

การวิเคราะห์และจำแนกคุณภาพของการเชื่อมความต้านแบบจุดโดยใช้
เทคนิคการเรียนรู้ของเครื่องจักรแบบเชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิศวกรรมศาสตรดุษฎีบัณฑิต
สาขาวิชาวิศวกรรมเมคคาทรอนิกส์
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2567

DEEP LEARNING FOR WELD QUALITY MONITORING IN
RESISTANCE SPOT WELDING




A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Doctor of Philosophy in Mechatronics Engineering
Suranaree University of Technology
Academic Year 2024

การวิเคราะห์และจำแนกคุณภาพของการเชื่อมความต้านแบบจุดโดยใช้เทคนิค
การเรียนรู้ของเครื่องจักรแบบเชิงลึก

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้หน่วยวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปริญญาคุษภีบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(รศ. ดร.บัณฑิต กฤตาคม)

ประธานกรรมการ



(รศ. ดร.จิระพล ศรีเสรีรุ่งผล)

กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(ผศ. ดร.โสรัฏฐา แข็งการ)

กรรมการ



(ผศ. ดร.อุเทน ลีตัน)

กรรมการ



(ผศ. ดร.สุเดช ตัญตริยรัตน์)

กรรมการ



(รศ. ดร.ยุพาพร รักสกุลพิวัฒน์)

รองอธิการบดีฝ่ายวิชาการและประกันคุณภาพ



(รศ. ดร.พรศิริ จงกล)

คณบดีสำนักวิชาวิศวกรรมศาสตร์

ณัฐพงศ์ ชื่นหมี่ : การวิเคราะห์และจำแนกคุณภาพของการเชื่อมความต้านแบบจุดโดยใช้
เทคนิคการเรียนรู้ของเครื่องจักรแบบเชิงลึก (DEEP LEARNING FOR WELD QUALITY
MONITORING IN RESISTANCE SPOT WELDING)

อาจารย์ที่ปรึกษา : รองศาสตราจารย์ ดร.จิระพล ศรีเสรีฐผล, 193 หน้า.

คำสำคัญ: การเชื่อมความต้านทานแบบจุด/การตรวจสอบการเชื่อม/การวิเคราะห์ข้อมูล/การเรียนรู้
ของเครื่อง/ตัวจำแนก

การเชื่อมความต้านทานแบบจุด (Resistance Spot Welding; RSW) เป็นกระบวนการเชื่อม
ที่นิยมใช้ในอุตสาหกรรมยานยนต์ มีความเหมาะสมสำหรับระบบการผลิตแบบอัตโนมัติขนาดใหญ่
เชิงบูรณาการ แม้ว่าจะมีข้อดีอยู่หลายประการแต่ความสามารถในการประเมินความแม่นยำ
ของกระบวนการยังคงเป็นเรื่องท้าทาย และหากเกิดข้อผิดพลาดทำให้คุณภาพการเชื่อมไม่เป็นไปตาม
มาตรฐานจากกระบวนการดังกล่าว ส่งผลให้เกิดต้นทุนที่ไม่จำเป็นเพิ่มมากขึ้นเพื่อใช้ในการปรับปรุง
แก้ไขให้คุณภาพการเชื่อมกลับมาได้มาตรฐานอีกครั้ง วิธีการตรวจสอบในปัจจุบันที่พึ่งพาการสุ่มตรวจ
หลังจากการออกจากกระบวนการ Body-in-White (BIW) มักส่งผลให้เกิดการสูญเสียเวลาอย่างมาก
ซึ่งเน้นย้ำถึงความจำเป็นในการปรับปรุงการประเมินคุณภาพ การศึกษานี้มีวัตถุประสงค์เพื่อเปลี่ยน
จากการสุ่มตรวจเป็นการตรวจสอบ 100 เปอร์เซ็นต์โดยใช้การวิเคราะห์ข้อมูลและเทคนิคการเรียนรู้
ของเครื่อง โดยการทำนายระดับคุณภาพของการเชื่อมก่อนที่การประกอบตัวถังรถจะเสร็จสมบูรณ์
วิธีการนี้มีเป้าหมายเพื่อปรับปรุงการควบคุมคุณภาพ มีการประเมินอัลกอริทึมที่แตกต่างกันห้าแบบ
ได้แก่ Artificial Neural Network (ANN), Convolutional Neural Network (CNN), Long Short-
Term Memory (LSTM), Random Forest Classifier (RFC) และ Extreme Gradient Boosting
(XGBoost) การวิจัยนี้ชี้ให้เห็นว่าวิธีการที่เสนอโดยเฉพาะการใช้ XGBoost สามารถทำนายความ
แม่นยำได้ถึง 97.1% เมื่อนำไปใช้กับข้อมูลที่ไม่เคยเห็นมาก่อน

สาขาวิชาวิศวกรรมเมคคาทรอนิกส์

ปีการศึกษา 2567

ลายมือชื่อนักศึกษา.....จิราวัฒน์ โฉมศรี

ลายมือชื่ออาจารย์ที่ปรึกษา.....

NUTTAPONG CHUENMEE : DEEP LEARNING FOR WELD QUALITY MONITORING IN
RESISTANCE SPOT WELDING.

THESIS ADVISOR : ASSOC. PROF. JIRAPHON SRISERTPHOL, Ph.D., 193 PP.

Keywords: Resistance Spot Welding (RSW)/Weld inspection/Data analysis/Machine
learning/Classifier

Resistance Spot Welding (RSW) stands as the primary joining process in the automotive industry, renowned for its suitability for automation and integration into high-production assembly lines. Despite its advantages, accurately evaluating RSW remains challenging, resulting in additional costs and production steps. Current inspection methods, reliant on random checks after cars leave the Body-in-White (BIW), often lead to significant time losses, emphasizing the necessity for enhanced quality assessment. This study aims to transition from random checks to 100 percent inspection using data analysis and machine learning techniques. By predicting weld quality levels prior to car body completion, this approach aims to improve quality control. Five distinct algorithms-Artificial Neural Network (ANN), Convolutional Neural Network (CNN), Long Short-Term Memory (LSTM), Random Forest Classifier (RFC), and Extreme Gradient Boosting (XGBoost)-were assessed. The research highlights that the proposed methodology, particularly leveraging XGBoost, achieves a notable prediction accuracy of 97.1% when applied to unseen data.

School of Mechatronics Engineering
Academic Year 2024

Student's Signature Nuttapong Chuenmee

Advisor's Signature Siraporn

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลงด้วยดี เนื่องจากได้รับโอกาสและความกรุณาเป็นอย่างสูงจาก รองศาสตราจารย์ ดร.จิระพล ศรีเสริมผล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่กรุณาให้ความช่วยเหลือ ให้ คำปรึกษา คำแนะนำ ทั้งในด้านวิชาการและการดำเนินการวิจัย ปรับปรุงแก้ไขข้อบกพร่องต่าง ๆ ด้วย ความเอาใจใส่อย่างยิ่ง ตลอดจนให้การสนับสนุนข้าพเจ้าในการดำเนินชีวิตด้วยความเมตตา อย่างสูง เป็นต้นแบบในการดำเนินชีวิตที่ดียิ่ง ผู้วิจัยตระหนักถึงความตั้งใจจริง ความทุ่มเทของ อาจารย์ และ ขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ ที่นี้

ขอขอบคุณ คุณ Sash Stanceski ที่ได้ช่วยให้ความรู้ในด้านวิชาการและทฤษฎีที่เป็น ประโยชน์ในการทำงานวิจัย ซึ่งผู้วิจัยได้นำความรู้ที่ได้รับมาประยุกต์ใช้

ขอขอบพระคุณ เจ้าหน้าที่ประจำสาขาวิชาวิศวกรรมเครื่องกล และเจ้าหน้าที่ประจำหลักสูตร วิศวกรรมเมคคาทรอนิกส์ มหาวิทยาลัยเทคโนโลยีสุรนารีทุกท่าน ที่อำนวยความสะดวกด้านธุรการ เอกสารต่าง ๆ ในระหว่างการศึกษา ให้คำแนะนำและกำลังใจอย่างดียิ่งตลอดมา

ขอขอบคุณ พี่ ๆ น้อง ๆ สมาชิก System and Control Engineering (SCE) Laboratory ที่ได้ให้ความช่วยเหลือและความรู้ในการดำเนินงานวิจัย ให้สำเร็จลงได้ด้วยดี

สุดท้ายนี้ ขอกราบขอบพระคุณคณาจารย์ทุกท่านที่ประสิทธิ์ประสาทความรู้ทางด้านต่าง ๆ ทั้งในอดีตและปัจจุบัน และขอกราบขอบพระคุณบิดา มารดา และสมาชิกครอบครัว สำหรับ แรง บันดาลใจในการทำวิทยานิพนธ์และให้การอุปการะเลี้ยงดูด้วยความรักความอบอุ่นให้ การสนับสนุน และเป็นกำลังใจให้กับผู้วิจัย จนสามารถจัดทำวิทยานิพนธ์สำเร็จลงได้ด้วยดี

ณัฐพงศ์ ชื่นหมื่น

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย).....	ก
บทคัดย่อ (ภาษาอังกฤษ).....	ข
กิตติกรรมประกาศ.....	ค
สารบัญ.....	ง
สารบัญตาราง.....	ฉ
สารบัญรูป.....	ญ
คำอธิบายสัญลักษณ์และคำย่อ	ต

บทที่

1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา	1
1.2 วัตถุประสงค์ของงานวิจัย.....	3
1.3 ขอบเขตของการวิจัย	4
1.4 ระเบียบวิธีวิจัย	5
1.5 สถานที่ทำวิจัย.....	6
1.6 เครื่องมือที่ใช้ในการทำวิจัย.....	6
1.7 ประโยชน์ที่คาดว่าจะได้รับ	6
2 ปรัชญารวบรวมและงานวิจัยที่เกี่ยวข้อง.....	7
2.1 บทนำ.....	7
2.1.1 การพัฒนา RSW ในการผลิตยานยนต์.....	7
2.1.2 หลักการพื้นฐาน อุปกรณ์ และข้อบกพร่องในกระบวนการ RSW	10
2.1.2.1 หุ่นยนต์และระบบอัตโนมัติในกระบวนการ RSW	11
2.1.2.2 ปืนเชื่อมและการออกแบบข้อต่อไฟฟ้า.....	13
2.1.2.3 คอมพิวเตอร์ควบคุมเวลาและควบคุมกระแสไฟฟ้า.....	13
2.1.2.4 ข้อบกพร่องที่พบบ่อยในกระบวนการ RSW และมาตรการ ควบคุมคุณภาพ	15

สารบัญ (ต่อ)

หน้า

2.2	ความท้าทายในการทำนายคุณภาพการเชื่อม.....	17
2.2.1	ตัวชี้วัดคุณภาพที่สำคัญและโหมดความเสียหายใน RSW.....	17
2.2.2	เทคนิคการตรวจสอบในปัจจุบัน.....	20
2.3	การตรวจสอบกระบวนการ RSW.....	23
2.3.1	เทอร์โมกราฟีอินฟราเรด (Infrared Thermography).....	23
2.3.2	เทคโนโลยีเซ็นเซอร์หลายตัว	24
2.3.3	การวัดด้วยคลื่นเสียง	25
2.3.4	การตรวจสอบกราฟของความต้านทานแบบไดนามิก.....	27
2.4	Machine Learning Applications in Welding Processes.....	28
2.4.1	Artificial Neural Network (ANN).....	28
2.4.2	Convolution Neural Networks (CNN).....	29
2.4.3	โครงข่ายหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory Networks, LSTM)	31
2.4.4	การจำแนกประเภทแบบการสุ่มป่าไม้ (Random Forest Classifier, RFC)....	34
2.4.5	Extreme Gradient Boosting (XGBoost).....	36
2.5	การสร้างคุณสมบัติและการเตรียมข้อมูลในงานทำนายคุณภาพ RSW	38
2.5.1	คุณสมบัติสำคัญที่ได้มาจากพารามิเตอร์ของ RSW	38
2.5.2	ความท้าทายด้านการนำข้อมูลการเชื่อม RSW มาใช้งาน	40
2.6	อัลกอริทึมการเรียนรู้ของเครื่อง	42
2.6.1	เซ็นเซอร์ที่ใช้ในการจับข้อมูลกระบวนการ RSW	42
2.6.2	ระบบการเก็บข้อมูลและความท้าทายในการตรวจสอบแบบเรียลไทม์	44
2.7	เทคนิคการตรวจสอบความถูกต้องของโมเดลในโมเดลการทำนายคุณภาพ	45
2.8	การเปรียบเทียบโมเดลการเรียนรู้ของเครื่องสำหรับการทำนายคุณภาพ RSW	47
2.9	ความท้าทายและข้อจำกัดในการประยุกต์ใช้โมเดลการเรียนรู้ของเครื่องใน อุตสาหกรรมการผลิต.....	52
2.10	ทิศทางในอนาคตของการตรวจสอบคุณภาพเชิงทำนายสำหรับ RSW	59
2.11	สรุป.....	64

สารบัญ (ต่อ)

หน้า

3	วิธีการดำเนินงานวิจัย.....	65
3.1	วิธีดำเนินงานวิจัย	65
3.2	เครื่องมือและอุปกรณ์ในการศึกษาวิจัย	66
3.2.1	หุ่นยนต์อุตสาหกรรม.....	66
3.2.2	คอมพิวเตอร์ควบคุมการเชื่อม	66
3.2.3	ปืนเชื่อม RSW	67
3.2.4	หัวเชื่อมทองแดงแบบผสม.....	67
3.2.5	เครื่องมือตรวจสอบรอยเชื่อม RSW	68
3.2.6	คอมพิวเตอร์	69
3.3	การเขียนรหัสโปรแกรมเพื่อเก็บค่าและแปลผล	69
3.4	พารามิเตอร์ที่ใช้ในการเชื่อม	70
3.5	การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก.....	72
3.5.1	แหล่งข้อมูล (Data source).....	72
3.5.1.1	ข้อมูลที่ได้จากการทดลอง	72
3.5.1.2	ข้อมูลที่ได้จากกระบวนการผลิต	73
3.5.2	กระบวนการเชื่อมด้วยความต้านทาน.....	74
3.5.3	การแยกข้อมูล (Data extraction)	74
3.5.4	การวัดและการแยกประเภทของรอยเชื่อมด้วยคลื่นเสียงความถี่สูง (UT measurement and labelling).....	76
3.5.5	การเตรียมข้อมูล (Data preparing)	77
3.5.6	การสกัดคุณลักษณะ (Feature Extraction).....	79
3.5.7	การสร้างแบบจำลองด้วยการเรียนรู้ของเครื่องและ การเรียนรู้เชิงลึก (Machine learning and Deep Learning model)....	83
3.5.8	การปรับจูนแบบจำลอง (Modeling tuning)	83
3.5.9	การปรับใช้และการปรับปรุงแบบจำลอง (Deployment and update)....	86
3.6	การใช้งานในสายการผลิต.....	86

สารบัญ (ต่อ)


หน้า

4 ผลการศึกษาและการวิเคราะห์ผล	89
4.1 บทนำ	89
4.2 การประเมินและเปรียบเทียบโมเดล	90
4.2.1 โครงข่ายประสาทเทียม (Artificial Neural Networks: ANN).....	90
4.2.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Networks: CNN)	93
4.2.3 โครงข่ายหน่วยความจำระยะยาว (Long Short-Term Memory: LSTM)	96
4.2.4 ตัวจัดหมวดหมู่แบบป่าการตัดสินใจแบบสุ่ม (Random Forest Classifier: RFC)	100
4.2.5 ตัวจัดหมวดหมู่แบบการเพิ่ม Gradient ขั้นสูง (Extreme Gradient Boosting Classifier: XGBoost).....	102
4.3 Performance Improvement	107
4.4 ผลการทดสอบจากการใช้งานจริง	111
4.5 สรุป.....	113
5 สรุปและข้อเสนอแนะ	115
5.1 สรุป.....	115
5.2 ข้อเสนอแนะ.....	115
5.2.1 ข้อเสนอแนะจากการวิจัยในส่วนการเก็บข้อมูล	115
5.2.2 ข้อเสนอแนะจากการวิจัยในส่วนการทำนายผลสำหรับการผลิต	116
5.2.3 ข้อเสนอแนะจากการวิจัยในส่วนการใช้งานจริง.....	116
รายการอ้างอิง	118
ภาคผนวก	
ภาคผนวก ก. การเขียนโปรแกรมการทำนายผลในสายการผลิต.....	127
ภาคผนวก ข. การใช้โปรแกรม Tessonic ในการวัดขนาดของรอยเชื่อม.....	154
ภาคผนวก ค. การเขียนโปรแกรมควบคุมหุ่นยนต์ในสายการผลิต.....	159
ภาคผนวก ง. การเขียนโปรแกรม PLC สำหรับควบคุมการแจ้งเตือนในสายการผลิต	171

สารบัญ (ต่อ)

หน้า

ภาคผนวก จ. บทความที่ได้รับการตีพิมพ์เผยแพร่.....	174
ประวัติผู้เขียน.....	193



สารบัญตาราง

ตารางที่	หน้า
3.1	ตารางการปรับพารามิเตอร์การเชื่อมแบบจุด 71
3.2	ตารางการจับคู่พารามิเตอร์การเชื่อม 71
3.3	ตัวอย่างข้อมูลได้จากการแปลงจาก RUI ไฟล์..... 75
3.4	ตารางข้อมูลที่ได้จากกระบวนการเชื่อมและการวัดขนาดด้วย UT..... 78
3.5	การกำหนดระดับของการจัดประเภท..... 79
3.6	การวิเคราะห์ความแตกต่างของพารามิเตอร์ (ช่วงความเชื่อมั่น 95%)..... 81
3.7	ตัวแปรสำหรับการฝึกอบรมโมเดล 82
3.8	การเปรียบเทียบไฮเปอร์พารามิเตอร์ระหว่างโมเดลอัลกอริทึมที่ใช้ค่าปริยายและค่าที่ ปรับแต่งแล้ว..... 85
4.1	การเปรียบเทียบตัวชี้วัดประสิทธิภาพระหว่าง 5 โมเดลอัลกอริทึม 105
4.2	การวิเคราะห์เชิงเปรียบเทียบของโมเดล XGBoost ก่อนและหลังการคัดเลือกคุณสมบัติ ด้วยคะแนน FI-score 111
4.3	ตัวอย่างของเสียที่ได้จากผลการทำนายจากสายการผลิต..... 112

สารบัญรูป

รูปที่	หน้า
1.1 การเชื่อม RSW ในอุตสาหกรรมรถยนต์	1
1.2 การเชื่อม RSW	1
1.3 แผนภาพการเชื่อม RSW	2
1.4 การตรวจสอบการเชื่อมแบบทำลาย	2
1.5 การตรวจสอบการเชื่อมแบบ UT	2
1.6 คอมพิวเตอร์สำหรับควบคุมการเชื่อม	3
2.1 กระบวนการเชื่อมในอุตสาหกรรมยานยนต์	7
2.2 ส่วนประกอบของตัวถังรถยนต์	8
2.3 พารามิเตอร์ในการเชื่อมที่ใช้สำหรับการเชื่อม RSW ของเหล็ก Usibor 1500	9
2.4 ภาพหน้าตัดการแตกหักของรอยเชื่อม (a) สภาวะโหลต TS (b) สภาวะโหลต CT	10
2.5 การเชื่อม RSW สำหรับสายการผลิตตัวถังรถยนต์	11
2.6 กรอบแนวคิดของระบบไซเบอร์-กายภาพ สำหรับการเชื่อม RSW	12
2.7 แผนผังเชิงโครงสร้างของการตรวจสอบรอยเชื่อมด้วยเทคนิค IR NDE แบบอินไลน์	12
2.8 ปีนเชื่อม RSW	13
2.9 ตัวควบคุมการเชื่อม(Weld Timer)	14
2.10 แผนผังไดอะแกรมของอินเวอร์เตอร์ คอมพิวเตอร์ควบคุมการเชื่อม และ หม้อแปลง	14
2.11 โหมดและกลไกความเสียหาย	15
2.12 หัววัดการตรวจจับด้วยคลื่นอัลตราโซนิก	16
2.13 การวัดและคำนวณขนาดเส้นผ่านศูนย์กลางของรอยเชื่อม	17
2.14 การทดสอบแรงดึงแบบสถิตตามมาตรฐาน DIN EN ISO 14273	17
2.15 รูปทรงและขนาดของตัวอย่างการทดสอบแรงดึง	18
2.16 ลำดับขั้นตอนการเกิดรอยเชื่อมของการเชื่อม RSW	19
2.17 การทดสอบรอยเชื่อมด้วยส่ว	20
2.18 โครงสร้างของเซ็นเซอร์ AE ที่ติดตั้งบนอิเล็กทรอนิกส์	21
2.19 การตรวจสอบคุณภาพการเชื่อม RSW ออนไลน์ด้วยหัววัดอัลตราโซนิกแบบติดตั้งในระบบ ..	22
2.20 แผนผังเชิงโครงสร้างของการทดลองการตรวจสอบรอยเชื่อม RSW	23

สารบัญรูป (ต่อ)

รูปที่	หน้า
2.21	กระบวนการโดยรวมและส่วนประกอบหลักของการตรวจจับขนาดรอยเชื่อมอัตโนมัติ 24
2.22	แผนผังเชิงโครงสร้างของเก็บสัญญาณจากการเชื่อม RSW 25
2.23	สัญญาณ AE ทัวไประหว่างการเชื่อม RSW 26
2.24	แผนผังการตรวจจับสัญญาณคลื่นยืดหยุ่น (Elastic Wave Signals) 27
2.25	การแปลความหมายของกราฟความต้านทานเชิงพลวัตในเชิงทฤษฎี 27
2.26	กระบวนการพื้นฐานของการเรียนรู้ของเครื่อง 28
2.27	แผนผังการเกิดรูปทรงเนื่องจากการเยื้องศูนย์ 29
2.28	อุปกรณ์ในระบบและกระบวนการเชื่อม RSW 30
2.29	แพลตฟอร์มการทดลอง PRONOSTIA 31
2.30	การจำแนกประเภทคุณภาพของรอยเชื่อม 32
2.31	แผนผังการออกแบบการเก็บรวบรวมข้อมูลสำหรับกระบวนการเชื่อมเลเซอร์ 33
2.32	แผนผังบล็อกของกรอบการทำนายแบบกลุ่ม 35
2.33	กระบวนการดำเนินการของวิธีการตรวจจับสัญญาณและการระบุวัสดุ 36
2.34	การตั้งค่าระบบการเชื่อมด้วยคลื่นอัลตราโซนิก 37
2.35	แผนผังเชิงโครงสร้างของตัวตรวจสอบกระบวนการสำหรับการตรวจสอบคุณภาพ 37
2.36	ผลของกระแสไฟฟ้าต่อภาพมาโครกราฟ 38
2.37	กรอบแนวคิดของสถาปัตยกรรมในการตรวจสอบคุณภาพของการเชื่อม RSW 39
2.38	ภาพรวมของวิธีการที่ใช้ในการปรับแต่งแบบจำลอง 39
2.39	การรวบรวมข้อมูลจากปิ่นเชื่อมไปยังระบบคลาวด์ผ่านแพลตฟอร์ม 41
2.40	ระบบแบบบูรณาการสำหรับการตรวจสอบในสายการผลิตของการเชื่อม RSW 41
2.41	กลยุทธ์การเรียนรู้แบบเพิ่มพูน 42
2.42	แผนผังโครงสร้างเครือข่าย (Network Topology Diagram) 43
2.43	การทดลองและแผนผังเชิงโครงสร้างของระบบตรวจสอบกระบวนการเชื่อม RSW 43
2.44	ภาพประกอบเชิงโครงสร้างของแนวคิดโดยรวมสำหรับระบบเก็บเกี่ยวพลังงานแม่เหล็ก DC แบบพัลส์ และหุ่นยนต์เชื่อมในโรงงานอัจฉริยะสำหรับยานยนต์ 45
2.45	ประเภทต่างๆ ของกระบวนการ ML ที่นำมาใช้ 48

สารบัญรูป (ต่อ)

รูปที่	หน้า
2.46	สัญญาณพลังงานการเชื่อมสำหรับคุณภาพการเชื่อมทั้งสามแบบ 49
2.47	หมวดหมู่ของภาพลักษณะรอยเชื่อม RSW 49
2.48	การระบุและจดจำลักษณะรอยเชื่อม RSW โดยใช้ AcmNet..... 50
2.49	กระบวนการทำงานของการเชื่อมพร้อมการทำนายคุณภาพ..... 51
2.50	ภาพรวมทางสถาปัตยกรรมของกระบวนการจัดการเหตุการณ์ของหุ่นยนต์และ ส่วนประกอบการทำงานของระบบ 52
2.51	การตั้งค่าและการติดตั้งกล้องถ่ายภาพความร้อน 53
2.52	การเปรียบเทียบคะแนนความแม่นยำของอัลกอริทึมการเรียนรู้ของเครื่อง 54
2.53	กรอบการทำงาน SecFL ซึ่งเป็นการผสมผสานระหว่างวิธีการ FL มาตรฐานและเทคนิค Signed DE 55
2.54	กรอบการทำงานของ POST-BaLSTM..... 56
2.55	แผนผังเชิงโครงสร้างของการเพิ่มประสิทธิภาพหลายวัตถุประสงค์แบบกำหนดเชิงขึ้นนำ..... 57
2.56	แพลตฟอร์มการเก็บข้อมูลประกอบด้วยฐานหุ่นยนต์ แขนหุ่นยนต์ และเซ็นเซอร์..... 59
2.57	กรอบแนวคิดของระบบดิจิทัลทวินสำหรับกระบวนการเชื่อม RSW 60
2.58	ระบบการเก็บข้อมูลแบบเรียลไทม์สำหรับกระบวนการเชื่อม RSW 61
2.59	อุปกรณ์ทดลองสำหรับกระบวนการเชื่อม RSW 62
2.60	สถาปัตยกรรมที่ใช้ดิจิทัลทวินสำหรับการควบคุมเชิงขดเซยแบบคาดการณ์ล่วงหน้า 63
3.1	แผนภูมิการดำเนินงานวิจัย 65
3.2	หุ่นยนต์อุตสาหกรรม 66
3.3	คอมพิวเตอร์ควบคุมการเชื่อมที่ใช้ในงานวิจัย..... 66
3.4	ปืนเชื่อม RSW ชนิด X-type ยี่ห้อ OBARA 67
3.5	ขนาดของหัวเชื่อมทองแดงแบบผสม (CuCrZr) ชนิด Dome แบบ F..... 68
3.6	เครื่องมือตรวจสอบรอยเชื่อม RSW ยี่ห้อ Tessonic 69
3.7	แผนภูมิการเขียนโปรแกรมเพื่อเก็บค่าและแสดงผล 70
3.8	ชิ้นงานทดลองสำหรับงานเชื่อม..... 72
3.9	ข้อมูลตัวแปรที่ใช้ในการเชื่อม 73
3.10	สถานีงานเชื่อมในอุตสาหกรรมรถยนต์ที่ใช้ในงานวิจัย..... 73

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.11 รอยเชื่อมที่ใช้ในงานวิจัย.....	74
3.12 กราฟกระแส แรงดันและความต้านทานที่ได้จากกระบวนการเชื่อม	76
3.13 ข้อมูลขนาดรอยเชื่อมจากโปรแกรม RSWA	76
3.14 การระบุประเภทข้อมูล (a)สภาพสมบูรณ์ (b)เกิดการแตกตัว (c)สภาพไม่สมบูรณ์.....	77
3.15 ตัวอย่างการวิเคราะห์แผนภาพกล่องของพารามิเตอร์ตัวอย่างหกตัวในแต่ละระดับ คุณภาพการเชื่อม.....	80
3.16 การวิเคราะห์เปรียบเทียบของโมเดล XGBoost ก่อนและหลังการคัดเลือกคุณลักษณะ โดยใช้คะแนน FI-score.....	84
3.17 ภาพรวมกระบวนการเชิงอัลกอริทึม.....	87
3.18 แผนภาพเปรียบเทียบการทำงานของหุ่นยนต์ก่อน-หลังการใช้การเรียนรู้ของเครื่องในการ ทำนายคุณภาพของรอยเชื่อมในกระบวนการผลิต.....	88
4.1 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ตั้งต้น ของโมเดล ANN	90
4.2 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ปรับแต่งของ โมเดล ANN	91
4.3 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์ของโมเดล ANN.....	92
4.4 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์ ของโมเดล ANN.....	92
4.5 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ตั้งต้น ของโมเดล CNN.....	94
4.6 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ปรับแต่งของ โมเดล CNN	94
4.7 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์ของโมเดล CNN.....	95
4.8 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์ของโมเดล LSTM	96
4.9 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ ตั้งต้นของโมเดล.....	97

สารบัญรูป (ต่อ)

รูปที่	หน้า
4.10 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ ปรับแต่งของโมเดล	98
4.11 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์ของโมเดล RFC	99
4.12 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์ ของโมเดล RFC.....	99
4.13 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์	100
4.14 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์.....	101
4.15 ผลการเปรียบเทียบ ROC ก่อน-หลังการปรับแต่งพารามิเตอร์.....	102
4.16 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์.....	103
4.17 การวิเคราะห์เปรียบเทียบ ROC และ AUC-ROC สำหรับโมเดลอัลกอริทึมทั้ง 5 โมเดล ...	106
4.18 a) ANN confusion matrix, (b) CNN confusion matrix, (c) LSTM confusion matrix, (d) RF confusion matrix, (e) XGBoost confusion matrix	107
4.19 การคัดเลือกคุณลักษณะโดยใช้คะแนน F1-score	108
4.20 (a) 29 คุณลักษณะ, (b) 20 คุณลักษณะ, (c) 19 คุณลักษณะ, (d) 18 คุณลักษณะ, (e) 17 คุณลักษณะ, (f) 16 คุณลักษณะ.....	109
4.21 XGBoost confusion matrix หลังจากลดจำนวนคุณลักษณะ เหลือ 17 คุณลักษณะ	110
4.22 เวลาที่ใช้ในการทำนายผลต่อ 1 รอยเชื่อม.....	112
ง.1 เครื่องมือวัดขนาดรอยเชื่อม RSW.....	155
ง.2 หัววัดขนาดรอยเชื่อม RSW.....	155
ง.3 หน้าต่างโปรแกรม RWSA	156
ง.4 พื้นที่ C-Scan	157
ง.5 พื้นที่ A-Scan	157

คำอธิบายสัญลักษณ์และคำย่อ

ANN	=	Artificial Neural Networks (โครงข่ายประสาทเทียม)
ANOVA	=	ANalysis Of Variance (การวิเคราะห์ความแปรปรวน)
AUC	=	Area Under the Curve (ค่าพื้นที่ใต้เส้นโค้ง)
BN	=	Bayesian Network (เครือข่ายแบบเบย์)
BRNN	=	Bidirectional Recurrent Neural Networks (โครงข่ายประสาทเทียมแบบวนซ้ำสองทิศทาง)
CART	=	Classification And Regression Trees (ต้นไม้การจำแนกและการถดถอย)
CM	=	Condition Monitoring (ระบบการตรวจสอบ)
CNN	=	Convolutional Neural Networks (โครงข่ายประสาทเทียมแบบคอนโวลูชัน)
CPS	=	Cyber-Physical Systems (ระบบไซเบอร์กายภาพ)
csv	=	Comma separated values (ค่าที่คั่นด้วยเครื่องหมายจุลภาค)
D	=	Diameter (เส้นผ่านศูนย์กลาง)
DKFE	=	Domain Knowledge based Feature Engineering (วิศวกรรมคุณลักษณะโดยอิงความรู้เฉพาะด้าน)
DL	=	Deep Learning (การเรียนรู้เชิงลึก)
DNN	=	Deep Neural Networks (โครงข่ายประสาทเทียมเชิงลึก)
DT	=	Decision Trees (ต้นไม้ตัดสินใจ)
ERW	=	Electric Resistance Welding (การเชื่อมด้วยความต้านทานไฟฟ้า)
F	=	Force (แรง)
FE	=	Feature Engineering (วิศวกรรมคุณลักษณะ)
FI	=	Feature Importance (ความสำคัญของคุณลักษณะ)
FI-score	=	Feature Importance Score (คะแนนความสำคัญของคุณลักษณะ)
FEM	=	Finite Element Method (วิธีไฟไนต์เอลิเมนต์)
FN	=	False Negative (ผลลบลง)

คำอธิบายสัญลักษณ์และคำย่อ (ต่อ)

FP	=	False Positive (ผลบวกหลง)
FS	=	Feature Selection (การคัดเลือกคุณลักษณะ)
FSW	=	Friction Stir Welding (การเชื่อมเสียดทานแบบหมุน)
FuzzyNN	=	Fuzzy Neural Networks (โครงข่ายประสาทเทียมแบบฟัซซี่)
GA	=	Genetic Algorithm (อัลกอริทึมเชิงพันธุกรรม)
GMAW	=	Gas Metal Arc Welding (การเชื่อมอาร์คโลหะแก๊ส)
GRNN	=	General Regression Neural Networks (โครงข่ายประสาทเทียมการถดถอยทั่วไป)
I	=	Current (กระแสไฟฟ้า)
IoT	=	Internet of Things (อินเทอร์เน็ตของสรรพสิ่ง)
IIoT	=	Industrial Internet of Things (อินเทอร์เน็ตของสรรพสิ่งในอุตสาหกรรม)
kNN	=	K-Nearest Neighbours (การคำนวณเพื่อนบ้านใกล้สุด)
LDA	=	Linear Discriminant Analysis (การวิเคราะห์การแยกเชิงเส้น)
LogisticR	=	Logistic Regression (การถดถอยโลจิสติก)
LogR	=	Linear Regression with Logarithmic terms (การถดถอยเชิงเส้นที่มีพจน์ลอการิทึม)
LR	=	Linear Regression (การถดถอยเชิงเส้น)
LSTM	=	Long Short-Term Memory (หน่วยความจำระยะยาวและระยะสั้น)
max	=	Maximum (ค่าสูงสุด)
min	=	Minimum (ค่าต่ำสุด)
ML	=	Machine Learning (การเรียนรู้ของเครื่อง)
MLP	=	Multilayer Perceptron (เพอร์เซ็ปตรอนหลายชั้น)
μ	=	Mean value (ค่าเฉลี่ย)
OEM	=	Original Equipment Manufactures (ผู้ผลิตอุปกรณ์ดั้งเดิม)
OWL	=	Ontology Web Language (ภาษาสำหรับออนโทโลยีบนเว็บ)
P, ProgNo	=	Welding program number (หมายเลขโปรแกรมการเชื่อม)
PCA	=	Principle Component Analysis (การวิเคราะห์องค์ประกอบหลัก)
PolyR	=	Polynomial Regression (การถดถอยพหุนาม)
Prog	=	Welding program (หมายเลขโปรแกรมการเชื่อม)

คำอธิบายสัญลักษณ์และคำย่อ (ต่อ)

PSO	=	Particle Swarm Optimization (การเพิ่มประสิทธิภาพด้วยฝูงอนุภาค)
QMM	=	Quality Monitoring in Manufacturing (การตรวจสอบคุณภาพในการผลิต)
R	=	Regression (การถดถอย)
RFC	=	Random Forest Classifier (ตัวจัดประเภทแบบสุ่มในป่า)
rms	=	Root mean squared (ค่ารากที่สองของค่าเฉลี่ยกำลังสอง)
RNN	=	Recurrent Neural Networks (โครงข่ายประสาทเทียมแบบวนซ้ำ)
ROC	=	Receiver Operating Characteristic (เส้นโค้งลักษณะการทำงานของตัวรับ)
ROC-AUC	=	Receiver Operating Characteristic - Area Under the Curve (ค่าพื้นที่ใต้เส้นโค้งลักษณะการทำงานของตัวรับ)
RSW	=	Resistance Spot Welding (การเชื่อมจุดต้านทาน)
σ , std	=	Standard deviation of a random variable (ส่วนเบี่ยงเบนมาตรฐานของตัวแปรสุ่ม)
SPC	=	Statistic Process Control (การควบคุมกระบวนการเชิงสถิติ)
SVM	=	Support Vector Machines (เครื่องเวกเตอร์สนับสนุน)
t	=	Time (เวลา)
T	=	Temperature (อุณหภูมิ)
TN	=	True Negative (ผลลบจริง)
TP	=	True Positive (ผลบวกจริง)
TS	=	Time Series (อนุกรมเวลา)
TSS	=	Tensile Shear Strength (ความแข็งแรงของแรงเฉือนในแรงดึง)
U	=	Voltage (แรงดันไฟฟ้า)
x	=	Value of a random variable (ค่าของตัวแปรสุ่ม)
X	=	Random variable (ตัวแปรสุ่ม)
XGBoost	=	Extreme Gradient Boosting (การเพิ่มประสิทธิภาพความชันแบบสุดขีด)
XML	=	eXtensible Markup Language (ภาษามาร์กอัปขยายได้)

บทที่ 1


บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ปัจจุบันอุตสาหกรรมยานยนต์ในประเทศไทยสามารถผลิตรถยนต์ได้หลายล้านคันต่อปี โดยรถยนต์นั่งส่วนบุคคลส่วนใหญ่ถูกออกแบบด้วยดีไซน์แบบชิ้นเดียวหรือโครงสร้างโมโนค็อก ซึ่งอาศัยตัวถังรถเพื่อความสะดวกของโครงสร้าง ส่วนประกอบหลักของโครงสร้างนี้ประกอบด้วยโลหะแผ่น ซึ่งส่วนใหญ่เชื่อมต่อกันด้วยกระบวนการเชื่อมด้วยความต้านทานแบบจุด (Resistance Spot Welding, RSW) ดังแสดงในรูปที่ 1.1 การเชื่อมแบบจุดนี้มีบทบาทสำคัญในการยึดตัวรถไว้ด้วยกัน และส่งผลโดยตรงต่อความปลอดภัยและความแข็งแรงของโครงสร้าง อย่างไรก็ตาม การประเมินคุณภาพของรอยเชื่อมแบบจุดอย่างแม่นยำเป็นเรื่องท้าทาย




รูปที่ 1.1 RSW ในอุตสาหกรรมรถยนต์



รูปที่ 1.2 การเชื่อม RSW

จากรูปที่ 1.2 แสดงกระบวนการเชื่อมด้วยความต้านทานแบบจุด ซึ่งเกิดขึ้นระหว่างแผ่นโลหะสองชิ้นขึ้นไป โดยอาศัยความต้านทานไฟฟ้าระหว่างชิ้นส่วนโลหะ แรงดันไฟฟ้าถูกจ่ายผ่านอิเล็กโทรดทองแดงที่ยึดชิ้นส่วนโลหะไว้ด้วยกันดังแสดงในภาพที่ 1.3 เมื่อกระแสไฟฟ้าไหลผ่านเพียงพอ ความต้านทานไฟฟ้าที่เกิดขึ้นบริเวณรอยต่อของแผ่นโลหะจะสร้างความร้อนจนทำให้โลหะแผ่นละลายและเชื่อมเข้าด้วยกัน



รูปที่ 1.3 แผนภาพการเชื่อม RSW

คุณภาพของรอยเชื่อมแบบจุดมีความสำคัญอย่างยิ่งในการรับรองความปลอดภัยของยานพาหนะในกรณีเกิดอุบัติเหตุ อย่างไรก็ตาม การประเมินคุณภาพของการเชื่อมแบบจุดโดยไม่ทำลายเป็นสิ่งที่ท้าทาย โดยทั่วไปแล้ว วิธีการทดสอบแบบทำลายดังแสดงในรูปที่ 1.4 เป็นวิธีปฏิบัติที่ใช้กันอย่างแพร่หลายในการตรวจสอบคุณภาพรอยเชื่อมในอุตสาหกรรม ซึ่งมักทำโดยใช้สว่านหรือการดึงเพื่อตรวจสอบขนาดและคุณภาพของรอยเชื่อม นอกจากนี้ ยังมีวิธีการทดสอบแบบไม่ทำลาย เช่น การใช้คลื่นเสียงความถี่สูง (Ultrasonic Testing, UT) ดังแสดงในรูปที่ 1.5 และการถ่ายภาพความร้อนแบบอินฟราเรด เพื่อตรวจสอบรอยเชื่อม อย่างไรก็ตาม วิธีการเหล่านี้มักไม่แม่นยำ เนื่องจากเป็นการตรวจสอบแบบสุ่มและขึ้นอยู่กับ การตรวจสอบด้วยมนุษย์ ซึ่งใช้เวลานานและมีค่าใช้จ่ายสูง




รูปที่ 1.4 การตรวจสอบแบบทำลาย



รูปที่ 1.5 การตรวจสอบแบบ UT

การตรวจสอบคุณภาพการเชื่อมด้วยการวิเคราะห์สัญญาณที่วัดได้ในระหว่างกระบวนการ (Process Signal Analysis) เป็นวิธีที่มีประสิทธิภาพมากกว่า เนื่องจากสามารถดำเนินการได้ในระหว่างกระบวนการผลิตโดยไม่ต้องหยุดสายการผลิต อุปกรณ์ควบคุมการเชื่อมซึ่งเป็นคอมพิวเตอร์ตั้ง

แสดงในภาพที่ 6 สามารถบันทึกสัญญาณต่างๆ เช่น กระแสไฟฟ้า แรงดันไฟฟ้า และเวลาเชื่อมได้ตลอดกระบวนการ ทำให้สามารถประเมินคุณภาพของรอยเชื่อมได้แบบเรียลไทม์



รูปที่ 1.6 คอมพิวเตอร์สำหรับควบคุมการเชื่อม

ในปัจจุบัน กระบวนการตรวจสอบคุณภาพการผลิตยังคงต้องพึ่งพาการใช้แรงงานมนุษย์ในการตรวจสอบแต่ละคัน ซึ่งต้องใช้เวลาน้อย 4 ชั่วโมง หรือมากกว่านั้น ขึ้นอยู่กับลักษณะของปัญหาที่เกิดขึ้น เมื่อพบข้อผิดพลาด ชิ้นงานจะต้องถูกนำออกจากกระบวนการผลิตเพื่อทำการซ่อมแซม ซึ่งกระบวนการนี้ใช้เวลาประมาณ 10 นาทีต่อคัน รถยนต์แต่ละคันใช้เวลาในการผลิต 150 วินาที แต่ในปี 2022 มีรถยนต์ที่เกิดข้อผิดพลาดประมาณ 120 คันจากทั้งหมด 600 คัน ส่งผลให้ต้องหยุดสายการผลิตนานถึง 8 ชั่วโมง และต้องใช้เวลาอีก 1 สัปดาห์ในการซ่อมนอกสายการผลิต

งานวิจัยนี้มุ่งเน้นไปที่การออกแบบและพัฒนาระบบจำแนกคุณภาพรอยเชื่อมแบบจุด โดยใช้ปัญญาประดิษฐ์ (Artificial Intelligence, AI) เพื่อเพิ่มความแม่นยำและความน่าเชื่อถือในการประเมินคุณภาพรอยเชื่อมในอุตสาหกรรมยานยนต์ ลดระยะเวลาและต้นทุนในการตรวจสอบตลอดจนเพิ่มประสิทธิภาพในกระบวนการผลิตโดยรวม

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 เพื่อพัฒนากระบวนการตรวจสอบคุณภาพการเชื่อมด้วยความต้านทานแบบจุดที่ใช้ในการผลิตตัวถังรถยนต์ โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องจักรแบบเชิงลึก (Deep Learning, DL) เพื่อเพิ่มความแม่นยำและประสิทธิภาพในการประเมินคุณภาพรอยเชื่อม

1.2.2 เพื่อออกแบบระบบตรวจสอบคุณภาพการเชื่อมด้วยความต้านทานแบบจุดที่ใช้ในการผลิตตัวถังรถยนต์ ซึ่งสามารถดำเนินการได้ในระหว่างกระบวนการผลิต เพื่อปรับปรุงความต่อเนื่องและความรวดเร็วในการควบคุมคุณภาพ

1.2.3 เพื่อออกแบบระบบการเก็บข้อมูลและแสดงสถานะของรถยนต์ที่ถูกผลิตในแต่ละคัน โดยมีระบบการตรวจสอบย้อนกลับ (Traceability) เพื่อให้สามารถติดตามข้อมูลการผลิตและคุณภาพการเชื่อมของรถแต่ละคันได้อย่างเป็นระบบ

1.3 ขอบเขตของการวิจัย

1.3.1 ศึกษากระบวนการเชื่อมด้วยความต้านทานแบบจุด (RSW) โดยอาศัยการรับรู้และการควบคุมจากระบบคอมพิวเตอร์ ซึ่งมีตัวแปรสำคัญ ได้แก่ กระแสไฟฟ้า แรงดันไฟฟ้า และเวลาที่ใช้ในการเชื่อม เพื่อใช้เป็นเกณฑ์ในการประเมินคุณภาพของรอยเชื่อม

1.3.2 การกระบวนการเชื่อมจะดำเนินการกับโลหะเหล็กทนแรงดึงสูง (High Strength Steel, HSS) โดยเชื่อมระหว่างแผ่นเหล็กหนา 0.65-0.70 mm (มีค่าความคลาดเคลื่อน ± 0.02 mm) ที่ผ่านการเคลือบกัลวาไนซ์ กับแผ่นเหล็กชนิดเดียวกันแต่ไม่ได้เคลือบผิว โดยโลหะทั้งสองชนิดสามารถรับแรงดึงได้ 270 MPa

1.3.3 ใช้หุ่นยนต์อุตสาหกรรมยี่ห้อ Kawasaki รุ่น BX200L ในกระบวนการเชื่อม โดยใช้ปืนเชื่อมแบบจุดยี่ห้อ OBARA รุ่น SRTC ซึ่งออกแบบมาเฉพาะสำหรับงานเชื่อมด้วยความต้านทานแบบจุด

1.3.4 ควบคุมการเชื่อมด้วยระบบคอมพิวเตอร์ยี่ห้อ Bosch รุ่น PSI63C3 ในโหมดการควบคุมกระแสไฟฟ้าแบบคงที่ พร้อมตัวควบคุมการทำงานแบบขั้นบันได เพื่อให้การจ่ายกระแสไฟฟ้าเป็นไปอย่างแม่นยำตลอดกระบวนการ

1.3.5 ใช้หัวเชื่อมตามมาตรฐาน ISO5821:2009 โดยเลือกใช้หัวเชื่อม class 2 type F ซึ่งมีขนาดหน้าตัด 6 mm เส้นผ่านศูนย์กลาง 16 mm และความยาว 23 mm เพื่อให้ได้รอยเชื่อมที่มีคุณภาพสูงสุด

1.3.6 กระบวนการเชื่อมถูกประเมินตามมาตรฐาน ISO14373:2015 โดยแบ่งการตรวจสอบคุณภาพรอยเชื่อมออกเป็น 3 ระดับ ได้แก่ รอยเชื่อมที่ไม่ดี รอยเชื่อมที่สมบูรณ์ และรอยเชื่อมที่มีสะเก็ดไฟเกิดขึ้น

1.3.7 พัฒนาเครื่องมือหรือโปรแกรมสำหรับการคาดการณ์และประเมินผลลัพธ์ของการเชื่อมแบบจุดในแต่ละครั้ง โปรแกรมนี้ต้องสามารถคาดการณ์คุณภาพของรอยเชื่อมในระดับต่างๆ ได้แก่ Undersize (ไม่เพียงพอ) Satisfy (สมบูรณ์) และ Explosion (เชื่อมมีสะเก็ด) ก่อนที่รถแต่ละ

คันจะถูกส่งผ่านสถานีจุดเชื่อม (Station) โดยกำหนดให้โปรแกรมต้องมีค่าความแม่นยำ (Precision) ไม่น้อยกว่า 90%

1.4 ระเบียบวิธีวิจัย

1.4.1 ศึกษาที่มาและผลกระทบของการเชื่อมความต้านทานแบบจุดโดยใช้หม้อแปลงไฟฟ้า กระแสตรงชนิดความถี่ปานกลาง (MFDC) เพื่อสนับสนุนความสำคัญของปัญหา และทำการวิเคราะห์หาสาเหตุที่ส่งผลกระทบต่อการทำงานที่ผิดพลาดของเครื่องจักรหรืออุปกรณ์สำหรับการเชื่อม

1.4.2 รวบรวมข้อมูลจากเครื่องจักรที่ใช้ในการเชื่อมย้อนหลังอย่างน้อย 3 เดือน โดยมุ่งเน้นเฉพาะพารามิเตอร์ที่เกี่ยวข้อง ซึ่งได้จากระบบคอมพิวเตอร์ควบคุมการเชื่อม เช่น ค่ากระแสไฟฟ้า แรงดันไฟฟ้า เวลาที่จ่ายกระแส และจำนวนครั้งในการเชื่อมหลังจากการทำความสะอาดหัวเชื่อม

1.4.3 ทดลองกระบวนการเชื่อมโดยใช้ชิ้นงานทดสอบ และปรับใช้พารามิเตอร์แบบต่าง ๆ เพื่อควบคุมหม้อแปลงไฟฟ้าในการเก็บค่าผลลัพธ์ที่ได้ เพื่อนำมาใช้ในการเปรียบเทียบผลการทดลอง

1.4.4 นำชุดข้อมูลที่รวบรวมได้เข้าสู่ระบบ Machine Learning (ML) โดยใช้เทคนิคการเรียนรู้แบบ Supervised Learning เพื่อให้ระบบเรียนรู้จากข้อมูลและสร้างโมเดลที่เหมาะสมที่สุดในการคาดการณ์ผลลัพธ์

1.4.5 ทำการวิเคราะห์หา Parameter เพิ่มเติมที่อาจมีนัยสำคัญต่อการเกิดผลลัพธ์เช่น Undersize และ Explosion จากการเชื่อม และป้อนเข้าสู่ระบบ Machine Learning อีกครั้ง เพื่อเพิ่มค่าความแม่นยำของโมเดล โดยใช้ข้อมูลจากการวัดด้วยเครื่องมือคลื่นเสียงความถี่สูง (Ultrasonic Testing, UT)

1.4.6 เปรียบเทียบผลลัพธ์ที่ได้จากโมเดลที่พัฒนาขึ้นกับผลการตรวจสอบรอยเชื่อมจริงในปัจจุบัน เพื่อยืนยันความถูกต้องของผลลัพธ์ที่โมเดลสามารถคาดการณ์ได้

1.4.7 ออกแบบระบบจัดเก็บข้อมูลและระบบแสดงผลสำหรับรถยนต์ที่ผลิตแต่ละคัน เพื่อให้สามารถตรวจสอบย้อนกลับข้อมูลการผลิตและคุณภาพรอยเชื่อมได้

1.4.8 วิเคราะห์และสรุปผลการวิจัย โดยพิจารณาผลลัพธ์จากการทดสอบและการเปรียบเทียบโมเดลกับข้อมูลจริง

1.4.9 จัดเตรียมรายงานสรุปผลการวิจัย และนำเสนอผลลัพธ์และข้อเสนอแนะในการปรับปรุงกระบวนการ

1.5 สถานที่ทำวิจัย

อาคาร บอดีชี้อป บริษัท ฟอร์ด มอเตอร์ คัมปะนี (ประเทศไทย) จำกัด 500/103 หมู่ 3 ตำบลตาสีหิ อำเภอลวกแดง จังหวัดระยอง

1.6 เครื่องมือที่ใช้ในการทำวิจัย

- 1.6.1 ศึกษาหุ่นยนต์สำหรับงานเชื่อมยี่ห้อ Kawasaki รุ่น BX200L
- 1.6.2 คอมพิวเตอร์ควบคุมการเชื่อมแบบจุด ยี่ห้อ Bosch รุ่น PSI 63C3
- 1.6.3 ปืนเชื่อมด้วยความต้านทานแบบจุด ยี่ห้อ OBARA ด้วยหม้อแปลง MFDC รุ่น SRTC
- 1.6.4 หัวเชื่อมทองแดงแบบผสม (CuCrZr)
- 1.6.5 แผ่นโลหะเหล็กชนิดความแข็งแรงสูงขนาด 350-500 MPa เคลือบด้วยกัลวาไนซ์ โดยมีความหนาแน่นระหว่าง 0.8 – 1.2 mm จำนวนสองชั้น
- 1.6.6 เครื่องมือตรวจสอบรอยเชื่อมแบบจุด ยี่ห้อ Tessonic รุ่น F1 ด้วยหัววัดขนาด 52 ตาราง
- 1.6.7 โปรแกรม Microsoft Visual Studio 2022 ด้วยภาษาโปรแกรม Python 3.12 (64-bit)
- 1.6.8 คอมพิวเตอร์ Lenovo AMD Ryzen 5 5800 with Nvidia RTX A4000 16GB, RAM 128 GB, Window 11 Home Single Language
- 1.6.9 คอมพิวเตอร์ Dell T7920 Intel XEON Silver 4108x2CPU with Nvidia RTX A4000 16GB, RAM 256 GB, Window 11 Pro for Workstation

1.7 ประโยชน์ที่คาดว่าจะได้รับ

- 1.7.1 เพิ่มการตรวจสอบคุณภาพจากการสุ่มตรวจเป็นตรวจสอบ 100% เนื่องจากมีโปรแกรมช่วยคาดการณ์การเกิดอาการความผิดปกติได้ล่วงหน้า
- 1.7.2 ลดภาระการทำงานของพนักงาน เนื่องจากความต้องการในการตรวจสอบลดลงจากการใช้โปรแกรมช่วยคาดการณ์ความผิดปกติ ทำให้จำนวนที่ต้องการตรวจสอบในแต่ละวันลดลงได้
- 1.7.3 ลดเวลาในการทดสอบย้อนกลับในกระบวนการ เนื่องจากมีโปรแกรมช่วยคาดการณ์ความเสียหาย ทำให้สามารถย้อนดูข้อมูลของกระบวนการได้ 100%
- 1.7.4 ลดจำนวนผลิตภัณฑ์ที่ไม่ได้คุณภาพที่ต้องซ่อมภายนอกกระบวนการลง เนื่องจากใช้โปรแกรมการคาดการณ์ทำให้สามารถซ่อมผลิตภัณฑ์ได้ภายในกระบวนการ

บทที่ 2

ปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้องบทนำ

2.1 บทนำ

การเชื่อม RSW เป็นหนึ่งในเทคนิคการเชื่อมต่อวัสดุที่มีความสำคัญอย่างยิ่งสำหรับอุตสาหกรรมยานยนต์ และได้มีการพัฒนากระบวนการนี้โดยการนำระบบอัตโนมัติและหุ่นยนต์มาใช้เนื่องจากมีความยืดหยุ่นของกระบวนการทำให้สามารถปรับใช้กับสายการผลิตหลากหลายขนาดได้ กระบวนการนี้ควบคุมได้ง่ายและใช้เครื่องมือที่ไม่ซับซ้อน โดยการปรับพารามิเตอร์สำคัญ เช่น กระแสไฟฟ้า เวลาที่ใช้ในการเชื่อม หรือ แรงที่ใช้กดชิ้นงาน อีกทั้งข้อได้เปรียบที่สำคัญของการเชื่อมแบบนี้คือความสามารถในการเชื่อมวัสดุโลหะได้หลากหลายชนิด อย่างไรก็ตาม การตรวจสอบขนาดของรอยเชื่อมในระหว่างการผลิตเป็นเรื่องยาก เนื่องจากกระบวนการนี้เกิดขึ้นภายใต้พื้นผิวของชิ้นงานเชื่อม จึงจำเป็นต้องมีการตรวจสอบ ซึ่งการตรวจสอบนั้นแบ่งออกเป็นสองประเภท คือ การตรวจสอบแบบทำลาย (Destructive Test, DT) และการตรวจสอบแบบไม่ทำลาย (Non-Destructive Test, NDT) ซึ่งไม่เหมาะกับการตรวจสอบบนสายการผลิตรถยนต์ในปัจจุบัน




รูปที่ 2.1 กระบวนการเชื่อมในอุตสาหกรรมยานยนต์

2.1.1 การพัฒนา RSW ในการผลิตรถยนต์

การเชื่อม RSW มีบทบาทสำคัญในอุตสาหกรรมการผลิตรถยนต์มาอย่างยาวนานกว่าหนึ่งศตวรรษ โดยเป็นกระบวนการที่รวดเร็วและคุ้มค่าในการเชื่อมแผ่นโลหะสำหรับการผลิตในปริมาณมาก ดังรูปที่ 2.1 เดิมที RSW ได้รับการพัฒนาขึ้นเพื่อลดการใช้แรงงานในกระบวนการเชื่อม

เมื่อเปรียบเทียบกับวิธีการอื่น เช่น การยึดด้วยหมุดย้ำหรือการเชื่อมอาร์ค อีกทั้งยังเป็นกระบวนการที่ช่วยเพิ่มความเป็นระบบในสายการประกอบโครงสร้างยานยนต์


เมื่ออุตสาหกรรมการผลิตยานยนต์พัฒนาขึ้น วัสดุที่ใช้ในการผลิตก็ได้พัฒนาไปพร้อมกัน โดยเฉพาะอย่างยิ่ง เหล็กที่มีความแข็งแรงสูง (High Strength Steel: HSS) และอะลูมิเนียม ซึ่งได้รับความนิยมมากขึ้นเนื่องจากสามารถลดน้ำหนักของยานยนต์ได้โดยไม่ลดทอนความปลอดภัย ซึ่งเป็นปัจจัยสำคัญในการเพิ่มประสิทธิภาพการใช้พลังงาน และตอบสนองต่อมาตรฐานด้านการปล่อยมลพิษและความยั่งยืน วัสดุที่มีน้ำหนักเบาเหล่านี้ได้ช่วยรักษาความสำคัญของ RSW โดยเฉพาะเมื่อต้องใช้งานเหล็กความแข็งแรงสูงขั้นสูง (Advanced High Strength Steels: AHSS) เช่น เหล็ก TRIP (Transformation Induced Plasticity) ซึ่งมีทั้งความแข็งแรงและความยืดหยุ่นที่ช่วยเสริมประสิทธิภาพโครงสร้างให้ทนต่อการชน



รูปที่ 2.2 ส่วนประกอบของตัวถังรถยนต์

งานวิจัยโดย (Brauser, S., Pepke, L., Weber, G., Rethmeier, M., 2010) [10] ได้เน้นย้ำถึงความเปลี่ยนแปลงในแนวทางการผลิตยานยนต์ที่มุ่งเน้นประสิทธิภาพพลังงานและความปลอดภัยมากยิ่งขึ้น แนวโน้มนี้ได้ผลักดันการพัฒนาเทคนิค RSW เพื่อรองรับคุณสมบัติเฉพาะของ AHSS ซึ่งแม้จะมีความแข็งแรงและความทนทานสูง แต่ก็มาพร้อมกับความท้าทายในด้านความสามารถในการเชื่อมและคุณภาพของรอยเชื่อม งานวิจัยระบุว่า AHSS มีแนวโน้มที่จะเกิดความล้มเหลว เช่น การแตกหักบริเวณรอยต่อวัสดุ (Interfacial Failure) และการแตกหักแบบ Partial Plug เมื่อเผชิญกับความเครียดสูง ซึ่งต่างจากเหล็กทั่วไป

ความท้าทายเหล่านี้นำไปสู่การใช้อุปกรณ์เชื่อมขั้นสูง เช่น ระบบควบคุมกระแสไฟฟ้าแบบคงที่ (Constant-Current Control: CCC) และการควบคุมอุณหภูมิที่แม่นยำ เพื่อให้มั่นใจถึงคุณภาพและความแข็งแรงของจุดเชื่อมในอุตสาหกรรมยานยนต์ (Oliveira, J.P., Ponder, K., Brizes, E., Abke, T. และ Ramirez, A., 2019) [53] ยิ่งไปกว่านั้น เนื่องจากยานยนต์ในปัจจุบันมักประกอบด้วยจุดเชื่อมหลายพันจุดดังภาพที่ 2.2 การรับประกันคุณภาพจุดเชื่อมจึงมีความสำคัญอย่างยิ่ง ทำให้เกิดการพัฒนาคณิตศาสตร์ และระบบตรวจสอบคุณภาพที่สามารถตรวจจับข้อบกพร่องได้แบบเรียลไทม์



รูปที่ 2.3 พารามิเตอร์ในการเชื่อมที่ใช้สำหรับการเชื่อม RSW ของเหล็ก Usibor 1500 [53]

งานวิจัย (Shafee, Shaik และ Naik, B., Sammaiah, D., 2015) (Dancette, S., Huin, T., Dupuy, T. และ Fabrègue, D., 2021) [69, 16] ยังแสดงให้เห็นว่าผู้ผลิตได้พัฒนากลยุทธ์การควบคุมที่สามารถปรับพารามิเตอร์การเชื่อมแบบไดนามิกในระหว่างกระบวนการดังภาพที่ 2.3 เพื่อเพิ่มประสิทธิภาพและคุณภาพของจุดเชื่อม แม้วัสดุที่ใช้จะมีข้อจำกัดหรือความท้าทายในการเชื่อมก็ตาม ยิ่งไปกว่านั้น การเปลี่ยนมาใช้วัสดุที่มีความแข็งแรงสูง เช่น AHSS ได้ผลักดันให้เกิดการพัฒนาเทคโนโลยีการตรวจสอบคุณภาพจุดเชื่อมที่ทันสมัย ทั้งในรูปแบบอัตโนมัติและการตรวจสอบแบบเรียลไทม์ การใช้ระบบเซ็นเซอร์ขั้นสูงในการตรวจสอบกระบวนการเชื่อมกลายเป็นมาตรฐานในอุตสาหกรรมยานยนต์ ซึ่งช่วยให้ผู้ผลิตสามารถควบคุมและปรับปรุงคุณภาพการเชื่อมได้อย่างรวดเร็ว





Fig. 16. Peak load-displacement curves for TS test (a) and CT test (b). Peak load and failure energy TS test (c) and CT test (d).



รูปที่ 2.4 ภาพหน้าตัดการแตกหักของรอยเชื่อม (a) สภาวะโหลด TS; (b) สภาวะโหลด CT. [14]

และมีประสิทธิภาพ งานวิจัยล่าสุด เช่น การศึกษาที่ (Chen, x., Li, Z., Wang, Y-Q., Yang, D., Yi, H. และ Xie, G.M., 2023) [14] ได้เน้นถึงความสำคัญของการปรับพารามิเตอร์เพื่อป้องกันข้อบกพร่องที่อาจเกิดขึ้นในกระบวนการเชื่อม เช่น การเกิดโพรง (Porosity) หรือการเปราะเนื่องจากโลหะเหลว ดังภาพที่ 2.4 การป้องกันข้อบกพร่องเหล่านี้ช่วยรับรองว่าจุดเชื่อมมีความคงทนและปลอดภัยในระยะยาว

การพัฒนาเทคนิคและอุปกรณ์ RSW ยังคงเป็นหัวใจสำคัญในการตอบสนองต่อความต้องการของอุตสาหกรรมยานยนต์ ซึ่งมุ่งเน้นด้านการลดน้ำหนัก เพิ่มความแข็งแรงของวัสดุและความปลอดภัยของโครงสร้าง การบรรลุเป้าหมายเหล่านี้จำเป็นต้องอาศัยการควบคุมกระบวนการเชื่อมที่แม่นยำมากขึ้น รวมถึงเทคโนโลยีการตรวจสอบคุณภาพที่ล้ำสมัย เพื่อตอบสนองต่อข้อกำหนดด้านความปลอดภัยของผู้บริโภค และมาตรฐานที่เข้มงวดในอุตสาหกรรมยานยนต์

2.1.2 หลักการพื้นฐาน อุปกรณ์ และข้อบกพร่องที่พบบ่อยในกระบวนการ RSW

การเชื่อม RSW ทำงานบนหลักการของการสร้างความร้อนที่เกิดจากความต้านทานไฟฟ้าบริเวณผิวสัมผัสระหว่างแผ่นโลหะสองแผ่นหรือมากกว่า ความร้อนนี้ทำให้โลหะหลอมละลายและเชื่อมติดกันเมื่อเย็นตัวลง กระบวนการนี้เกี่ยวข้องกับการปล่อยกระแสไฟฟ้าสูงผ่านโลหะ พร้อมกับการออกแรงกดจากหัวไฟฟ้า ปัจจัยสำคัญที่มีผลต่อคุณภาพและความสม่ำเสมอของจุดเชื่อม ได้แก่

กระแสไฟฟ้า แรงกด และระยะเวลาในการเชื่อม อุปกรณ์เฉพาะทาง เช่น หุ่นยนต์ ปืนเชื่อม และระบบควบคุมเวลาถูกนำมาใช้เพื่อเพิ่มประสิทธิภาพในกระบวนการ โดยเฉพาะอย่างยิ่งในสายการผลิตยานยนต์ที่ต้องการผลผลิตในปริมาณสูง


2.1.2.1 หุ่นยนต์และระบบอัตโนมัติในกระบวนการ RSW

ในกระบวนการผลิตยานยนต์สมัยใหม่ หุ่นยนต์ถูกนำมาใช้อย่างแพร่หลายในการเชื่อม RSW เพื่อเพิ่มความแม่นยำและความสม่ำเสมอ หุ่นยนต์ช่วยให้สามารถควบคุมแรงกดจากหัวไฟฟ้าได้อย่างสม่ำเสมอ ดังภาพที่ 2.6 และกำหนดตำแหน่งในการเชื่อมได้อย่างแม่นยำ ซึ่งมีความสำคัญต่อการสร้างจุดเชื่อมที่แข็งแรงและเชื่อถือได้ โดยอาศัย กรอบแนวคิดของระบบไซเบอร์-ฟิสิคัล(Cyber-Physical System: CPS) สำหรับการเชื่อม RSW เพื่อแก้ปัญหาช่องว่างในการรับรองคุณภาพการเชื่อม โดยระบบที่นำเสนอผลงานการทำงานของเครื่องเชื่อมและข้อมูลจากเซ็นเซอร์เข้ากับการวิเคราะห์ขั้นสูง ดังภาพที่ 2.6 (Ahmed, F., Jannat, N-E., Zamanzad G., Saeed R., Jeremy และ Kim, K-Y., 2019) (Bing, W., 2025) [1,9]

โดยทั่วไป หุ่นยนต์ที่ใช้ในกระบวนการ RSW มักเป็นหุ่นยนต์อุตสาหกรรมแบบ 6 แกน ซึ่งมีความยืดหยุ่นในการเข้าถึงตำแหน่งต่าง ๆ บนโครงสร้างรถยนต์ หุ่นยนต์เหล่านี้ทำงานร่วมกันกับอุปกรณ์อื่น ๆ เช่น ปืนเชื่อมและคอมพิวเตอร์ควบคุมเวลาในการเชื่อม โดยระบบอัตโนมัติช่วยให้กระบวนการเชื่อมสามารถปรับตัวให้เข้ากับวัสดุและรูปทรงที่หลากหลาย เพื่อตอบสนองต่อมาตรฐาน




รูปที่ 2.5 การเชื่อม RSW สำหรับสายการผลิตตัวถังรถยนต์ [27]



รูปที่ 2.6 กรอบแนวคิดของระบบไซเบอร์-กายภาพ สำหรับการเชื่อม RSW [1]


ด้านความปลอดภัยและความแข็งแรงของอุตสาหกรรมยานยนต์ โดยเฉพาะการวิเคราะห์ข้อมูลวิถีอินฟราเรด (Infrared Non-Destructive Evaluation: IR NDE) เพื่อตรวจสอบรูปร่างและขนาดของจุดเชื่อมด้วยความแม่นยำและความรวดเร็วสูง ดังรูปที่ 2.7 งานวิจัยนี้ใช้วิดีโอ 90 ชุด จาก 7 ชุดของวัสดุที่เชื่อม โดยพัฒนาวิธีใหม่ในการรวบรวมข้อมูลสำหรับการฝึกอบรมเครือข่ายประสาทเทียม (Mathisizik, C., Zschetzsche, J. และ Füssel, U., 2019) [47]



รูปที่ 2.7 แผนผังเชิงโครงสร้างของการตรวจสอบรอยเชื่อมด้วยเทคนิค IR NDE แบบออนไลน์ [47]

2.1.2.2 ปืนเชื่อมและการออกแบบขั้วไฟฟ้า

ปืนเชื่อมเป็นอุปกรณ์หลักในกระบวนการ RSW ที่ใช้แรงในการกดขั้วไฟฟ้าลงบนแผ่นโลหะ ปืนเชื่อมทั่วไปประกอบด้วยขั้วไฟฟ้าสองขั้ว (ขั้วบวกและขั้วลบ) ที่ติดตั้งบนแขนหุ่นยนต์ ซึ่งควบคุมด้วยระบบนิวแมติกหรือเซอร์โว ขึ้นอยู่กับการเข้าถึงและรูปทรงของชิ้นส่วน ปืนเชื่อมอาจมีหลายแบบ เช่น แบบ C-type และ X-type ดังภาพที่ 2.8 (Tiedra, P., Martín, Ó. และ López, M., 2011) [73] โดยปืนแบบ C-type มักถูกเลือกใช้เพื่อความสามารถในการออกแรงกดได้อย่างสมดุล ในขณะที่ปืนแบบ X-type ถูกใช้ในสถานการณ์ที่การเข้าถึงมีอย่างจำกัด การออกแบบขั้วไฟฟ้า ซึ่งมักทำจากทองแดงหรือโลหะผสมทองแดง ซึ่งถูกเลือกมาเพื่อการนำไฟฟ้าที่ดีและทนทาน เพราะขั้วไฟฟ้าจะต้องรับมือกับกระแสไฟฟ้าสูงและความเครียดทางกล แต่การเสื่อมสภาพของขั้วไฟฟ้าสามารถทำให้กระแสไฟฟ้าไม่สม่ำเสมอและเพิ่มโอกาสในการเกิดข้อบกพร่อง เช่น การเกิดโพรงหรือรอยแตกได้ ดังนั้นการบำรุงรักษาขั้วไฟฟ้า เช่น การแต่งรูปทรงจึงเป็นสิ่งจำเป็นเพื่อให้การเชื่อมมีคุณภาพสูงสม่ำเสมอในปริมาณการผลิตสูง (Summerville, C., Compston, P. และ Doolan, M., 2019) [70]




รูปที่ 2.8 ปืนเชื่อม RSW (a) X-Type (b) C-Type


2.1.2.3 คอมพิวเตอร์ควบคุมเวลาและควบคุมกระแสไฟฟ้า

ความแม่นยำในการควบคุมเวลาและกระแสไฟฟ้าเป็นปัจจัยพื้นฐานในการสร้างจุดเชื่อมที่มีคุณภาพสูง คอมพิวเตอร์ควบคุมเวลาจะแบ่งกระบวนการเชื่อมออกเป็นสามขั้นตอน ได้แก่ เวลาในการบีบ เวลาในการเชื่อม และเวลาในการกดชิ้นงานหลังการเชื่อม ดังรูปที่ 2.3 การบีบ คือ การออกแรงกดให้ขั้วไฟฟ้าติดแน่นกับแผ่นโลหะก่อนที่จะปล่อยกระแสไฟฟ้าเพื่อป้องกันไม่ให้เกิดช่องว่างในระหว่างการเชื่อม ส่วนเวลาในการเชื่อม คือ ช่วงเวลาที่ปล่อยกระแสไฟฟ้าเพื่อสร้างจุดเชื่อม

และเวลาในการกดขึ้นงานหลังการเชื่อมคือช่วงเวลาที่รักษาแรงกดให้โลหะหลอมได้เย็นและแข็งตัว การปรับเวลาและกระแสไฟฟ้าให้เหมาะสมเป็นสิ่งสำคัญเพื่อป้องกันข้อบกพร่อง เช่น ขนาดของ จุดเชื่อมไม่เพียงพอหรือรอยแตกที่เกิดจากความเครียดทางความร้อน โดยเฉพาะในเหล็กที่มีความ แข็งแรงสูง ระบบ RSW ที่ทันสมัยใช้ตัวควบคุมแบบตั้งโปรแกรมดังรูปที่ 2.9 ได้ซึ่งสามารถปรับ กระแสไฟฟ้าตามข้อมูลจากเซ็นเซอร์ที่ตรวจสอบพารามิเตอร์ต่าง ๆ ดังรูปที่ 2.10 เช่น อุณหภูมิ แรง และการเคลื่อนที่ของขั้วไฟฟ้า วิธีการควบคุมแบบปรับตัว(Adaptive control) เช่น การปรับ พารามิเตอร์การเชื่อมโดยอัตโนมัติเพื่อรองรับการเปลี่ยนแปลงในความหนาของวัสดุหรือการสึกหรอ ของขั้วไฟฟ้า เพื่อรักษาคุณภาพการเชื่อมให้สม่ำเสมอ โดยเน้นไปที่เปรียบเทียบการเชื่อม RSW ใน รอบก่อนหน้า (Han, L., Thornton, M. และ Shergold, M., 2010) [33]



รูปที่ 2.9 คอมพิวเตอร์ควบคุมการเชื่อม (Weld Timer)



รูปที่ 2.10 แผนผังไดอะแกรมของอินเวอร์เตอร์ คอมพิวเตอร์ควบคุมการเชื่อม และ หม้อแปลง

2.1.2.4 ข้อบกพร่องที่พบบ่อยในกระบวนการ RSW และมาตรการควบคุมคุณภาพ

แม้ว่าอุปกรณ์ RSW ที่ทันสมัยจะมีความแม่นยำสูง แต่ข้อบกพร่องในจุดเชื่อมยังคงพบได้เนื่องจากกระบวนการที่ซับซ้อนทั้งด้านความร้อนและกลศาสตร์ ซึ่งมีข้อบกพร่องที่สำคัญ ดังรูปที่ 2.11 ได้แก่


1) **การเกิดโพรง:** เกิดจากก๊าซที่ติดอยู่ภายในจุดเชื่อมระหว่างกระบวนการเย็นตัวอย่างรวดเร็ว ซึ่งทำให้จุดเชื่อมไม่แข็งแรง

2) **รอยแตก:** ความเครียดทางความร้อนสูงในวัสดุ เช่น AHSS สามารถทำให้เกิดรอยแตกภายในจุดเชื่อมซึ่งทำให้ความแข็งแรงลดลง (Pattanaik, A.K., Panda, S., Pal, K. และ Mishra, D., 2018) [55]

3) **การเกิดสะเก็ดการเชื่อม:** เมื่อมีการใช้กระแสไฟฟ้าหรือแรงกดมากเกินไป จะทำให้โลหะหลอมเหลวถูกดันออกมา ทำให้ขนาดจุดเชื่อมลดลงและจุดเชื่อมอ่อนแอลง


4) **ขนาดของจุดเชื่อมเล็กกว่ามาตรฐาน:** หากกระแสไฟฟ้าหรือเวลาในการเชื่อมไม่เพียงพอ จุดเชื่อมจะมีขนาดไม่ถึงเกณฑ์มาตรฐานที่ต้องการ ทำให้จุดเชื่อมแข็งแรงไม่เพียงพอ (Moshayedi, H., Sattari-Far, I., 2014) [51]

5) **การเปราะเนื่องจากโลหะเหลว (Liquid Metal Embrittlement: LME):** เป็นข้อบกพร่องที่เกิดขึ้นโดยเฉพาะใน AHSS ซึ่งการเคลือบด้วยสังกะสีอาจทำให้เกิดความเปราะภายใต้อุณหภูมิสูง ทำให้ความแข็งแรงของจุดเชื่อมลดลง (Geslain, E., Rogeon, P., Pierre, T., Pouvreau, C. และ Cretteur, L., 2017) [28]



รูปที่ 2.11 โหมดและกลไกความเสียหาย [70]

เพื่อลดข้อบกพร่องเหล่านี้ ผู้ผลิตใช้วิธีการควบคุมคุณภาพต่าง ๆ รวมถึง การทดสอบ DT และการทดสอบแบบ NDT และการตรวจสอบแบบเรียลไทม์ โดยวิธีการทดสอบแบบ ไม่ทำลาย เช่น การทดสอบ UT ถูกนำมาใช้เพื่อประเมินขนาดของจุดเชื่อมและตรวจหาข้อบกพร่อง ภายในโดยไม่ทำให้เกิดความเสียหายต่อจุดเชื่อม ดังภาพที่ 2.12 (Xiaokai, W., Sanyue, G., Lin, H., Bin, W. และ Ximing, H., 2018)(Ahmed, F. และ Kim, K-Y., 2017) [80,2] ได้นำเสนอการ ตรวจสอบแบบเรียลไทม์ ซึ่งบางครั้งพัฒนาโดยใช้อัลกอริทึม ML สามารถตรวจจับความผิดปกติใน พารามิเตอร์ต่าง ๆ เช่น การเคลื่อนที่ของขั้วไฟฟ้า กระแสไฟฟ้า หรืออุณหภูมิ ทำให้สามารถ ปรับเปลี่ยนการตั้งค่าล่วงหน้าได้เพื่อรักษาคุณภาพ (Geng, C., Buyun, S., Gaocai, F., Xiangxiang, C. และ Guangde, Z., 2024)(Kershaw, J., Ghassemi-Armaki, H., Carlson, B. และ Wang, P., 2024) [27,36] ยกตัวอย่างเช่น โมเดลที่ใช้ Data driven สามารถวิเคราะห์แนวโน้มโดยใช้ข้อมูลจาก เซ็นเซอร์และปรับพารามิเตอร์เพื่อป้องกันข้อบกพร่องก่อนที่จะเกิดขึ้น ตามที่ได้มีการศึกษาในงานวิจัย ที่มุ่งเน้นการตรวจจับข้อบกพร่องแบบเรียลไทม์ อีกทั้งยังใช้เทคนิคการเพิ่มข้อมูล (Data Augmentation) แบบใหม่เพื่อเพิ่มปริมาณข้อมูลฝึกอบรม ผลลัพธ์เชิงปริมาณแสดงให้เห็นว่าวิธีนี้มี ประสิทธิภาพสูงในการตรวจสอบคุณภาพการเชื่อม RSW ผ่านระบบวิชัน (Ahmed, F. และ Kim, K-Y., 2018) [3] ได้ทำการเก็บรวบรวมจากผู้ผลิตรถยนต์ เพื่อนำมาใช้ในสังกัดกฎการตัดสินใจโดยใช้ วิธีการต้นไม้ตัดสินใจ (Classification and Regression Trees: CART) เพื่อจับความหมายและเพิ่ม ความสามารถในการแพร่ความรู้ที่สร้างขึ้น ได้แสดงให้เห็นว่าออนโทโลยี RSW ซึ่งมีการสร้างกฎ ความสามารถในการเชื่อมจากชุดข้อมูล สามารถทำนายขนาดของรอยเชื่อม RSW ได้ โดยขนาดความ กว้างของรอยเชื่อมที่ทำนายมีขนาดใกล้เคียงกับค่าจริง




รูปที่ 2.12 (a) หัววัดการตรวจจับด้วยคลื่นอัลตราโซนิก , (b) ตัวอย่างงานเชื่อม RSW , (c) ปลาย อิเล็กโทรดของเครื่องเชื่อม RSW [80]


2.2 ความท้าทายในการทำนายคุณภาพการเชื่อม

2.2.1 ตัวชี้วัดคุณภาพที่สำคัญและโหมดความเสียหายใน RSW

ในกระบวนการเชื่อม RSW คุณภาพของจุดเชื่อมมักถูกประเมินโดยใช้ตัวชี้วัดสำคัญหลายประการ ได้แก่ ขนาดเส้นผ่านศูนย์กลางของจุดเชื่อม (nugget diameter) ดังภาพที่ 2.13, ความสามารถในการทนทานต่อแรงเฉือน (shear strength) ดังภาพที่ 2.14, และลักษณะการแตกหัก (fracture mode) ตัวชี้วัดเหล่านี้เป็นปัจจัยสำคัญที่ใช้ประเมินความแข็งแรงและความทนทานของจุดเชื่อม โดยเฉพาะอย่างยิ่งในอุตสาหกรรมยานยนต์ ซึ่งทุกจุดเชื่อมต้องสามารถรองรับความเครียดเชิงโครงสร้างได้อย่างมีประสิทธิภาพ



รูปที่ 2.13 การวัดและคำนวณขนาดเส้นผ่านศูนย์กลางของรอยเชื่อม [ES]



รูปที่ 2.14 การทดสอบแรงดึงแบบสถิตตามมาตรฐาน DIN EN ISO 14273


ขนาดและเส้นผ่านศูนย์กลางของจุดเชื่อมมีความสัมพันธ์โดยตรงกับความสามารถในการรับน้ำหนัก เนื่องจากจุดเชื่อมที่มีขนาดเล็กเกินไปมักมีความแข็งแรงน้อยกว่าและเสี่ยงต่อการ

เสียหาย นอกจากนี้ ความสามารถในการทนทานต่อแรงเฉือนยังเป็นตัวชี้วัดสำคัญที่ใช้ในการประเมินความสามารถของจุดเชื่อมในการต้านทานแรงที่กระทำในทิศทางขนานกับพื้นผิว ซึ่งเป็นปัจจัยสำคัญต่อความปลอดภัยและความน่าเชื่อถือของยานยนต์ในการใช้งานจริง

ในกระบวนการเชื่อม RSW โหมดความเสียหายที่สำคัญแบ่งออกเป็นสองประเภทหลัก ได้แก่ ความเสียหายที่พื้นผิว (Interfacial Failure) และ ความเสียหายแบบดึงออก (Pull-Out Failure) ซึ่งโหมดเหล่านี้เป็นตัวชี้วัดสำคัญที่สะท้อนถึงประสิทธิภาพของจุดเชื่อม ดังรูปที่ 2.15

1) ความเสียหายที่พื้นผิว เกิดขึ้นเมื่อจุดเชื่อมไม่สามารถเชื่อมต่อระหว่างแผ่นโลหะได้อย่างสมบูรณ์ ซึ่งมักเป็นผลจากการตั้งค่าพารามิเตอร์ที่ไม่เหมาะสม เช่น กระแสไฟฟ้าไม่เพียงพอหรือแรงกดจากขั้วไฟฟ้าไม่เพียงพอ ส่งผลให้แนวเชื่อมขาดความแข็งแรงและมีแนวโน้มที่จะเสียหายได้ง่าย


2) ความเสียหายแบบดึงออก เกิดขึ้นเมื่อแนวเชื่อมยังคงติดอยู่แต่ถูกดึงออกจากแผ่นโลหะหนึ่งภายใต้แรงดึงหรือแรงเครียดที่มากเกินไป ปัญหานี้มักเกิดจากการยึดติดทางกลที่ไม่เพียงพอ เช่น การกระจายแรงกดไม่สม่ำเสมอหรือการเชื่อมที่ไม่ครอบคลุมพื้นที่ที่เหมาะสม



รูปที่ 2.15 รูปทรงและขนาดของตัวอย่างการทดสอบแรงดึง: (a) แบบเยื้องศูนย์, (b) แบบตั้งฉาก, (c) แบบกากบาท [33]

โหมดความเสียหายทั้งสองประเภทมีผลกระทบอย่างมากต่อความแข็งแรงและความปลอดภัยของจุดเชื่อมในโครงสร้างยานยนต์ เนื่องจากแต่ละโหมดส่งผลต่อความสามารถในการรองรับแรงภายใต้เงื่อนไขการใช้งานที่แตกต่างกัน เพื่อประเมินความเสถียรของกระบวนการและโซนการเชื่อม (Heat Affected Zone: HAZ) ที่ยอมรับได้ในเวลาการเชื่อมที่แตกต่างกัน และวิเคราะห์คุณสมบัติเชิงกลผ่านการทดสอบแรงเฉือนและแรงดึงสำหรับจุดเชื่อมขนาดต่างๆ (Gorti, J., Mukhopadhyay, G. และ Dutta, K., 2022)(Shojaee, M., Midawi, A., Barber, B., Ghassemi-Armaki, H., Worswick, M. และ Biro, E., 2021) [31,65] อีกทั้งยังมีการนำเสนอวิธีใหม่สำหรับการตรวจวัดการทะลุของรอยเชื่อมในกระบวนการเชื่อม RSW ของหุ่นยนต์แบบเรียลไทม์และการทดสอบแบบ NDT ซึ่งถือเป็นตัวชี้วัดคุณภาพที่สำคัญสำหรับการผลิตตัวถังรถยนต์ วิธีนี้เน้นการวิเคราะห์โดยการดึงคุณสมบัติจากสัญญาณการเคลื่อนที่ของอิเล็กโทรด โดยมีการทดสอบความสามารถทั่วไปของคุณสมบัติสัญญาณทั้งในสภาวะการผลิตปกติและผิดปกติ จากนั้นจึงพัฒนาแบบจำลองเชิงวิเคราะห์สำหรับการพยากรณ์การทะลุของรอยเชื่อมผ่านการจำลองทางกายภาพ

งานวิจัยชี้ให้เห็นว่าการปรับเปลี่ยนพารามิเตอร์หลักในกระบวนการเชื่อม ได้แก่ กระแสไฟฟ้า, แรงกดจากขั้วไฟฟ้า, และ ระยะเวลาการเชื่อม ดังภาพที่ 2.16 มีผลอย่างมากต่อคุณภาพของจุดเชื่อมและโอกาสในการเกิดข้อบกพร่อง หากกระแสหรือแรงกดไม่เพียงพอ จุดเชื่อมอาจก่อตัวไม่สมบูรณ์ ส่งผลให้เกิดปัญหาการหลอมติดไม่เต็มที่ทำให้ความสามารถในการทนต่อแรงเฉือนลดลง ในทางตรงกันข้าม การใช้กระแสหรือแรงกดที่สูงเกินไป อาจทำให้เกิดข้อบกพร่อง เช่น รอยแตก ซึ่งเป็นผลจากการขยายตัวของความร้อนอย่างรวดเร็ว หรือ การเกิดโพรง ซึ่งเกิดจากก๊าซที่ถูกกักเก็บในแนวเชื่อม (Xia, Y-J., Zhou, L., Shen, Y., Wegner, D., Haselhuhn, A., Li, Y. และ Carlson, B., 2020) (Ravichandran, P., Anbu, C., Meenakshipriya, B. และ Sathiyavathi, S., 2020) [78,59]




รูปที่ 2.16 ลำดับขั้นตอนการเกิดรอยเชื่อมของการเชื่อม RSW

การควบคุมพารามิเตอร์เหล่านี้ให้เหมาะสมถือเป็นสิ่งสำคัญเพื่อลดข้อบกพร่องและเพิ่มคุณภาพของจุดเชื่อม งานวิจัยระบุว่า การใช้โมเดล ML ที่รวมตัวชี้วัดเหล่านี้สามารถช่วยให้ตรวจสอบกระบวนการแบบเรียลไทม์ได้อย่างมีประสิทธิภาพ โดยโมเดลเหล่านี้สามารถระบุแนวโน้มที่บ่งชี้ถึงความล้มเหลวของจุดเชื่อมล่วงหน้า ทำให้สามารถปรับพารามิเตอร์แบบทันทีเพื่อเพิ่มความสม่ำเสมอและคุณภาพของจุดเชื่อม การพัฒนาระบบคาดการณ์เช่นนี้ไม่เพียงช่วยลดข้อผิดพลาดในกระบวนการ แต่ยังเพิ่มความปลอดภัยและความน่าเชื่อถือในโครงสร้างของรถยนต์ได้อย่างมีนัยสำคัญ

2.2.2 เทคนิคการตรวจสอบในปัจจุบัน


เทคนิคการตรวจสอบแบบดั้งเดิมถูกนำมาใช้อย่างแพร่หลายในกระบวนการ RSW เพื่อรับรองคุณภาพของจุดเชื่อม โดยเฉพาะในด้านการผลิตยานยนต์ที่มีความสำคัญ เช่น การทดสอบ UT การถ่ายภาพเอ็กซเรย์ (X-ray) และการทดสอบแบบ DT โดยวิธีการทดสอบแบบทำลายถึงแม้จะมีความแม่นยำสูง แต่ต้องใช้วิธีการทำลายชิ้นงานเพื่อตรวจสอบปัจจัยต่าง ๆ เช่น ความสามารถในการทนแรงดึง ขนาดของแนวเชื่อม และลักษณะการแตกหัก การวิเคราะห์โครงสร้างภายในของจุดเชื่อมผ่านการทดสอบแบบทำลายสามารถให้ข้อมูลเชิงลึกเกี่ยวกับความสามารถของจุดเชื่อมในการทนต่อความเครียดทางกล ดังรูปที่ 2.17 อย่างไรก็ตาม ข้อเสียของวิธีนี้คือการต้องทำลายชิ้นงานซึ่งทำให้ต้นทุนสูงและไม่มีประสิทธิภาพในกระบวนการผลิตที่มีปริมาณสูง



รูปที่ 2.17 การทดสอบรอยเชื่อมด้วยส่ว


วิธีการทดสอบแบบ NDT เช่น การทดสอบด้วยคลื่นเสียงและการถ่ายภาพเอ็กซเรย์ได้รับความนิยมมากขึ้นเนื่องจากสามารถประเมินคุณภาพของจุดเชื่อมภายในโดยไม่ทำลายชิ้นงาน (Dejans, A., Kurtov, O. และ Rymenant, P., 2020) [18] เป็นการทดสอบด้วยวิธีการใช้คลื่นเสียงเพื่อการตรวจจับข้อบกพร่องภายใน ดังรูปที่ 2.18 เช่น รอยแตก การหลอมติดไม่สมบูรณ์ และการเกิดโพรง โดยข้อดีหลักของวิธีนี้คือมีความแม่นยำและสามารถให้ข้อมูลแบบเรียลไทม์ เหมาะสำหรับการตรวจสอบจุดเชื่อมในปริมาณมาก การถ่ายภาพเอ็กซเรย์ก็เป็นอีกหนึ่งวิธีสามารถแสดงภาพโครงสร้าง

ภายในของจุดเชื่อมได้อย่างละเอียด ทำให้สามารถมองเห็นข้อบกพร่องที่อาจเกิดขึ้นได้ อย่างไรก็ตามวิธีการ NDT เหล่านี้มีข้อจำกัด ทั้งใช้เวลานานและต้องการอุปกรณ์และทักษะเฉพาะทาง ซึ่งทำให้มีต้นทุนสูงโดยเฉพาะสำหรับอุตสาหกรรมยานยนต์ที่ต้องการกระบวนการผลิตที่รวดเร็ว)(Andreoli, A., Chertov, A. และ Maev, R., 2016) [6] ได้ศึกษาความสัมพันธ์ระหว่างการวัดด้วยระบบ Real Time Integrated Weld Analyzer และผลการทดสอบแบบลอก (Peel Test) การทดลองเกี่ยวข้องกับการศึกษาขนาดของรอยเชื่อม สำหรับความหนาแผ่นโลหะ เวลาการเชื่อม และกระแสไฟฟ้าที่แตกต่างกันในตัวอย่างเหล็กกล้าคาร์บอนต่ำ (Mild Steel) โดยมีจุดมุ่งหมายเพื่อประเมินศักยภาพการใช้งานระบบอัลตราโซนิกแบบในเวลาเรียลไทม์ในสภาพแวดล้อมอุตสาหกรรม ซึ่งช่วยให้สามารถประเมินคุณภาพของจุดเชื่อม ทั้งหมดได้โดยไม่ทำลายชิ้นงาน ซึ่งยืนยันได้ว่าการทดสอบด้วยอัลตราโซนิกแบบเรียลไทม์สามารถใช้ระบบนี้ในการประเมินการเชื่อม RSW ได้อย่างน่าเชื่อถือ




รูปที่ 2.18 โครงสร้างของเซ็นเซอร์ AE ที่ติดตั้งบนอิเล็กโทรดด้านล่าง รวมถึงเทอร์โมคัปเปิลที่ติดอยู่บนหัวเชื่อม [18]

จากข้อจำกัดของวิธีการตรวจสอบแบบดั้งเดิม การนำการเรียนรู้ของเครื่องเข้ามาใช้จึงเป็นที่สนใจในฐานะทางเลือกที่ช่วยเพิ่มประสิทธิภาพในการประเมินคุณภาพ การเรียนรู้ของเครื่องนั้นสามารถวิเคราะห์ข้อมูลจากเซ็นเซอร์จำนวนมากเพื่อตรวจจบบรูปแบบและความผิดปกติที่อาจบ่งชี้ถึงข้อบกพร่อง การตรวจสอบการเบี่ยงเบนในพารามิเตอร์ เช่น การเคลื่อนที่ของขั้วไฟฟ้า กระแสไฟฟ้า และอุณหภูมิ ดังรูปที่ 2.19 ทำให้สามารถคาดการณ์ปัญหาด้านคุณภาพก่อนที่จะแสดงผล โดยการเรียนรู้ของเครื่องมีข้อดีหลายประการ ได้แก่:



รูปที่ 2.19 การตรวจสอบคุณภาพการเชื่อม RSW ออนไลน์ด้วยหัววัดอัลตราโซนิกแบบติดตั้งในระบบ (In-line UT)

- 1) การตรวจสอบคุณภาพแบบเรียลไทม์: โมเดลการเรียนรู้ของเครื่องสามารถวิเคราะห์คุณภาพของจุดเชื่อมอย่างต่อเนื่อง ทำให้สามารถตรวจจับการเบี่ยงเบนได้ในทันทีที่อาจบ่งบอกถึงข้อบกพร่องที่เกิดขึ้นในระหว่างกระบวนการผลิต
- 2) ลดการพึ่งพาการทดสอบแบบ NDT: ด้วยการใช้ข้อมูลเชิงคาดการณ์จากการเรียนรู้ของเครื่อง ผู้ผลิตสามารถลดความถี่ในการใช้วิธี NDT แบบดั้งเดิม ประหยัดเวลาและทรัพยากร ในขณะที่ยังคงรักษาความแม่นยำไว้ (Moomen, A., Ali, A. และ Ramahi, O., 2016) [49]
- 3) การควบคุมคุณภาพแบบอัตโนมัติ: การใช้ระบบการเรียนรู้ของเครื่องยังช่วยในการตรวจจับข้อบกพร่องที่อาจเกิดขึ้นในกระบวนการเชื่อม โดยการวิเคราะห์รูปแบบและสัญญาณที่ได้รับจากเซ็นเซอร์ ดังรูปที่ 2.20 เมื่อพบความผิดปกติ ระบบสามารถแจ้งเตือนหรือปรับพารามิเตอร์การเชื่อมโดยอัตโนมัติเพื่อแก้ไขปัญหา วิธีการนี้ช่วยลดความเสี่ยงของการผลิตชิ้นงานที่มีคุณภาพต่ำ และเพิ่มความน่าเชื่อถือของกระบวนการผลิต (Ali, R., El-Betar, A. และ Magdy, M., 2024) [4]



รูปที่ 2.20 แผนผังเชิงโครงสร้างของการทดลองการตรวจสอบรอยเชื่อม RSW [4]


การเปลี่ยนแปลงไปสู่การนำ ML เข้ามาใช้ในการควบคุมคุณภาพเป็นทางออกที่มีศักยภาพสำหรับผู้ผลิตยานยนต์ โดยช่วยลดการพึ่งพาวิธีการตรวจสอบที่ใช้ทรัพยากรมาก และทำให้สามารถปรับเปลี่ยนการตั้งค่าทันที ซึ่งช่วยเพิ่มประสิทธิภาพในการผลิตและลดต้นทุนในการผลิต

2.3 การตรวจสอบกระบวนการ RSW

2.3.1 เทอร์โมกราฟีอินฟราเรด (Infrared Thermography)

เทอร์โมกราฟีอินฟราเรดเป็นวิธีการตรวจสอบกระบวนการเชื่อม RSW แบบไม่สัมผัสกับผิวชิ้นงานที่ใช้กันอย่างแพร่หลาย โดยในวิธีนี้จะใช้เครื่องถ่ายภาพความร้อนอินฟราเรดเพื่อจับข้อมูลความร้อนที่ผิวสัมผัสระหว่างขั้วไฟฟ้ากับวัสดุฐาน โดยแสดงรูปแบบของอุณหภูมิบนพื้นผิวของขั้วไฟฟ้าให้ข้อมูลที่สำคัญเกี่ยวกับการก่อตัวของแนวเชื่อม การกระจายความร้อน และคุณภาพของแนวเชื่อม โดยเฉพาะอย่างยิ่ง รูปร่างของ HAZ มีอุณหภูมิสัมพันธ์อย่างใกล้ชิดกับขนาดและความแข็งแรงของแนวเชื่อม พบว่ารูปร่างของ HAZ ของอุณหภูมิมีผลกระทบอย่างมากต่อความสามารถในการทนแรงเฉือนของแนวเชื่อม ซึ่งแสดงถึงความสัมพันธ์ชัดเจนระหว่างการกระจายความร้อนบน

พื้นผิวและคุณภาพโครงสร้างของแนวเชื่อม นอกจากนี้ การศึกษาล่าสุดยังรายงานว่าการใช้เทอร์โมกราฟีความละเอียดสูงช่วยให้สามารถตรวจจับความแตกต่างของอุณหภูมิที่มีเพียงเล็กน้อยได้ จึงเพิ่มความแม่นยำในการทำนายคุณภาพของรอยเชื่อมโดยเทคโนโลยีอินฟราเรด ดังภาพที่ 2.21 ที่พัฒนาแล้วยังช่วยให้สามารถใช้เทอร์โมกราฟีหลายความยาวคลื่นซึ่งเพิ่มความไวต่อการเปลี่ยนแปลงเล็กน้อยในการก่อตัวของแนวเชื่อม ทำให้เป็นวิธีที่มีความน่าเชื่อถือและแม่นยำมากขึ้นสำหรับการประเมินคุณภาพแบบเรียลไทม์ในสายการผลิตแบบอัตโนมัติ (Sim, J. และ Kim, K-Y., 2018) [28]




รูปที่ 2.21 กระบวนการโดยรวมและส่วนประกอบหลักของการตรวจจับขนาดรอยเชื่อมอัตโนมัติ ประกอบด้วยสองขั้นตอน (การควบคุมคุณภาพข้อมูลและการตรวจวัดขนาดรอยเชื่อม) และชุดข้อมูลที่มีการระบุป้ายกำกับและโมเดล CNN [8]

2.3.2 เทคโนโลยีเซ็นเซอร์หลายตัว

ระบบการตรวจสอบกระบวนการเชื่อม RSW แบบดั้งเดิมมักอาศัยการประมาณค่าจากพารามิเตอร์เช่น กระแสไฟฟ้า แรงดันไฟฟ้า และแรงกดจากขั้วไฟฟ้าเป็นตัวบ่งชี้คุณภาพของแนวเชื่อม แม้ว่าการวัดเหล่านี้จะให้ข้อมูลที่จำเป็น แต่ก็มักไม่สามารถจับการเปลี่ยนแปลงในสภาพแวดล้อมของการเชื่อมที่อาจส่งผลกระทบต่อคุณภาพ เช่น ความแปรปรวนของวัสดุหรือการสึกหรอของขั้วไฟฟ้า เทคโนโลยีเซ็นเซอร์หลายตัวจึงเข้ามาช่วยแก้ปัญหานี้ โดยการรวมเซ็นเซอร์หลายชนิด ดังรูปที่ 2.22 ที่มีการใช้เซ็นเซอร์วัดกระแสไฟฟ้า แรงดันไฟฟ้า อินฟราเรด อัลตราโซนิก และการใช้ high speed thermography เป็นเทคนิคที่มีประสิทธิภาพในการเปรียบเทียบเชิงปริมาณระหว่างข้อมูลทดลองและการจำลองอุณหภูมิ ช่วยยืนยันผลการทำนายประวัติอุณหภูมิของแบบจำลอง RSW ได้ (Brizes, E., Jaskowiak, J., Abke, T., Ghassemi-Armaki, H. และ Ramirez, A., 2021) [11] จากการศึกษาของ(Xing, B., Xiao, Y. และ Qin, Q., 2017) [82] ได้ประเมินผลกระทบจากการเบี่ยงเบนกระแสไฟฟ้า (Shunting Effect) ในการเชื่อม RSW โดยใช้สัญญาณการเคลื่อนที่ของอิเล็กโทรดเพื่อ

วิเคราะห์รอยเชื่อมในเหล็กกล้าคาร์บอนต่ำที่มีระยะห่างระหว่างรอยเชื่อมที่แตกต่างกัน โดยเทคโนโลยีเซ็นเซอร์หลายตัวนี้ช่วยเพิ่มความสามารถของระบบในการตรวจจับการเปลี่ยนแปลงในสภาพแวดล้อมแบบเรียลไทม์ โดยการให้สัญญาณเตือนล่วงหน้าเมื่อสภาวะเบี่ยงเบนจากปกติ ตัวอย่างเช่น เซ็นเซอร์อินฟราเรดสามารถตรวจจับการเปลี่ยนแปลงของอุณหภูมิพื้นผิว เซ็นเซอร์อัลตราโซนิกสามารถตรวจจับความผิดปกติภายในแนวเชื่อม และเซ็นเซอร์วัดแรงกดช่วยในการตรวจสอบการสึกหรอของขั้วไฟฟ้าและความไม่สม่ำเสมอของวัสดุ เซ็นเซอร์เหล่านี้รวมกันเพื่อให้การวัดขนาดมีความแม่นยำและสามารถปรับตัวได้สำหรับการประกันคุณภาพ ช่วยให้ผู้ผลิตสามารถรักษามาตรฐานสูงได้แม้ภายใต้สภาวะการผลิตที่แปรผัน จากการวิจัยของ(Daniel, I., Garcia, E., Soret, J. และ Martos, J., 2022) [17] ได้พัฒนาวิธีการตรวจสอบสภาพของความสัมพันธ์ของการแนวของหัวเชื่อม โดยอ้างอิงจากความสัมพันธ์ระหว่างความไม่ตรงกันของหัวเชื่อมและสนามแม่เหล็กที่เกิดขึ้น โดยใช้เครื่องมือวัดสนามแม่เหล็ก และนำเสนอระบบแบบบูรณาการสำหรับการตรวจจับความไม่ตรงกันในสายการผลิตจริง




รูปที่ 2.22 แผนผังเชิงโครงสร้างของเก็บสัญญาณจากการเชื่อม RSW [82]


2.3.3 การวัดด้วยคลื่นเสียง

การตรวจสอบด้วยคลื่นเสียง Acoustic Emission (AE) ใช้การตรวจจับคลื่นความถี่เสียงที่เกิดขึ้นจากการเปลี่ยนแปลงโครงสร้างระหว่างการเชื่อม เช่น การเสียรูปของวัสดุหรือการแตกคลื่นเสียงที่เกิดขึ้นนี้ถูกตรวจจับและวิเคราะห์โดยใช้เซ็นเซอร์ AE ในกระบวนการ RSW คลื่นเสียงจะถูกปล่อยออกมาระหว่างการก่อตัวของแนวเชื่อมและระหว่างการเปลี่ยนแปลงทางโลหะวิทยา โดยมีลักษณะสัญญาณที่แตกต่างกันตามระดับคุณภาพของแนวเชื่อม ดังรูปที่ 2.23 งานวิจัยของ(Polajnar,

I., Grum, J. และ ESMAIL, E., 1999) (Ono, K., 2011) [57,54] พบว่าสัญญาณ AE มีความไวสูงต่อการเปลี่ยนแปลงของพารามิเตอร์การเชื่อม ทำให้การตรวจสอบด้วย AE มีประสิทธิภาพสำหรับการควบคุมคุณภาพแบบเรียลไทม์ โดยการติดตั้งเซนเซอร์ที่หัวเชื่อมดังภาพที่ 2.24 ตัวอย่างเช่น ความแตกต่างของสัญญาณ AE สามารถบ่งบอกถึงความแข็งแรงของวัสดุหรือการเติบโตของแนวเชื่อม ช่วยให้ตรวจจบบริเวณเปราะในกระบวนการได้อย่างรวดเร็ว การวัด AE มีประโยชน์อย่างยิ่งในการตรวจสอบเหล็กที่มีความแข็งแรงสูง ซึ่งสัญญาณคลื่นเสียงช่วยระบุการเปลี่ยนแปลงที่สำคัญในโครงสร้างจุลภาคของโลหะระหว่างการเชื่อม วิธีการตรวจสอบแบบ AE นี้ช่วยให้สามารถตรวจจบบริเวณที่ผิดปกติ เช่น รอยแตกและการหลอมติดไม่สมบูรณ์ได้อย่างรวดเร็ว ทำให้มั่นใจได้ว่าแนวเชื่อมที่มีคุณภาพสูงเท่านั้นจะผ่านเข้าสู่สายการผลิตไปยังกระบวนการถัดไปได้ (Luo, Y., Li, J. และ Wu, W., 2013) [45]




รูปที่ 2.23 สัญญาณ AE หัวไประหว่างการเชื่อม RSW [57]



รูปที่ 2.24 แผนผังการตรวจจับสัญญาณคลื่นยืดหยุ่น (Elastic Wave Signals) [45]

2.3.4 การตรวจสอบกราฟของความต้านทานแบบไดนามิก

การตรวจสอบกราฟความต้านทานแบบไดนามิกได้กลายเป็นตัวบ่งชี้หลักของคุณภาพแนวเชื่อม เนื่องจากมีความสัมพันธ์ใกล้เคียงกับการไหลของกระแสและการสร้างความร้อนในกระบวนการ RSW ในระหว่างการเชื่อม โดยความต้านทานระหว่างวัสดุจะเปลี่ยนแปลงไปตามการก่อตัวของแนวเชื่อม ซึ่งโปรไฟล์ความต้านทานแบบไดนามิกนี้สามารถบอกข้อมูลที่สำคัญเกี่ยวกับคุณภาพของแนวเชื่อมได้ งานวิจัยหลายชิ้นพบว่า ลักษณะของความต้านทานที่เฉพาะเจาะจงสัมพันธ์กับแนวเชื่อมที่แข็งแรงและทนทาน ในขณะที่การเบี่ยงเบนจากลักษณะเหล่านี้มักบ่งชี้ถึงปัญหา เช่น การหลอมติดไม่สมบูรณ์หรือการเกิดโพรงที่มากเกินไป งานเริ่มต้นของ (Gedeon, S., Sorensen, C., Ulrich, K.T. และ Eagar, T., 1987) [26] เป็นผู้บุกเบิกวิธีการจับโปรไฟล์ความต้านทานดังรูปที่ 2.25 ขณะทำการ



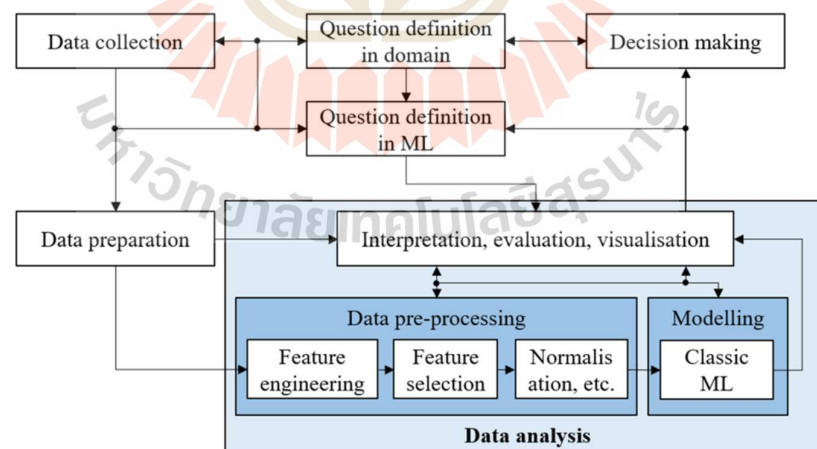
รูปที่ 2.25 การแปลความหมายของกราฟความต้านทานเชิงพลวัตในเชิงทฤษฎี [77]

การศึกษาเพิ่มเติมโดย (El Ouafi, A., Belanger, R. และ Guillot, M., 2012) [23] ได้พัฒนารูปแบบการทำนายคุณภาพแนวเชื่อมแบบเรียลไทม์ การตรวจสอบความต้านทานแบบไดนามิกมีประโยชน์อย่างยิ่งในสภาพแวดล้อมการผลิตความเร็วสูง เนื่องจากให้ข้อมูลย้อนกลับในทันที ทำให้สามารถปรับเปลี่ยนได้อย่างรวดเร็วเพื่อรักษาคุณภาพแนวเชื่อมให้คงที่ ด้วยการใช้อัลกอริทึมขั้นสูงในการวิเคราะห์รูปแบบความต้านทาน ทำให้สามารถระบุและแก้ไขปัญหาได้อย่างมีประสิทธิภาพ ลดความแปรปรวนและเพิ่มความน่าเชื่อถือโดยรวมของกระบวนการผลิต (Garza, F. และ Das, M., 2001) (Xia, Y-J., Liv, T., Ghassemi-Armaki, H., Li, Y. และ Carlson, B., 2023) [25,77]

2.4 Machine Learning Applications in Welding Processes


2.4.1 Artificial Neural Network (ANN)

โครงข่ายประสาทเทียม ANN เป็นโครงสร้างที่พัฒนาขึ้นเพื่อจัดการกับความสัมพันธ์ที่ไม่เป็นเชิงเส้นของข้อมูลในกระบวนการเชื่อม RSW ANN มีความยืดหยุ่นสูงในการจัดการกับข้อมูลที่มีหลายตัวแปรและซับซ้อนดังภาพที่ 2.26 ทำให้สามารถคาดการณ์ตัวชี้วัดคุณภาพของแนวเชื่อม เช่น ขนาดแนวเชื่อม ความสามารถในการทนแรงเค้น และประเภทของข้อบกพร่อง โดย ANN ใช้ข้อมูลที่ผ่านมาในการฝึกอบรมโมเดล เพื่อให้สามารถตรวจจับความแปรผันที่ซับซ้อนในพารามิเตอร์ของกระบวนการที่อาจบ่งชี้ถึงข้อบกพร่องในแนวเชื่อมได้ (Zhou, B., Pychynski, T., Reischl, M., Kharlamov, E. และ Mikut, R., 2022) [86]



รูปที่ 2.26 กระบวนการพื้นฐานของ ML [86]

การศึกษาหลายชิ้นพบว่า ANN มีความสามารถในการสร้างแบบจำลองความสัมพันธ์ที่ซับซ้อนในข้อมูล RSW ซึ่งช่วยให้สามารถตรวจจับปัญหาคุณภาพในกระบวนการเชื่อมได้อย่างแม่นยำ เช่น การคาดการณ์การเกิดรอยแตกหรือการหลอมติดไม่สมบูรณ์ ในแนวเชื่อม ทำให้ ANN เป็นเทคโนโลยีที่มีประสิทธิภาพในการตรวจสอบคุณภาพการเชื่อมในงานที่ต้องการการคาดการณ์แบบเรียลไทม์ (Arunchai, T., Sonthipermpon, K., Apichayakul, P. และ Tamee, K., 2014) [7] ตัวอย่างเช่น งานวิจัยของ (Lee, J., Noh, I., Jeong, S., Lee, Y. และ Lee, S-W., 2020) [42] ได้แสดงให้เห็นว่า ANN สามารถเรียนรู้จากการตรวจสอบและวินิจฉัยออนไลน์แบบเรียลไทม์สำหรับการเยื้องมุมที่ผิดปกติของการเชื่อม RSW ด้วยหุ่นยนต์ ดังรูปที่ 2.27 ซึ่งอาจส่งผลให้คุณภาพของจุดเชื่อมลดลงอย่างมาก เช่น การเกิดรูพรุน การใช้ข้อมูลจำนวนมากจากการติดตั้งเซ็นเซอร์แรงดันไฟฟ้าและกระแสไฟฟ้าเพื่อเก็บข้อมูลที่เกี่ยวข้องมาใช้ในการประมวลผลข้อมูลเหล่านี้ภายใต้เงื่อนไขปกติและผิดปกติของการเชื่อม RSW เพื่อใช้ในการทำนายคุณภาพของระบบการเชื่อม RSW




รูปที่ 2.27 แผนผังการเกิด nugget เนื่องจากการเยื้องศูนย์ [42]

2.4.2 Convolutional Neural Networks (CNN)

โครงข่ายประสาทแบบคอนโวลูชัน (CNN) เป็นโครงสร้างที่ถูกพัฒนาขึ้นเพื่อการประมวลผลข้อมูลแบบหลายมิติ เช่น ภาพและสัญญาณจากเซ็นเซอร์ CNN มีประสิทธิภาพสูงในการจำแนกลักษณะเฉพาะของข้อบกพร่องในกระบวนการเชื่อม RSW โดยทำหน้าที่เป็น “ตัวกรอง” ที่สามารถดึงข้อมูลสำคัญออกจากภาพหรือข้อมูลเซ็นเซอร์เพื่อตรวจจับข้อบกพร่องที่เกิดจากการเชื่อม เช่น การตรวจจ็รอยแตกร้าวหรือการหลอมที่ไม่สมบูรณ์


เพื่อแก้ปัญหาความคลาดเคลื่อนในการตรวจจ็รอยเชื่อมระบบเชื่อมอัตโนมัติของชิ้นงานเชื่อมขนาดใหญ่ในปัจจุบัน ดังภาพที่ 2.28 (Wu, Z., Gao, P., Han, J., Bai, L., Lu, J. และ

Zhao, Z., 2022) [76] ได้นำเสนอแบบจำลองการตรวจจับหลายงาน (Multi-Task Detection Model) ที่ใช้สถาปัตยกรรม CNN โดยแบบจำลองนี้ผสานเทคโนโลยีการแบ่งกลุ่มเชิงความหมาย (Semantic Segmentation) ซึ่งจำเป็นสำหรับการตรวจจับรอยเชื่อมและเทคโนโลยีการตรวจจับขอบ (Edge Detection) ซึ่งจำเป็นสำหรับการตรวจสอบคุณภาพของรอยเชื่อม โดยเฉพาะอย่างยิ่ง เพื่อให้สามารถทำนายรอยเชื่อมได้อย่างราบรื่นยิ่งขึ้น ได้มีการสร้างส่วนหัวแบบใหม่ (Segment Head) ที่ใช้เทคโนโลยี Sub-Pixel Convolution สำหรับการเพิ่มความละเอียด (Up-Sampling) นอกจากนี้ยังได้มีการพัฒนาฟังก์ชันการสูญเสีย (Loss Function) แบบปรับให้เหมาะสมร่วมกัน เพื่อลดปัญหาความไม่สมดุลของการกระจายตัวของข้อมูลในชุดข้อมูลชิ้นงานเชื่อมขนาดใหญ่



รูปที่ 2.28 อุปกรณ์ในระบบและกระบวนการเชื่อม RSW [76]

ในด้านการบำรุงรักษาเชิงป้องกัน CNN มีบทบาทสำคัญในการประเมินอายุการใช้งาน (Remaining Useful Life: RUL) ของเครื่องจักรในระบบอินเทอร์เน็ตของสรรพสิ่งทางอุตสาหกรรม (Industrial Internet of thing: IIoT) โดยทำการรวมข้อมูลจากเซนเซอร์หลายตัว (multi-sensor fusion) เพื่อประมวลผลข้อมูลที่มีความหลากหลาย ซึ่งช่วยให้การประเมินความเสี่ยงและการวินิจฉัยข้อบกพร่องมีความแม่นยำยิ่งขึ้น (Yu, P., Ping, M., Ma, J. และ Cao, J., 2024) [84]




รูปที่ 2.29 แพลตฟอรมการทดลอง PRONOSTIA [84]

โดยสรุป CNN เป็นโครงสร้างที่มีความสามารถสูงในงานประมวลผลและตรวจจับข้อบกพร่องของภาพและข้อมูลแบบหลายมิติ ทำให้เป็นเทคโนโลยีที่เหมาะสมและมีศักยภาพสำหรับการประยุกต์ใช้ในระบบการเชื่อม RSW เพื่อเพิ่มคุณภาพและประสิทธิภาพในการผลิต

2.4.3 โครงข่ายหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory Networks, LSTM)


โครงข่ายหน่วยความจำระยะสั้นแบบยาว (LSTM) เป็นส่วนหนึ่งของโครงข่ายประสาทแบบวนซ้ำ (Recurrent Neural Network: RNN) ที่มีความสามารถพิเศษในการจัดการข้อมูลตามลำดับเวลา โดยเฉพาะอย่างยิ่งสำหรับข้อมูลที่เป็นลำดับของเหตุการณ์ เช่น ข้อมูลจากระบบการเชื่อมแบบเรียลไทม์ ซึ่งมีความสำคัญอย่างมากในระบบการเชื่อม RSW ที่ต้องการตรวจสอบการเปลี่ยนแปลงของพารามิเตอร์แบบเรียลไทม์ เช่น กระแสไฟฟ้าและแรงกดของหัวเชื่อม เพื่อประเมินคุณภาพของรอยเชื่อม ดังรูปที่ 2.30 และคาดเดาผลลัพธ์จากการเปลี่ยนแปลงของพารามิเตอร์ต่างๆ สำหรับตัวถังรถยนต์ โดยใช้ข้อมูลกระแสไฟฟ้าและความต้านทานแบบไดนามิก โดยอ้างอิงกับการผสมผสานระหว่าง CNN, LSTM และกลไกความสนใจ (Attention Mechanism) (Chang, F., Zhou, G., Ding, K., Li, J., Jing, Y., Hui, J. และ Zhang, C., 2023) [12]



รูปที่ 2.30 การจำแนกประเภทคุณภาพของรอยเชื่อม (a) การเชื่อมปกติ, (b) การเชื่อมที่มีการเผาไหม้เกิน, และ (c) การเชื่อมไม่ติด

งานวิจัยที่เกี่ยวข้องชี้ให้เห็นว่า LSTM สามารถแสดงถึงความสัมพันธ์ระหว่างกระแสไฟเชื่อม, อัตราการสร้างความร้อนในทันที (Instantaneous Heat Rate: IHR) และขนาดปลายอิเล็กโทรด ที่ส่งผลต่อคุณภาพของการเชื่อม การจัดประเภทคุณภาพของการเชื่อมและการปรับกระแสไฟเชื่อมที่เหมาะสมโดยใช้แบบจำลองปัญญาประดิษฐ์ที่นำเสนอในงานวิจัยนี้ โดยการออกแบบจำลอง LSTM โดยใช้ปัจจัยนำเข้าหลายอย่างจากเครื่องเชื่อม RSW ที่ใช้ AC Inverter โดยคุณภาพของการเชื่อมขึ้นอยู่กับปัจจัยที่มีผลกระทบหลายอย่าง เช่น รอบเวลาเชื่อม, แรงกด, พื้นที่หน้าตัดของอิเล็กโทรด, กระแสไฟที่ใช้ในการเชื่อม (Vo, T., Tran, D., Nguyen, R., Le, N., Truong, C. และ Tran, T., 2024) [74]

นอกจากนี้ LSTM ยังถูกนำมาใช้ในการคาดการณ์แนวโน้มของคุณภาพการเชื่อมด้วยเลเซอร์ โดยการออกแบบระบบเก็บข้อมูลสำหรับรวบรวมการเปลี่ยนแปลงของลักษณะทางกายภาพระหว่างการเชื่อมด้วยเลเซอร์โดยใช้เซ็นเซอร์หลายตัวดังรูปที่ 2.31 จากข้อมูลที่ได้จากระบบเซ็นเซอร์ได้มีการออกแบบและตรวจสอบแบบจำลองการตรวจจับข้อบกพร่องในการเชื่อมด้วยเลเซอร์ที่มีประสิทธิภาพโดยใช้โครงข่ายประสาทเทียมแบบหลายมาตราส่วน (multiscale convolutional neural network: MSCNN), หน่วยความจำระยะสั้นและยาวแบบสองทิศทาง (bidirectional long short-term memory: BiLSTM) และกลไกความสนใจ (attention mechanism: AM)แบบจำลองการตรวจจับแบบผสม MSCNN-BiLSTM-AM ที่เสนอในขั้นสุดท้ายสามารถบรรลุความแม่นยำในการตรวจจับได้ถึง 99.38% ซึ่งทำให้ระบบการเชื่อมด้วยเลเซอร์มีประสิทธิภาพและเหมาะสมมากยิ่งขึ้น (Peng, P., Fan, K., Fan, X., Zhou, H. และ Guo, Z., 2023) [56]



รูปที่ 2.31 แผนผังการออกแบบการเก็บรวบรวมข้อมูลสำหรับกระบวนการเชื่อมเลเซอร์ [46]

การพัฒนาเทคนิค LSTM ยังรวมถึงการใช้เทคนิคการประมวลผลเพื่อทำนายความน่าจะเป็นของการเกิดการ expulsion สำหรับการเชื่อม RSW ในอนาคต โดยการปรับพารามิเตอร์ขึ้นอยู่กับชุดข้อมูลจริง ซึ่งได้มาจากสภาพแวดล้อมที่ซับซ้อนและเปลี่ยนแปลงได้ของสายการผลิต ซึ่งแตกต่างจากข้อมูลในห้องปฏิบัติการ ทำให้มั่นใจได้ว่าวิธีการที่นำเสนอสามารถจับความสัมพันธ์แบบไม่เชิงเส้น (Non-Linear Dependencies) และรูปแบบในข้อมูลลำดับ (Sequential Data) ได้เนื่องจากโครงสร้างแบบวนซ้ำ (Recurrent Structure) ซึ่งสามารถนำไปใช้ในอุตสาหกรรมได้จริง โดยมีประสิทธิภาพที่ดีที่สุดในทำนายการเกิด expulsion ได้ด้วยความแม่นยำ 95.41% ซึ่งช่วยให้สามารถปรับกระบวนการได้ก่อนที่จะเกิด expulsion ซึ่งช่วยลดการซ่อมแซมชิ้นงาน ลดต้นทุนการผลิตและประหยัดเวลาได้อย่างมีประสิทธิภาพ (Durnagöz, S., Mayer, M. และ Huber, M., 2024) [22] โดยสรุป LSTM เป็นเทคนิคที่มีประสิทธิภาพสูงสำหรับการจัดการและคาดการณ์ข้อมูลอนุกรมเวลาในกระบวนการเชื่อม RSW ช่วยเพิ่มความแม่นยำและประสิทธิภาพในการตรวจสอบคุณภาพของรอยเชื่อม ความสามารถในการทั่วไปของแบบจำลอง (Generalization Ability) มักต่ำเนื่องจากเงื่อนไขที่ซับซ้อนของไซต์การผลิต การศึกษานี้ได้แก้ไขปัญหาดังกล่าวโดยการปรับปรุงวิธีการประมวลผลข้อมูลล่วงหน้า (Data Preprocessing) และการเลือกแบบจำลอง (Model Selection) ผลการทดลองแสดงให้เห็นว่า เมื่อพารามิเตอร์ของกระบวนการไม่เปลี่ยนแปลง ความแม่นยำในการตรวจจับการกระเด็นสามารถมากกว่า 95% ได้อย่างง่ายดาย และเมื่อพารามิเตอร์ของกระบวนการมีการเปลี่ยนแปลง โมเดลยังคงความแม่นยำมากกว่า 90% โดยการเลือกวิธีการประมวลผลข้อมูลล่วงหน้าและการเลือกแบบจำลองที่เหมาะสมรวมถึงการคาดการณ์แนวโน้มและตรวจจับข้อบกพร่องต่าง ๆ ได้อย่างแม่นยำ ทำให้ LSTM เป็นทางเลือกที่เหมาะสมในการนำไปใช้งานในอุตสาหกรรมการผลิตที่ต้องการ


การประมวลผลแบบเรียลไทม์และการจัดการกับข้อมูลที่มีความซับซ้อนสูง (Zhou, L., Zhang, T., Zhang, Z., Zhenglong, L. และ Zhu, S., 2022) [88]

2.4.4 การจำแนกประเภทแบบการสุ่มป่าไม้ (Random Forest Classifier, RFC)

การจำแนกประเภทแบบการสุ่มป่าไม้ (RFC) เป็นเทคนิคการจำแนกประเภทที่ใช้กลุ่มของต้นไม้การตัดสินใจหลายต้นเพื่อเพิ่มความแม่นยำในการพยากรณ์ และลดข้อผิดพลาด ซึ่งทำให้เหมาะสำหรับการใช้งานในกระบวนการเชื่อม RSW เนื่องจากมีความสามารถในการจัดการกับข้อมูลที่มีสัญญาณรบกวนและความไม่สมดุลของข้อมูลได้ดี RFC ได้รับความนิยมเนื่องจากความทนทานต่อข้อมูลที่ซับซ้อน เช่น ข้อมูลที่มีสัญญาณรบกวนและความไม่สมดุลสูงในอุตสาหกรรมการผลิต ซึ่งเป็นลักษณะเฉพาะของข้อมูลที่ใช้ในการประเมินคุณภาพรอยเชื่อม (LeCun, Y., Bengio, Y. และ Hinton, G., 2015) [41]


Random Forest ถูกเสนอให้เป็นเครื่องมือมาตรฐานสำหรับการจำแนกผลลัพธ์ของกราฟอัลตราโซนิกของรอยเชื่อม RSW ผลการศึกษาพบว่าแบบจำลอง CART ให้ค่าความผิดพลาดที่สามารถยอมรับได้พร้อมกับความแม่นยำที่สูง ซึ่งคุณสมบัติเหล่านี้สามารถใช้เพื่อทำความเข้าใจและควบคุมกระบวนการตัดสินใจ ที่ปรับเปลี่ยนได้ตามความสำคัญของกระบวนการอุตสาหกรรม เมื่อเปรียบเทียบแบบจำลอง CART กับแบบ RFC ซึ่งสามารถลดอัตราความผิดพลาดได้ แต่ต้องแลกกับการลดความสามารถในการตีความการตัดสินใจ โดยใช้ค่าความสอดคล้องของป่าจำนวนมาก (agreement of the forest) เป็นตัวชี้วัดเพื่อลดภาระงานของผู้ปฏิบัติงาน ที่จะต้องมุ่งเน้นเฉพาะการวิเคราะห์กราฟอัลตราโซนิกที่ยากต่อแปลความหมายของกราฟเท่านั้น (Martín, Ó., Pereda, M., Santos, J. และ Galán, J. M., 2014) [46]

RFC ยังได้ถูกใช้ในงานทำนายอุณหภูมิของพื้นผิวถนนซึ่งเป็นปัจจัยสำคัญในการประเมินประสิทธิภาพและความสมบูรณ์ของโครงสร้างของพื้นถนนแอสฟัลต์ เนื่องจากพฤติกรรมความยืดหยุ่นของวัสดุ ปัจจุบันการพยากรณ์อุณหภูมิของแอสฟัลต์ใช้วิธีการวิเคราะห์เชิงตัวเลขและเชิงสถิติ ซึ่งต้องอาศัยการสำรวจภาคสนามที่ใช้แรงงานคนและเวลา ทำให้ยากต่อการนำไปใช้ในงาน ML เสนอวิธีการที่มีศักยภาพในการพยากรณ์แบบเรียลไทม์ที่เชื่อถือได้และแม่นยำโดยคำนึงถึงปัจจัยแวดล้อมที่มีการเปลี่ยนแปลง โดยใช้แผนภาพการพยากรณ์แบบกลุ่มดังรูปที่ 2.32 (Yared B.K., Ming-Der Y. และ Chien-Wei H., 2024) [83]



รูปที่ 2.32 แผนผังบล็อกของกรอบการทำนายแบบกลุ่ม [83]

RFC ยังสามารถใช้งานร่วมกับเทคนิคการวิเคราะห์ข้อมูลเชิงลึกอื่น ๆ เช่น (Shapley Additive explanations: SHAP) เพื่อช่วยให้เข้าใจถึงความสำคัญของคุณสมบัติต่าง ๆ ในแบบจำลอง ทำให้สามารถระบุความสัมพันธ์ระหว่างลักษณะของข้อมูลกับผลลัพธ์การพยากรณ์ได้ดีขึ้น ซึ่งช่วยในการเพิ่มความน่าเชื่อถือของผลการพยากรณ์ที่ได้จาก RFC โดยได้มีการดำเนินการตามขั้นตอนต่าง ๆ ได้แก่ การเก็บรวบรวมข้อมูล การประมวลผลสัญญาณ และการสร้างคุณลักษณะ เพื่อสร้างชุดข้อมูลสำหรับการทดสอบ ดังภาพที่ 2.33 โดยใช้แบบจำลองการระบุส่วนประกอบในการระบุสัญญาณของส่วนประกอบที่มีสัญญาณของชิ้นส่วนที่หลวมคลอน และใช้แบบจำลองการระบุวัสดุในการระบุวัสดุของชิ้นงานที่หลวมคลอน กระบวนการลงคะแนนเสียงส่วนใหญ่ (Majority Voting) ถูกนำมาใช้ในการแปลงผลลัพธ์การจัดหมวดหมู่เป็นผลลัพธ์การระบุ เพื่อให้ได้ผลการตรวจจับและการระบุวัสดุของชิ้นงานที่มีหลวมคลอนภายในชิ้นงาน ได้อย่างมีประสิทธิภาพและลดความเสี่ยงของการเกิด Overfitting ในข้อมูลที่มีความซับซ้อน (Sun, Z., Wang, G., Zhai, G., Li, P., Liang, Q. และ Zhang, M., 2024) [71]



รูปที่ 2.33 กระบวนการดำเนินการของวิธีการตรวจจับสัญญาณและการระบุวัสดุ [71]


2.4.5 Extreme Gradient Boosting (XGBoost)

XGBoost เป็นเทคนิคการเพิ่มกำลังในการเรียนรู้แบบถดถอย (Gradient Boosting) ได้รับการยอมรับอย่างกว้างขวางในแอปพลิเคชัน ML เนื่องจากความแม่นยำและประสิทธิภาพสูง โดยเฉพาะอย่างยิ่งในการจัดการข้อมูลขนาดใหญ่และมีคุณสมบัติที่ซับซ้อน เนื่องจากมีความสามารถในการจัดการข้อมูลที่มีมิติสูงซึ่งเป็นลักษณะทั่วไปในกระบวนการเจาะอุโมงค์ที่ต้องคำนึงถึงหลาย ๆ พารามิเตอร์ เช่น กระแสไฟฟ้า เวลา และความแข็งแรงของหิน (Ghorbani, E. และ Yagiz, S., 2024) [29]


ความนิยมของ XGBoost ในการสร้างแบบจำลองการทำนายคุณภาพของ RSW มีผลมาจากความสามารถในการลดปัญหา Overfitting ด้วยการใช้เทอมปกติ (regularization) ซึ่งช่วยให้รักษาความแม่นยำของโมเดลได้ดีแม้ในสภาวะที่มีความแตกต่างของข้อมูลสูง เช่น ในกระบวนการผลิตที่ข้อมูลมักจะมีสัญญาณรบกวน อันเป็นผลมาจากความเปลี่ยนแปลงของวัสดุหรือสภาพแวดล้อม ซึ่งความสามารถในการปรับตัวของ XGBoost นี้จึงมีความสำคัญสำหรับอุตสาหกรรมการผลิตยานยนต์ที่กระบวนการ RSW อาจพบการเปลี่ยนแปลงระหว่างชุดการผลิตได้บ่อยครั้ง

นอกจากนี้ XGBoost ยังถูกใช้ในงานตรวจจับและจำแนกสัญญาณ ซึ่งเหมาะสำหรับการตรวจจับข้อบกพร่องในกระบวนการเชื่อมด้วยคลื่นเสียงความถี่สูง โดยใช้ข้อมูลจากเซนเซอร์ต่างๆ เช่น คลื่นเสียง อุณหภูมิ และกระแสไฟฟ้า การผสมผสานกับข้อมูลจากเซนเซอร์นี้ดังภาพที่ 2.34 ช่วยให้สามารถตรวจจับข้อบกพร่องได้ในเวลาใกล้เคียงกับเรียลไทม์ โดยมีความสามารถในการทำนายข้อบกพร่องเช่น การเกิดรูพรุนหรือรอยร้าวในขณะที่กระบวนการเชื่อมกำลังดำเนินการเชื่อมอยู่

งานวิจัยได้แสดงให้เห็นว่า XGBoost เมื่อปรับแต่งด้วยเทคนิคการเลือกคุณสมบัติแล้ว จะมีประสิทธิภาพดีกว่าโมเดลการเรียนรู้อื่น ๆ เช่น การตัดสินใจจากต้นไม้ (decision tree) หรือ (Support Vector Machine: SVM) ทำให้เป็นทางเลือกที่เหมาะสมสำหรับการทำนายคุณภาพการเชื่อมด้วยคลื่นเสียงความถี่สูง ในสภาพแวดล้อมการผลิตที่ต้องการความเร็วในการตอบสนองและต้องมีการตรวจสอบในกระบวนการผลิตอย่างสม่ำเสมอ ดังภาพที่ 2.35 (Goldman, C., Baltaxe, M., Chakraborty, D., Arinez, J. และ Escobar, C., 2023) [30]



รูปที่ 2.34 การตั้งค่าระบบการเชื่อมด้วยคลื่นอัลตราโซนิก [30]





รูปที่ 2.35 แผนผังเชิงโครงสร้างของตัวตรวจสอบกระบวนการสำหรับการตรวจสอบคุณภาพ [30]

2.5 การสร้างคุณสมบัติและการเตรียมข้อมูลในงานทำนายคุณภาพ RSW

2.5.1 คุณสมบัติสำคัญที่ได้มาจากพารามิเตอร์ของ RSW

คุณสมบัติหลักที่มีผลต่อคุณภาพของ RSW ได้แก่ กระแสเชื่อม, เวลา, แรงกดของหัวเชื่อม และการเคลื่อนที่ของหัวเชื่อม การศึกษาแสดงให้เห็นว่าพารามิเตอร์เหล่านี้สัมพันธ์โดยตรงกับขนาดของรอยเชื่อม ความแข็งแรง และคุณสมบัติเชิงกล ซึ่งทั้งหมดนี้มีผลต่อความสมบูรณ์ของการเชื่อม การตั้งคุณสมบัติที่เกี่ยวข้องจากข้อมูลเซ็นเซอร์ RSW เช่น กระแสและการเคลื่อนที่ของหัวเชื่อม ที่ส่งผลทำให้เกิดความเสียหายดังรูปที่ 2.36 การใช้แบบจำลองเชิงทำนายทำให้สามารถตรวจจับความสัมพันธ์ที่สำคัญซึ่งส่งผลต่อคุณภาพได้ เทคนิคการตั้งคุณสมบัติเหล่านี้มีความสำคัญในการแปลงข้อมูลดิบจากเซ็นเซอร์ให้เป็นข้อมูลที่มีความหมายเพื่อใช้กับอัลกอริทึมได้อย่างมีประสิทธิภาพ (Sivaraj, P., Seeman, M., Kanagarajan d., D.K. และ Seetharaman, R., 2019) [67]


	Photograph of Nugget surface	Macrograph of nugget cross-section	Observation
40			Not welded
45			Welded but defect are present
50			Proper penetration
55			Due to current undercut has been taken place
60			Due to high current metal deformation has been taken place

รูปที่ 2.36 ผลของกระแสไฟฟ้าต่อภาพมาโครกราฟ [67]

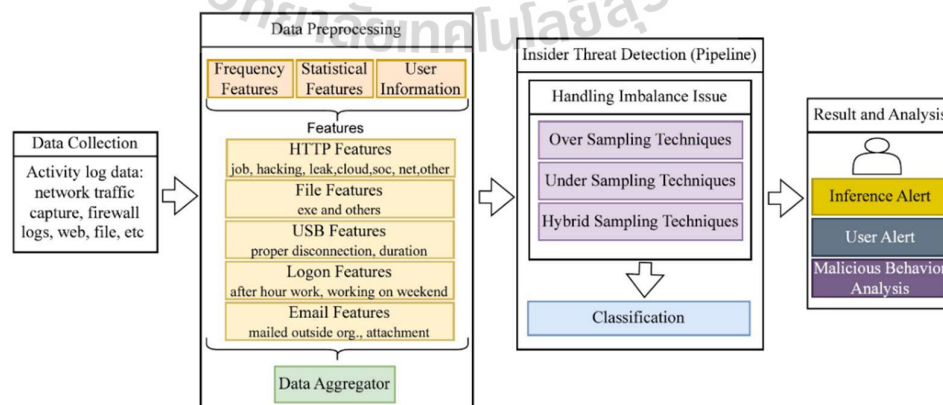
(Sachin K.D., Nilesh D. และ Shyamkumar D.K., 2023) [61] ได้ทำการศึกษาการวิเคราะห์ผลกระทบของพารามิเตอร์สำคัญในกระบวนการเชื่อม RSW ได้แก่ กระแสเชื่อม เวลาเชื่อม และแรงกดของอิเล็กโทรด ที่มีต่อคุณสมบัติของรอยเชื่อม โดยมีการศึกษาพารามิเตอร์อย่างละเอียดเพื่อให้เข้าใจถึงผลกระทบของการเปลี่ยนแปลงพารามิเตอร์ต่อโครงสร้างจุลภาค ขนาดของรอยเชื่อม (nugget) และบริเวณที่ได้รับผลกระทบจากความร้อน (HAZ) ของรอยต่อที่เชื่อมไว้ โดยให้

ความสำคัญกับพารามิเตอร์ในกระบวนการ เช่น กระแสเชื่อม เวลาเชื่อม แรงกดของอิเล็กโทรด และ วัสดุของอิเล็กโทรด มีผลโดยตรงต่อการป้องกันความร้อน วัฏจักรความร้อน และแรงดันที่ใช้ในกระบวนการเชื่อม การปรับพารามิเตอร์เหล่านี้อย่างเหมาะสมสามารถควบคุมการก่อตัวของรอยเชื่อมได้ ซึ่งมีบทบาทสำคัญในการกำหนดความแข็งแรงและความสมบูรณ์ของรอยต่อ นอกจากนี้ การเลือกพารามิเตอร์ที่เหมาะสมยังช่วยลดปัญหาเกี่ยวกับข้อบกพร่องในรอยเชื่อม เช่น การเกิดรูพรุน การแตกร้าว และการเชื่อมไม่ดี

วิธีการดัดคุณสมบัติแบบไฮบริด ซึ่งผสมผสานเทคนิคอย่างการวิเคราะห์องค์ประกอบหลัก (PCA) กับอัลกอริทึมการปรับแต่ง เช่น Grey-Wolf Optimization (GWO) ได้รับการพิสูจน์แล้วว่ามีความสำเร็จในการปรับปรุงชุดคุณสมบัติสำหรับข้อมูลที่ซับซ้อน (Santos, L. และ Ferreira, L., 2023) [62] ด้วยการแยกตัวแปรที่สำคัญและลดสัญญาณรบกวน วิธีการเหล่านี้ช่วยเพิ่มความแม่นยำของแบบจำลองและช่วยให้สามารถตรวจจับสัญญาณที่ซับซ้อนได้ในชุดข้อมูลที่มีหลายมิติ การใช้เทคนิคลดมิติ เช่น PCA จะช่วยลดความซับซ้อนของข้อมูลในขณะที่ยังคงรักษาข้อมูลหลักไว้ นำไปสู่แบบจำลองที่มีประสิทธิภาพและมีความสามารถในการตีความข้อมูลได้ดีขึ้น



รูปที่ 2.37 กรอบแนวคิดของสถาปัตยกรรมในการตรวจสอบคุณภาพของการเชื่อม RSW [62]



รูปที่ 2.38 ภาพรวมของวิธีการที่ใช้ในการปรับแต่งแบบจำลอง [34]


เครื่องมือที่ทันสมัยเช่น Atlantic framework ยังช่วยให้การสร้างคุณสมบัติเป็นไปอย่างมีประสิทธิภาพมากขึ้นโดยการทำให้อัตโนมัติขั้นตอนการเตรียมข้อมูลส่วนใหญ่เป็นไปโดยอัตโนมัติ ดังภาพที่ 2.37 เช่น การเข้ารหัสเวลาวันที่ การแปลงประเภทข้อมูล และการเติมข้อมูลส่วนที่ขาดหาย (Jaiswal, A., Dwivedi, P. และ Dewang, R., 2024) [34] โดยการทำงานแบบอัตโนมัตินี้ช่วยลดความเสี่ยงของข้อผิดพลาดที่เกิดจากมนุษย์และช่วยให้ผู้วิจัยสามารถมุ่งเน้นไปที่การปรับแต่งแบบจำลองมากกว่าการเตรียมข้อมูลที่ซ้ำซ้อนดังภาพที่ 2.38 เครื่องมือเฟรมเวิร์คเหล่านี้สามารถเพิ่มประสิทธิภาพของกระบวนการตรวจสอบความผิดปกติได้โดยทำให้การประมวลผลข้อมูลมีความสม่ำเสมอในแหล่งข้อมูลและรูปแบบต่างๆ ซึ่งช่วยเพิ่มความสามารถในการทำซ้ำและขยายผลในแอปพลิเคชันจริงได้ดียิ่งขึ้น

2.5.2 ความท้าทายด้านการนำข้อมูลการเชื่อม RSW มาใช้งาน


ลักษณะเฉพาะของข้อมูล RSW นำไปสู่ความท้าทายที่อาจซับซ้อนในการสร้างแบบจำลองเชิงทำนาย หนึ่งในความท้าทายหลักคือสัญญาณรบกวนของข้อมูลในเซ็นเซอร์ ซึ่งอาจบิดเบือนรูปแบบที่สำคัญและทำให้แบบจำลองยากต่อการรับรู้ถึงความสัมพันธ์พื้นฐานที่มีผลต่อคุณภาพสัญญาณรบกวนมักเกิดจากปัจจัยภายนอก เช่น การสั่นสะเทือนของเครื่องจักร ความคลาดเคลื่อนของเซ็นเซอร์ และการเปลี่ยนแปลงของสภาพแวดล้อม การใช้เทคนิคการกรองและการปรับเรียบสัญญาณเป็นขั้นตอนการเตรียมข้อมูลที่สำคัญเพื่อช่วยลดผลกระทบของสัญญาณรบกวน และทำให้สัญญาณที่เกี่ยวข้องกับคุณภาพการเชื่อมมีความชัดเจนมากขึ้น

ในอุตสาหกรรมยานยนต์ การเกิดความเสียหายของอุปกรณ์ในการเชื่อม RSW อาจทำให้สายการผลิตหยุดการทำงานโดยไม่ได้วางแผน ซึ่งอาจส่งผลให้สูญเสียกำลังการผลิตและความน่าเชื่อถือในระดับที่มีนัยสำคัญ การคาดการณ์ข้อบกพร่องของเครื่องเชื่อม RSW สามารถช่วยให้มีการพัฒนากลยุทธ์การบำรุงรักษาเชิงคาดการณ์และการตัดสินใจที่มีหลักการมากขึ้น อย่างไรก็ตาม การทำนายข้อบกพร่องของเครื่อง RSW กลายเป็นความท้าทายที่เพิ่มขึ้นเนื่องจากพฤติกรรมที่ซับซ้อนและความแปรปรวนของข้อมูลจากเครื่องเชื่อมเหล่านี้ (Xiaoye, W., Zhang, C. และ Wang, T., 2024) [81] ได้สร้างชุดข้อมูลมาตรฐาน และนำเสนอมาตรฐานการทำนายข้อบกพร่องของเครื่องเชื่อม เพื่อสนับสนุนการพัฒนา ML สำหรับการทำนายข้อบกพร่องของเครื่องเชื่อม RSW โดยชุดข้อมูลถูกเก็บรวบรวมจากส่วน Body-Shop ของ BMW Brilliance Automotive Ltd. จากส่วนประกอบต่าง ๆ ของเครื่องเชื่อม RSW หลายร้อยเครื่อง เพื่อเก็บรวบรวมรูปแบบและแนวโน้มก่อนเกิดข้อผิดพลาดของการเชื่อมด้วยข้อมูลในอดีต อีกทั้งยังได้เสนอมาตรฐาน ML บนวิธีการทำนายแบบอนุกรมเวลาในกรณีศึกษาของการทำนายข้อบกพร่องของเครื่องเชื่อม ดังภาพที่ 2.39 การศึกษานี้จะช่วยให้เข้าใจการทำนายแบบอนุกรมเวลา และเปิดโอกาสให้นักวิจัยด้าน ML สามารถมีส่วนร่วมในการทำนายข้อบกพร่องของเครื่องเชื่อม RSW ได้อย่างมีประสิทธิภาพมากขึ้น

วิธีการสร้างคุณสมบัติที่มีความน่าเชื่อถือซึ่งเน้นไปที่ข้อมูลเซ็นเซอร์ เช่น ในการวิเคราะห์ทางเคมีไฟฟ้า แสดงให้เห็นว่าสามารถปรับปรุงประสิทธิภาพการทำนายได้โดยการเลือกคุณสมบัติที่เฉพาะเจาะจงที่มีผลต่อความแม่นยำในการทำนายและลดสัญญาณรบกวน (Liu, P., Zhao, E., Meng, J., Zhou, X., Liu, C., Tian, H., Li, J., Zhao, X., Zhang, J., Zhao, H. และ Qi, C., 2024) [44] ได้นำเสนอวิธีการที่ช่วยให้แบบจำลองสามารถมุ่งเน้นไปที่คุณสมบัติที่มีผลกระทบสูง เช่น การอ่านค่าจากเซ็นเซอร์หรือค่าที่คำนวณจากการวัดหลายตัวดังภาพที่ 2.40 ซึ่งนำไปสู่การทำนายคุณภาพที่แม่นยำขึ้น ใน RSW การเลือกคุณสมบัติที่ส่งผลโดยตรงต่อคุณภาพการเชื่อมจะช่วยลดความซับซ้อนของแบบจำลองและทำให้การคำนวณเร็วและมีประสิทธิภาพมากขึ้น โดยเฉพาะเมื่อมีการจัดการข้อมูลขนาดใหญ่ การลดมิติ เช่น PCA ช่วยเปิดเผยโครงสร้างที่ซ่อนอยู่ในข้อมูล ทำให้ประสิทธิภาพการทำนายของแบบจำลองสูงขึ้นโดยมุ่งเน้นไปที่ข้อมูลที่มีประโยชน์มากที่สุด



รูปที่ 2.39 a) การรวบรวมข้อมูลจากป็นเชื่อมโยงไปยังระบบคลาวด์ผ่านแพลตฟอร์ม IoT และ b) โครงสร้างภายในและเซ็นเซอร์ในป็นเชื่อม RSW [81]




รูปที่ 2.40 ระบบแบบบูรณาการสำหรับการตรวจสอบในสายการผลิตของการเชื่อม RSW [44]


2.6 เทคโนโลยีเซ็นเซอร์และการเก็บข้อมูลแบบเรียลไทม์สำหรับ RSW

2.6.1 เซ็นเซอร์ที่ใช้ในการจับข้อมูลในกระบวนการ RSW

การเชื่อม RSW ถูกใช้อย่างแพร่หลายในโครงสร้างตัวถังรถยนต์และเป็นปัจจัยสำคัญที่ส่งผลต่อสมรรถนะของรถยนต์ การตรวจจับการเชื่อม RSW แบบอัตโนมัติด้วยการใช้เทคโนโลยีการมองเห็นด้วยเครื่อง (Machine Vision) เป็นวิธีที่มีประสิทธิภาพในการควบคุมคุณภาพการเชื่อมของตัวถังรถยนต์ อย่างไรก็ตาม วิธีการประมวลผลภาพแบบเดิมมักได้รับผลกระทบจากสภาพแวดล้อมและมีความแม่นยำไม่เพียงพอ ดังนั้น (Wei, D., Li, D., Tang, D., Jiang, Q., Wang, D., Wang, H. และ Peng, Y., 2021) [75] จึงได้นำเสนอแบบจำลองเครือข่ายดัดภาพที่ 2.41 สำหรับการตรวจจับวัตถุขนาดเล็ก เพื่อใช้ในการตรวจจับตำแหน่งและคุณภาพของจุดเชื่อมบนตัวถังรถยนต์ ในขณะที่เครื่องวัดกระแสไฟฟ้าช่วยตรวจสอบกระแสไฟฟ้าที่ไหลผ่านในกระบวนการเชื่อม เซ็นเซอร์วัดการเคลื่อนที่ที่ใช้สำหรับวัดการเคลื่อนที่ของขั้วไฟฟ้า ซึ่งสามารถบ่งบอกถึงความสม่ำเสมอของแนวเชื่อมและการก่อตัวของแนวเชื่อม ส่วนเซ็นเซอร์ตรวจจับคลื่นเสียงจะตรวจจับคลื่นเสียงที่เกิดขึ้นในกระบวนการเชื่อม ซึ่งช่วยให้สามารถตรวจจับการเปลี่ยนแปลงของโครงสร้าง เช่น รอยแตกหรือการหลอมไม่ติดได้ การวิเคราะห์ผลการทดลองแสดงให้เห็นการเชื่อมที่เกิดจากพารามิเตอร์การเชื่อมที่แตกต่างกัน ดังภาพที่ 2.42 พบว่าแรงยึดจับ (Clamping Force) และแอมพลิจูดการสั่นสะเทือน (Vibration Amplitude) ไม่มีผลกระทบอย่างมีนัยสำคัญต่อความแข็งแรงของแรงดึง (Tensile Strength) ในขณะที่ระยะเวลาการสั่นสะเทือน (Vibration Time) มีผลกระทบอย่างมีนัยสำคัญต่อความแข็งแรงของแรงดึง นอกจากนี้ การปรับพารามิเตอร์การเชื่อมทั้งหมดสามารถส่งผลกระทบอย่างมีนัยสำคัญต่อความแข็งแรงของแรงดึง (Zhao, D., Ren, D., Zhao, K., Pan, S. และ Guo, X., 2017) [85]




รูปที่ 2.41 กลยุทธ์การเรียนรู้แบบเพิ่มพูน [75]



รูปที่ 2.42 แผนผังโครงสร้างเครือข่าย (Network Topology Diagram) [85]


การศึกษาหลายชั้นแสดงให้เห็นถึงประสิทธิภาพของเซ็นเซอร์เหล่านี้ในการตรวจจับข้อบกพร่องได้ตั้งแต่เนิ่น ๆ เช่น การหลอมไม่ติด การเกิดโพรง และรอยแตก ตัวอย่างเช่น การใช้เทอร์โมคัปเปิลร่วมกับเซ็นเซอร์ตรวจจับคลื่นเสียงสามารถตรวจจับความผิดปกติของอุณหภูมิและการเปลี่ยนแปลงโครงสร้างที่บ่งชี้ถึงการเกิดข้อบกพร่องได้ ซึ่งช่วยเพิ่มคุณภาพในกระบวนการเชื่อม นอกจากนี้วิธีการรวมข้อมูลจากเซ็นเซอร์หลายตัวได้แสดงให้เห็นถึงความน่าเชื่อถือและความแม่นยำที่เพิ่มขึ้นในการตรวจสอบแบบเรียลไทม์ โดยการรวมข้อมูลจากเซ็นเซอร์หลายประเภท เช่น อุณหภูมิ กระแสไฟฟ้า และการเคลื่อนที่ของหัวเชื่อม ระบบการผสมผสานข้อมูลเซ็นเซอร์สามารถตรวจจับการเบี่ยงเบนเล็กน้อยได้อย่างมีประสิทธิภาพ โดยได้ทำการทดลองดังภาพที่ 2.43 ซึ่งช่วยให้สามารถทำนายและปรับปรุงกระบวนการได้ทันที (Kim, S., Hwang, I., Kim, D-Y., Kim, Y-M., Kang, M. และ Yu, J., 2021) [38]



รูปที่ 2.43 การจัดเตรียมการทดลอง (a) ระบบการเชื่อม RSW ที่รวมเซ็นเซอร์ (b) แผนผังเชิงโครงสร้างของระบบตรวจสอบสำหรับกระบวนการเชื่อม RSW [38]

2.6.2 ระบบการเก็บข้อมูลและความท้าทายในการตรวจสอบแบบเรียลไทม์

การนำระบบการเก็บข้อมูลและการตรวจสอบแบบเรียลไทม์มาใช้ในกระบวนการ RSW ต้องเผชิญกับความท้าทายหลายประการ เช่น การจัดเก็บข้อมูล ความเร็วในการประมวลผล และการผสมรวมกับโมเดลการเรียนรู้ของเครื่อง การตรวจสอบแบบเรียลไทม์จำเป็นต้องมีการเก็บข้อมูลและการประมวลผลอย่างรวดเร็วเพื่อให้สามารถปรับเปลี่ยนพารามิเตอร์การเชื่อมได้อย่างทันเวลา ระบบเหล่านี้ต้องจัดการข้อมูลจำนวนมากที่เกิดจากเซ็นเซอร์หลายตัวโดยรักษาระดับความแม่นยำสูง ซึ่งมักต้องใช้ความสามารถในการคำนวณที่รวดเร็วและมีประสิทธิภาพ อีกทั้งระบบการเก็บข้อมูลใน RSW ยังต้องสามารถกรองและเตรียมข้อมูลเบื้องต้นที่ได้รับมาแบบเรียลไทม์เพื่อลดสัญญาณรบกวนและเพิ่มคุณภาพของข้อมูลสำหรับการสร้างแบบจำลองในการทำนาย อีกทั้งการผสมโมเดลการเรียนรู้ของเครื่องเข้ากับระบบการตรวจสอบแบบเรียลไทม์ยังสร้างความซับซ้อนดังภาพที่ 2.44 เช่น ปัญหาความล่าช้าในการทำนายและความต้องการในการอัปเดตโมเดลอย่างสม่ำเสมอ โมเดลการเรียนรู้ของเครื่องต้องการการเข้าถึงข้อมูลแบบเรียลไทม์ที่มีคุณภาพสูงเพื่อให้สามารถทำนายได้อย่างแม่นยำและยังสามารถควบคุมกระบวนการเชิงปรับตัวได้ ระบบการเก็บข้อมูลขั้นสูงจึงตอบสนองความต้องการเหล่านี้โดยใช้ตัวประมวลผลความเร็วสูงและวิธีการจัดเก็บข้อมูลที่สามารถขยายขนาดได้ ซึ่งช่วยให้สามารถตรวจสอบได้อย่างต่อเนื่องและตอบสนองต่อการเบี่ยงเบนที่ตรวจพบในกระบวนการเชื่อมได้อย่างรวดเร็ว (Kim, D.H., Lee, B-Y., Min, S., Joe, D., An, J., Kim, B., Park, Y., Kang, S., Hwang, G. และ Lee, J., 2022) [37]



รูปที่ 2.44 (a) ภาพประกอบเชิงโครงสร้างของแนวคิดโดยรวมสำหรับระบบเก็บเกี่ยวพลังงานแม่เหล็ก DC แบบพัลส์ และหุ่นยนต์เชื่อมในโรงงานอัจฉริยะสำหรับยานยนต์ และภาพถ่ายกระบวนการเชื่อมยานยนต์ในโรงงานผลิตจริง (b) แผนผังเชิงโครงสร้างของตัวกำเนิดพลังงาน MME (c) กลไกของการเก็บเกี่ยวพลังงานสนามแม่เหล็ก DC แบบพัลส์ระหว่างการเชื่อม RSW (d) ผลการวิเคราะห์ XRD ของฟิล์มหนา PZT โดยแทรกแสดงสเปกตรัมรามานที่สังเกตจากฟิล์มหนา PZT (e) คุณสมบัติไดอิเล็กตริกของฟิล์มหนา PZT โครงสร้าง MIM เป็นฟังก์ชันของความถี่ โดยแทรกแสดงกราฟลูบฮิสเทอรีซิสของสนามไฟฟ้า-โพลาริซ (P-E) ของฟิล์มหนา PZT [37]

2.7 เทคนิคการตรวจสอบความถูกต้องของโมเดลในโมเดลการทำนายคุณภาพ

ในโมเดลการทำนายคุณภาพ เทคนิคการตรวจสอบความถูกต้องเป็นสิ่งสำคัญอย่างยิ่งในการประเมินความน่าเชื่อถือและความสามารถในการทั่วไปของโมเดลกับชุดข้อมูลที่แตกต่างกัน ซึ่งมี

ความสำคัญต่อการนำโมเดลไปใช้งานจริงในสภาพแวดล้อมการผลิต เช่น ในกระบวนการ RSW เทคนิคที่ใช้ในการตรวจสอบที่ใช้บ่อย ได้แก่ การตรวจสอบแบบ Cross-Validation และการแบ่งชุดข้อมูลแบบ Train-Test ซึ่งช่วยลดความเสี่ยงในการเกิดปัญหา Overfitting และเพิ่มความสามารถของโมเดลในการทำนายข้อมูลใหม่ การตรวจสอบแบบ Cross-Validation โดยเฉพาะการแบ่งข้อมูลแบบ k-fold เป็นการแบ่งชุดข้อมูลออกเป็น k ส่วน แล้วสลับกันใช้ k-1 ส่วนในการฝึกและส่วนที่เหลือในการทดสอบ ซึ่งไม่เพียงแต่ให้การประเมินที่แข็งแกร่งขึ้นโดยให้โมเดลได้เจอกับหลายชุดข้อมูล แต่ยังช่วยลดความเอนเอียงของการประเมินที่อาจเกิดจากการแบ่งชุดข้อมูลเพียงครั้งเดียว (Bansal, P., Zheng, Z., Shao, C., Li, J., Banu, M., Carlson, B. และ Li, Y., 2022) [8]

การศึกษาหลายชิ้นเน้นถึงความสำคัญของการรักษาสมาดุลระหว่างความแม่นยำของโมเดลกับการป้องกันการเกิด Overfitting โดยเฉพาะในด้านการผลิตที่ต้องการให้โมเดลการทำนายคุณภาพมีความยืดหยุ่นต่อการเปลี่ยนแปลงของข้อมูลอินพุต ตัวอย่างเช่น การตรวจสอบแบบ (Leave-One-Out Cross-Validation: LOOCV) ซึ่งเป็นรูปแบบของ k-fold ที่มีค่า k เท่ากับจำนวนตัวอย่างข้อมูลทั้งหมด นิยมใช้ในกรณีที่มีชุดข้อมูลขนาดเล็กเพื่อเพิ่มจำนวนข้อมูลฝึกฝนและยังคงให้การประเมินที่เข้มงวด นอกจากนี้การตรวจสอบแบบ Stratified k-fold มักนิยมใช้ในงานที่ต้องการจำแนกประเภทเพื่อให้แต่ละส่วนมีสัดส่วนของประเภทที่ใกล้เคียงกัน ซึ่งมีความสำคัญในงานตรวจจับข้อบกพร่องที่อาจมีความไม่สมดุลของประเภทข้อมูล (Amiri, N., Farrahi, G., Reza, K. และ Chizari, M., 2020) [5]

ในการประเมินประสิทธิภาพของโมเดล ตัวชี้วัดต่าง ๆ มักมีเป้าหมายเฉพาะของการทำนายคุณภาพ ตัวอย่างเช่น ในงานจำแนกประเภทจะใช้ตัวชี้วัด เช่น ความแม่นยำ (Accuracy), ความแม่นยำตรง (Precision), ความไวในการตรวจจับข้อบกพร่อง (Recall) และค่า F1-score ซึ่งตัวชี้วัดเหล่านี้ช่วยประเมินความสามารถของโมเดลในการตรวจจับข้อบกพร่องได้อย่างถูกต้อง Precision แสดงถึงความถูกต้องของความแม่นยำตรง ซึ่งเป็นส่วนสำคัญในการผลิต RSW เพื่อหลีกเลี่ยงการแจ้งเตือนที่ผิดพลาด ขณะที่ Recall แสดงถึงความสามารถในการตรวจจับข้อบกพร่องที่แท้จริง ซึ่งสำคัญในการป้องกันไม่ให้ข้อบกพร่องหลุดผ่านการตรวจสอบ F1-score ซึ่งเป็นค่าเฉลี่ยเชิงฮาร์โมนิกระหว่าง Precision และ Recall ช่วยให้ได้ค่าที่สมดุลเมื่อทั้งสองปัจจัยมีความสำคัญพอ ๆ กัน

สำหรับงานที่ต้องการทำนายค่าแบบต่อเนื่อง เช่น ขนาดของรอยเชื่อมหรือความสามารถในการทนแรงดึงใน RSW ตัวชี้วัดที่ใช้ได้แก่ค่า (Mean Absolute Error: MAE) และ (Root Mean Square Error: RMSE) ซึ่ง MAE เป็นตัววัดความผิดพลาดเฉลี่ยที่เข้าใจง่าย โดยคำนวณจากความแตกต่างเฉลี่ยแบบสัมบูรณ์ระหว่างค่าที่ทำนายกับค่าจริง ซึ่งมีประโยชน์ในงานที่ต้องการความแม่นยำของการทำนายค่าต่อเนื่อง RMSE ที่เน้นการตรวจสอบความผิดพลาดที่มีขนาดใหญ่เหมาะสำหรับงานที่ต้องหลีกเลี่ยงการเบี่ยงเบนจากค่าที่คาดหวังอย่างมาก ในงาน RSW การลดค่า MAE และ RMSE

ช่วยให้สามารถควบคุมขนาดของแนวเชื่อมและความสามารถในการทนแรงดึงได้อย่างแม่นยำ ซึ่งมีผลต่อคุณภาพแนวเชื่อมและความทนทานของผลิตภัณฑ์ (Chen, C. และ Chen, S., 2020) [13]


สรุปได้ว่าการเลือกใช้เทคนิคการตรวจสอบความถูกต้องและตัวชี้วัดที่เหมาะสมเป็นสิ่งสำคัญในการพัฒนาโมเดลทำนายคุณภาพสำหรับ RSW โดยการผสมผสานเทคนิคการตรวจสอบ เช่น Cross-Validation และ Train-Test Split ร่วมกับตัวชี้วัดอย่าง Accuracy, F1-score, MAE และ RMSE ช่วยให้ได้กรอบการประเมินที่ครอบคลุม ซึ่งเพิ่มความน่าเชื่อถือและความแม่นยำในการทำนายของโมเดล ทำให้โมเดลสามารถนำไปใช้ได้อย่างมีประสิทธิภาพในสถานการณ์จริงที่ต้องการความสม่ำเสมอของคุณภาพและการลดข้อบกพร่องให้น้อยที่สุด

2.8 การเปรียบเทียบโมเดล ML สำหรับการทำนายคุณภาพ RSW

RSW ถูกนำมาใช้กันอย่างแพร่หลายในกระบวนการผลิตโครงสร้างรถยนต์ โดยมีคุณสมบัติเด่นคือความน่าเชื่อถือและการทำงานอัตโนมัติที่ง่ายในการใช้งานในสายการผลิต อย่างไรก็ตาม การตรวจจ็บรอยเชื่อมที่มีข้อบกพร่องเป็นงานที่ท้าทาย ซึ่งมักต้องใช้วิธีการทดสอบแบบ DT หรือวิธีการทดสอบแบบ NDT ที่มีราคาแพงและช้า เช่น การตรวจสอบด้วย UT ซึ่งในกระบวนการผลิตปัจจุบันหุ่นยนต์ที่ทำการเชื่อมจะรวบรวมข้อมูลของกระบวนการโดยอัตโนมัติ (Ciravegna, G., Galante, F., Giordano, D., Cerquitelli, T. และ Mellia, M., 2024) [15] ได้ทำการศึกษาและทดสอบว่าข้อมูลเหล่านี้สามารถนำมาใช้เพื่อทำนายรอยเชื่อมที่มีข้อบกพร่องได้หรือไม่ โดยใช้ชุดข้อมูลที่เก็บรวบรวมจากโรงงานอุตสาหกรรมจริง ซึ่งข้อมูลดังกล่าวเกี่ยวข้องกับการเชื่อมและมีการระบุคุณภาพโดยการตรวจสอบด้วยคลื่นเสียงความถี่สูง

เราได้ใช้ข้อมูลเหล่านี้ในการพัฒนา Pipeline หลายรูปแบบ ดังภาพที่ 2.45 โดยใช้ทั้งอัลกอริทึมการเรียนรู้ของเครื่องแบบตื้น (Shallow Learning) และ DL รวมถึงการทดสอบประสิทธิภาพของ Pipeline เหล่านี้ในการทำนายรอยเชื่อมที่มีข้อบกพร่อง ผลการทดลองแสดงให้เห็นว่า แม้จะมีการพัฒนา Pipeline ที่หลากหลายและโมเดลที่ซับซ้อน แต่ประสิทธิภาพของอัลกอริทึมการตรวจจ็บข้อบกพร่องโดยใช้การเรียนรู้ของเครื่องยังคงมีข้อจำกัด

ในช่วงไม่กี่ปีที่ผ่านมา มีการประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่องต่าง ๆ อย่างกว้างขวางสำหรับการทำนายคุณภาพในการเชื่อม RSW โมเดลที่ได้รับการเปรียบเทียบบ่อย ๆ ได้แก่ ANN, CNN, LSTM, Random Forests และ XGBoost ซึ่งแต่ละโมเดลมีข้อดีที่แตกต่างกันในด้านความแม่นยำ ความสามารถในการตีความผล และประสิทธิภาพในการประมวลผล โมเดลเหล่านี้ถูกเลือกใช้งานตามความซับซ้อนของชุดข้อมูลและความต้องการเฉพาะของการใช้งาน เช่น ความสามารถในการทำนายแบบเรียลไทม์หรือความสะดวกในการปรับใช้ในสภาพแวดล้อมการผลิต




รูปที่ 2.45 ประเภทต่าง ๆ ของกระบวนการ ML ที่นำมาใช้ (A) ตัวจำแนกที่ทำงานกับข้อมูลแบบสแตติก, (B) โมเดล Time-series ที่สังเกตซีรีส์เวลาโดยตรง, (C) โมเดลแบบกลุ่ม (Ensemble model)

(Mezher, M., Pereira, A., Shakir, R. และ Trzepieciński, T., 2024) [48] ได้มีการดำเนินการวิจัยอย่างเป็นระบบเพื่อเปรียบเทียบประสิทธิภาพระหว่าง แบบจำลองการถดถอย (Regression Model) และ ANN ในการทำนายขนาดเส้นผ่านศูนย์กลางของรอยเชื่อม (Nugget) ในการเชื่อม RSW โดยการตรวจสอบสัญญาณกำลังไฟฟ้าแบบไดนามิกที่เกิดขึ้นระหว่างกระบวนการเชื่อม วัสดุที่ใช้ในการเชื่อมคือไทเทเนียมอัลลอย TC2 ที่มีความหนา 0.4 มม. และใช้เครื่องเชื่อม RSW ความถี่สูงที่มีความแม่นยำสูงในการเชื่อมแผ่นไทเทเนียมอัลลอยเข้าด้วยกัน

ในระหว่างกระบวนการเชื่อม ข้อมูลกระแสไฟฟ้าแบบไดนามิก ดังภาพที่ 2.46 ถูกตรวจวัดโดยใช้คอยล์ Rogowski เพื่อวัดดันไฟฟ้าระหว่างสายสองเส้นที่อยู่กับขั้วอิเล็กโทรดบนและล่าง การเปลี่ยนแปลงของสัญญาณกำลังไฟฟ้าระหว่างกระบวนการเชื่อมถูกตรวจสอบ และลักษณะของสัญญาณกำลังไฟฟ้าสำหรับกระแสไฟฟ้าและแรงกดของอิเล็กโทรดที่แตกต่างกันได้รับการวิเคราะห์

ผลการวิจัยพบว่าสัญญาณกำลังไฟฟ้าของแนวเชื่อมชนิดต่าง ๆ มีความแตกต่างกันอย่างมีนัยสำคัญ จึงได้มีการสกัดคุณลักษณะสำคัญ 5 ประการจากสัญญาณกำลังไฟฟ้าเพื่อนำมาอธิบายรูปร่างของกราฟ นอกจากนี้ การวิเคราะห์แบบถดถอยเชิงขั้นตอน (Stepwise Regression Analysis) และโครงข่ายประสาทเทียมแบบการถอยกลับ (Back Propagation Neural Network) ถูกนำมาใช้เพื่อจำแนกแนวเชื่อมออกเป็น 3 ประเภท ได้แก่ แนวเชื่อมที่ไม่ดี (Bad Welds) แนวเชื่อมที่ดี (Good Welds) และแนวเชื่อมที่เกิดการกระเด็น (Welds with Expulsion)




รูปที่ 2.46 สัญญาณพลังงานการเชื่อมสำหรับคุณภาพการเชื่อมทั้งสามแบบ [48]

ในปัจจุบัน RSW ยังคงพึ่งพาการตรวจสอบคุณภาพรูปลักษณะด้วยคนเพื่อแยกผลิตภัณฑ์ที่ไม่ได้มาตรฐานออกจากกระบวนการ ซึ่งนำไปสู่ประสิทธิภาพการตรวจจับที่ต่ำและอัตราความผิดพลาดที่สูง ดังภาพที่ 2.47 เพื่อตอบสนองต่อปัญหานี้ บทความนี้ได้นำเสนอวิธีการออกแบบแบบโมดูลาร์ (Modular Design Method) และเสนอ บล็อกการประกอบแบบคอนโวลูชันหลายสเกล (Multiscale Convolution Assemble Block) ซึ่งสามารถแยกความแตกต่างระหว่างจุดเชื่อมที่มีลักษณะคล้ายกันได้อย่างมีประสิทธิภาพ



รูปที่ 2.47 หมวดหมู่ของภาพลักษณะรอยเชื่อม RSW [79]

จากนั้นได้มีการออกแบบ Dual-Use Attention Block เพื่อปรับข้อมูลเชิงพื้นที่ และ ช่องสัญญาณ (Spatial and Channel Information) ของแผนที่คุณลักษณะ (Feature Maps) ของจุดเชื่อม เพื่อให้โมเดลสามารถมุ่งเน้นไปที่คุณลักษณะที่เกี่ยวข้องของจุดเชื่อมได้มากขึ้น โดยบล็อก Multiscale เหล่านี้ที่รวมกับกลไก Attention ถูกนำมาซ้อนกันเพื่อสร้างโครงสร้างหลักของ CNN สำหรับการจดจำรูปลักษณะของจุดเชื่อม อีกทั้งยังมีการใช้วิธี De-Pooling และ Feature Fusion เพื่อปรับปรุงประสิทธิภาพการคำนวณและความแม่นยำเพิ่มเติม โดยโมเดลนี้ถูกตั้งชื่อว่า AcmNet ดังรูปที่ 2.48 ซึ่งแสดงให้เห็นว่า กลยุทธ์ที่เสนอมีประสิทธิภาพ และ AcmNet มีความแม่นยำสูงถึง 95.2% ซึ่งสูงกว่าโมเดลที่มีอยู่ในปัจจุบัน และเหมาะสมอย่างยิ่งสำหรับสายการผลิตตัวถังรถยนต์



รูปที่ 2.48 การระบุและจดจำลักษณะรอยเชื่อม RSW โดยใช้ AcmNet [70]

ในทางตรงกันข้าม โมเดลที่ง่ายกว่า เช่น Decision Trees และ SVM มีความสามารถในการตีความผลได้ดีกว่า ทำให้ผู้ใช้งานสามารถเข้าใจเส้นทางการตัดสินใจและความสำคัญของข้อมูลอินพุตได้โดยตรง RFC ซึ่งเป็นการรวมกลุ่มของ Decision Trees ช่วยสร้างสมดุลระหว่างความแม่นยำและความสามารถในการทำนายผล โดยสามารถจับความสัมพันธ์แบบไม่เป็นเชิงเส้นได้โดยไม่ต้องใช้การประมวลผลสูงเหมือนโมเดลการเรียนรู้เชิงลึก การศึกษาหลายชิ้นพบว่า RFC มีประสิทธิภาพในการจำแนกข้อบกพร่องโดยอิงตามพารามิเตอร์หลักของกระบวนการ เช่น กระแสไฟฟ้า แรงกดที่ขึ้นงาน และการเคลื่อนที่ของหัวไฟฟ้า พร้อมทั้งมีความต้องการในการประมวลผลที่เหมาะสมสำหรับการใช้งานแบบเรียลไทม์ [5]

XGBoost ซึ่งเป็นอีกหนึ่งวิธีการเรียนรู้แบบกลุ่ม ได้รับความสนใจเนื่องจากความแม่นยำและประสิทธิภาพสูง ด้วยอัลกอริทึมที่ใช้การเสริมด้วยกราดีเอนต์ XGBoost ซึ่งสามารถทำงานได้ดีทั้งกับ

ข้อมูลที่มีโครงสร้างและข้อมูลแบบลำดับเวลาจากกระบวนการ RSW ซึ่งให้พลังการทำนายที่มีประสิทธิภาพพร้อมความสามารถในการตีความปานกลาง XGBoost มีประสิทธิภาพสูงเมื่อทำงานกับชุดข้อมูลที่มีมิติสูง โดยสามารถทำนายข้อบกพร่องได้อย่างแม่นยำภายใต้ Precision และ Recall ทำให้มีคุณภาพสำหรับงานที่ต้องการลดข้อผิดพลาดทั้งบวกเท็จและลบเท็จให้เหลือน้อยที่สุด [37]

(Zhou, B., Pychynski, T., Reischl, M. และ Mikut, R., 2018) [87] แสดงให้เห็นว่าแม้กระทั่งวิธีการสร้างแบบจำลองที่เรียบง่ายที่สุด เช่น การถดถอยเชิงเส้น (Linear Regression) ก็สามารถเพิ่มความสามารถในการทำนายได้อย่างมีนัยสำคัญเมื่อมีการออกแบบคุณลักษณะอย่างชาญฉลาด นอกจากนี้ ความโปร่งใสของกระบวนการสร้างคุณลักษณะยังช่วยให้สามารถตีความผลลัพธ์ของ ML เพื่อให้ได้ข้อมูลเชิงลึกทางวิศวกรรม ในทางกลับกัน หากทำการฝึก ML แบบสุ่มโดยไม่พิจารณาคุณลักษณะที่ถูกเลือกอาจไม่น่าเชื่อถือและมีความเสถียรน้อย


ประสิทธิภาพของโมเดลเหล่านี้ขึ้นอยู่กับคุณภาพของข้อมูลและความซับซ้อนของคุณสมบัติ โดยโมเดลการเรียนรู้เชิงลึกถึงแม้จะมีความแม่นยำสูง แต่ต้องการชุดข้อมูลขนาดใหญ่และทรัพยากรการประมวลผลที่สูงเพื่อฝึกฝนได้อย่างมีประสิทธิภาพ ซึ่งเป็นข้อจำกัดในสภาพแวดล้อมการผลิตที่ต้องการการประมวลผลรวดเร็วและการทำนายแบบเรียลไทม์ ดังภาพที่ 2.49 ในขณะที่โมเดลที่ง่ายกว่า เช่น Decision Trees และ SVM ถึงแม้จะมีความแม่นยำน้อยกว่าสำหรับชุดข้อมูลที่ซับซ้อน แต่มีการประมวลผลที่รวดเร็วกว่าและสามารถผสานเข้ากับระบบที่มีอยู่ได้ง่าย ซึ่งเป็นข้อได้เปรียบในการตรวจสอบคุณภาพแบบเรียลไทม์ในสภาพการผลิตปริมาณสูง (Zhou, B & Pychynski, T & Reischl, Ma., Kharlamov, E. และ Mikut, R., 2022)(Komenda, T., Brandstötter, M., Gharagyozyan, T., Pichler, A. และ Liemberger, W., 2022) [58,39] โดยสรุป การเลือกใช้โมเดลสำหรับการทำนายคุณภาพ RSW ขึ้นอยู่กับการตัดสินใจเลือกอย่างใดอย่างหนึ่งระหว่างความแม่นยำ ความสามารถในการทำนาย และประสิทธิภาพในการประมวลผล โมเดล ANN และ CNN มีความแม่นยำสูง โดยเฉพาะเมื่อใช้กับชุดข้อมูลที่ซับซ้อนและมีมิติสูง ในขณะที่โมเดลอย่าง LSTM, RFC และ XGBoost เสนอทางเลือกที่มีความสามารถในการตีความผลและประสิทธิภาพสูงกว่า สำหรับการใช้งานใน RSW ที่การทำนายคุณภาพเป็นสิ่งสำคัญ การใช้แนวทางแบบผสมที่ผสานการเรียนรู้เชิงลึกเพื่อความแม่นยำร่วมกับโมเดลที่ง่ายกว่าเพื่อการตีความผลอาจเป็นทางเลือกที่ดีที่สุดในการใช้งานในสภาพแวดล้อมการผลิต



รูปที่ 2.49 กระบวนการทำงานของการเชื่อมพร้อมการทำนายคุณภาพ [58]

2.9 ความท้าทายและข้อจำกัดในการประยุกต์ใช้โมเดล ML ในอุตสาหกรรมการผลิตยานยนต์


ความต้องการเครื่องมือที่ช่วยสนับสนุนการตัดสินใจในอุตสาหกรรมการผลิตกำลังเติบโตอย่างต่อเนื่อง การวิเคราะห์ที่ดำเนินการโดยเครื่องมือเหล่านี้จะช่วยให้ผู้ปฏิบัติงานและวิศวกรเข้าใจพฤติกรรมของกระบวนการผลิตได้ดียิ่งขึ้น และสามารถตัดสินใจบนพื้นฐานข้อมูลเพื่อปรับปรุงกระบวนการผลิตได้ เครื่องมือเหล่านี้ใช้เทคนิคที่ได้รับมาจากส่วนต่างๆ เช่น การวิเคราะห์ข้อมูล (Data Analytics), Big Data, การสร้างแบบจำลองเชิงพยากรณ์ (Predictive Modelling) และ ML อย่างไรก็ตาม เพื่อให้สามารถใช้เครื่องมือเหล่านี้ได้อย่างมีประสิทธิภาพ จำเป็นต้องมีข้อมูลจากพื้นโรงงานเป็นข้อมูลนำเข้า ข้อมูลนี้ได้ถูกสกัดมาจากสองแหล่งหลักๆ คือ PLCs และหุ่นยนต์ ในทางปฏิบัติ วิธีการสกัดข้อมูลที่ใช้งานได้จากหุ่นยนต์ยังคงค่อนข้างมีอยู่อย่างจำกัด (Farooqui, A., Bengtsson, K., Falkman, P. และ Fabian, M., 2018) [24] ได้นำเสนอแนวทางในการเก็บข้อมูลจากหุ่นยนต์ ซึ่งสามารถนำไปใช้ได้ทั้งในระบบการผลิตแบบเดิมและระบบที่ทันสมัย โดยแนวทางที่นำเสนอถูกพัฒนาขึ้นโดยใช้ Sequence Planner ดังภาพที่ 2.50 ซึ่งเป็นเครื่องมือสำหรับการสร้างแบบจำลองและการวิเคราะห์ระบบการผลิต และในปัจจุบันได้นำไปทดลองใช้ในบริษัทผู้ผลิตรถยนต์เป็นโครงการนำร่องสำหรับการแสดงผลและตรวจสอบกระบวนการที่กำลังดำเนินการอยู่ ด้วยการใช้โครงสร้างโค้ดของหุ่นยนต์ การกระทำของหุ่นยนต์จะถูกแปลงเป็นกระแสเหตุการณ์ที่ถูกย่อให้เป็นการดำเนินการ (operations) จากนั้นแสดงให้เห็นถึงการใช้งานของการดำเนินการเหล่านี้โดยการแสดงกระบวนการที่กำลังดำเนินอยู่ในรูปแบบแผนภูมิ Gantt แบบเรียลไทม์ ซึ่งช่วยสนับสนุนผู้ปฏิบัติงานในการบำรุงรักษา และข้อมูลยังถูกวิเคราะห์แบบออฟไลน์โดยใช้เทคนิคการทำเหมืองกระบวนการ (Process Mining) เพื่อสร้างแบบจำลองทั่วไปที่อธิบายพฤติกรรมพื้นฐานที่มีอยู่ในกระบวนการผลิต




รูปที่ 2.50 ภาพรวมทางสถาปัตยกรรมของกระบวนการจัดการเหตุการณ์ของหุ่นยนต์และส่วนประกอบการทำงานของระบบ [24]

อีกหนึ่งความท้าทายสำคัญคือเพิ่มการใช้งาน แม้ว่าโมเดลการเรียนรู้ของเครื่องจะทำงานได้ดีในสภาพแวดล้อมที่มีการควบคุมดังรูปที่ 2.51 การขยายการใช้งานเหล่านี้ไปยังสายการผลิตที่หลากหลายมักทำให้เกิดความแปรปรวนที่มีผลต่อความน่าเชื่อถือของโมเดล ตัวอย่างเช่น ปัจจัยต่าง ๆ เช่น ความแตกต่างของวัสดุในแต่ละล็อตและความแตกต่างของอุปกรณ์ในแต่ละโรงงานอาจส่งผลให้การพยากรณ์ของโมเดลไม่สม่ำเสมอ ซึ่งเน้นให้เห็นถึงความจำเป็นในการพัฒนาโมเดลที่สามารถปรับตัวได้ตามการเปลี่ยนแปลงเหล่านี้ได้อย่างมีประสิทธิภาพ (Oh, Y., Ransikarbum, K., Busogi, M., Kwon, D. และ Kim, N., 2018) (Saadallah, A., Abdulaaty, O., Buescher, J., Panusch, T., Morik, K. และ Deuse, J., 2022) [52,60] ในการกำหนดพารามิเตอร์ที่มีผลต่อกระบวนการตัดท่อในเครื่องตัด จากพารามิเตอร์เหล่านี้ (Görüç, V., Bahşı, M. และ Çevik, M., 2024) [32] ได้ทำการทดลองตัดท่อจำนวน 150 ครั้งในโรงงานอุตสาหกรรมเพื่อเก็บข้อมูล และผลลัพธ์จากการทดลองถูกใช้เป็นชุดข้อมูลสำหรับอัลกอริทึมการเรียนรู้ของเครื่อง (ML) โดยมีการใช้ ML ขั้นสูง 7 รูปแบบ ได้แก่ การถดถอยโลจิสติก (Logistic Regression), ต้นไม้ตัดสินใจ (Decision Tree), k-Nearest Neighbor (KNN), RFC, Naïve Bayes, SVM และ XGBoost ถูกนำมาใช้ผ่านไลบรารี Scikit-Learn ของ Python

ประสิทธิภาพของแต่ละอัลกอริทึมถูกเปรียบเทียบโดยใช้เมตริกซ์ความสับสน (Confusion Matrix) และเมตริกการจำแนกประเภท เช่น Accuracy, Precision, Recall, F1-Score, เส้นโค้งลักษณะการทำงานของตัวรับ (ROC Curve) และค่าพื้นที่ใต้เส้นโค้ง ROC (AUC) ดังภาพที่ 2.52




รูปที่ 2.51 การตั้งค่าและการติดตั้งกล้องถ่ายภาพความร้อน [52]




รูปที่ 2.52 การเปรียบเทียบคะแนนความแม่นยำของอัลกอริทึม ML [32]

ในการนำไปใช้กับกระบวนการ RSW ความแตกต่างของส่วนผสมวัสดุ ความหนา และสภาพพื้นผิวจำเป็นต้องให้โมเดลที่ไม่เพียงแต่ทำงานได้ดีในข้อมูลฝึกอบรมเท่านั้น แต่ยังต้องมีความแม่นยำเพียงพอที่จะสามารถใช้ได้กับสภาพแวดล้อมการผลิตที่แตกต่างกัน (Li, X., Zhang, M., Zhou, M., Wang, J., Zhu, W., Wu, C. และ Zhang, X., 2023) [43] ปัญหาความเป็นส่วนตัวของข้อมูลเพิ่มความซับซ้อนในการประยุกต์ใช้งานมากขึ้น โดยเฉพาะในกรณีที่มีข้อมูลที่มีความอ่อนไหว เช่น ข้อมูลเกี่ยวกับกระบวนการผลิตที่เป็นความลับหรือการตั้งค่าเครื่องจักร ซึ่งจำเป็นต้องมีมาตรการเพื่อคุ้มครองความเป็นส่วนตัวของข้อมูลเพื่อให้สอดคล้องกับมาตรฐานทางกฎหมายและเพื่อปกป้องทรัพย์สินทางปัญญา หนึ่งในวิธีแก้ไขปัญหาคือการใช้โปรโตคอลการแบ่งปันข้อมูลที่ปลอดภัย ดังภาพที่ 2.53 เช่น การเรียนรู้แบบรวม (Federated Learning) ซึ่งช่วยให้สามารถฝึกอบรมโมเดลได้โดยไม่ต้องเปิดเผยข้อมูลที่มีความอ่อนไหว (Dib, M., Prates, P. และ Ribeiro, B., 2023) [19]



รูปที่ 2.53 กรอบการทำงาน SecFL ซึ่งเป็นการผสมผสานระหว่างวิธีการ FL มาตรฐานและเทคนิค Signed DE [19]

การดูแลรักษาโครงสร้างพื้นฐานด้านข้อมูลที่เป็นในการรองรับโมเดลการเรียนรู้ของเครื่องก็เป็นอีกหนึ่งความท้าทายที่สำคัญ ข้อมูลที่เกิดจากเซนเซอร์ที่บันทึกข้อมูลการผลิต และการตรวจสอบคุณภาพต้องถูกเก็บรวบรวม จัดการ และประมวลผลอย่างมีประสิทธิภาพเพื่อรองรับการพยากรณ์แบบเรียลไทม์หรือใกล้เคียงกับเวลาจริง ในทางปฏิบัตินั้นมักต้องการโครงสร้างพื้นฐานด้านฮาร์ดแวร์และซอฟต์แวร์ที่เฉพาะเจาะจงซึ่งสามารถจัดการข้อมูลขนาดใหญ่ได้ ซึ่งทั้งมีค่าใช้จ่ายสูงและมีความซับซ้อนในการดูแลรักษาในระยะยาว นอกจากนี้ ตัวข้อมูลเองอาจเสื่อมคุณภาพลงตามกาลเวลา ทำให้ต้องมีการตรวจสอบและรับรองคุณภาพข้อมูลอย่างสม่ำเสมอ ดังภาพที่ 2.54 เพื่อให้แน่ใจว่าโมเดลการเรียนรู้ของเครื่องได้รับข้อมูลที่ถูกต้อง (Soto-Ferrari, M., Bhattacharyya, K. และ Schikora, P., 2023) [68]




รูปที่ 2.54 กรอบการทำงานของ POST-BaLSTM [68]

ข้อจำกัดอีกประการหนึ่งคือความจำเป็นในการอัปเดตโมเดลอย่างต่อเนื่องเพื่อรองรับการเปลี่ยนแปลงในกระบวนการผลิต การสึกหรอของเครื่องจักร และการเปลี่ยนแปลงในคุณสมบัติของวัสดุ ในสภาพแวดล้อมที่มีการเปลี่ยนแปลงอย่างรวดเร็วเช่นอุตสาหกรรมการผลิตรถยนต์ โมเดลการเรียนรู้ของเครื่องสามารถล้าสมัยได้อย่างรวดเร็วเมื่อสภาพการผลิตเปลี่ยนแปลง ทำให้จำเป็นต้องมีการฝึกอบรมโมเดลและการตรวจสอบใหม่อยู่เสมอ ความต้องการนี้อาจใช้ทรัพยากรมาก เนื่องจากต้องมีการตรวจสอบอย่างสม่ำเสมอ โครงสร้างพื้นฐานสำหรับการฝึกอบรมใหม่ และบางครั้งถึงขั้นต้องออกแบบโมเดลใหม่เพื่อให้เข้ากับการกระจายข้อมูล (Schuh, G., Gützlaff, A., Thomas, K. และ Welsing, M., 2021) [63]

การเพิ่มประสิทธิภาพกระบวนการผลิต เป็นสิ่งสำคัญอย่างยิ่งเพื่อให้มั่นใจว่าเซลล์แบตเตอรี่ (Lithium-Ion Battery: LIB) มีคุณภาพสูง โดยเฉพาะอย่างยิ่งในการใช้งานยานยนต์ กระบวนการผลิต LIB เป็นกระบวนการที่ซับซ้อนหลายขั้นตอนและพารามิเตอร์จำนวนมาก ในงานวิจัยของ (Duquesnoy, M., Liu, C., Zapata D., D., Kumar, V., Ayerbe, E. และ Franco, A., 2023) [21] ได้แสดงให้เห็นว่า แบบจำลองฟิสิกส์เชิงลึกแบบ 3 มิติ เป็นเครื่องมือที่มีประโยชน์อย่างมากในการให้ข้อมูลเชิงลึกเกี่ยวกับผลกระทบของพารามิเตอร์ในกระบวนการผลิตต่อคุณสมบัติด้านโครงสร้างและ

ประสิทธิภาพของขั้วไฟฟ้า อย่างไรก็ตาม การใช้งานแบบจำลองเหล่านี้ในกระบวนการเพิ่มประสิทธิภาพคุณสมบัติของขั้วไฟฟ้าและการออกแบบย้อนกลับพารามิเตอร์กระบวนการผลิตยังคงมีข้อจำกัด เนื่องจากต้นทุนการคำนวณที่สูง



รูปที่ 2.55 แผนผังเชิงโครงสร้างของการเพิ่มประสิทธิภาพหลายวัตถุประสงค์แบบเชิงซ้ำ [21]


งานวิจัยนี้ได้แก้ไขปัญหาโดยเสนอแนวทางใหม่ที่สามารถปรับใช้ได้ทั่วไป ซึ่งสนับสนุนโดยกระบวนการที่ใช้ ML แบบกำหนดแนวทาง (Deterministic ML-assisted pipeline) สำหรับการเพิ่มประสิทธิภาพหลายเป้าหมายของคุณสมบัติขั้วไฟฟ้า LIB และการออกแบบย้อนกลับกระบวนการผลิต ดังภาพที่ 2.55

การตีความและความโปร่งใสของโมเดลการเรียนรู้ของเครื่องยังเป็นข้อท้าทายในการประยุกต์ใช้เช่นกัน ในอุตสาหกรรมการผลิตรถยนต์ ซึ่งมีมาตรฐานคุณภาพและความปลอดภัยสูง วิศวกรฝ่ายผลิตยังต้องการคำอธิบายที่ชัดเจนเกี่ยวกับผลการทำนายของโมเดลและกระบวนการตัดสินใจของโมเดล สิ่งนี้อาจเป็นปัญหาโดยเฉพาะอย่างยิ่งเมื่อใช้โมเดลที่มีความซับซ้อน เช่น DL ที่มักถูกมองว่าเป็น "กล่องดำ" ซึ่งหากไม่มีการตีความที่เพียงพอ วิศวกรฝ่ายผลิตอาจไม่มั่นใจในความน่าเชื่อถือและการใช้งานผลการพยากรณ์ของโมเดลอย่างมีประสิทธิภาพ ซึ่งอาจจำกัดผลกระทบเชิงปฏิบัติของการนำ ML ไปใช้ในอุตสาหกรรม (Lai, X., Qiu, T., Shui, H., Ding, D. และ Ni, J., 2023) [40]

ระบบอัตโนมัติเป็นแรงขับเคลื่อนสำคัญในอุตสาหกรรมการผลิต ซึ่งช่วยเพิ่มคุณภาพและความสามารถในการขยายตัวในกระบวนการผลิตและการประกอบ เมื่อเปรียบเทียบกับอุตสาหกรรม

ยานยนต์ การนำระบบอัตโนมัติมาใช้ในอุตสาหกรรมการบินพลเรือนยังล่าช้า อย่างไรก็ตาม อัตราการยอมรับวิธีการที่นำระบบอัตโนมัติใช้ในกระบวนการผลิต การประกอบ และการทดสอบกำลังเร่งตัวขึ้น โดยมีการทดสอบเทคโนโลยีใหม่ๆ เพื่อช่วยให้การประกอบและการตรวจสอบมีความน่าเชื่อถือและปลอดภัยยิ่งขึ้น (Mosca, N., Renò, V., Nitti, M., Patruno, C., Negri, S. และ Stella, E., 2024) [50] ได้นำเสนอระบบกึ่งอัตโนมัติสำหรับการควบคุมคุณภาพในขั้นตอนสุดท้ายของการผลิตเครื่องบินพาณิชย์ขนาดลำเดียว โดยเฉพาะหลังจากการประกอบแบบอัตโนมัติของส่วนหมวกเก็บของและผนังด้านข้าง ในพื้นที่ผู้โดยสาร ก่อนที่จะติดตั้งส่วนที่นั่ง โดยใช้ระบบควบคุมคุณภาพนี้ใช้กล้องสีและกล้อง 3 มิติที่ติดตั้งบนหุ่นยนต์เคลื่อนที่ 2.56 ที่เป็นแบบไฮโลนอมิกที่ออกแบบเฉพาะ ข้อมูลที่ได้จะถูกประมวลผลเพื่อตรวจสอบข้อบกพร่องด้านเรขาคณิตหรือพื้นผิวโดยใช้อัลกอริทึมที่อิงกับ ML และการประมวลผลแบบ 3 มิติ

การใช้งานเทคโนโลยีดิจิทัลขั้นสูง เช่น อุปกรณ์ IoT และ CPS ในสภาพแวดล้อมอุตสาหกรรมที่เพิ่มมากขึ้น ช่วยให้การใช้อัลกอริทึม ML ในโดเมนการผลิตมีประสิทธิภาพมากขึ้น อย่างไรก็ตาม เมื่อแอปพลิเคชัน ML ก้าวข้ามจากการวิจัยไปสู่การใช้งานจริงในสภาพแวดล้อมอุตสาหกรรม คำถามเกี่ยวกับความน่าเชื่อถือก็เกิดขึ้น เนื่องจากแบบจำลอง ML ส่วนใหญ่ถูกฝึกและประเมินบนชุดข้อมูลคงที่ การตรวจสอบประสิทธิภาพแบบออนไลน์อย่างต่อเนื่องจึงเป็นสิ่งจำเป็นในการสร้างระบบที่น่าเชื่อถือ นอกจากนี้ การเปลี่ยนแปลงของแนวคิดและเซ็นเซอร์ สามารถนำไปสู่การลดลงของความแม่นยำของอัลกอริทึมเมื่อเวลาผ่านไป ซึ่งอาจส่งผลกระทบต่อ ความน่าเชื่อถือ หากไม่ได้รับการตรวจสอบและจัดการอย่างเหมาะสม (Jourdan, N., Sen, S., Husom, E.J., Garcia C., Enrique & Biegel, T. และ Metternich, J., 2021) [35] ได้แสดงให้เห็นถึงผลกระทบของปัญหาโดยใช้ชุดข้อมูลที่เผยแพร่สาธารณะ ซึ่งถูกรวบรวมในช่วงเวลา 36 เดือน และอธิบายแหล่งที่มาที่เป็นไปได้ของการเปลี่ยนแปลงดังกล่าว จากการประเมินความทนทานของอัลกอริทึม ML ที่ใช้กันทั่วไปในอุตสาหกรรม การผลิต และพบว่าความแม่นยำลดลงอย่างมากเมื่อเกิดการเปลี่ยนแปลงในข้อมูลสำหรับอัลกอริทึมทั้งหมดที่ทดสอบ นอกจากนี้ เรายังศึกษาเพิ่มเติมว่าการประเมินความไม่แน่นอน (Uncertainty Estimation) สามารถถูกนำมาใช้ในการประเมินประสิทธิภาพแบบออนไลน์



รูปที่ 2.56 แพลตฟอร์มการเก็บข้อมูลประกอบด้วยฐานหุ่นยนต์ แขนหุ่นยนต์ และเซ็นเซอร์ของชิ้นส่วนเครื่องบิน [50]

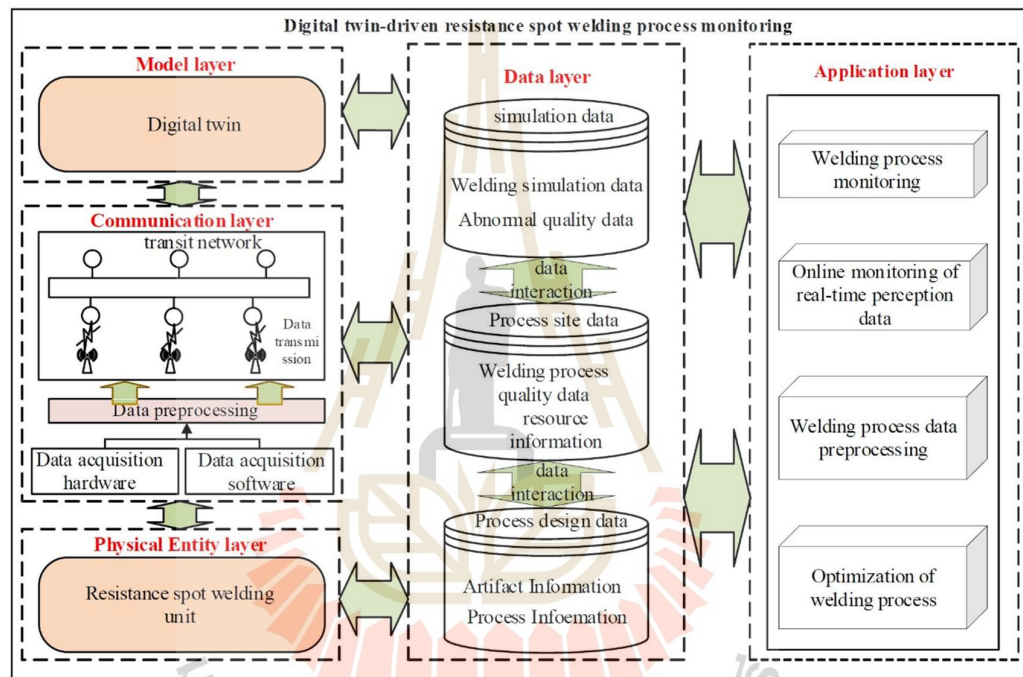
สรุปแล้ว ความสำเร็จในการประยุกต์ใช้โมเดลการเรียนรู้ของเครื่องในอุตสาหกรรมการผลิตรถยนต์ไม่เพียงแต่ต้องพัฒนาทางเทคนิคเท่านั้น แต่ยังต้องคำนึงถึงความท้าทายเชิงปฏิบัติเหล่านี้ด้วยการจัดการกับปัญหาด้านการบูรณาการ การขยายขอบเขตการใช้งาน ความเป็นส่วนตัวของข้อมูล การดูแลรักษาโครงสร้างพื้นฐาน การอัปเดตโมเดลอย่างต่อเนื่อง ความสามารถในการตีความ และการประมวลผลแบบเรียลไทม์นั้นเป็นสิ่งสำคัญสำหรับการเปลี่ยนแปลง ML จากเทคโนโลยีที่มีศักยภาพไปสู่เครื่องมือที่เชื่อถือได้ในการเพิ่มคุณภาพและประสิทธิภาพในอุตสาหกรรมการผลิตรถยนต์

2.10 ทิศทางในอนาคตของการตรวจสอบคุณภาพเชิงทำนายสำหรับ RSW


ในขณะที่การตรวจสอบคุณภาพเชิงทำนายสำหรับการเชื่อม RSW กำลังพัฒนาไป เทคโนโลยีใหม่ ๆ กำลังเข้ามามีบทบาทสำคัญในการสร้างระบบการตรวจสอบคุณภาพยุคใหม่ ความก้าวหน้าที่สำคัญได้แก่ การรวมอุปกรณ์ IoT เพื่อการเก็บข้อมูลแบบเรียลไทม์ การใช้ดิจิทัลทวินในการจำลองกระบวนการเชื่อม และการนำสถาปัตยกรรมการเรียนรู้เชิงลึกขั้นสูงมาใช้ โดยเทคโนโลยีเหล่านี้มีศักยภาพในการเพิ่มความแม่นยำ ประสิทธิภาพ และความสามารถในการทำนายของการตรวจสอบคุณภาพ

การรวมอุปกรณ์ IoT ช่วยให้สามารถเก็บข้อมูลแบบเรียลไทม์ได้อย่างต่อเนื่องในหลายขั้นตอนของกระบวนการเชื่อม ซึ่งเอื้อต่อการวิเคราะห์และการปรับเปลี่ยนกระบวนการได้ทันที เซ็นเซอร์ที่เชื่อมต่อกับระบบ IoT จะเก็บข้อมูลที่หลากหลาย เช่น อุณหภูมิ กระแสไฟฟ้า และการ

เคลื่อนที่ของหัวเชื่อม ซึ่งนำไปสร้างชุดข้อมูลที่สมบูรณ์สำหรับโมเดลการทำนาย ดังรูปที่ 2.57 การเชื่อมต่อเหล่านี้ทำให้ผู้ผลิตสามารถก้าวข้ามการตรวจสอบคุณภาพแบบดั้งเดิมสู่การเฝ้าติดตามเชิงรุก และการปรับพารามิเตอร์การเชื่อมแบบเรียลไทม์ นอกจากนี้ การรวม IoT ยังสนับสนุนการจัดเก็บข้อมูลและการวิเคราะห์ผ่านระบบคลาวด์ ดังรูปที่ 2.58 ซึ่งช่วยเพิ่มความสามารถในการขยายขนาด และรองรับการตรวจสอบกระบวนการเชื่อมในโรงงานได้อย่างมีประสิทธิภาพ (Dong, J., Hu, J. และ Luo, Z., 2023) [20]




รูปที่ 2.57 กรอบแนวคิดของระบบดิจิทัลทวินสำหรับกระบวนการเชื่อม RSW [20]



รูปที่ 2.58 ระบบการเก็บข้อมูลแบบเรียลไทม์สำหรับกระบวนการเชื่อม RSW [86]

(Tao, J., Nor, N. และ Abdullah, A.B., 2024) [72] ได้สำรวจสภาพแวดล้อมการทำงานของการเชื่อมหุ่นยนต์ โดยได้ทำการสกัดคุณลักษณะในโดเมนเวลาและโดเมนความถี่จำนวน 26 รายการจากสัญญาณเสียงของรอยเชื่อม และใช้การวิเคราะห์ทางสถิติและวิธีการเปรียบเทียบเพื่อระบุความแตกต่างในคุณลักษณะของสัญญาณที่มีข้อบกพร่องและแปลความหมายในเชิงฟิสิกส์ ด้วยการใช้ลักษณะเฉพาะของสัญญาณเสียงเหล่านี้ โดยได้สร้างแบบจำลองการระบุเชิงทำนายและตัวควบคุมแบบป้อนกลับออนไลน์ โดยสามารถระบุระดับความลึกที่แตกต่างกันในกระบวนการเชื่อมได้อย่างมีประสิทธิภาพ และผลการระบุเหล่านี้ถูกนำมาใช้เป็นข้อมูลอ้างอิงสำหรับการปรับความเร็วการเชื่อมแบบออนไลน์ผ่านตัวควบคุม นอกจากนี้ ระบบดิจิทัลทวินยังถูกพัฒนาขึ้นโดยที่แบบจำลองการระบุและตัวควบคุมทำงานเป็นวัตถุดิจิทัลบนคอมพิวเตอร์และการประมวลผลข้อมูลให้แสดงผลเร็วใกล้เคียงกับความเร็วของเครือข่าย (Edge Computer) ตามลำดับ การทดสอบเชิงทดลองได้แสดงให้เห็นถึงประสิทธิภาพที่เหนือกว่าของระบบและแบบจำลองในการสะท้อนระดับความลึกของรอยเชื่อม การปรับและรักษาเสถียรภาพของความเร็วการเชื่อม และการยกระดับคุณภาพของรอยเชื่อมอย่างมีนัยสำคัญ




รูปที่ 2.59 อุปกรณ์ทดลองสำหรับกระบวนการเชื่อม RSW [72]

ดิจิทัลทวินเป็นอีกหนึ่งเทคโนโลยีที่มีศักยภาพในด้านการตรวจสอบคุณภาพเชิงทำนาย โดยการสร้างแบบจำลองเสมือนของกระบวนการ RSW ดิจิทัลทวินสามารถจำลองการเชื่อมภายใต้เงื่อนไขที่หลากหลายและทำนายผลลัพธ์ได้โดยไม่ส่งผลกระทบต่อการผลิตจริง ความสามารถนี้มีประโยชน์อย่างมากในด้านการบำรุงรักษาเชิงทำนาย เนื่องจากดิจิทัลทวินสามารถช่วยคาดการณ์การสึกหรอของหัวเชื่อมเพื่อตรวจจับข้อบกพร่องที่อาจเกิดขึ้น และประเมินผลกระทบของการปรับเปลี่ยนพารามิเตอร์ต่อคุณภาพการเชื่อม งานวิจัยแสดงให้เห็นว่าด้วยการจำลองพฤติกรรมของอุปกรณ์เชื่อมในสภาพแวดล้อมจริง ดิจิทัลทวินสามารถช่วยคาดการณ์ความต้องการการบำรุงรักษาได้แม่นยำมากขึ้น ลดเวลาที่เครื่องจักรหยุดทำงาน และเพิ่มอายุการใช้งานของอุปกรณ์ นอกจากนี้ ดิจิทัลทวินยังเป็นสภาพแวดล้อมที่ปลอดภัยและมีประสิทธิภาพในการทดลองพารามิเตอร์ใหม่ ๆ ซึ่งเร่งให้เกิดนวัตกรรมในเทคนิคในการเชื่อม RSW

การติดตามแนวรอยเชื่อม (Seam Tracking) เป็นสิ่งจำเป็นในกระบวนการเชื่อมเพื่อให้มั่นใจในความแม่นยำของการเชื่อม เพื่อช่วยลดข้อผิดพลาดในกระบวนการเชื่อมแผ่นเหล็กสำหรับเรือสำราญขนาดใหญ่ ได้มีการนำเสนอแนวทางการควบคุมการชดเชยเชิงพยากรณ์โดยใช้ดิจิทัลทวิน ดังภาพที่ 2.60 (Shang, G., Xu, L., Li, Z., Zhou, Z. และ Xu, Z., 2024) [64] ได้มีการวิเคราะห์ลักษณะเฉพาะที่เหมาะสมสำหรับกระบวนการเชื่อม โดยนำเสนอสถาปัตยกรรมแบบดิจิทัลทวินสำหรับการควบคุมการชดเชยเชิงทำนายในกระบวนการติดตามแนวรอยเชื่อม จากนั้น จึงควบคุมการชดเชยเชิงทำนายสำหรับการติดตามแนวรอยเชื่อม นอกจากนี้ ได้มีการพัฒนาโมเดลแบบวนซ้ำที่ผสมผสานวิธีการทากูชิและอัลกอริทึมค้นหาสแปร์โรว์ (Recursive Grey Model Based on Taguchi Method and Sparrow Search Algorithm: RGMbTM-SSA) เพื่อปรับปรุงความแม่นยำในการพยากรณ์

สุดท้าย ได้มีการตรวจสอบความแม่นยำของ RGMbTM-SSA และความเป็นไปได้ของกลยุทธ์การควบคุมการชดเชยเชิงพยากรณ์ที่ใช้ดิจิทัลทวิน ผ่านกรณีศึกษาจริงในกระบวนการผลิตการเชื่อมแผ่นเหล็กสำหรับเรือสำราญขนาดใหญ่ ในการทำนายข้อผิดพลาดของการติดตามแนวรอยเชื่อม RGMbTM-SSA มีประสิทธิภาพดีกว่าโมเดลแบบทั่วไปและอัลกอริทึมการเรียนรู้ของเครื่องบางประเภท ในระบบดิจิทัลทวินที่พัฒนาขึ้นสำหรับการติดตามแนวรอยเชื่อม ประสิทธิภาพโดยรวมของกลยุทธ์การควบคุมการชดเชยเชิงพยากรณ์ที่ดีที่สุดเมื่อกำหนดเวลาเผื่อล่วงหน้า (Advance Time) ไว้ที่ 2 วินาที




รูปที่ 2.60 สถาปัตยกรรมที่ใช้ดิจิทัลทวินสำหรับการควบคุมเชิงชดเชยแบบคาดการณ์ล่วงหน้าสำหรับการติดตามรอยเชื่อมในกระบวนการเชื่อมแผ่นเหล็กของเรือสำราญขนาดใหญ่ [88]

โดยสรุป อนาคตของการตรวจสอบคุณภาพเชิงทำนายสำหรับ RSW มีแนวโน้มที่จะก้าวหน้าอย่างมาก ด้วยการนำเทคโนโลยี IoT ดิจิทัลทวิน และโมเดล ML ขั้นสูง เช่น Transformer ผู้ผลิตสามารถสร้างระบบการตรวจสอบคุณภาพที่มีความยืดหยุ่นและชาญฉลาดมากขึ้น เทคโนโลยีเหล่านี้ไม่เพียงช่วยเพิ่มความแม่นยำในการตรวจจับข้อบกพร่องแบบเรียลไทม์ แต่ยังช่วยในการบำรุงรักษาเชิงทำนายและการควบคุมแบบปรับตัว ซึ่งจะนำไปสู่การผลิตที่มีประสิทธิภาพและความยั่งยืนมากขึ้น

2.11 สรุป

ในงานวิจัยที่มุ่งเน้นการประยุกต์ใช้ทฤษฎีปัญญาประดิษฐ์โดยวิธี Supervised Learning นั้น เป็นการเลือกตั้งต้นที่เหมาะสม เนื่องจากวิธีการนี้ทำให้ระบบสามารถเรียนรู้จากข้อมูลการผลิตที่ผ่านมาได้อย่างมีประสิทธิภาพ และในขั้นตอนการเรียนรู้ ข้อมูลจะถูกจัดการและวิเคราะห์ด้วยวิธีทางสถิติ ซึ่งช่วยเพิ่มประสิทธิภาพให้กับกระบวนการเรียนรู้ของปัญญาประดิษฐ์อย่างมีประสิทธิภาพ ซึ่งผลลัพธ์ที่ได้จะมีความแม่นยำและทันสมัยมากยิ่งขึ้น โดยการใช้วิธีทางสถิติในการจัดการข้อมูลช่วยลดเวลาและแรงงานที่เสียไปในการประมวลผลข้อมูลอย่างมีประสิทธิภาพเช่นกัน ดังนั้น การใช้ supervised learning ในทฤษฎีปัญญาประดิษฐ์เป็นทางเลือกที่สอดคล้องกับความต้องการและประสิทธิภาพในงานวิจัยต่าง ๆ ในปัจจุบันและอนาคต




บทที่ 3

วิธีการดำเนินงานวิจัย

3.1 วิธีดำเนินงานวิจัย

งานวิจัยนี้มุ่งเน้นไปที่การทำนายคุณภาพของรอยเชื่อม โดยอาศัยค่าของแรงดันและกระแสที่เกิดขึ้นในขณะเชื่อม โดยการออกแบบปัญญาประดิษฐ์เพื่อช่วยในการทำนายคุณภาพ โดยเริ่มต้นจากการทำการทดสอบการเชื่อมบนชิ้นงานตัวอย่างด้วยพารามิเตอร์ต่าง ๆ การเก็บค่าตัวแปรจากเครื่องจักร การออกแบบปัญญาประดิษฐ์ การเก็บค่าตัวแปรจากการผลิต ซึ่งขั้นตอนการดำเนินการวิจัยดังกล่าวมาข้างต้นสามารถแสดงเป็นแผนภูมิได้ดังรูปที่ 3.1 โดยอธิบายเป็นขั้นตอนสังเขปดังนี้



รูปที่ 3.1 แผนภูมิการดำเนินงานวิจัย

3.2 เครื่องมือและอุปกรณ์ในการศึกษาวิจัย

3.2.1 หุ่นยนต์อุตสาหกรรมสำหรับงานเชื่อมยี่ห้อ Kawasaki รุ่น BX200L

Kawasaki รุ่น BX200L เป็นหุ่นยนต์อุตสาหกรรมที่ออกแบบมาเพื่องานเชื่อม โดยเฉพาะในอุตสาหกรรมยานยนต์ สามารถรองรับน้ำหนักได้ 200 กิโลกรัมและมีระยะเอื้อมถึง 3,012 mm ทำให้เหมาะสำหรับการจัดการชิ้นส่วนที่มีขนาดใหญ่ พร้อมด้วยมอเตอร์ความเร็วสูงและระบบควบคุมที่แม่นยำ ทำให้การเชื่อมเป็นไปอย่างรวดเร็วและแม่นยำ โดยเฉพาะการเชื่อมอาร์คและการเชื่อมแบบจุด การตั้งโปรแกรมที่ยืดหยุ่นและการออกแบบที่แข็งแรงทนทานช่วยเพิ่มประสิทธิภาพการผลิตและลดข้อผิดพลาดในกระบวนการเชื่อมอัตโนมัติในสภาพแวดล้อมสำหรับอุตสาหกรรมยานยนต์



รูปที่ 3.2 หุ่นยนต์อุตสาหกรรม

3.2.2 คอมพิวเตอร์ควบคุมการเชื่อมแบบจุด ยี่ห้อ Bosch รุ่น PSI 63C3

Bosch PSI 63C3 เป็นตัวควบคุมเวลาและกระแสไฟฟ้าในการเชื่อมที่มีความแม่นยำสูงสำหรับกระบวนการเชื่อมต้านทาน โดยใช้ในอุตสาหกรรมยานยนต์เป็นหลัก มีความสามารถในการตั้งค่าพารามิเตอร์การเชื่อม เช่น กระแสไฟ เวลา และแรงกด ให้สอดคล้องกับความต้องการเฉพาะของงาน ระบบนี้ยังสามารถตรวจสอบค่าพารามิเตอร์สำคัญได้แบบเรียลไทม์ ทำให้ปรับเปลี่ยนได้ทันทีเพื่อ




รูปที่ 3.3 คอมพิวเตอร์ควบคุมการเชื่อม

รักษาคุณภาพงานเชื่อมอย่างต่อเนื่อง นอกจากนี้ยังมีการบันทึกข้อมูลการเชื่อมเพื่อใช้ในการควบคุมคุณภาพและวิเคราะห์ และมีการออกแบบที่แข็งแรงทนทาน รองรับการใช้งานในสภาพแวดล้อมการผลิตปริมาณมาก เครื่องนี้มักถูกนำไปใช้ในระบบอัตโนมัติ รวมถึงการเชื่อมด้วยหุ่นยนต์ เพื่อเพิ่มประสิทธิภาพและความแม่นยำในการเชื่อม

3.2.3 ปืนเชื่อมด้วยความต้านทานแบบจุด ยี่ห้อ OBARA

ปืนเชื่อมแบบจุดยี่ห้อ OBARA ที่ใช้ร่วมกับหม้อแปลง MFDC รุ่น SRTC เป็นอุปกรณ์เฉพาะทางสำหรับการเชื่อมด้วยความต้านทานแบบจุด ซึ่งนิยมใช้ในอุตสาหกรรม เช่น การผลิตรถยนต์ โดยใช้เทคโนโลยีกระแสตรงความถี่ปานกลาง (MFDC) ที่ทำงานด้วยความถี่สูงกว่าระบบทั่วไป ทำให้ประหยัพลังงานมากขึ้นและควบคุมกระบวนการเชื่อมได้ดีขึ้น ส่งผลให้คุณภาพการเชื่อมสม่ำเสมอ ลดการใช้พลังงาน และเกิดความร้อนน้อยลง การออกแบบที่กะทัดรัดและน้ำหนักเบาทำให้ง่ายต่อการใช้งานร่วมกับระบบหุ่นยนต์ ทั้งยังมีความทนทานต่อการใช้งานในสภาพแวดล้อมอุตสาหกรรมหนัก จึงเหมาะสำหรับงานเชื่อมที่ต้องการความแม่นยำและการผลิตจำนวนมาก เช่น การเชื่อมตัวถังและชิ้นส่วนโครงสร้างของรถยนต์




รูปที่ 3.4 ปืนเชื่อมด้วยความต้านทานแบบจุด ยี่ห้อ OBARA

3.2.4 หัวเชื่อมทองแดงแบบผสม (CuCrZr) ชนิด Dome แบบ F

หัวเชื่อมทองแดงแบบผสม (CuCrZr) เป็นอุปกรณ์ที่มีประสิทธิภาพสูงสำหรับการเชื่อมด้วยความต้านทาน โดยผสมผสานการนำไฟฟ้าและความร้อนที่ยอดเยี่ยมของทองแดงเข้ากับ ความแข็งแรงที่เพิ่มขึ้นจากโครเมียมและเซอร์โคเนียม ทำให้ทนทานต่อการสึกหรอและความร้อนได้ดี หัวเชื่อมนี้สามารถรักษารูปร่างและประสิทธิภาพได้แม้ในอุณหภูมิสูง ช่วยให้การเชื่อมมีคุณภาพ

สม่ำเสมอ ความทนทานนี้ทำให้หัวเชื่อมมีอายุการใช้งานยาวนานขึ้น ลดความถี่ในการเปลี่ยนใหม่ หัวเชื่อม CuCrZr นิยมใช้ในอุตสาหกรรมยานยนต์และอวกาศสำหรับการเชื่อมจุดวัสดุ เช่น เหล็กและอะลูมิเนียม ที่ต้องการการนำไฟฟ้าและความเสถียรสูง

ELECTRODE TIP STANDARD ISO 5281:2009



รูปที่ 3.5 หัวเชื่อมทองแดงแบบผสม (CuCrZr) ชนิด Dome แบบ F

3.2.5 เครื่องมือตรวจสอบรอยเชื่อมแบบจุด ยี่ห้อ Tessonic รุ่น F1 ด้วยหัววัดขนาด 52 ตาราง

เครื่องมือตรวจสอบรอยเชื่อมแบบจุด Tessonic รุ่น F1 พร้อมหัววัดขนาด 52 ตาราง เป็นอุปกรณ์ที่ใช้สำหรับตรวจสอบคุณภาพรอยเชื่อมในกระบวนการเชื่อมแบบจุด โดยใช้เทคโนโลยีอัลตราโซนิกเพื่อตรวจจับความสมบูรณ์ของรอยเชื่อม หัววัดขนาด 52 ตารางสามารถครอบคลุมพื้นที่ตรวจสอบได้มาก ช่วยให้ตรวจสอบได้อย่างรวดเร็วและมีประสิทธิภาพ เครื่องมือนี้ออกแบบมาให้ใช้งานง่าย มีความแม่นยำสูง และสามารถตรวจจับข้อบกพร่องเล็ก ๆ ในรอยเชื่อมได้เหมาะสมสำหรับอุตสาหกรรมที่ต้องการควบคุมคุณภาพรอยเชื่อม เช่น การผลิตตัวถังรถยนต์และอากาศยาน เพื่อให้แน่ใจว่ารอยเชื่อมมีความแข็งแรงและสม่ำเสมอ



(a) Matrix Array Probe


(b) Resistance Spot Weld Analyzer

รูปที่ 3.6 เครื่องมือตรวจสอบรอยเชื่อมแบบจุด ยี่ห้อ Tessonic

3.2.6 คอมพิวเตอร์ Dell T7920 Intel XEON Silver 4108x2CPU with Nvidia RTX A4000 16 GB, RAM 256 GB, Window 11 Pro for Workstation

3.3 การเขียนรหัสโปรแกรมเพื่อเก็บค่าและแปลผล

การเขียนรหัสโปรแกรมเอบทำการเก็บค่าและแปลผลของข้อมูลที่ได้จากการเชื่อมแต่ละครั้งนั้น จะใช้ภาษา Python ในการเขียนรหัสโปรแกรมผ่านโปรแกรม Visual Studio Code เพื่อทำการแปลผลข้อมูลที่ได้ ดังแสดงในแผนภาพด้านล่าง ดังรูปที่ 3.7



รูปที่ 3.7 แผนภูมิการเขียนโปรแกรมเพื่อเก็บค่าและแสดงผล










3.4 ตัวแปรที่ใช้ในการเชื่อม

จากมาตรฐานงานเชื่อมของบริษัทรถยนต์แห่งหนึ่งกำหนดให้ใช้แรงในการกดแผ่นโลหะขณะเชื่อมอยู่ที่ 2.7 kN ดังตารางที่ 3.2 สำหรับแผ่นเหล็กที่มีความหนาระหว่าง 0.65 – 0.71 mm เมื่อชิ้นงานนั้นมีขนาดเท่ากันทั้งคู่ โดยด้านบนนั้นเป็นเหล็กที่เคลือบกัลวาไนซ์และชั้นล่างนั้นเป็นเหล็กที่ไม่เคลือบผิว โดยทั้งสองชิ้นเป็นเหล็กที่มีค่า UTS ระหว่าง 350 – 590 MPa ดังตารางที่ 3.2

ตารางที่ 3.1 ตารางการปรับพารามิเตอร์การเชื่อมแบบจุด

Governing Metal Thickness Useful Range -- Nominal (mm)		Button Size Setup Reference (mm)	Cap Face Diameter (mm)	Uncoated Design Weld Current (kA)	Coated Design Weld Current (kA)	Design Weld Time (cyc) (ms)		Design Weld Force (lbs) (kN)	
0.50	0.56	4.4	6	6.3	9.8	10	167	530	2.4
0.57	0.64	4.4	6	6.5	10.0	10	167	560	2.5
0.65	0.71	4.4	6	6.6	10.0	11	183	580	2.6
0.72	0.79	4.4	6	6.8	10.2	11	183	600	2.7
0.80	0.86	5.0	6	7.2	10.6	12	200	630	2.8
0.87	0.94	5.0	6	7.5	11.0	12	200	660	2.9
0.95	1.04	5.0	6	8.0	11.4	12	200	720	3.2
1.05	1.14	5.0	6	8.4	11.9	13	217	780	3.5
1.15	1.24	5.0	6	9.1	12.3	14	233	850	3.8
1.25	1.40	6.3	8	10.3	14.0	15	250	1000	4.4
1.41	1.55	6.3	8	11.1	14.9	17	283	1100	4.9
1.56	1.68	6.3	8	11.8	15.5	19	317	1200	5.3
1.69	1.85	6.3	8	12.1	15.8	21	350	1300	5.8
1.86	1.99	6.3	8	12.4	16.0	23	383	1430	6.3
2.00	2.24	7.9	8	12.9	16.7	26	433	1630	7.2
2.25	2.46	7.9	8	13.3	16.9	29	483	1730	7.7
2.47	2.72	7.9	8	13.9	17.6	34	567	1900	8.4
2.73	3.00	7.9	8	14.5	18.1	39	650	2100	9.3

ตารางที่ 3.2 ตารางการจับคู่พารามิเตอร์การเชื่อม

		Truncated-to-Truncated Electrode Arrangement 		
Metal Combinations & Arrangements		Governing Metal Thickness (GMT)	Weld Schedule Force and Current Adjustment (see Note **)	Maximum Thickness Ratio
1	 Two Equal Metal Thicknesses	X	—	See Note 3
Least Critical of all Welding Conditions Shown				
2	 Two Unequal Metal Thicknesses	X	—	See Note 3
See Note 1				
3	 Three Equal Metal Thicknesses	X	+10%	See Note 3
One of the Least Critical of the Three Metal Thickness Conditions				
4	 Three Unequal Metal Thicknesses: Lightest Gage in Center	X	+10%	See Note 3
See Note 2				
5	 Three Unequal Metal Thicknesses: Heaviest Gage in Center	Z	+10%	See Note 3
See Note 2				
6	 Three Unequal Metal Thicknesses: Medium Gage in Center	Y	+10%	See Note 3
Condition in Which Thickness Ratio Limitation is Most Critical				
7	 Three metal Thicknesses: Two Equal and One Lighter, Lighter Gage in Center	X	—	See Note 3
One of the Least Critical of the Three Metal Thickness Conditions				
8	 Three Metal Thicknesses: Two Equal and One Heavier, Heavier Gage in Center	X	+10%	See Note 3
See Note 1				
9	 Three Metal Thicknesses: Two Equal and One Lighter, Lighter Gage on Outside	Z	+10%	See Note 3
See Note 2				
10	 Three Metal Thicknesses: Two Equal and One Heavier Gage on Outside	X	+15%	See Note 3
See Note 2				


3.5 การเรียนรู้ของเครื่องจักรและการเรียนรู้เชิงลึก

3.5.1 แหล่งข้อมูล (Data source)

ข้อมูลถูกเก็บจาก 2 ส่วน ได้แก่ การเก็บข้อมูลจากการทดลองและข้อมูลจากสายการผลิตจริง โดยข้อมูลที่ได้


3.5.1.1 ข้อมูลที่ได้จากการทดลอง

จากการทดลองนั้นได้มาจากการเชื่อมจุดบนชิ้นงานตัวอย่าง (Coupon) คือแผ่นโลหะเหล็กชนิดความแข็งแรงสูงขนาด 350-500 MPa โดยมีความหนาระหว่าง 0.7 ± 0.05 mm โดยชิ้นบนเป็นเหล็กที่เคลือบด้วยกัลวาไนซ์ส่วนชิ้นล่างเป็นเหล็กที่ไม่เคลือบกัลวาไนซ์ โดยกำหนดให้จุดเชื่อมแต่ละจุดอยู่ห่างกันไม่น้อยกว่า 20 mm



รูปที่ 3.8 ชิ้นงานทดลองสำหรับงานเชื่อม

ในการทดลองนั้นกำหนดให้การเชื่อมมีการใช้พารามิเตอร์จาก Lobe curve โดยกำหนดให้ 0 หมายถึง ไม่มีการใช้พารามิเตอร์นี้ในการทดลอง และ 1 หมายถึงการใช้พารามิเตอร์ในการทดลอง โดยระบุตัวแปรสำหรับการเชื่อมคือ เวลา และ กระแสที่ใช้ในการเชื่อม ดังรูปที่กำหนดไว้ในภาพที่ 3.9



รูปที่ 3.9 ข้อมูลตัวแปรที่ใช้ในการเชื่อม


3.5.1.2 ข้อมูลที่ได้จากกระบวนการผลิต

กระบวนการผลิตสำหรับแผนกประกอบตัวถัง เริ่มต้นจากการประกอบโครงสร้างต่าง ๆ ของตัวถังรวมถึงส่วนกระเบ เนื่องจากขั้นตอนในการประกอบตัวถังรถยนต์ มีความละเอียดและซับซ้อนในการเชื่อมจุดต่าง ๆ มาก จึงมีเครื่องเชื่อมมากกว่า 200 เครื่อง พร้อมหุ่นยนต์ที่ทันสมัยในการเชื่อมจุดต่างๆ มากกว่า 3,500 จุด ในส่วนของงานวิจัยนั้นได้เลือกใช้ข้อมูลในส่วนของพื้นของห้องโดยสาร ระหว่างห้องโดยสารด้านหน้าและห้องโดยสารด้านหลัง ในส่วนนี้นั้นได้ใช้หุ่นยนต์อุตสาหกรรม ในการเชื่อมจำนวน 2 ตัว ในการเชื่อมซ้าย-ขวา ดังรูปที่ 3.10



รูปที่ 3.10 งานเชื่อมในอุตสาหกรรมรถยนต์

ในการเชื่อมของหุ่นยนต์ 1 ตัวนั้นหุ่นยนต์จะทำการเชื่อมทั้งหมด 12 จุด โดยแบ่งตามจำนวนชั้นของแผ่นเหล็ก โดย 6 จุดแรกเป็นการเชื่อมบนความหนาของแผ่นเหล็กจำนวน 3 ชั้น และ 6 จุดที่เหลือนั้นเป็นการเชื่อมบนความหนาของแผ่นเหล็กจำนวน 2 ชั้น ซึ่งเป็นจุดเชื่อมที่ใช้ในการทำวิจัย ดังรูปที่ 3.11 ในปัจจุบันนั้นมีการผลิตต่อวันมากกว่า 450 คัน



รูปที่ 3.11 รอยเชื่อมที่ใช้ในงานวิจัย

3.5.2 กระบวนการเชื่อมด้วยความต้านทาน (RSW process)


กระบวนการนี้เริ่มต้นจากการที่หุ่นยนต์ได้รับคำสั่งจาก PLC เพื่อเชื่อมในตำแหน่งที่กำหนด หลังจากกระบวนการเชื่อมเสร็จสิ้น เราได้เขียนโปรแกรมในภาษา Python โดยใช้ Jupyter Notebook เพื่ออ่านไฟล์ RUI และตรวจสอบความสมบูรณ์ของข้อมูลการเชื่อม เพื่อยืนยันว่ากระบวนการเชื่อมเสร็จสมบูรณ์แล้ว เนื่องจากโปรแกรมทั่วไปไม่สามารถอ่านไฟล์ประเภทนี้ได้

3.5.3 การแยกข้อมูล (Data extraction)

หลังจากที่ดึงข้อมูลที่จำเป็น เช่น วันที่และเวลาที่กระบวนการเริ่ม กระแสไฟฟ้า แรงดันไฟฟ้า และเวลาที่ใช้ในกระบวนการเชื่อมแล้วดังตารางที่ 3.3 ค่าเหล่านี้จะถูกคำนวณ จากนั้นเราจะทำการพล็อตกราฟแรงดัน กระแส และความต้านทานเทียบกับเวลาที่ใช้ในกระบวนการเชื่อม กราฟที่ได้ดังรูปที่ 3.12 จะถูกใช้เป็นหนึ่งในการามิเตอร์ในชุดข้อมูลเพื่อสร้างแบบจำลอง

ตารางที่ 3.3 ตัวอย่างข้อมูลได้จากการแปลงจาก RUI ไฟล์


Time (ms)	Volt (V)	Current (kA)	Resistance (Ω)
0	0.07843	0.16068	0.48813
1	0.93137	2.53065	0.36804
2	1.97059	5.74417	0.34306
3	2.33333	7.31076	0.31916
4	2.47059	8.31499	0.29712
5	2.5	8.87735	0.28162
6	2.39216	9.11837	0.26234
7	2.29412	9.23887	0.24831
8	2.27451	9.47989	0.23993
9	2.22549	9.6004	0.23181
10	2.13725	9.56023	0.22356
11	2.13725	9.7209	0.21986
⋮	⋮	⋮	⋮
350	2.06863	9.76107	0.21193




รูปที่ 3.12 กระแส แรงดันและความต้านทานที่ได้จากกระบวนการเชื่อม

3.5.4 การวัดและการแยกประเภทของรอยเชื่อมด้วยคลื่นเสียงความถี่สูง (UT measurement and labelling)

จากรอยเชื่อมทั้งหมดที่ได้จากการทดลองนั้นจะการวัดขนาดของรอยเชื่อมใช้วิธีการ UT โดยใช้โปรแกรม RSWA จาก Tessonic โดยการวัดทั้งหมดจำนวน 450 จุด พบว่ามีจำนวนรอยเชื่อมที่สามารถอ่านค่าได้จำนวน 410 จุด ดังตัวอย่างที่แสดงในรูปที่ 3.13



จากข้อมูลในตารางที่ 3.3 กำหนดให้รอยเชื่อมที่มีสภาพสมบูรณ์นั้นต้องมีขนาดเส้นผ่านศูนย์กลางของรอยเชื่อมมากกว่า 3.5 mm ซึ่งกำหนดให้เป็น Label : 0, รอยเชื่อมที่มีสภาพสมบูรณ์นั้นต้องมีขนาดเส้นผ่านศูนย์กลางของรอยเชื่อมมากกว่า 3.5 mm และเกิดการระเบิดซึ่งกำหนดให้เป็น Label : 1 และ รอยเชื่อมที่มีสภาพสมบูรณ์นั้นต้องมีขนาดเส้นผ่านศูนย์กลางของรอยเชื่อมน้อยกว่า 3.5 mm ซึ่งกำหนดให้เป็น Label : 2 โดยขนาดเส้นผ่านศูนย์กลางที่ได้้นั้นมาจากการวัดด้วยเครื่องมือ UT ดังรูปที่ 3.14



รูปที่ 3.14 การระบุประเภทข้อมูล (a) สภาพสมบูรณ์ (b) เกิดการแตกตัว (c) สภาพไม่สมบูรณ์

3.5.5 การเตรียมข้อมูล (Data preparing)

ในขั้นตอนนี้ เราจะนำชุดข้อมูลทั้งหมด 410 ชุด (ตัวอย่างชุดข้อมูลดิบดังแสดงในตารางที่ 3.4) มาสุ่มแบ่งออกเป็นสองชุด โดยชุดแรกประกอบด้วยข้อมูล 274 ชุด เพื่อใช้สร้างแบบจำลองการเรียนรู้ของเครื่อง ส่วนชุดที่สองประกอบด้วยข้อมูล 136 ชุด (หรือหนึ่งในสามของทั้งหมด) เพื่อใช้ตรวจสอบแบบจำลองด้วยข้อมูลที่แบบจำลองไม่เคยเห็น โดยที่มาของชุดข้อมูลทั้งหมด 410 ชุดดังแสดงในตารางที่ 3.5

ตารางที่ 3.4 ตารางข้อมูลที่ได้จากกระบวนการเชื่อมและการวัดขนาดด้วย UT

No	Name	Station	Program	Time	Parameter Time	UT (mm)	Label
1	8Y025WC05_Prog1_20230707_141015_1-2	8Y025WC05	Prog1	7/7/2023 14:10	7/7/2023 14:10	0	2
2	8Y025WC05_Prog1_20230707_141736_2-2	8Y025WC05	Prog1	7/7/2023 14:17	7/7/2023 14:17	2.05	2
3	8Y025WC05_Prog1_20230707_142223_3-2	8Y025WC05	Prog1	7/7/2023 14:22	7/7/2023 14:22	8.88	0
4	8Y025WC05_Prog1_20230707_142422_4-2	8Y025WC05	Prog1	7/7/2023 14:24	7/7/2023 14:24	3.17	2
5	8Y025WC05_Prog1_20230707_142553_5-2	8Y025WC05	Prog1	7/7/2023 14:25	7/7/2023 14:25	5.42	0
6	8Y025WC05_Prog1_20230707_142710_6-2	8Y025WC05	Prog1	7/7/2023 14:27	7/7/2023 14:27	5.96	0
7	8Y025WC05_Prog1_20230707_142827_7-2	8Y025WC05	Prog1	7/7/2023 14:28	7/7/2023 14:28	5.48	1
8	8Y025WC05_Prog1_20230707_142959_8-2	8Y025WC05	Prog1	7/7/2023 14:29	7/7/2023 14:29	5.55	1
9	8Y025WC05_Prog1_20230707_143126_9-3	8Y025WC05	Prog1	7/7/2023 14:31	7/7/2023 14:31	5.67	0
10	8Y025WC05_Prog1_20230707_143439_10-2	8Y025WC05	Prog1	7/7/2023 14:34	7/7/2023 14:34	2.05	2
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
410	8Y025WC05_Prog1_20230716_162641_A49-1	8Y025WC05	Prog1	7/16/2023 16:26	7/16/2023 16:26	6.19	1



ตารางที่ 3.5 การกำหนดระดับของการจัดประเภท

Class level	Weld quality	Level condition	Dataset	
			Training	Unseen
Class 0	Satisfy	Nugget size > 3.5 mm	163	81
Class 1	Expulsion	Nugget size > 3.5 mm	44	22
		& Expulsion		
Class 2	Cold weld	Nugget size < 3.5 mm	67	33

3.5.6 การเลือกคุณลักษณะ (Feature Extraction)

ในการดึงข้อมูลจากหุ่นยนต์เชื่อม เราสามารถดึงข้อมูลจากคอมพิวเตอร์ควบคุมการเชื่อม ในรูปแบบ RUI และแปลงเป็นไฟล์ CSV โดยใช้ Python หลังจากแปลงข้อมูลแล้วแล้ว ในงานวิจัยได้เลือกข้อมูลที่ต้องการ ได้แก่ วันที่และเวลาเริ่มกระบวนการ, แรงดันไฟฟ้า (V), กระแสไฟฟ้า (I), พลังงานที่ใช้ในกระบวนการเชื่อม (BEnergy), ความร้อนที่เกิดขึ้นในกระบวนการเชื่อม (BPmax) และเวลาที่ใช้ในกระบวนการเชื่อม (Weldtime) นอกจากนี้ยังมีค่าแฟกเตอร์กระแสไฟฟ้า (Ifactor) และ แฟกเตอร์แรงดันไฟฟ้า (Vfactor) ที่ได้มาจากหม้อแปลงไฟฟ้าพร้อมด้วยพารามิเตอร์ที่คำนวณ เช่น ค่าความร้อน การใช้ค่าแรงดันไฟฟ้าและกระแสไฟฟ้า เราสามารถคำนวณค่าความต้านทานตามกฎของโอห์ม ซึ่งระบุว่า I แปรผกผันตรงกับ V และแปรผกผันกับความต้านทาน I ความสัมพันธ์ระหว่าง V, I และ R แสดงอยู่ในสมการที่ (3.1)

$$R = \frac{V}{I} \quad (3.1)$$


ในกระบวนการเชื่อม RSW กฎข้อที่หนึ่งของจูลส์แสดงให้เห็นถึงความสัมพันธ์ระหว่างความร้อนที่เกิดขึ้นและกระแสไฟฟ้าที่ไหลผ่านตัวนำ ที่นี่ Q แทนค่าความร้อน และ T แทนเวลา ตามที่แสดงในสมการที่ (3.2)

$$Q = I^2RT \quad (3.2)$$

พลังงานทั้งหมด I ที่ใช้ในกระบวนการเชื่อมจะวัดด้วยความต้านทานคำนวณได้จากการหาค่าผลคูณของ V และ I ตลอดเวลาในการเชื่อม (t) ตามที่แสดงในสมการที่ (3.3) การคำนวณนี้แตกต่างจาก Benergy ซึ่งไม่รวมค่าที่สูงที่สุดในจุดสุดท้ายบนกราฟ (รูปที่ 3.13)

$$E = \int_0^T V(t) \times I(t) dt \quad (3.3)$$

ค่าแรงดันไฟฟ้า, กระแสไฟฟ้า และความต้านทานถูกนำไปพล็อตกราฟตามเวลาที่ใช้ในกระบวนการเชื่อม จากกราฟที่ได้แสดงในรูปที่ 3.13 มีการคำนวณสถิติต่าง ๆ เพื่อใช้เป็นพารามิเตอร์ในชุดข้อมูลที่ใช้สร้างโมเดล พารามิเตอร์เหล่านี้ประกอบด้วยค่าเฉลี่ยของ 5 ms แรก, ค่าเฉลี่ยของ 5 ms สุดท้าย, ค่าสูงสุดหลังจาก 5 ms แรก, ค่าต่ำสุดหลังจาก 5 ms แรก, ค่าเฉลี่ยทั้งหมด, ผลรวมทั้งหมด และค่าสุดท้ายของกราฟ ชุดข้อมูลหนึ่งชุดที่ได้จาก WT สอดคล้องกับจุดเชื่อมต่อหนึ่งจุดบนพื้นด้านหน้า/ด้านหลัง มีพารามิเตอร์ทั้งหมด 31 พารามิเตอร์ แต่พารามิเตอร์ใดบ้างที่สามารถใช้ในการสร้างโมเดลได้ แม้ว่าทุกพารามิเตอร์จะเกี่ยวข้องกับกระบวนการ RSW แต่จำเป็นต้องทดสอบและวิเคราะห์ความสัมพันธ์ระหว่างตัวแปรอิสระและตัวแปรตาม วิธีที่เราใช้คือ ANOVA แบบทางเดียว โดยตัวแปรคือตัวแปรกลุ่มข้อมูลที่ถูกจำแนกออกเป็นระดับต่าง ๆ และตัวแปรตามคือพารามิเตอร์ทั้ง 31 พารามิเตอร์ที่ถูกรวบรวม



รูปที่ 3.15 ตัวอย่างการวิเคราะห์แผนภาพกล่องของพารามิเตอร์ตัวอย่างหกตัวในแต่ละระดับคุณภาพการเชื่อม

ในกระบวนการทดสอบ เราจะตั้งสมมติฐานดังนี้:

สมมติฐานว่าง (H_0): ค่าเฉลี่ยของชุดข้อมูลในแต่ละระดับของคุณภาพการเชื่อมไม่แตกต่างกัน

สมมติฐานทางเลือก (H_1): ค่าเฉลี่ยของชุดข้อมูลในแต่ละระดับของคุณภาพการเชื่อมแตกต่างกัน

เราได้ตั้งระดับความเชื่อมั่นที่ 0.05 หรือช่วงความเชื่อมั่น 95% ผลการวิเคราะห์ค่าเฉลี่ยของชุดข้อมูลในทุกระดับของคุณภาพการเชื่อมที่มีค่า P-value มากกว่า 0.05 หมายความว่ายอมรับ H_0 ซึ่งบ่งชี้ว่าความแปรปรวนของชุดข้อมูลในแต่ละกลุ่มอย่างน้อยสองกลุ่มเหมือนกัน ดังนั้นจึงจะไม่ถูกพิจารณา รูปที่ 3.15 แสดงผลการวิเคราะห์ชุดข้อมูลสำหรับแต่ละระดับของคุณภาพการเชื่อมในรูปแบบแผนภาพกล่อง เมื่อเปรียบเทียบกับผลการวิเคราะห์ ANOVA แบบทางเดียวตามที่แสดงในตารางที่ 3.6 โดยใช้พารามิเตอร์หกตัวเป็นตัวอย่าง จากพารามิเตอร์ทั้งหมด 31 ตัว ผลสรุปจากการวิเคราะห์พบว่าพารามิเตอร์ 2 ตัว ได้แก่ BWear และ R1 จะถูกตัดออก ทำให้เหลือพารามิเตอร์ทั้งหมด 29 ตัวเพื่อใช้สร้างโมเดลต่อไปตามที่แสดงในตารางที่ 3.7

ตารางที่ 3.6 การวิเคราะห์ความแตกต่างของพารามิเตอร์ (ช่วงความเชื่อมั่น 95%)

No.	Parameter	P-value	Significant
1	BWear	0.47115	No
2	R1	0.28364	No
3	Rh	0.10312	Yes
4	Vall	0.04702	Yes
5	Weldtime	0.02935	Yes
6	V2	0.01424	Yes
7	Call	0.00321	Yes
8	Rall	0.00126	Yes
9	C2	0.00006	Yes
10	R2	0	Yes
11	BEnergy	0	Yes
12	RE	0	Yes
13	Ra	0	Yes
14	R	0	Yes
15	Rl	0	Yes
16	Valst	0	Yes
17	Cl	0	Yes
18	Vl	0	Yes
19	C1	0	Yes

ตารางที่ 3.6 การวิเคราะห์ความแตกต่างของพารามิเตอร์ (ช่วงความเชื่อมั่น 95%) (ต่อ)

No.	Parameter	P-value	Significant
20	Q	0	Yes
21	V1	0	Yes
22	BPmax	0	Yes
23	Va	0	Yes
24	Clast	0	Yes
25	Ca	0	Yes
26	Vfactor	0	Yes
27	Vh	0	Yes
28	Ifactor	0	Yes
29	Ch	0	Yes
30	BSplash	0	Yes
31	Spatter	0	

ตารางที่ 3.7 ตัวแปรสำหรับการฝึกอบรมโมเดล

Parameter	Unit	Meaning description
R	m Ω	Resistance (from equation (3.1))
Q	J	RSW heat (from equation (3.2))
E	J/s	Energy (from equation (3.3))
Ifactor	—	Current factor of MF inverter
Vfactor	—	Voltage factor of MF inverter
BEnergy	J/s	Energy using during spot welding
BPmax	J	Heat during spot welding
Weldtime	ms	Weld time
Spatter	—	Status *(0, 1) of BSplash
C1	kA	Average current first 5 ms
C2	kA	Average current last 5 ms
Ca	kA	Average current
Call	kA	Sum current

ตารางที่ 3.7 ตัวแปรสำหรับการฝึกอบรมโมเดล (ต่อ)

Parameter	Unit	Meaning description
V1	V	Average voltage first 5 ms
V2	V	Average voltage last 5 ms
Va	V	Average voltage
Vall	V	Sum voltage
R1	m Ω	Average resistance first 5 ms
R2	m Ω	Average resistance last 5 ms
Ra	m Ω	Average resistance
Rall	m Ω	Sum resistance
Ch	kA	High peak current after 5 ms
Cl	kA	Low peak current after 5 ms
Vh	V	High peak voltage after 5 ms
Vl	V	Low peak voltage after 5 ms
Rh	m Ω	High peak resistance after 5 ms
Rl	m Ω	Low peak resistance after 5 ms
Clast	kA	Last value of current


3.5.7 การสร้างแบบจำลองด้วยการเรียนรู้ของเครื่องจักรและการเรียนรู้เชิงลึก (Machine learning and Deep learning model)

ชุดข้อมูลที่ใช้สร้างแบบจำลอง (274 ชุด) ถูกแบ่งแบบสุ่มออกเป็นสองส่วน โดยใช้ข้อมูล 80% สำหรับการฝึกอบรมแบบจำลองและอีก 20% สำหรับการทดสอบความแม่นยำของแบบจำลอง จากนั้นเราจะเลือกแบบจำลองที่ดีที่สุดจากอัลกอริทึมห้าแบบได้แก่ ANN, CNN, LSTM, RF และ XGBoost โดยพิจารณาจากเงื่อนไขที่ป้องกันการ Overfitting ของแบบจำลองจากการปรับแต่งไฮเปอร์พารามิเตอร์ ดังแสดงในตารางที่ 3.8

3.5.8 การปรับจูนแบบจำลอง (Modeling tuning)

แบบจำลองที่ดีที่สุดจะถูกนำมาทำนายด้วยข้อมูลที่ไม่เคยเห็นมาก่อน (136 ชุด) เพื่อให้มั่นใจว่าความแม่นยำของแบบจำลองจะไม่ต่ำกว่า 90% หากความแม่นยำต่ำกว่าเกณฑ์นี้ กระบวนการจะย้อนกลับไปยังขั้นตอนการเตรียมข้อมูลเพื่อนำข้อมูลทั้ง 410 ชุดมาสุ่มแจกจ่ายใหม่อีกครั้งดังรูปที่ 3.16 ทั้งนี้ เนื่องจากมีข้อมูลจำกัดสำหรับการสร้างแบบจำลอง เราจำเป็นต้องใช้ข้อมูลเดิม

ในการสุ่มแบ่งเพื่อหาวิธีการสร้างแบบจำลองที่ดีที่สุดจากการแบ่งข้อมูลอย่างเหมาะสม นอกจากนี้ยังใช้เทคนิควิศวกรรมคุณลักษณะ (Feature Engineering - FE) เพื่อลดคุณลักษณะที่ไม่สำคัญออก โดยใช้คะแนนความสำคัญของคุณลักษณะ (Feature Importance - FI) เพื่อเพิ่มประสิทธิภาพของแบบจำลอง ในกระบวนการนี้จะทำซ้ำไปเรื่อย ๆ จนกว่าแบบจำลองที่ดีที่สุดและสมบูรณ์ที่สุดจะพร้อมใช้งานจริง เช่น ในสายการผลิต



รูปที่ 3.16 การวิเคราะห์เปรียบเทียบของโมเดล XGBoost ก่อนและหลังการคัดเลือกคุณลักษณะโดยใช้คะแนน FI-score

ตารางที่ 3.8 การเปรียบเทียบไฮเปอร์พารามิเตอร์ระหว่างโมเดลอัลกอริทึมที่ใช้ค่าปริยายและค่าที่ปรับแต่งแล้ว

Algorithm	Hyperparameter	Default	Tuned
ANN	output_size	1	1
	hidden_sizes	[128,64]	[1024, 512, 256, 128, 64, 32, 16, 8, 4]
	batch_size	32	32
	epochs	10	2000
	lr	0.001	0.0005
	dropout_rate	0	0.2
	Optimizer		Adam
	Criterion		CrossEntropyLoss
CNN	output_size	1	1
	batch_size	32	32
	epochs	10	1000
	lr	0.001	0.0001
	dropout_rate	0.1	0.1
	random_state	10	10
LSTM	output_size	3	1
	batch_size	32	32
	epochs	10	100
	random_state	42	37
	learning_rate	0.001	0.0001
RF	N_estimators	100	12
	Max_depth	1	11
	Min_samples_split	2	2
	Min_samples_leaf	1	10
	N_jobs	-1	-1
	Test_size	0.2	0.2
	Random_state1	0	7
	Random_state2	1	48
XGB	Max_depth	None	8
	N_estimators	100	5
	Random_state1	None	5
	Random_state2	1	96
	tree_method	None	GPU Hist

3.5.9 การปรับใช้และการปรับปรุงแบบจำลอง (Development and update)

จากขั้นตอนนี้ แบบจำลองจะถูกพัฒนาในแต่ละวันโดยอิงตามข้อมูลจริง เริ่มแรกผู้ทำการวิจัยจะทดสอบแบบจำลองโดยใช้ข้อมูลจากสายการผลิตจำนวน 12 ชุดในหนึ่งวัน ข้อมูลทั้ง 12 ชุดจะผ่านกระบวนการเตรียมข้อมูลเช่นเดียวกับชุดข้อมูลการทดลองที่กล่าวไว้ก่อนหน้านี้ ข้อมูลเหล่านี้จะถูกนำมาใช้ในการทำนายและบันทึกผลเพื่อติดตามการเก็บข้อมูลต่อไป ข้อมูลทั้ง 12 ชุดจะถูกรวมเข้ากับข้อมูลฝึกอบรมเดิมที่มีอยู่ 274 ชุด ทำให้มีข้อมูลรวมทั้งหมด 286 ชุด ซึ่งจะถูกนำไปฝึกอบรมใหม่เพื่อให้แบบจำลองได้เรียนรู้เพิ่มเติม กระบวนการนี้จะดำเนินต่อไปเป็นเวลา 10 วัน จนได้ข้อมูลจากสายการผลิตจำนวน 120 ชุด รวมข้อมูลทั้งหมดเป็น 394 ชุด จากนั้นจะบันทึกข้อมูลสุดท้ายและสรุปผล โดยชุดข้อมูลที่ได้นั้นจะถูกนำมาใช้ในการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ดังแผนรูปที่ 3.17 ซึ่งแสดงถึงภาพรวมกระบวนการเชิงอัลกอริทึมที่ใช้ในงานวิจัย

3.6 การใช้งานในสายการผลิต

การใช้ในสายการผลิต การปรับปรุงการทำงานของหุ่นยนต์เชื่อมเป็นสิ่งสำคัญเพื่อเพิ่มประสิทธิภาพและความแม่นยำในการผลิต การทดสอบนี้ได้มุ่งเน้นการพัฒนาระบบที่ช่วยให้หุ่นยนต์เชื่อมทำงานได้อย่างมีประสิทธิภาพและรวดเร็วมากขึ้น โดยใช้เทคโนโลยีการประมวลผลข้อมูลและการเชื่อมต่อในระบบเครือข่ายดังนี้:

1) การรับค่าการประมวลผลการเชื่อม


ในกระบวนการนี้, หุ่นยนต์เชื่อมจะได้รับค่าพารามิเตอร์จากกระบวนการเชื่อมต่าง ๆ เช่น ความเร็วในการเชื่อม, อุณหภูมิของเครื่องมือเชื่อม, หรือแรงดันที่ใช้ในระหว่างการเชื่อม เพื่อให้หุ่นยนต์สามารถปรับการทำงานได้ตามค่าพารามิเตอร์เหล่านี้ การรับข้อมูลนี้ทำให้หุ่นยนต์สามารถทำงานได้แม่นยำมากยิ่งขึ้น โดยการปรับค่าการเชื่อมตามสถานการณ์ที่เกิดขึ้นในขณะนั้น เช่น การแก้ไขปัญหาหรือการปรับความเร็วในการเชื่อมให้เหมาะสมกับวัสดุหรือสภาพแวดล้อมที่เปลี่ยนไป

2) การเชื่อมต่อเครือข่าย Ethernet

เพื่อให้สามารถประมวลผลและส่งข้อมูลได้อย่างรวดเร็วและมีประสิทธิภาพ การเชื่อมต่อหุ่นยนต์กับระบบคอมพิวเตอร์จะผ่านเครือข่าย Ethernet ซึ่งช่วยให้การสื่อสารระหว่างหุ่นยนต์กับคอมพิวเตอร์และอุปกรณ์อื่น ๆ ในระบบการผลิตสามารถส่งข้อมูลที่ได้จากการทำนายการเชื่อมที่ได้จากคอมพิวเตอร์ไปยังหุ่นยนต์ เพื่อปรับกระบวนการเชื่อมในขั้นตอนถัดไปได้ทันที

3) การส่งข้อมูลการทำนายให้กับหุ่นยนต์หลังการเชื่อม

หลังจากที่หุ่นยนต์ได้ทำการเชื่อมเสร็จสิ้น ระบบคอมพิวเตอร์จะทำการประมวลผลข้อมูลคุณภาพของรอยเชื่อมแล้วส่งข้อมูลเหล่านี้กลับไปยังหุ่นยนต์ ผ่านเครือข่าย Ethernet ซึ่งหุ่นยนต์จะใช้ข้อมูลที่ได้รับมาในการปรับปรุงกระบวนการทำงานในครั้งต่อไป ในกรณีที่ระบบพบว่ารอยเชื่อมมี




รูปที่ 3.17 ภาพรวมกระบวนการเชิงอัลกอริทึม

ปัญหา หุ่นยนต์จะทำการเชื่อมซ้ำตำแหน่งเดิมอีกครั้ง เพื่อให้ขนาดของรอยเชื่อมนั้นผ่านมาตรฐานที่กำหนดไว้

4) ผลลัพธ์จากการทดสอบ

จากการทดสอบในสายการผลิตนี้ พบว่า การปรับปรุงการทำงานของหุ่นยนต์เชื่อมทำให้ประสิทธิภาพในการผลิตเพิ่มขึ้นอย่างมีนัยสำคัญ โดยลดข้อผิดพลาดจากการเชื่อมที่ไม่ได้มาตรฐาน นอกจากนี้ยังสามารถปรับปรุงกระบวนการทำงานในแต่ละขั้นตอนได้ตามข้อมูลที่ได้รับจากการทำนายหลังการเชื่อม ทำให้การผลิตมีความยืดหยุ่นและสามารถปรับเปลี่ยนตามสถานการณ์หรือข้อกำหนดที่เปลี่ยนแปลงได้ดีขึ้น

ในการทำงานของหุ่นยนต์นั้นได้มีการกำหนดการทำงานของหุ่นยนต์เพิ่มขึ้นจากเดิมซึ่งแสดงดังรูปที่ 3.18 โดยทำการเปรียบเทียบการทำงานของหุ่นยนต์ก่อนและหลังการใช้การเรียนรู้ของเครื่องในการทำนายคุณภาพของรอยเชื่อม



รูปที่ 3.18 แผนภาพเปรียบเทียบการทำงานของหุ่นยนต์ก่อน-หลังการใช้การเรียนรู้ของเครื่องในการทำนายคุณภาพของรอยเชื่อม

บทที่ 4

ผลการศึกษาและการวิเคราะห์ผล

4.1 บทนำ

งานวิจัยนี้นำเสนอวิธีการเชิงทำนายสำหรับการประเมินคุณภาพของรอยเชื่อมในกระบวนการผลิต โดยเฉพาะในอุตสาหกรรมการผลิตตัวถังรถยนต์ ซึ่งรอยเชื่อมต้องมีความทนทานและคุณภาพสูง เพื่อตอบสนองต่อมาตรฐานด้านความปลอดภัยและความแข็งแรง วิธีการที่นำเสนอให้ความสำคัญกับปัจจัยหลักในกระบวนการเชื่อม ได้แก่ กระแสไฟฟ้าและระยะเวลาที่ใช้ในกระบวนการ โดยมุ่งเน้นไปที่การวิเคราะห์พารามิเตอร์เหล่านี้เพื่อตรวจสอบและทำนายคุณภาพของรอยเชื่อมในสภาพการผลิตจริง

ในการวิจัยนี้ ข้อมูลที่เก็บได้จากกระบวนการผลิตจริงจะถูกนำมาใช้เป็นข้อมูลป้อนเข้าของโมเดลเชิงทำนาย ซึ่งจะช่วยให้สามารถวิเคราะห์ความสัมพันธ์ระหว่างพารามิเตอร์ต่าง ๆ และคุณภาพของรอยเชื่อมได้อย่างแม่นยำมากยิ่งขึ้น นอกจากนี้ การใช้ข้อมูลที่เกิดขึ้นจริงในกระบวนการผลิตยังช่วยให้โมเดลสามารถปรับตัวให้เข้ากับสภาพแวดล้อมการผลิตที่เปลี่ยนแปลงไปได้อย่างเหมาะสม ซึ่งเป็นการเพิ่มประสิทธิภาพของการทำนายโดยการใช้ข้อมูลป้อนกลับจากกระบวนการผลิตในการปรับปรุงโมเดลอย่างต่อเนื่อง


เพื่อประเมินประสิทธิภาพของวิธีการทำนายที่เสนอ งานวิจัยนี้จะเปรียบเทียบโมเดลการเรียนรู้เชิงลึกจำนวน 5 โมเดล ซึ่งเป็นโมเดลที่มีการใช้อย่างแพร่หลายในงานด้านการทำนายคุณภาพ โดยแต่ละโมเดลจะถูกทดสอบและวิเคราะห์ภายใต้เงื่อนไขการทดสอบที่กำหนด เพื่อให้เห็นถึงความสามารถในการทำนายคุณภาพของรอยเชื่อมในระดับที่สอดคล้องกับข้อกำหนดทางอุตสาหกรรม การเปรียบเทียบนี้ไม่เพียงช่วยในการค้นหาโมเดลที่มีประสิทธิภาพสูงสุด แต่ยังช่วยให้เข้าใจข้อจำกัดและจุดเด่นของแต่ละโมเดลในบริบทของกระบวนการผลิตตัวถังรถยนต์

เป้าหมายหลักของงานวิจัยนี้คือการปรับปรุงความแม่นยำของระบบการทำนายคุณภาพรอยเชื่อมในกระบวนการผลิตตัวถังรถยนต์ การพัฒนาระบบทำนายที่มีความแม่นยำสูงจะไม่เพียงช่วยลดข้อบกพร่องที่อาจเกิดขึ้นในกระบวนการผลิต แต่ยังช่วยเสริมสร้างความมั่นใจในคุณภาพของรอยเชื่อม ซึ่งมีผลต่อความแข็งแรงและความปลอดภัยของผลิตภัณฑ์โดยรวม การประยุกต์ใช้โมเดลทำนายคุณภาพในระบบควบคุมคุณภาพเชิงทำนายนี้จึงถือเป็นการสร้างนวัตกรรมที่สามารถปรับปรุงกระบวนการผลิตในอุตสาหกรรมยานยนต์ให้มีประสิทธิภาพและความน่าเชื่อถือสูงขึ้น

4.2 การประเมินและเปรียบเทียบโมเดล

4.2.1 โครงข่ายประสาทเทียม (Artificial Neural Networks, ANN)


ANN ถูกเลือกใช้เนื่องจากความสามารถในการเรียนรู้รูปแบบที่ซับซ้อนในข้อมูล โดยเฉพาะการคาดการณ์ผลลัพธ์จากความสัมพันธ์ที่ไม่เป็นเชิงเส้น (Nonlinear Relationships) ซึ่งมักพบในกระบวนการผลิตที่ซับซ้อน เช่น การเชื่อม RSW ชุดข้อมูลที่ใช้สำหรับการฝึก ANN ประกอบด้วยข้อมูลเชิงโครงสร้าง (Structured Data) เช่น พารามิเตอร์การเชื่อม และสภาพแวดล้อม รวมถึงข้อมูลที่ไม่เป็นโครงสร้าง (Unstructured Data) เช่น ภาพถ่ายและการอ่านค่าจากเซนเซอร์ โดยมีคุณลักษณะที่ครอบคลุมทั้งคุณสมบัติที่คงที่ เช่น ประเภทของวัสดุ และคุณสมบัติที่เปลี่ยนแปลงตามเวลา เช่น กระแส, แรงกด, เวลา การเตรียมข้อมูลล่วงหน้า (Preprocessing) รวมถึงการปรับขนาด (Scaling) และการทำให้เป็นมาตรฐาน (Normalization) เพื่อให้ข้อมูลที่ป้อนเข้าสู่โครงข่ายมีมาตราส่วนที่เทียบเคียงกัน ซึ่งช่วยเพิ่มประสิทธิภาพในการฝึก การปรับพารามิเตอร์ (Hyperparameter Tuning) รวมถึงการกำหนดจำนวนเลเยอร์ที่ซ่อนอยู่ (Hidden Layers) จำนวนโหนดต่อเลเยอร์ อัตราการเรียนรู้ (Learning Rate) และฟังก์ชันกระตุ้น (Activation Functions) เช่น ReLU ในเลเยอร์ที่ซ่อน และ Softmax ในเลเยอร์เอาต์พุต เทคนิคการป้องกัน Overfitting เช่น Dropout และ L2 Regularization ถูกนำมาใช้ อัลกอริทึม Backpropagation และตัวปรับน้ำหนัก Adam Optimizer



รูปที่ 4.1 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ตั้งต้นของโมเดล


ถูกใช้ในการปรับน้ำหนักเพื่อมิให้ค่าฟังก์ชันการสูญเสีย (Loss Function) แบบวนซ้ำ ทำให้ ANN สามารถประมวลผลสถานการณ์ต่าง ๆ ของคุณภาพการเชื่อมต่อได้ดีและมีความแม่นยำสูง

ในงานวิจัยนี้ได้ทำการทดลองเปรียบเทียบประสิทธิภาพของโมเดลที่ใช้พารามิเตอร์ตั้งต้นกับโมเดลที่ใช้พารามิเตอร์ที่ได้รับการปรับแต่งให้เหมาะสมกับชุดข้อมูล โดยในตารางที่ 3.8 แสดงรายละเอียดการเปรียบเทียบพารามิเตอร์ทั้งสองแบบ และรูปที่ 4.1 แสดงค่าความแม่นยำของโมเดลเมื่อใช้พารามิเตอร์ตั้งต้น ซึ่งมีค่าความแม่นยำอยู่ที่ 90% ในขณะที่ค่าความแม่นยำของโมเดลที่ใช้พารามิเตอร์ปรับแต่งเพิ่มขึ้นเป็น 94% ดังแสดงในรูปที่ 4.2




รูปที่ 4.2 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ปรับแต่งของโมเดล

เมื่อพิจารณาค่า Receiver Operating Characteristic (ROC) ของโมเดล พบว่าโมเดลที่ใช้พารามิเตอร์ปรับแต่งซึ่งแสดงในเส้นสีแดงมีค่า ROC สูงถึง 0.973 ซึ่งมากกว่าโมเดลที่ใช้พารามิเตอร์ตั้งต้นซึ่งแสดงในเส้นสีน้ำเงินมีค่า ROC อยู่ที่ 0.873 ดังแสดงในรูปที่ 4.3 แสดงให้เห็นว่าการปรับแต่งพารามิเตอร์สามารถเพิ่มประสิทธิภาพของโมเดลได้อย่างชัดเจน



รูปที่ 4.3 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์




รูปที่ 4.4 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์


ผล Classification Report ของ ANN ได้ดังรูปที่ 4.4 เมื่อพิจารณาจากงานดี (Satisfy) จะได้ค่า Precision 90.1%, ซึ่งให้ค่าประสิทธิภาพของโมเดลที่ค่อนข้างดี, พิจารณาจากงานที่ต้องปรับปรุง (Explosion) ได้ค่า Precision 100% แต่เมื่อพิจารณาจากงานเสีย (Cold Weld) จะได้ค่า Precision เพียง 78.8% สำหรับพารามิเตอร์ตั้งต้น ซึ่งเป็นค่าประสิทธิภาพของโมเดลที่ค่อนข้างต่ำเนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี มีอัตราสูง แม้ว่า accuracy สูงถึง 90% เปรียบเทียบกับพารามิเตอร์แบบปรับแต่ง เมื่อพิจารณา satisfy จะได้ค่า Precision ลดลงที่ 95.1% ยังคงถือว่าค่าประสิทธิภาพของโมเดลค่อนข้างดี พิจารณาจาก Explosion ได้ค่า Precision 100% แต่เมื่อพิจารณาจาก Cold Weld จะได้ค่า Precision เพิ่มขึ้นเป็น 84.8% ซึ่งถือว่ามีประสิทธิภาพพอใช้ แต่เนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี มีอัตราสูง แม้ว่า accuracy สูงถึง 94%

4.2.2 โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolution Neural Networks, CNN)

CNN ถูกนำมาใช้ในการจัดการข้อมูลเชิงภาพและข้อมูลเชิงพื้นที่ ซึ่งจำเป็นในการวิเคราะห์ข้อบกพร่องบนพื้นผิวหรือรูปทรงของการเชื่อมที่บ่งชี้ถึงคุณภาพการเชื่อม การตั้งค่า CNN มุ่งเน้นการเรียนรู้ลำดับชั้นเชิงพื้นที่ในภาพผ่านเลเยอร์คอนโวลูชัน ซึ่งจะสร้างแผนที่คุณลักษณะ (Feature Maps) ที่สะท้อนคุณลักษณะของคุณภาพการเชื่อม การปรับพารามิเตอร์ของ CNN รวมถึงการกำหนดขนาดของฟิลเตอร์ จำนวนฟิลเตอร์ต่อเลเยอร์ อัตราการเรียนรู้ (Learning Rate) และค่า Dropout เพื่อเพิ่มประสิทธิภาพ ขั้นตอนการทำ Pooling ถูกเพิ่มหลังแต่ละเลเยอร์คอนโวลูชันเพื่อลดมิติของคุณลักษณะ (Feature Dimensions) ซึ่งช่วยป้องกัน Overfitting และเพิ่มความเร็วในการคำนวณ ด้วยการแชร์พารามิเตอร์และการเชื่อมต่อแบบท้องถิ่นในเลเยอร์คอนโวลูชัน CNN สามารถประมวลผลข้อมูลภาพที่มีมิติสูงได้อย่างมีประสิทธิภาพ และช่วยให้การจัดหมวดหมู่คุณภาพการเชื่อมมีความแม่นยำมากขึ้น




รูปที่ 4.5 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ตั้งต้นของโมเดล




รูปที่ 4.6 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ปรับแต่งของโมเดล

การทดลองเปรียบเทียบประสิทธิภาพของโมเดลที่ใช้พารามิเตอร์ตั้งต้นกับโมเดล CNN ที่ใช้พารามิเตอร์ที่ได้รับการปรับแต่งให้เหมาะสมกับชุดข้อมูล โดยในตารางที่ 3.8 แสดงรายละเอียดการเปรียบเทียบพารามิเตอร์ทั้งสองแบบ และรูปที่ 4.5 แสดงค่าความแม่นยำของโมเดลเมื่อใช้พารามิเตอร์ตั้งต้น ซึ่งมีค่าความแม่นยำอยู่ที่ 90% ในขณะที่ค่าความแม่นยำของโมเดลที่ใช้พารามิเตอร์ปรับแต่งเพิ่มขึ้นเป็น 94% ดังแสดงในรูปที่ 4.6



รูปที่ 4.7 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์

เมื่อพิจารณาค่า Receiver Operating Characteristic (ROC) ของโมเดล พบว่าโมเดลที่ใช้พารามิเตอร์ปรับแต่งซึ่งแสดงในเส้นสีแดงมีค่า ROC สูงถึง 0.969 ซึ่งมากกว่าโมเดลที่ใช้พารามิเตอร์ตั้งต้นซึ่งแสดงในเส้นสีน้ำเงินมีค่า ROC อยู่ที่ 0.941 ดังแสดงในรูปที่ 4.7 แสดงให้เห็นว่าการปรับแต่งพารามิเตอร์สามารถเพิ่มประสิทธิภาพของโมเดลเพิ่มขึ้นได้




รูปที่ 4.8 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์

ผล Classification Report ของ CNN ได้ดังรูปที่ 4.8 เมื่อพิจารณา Satisfy จะได้ค่า Precision 95.1%, ซึ่งให้ค่าประสิทธิภาพของโมเดลที่ค่อนข้างดี, พิจารณาจาก Expulsion ได้ค่า Precision 100% แต่เมื่อพิจารณาจากงานเสีย (Cold Weld) จะได้ค่า Precision เพียง 75.8% สำหรับพารามิเตอร์ตั้งต้น ซึ่งเป็นค่าประสิทธิภาพของโมเดลที่ค่อนข้างต่ำเนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี มีอัตราสูง แม้ว่า accuracy สูงถึง 90% เปรียบเทียบกับพารามิเตอร์แบบปรับแต่ง เมื่อพิจารณา satisfy จะได้ค่า Precision ลดลงที่ 93.8% ยังคงถือว่าค่าประสิทธิภาพของโมเดลค่อนข้างดี พิจารณาจาก Expulsion ได้ค่า Precision 100% แต่เมื่อพิจารณาจาก Cold Weld จะได้ค่า Precision เพิ่มขึ้นเป็น 87.9% ซึ่งถือว่ามีประสิทธิภาพพอใช้ เนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี มีอัตราสูง แม้ว่า accuracy สูงถึง 94%

4.2.3 โครงข่ายหน่วยความจำระยะยาว (Long Short-Term Memory, LSTM)

LSTM ถูกเลือกมาใช้เนื่องจากสามารถจำลองการพึ่งพาและแนวโน้มในข้อมูลแบบลำดับเวลา (Sequential Data) เช่น ข้อมูลเซนเซอร์ กระแสไฟ หรือแรงกดที่เปลี่ยนแปลงในระหว่างกระบวนการเชื่อม โมเดลนี้เหมาะสำหรับการจับแนวโน้มว่า การเปลี่ยนแปลงในรอบการเชื่อมก่อนหน้านี้ ส่งผลต่อคุณภาพการเชื่อมในปัจจุบันอย่างไร ชุดข้อมูลสำหรับ LSTM ประกอบด้วยลำดับ


เหตุการณ์ที่สะท้อนถึงลำดับขั้นตอนการเชื่อม โดยแต่ละเหตุการณ์ในลำดับจะมีค่าที่ประทับเวลา (Timestamped Value) การเตรียมข้อมูลล่วงหน้ารวมถึงการเติมลำดับ (Sequence Padding) ให้มีความยาวเท่ากัน และการทำให้เป็นมาตรฐาน (Normalization) เพื่อเพิ่มประสิทธิภาพในการเรียนรู้ของโมเดล การปรับพารามิเตอร์รวมถึงจำนวนหน่วย LSTM (LSTM Units) อัตราการเรียนรู้ (Learning Rate) และค่า Dropout กลไกในเซลล์ LSTM เช่น Gate การป้อนข้อมูล การลืม และการส่งออก ช่วยจัดการการไหลของข้อมูลอย่างเหมาะสม ทำให้โมเดลสามารถเก็บหรือทิ้งข้อมูลได้ตามความจำเป็น ช่วยป้องกันปัญหาการสูญเสย Gradient (Vanishing Gradient) อัลกอริทึม Adam Optimizer ถูกใช้ในการปรับน้ำหนัก และความลึกของ LSTM ถูกปรับเพื่อค้นหาโครงสร้างที่เหมาะสมที่สุดสำหรับการจับรูปแบบลำดับเวลาในการคาดการณ์คุณภาพการเชื่อม



รูปที่ 4.9 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ตั้งต้นของโมเดล


การทดลองเปรียบเทียบประสิทธิภาพของโมเดลที่ใช้พารามิเตอร์ตั้งต้นกับโมเดล LSTM ที่ใช้พารามิเตอร์ที่ได้รับการปรับแต่งให้เหมาะสมกับชุดข้อมูล โดยในตารางที่ 3.8 แสดงรายละเอียดการเปรียบเทียบพารามิเตอร์ทั้งสองแบบ และรูปที่ 4.9 แสดงค่าความแม่นยำของโมเดล

เมื่อใช้พารามิเตอร์ตั้งต้น ซึ่งมีค่าความแม่นยำอยู่ที่ 76.36% ในขณะที่ค่าความแม่นยำของโมเดลที่ใช้พารามิเตอร์ที่ได้รับการปรับแต่งเพิ่มขึ้นเป็น 92.65% ดังแสดงในรูปที่ 4.10




รูปที่ 4.10 ผลการเปรียบเทียบค่าความแม่นยำของข้อมูล Train-Test ด้วยพารามิเตอร์ปรับแต่งของโมเดล

เมื่อพิจารณาค่า Receiver Operating Characteristic (ROC) ของโมเดล พบว่าโมเดลที่ใช้พารามิเตอร์ปรับแต่งซึ่งแสดงในเส้นสีแดงมีค่า ROC สูงถึง 0.988 ซึ่งมากกว่าโมเดลที่ใช้พารามิเตอร์ตั้งต้นซึ่งแสดงในเส้นสีน้ำเงินมีค่า ROC อยู่ที่ 0.930 ดังแสดงในรูปที่ 4.11 แสดงให้เห็นว่าการปรับแต่งพารามิเตอร์สามารถเพิ่มประสิทธิภาพของโมเดลเพิ่มขึ้นได้



รูปที่ 4.11 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์




รูปที่ 4.12 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์

ผล Classification Report ของ LSTM ได้ดังรูปที่ 4.12 เมื่อพิจารณา Satisfy จะได้ค่า Precision 81.5%, ซึ่งให้ค่าประสิทธิภาพของโมเดลที่พอใช้, พิจารณาจาก Explosion ได้ค่า Precision 68.2% ซึ่งให้ค่าประสิทธิภาพของโมเดลที่ค่อนข้างต่ำ แต่เมื่อพิจารณาจาก Cold Weld

จะได้ค่า Precision เพียง 87.9% สำหรับพารามิเตอร์ตั้งต้น ซึ่งเป็นค่าประสิทธิภาพของโมเดลที่ค่อนข้างต่ำเนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี อีกทั้งยังทำนายของดีเป็นของเสียจำนวนมาก แม้ว่า accuracy สูงถึง 80% เปรียบเทียบกับพารามิเตอร์แบบปรับแต่ง เมื่อพิจารณา satisfy จะได้ค่า Precision เพิ่มขึ้นที่ 95.1% ยังคงถือว่าค่าประสิทธิภาพของโมเดลค่อนข้างดี พิจารณาจาก Explosion ได้ค่า Precision 100% แต่เมื่อพิจารณาจาก Cold Weld จะได้ค่า Precision เพิ่มขึ้นเป็น 87.9% ซึ่งถือว่ามีประสิทธิภาพพอใช้ เนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี มีอัตราสูง แม้ว่า accuracy สูงถึง 94%

4.2.4 ตัวจัดหมวดหมู่แบบป่าการตัดสินใจกลุ่ม (Random Forest Classifier, RFC)


RFC ถูกเลือกใช้เนื่องจากความทนทานในการจัดการกับชุดข้อมูลที่ซับซ้อนและมีมิติสูง รวมถึงมี Noise ซึ่งเป็นลักษณะทั่วไปในข้อมูลกระบวนการเชื่อม โมเดลนี้สามารถจัดการคุณลักษณะหลากหลายประเภท เช่น ข้อมูลตัวเลขและข้อมูลประเภทหมวดหมู่ (Categorical) ได้อย่างมีประสิทธิภาพ การเตรียมข้อมูลล่วงหน้ารวมถึงการจัดการค่าที่ขาดหาย (Missing Values) และการเข้ารหัสตัวแปรเชิงหมวดหมู่ด้วย One-Hot Encoding เพื่อให้ข้อมูลที่ป้อนเข้าสู่แต่ละต้นไม้มีคุณภาพ การปรับพารามิเตอร์ (Hyperparameter Tuning) เน้นที่จำนวนต้นไม้ในป่า (Number of Trees) ความลึกสูงสุดของต้นไม้ (Maximum Tree Depth) จำนวนตัวอย่างขั้นต่ำต่อใบ (Minimum Samples per Leaf) และจำนวนคุณลักษณะที่พิจารณาในแต่ละการแยก (Features per Split) โดยใช้ Grid Search เพื่อค้นหาค่าที่เหมาะสมที่สุด RFC รวมการคาดการณ์จากต้นไม้หลายต้นเพื่อให้ได้การจัดหมวดหมู่ที่ทนทานและเชื่อถือได้ ซึ่งมีประโยชน์อย่างยิ่งในการทำความเข้าใจปฏิสัมพันธ์ที่ซับซ้อนของคุณลักษณะในกระบวนการประเมินคุณภาพการเชื่อม



รูปที่ 4.13 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์

เมื่อพิจารณาค่า Receiver Operating Characteristic (ROC) ของโมเดล พบว่าโมเดลที่ใช้พารามิเตอร์ปรับแต่งซึ่งแสดงในเส้นสีแดงมีค่า ROC สูงถึง 0.976 ซึ่งมากกว่าโมเดลที่ใช้พารามิเตอร์ตั้งต้นซึ่งแสดงในเส้นสีน้ำเงินมีค่า ROC อยู่ที่ 0.857 ดังแสดงในรูปที่ 4.13 แสดงให้เห็นว่าการปรับแต่งพารามิเตอร์สามารถเพิ่มประสิทธิภาพของโมเดลเพิ่มขึ้นได้อย่างมาก

ผล Classification Report ของ RFC ได้ดังรูปที่ 4.14 เมื่อพิจารณา Satisfy จะได้ค่า Precision 97.5%, ซึ่งให้ค่าประสิทธิภาพของโมเดลที่สูง, พิจารณาจาก Explosion ได้ค่า Precision 0% ซึ่งให้ค่าประสิทธิภาพของโมเดลที่ไม่สามารถใช้งานได้ แต่เมื่อพิจารณาจาก Cold Weld จะได้ค่า Precision เพียง 69.7% สำหรับพารามิเตอร์ตั้งต้น ซึ่งเป็นค่าประสิทธิภาพของโมเดลที่ค่อนข้างต่ำเนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี อีกทั้งยังไม่สามารถทำนายของดีเป็นของเสียจำนวนมากในกรณี Explosion เปรียบเทียบกับพารามิเตอร์แบบปรับแต่ง เมื่อพิจารณา satisfy จะได้ค่า Precision ลดลงที่ 95.1% ยังคงถือว่าค่าประสิทธิภาพของโมเดลค่อนข้างดี พิจารณาจาก Explosion ได้ค่า Precision 100% แต่เมื่อพิจารณาจาก Cold Weld จะได้ค่า Precision เพิ่มขึ้นเป็น 81.8% ซึ่งถือว่ามีประสิทธิภาพพอใช้ เนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี มีอัตราสูงถึง 18.2%




รูปที่ 4.14 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์


4.2.5 ตัวจัดหมวดหมู่แบบการเพิ่ม Gradient ขั้นสูง (Extreme Gradient Boosting Classifier, XGBoost)

Extreme Gradient Boosting (XGBoost) ถูกเลือกใช้งานเนื่องจากประสิทธิภาพและความแม่นยำในการทำนายที่สูง เหมาะสมอย่างยิ่งสำหรับการจับความสัมพันธ์ที่ซับซ้อนระหว่างพารามิเตอร์ของการเชื่อมและปัจจัยสิ่งแวดล้อม โมเดลนี้ใช้เทคนิคการบูสต์แบบไล่ระดับขั้นสูงในการลดข้อผิดพลาดของการทำนายที่ละขั้นตอน ลักษณะของชุดข้อมูลประกอบด้วยคุณสมบัติหลากหลายประเภท ซึ่งทั้งหมดได้รับการประมวลผลล่วงหน้าผ่านกระบวนการทำให้อยู่ในช่วงมาตรฐาน (Normalization), การเข้ารหัส (Encoding) และการวิศวกรรมคุณลักษณะ (Feature Engineering) เพื่อเพิ่มความชัดเจนของสัญญาณและประสิทธิภาพของโมเดล การคัดเลือกคุณสมบัติ (Feature Selection) มีบทบาทสำคัญในการลดมิติของข้อมูลให้เหลือเฉพาะคุณสมบัติที่มีศักยภาพในการทำนายมากที่สุด ช่วยเพิ่มทั้งความแม่นยำและความสามารถในการตีความของโมเดล

การปรับค่าพารามิเตอร์ (Hyperparameter Tuning) ของ XGBoost รวมถึงการปรับอัตราการเรียนรู้ (Learning Rate), ความลึกสูงสุดของต้นไม้ (Maximum Tree Depth), อัตราการสุ่มตัวอย่าง (Subsampling Ratio) และพารามิเตอร์การปรับค่า L1 และ L2 เพื่อควบคุมการเกิด Overfitting โดยใช้วิธีการค้นหาแบบกริด (Grid Search) และการค้นหาแบบสุ่ม (Random Search) เพื่อปรับแต่งพารามิเตอร์เหล่านี้ให้เหมาะสม ประสิทธิภาพของโมเดลยังได้รับการเพิ่มขึ้นด้วยการตัดกิ่งต้นไม้ (Tree Pruning) เพื่อลดความซับซ้อนที่เกินไป และการประมวลผลแบบขนาน (Parallel Processing) เพื่อเร่งความเร็วในการฝึกโมเดล ด้วยความสามารถในการปรับตัวและความแม่นยำของ XGBoost โมเดลนี้สามารถทำนายรูปแบบที่แสดงคุณภาพของการเชื่อมได้อย่างแม่นยำ และมีประสิทธิภาพเหนือกว่าโมเดลอื่น ๆ อย่างชัดเจนในแง่ของค่า Precision และ Recall



รูปที่ 4.15 ผลการเปรียบเทียบค่า ROC ก่อน-หลังการปรับแต่งพารามิเตอร์



รูปที่ 4.16 ผลการเปรียบเทียบ Confusion matrix ก่อน-หลังการปรับแต่งพารามิเตอร์

เมื่อพิจารณาค่า Receiver Operating Characteristic (ROC) ของโมเดล พบว่าโมเดลที่ใช้พารามิเตอร์ปรับแต่งซึ่งแสดงในเส้นสีแดงมีค่า ROC สูงถึง 0.997 ซึ่งมากกว่าโมเดลที่ใช้พารามิเตอร์ตั้งต้นซึ่งแสดงในเส้นสีน้ำเงินมีค่า ROC อยู่ที่ 1.000 ดังแสดงในรูปที่ 4.15 แสดงให้เห็นว่าพารามิเตอร์แบบตั้งต้นนั้นเป็นไปได้ว่าเกิด Overfitting ในกระบวนการ แต่หลังจากการปรับแต่งพารามิเตอร์แล้วสามารถลดการเกิด Overfitting ได้ อย่างไรก็ตามการประเมินประสิทธิภาพของโมเดลนั้นยังต้องดูในส่วนของ Confusion matrix ประกอบด้วย

ผล Classification Report ของ XGBoost ได้ดังรูปที่ 4.16 เมื่อพิจารณา Satisfy จะได้ค่า Precision 95.1%, ซึ่งให้ค่าประสิทธิภาพของโมเดลที่สูง, พิจารณาจาก Explosion ได้ค่า Precision 100% แต่เมื่อพิจารณาจาก Cold Weld จะได้ค่า Precision เพียง 81.8% สำหรับพารามิเตอร์ตั้งต้น ซึ่งเป็นค่าประสิทธิภาพของโมเดลที่ค่อนข้างพอใช้เนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี เปรียบเทียบกับพารามิเตอร์แบบปรับแต่ง เมื่อพิจารณา Satisfy จะได้ค่า Precision ลดลงที่ 93.8% ยังคงถือว่าค่าประสิทธิภาพของโมเดลค่อนข้างดี พิจารณาจาก Explosion ได้ค่า Precision 100% แต่เมื่อพิจารณาจาก Cold Weld จะได้ค่า Precision เพิ่มขึ้นเป็น 97.0% ซึ่งถือว่าประสิทธิภาพที่สูง เนื่องจากความผิดพลาดในการทำนายงานเสียว่าเป็นงานดี มีอัตราต่ำ

เพียง 3.0% โมเดลที่มีการปรับแต่งพารามิเตอร์นี้มีความสามารถในการทำนายงานเสียได้ค่อนข้างดี และมีความผิดพลาดในการทำนายงานดีว่าเป็นงานเสียค่อนข้างต่ำ

การศึกษานี้นำเสนอการสร้างแบบจำลองการทำนายคุณภาพรอยเชื่อมในกระบวนการผลิตตัวถังรถยนต์ โดยแบ่งคุณภาพของรอยเชื่อมออกเป็นสามระดับ ได้แก่ Satisfy, Explosion และ Cold Weld โมเดลที่นำมาใช้ในการทำนายนี้ประกอบด้วยอัลกอริทึมการเรียนรู้ของเครื่องสามแบบ ได้แก่ LSTM, RF, และ XGBoost และอัลกอริทึมการเรียนรู้เชิงลึกอีกสองแบบ คือ ANN และ CNN โดยได้ทำการปรับแต่งไฮเปอร์พารามิเตอร์ของแต่ละโมเดลเพื่อเพิ่มประสิทธิภาพและนำมาเปรียบเทียบกัน ดังแสดงในรูปที่ 4.16

ในการวิเคราะห์ประสิทธิภาพของโมเดลจากกราฟ ROC AUC ถูกนำมาใช้เพื่อประเมินความสามารถในการจำแนกประเภทคุณภาพของรอยเชื่อม เส้นโค้ง ROC แสดงถึงการปรับสมดุลระหว่าง True Positive Rate และ False Positive Rate จากรูปที่ 4.17 จะเห็นว่าแบบจำลอง XGBoost, LSTM, RF และ CNN แสดงประสิทธิภาพการจำแนกที่ยอดเยี่ยม โดยค่า AUC ของแต่ละโมเดลอยู่ที่ 0.998, 0.990, 0.979 และ 0.967 ตามลำดับ ในขณะที่แบบจำลอง ANN มีค่า AUC ต่ำกว่าที่ 0.859 ซึ่งบ่งชี้ถึงประสิทธิภาพในการจำแนกที่ต่ำกว่าเมื่อเปรียบเทียบกับโมเดลอื่น ๆ

แม้ว่าค่า AUC จะเป็นตัวชี้วัดที่มีประโยชน์ในการประเมินประสิทธิภาพการจำแนก แต่การเลือกโมเดลที่ดีที่สุดจำเป็นต้องพิจารณาตัวชี้วัดเสริมอื่น ๆ เพื่อให้เห็นภาพรวมที่ครอบคลุมมากขึ้น ดังที่แสดงในตารางที่ 4.1 ตัวชี้วัดเชิงลึก เช่น Precision, Recall, F1-score และ Accuracy ถูกนำมาใช้เพื่อประเมินประสิทธิภาพของแต่ละโมเดลในมิติที่แตกต่างกัน รวมถึงการทดสอบในชุดข้อมูลฝึกอบรม, ชุดข้อมูลทดสอบ และชุดข้อมูลที่ไม่เคยพบมาก่อน


มหาวิทยาลัยเทคโนโลยีสุรนารี

ตารางที่ 4.1 การเปรียบเทียบตัวชี้วัดประสิทธิภาพระหว่าง 5 โมเดลอัลกอริทึม

	ANN		CNN		LSTM		RF		XGB	
	Default	Tuned	Default	Tuned	Default	Tuned	Default	Tuned	Default	Tuned
Precision	72.73	98.17	69.09	94.52	81.30	92.50	55.88	92.24	85.81	93.33
Recall	72.73	90.91	69.09	92.73	76.36	92.73	63.64	90.91	84.02	98.15
F1	72.73	91.91	69.09	93.38	76.99	92.37	57.68	91.91	84.45	95.34
Train ACC	72.76	93.55	72.60	92.73	84.02	98.17	77.17	88.76	100.00	99.54
Test ACC	72.73	89.55	69.90	92.73	80.88	92.73	63.64	90.21	81.82	96.36
Unseen ACC	72.06	91.11	69.85	92.73	76.36	92.65	75.00	89.42	92.65	95.59


จากข้อมูลในตารางที่ 4.1 พบว่าการใช้ไฮเปอร์พารามิเตอร์เริ่มต้นสามารถให้ผลลัพธ์ที่ดีได้ แต่ประสิทธิภาพของโมเดลสามารถพัฒนาได้อย่างมีนัยสำคัญด้วยการปรับแต่งไฮเปอร์พารามิเตอร์ การใช้ไฮเปอร์พารามิเตอร์เริ่มต้นอาจนำไปสู่ Overfitting ในบางกรณี เช่น แบบจำลอง XGBoost ที่แสดงความแม่นยำในชุดฝึกอบรมถึง 100% แต่ลดลงในชุดข้อมูลทดสอบและชุดข้อมูลที่ไม่เคยพบ การปรับแต่งไฮเปอร์พารามิเตอร์ช่วยให้แบบจำลองมีความสมดุลมากขึ้น โดยลดปัญหา Overfitting และเพิ่มความสามารถในการทำนายได้ดีในทุกชุดข้อมูล

โดยสรุป การประเมินทั้งจากกราฟ ROC และตัวชี้วัดในตารางชี้ให้เห็นว่า XGBoost และ LSTM เป็นแบบจำลองที่มีประสิทธิภาพสูงที่สุดในการทำนายคุณภาพของรอยเชื่อม โดยเฉพาะเมื่อมีการปรับแต่งไฮเปอร์พารามิเตอร์ อย่างไรก็ตาม แบบจำลองอื่น ๆ เช่น RF และ CNN ก็แสดงให้เห็นถึงศักยภาพที่ดีในการทำนายเช่นกัน แม้ว่า ANN จะมีค่า AUC ต่ำกว่า แต่ยังสามารถปรับปรุงประสิทธิภาพได้เมื่อปรับแต่งไฮเปอร์พารามิเตอร์ ค่า ROC AUC ที่ได้จากการเปรียบเทียบนี้ช่วยให้สามารถเลือกแบบจำลองที่เหมาะสมที่สุดสำหรับการทำนายคุณภาพรอยเชื่อมได้อย่างมีประสิทธิภาพมากขึ้น



รูปที่ 4.17 การวิเคราะห์เปรียบเทียบ ROC และ AUC-ROC สำหรับโมเดลอัลกอริทึมทั้ง 5 โมเดล

การศึกษานี้ยังได้นำเสนอการปรับเปลี่ยนไฮเปอร์พารามิเตอร์เพื่อให้เกิดประสิทธิภาพสูงที่สุดในการทำนายคุณภาพรอยเชื่อม โดยพบว่าโมเดล XGBoost และ LSTM มีประสิทธิภาพที่ยอดเยี่ยมเมื่อมีการปรับเปลี่ยนไฮเปอร์พารามิเตอร์อย่างเหมาะสม ในขณะที่โมเดล ANN แม้จะมีค่า AUC ต่ำกว่า แต่ก็สามารถปรับปรุงประสิทธิภาพด้วยการปรับแต่งไฮเปอร์พารามิเตอร์เพิ่มเติมได้เช่นกัน การวิเคราะห์นี้ช่วยให้เข้าใจถึงข้อจำกัดและจุดเด่นของแต่ละโมเดล และสามารถนำไปประยุกต์ใช้ในกระบวนการผลิตจริง




รูปที่ 4.18 (a) ANN confusion matrix, (b) CNN confusion matrix, (c) LSTM confusion matrix, (d) RF confusion matrix, (e) XGBoost confusion matrix

ผลการทดลองแสดงให้เห็นว่า XGBoost เป็นอัลกอริทึมที่ให้ประสิทธิภาพดีที่สุดเมื่อเปรียบเทียบกับโมเดลอื่น ๆ โดยการประเมินประสิทธิภาพผ่าน Confusion Matrix ของข้อมูลที่ไม่เคยถูกใช้งานมาก่อน โดยมีอัตราการทำนายผิดพลาดในกรณีทำงานเสียถูกระบุว่าเป็นงานดีเพียง 3.0% และอัตราการทำนายผิดพลาดในกรณีทำงานดีถูกระบุว่าเป็นงานเสียเพียง 6.2% ซึ่งแสดงถึงความน่าเชื่อถือและศักยภาพในการพัฒนาเพิ่มเติมให้เหมาะสมสำหรับการนำไปใช้ในกระบวนการผลิตจริง

4.3 Performance Improvement

ในสายการผลิตตัวถังรถยนต์นั้นประกอบไปด้วยหลาย ๆ สถานีเพื่อทำให้การผลิตนั้นสามารถทำได้อย่างรวดเร็ว ในงานวิจัยนี้นั้นได้ทำการเลือกสถานีเชื่อมระหว่างพื้นด้านหน้าและด้านหลังรถยนต์ประกอบไปด้วยหุ่นยนต์ที่ใช้ในการเชื่อมทั้งหมด 4 ตัว โดยทำการเลือกเพียงสองตัวที่มีความสมมาตรกัน โดยหุ่นยนต์ 1 ตัวนั้นจะทำการเชื่อมทั้งหมด 12 จุด ภายในเวลา 90 วินาที โดยระยะห่างของเวลาระหว่างจุดหนึ่งไปยังจุดหนึ่งที่น้อยที่สุดนั้นอยู่ที่ 3 วินาที หมายถึงการทำนายผลสำหรับการใช้สายการผลิตนั้น จำเป็นต้องใช้เวลาน้อยกว่า 3 วินาที (เป็นเวลาที่หุ่นยนต์ใช้เวลาในการเคลื่อนที่จากจุดหนึ่งไปยังจุดถัดไป) เพื่อให้หุ่นยนต์นั้นหยุดการทำงานเมื่อพบข้อผิดพลาดของคุณภาพก่อนที่จะทำการเชื่อมในจุดถัดไป


จากการทดลองที่ผ่านมาเห็นว่า XGBoost เป็นโมเดลที่ดีที่สุดในการทำนายคุณภาพของรอยเชื่อม เพื่อให้โมเดลมีประสิทธิภาพที่ดีขึ้นจึง ได้มีการเทคนิควิศวกรรมคุณลักษณะ (Feature Engineering - FE) จากภาพที่ 3.16 เพื่อลดคุณลักษณะที่ไม่สำคัญออก โดยใช้คะแนนความสำคัญของคุณลักษณะ (Feature Importance - FI) เพื่อเพิ่มประสิทธิภาพของแบบจำลอง โดยเริ่มต้นกระบวนการนั้นมีจำนวนคุณลักษณะ ทั้งหมด 32 คุณลักษณะ ผู้ทการวิจัยจึงได้ทำการตัดคุณลักษณะที่ซ้ำกันออก ทำให้เหลือคุณลักษณะเฉพาะที่ 29 คุณลักษณะ จากนั้นจึงนำมาเรียงลำดับคะแนนความสำคัญคุณลักษณะ (FI) ซึ่งสามารถจำแนกออกได้ดังรูปที่ 4.18



รูปที่ 4.19 การคัดเลือกคุณลักษณะโดยใช้คะแนน FI-score

จากรูปที่ 4.19 ได้ทำการเรียงลำดับคะแนนความสำคัญคุณลักษณะโดยเรียงจากมากไปหาน้อย พบว่ามีคุณลักษณะที่ไม่มีความสำคัญ 9 คุณลักษณะ จึงได้ทำการตัดออกเพื่อทำการทดสอบการเรียนรู้ของ XGBoost อีกครั้งด้วยคุณลักษณะที่เหลือ 20 คุณลักษณะด้วยวิธีการ brute-force จากการลดคุณลักษณะลงนั้นทำให้คุณภาพงานเสียถูกระบุว่าเป็นงานดีเพียง 9.1% และมีอัตราการทำนายผิดพลาดในกรณีที่งานดีถูกระบุว่าเป็นงานเสียลดลงจาก 7.4% เหลือ 6.2% ดังรูปที่ 4.20

จากนั้นจึงได้ทำการลดคุณลักษณะของโมเดลลงเหลือ 19 คุณลักษณะ พบว่าสามารถเพิ่มความสามารถในการทำนายผลได้เล็กน้อย โดยผลลัพธ์ที่ได้นั้นพบว่าอัตราการทำนายผิดพลาดในกรณีทำงานดีถูกระบุว่าเป็นงานเสียที่ 6.2% เท่ากับ 20 คุณลักษณะ อีกทั้งยังสามารถเพิ่มความเร็วในการทำนายผลได้ โดยใช้เวลาในการทำนายผลลดลงจาก 38 ms เหลือเพียง 33 ms จากนั้นจึงใช้วิธีการ




รูปที่ 4.20 (a) 29 คุณลักษณะ, (b) 20 คุณลักษณะ, (c) 19 คุณลักษณะ, (d) 18 คุณลักษณะ, (e) 17 คุณลักษณะ, (f) 16 คุณลักษณะ

เดียวกันในการลดจำนวนคุณลักษณะลงเหลือ 18 คุณลักษณะ พบว่า สามารถเพิ่มความสามารถในการทำนายผลได้เล็กน้อย โดยผลลัพธ์ที่ได้นั้นพบว่าอัตราการทำนายผิดพลาดในกรณีทำงานดีถูกระบุว่าเป็นงานเสียลดลงจาก 6.2% เหลือ 3.7% แต่ในกรณีการทำนายงานเสียนั้นยังคงเท่าเดิมที่ 6.2% เมื่อเทียบกับ 19 คุณลักษณะ จากนั้นจึงใช้วิธีการเดียวกันในการลดจำนวนคุณลักษณะลงเหลือ 17 คุณลักษณะ โดยผลลัพธ์ที่ได้นั้นพบว่าอัตราการทำนายผิดพลาดในกรณีทำงานเสียถูกระบุว่าเป็นงานดีลดลงจาก 9.1% เหลือ 3.0% แต่ในกรณีการทำนายงานดีนั้นยังคงเท่าเดิมที่ 3.7% เมื่อเทียบกับ 18 คุณลักษณะ แต่เมื่อลดจำนวนคุณลักษณะลงเหลือ 16 คุณลักษณะ โดยผลลัพธ์ที่ได้นั้นพบว่าอัตราการทำนายผิดพลาดในกรณีทำงานเสียถูกระบุว่าเป็นงานดีเพิ่มขึ้นจาก 3.0% เป็น 6.1% แต่ในกรณีการทำนายงานดีนั้นยังคงเท่าเดิมที่ 3.7%

ความแม่นยำลดลงเหลือเพียง 94.12% แต่สามารถลดเวลาในการทำนายผลลงได้เหลือ 33 ms ในการวิจัยจึงได้ทำการลดจำนวนคุณลักษณะ ลงเหลือ 17 คุณลักษณะ พบว่าสามารถทำให้ความแม่นยำเพิ่มขึ้นเป็น 97.06% ดังรูปที่ 4.21 อีกทั้งยังใช้เวลาเท่ากับการทดลองก่อนหน้านี้ที่ 33 ms จึงได้ทำการทดลองลดจำนวนคุณลักษณะลง พบว่าไม่สามารถลดเวลาในการทำนายผลลงได้ และยังทำให้ประสิทธิภาพของโมเดลต่ำลง อีกทั้งยังพบว่าอัตราการทำนายผิดพลาดในกรณีที่งานเสียถูกระบุว่าเป็นงานดีเพิ่มจาก 3.0% เป็น 6.1%

สรุปได้ว่าค่าที่เหมาะสมที่สุดสำหรับการใช้งานในสายการผลิตคือจำนวนคุณลักษณะที่ 17 คุณลักษณะ เนื่องจากได้ค่าความแม่นยำสูงสุดและใช้เวลาในการทำนายผลน้อยที่สุด ที่ความแม่นยำ 97.06% ของชุดข้อมูล Unseen ด้วยเวลา 33 ms ต่อจุดเชื่อม โดยยังคงประสิทธิภาพในการทำนายของเสียที่ 97.0% และยังสามารถเพิ่มประสิทธิภาพในการทำนายของดีถึง 96.3%



รูปที่ 4.21 XGBoost confusion matrix หลังจากลดจำนวนคุณลักษณะ เหลือ 17 คุณลักษณะ

ตารางที่ 4.2 การวิเคราะห์เชิงเปรียบเทียบของโมเดล XGBoost ก่อนและหลังการคัดเลือกคุณสมบัติ ด้วยคะแนน F1-score

No. of feature	Precision	Recall	F1	Train ACC	Test ACC	Unseen ACC	Prediction time Avg. 10 time(ms)
29	0.9630	0.9907	0.9757	99.09	98.18	93.38	38
20	0.9091	0.9722	0.9329	99.54	94.55	94.12	33
19	0.9091	0.9722	0.9329	99.54	96.36	95.59	33
18	0.9491	0.9491	0.9491	99.09	96.36	95.59	33
17	0.9630	0.9907	0.9757	99.09	98.18	97.06	33
16	0.9333	0.9815	0.9534	99.09	96.36	96.32	34
15	0.9630	0.9907	0.9757	99.09	98.18	93.38	34
14	0.9630	0.9907	0.9757	99.09	98.18	93.38	33


จากตารางที่ 4.2 จะเห็นได้ว่าการใช้คุณลักษณะที่ 29 นั้นมีความแม่นยำที่ 95.59% และใช้เวลาในการทำนายผลสำหรับ 1 จุดอยู่ที่ 38 ms แต่เมื่อทำการลดจำนวนคุณลักษณะลง เหลือ 20 feature ทำให้ความแม่นยำลดลงเหลือเพียง 94.12% แต่สามารถลดเวลาในการทำนายผลลงได้เหลือ 33 ms ในการวิจัยจึงได้ทำการลดจำนวนคุณลักษณะจนเหลือ 17 คุณลักษณะ พบว่าสามารถทำให้ความแม่นยำเพิ่มขึ้นเป็น 97.06% ดังรูปที่ 4.21 อีกทั้งยังใช้เวลาเท่ากับการทดลองก่อนหน้านี้ที่ 33 ms จึงได้ทำการทดลองลดจำนวน feature ลง พบว่าไม่สามารถลดเวลาในการทำนายผลลงได้ และยังทำให้ประสิทธิภาพของโมเดลต่ำลง อีกทั้งยังพบว่าอัตราการทำนายผิดพลาดในกรณีทำงานเสียถูกระบุว่าเป็นงานดีเพิ่มจาก 3.0% เป็น 6.1%

สรุปได้ว่าค่าที่เหมาะสมที่สุดสำหรับการใช้งานในสายการผลิตคือจำนวนคุณลักษณะที่ 17 คุณลักษณะ เนื่องจากได้ค่าความแม่นยำสูงสุดและใช้เวลาในการทำนายผลน้อยที่สุด ที่ความแม่นยำ 97.06% ของชุดข้อมูล Unseen ด้วยเวลา 33 ms ต่อจุดเชื่อม โดยยังคงประสิทธิภาพในการทำนายของเสียที่ 97.0% และยังสามารถเพิ่มประสิทธิภาพในการทำนายของดีถึง 96.3%

4.4 ผลการทดสอบจากการใช้งานจริง

จากการทดสอบในการใช้งานจริงนั้น ได้ทำการติดตั้งคอมพิวเตอร์สำหรับการรับค่าและประมวลผลบนเครือข่ายเดียวกับเครื่องจักร โดยคอมพิวเตอร์จะทำการเก็บข้อมูลของรอยเชื่อม ณ ขณะนั้นเพื่อแปลงข้อมูลของรอยเชื่อมที่ได้ในรูปแบบชนิดข้อมูลแบบแถวเดียวในรูปแบบ CSV สำหรับ

รอยเชื่อมที่เกิดขึ้นทั้งหมดและทำการทำนายผลของรอยเชื่อมที่ได้กำหนดไว้ในเวลาเดียวกัน จากนั้นจึงทำการเก็บค่าผลของการทำนายที่ได้ในรูปแบบ CSV และ ทำการแสดงผลในรูปแบบของข้อความ ซึ่งในการใช้งานจริงนั้นระบบจะใช้เวลาในการประมวลผลมากกว่าเวลาที่ได้ทำการทดสอบถึง 2-5 เท่าดังรูปที่ 4.22 แต่ยังไม่เพียงพอกับการใช้งานจริงในการผลิต ดังนั้นเพื่อป้องกันการเกิดปัญหาในการใช้เวลาในการทำนายผลมากเกินไป ผู้การวิจัยจึงต้องออกแบบโปรแกรมเพื่อย้ายข้อมูลที่ทำนายผลแล้วนั้นไปเก็บในโฟลเดอร์สำรองข้อมูลเพื่อให้เวลาในการทำนายผลยังคงน้อยกว่า 150 ms ในทุกๆสัปดาห์ของการผลิต



```

Select mwp5 - Shortcut
No prediction
The time of execution of 8X015WC05_Prog131_20241006_161609 is : 63 ms
No prediction
The time of execution of 8X015WC06_Prog133_20241006_161621 is : 62 ms
No prediction
The time of execution of 8X020WC04_Prog113_20241006_161542 is : 66 ms
No prediction
The time of execution of 8Y025WC02_Prog101_20241006_161620 is : 47 ms
Result prediction : Satisfy
No prediction
The time of execution of 8Y025WC05_Prog101_20241006_161618 is : 109 ms
No prediction
The time of execution of 8X015WC05_Prog136_20241006_161627 is : 68 ms
No prediction
The time of execution of 8X020WC03_Prog101_20241006_161637 is : 62 ms
No prediction
The time of execution of 8X020WC04_Prog103_20241006_161645 is : 78 ms
No prediction
The time of execution of 8Y025WC01_Prog112_20241006_161649 is : 62 ms
Result prediction : Satisfy
No prediction
The time of execution of 8Y025WC05_Prog107_20241006_161628 is : 109 ms
No prediction
No prediction
The time of execution of 8Y025WC05_Prog116_20241006_161643 is : 78 ms
No prediction
The time of execution of 8Y025WC06_Prog117_20241006_161646 is : 62 ms
No prediction
The time of execution of 8X020WC03_Prog109_20241006_161651 is : 78 ms
No prediction
  
```

รูปที่ 4.22 เวลาที่ใช้ในการทำนายผลต่อ 1 รอยเชื่อม

ตารางที่ 4.3 ตัวอย่างของเสียที่ได้จากผลการทำนายจากสายการผลิต

No.	Name	PGnumber	Time	Predicted
8241	8Y025WC05_Prog107_20240819_231008	107	8/19/2024 23:10	Cold Weld
8444	8Y025WC05_Prog101_20240820_013458	101	8/20/2024 1:34	Cold Weld
8459	8Y025WC05_Prog101_20240820_014744	101	8/20/2024 1:47	Cold Weld
8461	8Y025WC05_Prog113_20240820_014800	113	8/20/2024 1:48	Cold Weld
8462	8Y025WC05_Prog101_20240820_014932	101	8/20/2024 1:49	Cold Weld
8490	8Y025WC05_Prog101_20240820_030840	101	8/20/2024 3:08	Cold Weld
8496	8Y025WC05_Prog101_20240820_031020	101	8/20/2024 3:10	Cold Weld
8500	8Y025WC05_Prog101_20240820_031318	101	8/20/2024 3:13	Cold Weld
⋮	⋮	⋮	⋮	⋮
24617	8Y025WC05_Prog113_20241011_160855	113	10/11/2024 16:08	Cold Weld

ในงานวิจัยนี้ ได้ทำการทดสอบการใช้งานจริงในสายการผลิตเป็นเวลามากกว่า 14 เดือน เป็นจำนวนการผลิตมากกว่า 100,000 คัน นับเป็นจำนวนรอยเชื่อมที่ผ่านการทำนายผลมากกว่า 800,000 รอยเชื่อม สามารถตรวจพบรอยเชื่อมที่มีปัญหา 343 จุด รวมทั้งหมด 247 คัน ดังตารางที่ 4.3 และรอยเชื่อมที่ต้องปรับปรุง 2,543 จุด ในระหว่างวันที่ 4 กันยายน 2566 – 10 พฤศจิกายน 2567 โดยทั้ง 2 ปัญหาที่พบนั้นไม่สามารถตรวจพบได้จากกระบวนการตรวจสอบตามปกติ ทำให้จำนวนของเสียที่เกิดขึ้นบนสายการผลิตนั้นลดจำนวนการเกิดขึ้นแบบต่อเนื่องได้ จากการทดสอบการใช้งานบนสายการผลิตจริงนั้นพบว่าระบบยังมีความผิดพลาดในส่วนของการทำนายผลที่ยอมรับได้โดยการทำนายของดีเป็นของเสียจำนวน 32 จุด รวมทั้งหมด 21 คัน โดยคิดเป็น 0.09% ของจำนวนของเสีย

4.5 สรุป

งานวิจัยนี้ได้พัฒนาระบบการทำนายคุณภาพรอยเชื่อมในสายการผลิตตัวถังรถยนต์ที่สามารถทำงานได้อย่างแม่นยำและทันต่อกระบวนการผลิตที่มีความเร็วสูง โดยระบบสามารถตรวจจับข้อผิดพลาดของรอยเชื่อมได้อย่างแม่นยำถึง 97.06% สำหรับ Unseen Data ด้วยการลดจำนวนคุณลักษณะ คงเหลือ 17 คุณลักษณะ ซึ่งช่วยลดเวลาในการทำนายผลเหลือเพียง 33 ms ต่อรอยเชื่อม ในช่วงแรก แต่เมื่อข้อมูลมีปริมาณมากกว่า 25,000 จุดในโพลเดอร์เก็บข้อมูลจะทำให้เวลาในกระบวนการทำนายผลใช้เวลาเพิ่มขึ้นถึง 5 เท่า (>150 ms) ทั้งนี้ ระบบยังสามารถหยุดการทำงานของหุ่นยนต์เชื่อมได้เมื่อพบความผิดพลาด เพื่อป้องกันข้อบกพร่องเพิ่มเติมในกระบวนการผลิต

4.5.1 ผลการทดสอบในสายการผลิตจริง

ระบบได้ผ่านการใช้งานจริงในสายการผลิตมากกว่า 14 เดือน สำหรับการผลิตมากกว่า 100,000 คัน และรอยเชื่อมมากกว่า 800,000 จุด โดยสามารถตรวจพบรอยเชื่อมที่มีปัญหาได้ 343 จุด และจุดที่ต้องปรับปรุงเพิ่มเติม 2,543 จุด ซึ่งปัญหาเหล่านี้ไม่สามารถตรวจพบได้จากการตรวจสอบตามปกติ ทั้งนี้ การใช้งานระบบช่วยลดปริมาณของเสียในสายการผลิตอย่างมีนัยสำคัญ

4.5.2 จุดเด่นของระบบ

1) ความแม่นยำสูง

ระบบนี้ได้รับการพัฒนาให้มีความแม่นยำในการทำนายสูงถึง 97.1% ซึ่งเกินเป้าหมายที่กำหนดไว้ นั้นหมายความว่าระบบสามารถทำนายคุณภาพรอยเชื่อมได้อย่างถูกต้องในสถานการณ์การผลิตจริง ความแม่นยำนี้มีผลโดยตรงต่อการลดความสูญเสียจากข้อบกพร่องและการปรับปรุงคุณภาพของผลิตภัณฑ์ให้อยู่ในระดับมาตรฐานสากล

2) ประสิทธิภาพสูงในสายการผลิต

ด้วยการออกแบบระบบให้สามารถทำนายได้ในเวลาอันสั้น ทำให้ระบบนี้สามารถตอบสนองความต้องการของสายการผลิตที่มีความเร็วสูงได้อย่างเหมาะสม การทำงานแบบเรียลไทม์ช่วยให้โรงงานสามารถบริหารจัดการเวลาและทรัพยากรได้อย่างมีประสิทธิภาพ ส่งผลให้ต้นทุนการผลิตลดลงและการส่งมอบสินค้าทำได้ทันเวลา

3) ลดของเสียและเพิ่มความปลอดภัย

ระบบนี้มีฟังก์ชันในการแจ้งเตือนเมื่อพบข้อผิดพลาดในกระบวนการผลิต รวมถึงความสามารถในการหยุดการทำงานในกรณีที่เกิดข้อผิดพลาดร้ายแรง เพื่อป้องกันการผลิตสินค้าที่มีคุณภาพต่ำออกสู่ตลาด นอกจากนี้ยังช่วยลดปริมาณของเสียจากกระบวนการผลิต ทำให้เกิดการใช้ทรัพยากรอย่างคุ้มค่าและลดผลกระทบต่อสิ่งแวดล้อม

4) การประยุกต์ใช้งานจริง

ระบบได้รับการทดสอบและออกแบบให้สามารถใช้งานได้จริงในโรงงานอุตสาหกรรม ความสามารถในการทำงานร่วมกับอุปกรณ์ที่มีอยู่และการปรับตัวเข้ากับเงื่อนไขต่าง ๆ ในกระบวนการผลิต ทำให้ระบบนี้สามารถช่วยลดข้อผิดพลาดที่เกิดจากปัจจัยมนุษย์ และเพิ่มความสม่ำเสมอในคุณภาพของผลิตภัณฑ์

4.5.3 ข้อจำกัดและโอกาสพัฒนาในอนาคต

แม้ระบบจะมีความแม่นยำและตอบโจทย์การใช้งานในสายการผลิตจริง แต่ยังพบข้อผิดพลาดเล็กน้อยในการทำนาย เช่น การทำนายของดีเป็นของเสีย (False Positive) ในอัตราที่รับได้ 0.09% ซึ่งเปิดโอกาสให้พัฒนาต่อเพื่อเพิ่มความแม่นยำและลดข้อผิดพลาดในอนาคต

บทที่ 5

สรุปผลและข้อเสนอแนะ

5.1 สรุป

งานวิจัยฉบับนี้มีวัตถุประสงค์เพื่อศึกษาอัลกอริทึมการประมวลผลและตรวจหาข้อบกพร่องในกระบวนการเชื่อมด้านทานไฟฟ้า (RSW) เพื่อเพิ่มประสิทธิภาพกระบวนการตรวจสอบคุณภาพในอุตสาหกรรมยานยนต์ โดยมุ่งพัฒนาอุปกรณ์ประมวลผลข้อมูลที่ได้จากกระบวนการผลิตมาประยุกต์ใช้ร่วมกับเทคนิคปัญญาประดิษฐ์แบบการเรียนรู้เชิงลึก (Deep Learning) ซึ่งสามารถระบุข้อบกพร่องในการเชื่อมได้แบบเรียลไทม์โดยอัตโนมัติ งานวิจัยนี้ยังรวมถึงการออกแบบและพัฒนาเพื่อใช้ในกระบวนการควบคุมคุณภาพของจุดเชื่อม โดยใช้เทคนิคทางปัญญาประดิษฐ์ในการแยกแยะและจัดประเภทข้อบกพร่องที่เกิดขึ้นในกระบวนการเชื่อม

ผลการศึกษามีประสิทธิภาพสูงถึง 97.06% ซึ่งสามารถตรวจพบและจำแนกข้อบกพร่องของการเชื่อมในแบบเรียลไทม์สำหรับวัสดุเชื่อมที่มีความหนา 2 ชั้น โดยจำแนกคุณภาพการเชื่อมออกเป็น 3 ระดับ กระบวนการจำลองนี้ใกล้เคียงกับขั้นตอนการตรวจสอบคุณภาพในสภาพแวดล้อมการผลิตจริง นอกจากนี้ยังใช้ข้อมูลที่ได้จากการผลิตเพื่อปรับปรุงอัลกอริทึมที่ใช้ในการระบุข้อบกพร่องของการเชื่อมอีกด้วย

สรุปได้ว่า อัลกอริทึมการประมวลผลและตรวจหาข้อบกพร่องในกระบวนการเชื่อมต้นแบบที่พัฒนาขึ้นจากงานวิจัยนี้สามารถนำไปประยุกต์ใช้ในกระบวนการผลิตจริงได้อย่างมีประสิทธิภาพ ช่วยลดปัญหาความผิดพลาดที่เกิดจากกระบวนการ ข้อจำกัดทางกายภาพ และเพิ่มความสามารถในการตรวจสอบข้อบกพร่องที่เกิดการเชื่อมเพื่อลดจำนวนของเสียที่เกิดขึ้นในกระบวนการผลิต

5.2 ข้อเสนอแนะ

5.2.1 ข้อเสนอแนะจากการวิจัยในส่วนการเก็บข้อมูล

การออกแบบระบบเก็บข้อมูลในส่วนของการผลิตตัวถังรถยนต์นั้น การเชื่อมตัวถังเป็นส่วนสำคัญที่สุดในกระบวนการที่เป็นการกำหนดมาตรฐานและคุณภาพของการผลิต ผู้วิจัยใช้วิธีการเก็บค่าโดยตรงจากคอมพิวเตอร์ควบคุมการเชื่อม ซึ่งมีขีดความสามารถในการเก็บค่าได้เพียงแค่ค่ากระแสไฟฟ้า และ แรงดันไฟฟ้า ที่เวลาทุก ๆ 1 มิลลิวินาทีเท่านั้น โดยเป็นการใช้ทรัพยากรที่มีอยู่เดิมอย่างมีประสิทธิภาพสูงสุด หากต้องการเก็บค่า กระแสไฟฟ้า และ แรงดันไฟฟ้า ให้ได้ละเอียดมาก

ขึ้น หรือสามารถที่จะเก็บค่าตัวแปรอื่นเพิ่มขึ้น อาจจำเป็นต้องมีการเปลี่ยนอุปกรณ์หรือติดตั้งตัววัดสัญญาณ เช่น แรงกดจากหุ่นยนต์ เพื่อให้มีความเหมาะสมในการใช้งานในอุตสาหกรรมมากขึ้น

5.2.2 ข้อเสนอแนะจากการวิจัยในส่วนการทำนายผลสำหรับการผลิต

การเชื่อมในกระบวนการผลิตตัวถังรถยนต์เป็นขั้นตอนสำคัญที่มีบทบาทอย่างยิ่งในการกำหนดมาตรฐานและคุณภาพของการผลิต ในการวิจัยนี้ ได้มีการเก็บข้อมูลโดยตรงจากคอมพิวเตอร์ควบคุมการเชื่อม ซึ่งสามารถเก็บข้อมูลได้เพียงสองพารามิเตอร์ ได้แก่ กระแสไฟฟ้าและแรงดันไฟฟ้า โดยทำการบันทึกข้อมูลในทุกช่วงเวลา 1 มิลลิวินาที แม้ว่าจะมีข้อจำกัดในด้านการเก็บข้อมูล แต่การใช้ทรัพยากรที่มีอยู่เดิมนั้นถือว่าการใช้ทรัพยากรอย่างมีประสิทธิภาพสูงสุดในการของการเก็บข้อมูลจากกระบวนการผลิต

อย่างไรก็ตาม เพื่อเพิ่มความละเอียดในการเก็บข้อมูล หรือเพื่อสามารถบันทึกพารามิเตอร์เพิ่มเติมที่อาจช่วยในการเพิ่มประสิทธิภาพในการทำนายผลของคุณภาพของกระบวนการเชื่อม เช่น การวัดแรงกดของหุ่นยนต์ อาจจำเป็นต้องมีการปรับปรุงเพิ่มจากระบบปัจจุบัน ซึ่งอาจรวมถึงการเปลี่ยนอุปกรณ์หรือการติดตั้งเซนเซอร์เพิ่มเติมเพื่อให้สามารถเก็บสัญญาณที่ซับซ้อนเพิ่มขึ้นได้ การปรับปรุงดังกล่าวจะทำให้ระบบการเก็บข้อมูลมีความละเอียดและครอบคลุมมากขึ้น ซึ่งจะนำไปสู่การเพิ่มประสิทธิภาพการใช้งานในอุตสาหกรรม และช่วยให้การทำนายผลของกระบวนการเชื่อมสอดคล้องกับมาตรฐานคุณภาพที่เข้มงวดในอุตสาหกรรมการผลิตตัวถังรถยนต์มากยิ่งขึ้น ส่งผลให้การทำนายผลคุณภาพของรอยเชื่อมสำหรับผลิตภัณฑ์มีความน่าเชื่อถือและมีคุณภาพสูงตามที่กำหนด

5.2.3 ข้อเสนอแนะจากการวิจัยในส่วนการใช้งานจริง

การตรวจสอบรอยเชื่อมในกระบวนการผลิตตัวถังรถยนต์เป็นขั้นตอนที่มีความสำคัญอย่างยิ่ง เนื่องจากเป็นกระบวนการหลักในการรับรองคุณภาพและมาตรฐานของผลิตภัณฑ์ในทุกขั้นตอนการผลิต โดยทั่วไปจะมีการตรวจสอบรอยเชื่อมอย่างสม่ำเสมอและต่อเนื่อง เพื่อให้มั่นใจได้ว่าระบบการผลิตดำเนินไปอย่างมีประสิทธิภาพและความน่าเชื่อถือสูงสุด

อย่างไรก็ตาม การพัฒนาวิธีการทำนายคุณภาพของรอยเชื่อมยังต้องการการปรับปรุง โดยเฉพาะในกระบวนการตรวจสอบและการเก็บข้อมูลที่ใช้เทคนิค UT และการทดสอบแบบทำลาย ซึ่งจำเป็นต้องเพิ่มความแม่นยำและความครอบคลุมของการวัดข้อมูลให้มากยิ่งขึ้น การปรับปรุงดังกล่าวจะช่วยยกระดับคุณภาพของการตรวจสอบรอยเชื่อมที่ได้รับการทดสอบแล้วให้มีความน่าเชื่อถือมากขึ้น และยังช่วยขยายศักยภาพในการทำนายผลของรอยเชื่อมในส่วนอื่น ๆ ของตัวถังที่ไม่ได้ผ่านการตรวจสอบโดยตรงได้อีกด้วย

การปรับปรุงกระบวนการตรวจสอบและการทำนายนี้จะช่วยให้กระบวนการผลิตมีความเสถียรและมีประสิทธิภาพมากยิ่งขึ้น ซึ่งไม่เพียงแต่ส่งผลดีต่อการตรวจสอบและประกันคุณภาพ

ของรอยเชื่อมแต่ยังส่งเสริมความเชื่อมั่นในคุณภาพของผลิตภัณฑ์ในอุตสาหกรรมการผลิตยานยนต์
โดยรวม



รายการอ้างอิง

- [1] Ahmed, F., Jannat, N-E., Zamanzad G., Saeed R. J. & Kim, K-Y. (2019). A Conceptual Framework for Cyber-physical System in Connected RSW Weldability Certification. *Procedia Manufacturing*. 38. pp. 431-438.
- [2] Ahmed, F. & Kim, K-Y. (2017). Data-driven Weld Nugget Width Prediction with Decision Tree Algorithm. *Procedia Manufacturing*. 10. pp. 1009-1019.
- [3] Ahmed, F. & Kim, K-Y. (2018). Semantic weldability prediction with RSW quality dataset and knowledge construction. *Advanced Engineering Informatics*. 38.
- [4] Ali, R., El-Betar, A. & Magdy, M. (2024). A review on optimization of autonomous welding parameters for robotics applications. *The International Journal of Advanced Manufacturing Technology*. 134. pp. 5065-5086.
- [5] Amiri, N., Farrahi, G., Reza, K. & Chizari, M. (2020). Applications of ultrasonic testing and machine learning methods to predict the static, fatigue behavior of spot-welded joints. *Journal of Manufacturing Processes*. 52. pp. 26-34.
- [6] Andreoli, A., Chertov, A. & Maev, R. (2016). Correlation between Peel Test and Real Time Ultrasonic Test for Quality Diagnosis in Resistance Spot Welding. *Soldagem, Inspeção*. 21. pp. 282-289.
- [7] Arunchai, T., Sonthipermpon, K., Apichayakul, P. & Tamee, K. (2014). Research Article Resistance Spot Welding Optimization Based on Artificial Neural Network. *Manufacturing Engineering*. 2014.
- [8] Bansal, P., Zheng, Z., Shao, C., Li, J., Banu, M., Carlson, B. & Li, Y. (2022). Physics-Informed Machine Learning Assisted Uncertainty Quantification for the Corrosion of Dissimilar Material Joints. *Reliability Engineering, System Safety*. 227.
- [9] Bing W. (2025). A research on resistance spot welding quality judgment of stainless steel sheets based on revised quantum genetic algorithm and hidden markov model. *Mechanical Systems and Signal Processing* 223.

- [10] Brauser, S., Pepke, L., Weber, G. & Rethmeier, M. (2010). Deformation behaviour of spot-welded high strength steels for automotive applications. *Materials Science and Engineering A-structural Materials Properties Microstructure and Processing - MATER SCI ENG A-STRUCT MATER*. 527. pp. 7099-7108.
- [11] Brizes, E., Jaskowiak, J., Abke, T., Ghassemi-Armaki, H. & Ramirez, A. (2021). Evaluation of heat transfer within numerical models of resistance spot welding using high-speed thermography. *Journal of Materials Processing Technology*. 297. 117276.
- [12] Chang, F., Zhou, G., Ding, K., Li, J., Jing, Y., Hui, J. & Zhang, C. (2023). A CNN-LSTM and Attention-Mechanism-Based Resistance Spot Welding Quality Online Detection Method for Automotive Bodies. *Mathematics*. 11.
- [13] Chen, C. & Chen, S. (2020). Welding penetration monitoring for pulsed GTAW using visual sensor based on AAM and random forests. *Journal of Manufacturing Processes*. 63.
- [14] Chen, x., Li, Z., Wang, Y-Q., Yang, D., Yi, H. & Xie, G.M. (2023). Achieving Excellent Properties of Resistance Spot Welded 2gpa-Grade Press Hardened Steel and Galvanized Dp980 Steel Via Double-Pulse.
- [15] Ciravegna, G., Galante, F., Giordano, D., Cerquitelli, T. & Mellia, M. (2024). Fault Prediction in Resistance Spot Welding: A Comparison of Machine Learning Approaches. *Electronics*. 13.
- [16] Dancette, S., Huin, Thibaut & Dupuy, T. & Fabrègue, D. (2021). Finite element modeling of deformation and fracture of advanced high strength steels dissimilar spot welds. *Engineering Fracture Mechanics*. 258.
- [17] Daniel, I., Garcia, E., Soret, J. & Martos, J. (2022). Real-Time Condition Monitoring System for Electrode Alignment in Resistance Welding Electrodes. *Sensors*. 22. 8412.
- [18] Dejans, A., Kurtov, O. & Rymentant, P. (2020). Acoustic emission as a tool for prediction of nugget diameter in resistance spot welding. *Journal of Manufacturing Processes*. 62. pp. 7-17.

- [19] Dib, M., Prates, P. & Ribeiro, B. (2023). SecFL – Secure Federated Learning Framework for predicting defects in sheet metal forming under variability. *Expert Systems with Applications*. 235.
- [20] Dong, J., Hu, J. & Luo, Z. (2023). Quality Monitoring of Resistance Spot Welding Based on a Digital Twin. *Metals*. 13.
- [21] Duquesnoy, M., Liu, C., Zapata D., D., Kumar, V., Ayerbe, E. & Franco, A. (2023). Machine Learning-Assisted Multi-Objective Optimization of Battery Manufacturing from Synthetic Data Generated by Physics-Based Simulations. *ECS Meeting Abstracts*. MA2023-01. pp. 704-704.
- [22] Durnagöz, S., Mayer, M. & Huber, M. (2024). An Approach for Expulsion Predicting in Resistance Spot Welding. *Procedia CIRP*. 130. pp. 1732-1738.
- [23] El Ouafi, A., Belanger, R. & Guillot, M. (2012). Dynamic Resistance Based Model for On-Line Resistance Spot Welding Quality Assessment. *Materials Science Forum*. pp. 706-709.
- [24] Farooqui, A., Bengtsson, K., Falkman, P. & Fabian, M. (2018). From Factory Floor to Process Models: A Data Gathering Approach to Generate Transform and Visualize Manufacturing Processes. *CIRP Journal of Manufacturing Science and Technology*. 24.
- [25] Garza, F. & Das, M. (2001). On real time monitoring and control of resistance spot welds using dynamic resistance signatures. 1. pp. 41 – 44.
- [26] Gedeon, S., Sorensen, C., Ulrich, K.T. & Eagar, T. (1987). Measurement of dynamic electrical and mechanical properties of resistance spot welds. *WRC Bull*. 322. pp. 378-385.
- [27] Geng, C., Buyun, S., Gaocai, F., Xiangxiang, C. & Guangde, Z. (2024). A GAN-based method for diagnosing bodywork spot welding defects in response to small sample condition. *Applied Soft Computing*. 157. 111544.
- [28] Geslain, E., Rogeon, P., Pierre, T., Pouvreau, C. & Cretteur, L. (2017). Coating effects on contact conditions in resistance spot weldability. *Journal of Materials Processing Technology*. 253.
- [29] Ghorbani, E. & Yagiz, S. (2024). Estimating the penetration rate of tunnel boring machines via gradient boosting algorithms. 136. 108985.

- [30] Goldman, C., Baltaxe, M., Chakraborty, D., Arinez, J. & Escobar, C. (2023). Interpreting learning models in manufacturing processes: Towards explainable AI methods to improve trust in classifier predictions. *Journal of Industrial Information Integration*. 33.
- [31] Gorti, J., Mukhopadhyay, G. & Dutta, K. (2022). Failure mechanism of resistance spot-welded DP600 steel under high cycle fatigue. *Materials Today: Proceedings*. 59.
- [32] Görüş, V., Bahşı, M. & Çevik, M. (2024). Machine learning for the prediction of problems in steel tube bending process. *Engineering Applications of Artificial Intelligence*. 133.
- [33] Han, L., Thornton, M. & Shergold, M. (2010). A comparison of the mechanical behavior of self-piercing riveted and resistance spot welded aluminum sheets for the automotive industry. *Materials and Design*. 31.
- [34] Jaiswal, A., Dwivedi, P. & Dewang, R. (2024). Handling imbalance dataset issue in insider threat detection using machine learning methods. *Computers and Electrical Engineering*. 120.
- [35] Jourdan, N., Sen, S., Husom, E.J., Garcia C., Enrique B.T. & Metternich, J. (2021). On The Reliability Of Machine Learning Applications In Manufacturing Environments.
- [36] Kershaw, J., Ghassemi-Armaki, H., Carlson, B. & Wang, P. (2024). Advanced process characterization and machine learning-based correlations between interdiffusion layer and expulsion in spot welding. *Journal of Manufacturing Processes*. 109. pp. 222-234.
- [37] Kim, D.H., Lee, B-Y., Min, S., Joe, D., An, J., Kim, B., Park, Y., Kang, S., Hwang, G. & Lee, J. (2022). Pulsed direct current magnetic energy harvesting by robotic spot-welding in smart automotive factory. *Nano Energy*. 104.
- [38] Kim, S., Hwang, I., Kim, D-Y., Kim, Y-M., Kang, M. & Yu, J. (2021). Weld-Quality Prediction Algorithm Based on Multiple Models Using Process Signals in Resistance Spot Welding. *Metals*. 11.

- [39] Komenda, T., Brandstötter, M., Gharagyozyan, T., Pichler, A. & Liemberger, W. (2022). Failure Prediction in Robotic Spot-Welding Applications – Challenges in Data Management. *Procedia CIRP*. 112. pp. 454-458.
- [40] Lai, X., Qiu, T., Shui, H., Ding, D. & Ni, J. (2023). Predicting future production system bottlenecks with a graph neural network approach. *Journal of Manufacturing Systems*. 67. pp. 201-212.
- [41] LeCun, Y., Bengio, Y. & Hinton, G. (2015). Deep Learning. *Nature*. 521. pp. 436-444.
- [42] Lee, J., Noh, I., Jeong, S., Lee, Y. & Lee, S-W. (2020). Development of Real-time Diagnosis Framework for Angular Misalignment of Robot Spot-welding System Based on Machine Learning. *Procedia Manufacturing*. 48. pp. 1009-1019.
- [43] Li, X., Zhang, M., Zhou, M., Wang, J., Zhu, W., Wu, C. & Zhang, X. (2023). Qualify assessment for extrusion-based additive manufacturing with 3D scan and machine learning. *Journal of Manufacturing Processes*. 90. pp. 274-285.
- [44] Liu, P., Zhao, E., Meng, J., Zhou, X., Liu, C., Tian, H., Li, J., Zhao, X., Zhang, J., Zhao, H. & Qi, C. (2024). On-line measurement of nugget diameter in automatic resistance spot welding based on embedded ultrasound probe. *Measurement*. 226.
- [45] Luo, Y., Li, J. & Wu, W. (2013). Characterization of nugget nucleation quality based on the structure-borne acoustic emission signals detected during resistance spot welding process. *Measurement*. 46. pp. 1053–1060.
- [46] Martín, Ó., Pereda, M., Santos, J. & Galán, J. M. (2014). Assessment of resistance spot welding quality based on ultrasonic testing and tree-based techniques. *Journal of Materials Processing Technology*. 214. pp. 2478–2487.
- [47] Mathiszik, C., Zschetzsche, J. & Füßel, U. (2019). Automated Non-Destructive Evaluation of Spot Welds using the Imaging Analyses of the Residual Magnetic Flux Density.
- [48] Mezher, M., Pereira, A., Shakir, R. & Trzepieciński, T. (2024). Application of machine learning and neural network models based on experimental evaluation of dissimilar resistance spot-welded joints between grade 2 titanium alloy and AISI 304 stainless steel. *Heliyon*. 10.

- [49] Moomen, A., Ali, A. & Ramahi, O. (2016). Reducing Sweeping Frequencies in Microwave NDT Employing Machine Learning Feature Selection. *Sensors*. 16. 559.
- [50] Mosca, N., Renò, V., Nitti, M., Patruno, C., Negri, S. & Stella, E. (2024). VISTA — Vision-based inspection system for automated testing of aircraft interiors: A panoramic view. *Results in Engineering*. 24.
- [51] Moshayedi, H. & Sattari-Far, I. (2014). Resistance spot welding and the effects of welding time and current on residual stresses. *Journal of Materials Processing Technology*. 214. pp. 2545–2552.
- [52] Oh, Y., Ransikarbum, K., Busogi, M., Kwon, D. & Kim, N. (2018). Adaptive SVM-based Real-time Quality Assessment for Primer-Sealer Dispensing Process of Sunroof Assembly Line. *Reliability Engineering, System Safety*. 184.
- [53] Oliveira, J. P. & Ponder, K., Brizes, E., Abke, T. & Ramirez, A. (2019). Combining resistance spot welding and friction element welding for dissimilar joining of aluminum to high strength steels. *Journal of Materials Processing Technology*. 273.
- [54] Ono, K. (2011). ACOUSTIC EMISSION IN MATERIALS RESEARCH – A REVIEW. *Journal of acoustic emission*. 29.
- [55] Pattanaik, A.K., Panda, S., Pal, K. & Mishra, D. (2018). A Comparative Investigation to Process Parameter Optimization for Spot Welding Using Taguchi Based Grey Relational Analysis and Metaheuristics. *Materials Today: Proceedings*. 5. pp. 11408-11414.
- [56] Peng, P., Fan, K., Fan, X., Zhou, H. & Guo, Z. (2023). Real-Time Defect Detection Scheme Based on Deep Learning for Laser Welding System. *IEEE Sensors Journal*. pp. 1-10.
- [57] Polajnar, I., Grum, J. & ESMail, E. (1999). Sources of acoustic emission in resistance spot welding. *Strojniski Vestnik/Journal of Mechanical Engineering*. 45.
- [58] Psarommatis, F., Zhou, B. & Kharlamov, E. (2024). Implementation of Zero-Defect Manufacturing using quality prediction: a spot welding case study from Bosch. *Procedia Computer Science*. 232. pp. 1299-1308.

- [59] Ravichandran, P., Anbu, C., Meenakshipriya, B. & Sathiyavathi, S. (2020). Process parameter optimization and performance comparison of AISI 430 and AISI 1018 in resistance spot welding process. *Materials Today: Proceedings*. 33.
- [60] Saadallah, A., Abdulaaty, O., Buescher, J., Panusch, T., Morik, K. & Deuse, J. (2022). Early Quality Prediction using Deep Learning on Time Series Sensor Data. *Procedia CIRP*. 107. pp. 611-616.
- [61] Sachin K.D., Nilesh D. & Shyamkumar D.K. (2019). Optimization of the Process Parameters of Resistance Spot Welding of AISI 316L Sheets Using Taguchi Method. *Mechanics and Mechanical Engineering*. 23. pp. 64-69.
- [62] Santos, L. & Ferreira, L. (2023). Atlantic—Automated data preprocessing framework for supervised machine learning. *Software Impacts*. 17.
- [63] Schuh, G., Gützlaß, A., Thomas, K. & Welsing, M. (2021). Machine learning based defect detection in a low automated assembly environment. *Procedia CIRP*. 104. pp. 265-270.
- [64] Shang, G., Xu, L., Li, Z., Zhou, Z. & Xu, Z. (2024). Digital-twin-based predictive compensation control strategy for seam tracking in steel sheets welding of large cruise ships. *Robotics and Computer-Integrated Manufacturing*. 88.
- [65] Shojaei, M., Midawi, A., Barber, B., Ghassemi-Armaki, H., Worswick, M. & Biro, E. (2021). Mechanical properties and failure behavior of resistance spot welded third-generation advanced high strength steels. *Journal of Manufacturing Processes*. 65. pp. 364-372.
- [66] Sim, J. & Kim, K-Y. (2018). Hybrid Nugget Diameter Prediction for Resistance Spot Welding. *Procedia Manufacturing*. 17. pp. 395-402.
- [67] Sivaraj, P., Seeman, M., Kanagarajan d., D.K. & Seetharaman, R. (2019). Influence of welding parameter on mechanical properties and microstructural features of resistance spot welded dual phase steel sheets joint. *Materials Today: Proceedings*. 22.
- [68] Soto-Ferrari, M., Bhattacharyya, K. & Schikora, P. (2023). POST-BaLSTM: A Bagged LSTM Forecasting Ensemble Embedded with a Postponement Framework to Target the Semiconductor Shortage in the Automotive Industry. *Computers, Industrial Engineering*. 185.

- [69] SShafee, Shaik & Naik, B. & Sammaiah, D. (2015). Resistance Spot Weld Quality Characteristics Improvement by Taguchi Method. *Materials Today: Proceedings*. 2. pp. 2595-2604.
- [70] Summerville, C., Compston, P. & Doolan, M. (2019). A comparison of resistance spot weld quality assessment techniques. *Procedia Manufacturing*. 29. 305-312.
- [71] Sun, Z., Wang, G., Zhai, G., Li, P., Liang, Q. & Zhang, M. (2024). Signal detection and material identification method for loose particles inside sealed relays based on fusion classification model. *Engineering Applications of Artificial Intelligence*. 127. 107284.
- [72] Tao, J., Nor, N. & Abdullah, A.B. (2024). Acoustic signal-based automated control of welding penetration using digital twin technology. *Mechanical Systems and Signal Processing*. 208.
- [73] Tiedra, P., Martín, Ó. & López, M. (2011). Combined Effect of Resistance Spot Welding and Post-Welding Sensitization on the Pitting Corrosion Behavior of AISI 304 Stainless Steel. *Corrosion Science - CORROS SCI*. 53. pp. 2670-2675.
- [74] Vo, T., Tran, D., Nguyen, R., Le, N., Truong, C. & Tran, T. (2024). LSTM-based welding quality forecasting system in smart manufacturing. 54-60.
- [75] Wei, D., Li, D., Tang, D., Jiang, Q., Wang, D., Wang, H. & Peng, Y. (2021). Deep learning assisted vision inspection of resistance spot welds. *Journal of Manufacturing Processes*. 62. pp. 262-274.
- [76] Wu, Z., Gao, P., Han, J., Bai, L., Lu, J. & Zhao, Z. (2022). Real-time segmentation network for accurate weld detection in large weldments. *Engineering Applications of Artificial Intelligence*. 117. 105008.
- [77] Xia, Y-J., Liv, T., Ghassemi-Armaki, H., Li, Y. & Carlson, B. (2023). Quantitative Interpretation of Dynamic Resistance Signal in Resistance Spot Welding. *Welding Journal*. 102. pp. 69-87.
- [78] Xia, Y-J., Zhou, L., Shen, Y., Wegner, D., Haselhuhn, A., Li, Y. & Carlson, B. (2020). Online Measurement of Weld Penetration in Robotic Resistance Spot Welding Using Electrode Displacement Signals. *Measurement*. 168.

- [79] Xiao, M., Yang, B., Wang, S., Zhang, Z., Tang, X. & Kang, L. (2022). A feature fusion enhanced multiscale CNN with attention mechanism for spot-welding surface appearance recognition. *Computers in Industry*. 135.
- [80] Xiaokai, W., Sanyue, G., Lin, H., Bin, W. & Ximing, H. (2018). Classification of spot-welded joint strength using ultrasonic signal time-frequency features and PSO-SVM method. *Ultrasonics*. 91.
- [81] Xiaoye, W., Zhang, C. & Wang, T. (2024). Benchmark for welding gun fault prediction with multivariate time series data. *Scientific Data*. 11.
- [82] Xing, B., Xiao, Y. & Qin, Q. (2017). Characteristics of shunting effect in resistance spot welding in mild steel based on electrode displacement. *Measurement*. 115.
- [83] Yared B.K., Ming-Der Y. & Chien-Wei H. (2024). Real-time pavement temperature prediction through ensemble machine learning. *Engineering Applications of Artificial Intelligence*. 135.
- [84] Yu, P., Ping, M., Ma, J. & Cao, J. (2024). Unsupervised Signal Anomaly Transformer method: Achieving bearing life anomaly detection without the need for failure samples. *Engineering Applications of Artificial Intelligence*. 136.
- [85] Zhao, D., Ren, D., Zhao, K., Pan, S. & Guo, X. (2017). Effect of welding parameters on tensile strength of ultrasonic spot welded joints of aluminum to steel – By experimentation and artificial neural network. *Journal of Manufacturing Processes*. 30. pp.63-74.
- [86] Zhou, B., Pychynski, T., Reischl, M., Kharlamov, E. & Mikut, R. (2022). Machine learning with domain knowledge for predictive quality monitoring in resistance spot welding. *Journal of Intelligent Manufacturing*. 33. pp. 1-25.
- [87] Zhou, B., Pychynski, T., Reischl, M. & Mikut, R. (2018). Comparison of Machine Learning Approaches for Time-series-based Quality Monitoring of Resistance Spot Welding (RSW).
- [88] Zhou, L., Zhang, T., Zhang, Z., Zhenglong, L. & Zhu, S. (2022). Monitoring of resistance spot welding expulsion based on machine learning. *Science and Technology of Welding and Joining*. 27. pp. 1-9.

ภาคผนวก ก

การเขียนโปรแกรมการทำนายผลในสายการผลิต



ภาคผนวกนี้แนะนำขั้นตอนการพัฒนาโปรแกรมด้วยภาษา Python เพื่อทำการอ่านและประมวลผลข้อมูลจากไฟล์ RUI ซึ่งเป็นรูปแบบไฟล์ที่ใช้ในการจัดเก็บข้อมูลที่มีลักษณะเฉพาะ โดยในงานวิจัยนี้ได้ใช้ไฟล์ RUI เพื่อเก็บข้อมูลที่เกี่ยวข้องกับกระบวนการ Resistance Spot Welding (RSW) ในการทำนายคุณภาพการเชื่อมในกระบวนการผลิตยานยนต์ และใช้ในการทำนายผล เพื่อส่งข้อมูลผลของการทำนายไปที่ PLC

```
import os
import gc
import sys
import shutil
import paramiko
import time
import logging
import glob
import csv
import pickle
import numpy as np
import pandas as pd
import seaborn as sns
import xml.etree.ElementTree as ET
import mpl_toolkits.axisartist as AA
import matplotlib.pyplot as plt
from watchdog.observers import Observer
from watchdog.events import FileSystemEventHandler
from distutils.dir_util import copy_tree
from xml.dom.minidom import parseString
from mpl_toolkits.axes_grid1 import host_subplot
from datetime import datetime
from pprint import pprint
from sklearn.metrics import accuracy_score, auc, classification_report,
confusion_matrix, roc_curve
```

```

from sklearn.model_selection import train_test_split, KFold, cross_val_score
from sklearn.metrics import confusion_matrix, accuracy_score, classification_report
from sklearn.metrics import precision_score, recall_score, f1_score
import warnings
warnings.filterwarnings('ignore')
resis_header = ['Name','Station','Time','Resistance']
result_header = ['Name','PGnumber','Time','Predicted']
f_date = datetime.now().strftime("%Y%m%d_%H%M%S")
config_file = r'C:\RSW\config.txt'
port = 22 # Default SSH port
logging.basicConfig(filename='file_mover.log', level=logging.INFO, format='%(asctime)s
- %(levelname)s - %(message)s')
def read_config_file(config_file):
    config = {}
    try:
        with open(config_file, 'r') as f:
            for line in f:
                if '=' in line:
                    key, value = line.strip().split('=')
                    config[key.strip()] = value.strip()
    except Exception as e:
        logging.error(f"Error reading config file: {e}")
    return config
config = read_config_file(config_file)
src = config.get('src_directory', "")
hostname = config.get('hostname', "")
username = config.get('username', "")
password = config.get('password', "")
dest_local = config.get('dest_local_directory', "")
dest_remote = src
ModelPath = config.get('model_directory', "")

```

```

csv_resis = config.get('Resistance CSV File', "")
csv_result = config.get('result csv', "")
machine_src = dest_local
path_raw = config.get('RawPath', "")
src_extract = config.get('ExtractPath', "")
MLmodel = config.get('Model', "")
model = MLmodel
sys.path.append(ModelPath)
if not os.path.exists(path_raw):
    os.makedirs(path_raw)
if not os.path.exists(src_extract):
    os.makedirs(src_extract)
print("Ready for Prediction")
combi=[]
spot_data=[]
data_ext=[]
result_rsw=[]
csv_data=[]
predictions=[]
print("Close Program to stop")
runing = True
def move_files_locally(src, dest):
    try:
        if os.path.isdir(src):
            for root, dirs, files in os.walk(src):
                for file in files:
                    src_file = os.path.join(root, file)
                    relative_path = os.path.relpath(src_file, src)
                    dest_file = os.path.join(dest, relative_path)
                    os.makedirs(os.path.dirname(dest_file), exist_ok=True)
                    shutil.move(src_file, dest_file)

```

```

        logging.info(f"Moved {src_file} to {dest_file}")
    else:
        dest_file = os.path.join(dest, os.path.basename(src))
        shutil.move(src, dest_file)
        logging.info(f"Moved {src} to {dest_file}")
    except Exception as e:
        logging.error(f"Local move error: {e}")
def move_files_remotely(src, dest, hostname, port, username, password):
    try:
        transport = paramiko.Transport((hostname, port))
        transport.connect(username=username, password=password)
        sftp = paramiko.SFTPClient.from_transport(transport)
        def sftp_put_file(local_file, remote_dir):
            remote_file = os.path.join(remote_dir, os.path.relpath(local_file,
src)).replace("\\", "/")
            try:
                sftp.remove(remote_file) # Remove existing remote file if exists
            except Exception as e:
                pass # Ignore if file doesn't exist
            sftp.put(local_file, remote_file)
            logging.info(f"Uploaded {local_file} to {remote_file}")
        if os.path.isdir(src):
            for root, dirs, files in os.walk(src):
                for file in files:
                    local_file = os.path.join(root, file)
                    sftp_put_file(local_file, dest)
        else:
            sftp_put_file(src, dest)
        sftp.close()
        transport.close()
    except paramiko.SSHException as ssh_error:

```

```

        logging.error(f"Remote SSH error: {ssh_error}")
    except Exception as e:
        logging.error(f"Remote move error: {e}")
class FileChangeHandler(FileSystemEventHandler):
    def on_any_event(self, event):
        logging.info(f"Detected change: {event.event_type} - {event.src_path}")
        try:
            move_files_locally(src, dest_local)
            move_files_remotely(src, dest_remote, hostname, port, username,
password)
        except Exception as e:
            logging.error(f"Error processing change: {e}")
def movefile(machine_src, path_raw):
    copy_tree(machine_src, path_raw)
    for root, dirs, files in os.walk(machine_src):
        for filename in files:
            try:
                os.remove(os.path.join(root, filename))
            except Exception as e:
                print(f"Error removing file: {e}")
    for root, dirs, files in os.walk(path_raw):
        for filename in files:
            if filename.endswith('.rui'):
                parts = filename.split('_')
                new_filename = '_' + parts[2] + parts[3:5] if len(parts) >= 5 else
filename
            try:
                os.rename(os.path.join(root, filename), os.path.join(root,
new_filename))
            except Exception as e:
                print(f"Error renaming file: {e}")

```

```

time.sleep(0.1)
def ML(spot_data):
    model_path = model
    with open(model_path, 'rb') as file:
        loaded_model = pickle.load(file)
    real_data = spot_data.drop(columns=['No', 'Name', 'Station', 'Program', 'Parameter
Time', 'Time', 'PGnumber','Zmax','GunResistance','Result'])
    prediction = loaded_model.predict(real_data)
    predictions = int(prediction[0])
    if predictions == 1:
        result = "Satisfy"
    elif predictions == 0:
        result = "Cold Weld"
    elif predictions == 2:
        result = "Expulsion"
    else: result = "Unknown"
    print("Result prediction : ",result)
    predictions_df = pd.DataFrame({'Name': spot_data['Name'], 'PGnumber':
spot_data['PGnumber'],'Time': spot_data['Parameter Time'], 'Predicted': result})
    file_exists = os.path.isfile(csv_result)
    with open(csv_result, 'a', newline="") as f:
        predictions_df.to_csv(f, index=False, header=not file_exists)
def tip_check(spot_data):
    tip_data = pd.DataFrame({'Name': spot_data['Name'],'Station':
spot_data['Station'],'Time': spot_data['Parameter Time'],
'Resistance': spot_data['Resistance']})
    file_exists = os.path.isfile(csv_resis)
    with open(csv_resis, 'a', newline="") as f:
        tip_data.to_csv(f, index=False, header=not file_exists)
def tip_station(csv_resis):
    station_data = {}

```

```

def initialize_station(station):
    if station not in station_data:
        station_data[station] = []
    with open(csv_resis, newline="") as csvfile:
        reader = csv.reader(csvfile)
        next(reader)
        for row in reader:
            name, station, time, resistance = row
            initialize_station(station)
            station_data[station].append((name, station, time, resistance))

def delete_empty_files(root_dir):
    for dirpath, _, filenames in os.walk(root_dir):
        for filename in filenames:
            file_path = os.path.join(dirpath, filename)
            try:
                if os.path.getsize(file_path) == 0:
                    print(f"Deleting {file_path}...")
                    os.remove(file_path)
            except FileNotFoundError:
                pass
            except Exception as e:
                print(f"Error deleting {file_path}: {e}")
                time.sleep(2)
                try: os.remove(file_path)
            except Exception as e:
                print(f"Error deleting {file_path} after retry: {e}")

def rui2csv(path_raw,src_extract,spot_data,result_rsw,csv_data,predictions):
    for root, dirs, files in os.walk(path_raw):
        for filename in files:
            if filename.endswith('.rui'):
                nameA = os.path.splitext(filename)

```

```

nameA = nameA[0]
try:
    for root, dirs, files in os.walk(path_raw):
        start = time.time()
        RUIfolder = root
        XMLfolder = RUIfolder
        SUMfolder = RUIfolder
        RUIname=[]
        XMLname=[]
        HEAT=[]
        Ener=[]
        Cuv=[]
        Number=[]
        B_Ifac=[]
        B_Vfac=[]
        B_Ener=[]
        B_Pmax=[]
        B_CorrF=[]
        B_Wear=[]
        B_Splash=[]
        B_GunRes=[]
        B_Zmax=[]
        B_PGnumber=[]
        B_WeldTime=[]
        B_Regulation = []
        B_MinI = []
        B_MaxI = []
        B_MaxT = []
        B_TipRes = []
        B_Unknow = []
        D_name = []

```

```

D_Station = []
D_Program = []
D_Time = []
P_Time=[]
P_aveR=[]
P_spatter = []
Ca = []
Va = []
Ra = []
Cm = []
Vm = []
Rm = []
Cl = []
Vl = []
Rl = []
Clast = []
Vlast = []
for filename in glob.glob(os.path.join(RUIfolder,'*.rui')):
    RUIname.append(str(filename))
n=len(RUIname)
if n != 0 :
    XMLname = [os.path.splitext(filename)[0] for filename in
os.listdir(RUIfolder)]
    SUMname = [os.path.splitext(filename)[0] for filename in
os.listdir(RUIfolder)]
    files = [os.path.splitext(filename)[0] for filename in
os.listdir(RUIfolder)]
    nn=range(n)
    for i in nn:
        lines = []
        with open(RUIname[i], 'r') as fp:

```

```

try:
    lines = fp.readlines()
except: continue
with open(RUlname[i], 'w') as fp:
    for number, line in enumerate(lines):
        if number not in [2,3]:
            fp.write(line)
name1 = SUMname[-1].split('_')
name1 = name1[0]+'_'+name1[1]+'_'+name1[2]+'_'+name1[3]
for i in nn:
    file_path = RUlname[i]
    if os.path.getsize(file_path) == 0:
        print(f"Skipping empty file {file_path}")
        time.sleep(0.1)
        delete_empty_files(XMLfolder)
        continue
    try:
        Axml = open(RUlname[i],encoding='utf-8')
        for line in Axml:
            Bxml = XMLfolder+'\\'+XMLname[i]
            Cxml = parseString(line)
            with open(Bxml, 'w') as file:
                Cxml.writexml(file, indent='\n', addindent=' ')
            Axml.close()
        except Exception as e:
            print(f"Error parsing XML for {XMLname[i]}: {str(e)}")
            continue
    for i in nn:
        try: xmldata = ET.parse(XMLfolder+'\\'+XMLname[i])
        except Exception as e: pass
        continue

```

```

FileName = nameA.split('_')
Cuv_name = nameA
Station = FileName[0]
Program = FileName[1]
D = FileName[2]
Tt = FileName[3]
T = str(D)+str(Tt)
Time = pd.to_datetime(T, format = '%Y%m%d%H%M%S')
copy_tree(path_raw, src_extract)
xmlroot = xmltree.getroot()
for x in xmlroot.iter('DAY'):
    DD=x.text
for x in xmlroot.iter('MONTH'):
    MM=x.text
for x in xmlroot.iter('YEAR'):
    YY=x.text
for x in xmlroot.iter('HOUR'):
    hh=x.text
for x in xmlroot.iter('MINUTE'):
    mm=x.text
for x in xmlroot.iter('SECOND'):
    ss=x.text
DATE=[YY,MM,DD]
TIME=[hh,mm,ss]
for x in xmlroot.findall('HEADER'):
    Version =x.find('VERSION_NO').text
    pg = x.find('PROGRAM_NUMBER').text
    U = x.find('UMAX').text
    I = x.find('IMAX').text
    E = x.find('ENERGIE').text
    P = x.find('PMAX').text

```

```

CUR = x.find('CUR_CORR_FACTOR').text
Wear = x.find('WEAR_COUNTER').text
Milling = x.find('MILLING_COUNTER').text
Splash = x.find('SPLASH_TIME').text
GunRes = x.find('GUN_RESISTANCE').text
Zmax = x.find('ZMAX').text
PGnumber = x.find('PROGRAM_NUMBER').text
WeldTime = x.find('NUMBER_OF_DATA').text

for z in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1338']"):
    for z1 in z.findall("./PARAMETER[@ID='2327']"):
        for z2 in z1.findall("./VALUE"):
            Reg = z2.text
    for z1 in z.findall("./PARAMETER[@ID='2358']"):
        for z2 in z1.findall("./VALUE"):
            MinI = z2.text
    for z1 in z.findall("./PARAMETER[@ID='2359']"):
        for z2 in z1.findall("./VALUE"):
            MaxI = z2.text
    for z1 in z.findall("./PARAMETER[@ID='2360']"):
        for z2 in z1.findall("./VALUE"):
            MaxT = z2.text
    for z1 in z.findall("./PARAMETER[@ID='2857']"):
        for z2 in z1.findall("./DAY"):
            P_day = z2.text
        for z2 in z1.findall("./MONTH"):
            P_month = z2.text
        for z2 in z1.findall("./YEAR"):
            P_year = z2.text
        for z2 in z1.findall("./HOUR"):
            P_hour = z2.text

```

```

for z2 in z1.findall("./MINUTE"):
    P_minute = z2.text
for z2 in z1.findall("./SECOND"):
    P_second = z2.text
for z1 in z.findall("./PARAMETER[@ID='3296']"):
    for z2 in z1.findall("./VALUE"):
        TipRes = z2.text
for z1 in z.findall("./PARAMETER[@ID='3234']"):
    for z2 in z1.findall("./VALUE"):
        Unknow = z2.text
Version = float(Version)
pg = float(pg)
U = float(U)
I = float(I)
E = float(E)
P = float(P)
CUR = float(CUR)
Wear = int(Wear)
Milling = int(Milling)
Splash = int(Splash)
GunRes = int(GunRes)
Zmax = float(Zmax)
PGnumber = int(PGnumber)
WeldTime = int(WeldTime)
Regulation = int(Reg)
MinI = int(MinI)
MaxI = int(MaxI)
MaxT = int(MaxT)
TipRes = int(TipRes)
Unknow = int(Unknow)
if Splash > 0: spatter = 1

```

```

else: spatter = 0

P_date = str(P_year)+str(P_month)+ str(P_day)+
str(P_hour)+str(P_minute)+ str(P_second)

P_time = pd.to_datetime(P_date, format =
'%Y%m%d%H%M%S')

for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1310']"):
    for d1 in y.findall("./DATA_SET1"):
        d1_1310=d1.text
    for d2 in y.findall("./DATA_SET2"):
        d2_1310=d2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1311']"):
        for d1 in y.findall("./DATA_SET1"):
            d1_1311=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1311=d2.text
        for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1312']"):
            for d1 in y.findall("./DATA_SET1"):
                d1_1312=d1.text
            for d2 in y.findall("./DATA_SET2"):
                d2_1312=d2.text
            for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1313']"):
                for d1 in y.findall("./DATA_SET1"):
                    d1_1313=d1.text
                for d2 in y.findall("./DATA_SET2"):
                    d2_1313=d2.text
                for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1314']"):

```

```

        for d1 in y.findall("./DATA_SET1"):
            d1_1314=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1314=d2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1315']"):
        for d1 in y.findall("./DATA_SET1"):
            d1_1315=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1315=d2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1316']"):
        for d1 in y.findall("./DATA_SET1"):
            d1_1316=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1316=d2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1317']"):
        for d1 in y.findall("./DATA_SET1"):
            d1_1317=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1317=d2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1318']"):
        for d1 in y.findall("./DATA_SET1"):
            d1_1318=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1318=d2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1319']"):
        for d1 in y.findall("./DATA_SET1"):

```

```

        d1_1319=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1319=d2.text
        for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1320']"):
        for d1 in y.findall("./DATA_SET1"):
            d1_1320=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1320=d2.text
        for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1321']"):
        for d1 in y.findall("./DATA_SET1"):
            d1_1321=d1.text
        for d2 in y.findall("./DATA_SET2"):
            d2_1321=d2.text
        for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1320']"):
        for f1 in y.findall("./DATA_SET1"):
            f1_1320=f1.text
        for f2 in y.findall("./DATA_SET2"):
            f2_1320=f2.text
        for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1321']"):
        for f1 in y.findall("./DATA_SET1"):
            f1_1321=f1.text
        for f2 in y.findall("./DATA_SET2"):
            f2_1321=f2.text
        for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1322']"):
        for f1 in y.findall("./DATA_SET1"):
            f1_1322=f1.text

```

```

        for f2 in y.findall("./DATA_SET2"):
            f2_1322=f2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1323']"):
    for f1 in y.findall("./DATA_SET1"):
        f1_1323=f1.text
    for f2 in y.findall("./DATA_SET2"):
        f2_1323=f2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1324']"):
    for f1 in y.findall("./DATA_SET1"):
        f1_1324=f1.text
    for f2 in y.findall("./DATA_SET2"):
        f2_1324=f2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1325']"):
    for f1 in y.findall("./DATA_SET1"):
        f1_1325=f1.text
    for f2 in y.findall("./DATA_SET2"):
        f2_1325=f2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1326']"):
    for f1 in y.findall("./DATA_SET1"):
        f1_1326=f1.text
    for f2 in y.findall("./DATA_SET2"):
        f2_1326=f2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1327']"):
    for f1 in y.findall("./DATA_SET1"):
        f1_1327=f1.text
    for f2 in y.findall("./DATA_SET2"):

```

```

        f2_1327=f2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1328']"):
        for f1 in y.findall("./DATA_SET1"):
            f1_1328=f1.text
        for f2 in y.findall("./DATA_SET2"):
            f2_1328=f2.text
    for y in
xmlroot.findall("./OBJECTS_DATA/OBJECT[@NUMBER='1329']"):
        for f1 in y.findall("./DATA_SET1"):
            f1_1329=f1.text
        for f2 in y.findall("./DATA_SET2"):
            f2_1329=f2.text
    data1 =
np.concatenate((d1_1310.split("|"),d1_1311.split("|"),d1_1312.split("|"),d1_1313.split("|"),d
1_1314.split("|")\
                ,d1_1315.split("|"),d1_1316.split("|"),d1_1317.split("|")))
    data2 =
np.concatenate((d2_1310.split("|"),d2_1311.split("|"),d2_1312.split("|"),d2_1313.split("|"),d
2_1314.split("|")\
                ,d2_1315.split("|"),d2_1316.split("|"),d2_1317.split("|")))
    dataset1 = np.array(data1).astype(int)
    dataset2 = np.array(data2).astype(int)
    dataset1=dataset1[dataset1!=0]
    dataset2=dataset2[dataset2!=0]
    fdata1 =
np.concatenate((f1_1320.split("|"),f1_1321.split("|"),f1_1322.split("|"),f1_1323.split("|"),f1_
1324.split("|"),f1_1325.split("|"),f1_1326.split("|"),f1_1327.split("|"),f1_1328.split("|"),f1_132
9.split("|")))

```

```

fdata2 =
np.concatenate((f2_1320.split("|"),f2_1321.split("|"),f2_1322.split("|"),f2_1323.split("|"),f2_
1324.split("|")\
,f2_1325.split("|"),f2_1326.split("|"),f2_1327.split("|"),f2_1328.split("|"),f2_1329.split("|")))

fdataset1 = np.array(fdata1).astype(int)
fdataset2 = np.array(fdata2).astype(int)
#fdataset1=fdataset1[fdataset1!=0]
fdat=fdataset2[fdataset2!=0]
fdataset1.astype(int)
fdataset2.astype(int)
t2 = len (fdataset2)
T2=np.arange(0,t2)
t3=len (fdat)
volt = U*(1/100)*dataset1
current = I*dataset2/10000
max_l = max(len(volt), len(current))
volt = np.pad(volt, (0, max_l - len(volt)))
current = np.pad(current, (0, max_l - len(current)))
if current.any()>0 :
    R=volt/current
    energy=volt*current
else :
    R=0
    current=current
    volt=0
C = []
for a in range(0, len(current), 5):
    current_chunk = current[a:a+5]
    C_sum = sum(current_chunk)
    C.append(round(C_sum, 5))
Cfirst_array = C[0]/5

```

```

Clast_array = C[len(C)-1]/5
Cavg_value = round(sum(C) / len(C), 5)/5
C_val = sum(C)
C_a = [Cfirst_array, Clast_array, Cavg_value,C_val]
Ca.append(C_a)

V = []
for a in range(0, len(volt), 5):
    volt_chunk = volt[a:a+5]
    V_sum = sum(volt_chunk)
    V.append(round(V_sum, 5))
Vfirst_array = V[0]/5
Vlast_array = V[len(V)-1]/5
Vavg_value = round(sum(V) / len(V), 5)/5
V_val = sum(V)
V_a = [Vfirst_array, Vlast_array, Vavg_value,V_val]
Va.append(V_a)

Rt = []
for a in range(0, len(R), 5):
    res_chunk = R[a:a+5]
    R_sum = sum(res_chunk)
    Rt.append(round(R_sum, 5))
Rfirst_array = Rt[0]/5
Rlast_array = Rt[len(Rt)-1]/5
Ravg_value = round(sum(Rt) / len(Rt), 5)/5
Rt_val = sum(Rt)
Rt_a = [Rfirst_array, Rlast_array, Ravg_value,Rt_val]
Ra.append(Rt_a)

Cmax = round(max(current),5)
Cm.append(Cmax)

Vmax = round(max(volt),5)
Vm.append(Vmax)

```

```

Rmax = round(max(R),5)
Rm.append(Rmax)
Clow = round(min(current[25:]),5)
Cl.append(Clow)
Vlow = round(min(volt[25:]),5)
Vl.append(Clow)
Rlow = round(min(R[25:]),5)
Rl.append(Rlow)
Clst = round(current[-1],5)
Clast.append(Clst)
Vlst= round(volt[-1],5)
Vlast.append(Vlst)
t1=len(R)
aveR = np.mean(R[40:])*1000
T=np.arange(0,t1)
constant = (t1,12)
constant = np.zeros(constant)
ener= round((sum(energy)),5)
heat=round(ener/(t1/1000),5)
B_e=E/1000000
HEAT.append(heat)
Ener.append(ener)
B_lfac.append(I)
B_Vfac.append(U)
B_Ener.append(B_e)
B_Pmax.append(P)
B_CorrF.append(CUR)
B_Wear.append(Wear)
B_Splash.append(Splash)
B_GunRes.append(GunRes)
B_Zmax.append(Zmax)

```

```

B_PGnumber.append(PGnumber)
B_WeldTime.append(WeldTime)
B_Regulation.append(Regulation)
B_MinI.append(MinI)
B_MaxI.append(MaxI)
B_MaxT.append(MaxT)
B_TipRes.append(TipRes)
B_Unknow.append(Unknow)
D_name.append(Cuv_name)
D_Station.append(Station)
D_Program.append(Program)
D_Time.append(Time)
P_Time.append(P_time)
P_aveR.append(aveR)
P_spatter.append(spatter)
No = i+1
Number.append(No)
os.remove(XMLfolder+'\\'+XMLname[i])
count = 0
Ener=np.array(Ener).astype(float)
HEAT=np.array(HEAT).astype(float)
Cuv=np.array(XMLname).astype(str)
B_Ifac = np.array(B_Ifac).astype(float)
B_Vfac = np.array(B_Vfac).astype(float)
B_Ener = np.array(B_Ener).astype(float)
B_Pmax = np.array(B_Pmax).astype(float)
B_CorrF = np.array(B_CorrF).astype(float)
B_Wear = np.array(B_Wear).astype(int)
B_Splash = np.array(B_Splash).astype(int)
B_GunRes = np.array(B_GunRes).astype(int)
B_Zmax = np.array(B_Zmax).astype(float)

```

```

B_PGnumber = np.array(B_PGnumber).astype(int)
B_WeldTime = np.array(B_WeldTime).astype(int)
B_Regulation = np.array(B_Regulation).astype(int)
B_MinI = np.array(B_MinI).astype(int)
B_MaxI = np.array(B_MaxI).astype(int)
B_MaxT = np.array(B_MaxT).astype(int)
B_TipRes = np.array(B_TipRes).astype(int)
B_Unknow = np.array(B_Unknow).astype(int)
D_name = np.array(D_name).astype(str)
D_Station = np.array(D_Station).astype(str)
D_Program = np.array(D_Program).astype(str)
D_Time = np.array(D_Time).astype(str)
P_Time = np.array(P_Time).astype(str)
P_aveR = np.array(P_aveR).astype(float)
P_spatter = np.array(P_spatter).astype(int)
P_aveR = np.round(P_aveR, 3)
combi =
np.array([Number,D_name,D_Station,D_Program,D_Time,P_Time,B_PGnumber,Ener,HE
AT,B_Ifac,B_Vfac ,B_Ener,B_Pmax,B_CorrF,B_Wear,
B_Splash,B_GunRes,B_Zmax,B_WeldTime,
P_aveR,P_spatter,Ca,Va,Ra,Cm,Cl,Vm,Vl,Rm,Rl,Clast,Vlast], dtype=object)
combi=np.transpose(combi)
def remove_square_brackets(arr):
    return np.array([[str(item).strip('[').strip(']') if isinstance(item, list)
else item for item in row] for row in arr])
combi = remove_square_brackets(combi)
csv_data = RUIfolder+'\\'+nameA+'.csv'
header = "No,Name,Station,Program,Time,Parameter
Time,PGnumber,Energy,Heat,Ifactor,Vfactor," \
"BEnergy,BPmax,BCorrF,BWear,BSplash,GunResistance,Zmax,Welddtime,Resistance," \
"Spatter,C1,C2,Ca,Call,V1,V2,Va,Vall,R1,R2,Ra,Rall,Ch,Cl,Vh,Vl,Rh,Rl,Clast,Vlast,Result"

```

```

np.savetxt(csv_data, combi, delimiter=',', fmt="%s",
header=header, comments="")

spot_data = pd.read_csv(csv_data)
for root, dirs, files in os.walk(path_raw):
    for filename in files:
        if filename.endswith('.rui'):
            try:
                os.remove(os.path.join(root, filename))
            except Exception as e:
                print(f"1Error removing file: {e}")
for root, dirs, files in os.walk(src_extract):
    for filename in files:
        if not filename.endswith('.rui'):
            try:
                os.remove(os.path.join(root, filename))
            except Exception as e:
                print(f"2Error removing file: {e}")
spot_program = int(combi[0][6])
spot_station = str(combi[0][2])
if spot_station == '8Y025WC05':
    if spot_program in [101, 102, 104, 107, 109, 113]:
        ML(spot_data)
    else:
        print("No prediction")
else: pass
if spot_program in [255]:
    tip_check(spot_data)
    print("No prediction")
else:
    print("No prediction")
end = time.time()

```

```

        print("The time of execution of "+nameA+" is :",round((end-start) *
10**3), "ms")

    except Exception as e:
        print(f"333Error renaming file: {e}")
    try: os.remove(csv_data)
    except: continue

if __name__ == "__main__":
    if not os.path.exists(csv_resis):
        with open(csv_resis, 'w', newline="") as file:
            writer = csv.writer(file)
            writer.writerow(resis_header)
            print(f'Created a new CSV file: {csv_resis}')
    if not os.path.exists(csv_result):
        with open(csv_result, 'w', newline="") as file:
            writer = csv.writer(file)
            writer.writerow(result_header)
            print(f'Created a new CSV file: {csv_result}')
    move_files_locally(src, dest_local)
    move_files_remotely(src, dest_remote, hostname, port, username, password)
    event_handler = FileChangeHandler()
    observer = Observer()
    observer.schedule(event_handler, src, recursive=True)
    observer.start()

    try:
        while True:
            gc.disable()
            movefile(machine_src, path_raw)
            rui2csv(path_raw, src_extract, spot_data, result_rsw, csv_data, predictions)
            time.sleep(0.1)
            tip_station(csv_resis)
            gc.enable()

```

```
except KeyboardInterrupt:  
    observer.stop()  
observer.join()
```



ภาคผนวก ข

การเขียนโปรแกรม Tessonnic ในการวัดขนาดของรอยเชื่อม




การใช้งานเครื่องมือ Tessonics F1


ระบบการวัดนี้ได้รับการพัฒนาเพื่อการควบคุมคุณภาพการเชื่อม RSW ในแบบสองมิติและไม่สามารถฉายขึ้นงาน เป็นอุปกรณ์แบบพกพาดังภาพที่ ง.1 ที่ใช้งานง่ายนี้สามารถสร้างภาพของโครงสร้างภายในของจุดเชื่อมได้ โดยการแสดงภาพแบบเรียลไทม์บนหน้าจอ เครื่องมือนี้ยังสามารถประเมินขนาดเส้นผ่านศูนย์กลางของรอยเชื่อม(nugget)และเปรียบเทียบกับข้อกำหนดขั้นต่ำของขนาดนักเก็ตที่กำหนดไว้ล่วงหน้าได้ ด้วยเทคโนโลยีเฉพาะของตัวแปลงสัญญาณอัลตราโซนิกแบบเมทริกซ์หลายช่อง (multi-channel ultrasonic matrix transducer) ดังภาพที่ ง.2 เพื่อเก็บข้อมูลจากพื้นผิวและโครงสร้างภายในของนักเก็ตได้ โดยใช้ข้อมูลนี้ในการสร้างภาพของจุดเชื่อมขึ้นใหม่และประเมินค่าเส้นผ่านศูนย์กลางเฉลี่ยของพื้นที่นักเก็ตแบบเรียลไทม์



รูปที่ ง.1 เครื่องมือวัดขนาดรอยเชื่อม RSW (1) F1 Tablet (2) Probe (3) Batteries (4) Shoulder strap (5) RF remote control (6) Charging cable (7) Charger/AC adapter



รูปที่ ง.2 หัววัดขนาดรอยเชื่อม RSW (1) Housing (2) Matrix transducer (3) Delay line (4) Coupler




รูปที่ ง.3 หน้าต่างโปรแกรม RWSA

โดยหน้าต่างโปรแกรมนั้น ได้มีคำสั่งและส่วนแสดงผลดังนี้


- 1) Button area แสดงคำสั่งที่ใช้ภายในโปรแกรม
 Setup: ตั้งค่าอุปกรณ์สำหรับการวัดการเชื่อมบนวัสดุโลหะ
 Get: ทำการรับสัญญาณการวัด
 Pass: ปุ่มนี้เพื่อยืนยันคุณภาพของจุดเชื่อม ณ ปัจจุบัน
 Fail: ปุ่มนี้เพื่อยืนยันคุณภาพของจุดเชื่อมว่าไม่ผ่าน
- 2) Indicator แสดงขนาดเส้นผ่านศูนย์กลางของรอยเชื่อม (nugget) และแสดงการประมาณขนาดของรอยเชื่อม(nugget)และการยุบของรอยเชื่อม
- 3) C-scan area
 วงกลมเส้นประ : แสดงการประมาณตำแหน่งและเส้นผ่านศูนย์กลางของนั้กเกิดเชื่อมโดยอัตโนมัติ หากการประมาณผิดพลาด
 สีเหลี่ยมพื้นหลังขนาดเล็ก : แทนองค์ประกอบของตัวแปลงสัญญาณ องค์ประกอบที่เลือกอยู่ในปัจจุบันจะแสดงรูปคลื่นในพื้นที่ A-scan
 วงล้อหมุน : แสดงขนาดขั้นต่ำและขนาดมาตรฐานของจุดเชื่อม

ปุ่มการเว้นของรอยเชื่อม : ตั้งค่าช่วงการเว้นที่ยอมรับได้สำหรับรอยเชื่อมที่กำลังวัด



รูปที่ ๔.4 พื้นที่ C-Scan

- 4) Inspection and information area แสดงภาพชิ้นงานที่กำลังทำการวัดหรือตรวจสอบในปัจจุบัน
- 5) Measurement history จัดเก็บโดยเรียงตามลำดับเวลาการวัด หากไม่ได้อยู่ในโหมดการตรวจสอบ จะแสดงเฉพาะประวัติการวัดที่เคยดำเนินการ หากอยู่ในโหมดการตรวจสอบ แถบนี้จะแสดงการวัดทั้งหมด
- 6) A-scan area แสดงรูปคลื่น (A-Scans) สำหรับองค์ประกอบแต่ละส่วนในเมทริกซ์ของตัวแปลงสัญญาณ



รูปที่ ๔.5 พื้นที่ A-Scan

เส้นขาว : แสดง A-scan สำหรับองค์ประกอบที่เลือกอยู่ในปัจจุบัน
 เงาในพื้นที่หลัง : แสดง A-scans ที่ประกอบขึ้นจากองค์ประกอบทั้งหมด
 กล้องตัวเลข : แสดงตำแหน่งของการสะท้อนจากผนังด้านหน้าและด้านหลัง
 เส้นแนวตั้งสีเขียว: แสดงช่วงสำหรับการเก็บข้อมูล C-scan

- 7) Status bar แสดงชื่อผู้ใช้ที่ล็อกอินอยู่ในปัจจุบัน การตรวจสอบ (Inspection) และลำดับการตรวจสอบ (Inspection Order) ที่กำลังดำเนินการวัดอยู่



ภาคผนวก ค

การเขียนโปรแกรมควบคุมหุ่นยนต์ในสายการผลิต

มหาวิทยาลัยเทคโนโลยีสุรนารี

KAWASAKI Robot program with AS Language

```
.PROGRAM pg11()#248009;P703 CC WORK PROGRAM
,*****
;
; COMPANY : FORD
; PROGRAM : Pg11
; REVISED LAST: 18/11/2022
; Produced by COMAU CHINA ,Modify by NUTTAPONG
,*****
CALL verify11; CHECK PROGRAM 11 SELECT FROM PLC
,*****
HOME
;
SIGNAL 1,2,3 ; CLR TO ADV XFER, CLR TO RET XFER, CLR TO UNCLAMP
SIGNAL -1,-2,-3 ; ROBOT IN CYCLE
SWAIT 1002 ; CYCLE START
;
CALL pg11weld1; robot weld path
;
SIGNAL 1,2,3; CLR TO ADV XFER, CLR TO RET XFER, CLR TO UNCLAMP
;
HOME
;
.END

.PROGRAM pg11weld1()#247996;P703 CC WELDING PROGRAM
,*****
;
; COMPANY : FORD
; PROGRAM : S025R01_DownloadProgram Signal Weld
; REVISED LAST: 20/11/2022
; Produced by COMAU CHINA ,Modify by NUTTAPONG
,*****
HOME
```

```

CALL entzone(9); Welding in 025_Station
;
; modelid = 11
CALL model_id(11)
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[53.088,-27.025,-28.748,-
111.39,25.669,46.208,99.999] ;via387
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[51.462,-16.291,-49.744,-56.042,44.947,-16.976,226.9]
;via386
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.183,-5.2362,-41.452,-46.843,42.633,-24.739,226.9]
;via385
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[46.887,-4.9968,-34.835,-55.385,39.527,-
15.156,26.938] ;
;60500_05_L_P703_CC_T3
;weld_pg101
LINEAR SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,1,1,1) OX= WX=
CL1=3.200,20.0,5.0,20.0,5.0,20.0,5.0 #[47.023,-5.2068,-33.594,-56.954,38.828,-
13.669,3.9638] ;60500_05_L_P703_CC_T3
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[46.887,-4.9968,-34.835,-55.385,39.527,-
15.156,26.936] ;
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[49.108,-9.733,-48.366,-37.386,50.946,-29.577,76.793]
;
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[49.601,-11.721,-49.107,-37.797,50.391,-
28.562,32.173] ;
;60500_04_L_P703_CC_T3

```

;weld_pg102

LINEAR SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,2,1,1) OX= WX=
CL1=3.200,20.0,7.0,20.0,7.0,20.0,7.0 #[50.337,-12.175,-48.086,-39.248,49.797,-
26.973,3.6511] ;60500_04_L_P703_CC_T3

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[49.611,-11.243,-48.93,-37.797,50.391,-28.562,43.505]

;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[46.85,-9.0038,-45.307,-35.975,48.009,-29.636,29.199]

;

;60500_02_L_P703_CC_T3

;weld_pg103

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,3,1,1) OX= WX=
CL1=3.200,15.0,5.0,15.0,5.0,15.0,5.0 #[47.566,-9.5102,-44.331,-37.628,47.171,-
27.802,3.0814] ;60500_02_L_P703_CC_T3

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[46.85,-9.0038,-45.306,-35.975,48.009,-29.636,29.201]

;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.436,-3.5368,-36.117,-46.089,42.299,-
21.891,62.591] ;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[42.983,2.0148,-25.956,-56.869,34.935,-
11.698,42.665] ;

;60500_01_L_P703_CC_T3

;weld_pg104

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,4,1,1) OX= WX=
CL1=3.200,20.0,7.0,20.0,7.0,20.0,7.0 #[43.485,1.5938,-24.873,-58.579,34.691,-
9.8388,3.1594] ;60500_01_L_P703_CC_T3

```

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[43.081,1.9153,-25.956,-56.869,34.935,-11.698,40.67]
;
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[40.646,3.3641,-22.588,-59.314,32.008,-10.64,33.249]
;
;60500_06_L_P703_CC_T3
;weld_pg105
JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,5,1,1) OX= WX=
CL1=3.200,20.0,7.0,20.0,7.0,20.0,7.0 #[41.132,3.3737,-21.191,-61.627,31.576,-
8.0778,2.9496] ;60500_06_L_P703_CC_T3
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[40.813,3.3639,-22.588,-59.314,32.008,-10.64,33.247]
;via388
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[39.467,5.6815,-20.989,-56.694,31.363,-
13.015,52.299] ;via388
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[38.106,7.021,-19.243,-55.513,30.125,-13.683,52.299]
;via389
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[38.141,6.9238,-18.784,-56.358,29.839,-12.726,42.8] ;
;60501_06_L_P703_CC_T3
;weld_pg106
JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,6,1,1) OX= WX=
CL1=3.000,20.0,7.0,20.0,7.0,20.0,7.0 #[38.668,7.0372,-17.126,-59.327,29.422,-
9.5656,2.6666] ;60501_06_L_P703_CC_T3
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[38.363,7.0728,-18.428,-56.947,29.893,-
12.157,35.206] ;

```

```

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[36.632,7.1938,-17.992,-54.301,28.527,-
15.534,38.399] ;
;60501_05_L_P703_CC_T3
;weld_pg107

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,7,1,1) OX= WX=
CL1=3.000,15.0,7.0,15.0,7.0,15.0,7.0 #[37.104,7.2792,-16.453,-57.179,28.064,-
12.488,2.4872] ;60501_05_L_P703_CC_T3

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[36.721,7.1662,-17.646,-54.987,28.376,-14.796,21.2]
;via390

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[36.985,7.1235,-21.758,-50.434,30.909,-
18.977,135.96] ;via390

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[41.384,22.078,-10.142,-58.389,38.825,-
1.6409,146.72] ;via391

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[46.008,29.398,-1.9511,-63.28,54.842,2.0098,29.947] ;
;60501_10_L_P703_CC_T3
;weld_pg108

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,8,1,1) OX= WX=
CL1=3.500,15.0,7.0,15.0,7.0,15.0,7.0 #[46.449,29.699,-0.37457,-
64.433,54.622,3.6159,2.3189] ;60501_10_L_P703_CC_T3

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[46.008,29.398,-1.9511,-63.28,54.842,2.0098,29.947] ;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.728,29.762,-1.6253,-63.282,55.64,2.1896,43.087] ;
;60502_06_L_P703_CC_T2
;weld_pg109

```

```

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,9,1,1) OX= WX=
CL1=2.600,15.0,7.0,15.0,7.0,15.0,7.0 #[46.164,29.461,-0.39328,-
64.273,55.312,3.681,2.8312] ;60502_06_L_P703_CC_T2
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.825,29.208,-1.6477,-63.392,55.491,2.4318,22.391]
;
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.23,29.536,-0.83926,-63.269,54.131,2.6997,27.456]
;
;60502_05_L_P703_CC_T2
;weld_pg110
JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,10,1,1) OX= WX=
CL1=2.600,20.0,7.0,20.0,7.0,20.0,7.0 #[45.571,29.793,0.4192,-
64.186,53.953,3.9717,2.897] ;60502_05_L_P703_CC_T2
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.286,29.76,-0.76569,-63.218,54.242,2.5627,21.2] ;
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.491,30.128,-0.59019,-
63.284,53.942,2.4637,23.293] ;
;60501_11_L_P703_CC_T3
;weld_pg111
JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,11,1,1) OX= WX=
CL1=3.500,20.0,7.0,20.0,7.0,20.0,7.0 #[45.852,30.35,0.72625,-
64.285,53.739,3.8511,2.1468] ;60501_11_L_P703_CC_T3
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.491,30.128,-0.59019,-
63.284,53.942,2.4637,23.295] ;via393
JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[45.161,28.101,-11.468,-54.699,60.675,-
8.5107,214.55] ;via393

```

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [38.541,0.55619,-30.407,-50.12,33.404,-
 20.292,219.12] ;via395

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [44.059,-8.5405,-33.724,-63.919,34.354,-
 6.8269,227.12] ;via396

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [58.465,-28.27,-44.611,-
 83.892,44.995,12.284,150];via397

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [5.8555,-35.228,-46.111,-77.323,-61.057,5.3006,150] ;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [52.503,-43.497,-39.191,-20.389,-60.449,3.5487,200]
 ;via403

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [25.678,-34.421,-40.172,-35.878,-
 65.388,37.527,250.24] ;via402

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [34.935,-29.71,-45.109,-27.856,-48.154,29.985,250.24]
 ;via401

CALL entzone(2); with 8Y025_R02_bx200l_b001

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [26.133,-5.1516,-22.69,-36.16,-48.604,31.844,259.37]
 ;via400

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [15.044,-13.61,-33.69,-51.141,-
 57.321,62.368,200];via400

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [-1.8221,-2.7019,-31.403,-56.634,-79.971,89.856,200]
 ;via399

```

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[3.8141,-2.5701,-33.79,-59.348,-74.496,89.39,200] ;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[3.8455,-3.4858,-36.446,-59.787,-73.592,90.935,22.58]
;

;60501_12_L_P703_CC_T3
;weld_pg112

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,12,1,1) OX= WX=
CL1=3.000,20.0,7.0,20.0,7.0,20.0,7.0 #[4.3701,-4.7994,-36.883,-59.782,-
73.651,89.914,3.53] ;60501_12_L_P703_CC_T3

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[3.8453,-3.4858,-36.446,-59.787,-73.592,90.935,22.58]
;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[2.8962,-3.7664,-35.146,-59.016,-
75.088,89.948,27.439] ;

;60502_07_L_P703_CC_T2
;weld_pg113

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,13,1,1) OX= WX=
CL1=2.600,20.0,7.0,20.0,7.0,20.0,7.0 #[3.1401,-5.169,-35.935,-58.974,-
75.225,89.292,2.1932] ;60502_07_L_P703_CC_T2

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[2.8022,-3.4302,-34.961,-59.017,-
75.071,90.113,41.215] ;

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[-2.6376,-1.2601,-33.273,-56.115,-
82.511,100.32,43.99] ;

;60503_09_L_P703_CC_T3
;weld_pg114

```

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,14,1,1) OX= WX=
 CL1=0.000,20.0,7.0,20.0,7.0,20.0,7.0 #[-2.9618,-2.6578,-34.824,-56.077,-
 82.789,101.05,2.5294] ;60503_09_L_P703_CC_T3
 JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[-2.6376,-1.2601,-33.273,-56.115,-
 82.511,100.32,43.99] ;via990
 JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[-4.0316,3.8271,-24.928,-60.275,-
 90.979,92.454,59.997] ;via990
 JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[-4.7442,4.8246,-23.264,-62.731,-
 93.125,89.616,59.996] ;via150
 JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[-3.3769,6.8228,-16.527,-64.961,-
 94.366,78.272,59.996] ;via621
 JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[-1.061,12.259,-4.2472,-64.696,-97.056,63.953,59.996]
 ;via629
 JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[0.42163,13.665,-0.12565,-58.292,-99.444,63.253,60]
 ;via989
 JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[1.9503,10.531,-3.7422,-57.344,-95.252,63.043,28.06]
 ;
 ;60503_08_L_P703_CC_T3
 ;weld_pg115
 JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,15,1,1) OX= WX=
 CL1=2.800,20.0,7.0,20.0,7.0,20.0,7.0 #[2.1324,9.4716,-4.2189,-57.443,-
 95.416,62.453,2.5648] ;60503_08_L_P703_CC_T3

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [1.9355,10.629,-3.6991,-57.335,-
 95.235,63.096,47.359] ;via404

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [0.59792,14.484,0.84355,-74.796,-
 87.513,45.562,59.998] ;via404

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [1.2049,18.713,9.5229,-76.555,-84.395,34.572,60]
 ;via406

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [1.238,21.977,15.591,-77.888,-82.387,27.014,28.84] ;
 ;60503_07_L_P703_CC_T3
 ;weld_pg116

JOINT SPEED9 ACCU0 TIMER0 TOOL1 WORK0 CLAMP1 (ON,16,1,1) OX= WX=
 CL1=2.800,20.0,5.0,20.0,5.0,20.0,5.0 # [1.1628,21.638,16.139,-78.076,-
 82.872,26.183,2.3745] ;60503_07_L_P703_CC_T3

SIGNAL 272; WELD SEQUENCE 1 COMPLETE

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [1.2378,21.977,15.591,-77.888,-82.387,27.014,28.84]
 ;via407

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [1.2049,18.713,9.5231,-76.555,-84.395,34.572,59.998]
 ;via407

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [0.65623,21.753,15.995,-74.624,-
 81.549,26.094,242.66] ;via408

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
 CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 # [11.541,21.335,23.942,-56.532,-70.135,9.7426,281.81]
 ;via409

```

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[16.992,23.678,37.58,-42.648,-73.082,-5.9038,278.61]
;via410

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[9.583,21.483,36.865,-45.544,-79.134,-1.6622,279.02]
;via412

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[10.827,-5.1643,19.455,-44.083,-84.87,-9.0715,260]
;via413

JOINT SPEED9 ACCU4 TIMER0 TOOL1 WORK0 CLAMP1 (OFF,0,1,1) OX= WX=
CL1=0.000,0.0,0.0,0.0,0.0,0.0,0.0 #[6.8274,-49.088,-21.969,-91.878,-4.3361,25.822,260] ;
HOME
SIGNAL -272; WELD SEQUENCE 1 COMPLETE
; modelid = 0
CALL model_id(0)
CALL extzone(2); Clear Zone with 8Y025_R02_bx200l_b001
CALL extzone(9); Welding out 025_Station
IF SIG(1238) THEN ;TipDress REQ from PLC
CALL pg10tipdress1
END


```

ภาคผนวก ง


การเขียนโปรแกรม PLC สำหรับควบคุมการแจ้งเตือนในสายการผลิต




1) ออกแบบส่วนการรับสัญญาณจากหุ่นยนต์



2) ออกแบบส่วนการรับสัญญาณจากคอมพิวเตอร์ทำนายผล



3) ออกแบบส่วนการส่งสัญญาณแจ้งเตือนและทำงานซ้ำของหุ่นยนต์




ภาคผนวก จ

บทความทางวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา



รายชื่อบทความทางวิชาการที่ได้รับการตีพิมพ์เผยแพร่ในระหว่างศึกษา

Nuttapong Chuenmee, Nattachai Phothi, Kontorn Chamniprasart, Sorada Khaengkarn and Jiraphon Srisertpol (2024). “Machine Learning for Predicting Resistance Spot Weld Quality in Automotive Manufacturing” **Results in Engineering**, 25, 103570; <https://doi.org/10.1016/j.rineng.2024.103570>





Research paper

Machine learning for predicting resistance spot weld quality in automotive manufacturing

Nuttapong Chuenmee^a, Nattachai Phothi^b, Kontorn Chamniprasart^a, Sorada Khaengkarn^a, Jiraphon Srisertpol^{a,*}^a Mechatronics Engineering Program, School of Mechanical Engineering, Suranaree University of Technology, Nakhon Ratchasima, Thailand^b Department of Production Engineering Technology, Faculty of Industrial Technology, Loei Rajabhat University, Loei, Thailand

ARTICLE INFO

Keywords:

Resistance spot welding (RSW)
Weld inspection
Weld quality classification
Data analysis
Machine learning

ABSTRACT

Resistance Spot Welding (RSW) stands as the primary joining process in the automotive industry, renowned for its suitability for automation and integration into high-production assembly lines. Despite its advantages, accurately evaluating RSW remains challenging, resulting in additional costs and production steps. Current inspection methods, reliant on random checks after cars leave the Body-in-White (BIW), often lead to significant time losses, emphasizing the necessity for enhanced quality assessment. This study aims to transition from random checks to 100 percent inspection using data analysis and machine learning techniques. By predicting weld quality levels prior to car body completion, this approach aims to improve quality control. Five distinct algorithms—Artificial Neural Network (ANN), Convolution Neural Network (CNN), Long Short-Term Memory (LSTM), Random Forest Classifier (RFC), and Extreme Gradient Boosting (XGBoost)—were assessed. The research highlights that the proposed methodology, particularly leveraging XGBoost, achieves a notable prediction accuracy of 97.1% when applied to unseen data.

1. Introduction

In the assembly of automobile parts, quality control in welding is paramount, ensuring the durability and safety of the vehicle. Welding, which accounts for a quarter of the primary manufacturing processes in car manufacturing, demands strict adherence to quality and precision standards. According to the Federation of Thai Industries, Thailand's vehicle production from January to December 2023 nearly reached two million, with pickup trucks accounting for over 1.1 million units, or 62.7% of total production. A typical pickup truck consists of more than 15,000 essential components, including the engine, transmission, suspension, steering systems, brakes, wheels, interior features, electrical and safety systems, and the body and frame, which vary according to the model. The car body is the primary focus of welding operations, with the monocoque design being a common technique for constructing vehicle bodies, involving the assembly and welding of over a hundred steel parts to form the car's structure.

In the automotive body assembly industry, some components still necessitate human labor welding due to cost constraints, while industrial robots can weld nearly all components. An automotive assembly

plant might have as many as 300 welding robots, and the plant we studied has been using welding robots for over seven years. Despite rigorous maintenance to preserve welding efficiency, the search for measuring instruments to assess welding quality remains a vital aspect of quality control. Instruments such as force sensors [1], distance sensors [2], vision camera [3], thermal cameras [4,5], vibration sensors [6] and acoustics sensors [7] are considered, though their high costs significantly impact production expenses, as each robot would need its own installation. This raises an important question: is this investment worthwhile?

Currently, the plant we studied employs a random sampling method for welding quality [8,9] checks, in line with IATF 16949:2016, utilizing Ultrasonic Testing (UT) [10], pry-bar testing [11], and teardown method [12]. Among these, UT is widely used despite its high cost, as it allows for post-welding inspections to measure material thickness and detect defects. However, UT inspections are limited by their random sampling approach and are conducted only after the monocoque body assembly is complete, potentially missing critical defects. Each inspection requires a team of 12 persons, including 1 engineer, 3 technicians, and 8 inspectors, underscoring the resource-intensive nature of the current system.

^{*} Corresponding author.E-mail address: jiraphon@sut.ac.th (J. Srisertpol).<https://doi.org/10.1016/j.rineng.2024.103570>

Received 29 August 2024; Received in revised form 20 November 2024; Accepted 27 November 2024

Available online 20 December 2024

2590-1230/© 2024 The Author(s). Published by Elsevier B.V. This is an open access article under the CC BY-NC license (<http://creativecommons.org/licenses/by-nc/4.0/>).

The efficient utilization of advanced manufacturing technologies, as shown in studies applying Finite Element Analysis (FEA) and response surface methods for design optimization [13], highlights the potential for system-wide improvements. In the existing automated systems, only 5% of weld joints are inspected, with heavy reliance on low-density manual inspections. With the integration of Machine Learning for Predicting Resistance Spot Weld Quality, inspection coverage has been enhanced to 100%. This transformative improvement significantly reduces dependency on manual labor while enabling targeted inspections in areas of concern, thereby improving efficiency and accuracy.

Currently, UT pry inspections are performed at a rate of one inspection per joint per shift. In newly launched systems, the machine learning framework aims to achieve 90%–95% inspection coverage for joints, with recurring inspections on stable joints expected to decrease from once per shift to once per week during the transitional phase. Additionally, the system provides real-time notifications for areas requiring attention, further augmenting the overall inspection process and driving proactive quality assurance.

A clear example of this impact is when a weld in the Floor Panel Carrier System fails to meet the factory's quality standards. The team then analyzes the cause and origin of the defect to determine the specific process in which it occurred. For instance, was the defect introduced during the welding of the Floor Panel Carrier System itself or during its assembly with other parts in the monocoque body construction? If the analysis indicates that the defect originated in the welding process of the Floor Panel Carrier System, the production line halts immediately to inspect all related parts, tracing back to the BIW. This rapid response is feasible because the defect's location on the part is precisely identified, and inspecting a single weld defect takes no more than two minutes. If additional parts with substandard welds are discovered during the inspection, they are gathered and sent for repair before being reintegrated into the production line. Although the defect was identified only in the Floor Panel Carrier System welds, the simultaneous welding of other parts in the monocoque body construction necessitates halting the entire production line. This halt affects multiple sections—including the Dash Compartment, Rear Compartment, Roof, Left-Side Frame, and Right-Side Frame (as illustrated in Fig. 5)—until the inspection and repair of the Floor Panel Carrier System welds are completed. The inspection process is thorough, covering more than just the welding procedure of the Floor Panel Carrier System. It includes a forward trace, in which previously assembled monocoque bodies are also inspected—reviewing 30 vehicles per inspection cycle, equivalent to approximately one hour of production. This forward trace continues until the Floor Panel Carrier System is confirmed to be free of weld defects within the cycle. If a defect is detected, an additional retrospective inspection is carried out, reviewing another 30 vehicles.

In 2022, when an incident report revealed that 120 out of 600 manufactured vehicle bodies exhibited weld quality issues at the BIW stage. This resulted in approximately 10 hours of inspection and repair time, equivalent to a full day of remedial work. Furthermore, one vehicle displayed performance issues after production, prompting the company to assemble a team of specialists for a thorough investigation. The analysis traced the problem to welds that did not meet required standards, identifying inferior weld seams as the primary cause. This led to a temporary suspension of the BIW process to allow the team to examine the welding robots and guns, implement corrective actions, and improve the process.

The examples provided demonstrate that the weld quality inspection process occurs after the completion of the monocoque body. If the welds do not meet the required standards, it is necessary to trace back to the BIW process and monocoque body simultaneously in both directions, resulting in considerable time and labor expenditures. This raises a critical question: is it possible to evaluate welding quality in real-time during welding robot operation, enabling immediate corrections before advancing to the monocoque body welding phase? This research aims to leverage Industry 4.0 technologies to transform the existing inspection

process into an automated system [14–17]. By harnessing data from welding robots and incorporating artificial intelligence, we aim to identify and categorize weld quality, enhancing the efficiency and accuracy of the inspection process.

This research focuses on evaluating the weld quality of Front/Rear floor components in vehicles. These components are shaped from sheet metal through a pressing process and joined using Resistance Spot Welding (RSW) [18] to create a larger assembly known as the Floor Panel Carrier System. This assembly is integral to the vehicle's structure, providing the base of the passenger compartment and distributing stress and weight evenly. It also collaborates with other components to mitigate impact forces, safeguarding passengers. Typically, this welding is executed by automated robots. Ensuring the precision and quality of RSW is critical for the vehicle's safety and structural integrity. Nevertheless, accurately assessing RSW quality poses significant challenges.

The weld quality inspection process commonly identifies six defect types: undersized, discrepant, edge, missing, off-location, and explosion defects. This research focuses on three defect types: undersized, discrepant, and explosion. Undersized and discrepant defects are grouped under the term "Cold weld" in accordance with the factory's quality standards, as they pose safety risks and require repair before the components are sent to the paint shop. Explosion defects are included due to their high frequency and potential severity. This paper introduces an AI-enhanced inspection process that categorizes weld quality into three levels: Level 0 for "Satisfy," Level 1 for "Expulsion," and Level 2 for "Cold weld."

The aim is to create a real-time system for immediate detection of welding defects, ensuring complete inspection of every vehicle structure, thereby achieving 100% inspection coverage. This is a significant improvement over the current method, which randomly inspects only 5% of production using a combination of non-destructive and destructive tests. The proposed system is expected to attain a minimum accuracy rate of 90% to be considered effective.

2. Literature reviews

In a study by Sim and Yun Kim [19], the researchers propose a hybrid prediction method that combines a theoretical physical model with a machine learning approach. This hybrid method integrates the theoretical model with spline interpolation, establishing a mathematical framework for predicting nugget growth and formation in RSW. Experimental results indicate that the proposed hybrid method produces more accurate and meaningful predictions compared to existing algorithms when applied to RSW datasets. Furthermore, the hybrid method demonstrates robustness to data errors, making it a durable and reliable prediction approach.

Wang et al. [20] conducted a study utilizing a particle swarm optimization (PSO) algorithm for intelligent parameter measurement in a three-phase medium-frequency direct current (MFDC) RSW machine. To evaluate the accuracy and reliability of these measurements, a numerical model was developed using MATLAB Simulink. The comparative analysis indicated a maximum error of only 1% across all measured parameters, underscoring the effectiveness of the proposed intelligent parameter measurement method and demonstrating its ability to deliver accurate and reliable results for the RSW machine.

In their study, Yu et al. [21] introduced a reference-based adaptive RSW method aimed at mitigating the shunting effect in short-pitch (≤ 40 mm) RSW. They developed an exponential model to predict weld pitch as a function of dynamic factors, analyzed the relationship between nugget diameter and heat input relative to weld pitch, and established a logistic growth model for predicting heat input compensation. Experimental results showed that this approach increased nugget diameter and decreased the shunting effect compared to conventional welding methods. These findings underscore the effectiveness of the proposed reference-based adaptive RSW method in minimizing the shunting effect in short-pitch RSW.

Dwivedi et al. [22] investigated the effects of weld time on joint strength, nugget size, and fracture mode in Hastelloy X weldments, a Nickel-Chromium-Iron-Molybdenum alloy, produced via the RSW process. The study aimed to determine the parameters and primary causes of failure using fractography, which analyzes the fracture surfaces of materials using Scanning Electron Microscopy (SEM). The principal findings indicated that the diameter of the weld nugget increased proportionally with weld time, and the joint strength of the spot-welded alloy improved until reaching an optimal weld duration. Nonetheless, the application of excessive heat and electrode pressure during the welding process initiated cracking.

Moshayedi and Sattari-Far [23] explored the correlation between nugget size, welding time, and current, comparing predicted nugget sizes with actual experimental results using a two-dimensional finite element model. This model, developed through fully coupled electrical-thermal and incrementally coupled thermal-mechanical analyses. The study also investigated variations in pressure and contact area during the welding process. Findings indicated compressive stress at the nugget center, with tensile stress increasing toward the edge. The highest tensile stress appeared outside the nugget, near its periphery. Additionally, radial residual stress magnitudes in the inner and outer areas of the weld nugget rose with increased welding time and current, though a slight decrease was observed in the edge regions of the nugget.

In their study, Podrżaj et al. [24] developed an experimental setup to investigate the effects of poor fit-up conditions on welding outcomes. This setup enabled the measurement of welding force during the initial contact between electrode tips and weld pieces, considering varying intensities of deformation and pin distances. Additionally, the system allowed precise quantification of welding force during initial contact. To reduce the negative impact of poor fit-up conditions on weld strength, the researchers examined the introduction of a preheating phase. While preheating improved weld strength, a notable disparity remained between the weld strength of non-deformed welds and those under poor fit-up conditions, even at elevated preheating currents.

Kang et al. [25] conducted experimental validation of theoretical analyses on constant current control (CCC) and constant power control (CPC) in welding processes. The results indicated that CCC outperforms CPC, as the latter is subject to a higher number of interfering variables. Furthermore, dynamic resistance analysis demonstrated that CCC supports a more reliable welding process, enabling earlier detection of the initial melting point compared to CPC. This experimental validation provides valuable insights for practical welding production, guiding welders in selecting an appropriate control strategy and contributing to enhanced energy efficiency in welding applications.

Xia et al. [26] introduced a novel approach to nondestructive measurement of weld penetration in robotic RSW. Their study involved in-depth analysis of electrode displacement signals through mechanism analysis and feature extraction. The reliability of these signal features was evaluated under normal and abnormal manufacturing conditions. Furthermore, they established an analytical model to predict weld penetration using physical modeling, which facilitates online measurement.

Zhou et al. [27] conducted a study focusing on the characteristics of the RSW process and the fundamental principle of electrical resistivity. They developed a comprehensive mathematical description for measuring the electrical resistivity of molten nuggets. Subsequently, a series of experiments were conducted, involving RSW operations to acquire dynamic resistance data, online temperature measurements to determine the electrical resistivity of solid metals, and metallurgical analyses to ascertain the size of molten nuggets. This work contributes to the establishment of accurate mathematical models for the RSW process, thereby aiding in welding automation, related research endeavors, and practical production processes.

In their study, Xia et al. [28] presented a novel approach for the online evaluation of expulsion intensity in RSW. By employing an advanced multi-sensor monitoring system and high-speed camera, they simultaneously monitored dynamic resistance, electrode force, and elec-

trode displacement signals to analyze their instantaneous features. The experimental results revealed that the magnitude of the sudden decrease in force and displacement signals correlates with the expelled metal's weight, while no clear relationship was found between the sudden drop in resistance and expulsion severity. Further analysis established that sudden variations in electrode force serve as an optimal indicator for accurately assessing expulsion magnitude in servo gun systems.

Nazir et al. [29] proposed a comprehensive online tool condition monitoring (TCM) system for ultrasonic metal welding (UMW) that leverages sensor fusion and machine learning (ML) techniques. They engineered a data acquisition (DAQ) system to gather in-situ sensing signals throughout the welding process. From this data, a large pool of features was extracted, and a subset was selected for machine learning classification. Several classification models were trained, validated, and tested with experimental data, achieving near-perfect classification accuracy, nearly 100%, for both training and testing datasets.

In the study by Lee et al. [30], the focus is on developing a real-time online monitoring and diagnosis framework for angular misalignment in robot spot-welding systems. Data is collected using voltage and current sensors, capturing the associated mass data under both normal and abnormal (angular misalignment) conditions. Two categories of features are extracted: dynamic resistance (DR) features and voltage and current features decomposed by wavelet transform. Three types of critical feature sets—DR features, wavelet transform features, and hybrid features combining both—are prepared to train machine learning-based models. Support vector machine (SVM) and probabilistic neural network (PNN) are applied to establish the diagnosis models, and their diagnostic accuracy and robustness are evaluated.

El-Sari et al. [31] investigated the ability of multi-layer perceptron regression models to extrapolate, applying them with data markedly different from the training data in material and coating composition to predict nugget diameter based on process data. The study found that models which included features from the dynamic resistance curve performed better than those based solely on process parameters. This highlights the beneficial influence of process signals on the predictive precision and stability of ANN algorithms, particularly for datasets beyond the original training range.

Chino et al. [32] developed a nugget model for RSWs and extended the inherent strain method to predict RSW deformation quickly. Deformation induced by RSW involves electrical-thermal-mechanical coupling analysis, which is complex and time-consuming. Furthermore, using the inherent strain method, they efficiently predicted the deformation of a vehicle part with 23 RSWs in approximately 90 minutes, demonstrating good accuracy compared to measurements.

Hua et al. [33] have developed an in-situ ultrasonic detection system for automatic evaluation of RSW quality. This system utilizes an embedded probe to capture UT signals from spot welds post-RSW. Various signal eigenvalues, including acoustic pressure amplitude, echo distance, main frequency, main frequency amplitude, and low-frequency component, are obtained. Corresponding mathematical calculation models are established to enable quantitative ultrasonic evaluation of RSW quality. Additionally, specialized evaluation software has been developed to automatically calculate nugget sizes and classify weld types.

3. Methodology

The RSW process in the BIW stage of this automobile manufacturing involves welding sheet metal components by applying voltage and electric current through a copper alloy electrode, generating heat to create a weld nugget. This critical process in monocoque assembly is carried out automatically using robotic arms for precision and consistency. The main equipment is robotic welding guns. Weld quality is ensured through both destructive and non-destructive testing, including UT and a destructive method called teardown. These methods help increase efficiency, safety, and cost-effectiveness, allowing for high-speed production and strong, reliable welds essential for vehicle safety and




Fig. 1. A schematic of the metal RSW process [34].




Fig. 2. WT and MF inverter diagram [10].

structural integrity. This article focuses solely on the robotic RSW process and non-destructive testing using UT, enabling data extraction from welding machines and measuring devices for modeling. In contrast, the teardown method provides only pass/fail results without additional information, which is why the selected devices are used for data retrieval.

3.1. Resistance spot welding

RSW is a cost-effective method for joining metals, relying on heat energy and pressure to create welds. The basics involve applying heat energy and pressure to reach the plastic state of materials, with factors such as pressure, current, and weld time playing essential roles. Metal transitions from a solid state to a partially liquid state and halted before full liquefaction to prevent expulsion and ensure weld integrity. Careful control of these parameters allowed RSW to produce strong, reliable welds for various applications. The term RSW originates from the electrical resistance of metals generating heat when current flows through them, leading to the formation of welding nuggets as the workpieces melt and solidify upon cooling. Different metals require varying

degrees of control due to their unique characteristics, highlighting the importance of understanding and managing the process parameters for successful resistance welding, as shown in Fig. 1.

The RSW experiments were conducted using a robotic RSW consisting of an RK robot model, and an RO C-type servomotor driven with a B6 unit, as shown in Fig. 2. The B6 includes a weld timer (WT) and a medium-frequency power unit (MF inverter). The tasks of the MF inverter include generating the required current and weld time, as well as controlling the MF inverter itself. Meanwhile, the tasks of the WT involve controlling, regulating, and monitoring all programmed welding schedules, including message (status and errors), logging (recording every millisecond), and operation. Additionally, the WT facilitates communication with devices on the same process level via I/O connection, such as the robot, PLC (Programmable logic controller), control panel, and records the results in the form of an RUI file (a Bosch-designated file extension where 'R' stands for resistance, 'U' for voltage, and 'I' for current). These various equipment components work together to control the current delivered to the final device, the welding gun.




Fig. 3. Process parameters for RSW [35].

The welding standards follow ISO 14373:2015 which outlines the requirements for RSW in the assembly of uncoated and coated low carbon steel. Two identical dome-shaped F-type chromium-zirconium copper electrodes (ISO 5821, 2009) with a tip diameter of 6 mm were used, positioned as the upper and lower electrodes. Fig. 3 explains a typical basic RSW sequence. Critical to the proper formation of the weld nugget between the metal workpieces being welded are factors such as the resistance of the metal, the weld current, the duration of the current flow, and the welding force that compresses the workpieces together. The duration for which the welding current flows through the two workpieces of metal to be welded is particularly crucial. The following definitions may aid in understanding this drawing:

Squeeze time is the initial parameter between weld force and weld current. It must match mechanical motion. The instrument in this research allows adjustable parameters of 100–300 ms.

Weld time is the duration of weld current applied to the workpiece. Understanding the material helps in selecting the right time. The adjustable parameter range is 200–700 ms.

Hold time is the duration after weld current stops, maintaining weld force to solidify the weld nugget before releasing the parts. This parameter can be adjusted from 100–400 ms.

Off time is the period when the electrodes are not in contact with the workpiece during a repetitive welding cycle. It's necessary for moving the work between weld sequences. The necessary time to start the next weld process for the basic welding cycle, including the pre-heating time (Y), upslope time, and downslope time, is determined.

3.2. Ultrasonic testing

The RSW inspection tool used is the Tessonic brand, model F1, featuring 52 coaxial channels for estimating nugget diameter and indentations from the specimen. It is powered by an Intel® Atom N270 1.6 GHz processor and employs high-frequency sound waves to detect flaws, measure material thickness, and evaluate the internal structure of the test object. This tool supports both automatic and manual nugget size estimation and detection, with a scanning depth suitable for metal plates with thicknesses ranging from 0.6 to 2.4 mm. It is compatible with various materials, including mild steel, high-strength steel, dual-phase ultra-high-strength steel, and aluminum. The F1 can detect materials with and without coatings, such as zinc coatings (galvanized, galvanneal), e-coating, and paint. It is a portable and user-friendly device capable of producing images of spot welds' internal structures. In addition to welding images, this device detects cracks and inclusions, lack of fusion, and estimates the nugget diameter, shape, orientation, and

thickness of the weld and the heat-affected zone (HAZ). It compares these measurements with predefined minimum nugget requirements to ensure that welds comply with industry standards, codes, and regulations, such as those from ASME, AWS, and ISO.

The F1 collects data from the surface and internal structures of the nugget. Special algorithms use this data to reconstruct the image of the spot weld and estimate the average diameter of the nugget area in real time. For this reason, this car manufacturing company uses the UT F1 equipment to evaluate welding quality. The equipment displays images and graphs from wave transmission to measure the size and thickness of the weld to judge its quality.

3.3. Methodology

For this research to yield high-quality components and achieve optimal results in model design, the dataset used to build the model is paramount. Accurate research results and maximum modeling values depend on proper data collection and preparation procedures. Furthermore, selecting the appropriate algorithm, model tuning, and employing data analysis tools, as well as methods for developing the model to be most efficient, are critical. Fig. 4 illustrates a flow chart with all the details of this research process.

1) Data source

Data is collected from two sources: experimental settings and actual production line data. The experimental data, obtained from spot welding on defined workpieces, resulted in a dataset of 450 points under the setting parameters of current and weld time. Meanwhile, the actual production line data was collected, totaling 120 points. The experimental datasets will be used to create the model, while the real data from the production line will be utilized to enhance the model for actual deployment in the production line. The next step involves the RSW process, where data from both sources will undergo the same procedures.

2) RSW process

This process starts with the robot receiving a command from the PLC to weld at the specified position. After completing the welding process, we have written a program in Python, using Jupyter Notebook, to read the RUI file and check the completeness of the weld data to determine if the process is complete, as standard programs cannot read this file type.




Fig. 4. Algorithmic procedure overview.

3) Data extraction

After extracting the necessary information, such as the date and time the process starts, voltage, current, voltage factor, current factor, and time spent in the welding process, these values are calculated. Subsequently, the voltage, current, and resistance values are plotted against the time spent in the welding process. The resulting graphs are used as one of the parameters in the dataset to build the model.

4) UT measurement and labeling

0.5 percent of the welding work will involve using a UT machine to measure the size of the welding spots in the front/rear floors. According to the company's standards, there are specific nugget size specifications for the front/rear floors, which will be used to classify welding quality into three levels. From this step, the production line data set detected welds that met all three levels at all 120 points. However, while the

N. Chuenmee, N. Phothi, K. Chamnirasari et al.

experimental data set totaled 450 points, only 410 welds were found to meet the criteria.

5) Data preparing

In this step, we take a total of 410 datasets, and randomly divide them into two sets. The first set consists of 70% (274 datasets) used for building machine learning models, while the second set, comprising 30% (136 datasets), is used to validate the model as unseen data.

6) Machine learning model

The model dataset (274 datasets) was randomly divided into two parts, with 80% of the dataset used for training the model and 20% used for testing the model's accuracy. The best model was then selected from five different algorithms: ANN, CNN, LSTM, RFC, and XGBoost, considering conditions to prevent model overfitting.

7) Modeling tuning

The best model is used to make predictions with unseen data (136 datasets), ensuring that the model's accuracy is no less than 90%. If the accuracy falls below this threshold, the process will revert to the data preparation step to randomly redistribute all the 410 datasets. This is necessary due to the limited dataset available for model building. The same dataset must be reused, allowing for random reallocation to find the best model from the optimal dataset division. Feature engineering (FE) techniques are employed to enhance model efficiency by reducing less important features or parameters using feature importance (FI) score, ensuring that the model's accuracy is not less than the most recent value obtained. This process continues until the best final model is achieved, ready to be deployed in real situations, such as the production line.

8) Deployment and update

From this step, the model is developed daily based on real data. First, we will test the model using 12 datasets from the production line in one day. All 12 datasets undergo the same data preparation process as the experimental datasets mentioned above. These datasets are used to make predictions and record the results for follow-up data collection. The 12 datasets are then combined with the previous 274 train datasets, creating a total of 286 datasets, which are re-trained to allow the model to learn. This process continues for 10 days, resulting in 120 datasets from the production line, a total of 394 datasets. The final data is recorded, and the results are summarized.

3.3.1. Database analysis

The BIW process involves assembling the main parts to form a monocoque, including the dash compartment, floor panel carrier system, rear compartment, roof, and left-right side frames using the RSW method. In this article, we have collected information from a model TA pickup truck. The connection points of interest are between the front compartment (dash compartment welded assembly with floor panel carrier system) and the rear compartment. Both compartments, when welded together, are referred to as the "front/rear floor". These points are critical for safety as they support the entire weight of the cabin and the vehicle's drivetrain. After completing the welding process, the next step is to randomly select cars from the total produced each day. On average, the factory produces over 400 monocoques per day in the BIW process. Two car bodies are randomly selected each day for UT inspection to measure the weld nugget size. The remaining car bodies are sent directly to the painting process. If the UT inspection reveals that the nugget size does not meet the factory standards, the chassis is sent to a specialized repair department for adjustments before returning to nor-




Fig. 5. Step in the BIW process.

mal production for the painting process. Fig. 5 shows the steps within the BIW process.

3.3.2. Dataset

The obtained data must undergo several steps before it can be utilized. Starting from extracting raw data from WT, we select relevant data, such as removing constant values and irrelevant text that cannot be converted to usable numbers. The data is then organized into sets or groups with similar properties according to the specified structure or class, which will be used to train the algorithm to create a model. A high-quality dataset is valuable to both the data provider and the user. Therefore, we will focus on the method of obtaining the initial data first. As mentioned above, there are two groups of data sources: from experiments and production processes involving RSW between two workpieces of HSS-type (high tensile steel) metal. Each steel plate is 0.7 mm thick (with a tolerance of ± 0.02 mm) and coated with galvanization. This steel type withstands a tensile force of 270 MPa. The details and sources are discussed in the next section below.

3.3.2.1. Experiment dataset In the present era, technology has developed significantly to make work more efficient and reduce errors. The robotic RSW methods are a prime example of this advancement. It has been modernized to minimize mistakes and is extensively used in critical areas concerning structure and user safety. Processes are designed with precision and high standards. However, no system is perfect; over time, the deterioration of machinery or the properties of the material itself can affect welding quality. When mistakes occur, they can cause significant damage, especially in crucial parts or positions. Therefore, identifying problems before they escalate to the next process and promptly solv-

Table 1
Classification levels definition.

Class level	Weld quality	Level condition	Dataset	
			Training	Unseen
Class 0	Satisfy	Nugget size > 3.5 mm	163	81
Class 1	Expulsion	Nugget size > 3.5 mm & Expulsion	44	22
Class 2	Cold weld	Nugget size < 3.5 mm	67	33




Fig. 6. RSW parameters setting using lobe curve technique.

ing them is essential and should be a primary focus. RSW mistakes are rare, resulting in almost no data. Therefore, it is necessary to conduct an experiment. The parameters affecting welding quality are the welding current and time. We designed the experiment to adjust both parameters, which can be set at WT before welding. We used the Lobe curve principle techniques [36] to define the range of settings, consisting of 75 parameter pairs as shown in Fig. 6, to be used for further model training. In the Lobe curve, a value of 1 indicates the parameter is used, while 0 means it is not. The red color of 1 indicates that, although the parameter pair is used, no weld nugget is formed between the workpieces due to insufficient current and weld time. The experimental setup included 150 specimens, each measuring 75x150x0.7 mm, cut from raw materials used in building real vehicles. Three spot welds were performed on each specimen, spaced 20 mm apart, resulting in raw data collection of 450 spot welds (150 specimens x 3 spot welds). However, 40 failed welds went undetected by UT, leaving 410 datasets for machine learning.

3.3.2.2. Production dataset The number of welding points on the front/rear floor totals nearly 90, with an equal number on each side. In this article, we will focus on the left-hand side, as both sides have identical welding requirements and are welded in the same positions, i.e., symmetrically. Of the total welding points on both sides, 17 are on 2 workpieces, and 27 are on 3 workpieces. For the scope of this research, we will only consider the welding points on 2 workpieces. A total of 8 RSW welding robots (4 per side) are used to weld all the points, with each robot responsible for different positions and numbers of welding points. This research specifically studies and extracts data from the fourth welding robot, an RK model, which performs 17 welding points (including 13 on 2 workpieces and 4 on 3 workpieces) on the left-hand side. In designing the welding points, allowances have been made for critical and additional welding points. Therefore, we will focus on the 6 critical welding points on 2 workpieces out of the 13 handled by the fourth welding robot. Data from the BIW process for the front/rear floor parts were collected daily over ten days (2 cars/day), totaling 120 spot welds (20 cars x 6 weld spots per car), all of which met the criteria according to the UT method.

3.3.3. Fault types

Weld quality guarantees the integrity and overall characteristics of the welding assembly during production. Maintaining high-quality welds is crucial to ensure the reliability and safety of the welded structure or component. There are eight types of weld quality: satisfactory (meets engineering requirements), undersized (dimension less than satisfactory), discrepant (below undersized), edge (weld located beyond trim edge), missing (weld not present as specified), off location (weld not within a 10 mm radius of the specified location), expulsion (splatter at the spot point).

For our study, we will focus on four weld quality categories: satisfactory, undersized, discrepant, and expulsion. These will be classified into three levels using machine learning. The details for each level are as follows:

Level 0: Satisfy

This level describes welding quality that meets the engineering principles and requirements of this factory, specifically requiring a nugget size greater than 3.5 mm.

Level 1: Expulsion

This level includes the expansion of molten material between the electrode tip faces, where excessive expulsion is undesirable. The nugget size remains within standard, specifically greater than 3.5 mm, with scattered welding flakes present.

Level 2: Cold weld

This last level combines two types of weld quality: undersized and discrepant, both of which indicate a weld size requirement of less than 3.5 mm nugget size.

After establishing the criteria, we will apply these standards to classify datasets obtained from both experimental setups and the production line into categories based on welding quality levels, as illustrated in Table 1. Fig. 7 displays the C-scan areas obtained from the UT for all three welding quality classes. These C-scan images are generated from the collected measurement data, highlighting different regions of fusion within the weld. The green areas indicate regions where proper fusion has occurred, while the red areas represent regions with no fusion. This visual representation helps in distinguishing between satisfactory welds, expulsion, and cold welds.

3.3.4. Feature extraction

In the data exported from an RSW robot, we can extract data from the WT in RUI format and convert it to a CSV file using Python. After conversion, we selected the required data, including the datetime of the process start, voltage (V), current (I), energy during RSW (BEnrgy), heat during RSW (Bpmax) and time spent in the welding process (Weldtime). Additionally, values include the current factor (Ifactor) and voltage factor (Vfactor) obtained from the MF inverter, along with calculated parameters like heat value. Using a voltage and current values, we can calculate resistance according to Ohm's Law, which states that I is directly proportional to V and inversely proportional to resistance (R). The relationship between V, I, and R is expressed in Equation (1).

$$R = \frac{V}{I} \quad (1)$$

During RSW welding, Joule's first law illustrates the relationship between the heat produced and the flowing electric current through a conductor. Here, Q represents the amount of heat, and T represents time, as shown in Equation (2).




Fig. 7. C-scan area for each weld quality. (a) Satisfy, (b) Expulsion, (c) Cold weld.




Fig. 8. Graph of voltage, current, and resistance during welding.

Table 2
Parameter differences analysis (95% CI).

No.	Parameter	P-value	Significant
I	BWear	0.273932	No
II	Weldtime	0.004022	Yes
III	R1	0.223971	No
IV	Clast	0	No
V	Vall	0.017031	Yes
VI	Ra	0	Yes

$$Q = I^2 RT \quad (2)$$

The total energy (E) consumed during resistance spot welding is calculated by integrating the product of V and I over the welding time (t), as expressed in Equation (3). This calculation differs from BEnergy,

which excludes the high value at the last point on the graph (Fig. 8). The WT records data from the secondary circuit using embedded voltage and current sensors, capturing values every millisecond for heat and energy calculations in the weld timer. According to Joule's first law, heat and energy are essential for nugget formation: insufficient heat results in weak joints, while excessive heat can cause defects such as over-fusion. These parameters are critical inputs for the machine learning model, which uses them to predict weld quality based on calculated heat input, enhancing predictive accuracy in determining the likelihood of producing a quality weld.

$$E = \int_0^T V(t) \times I(t) dt \quad (3)$$




Fig. 9. Box plot analysis of 6 sample parameters across weld quality levels.

The voltage, current, and resistance values were plotted against the time spent in the welding process. From the obtained graph, shown in Fig. 8, various statistics were calculated to serve as parameters in the dataset used to build the model. These parameters include the mean of the first 5 milliseconds, the mean of the last 5 milliseconds, the maximum value after the first 5 milliseconds, the minimum value after the first 5 seconds, the overall average, the total sum, and the final value of the graph. One dataset obtained from the WT corresponds to one connection point on the front/rear floor. There are 31 parameters in total, but which parameters can be used to build the model? Although every parameter is related to the RSW process, it is necessary to test and analyze the relationship between the independent variable and the dependent variable. The method we use is one-way ANOVA. Here, variables are groups of datasets classified into levels, and the dependent variables are all 31 parameters that were collected. In the process of testing, we will formulate hypotheses as follows:

Null hypothesis (H_0): The average values of the datasets at each level of welding quality are not different.

Alternative hypothesis (H_1): The average values of the datasets for each level of welding quality are different.

We have set a significant level of 0.05 or 95% confidence interval. The results of analyzing the mean of each dataset at all three levels of weld quality with a P-value greater than 0.05 means that (H_0) is accepted, indicating that the variances of each dataset across at least two groups are the same and therefore will not be considered. Fig. 9 shows the results of the analysis of the dataset for each weld quality level in a box plot format, compared with the results of the one-way ANOVA analysis as shown in Table 2, using 6 parameters as examples. From a total of 31 parameters, the summary results from the analysis found that three parameters, namely BWear, and R1, will be eliminated, leaving a total of 29 parameters to continue building the model as shown in Table 3.

3.3.5. Artificial neural networks

ANN were selected for their ability to learn intricate patterns in data, particularly when predicting outcomes from nonlinear relationships, which are common in complex manufacturing processes like RSW. The dataset used for training ANNs consisted of both structured (e.g., welding parameters, environmental conditions) and unstructured data (e.g., images, sensor readings), with features capturing both static properties (material type) and dynamic attributes (current, pressure, time). Preprocessing included scaling and normalization to ensure that features fed into the network were on a comparable scale, enhancing the model's convergence during training.

Table 3

Model training dataset parameters.

Parameter	Unit	Meaning description
R	mΩ	Resistance (from equation (1))
Q	J	RSW heat (from equation (2))
E	J/s	Energy (from equation (3))
Bfactor	-	Current factor of MF inverter
Vfactor	-	Voltage factor of MF inverter
Benergy	J/s	Energy using during RSW
Bpmax	J	Heat using during RSW
BSplash	ms	Time at high peak current
Splash	-	Status *0, 1 of BSplash
Weldtime	ms	Weld time (refer to Fig. 3)
C1	kA	Average current first 5 ms
C2	kA	Average current last 5 ms
Ca	kA	Average current
Call	kA	Sum current
V1	V	Average voltage first 5 ms
V2	V	Average voltage last 5 ms
Va	V	Average voltage
Vall	V	Sum voltage
R2	mΩ	Average resistance last 5 ms
Ra	mΩ	Average resistance
Rall	mΩ	Sum resistance
Chigh	kA	High peak current after 5 ms
Clow	kA	Low peak current after 5 ms
Vhigh	V	Voltage at Chigh
Vlow	V	Voltage at Clow
Rhigh	mΩ	Resistance at Chigh
Rlow	mΩ	Resistance at Clow
Clast	kA	Last value of current
Vlast	V	Last value of voltage

*0: No high peak current (no BSplash).

1: High peak current (has BSplash).

Hyperparameter tuning involved adjusting the number of hidden layers, the number of neurons per layer, learning rates, and activation functions (such as ReLU in hidden layers and softmax in the output layer). Regularization techniques like dropout and L2 regularization were applied to prevent overfitting. The backpropagation algorithm, along with the Adam optimizer, was used to adjust weights, minimizing the loss function iteratively and improving predictive accuracy. This setup allowed the ANN to generalize well across diverse weld quality scenarios, enhancing its robustness in prediction.

3.3.6. Convolutional neural networks

CNN were incorporated to handle image-based and spatial data, essential in analyzing surface defects or weld geometry that are indicative of weld quality. The CNNs were configured to learn spatial hierarchies within images using convolutional layers, which extracted feature maps

N. Chuenmea, N. Phothi, K. Chammiprasari et al.

representing weld quality attributes (e.g., seam uniformity, porosity indicators). Preprocessing involved resizing, normalization, and data augmentation (rotation, flipping, and scaling) to increase the variability and robustness of the model in handling weld image inconsistencies.

Hyperparameter tuning for CNNs included adjusting filter sizes, the number of filters per layer, learning rate, and the dropout rate to optimize performance. Cross-validation and a grid search approach were used to identify the best combinations of these parameters. Pooling layers were incorporated after each convolutional layer to reduce the feature dimensions, preventing overfitting and speeding up computation. By leveraging parameter sharing and local connectivity in convolutional layers, the CNNs were able to process high-dimensional image data effectively, contributing to accurate weld quality classification.

3.3.7. Long short-term memory

LSTM were selected to model temporal dependencies and trends in sequential data, such as time-series sensor data, current, or pressure sequences that evolve during the welding process. This model was essential for capturing how past welding cycles or temporal changes affect current quality predictions. The dataset for LSTM consisted of sequences reflecting the chronological order of welding steps, where each sequence element represented a timestamped value of the variables under consideration. Preprocessing involved sequence padding to standardize input lengths and normalization to improve model convergence.

To optimize LSTM performance, hyperparameter tuning was performed on parameters like the number of LSTM units, learning rate, and dropout rate. Gate mechanisms within LSTM cells (input, forget, and output gates) managed the information flow, allowing the model to retain or forget information as necessary, essential in preventing the vanishing gradient problem. An Adam optimizer was employed to adjust weights iteratively, and LSTM depth was varied to identify an optimal architecture capable of accurately capturing the temporal patterns critical for weld quality prediction.

3.3.8. Random forest classifier

The Random Forest Classifier (RFC) was selected for its robustness in handling complex datasets with high dimensionality and noise, which are common in welding process data. This ensemble model effectively handled various feature types (categorical, numerical) present in the dataset, from material specifications to environmental factors impacting weld quality. Preprocessing involved handling missing values and converting categorical variables using one-hot encoding, ensuring each tree received a consistent, high-quality data input.

Hyperparameter tuning focused on the number of trees in the forest, maximum tree depth, minimum samples per leaf, and the number of features considered per split. A grid search method helped in identifying the optimal parameter combinations, enhancing the model's performance while minimizing overfitting. The RFC aggregated predictions from multiple decision trees, providing robust and reliable classifications, particularly valuable for understanding complex feature interactions in weld quality assessment.

3.3.9. Extreme gradient boosting classifier

Extreme Gradient Boosting (XGBoost) was selected for its efficiency and high predictive accuracy, making it suitable for capturing complex interactions among welding parameters and environmental factors. The model leveraged advanced gradient boosting techniques to iteratively minimize prediction errors. The dataset characteristics included various types of features, all of which were preprocessed through normalization, encoding, and feature engineering to enhance signal clarity and model effectiveness. Feature selection played a crucial role, reducing the dimensionality to only the most predictive, improving both the model's accuracy and interpretability.

Hyperparameter tuning for XGBoost included optimizing the learning rate, maximum tree depth, subsampling ratio, and the L1 and L2 regularization parameters to control overfitting. Grid and random search

Results in Engineering 25 (2025) 103570

		True Class	
		Positive	Negative
Predicted Class	Positive	TP	FP
	Negative	FN	TN

Fig. 10. Typical structure of confusion matrix.

methods were employed to fine-tune these hyperparameters. The model's efficiency was further enhanced by tree pruning (to prevent over-complexity) and parallel processing (to speed up training). With XGBoost's adaptability and precision, the model achieved high predictive performance, accurately identifying patterns indicative of weld quality and significantly outperforming other models in terms of precision and recall.

3.4. Performance metrics

Using default algorithms for modeling is generally acceptable, but it is crucial to carefully evaluate whether their results are correct and suitable. Each algorithm is designed to fit different types of datasets, such as classification, regression, or clustering, each with unique characteristics depending on how the data was sourced. Considerations like data collection methods and feature selection play vital roles. Selecting the right algorithm tailored to the dataset is the primary consideration. However, performance alone isn't the sole criterion. Overfitting can occur when model results seem excessively accurate training, potentially due to the dataset's limited diversity, causing the algorithm to learn noise or specific dataset details rather than general patterns. To mitigate this, additional datasets are often introduced to enhance machine learning—a common practice. Another effective approach is hyperparameter tuning, which involves adjusting values that control model complexity to strike balance against overfitting. Optimized parameters can significantly improve a model's ability to generalize to new, unseen data, thereby enhancing overall performance on a given dataset. Finding the right parameter combination that maximizes performance measures is critical for ensuring the model's reliability and practical utility. In our study, the initial results were promising. However, due to material constraints in our experiments, acquiring additional datasets for training wasn't feasible. Hence, we focused on adjusting parameters to optimize model performance. Table 4 presents the adjusted parameters for each model compared to their default settings. What is the best and most suitable machine learning model? This section discusses standard performance indicators used to evaluate a model's accuracy based on how well it predicts outcomes. These indicators are used to compare algorithms to select the best model, ensuring it meets standards of accuracy and reliability. The indicators used to evaluate models categorized into discrete classes include accuracy, precision, recall, and F1 score. These metrics are calculated using the values in the confusion matrix, as shown in Fig. 10, and are used to evaluate the performance of all four indicators as follows: Precision: Calculates the ratio of true positive predictions to the total positive predictions made by the model, as shown in Equation (4).

$$\text{Precision} = \frac{TP}{TP + FP} \quad (4)$$

Recall (Sensitivity or True positive rate): Calculates the percentage of actual positive instances that were correctly identified as positive, as indicated in Equation (5).

$$\text{Recall} = \frac{TP}{TP + FN} \quad (5)$$

Table 4
Hyperparameter comparison for default and tuned algorithm models.

Algorithm	Hyperparameter	Default	Tuned
ANN	output_size	1	1
	hidden_size	[128,64]	[1024, 512, 256, 128, 64, 32, 16, 8, 4]
	batch_size	32	32
	epochs	10	2000
	lr	0.001	0.0005
	dropout_rate	0	0.2
	Optimizer	-	Adam
CNN	Criterion	-	CrossEntropyLoss
	output_size	1	1
	batch_size	32	32
	epochs	10	1000
	lr	0.001	0.0001
	dropout_rate	0.1	0.1
LSTM	random_state	10	10
	output_size	3	1
	batch_size	32	32
	epochs	10	100
	random_state	42	37
	learning_rate	0.001	0.0001
RF	N_estimators	100	12
	Max_depth	1	11
	Min_samples_split	2	2
	Min_samples_leaf	1	10
	N_jobs	-1	-1
	Test_size	0.2	0.2
	Random_state1	0	7
	Random_state2	1	48
XGB	Max_depth	None	8
	N_estimators	100	5
	Random_state1	None	5
	Random_state2	1	96
	tree_method	None	GPU Hist

F1 score: The harmonic mean of precision and recall, balancing both metrics, as demonstrated in Equation (6).

$$F1\ score = \frac{2 \times (Precision \times Recall)}{Precision + Recall} \quad (6)$$

Accuracy: Calculates the percentage of accurately predicted instances out of the total instances, as shown in Equation (7).

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (7)$$

where:

True positive (TP) = A prediction that correctly matches the actual positive outcome.

True negative (TN) = A prediction that correctly matches the actual negative outcome.

False positive (FP) = A prediction that does not match the actual outcome, where the prediction is positive, but the actual result is negative.

False negative (FN) = A prediction that does not match the actual outcome, where the prediction is negative, but the actual result is positive.

The ROC (Receiver Operating Characteristic) curve will be used to visualize the trade-off between recall and false positive rates across different threshold settings. This helps in understanding how changing the decision threshold affects model performance. Different models can be compared, with the ROC curve closer to the upper left corner indicating better model performance. By comparing the ROC curves of multiple models, we can determine which model performs best under different criteria but with same dataset. Conversely, a model with a curve closer to the 45-degree diagonal (random chance line) shows poor performance. Additionally, we can calculate the AUC (Area Under the Curve), a single scalar value summarizing the model's overall performance. Higher AUC values indicate better model performance, making it a particularly useful metric for comparing models.

4. Experiments and results

Modelling to predict weld quality at three levels—Satisfy (Level 0), Expulsion (Level 1), and Gold weld (Level 2)—were created using five different algorithms. Three models were built using machine learning algorithms (LSTM, RF, and XGBoost), and the other two were built using deep learning algorithms (ANN and CNN) through hyperparameter tuning. These models were then compared. As shown in Fig. 11, the results from the five models are plotted using ROC curves along with their respective AUC values. The ROC curves for XGBoost, LSTM, RF, and CNN all closely approach the upper left corner, indicating strong model performance, with AUC values of 0.998, 0.990, 0.979, and 0.967, respectively. The ANN model, however, has a lower AUC of 0.859. The visual comparison of the ROC curves makes it easy to observe differences in model performance. When combined with the AUC values, it provides a clearer understanding of each model's effectiveness. However, determining the best model is challenging, as two models—LSTM and XGBoost—yielded almost equal results. Therefore, it is necessary to consider additional performance metrics, as shown in Table 5.

From the information in Table 5, it is evident that while models using default hyperparameters yield good results, there is still room for improvement through hyperparameter tuning. Using default hyperparameters does not entirely prevent overfitting. For instance, the default XGBoost model has a training accuracy (Train ACC) of 100%, but its testing accuracy (Test ACC) drops to 81.8%. Similarly, the default RF model has a Train ACC of 77.2% and a Test ACC of only 63.6%. Despite the high AUC-ROC scores of both models, which are over 0.9 and nearly on par with LSTM and CNN, they still manage to protect themselves from overfitting, much like the ANN model, which has the smallest AUC-ROC score. After proper hyperparameter tuning, XGBoost demonstrated the best overall performance, with a Train ACC of 99.5% and a Test ACC of 96.4%. The second-best model was the ANN, which, after tuning,




Fig. 11. ROC and AUC-ROC analysis comparison for five algorithm models.

Table 5
Performance metrics comparison between five algorithm models.

Model	Type	Precision	Recall	F1-score	Train ACC	Test ACC	Unseen ACC
ANN	Default	72.73	72.73	72.73	72.76	72.73	72.06
	Tuned	98.17	90.91	91.91	93.55	89.55	91.11
CNN	Default	69.09	69.09	69.09	72.60	69.90	69.85
	Tuned	94.52	92.73	93.38	92.73	92.73	92.73
LSTM	Default	81.30	76.36	76.99	84.02	80.88	76.36
	Tuned	92.50	92.73	92.37	98.17	92.73	92.65
RF	Default	55.88	63.64	57.68	77.17	63.64	75.00
	Tuned	92.24	90.91	91.91	88.76	90.21	89.42
XGB	Default	85.81	84.02	84.45	100.00	81.82	92.65
	Tuned	93.33	98.15	95.34	99.54	96.36	95.59

achieved a Train ACC of 98.6% and a Test ACC of 92.7%. This performance was closely followed by the LSTM model, which had Train ACC and Test ACC values of 98.2% and 92.7%, respectively. The RF model also showed significant improvement, with Train ACC and Test ACC values of 93.6% and 92.7%. The CNN model, while still effective, had the lowest performance among the tuned models, with a Train ACC of 97.3% and a Test ACC of 89.1%.

However, we are not completely satisfied with just considering the overall performance. We prioritize avoiding under-killed predictions over over-killed ones. This means we will not accept predictions that incorrectly classify a poor-quality weld as a good one, but we can tolerate predictions that correctly classify a good-quality weld as poor. Specifically, in our case, it is unacceptable if the model predicts a cold weld (Level 2) as satisfactory (Level 0). We will examine this further through the confusion matrix analysis of each model's predictions on unseen data, as shown in Fig. 12.

All models were able to predict the Expulsion (Level 1) class from unseen datasets with 100% accuracy. For the Satisfy (Level 0) class, all

models similarly misclassified some datasets as Cold weld (Level 2), but none misclassified them as Expulsion (Level 1). As mentioned, we can tolerate over-killed predictions, especially when the error rate is below 7%, though ideally, it should be zero. Our primary focus is on avoiding under-killed predictions for Cold weld (Level 2). Among all the models, XGBoost made only one incorrect prediction out of 33 unseen datasets, achieving a prediction accuracy (Prediction ACC) of 95.6%.

In our evaluation of machine learning models for weld quality prediction, minimizing under-killed predictions—where poor-quality welds are classified as satisfactory—was our priority, while we tolerated over-killed predictions, where good-quality welds might be flagged as poor. This approach ensures the structural integrity of the final product by preventing faulty welds from being misclassified as acceptable. Below, we present a comparative analysis of the models tested, focusing on their ability to predict Cold welds (Level 2), which are critical for quality assurance.

ANN performed reasonably well across most classes but faced challenges in maintaining high specificity for Cold weld predictions. While

N. Chuenmee, N. Phothi, K. Champrasari et al.




Fig. 12. (a) ANN confusion matrix, (b) CNN confusion matrix, (c) LSTM confusion matrix, (d) RF confusion matrix, (e) XGBoost confusion matrix.

the ANN architecture effectively captured general patterns in the data, it lacked the capacity to focus on minority classes, which led to occasional under-killed predictions. This model's limitations underscore the difficulty in using general-purpose neural networks for highly specialized tasks involving imbalanced classes. The CNN, although highly effective in tasks requiring spatial pattern recognition, was less successful here. Since the dataset lacks spatial correlations typical in image or signal data, CNN's convolutional layers could not capture the specific, non-spatial relationships between features essential for weld quality prediction. As a result, CNN struggled with classification accuracy for Cold welds, a limitation inherent to its architecture when applied to non-image-based, tabular datasets.

Similarly, the LSTM network, which is traditionally used for sequential or time-series data, was less effective in this context. The LSTM's temporal dependency modeling did not align with the static nature of weld quality data, which does not follow a sequential pattern. Consequently, the LSTM could not capture the nuanced, inter-feature dependencies required for differentiating weld quality levels, leading to higher error rates in critical classifications.

The RFC showed strong overall performance due to its ensemble approach, which captures feature interactions effectively. However, RFC's reliance on decision tree splits made it challenging to accurately predict less common but essential Cold weld classes. Despite its stability and robust performance for general classification, RFC did not handle the imbalanced class distribution as effectively, resulting in occasional under-killed errors.

XGBoost, on the other hand, achieved the highest accuracy, especially excelling in identifying Cold weld (Level 2) cases with minimal under-killed errors. This model's superior performance can be attributed to several factors. First, XGBoost's iterative boosting process emphasizes misclassified examples, effectively addressing the class imbalance inherent in weld quality data. By focusing computational resources on difficult-to-predict cases through successive iterations, XGBoost signifi-

cantly reduced errors in edge cases where other models struggled. Additionally, XGBoost's capacity to dynamically capture feature interactions enabled it to identify complex dependencies between welding parameters, which proved crucial for accurate predictions. With an overall accuracy of 95.6% and only one misclassified Cold weld prediction out of 33 unseen samples, XGBoost's robustness makes it an ideal choice for critical quality prediction tasks in manufacturing.

XGBoost's superior results suggest that boosted tree algorithms are well-suited for quality prediction tasks where data is imbalanced and under-killed errors have significant quality implications. Its ability to adjust feature importance dynamically and handle interactions between variables makes it particularly effective for welding datasets where weld quality depends on intricate interdependencies between parameters. Furthermore, XGBoost's built-in regularization mitigates overfitting, an advantage for deployment in real-world production where unseen data might differ from the training set. This robustness underscores its suitability for high-stakes prediction tasks in manufacturing contexts.

The choice of models for this study, including XGBoost, RFC, ANN, CNN, and LSTM, aimed to explore a diverse range of architectures. Models like XGBoost and RFC were selected for their proven effectiveness with structured, tabular data, while ANN offered a flexible, non-linear modeling approach. CNN and LSTM, despite their high performance in image and sequential data tasks, were tested to assess whether their architectures could capture the nuanced feature relationships needed for weld quality prediction. However, as the data did not possess spatial or temporal characteristics, CNN and LSTM faced limitations, highlighting the importance of model alignment with dataset structure.

In summary, XGBoost's capacity to minimize under-killed predictions emphasizes its adaptability and effectiveness in complex prediction tasks involving imbalanced classes. This finding supports the adoption of boosted tree algorithms in scenarios where high-stakes, imbalanced predictions are common, such as weld quality assessments in manufacturing. The results from CNN and LSTM, meanwhile, underline the

No. of Features	Precision	Recall	F1 Score	Train ACC	Test ACC	Unseen ACC	Prediction Time (ms)
29	93.333	98.148	95.344	99.543	96.364	95.588	38
20	90.909	97.222	93.288	99.543	94.545	94.118	33
17	96.296	99.074	97.570	99.087	98.182	97.059	33
15	95.118	93.600	94.696	94.545	91.176	92.314	33




Fig. 13. Typical structure of confusion matrix

model's performance and execution time before and after feature reduction. The experiment revealed that reducing the number of features did not always yield optimal results. However, using the reduced FI-score method, the XGBoost model with 17 features achieved the best performance, resulting in a higher accuracy of 97.1% on the unseen dataset, an improvement over the original model. Although this method did not reduce under-killed predictions, it successfully reduced over-killed predictions from 7% to 4%, as shown in Fig. 14. The primary purpose of this feature reduction was to decrease the model's prediction time, and with 17 features, the XGBoost model's prediction time was reduced to 33 milliseconds.

Sensitivity analysis revealed that critical features such as weld current, weld voltage and weld time had the highest impact on predictions, while secondary features such as sheet thickness contributed less significantly. This underscores the importance of accurate sensor data for key parameters in maintaining model performance. Validation techniques, including the use of confusion matrices and testing on unseen production data, demonstrated the robustness and generalizability of the models. The XGBoost model achieved an accuracy of 97.1% on unseen data, confirming its reliability for industrial deployment. Moreover, performance testing under varied conditions, such as sensor noise and reduced feature sets, highlighted the XGBoost model's resilience, maintaining high accuracy even with moderate input variations.

To validate the robustness and applicability of the model in a real-world production setting, we deployed it on the production line from 2023 to 2024. During this period, data from over 100,000 vehicles were captured, with each vehicle involving 8 welding spots monitored by two robots using the machine learning model to predict weld quality in total over 800,000 spot welds in real-time.

The deployment revealed the model's ability to detect cold weld issues with high accuracy. Specifically, 247 vehicles with cold weld defects were identified. These defects would likely have gone unnoticed under traditional random inspection methods, which lack the comprehensive coverage offered by real-time predictive modeling. By identifying these issues early in the process, the model also reduced the likelihood of downstream failures, allowing the production line to address defects proactively and avoid further complications. This demonstrates the effectiveness of the model in enhancing weld quality assurance and reducing production risks.

If we evaluate the potential benefits of applying the model developed in this research to the actual production process, particularly in

welding quality inspection at this company, significant improvements can be expected. Currently, the quality inspection of car body welds using UTs requires 4 operators per shift (2 shifts per day). Implementing machine learning could reduce this number to 2 operators per shift, as the remaining operators would only need to review predictions flagged by the model as Expulsion (Level 1) or Cold weld (Level 2), rather than checking every welding point, including those that are likely to be Satisfy (Level 0).

Moreover, the current method relies on random inspections for Level 0 and Level 2 welds, which may allow some welding errors in the BIW to slip through to the paint section. In contrast, using the prediction model would enable inspection of every car body, as the model predicts welding quality during the process. If a defect is detected, corrective actions can be taken immediately before the RSW robot welds the next point. Rough calculations suggest that reducing the number of operators would lead to considerable cost savings. Additionally, the costs associated with calibrating the UTs could be reduced, as the current process involves 4 UTs.

After the welding process, each car body typically requires 2 operators per shift to inspect for Level 2 defects and polish the surface before painting, particularly to remove any spatter around the welds (Expulsion). However, with the implementation of this real-time weld quality prediction model, maintenance technicians can more effectively adjust the welding current or conditions and clean the body surface at the welding location during the BIW process. This proactive approach reduces the occurrence of expulsions, thereby allowing the number of operators needed for inspection and polishing per shift to be reduced from 2 to 1.

5. Conclusion

This study demonstrates the significant potential of various machine learning and deep learning models in accurately predicting the quality of RSW outcomes, categorized as Satisfy (Level 0), Expulsion (Level 1), and Cold Weld (Level 2). The raw data used to build the predictive model was extracted from the WT of the RSW robot. Basic statistical methods were applied, relating pressure, current, and resistance (derived from calculations) to welding time to create the features necessary for the model. Additionally, heat and energy were calculated using parameters from the WT, resulting in a total of 31 features. We confirmed that all features were useful for model building, ensuring that no irrelevant data would influence the machine learning process. This allowed us to eliminate features that were not significantly related to the classification data, reducing the feature set to 29 for model training. We employed different algorithms to compare the results using both default hyperparameters and tuned hyperparameters, including ANN, CNN, LSTM, RF, and XGBoost. Among these, the modified XGBoost model outperformed the others. By evaluating AUC-ROC, Train ACC, Test ACC, and confusion matrices—particularly focusing on under-killed predictions as a selection criterion. The XGBoost model achieved a Prediction ACC of 95.6% on unseen data. Further refinement through feature elimination, reducing the feature set to 17, improved prediction speed from 38 milliseconds to 33 milliseconds and increased the model's Prediction ACC to 97.06% while reducing the over-killed rate.

These findings highlight the transformative potential of machine learning techniques in enhancing the quality control of RSW, particularly in real-time production environments. The models' high accuracy suggests a significant opportunity to reduce defects and improve overall manufacturing efficiency and product quality, especially in critical industries like automotive manufacturing. The ability to provide reliable, real-time predictions opens the door for automated quality control systems that can proactively intervene during production, preventing defects and leading to substantial cost savings and operational efficiencies. Future research will aim to refine these models further, improving their predictive accuracy and exploring their integration with other industrial data sources and control systems. This study not only demonstrates

the feasibility of advanced machine learning for predicting RSW quality but also paves the way for future innovations that could revolutionize data-driven quality control in manufacturing technology currently used by the factory.

Future advancements in machine learning models will enable AI not only to predict defects but also to diagnose root causes of quality issues, identifying subtle patterns in historical and real-time sensor data to prevent defects before they occur. Self-learning systems will evolve, adapting continuously to changing production conditions and materials, enhancing early detection of quality issues. Additionally, real-time defect detection through edge computing will enable immediate adjustments on the production floor, bypassing cloud latency. Predictive maintenance using digital twins will monitor welding equipment health, predicting wear and malfunctions to reduce downtime and optimize process quality. Future enhancements include incorporating additional parameters like electrode wear, electrode gap, and applied welding force, ensemble learning, hyperparameter tuning, domain adaptation, and model interpretability techniques, as well as integrating predictive models with real-time feedback systems to create a closed-loop quality assurance process. However, there are potential challenges in real-world deployment:

Scalability and Real-Time Processing: The XGBoost model outperformed other algorithms due to its ability to handle complex feature interactions and mitigate overfitting, especially with a reduced feature set of 17. Unlike deep learning models such as CNN and LSTM, which require extensive computational resources and large datasets for optimal performance, XGBoost effectively leveraged the structured tabular data and handled noise and missing values efficiently. Its high accuracy and faster inference times (33 ms per prediction) made it particularly well-suited for real-time production environments.

Dealing with Sensor Noise and Data Quality: Sensor data in automotive manufacturing environments can be noisy, incomplete, or inconsistent due to equipment malfunctions or environmental factors, potentially degrading model performance. Although XGBoost can handle missing data, excessive noise or data gaps could affect prediction accuracy. To address this, real-time data filtering or additional preprocessing would be essential for improving model robustness.

Adaptability to Changing Conditions: Over time, the welding process may vary due to factors like electrode wear or aging equipment. Static models like XGBoost may struggle to adjust without regular retraining. To maintain accuracy, frequent model retraining or an online learning system could be implemented. Techniques like transfer learning could also help the model adapt to changes in production processes or equipment conditions. Addressing these challenges will be crucial for advancing the adoption of machine learning in quality control for RSW, ensuring the models are both accurate and resilient in dynamic production environments.

Key Contributions: The study demonstrates the effective application of various machine learning models, particularly XGBoost, for predicting weld quality, improving upon traditional RSW inspection methods. Predictive models provide real-time insights, allowing for continuous monitoring of weld quality, thus reducing the reliance on random post-production inspections and enhancing quality control in real-time. The integration of predictive analytics into the RSW process shows potential for reducing production costs, improving product quality, and increasing efficiency across automotive production lines.

Future Work: Future research should focus on integrating IoT-enabled sensors for real-time data collection, providing a constant flow of high-quality data to enhance defect detection accuracy. Developing interpretable machine learning models will help engineers identify factors influencing weld quality and enable informed process adjustments. Moreover, incorporating edge computing architectures will ensure the scalability of predictive models for high-volume production lines, maintaining real-time performance without slowing manufacturing operations. Finally, embedding continuous learning algorithms will allow the mod-

N. Chuenmee, N. Phothi, K. Champrasari et al.

els to adapt to dynamic production conditions, such as electrode wear and material variations, ensuring long-term reliability.

CRediT authorship contribution statement

Conceptualization, N.C. and J.S.; methodology, N.C. and J.S.; software, N.C.; validation, N.C. and J.S.; formal analysis, N.C. and N.P.; investigation, N.C. and J.S.; resources, N.C. and S.K.; data creation, N.C. and J.S.; writing-original draft presentation, N.C. and J.S.; writing-review and editing, J.S., N.P. and S.K.; visualization, N.C.; supervision, S.K. and J.S.; project administration, K.C. and J.S.; funding acquisition, K.C. and J.S. All authors have read and agreed to the published version of the manuscript.

Funding

Not applicable.

Declaration of competing interest

The authors declare no conflict of interest.

Data availability

Not applicable.

References

- [1] Jing Wen, Hongde Jia, Real-time monitoring system for resistance spot welding quality, *Eng. Res. Express* 5 (Jan. 2023), <https://doi.org/10.1088/2631-8695/acb130>.
- [2] Lang Zhou, et al., Comparative study on resistance and displacement based adaptive output tracking control strategies for resistance spot welding, *J. Manuf. Process.* 63 (Apr. 2020), <https://doi.org/10.1016/j.jmapro.2020.03.061>.
- [3] Dai Wei, et al., Deep learning assisted vision inspection of resistance spot welds, *J. Manuf. Process.* 62 (Feb. 2021) 262–274, <https://doi.org/10.1016/j.jmapro.2020.12.015>.
- [4] Jian Zhou, et al., Autonomous nondestructive evaluation of resistance spot welded joints, *Robot. Comput.-Integr. Manuf.* 72 (Dec. 2021) 102183, <https://doi.org/10.1016/j.rcim.2021.102183>.
- [5] Eric Brizes, et al., Evaluation of heat transfer within numerical models of resistance spot welding using high-speed thermography, *J. Mater. Process. Technol.* 297 (June 2021) 117276, <https://doi.org/10.1016/j.jmatprotec.2021.117276>.
- [6] Zerui Xi, et al., An intelligent inspection method for body-in-white weld quality based on vibration excitation response signals, *Measurement* 229 (Apr. 2024) 114482, <https://doi.org/10.1016/j.measurement.2024.114482>.
- [7] Arnout Dejans, Oleksandr Kurtov, Patrick Rymenant, Acoustic emission as a tool for prediction of nugget diameter in resistance spot welding, *J. Manuf. Process.* 62 (Dec. 2020) 7–17, <https://doi.org/10.1016/j.jmapro.2020.12.002>.
- [8] Cameron Summerville, Paul Compton, Matthew Doolan, A comparison of resistance spot weld quality assessment techniques, *Proc. Manuf.* 29 (Jan. 2019) 305–312, <https://doi.org/10.1016/j.promfg.2019.02.142>.
- [9] Shaik Shafee, B. Naik, Dr Sammalah, Resistance spot weld quality characteristics improvement by Taguchi method, *Mater. Today Proc.* 2 (Dec. 2015) 2595–2604, <https://doi.org/10.1016/j.matpr.2015.07.215>.
- [10] Cameron Summerville, et al., Nugget diameter in resistance spot welding: a comparison between a dynamic resistance based approach and ultrasound C-scan, *Proc. Eng.* 183 (Dec. 2017) 257–263, <https://doi.org/10.1016/j.proeng.2017.04.033>.
- [11] Monachem Kinnawong, Resistance Spot Welding Quality, Testing, Monitoring, and Control, ISBN 978-3-031-25782-7, Apr. 2023, pp. 89–104.
- [12] Xia-Jian Yuan, et al., Resistance spot welding of dissimilar DP600 and DC54D steels, *J. Mater. Process. Technol.* 239 (Jan. 2017), <https://doi.org/10.1016/j.jmatprotec.2016.08.012>.
- [13] Abhishek Agarwal, et al., Strategic Design Optimization of Cutting Tools for Enhanced Manufacturing Efficiency, ISBN 978-3-031-68270-4, Sept. 2024, pp. 251–276.
- [14] Maneerat Rakcheep, et al., Enhancing testing cell set efficiency: a machine learning approach on hard disk drive data, *Manuf. Rev.* 11 (Apr. 2024) 11, <https://doi.org/10.1051/mfreview/2024008>.
- [15] Prathan Chommuangpuck, Thanasak Wanglomklang, Jiraphon Srisertpol, Fault detection and diagnosis of linear bearing in auto core adhesion mounting machines based on condition monitoring, *Syst. Sci. Control Eng.* 9 (Jan. 2021) 290–303, <https://doi.org/10.1080/21642583.2021.1895901>.
- [16] Thanasak Wanglomklang, et al., Using fault detection and classification techniques for machine breakdown reduction of the HGA process caused by the slider loss defect, *Manuf. Rev.* 9 (Aug. 2022), <https://doi.org/10.1051/mfreview/2022020>.
- [17] Chaweng Sapaporn, Sontaree Seangari, Jiraphon Srisertpol, Classifying and optimizing spiral seed self-servo writer parameters in manufacturing process using artificial intelligence techniques, *Systems* 11 (May 2023) 268, <https://doi.org/10.3390/systems11060268>.
- [18] I. Polajnar, J. Diaci, Z. Kariž, Overview of resistance spot welding control, *Sci. Technol. Weld. Join.* 13 (Apr. 2008) 215–224, <https://doi.org/10.1179/174329308X283893>.
- [19] Jaemin Sim, Kyoung-Yun Kim, Hybrid nugget diameter prediction for resistance spot welding, *Proc. Manuf.* 17 (Jan. 2018) 395–402, <https://doi.org/10.1016/j.promfg.2018.10.062>.
- [20] Xingfang Wang, Kang Zhou, Shanghui Shen, Intelligent parameters measurement of electrical structure of medium frequency DC resistance spot welding system, *Measurement* 171 (Feb. 2021), <https://doi.org/10.1016/j.measurement.2020.108795>.
- [21] Jiyoung Yu, Adaptive resistance spot welding process that reduces the shunting effect for automotive high-strength steels, *Metals* 8 (Sept. 2018) 775, <https://doi.org/10.3390/met8100775>.
- [22] Swagat Dwibedi, et al., To investigate the influence of weld time on joint characteristics of Hastelloy X weldments fabricated by RSW process, *Mater. Today Proc.* 26 (Mar. 2020), <https://doi.org/10.1016/j.matpr.2020.02.576>.
- [23] Hossain Moshayedi, Iraj Sattari-Far, Resistance spot welding and the effects of welding time and current on residual stresses, *J. Mater. Process. Technol.* 214 (Nov. 2014) 2545–2552, <https://doi.org/10.1016/j.jmatprotec.2014.05.008>.
- [24] Boris Jerman, Samo Simončič, Poor fit-up condition in resistance spot welding, *J. Mater. Process. Technol.* 230 (Dec. 2015), <https://doi.org/10.1016/j.jmatprotec.2015.11.009>.
- [25] Kang Zhou, Yao Ping, Lilong Cai, Constant current vs. constant power control in AC resistance spot welding, *J. Mater. Process. Technol.* 223 (Apr. 2015), <https://doi.org/10.1016/j.jmatprotec.2015.04.018>.
- [26] Yu-Jun Xia, et al., Online measurement of weld penetration in robotic resistance spot welding using electrode displacement signals, *Measurement* 168 (Sept. 2020), <https://doi.org/10.1016/j.measurement.2020.108397>.
- [27] Lilong Cai, Kang Zhou, Tuo Shi, Online measuring the electrical resistivity of molten nugget of stainless steel in resistance spot welding, *J. Manuf. Process.* 28 (Aug. 2017) 109–115, <https://doi.org/10.1016/j.jmapro.2017.05.026>.
- [28] Yu-Jun Xia, et al., Online quantitative evaluation of expulsion in resistance spot welding, *J. Manuf. Process.* 46 (Sept. 2019) 34–43, <https://doi.org/10.1016/j.jmapro.2019.08.004>.
- [29] Qasim Nazir, Chenhui Shao, Online tool condition monitoring for ultrasonic metal welding via sensor fusion and machine learning, *J. Manuf. Process.* 62 (Feb. 2021) 806–816, <https://doi.org/10.1016/j.jmapro.2020.12.050>.
- [30] Jiho Lee, et al., Development of real-time diagnosis framework for angular misalignment of robot spot-welding system based on machine learning, *Proc. Manuf.* 48 (Jan. 2020) 1009–1019, <https://doi.org/10.1016/j.promfg.2020.05.140>.
- [31] Bassel El-Sari, Max Biegler, Michael Rehmeier, Investigation of the extrapolation capability of an artificial neural network algorithm in combination with process signals in resistance spot welding of advanced high-strength steels, *Qual. Assess. Process Manag. Welded Joints* (Oct. 2021), <https://doi.org/10.20944/preprints202110.0411.v1>.
- [32] T. Chino, et al., Fast prediction for resistance spot welding deformation using inherent strain method and nugget model, *Materials* 14 (2021) 1–13, <https://doi.org/10.3390/ma14237180>.
- [33] Lin Hua, et al., In-situ ultrasonic detection of resistance spot welding quality using embedded probe, *J. Mater. Process. Technol.* 267 (Dec. 2018), <https://doi.org/10.1016/j.jmatprotec.2018.12.008>.
- [34] Kw Ziyad, Manohar Das, An electro-thermal model based adaptive control of resistance spot welding process, *Intell. Control Autom.* 06 (Jan. 2015) 134–146, <https://doi.org/10.4236/ica.2015.62014>.
- [35] P. Ravichandran, et al., Process parameter optimization and performance comparison of AISI 430 and AISI 1018 in resistance spot welding process, *Mater. Today Proc.* 33 (June 2020), <https://doi.org/10.1016/j.matpr.2020.05.197>.
- [36] Sangun Ha, et al., Estimation of lobe curve with material strength in resistance projection welding, *J. Mater. Process. Technol.* 263 (2019) 101–111, <https://doi.org/10.1016/j.jmatprotec.2018.07.037>.

ประวัติผู้เขียน

นายณัฐพงศ์ ชื่นหมี่ เกิดเมื่อวันที่ 12 กันยายน 2530 ที่อำเภอเมืองตาก จังหวัดตาก เริ่มการศึกษาระดับประถมศึกษาปีที่ 1 – 6 ที่โรงเรียนตากสินราชานุสรณ์ และมีธยมศึกษาปีที่ 1 – ที่โรงเรียนตากพิทยาคม จังหวัดตาก สำเร็จการศึกษาวิศวกรรมศาสตรบัณฑิต (วิศวกรรมยานยนต์) สำนักวิชาวิศวกรรมศาสตร์มหาวิทยาลัยเทคโนโลยีสุรนารี จังหวัดนครราชสีมา เมื่อ พ.ศ. 2552 หลังจบการศึกษาได้ทำงานเป็นผู้ช่วยสอนและวิจัยในรายวิชาของสาขาวิชาวิศวกรรมเครื่องกล เป็นเวลา 2 ปี เมื่อปี พ.ศ. 2554 ได้รับทุนการศึกษาจากมหาวิทยาลัยเพื่อศึกษาต่อระดับวิศวกรรมศาสตรมหาบัณฑิต สาขาวิชาวิศวกรรมแมคคาทรอนิกส์ ขณะศึกษาได้ทำงานเป็นวิศวกรวิเคราะห์การสั่นที่สถาบันเทคโนโลยีไทย-เยอรมัน จังหวัดชลบุรี สำเร็จการศึกษาระดับปริญญาโท วิศวกรรมศาสตรมหาบัณฑิต ในปีการศึกษา 2556 เมื่อปีการศึกษา 2557 หลังจากสำเร็จการศึกษาในระดับปริญญาโท ผู้วิจัยได้เข้าทำงานเป็นวิศวกรกระบวนการที่บริษัทบ๊อช ออโตโมทีฟ ประเทศไทย เป็นเวลา 6 ปี และ ทำงานเป็นวิศวกรออกแบบกระบวนการที่บริษัทบ๊อช ออโตโมทีฟ ประเทศญี่ปุ่น เป็นเวลา 2 ปี ทำให้เกิดแรงจูงใจ ในการศึกษาต่อในระดับปริญญาเอกด้านระบบควบคุม ศาสตร์แห่งการประยุกต์ และสหวิทยาการ จึงได้ศึกษาต่อในระดับปริญญาเอกในสาขาวิชาวิศวกรรมเครื่องกล หลักสูตรวิศวกรรมแมคคาทรอนิกส์ ที่มหาวิทยาลัยเทคโนโลยีสุรนารี เมื่อปี พ.ศ. 2564 และทำงานด้านวิศวกรซ่อมบำรุง และวิศวกรการเชื่อมตัวถังรถยนต์ ที่บริษัท ฟอร์ด ประเทศไทย ผู้วิจัยมีความสนใจในด้านระบบควบคุมอัตโนมัติ ปัญญาประดิษฐ์ และการประยุกต์ใช้ปัญญาประดิษฐ์ในอุตสาหกรรม