประกาศ.....	III
สารบัญ.....	IV
สารบัญตาราง.....	VIII
สารบัญรูป	IX
บทที่ 1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์และจุดมุ่งหมายของการศึกษา.....	5
1.3 สมมุติฐานของการศึกษา.....	6
บทที่ 2 ทฤษฎีที่เกี่ยวข้อง.....	8
2.1 ความรู้เบื้องต้นเกี่ยวกับรางรถไฟ.....	8
2.1.1 ราง.....	8
2.1.2 ขนาดของราง.....	8
2.1.3 มาตรฐานหน้าตัดราง.....	9
2.1.4 การทดสอบคุณภาพของราง.....	10
2.1.5 การตรวจสอบองค์ประกอบทางเคมี.....	11
2.1.6 การตรวจสอบปริมาณไฮโดรเจนตกค้าง.....	12
2.2 การทดสอบเชิงกล.....	12
2.2.1 การทดสอบความสามารถในการรับน้ำหนักตกระแทก.....	12
2.2.2 การทดสอบความต้านทานแรงดึง.....	13
2.2.3 การทดสอบความแข็งที่ผิวราง.....	14
2.2.4 การทดสอบด้วยตาเปล่า.....	15
2.2.5 การตรวจสอบมิติและลักษณะทั่วไป.....	16
2.2.6 การตรวจสอบน้ำหนัก.....	20
2.3 การเกิดรอยบกร่องในรางรถไฟ.....	21
2.4 การตรวจสอบแบบไม่ทำลาย.....	23
2.4.1 การตรวจสอบด้วยวิธีอัลตราโซนิก.....	23
2.4.2 การตรวจสอบด้วยวิธีเหนี่ยวนำแม่เหล็ก.....	23
2.4.3 การตรวจสอบด้วยวิธีกระแสไหลวน.....	24

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4.4 การตรวจสอบด้วยวิธีกล้องถ่ายภาพ	25
2.4.5 การตรวจสอบด้วยวิธีถ่ายภาพรังสี	26
2.5 การทดสอบโดยวิธีอคูสติกอิมิชัน.....	27
2.5.1 ข้อได้เปรียบของการทดสอบ.....	28
2.5.2 ข้อเสียเปรียบของการทดสอบ.....	28
2.6 ทฤษฎีการทดสอบด้วยอคูสติกอิมิชัน.....	28
2.7 อุปกรณ์ทดสอบด้วยอคูสติกอิมิชัน.....	30
2.7.1 หัววัดอคูสติกอิมิชัน.....	30
2.7.2 หัววัดอคูสติกอิมิชันแบบสัมผัส.....	30
2.7.3 อุปกรณ์ขยายสัญญาณ.....	31
2.7.4 อุปกรณ์กรองสัญญาณ.....	31
2.8 อุปกรณ์รับประมวลผลสัญญาณ.....	32
2.9 ชนิดของคลื่น (Type of Wave).....	32
2.9.1 แบบต่อช่วง (Burst).....	32
2.9.2 แบบต่อเนื่อง (Continuous).....	33
2.10 อคูสติกพารามิเตอร์.....	33
2.11 มาตรฐาน ASTM E976.....	34
2.12 สถาปัตยกรรมของโครงข่าย.....	35
2.12.1 หลักการของเครือข่ายประสาทเทียมสำหรับในคอมพิวเตอร์.....	36
2.12.2 การทำงานของเครือข่ายประสาทเทียม.....	37
2.12.3 การเรียนรู้สำหรับโครงข่ายประสาทเทียม.....	37
2.12.3.1 การเรียนรู้แบบมีผู้ฝึกสอน (Supervised Training).....	37
2.12.3.2 การเรียนรู้แบบไม่มีผู้ฝึกสอน (Unsupervised Training).....	37
2.12.4 ตัวอย่างการประยุกต์ใช้โครงข่ายประสาทเทียม.....	38
2.13 ฟังก์ชันกระตุ้น (Activation function).....	38
2.12.1 ฟังก์ชันซิกมอยด์ (Sigmoid).....	39
2.12.2 ฟังก์ชันไฮเปอร์โบลิก เทนเจนท์ (Hyperbolic tangent (tanh)).....	39
2.12.3 ฟังก์ชันเรกติไฟด์ ลิเนียร์ ยูนิท (Rectified Linear Unit (ReLU)).....	40
2.12.4 ฟังก์ชันพาราเมตริกเรกติไฟด์ ลิเนียร์ ยูนิท (Parametric Rectified Linear Unit (PReLU)).....	40
2.12.5 ฟังก์ชันซอฟต์แม็กซ์ (Softmax Function).....	41
2.14 ขั้นตอนการส่งค่าไปข้างหน้า (Forward Propagation).....	42
2.15 ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation).....	43

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.16 การประเมินประสิทธิภาพของโมเดล.....	44
2.17 Receiver Operating Characteristic curve (ROC curve).....	47
บทที่ 3 ระเบียบวิธีวิจัย	48
3.1 ระเบียบวิธีการวิจัย.....	48
3.2 หัววัดอคูสติกอิมิชชั่น (Acoustic Emission Sensor).....	49
3.3 ชุดเก็บข้อมูลสัญญาณอคูสติกอิมิชชั่น (AE Data Acquisition).....	50
3.4 โครงสร้างการเรียนรู้เชิงลึก (Structure of Deep Learning).....	50
3.5 วัสดุสำหรับการทดลองและการตั้งค่า (Experimental material and setup)	51
3.5.1 รางรถไฟ (Experimental steel rail).....	51
3.5.2 อคูสติกเซ็นเซอร์และชุดเก็บข้อมูล (AE data sensor and acquisition module). 51	
3.5.3 การทดสอบแอมพลิจูดของหัววัดอคูสติกอิมิชชั่น (AE sensor amplitude testing) 52	
3.5.4 การเตรียมชุดข้อมูลเพื่อสำหรับการฝึกโมเดล (Training) และการทดสอบโมเดล (Testing) สำหรับการเรียนรู้เชิงลึก (Datasets for training and testing the deep learning algorithmic model)	53
3.6 การลดสัญญาณรบกวน (Noise reduction)	56
3.7 การแปลงสัญญาณอคูสติกอิมิชชั่นเป็นชุดข้อมูลแบบจุด.....	59
3.8 การใช้การเรียนรู้เชิงลึกเพื่อจำแนกประเภท (Proposed deep learning algorithm for classification).....	61
3.9 การฝึกโมเดลและทดสอบโมเดลของอัลกอริธึมการเรียนรู้เชิงลึก	63
3.6 การประเมินผลของการเรียนรู้เชิงลึก (Evaluation of the deep learning algorithm)... 66	
3.6.6.1 การวิเคราะห์ Receiver operating characteristic (ROC) curve	66
3.6.6.2 Confusion matrix, F1 score and total accuracy.....	66
3.7 การทดสอบภาคสนาม (Onsite experimental testing)	67
3.7.1 การทดสอบโดยใช้เครื่องอัลตราโซนิกแบบเรียงเฟส (Advanced phased array ultrasonic testing (PAUT)).....	67
3.7.2 การวัดอุณหภูมิของรางรถไฟก่อนการทดสอบ	68
3.7.3 การเก็บข้อมูลขณะรถไฟกำลังวิ่งผ่าน	68
บทที่ 4 ผลการดำเนินงาน	70
4.1. ผล Receiver operating characteristic (ROC) curve.....	70
4.2. ผล Confusion matrix	75
4.3. ผล F1 scores ของการเรียนรู้เชิงลึก	77
4.4. ผลการทดสอบภาคสนามของสัญญาณอคูสติกอิมิชชั่นในรางรถไฟ (Onsite AE signals using the proposed AE scheme).....	79

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 5 สรุปผลงานวิจัยและข้อเสนอแนะ.....	80
เอกสารอ้างอิง	82
ภาคผนวก ก.....	87
ผลงานที่ได้รับการตีพิมพ์วารสารนานาชาติ.....	87
ประวัติผู้เขียน.....	107



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สารบัญตาราง

ตารางที่ 3.1	คุณสมบัติของอุปกรณ์หลักที่ใช้ในการวิจัย	48
ตารางที่ 3.2	องค์ประกอบทางเคมีของเหล็กแรงกดไฟชนิด UIC 54.....	51
ตารางที่ 3.3	พีคแอมพลิจูดและค่าเฉลี่ยแอมพลิจูดของอคูสติกอิมพัลส์เซ็นเซอร์.....	53
ตารางที่ 4.1	Comparison between F1 score and total accuracy ของสัญญาณอคูสติกอิมพัลส์เซ็นเซอร์จำนวน 150 ชุดข้อมูล (กลุ่มที่ 1) และสัญญาณอคูสติกอิมพัลส์เซ็นเซอร์จำนวน 300 ชุดข้อมูล (กลุ่มที่ 2) ...	78



สารบัญรูป

รูปที่ 1.1	หน้าสัมผัสระหว่างล้อและราง	1
รูปที่ 1.2	ถังเก็บน้ำมันและก๊าซปิโตรเลียมเหลวบนเรือบรรทุกน้ำมัน	2
รูปที่ 1.3	การตรวจถังก๊าซธรรมชาติ (NGV) ของภาชนะรับความดันสำหรับรถยนต์	3
รูปที่ 1.4	การตรวจถังถังกักเก็บน้ำทรงกลมใช้วิธีการตรวจสอบอคูสติกอิมพัลส์ร่วมกับอัลกอริธึมแบบ ซัพพอร์ตเวกเตอร์แมชชีน (SVM) เพื่อจำแนกประเภทการกัดกร่อนและการรั่วไหล [39]	4
รูปที่ 2.1	ส่วนประกอบราง [45]	8
รูปที่ 2.2	หน้าตัดราง BS 80 A [45]	9
รูปที่ 2.3	หน้าตัดราง 100 A [45]	10
รูปที่ 2.4	การวิเคราะห์ส่วนผสมทางเคมีด้วยระบบอัตโนมัติ [45]	11
รูปที่ 2.5	การตรวจสอบปริมาณไฮโดรเจนตกค้าง [45]	12
รูปที่ 2.6	ชิ้นรางที่ผ่านการรับน้ำหนักตกกระแทก [45]	13
รูปที่ 2.7	ชิ้นรางที่ผ่านการรับน้ำหนักตกกระแทกและวัดค่าแอนตัว [45]	13
รูปที่ 2.8	การทดสอบความต้านทานแรงดึง [45]	14
รูปที่ 2.9	การทดสอบความต้านทานแรงดึงจนกระทั่งขาดออกจากกัน [45]	14
รูปที่ 2.10	การทดสอบความแข็งแรงแบบไบรเนลล์ที่ผิวราง [45]	15
รูปที่ 2.11	Baumann Sulfur Print [45]	16
รูปที่ 2.12	ตรวจสอบความ (ก) สูงของรางและ (ข) ความกว้างที่ฐานราง [45]	19
รูปที่ 2.13	ตรวจสอบ (ก) ความกว้างของหัวราง (ข) ความหนาของเอวราง [45]	19
รูปที่ 2.14	ตรวจสอบระยะระหว่างผิวสัมผัสเหล็ก (ก) ประกบราง (ข) ความไม่สมมาตรของหน้าตัด ราง [45]	20
รูปที่ 2.15	การหาหน้าหนักแท้จริงของรางโดยการชั่งน้ำหนักชิ้นราง [45]	21
(ข)		22
รูปที่ 2.16	ลักษณะความชำรุดของราง (ก) Rail Surface Defect (ข) Rail Subsurface Defect ..	22
รูปที่ 2.17	เครื่องอัลตราโซนิกสำหรับงานตรวจสอบรางรถไฟ	23
รูปที่ 2.18	เครื่องตรวจสอบด้วยวิธีเหนี่ยวนำแม่เหล็กสำหรับงานตรวจสอบรางรถไฟ	24
รูปที่ 2.19	เครื่องตรวจสอบด้วยวิธีกระแสไหลวนสำหรับงานตรวจสอบรางรถไฟ	25
รูปที่ 2.20	กล้องถ่ายภาพสำหรับงานตรวจสอบรางรถไฟ	26
รูปที่ 2.21	เครื่องถ่ายภาพรังสีสำหรับงานตรวจสอบรางรถไฟ	26
รูปที่ 2.22	รถตรวจรางร้าว การรถไฟแห่งประเทศไทย	27
รูปที่ 2.23	การทดสอบโดยวิธีอคูสติกอิมพัลส์	28

รูปที่ 2.24 หลักการทดสอบด้วยวิธีอคูสติกอิมิชชัน	29
รูปที่ 2.25 หัววัดอคูสติกอิมิชชัน.....	30
รูปที่ 2.26 หัววัดแบบสัมผัส	31
รูปที่ 2.27 ช่วงการตอบสนองต่อความถี่ของหัววัด รุ่น VS 150 RIC.....	31
รูปที่ 2.28 บอร์ด FPGA รุ่น ASIP-2.....	32
รูปที่ 2.29 ชนิดของคลื่นอคูสติกอิมิชชัน [46]	33
รูปที่ 2.30 อคูสติกพารามิเตอร์.....	34
รูปที่ 2.31 ค่าสูงสุดของแอมพลิจูดในโดเมนเวลาของสัญญาณอคูสติกอิมิชชัน.....	35
รูปที่ 2.32 การหักไส้ดินสอ (Pencil Lead Break) ตามมาตรฐาน ASME E976	35
รูปที่ 2.33 สถาปัตยกรรมของ Deep Neural Networks	36
รูปที่ 2.34 แบบจำลองของนิวรอนในคอมพิวเตอร์.....	37
รูปที่ 2.35 กราฟ Sigmoid function	39
รูปที่ 2.36 กราฟ Hyperbolic tangent function.....	40
รูปที่ 2.37 กราฟ Rectified Linear Unit – ReLU.....	40
รูปที่ 2.38 กราฟ Parametric Rectified Linear Unit.....	41
รูปที่ 2.39 การทำงานของฟังก์ชันซอฟต์แวร์แม็กซ์.....	41
รูปที่ 2.40 กราฟ Softmax Function	42
รูปที่ 2.41 กระบวนการ Forward Propagation	43
รูปที่ 2.42 (ก) กรณีตั้งค่าอัตราการเรียนรู้สูง (ข) กรณีตั้งค่าอัตราการเรียนรู้ต่ำ.....	43
รูปที่ 2.43 การส่งผ่านไปข้างหน้า (Forward Pass) และการส่งผ่านย้อนกลับ (Backward Pass)...	44
รูปที่ 2.44 ตารางขนาด Confusion Matrix 2 x 2	45
รูปที่ 2.45 Model ROC Curve และ AUC.....	47
รูปที่ 3.1 ระบบการเก็บข้อมูลสัญญาณอคูสติกอิมิชชันจากตำแหน่งรอยบกพร่องที่เกิดขึ้นที่ตำแหน่ง ต่างๆ ของรางรถไฟ โดยการใช้หลักการเรียนรู้เชิงลึก (Deep Learning) เพื่อหาระบุตำแหน่ง.....	48
รูปที่ 3.2 หัววัดอคูสติกอิมิชชัน	49
รูปที่ 3.3 ชุดเก็บข้อมูลสัญญาณอคูสติกอิมิชชัน รุ่น AMSY-6.....	50
รูปที่ 3.4 แผนภาพการเรียนรู้เชิงลึกสำหรับการจำแนกประเภท	51
รูปที่ 3.5 หัววัดอคูสติกอิมิชชันและชุดเก็บข้อมูลสัญญาณอคูสติกอิมิชชัน (ก) ชุดเก็บข้อมูลของ สัญญาณอคูสติกอิมิชชัน (ข) หัววัดอคูสติกอิมิชชัน, ชุดจับยึดแบบแม่เหล็ก (MAG4R) และ Hsu- Nielsen source.....	52
รูปที่ 3.6 พิกัดแอมพลิจูดของอคูสติกอิมิชชันเซ็นเซอร์ (dB) เทียบกับเวลา (s).....	53
รูปที่ 3.7 ตำแหน่งของการหักไส้ดินสอเพื่อสร้างสัญญาณอคูสติกอิมิชชันจำลอง (ก) ที่ตำแหน่งหัวราง (Rail Head) (ข) ที่ตำแหน่งเอวราง (Rail Web) (ค) ที่ตำแหน่งฐานราง (Rail Foot).....	54

รูปที่ 3.8 การแบ่งกลุ่มชุดข้อมูลสำหรับการฝึกโมเดลและการทดสอบโมเดล.....	54
รูปที่ 3.9 สัญญาณอคูสติกอิมิชชันจำลองที่ยังไม่ถูกกำจัดสัญญาณรบกวนที่ตำแหน่งของรางรถไฟ (ก) ที่ตำแหน่งหัวราง (Rail Head) (ข) ที่ตำแหน่งเอวราง (Rail Web) (ค) ที่ตำแหน่งฐานราง (Rail Foot)	56
รูปที่ 3.10 สัญญาณอคูสติกอิมิชชันที่กำเนิดจากรอยบกพร่อง (ก) สัญญาณอคูสติกอิมิชชันก่อนลดสัญญาณรบกวน (ข) สัญญาณอคูสติกอิมิชชันหลังลดสัญญาณรบกวน	56
รูปที่ 3.11 ขั้นตอนการทำ Majorization-minimization (MM) (ก) cost function $F(x)$ ที่กำหนดค่าเริ่มต้นของ x_0 (ข) การวนซ้ำครั้งที่ 1 เมื่อ majorizer $G_0(x)$ คือ tangent to $F(x)$ ที่ x_0 และ minimize $G_0(x)$ ของ x_1 (ค) การวนซ้ำครั้งที่ 2 เมื่อ majorizer $G_1(x)$ คือ tangent to $F(x)$ ที่ x_1 และ minimize $G_1(x)$ ของ x_2	58
รูปที่ 3.12 แปลงสัญญาณอคูสติกอิมิชชันจำลองหลังจากการกำจัดสัญญาณรบกวนในห้องปฏิบัติการเป็นจุดของข้อมูล 300,000 จุด (Data points) ในรูปแบบสเปรดชีต	60
รูปที่ 3.13 รูปแบบสเปรดชีตของข้อมูลคุณลักษณะ (Feature) และข้อมูลเป้าหมาย (Target).....	61
รูปที่ 3.14 สัญญาณอคูสติกอิมิชชันเป็นชุดข้อมูลคุณลักษณะ (Feature) เป็นจุดของข้อมูล 300,000 จุด (Data points) ในรูปแบบสเปรดชีต	61
รูปที่ 3.15 โมเดลการเรียนรู้เชิงลึกสำหรับการจำแนกประเภท	62
รูปที่ 3.16 ขั้นตอนการฝึกโมเดล (Training) และทดสอบโมเดล (Testing) สำหรับการเรียนรู้เชิงลึก	63
รูปที่ 3.17 (ก) ตัวอย่างข้อมูลสำหรับฝึกให้กับโมเดลก่อนทำการแปลงให้เป็นเมตริกซ์และยังไม่ได้ปรับช่วงข้อมูล (ข) ตัวอย่างข้อมูลสำหรับฝึกให้กับโมเดลหลังจากทำการแปลงให้เป็นเมตริกซ์และปรับช่วงข้อมูลแล้ว	64
รูปที่ 3.18 การทดสอบภาคสนามด้วยเครื่องอัลตราโซนิกแบบเรียงเฟส (ก) เครื่องอัลตราโซนิกแบบเรียงเฟสตรวจสอบแนวเชื่อมของรางรถไฟ (ข) สัญญาณรอยบกพร่องบริเวณแนวเชื่อมของรางรถไฟที่ตรวจพบโดยเครื่องอัลตราโซนิกแบบเรียงเฟส	68
รูปที่ 3.19 การวัดอุณหภูมิรางรถไฟโดยการใช้กล้องถ่ายภาพความร้อน.....	68
รูปที่ 3.20 การเก็บข้อมูลสัญญาณอคูสติกอิมิชชันในขณะรถไฟกำลังวิ่งผ่าน (ก) การติดตั้งหัววัด.....	69
อคูสติกอิมิชชันที่รางรถไฟ (ข) สัญญาณอคูสติกอิมิชชันของรางรถไฟภายใต้ภาวะ	69
รูปที่ 4.1 Receiver operating characteristic (ROC) curve คลาส 0, 1, และ 2 ที่บ่งชี้ตำแหน่งหัวราง (Rail head), เอวราง (Rail web) และ ฐานราง (Rail foot) สัญญาณอคูสติกอิมิชชันจำนวน 150 ชุดข้อมูล (กลุ่มที่ 1).....	70
รูปที่ 4.2 Receiver operating characteristic (ROC) curve คลาส 0, 1, และ 2 ที่บ่งชี้หัวราง (Rail head), เอวราง (Rail web) และ ฐานราง (Rail foot) สัญญาณอคูสติกอิมิชชันจำนวน 300 ชุดข้อมูล (กลุ่มที่ 2)	71

รูปที่ 4.3 Receiver operating characteristic (ROC) curve คลาส 0 ที่บ่งชี้ที่ตำแหน่งหัวราง (Rail head) สัญญาณอคูสติกอิมพัลส์จำนวน 150 ชุดข้อมูล (กลุ่มที่ 1).....	71
รูปที่ 4.4 Receiver operating characteristic (ROC) curve คลาส 1 ที่บ่งชี้ที่ตำแหน่งเอวราง (Rail web) สัญญาณอคูสติกอิมพัลส์จำนวน 150 ชุดข้อมูล (กลุ่มที่ 1).....	72
รูปที่ 4.5 Receiver operating characteristic (ROC) curve คลาส 2 ที่บ่งชี้ที่ตำแหน่งฐานราง (Rail foot) สัญญาณอคูสติกอิมพัลส์จำนวน 150 ชุดข้อมูล (กลุ่มที่ 1).....	72
รูปที่ 4.6 Receiver operating characteristic (ROC) curve คลาส 0 ที่บ่งชี้ที่ตำแหน่งหัวราง (Rail head) สัญญาณอคูสติกอิมพัลส์จำนวน 300 ชุดข้อมูล (กลุ่มที่ 2).....	73
รูปที่ 4.7 Receiver operating characteristic (ROC) curve คลาส 1 ที่บ่งชี้ที่ตำแหน่งเอวราง (Rail web) สัญญาณอคูสติกอิมพัลส์จำนวน 300 ชุดข้อมูล (กลุ่มที่ 2).....	74
รูปที่ 4.8 Receiver operating characteristic (ROC) curve คลาส 2 ที่บ่งชี้ที่ตำแหน่งฐานราง (Rail foot) สัญญาณอคูสติกอิมพัลส์จำนวน 300 ชุดข้อมูล (กลุ่มที่ 2).....	74
รูปที่ 4.9 ผล Confusion matrix สัญญาณอคูสติกอิมพัลส์จำนวน 30 ชุดข้อมูล	76
รูปที่ 4.10 ผล Confusion matrix สัญญาณอคูสติกอิมพัลส์จำนวน 60 ชุดข้อมูล	77
รูปที่ 4.11 สัญญาณอคูสติกอิมพัลส์ชั้นของรอยร้าวที่ตำแหน่งแนวเชื่อมของรางรถไฟภายใต้ภาวะ โดยใช้หัววัดอคูสติกอิมพัลส์แบบเซ็นเซอร์เดียว.....	79

บทที่ 1


บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

การขนส่งทางรถไฟมีบทบาทสำคัญในการถ่ายโอนผู้โดยสารจำนวนมากและการขนส่งสินค้าระหว่างจุดหมายปลายทาง ความสำคัญของทางรถไฟจึงจำเป็นต้องมีการตรวจสอบสภาพของโครงสร้าง (Structural Health Monitoring (SHM)) เป็นประจำ เพื่อระบุข้อบกพร่องแบบความไม่ต่อเนื่อง (Discontinuity defects) ของแนวเชื่อมต่อของรางรถไฟและรักษาสภาพของรางรถไฟตามกำหนดระยะเวลา เพื่อช่วยป้องกันการเกิดอุบัติเหตุทางรถไฟและเพิ่มความสะดวกสบายของผู้โดยสาร

การตรวจสอบการปลดปล่อยคลื่นเสียง หรือที่เรียกว่า การตรวจสอบวิธีอคูสติกอิมิชชัน (Acoustic Emission Testing (AET)) ซึ่งเป็นวิธีการหนึ่งในวิธีการตรวจสอบแบบไม่ทำลาย (Nondestructive Testing) โดยการตรวจสอบวิธีอคูสติกอิมิชชันเป็นเทคนิคแบบพาสซีฟ ซึ่งเป็นการตรวจจับพลังงานยืดหยุ่นที่ปลดปล่อยออกมาเองจากวัสดุที่มีรอยแตกร้าวและรอยบกพร่อง [1-4] นอกจากนี้ยังมีการนำเทคนิคการตรวจสอบวิธีอคูสติกอิมิชชันมาใช้เพื่อกำหนดลักษณะของการเกิดรอยบกพร่องภายใต้ภาระ สัญญาณอคูสติกอิมิชชันเป็นคลื่นเสียงแบบยืดหยุ่นชั่วคราว อยู่ในช่วงความถี่ 95 kHz - 300 kHz ข้อดีของเทคนิคอคูสติกอิมิชชันแบบพาสซีฟ (Passive AE) ที่ดีกว่าวิธีการทดสอบแบบไม่ทำลายแบบแอคทีฟ (Active Nondestructive Testing) แบบดั้งเดิม เช่น สามารถตรวจสอบแบบออนไลน์ (Online Monitoring), มีความไวสูง (High Sensitivity) การตรวจสอบรอยบกพร่องในระยะเริ่มต้นและรวดเร็ว (Early and Rapid Defect Detection) [5-8]

สัญญาณอคูสติกอิมิชชันที่เกิดจากรอยบกพร่องในรางรถไฟที่เกิดจากความเมื่อยล้า (Fatigue) ในหน้าสัมผัสอย่างไม่สม่ำเสมอจากล้อและราง รอยบกพร่องของรางที่เกิดจากการสัมผัสล้อและรางซึ่งเป็นแบบไดนามิกและการกระทำอาจส่งผลกระทบต่อให้เกิดความเสียหายอย่างร้ายแรง [9-13] รอยบกพร่องในรางรถไฟซึ่งส่วนใหญ่เกิดจากรอยแตกเมื่อยล้า (Fatigue) [14-16]




รูปที่ 1.1 หน้าสัมผัสระหว่างล้อและราง

เทคโนโลยีอคูสติกอิมิชชัน (AE) แบบดั้งเดิมที่ไม่มีอัลกอริทึมของการเรียนรู้เชิงลึก (Deep Learning) ของเครื่องได้ถูกนำไปใช้งานอย่างแพร่หลายในปัจจุบัน เช่น การตรวจสอบรอยร้าวและตรวจสอบความสมบูรณ์ของอาคารหรือโครงสร้างภาชนะรับแรงดัน, ท่อขนส่งน้ำมัน, ส่วนประกอบต่างๆของอากาศยาน, ถังเก็บน้ำมันและก๊าซปิโตรเลียมเหลวบนเรือบรรทุกน้ำมันดังแสดงในรูปที่ 1.2 และในการวิจัยต่างๆทางด้านวัสดุศาสตร์ [17-20] ในงานด้านความสมบูรณ์ของโครงสร้างโดยการตรวจสอบด้วยวิธีการอคูสติกอิมิชชัน (AE) ได้ถูกนำมาใช้เพื่อตรวจสอบและเฝ้าติดตามรอยร้าวแบบเมื่อยล้า (Fatigue Crack) ที่เกิดขึ้นใหม่ในสะพานเหล็กที่ขณะใช้งาน [21-23] ในการตรวจสอบภาชนะรับความดันได้นำเทคโนโลยีการตรวจสอบอคูสติกอิมิชชัน (AE) มาใช้สำหรับการตรวจสอบรอยร้าวแบบเมื่อยล้า (Fatigue Crack) แบบออนไลน์ และการนำมาใช้ในการตรวจสอบถึงก๊าซปิโตรเลียมเหลว (LPG) และถึงก๊าซธรรมชาติ (NGV) ของภาชนะรับความดันสำหรับรถยนต์ภายใต้ภาระ (Under load) ดังแสดงในรูปที่ 1.3 [24,25] นอกจากนี้มีการนำวิธีตรวจสอบอคูสติกอิมิชชัน (AE) เพื่อตรวจสอบและค้นหาสาเหตุการเกิดกั๊กกร่อนและการรั่วไหลในท่อส่งน้ำมันใต้ดินและท่อของก๊าซปิโตรเลียมเหลว (LPG) และท่อของก๊าซธรรมชาติ (NGV) [26,27]



รูปที่ 1.2 ถังเก็บน้ำมันและก๊าซปิโตรเลียมเหลวบนเรือบรรทุกน้ำมัน

Diagram of Acoustic Emission Test on a Pressure Vessel




รูปที่ 1.3 การตรวจถังก๊าซธรรมชาติ (NGV) ของภาชนะรับความดันสำหรับรถยนต์

ในส่วนประกอบของอากาศยานได้นำเทคโนโลยีอคูสติกอิมิชชั่น (AE) เพื่อตรวจสอบรอยบกพร่องแบบเมื่อยล้าภายใต้ภาระ [28-30] ในถังเก็บน้ำมันการตรวจสอบวิธีอคูสติกอิมิชชั่น (AE) ถูกนำมาใช้เพื่อตรวจสอบความสมบูรณ์ของถังเก็บน้ำมันและเพื่อตรวจสอบและค้นหาการเกิดการกัดกร่อนและการรั่วไหลในแผ่นพื้นถังเก็บด้านล่างของถังเก็บ [31,32] ในการวิจัยทางด้านวัสดุ เทคโนโลยีอคูสติกอิมิชชั่น (AE) ถูกนำมาใช้เพื่อระบุคุณสมบัติของวัสดุที่เสียหายและกลไกการแตกร้าว [33,34] ในรางรถไฟเทคโนโลยีนี้ได้ถูกนำมาใช้เพื่อตรวจสอบและกำหนดหาตำแหน่งรอยแตกเมื่อยล้าในรางรถไฟและส่วนประกอบรางรถไฟที่รับภาระโหลด [35-37] อย่างไรก็ตามเทคโนโลยีอคูสติกอิมิชชั่น (AE) แบบเดิมสำหรับการตรวจสอบและการแปลผลของรอยแบบเมื่อยล้า นั้นต้องอาศัยเซ็นเซอร์สองตัวขึ้นไปและการแปลผลการตรวจสอบโดยมนุษย์ซึ่งมีแนวโน้มที่จะเกิดข้อผิดพลาด

เพื่อแก้ไขข้อผิดพลาดของมนุษย์ที่ใช้เทคโนโลยีอคูสติกอิมิชชั่น (AE) แบบดั้งเดิม ซึ่งในปัจจุบันการเรียนรู้เชิงลึกจากรูปภาพได้ถูกนำมาใช้งานร่วมกับเทคโนโลยีอคูสติกอิมิชชั่น (AE) เพื่อหาตำแหน่งแหล่งกำเนิดที่มาของรอยบกพร่องในโครงสร้างแบบแผ่น [38] ในถังเก็บน้ำมันทรงกลมใช้วิธีการตรวจสอบอคูสติกอิมิชชั่น (AE) ร่วมกับอัลกอริธึมแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) เพื่อจำแนกประเภทการกัดกร่อนและการรั่วไหลแต่ยังไม่สามารถระบุแหล่งที่มาได้ [39] ดังแสดงในรูปที่ 1.4 ในวัสดุคอมโพสิตได้นำเทคโนโลยีอคูสติกอิมิชชั่น (AE) ร่วมกับอัลกอริธึมแบบจำลองมาร์คอฟ (ซึ่งความน่าจะเป็น) ที่ไม่เป็นวัสดุเนื้อเดียวกันถูกนำมาใช้เพื่อทำนายอายุการใช้งานที่เหลืออยู่และความล้าของวัสดุ [40] ในการตรวจสอบความเสียหายของตลับลูกปืนโดยใช้วิธีการตรวจสอบอคูสติกอิมิชชั่น (AE) ร่วมกับอัลกอริธึมแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) ถูกนำมาใช้เพื่อตรวจสอบแรงเสียดทานและการสึกหรอของตลับลูกปืน [41] ในงานด้านการตรวจสอบหม้อแปลงไฟฟ้าในสถานีไฟฟ้าย่อยได้นำเทคโนโลยีการตรวจสอบอคูสติกอิมิชชั่น (AE) ร่วมกับอัลกอริธึมแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) ถูกนำมาใช้เพื่อการตรวจสอบความเสียหายแบบทริอิงทางไฟฟ้า [42] แม้ว่าการเรียนรู้เชิงลึกโดยการใช้รูปภาพจะสามารถแปลผลแหล่งที่มาของรอยบกพร่องได้ แต่โครงสร้างของอัลกอริธึมดังกล่าวข้างต้น ต้องใช้ทรัพยากรในการคำนวณจำนวนมากกว่าโครงสร้างของ

อัลกอริธึมการเรียนรู้เชิงลึกสำหรับการจำแนกประเภทตามสัญญาณอคูสติกอิมมิชชัน (AE) ในขณะเดียวกันเทคโนโลยีก็มีความน่าจะเป็นและเทคโนโลยีการตรวจสอบอคูสติกอิมมิชชัน (AE) ที่ร่วมกับอัลกอริธึมแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) ไม่สามารถจำแนกตำแหน่งความเสียหายของรางรถไฟได้



รูปที่ 1.4 การตรวจถึงถังเก็บน้ำทรงกลมใช้วิธีการตรวจสอบอคูสติกอิมมิชชันร่วมกับอัลกอริธึมแบบซัพพอร์ตเวกเตอร์แมชชีน (SVM) เพื่อจำแนกประเภทการกัดกร่อนและการรั่วไหล [39]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

งานวิจัยนี้ได้นำเสนอรูปแบบวิธีการตรวจสอบอคูสติกอิมิชชัน (AE) แบบหัววัดสัญญาณอคูสติกอิมิชชันจำนวนหนึ่งหัววัด ซึ่งเป็นวิธีการตรวจสอบแบบไม่ทำลายร่วมกับอัลกอริธึมการเรียนรู้เชิงลึกโดยการใช้สัญญาณอคูสติกอิมิชชัน (AE) สำหรับการตรวจสอบและการแปรผลตำแหน่งรอยบัพพร้อมในรางรถไฟภายใต้ภาระ โดยการนำสัญญาณอคูสติกอิมิชชันจำลอง (Artificial Acoustic Emission Signal) ของการเกิดสัญญาณอคูสติกอิมิชชันจากรอยบัพพร้อม โดยการหักไส้ดินสอด (Pencil Lead Break (PLB)) ตามมาตรฐาน ASTM E976 ที่ตำแหน่งส่วนหัวราง (Rail head), เอวราง (Rail web) และ ฐานราง (Rail foot) ของรางรถไฟในห้องปฏิบัติการ นำมาใช้เพื่อฝึกโมเดล (Training) และทดสอบโมเดล (Testing) ของอัลกอริธึมการเรียนรู้เชิงลึกที่ออกแบบและพัฒนาขึ้น ในการฝึกโมเดลและทดสอบโมเดลของอัลกอริธึม สัญญาณอคูสติกอิมิชชัน (AE) ถูกแบ่งออกเป็นสองกลุ่มชุดข้อมูล เพื่อนำมาเปรียบเทียบความแม่นยำในการจำแนกประเภทตำแหน่งที่เกิดรอยบัพพร้อมของโมเดลในห้องปฏิบัติการ และนำโมเดลที่ได้จากห้องปฏิบัติการมาทดสอบกับข้อมูลที่เก็บผลการตรวจสอบจากภาคสนาม โดยนำสัญญาณอคูสติกอิมิชชัน (AE) ที่ตำแหน่งแนวเชื่อมเพื่อตรวจสอบหารอยบัพพร้อมในรางรถไฟและนำมาประมวลผลโดยการใช้โมเดลการเรียนรู้เชิงลึก และนำผลลัพธ์ที่ได้จากการใช้โมเดลการเรียนรู้เชิงลึกเพื่อเปรียบเทียบประสิทธิภาพการจำแนกตำแหน่งของการเกิดรอยบัพพร้อมที่ได้จากผลการตรวจสอบโดยใช้คลื่นเสียงความถี่สูงแบบเรียงเฟส (Phased Array Ultrasonic Testing) และวิเคราะห์ผลความถูกต้องโดยรวมของอัลกอริธึมการเรียนรู้เชิงลึกที่ออกแบบและพัฒนาขึ้นในห้องปฏิบัติการ

1.2 วัตถุประสงค์และจุดมุ่งหมายของการศึกษา

1. ในการศึกษานี้มีเป้าหมายเพื่อค้นคว้าวิธีการค้นหาตำแหน่งรอยบัพพร้อมในรางรถไฟ โดยใช้หลักการและคุณสมบัติของสัญญาณอคูสติกอิมิชชัน (Acoustic Emission; AE) แบบหัววัดสัญญาณอคูสติกอิมิชชันหนึ่งตัว (Single sensor)
2. ในการศึกษานี้ต้องการนำสัญญาณอคูสติกอิมิชชันที่ตรวจสอบได้นำไปประยุกต์ใช้งานร่วมกับการเรียนรู้เชิงลึก (Deep Learning) เพื่อระบุตำแหน่งรอยบัพพร้อมในรางรถไฟที่มีแหล่งกำเนิดจากตำแหน่ง หัวราง (Rail head), เอวราง (Rail web) และ ฐานราง (Rail foot)
3. ในการศึกษานี้ต้องการเป็นส่วนหนึ่งในการวิจัยและนำไปพัฒนาต่อยอดเชิงพาณิชย์ เพื่อนำมาใช้เป็นการตรวจสอบรางรถไฟ โดยการพัฒนาอัลกอริธึมการเรียนรู้เชิงลึกที่ออกแบบและพัฒนาขึ้นให้มีความเหมาะสมกับสภาพแวดล้อมของการทำงานของรางรถไฟในประเทศไทย และทดแทนการจัดซื้อจากต่างประเทศซึ่งมีราคาค่อนข้างสูงในปัจจุบัน

1.3 สมมุติฐานของการศึกษา

ในการศึกษางานวิจัยนี้สามารถค้นหาวีธีการใหม่สำหรับการตรวจสอบรอยบกพร่องในรางรถไฟภายใต้ภาวะ โดยการใช้หลักการตรวจสอบสัญญาณคอสติกอิมิชชัน (Acoustic Emission) ที่เกิดจากความเสียหายหรือรอยบกพร่องภายในรางรถไฟ แบบหัววัดสัญญาณคอสติกอิมิชชันหนึ่งตัว (Single sensor) ร่วมกับการพัฒนาอัลกอริธึมการเรียนรู้เชิงลึก (Deep Learning) ซึ่งโดยปกติแล้วการระบุตำแหน่งโดยหลักการวิธีตรวจสอบคอสติกอิมิชชันแบบดั้งเดิม (Conventional Acoustic Emission) ต้องอาศัยจำนวนหัววัดสัญญาณคอสติกอิมิชชันตั้งแต่สองตัวขึ้นไป เพื่อระบุตำแหน่งรอยบกพร่องในรางรถไฟที่ตำแหน่ง หัวราง (Rail head), เอเวราง (Rail web) และ ฐานราง (Rail foot) โดยหลักการที่ศึกษาวิจัยสามารถตรวจสอบรอยบกพร่องในรางรถไฟภายใต้ภาวะ โดยการใช้สัญญาณคอสติกอิมิชชันแบบหัววัดสัญญาณคอสติกอิมิชชันแบบเซ็นเซอร์เดียว (Single sensor) ร่วมกับการพัฒนาอัลกอริธึม Majorization-Minimization (MM) [44] เพื่อลดสัญญาณรบกวนจากสถานะแวดล้อมและเสียงจากการสัมผัสของล้อและราง โดยชุดข้อมูลที่ถูกลดสัญญาณรบกวนแล้ว (Denoised) ก่อนนำไปการประมวลผลจะมีการเตรียมชุดข้อมูลเพื่อระบุตำแหน่งรอยบกพร่องในรางรถไฟ โดยสัญญาณคอสติกอิมิชชันจำลองความเสียหายหรือการเกิดรอยบกพร่องในรางรถไฟ สามารถสร้างสัญญาณคอสติกอิมิชชันจำลองจากการหักได้ดินสอ (PLB) ตามมาตรฐาน ASTM E967 เพื่อสร้างสัญญาณคอสติกอิมิชชันจำลองที่เสมือนสัญญาณคอสติกอิมิชชันที่เกิดขึ้นจากการปลดปล่อยสัญญาณคอสติกอิมิชชันจากรอยบกพร่องในรางรถไฟที่เกิดขึ้นในตำแหน่ง หัวราง (Rail head), เอเวราง (Rail web) และ ฐานราง (Rail foot) ชุดข้อมูลที่ได้จะนำมาใช้ในการฝึกโมเดล (Training) และทดสอบโมเดล (Testing) ในอัลกอริธึมการเรียนรู้เชิงลึกที่ออกแบบและพัฒนาขึ้น ในการฝึกโมเดล (Training) และทดสอบโมเดล (Testing) ในอัลกอริธึมการเรียนรู้เชิงลึก ชุดข้อมูลทั้งหมดจำนวน 450 ชุดข้อมูล จะแบ่งออกเป็นสองกลุ่มคือ กลุ่มแรกสัญญาณคอสติกอิมิชชันจำลองจำนวน 150 ชุดข้อมูล และสัญญาณคอสติกอิมิชชันจำลองจำนวน 300 ชุดข้อมูล เพื่อเปรียบเทียบความแม่นยำของโมเดลในการจำแนกประเภทของตำแหน่งการเกิดรอยบกพร่องในรางรถไฟ นอกจากนี้ยังมีการนำหลักการตรวจสอบคอสติกอิมิชชันร่วมกับอัลกอริธึมการเรียนรู้เชิงลึกมาใช้ในจำแนกตำแหน่งของการเกิดรอยบกพร่องของชุดข้อมูลที่เก็บข้อมูลสัญญาณคอสติกอิมิชชันจากภาคสนามเพื่อตรวจสอบรอยบกพร่องในรางรถไฟ โดยความแม่นยำรวมภายใต้การจัดกลุ่มชุดข้อมูลแบบที่ 1 จำนวน 150 ชุดข้อมูล โดยมีความแม่นยำรวมของโมเดลคือ 86.6% และการจัดกลุ่มชุดข้อมูลแบบที่ 2 จำนวน 300 ชุดข้อมูล มีความแม่นยำรวมของโมเดลคือ 96.6% ซึ่งการจัดกลุ่มชุดข้อมูลแบบที่ 2 จำนวน 300 ชุดข้อมูล มีความแม่นยำรวมของโมเดลมากที่สุด จึงนำโมเดลการเรียนรู้เชิงลึกที่มีความแม่นยำรวมมากที่สุดมาใช้ในการวิเคราะห์ผลข้อมูลที่ได้จากการทดสอบภาคสนาม โดยผลจากการทดสอบภาคสนามมีความแม่นยำรวม 77.33% โดยความใหม่ของงานวิจัยนี้คือการใช้สัญญาณคอสติกอิมิชชันเซ็นเซอร์แบบหัววัดสัญญาณคอสติกอิมิชชันหนึ่งตัว (Single sensor) ร่วมกับอัลกอริธึมการเรียนรู้เชิงลึกจากการเรียนรู้ชุดข้อมูลของสัญญาณคอสติกอิมิชชันจำลองในห้องปฏิบัติการ สามารถตรวจสอบและระบุ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตำแหน่งความเสียหายหรือรอยบกพร่องในรางรถไฟได้อย่างมีประสิทธิภาพ ซึ่งแตกต่างจากเทคโนโลยีคอมพิวเตอร์วิชั่นแบบดั้งเดิมที่มีใช้อยู่ในปัจจุบัน ซึ่งจำนวนหัววัดสัญญาณคอมพิวเตอร์วิชั่นตั้งแต่สองตัวขึ้นไปและการแปรความผลชุดข้อมูลต่างๆโดยมนุษย์ ซึ่งจะเห็นได้ว่าการนำการเรียนรู้เชิงลึก (Deep Learning) มาใช้ตรวจสอบสัญญาณคอมพิวเตอร์วิชั่นที่เกิดจากความเสียหายหรือรอยบกพร่องภายในรางรถไฟสามารถลดจำนวนหัววัดสัญญาณคอมพิวเตอร์วิชั่นและสามารถแปรผลได้อัตโนมัติ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

บทที่ 2

ทฤษฎีที่เกี่ยวข้อง


ในบทนี้จะกล่าวถึงหลักการและทฤษฎีพื้นฐานที่ใช้แก้ปัญหาในงานวิจัยซึ่งประกอบหลักการทำงาน โดยประกอบด้วย ความรู้เบื้องต้นเกี่ยวกับราง การทดสอบเชิงกล การตรวจสอบแบบไม่ทำลาย การตรวจสอบด้วยวิธีการปลดปล่อยคลื่นเสียง (Acoustic Emission Testing), และโครงข่ายประสาทเทียม

2.1 ความรู้เบื้องต้นเกี่ยวกับรางรถไฟ

2.1.1 ราง

รูปแบบของรางรถไฟมีหน้าตัดคล้ายกับเหล็กรูปพรรณตัวไอ (I) ซึ่งเป็นรูปแบบที่ได้รับการยอมรับการใช้งานด้านเทคนิคและเป็นหน้าตัดรางที่ประหยัด (Economic) ให้ความแข็งแกร่ง (Stiffness) และมีความคงทนต่อการใช้งาน (Durability)

รูปร่าง (Profile) ของรางจะประกอบด้วยส่วนของหัวราง (Head), เอวราง (Web) และฐานราง (Foot) ดังแสดงในรูปที่ 2.1



รูปที่ 2.1 ส่วนประกอบราง [45]

2.1.2 ขนาดของราง

ขนาดรางที่ใช้งานจะกำหนดเป็นน้ำหนักของรางต่อความยาวราง เช่น น้ำหนักเป็นกิโลกรัมต่อเมตร หรือปอนด์ ต่อหลา เช่น รางขนาด 100 ปอนด์ หน้าตัดราง (Profile) ตามมาตรฐานอังกฤษ (BS) มีน้ำหนัก 100 ปอนด์ต่อหลา หรือรางขนาด 50 N เป็นรางหน้าตัดตามมาตรฐานญี่ปุ่น (JIS) มีน้ำหนัก 50 กิโลกรัมต่อเมตร เป็นต้น


ขนาดน้ำหนักของหน้าตัดรางที่แตกต่างกัน จะให้คุณสมบัติความแข็งแรงในการรับน้ำหนักได้ไม่เท่ากัน ดังนั้นจึง จำเป็นต้องออกแบบคานวณหาขนาดของรางที่เหมาะสมเพื่อนำมาใช้งานให้ได้ตามมาตรฐานที่กำหนด

การรถไฟแห่งประเทศไทย กำหนดขนาดรางใช้กับทางประธาน ให้รับน้ำหนักเพลลา 20 ตัน ความเร็ว 120 กิโลเมตรต่อชั่วโมง ใช้ขนาดราง 100 ปอนด์ หน้าตัดตามมาตรฐานอังกฤษ (BS) คุณสมบัติของเนื้อวัสดุรางตามมาตรฐาน UIC 860 Grade 900 A

2.1.3 มาตรฐานหน้าตัดราง


รูปร่างของหน้าตัดราง (Profile) จะแตกต่างกันตามมาตรฐานที่การรถไฟในแต่ละประเทศใช้งาน เช่น AREA, AREMA มาตรฐานของอเมริกา, BS มาตรฐานของอังกฤษ, EN มาตรฐานของยุโรป, GB, TB มาตรฐานของจีน, JIS มาตรฐานของญี่ปุ่น, RSR, SRT มาตรฐานของการรถไฟแห่งประเทศไทย, UIC มาตรฐานของ International Union of Railways

ปัจจุบันการรถไฟใช้รางหน้าตัดตามมาตรฐานของอังกฤษ (BS) เป็นหลักสำหรับรถไฟธรรมดา และใช้รางหน้าตัดตามมาตรฐาน UIC และ EN สำหรับรถไฟฟ้า ดังแสดงในรูปที่ 2.2 และ 2.3



รูปที่ 2.2 หน้าตัดราง BS 80 A [45]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.3 หน้าตัดราง 100 A [45]

2.1.4 การทดสอบคุณภาพของราง

ในการตรวจสอบคุณภาพของรางที่ผลิตผู้ซื้อจะแต่งตั้งวิศวกรตรวจ (Inspecting Engineer) เพื่อทำการตรวจสอบรางตามรายการจำเพาะทางเทคนิค (Technical Specification) โดยรายละเอียดของการตรวจสอบ ได้แก่

1. กระบวนการผลิตเหล็กกล้า (Steel Making Process)
2. การวิเคราะห์ส่วนผสมทางเคมี (Chemical Analysis)
3. การทดสอบเชิงกล (Mechanical Test) ประกอบด้วย
 - การทดสอบการรับน้ำหนักตกกระแทก (Falling Weight Test)
 - การทดสอบความต้านแรงดึง (Tensile Test)
 - การทดสอบความแข็งที่ผิวราง (Brinell Hardness Test)
 - การทดสอบด้วยตาเปล่า (Macroscopic Test)
4. การทดสอบน้ำหนัก ซึ่งทำโดยการชั่งน้ำหนักรางเพื่อหาน้ำหนักเฉลี่ยของราง ซึ่งถือว่าเป็นน้ำหนักจริง (Actual Weight)

นอกจากนี้ยังมีการตรวจสอบมิติ (Dimensional Inspection) ของรางตามมาตรฐานและแบบรูป ประกอบด้วยการวัดมิติต่างๆ ดังต่อไปนี้

1. ส่วนสูงของราง (Height of Rail)
2. ความกว้างของฐานราง (Width of Flange)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3. ความกว้างของหัวราง (Width of Head)
4. ความหนาของเอวราง (Thickness of Web)
5. ระยะระหว่างผิวสัมผัสเหล็กประกบราง (Distance between Fishing Surfaces)
6. ความลาดเอียงของผิวสัมผัสเหล็กประกบราง (Inclination of Fishing Surfaces)
7. การได้ฉากของส่วนสูง (Squareness of Height)
8. การได้ฉากของฐานราง (Squareness of Flange)
9. ความไม่สมมาตรของหน้าตัดราง (Asymmetry of Rail Section)
10. ความตรงที่ปลายราง (Straightness at Rail End)
11. ทวิสต์ที่ปลายฐานราง (Twist at Rail End)

2.1.5 การตรวจสอบองค์ประกอบทางเคมี

การวิเคราะห์ส่วนผสมทางเคมีของเหล็กกล้าจะกระทำก่อนรีดและหลังรีดเหล็ก เพื่อหาปริมาณของธาตุหลักอื่นประกอบด้วย คาร์บอน (C), แมงกานีส (Mn), ซิลิกอน (Si), ฟอสฟอรัส (P) และซัลเฟอร์หรือกำมะถัน (S)

การตรวจสอบก่อนรีดกระทำโดยการนำเหล็กเหลวจาก Ladle ไปแช่เย็นให้แข็งตัวแล้วตัดเป็นแผ่นตัวอย่างขนาดผิวหน้าด้านบนให้เรียบ นำไปเข้าเครื่อง Vacuum – Emission Spectrophotometric Analyzer เมื่อเดินเครื่องจะเกิด Electric Arc และเครื่องจะตรวจวัดปริมาณของธาตุและโลหะอื่นๆ ที่ผสมอยู่ในเหล็ก แล้วแสดงผลเป็นเปอร์เซ็นต์ทางจอภาพ (Monitor) ขณะเดียวกันก็มีการพิมพ์ผลออกมาทางเครื่องพิมพ์ (Printer) ดังแสดงในรูปที่ 2.4

การตรวจสอบหลังรีดก็เป็นไปในทางนองเดียวกัน คงต่างกันที่แผ่นตัวอย่างซึ่งได้จากการตัดชิ้นส่วนจากรางที่ผลิตเสร็จ

ส่วนผสมทางเคมีสำหรับราง Grade 900 A จะต้องอยู่ภายในพิสัยที่กำหนดตามมาตรฐาน UIC 860-0



รูปที่ 2.4 การวิเคราะห์ส่วนผสมทางเคมีด้วยระบบอัตโนมัติ [45]


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.1.6 การตรวจสอบปริมาณไฮโดรเจนตกค้าง

การตรวจสอบปริมาณไฮโดรเจนตกค้าง (Residual Hydrogen) กระทำทั้งก่อนรีดและหลังรีดเหล็ก การตรวจสอบก่อนรีดกระทำโดยใช้หลอดดูดเหล็กเหลวจาก Ladle นำไปแช่เย็นให้แข็งตัว แล้วตัดเป็นก้อนตัวอย่าง หนักประมาณ 2 กรัม นำไปเข้าเครื่อง Hydrogen Determinator พร้อมกับใส่ Electrode เมื่อปล่อยกระแสไฟฟ้าผ่านก้อนตัวอย่างจะเกิดความร้อนสูงจนกระทั่งก้อนตัวอย่างหลอมละลาย แก๊สไฮโดรเจนที่ตกค้างจะแยกตัวออกจากโลหะเหลวไปผ่านเครื่องตรวจนับปริมาณไฮโดรเจน (Hydrogen Counter) ปริมาณไฮโดรเจนที่ตกค้างจะปรากฏทางจอภาพ ขณะเดียวกันก็มีการพิมพ์ผลออกมาทางเครื่องพิมพ์ ดังแสดงในรูปที่ 2.5

การตรวจสอบหลังการรีดก็เป็นไปในทำนองเดียวกัน คงต่างกันที่ก้อนตัวอย่างซึ่งได้จากการตัดชิ้นส่วนจากราง

ปริมาณไฮโดรเจนตกค้างหลังรีดจะต้องไม่เกิน 1.5 ppm



รูปที่ 2.5 การตรวจสอบปริมาณไฮโดรเจนตกค้าง [45]


2.2 การทดสอบเชิงกล

2.2.1 การทดสอบความสามารถในการรับน้ำหนักตกกระทก

การทดสอบด้วยน้ำหนักตกกระทก (Falling Weight Test) กระทำโดยนำท่อนรางตัวอย่างความยาวไม่น้อยกว่า 1.3 เมตร วางตั้งบนที่รองรับ (Bearers) 2 จุด แต่ละจุดห่างกัน 1 เมตร แล้วปล่อยแท่งน้ำหนัก 1,000 กก. จากระดับความสูงประมาณ 7.6 ม. ตกลงไปกระทกตรงกลางท่อนราง ท่อนรางตัวอย่างจะต้องทนทานแรงตกกระทกดังกล่าวได้โดยไม่แตกหักหรือมีรอยร้าวเกิดขึ้น โดยเฉพาะบริเวณด้านล่างของฐานราง ดังแสดงในรูปที่ 2.6 วัดค่าแอ่นตัว (Deflection) ของรางไว้ ค่าแอ่นตัวควรอยู่ระหว่าง 40 – 50 มิลลิเมตร สำหรับราง Grade 900 A ดังแสดงในรูปที่ 2.7



รูปที่ 2.6 ชิ้นรางที่ผ่านการรับน้ำหนักตกกระแทก [45]



รูปที่ 2.7 ชิ้นรางที่ผ่านการรับน้ำหนักตกกระแทกและวัดค่าแอนตัว [45]

2.2.2 การทดสอบความต้านทานแรงดึง

การทดสอบความต้านทานแรงดึง (Tensile Test) ดังแสดงในรูปที่ 2.8 กระทำโดยนำแท่งตัวอย่างกลมขนาดเส้นผ่านศูนย์กลาง 10 มิลลิเมตร ความยาว (Gauge Length) 50 มิลลิเมตร ที่ตัดมาจากรางไปเข้าเครื่องดึง ดึงจนกระทั่งขาดออกจากกัน บันทึกค่าแรงดึงสูงสุดและความยาวของแท่งตัวอย่างที่เปลี่ยนแปลงไว้เพื่อนำไปคำนวณหาความต้านทานแรงดึงสูงสุด (Ultimate Tensile Strength) และการยืดตัว ณ จุดขาด (Elongation at Break) ซึ่งค่าที่คำนวณได้สำหรับราง Grade 900 A จะต้องไม่น้อยกว่า 90 กิโลกรัม ต่อ ตารางมิลลิเมตร และ 10% ตามลำดับดังแสดงในรูปที่ 2.9




รูปที่ 2.8 การทดสอบความต้านทานแรงดึง [45]



รูปที่ 2.9 การทดสอบความต้านทานแรงดึงจนกระทั่งขาดออกจากกัน [45]

2.2.3 การทดสอบความแข็งที่ผิววราง

การทดสอบความแข็งแบบโบรเนลล์ที่ผิววราง (Brinell Hardness Test) กระทำโดยนำแผ่นตัวอย่างหน้าตัดตรงสำหรับการทดสอบไปขัดผิวด้านบนให้เรียบและสะอาดแล้วนำไปปรับการกดด้วยเครื่องกดที่มีหัวกดขนาดเส้นผ่านศูนย์กลาง 10 มิลลิเมตร น้ำหนักกด 3,000 กิโลกรัม โดยค้ำน้ำหนักไว้นาน 15 นาที แล้วหาค่า Brinell Hardness Number (BHN) โดยการเปรียบเทียบขนาดของหลุมบนแผ่นตัวอย่างกับขนาดของหลุมบนแผ่นมาตรฐานที่ทราบค่า BHN แล้ว ค่า BHN ที่ได้ควรอยู่ระหว่าง 270 – 290 สำหรับราง Grade 900 A ดังแสดงในรูปที่ 2.10



รูปที่ 2.10 การทดสอบความแข็งแบบไฮรเนลที่ผิวราง [45]

2.2.4 การทดสอบด้วยตาเปล่า

การทดสอบด้วยตาเปล่า (Macroscopic Test) กระทำโดยนำแผ่นตัวอย่างหน้าตัดตรงสำหรับการทดสอบไปขัดผิวด้านบนให้เรียบและสะอาด ตรวจสอบรอยแยก (Shrinkage Cavity) ด้วยตาเปล่า แผ่นหน้าตัดตรงจะต้องปราศจากรอยแยกจึงจะใช้เป็นตัวอย่างในการทดสอบได้ นำกระดาษถ่ายรูป (Photographic Paper) ขนาดโตกว่าขนาดหน้าตัดตรงเล็กน้อยที่แช่ไว้ในกรดกำมะถันเจือจาง (5% Sulphuric Acid Solution) มาเช็ดน้ำกรดออก ทาบกระดาษลงไปบนผิวหน้าตัดตรงที่เตรียมไว้แล้วชุบรีดไปมาให้ทั่วหน้าตัดตรงเป็นเวลาประมาณ 3 นาที จึงดึงกระดาษออกจากหน้าตัดตรง นำไปแช่ในน้ำยา 15 – 40% Aqueous Solution ประมาณ 10 นาที แล้วจึงนำกระดาษไปล้างน้ำก่อนนำเข้าเครื่องอบกระดาษให้แห้ง เมื่อกระดาษแห้งก็จะปรากฏรูปหน้าตัดตรง (Baumann Sulfur Print) ขึ้น

วัตถุประสงค์ของ Macroscopic Test ก็เพื่อตรวจสอบคุณภาพของเหล็กด้วยการดูเนื้อเหล็ก ถ้าการกระจายของ Sulfide บนเนื้อเหล็กตามที่ปรากฏในรูปเป็นไปอย่างสม่ำเสมอ กล่าวคือ ความเข้มของสี (ขาว – ดำ) ในรูปกลมกลืนกัน ย่อมแสดงถึงเหล็กที่มีคุณภาพ ส่วนคุณภาพจะดีมาน้อยเพียงใดสามารถจําแนกได้โดยการนารูปที่ได้ไปเปรียบเทียบกับรูปมาตรฐาน ดังแสดงในรูปที่ 2.11



รูปที่ 2.11 Baumann Sulfur Print [45]

2.2.5 การตรวจสอบมิติและลักษณะทั่วไป

การตรวจสอบมิติและลักษณะทั่วไป ประกอบด้วย การตรวจสอบขนาด (Dimension) รูปร่าง (Shape) และสภาพผิว (Surface Condition) ดังนี้

1. ตรวจสอบความยาวของราง

ตรวจโดยการวัดด้วยเทปเหล็ก การวัดควรวัดที่เอวราง ความยาวรางที่วัดได้ต้องอยู่ในพิสัย ± 6 มิลลิเมตร สำหรับรางความยาวมาตรฐาน 24 เมตร หรือต่ำกว่า และ ± 10 มิลลิเมตร สำหรับรางความยาวมาตรฐาน 25 – 36 เมตร

2. ตรวจสอบความชำรุดที่ผิวราง (Surface Defects)

ตรวจด้วยตาเปล่าโดยเดินตรวจตลอดความยาวราง และสังเกตทั้งที่สันราง ฐานราง และเอวรางทั้งสองด้าน การตรวจให้ตรวจที่สันรางก่อนแล้วพลิกราง เพื่อตรวจฐานราง และเอวรางด้านหนึ่งไปพร้อมกัน หลังจากนั้นจึงพลิกรางเพื่อตรวจเอวรางอีกด้านหนึ่ง ผิวรางต้องเรียบร้อย ไม่มีแผลหรือรอยชำรุดใดๆ ปรากฏให้เห็น

3. ตรวจสอบความตรงของรางทั้งท่อน

ตรวจโดยเล็งดูด้วยตา แนวรางต้องตรงตลอดท่อน ไม่มีส่วนใดคดโค้ง

4. ตรวจสอบความตรงที่ปลายราง

ตรวจโดยใช้บรรทัดเหล็ก (Straight – Edge) ยาว 1.5 เมตร ทาบที่ด้านข้างของหัวรางทั้งสองด้านเพื่อวัดความตรงในแนวนอน และทาบไปบนสันรางเพื่อวัดความตรงในแนวตั้ง ถ้ารางตรงได้ที่ยอมไม่ปรากฏช่องว่างระหว่างรางกับบรรทัดเหล็กตลอดความยาวของบรรทัดเหล็ก หากปรากฏช่องว่าง ณ ส่วนใด ให้ใช้ Feeler Gauge หรือ Taper Gauge วัดขนาดของช่องว่าง ค่าที่วัดได้ต้องไม่เกิน 0.7 มิลลิเมตร

5. ตรวจสอบทวิสต์ที่ปลายฐานราง

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ตรวจโดยใช้เครื่องมือ ซึ่งมีลักษณะเป็นแผ่นอะลูมิเนียม (หนา 12 มิลลิเมตร กว้าง 173 มิลลิเมตร ยาว 1.07 เมตร) เจาะรูตรงกลาง และมีขาเป็นปุ่มแหลม 4 ขา ตั้งอยู่บริเวณปลายแผ่น ปลายละคู่ห่างกัน 1 เมตร หนึ่งในสี่ขานั้นสามารถขยับขึ้นลงได้ และเชื่อมต่อกับ Dial Gauge ส่วนอีก 3 ขาดัดตาย การวัดกระทำโดยวางฐานรางขึ้น วางเครื่องมือลงบนฐานราง ขยับขาที่ติด Dial Gauge ให้แตะฐานราง แล้วอ่านค่าจาก Dial Gauge ค่าที่อ่านได้ต้องไม่เกิน 0.4 มิลลิเมตร ปัจจุบันมีเครื่องมือ วัดแบบดิจิตอลที่สามารถอ่านค่าวิสต์จากการวัดได้ทันที

6. ตรวจสอบความสูงของราง

ตรวจโดยใช้เครื่องมือแบบ GO/NO GO ซึ่งจัดทำภายใต้ค่าความคลาดเคลื่อน ± 0.5 มิลลิเมตร ดังแสดงในรูปที่ 2.12 (ก)

7. ตรวจสอบความกว้างของฐานราง

ตรวจโดยใช้เครื่องมือแบบ GO/NO GO ซึ่งจัดทำภายใต้ค่าความคลาดเคลื่อน ± 1.0 มิลลิเมตร ดังแสดงในรูปที่ 2.12 (ข)

8. ตรวจสอบความกว้างของหัวราง

ตรวจโดยใช้เครื่องมือแบบ GO/NO GO ซึ่งจัดทำภายใต้ค่าความคลาดเคลื่อน ± 0.5 มิลลิเมตร ดังแสดงในรูปที่ 2.13 (ก)

9. ตรวจสอบความหนาของเอวราง

ตรวจโดยใช้เครื่องมือแบบ GO/NO GO ซึ่งจัดทำภายใต้ค่าความคลาดเคลื่อน $+1.0$ กับ -0.5 มิลลิเมตร ดังแสดงในรูปที่ 2.13 (ข)

10. ตรวจสอบระยะระหว่างผิวสัมผัสหลักประกัราง

ตรวจระยะระหว่างผิวสัมผัสหลักประกัรางทั้งด้านซ้ายและด้านขวาของเอวรางโดยใช้ Gauge A และ Gauge B ซึ่งจัดทำภายใต้ค่าความคลาดเคลื่อน ± 0.5 มิลลิเมตร การตรวจสอบกระทำโดยสอดเครื่องมือเข้าที่เอวรางโดยให้เครื่องมือตั้งฉากกับแนวราง ดังแสดงในรูปที่ 2.14 (ก)

11. ตรวจสอบความลาดเอียงของผิวสัมผัสหลักประกัราง

ตรวจสอบความลาดเอียงของผิวสัมผัสหลักประกัรางทั้งด้านซ้ายและด้านขวาของเอวราง โดยใช้เครื่องมืออันเดียวกับ Gauge A ดังกล่าวข้างต้น การตรวจสอบกระทำโดยสอดเครื่องมือเข้าที่เอวราง โดยให้เครื่องมือตั้งฉากกับแนวราง แล้วใช้ Feeler Gauge หรือ Taper Gauge วัดขนาดของช่องว่าง (ถ้ามี) บริเวณผิวสัมผัสหลักประกัรางทั้งที่คางรางและฐานราง ค่าที่วัดได้ต้องไม่เกิน 0.5 มิลลิเมตร

12. ตรวจสอบการได้ฉากของส่วนสูงของราง

ตรวจโดยใช้เหล็กฉาก ด้วยการวางขาข้างหนึ่งของเหล็กฉากบนหน้าตัดราง ส่วนขาอีกข้างหนึ่งทาไปบนสันรางหรือด้านล่างของฐานรางโดยขนานกับแนวราง ถ้าส่วนสูงของรางไม่ได้ฉากยอมเกิดช่องว่างระหว่างเหล็กฉากกับหน้าตัดราง วัดขนาดช่องว่างดังกล่าวด้วย Feeler Gauge หรือ Taper Gauge ค่าที่วัดได้ต้องไม่เกิน 0.6 มิลลิเมตร

13. ตรวจสอบการได้ฉากของฐานราง

ตรวจโดยใช้เหล็กฉาก ด้วยการวางขาข้างหนึ่งของเหล็กฉากทาบไปบนหน้าตัดของฐานราง ส่วนขาอีกข้างหนึ่งทาบไปตามแนวด้านข้างของฐานราง ถ้าฐานรางไม่ได้ฉากยอมเกิดช่องว่างระหว่างเหล็กฉากกับหน้าตัดของฐานราง วัดขนาดช่องว่างดังกล่าวด้วย Feeler Gauge หรือ Taper Gauge ค่าที่วัดได้ต้องไม่เกิน 0.6 มิลลิเมตร

14. ตรวจสอบความไม่สมมาตรของหน้าตัดราง

ตรวจสอบความไม่สมมาตรของหน้าตัดรางทั้งด้านซ้ายและด้านขวาของเอวราง โดยใช้เครื่องมือ ทั้ง Plus Gauge และ Minus Gauge ซึ่งจัดทำภายใต้ค่าความคลาดเคลื่อน ± 1.2 มิลลิเมตร ดังแสดง ในรูปที่ 2.14 (ข)

กรณีตรวจสอบด้วย Plus Gauge เมื่อจะงอส่วนบนของเครื่องมือแต่ละด้านข้างของหัวราง ต้องปรากฏช่องว่างในแนวนอนที่ฐานรางระหว่างเครื่องมือกับด้านข้างของฐานรางหรืออย่างน้อย เครื่องมือต้องสัมผัสราง 2 จุด คือ ทั้งที่หัวรางและฐานราง

กรณีตรวจสอบด้วย Minus Gauge เมื่อเครื่องมือแต่ละด้านข้างของฐานรางต้องปรากฏ ช่องว่างในแนวนอนที่หัวรางระหว่างจะงอส่วนบนของเครื่องมือกับด้านข้างของหัวรางหรืออย่างน้อย เครื่องมือต้องสัมผัสราง 2 จุด คือทั้งที่ฐานรางและหัวราง




(ก)



(ข)

รูปที่ 2.12 ตรวจสอบความ (ก) สูงของรางและ (ข) ความกว้างที่ฐานราง [45]



(ก)



(ข)

รูปที่ 2.13 ตรวจสอบ (ก) ความกว้างของหัวราง (ข) ความหนาของเอวราง [45]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



(ก)



(ข)

รูปที่ 2.14 ตรวจสอบระยะระหว่างผิวสัมผัสเหล็ก (ก) ปรึกษาราง (ข) ความไม่สมมาตรของหน้าตัด
ราง [45]

2.2.6 การตรวจสอบน้ำหนัก

การชั่งน้ำหนักเพื่อหาน้ำหนักที่แท้จริงของราง กระทำโดยสุ่มตัวอย่างรางที่ผ่านการตรวจสอบและการทดสอบตามที่กำหนดแล้ว วัดความยาวรางแต่ละท่อนก่อนนำไปชั่งน้ำหนัก โดยแยกเป็นแต่ละ Charge Number ไม่ปะปนกัน รวมความยาวและน้ำหนักของรางทั้งหมด แล้วหาค่าเฉลี่ยเป็นกิโลกรัมต่อเมตร ซึ่งจะถือเป็นน้ำหนักแท้จริงของราง (Actual Weight) น้ำหนักแท้จริงของรางนี้ยอมให้แตกต่างจากน้ำหนักมาตรฐาน (Calculated Weight) ได้ภายในพิกัด -0.5 กับ $+2.0\%$ เช่น ราง BS 100 A มีน้ำหนักมาตรฐาน (Theoretical Weight) เท่ากับ 50.182 กิโลกรัม ต่อเมตร น้ำหนักแท้จริงควรมีค่าตั้งแต่ 49.9311 ถึง 51.1856 กิโลกรัมต่อเมตร ดังแสดงในรูปที่ 2.15



รูปที่ 2.15 การนำหน้าหนักแท้จริงของรางโดยการชั่งน้ำหนักขึ้นราง [45]

รางที่เย็นแล้วจะถูกนำเข้าสู่เครื่องตัด (Roller Straightener) รางที่ตัดแล้วจะต้องผ่านการตรวจเบื้องต้น (Preliminary Inspection) ซึ่งเป็นการตรวจสอบด้วยตาเปล่า เพื่อตรวจสอบ ความเรียบร้อยของผิวราง ความคดโค้ง (Sweep) ความโก่งงอ (Camber) การบิดตัว (Twist) และความราบเรียบ (Flatness) ได้ฐานราง หลังจากตรวจเบื้องต้นเรียบร้อย จะถูกนำไปตรวจสอบแบบ ไม่ทำลาย (On-line Inspection, Non-destructive Test – NDT) การตรวจสอบข้อบกพร่องบริเวณผิวส่วนบนของรางด้วยไฟฟ้า (Eddy Current) และรางทุกท่อนจะต้องผ่านการตรวจสอบความชำรุดภายในด้วยคลื่นเสียงความถี่สูง (Ultrasonic)

2.3 การเกิดรอยบกพร่องในรางรถไฟ

การชำรุดของรางรถไฟเกิดขึ้นได้จากหลายสาเหตุเช่น ขบวนการผลิตราง ได้แก่ เกิดการผิดพลาดในการผลิตราง เช่น เทคนิคของส่วนผสมทางเคมีของเนื้อราง หรืออาจมีสิ่งเจือปนและตำหนิ (Defects) อยู่ในเนื้อรางหรือเกิดขึ้นจากการใช้งาน ทำให้เกิดรางหัก/ร้าว หัวต่อแบนตกตาย เกิดจาก แผลล้อรถจักรดีเซล สันรางเป็นคลื่น สันรางสึก/แบน ซึ่งเกิดในทางโค้งและการรับน้ำหนักผ่านทาง สะสมเกินมาก การเกิดรอยบกพร่องในรางรถไฟที่เกิดจากการรับน้ำหนักและล้อของรถไฟวิ่งผ่านใน ขณะที่มีการใช้งานนั้น ลักษณะการเกิดปัญหาแบบความเหนื่อยล้า (Fatigue) โดยปัญหาการเกิดรอย บกพร่องที่เกิดขึ้นและพบได้บ่อยมักจะเกิดรอยบกพร่องที่บริเวณพื้นผิวของรางรถไฟที่สัมผัสกับล้อ รถไฟในขณะใช้งานซึ่งลักษณะความเสียหายที่เกิดขึ้นและพบได้บ่อยในประเทศไทยได้แก่ การแตก เป็นเส้นที่หัวราง (Head Checking with Spalling), ล้อดีน (Wheel Bums), เนื้อหลุ่ร้อนและแตก เป็นเส้นที่หัวราง (Flaking with Head Checking), การเสียรูปของราง (Rail plastic flow), สันราง เป็นคลื่น (Corrugation) ดังแสดงในรูปที่ 2.16 (ก) นอกจากนี้รอยบกพร่องของรางรถไฟอาจเกิดขึ้น ภายในตำแหน่งต่างๆ ของรางรถไฟได้แก่ หัวราง (Rail head), เหวราง (Rail web) และฐานราง (Rail foot) ได้เช่นกัน ดังแสดงในรูปที่ 2.16 (ข)

ลักษณะความชำรุดของรางที่พบได้บ่อย (Rail Surface Defects)



การแตกเป็นเส้นที่หัวราง
(Head Checking with Spalling)



ล้อดับ
(Wheel Burns)



เนื้อหลุดร่อนและแตกเป็นเส้นที่หัวราง
(Flaking with Head Checking)



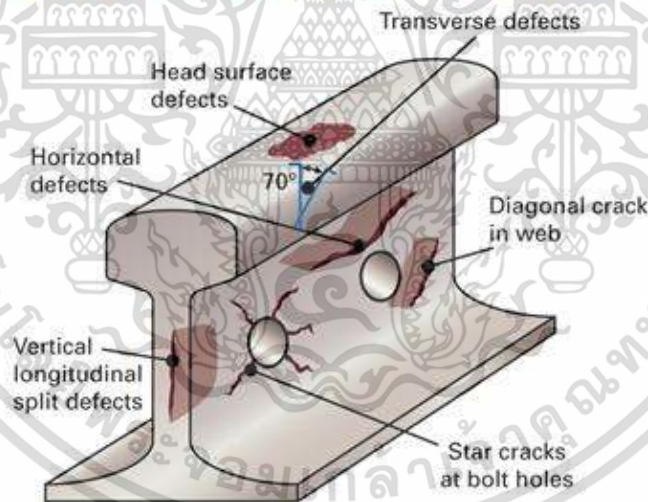
การเสียรูปของราง
(Rail plastic flow)



สันรางเป็นคลื่น
(Corrugation)

(ก)

NATURE OF DEFECTS BASED ON LOCATION



(ข)

รูปที่ 2.16 ลักษณะความชำรุดของราง (ก) Rail Surface Defect (ข) Rail Subsurface Defect

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4 การตรวจสอบแบบไม่ทำลาย

การตรวจสอบอย่างเป็นระบบสำหรับข้อบกพร่องที่ผิวและภายใน ทั้งนี้เทคโนโลยีที่ใช้ในการตรวจสอบเป็นแบบไม่ทำลายตัวอย่าง เช่น อัลตราโซนิก (Ultrasonics) การเหนี่ยวนำแม่เหล็ก (Magnetic induction) กระแสไหลวน (Eddy Current) การใช้กล้องถ่ายภาพ (Visual Inspection) หรือ การถ่ายภาพรังสี (Radiography) โดยแต่ละวิธีมีหลักการดังนี้

2.4.1 การตรวจสอบด้วยวิธีอัลตราโซนิก

การใช้คลื่นอัลตราโซนิก สามารถใช้ตรวจวัดได้กับเครื่องมือหลายประเภท ตั้งแต่แบบควบคุมด้วยมือจนถึงยานพาหนะความเร็วสูงที่ติดตั้งหัววัด โดยใช้หลักการการส่งคลื่นเสียงความถี่สูงบริเวณรถไฟ และค้นหาการย้อนกลับของคลื่นเสียงความถี่สูงและสะท้อนกลับโดยใช้ หัววัดจับความสูงของคลื่นใดๆ ที่หักเหพร้อมกับเวลาที่เกิดขึ้น สามารถบอกเกี่ยวกับความแข็งแรงของรางรถไฟ เนื่องจาก ไม่สามารถทำนายข้อบกพร่องได้ทั้งหมดจึงต้องมีการส่งพลังงานคลื่นอัลตราโซนิกที่มุมเอียงต่างๆ เพื่อให้ครอบคลุมบริเวณที่มีข้อบกพร่อง ดังแสดงในรูปที่ 2.17



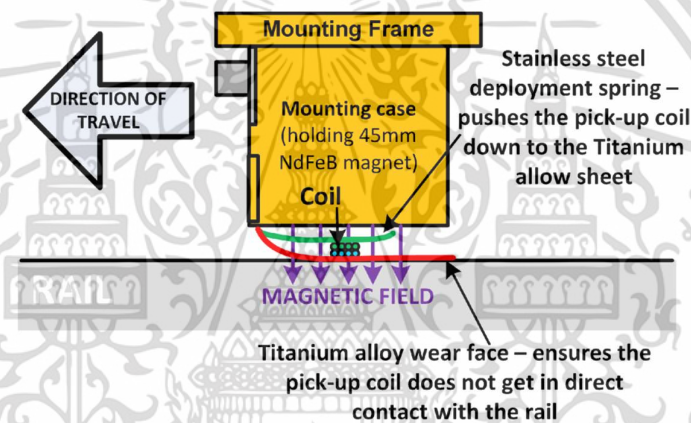
รูปที่ 2.17 เครื่องอัลตราโซนิกสำหรับงานตรวจสอบรางรถไฟ

2.4.2 การตรวจสอบด้วยวิธีเหนี่ยวนำแม่เหล็ก

การใช้การเหนี่ยวนำแม่เหล็กนี้ถูกนำมาใช้อย่างกว้างขวาง สำหรับการประเมินแบบไม่ทำลาย ส่วนประกอบ โครงสร้างเหล็กที่เป็นแม่เหล็กโดยเฉพาะอุตสาหกรรมปิโตรเคมี รางรถไฟ พลังงาน และ โลหะ หลักการคือใช้การเหนี่ยวนำแม่เหล็กโดยหัวตรวจจับการรั่วไหลฟลักซ์แม่เหล็กถูกต้องเข้ากับแม่เหล็กถาวรหรือแม่เหล็กไฟฟ้ากระแสตรง เพื่อทำให้เกิดสนามแม่เหล็กกำลังสูงในการทำให้ขึ้นทดสอบเป็นแม่เหล็ก เส้นฟลักซ์ แม่เหล็กจะเชื่อมติดกับขึ้นทดสอบ และหัวตรวจจับถูกจัดวางที่ระยะ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

คงที่จากรางรถไฟเพื่อตรวจสอบการเปลี่ยนแปลงใดๆ ในสนามแม่เหล็กในบริเวณข้อบกพร่องแนวขวางที่ผิวหรือใกล้ผิว ที่ปรากฏในรางรถไฟ การตรวจสอบรางรถไฟโดยการใช้การเหนี่ยวนำแม่เหล็กนิยมใช้ในการตรวจสอบข้อบกพร่องใกล้ผิวหรือในแนวขวางใกล้ผิว เช่น รอยแตกจากความล้า แต่มีข้อจำกัดในการตรวจสอบรอยแยกในแนวขวางเพราะวาร์รอยแยกแตกยาวขนานกับเส้นฟลักซ์แม่เหล็กทำให้เกิดการรั่วของฟลักซ์แม่เหล็ก ที่ไม่เพียงพอนอกจากนั้นวิธีการเหนี่ยวนำแม่เหล็กได้รับผลกระทบจากความเร็วการตรวจสอบที่เพิ่มขึ้น เนื่องจากความเร็ว การตรวจสอบที่เพิ่มขึ้นทำให้ความหนาแน่นฟลักซ์แม่เหล็กลดลง สัญญาณจึงอ่อนลงมากสำหรับการตรวจสอบข้อบกพร่องที่ ความเร็วเกิน 35 กิโลเมตรต่อชั่วโมง หากมีการรวมเข้าของหัววัด Hall เข้ากับวิธีการเหนี่ยวนำแม่เหล็ก จะสามารถปรับปรุงสมรรถภาพของวิธีการเหนี่ยวนำแม่เหล็กในการตรวจสอบข้อบกพร่องที่ความเร็วสูงขึ้น ดังแสดงในรูปที่ 2.18



รูปที่ 2.18 เครื่องตรวจสอบด้วยวิธีเหนี่ยวนำแม่เหล็กสำหรับงานตรวจสอบรางรถไฟ

2.4.3 การตรวจสอบด้วยวิธีกระแสไหลวน

การใช้กระแสไหลวน วิธีนี้จะให้กระแสไฟฟ้าแบบสลับป้อนเข้าสู่ขดลวดกระตุ้น ทำให้เกิดสนามแม่เหล็กใกล้กับผิว ของหัวรางรถไฟ การเปลี่ยนแปลงในสนามแม่เหล็กจะทำให้ กระแสไหลวน ถูกชักนำสู่ภายใต้ผิวของหัวรางรถไฟ การเปลี่ยนแปลง ในสนามแม่เหล็กทุกขุมที่ถูกทำให้เกิดขึ้นโดยกระแสไหลวน จะถูกตรวจจับโดยขดลวดตรวจจับในรูปของแรงดันไฟฟ้าที่ถูกเหนี่ยวนำ ถ้าพื้นที่ที่ตรวจสอบปราศจากข้อบกพร่องผลคือ ความต้านทานกระแสไฟฟ้ายังคงที่ไม่เปลี่ยนแปลง หากพบข้อบกพร่องที่ผิวหรือใกล้ผิวปรากฏในหัวรางรถไฟ กระแสไหลวน จะถูกรบกวน เป็นสาเหตุในการผันแปรของสนามแม่เหล็กทุกขุมทำให้เกิดการเปลี่ยนแปลงในความต้านทานกระแสไฟฟ้า ทำให้ผู้ตรวจสอบมองหาการเปลี่ยนแปลงใดๆ ในสัญญาณความต้านทานกระแสไฟฟ้า การตรวจสอบด้วยกระแสไหลวนนิยมใช้กับการตรวจสอบความล้า การไหม้ของล้อรถไฟ รอยจากการเสียดสี และรอยย่นที่

เป็นคลื่น อย่างไรก็ตามหัวตรวจจับกระแสไหลวนไวต่อ การเปลี่ยนแปลงการยกตัวด้วยเหตุผลนี้ควรวางหัวตรวจจับที่ ระยะคงที่ไม่เกิน 2 มิลลิเมตรห่างจากผิวของหัวรางรถไฟ ดังแสดงในรูปที่ 2.19



รูปที่ 2.19 เครื่องตรวจสอบด้วยวิธีกระแสไหลวนสำหรับงานตรวจสอบรางรถไฟ

2.4.4 การตรวจสอบด้วยวิธีกล้องถ่ายภาพ

การใช้กล้องถ่ายภาพ โดยอาศัยหลักการการใช้กล้องถ่ายภาพความเร็วสูง ที่สามารถจับภาพวิดีโอทางรถไฟเมื่อรถไฟเคลื่อนที่ผ่าน ภาพถ่ายที่จับได้จะถูกวิเคราะห์โดยซอฟต์แวร์ คอมพิวเตอร์การจำแนกวัตถุโดยใช้ซอฟต์แวร์จะเกี่ยวข้องกับ ความสามารถในการประมวลผล เวลาการประมวลผลเพื่อแบ่งประเภทรูปแบบภาพให้เล็กเพื่อจะตรวจสอบวัตถุขนาดเล็กได้ เช่น ข้อบกพร่องบนผิวของทางรถไฟ ดังนั้นความละเอียดของภาพวิดีโอที่ถ่ายจะต้องสูงขึ้น การตรวจสอบรางรถไฟโดยการใช้กล้องถ่ายภาพสามารถใช้วัดรูปร่างภายนอกหัวรางรถไฟ ร้อยละการสึกหรอ ระยะห่างรางรถไฟ การเคลื่อนที่ของหมอนรถไฟ การหายของ เศษหินและกรวดที่โรยทางรถไฟ การหายของน็อต และความเสียหายที่ผิวซึ่งรวมถึงความล้าและการเป็นคลื่น ความเร็วในการตรวจสอบสามารถเปลี่ยนแปลงได้จาก 1 ถึง 320 กิโลเมตรต่อชั่วโมง ขึ้นอยู่กับประเภทของการตรวจสอบและคุณภาพความละเอียดที่ต้องการเช่น การตรวจสอบการเป็นคลื่นสามารถทำได้เร็วกว่าการตรวจสอบรอยแตกจากความล้า แต่ทว่าการตรวจสอบรางรถไฟโดยการใช้กล้องถ่ายภาพไม่สามารถให้ข้อมูลเกี่ยวกับการปรากฏของข้อบกพร่องภายใน ดังแสดงในรูปที่ 2.20



รูปที่ 2.20 กล้องถ่ายภาพสำหรับงานตรวจสอบรางรถไฟ

2.4.5 การตรวจสอบด้วยวิธีถ่ายภาพรังสี

การใช้การถ่ายภาพรังสีโดยการฉายรังสีเอ็กซ์หรือแกมมา ถ่ายลงฟิล์มเพื่อให้ได้การถ่ายภาพรังสีของพื้นที่การตรวจสอบ การตรวจสอบแบบถ่ายภาพรังสีสามารถให้ข้อมูลเกี่ยวกับ ตำแหน่ง ขนาด และลักษณะของข้อบกพร่องภายใน และการหักเหของรังสีสามารถใช้ตรวจสอบความเค้นหลงเหลือ ใกล้กับผิว ของหัวรางรถไฟได้นอกจากนั้นการถ่ายภาพรังสีสามารถใช้เป็นเครื่องมือการตรวจสอบความถูกต้องของข้อบกพร่องที่ได้ตรวจ สอบแล้วโดยวิธีการตรวจสอบแบบไม่ทำลายอื่น ข้อจำกัดของวิธีนี้คือมีประสิทธิภาพต่ำในการตรวจสอบข้อบกพร่องในแนวขวาง และในเรื่องของความปลอดภัยและสุขภาพ ดังแสดงในรูปที่ 2.21



รูปที่ 2.21 เครื่องถ่ายภาพรังสีสำหรับงานตรวจสอบรางรถไฟ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ในปัจจุบันระบบรางรถไฟในประเทศไทยกำลังพัฒนาอย่างต่อเนื่องเพื่อรองรับการพัฒนาของประเทศ หมายความว่าระบบรางรถไฟจะเข้ามามีบทบาทที่สำคัญมากขึ้น เพื่อความน่าเชื่อถือของระบบรางรถไฟในการให้บริการการตรวจสอบและควบคุมคุณภาพระบบรางรถไฟจึงมีความสำคัญมาก โดยนำรถตรวจรางร้าวด้วยระบบตรวจจับข้อบกพร่องของรถตรวจสอบรางอัลตราโซนิคจะตรวจจับข้อบกพร่องของรางภายในขณะที่รถวิ่งไปตามรางด้วยความเร็วสูงได้ (40 กม. / ชม.) และด้วยตัวเลือกระบบการวัดระยะทางสามารถตรวจจับตำแหน่งตำแหน่งได้อย่างแม่นยำนอกเหนือจากการตรวจจับข้อบกพร่องตัวเลือกระบบเพิ่มเติมยังรวมถึงการวัดการสึกหรอตามส่วนโดยใช้เทคโนโลยีการประมวลผลภาพใหม่ล่าสุดและการวัดโดยใช้เลเซอร์ รถตรวจสอบรางอัลตราโซนิคได้นำมาใช้บริษัทการรถไฟของญี่ปุ่นรวมถึงชินคันเซ็นและบริษัทรถไฟเอกชนรายใหญ่ทุกแห่งรวมถึงประเทศไทยที่เริ่มนำมาใช้ในปี 2561 ดังแสดงในรูปที่ 2.22




รูปที่ 2.22 รถตรวจรางร้าว การรถไฟแห่งประเทศไทย

2.5 การทดสอบโดยวิธีอคูสติกอิมิตชัน

การทดสอบโดยวิธีอคูสติกอิมิตชัน หรือเรียกอีกอย่างหนึ่งว่าวิธีรับคลื่นเสียง เป็นวิธีหนึ่งในการทดสอบหรือประเมินสภาพของวัสดุแบบไม่ทำลาย การทดสอบด้วยวิธีนี้แตกต่างจากการทดสอบโดยไม่ทำลายวิธีดั้งเดิมอื่นๆ ซึ่งเป็นที่นิยมใช้กันอยู่ในปัจจุบันได้แก่ วิธีการถ่ายภาพด้วยรังสี วิธีอนุภาคแม่เหล็ก วิธีกระแสไหลวน และวิธีสารแทรกซึม เนื่องจากการทดสอบด้วยวิธีดั้งเดิมเหล่านี้เป็นการทดสอบหลังจากที่มีรอยความไม่ต่อเนื่องเกิดขึ้นในเนื้อวัสดุแล้ว ส่วนการทดสอบด้วยวิธีอคูสติกอิมิตชัน สามารถทดสอบพบรอยความไม่ต่อเนื่องในขณะที่กำลังเกิดหรือกำลังขยายตัว ได้ทั้งในระดับอนุภาค (Micro structure) และระดับมหภาค (Macro structure) โดยรอยความไม่ต่อเนื่องจะเป็นแหล่งปลดปล่อยพลังงานออกมาในรูปของคลื่นเสียง ดังนั้นข้อได้เปรียบของการทดสอบด้วยวิธี

นี้เมื่อเทียบกับวิธีอื่น คือเป็นการทดสอบแบบเวลาจริง (real time) สามารถใช้เฝ้าระวังเตือนภัยล่วงหน้าก่อนที่ความเสียหายจะลุกลาม ดังแสดงในรูปที่ 2.23



รูปที่ 2.23 การทดสอบโดยวิธีอคูสติกอิมิสชัน

2.5.1 ข้อได้เปรียบของการทดสอบ

1. ทดสอบได้ในขณะที่รอยความไม่ต่อเนื่องกำลังเกิด และ หรือ กำลังขยายตัว สามารถใช้เป็นวิธีเฝ้าระวังได้
2. ครอบคลุมพื้นที่ในการทดสอบเป็นบริเวณกว้างในการทดสอบเพียงคราวเดียว
3. มีความต้องการ การเข้าถึงชิ้นงานเพื่อการทดสอบน้อยกว่าการทดสอบวิธีอื่น
4. ทดสอบได้โดยไม่ต้องหยุดกระบวนการผลิต หรือการทำงานของอุปกรณ์


2.5.2 ข้อเสียเปรียบของการทดสอบ

1. สัญญาณรบกวนของสภาวะแวดล้อม และอุปกรณ์การทำงาน ถ้ามีความถี่ของคลื่นเสียงอยู่ในย่านเดียวกันกับคลื่นเสียงที่ปลดปล่อยจากรอยความไม่ต่อเนื่อง อาจทำให้การทดสอบทำได้ยากหรือทำไม่ได้ ถ้าไม่สามารถกำจัดสัญญาณรบกวนออกได้
2. เมื่อความเสียหายนั้นเกิดขึ้นและผ่านไปแล้ว ไม่สามารถทำการทดสอบซ้ำได้อีก ข้อมูลที่ตรวจจับได้ใหม่จะเป็นข้อมูลของรอยความไม่ต่อเนื่องครั้งใหม่ หรือของความเสียหายเก่าที่กำลังขยายตัว

2.6 ทฤษฎีการทดสอบด้วยอคูสติกอิมิชชัน

อคูสติกอิมิชชัน ใช้หลักการตรวจจับพลังงานซึ่งอยู่ในรูปของคลื่นยืดหยุ่นแบบชั่วคราว (Transient elastic wave) ที่ปลดปล่อยจากรอยความไม่ต่อเนื่องของวัสดุ การตรวจจับคลื่นยืดหยุ่นสามารถทำได้โดยใช้หัววัด (Sensor) ยึดติดที่ผิวหน้าของวัสดุ หัววัดจะทำหน้าที่เปลี่ยนพลังงานในรูปของคลื่นเสียง

ให้เป็นคลื่นไฟฟ้า และสัญญาณคลื่นไฟฟ้าจะถูกขยายสัญญาณด้วยอุปกรณ์ขยายสัญญาณเบื้องต้น (Pre-amplifier) และส่งผ่านไปยังตัวกรองความถี่ (Filter) เพื่อกรองความถี่บางช่วงความถี่ออก และส่งผ่านสัญญาณนั้นไปวิเคราะห์เทียบกับขนาดหรือความรุนแรงของรอยความไม่ต่อเนื่อง การวิเคราะห์สัญญาณอาจทำได้ทั้งในโดเมนเวลา (Time domain) และโดเมนความถี่ (Frequency domain) หรือใช้ร่วมกันทั้งสองโดเมน



รูปที่ 2.24 หลักการทดสอบด้วยวิธีอคูสติกอิมิชชัน

ความถี่ที่นำไปวิเคราะห์โดยทั่วไปมักอยู่ในช่วงตั้งแต่ 25 kHz จนถึง 3 MHz แต่ความถี่ที่นิยมในงานต่างๆ มักอยู่ในช่วง 100 kHz ถึง 1 MHz อคูสติกอิมิชชันมีความไวในการทดสอบสูงมาก คลื่นผิว (Surface wave) ที่เกิดขึ้นบริเวณผิวของวัสดุที่ทำให้เกิดระยาะขจัดที่มีขนาดเล็กเพียง สามารถทดสอบพบได้


แสดงตัวอย่างของการวิเคราะห์ด้วยอคูสติกอิมิชชัน โดยเมื่อวัสดุชนิดหนึ่งถูกแรงดึงกระทำที่ปลายทั้งสองจนกระทั่งเกิดการเสียรูปแบบพลาสติกหรือเกิดการแตกในเนื้อวัสดุ รอยแตกนั้นจะทำหน้าที่เป็นแหล่งกำเนิดเสียงทั้งแบบคลื่นเสียงตามยาว และคลื่นเสียงตามขวาง คลื่นเสียงทั้งสองชนิดจะเคลื่อนที่ไปทุกทิศทางจนถึงที่ผิวของวัสดุและทำให้เกิดคลื่นเสียงที่ผิวขึ้น หัววัดที่ติดตั้งไว้ที่ผิวของวัสดุก็จะทำหน้าที่เปลี่ยนพลังงานกลของคลื่นเสียงไปเป็นพลังงานไฟฟ้า และสัญญาณทางไฟฟ้านั้นจะถูกนำไปวิเคราะห์ต่อไปดังแสดงในรูปที่ 2.24

2.7 อุปกรณ์ทดสอบด้วยคอสติกอิมิชชัน

2.7.1 หัววัดคอสติกอิมิชชัน

หัววัดคอสติกอิมิชชัน หมายถึงหัววัดที่ใช้สำหรับตรวจจับคลื่นเสียงบริเวณ ผิววัสดุ เพื่อรับคลื่นเสียงจากการปลดปล่อยจากภายในวัสดุ และเปลี่ยนกลับเป็นสัญญาณไฟฟ้า โดยเอาท์พุทของสัญญาณไฟฟ้าที่ได้ขึ้นอยู่กับคุณลักษณะของหัววัด ซึ่งมีความสำคัญต่อความไว (Sensitivity) ในการตรวจสอบ และการทำซ้ำ (Repeatability) ในการตรวจสอบ หัววัดแบบคอสติกชนิดเพียโซอิเล็กทริก โดยทั่วไปแบ่งออกได้เป็น 2 ประเภทคือ แบบความถี่เรโซแนนซ์ (Resonance) และแบบช่วงความถี่กว้าง (Broad band) โครงสร้างของหัววัดมีส่วนประกอบหลักดังแสดงในรูปที่ 2.25 คือ

- วัสดุเพียโซอิเล็กทริกเป็นวัสดุที่สามารถให้สนามไฟฟ้าได้ เมื่อให้แรงกระทำทางกลต่อวัสดุนั้น หรือในทางกลับกันถ้าให้สนามไฟฟ้าผ่านวัสดุก็จะทำให้รูปร่างของวัสดุนั้นเปลี่ยนแปลง
- วัสดุรองหลัง ใช้สำหรับช่วยลดทอนพลังงานเสียงในช่วงความถี่อื่นในการสั่นของวัสดุเพียโซอิเล็กทริกและช่วยลดดูดซับพลังงานนั้นไว้โดยที่ไม่ทำให้เกิดการสะท้อนกลับของคลื่นเสียง
- แผ่นป้องกันสึก เป็นวัสดุที่ใช้ป้องกันหน้าสัมผัสของวัสดุเพียโซอิเล็กทริก
- ตัวเรือนหัววัด (housing) ใช้ป้องกันการกระทบกระเทือนวัสดุเพียโซอิเล็กทริก



รูปที่ 2.25 หัววัดคอสติกอิมิชชัน

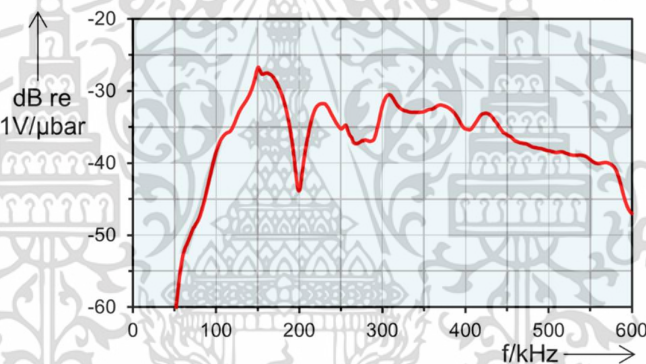
2.7.2 หัววัดคอสติกอิมิชชันแบบสัมผัส

หัววัดชนิดนี้จะติดตั้งโดยการสัมผัสกับวัตถุที่จะทดสอบโดยตรง โดยใช้สารช่วยสัมผัส (Couplant) ในการช่วยให้การส่งผ่านคลื่นเสียงได้ดียิ่งขึ้น ชนิดของสารช่วยสัมผัสจะเป็นชนิดเดียวกันกับการทดสอบด้วยคลื่นเสียงความถี่สูง การยึดติดกับวัตถุที่ทดสอบอาจทำได้โดยใช้แม่เหล็กหรือการใช้ไอพอกซี ส่วนประกอบภายในหัววัดชนิดนี้จะมีลักษณะเหมือนกับหัววัดคลื่นเสียงความถี่สูง ซึ่งประกอบด้วยวัสดุรองหลังและไอพอกซีที่ทำหน้าที่ให้หัววัดรูปร่างและตำแหน่งอยู่ได้ ภายในหัววัดจะมีผลึก ซึ่งปัจจุบันนิยมใช้ผลึกชนิดเพียโซอิเล็กทริก (Lead Zirconate Titanate : PZT) ทำหน้าที่เปลี่ยนพลังงานกลของคลื่นเสียง เป็นพลังงานทางไฟฟ้าและส่งต่อสัญญาณผ่านสายเคเบิลไปยัง

อุปกรณ์ขยายเบื้องต้นที่ติดตั้งอุปกรณ์กรองสัญญาณอยู่ภายใน ซึ่งในการวิจัยนี้ใช้หัววัดแบบสัมผัส ดังแสดงในรูปที่ 2.26 และ 2.27



รูปที่ 2.26 หัววัดแบบสัมผัส



รูปที่ 2.27 ช่วงการตอบสนองต่อความถี่ของหัววัด รุ่น VS 150 RIC

2.7.3 อุปกรณ์ขยายสัญญาณ

ทำหน้าที่ขยายสัญญาณทางไฟฟ้าให้มีขนาดใหญ่ขึ้น ปกติแล้วอุปกรณ์ขยายสัญญาณเบื้องต้นควรอยู่ใกล้กับหัววัดมากที่สุด เพื่อทำการขยายสัญญาณก่อนที่สัญญาณจะถูกลดทอนลง เมื่อถูกส่งผ่านสายเคเบิลหรืออุปกรณ์อื่น อุปกรณ์ขยายสัญญาณเบื้องต้นสำหรับงานวิจัยนี้ถูกออกแบบให้อยู่ในหัววัด

2.7.4 อุปกรณ์กรองสัญญาณ

มักจะติดตั้งอยู่ภายในอุปกรณ์ขยายสัญญาณเบื้องต้น เพื่อทำหน้าที่กรองสัญญาณเสียงในย่านความถี่ที่ไม่เกี่ยวข้อง หรือสัญญาณรบกวน (Noise) ออกไปอุปกรณ์กรองสัญญาณมี 3 ชนิด

1. แบบไฮพาส (High Pass) จะยอมให้เฉพาะสัญญาณที่มีความถี่สูงที่กำหนดผ่าน เช่น กำหนดให้สัญญาณที่มีความถี่สูงกว่า 100 kHz ผ่าน

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2. แบบแบนด์พาส (Band Pass) จะยอมให้เฉพาะสัญญาณที่มีความถี่ที่อยู่ในช่วงที่กำหนดผ่าน 100 – 300 kHz แบบแบนด์พาส จะยอมให้สัญญาณที่อยู่ในช่วง 100 – 300 kHz ผ่าน
3. แบบโลพาส (Low Pass) จะยอมให้สัญญาณที่มีความถี่ต่ำที่กำหนดผ่าน เช่น 100 kHz แบบโลพาส จะยอมให้สัญญาณที่มีความถี่ต่ำกว่า 100 kHz ผ่าน

แบบแบนด์พาส จะเป็นที่ใช้กันมากกว่าชนิดการกรองสัญญาณอื่น เนื่องจากโดยปกติในการทดสอบด้วยวิธีการออสติโกมิซชัน มักต้องการตัดเสียงรบกวนทั้งความถี่ต่ำและความถี่สูงออก เช่น ตัดความถี่ต่ำจากการสั่นสะเทือนออก และตัดเสียงรบกวน เช่น จากสัญญาณทางไฟฟ้า หรือจากอุปกรณ์อิเล็กทรอนิกส์ที่มีความถี่สูงออก

2.8 อุปกรณ์ประมวลผลสัญญาณ

ทำหน้าที่เปลี่ยนสัญญาณจากอนาล็อก (Analog) เป็นดิจิทัล (Digital) และประมวลผลสัญญาณนั้นให้อยู่ในรูปของออสติโกพารามิเตอร์ (AE parameter) อุปกรณ์รับและประมวลผลสัญญาณงานวิจัยนี้ใช้ FPGA รุ่น ASIP-2 ดังแสดงในรูปที่ 2.28



รูปที่ 2.28 บอร์ด FPGA รุ่น ASIP-2

2.9 ชนิดของคลื่น (Type of Wave)

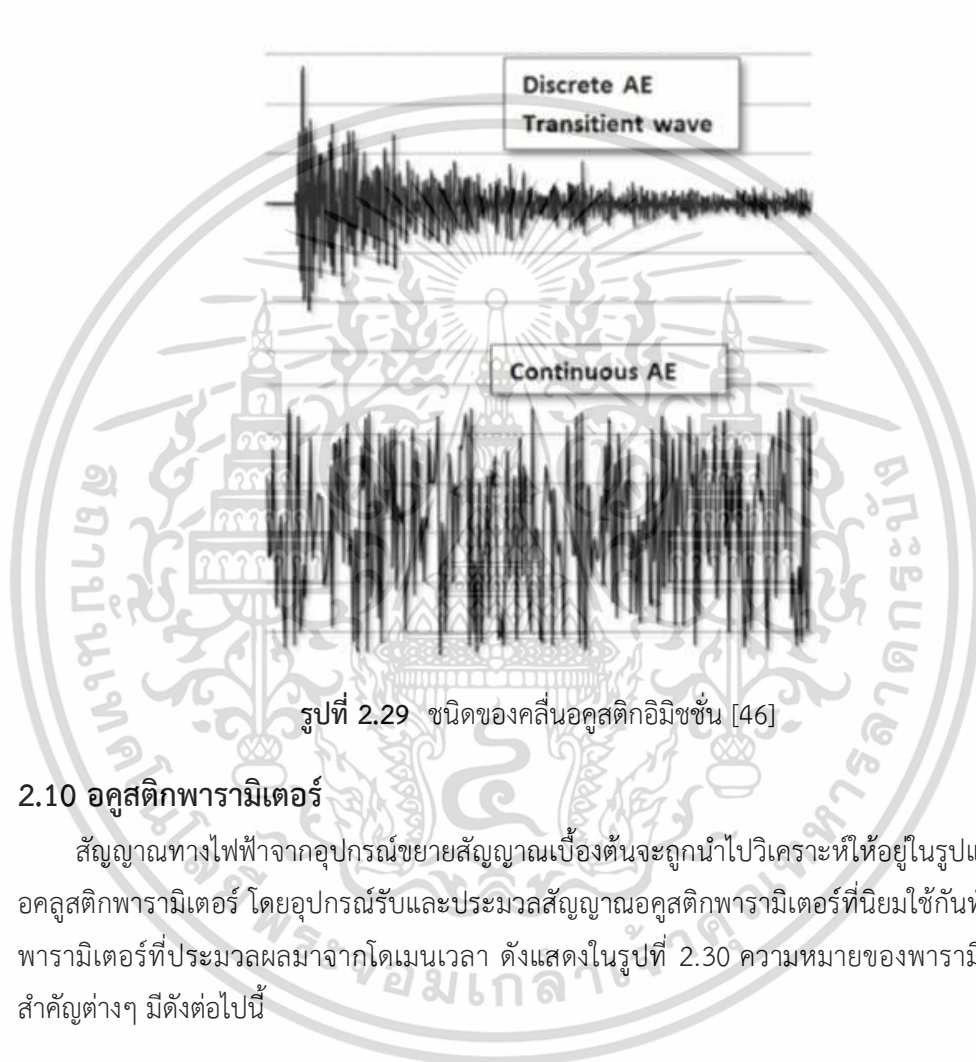
คลื่นเสียงทางกลที่ปลดปล่อยออกจากวัสดุและตรวจจับด้วยหัวทดสอบนั้น คลื่นเสียงชนิดคลื่นที่ผิว (Surface Wave) มักส่งผลมากกว่าคลื่นชนิดตามยาว (Longitudinal Wave) และคลื่นชนิดตามขวาง (Shear Wave) ทั้งนี้เนื่องจากแอมพลิจูดของระยะขจัดสูงกว่า และการลดทอนของพลังงานน้อยกว่าคลื่นชนิดอื่นเนื่องจากการเคลื่อนที่ไปบนผิวของวัสดุ เมื่อหัววัดเปลี่ยนคลื่นเสียงทางกลเป็นคลื่นเสียงทางไฟฟ้าแล้ว สามารถแบ่งได้เป็น 2 ชนิดคือ

2.9.1 แบบต่อช่วง (Burst)

เป็นคลื่นที่มีลักษณะเกิดขึ้นเป็นช่วง ดังแสดงในรูป 2.29 พารามิเตอร์ที่นิยมใช้ในการวิเคราะห์ข้อมูลกับงานที่มีสัญญาณแบบเป็นช่วง ได้แก่ เคานท์ (Count), แอมพลิจูด (Amplitude), ฮิต (Hit)

2.9.2 แบบต่อเนื่อง (Continuous)

เป็นคลื่นที่เกิดต่อเนื่องกันไป ดังแสดงในรูปที่ 2.29 เช่น สัญญาณเสียงจากการรั่วของวาล์วเป็นต้น พารามิเตอร์ที่มักใช้วิเคราะห์ข้อมูลกับสัญญาณแบบต่อเนื่องคือ ค่าระดับสัญญาณเฉลี่ย (ASL), AErms หรือ ทางโดเมนความถี่ เป็นต้น [46]



รูปที่ 2.29 ชนิดของคลื่นอคูสติกอิมพัลส์ [46]

2.10 อคูสติกพารามิเตอร์

สัญญาณทางไฟฟ้าจากอุปกรณ์ขยายสัญญาณเบื้องต้นจะถูกนำไปวิเคราะห์ให้อยู่ในรูปแบบของอคูสติกพารามิเตอร์ โดยอุปกรณ์รับและประมวลสัญญาณอคูสติกพารามิเตอร์ที่นิยมใช้กันทั่วไปคือพารามิเตอร์ที่ประมวลผลมาจากโดเมนเวลา ดังแสดงในรูปที่ 2.30 ความหมายของพารามิเตอร์ที่สำคัญต่างๆ มีดังต่อไปนี้

- เคาท์ (Counts) คือ จำนวนครั้งที่สัญญาณคลื่นอคูสติกมีขนาดแอมพลิจูดสูงกว่าค่าขีดเปลี่ยน (Threshold)

- แอมพลิจูดสูงสุด (Peak amplitude) คือ ขนาดของค่าสูงสุดของแอมพลิจูดของสัญญาณคลื่น


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

อคูสติค

- ไรส์ไทม์ (Rise Time) คือระยะเวลาที่เริ่มนับตั้งแต่สัญญาณที่มีค่าสูงกว่าขีดเริ่มเปลี่ยนจนถึงเวลาที่สัญญาณมีขนาดแอมพลิจูดสูงสุด

- ดิวเรชั่นไทม์ (Duration time) คือระยะเวลาที่เริ่มนับตั้งแต่สัญญาณที่มีค่าสูงกว่าขีดเริ่มเปลี่ยนจนถึงระยะเวลาที่สัญญาณต่ำกว่าขีดเริ่มเปลี่ยน

- พลังงาน (Energy) คือพลังงานของคลื่นอคูสติคที่เทียบได้จากการอินทิเกรตแรงดันไฟฟ้าที่ยกกำลังสอง เทียบกับเวลาแล้วหารด้วยความต้านทานไฟฟ้าของอุปกรณ์ตรวจวัด

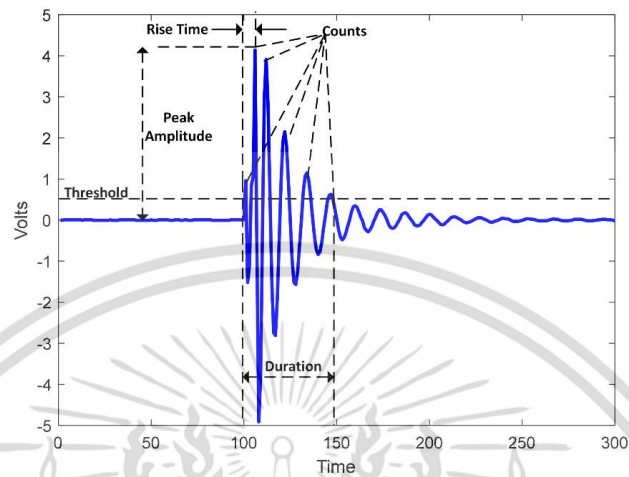


รูปที่ 2.30 อคูสติคพารามิเตอร์


2.11 มาตรฐาน ASTM E976

มาตรฐาน ASTM E976 เป็นมาตรฐานเพื่อใช้สำหรับการตรวจสอบการตอบสนองความไวของการรับสัญญาณอคูสติคอิมิชชั่นของอคูสติคอิมิชชั่นเซ็นเซอร์และเพื่อสร้างสัญญาณจำลองของสัญญาณอคูสติคอิมิชชั่นแบบต้อช่วง (Burst) ดังแสดงในรูปที่ 2.31 โดยการหักไส้ดินสอด (Pencil Lead Break) ซึ่งในการหักไส้ดินสอดเพื่อสร้างสัญญาณอคูสติคอิมิชชั่นนั้นจะต้องมี Nielsen Shoe เพื่อสำหรับช่วยให้มุมของไส้ดินสอดทำมุมที่ 30 องศาที่บรรนาบของวัสดุที่ทำการตรวจสอบ โดยความยาวของไส้ดินสอดจะมีความยาว 3 มม. ขนาดของไส้ดินสอด 0.3 มม. หรือ 0.5 มม. และความแข็งของไส้ดินสอดชนิด 2H ดังแสดงในรูปที่ 2.32 ในการตรวจสอบการตอบสนองความไวของหัววัดแต่ละหัววัดอคูสติคอิมิชชั่น ทำโดยการหักไส้ดินสอดที่ระยะคงที่ห่างจากหัววัดอคูสติคอิมิชชั่นและบันทึกค่าสูงสุดของแอมพลิจูดในโดเมนเวลาของสัญญาณอคูสติคอิมิชชั่น จำนวน 5 ครั้ง ให้การตรวจสอบแต่

ละห้วงว้ดอคูสติกอิมพัลส์ จะต้องมีค่าเฉลี่ยของแอมพลิจูดสูงสุด ไม่เกิน ± 4 dB ตามมาตรฐาน ASME E976



รูปที่ 2.31 ค่าสูงสุดของแอมพลิจูดในโดเมนเวลาของสัญญาณอคูสติกอิมพัลส์




รูปที่ 2.32 การหักไส้ดินสอ (Pencil Lead Break) ตามมาตรฐาน ASME E976

2.12 สถาปัตยกรรมของโครงข่าย

โดยทั่วไป โครงข่ายประสาทเทียมแบบลึกลับประกอบไปด้วยหลายชั้น (Layer) ของโครงข่าย ในแต่ละชั้นของโครงข่าย จะประกอบไปด้วย เซลล์ประสาท (Neuron) ในที่นี้เรียกว่านิวรอน ซึ่งอาจมีได้

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


หลายนิวรอนในชั้นเดียวกัน การเชื่อมต่อกันของแต่ละชั้นเชื่อมต่อกันด้วยค่าน้ำหนัก (Weight) ในที่นี้สำหรับสถาปัตยกรรมพื้นฐานของโครงข่ายประสาทเทียม จะประกอบไปด้วย 3 ชั้นหลัก คือ ชั้นรับข้อมูลเข้า (Input layer) ชั้นเซลล์ประสาทซ่อน (Hidden layer) และชั้นข้อมูลออก (Output layer) ดังแสดงในรูปที่ 2.33



รูปที่ 2.33 สถาปัตยกรรมของ Deep Neural Networks

2.12.1 หลักการของเครือข่ายประสาทเทียมสำหรับในคอมพิวเตอร์

นิวรอนประกอบด้วยอินพุตและเอาต์พุตเหมือนกัน โดยจำลองให้อินพุตแต่ละหน่วยมีค่าน้ำหนัก (weight) เป็นตัวกำหนดน้ำหนักของอินพุต โดยนิวรอนแต่ละหน่วยจะมีค่า threshold เป็นตัวกำหนดว่าน้ำหนักรวมของอินพุตต้องมากขนาดไหน จึงจะสามารถส่งเอาต์พุตไปยังนิวรอนตัวอื่นได้เมื่อนิวรอนแต่ละหน่วยมาต่อกันให้ทำงานร่วมกัน การทำงานนี้ในทางตรรกะแล้วก็จะเหมือนกับปฏิกิริยาเคมีที่เกิดในสมอง เพียงแต่ในคอมพิวเตอร์ทุกอย่างเป็นตัวเลขเท่านั้น ดังแสดงในรูปที่ 2.34



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 2.34 แบบจำลองของนิเวรอนในคอมพิวเตอร์

2.12.2 การทำงานของเครือข่ายประสาทเทียม

เมื่อมีอินพุตเข้ามายังเครือข่ายประสาทเทียม เครือข่ายจะนำเอาอินพุตมาคูณกับน้ำหนักของแต่ละขาผลที่ได้จากอินพุตทุกขาของนิเวรอนจะเอามารวมกันแล้วนำมาเทียบกับค่า ชิดเริ่มเปลี่ยน (threshold) ที่กำหนดไว้ ถ้าผลรวมมีค่ามากกว่าค่าชิดเริ่มเปลี่ยนที่กำหนด นิเวรอนจะส่งเอาท์พุตออกไปยังอินพุตของนิเวรอนอื่น ๆ ที่เชื่อมกันในเครือข่าย ถ้าค่าผลรวมมีค่าน้อยกว่าค่าชิดเริ่มเปลี่ยนจะไม่เกิดเอาท์พุต

สิ่งที่สำคัญคือต้องทราบค่าน้ำหนักและค่าชิดเริ่มเปลี่ยนสำหรับสิ่งที่ต้องการ เพื่อให้คอมพิวเตอร์รู้จัก ซึ่งเป็นค่าที่ไม่แน่นอนแต่สามารถกำหนดให้คอมพิวเตอร์ปรับเปลี่ยน ค่าเหล่านั้นได้ โดยการสอนให้รู้จักกับรูปแบบของสิ่งที่ต้องการให้รู้จักเรียกว่า back-propagation

ซึ่งเป็นกระบวนการย้อนกลับของการรู้จักในการฝึกสอนเครือข่ายนิเวรอน แบบไปข้างหน้า จะมีการใช้อัลกอริทึมแบบ back-propagation เพื่อใช้ในการปรับปรุงน้ำหนัก น้ำหนักของเครือข่ายหลังจากใส่รูปแบบข้อมูลสำหรับฝึกสอนในแต่ละครั้งแล้ว ค่าที่ได้รับจากเอาท์พุตของเครือข่ายจะถูกนำไปเปรียบเทียบกับผลที่คาดหวังแล้วทำการคำนวณหาค่าความผิดพลาด ซึ่งค่าความผิดพลาดนี้จะถูกส่งกลับเข้าสู่เครือข่ายอีกครั้ง เพื่อใช้แก้ไขค่าน้ำหนักของเครือข่ายต่อไป

2.12.3 การเรียนรู้สำหรับโครงข่ายประสาทเทียม

2.12.3.1 การเรียนรู้แบบมีผู้ฝึกสอน (Supervised Training)

การฝึกแบบมีผู้สอนคือ การฝึกสอนที่ตัวระบบทราบค่าจริงของผลลัพธ์ว่ามีค่าเป็นเท่าใด ตัวอย่างเช่น การฝึกสอนแบบ การแก้ไขข้อผิดพลาด (Error-Correction learning) ระบบจะทำการคำนวณค่าผิดพลาดจากผลลัพธ์ที่ได้กับค่าจริงที่ทราบ แล้วนำค่าความผิดพลาดนั้นไปทำกระบวนการปรับค่าน้ำหนัก เพื่อใช้ฝึกสอนต่อไป เป้าหมายคือคือให้ค่าความผิดพลาดนั้นมีค่าต่ำมากที่สุดที่สามารถยอมรับได้

2.12.3.2 การเรียนรู้แบบไม่มีผู้ฝึกสอน (Unsupervised Training)

การฝึกสอนแบบไม่มีผู้สอนคือ การฝึกสอนที่ตัวระบบไม่ทราบค่าเป้าหมายจริงของผลลัพธ์ ระบบโครงข่ายจะทำการปรับตัวระบบเองตามพฤติกรรมของข้อมูล ตัวอย่างเช่น ระบบพยายามให้ข้อมูลฝึกสอนที่มีพฤติกรรมคล้ายคลึงกันมาอยู่ด้วยกัน เป็นปัญหาลักษณะการจัดกลุ่ม ตัวกลางของแต่ละ

ละกลุ่มหรืออาจเรียกเป็นค่าน้ำหนักก็ได้เช่นกัน จะถูกปรับค่าในระหว่างการฝึกสอนข้อมูล ท้ายที่สุด การฝึกสอนจะสิ้นสุดลงก็ต่อเมื่อมีการวัดว่า ตัวกลางของกลุ่มหรือค่าน้ำหนักนั้นมีความคงที่แล้ว

2.12.4 ตัวอย่างการประยุกต์ใช้โครงข่ายประสาทเทียม

เนื่องจากความสามารถในการจำลองพฤติกรรมทางกายภาพของระบบที่มีความซับซ้อนจาก ข้อมูลที่ป้อนให้ เพื่อการเรียนรู้และการประยุกต์ใช้เครือข่ายประสาทเทียม จากยุคเริ่มต้นในการ พัฒนาเครือข่ายประสาทเทียมจนถึงยุคปัจจุบันได้มีผู้นำมาประยุกต์ใช้งานหลาย ประเภทในงาน ด้านต่าง ๆ เช่น

1. การจำรูปแบบที่ยาก (Pattern Recognition) เช่น การรู้จำลายนิ้วมือ การรู้จำใบหน้า มนุษย์ การอ่านความรู้สึกจากใบหน้า การรู้จำป้ายทะเบียนรถยนต์ เป็นต้น
2. ปัญหาการพยากรณ์ เช่น การพยากรณ์สภาพภูมิอากาศ ปริมาณน้ำฝน อุณหภูมิโลก ราคา น้ำมันและพลังงาน การใช้พลังงาน ราคาหุ้น อัตราการแลกเปลี่ยน เป็นต้น
3. การจำแนกประเภท หรือการจัดหมวดหมู่ เช่น การจำแนกหรือการระบุว่า เป็นโรคทาง การแพทย์ การจำแนกเซลล์มะเร็ง การจำแนกสัญญาณการเต้นของหัวใจ หรือคลื่นสมอง เป็นต้น
4. การควบคุม (Control) เช่นการควบคุมหุ่นยนต์
5. การประมวลผลแบบขนาน ใช้กับข้อมูลปริมาณมากๆ
6. ความสามารถในการเรียนรู้ เฉกเช่นเดียวกับมนุษย์

ประโยชน์อย่างอื่นที่ได้รับเมื่อใช้โครงข่ายประสาทเทียม เช่น การปรับตัวของระบบในขณะที่ การเรียนรู้ (Adaptive learning) ความสามารถในการสร้างระบบหรือสามารถอธิบายข้อมูลเอง (Self-organization)

2.13 ฟังก์ชันกระตุ้น (Activation function)

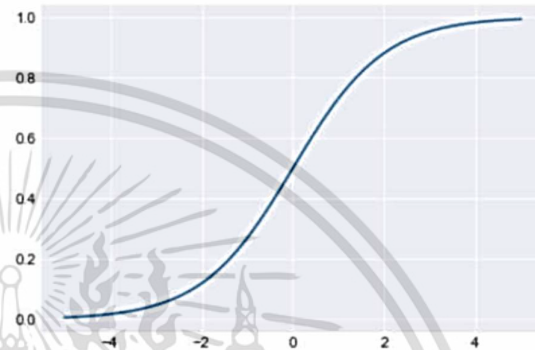
ฟังก์ชันกระตุ้น (Activation function) หรือบางที่เรียกว่าฟังก์ชันส่งผ่าน (transfer function) ทำหน้าที่ตัดสินใจว่าจะส่งสัญญาณเอาต์พุตออกไปในรูปใด มีบทบาทต่อการปรับค่าเข้าสู่ การเรียนรู้ของประสาทเทียม เปลี่ยนจากความเป็นเชิงเส้นให้กลายเป็นไม่เป็นเชิงเส้น เพื่อให้ระบบ สามารถนำมาใช้แก้ปัญหาในโลกความเป็นจริงได้เนื่องจากปัญหาที่พบในความเป็นจริงไม่ได้เป็นเชิง เส้น การเลือกใช้ฟังก์ชันแบบใดจะขึ้นอยู่กับลักษณะของระบบ ที่นำเอาโครงข่ายประสาทเทียมไป ประยุกต์ใช้ ฟังก์ชันกระตุ้นนี้มีหลายตัวที่นิยมใช้ได้แก่

2.12.1 ฟังก์ชันซิกมอยด์ (Sigmoid)

จากรูปที่ 2.35 กราฟของซิกมอยด์ให้ค่าได้ตั้งแต่ 0 ถึง 1 ตามสมการด้านล่าง เป็นค่าต่อเนื่อง ซึ่งเหมาะกับการใช้เป็นค่าความเป็นไปได้ แล้วแปลงออกมาเป็นค่าสำหรับจำแนกประเภท

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}} \quad (2.1)$$

$$\text{sigmoid}(x) = \frac{1}{1 + e^{-x}}$$



รูปที่ 2.35 กราฟ Sigmoid function


แต่ปัญหาอย่างหนึ่งของฟังก์ชันนี้ คือ การเปลี่ยนแปลงค่า Y มีผลต่อค่า X ทำให้ค่า X มีค่าน้อยลงมาก ส่งผลให้เกิดการหายไประหว่างการหาค่าต่ำสุดของฟังก์ชันสูญเสีย (Gradients) (Shanmugamani, R., 2018)

2.12.2 ฟังก์ชันไฮเปอร์โบลิค เทนเจนท์ (Hyperbolic tangent (tanh))

เป็นฟังก์ชันที่มีลักษณะคล้ายฟังก์ชันซิกมอยด์ ให้ค่าผลลัพธ์ (y) อยู่ในช่วง -1 ถึง 1 ทำให้การหายระหว่างหาค่าต่ำสุดของฟังก์ชันสูญเสียน้อยกว่าฟังก์ชันซิกมอยด์ แต่ยังคงให้ผลลัพธ์ตลอดเวลา ส่งผลให้ระบบประสาทเทียมทำงานหนักตลอดเวลา ดังแสดงในรูปที่ 2.36

$$\text{tanh}(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.2)$$

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

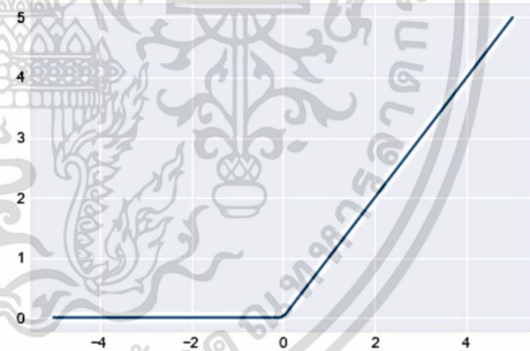


รูปที่ 2.36 กราฟ Hyperbolic tangent function

2.12.3 ฟังก์ชันเรคตีไฟต์ ลิเนียร์ ยูนิท (Rectified Linear Unit (ReLU))

ฟังก์ชันนี้จะหยุดปัญหาส่งผลลัพธ์ไม่หยุด เมื่อเข้าฟังก์ชัน ReLU ด้วยค่าเป็นลบ ไม่ว่าจะจำนวนเท่าใดก็ตาม ก็จะแปลงเป็นค่า 0 ซึ่งเป็นผลลัพธ์ที่ทำให้ประสาทเทียมไม่ทำงานตลอดเวลา ทำให้การฝึกการเรียนรู้ทำงานได้รวดเร็ว ยกเว้นค่าเป็นบวก จะให้ผลลัพธ์ตามค่าที่ส่งเข้ามา ดังการแสดงด้วยกราฟ ดังแสดงในรูปที่ 2.37

$$\text{relu}(x) = \begin{cases} 0 & \text{if } x < 0 \\ x & \text{if } x \geq 0 \end{cases}$$




รูปที่ 2.37 กราฟ Rectified Linear Unit – ReLU

2.12.4 ฟังก์ชันพารามेटริกเรคตีไฟต์ ลิเนียร์ ยูนิท (Parametric Rectified Linear Unit (PReLU))

คล้ายฟังก์ชันเรคตีไฟต์ ลิเนียร์ ยูนิทที่กล่าวไปก่อนหน้านี้ ต่างกันที่ฟังก์ชันนี้ไม่ให้ค่าเป็น 0 กรณีค่าอินพุตเป็น 0 หรือน้อยกว่าจะได้ค่าเป็น ผลคูณแอลฟากับค่านั้นๆ ส่วนกรณีค่ามากกว่า 0 จะให้ผลลัพธ์เป็นค่านั้นๆ ดังแสดงในรูปที่ 2.38

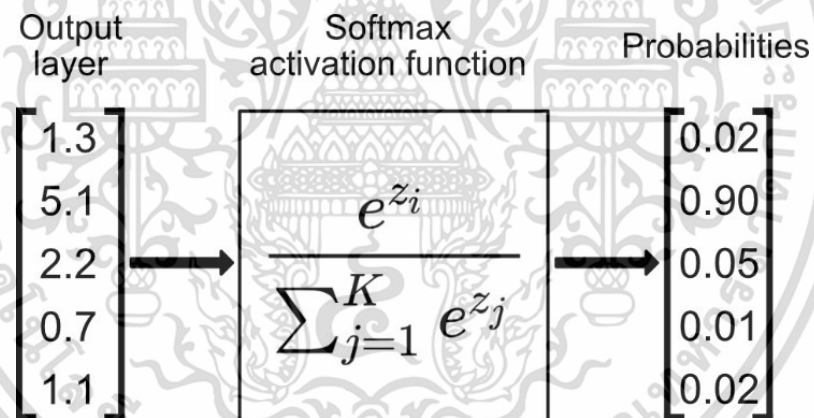
$$f(x) = \begin{cases} x & \text{if } x > 0 \\ ax & \text{otherwise} \end{cases}$$



รูปที่ 2.38 กราฟ Parametric Rectified Linear Unit


2.12.5 ฟังก์ชันซอฟต์แม็กซ์ (Softmax Function)

ฟังก์ชันซอฟต์แม็กซ์ (Softmax Function) หรือ Normalized Exponential Function คือ ฟังก์ชันที่รับค่าอินพุตเป็นเวกเตอร์ของลอจิกจำนวนจริง แล้วนอร์มอลไรซ์ (Normalize) ออกมาเป็นความน่าจะเป็น (Probability) ที่ผลรวมเท่ากับ 1 ดังแสดงในรูปที่ 2.39 และ 2.40



รูปที่ 2.39 การทำงานของฟังก์ชันซอฟต์แม็กซ์

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้



รูปที่ 2.40 กราฟ Softmax Function

2.14 ขั้นตอนการส่งค่าไปข้างหน้า (Forward Propagation)


หลังจากกำหนดตัวพารามิเตอร์ที่จำเป็นอย่างน้ำหนักและค่าไบแอสเรียบร้อยแล้ว จึงเริ่มต้นกระบวนการส่งค่าไปข้างหน้า (Forward Propagation) ซึ่งคือ การนำข้อมูล x เข้ามาประมวลผลร่วมกับพารามิเตอร์เหล่านั้นเป็นชั้นๆ จนได้ค่าตอบออกมาในท้ายที่สุด อย่างไรก็ตามในตอนเริ่มต้นโมเดลจะยังไม่มีพารามิเตอร์ที่ถูกต้อง จึงต้องสุ่มค่าเริ่มต้นของพารามิเตอร์ขึ้นมาก่อน แล้วค่อยปรับให้ได้ค่าที่ดีที่สุดด้วยกระบวนการที่เรียกว่า Backward propagation ดังแสดงในรูปที่ 2.41

ซึ่งในกระบวนการต้องกำหนดค่าพารามิเตอร์อีกตัวที่เป็นไฮเปอร์พารามิเตอร์ (hyperparameter) ชื่อ อัตราการเรียนรู้ (Learning Rate : lr) ทำหน้าที่ควบคุมว่าในหนึ่งส tep ของการเทรนว่าจะปรับค่าน้ำหนัก (Weight) ของโครงข่ายประสาทเทียมมากน้อยแค่ไหน

ค่าน้ำหนัก (weights) คือ สิ่งที่ได้จากการเรียนรู้ของโครงข่ายประสาทเทียม หรือเรียกอีกอย่างหนึ่งว่า ค่าความรู้ (knowledge) ค่านี้จะถูกเก็บเป็นทักษะเพื่อใช้ในการจดจำข้อมูลอื่น ๆ ที่อยู่ในรูปแบบเดียวกัน

ถ้าอัตราการเรียนรู้มีค่าน้อย ค่าน้ำหนักของโมเดลก็จะเปลี่ยนแปลงน้อย การทำงานของโมเดลก็จะเปลี่ยนไปน้อย ค่าสูญเสีย (Loss) ก็ไม่ค่อยเปลี่ยนเท่าไร

ถ้าอัตราการเรียนรู้มีค่ามาก ค่าน้ำหนักของโมเดลก็จะเปลี่ยนแปลงมาก การทำงานของโมเดลก็จะเปลี่ยนไปมาก ค่าสูญเสียก็จะเปลี่ยนแปลงมาก ดังแสดงในรูปที่ 2.42



รูปที่ 2.41 กระบวนการ Forward Propagation

Big learning rate

Small learning rate

(ก)

(ข)


รูปที่ 2.42 (ก) กรณีตั้งค่าอัตราการเรียนรู้สูง (ข) กรณีตั้งค่าอัตราการเรียนรู้ต่ำ

2.15 ขั้นตอนการส่งค่าย้อนกลับ (Backpropagation)

นิยามได้ง่ายๆ ว่าเป็นกระบวนการย้อนกลับสำหรับปรับค่าน้ำหนัก (w) ในแต่ละเส้นโดยใช้ค่าความผิดพลาด (Error/Cost value) ที่เกิดขึ้นในแต่ละนิวรอน เมื่อขั้นตอนการส่งค่าไปข้างหน้า (Forward propagation) ทำงานจบ 1 เทียบ ก็จะเปรียบเทียบผลการพยากรณ์กับคำตอบที่รู้อยู่แล้ว จากนั้นโมเดลจะใช้กระบวนการตรงกันข้าม คือ Backward propagation ในการปรับค่าพารามิเตอร์ให้สะท้อนข้อมูลในเซตฝึก (Train set) มากขึ้น ทำอย่างนี้หลายๆ รอบจนกระทั่งได้ความแม่นยำของโมเดลตามที่ต้องการ โดยเรียกการทำงานไป-กลับแต่ละรอบว่า 1 Epoch

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

สำหรับการฝึกโมเดลกระบวนการส่งค่าย้อนกลับ ประกอบด้วย 2 ส่วนย่อยคือ การส่งผ่านไปข้างหน้า (Forward Pass) การส่งผ่านย้อนกลับ (Backward Pass) สำหรับการส่งผ่านไปข้างหน้า ข้อมูลจะผ่านเข้าโครงข่ายประสาทเทียมที่ชั้นข้อมูลเข้าและจะส่งผ่าน จากอีกชั้นหนึ่งไปสู่อีกชั้นหนึ่ง จนกระทั่งถึงชั้นข้อมูลออก ส่วนการส่งผ่านย้อนกลับค่าน้ำหนักการเชื่อมต่อจะถูกปรับเปลี่ยนให้สอดคล้องกับกฎการแก้ข้อผิดพลาด (Error-Correction) คือผลต่างของผลตอบที่แท้จริง (Actual Response) กับผลตอบเป้าหมาย (Target Response) เกิดเป็นสัญญาณผิดพลาด (Error Signal) ซึ่งสัญญาณผิดพลาดนี้จะถูกส่งย้อนกลับเข้าสู่โครงข่ายประสาทเทียมในทิศทางตรงกันข้ามกับการเชื่อมต่อ และค่าน้ำหนักของการเชื่อมต่อจะถูกปรับจนกระทั่งผลตอบที่แท้จริงเข้าใกล้ผลตอบเป้าหมาย ดังแสดงในรูปที่ 2.43



รูปที่ 2.43 การส่งผ่านไปข้างหน้า (Forward Pass) และการส่งผ่านย้อนกลับ (Backward Pass)

2.16 การประเมินประสิทธิภาพของโมเดล

การสร้างโมเดลจะต้องมีการทดสอบหรือประเมินประสิทธิภาพความแม่นยำของโมเดลที่สร้างสำหรับระบบ Machine Learning หรือ Deep Learning ที่ทำงานในลักษณะการจำแนก, แยกแยะ หรือการจัดกลุ่ม การประเมินแต่ละอย่างจะมีค่าเป้าหมายต่างกัน ในส่วนโมเดลวัดค่าความแม่นยำเป็นหลัก เช่น แม่นยำที่เปอร์เซ็นต์ ทำนายถูกที่เปอร์เซ็นต์ ในกรณีการใช้ Supervised Learning แบ่งออกเป็น 2 กลุ่มคือ

Regression คือ การคำนวณทำนาย ได้ผลลัพธ์เป็นค่าเป็นตัวเลข ในการประเมินโมเดลหลักๆคือวัดระยะที่คลาดเคลื่อน (Error หรือ Residual) เช่นการคำนวณค่า R2, MSE, MAE และ RMSE เป็นต้น

Classification คือ การจำแนก, แยกแยะ ทำหน้าที่ในการจำแนก, แยกแยะ ซึ่งการทำนายจะให้ผลลัพธ์เป็นข้อมูลแบบหมวดหมู่ (Category) หรือให้ค่าออกมาเป็น Class/Target/Label (Predicted Label) จะมีการประเมินหลายด้าน มากกว่า Regression โดยต้องใช้ตารางที่เรียกว่า Confusion Matrix มาประเมินร่วมด้วย

ตาราง Confusion Matrix เป็นตารางที่ใช้ในการประเมินผลการทำงานของผลลัพธ์ (Prediction) เปรียบเทียบกับค่าจริง (Actual) ของจริง ตารางประเมิน Confusion Matrix ของ 2 Class จะได้ตารางเมทริกซ์ 2×2 ดังแสดงในรูปที่ 2.44 แต่ถ้ระบบ Classification 3 Class เช่น ทำนายว่าเป็น Rail Head, Rail Web, Rail Foot จะได้ตาราง 3×3 แต่ละช่องของตารางสำหรับใส่จำนวน ผลลัพธ์ที่ได้จากการทำนายและค่าของจริง นั่นคือต้องผ่านขั้นตอนการทำนายแล้ว (Predicted) ได้ผลลัพธ์แล้ว ก็นำจำนวนผลลัพธ์ที่ได้การทำนายและของจริงมารอกลงในตาราง การกรอกใส่จำนวน ให้ทำในลักษณะ 2 มิติ โดยฝั่งซ้ายอ่านค่าทิศทางแนวนอนไปทางขวา จะแสดงค่าจริง (Actual) หมายถึง Class /Label ของจริง ส่วนด้านบนอ่านแนวตั้งลงมาจะแสดงผล (Output) ที่ระบบหรือ Model ทำนายออกมา ความหมายในแต่ละช่อง สำหรับ Confusion Matrix มีดังนี้ [47]

		Predicted Class		
		Positive	Negative	
Actual Class	Positive	True Positive (TP)	False Negative (FN) Type II Error	Sensitivity $\frac{TP}{(TP + FN)}$
	Negative	False Positive (FP) Type I Error	True Negative (TN)	Specificity $\frac{TN}{(TN + FP)}$
		Precision $\frac{TP}{(TP + FP)}$	Negative Predictive Value $\frac{TN}{(TN + FN)}$	Accuracy $\frac{TP + TN}{(TP + TN + FP + FN)}$

รูปที่ 2.44 ตารางขนาด Confusion Matrix 2×2

True Positive (TP) คือ ทำนายถูกต้องสำหรับผลในทางบวก ในทาง Machine Learning ถือว่า ให้ผลทำนายถูกในทางบวก หรือ TP

True Negative (TN) คือ ทำนายถูกต้องสำหรับผลในทางลบ ในทาง Machine Learning ถือว่า ให้ผลทำนายถูกในทางลบ หรือ TN

False Positive (FP) คือ ทำนายผิด โดยให้ผลเป็นบวก (ของจริงไม่ใช่ แต่บอกว่าใช่) สรุปได้ว่า ให้ผลการทำนายผิด เรียกว่า FP

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

False Negative (FN) คือ ทำนายผิด โดยให้ผลเป็นลบ (ของจริงใช่ แต่บอกไม่ใช่) สรุปได้ว่า ให้ผลการทำนายผิด เรียกว่า FN

ซึ่งค่าต่างๆที่ได้จากตาราง Confusion Matrix สามารถใช้ในการคำนวณหาค่า Accuracy, Precision, Recall และ F1 score ของโมเดล

Accuracy คือ สัดส่วนเปอร์เซ็นต์ถูกต้อง คือ จำนวนที่ทำนายถูก/จำนวนทั้งหมด สูตรการคำนวณดังแสดง

$$\text{Individual - class Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.3)$$

Precision คือ ความแม่นยำผลทำนาย จำนวนโดยสัดส่วนที่ทำนายว่าเป็น Positive กับ Negative ก็เปอร์เซ็นต์ สูตรการคำนวณดังแสดง

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.4)$$

Recall คือ การวัดความแม่นยำอีกมิติ ที่สนใจผลลัพธ์เทียบกับที่เป็นของจริง (Actual) สูตรการคำนวณดังแสดง


$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.5)$$

F1 Score คือ ค่าที่แสดงประสิทธิภาพ โดยการนำ Precision กับ Recall มาคำนวณหาค่าเฉลี่ย (ในทางเทคนิคเรียกว่า Harmonic mean) ซึ่งค่าสูงๆ ถือว่าโมเดลมีประสิทธิภาพดี สูตรการคำนวณดังแสดง

$$\text{F1 Score} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.6)$$

2.17 Receiver Operating Characteristic curve (ROC curve)

ROC curve มาจากคำว่า Receiver Operating Characteristic curve เป็นตัวชี้วัดที่บอกความสามารถว่า Model สามารถจำแนกแยกแยะ (classify) 2 กลุ่มออกจากกันได้ดีแค่ไหน และยังสามารถใช้บอกจุดตัด (Cut-off) ที่เหมาะสมที่สุดเพื่อให้ได้ผลการจำแนกหรือทำนายได้แม่นยำที่สุดอีกด้วย ส่วน AUC มาจากคำว่า Area Under the Curve คือค่าพื้นที่ใต้เส้น ROC curve ใช้เป็นตัวชี้วัดบอกประสิทธิภาพของ Model ROC Curve และ AUC มีลักษณะเป็นกราฟดังรูปที่ 2.45



รูปที่ 2.45 Model ROC Curve และ AUC

กราฟ ROC curve ได้จากการพล็อตแกน x คืออัตรา False Positive Rate (FPR ทำนายผิดว่าเป็น Positive) และแกน y คือ True Positive Rate (TPR ทำนายถูกต้องว่าเป็น Positive) ณ จุดหรือค่าเกณฑ์ตัดสิน (เรียกว่าค่า Threshold จะอธิบายภายหลัง) โดยสูตร มีดังนี้

$$\text{True positive rate (TPR)} = \frac{TP}{TP + FN} \quad (2.7)$$

$$\text{False positive rate (FPR)} = \frac{FP}{TN + FP} \quad (2.8)$$

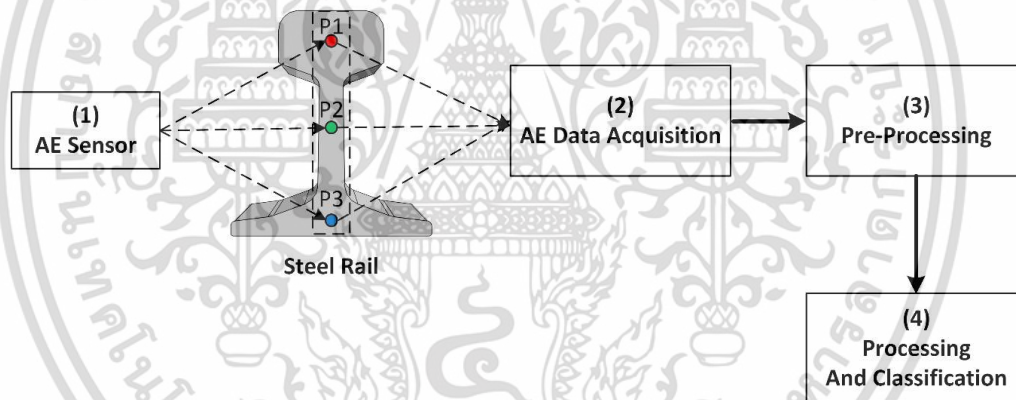
ค่าความไว (Sensitivity) คือ ค่าแสดงความสามารถในกาตรวจจับ Positive และค่าความจำเพาะ (Specificity) คือ ค่าแสดงความสามารถในการบอกได้ว่าเป็น Negative

บทที่ 3

ระเบียบวิธีวิจัย

3.1 ระบบวิธีการวิจัย

เนื้อหาในหัวข้อนี้เราจะกล่าวถึงวิธีการศึกษาวิจัยในหัวข้อการวิเคราะห์ความเสียหายของรางรถไฟ (Rail Defects) ด้วยการใช้หลักการการคูดสติกอิมิชชั่น (Acoustic Emission) ภายใต้ภาระในขณะรถไฟกำลังปฏิบัติงาน เพื่อหาตำแหน่งรอยบกพร่องที่เกิดขึ้นที่ตำแหน่ง หัวราง (Rail Head), เอวราง (Rail Web) และ ฐานราง (Rail Foot) ซึ่งจะทำการสร้างโมเดลโดยมีข้อมูลทั้งหมด 450 ชุดข้อมูล โดยแบ่งจำนวนข้อมูลออกเป็น 2 ชุดข้อมูล ได้แก่ 150 และ 300 ชุดข้อมูล เพื่อทำการเปรียบเทียบความแม่นยำในการทำนายของโมเดล 150 ชุดข้อมูล และ 300 ชุดข้อมูล โดยการใช้หลักการเรียนรู้เชิงลึก (Deep Learning) โดยจะทำการคำนวณเพื่อค้นหาตำแหน่งของรอยบกพร่องที่เกิดขึ้นที่ตำแหน่งต่างๆของรางรถไฟ ดังแสดงในรูปที่ 3.1 โดยในตารางที่ 3.1 แสดงคุณสมบัติของอุปกรณ์ที่ใช้ในการวิจัย



รูปที่ 3.1 ระบบการเก็บข้อมูลสัญญาณคูดสติกอิมิชชั่นจากตำแหน่งรอยบกพร่องที่เกิดขึ้นที่ตำแหน่งต่างๆของรางรถไฟ โดยการใช้หลักการเรียนรู้เชิงลึก (Deep Learning) เพื่อหาระบุตำแหน่ง

ตารางที่ 3.1 คุณสมบัติของอุปกรณ์หลักที่ใช้ในการวิจัย

อุปกรณ์ที่ใช้	ชื่อโมเดลของอุปกรณ์	รายละเอียดของอุปกรณ์
หัววัดคูดสติกอิมิชชั่น	Vallen, VS150-RIC	Frequency Range (fPeak) : 100 – 450 kHz.
ตัวเก็บข้อมูลสัญญาณคูดสติกอิมิชชั่น	Valle, AMSY-6	ASIP-2 Dual channel (4 Channel), TR-2/512MB Transient recorder module for ASIP-2.

3.2 หัววัดอคูสติกอิมิชัน (Acoustic Emission Sensor)

หัววัดอคูสติกอิมิชันในการทดลองทำหน้าที่เปลี่ยนพลังงานกลของคลื่นเสียงเป็นพลังงานไฟฟ้า เป็นแบบสัมผัส (Contact) โดยมีย่านในการรับความถี่ของคลื่นเสียงตั้งแต่ 100 kHz ถึง 400 kHz เนื่องจากความถี่ธรรมชาติรอยบกพร่องของรางรถไฟจะอยู่ที่ช่วงความถี่ประมาณ 150 kHz โดยหัววัดชนิดนี้จะติดตั้งโดยการสัมผัสกับรางรถไฟที่จะทดสอบโดยตรง โดยก่อนติดตั้งจะใช้สารช่วยสัมผัส (Couplant) ในการช่วยให้การส่งผ่านคลื่นเสียงจากรางรถไฟมายังหัววัด อคูสติกอิมิชันได้ดียิ่งขึ้น โดยชนิดของสารช่วยสัมผัสจะเป็นชนิดเดียวกันกับการตรวจสอบคลื่นเสียงความถี่สูง (Ultrasonic Testing) แต่จะต้องพิจารณาอุณหภูมิที่ใช้ในการตรวจสอบประกอบในการเลือกใช้ชนิดของสารช่วยสัมผัสด้วย

การปล่อยอคูสติกอิมิชันจากรอยบกพร่องเป็นคลื่นยืดหยุ่นชั่วคราวในของแข็งที่เกิดขึ้นเมื่อโครงสร้างภายในของวัสดุเกิดการเสียรูปเนื่องจากการเปลี่ยนรูปแบบพลาสติก (Plastic deformation) จากการขยายตัวของรอยบกพร่องในรางรถไฟที่เกิดจากความเมื่อยล้า งานวิจัยนี้มุ่งเน้นไปที่สัญญาณอคูสติกอิมิชันที่เกิดจากการแตกเมื่อยล้าในรางรถไฟภายใต้ภาวะ

หัววัดอคูสติกอิมิชันที่ใช้ในงานวิจัย ยี่ห้อ Vallen รุ่น VS150-RIC ที่มีแบนด์วิดท์ 80 kHz - 500 kHz และอุณหภูมิในการทำงาน -40°C ถึง $+85^{\circ}\text{C}$ ความถี่ธรรมชาติอยู่ที่ 150 kHz ดังแสดงในรูปที่ 3.2

หัววัดอคูสติกอิมิชันถูกใช้เพื่อตรวจจับสัญญาณอคูสติกอิมิชัน (คลื่นเสียงแบบยืดหยุ่น) ในรางรถไฟ อคูสติกอิมิชันเซ็นเซอร์ที่ใช้งานเป็นประเภทเพียโซอิเล็กทริก เพื่อแปลงคลื่นเสียงแบบยืดหยุ่นในรางรถไฟเป็นสัญญาณไฟฟ้า เพื่อลดผลกระทบของไตรโบอิเล็กทริก (Trieboelectric) ของหัววัดอคูสติกอิมิชันในการตรวจสอบสภาพสนามของงานวิจัยนี้ จึงเลือกใช้คูสติกอิมิชันเซ็นเซอร์เพียโซอิเล็กทริกอิเล็กทรอนิกส์แบบ IEPE ในตัว ซึ่งหากเลือกใช้หัววัดอคูสติกอิมิชันที่ไม่ใช่แบบ IEPE จะมีแนวโน้มที่จะเกิดผลกระทบจากไตรโบอิเล็กทริก (Trieboelectric) เพื่อลดผลกระทบจากไตรโบอิเล็กทริก (Trieboelectric) เพิ่มเติมในช่วงความถี่ที่ใช้งาน ได้เพิ่มตัวกรองความถี่แบบแบนด์พาสในช่วงความถี่ 95 kHz - 300 kHz



รูปที่ 3.2 หัววัดอคูสติกอิมิชัน

3.3 ชุดเก็บข้อมูลสัญญาณอคูสติกอิมิชัน (AE Data Acquisition)


ทำหน้าที่เปลี่ยนสัญญาณจากอนาล็อก (Analog) จากหัววัดอคูสติกอิมิชัน เป็นสัญญาณในรูปแบบดิจิทัล (Digital) โดยจะประมวลผลสัญญาณอคูสติกอิมิชันจากการตรวจสอบให้อยู่ในรูปแบบของอคูสติกพารามิเตอร์ (AE Parameter) แต่สำหรับงานวิจัยนี้มีการบันทึกข้อมูลสัญญาณทางโดเมนเวลา เพื่อใช้สำหรับนำไปวิเคราะห์หาค่าคุณลักษณะของสัญญาณอคูสติกอิมิชันจากตำแหน่งรอยบกร่องที่เกิดขึ้นที่หัวราง (Rail Head), เหวราง (Rail Web) และ ฐานราง (Rail Foot) ดังแสดงในรูปที่ 3.3



รูปที่ 3.3 ชุดเก็บข้อมูลสัญญาณอคูสติกอิมิชัน รุ่น AMSY-6

3.4 โครงสร้างการเรียนรู้เชิงลึก (Structure of Deep Learning)

ในรูปที่ 3.4 แสดงให้เห็นถึงโครงสร้างการเรียนรู้เชิงลึกและอัลกอริทึมการเรียนรู้เชิงลึกทั่วไปสำหรับการจำแนกประเภท ซึ่งประกอบด้วยชั้นอินพุต (คุณลักษณะ) ชั้นที่ซ่อนอยู่ในชั้นต่างๆจนถึงชั้นที่ซ่อนอยู่จำนวน N ชั้น ชั้นเอาต์พุต (เป้าหมาย) ในงานวิจัยนี้ฟังก์ชันกระตุ้น (Activation function) ระหว่างชั้นที่ซ่อนอยู่คือฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ ($\tanh(z)$) เนื่องจากเป็นฟังก์ชันนี้เหมาะสมอย่างยิ่งสำหรับลักษณะสัญญาณอคูสติกอิมิชันแบบชั่วคราว (Transient) และสามารถลดเสียงรบกวนและสัญญาณรบกวนได้ ฟังก์ชันการใช้งาน softmax ($\text{softmax}(z)$) ถูกใช้สำหรับการจำแนกประเภท โดยหลักการความน่าจะเป็น จุดมุ่งหมายของอัลกอริทึมการเรียนรู้เชิงลึกสำหรับการจำแนกประเภทตำแหน่งรอยบกร่องในหัวราง (Rail Head), เหวราง (Rail Web) และ ฐานราง (Rail Foot)



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.4 แผนภาพการเรียนรู้เชิงลึกสำหรับการจำแนกประเภท

3.5 วัสดุสำหรับการทดลองและการตั้งค่า (Experimental material and setup)

3.5.1 รางรถไฟ (Experimental steel rail)

รางรถไฟสำหรับการวิจัยเป็นประเภท UIC 54 ซึ่งเป็นรางรถไฟที่ใช้กันทั่วไปในประเทศในภูมิภาคเอเชียตะวันออกเฉียงใต้รวมถึงประเทศไทย องค์ประกอบองค์ประกอบของรางรถไฟชนิด UIC 54 ได้ทำการวิเคราะห์ส่วนประกอบทางเคมีโดยเครื่องวิเคราะห์สเปกโทรสโกปี (spectroscopy) (LIBS) ที่อาศัยหลักการเหนี่ยวนำด้วยเลเซอร์ (laser induced breakdown spectroscopy) แบบพกพา ยี่ห้อ SciAps, รุ่น Z-300 ตารางที่ 3.2 แสดงส่วนประกอบทางเคมีของรางรถไฟชนิด UIC 54 ดังแสดงในตารางที่ 3.2

ตารางที่ 3.2 องค์ประกอบทางเคมีของเหล็กรางรถไฟชนิด UIC 54

%C	%Si	%Mn	%V	%Ni	%Cu
0.68	0.22	1.18	0.003	0.0068	0.0109

3.5.2 อคูสติคเซ็นเซอร์และชุดเก็บข้อมูล (AE data sensor and acquisition module)

รูปที่ 3.5 (ก) แสดงโมดูลการรับข้อมูล AE พร้อม ADC 16 บิต และอัตราการสุ่มตัวอย่าง 20 MHz (Vallen AMSY-6) รูปที่ 3.5 (ข) แสดงหัววัดคูสติกอิมิชชัน (S/N 10453) ที่มีแบนด์วิดท์ 80 KHz - 500 KHz และอุณหภูมิในการทำงาน -40°C ถึง $+85^{\circ}\text{C}$ (ยี่ห้อVallen รุ่น VS150-RIC) ตัวยึดสำหรับหัววัดคูสติกอิมิชชันแบบแม่เหล็ก MAG4R ถูกใช้เพื่อยึดติดหัววัดคูสติกอิมิชชันเข้ากับรางรถไฟ (ที่ด้านสนามของตำแหน่งหัวราง)

แหล่งกำเนิด Hsu-Nielsen ถูกนำมาใช้เป็นแหล่งกำเนิดสัญญาณคูสติกอิมิชชัน (Artificial source) ประกอบด้วยไส้ดินสอด 2H (0.5 มม.) โดยไส้ดินสอดจะหักที่ตำแหน่ง หัวราง (Rail Head), เอวราง (Rail Web) และ ฐานราง (Rail Foot) ที่มีมุม 30° ในแนวระนาบ ตามมาตรฐาน ASTM E976



(ก)



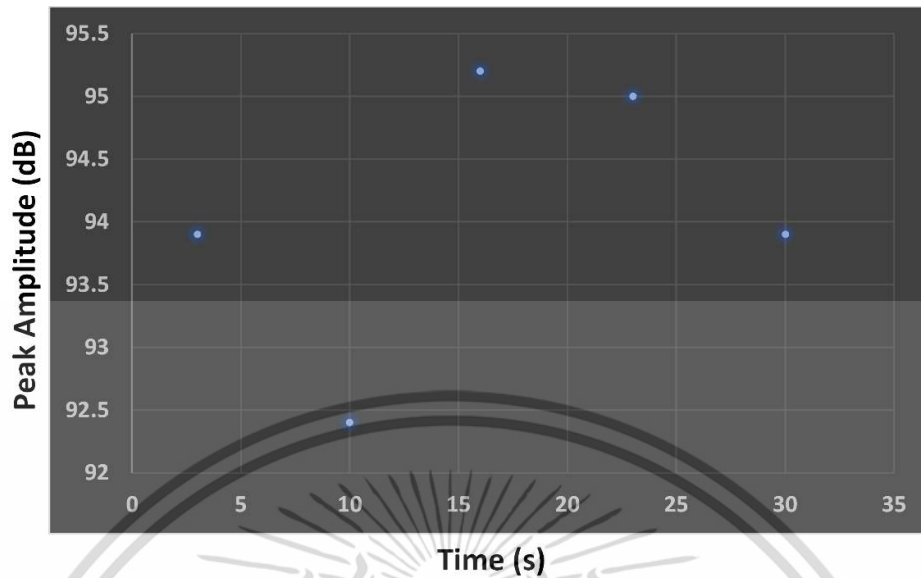
(ข)

รูปที่ 3.5 หัววัดคอสติกอิมิชันและชุดเก็บข้อมูลสัญญาณคอสติกอิมิชัน (ก) ชุดเก็บข้อมูลของสัญญาณคอสติกอิมิชัน (ข) หัววัดคอสติกอิมิชัน, ชุดจับยึดแบบแม่เหล็ก (MAG4R) และ Hsu-Nielsen source

3.5.3 การทดสอบแอมพลิจูดของหัววัดคอสติกอิมิชัน (AE sensor amplitude testing)

ก่อนการนำหัววัดคอสติกอิมิชันไปใช้งานต้องมีการทดสอบเพื่อให้มั่นใจว่ายังสามารถใช้งานได้ตามปกติ โดยการทดสอบหัววัดคอสติกอิมิชันจะนำไปติดตั้งที่ตำแหน่งหัวรางและทำการทดสอบโดยการหักไส้ดินสอ มีความแข็งของไส้ดินสอ 2H (0.5 มม.) กับรางรถไฟที่ระยะคงที่จำนวนทั้งหมด 5 ครั้ง และหาค่าเฉลี่ยของผลทดสอบ

รูปที่ 3.6 แสดงแอมพลิจูดสูงสุด (dB) ของหัววัดคอสติกอิมิชันเทียบกับ เวลา (s) จากผลลัพธ์ดังแสดงในตารางที่ 3.3 ค่าแอมพลิจูดสูงสุดสูงสุดของหัววัดคอสติกอิมิชันซึ่งจากการทดสอบมีค่ามากกว่า 80 dB (> 80 dB) ซึ่งระบุว่าได้ว่าการติดตั้งสมบูรณ์และสามารถติดตั้งหัววัดคอสติกอิมิชันเพื่อตรวจสอบสัญญาณคอสติกอิมิชันเพื่อทดสอบหารอยบกพร่องในรางรถไฟได้




รูปที่ 3.6 พีคแอมพลิจูดของอคูสติกอิมิชชันเซ็นเซอร์ (dB) เทียบกับเวลา (s)

ตารางที่ 3.3 พีคแอมพลิจูดและค่าเฉลี่ยแอมพลิจูดของอคูสติกอิมิชชันเซ็นเซอร์

Sensor S/N	1 st PLB	2 nd PLB	3 rd PLB	4 th PLB	5 th PLB	Average
10453	93.90	92.40	95.20	95.00	93.90	94.08

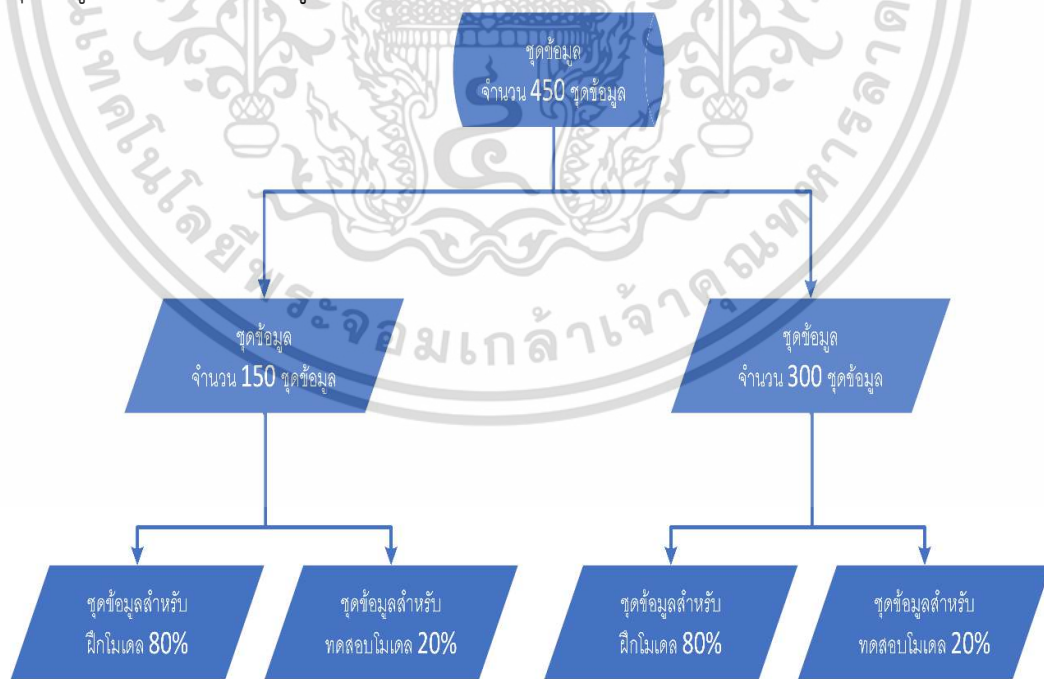
3.5.4 การเตรียมชุดข้อมูลเพื่อสำหรับการฝึกโมเดล (Training) และการทดสอบโมเดล (Testing) สำหรับการเรียนรู้เชิงลึก (Datasets for training and testing the deep learning algorithmic model)

ในการเตรียมชุดข้อมูล (Dataset) เพื่อสำหรับการฝึกโมเดล (Training) และการทดสอบโมเดล (Testing) ในงานวิจัยนี้ใช้วิธีการหักไล่ดินสอ (PLB) ตามมาตรฐาน ASTM E976 เพื่อสร้างสัญญาณอคูสติกจำลอง (Artificial acoustic emission signal) ของสัญญาณอคูสติกอิมิชชันที่เกิดจากรอยบกพร่องที่ตำแหน่งต่างๆของรางรถไฟที่ส่วนหัวราง (Rail Head), เหวราง (Rail Web) และฐานราง (Rail Foot) เพื่อใช้เป็นชุดข้อมูลสำหรับการเทรนโมเดลและการทดสอบโมเดลแบบจำลองอัลกอริธึมการเรียนรู้เชิงลึกโดยเก็บข้อมูลของสัญญาณอคูสติกจำลอง (Artificial acoustic emission signal) จำนวนทั้งหมด 450 ชุดข้อมูล ที่ส่วนหัวราง (Rail Head), เหวราง (Rail Web) และฐานราง (Rail Foot) ของรางรถไฟ (รูปที่ 3.7)



รูปที่ 3.7 ตำแหน่งของการหักใส่ดินสอดเพื่อสร้างสัญญาณอคูสติกอิมิชันจำลอง (ก) ที่ตำแหน่งหัวราง (Rail Head) (ข) ที่ตำแหน่งเอวราง (Rail Web) (ค) ที่ตำแหน่งฐานราง (Rail Foot)

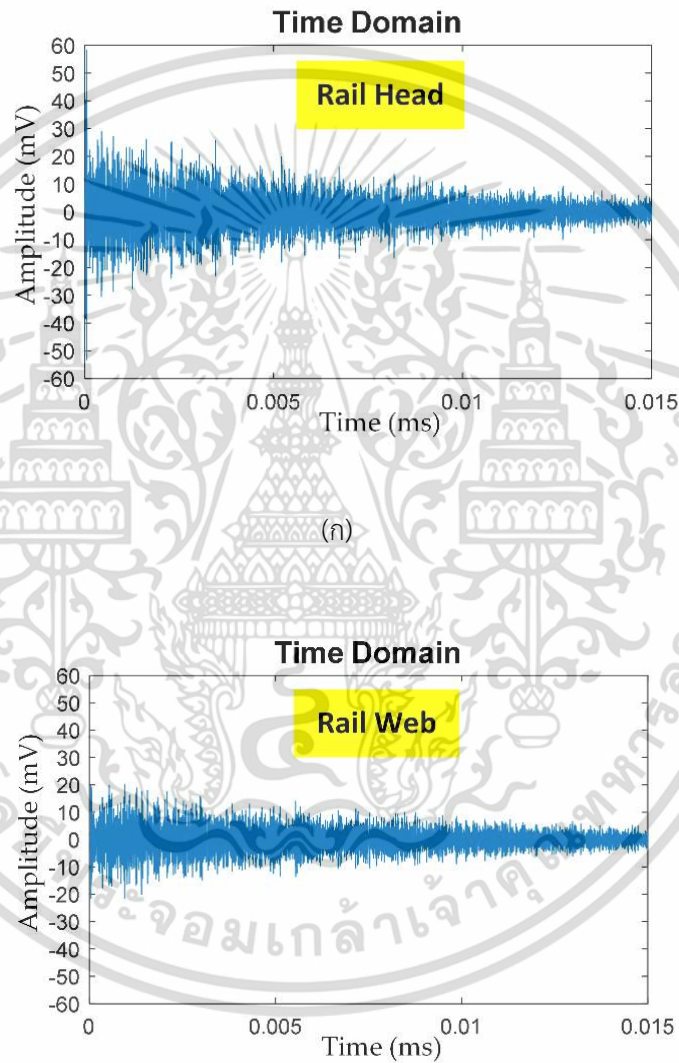
สัญญาณอคูสติกอิมิชันจำลอง (Artificial acoustic emission signal) ที่ได้จากการเก็บข้อมูลจำนวน 450 ชุดข้อมูล ทำการแบ่งออกเป็นสองกลุ่มคือ 150 ชุดข้อมูล และ 300 ชุดข้อมูล เพื่อตรวจสอบผลความแม่นยำในการทำนายของโมเดลอัลกอริธึมการเรียนรู้เชิงลึกของสแกกลุ่มข้อมูล ภายใต้การจัดกลุ่มแรก 150 ชุดข้อมูล ข้อมูลอินพุตจะถูกแบ่งออกเป็นชุดข้อมูลสำหรับการฝึกโมเดล 80% ของชุดข้อมูลอินพุต และชุดข้อมูลการทดสอบ 20% และการจัดกลุ่มที่สอง 300 ชุดข้อมูล ข้อมูลอินพุต 80% เป็นชุดข้อมูลการเทรนโมเดลและเป็นการทดสอบชุดข้อมูล 20% เป็นการทดสอบชุดข้อมูลเช่นกัน ดังแสดงในรูป 3.8



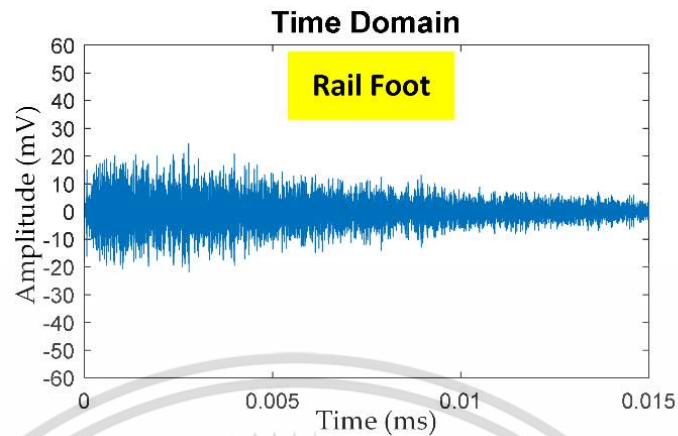
รูปที่ 3.8 การแบ่งกลุ่มชุดข้อมูลสำหรับการฝึกโมเดลและการทดสอบโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นอนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

จากรูปที่ 3.9 (ก) - (ค) แสดงสัญญาณอคูสติกอิมพัลส์จำลองของการหักเสียดินสอ (PLB) ที่ตำแหน่งหัวราง (Rail Head), เเวราง (Rail Web) และฐานราง (Rail Foot) ของรางรถไฟ โดยสัญญาณอคูสติกอิมพัลส์จำลองของการหักเสียดินสอ (PLB) ที่รับจากหัววัดอคูสติกอิมพัลส์ (AE Sensor) ก่อนทำการกำจัดสัญญาณรบกวนโดยอัลกอริธึมการกำจัดสัญญาณรบกวนในงานวิจัยนี้เลือกใช้แบบ TVD เพื่อลดสัญญาณรบกวนรอบข้างต่างๆในห้องปฏิบัติการ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




(ค)

รูปที่ 3.9 สัญญาณอคูสติกอิมพัลส์จําลองที่ยังไม่ถูกกําจัดสัญญาณรบกวนที่ตำแหน่งของรางรถไฟ (ก) ที่ตำแหน่งหัวราง (Rail Head) (ข) ที่ตำแหน่งเอวราง (Rail Web) (ค) ที่ตำแหน่งฐานราง (Rail Foot)

3.6 การลดสัญญาณรบกวน (Noise reduction)


สัญญาณอคูสติกอิมพัลส์ที่เก็บข้อมูลจากในห้องปฏิบัติการหรือการทดสอบภาคสนาม จะมีสัญญาณรบกวนในสภาวะแวดล้อมต่างๆและสัญญาณรบกวนในขณะรถไฟวิ่งผ่านรวมกับสัญญาณอคูสติกอิมพัลส์ที่เกิดจากรอยบกพร่อง ซึ่งการ Clean data เพื่อเป็นการเตรียมข้อมูลเพื่อนำไปเป็นชุดข้อมูลสำหรับการฝึกโมเดลและการทดสอบโมเดล ดังแสดงในรูปที่ 3.10




(ก)

(ข)


รูปที่ 3.10 สัญญาณอคูสติกอิมพัลส์ที่กําเนิดจากรอยบกพร่อง (ก) สัญญาณอคูสติกอิมพัลส์ก่อนลดสัญญาณรบกวน (ข) สัญญาณอคูสติกอิมพัลส์หลังลดสัญญาณรบกวน



(ก)



(ข)



(ค)

รูปที่ 3.11 ขั้นตอนการทำ Majorization-minimization (MM) (ก) cost function $F(x)$ ที่กำหนดค่าเริ่มต้นของ x_0 (ข) การวนซ้ำครั้งที่ 1 เมื่อ majorizer $G_0(x)$ คือ tangent to $F(x)$ ที่ x_0 และ minimize $G_0(x)$ ของ x_1 (ค) การวนซ้ำครั้งที่ 2 เมื่อ majorizer $G_1(x)$ คือ tangent to $F(x)$ ที่ x_1 และ minimize $G_1(x)$ ของ x_2


เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

3.7 การแปลงสัญญาณอคูสติกอิมิชชันเป็นชุดข้อมูลแบบจุด

ซึ่งขั้นตอนที่มีความสำคัญอย่างยิ่งก่อนที่จะแปลงข้อมูลจากสัญญาณอคูสติกอิมิชชันเป็นชุดข้อมูลคุณลักษณะ (Feature) เป็นจุดของข้อมูล 300,000 จุด (Data points) ในรูปแบบสเปกตรัมที่กำหนดเป็นค่าอินพุต และเป้าหมาย (Target) ในรูปแบบ one-hot ที่กำหนดเป็นค่าเอาต์พุต

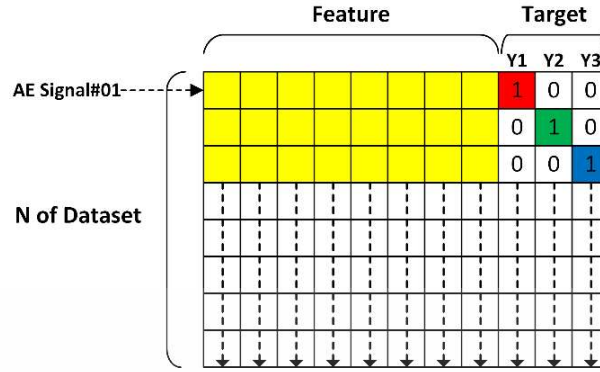
จากรูปที่ 3.12 แสดงถึงขั้นตอนการแปลงสัญญาณอคูสติกอิมิชชันหลังจากการกำจัดสัญญาณรบกวน (AE denoised) ต่างๆในห้องปฏิบัติการ หลังจากนั้นจะนำสัญญาณอคูสติกอิมิชชันจำลองแปลงเป็นจุดของข้อมูล 300,000 จุด (Data points) ต่อหนึ่งสัญญาณอคูสติกอิมิชชันจำลอง เพื่อเป็นชุดข้อมูลคุณลักษณะ (Feature) สำหรับการฝึกโมเดลและการทดสอบโมเดลของอัลกอริธึมการเรียนรู้เชิงลึก ชุดข้อมูลการฝึกโมเดลและการทดสอบถูกแปลงจากสัญญาณอคูสติกอิมิชชันจำลองเป็นรูปแบบของค่าตำแหน่งของข้อมูลในรูปแบบสเปกตรัม ชุดข้อมูลคุณลักษณะ (Feature) แบ่งออกเป็นสองชุด คือ 150 ชุดข้อมูล และ 300 ชุดข้อมูล เพื่อตรวจสอบผลของจำนวนข้อมูลอินพุตที่มีต่อความแม่นยำในการจำแนกประเภทของแบบจำลองอัลกอริธึมการเรียนรู้เชิงลึก

ภายใต้การจัดกลุ่มชุดแรกข้อมูลคุณลักษณะ (Feature) ทั้งหมด 150 ชุดข้อมูล เป็นของการหักได้ดินสอเพื่อสร้างสัญญาณอคูสติกอิมิชชันจำลองที่ตำแหน่งต่างๆ หัวราง (Rail Head), เอรราง (Rail Web) และฐานราง (Rail Foot) จำนวนตำแหน่งละ 50 ชุดข้อมูลของรางรถไฟ ชุดข้อมูลคุณลักษณะ (Feature) แบ่งออกเป็นชุดข้อมูลสำหรับการฝึกโมเดล 80% และชุดข้อมูลสำหรับการทดสอบโมเดล 20% และภายใต้การจัดกลุ่มชุดที่สองข้อมูลคุณลักษณะ (Feature) ทั้งหมด 300 ชุดข้อมูล เป็นของการหักได้ดินสอเพื่อสร้างสัญญาณอคูสติกอิมิชชันจำลองที่ตำแหน่งต่างๆ หัวราง (Rail Head), เอรราง (Rail Web) และฐานราง (Rail Foot) จำนวนตำแหน่งละ 100 ชุดข้อมูลของรางรถไฟ ชุดข้อมูลคุณลักษณะ (Feature) แบ่งออกเป็นชุดข้อมูลสำหรับการฝึกโมเดล 80% และชุดข้อมูลสำหรับการทดสอบโมเดล 20% ด้วยอัตราการสุ่มตัวอย่าง 20 MHz ของการเก็บข้อมูลสัญญาณอคูสติกอิมิชชันจำลอง โดยสัญญาณอคูสติกอิมิชชันจำลองจะมีจุดของข้อมูล 300,000 จุด (Data points) ในรูปแบบสเปกตรัม

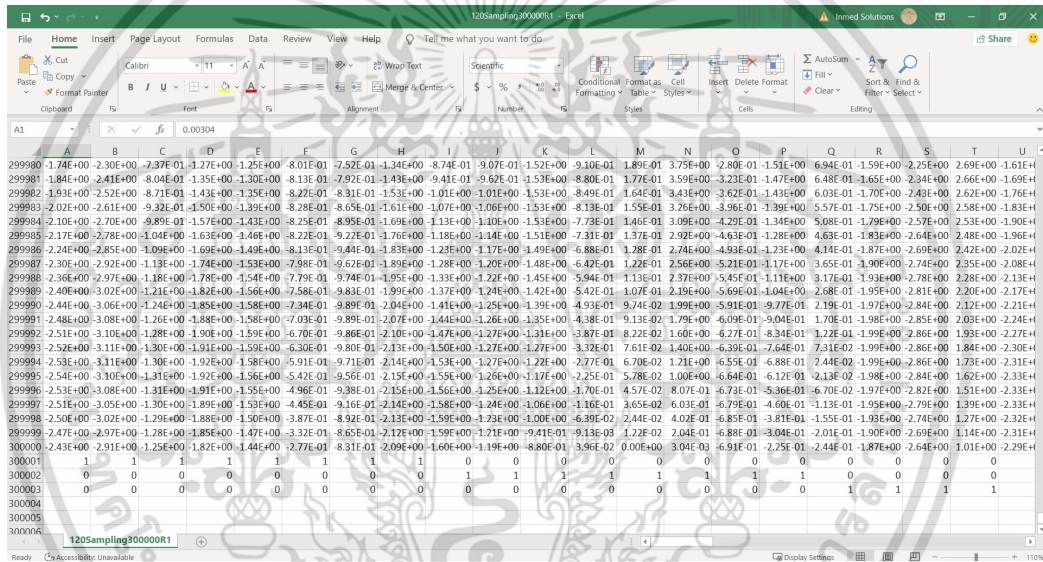


รูปที่ 3.12 แปลงสัญญาณอนุภาคอิมพัลส์จําลองหลังจากการกําจัดสัญญาณรบกวนในห้องปฏิบัติการเป็นจุดของข้อมูล 300,000 จุด (Data points) ในรูปแบบสเปรดชีต

จากรูปที่ 3.13 แสดงชุดข้อมูลคุณลักษณะ (Feature) เป็นจุดของข้อมูล 300,000 จุด (Data points) ในรูปแบบสเปรดชีตที่กำหนดเป็นค่าอินพุต และเป้าหมาย (Target) ในรูปแบบ one-hot ที่กำหนดเป็นค่าเอาต์พุต ในรูปแบบสเปรดชีตสำหรับการฝึกโมเดลและการทดสอบโมเดลของอัลกอริธึมการเรียนรู้เชิงลึก ดังแสดงในรูปที่ 3.14 ในการกําหนดค่าเอาต์พุตเป็นแบบ one-hot ถูกนำไปใช้กับชุดข้อมูลเป้าหมาย (Target) เพื่อกําหนดตำแหน่งต่างๆของสัญญาณอนุภาคอิมพัลส์จําลองของการหักได้ดินดินสอสำหรับการสร้างสัญญาณอนุภาคอิมพัลส์จําลองที่เกิดจากแหล่งกําเนิดรอยบกพร่องที่ตำแหน่งหัวราง (Rail Head), เหวราง (Rail Web) และ ฐานราง (Rail Foot) โดย Y1 มีค่าเป็น 1 คือ สัญญาณอนุภาคอิมพัลส์จําลองที่เกิดจากแหล่งกําเนิดรอยบกพร่องที่ตำแหน่งหัวราง (Rail Head), Y2 มีค่าเป็น 1 คือ สัญญาณอนุภาคอิมพัลส์จําลองที่เกิดจากแหล่งกําเนิดรอยบกพร่องที่ตำแหน่ง เหวราง (Rail Web) และ Y3 มีค่าเป็น 1 คือ สัญญาณอนุภาคอิมพัลส์จําลองที่เกิดจากแหล่งกําเนิดรอยบกพร่องที่ตำแหน่ง ฐานราง (Rail Foot) ตามลำดับ



รูปที่ 3.13 รูปแบบสเปรตชีตของข้อมูลคุณลักษณะ (Feature) และข้อมูลเป้าหมาย (Target)

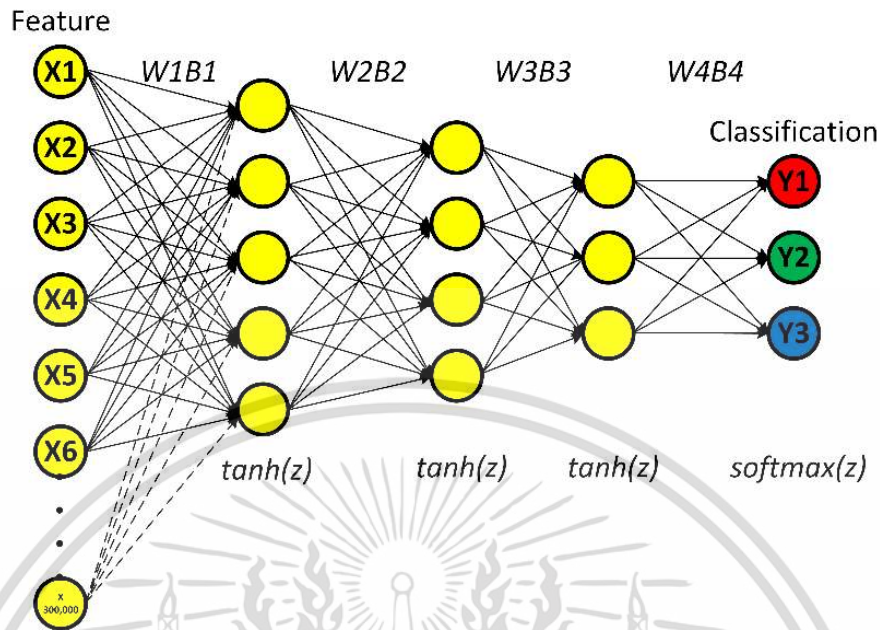


รูปที่ 3.14 สัญญาณอคูสติกอิมิชันเป็นชุดข้อมูลคุณลักษณะ (Feature) เป็นจุดของข้อมูล 300,000 จุด (Data points) ในรูปแบบสเปรตชีต

3.8 การใช้การเรียนรู้เชิงลึกเพื่อจำแนกประเภท (Proposed deep learning algorithm for classification)

จากรูปที่ 3.15 แสดงอัลกอริทึมการเรียนรู้เชิงลึกที่เสนอในงานวิจัยสำหรับการจำแนกประเภทแบบเวกเตอร์ของข้อมูลสัญญาณอคูสติกอิมิชัน เป็นอินพุตของเลเยอร์ (Input Layer) ของข้อมูลคุณลักษณะและสัญญาณอคูสติกอิมิชันจำลองของหนึ่งสัญญาณจะมีข้อมูล 300,000 ในรูปแบบเวกเตอร์ แสดงโดย $X_1, X_2, X_3 \dots X_{300000}$ ในงานวิจัยนี้มีสัญญาณอคูสติกอิมิชันจำลองจำนวนทั้งหมด 450 ชุดข้อมูล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ทางการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้




รูปที่ 3.15 โมเดลการเรียนรู้เชิงลึกสำหรับการจำแนกประเภท

โมเดลอัลกอริทึมที่นำเสนอในงานวิจัยนี้จะประกอบด้วยชั้นที่ซ่อน (Hidden Layer) อยู่สามชั้น และชั้นเอาต์พุตหนึ่งชั้น โดยชั้นแรกของชั้นที่ซ่อน (Hidden Layer) จะมีทั้งหมด 5 โหนด (Node), ชั้นที่สองของชั้นที่ซ่อน (Hidden Layer) จะมีทั้งหมด 4 โหนด (Node) และชั้นสามของชั้นที่ซ่อน (Hidden Layer) จะมีทั้งหมด 3 โหนด (Node) ตามลำดับ ในแต่ละชั้นจะมีฟังก์ชันกระตุ้น (Activation Function) ระหว่างชั้นที่ซ่อนอยู่คือฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ ($\tanh(z)$) ซึ่งมีค่าการเปลี่ยนแปลงของฟังก์ชันนี้ระหว่าง $-1, 1$ ชั้นเอาต์พุตประกอบด้วย Y1 (สัญญาณอนุสติกิมิซชั้นจำลองของรอยบกพร่องที่เกิดขึ้นตำแหน่งหัวราง (Rail Head)), Y2 (สัญญาณอนุสติกิมิซชั้นจำลองของรอยบกพร่องที่เกิดขึ้นตำแหน่งเอวราง (Rail Web)) และ Y3 (สัญญาณอนุสติกิมิซชั้นจำลองของรอยบกพร่องที่เกิดขึ้นตำแหน่งฐานราง (Rail Foot)) ในส่วนของการจำแนกประเภทตามหลักการความน่าจะเป็นของตำแหน่งของการเกิดรอยบกพร่องจะใช้ฟังก์ชัน Softmax ($\text{softmax}(z)$) จุดมุ่งหมายของอัลกอริทึมการเรียนรู้เชิงลึกในงานวิจัยนี้ เพื่อสำหรับการจำแนกประเภทของแหล่งกำเนิดสัญญาณอนุสติกิมิซชั้นของรอยบกพร่องที่ตำแหน่งหัวราง (Rail Head) หรือ (Y1), สัญญาณอนุสติกิมิซชั้นของรอยบกพร่องที่ตำแหน่งเอวราง (Rail Web) หรือ (Y2) และสัญญาณอนุสติกิมิซชั้นของรอยบกพร่องที่ตำแหน่งฐานราง (Rail Foot) หรือ (Y3) โดยใช้หัววัดอนุสติกิมิซชั้นเพียงหนึ่งหัววัด ซึ่งแตกต่างจากหลักการเดิมที่จำเป็นต้องใช้หัววัดอนุสติกิมิซชั้นอย่างน้อย 2 หัววัด เพื่อระบุหาตำแหน่งต่างๆของแหล่งกำเนิดสัญญาณอนุสติกิมิซชั้นของรอยบกพร่องในรางรถไฟ

3.9 การฝึกโมเดลและทดสอบโมเดลของอัลกอริธึมการเรียนรู้เชิงลึก

จากรูปที่ 3.16 แสดงขั้นตอนการฝึกโมเดลและทดสอบโมเดลของอัลกอริธึมการเรียนรู้เชิงลึกที่นำเสนองานวิจัยและการตรวจสอบโมเดล ชุดข้อมูลสัญญาณอคูสติกอิมิชชันจากการหักไล่ดินสอเพื่อสร้างสัญญาณอคูสติกอิมิชชันจำลองของแหล่งกำเนิดจากรอยบกพร่อง ชุดข้อมูลคุณลักษณะ (Feature) และชุดข้อมูลเป้าหมาย (Target) แบ่งออกเป็นชุดข้อมูลสำหรับการฝึกโมเดลจำนวน 80% ของจำนวนทั้งหมดของชุดข้อมูล และชุดข้อมูลการทดสอบโมเดลจำนวน 20% ของทั้งหมดของชุดข้อมูล



รูปที่ 3.16 ขั้นตอนการฝึกโมเดล (Training) และทดสอบโมเดล (Testing) สำหรับการเรียนรู้เชิงลึก

ก่อนการเทรนอัลกอริทึม (Algorithm training) และการตรวจสอบความถูกต้องข้อมูลอินพุต (คุณลักษณะ) จะถูกปรับขนาดโดยใช้การกำหนดมาตรฐาน (Z-score) เพื่อให้เป็นมาตรฐานดังแสดงในสมการ (3.4)

$$\text{Standardization (Z - score)} = \frac{X - \text{Mean } X}{SD} \quad (3.4)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เมื่อ X คือ คุณลักษณะ (Feature) ที่เป็นข้อมูลอินพุต, $Mean X$ คือ ค่าเฉลี่ยของข้อมูลคุณลักษณะ และ SD คือ ค่าเบี่ยงเบนมาตรฐาน

โดยข้อมูลสำหรับฝึกให้กับโมเดลก่อนทำการแปลงให้เป็นเมตริกซ์และยังไม่ได้ปรับช่วงข้อมูล ในรูปแบบสเปรดชีตสำหรับการฝึกโมเดลและการทดสอบโมเดลของอัลกอริธึมการเรียนรู้เชิงลึก ดังแสดงในรูปที่ 3.17 (ก) และข้อมูลสำหรับฝึกให้กับโมเดลหลังจากทำการแปลงให้เป็นเมตริกซ์และปรับช่วงข้อมูลแล้ว ดังแสดงในรูปที่ 3.17 (ข)

(ก)

```
In [121]: 1 X_Train_Norm
Out[121]: array([[[-7.45650442e-01, -6.81844715e-01, -3.19815511e-01, ...,
-8.19427197e-01, -7.81723509e-01, -7.37684971e-01],
[ 3.72136552e-01, 3.75416518e-01, 3.65261990e-01, ...,
-1.19442093e+00, -1.20562585e+00, -1.21296491e+00],
[-5.10125499e-05, 2.33821100e-02, 2.27232395e-02, ...,
-1.61832688e+00, -1.62121639e+00, -1.62034772e+00],
...,
[ 7.45548417e-01, 7.28608934e-01, 7.08927513e-01, ...,
-8.60187386e-01, -8.48217995e-01, -8.31043531e-01],
[-3.72238577e-01, -3.28652298e-01, -3.19815511e-01, ...,
-1.58571873e+00, -1.55472190e+00, -1.51001488e+00],
[-5.10125499e-05, 2.33821100e-02, 2.27232395e-02, ...,
1.71585650e+00, 1.65197466e+00, 1.57845604e+00]])

In [227]: 1 X_Train_Norm.shape
Out[227]: (120, 299999)
```

(ข)

รูปที่ 3.17 (ก) ตัวอย่างข้อมูลสำหรับฝึกให้กับโมเดลก่อนทำการแปลงให้เป็นเมตริกซ์และยังไม่ได้ปรับช่วงข้อมูล (ข) ตัวอย่างข้อมูลสำหรับฝึกให้กับโมเดลหลังจากทำการแปลงให้เป็นเมตริกซ์และปรับช่วงข้อมูลแล้ว

ชุดข้อมูลการฝึกโมเดลประกอบด้วย X_Train (ชุดข้อมูลคุณลักษณะ/อินพุต) และ Y_Train (ชุดข้อมูลเป้าหมาย/เอาต์พุต) ในขณะที่ชุดข้อมูลการทดสอบโมเดลประกอบด้วย X_Test (ชุดข้อมูลคุณลักษณะ) และ Y_Test (ชุดข้อมูลเป้าหมาย) ค่าน้ำหนักเริ่มต้น (Weight (W)) และความลำเอียง (Bias (B)) ในเลเยอร์ที่ซ่อนอยู่ ($B_0, W_1, B_1, W_2, B_2, W_3, B_3$) ในครั้งแรกจะเป็นแบบสุ่ม (Random)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

โดยให้อัตราการเรียนรู้ (Learning Rate) (α) กำหนดค่า 0.1 และการวนรอบ (Epoch) จำนวน 1,000 รอบ

ในการฝึกพอร์เวิร์ดเป็นฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ (Hyperbolic tangent function ($\tanh(z)$) เป็นฟังก์ชันกระตุ้น (Activation function) ระหว่างเลเยอร์ที่ซ่อนอยู่ดังแสดงในสมการ (3.5) โดยที่ $\tanh(z) = [-1, 1]$ ชั้นเอาต์พุตใช้ softmax (z) เป็นฟังก์ชันกระตุ้น (Activation function) สำหรับการจำแนกแยกแยะที่ใช้หลักการความน่าจะเป็น (Probability) จะเป็นดังแสดงในสมการ (3.6) และการรวมกันเชิงเส้น (Linear combination) ดังแสดงในสมการ (3.7)

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \quad (3.5)$$

$$\text{softmax}(z) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \quad (3.6)$$

$$Z = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix} = \begin{bmatrix} x_1^1 w_1 & x_1^2 w_2 & \dots & x_1^D w_D \\ x_2^1 w_1 & x_2^2 w_2 & \dots & x_2^D w_D \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 w_1 & x_N^2 w_2 & \dots & x_N^D w_D \end{bmatrix} + [B_1 \quad B_2 \quad \dots \quad B_D] \quad (3.7)$$

อนุพันธ์ย่อยของฟังก์ชันไฮเพอร์โบลิกแทนเจนต์ ($\tanh(z)$) ถูกใช้ในการแพร่กระจายกลับ (Back propagation) ดังแสดงในสมการ (3.8)

$$\frac{\partial[\tanh(z)]}{\partial z} = 1 - \tanh^2(z) = \text{sech}^2(z) \quad (3.8)$$

Cross entropy loss function สำหรับหลายคลาส (Multi class) ถูกนำมาใช้เพื่อปรับแต่งการเพิ่มประสิทธิภาพสำหรับการเทรนโมเดลดังแสดงในสมการ (3.9)

$$J(w) = -\frac{1}{N} \sum_{n=1}^N (Y_n \log(\hat{Y}_n)) \quad (3.9)$$

โดย Y_n คือ ค่าเอาต์พุตจริง (true output value) และ \hat{Y}_n ค่าเอาต์พุตพยากรณ์ (predicted output value)

ในขั้นตอนการฝึกโมเดลและการทดสอบโมเดลมีการกำหนดมาตรฐาน L1-norm ถูกนำมาใช้เพื่อหลีกเลี่ยง Over fitting มากเกินไปเนื่องจากจุดข้อมูลที่มีจำนวนมากเกินไป (จุดข้อมูล 300,000 จุด ต่อหนึ่งสัญญาณอคูสติคมิชชั่น) และการสูญเสียเอนโทรปีข้าม (Cross entropy loss) นำมาใช้ในปรับจูนของการชุดข้อมูลฝึกโมเดล

ผลการฝึกโมเดลของแบบจำลองอัลกอริทึมที่ปรับให้เหมาะสม (Y_{Predict}) จะถูกนำไปเปรียบเทียบกับชุดข้อมูลการฝึกโมเดล (Y_{Train}) และ เป้าหมาย (Target) ของการทดสอบโมเดล

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นิยมนำไปใช้ประโยชน์ด้านการค้า ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

(Y_Test) เพื่อประเมินประสิทธิภาพของอัลกอริทึมการเรียนรู้เชิงลึกที่นำมาใช้ในการวิจัยได้แก่ ROC Curve, Confusion Matrix และ F1 Score และ Total Accuracy

3.6 การประเมินผลของการเรียนรู้เชิงลึก (Evaluation of the deep learning algorithm)

ประสิทธิภาพการจำแนกประเภทของแบบจำลองอัลกอริทึมการเรียนรู้เชิงลึกที่นำเสนอได้รับการประเมินโดยการเปรียบเทียบผลการจำแนกโดยใช้แบบจำลองอัลกอริทึมกับชุดข้อมูลเป้าหมายการเทรนโมเดลและการทดสอบโมเดล ได้แก่ ROC Curve, Confusion Matrix และ F1 Score และ Total Accuracy

3.6.6.1 การวิเคราะห์ Receiver operating characteristic (ROC) curve

Receiver operating characteristic (ROC) curve แสดงประสิทธิภาพการจำแนกประเภทของโมเดลอัลกอริทึมโดยใช้พื้นที่ใต้เส้นโค้ง ROC เป็นตัวบ่งชี้ประสิทธิภาพของโมเดล เส้นโค้ง ROC จะแปลงพารามิเตอร์สองตัวคือ อัตราบวกจริง (True positive rate) ในแนวแกน Y และอัตราบวกเท็จ (False positive rate) ในแนวแกน X อัตราบวกจริง (TPR) และอัตราบวกเท็จ (FPR) สามารถคำนวณได้โดยสมการ (3.10) และ (3.11) ตามลำดับ

$$\text{True positive rate (TPR)} = \frac{TP}{TP + FN} \quad (3.10)$$

โดยที่ TP คือจำนวนผลบวกจริงที่จำแนกตามแบบจำลองอัลกอริทึมและ FN คือจำนวนเชิงลบเท็จที่จำแนกตามแบบจำลองอัลกอริทึม

$$\text{False positive rate (FPR)} = \frac{FP}{TN + FP} \quad (3.11)$$

โดยที่ FP คือจำนวนผลบวกเท็จที่จำแนกตามแบบจำลองอัลกอริทึมและ TN คือจำนวนเชิงลบที่แท้จริงซึ่งจำแนกตามแบบจำลองอัลกอริทึม

3.6.6.2 Confusion matrix, F1 score and total accuracy

Confusion matrix คือ ตารางที่ทำให้เห็นภาพของประสิทธิภาพการจำแนกประเภทของโมเดลอัลกอริทึม ส่วน F1 score เป็นค่าที่ระบุประสิทธิภาพการจำแนกประเภทของโมเดลอัลกอริทึมโดยใช้ความแม่นยำ (Precision) ในสมการ (3.12) และการเรียกคืน (Recall) สมการการเรียกคืน (Recall) ในการคำนวณคะแนน F1 จะเหมือนกับสมการ (3.10) อัตราการบวกจริง (True positive rate) ด้วยเหตุนี้จึงสามารถใช้สมการ (3.10) ในการคำนวณการเรียกคืน (Recall) ได้ คะแนน F1,

ความแม่นยำของแต่ละประเภท และความแม่นยำรวม (ค่าเฉลี่ยของคะแนน $F1$) สามารถคำนวณได้โดยสมการ (3.13), (3.14) และ (3.15) ตามลำดับ

$$Precision = \frac{TP}{TP + FP} \quad (3.12)$$

$$F1 \text{ Score} = \frac{2 * Precision * Recall}{Precision + Recall} \quad (3.13)$$

$$Individual - class Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (3.14)$$

$$Total Accuracy = \frac{(F1 \text{ score (class 0)}) + (F1 \text{ score (class 1)}) + (F1 \text{ score (class 2)})}{3} \quad (3.15)$$


3.7 การทดสอบภาคสนาม (Onsite experimental testing)

3.7.1 การทดสอบโดยใช้เครื่องอัลตราโซนิกแบบเรียงเฟส (Advanced phased array ultrasonic testing (PAUT))

ก่อนที่จะทดสอบสำหรับการตรวจสอบรอยบกพร่องในรางไฟ PAUT ขั้นสูงพร้อมโพรบอาร์เรย์จำนวน 64 แชนเนล ความถี่ 5 MHz (รุ่น GEKKO; M2M, ฝรั่งเศส) ถูกนำไปใช้สำหรับการตรวจสอบแนวเชื่อมของรางรถไฟเพื่อค้นหาตำแหน่งของรอยบกพร่อง การตรวจสอบโดยใช้ PAUT ดำเนินการตรวจสอบแนวเชื่อมเนื่องจากเป็นจุดที่พบรอยบกพร่องได้บ่อยเพื่อค้นหาตำแหน่งของรอยบกพร่องในรางรถไฟ ต่อมาจึงนำหัววัดคอสติกอิมิชัน (AE Sensor) มาตรวจสอบที่ตำแหน่งแนวเชื่อมเดียวกันที่มีข้อบกพร่อง เพื่อนำผลการตรวจสอบมาเปรียบเทียบกับ PAUT เพื่อประเมินประสิทธิภาพการจำแนกประเภทของโมเดลอัลกอริธึมการเรียนรู้เชิงลึก จากรูปที่ 3.18 (ก) - (ข) แสดงเครื่องอัลตราโซนิกแบบเรียงเฟสขั้นสูงบนรอยเชื่อมของรางเหล็กและข้อบกพร่องในรอยเชื่อม



(ก)




(ข)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

รูปที่ 3.18 การทดสอบภาคสนามด้วยเครื่องอัลตราโซนิกแบบเรียงเฟส (ก) เครื่องอัลตราโซนิกแบบเรียงเฟสตรวจสอบแนวเชื่อมของรางรถไฟ (ข) สัญญาณรอยบกพร่องบริเวณแนวเชื่อมของรางรถไฟที่ตรวจพบโดยเครื่องอัลตราโซนิกแบบเรียงเฟส

3.7.2 การวัดอุณหภูมิของรางรถไฟก่อนการทดสอบ

เมื่อพิจารณาถึงช่วงอุณหภูมิในการทำงานที่ -40 ถึง 85°C ของหัววัดอุณหภูมิขั้ว (AE Sensor) รุ่น VS 150 RIC การตรวจสอบอุณหภูมิของรางรถไฟในช่วงกลางวัน ตรวจสอบโดยใช้กล้องถ่ายภาพความร้อน (FLIR, U.S.A.) ก่อนการติดตั้งหัววัดอุณหภูมิขั้ว (AE Sensor) อุณหภูมิของรางรถไฟอยู่ที่ $56.7 - 61.1^{\circ}\text{C}$ ดังแสดงในรูปที่ 3.19 ซึ่งอุณหภูมิรางไฟอยู่ในช่วงอุณหภูมิการทำงานของหัววัดอุณหภูมิขั้วได้



รูปที่ 3.19 การวัดอุณหภูมิรางรถไฟโดยการใช้กล้องถ่ายภาพความร้อน

3.7.3 การเก็บข้อมูลขณะรถไฟกำลังวิ่งผ่าน

จากรูปที่ 3.20 (ก) แสดงการติดตั้งหัววัดอุณหภูมิขั้ว (AE Sensor) ที่ด้านข้างของส่วนหัวของรางรถไฟเพื่อตรวจสอบรอยบกพร่อง ในรูปที่ 3.20 (ข) แสดงการทดสอบนอกสถานที่ (Onsite testing) ของรางรถไฟภายใต้ภาวะ สัญญาณอุณหภูมิขั้วของรางรถไฟภายใต้ภาวะที่เกิดขึ้นจากบกพร่องจะเป็นลักษณะรอยแตกแบบเมื่อยล้าที่เกิดขึ้นจากหน้าสัมผัสล้อและราง สัญญาณอุณหภูมิขั้วจะถูกตรวจจับสัญญาณอุณหภูมิขั้วโดยหัววัดและแปลงเป็นข้อมูลสัญญาณดิจิทัลโดยชุดเก็บข้อมูลสัญญาณอุณหภูมิขั้ว ข้อมูลสัญญาณดิจิทัลได้รับการประมวลผล เพื่อแสดงและประมวลผลโดยแบบจำลองอัลกอริทึมการเรียนรู้เชิงลึกเพื่อระบุตำแหน่งของรอยบกพร่องในรางรถไฟ



(ก)

(ข)

รูปที่ 3.20 การเก็บข้อมูลสัญญาณอคูสติกอิมพัลส์ในขณะรถไฟกำลังวิ่งผ่าน (ก) การติดตั้งหัววัดอคูสติกอิมพัลส์ที่รางรถไฟ (ข) สัญญาณอคูสติกอิมพัลส์ของรางรถไฟภายใต้ภาระ

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


บทที่ 4

ผลการดำเนินงาน


เนื้อหาในบทนี้ จะเป็นส่วนของผลการดำเนินการวิจัยที่ได้ทำตามรายละเอียดที่ได้อธิบายไปในระเบียบวิจัยในบทที่ 3 ดังนั้นเนื้อหาในบทนี้จะแบ่งออกเป็น 3 หัวข้อ คือ ผลการวัดประสิทธิภาพของแต่ละคลาสโดยการใช้ Receiver operating characteristic (ROC) curve, ผลการวัดประสิทธิภาพของโมเดลโดยการใช้ Confusion Matrix และผลการทดลองภาคสนามของการค้นหาตำแหน่งรอยบกพร่องของรางรถไฟด้วยวิธีการใช้การเรียนรู้เชิงลึก

4.1. ผล Receiver operating characteristic (ROC) curve

ผลการวัดประสิทธิภาพของแต่ละคลาสโดยใช้ ROC ที่มีต่อความแม่นยำในการจำแนกประเภทของรอยบกพร่องที่เกิดขึ้นตำแหน่งต่างๆของแบบจำลองอัลกอริธึมการเรียนรู้เชิงลึก ถูกกำหนดโดยการแบ่งชุดข้อมูลออกเป็นสองกลุ่ม โดยชุดข้อมูลแรกมีสัญญาณอนุศตติกิมิซชั้นจำนวน 150 ชุดข้อมูล และชุดข้อมูลที่สองมีสัญญาณอนุศตติกิมิซชั้นจำนวน 300 ชุดข้อมูล โดยผลการวัดประสิทธิภาพของแต่ละคลาสโดยใช้ ROC ดังแสดงในรูปที่ 4.1 (150 ชุดข้อมูล) และ 4.2 (300 ชุดข้อมูล) โดยที่คลาส 0 แสดงถึงตำแหน่งที่เกิดรอยบกพร่องที่หัวราง (Rail head), คลาส 1 แสดงถึงตำแหน่งที่เกิดรอยบกพร่องที่เอวราง (Rail web) และคลาส 2 แสดงถึงตำแหน่งที่เกิดรอยบกพร่องที่ฐานราง (Rail foot) ตามลำดับ




รูปที่ 4.1 Receiver operating characteristic (ROC) curve คลาส 0, 1, และ 2 ที่บ่งชี้ตำแหน่งหัวราง (Rail head), เอวราง (Rail web) และ ฐานราง (Rail foot) สัญญาณอนุศตติกิมิซชั้นจำนวน 150 ชุดข้อมูล (กลุ่มที่ 1)




รูปที่ 4.2 Receiver operating characteristic (ROC) curve คลาส 0, 1, และ 2 ที่บ่งชี้หัวราง (Rail head), เหวราง (Rail web) และ ฐานราง (Rail foot) สัญญาณอคูสติกอิมพัลส์จำนวน 300 ชุด ข้อมูล (กลุ่มที่ 2)

ภายใต้การจัดกลุ่มแรก ประสิทธิภาพความแม่นยำของโมเดลในแต่ละคลาส โดยผลการวิจัยในคลาส 0 คือ รอยบกพร่องจากตำแหน่งหัวรางมีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 100% (1.00) ดังแสดงในรูปที่ 4.3




รูปที่ 4.3 Receiver operating characteristic (ROC) curve คลาส 0 ที่บ่งชี้ตำแหน่งหัวราง (Rail head) สัญญาณอคูสติกอิมพัลส์จำนวน 150 ชุดข้อมูล (กลุ่มที่ 1)

คลาส 1 คือ รอยบกพร่องจากตำแหน่งเอวรางมีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 95% (0.95) ดังแสดงในรูปที่ 4.4



รูปที่ 4.4 Receiver operating characteristic (ROC) curve คลาส 1 ที่บ่งชี้ที่ตำแหน่งเอวราง (Rail web) สัญญาณอคูสติกอิมพัลส์จำนวน 150 ชุดข้อมูล (กลุ่มที่ 1)

คลาส 2 คือ รอยบกพร่องจากตำแหน่งฐานรางมีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 82% (0.82) ดังแสดงในรูปที่ 4.5




รูปที่ 4.5 Receiver operating characteristic (ROC) curve คลาส 2 ที่บ่งชี้ที่ตำแหน่งฐานราง (Rail foot) สัญญาณอคูสติกอิมพัลส์จำนวน 150 ชุดข้อมูล (กลุ่มที่ 1)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้


ซึ่งจากผลการวิจัยพบว่าความแม่นยำในการจำแนกประเภทของแบบจำลองอัลกอริธึมการเรียนรู้เชิงลึก และประสิทธิภาพความแม่นยำของโมเดลของสัญญาณอนุภาคอิมิกซ์ชันจำนวน 150 ชุดข้อมูล ในกลุ่มแรกพบว่าคลาส 0 คือ รอยบกพร่องจากตำแหน่งหัวราง (Rail head) มีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 100% (1.00) ซึ่งมีประสิทธิภาพความแม่นยำสูงสุด และมีประสิทธิภาพความแม่นยำน้อยสุด ที่คลาส 2 คือ รอยบกพร่องจากตำแหน่งฐานราง (Rail web) มีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 82% (0.82)

ภายใต้การจัดกลุ่มที่สอง ประสิทธิภาพความแม่นยำสำหรับในแต่ละคลาส โดยผลการวิจัยในคลาส 0 คือ รอยบกพร่องจากตำแหน่งหัวราง มีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 97% (0.97) ดังแสดงในรูปที่ 4.6



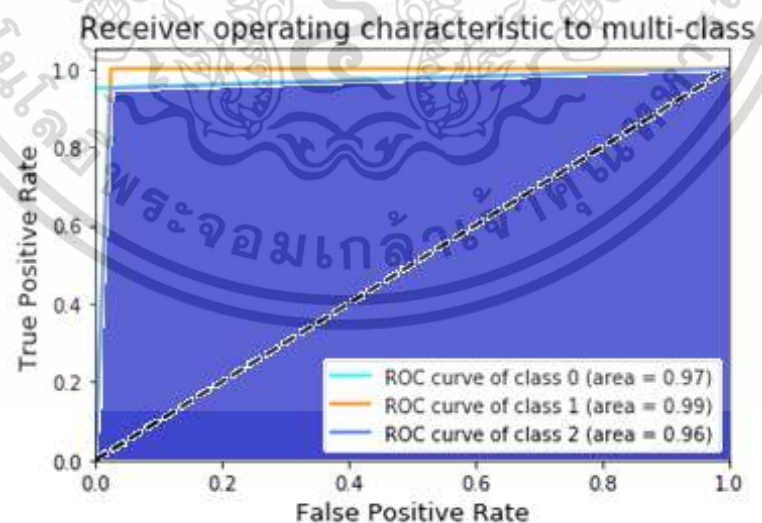
รูปที่ 4.6 Receiver operating characteristic (ROC) curve คลาส 0 ที่บ่งชี้ตำแหน่งหัวราง (Rail head) สัญญาณอนุภาคอิมิกซ์ชันจำนวน 300 ชุดข้อมูล (กลุ่มที่ 2)

คลาส 1 คือ รอยบกพร่องจากตำแหน่งเอวรางมีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 99% (0.99) ดังแสดงในรูปที่ 4.7



รูปที่ 4.7 Receiver operating characteristic (ROC) curve คลาส 1 ที่บ่งชี้ที่ตำแหน่งเอวราง (Rail web) สัญญาณอคูสติกอิมพัลส์จำนวน 300 ชุดข้อมูล (กลุ่มที่ 2)

และคลาส 2 คือรอยบกพร่องจากตำแหน่งฐานรางมีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 96% (0.96) ดังแสดงในรูปที่ 4.8



รูปที่ 4.8 Receiver operating characteristic (ROC) curve คลาส 2 ที่บ่งชี้ที่ตำแหน่งฐานราง (Rail foot) สัญญาณอคูสติกอิมพัลส์จำนวน 300 ชุดข้อมูล (กลุ่มที่ 2)

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ซึ่งจากผลการวิจัยพบว่าความแม่นยำในการจำแนกประเภทของแบบจำลองอัลกอริธึมการเรียนรู้เชิงลึก และประสิทธิภาพความแม่นยำของโมเดลของสัญญาณอนุคตติกิมิซันจำนวน 300 ชุดข้อมูล ในกลุ่มสองพบว่าคลาส 1 คือ รอยบกพร่องจากตำแหน่งเอวราง (Rail web) มีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 99% (0.99) ซึ่งมีประสิทธิภาพความแม่นยำสูงสุด และมีประสิทธิภาพความแม่นยำน้อยสุด ที่คลาส 2 คือ รอยบกพร่องจากตำแหน่งฐานราง (Rail web) มีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 96% (0.96)


จากผลการวิจัยพบว่าความแม่นยำในการจำแนกประเภทของแบบจำลองอัลกอริธึมการเรียนรู้เชิงลึกจากผลการวัดประสิทธิภาพความแม่นยำของโมเดลโดยการใช้ ROC พบว่าหากมีการเพิ่มจำนวนชุดข้อมูลของสัญญาณอนุคตติกิมิซันเป็นจำนวน 300 ชุดข้อมูล จะทำให้มีการเพิ่มประสิทธิภาพความแม่นยำของโมเดลในแต่ละคลาสเพิ่มขึ้น เมื่อเทียบกับผลกับจำนวนชุดข้อมูลของสัญญาณอนุคตติกิมิซันเป็นจำนวน 150 ชุดข้อมูล ในกลุ่มแรกจะพบว่าที่คลาส 2 คือ รอยบกพร่องจากตำแหน่งฐานราง (Rail web) มีประสิทธิภาพความแม่นยำมีค่าเท่ากับ 82% (0.82) ซึ่งมีประสิทธิภาพความแม่นยำน้อยสุด ซึ่งมีค่าต่ำกว่า 95% (0.95) เมื่อเปรียบเทียบผลประสิทธิภาพความแม่นยำของโมเดลของสัญญาณอนุคตติกิมิซันจำนวน 300 สัญญาณในกลุ่มสอง ซึ่งมีค่าเฉลี่ยประสิทธิภาพความแม่นยำของโมเดลในแต่ละคลาสสูงกว่า 95% (0.95)

4.2. ผล Confusion matrix


Confusion Matrix เป็นเครื่องมือสำคัญในการประเมินผลลัพธ์ของการทำนาย เมทริกซ์ความสับสน (Confusion matrix) ของแบบจำลองอัลกอริธึมการเรียนรู้เชิงลึกสำหรับงานวิจัยนี้ มีการเปรียบเทียบการประเมินประสิทธิภาพของโมเดลการทำนาย คือ ชุดข้อมูลแรก จำนวน 150 ชุดข้อมูล และชุดข้อมูลที่สอง จำนวน 300 ชุดข้อมูล ของชุดข้อมูลสัญญาณอนุคตติกิมิซัน ภายใต้การจัดกลุ่มแรกชุดข้อมูล 30 ชุดข้อมูล เป็นของการหักไล่ดินสอเพื่อสร้างสัญญาณอนุคตติกิมิซันจำลองในแต่ละตำแหน่งคือที่ตำแหน่งคือที่ตำแหน่งหัวราง (Rail head), เอวราง (Rail web) และฐานราง (Rail foot) ของรางรถไฟ ในขณะที่เดียวกันภายใต้การจัดกลุ่มที่สองชุดข้อมูล 60 ชุดข้อมูลเป็นของการหักไล่ดินสอเพื่อสร้างสัญญาณอนุคตติกิมิซันจำลองในแต่ละตำแหน่งคือที่ตำแหน่งหัวราง (Rail head), เอวราง (Rail web) และฐานราง (Rail foot) ของรางรถไฟตามลำดับ

ผลการประเมินผลลัพธ์ของการทำนายของ Confusion Matrix ของชุดข้อมูลแรกจำนวน 150 ชุดข้อมูลในการฝึกโมเดล โดยผลลัพธ์สัญญาณอนุคตติกิมิซันจริงที่ตำแหน่งหัวรางจำนวน 10 ชุดข้อมูล โดยโมเดลอัลกอริทึมสามารถทำนายสัญญาณอนุคตติกิมิซัน 10 ชุดข้อมูล ได้อย่างถูกต้องทั้งหมดที่ตำแหน่งหัวราง สำหรับสัญญาณอนุคตติกิมิซันจริงที่ตำแหน่งเอวรางจำนวน 10 ชุดข้อมูล

โดยโมเดลอัลกอริทึมสามารถทำนายสัญญาณอิมิชัน 9 สัญญาณได้อย่างถูกต้อง โดยทำนายผิดที่ตำแหน่งฐานรางจำนวน 1 สัญญาณ และสัญญาณอคูสติกอิมิชันจริงที่ตำแหน่งฐานรางจำนวน 10 สัญญาณ โดยโมเดลอัลกอริทึมสามารถทำนายสัญญาณอคูสติกอิมิชัน 7 สัญญาณได้อย่างถูกต้อง โดยทำนายผิดที่ตำแหน่งหัวรางจำนวน 3 สัญญาณ ดังแสดงในรูปที่ 4.9



ผลการประเมินผลลัพธ์ของการทำนายของ Confusion Matrix ของชุดข้อมูลที่สองจำนวน 300 ชุดข้อมูลในการฝึกโมเดล โดยให้สัญญาณอคูสติกอิมิชันจริงที่ตำแหน่งหัวรางจำนวน 20 ชุดข้อมูล โดยโมเดลอัลกอริทึมสามารถทำนายสัญญาณอคูสติกอิมิชัน 19 ชุดข้อมูล ได้อย่างถูกต้อง โดยทำนายผิดที่ตำแหน่งฐานรางจำนวน 1 ชุดข้อมูล สำหรับสัญญาณอคูสติกอิมิชันจริงที่ตำแหน่งเอวรางจำนวน 20 ชุดข้อมูล โดยโมเดลอัลกอริทึมสามารถทำนายสัญญาณอิมิชัน 20 ชุดข้อมูลได้อย่างถูกต้องทั้งหมดที่ตำแหน่งเอวราง และสัญญาณอคูสติกอิมิชันจริงที่ตำแหน่งฐานรางจำนวน 20 สัญญาณ โดยโมเดลอัลกอริทึมสามารถทำนายสัญญาณอคูสติกอิมิชัน 19 ชุดข้อมูลได้อย่างถูกต้อง โดยทำนายผิดที่ตำแหน่งเอวรางจำนวน 1 ชุดข้อมูล ดังแสดงในรูปที่ 4.10



รูปที่ 4.10 ผล Confusion matrix สัญญาณอคูสติกอิมิชันจำนวน 60 ชุดข้อมูล

4.3. ผล F1 scores ของการเรียนรู้เชิงลึก

จากตารางที่ 4.1 เปรียบเทียบคะแนน F1 และความแม่นยำรวม (Total Accuracy) ของการจัดกลุ่มสัญญาณอคูสติกอิมิชันจำนวน 150 ชุดข้อมูล และสัญญาณอคูสติกอิมิชันจำนวน 300 ชุดข้อมูล โดยความแม่นยำ (Precision) และการเรียกคืน (Recall) คำนวณจากเมทริกซ์ความสับสน (Confusion Matrix) ภายใต้การจัดกลุ่มข้อมูลแรก ค่าคะแนน F1 สำหรับตำแหน่งหัวราง (Rail head) มีค่า 86.9%, เอวราง (Rail web) มีค่า 94.7% และฐานราง (Rail foot) มีค่า 77.7% ของรางรถไฟตามลำดับ โดยมีความแม่นยำรวม (Total Accuracy) เท่ากับ 86.6% และภายใต้การจัดกลุ่มข้อมูลที่สอง ค่าคะแนน F1 สำหรับตำแหน่งหัวราง (Rail head) มีค่า 97.4%, เอวราง (Rail web) มีค่า 97.4% และฐานราง (Rail foot) 95% ของรางรถไฟตามลำดับ โดยมีความแม่นยำรวม (Total Accuracy) 96.6% จากผลการวิจัยพบว่าคะแนน F1 และความแม่นยำรวม (Total Accuracy) มีค่าดีขึ้นเมื่อจำนวนสัญญาณอคูสติกอิมิชันของชุดข้อมูลเพิ่มขึ้นจากจำนวน 150 ชุดข้อมูล เพิ่มขึ้นเป็นจำนวน 300 ชุดข้อมูล


ตารางที่ 4.1 Comparison between F1 score and total accuracy ของสัญญาณอคูสติกอิมิชันจำนวน 150 ชุดข้อมูล (กลุ่มที่ 1) และสัญญาณอคูสติกอิมิชันจำนวน 300 ชุดข้อมูล (กลุ่มที่ 2)

	Rail head (150 AE signals)	Rail head (300 AE signals)	Rail web (150 AE signals)	Rail web (300 AE signals)	Rail foot (150 AE signals)	Rail foot (300 AE signals)
Precision (%)	76.9	100	100	95.2	87.5	95
Recall (%)	100	95	90	100	70	95
F1 score (%)	86.9	97.4	94.7	97.5	77.7	95
Total Accuracy (%)	86.6 (150 AE signals)					
Total Accuracy (%)	96.6 (300 AE signals)					

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

4.4. ผลการทดสอบภาคสนามของสัญญาณอคูสติกอิมิชชันในรางรถไฟ (Onsite AE signals using the proposed AE scheme)

จากรูปที่ 4.11 แสดงสัญญาณอคูสติกอิมิชชันของรอยบกร่องในแนวเชื่อมของรางรถไฟภายใต้ภาวะโดยใช้หัววัดอคูสติกอิมิชชันแบบเซ็นเซอร์เดี่ยวแบบไม่ทำลาย ก่อนที่จะเก็บข้อมูลความเสียหายของรอยบกร่องภายในรางรถไฟ ในงานวิจัยได้นำเครื่องอัลตราโซนิกแบบเรียงเฟส (Advanced phased array ultrasonic testing (PAUT)) เพื่อค้นหาตำแหน่งรอยบกร่องในรางรถไฟก่อนเพื่อเป็นการอ้างอิงตำแหน่งของการเกิดรอยบกร่องภายในรางรถไฟ ซึ่งตำแหน่งของรอยบกร่องภายในที่มักจะพบบ่อยคือตำแหน่งแนวเชื่อมของรางรถไฟ โดยตำแหน่งที่ตรวจพบที่เป็นตำแหน่งเดียวกันกับตำแหน่งที่ติดตั้งหัววัดอคูสติกอิมิชชันแบบเซ็นเซอร์เดี่ยว ซึ่งจะเก็บข้อมูลสัญญาณอคูสติกอิมิชชันภายใต้ภาวะที่รถไฟกำลังวิ่งผ่านตำแหน่งแนวเชื่อมที่พบรอยบกร่อง โดยข้อมูลของสัญญาณอคูสติกอิมิชชันจากการทดสอบภาคสนามได้ถูกนำมาวิเคราะห์อัลกอริธึมการเรียนรู้เชิงลึกจากโมเดลที่ผ่านการพัฒนา อัลกอริธึมการเรียนรู้เชิงลึกที่นำเสนอในงานวิจัยนี้ได้กำหนดรอยบกร่องในรางรถไฟสำหรับสัญญาณอคูสติกอิมิชชัน โดยพิจารณาจากค่าความน่าจะเป็นที่เกิดจากการเรียนรู้เชิงลึกสูงสุด ผลการวิเคราะห์รอยบกร่องโดยใช้หัววัดอคูสติกอิมิชชันแบบเซ็นเซอร์เดี่ยวที่เน้นการเรียนรู้เชิงลึกที่นำเสนอในงานวิจัยถูกเปรียบเทียบกับข้อมูลอ้างอิงจากผลการวิเคราะห์โดยเครื่องอัลตราโซนิกแบบเรียงเฟส ในงานวิจัยนี้ค่าคะแนน F1 (ความแม่นยำในการจำแนกประเภท) โดยใช้หัววัดอคูสติกอิมิชชันแบบเซ็นเซอร์เดี่ยวสำหรับการวิเคราะห์รอยบกร่องในตำแหน่งหัวราง (Rail head), เอวราง (Rail web) และฐานราง (Rail foot) มีค่าคะแนน F1 ที่ตำแหน่งหัวรางคือ 78%, ที่ตำแหน่งเอวรางคือ 80% และที่ตำแหน่งฐานรางคือ 74% เมื่อเทียบกับผลการวิเคราะห์จากเครื่องอัลตราโซนิกแบบเรียงเฟส โดยความแม่นยำรวม (Total Accuracy) ของหัววัดอคูสติกอิมิชชันแบบเซ็นเซอร์เดี่ยวที่นำเสนอคือ 77.33%



รูปที่ 4.11 สัญญาณอคูสติกอิมิชชันของรอยร้าวที่ตำแหน่งแนวเชื่อมของรางรถไฟภายใต้ภาวะ โดยใช้หัววัดอคูสติกอิมิชชันแบบเซ็นเซอร์เดี่ยว

บทที่ 5

สรุปผลงานวิจัยและข้อเสนอแนะ

ในวิทยานิพนธ์นี้ได้เสนองานวิจัยในหัวข้อ “วิธีอคูสติกอิมิชันโดยหลักการเรียนรู้เชิงลึกเพื่อหาตำแหน่งรอยบกพร่องโดยไม่ทำลายในรางรถไฟภายใต้ภาวะ” ซึ่งงานวิจัยนี้ได้นำเสนอหัวข้ออคูสติกอิมิชันแบบเซ็นเซอร์เดี่ยวแบบไม่ทำลายร่วมกับการเรียนรู้เชิงลึกสำหรับการตรวจสอบรอยบกพร่องในตำแหน่งหัวราง (Rail head), เอรราง (Rail web) และฐานราง (Rail foot) ของรางรถไฟภายใต้ภาวะ โดยการวิจัยนี้เสนอการตรวจสอบสัญญาณอคูสติกอิมิชันโดยหัวข้ออคูสติกอิมิชันแบบเซ็นเซอร์เดี่ยว และการเก็บข้อมูลเป็นข้อมูลสัญญาณในรูปแบบดิจิทัล ข้อมูลดิจิทัลได้รับการประมวลผลโดยใช้อัลกอริทึม TVD เพื่อช่วยลดสัญญาณเสียงรบกวนและเสียงในขณะรถไฟกำลังวิ่งผ่านในขณะที่เก็บข้อมูล ข้อมูลสัญญาณที่ผ่านการลดสัญญาณรบกวนแล้ว ได้รับการประมวลผลและจัดประเภทเพื่อการจำแนกตำแหน่งที่เกิดรอยบกพร่องโดยการใช้อัลกอริทึมการเรียนรู้เชิงลึก ในการฝึกโมเดลและทดสอบโมเดลของอัลกอริทึม จะได้วิธีการเก็บชุดข้อมูลสัญญาณอคูสติกอิมิชันของการหักไส้ดินสอ (PLB) ขนาด 2H (PLB; 0.5 มม.) เพื่อสร้างสัญญาณอคูสติกอิมิชันจำลองที่ตำแหน่งโมเดลอัลกอริทึมของรางรถไฟตามมาตรฐาน ASTM E976 โดยมีการเก็บข้อมูลในแต่ละตำแหน่งจำนวน 150 ชุดข้อมูลที่ ตำแหน่งหัวราง (Rail head), เอรราง (Rail web) และฐานราง (Rail foot) จำนวนรวมทั้งหมด 450 ชุดข้อมูล โดยข้อมูลทั้งหมดจะถูกแบ่งออกเป็นสองกลุ่มชุดข้อมูลคือ กลุ่มแรกมีชุดข้อมูลจำนวน 150 ชุดข้อมูล และกลุ่มที่สองมีชุดข้อมูลจำนวน 300 ชุดข้อมูล เพื่อเปรียบเทียบผลของจำนวนข้อมูลอินพุต โดยการวัดประสิทธิภาพในแต่ละคลาสและความแม่นยำในการจำแนกประเภทของอัลกอริทึมการเรียนรู้เชิงลึก โดยหัวข้ออคูสติกอิมิชันแบบเซ็นเซอร์เดี่ยวด้วยการเรียนรู้เชิงลึก โดยโมเดลอัลกอริทึมที่มีประสิทธิภาพและแม่นยำที่สุดจะถูกนำไปใช้ในการทดสอบกับชุดข้อมูลของการเก็บชุดข้อมูลจากภาคสนามเพื่อทำนายผลการเกิดรอยบกพร่องในตำแหน่งโมเดลอัลกอริทึม ผลการวิจัยพบว่าการแบ่งชุดข้อมูลจำนวน 150 ชุดข้อมูล โดยมีค่าคะแนน F1 ของโมเดลอัลกอริทึมที่ตำแหน่งหัวรางคือ 86.9%, ที่ตำแหน่งเอรรางคือ 94.7% และตำแหน่งฐานรางคือ 77.7% โดยมีความแม่นยำรวม (Total Accuracy) คือ 86.6% ในการแบ่งชุดข้อมูลจำนวน 300 ชุดข้อมูล โดยมีค่าคะแนน F1 ของโมเดลอัลกอริทึมที่ตำแหน่งหัวรางคือ 97.4%, ที่ตำแหน่งเอรรางคือ 97.5% และตำแหน่งฐานรางคือ 95% โดยมีความแม่นยำรวม (Total Accuracy) คือ 96.6% มีค่าประสิทธิภาพของโมเดลเพิ่มขึ้นเมื่อเพิ่มจำนวนสัญญาณอคูสติกอิมิชันของชุดข้อมูลเพิ่มขึ้นจากจำนวน 150 ชุดข้อมูล เพิ่มขึ้นเป็นจำนวน 300 ชุดข้อมูล โดยค่าคะแนน F1 ของการทดสอบภาคสนามที่ตำแหน่งหัวรางคือ 78%, ที่ตำแหน่งเอรรางคือ 80% และตำแหน่งฐานรางคือ 74% โดยมีความแม่นยำรวม (Total Accuracy) คือ 77.33% จากการวิจัยพบว่าการเพิ่มความแม่นยำของโมเดลของการวิจัยต่อในอนาคตควรเพิ่มจำนวนชุดข้อมูลสัญญาณอคูสติกอิมิชันสำหรับการฝึกโมเดลและการพัฒนาการหาวิธีการเพื่อช่วยลดสัญญาณรบกวนสำหรับการทดสอบภาคสนามก่อนนำมา

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่นุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

วิเคราะห์ผลโดยการใช้อัลกอริธึมการเรียนรู้เชิงลึก ตลอดจนถึงการนำข้อมูลที่ได้จากการทดสอบภาคสนามมาใช้พัฒนาในการฝึกโมเดล เพื่อเพิ่มประสิทธิภาพในการวิเคราะห์ผลที่ได้จากการเก็บข้อมูลภาคสนามเพื่อทำนายผลจากการทดสอบภาคสนามต่อไปในอนาคต



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

เอกสารอ้างอิง

- [1] Jiang, Xiaoning, Kyungrim Kim, Shujun Zhang, Joseph Johnson, and Giovanni Salazar. "High-Temperature Piezoelectric Sensing." *Sensors* 14, no. 1 (2014): 144-69.
- [2] LORD JR, ARTHUR E. "Acoustic Emission." In *Physical Acoustics*, 289-353: Elsevier, 1975.
- [3] Schabowicz, Krzysztof. "Non-Destructive Testing of Materials in Civil Engineering." Multidisciplinary Digital Publishing Institute, 2019.
- [4] Zaki, Ahmad, Hwa Kian Chai, Dimitrios G Aggelis, and Ninel Alver. "Non-Destructive Evaluation for Corrosion Monitoring in Concrete: A Review and Capability of Acoustic Emission Technique." *Sensors* 15, no. 8 (2015): 19069-101.
- [5] Bi, Haisheng, Huiyao Li, Wei Zhang, Lin Wang, Qinglei Zhang, Suzhen Cao, and Isaac Toku-Gyamerah. "Evaluation of the Acoustic Emission Monitoring Method for Stress Corrosion Cracking on Aboveground Storage Tank Floor Steel." *International Journal of Pressure Vessels and Piping* 179 (2020): 104035.
- [6] Kwon, Jeong-Rock, Geun-Jun Lyu, Tae-Hee Lee, and Jee-Yoon Kim. "Acoustic Emission Testing of Repaired Storage Tank." *International journal of pressure vessels and piping* 78, no. 5 (2001): 373-78.
- [7] Morhain, A, and David Mba. "Bearing Defect Diagnosis and Acoustic Emission." *Proceedings of the Institution of Mechanical Engineers, Part J: Journal of Engineering Tribology* 217, no. 4 (2003): 257-72.
- [8] Song, Xiao-chun, Song-ling Huang, and Wei Zhao. "Optimization of the Magnetic Circuit in the MFL Inspection System for Storage-Tank Floors." *Russian journal of nondestructive testing* 43, no. 5 (2007): 326-31.
- [9] Barke, Derek, and Wing Kong Chiu. "Structural Health Monitoring in the Railway Industry: A Review." *Structural Health Monitoring* 4, no. 1 (2005): 81-93.
- [10] Ekberg, Anders, and Elena Kabo. "Fatigue of Railway Wheels and Rails under Rolling Contact and Thermal Loading—an Overview." *Wear* 258, no. 7-8 (2005): 1288-300.
- [11] Li, Zili, Xin Zhao, and Rolf Dollevoet. "An Approach to Determine a Critical Size for Rolling Contact Fatigue Initiating from Rail Surface Defects." *International Journal of Rail Transportation* 5, no. 1 (2017): 16-37.

- [12] Nielsen, Jens CO, and Anders Johansson. "Out-of-Round Railway Wheels-a Literature Survey." *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit* 214, no. 2 (2000): 79-91.
- [13] Zerbst, Uwe, Roger Lundén, K-O Edel, and Roderick A Smith. "Introduction to the Damage Tolerance Behaviour of Railway Rails—a Review." *Engineering fracture mechanics* 76, no. 17 (2009): 2563-601.
- [14] Ekberg, Anders, Bengt Åkesson, and Elena Kabo. "Wheel/Rail Rolling Contact Fatigue—Probe, Predict, Prevent." *Wear* 314, no. 1-2 (2014): 2-12.
- [15] Kapoor, Ajay, DI Fletcher, and Francis J Franklin. "The Role of Wear in Enhancing Rail Life." In *Tribology Series*, 331-40: Elsevier, 2003.
- [16] Ngamkhanong, Chayut, Sakdirat Kaewunruen, and Bruno J Afonso Costa. "State-of-the-Art Review of Railway Track Resilience Monitoring." *Infrastructures* 3, no. 1 (2018): 3.
- [17] Behnia, Arash, Hwa Kian Chai, and Tomoki Shiotani. "Advanced Structural Health Monitoring of Concrete Structures with the Aid of Acoustic Emission." *Construction and Building Materials* 65 (2014): 282-302.
- [18] Lédeczi, Ákos, Thomas Hay, Péter Volgyesi, D Robert Hay, András Nádas, and Subash Jayaraman. "Wireless Acoustic Emission Sensor Network for Structural Monitoring." *IEEE Sensors Journal* 9, no. 11 (2009): 1370-77.
- [19] Nair, Archana, and CS Cai. "Acoustic Emission Monitoring of Bridges: Review and Case Studies." *Engineering structures* 32, no. 6 (2010): 1704-14.
- [20] Zelenyak, Andreea-Manuela, Marvin A Hamstad, and Markus GR Sause. "Modeling of Acoustic Emission Signal Propagation in Waveguides." *Sensors* 15, no. 5 (2015): 11805-22.
- [21] Holford, Karen Margaret, AW Davies, R Pullin, and DC Carter. "Damage Location in Steel Bridges by Acoustic Emission." *Journal of intelligent material systems and structures* 12, no. 8 (2001): 567-76.
- [22] Li, Dongsheng, Jinping Ou, Chengming Lan, and Hui Li. "Monitoring and Failure Analysis of Corroded Bridge Cables under Fatigue Loading Using Acoustic Emission Sensors." *Sensors* 12, no. 4 (2012): 3901-15.
- [23] Roberts, Terence Martin, and M Talebzadeh. "Fatigue Life Prediction Based on Crack Propagation and Acoustic Emission Count Rates." *Journal of Constructional Steel Research* 59, no. 6 (2003): 679-94.

- [24] Chou, HY, AP Mouritz, MK Bannister, and Anthony R Bunsell. "Acoustic Emission Analysis of Composite Pressure Vessels under Constant and Cyclic Pressure." *Composites Part A: Applied Science and Manufacturing* 70 (2015): 111-20.
- [25] Ennaceur, C, A Laksimi, C Herve, and M Cherfaoui. "Monitoring Crack Growth in Pressure Vessel Steels by the Acoustic Emission Technique and the Method of Potential Difference." *International journal of pressure vessels and piping* 83, no. 3 (2006): 197-204.
- [26] Mostafapour, A, and S Davoudi. "Analysis of Leakage in High Pressure Pipe Using Acoustic Emission Method." *Applied Acoustics* 74, no. 3 (2013): 335-42.
- [27] Shehadeh, M, JA Steel, and RL Reuben. "Acoustic Emission Source Location for Steel Pipe and Pipeline Applications: The Role of Arrival Time Estimation." *Proceedings of the Institution of Mechanical Engineers, Part E: Journal of Process Mechanical Engineering* 220, no. 2 (2006): 121-33.
- [28] Esola, Shane, Brian J Wisner, Prashanth Abraham Vanniamparambil, John Geriguis, and Antonios Kotsos. "Part Qualification Methodology for Composite Aircraft Components Using Acoustic Emission Monitoring." *Applied Sciences* 8, no. 9 (2018): 1490.
- [29] Holford, Karen Margaret, Rhys Pullin, Samuel Lewin Evans, Mark Jonathan Eaton, J Hensman, and K Worden. "Acoustic Emission for Monitoring Aircraft Structures." *Proceedings of the Institution of Mechanical Engineers, Part G: Journal of Aerospace Engineering* 223, no. 5 (2009): 525-32.
- [30] Zhang, Zhiheng, Guoan Yang, and Kun Hu. "Prediction of Fatigue Crack Growth in Gas Turbine Engine Blades Using Acoustic Emission." *Sensors* 18, no. 5 (2018): 1321.
- [31] Bi, Haisheng, Huiyao Li, Wei Zhang, Lin Wang, Qinglei Zhang, Suzhen Cao, and Isaac Toku-Gyamerah. "Evaluation of the Acoustic Emission Monitoring Method for Stress Corrosion Cracking on Aboveground Storage Tank Floor Steel." *International Journal of Pressure Vessels and Piping* 179 (2020): 104035.
- [32] Jirarungsatian, C, and A Prateepasen. "Pitting and Uniform Corrosion Source Recognition Using Acoustic Emission Parameters." *Corrosion Science* 52, no. 1 (2010): 187-97.
- [33] Čapek, Jan, Michal Knapek, Peter Minárik, Jan Dittrich, and Kristián Máthis. "Characterization of Deformation Mechanisms in Mg Alloys by Advanced Acoustic Emission Methods." *Metals* 8, no. 8 (2018): 644.

- [34] Ono, Kanji. "Acoustic Emission in Materials Research-a Review." *Journal of acoustic emission* 29 (2011).
- [35] Kostryzhev, AG, CL Davis, and C Roberts. "Detection of Crack Growth in Rail Steel Using Acoustic Emission." *Ironmaking & Steelmaking* 40, no. 2 (2013): 98-102.
- [36] Shi, Shengrun, Zhiyuan Han, Zipeng Liu, Patrick Vallely, Slim Soua, Sakdirat Kaewunruen, and Mayorkinos Papaelias. "Quantitative Monitoring of Brittle Fatigue Crack Growth in Railway Steel Using Acoustic Emission." *Proceedings of the Institution of Mechanical Engineers, Part F: Journal of Rail and Rapid Transit* 232, no. 4 (2018): 1211-24.
- [37] Thakkar, NA, JA Steel, and RL Reuben. "Rail-Wheel Interaction Monitoring Using Acoustic Emission: A Laboratory Study of Normal Rolling Signals with Natural Rail Defects." *Mechanical Systems and Signal Processing* 24, no. 1 (2010): 256-66.
- [38] Ebrahimkhanlou, Arvin, and Salvatore Salamone. "Single-Sensor Acoustic Emission Source Localization in Plate-Like Structures Using Deep Learning." *Aerospace* 5, no. 2 (2018): 50.
- [39] Sohaib, Muhammad, Manjurul Islam, Jaeyoung Kim, Duck-Chan Jeon, and Jong-Myon Kim. "Leakage Detection of a Spherical Water Storage Tank in a Chemical Industry Using Acoustic Emissions." *Applied Sciences* 9, no. 1 (2019): 196.
- [40] Mokhtari, Noushin, Jonathan Gerald Pelham, Sebastian Nowoisky, José-Luis Bote-Garcia, and Clemens Gühmann. "Friction and Wear Monitoring Methods for Journal Bearings of Geared Turbofans Based on Acoustic Emission Signals and Machine Learning." *Lubricants* 8, no. 3 (2020): 29.
- [41] Dobrzycki, Arkadiusz, Stanisław Mikulski, and Władysław Opydo. "Using ANN and SVM for the Detection of Acoustic Emission Signals Accompanying Epoxy Resin Electrical Treeing." *Applied Sciences* 9, no. 8 (2019): 1523.
- [42] del Val, Lara, Alberto Izquierdo, Juan J Villacorta, and Luis Suárez. "Comparison of Methodologies for the Detection of Multiple Failures Using Acoustic Images in Fan Matrices." *Shock and Vibration* 2020 (2020).
- [43] Loutas, Theodoros, Nick Eleftheroglou, and Dimitrios Zarouchas. "A Data-Driven Probabilistic Framework Towards the in-Situ Prognostics of Fatigue Life of Composites Based on Acoustic Emission Data." *Composite Structures* 161 (2017): 522-29.

- [44] Selesnick, Ivan. "Total Variation Denoising (an MM Algorithm)." NYU Polytechnic School of Engineering Lecture Notes 32 (2012).
- [45] เจน บุญชื้อ. ความรู้เบื้องต้นวิศวกรรมรถไฟ. ห้างหุ้นส่วนจำกัด แผงไทย. 2554.
- [46] อาษา ประทีปเสน. การทดสอบโดยไม่ทำลายในงานเชื่อมและงานวิจัย. คณะวิศวกรรมศาสตร์. มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าธนบุรี. 2537.
- [47] กอบเกียรติ สระอุบล. เรียนรู้ Data Science และ AI : Machine Learning ด้วย Python. หสม มีเดีย เนทเวิร์ค. พิมพ์ครั้งที่ 1 มิถุนายน 2563.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ภาคผนวก ก.

ผลงานที่ได้รับการตีพิมพ์วารสารนานาชาติ



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

Article

Deep Learning-Based Acoustic Emission Scheme for Nondestructive Localization of Cracks in Train Rails under a Load

Wara Suwansin and Pattarapong Phasukkit * 

School of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand; 58601023@kmitl.ac.th

* Correspondence: pattarapong.ph@kmitl.ac.th; Tel.: +66-86045-5445

Abstract: This research proposes a nondestructive single-sensor acoustic emission (AE) scheme for the detection and localization of cracks in steel rail under loads. In the operation, AE signals were captured by the AE sensor and converted into digital signal data by AE data acquisition module. The digital data were denoised to remove ambient and wheel/rail contact noises, and the denoised data were processed and classified to localize cracks in the steel rail using a deep learning algorithmic model. The AE signals of pencil lead break at the head, web, and foot of steel rail were used to train and test the algorithmic model. In training and testing the algorithm, the AE signals were divided into two groupings (150 and 300 AE signals) and the classification accuracy compared. The deep learning-based AE scheme was also implemented onsite to detect cracks in the steel rail. The total accuracy (average F1 score) under the first and second groupings were 86.6% and 96.6%, and that of the onsite experiment was 77.33%. The novelty of this research lies in the use of a single AE sensor and AE signal-based deep learning algorithm to efficiently detect and localize cracks in the steel rail, unlike existing AE crack-localization technology that relies on two or more sensors and human interpretation.

Keywords: acoustic emission sensor; acoustic emission testing; deep learning; nondestructive testing (NDT)



Citation: Suwansin, W.; Phasukkit, P. Deep Learning-Based Acoustic Emission Scheme for Nondestructive Localization of Cracks in Train Rails under a Load. *Sensors* **2021**, *21*, 272. <http://doi.org/10.3390/s21010272>

Received: 6 December 2020

Accepted: 30 December 2020

Published: 3 January 2021

Publisher's Note: MDPI stays neutral with regard to jurisdictional claims in published maps and institutional affiliations.



Copyright: © 2021 by the authors. Licensee MDPI, Basel, Switzerland. This article is an open access article distributed under the terms and conditions of the Creative Commons Attribution (CC BY) license (<https://creativecommons.org/licenses/by/4.0/>).

1. Introduction

Rail transport plays an important role in transferring a large number of passengers and freight between destinations. The significance of the railway thus necessitates regular structural health monitoring (SHM) to identify welding discontinuity defects in the rail track and maintain the health of steel rail. Scheduled SHM prevents the incidence of rail accidents and improves passenger comfort.

Nondestructive acoustic emission (AE) testing is a passive technique to detect elastic energy spontaneously released by material with developing cracks [1–4]. The AE technique is also deployed to characterize the crack behavior under a load. AE is a transient elastic wave in the frequency range of 95 kHz–300 kHz. The advantages of a passive AE technique over conventional active nondestructive testing (NDT) methods include online monitoring, high sensitivity, early and rapid defect detection [5–8].

The AE signal from cracks in the steel rail is caused by fatigue in wheel/rail contact. If improperly attended to, the rail crack induced by dynamic wheel/rail contact and interaction could result in disastrous failures [9–13]. The defects in steel rail are predominantly fatigue cracks [14–16].

The conventional AE technology (without machine learning) has been applied to inspection and monitoring of building or structural integrity, pressure vessel, pipeline, aircraft components, storage tanks, tanks on tank ship and in material research [17–20]. In structural integrity, AE testing was used to inspect and monitor emerging fatigue cracks

in in-service steel bridges [21–23]. In a pressure vessel, the AE technology was used for online monitoring of fatigue cracks in liquified petroleum gas (LPG) and natural gas for vehicle (NGV) pressure vessels under a load [24,25]. AE was also used to detect and locate corrosion and leakage in underground oil, LPG, and NGV pipelines [26,27].

In aircraft components, the AE technology was used to detect fatigue cracks under a load [28–30]. In a storage tank, AE testing was used to monitor the storage tank health and to detect and locate corrosion and leakage in the bottom plate of storage tank [31,32]. In material research, the AE technology was used to characterize material properties, failures, and crack mechanics [33,34]. In a railway, the technology was utilized to detect and localize fatigue cracks in the steel rail and rail components under a load [35–37]. However, the conventional AE technology for detection and localization of fatigue cracks relies on two or more sensors and on human interpretation, which is prone to error.

To address the human error inherent in the conventional AE technology, image-based deep learning was integrated into the AE technology to localize crack sources in plate-like structures [38]. In a spherical water storage tank, the AE scheme with support vector machine (SVM) was used to classify corrosion and leakage but the scheme failed to localize the source [39]. In a journal bearing, the AE scheme with SVM was used to detect friction and wear [40]. In substation transformer, the AE technology with SVM was used to detect electrical treeing [41]. In [42], an acoustic sensor array with SVM algorithms was proposed to detect shock and vibration in fan matrices. In composite materials, the AE technology with a nonhomogeneous hidden semi-Markov (semi-probability) model was used to predict the remaining useful life and fatigue [43].

Specifically, in [38], a single-sensor AE scheme based on image-based deep learning was proposed to localize defects in plate-like structures. Their proposed scheme utilized a single sensor, similar to this current research. Nevertheless, the deep learning algorithm was image-based while the algorithm of this research is signal-based. In [39–42], multi-sensor and sensor array AE schemes with SVM algorithms were used to detect defects in material. Unlike this current research, their schemes utilized two or more sensors or sensor-array and SVM algorithms. In [43], a multi-sensor AE scheme with hidden semi-Markov (semi-probability) model was proposed for in-situ prognostics of fatigue life of composites. Although the image-based deep learning could localize crack sources, the image-based algorithm requires more computational resources than the proposed AE signal-based classification deep-learning algorithmic scheme.

As a result, this research proposes a nondestructive single-sensor AE scheme with AE signal-based deep learning algorithm for detection and localization of cracks in the steel rail under a load. The AE signals of pencil lead break (PLB) at the head, web, and foot of steel rail were used to train and test the deep learning algorithmic model. In training and testing the algorithm, the AE signals were divided into two groupings and the classification accuracy compared. The AE scheme was subsequently implemented onsite to detect cracks in the steel rail and a comparison of the resulting classification performance was conducted.

2. The Proposed Single-Sensor AE Scheme

Figure 1 illustrates the diagram of the proposed nondestructive single-sensor AE scheme for crack detection in steel rail. Under the proposed scheme, AE signals were captured by the AE sensor and converted into digital signal data by AE data acquisition module. The digital signal data were pre-processed to remove noises using a total variation denoising algorithm. The denoised digital signal data were processed and classified to localize cracks in the steel rail. In the figure, P1, P2, and P3 denote rail head, rail web, and rail foot, respectively.

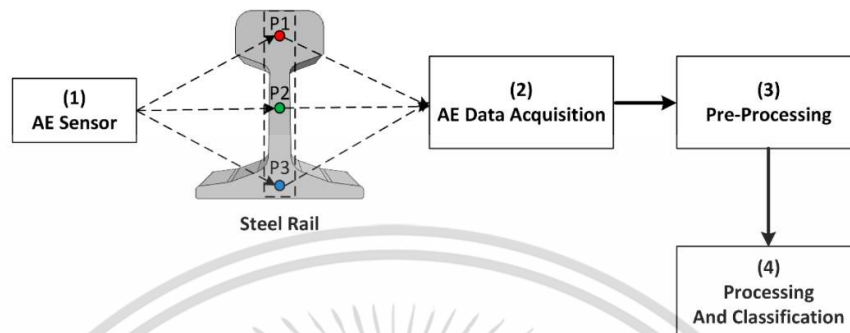


Figure 1. The diagram of the nondestructive single-sensor acoustic emission (AE) scheme for crack detection in steel rail.

2.1. Acoustic Emission Sensor

Acoustic emission (AE) is the transient elastic waves in solids that occur when the internal structure of a material undergoes deformation due to plastic deformation, crack propagation, erosion, corrosion impact, leakage, and fatigue. This research focused on the AE signals caused by fatigue cracks in the steel rail under a load.

The AE sensor was Vallen model VS150-RIC with an 80 kHz–500 kHz bandwidth and -40°C to $+85^{\circ}\text{C}$ operating temperatures. Given the natural frequency of cracks at 150 kHz, the AE sensor was used to capture crack signals (elastic waves) in the steel rail. The AE sensor was of piezoelectric type to convert elastic waves in the steel rail into electrical AE signal. To mitigate the triboelectric effect, the AE sensor of the proposed scheme was integrated electronics piezoelectric (IEPE) sensor, as opposed to the non-IEPE sensor which is more prone to the triboelectric effect. To further mitigate the triboelectric effect, the bandpass filter frequency range of the proposed deep learning-based AE sensor scheme was set at 95 kHz–300 kHz.

2.2. AE Data Acquisition Module

The AE signals captured by the AE sensor were converted into digital signal data by an AE data acquisition module (Vallen AMSY-6) with 16-bit analog-to-digital conversion (ADC). The sampling rate of ADC conversion was 20 MHz. A computer was used for storage of digital signal data.

2.3. Pre-processing of AE Signal Data

Total variation denoising (TVD) algorithm was used to remove noise in the AE signal of cracks in a steel rail. In practical use, TVD is effective in removing ambient noise and rolling noise. Figure 2a shows the AE signal of cracks in steel rail with ambient and wheel/rail noise, and Figure 2b illustrates the denoised AE signal using TVD.

The AE signal with ambient noise and rolling noise is mathematically expressed in Equation (1).

$$y = x + w \quad (1)$$

where y is noisy AE signal, x is unnoisy AE signal, and w is additive white Gaussian noise.




Figure 3. Majorization-minimization (MM) procedure: (a) cost function $F(x)$ to be minimized and initial x_0 ; (b) iteration 1 where majorizer $G_0(x)$ is tangent to $F(x)$ at x_0 and minimize $G_0(x)$ for x_1 ; (c) iteration 1 where majorizer $G_1(x)$ is tangent to $F(x)$ at x_1 and minimize $G_1(x)$ for x_2 .

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

2.4. Processing and Classification

Figure 4 illustrates the typical deep learning algorithm for classification, consisting of the input (feature) layer, hidden layers through to N hidden layer, and output (target) layer. In this research, the activation function between hidden layers was hyperbolic tangent function ($\tanh(z)$) since the function is ideal for the transient nature of AE signal and is capable of suppressing noises and interferences. The softmax activation function ($\text{softmax}(z)$) was used for classification based on probability. The aim of deep learning algorithm for classification is to localize cracks in the rail head, rail web, and rail foot of steel rail.




Figure 4. The typical deep learning algorithm for classification.

Prior to algorithm training and validation, input (feature) data were scaled using standardization to normalize, as shown in Equation (5).

$$\text{Standardization} = \frac{x - \text{Mean } X}{SD} \tag{5}$$

where x is the feature (input data), Mean x is the mean value of feature, and SD is standard deviation.

In training the algorithmic model, the initial weight (W) and bias (B) (i.e., $W_1, B_1, W_2, B_2, W_3, B_3, W_4, B_4$), were random. In feedforward, hyperbolic tangent function ($\tanh(z)$) was the activation function between hidden layers, as shown in Equation (6) where $\tanh(z) = [-1, 1]$. The output layer used $\text{softmax}(z)$ as the activation function for classification based on probability, as shown in Equation (7) and the linear combination, as shown in Equation (8).

$$\tanh(z) = \frac{e^z - e^{-z}}{e^z + e^{-z}} \tag{6}$$

$$\text{softmax}(z) = \frac{e^{z_i}}{\sum_{j=1}^k e^{z_j}} \tag{7}$$

$$Z = \begin{bmatrix} z_1 \\ z_2 \\ \vdots \\ z_N \end{bmatrix} = \begin{bmatrix} x_1^1 w_1 & x_1^2 w_2 & \dots & x_1^D w_D \\ x_2^1 w_1 & x_2^2 w_2 & \dots & x_2^D w_D \\ \vdots & \vdots & \ddots & \vdots \\ x_N^1 w_1 & x_N^2 w_2 & \dots & x_N^D w_D \end{bmatrix} + [B_1 \ B_2 \ \dots \ B_D] \tag{8}$$

Partial derivative of the hyperbolic tangent function ($\tanh(z)$) was used in back propagation, as shown in Equation (9).

$$\frac{\partial[\tanh(z)]}{\partial z} = 1 - \tanh^2(z) = \text{sech}^2(z) \tag{9}$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

The cross-entropy loss function for multiclass was used to fine-tune the optimization of the algorithmic model, as shown in Equation (10).

$$J(w) = -\frac{1}{N} \sum_{n=1}^N (Y_n \log(\hat{Y}_n)) \quad (10)$$

where Y_n is true output value and \hat{Y}_n is predicted output value.

3. Experimental Material and Setup

3.1. Experimental Steel Rail

The experimental steel rail was of UIC 54 type, which is the steel rail commonly used in countries in the Southeast Asian region. The elemental composition of UIC 54 steel rail was analyzed by handheld laser-induced breakdown spectroscopy (LIBS) analyzer (SciAps, model Z-300). Table 1 tabulates the elemental composition of UIC 54 steel rail.

Table 1. Elemental composition of UIC 54 steel rail.

%C	%Si	%Mn	%V	%Ni	%Cu
0.68	0.22	1.18	0.003	0.0068	0.0109

3.2. AE Data Sensor and Acquisition Module

Figure 5a shows the AE data acquisition module with 16-bit ADC and a sampling rate of 20 MHz (Vallen AMSY-6). Figure 5b illustrates the AE sensor (S/N 10453) with 80 kHz–500 kHz bandwidth and -40 °C to $+85$ °C operating temperatures (Vallen model VS150-RIC). The MAG4R magnetic holder was used to attach the AE sensor to the steel rail (on the field side of the rail head).




Figure 5. AE data sensor and acquisition: (a) AE data acquisition module; (b) AE sensor, MAG4R magnetic holder, and Hsu-Nielsen source.

The Hsu-Nielsen source was used as the artificial source of AE signal of crack, consisting of 2H pencil lead (0.5 mm), guide tube, and mechanical pencil. The pencil lead was broken against the head, web, and foot of steel rail at 30° , in accordance with the American Society for Testing and Materials (ASTM E976) standard.

3.3. AE Sensor Amplitude Testing

The AE sensor amplitude was analyzed prior to capturing the AE signals of cracks in the steel rail to determine the sensor sensitivity and sensor coupling. The AE sensor amplitude testing was carried out at the rail head by breaking 2H pencil lead (0.5 mm) against the steel rail. The testing was performed five consecutive times and results averaged.

Figure 6 illustrates the peak amplitude (dB) of the AE sensor relative to time (s), and the results are tabulated in Table 2. In Figure 6, the maximum peak amplitude of the

experimental AE sensor was greater than 80 dB (>80 dB), indicating that the AE sensor could be deployed to capture the AE signals of cracks in the steel rail.




Figure 6. Peak amplitude of AE sensor relative to time.

Table 2. Peak amplitude and average amplitude of the AE sensor.

Sensor S/N	1st PLB	2nd PLB	3rd PLB	4th PLB	5th PLB	Average
10,453	93.90	92.40	95.20	95.00	93.90	94.08

3.4. Datasets for Training and Testing the Deep Learning Algorithmic Model

The digital signal data of PLB at the head, web, and foot of steel rail were datasets for training and testing the proposed deep learning algorithmic model. PLB were carried out 150 times each at the head, web, and foot of steel rail; and the AE signals were captured, totaling 450 AE signals (Figure 7).




Figure 7. Locations of pencil lead break (PLB): (a) rail head, (b) rail web, (c) rail foot.

The un-dennoised AE signals were subsequently divided into two groupings (150 and 300 AE signals) to investigate the effect of number of input data on the classification accuracy of the deep learning algorithmic model. Under the first grouping (150 AE signals), the input data were divided into a training dataset (80% of the input data) and a testing dataset (20%). Under the second grouping (300 AE signals), 80% of the input data were training dataset and the rest (20%) were testing dataset.

Figure 8a–c shows the un-denoised AE signals (prior to pre-processing) of PLB at the head, web, and foot of steel rail. The AE signals of PLB were captured by the AE sensor and converted by the AE acquisition module into un-denoised AE digital signal data prior to pre-processing by total variation denoising (TVD) algorithm to remove the ambient noise.




Figure 8. Un-denoised AE signals of PLB at: (a) rail head, (b) rail web, (c) rail foot.

Figure 9 illustrates the conversion procedure of denoised AE signals (after pre-processing) of PLB into feature datasets (input data) for training and testing the deep learning algorithmic model. The training and testing datasets were transferred to a spreadsheet. The feature datasets were divided into two groupings (150 and 300 feature datasets) to investigate the effect of number of input data on the classification accuracy of the deep learning algorithmic model.

Under the first grouping (150 feature datasets), 50 datasets each belonged to PLB at the head, web, and foot of steel rail. The feature datasets were divided into training dataset (80%) and testing dataset (20%). Under the second grouping (300 feature datasets), 100 datasets each belonged to PLB at the head, web, and foot of steel rail. Likewise, 80% of the input data were training dataset and the rest (20%) were testing dataset. Given the sampling rate of 20 MHz of the AE acquisition module, one feature dataset (i.e., one denoised AE signal) contained 300,000 data points.

In this research, one AE signal contains 300,000 data points, and the time to capture one data point is 0.05 μ s, given $f_s = 20$ MHz. As a result, the time required to capture one AE signal (i.e., 300,000 data points) is 0.015 s ($= 300,000 \times 0.05 \times 10^{-6}$).

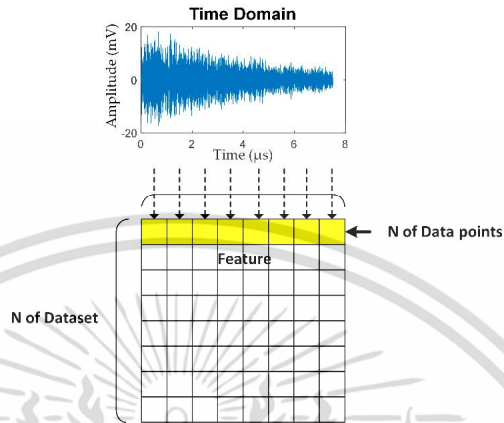


Figure 9. Conversion of denoised AE signals (after pre-processing) of PLB into dataset for training and testing the deep learning algorithmic model.

In Figure 10, one row of yellow grid cells represents one AE signal (300,000 data points), and the total number of rows (i.e., N of Dataset) represents 450 AE signals (PLB digital signal data = 450 signals) at the rail head, web, and foot. In the columns “Target”, the rail head, rail web, and rail foot are represented by red, green, and blue colors, respectively.




Figure 10. Feature and target datasets for training and testing the deep learning algorithmic model.

In training the deep learning algorithm, a specific target (either rail head, web, or foot) was assigned to each row of yellow grid cells (i.e., each AE signal) using one-hot encoding, where 1 denotes a 100% probability and 0 a zero probability. The training was carried out separately for the first grouping (80% of the input data = 120 signals) and second grouping (80% of the input data = 240 signals) of AE signals.

In testing the deep learning algorithm, a given AE signal was applied to the trained deep-learning algorithm and the algorithm classified the crack location based on probability, where Y1, Y2, and Y3 denote the head, web, and foot of steel rail, respectively. In testing the algorithm, there were 30 signals (20% of the input data) for the first grouping, consisting of 10 signals each for rail head, web, and foot. Meanwhile, there were 60 signals (20% of the input data) for the second grouping, consisting of 20 signals each for rail head, web, and foot.

The following example is to show the testing process of the algorithm, assuming that the deep learning-generated probability of Y1, Y2, and Y3 of the first row of yellow grid cells (AE signal#01) are 0.1 (10%), 0.4 (40%), and 0.5 (50%), the proposed deep learning algorithm would select Y3 (rail foot) as the location of the crack, based on the highest probability value.

3.5. Proposed Deep Learning Algorithm for Classification

Figure 11 illustrates the proposed deep learning algorithm for classification. The AE data points were input of the feature layer, and one AE signal contained 300,000 data points, as represented by X1, X2, X3 ... X300,000. In this research, there were 450 AE signals of PLB under two groupings.




Figure 11. The proposed deep learning algorithm for classification.

The proposed algorithmic model consisted of three hidden layers and one output layer. The first, second, and third hidden layers had 5, 4, and 3 nodes, respectively. The activation function between hidden layers was hyperbolic tangent function ($\tanh(z)$), which transforms linear to nonlinear function. The output layer consisted of Y1 (crack in the rail head), Y2 (crack in the rail web), and Y3 (crack in the rail foot). The softmax activation function ($\text{softmax}(z)$) was used for classification based on probability. The aim of the proposed deep learning algorithm for classification is to localize cracks in the rail head, rail web, and rail foot of steel rail.

Figure 12 illustrates the process of training and testing the proposed deep learning algorithmic model and the model validation. The AE datasets (feature and target datasets) were divided into a training dataset (80%) and a testing dataset (20%).

The training dataset consisted of X_Train (normalized feature/input dataset) and Y_Train (target/output dataset), while the testing dataset comprised X_Test (normalized feature dataset) and Y_Test (target dataset). The initial weight (W) and bias (B) in the hidden layers ($W_1, B_1, W_2, B_2, W_3, B_3, W_4, B_4$) were random, given the learning rate (α) of 0.1 and epoch of 1000. W and B were fine-tuned by gradient descent iterative optimization algorithm.

In the training and testing processes, L1-norm regularization was utilized to avoid overfitting due to excessive data points (300,000 data points per AE signal) and divergence between the cross-entropy loss of training and testing datasets.

The classification results of the optimized algorithmic model ($Y_{Predict}$) were compared against the training (Y_{Train}) and testing target (Y_{Test}) datasets to evaluate the classification performance of the proposed deep learning algorithm.




Figure 12. Training and testing the proposed deep learning algorithm and the model validation.

3.6. Evaluation of the Deep Learning Algorithm

The classification performance of the proposed deep learning algorithmic model was evaluated by comparing the classification results using the algorithmic model against the training and testing target datasets. The performance metrics were the receiver operating characteristic (ROC) curve, confusion matrix, F1 score, and total accuracy (average F1 score).

3.6.1. Receiver Operating Characteristic (ROC) Curve

A receiver operating characteristic (ROC) curve shows the classification performance of an algorithmic model whereby the area under the ROC curve is used as a performance indicator of the model. The ROC curve plots two parameters: true positive rate (y-axis) and false positive rate (x-axis). The true positive rate (TPR) and false positive rate (FPR) can be calculated by Equations (11) and (12), respectively.

$$\text{True positive rate (TPR)} = \frac{TP}{TP + FN} \quad (11)$$

where TP is the number of true positives classified by the algorithmic model and FN is the number of false negatives classified by the algorithmic model.

$$\text{False positive rate (FPR)} = \frac{FP}{TN + FP} \quad (12)$$

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

where FP is the number of false positives classified by the algorithmic model and TN is the number of true negatives classified by the algorithmic model.

3.6.2. Confusion Matrix, F1 Score and Total Accuracy (Average F1 Score)

The confusion matrix is a table layout that enables visualization of the classification performance of an algorithmic model. F1 score is a value that indicates the classification performance of the algorithmic model using Precision (Equation (13)) and Recall. The Recall equation in the F1 Score calculation is identical to Equation (11) (true positive rate). As a result, equation (11) can be used in the Recall calculation. F1 Score, Individual-class Accuracy and Total accuracy (the average of F1 scores) can be calculated by Equations (14)–(16), respectively.

$$\text{Precision} = \frac{TP}{TP + FP} \quad (13)$$

$$\text{F1 Score} = \frac{2 * \text{Precision} * \text{Recall}}{\text{Precision} + \text{Recall}} \quad (14)$$

$$\text{Individual-class Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (15)$$

$$\text{Total Accuracy (average F1 Score)} = \frac{(\text{F1 score (class 0)}) + (\text{F1 score (class 1)}) + (\text{F1 score (class 2)})}{3} \quad (16)$$

4. Onsite Experimental Setup

4.1. Onsite Advanced Phased Array Ultrasonic Testing (PAUT)

Prior to the implementation of the proposed AE scheme for crack detection in steel rail, advanced PAUT with 5 MHz 64-channel linear array probe (model GEKKO; M2M, France) was applied to welding joints of the steel rail to determine and localize cracks. The PAUT detection was carried out on the welding joints due to their susceptibility to subsurface crack. The proposed AE scheme was subsequently applied to the same welding joints with defects, and the detection results of the AE scheme were validated against those of PAUT to evaluate the classification performance of the deep learning algorithmic model. Figure 13a,b show the advanced PAUT on a welding joint of the steel rail and the defect in the welding joint.




Figure 13. Onsite experimental setup: (a) advanced phased array ultrasonic testing (PAUT) on welding joint of the steel rail; (b) PAUT detection with defect in the welding joint.

4.2. Steel Rail Temperatures

Given the operating temperature range of -40 to 85 °C of the experimental AE sensor, the temperatures of steel rail around mid-day were measured by using a thermal imaging

camera (FLIR, USA.) prior to the installation of the AE sensor. The steel rail temperatures were 56.7–61.1 °C, as shown in Figure 14. The steel rail temperatures were within the operating temperature range of the AE sensor.




Figure 14. Steel rail temperature measurement.

4.3. Onsite Experiment on the Steel Rail under Load

Figure 15a illustrates the installation of the AE sensor on the field side of the head of steel rail to detect crack. Figure 15b shows the onsite experiment of the AE scheme with the steel rail under a load. The AE signals of the steel rail under a load were fatigue cracks induced by wheel/rail contact. The AE signals were captured by the sensor and converted into digital signal data by the data acquisition module. The digital signal data were pre-processed to denoise and processed by the deep learning algorithmic model to localize cracks in the steel rail.



Figure 15. Onsite experiment on steel rail using the AE scheme: (a) installation of the AE sensor on the steel rail; (b) AE signal data of the steel rail under a load.

5. Results and Discussion

5.1. Receiver Operating Characteristic (ROC) Curve

The effects of different number of feature datasets (input data) on the classification accuracy of the deep learning algorithmic model were determined by dividing the datasets into two groupings (150 and 300 AE signals). Figure 16a,b respectively illustrate the ROC curves under the first and second groupings, where classes 0, 1, and 2 denote the head, web, and foot of steel rail.

Under the first grouping, the accuracy performance of the deep learning algorithmic model for class 0 (crack from the rail head), class 1 (rail web), and class 2 (rail foot) were

100% (ROC curve area = 1.0), 95% (0.95), and 82% (0.82). Under the second grouping, the accuracy performance for class 0, class 1, and class 2 were 97% (0.97), 99% (0.99), and 96% (0.96), respectively. The results indicated that the classification accuracy of the deep learning algorithmic model increased with increase in the datasets.




Figure 16. Receiver operating characteristic (ROC) curve where classes 0, 1, and 2 denote rail head, rail web, and rail foot: (a) 150 AE signals (first grouping); (b) 300 AE signals (second grouping).

5.2. Confusion Matrix of the Deep Learning Algorithmic Model

Figure 17a,b show the confusion matrix of the deep learning algorithmic model for classification under first (150 datasets) and second (300 datasets) groupings of AE signal datasets. In Figure 17a (the first grouping), given 10 crack signals from the rail head (actual), the algorithmic model accurately classified 10 signals (predicted) as from the rail head. For the rail web, out of 10 crack signals (actual), the algorithmic model accurately classified 9 signals (predicted) as from the rail web and erroneously one signal as from the rail foot. For the rail foot, out of 10 crack signals (actual), the model accurately classified 7 signals (predicted) as from the rail foot and erroneously three signals as from the rail head.




Figure 17. Confusion matrix of the deep learning algorithm for classification: (a) 150 AE signals (first grouping); (b) 300 AE signals (second grouping).

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

In Figure 17b (the second grouping), given 20 crack signals from rail head (actual), the algorithmic model accurately classified 19 signals (predicted) as from the rail head and erroneously one signal as from the rail foot. For the rail web, out of 20 crack signals (actual), the algorithmic model accurately classified 20 signals (predicted) as from the rail web. For the rail foot, out of 20 crack signals (actual), the model accurately classified 19 signals (predicted) as from the rail foot and erroneously one signal as from the rail web.

5.3. F1 Scores of the Deep Learning Algorithmic Model

Table 3 compares the F1 scores and total accuracy of the first (150 AE signals) and second (300 AE signals) groupings. *Precision* and *Recall* were calculated from the confusion matrix (Figure 17). Under the first grouping, the F1 scores for the head, web, and foot of steel rail were 90%, 90%, and 85%, respectively, with a total accuracy of 88.33%. Under the second grouping, the corresponding F1 scores were 95%, 95%, and 92.5%, with a total accuracy of 94.5%. The F1 scores and total accuracy improved as the number of AE signals increased from 150 to 300 signals.

Table 3. Comparison between F1 score and total accuracy of the first (150 AE signals) and second groupings (300 AE signals).

	Rail Head (150 AE Signals)	Rail Head (300 AE Signals)	Rail Web (150 AE Signals)	Rail Web (300 AE Signals)	Rail Foot (150 AE Signals)	Rail Foot (300 AE Signals)
Precision (%) (Equation (13))	76.9	100	100	95.2	87.5	95
Recall (%) (Equation (11))	100	95	90	100	70	95
F1 score (%) (Equation (14))	86.9	97.4	94.7	97.5	77.7	95
Accuracy (%) (Equation (15))	90	98	96	98	86	96
Total Accuracy (%) (Equation (16))			86.6 (150 AE signals)			
Total Accuracy (%) (Equation (16))			96.6 (300 AE signals)			

5.4. Onsite AE Signals Using the Proposed AE Scheme

Figure 18 shows the AE signals of cracks in the welding joint of the steel rail under a load using the nondestructive single-sensor AE scheme. Prior to the implementation of the proposed AE sensor scheme under a load, the advanced PAUT was first used to localize cracks in the steel rail, and the crack locations were used as reference (i.e., actual results). The crack localization by PAUT was carried out at welding joints of the steel rail since the welding joints are highly susceptible to crack. In the crack location, the PAUT probe was placed on top of the steel rail above the welding joint (offline monitoring), in accordance with ASTM E2700 standard (Figure 13).

The proposed AE sensor scheme was then implemented under a load (online monitoring) at the same welding joints previously analyzed by the PAUT. The proposed deep learning algorithm localized the crack in steel rail for each AE signal (from steel rail under a load) based on the highest deep learning-generated probability value. The crack localization results by the proposed deep learning-based AE sensor scheme were compared against the reference (actual results by the PAUT). In this research, the F1 scores (classification accuracy) of the proposed AE sensor scheme for onsite localization of cracks in the rail head, web, and foot were 78%, 80%, and 74%, compared with the PAUT results. The total accuracy (average F1 score) of the proposed AE sensor scheme was 77.33%.




Figure 18. AE signals of cracks in the welding joint of the steel rail under a load using the single-sensor AE scheme.

6. Conclusions

This research proposed the deep learning-based single-sensor AE scheme for localization of cracks in the head, web, and foot of steel rail under a load. The AE signals captured by the AE sensor were converted into digital signal data and denoised using a TVD algorithm. The denoised signal data were used to localize the cracks by using a deep learning algorithm. The proposed AE sensor scheme was also implemented onsite to detect cracks in the head, web, and foot of steel rail. The experimental results showed that the classification accuracy (F1 scores) of the AE sensor scheme for onsite localization of cracks in the rail head, web, and foot were 78%, 80%, and 74%, compared with the PAUT results. The total accuracy (average F1 score) of the AE sensor scheme was 77.33%. To improve the total accuracy (average F1 score), subsequent research should increase the number of AE signal data in training the deep learning algorithm, in addition to experimenting with alternative pre-processing algorithms with a higher denoising capability.

Author Contributions: Conceptualization, W.S.; methodology, W.S. and P.P.; validation, W.S. and P.P.; formal analysis, W.S. and P.P.; investigation, W.S. and P.P. writing—original draft preparation, W.S.; writing—review and editing, W.S. and P.P.; funding acquisition, P.P. All authors have read and agreed to the published version of the manuscript.

Funding: This research was funded by the School of Engineering, King Mongkut's Institute of Technology Ladkrabang, Bangkok 10520, Thailand.

Institutional Review Board Statement: Not applicable.

Informed Consent Statement: Not applicable.

Data Availability Statement: Not applicable.

Acknowledgments: The authors would like to express deep gratitude to BURNLAB, Department of Electronics, the Faculty of Engineering; and to the International Academy of Aviation Industry (IAAI), King Mongkut's Institute of Technology Ladkrabang (KMITL). Sincere appreciation also goes to Jirasak Tharajak for the acoustic emission system, Soemsak Yooyen for the co-working space at IAAI, and BURNLAB members for onsite data collection.

Conflicts of Interest: The authors declare no conflict of interest.

References

- Jiang, X.; Kim, K.; Zhang, S.; Johnson, J.; Salazar, G. High-Temperature Piezoelectric Sensing. *Sensors* **2014**, *14*, 144–169. [[CrossRef](#)] [[PubMed](#)]
- Lord, A.E. Acoustic Emission. In *Physical Acoustics*; Elsevier: Amsterdam, The Netherlands, 1975; pp. 289–353.
- Schabowicz, K. Non-Destructive Testing of Materials in Civil Engineering. *Materials* **2019**, *12*, 3237. [[CrossRef](#)] [[PubMed](#)]
- Zaki, A.; Chai, H.K.; Aggelis, D.G.; Alver, N. Non-Destructive Evaluation for Corrosion Monitoring in Concrete: A Review and Capability of Acoustic Emission Technique. *Sensors* **2015**, *15*, 19069–19101. [[CrossRef](#)] [[PubMed](#)]
- Zhang, X.; Feng, N.; Wang, Y.; Shen, Y. An Analysis of the Simulated Acoustic Emission Sources with Different Propagation Distances, Types and Depths for Rail Defect Detection. *Appl. Acoust.* **2014**, *86*, 80–88. [[CrossRef](#)]

6. Kwon, J.-R.; Lyu, G.-J.; Lee, T.-H.; Kim, J.-Y. Acoustic emission testing of repaired storage tank. *Int. J. Press. Vessel. Pip.* **2001**, *78*, 373–378. [[CrossRef](#)]
7. Morhain, A.; Mba, D. Bearing defect diagnosis and acoustic emission. *Proc. Inst. Mech. Eng. Part J J. Eng. Tribol.* **2003**, *217*, 257–272. [[CrossRef](#)]
8. Song, X.-C.; Huang, S.-L.; Zhao, W. Optimization of the magnetic circuit in the MFL inspection system for storage-tank floors. *Russ. J. Nondestruct. Test.* **2007**, *43*, 326–331. [[CrossRef](#)]
9. Barke, D.; Chiu, W.K. Structural Health Monitoring in the Railway Industry: A Review. *Struct. Health Monit.* **2005**, *4*, 81–93. [[CrossRef](#)]
10. Ekberg, A.; Kabo, E. Fatigue of railway wheels and rails under rolling contact and thermal loading—An overview. *Wear* **2005**, *258*, 1288–1300. [[CrossRef](#)]
11. Li, Z.; Zhao, X.; Dollevoet, R. An approach to determine a critical size for rolling contact fatigue initiating from rail surface defects. *Int. J. Rail Transp.* **2016**, *5*, 16–37. [[CrossRef](#)]
12. Nielsen, J.C.O.; Johansson, A. Out-of-round railway wheels—A literature survey. *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit* **2000**, *214*, 79–91. [[CrossRef](#)]
13. Zerbst, U.; Lundén, R.; Edel, K.-O.; Smith, R. Introduction to the damage tolerance behaviour of railway rails—A review. *Eng. Fract. Mech.* **2009**, *76*, 2563–2601. [[CrossRef](#)]
14. Ekberg, A.; Åkesson, B.; Kabo, E. Wheel/rail rolling contact fatigue—Probe, predict, prevent. *Wear* **2014**, *314*, 2–12. [[CrossRef](#)]
15. Kapoor, A.; Fletcher, D.; Franklin, F.J. The role of wear in enhancing rail life. In *Tribology Series*; Elsevier: Amsterdam, The Netherlands, 2003; pp. 331–340.
16. Ngamkhanong, C.; Kaewunruen, S.; Costa, B.J.A. State-of-the-Art Review of Railway Track Resilience Monitoring. *Infrastructures* **2018**, *3*, 3. [[CrossRef](#)]
17. Behnia, A.; Chai, H.K.; Shiotani, T. Advanced structural health monitoring of concrete structures with the aid of acoustic emission. *Constr. Build. Mater.* **2014**, *65*, 282–302. [[CrossRef](#)]
18. Ledeczi, A.; Hay, T.; Volgyesi, P.; Hay, D.; Nadas, A.; Jayaraman, S. Wireless Acoustic Emission Sensor Network for Structural Monitoring. *IEEE Sens. J.* **2009**, *9*, 1370–1377. [[CrossRef](#)]
19. Nair, A.; Cai, C. Acoustic emission monitoring of bridges: Review and case studies. *Eng. Struct.* **2010**, *32*, 1704–1714. [[CrossRef](#)]
20. Zelenyák, A.-M.; Hamstad, M.A.; Sause, M.G.R. Modeling of Acoustic Emission Signal Propagation in Waveguides. *Sensors* **2015**, *15*, 11805–11822. [[CrossRef](#)]
21. Holford, K.M.; Davies, A.; Pullin, R.; Carter, D. Damage Location in Steel Bridges by Acoustic Emission. *J. Intell. Mater. Syst. Struct.* **2001**, *12*, 567–576. [[CrossRef](#)]
22. Li, D.; Ou, J.; Lan, C.; Li, H. Monitoring and Failure Analysis of Corroded Bridge Cables under Fatigue Loading Using Acoustic Emission Sensors. *Sensors* **2012**, *12*, 3901–3915. [[CrossRef](#)]
23. Roberts, T.; Talebzadeh, M. Fatigue life prediction based on crack propagation and acoustic emission count rates. *J. Constr. Steel Res.* **2003**, *59*, 679–694. [[CrossRef](#)]
24. Chou, H.; Mouritz, A.; Bannister, M.; Bunsell, A.R. Acoustic emission analysis of composite pressure vessels under constant and cyclic pressure. *Compos. Part A Appl. Sci. Manuf.* **2015**, *70*, 111–120. [[CrossRef](#)]
25. Ennacour, C.; Laksimi, A.; Hervé, C.; Cherfaoui, M. Monitoring crack growth in pressure vessel steels by the acoustic emission technique and the method of potential difference. *Int. J. Press. Vessel. Pip.* **2006**, *83*, 197–204. [[CrossRef](#)]
26. Mostafapour, A.; Davoudi, S. Analysis of leakage in high pressure pipe using acoustic emission method. *Appl. Acoust.* **2013**, *74*, 335–342. [[CrossRef](#)]
27. Shehadeh, M.; Steel, J.A.; Reuben, R.L. Acoustic Emission Source Location for Steel Pipe and Pipeline Applications: The Role of Arrival Time Estimation. *Proc. Inst. Mech. Eng. Part E J. Process. Mech. Eng.* **2006**, *220*, 121–133. [[CrossRef](#)]
28. Esola, S.; Wisner, B.; Vanniamparambil, P.A.; Geriguis, J.; Kotsos, A. Part Qualification Methodology for Composite Aircraft Components Using Acoustic Emission Monitoring. *Appl. Sci.* **2018**, *8*, 1490. [[CrossRef](#)]
29. Holford, K.M.; Pullin, R.; Evans, S.L.; Eaton, M.J.; Hensman, J.; Worden, K. Acoustic emission for monitoring aircraft structures. *Proc. Inst. Mech. Eng. Part G J. Aerosp. Eng.* **2009**, *223*, 525–532. [[CrossRef](#)]
30. Zhang, Z.; Yang, G.; Liu, K. Prediction of Fatigue Crack Growth in Gas Turbine Engine Blades Using Acoustic Emission. *Sensors* **2018**, *18*, 1321. [[CrossRef](#)]
31. Bi, H.; Li, H.; Zhang, W.; Wang, L.; Zhang, Q.; Cao, S.; Toku-Gyamerah, I. Evaluation of the acoustic emission monitoring method for stress corrosion cracking on aboveground storage tank floor steel. *Int. J. Press. Vessel. Pip.* **2020**, *179*, 104035. [[CrossRef](#)]
32. Jirungsatian, C.; Prateepasen, A. Pitting and uniform corrosion source recognition using acoustic emission parameters. *Corros. Sci.* **2010**, *52*, 187–197. [[CrossRef](#)]
33. Čapek, J.; Knapek, M.; Minárik, P.; Dittrich, J.; Máthys, K. Characterization of Deformation Mechanisms in Mg Alloys by Advanced Acoustic Emission Methods. *Metals* **2018**, *8*, 644. [[CrossRef](#)]
34. Ono, K. Acoustic Emission in Materials Research—A Review. *J. Acoust. Emiss.* **2011**, *29*, 284–308.
35. Kostryzhev, A.G.; Davis, C.L.; Roberts, C. Detection of crack growth in rail steel using acoustic emission. *Ironmak. Steelmak.* **2013**, *40*, 98–102. [[CrossRef](#)]
36. Shi, S.; Han, Z.; Liu, Z.; Vallely, P.; Souza, S.; Kaewunruen, S.; Papaelias, M. Quantitative monitoring of brittle fatigue crack growth in railway steel using acoustic emission. *Proc. Inst. Mech. Eng. Part F J. Rail Rapid Transit* **2018**, *232*, 1211–1224. [[CrossRef](#)]

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

37. Thakkar, N.; Steel, J.; Reuben, R.L. Rail-wheel interaction monitoring using Acoustic Emission: A laboratory study of normal rolling signals with natural rail defects. *Mech. Syst. Signal Process.* **2010**, *24*, 256–266. [[CrossRef](#)]
38. Ebrahimkhanlou, A.; Salamone, S. Single-Sensor Acoustic Emission Source Localization in Plate-Like Structures Using Deep Learning. *Aerospace* **2018**, *5*, 50. [[CrossRef](#)]
39. Sohaib, M.; Islam, M.M.M.; Kim, J.Y.; Jeon, D.-C.; Kim, J.-M. Leakage Detection of a Spherical Water Storage Tank in a Chemical Industry Using Acoustic Emissions. *Appl. Sci.* **2019**, *9*, 196. [[CrossRef](#)]
40. Mokhtari, N.; Pelham, J.G.; Nowoisky, S.; Bote-Garcia, J.-L.; Gühmann, C. Friction and Wear Monitoring Methods for Journal Bearings of Geared Turbofans Based on Acoustic Emission Signals and Machine Learning. *Lubricants* **2020**, *8*, 29. [[CrossRef](#)]
41. Dobrzycki, A.; Mikulski, S.; Opydo, W. Using ANN and SVM for the Detection of Acoustic Emission Signals Accompanying Epoxy Resin Electrical Treeing. *Appl. Sci.* **2019**, *9*, 1523. [[CrossRef](#)]
42. Del Val, L.; Izquierdo, A.; Villacorta, J.J.; Suárez, L. Comparison of Methodologies for the Detection of Multiple Failures Using Acoustic Images in Fan Matrices. *Shock. Vib.* **2020**, *2020*, 5816050. [[CrossRef](#)]
43. Loutas, T.; Eleftheroglou, N.; Zarouchas, D. A data-driven probabilistic framework towards the in-situ prognostics of fatigue life of composites based on acoustic emission data. *Compos. Struct.* **2017**, *161*, 522–529. [[CrossRef](#)]
44. Ivan, S. *Total Variation Denoising (An MM Algorithm)*; NYU Polytechnic School of Engineering Lecture Notes 32; NYU: New York, NY, USA, 2012.



เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า
ไม่ว่ากรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

ประวัติผู้เขียน

ชื่อ-นามสกุล	นายวรา สุวรรณสินธุ์
วัน เดือน ปีเกิด	19 กุมภาพันธ์ 2518 ที่จังหวัดพระนครศรีอยุธยา
ที่อยู่	456/89 หมู่บ้านพร้อมพัฒนาพร้าว ถนนปัญญาอินทรา แขวงสามวาตะวันตก เขตคลองสามวา กรุงเทพมหานคร 10510 โทร. 086-627-4578
ประวัติการศึกษา	พ.ศ. 2542 วิศวกรรมศาสตรบัณฑิต สาขาวิชา วิศวกรรมอิเล็กทรอนิกส์ มหาวิทยาลัยเทคโนโลยีมหานคร พ.ศ. 2557 วิศวกรรมศาสตรมหาบัณฑิต สาขาวิชา วิศวกรรมชีวการแพทย์ สถาบันเทคโนโลยีพระจอมเกล้าเจ้าคุณทหารลาดกระบัง
ประสบการณ์การทำงานและผลงานวิจัย	
พ.ศ. 2549 - ปัจจุบัน	ตำแหน่ง General Manager บริษัท อินเมต โซลูชั่น จำกัด
พ.ศ. 2555	ตีพิมพ์หัวข้อวิจัย “Analysis of heat transfer and specific absorption rate of electromagnetic field in human body at 915 MHz and 2.45 GHz with 3D finite element method,” 2012 5th Biomedical Engineering International Conference (BMEiCON), Ubon Ratchathani, Thailand, December 2012, DOI: 10.1109/BMEiCon.2012.6465473
พ.ศ. 2556	ตีพิมพ์หัวข้อวิจัย “Simulation of Bio-effects and SAR of Electromagnetic Field in human body at 915 MHz and 2.45 GHz with 3D finite element method,” 2013 International Conference on Simulation Technology (JSST 2013). September 11 – 13, 2013, Meiji University Surugadai campus, Japan
พ.ศ. 2558	ตีพิมพ์หัวข้อวิจัย “Model of Electromagnetic Wave Penetration in Human Body due to Emission from Industrial Electromagnetic Field Source,” 2015 International Conference on Simulation Technology (JSST 2015). October 12 – 14, 2015, Toyama, Japan
พ.ศ. 2558	ตีพิมพ์หัวข้อวิจัย “3D Finite Element Analysis of Specific Absorption Rate Distribution in Virtual Physiological Human Modeling,” 2015

เอกสารนี้เป็นเอกสารที่สงวนไว้สำหรับการใช้งานเพื่อการศึกษาเท่านั้น ไม่อนุญาตให้นำไปใช้ประโยชน์ด้านการค้า ไม่ว่าจะกรณีใดๆ ทั้งสิ้น อีกทั้งห้ามมิให้ดัดแปลงเนื้อหา และต้องอ้างอิงถึงเจ้าของเอกสารทุกครั้งที่มีการนำไปใช้

International Symposium on Multimedia and Communication Technology. September 23 – 25, 2015, Classic Kameo Hotel, Ayutthaya, Thailand

- พ.ศ. 2559 ตีพิมพ์หัวข้อวิจัย “Phantom-Model Experiment of Breast Cancer Detection using UWB,” 2016 International Symposium on Multimedia and Communication Technology (ISMAC), August 31 – September 2, 2016. Tokyo City University, Tokyo, Japan
- พ.ศ. 2560 ตีพิมพ์หัวข้อวิจัย “Dielectric Properties of Tissue Analysis for Breast Cancer Detection,” 2017 International Symposium on Multimedia and Communication Technology. August 23 – 25, 2017, Classic Kameo Hotel, Ayutthaya, Thailand
- พ.ศ. 2562 ตีพิมพ์หัวข้อวิจัย “Using Multi Regression for the Prediction of Aircraft Takeoff Airspeeds at the Paro Airport,” 2019 1st Innovation Aviation & Aerospace Industry – International Conference 2020 (IAAI 2020), Chumphon, Thailand, 2019”
- พ.ศ. 2564 ตีพิมพ์หัวข้อวิจัย “Deep Learning-based Acoustic Emission scheme for Nondestructive Localization of Cracks in Train Rails under a Load” ในวารสารนานาชาติ “Sensors” ในเครือข่าย Multidisciplinary Digital Publishing Institute (MDPI)