

การตรวจจับความผิดปกติของเครื่องมือตัดซีเอ็นซีด้วยเทคนิคการเรียนรู้
ของเครื่องแบบไม่มีผู้สอน



นายพัชรพล เกียรติภูมิพงศา

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาปรัชญาดุษฎีบัณฑิต
สำนักวิทยาศาสตร์และศิลปดิจิทัล
มหาวิทยาลัยเทคโนโลยีสุรนารี
ปีการศึกษา 2568

ANOMALY DETECTION IN CNC CUTTING TOOLS USING
UNSUPERVISED MACHINE LEARNING TECHNIQUES

PATCHARAPOL KIATTIPOOMPHONGSA



A Thesis Submitted in Partial Fulfillment of the Requirements for the
Degree of Doctor of Philosophy
School of Digital Science and Arts
Suranaree University of Technology
Academic Year 2025

การตรวจจับความผิดปกติของเครื่องมือตัดซีเอ็นซีด้วยเทคนิคการเรียนรู้
ของเครื่องแบบไม่มีผู้สอน

มหาวิทยาลัยเทคโนโลยีสุรนารี อนุมัติให้นักวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของการศึกษา
ตามหลักสูตรปรัชญาดุษฎีบัณฑิต

คณะกรรมการสอบวิทยานิพนธ์



(รองศาสตราจารย์ ดร.ชุนันท์ รัตนโกศา)
ประธานกรรมการ



(รองศาสตราจารย์ ดร.ชรา อังสกุล)
กรรมการ (อาจารย์ที่ปรึกษาวิทยานิพนธ์)



(รองศาสตราจารย์ ดร.ศิริพงษ์ บุญครอง)
กรรมการ




(ผู้ช่วยศาสตราจารย์ ดร.ศุภกฤษฎ์ นิวัฒนากุล)
กรรมการ



(อาจารย์ ดร.อรรคพล วงศ์กอบलग)
กรรมการ



รองศาสตราจารย์ ดร.ยุพาพร รักสกุลพิวัฒน์)
รักษาการแทนรองอธิการบดีฝ่ายวิชาการและ
ประกันคุณภาพ



(รองศาสตราจารย์ ดร.ชรา อังสกุล)
คณบดีสำนักวิชาศาสตร์และศิลป์ดิจิทัล

พัชรพล เกียรติภูมิพงศา : การตรวจจับความผิดปกติของเครื่องมือตัดซีเอ็นซีด้วยเทคนิคการเรียนรู้ของเครื่องแบบไม่มีผู้สอน (ANOMALY DETECTION IN CNC CUTTING TOOLS USING UNSUPERVISED MACHINE LEARNING TECHNIQUES)

อาจารย์ที่ปรึกษา:รองศาสตราจารย์ ดร.ธรา อังสกุล, 103 หน้า.

คำสำคัญ : การตรวจจับความผิดปกติ เครื่องมือตัด เครื่องจักร CNC การเรียนรู้ของเครื่อง

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาวิธีการตรวจจับความผิดปกติในการทำงานของเครื่องมือตัดของเครื่องจักรควบคุมเชิงตัวเลข (CNC) โดยประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อสนับสนุนการบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) และลดความเสียหายที่อาจเกิดขึ้นระหว่างกระบวนการผลิต ข้อมูลที่ใช้ในการวิจัยได้มาจากการทดลองตัดเฉือนชิ้นงานจริง โดยเก็บข้อมูลแรงตึงและการสั่นสะเทือนของเครื่องจักรในสภาวะการทำงานที่แตกต่างกัน วิธีการที่นำเสนอประกอบด้วยการประมวลผลข้อมูลเบื้องต้นเพื่อลดสัญญาณรบกวน จากนั้นนำข้อมูลเข้าสู่ขั้นตอนการตรวจจับความผิดปกติด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ร่วมกับการกำหนดค่าเกณฑ์การตัดสินใจแบบควอนไทล์ (Quantile Threshold) เพื่อเพิ่มความเหมาะสมในการแยกแยะระหว่างสภาวะปกติและสภาวะผิดปกติของการทำงานเครื่องมือตัด ผลการทดลองแสดงให้เห็นว่าวิธีการที่นำเสนอสามารถตรวจจับแนวโน้มความผิดปกติได้อย่างมีประสิทธิภาพ และสามารถระบุสัญญาณเตือนล่วงหน้าก่อนเกิดความเสียหายรุนแรงของเครื่องมือตัด ผลการวิจัยที่ได้แสดงให้เห็นถึงศักยภาพของการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องในการเฝ้าระวังสภาพการทำงานของเครื่องจักร CNC ซึ่งสามารถนำไปประยุกต์ใช้ในภาคอุตสาหกรรมจริงเพื่อเพิ่มความน่าเชื่อถือของกระบวนการผลิต ลดต้นทุนการบำรุงรักษา และยืดอายุการใช้งานของเครื่องจักรได้อย่างมีประสิทธิภาพ

สำนักวิทยาศาสตร์และศิลปดิจิทัล
ปีการศึกษา 2568

ลายมือชื่อนักศึกษา
ลายมือชื่ออาจารย์ที่ปรึกษา

PATCHARAPOL KIATTIPOOMPHONGSA : ANOMALY DETECTION IN CNC CUTTING
TOOLS USING UNSUPERVISED MACHINE LEARNING TECHNIQUES
ADVISOR: ASSOCIATE PROFESSOR DR. THARA ANGSKUN, 103 PAGES.

Keywords: Anomaly Detection/ Cutting Tool/ CNC Machine/ Machine Learning

This research aims to develop an anomaly detection approach for cutting tool operations in Computer Numerical Control (CNC) machines by applying machine learning techniques to support predictive maintenance and to reduce potential damage during the manufacturing process. The data used in this study were obtained from real machining experiments, in which cutting force and machine vibration signals were collected under different operating conditions. The proposed methodology consists of data preprocessing to reduce noise, followed by anomaly detection using the Isolation Forest algorithm in combination with a quantile-based threshold (Quantile Threshold) to improve the discrimination between normal and abnormal cutting tool operating conditions. Experimental results demonstrate that the proposed approach can effectively detect abnormal trends and provide early warning signals prior to severe cutting tool damage. The research findings highlight the potential of applying machine learning techniques for monitoring the operating condition of CNC machines. The proposed method can be practically implemented in industrial environments to enhance production reliability, reduce maintenance costs, and extend the service life of machinery in an efficient manner.

Institute of Digital Arts and Science
Academic Year 2025

Student's Signature
Advisor's Signature

กิตติกรรมประกาศ

งานวิจัยฉบับนี้สำเร็จลงได้ด้วยดี ผู้วิจัยขอกราบขอบพระคุณอย่างสูงต่อ รองศาสตราจารย์ ดร. ธรา อังสกุล อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้กรุณาให้คำแนะนำ ชี้แนะ และสนับสนุนด้านวิชาการอย่างใกล้ชิดมาโดยตลอด ตั้งแต่การกำหนดแนวทางการวิจัย การออกแบบวิธีการศึกษา การวิเคราะห์ผลการทดลอง ตลอดจนการเรียบเรียงและปรับปรุงวิทยานิพนธ์ฉบับสมบูรณ์ ความเอาใจใส่และข้อเสนอแนะอันทรงคุณค่าของท่านมีส่วนสำคัญอย่างยิ่งต่อคุณภาพและความสมบูรณ์ของงานวิจัยฉบับนี้ ผู้วิจัยขอกราบขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ทุกท่าน ได้แก่ รองศาสตราจารย์ ดร. ชูพันธุ์ รัตนโกศา, ผู้ช่วยศาสตราจารย์ ดร. ศุภกฤษฎี นิวัฒนากุล, รองศาสตราจารย์ ดร. ศิริปรัชญ์ บุญครอง และอาจารย์ ดร. อรรถพล วงศ์กอบลาภ ที่ได้กรุณาให้ข้อคิดเห็น คำแนะนำ และข้อเสนอแนะอันเป็นประโยชน์ ซึ่งช่วยยกระดับความถูกต้อง ความชัดเจน และความสมบูรณ์ของงานวิจัยให้ดียิ่งขึ้น ผู้วิจัยขอขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร. ภูษิต มิตรสมหวัง และอาจารย์ชุตินมณฑน์ เมธีสาขาวิชาวิศวกรรมโลหการ มหาวิทยาลัยเทคโนโลยีสุรนารี ที่ได้ให้ความช่วยเหลือและสนับสนุนในการดำเนินการทดลอง การเก็บรวบรวมข้อมูล และการใช้เครื่องมือทางห้องปฏิบัติการ ซึ่งมีส่วนสำคัญต่อความครบถ้วนและความน่าเชื่อถือของข้อมูลที่ใช้ในการวิจัยครั้งนี้ ผู้วิจัยขอขอบพระคุณ สาขาวิชาวิศวกรรมโลหการ มหาวิทยาลัยเทคโนโลยีสุรนารี รวมถึงโรงเครื่องมือ อาคารเครื่องมือ 1 (F1) สำหรับการสนับสนุนด้านสถานที่ เครื่องจักร อุปกรณ์ และทรัพยากรที่จำเป็นต่อการดำเนินการทดลอง ซึ่งมีบทบาทสำคัญต่อความสำเร็จของงานวิจัยนี้ ท้ายที่สุด ผู้วิจัยขอขอบคุณทุกท่านที่มีส่วนเกี่ยวข้องทั้งทางตรงและทางอ้อมที่ได้กล่าวนามไว้ ณ ที่นี้ ซึ่งได้ให้ความช่วยเหลือ สนับสนุน และเป็นกำลังใจตลอดระยะเวลาการดำเนินงานวิจัย จนทำให้งานวิจัยฉบับนี้สามารถสำเร็จลงไปได้ด้วยดี

พัชรพล เกียรติภูมิพงศ์

สารบัญ

หน้า

บทคัดย่อ (ภาษาไทย)	ก
บทคัดย่อ (ภาษาอังกฤษ)	ข
กิตติกรรมประกาศ	ค
สารบัญ	ง
สารบัญตาราง	ช
สารบัญรูป	ฉ
บทที่	
1 บทนำ.....	1
1.1 ความสำคัญและที่มาของปัญหางานวิจัย.....	1
1.2 วัตถุประสงค์งานวิจัย	7
1.3 คำถามนำงานวิจัย	7
1.4 ขอบเขตงานวิจัย	7
1.5 ขอบเขตงานวิจัย	8
1.6 ประโยชน์ที่คาดว่าจะได้รับ.....	8
1.7 คำอธิบายศัพท์	8
2 ปรัชญาบรรณกรรมและงานวิจัยที่เกี่ยวข้อง	10
2.1 เครื่องจักรควบคุมเชิงตัวเลข (CNC).....	10
2.1.1 ความหมายและพัฒนาการของเครื่องจักรควบคุมเชิงตัวเลข	10
2.1.2 ส่วนประกอบสำคัญของเครื่องจักรควบคุมเชิงตัวเลข	10
2.1.3 บทบาทและความสำคัญของสปีนเดิลในการผลิต	11
2.2 การสึกหรอของเครื่องมือตัด	12
2.2.1 ประเภทของการสึกหรอ	12
2.2.2 ปัจจัยที่มีผลต่อการสึกหรอ	13
2.2.3 ผลกระทบของการสึกหรอต่อคุณภาพชิ้นงานและกระบวนการผลิต	14

สารบัญ (ต่อ)

หน้า

2.3 การตรวจจับความผิดปกติ.....	15
2.3.1 ความหมายของความผิดปกติในงานอุตสาหกรรมการผลิต.....	15
2.3.2 เทคนิคการตรวจจับความผิดปกติแบบดั้งเดิม.....	16
2.3.3 วิธีป่าแยกตัว (Isolation Forest).....	17
2.3.4 เทคนิคการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold).....	18
2.4 เทคนิคการเรียนรู้ของเครื่อง	19
2.4.1 การเรียนรู้แบบมีผู้สอน	19
2.4.2 การเรียนรู้แบบไม่มีผู้สอน	21
2.4.3 การเรียนรู้เชิงลึกที่เกี่ยวข้องกับงานอุตสาหกรรม	21
2.5 งานวิจัยที่เกี่ยวข้อง.....	23
3 วิธีดำเนินการวิจัย.....	30
3.1 ขั้นตอนการดำเนินงานวิจัย	30
3.1.1 ขั้นตอนการดำเนินงานวิจัยโดยภาพรวม.....	30
3.1.2 แผนผังการดำเนินงานวิจัย.....	31
3.2 เครื่องจักร วัสดุ และอุปกรณ์.....	32
3.2.1 เครื่องจักรและอุปกรณ์	32
3.2.2 การเตรียมวัสดุสำหรับการทดลอง	36
3.2.3 ขั้นตอนการเก็บข้อมูล.....	40
3.3 การประมวลผลและวิเคราะห์ข้อมูล	42
3.3.1 การวิเคราะห์แรงตัดด้วย Linear Regression.....	42
3.3.2 การตรวจสอบ Flank Wear ด้วยกล้องจุลทรรศน์และการประมวลผลภาพ.....	43
3.3.3 การวิเคราะห์แรงสั่นสะเทือน.....	48
3.3.4 การตรวจจับความผิดปกติด้วย Isolation Forest	48
3.3.5 การตรวจจับความผิดปกติด้วย Local Outlier Factor (LOF).....	50
3.3.6 การกำหนดค่า Quantile Threshold	52
3.3.7 ความแตกต่างระหว่างการพยากรณ์ (Prediction) และการตรวจจับความผิดปกติ (Anomaly Detection).....	54

สารบัญ (ต่อ)

หน้า

4 ผลการวิจัยและอภิปรายผล	56
4.1 ผลการทดลองและการจัดเตรียมข้อมูล	56
4.1.1 ผลการเก็บข้อมูลแรงตัดและแรงบิดจากเครื่อง	56
4.1.2 ผลการตรวจวัด Flank Wear ด้วยกล้องจุลทรรศน์	57
4.1.3 ผลการวิเคราะห์แรงสั่นสะเทือน	59
4.2 ผลการสร้างและประเมินแบบจำลอง Linear Regression	60
4.2.1 ผลการสร้างแบบจำลองและการประเมินประสิทธิภาพเชิงพยากรณ์	60
4.2.2 การวิเคราะห์ความทนทานของแบบจำลองต่อสัญญาณรบกวนและ ค่าผิดปกติ (Robustness Analysis)	61
4.3 ผลการวิเคราะห์ด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest)	63
4.4 ผลการกำหนดค่าเกณฑ์แบบควอนไทล์	65
4.4.1 ผลการทดลองและการเปรียบเทียบค่าเกณฑ์แบบควอนไทล์	65
4.4.2 การพิจารณาเชิงสถิติของ Quantile Threshold	66
4.5 การประเมินประสิทธิภาพของแบบจำลองและการเปรียบเทียบกับวิธีอ้างอิง	69
4.5.1 ตัวชี้วัดการประเมิน (Performance Metrics)	69
4.5.2 วิธีอ้างอิง (Baseline) ของ Isolation Forest แบบค่าเกณฑ์คงที่	71
4.5.3 การเปรียบเทียบค่า Precision ระหว่าง Adaptive และ Fixed Threshold	72
4.6 การวิเคราะห์ผลกระทบด้านต้นทุนและการลดความสูญเสียในกระบวนการผลิต	73
4.7 การวิเคราะห์ข้อดีของระบบตรวจจับความผิดปกติเมื่อเทียบกับอายุการใช้งาน ของหัวเจาะ	75
4.8 การอภิปรายผล	75
4.8.1 ความเหมาะสมของแบบจำลองเชิงเส้นและ Isolation Forest เมื่อเทียบกับ กับวิธีการเรียนรู้เชิงลึก	76
4.8.2 ความเหมาะสมของ Isolation Forest สำหรับสัญญาณไม่คงที่ (Non- stationary Signal)	76
4.8.3 เหตุผลเชิงแนวคิดของการใช้ Quantile Threshold ร่วมกับ Isolation Forest	77

สารบัญ (ต่อ)

หน้า

4.8.4	ข้อจำกัดและข้อพึงระวังของการตั้งค่า Quantile Threshold	77
4.8.5	การเปรียบเทียบเชิงแนวคิดกับงานวิจัยอื่น และนัยต่อ Predictive Maintenance ในอุตสาหกรรมไทย.....	78
4.8.6	การอภิปรายเปรียบเทียบกับงานวิจัยที่เกี่ยวข้องก่อนหน้านี้	79
4.8.7	การอภิปรายการประยุกต์ใช้แนวทางที่นำเสนอเกี่ยวกับเครื่องจักรและหัวเจาะชนิดอื่น.....	81
4.8.8	นัยต่อการประยุกต์ใช้ในระบบตรวจสอบแบบเรียลไทม์	82
4.8.9	ขอบเขตการใช้งานและการปรับเทียบเมื่อเปลี่ยนเครื่องมือหรือเงื่อนไขการผลิต.....	83
5	สรุปและข้อเสนอแนะ	89
5.1	สรุปผลการวิจัย	89
5.2	ข้อจำกัดของการวิจัย	89
5.3	การประยุกต์ผลการวิจัย.....	90
5.4	ขอเสนอแนะในการวิจัยครั้งต่อไป.....	91
	รายการอ้างอิง.....	92
	ภาคผนวก	95
	ภาคผนวก ก ภาพถ่ายหัวเจาะจากกล้องจุลทรรศน์ตั้งแต่การเจาะรูที่ 0 ถึงรูที่ 140	96
	ภาคผนวก ข บรรยายภาพการทดลองเจาะชิ้นงาน ณ อาคารเครื่องมือ F1 มหาวิทยาลัยเทคโนโลยีสุรนารี.....	98
	ประวัติผู้เขียน	103

สารบัญตาราง

ตารางที่	หน้า
2.1 การเปรียบเทียบงานวิจัยที่เกี่ยวข้องกับการตรวจจับความผิดปกติของเครื่องมือตัด.....	29
3.1 พารามิเตอร์การทดลองในการเจาะด้วยเครื่องจักร CNC.....	35
3.2 การเปรียบเทียบผลการตรวจจับความผิดปกติระหว่างวิธี Isolation Forest และวิธี Local Outlier Factor	52
4.1 ผลการวิเคราะห์ทางสถิติของสัญญาณแรงสั่นสะเทือนด้วย One-way ANOVA และ Spearman's Correlation	60
4.2 ผลการประเมินประสิทธิภาพของแบบจำลอง Linear Regression ในการพยากรณ์ แรงตัดสำหรับเหล็กและอะลูมิเนียม	61
4.3 การเปรียบเทียบค่าเกณฑ์แบบควอนไทล์และประสิทธิภาพการแจ้งเตือนล่วงหน้า ในแต่ละชุดข้อมูล.....	66
4.4 แสดงผลการประเมินการแจ้งเตือนในระดับเหตุการณ์สำหรับแต่ละชุดข้อมูล โดยรายงานค่าอัตราการตรวจพบล่วงหน้า ระยะเวลาการแจ้งเตือนล่วงหน้า และผลการจัดประเภทเหตุการณ์ของการแจ้งเตือน	70
4.5 การประเมินผล Baseline: IF + Fixed Threshold (0.7445)	72
4.6 การเปรียบเทียบค่า Precision ระหว่าง Adaptive และ Fixed Threshold.....	73
4.7 การเปรียบเทียบต้นทุนหัวเจาะต่อปี ระหว่างแผนบำรุงรักษาเดิมและแผนที่ใช้ ระบบตรวจจับความผิดปกติ	74
4.8 ตัวอย่างวัสดุโลหะที่สามารถประยุกต์ใช้วิธีการตรวจจับความผิดปกติที่นำเสนอ	84
4.9 ตัวอย่างเครื่องมือตัดที่สามารถประยุกต์ใช้วิธีการตรวจจับความผิดปกติที่นำเสนอ	85

สารบัญรูป

รูปที่	หน้า
2.1 ตัวอย่างโครงสร้างสปินเดิลของเครื่องจักร CNC ซึ่งเป็นส่วนประกอบหลักที่ทำหน้าที่หมุนเครื่องมือตัดและเป็นแหล่งกำเนิดแรงและการสั่นสะเทือนในกระบวนการตัดเฉือน	12
2.2 โครงสร้างพื้นฐานของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN)	22
3.1 แผนผังการทำงานของระบบพยากรณ์การสึกหรอและตรวจจับความผิดปกติสำหรับเครื่องจักร CNC เพื่อการบำรุงรักษาเชิงคาดการณ์	32
3.2 เครื่องจักร CNC แบบ 5 แกน รุ่น DMU 50	32
3.3 เซนเซอร์วัดแรงและแรงบิด Kistler 9272	33
3.4 เครื่องวัดการสั่นสะเทือนรุ่น ST-140 / ST-140D	33
3.5 กล้องจุลทรรศน์ Olympus รุ่น SZ61	34
3.6 โลหะเพลากลม	36
3.7 ตัวอย่างชิ้นงานโลหะ	37
3.8 ตัวอย่างกระบวนการลบมุมชิ้นงาน	37
3.9 ชิ้นงานที่ผ่านการทำความสะอาดและเคลือบเงา	38
3.10 การตั้งศูนย์ของเครื่องจักร	38
3.11 หน้าจอเครื่องจักร CNC	39
3.12 แผนผังกระบวนการเตรียมวัสดุสำหรับการทดลอง	39
3.13 กระบวนการเก็บข้อมูลสำหรับการวิเคราะห์การสึกหรอของเครื่องมือตัด	41
3.14 ตัวอย่างสัญญาณแรงตัดในทิศทางแกน Z จากการเจาะต่อเนื่องหลายรูตามลำดับเวลา	42
3.15 Workflow ของกระบวนการคำนวณค่า VBmax ด้วยเทคนิคการประมวลผลภาพดิจิทัล	47
3.16 ตัวอย่างการตรวจวัดค่า VB ของเครื่องมือตัดรูที่ 140	47
3.17 ตัวอย่างข้อมูลจากไฟล์ averaged_forces_by_cycle.csv ประกอบด้วยข้อมูลเวลา (Time) และค่าแรงตัดเฉลี่ย ได้แก่ Fz, Fx, Fy และโมเมนต์ Mz ซึ่งถูกนำมาใช้เป็นข้อมูลอินพุตสำหรับการตรวจจับความผิดปกติด้วย Isolation Forest	49
3.18 สัญญาณแรงตัด Fz ตามเวลาในระหว่างการเจาะต่อเนื่องจำนวน 10 รู	49
3.19 ข้อมูลเมื่อทำการแปลงค่าเฉลี่ยให้เป็นแต่ละรูการเจาะ	50

สารบัญรูป (ต่อ)

รูปที่	หน้า
3.20 แสดงตัวอย่างโค้ดการใช้วิธีป่าแยกตัว	50
3.21 ผลการตรวจจับความผิดปกติของข้อมูลแรงตัดในทิศทางแกน Z ด้วยวิธี Local Outlier Factor (LOF) ตามลำดับการเจาะรู.....	51
3.22 แสดงตัวอย่าง การคำนวณค่าเกณฑ์ Quantile Threshold	52
3.23 กำหนดช่วงเวลาขั้นต่ำก่อนเริ่มพิจารณาผิดปกติ	53
4.1 การเปรียบเทียบค่าแรงตัดเฉลี่ยในทิศทางแกน Z ระหว่างเหล็กและอะลูมิเนียม ตามจำนวนรูที่ทำการเจาะ	57
4.2 ตัวอย่างภาพการสึกหรอบริเวณผิวหลบ (Flank Wear) ของเครื่องมือตัดจาก การเจาะเหล็ก ในแต่ละช่วงของอายุการใช้งาน	58
4.3 ความสัมพันธ์ระหว่างค่าการสึกหรอสูงสุดบริเวณผิวหลบ (VB_max) กับจำนวนรู ที่ทำการเจาะในวัสดุเหล็ก.....	59
4.4 การแสดงค่าแรงตัดจริง ค่าแรงตัดที่พยากรณ์ และค่าความคลาดเคลื่อน (Error) ของแบบจำลอง Linear Regression ตามลำดับข้อมูลการผลิต.....	63
4.5 ความสัมพันธ์ระหว่างการสึกหรอของเครื่องมือตัดและลำดับการตรวจจับความผิดปกติ ด้วย Isolation Forest (Tool wear vs anomaly Detection Timeline).....	64
4.6 การกระจายตัวของค่าแรงตัดเฉลี่ย (Avg_Fz) ระหว่างชุดข้อมูลที่เครื่องมือตัดแตกหัก และไม่แตกหัก	64
4.7 กราฟแสดง Time-series plot พร้อม anomaly flags	68
4.8 การกระจายตัวของค่า Anomaly Score และเส้นค่าเกณฑ์แบบควอนไทล์จากชุดข้อมูล MATWI Set 1	68
4.9 ระบบวัดการเคลื่อนที่ความละเอียดสูงแบบเชิงเรขาคณิตด้วยเซนเซอร์ attocube (attocube IDS3010).....	88
4.10 ระบบการวัดเชิงเรขาคณิตแบบแกนหมุน (Rotary-Axis Measurement System) และกระบวนการประมวลผลข้อมูล.....	88

บทที่ 1

บทนำ

1.1 ความสำคัญและที่มาของปัญหาทางวิจัย

ในปัจจุบัน อุตสาหกรรมการผลิตทั่วโลกกำลังเผชิญกับความท้าทายที่หลากหลาย ไม่ว่าจะเป็นมาตรฐานด้านคุณภาพที่เข้มงวดขึ้น ต้นทุนวัตถุดิบที่สูงขึ้น และการแข่งขันเชิงประสิทธิภาพที่ต้องอาศัยความแม่นยำและความรวดเร็วเป็นตัวชี้วัดสำคัญ ทำให้เครื่องจักร CNC ได้รับความสำคัญอย่างยิ่งในฐานะเทคโนโลยีหลักที่ช่วยรองรับการผลิตที่ต้องการความเที่ยงตรงสูง โดยเฉพาะในอุตสาหกรรมยานยนต์ อากาศยาน แม่พิมพ์ ชิ้นส่วนอิเล็กทรอนิกส์ และอุปกรณ์การแพทย์ ซึ่งต้องใช้ชิ้นงานที่มีความละเอียดระดับไมครอนขึ้นไป จากรายงานการสำรวจตลาด CNC ล่าสุดพบว่า มูลค่าตลาดเครื่องจักร CNC ทั่วโลกมีมูลค่าสูงถึง 67.5 พันล้านดอลลาร์สหรัฐในปี 2023 และคาดว่าจะขยายตัวเป็น 80.4 พันล้านดอลลาร์สหรัฐภายในปี 2028 ด้วยอัตราการเติบโตเฉลี่ยราว 3.5% ต่อปี ซึ่งสะท้อนให้เห็นถึงความต้องการใช้งานเครื่องจักรความเที่ยงตรงสูงที่เพิ่มขึ้นอย่างต่อเนื่องภายใต้บริบทของการพัฒนาไปสู่ระบบการผลิตอัจฉริยะ (Smart Manufacturing) ตามแนวคิดอุตสาหกรรม 4.0 (MarketsandMarkets, 2024)

สำหรับบริบทของประเทศไทยภาคอุตสาหกรรมการผลิตถือเป็นกลไกสำคัญในการขับเคลื่อนเศรษฐกิจ โดยเฉพาะอุตสาหกรรมยานยนต์ซึ่งประเทศไทยเป็นฐานการผลิตที่สำคัญในภูมิภาคเอเชียและติดอันดับหนึ่งของอาเซียน โดยมีการส่งออกรถยนต์และชิ้นส่วนไปยังต่างประเทศในสัดส่วนที่สูง อุตสาหกรรมในประเทศจึงจำเป็นต้องใช้เครื่องจักร CNC จำนวนมาก เพื่อรองรับการผลิตแม่พิมพ์ ชิ้นส่วนเครื่องยนต์ และอุปกรณ์ประกอบต่าง ๆ ที่ต้องการความเที่ยงตรงสูง นอกจากนี้ยังมีอุตสาหกรรมอิเล็กทรอนิกส์ รวมถึงอุตสาหกรรมทางการแพทย์ที่มีการใช้ CNC ในการผลิตชิ้นส่วนขนาดเล็กที่ต้องการความละเอียดสูงเช่นกัน แม้ประเทศไทยจะมีการใช้งาน CNC อย่างแพร่หลาย แต่ระบบการตรวจสอบสภาพเครื่องมือในหลายโรงงานกลับยังคงอาศัยประสบการณ์ของช่างหรือผู้ควบคุมเครื่องจักรเป็นหลัก ซึ่งมีข้อจำกัดทั้งด้านความสม่ำเสมอ ความแม่นยำ และความสามารถในการคาดการณ์

เครื่องมือตัดจึงมีบทบาทสำคัญต่อความเสถียรของกระบวนการผลิต เนื่องจากเป็นองค์ประกอบหลักที่เชื่อมต่อระหว่างเครื่องจักรและชิ้นงานโดยตรง หากสภาพของเครื่องมือตัดเริ่มเสื่อมลง จะทำให้การสั่นสะเทือนในกระบวนการตัดเพิ่มสูงขึ้น ส่งผลให้แรงตัดไม่คงที่ คุณภาพผิวของชิ้นงานลดลง และอาจเกิดความคลาดเคลื่อนในมิติของชิ้นงานมากขึ้นเรื่อย ๆ ในกรณีที่มีการสึกหรอรุนแรงหรือผิดปกติ อาจทำให้เกิดแรงกระทำต่อระบบการตัดเฉือนสูงผิดปกติจนเกิดความเสียหาย ซึ่ง

การหยุดเครื่องจักรเพื่อซ่อมบำรุงหรือเปลี่ยนเครื่องมือตัดมีค่าใช้จ่ายสูงและกระทบต่อความต่อเนื่องของกระบวนการผลิตอย่างมาก จากรายงาน The True Cost of Downtime 2024 โดย Siemens ระบุว่าต้นทุนการหยุดเครื่องจักรโดยไม่คาดคิดในภาคอุตสาหกรรมสมัยใหม่มีมูลค่าสูงอย่างมีนัยสำคัญ โดยเฉพาะในอุตสาหกรรมยานยนต์ที่อาจมีความสูญเสียมากกว่า 2.3 ล้านดอลลาร์สหรัฐต่อชั่วโมง ในขณะที่อุตสาหกรรมสินค้าอุปโภคบริโภค (FMCG) มีการสูญเสียเฉลี่ยกว่า 36,000 ดอลลาร์สหรัฐต่อชั่วโมง ซึ่งสะท้อนให้เห็นว่าแม้การหยุดเครื่องเพียงช่วงเวลาสั้น ๆ ก็สามารถสร้างความเสียหายทางเศรษฐกิจได้อย่างมหาศาล (Siemens, 2024) นอกจากนี้ ค่าใช้จ่ายของเครื่องมือตัดยังเป็นสัดส่วนสำคัญของต้นทุนการผลิต โดยมีรายงานจากผู้ผลิตเครื่องมือตัดระดับอุตสาหกรรมระบุว่าต้นทุนเครื่องมือตัดคิดเป็นประมาณ 10–20% ของต้นทุนการผลิตรวม ในหลายกระบวนการตัดเฉือน ดังนั้น หากสามารถยืดอายุการใช้งานของเครื่องมือตัดได้แม้เพียงเล็กน้อย ก็จะช่วยลดต้นทุนการผลิตและเพิ่มประสิทธิภาพการใช้ทรัพยากรได้อย่างมีนัยสำคัญ

ดังนั้นการตรวจสอบสภาพเครื่องมือตัดและการเฝ้าติดตามสภาพการทำงานของเครื่องจักร อย่างแม่นยำจึงเป็นสิ่งสำคัญต่อประสิทธิภาพของโรงงานอุตสาหกรรม ปัญหาที่เกิดขึ้นในหลายสถานประกอบการ คือการใช้วิธีตรวจสอบแบบคงที่หรือการประเมินเชิงประสบการณ์ ซึ่งไม่สามารถรองรับการเปลี่ยนแปลงของสภาวะการตัดจริงได้อย่างมีประสิทธิภาพ การประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องจึงถูกนำมาใช้เพื่อแก้ไขข้อจำกัดดังกล่าว โดยเฉพาะเทคนิคแบบไม่ต้องมีข้อมูลป้ายกำกับ (Unsupervised Learning) เช่น วิธีป่าแยกตัว (Isolation Forest) ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) ซึ่งช่วยให้สามารถจำแนกสภาวะผิดปกติได้อย่างยืดหยุ่นและมีความแม่นยำสูง สามารถรองรับความไม่แน่นอนของสภาวะการผลิตจริง รวมถึงลดการแจ้งเตือนผิดพลาดที่อาจเกิดจากสัญญาณรบกวนหรือการเปลี่ยนแปลงของกระบวนการตัดที่ไม่ได้บ่งบอกถึงความผิดปกติจริง

งานวิจัยนี้จึงมุ่งเน้นการพัฒนาแนวทางการตรวจจับความผิดปกติของเครื่องมือตัดที่สามารถใช้งานได้จริงในโรงงานอุตสาหกรรมไทย เพื่อช่วยลดความเสี่ยงในการเกิดความเสียหายของเครื่องจักร ลดการหยุดชะงักที่ไม่คาดคิด ยกระดับประสิทธิภาพการผลิต และสนับสนุนการเปลี่ยนผ่านสู่ระบบบำรุงรักษาเชิงคาดการณ์อย่างยั่งยืน ซึ่งเป็นปัจจัยสำคัญในการเพิ่มขีดความสามารถในการแข่งขันของอุตสาหกรรมไทยในระยะยาว นอกจากนี้ การยกระดับภาคอุตสาหกรรมการผลิตของไทยสู่ระบบการผลิตอัจฉริยะตามนโยบายของภาครัฐและภาคอุตสาหกรรม เช่น แผนพัฒนาอุตสาหกรรม 4.0 และการสนับสนุนโรงงานเข้าสู่มาตรฐานโรงงานอัจฉริยะ (Smart Factory) ยังเป็นอีกปัจจัยหนึ่งที่ทำให้บทบาทของระบบตรวจสอบสภาพเครื่องมือและเครื่องจักรเพิ่มความสำคัญมากขึ้น โรงงานจำนวนมากมีความต้องการระบบที่สามารถตรวจวัด วิเคราะห์ และแจ้งเตือนความผิดปกติได้แบบอัตโนมัติ เพื่อช่วยลดความพึงพิงประสบการณ์ของบุคลากร ลดความผิดพลาดที่เกิดจากมนุษย์ และเพิ่มประสิทธิภาพ

การผลิตโดยรวม อย่างไรก็ตาม การนำเทคโนโลยีดังกล่าวมาใช้ในโรงงานจริงยังคงเป็นความท้าทาย เนื่องจากต้องรองรับเงื่อนไขการผลิตที่หลากหลายและแตกต่างกันในแต่ละโรงงาน ทั้งประเภทของวัสดุที่ใช้ตัด ความเร็วและแรงตัดที่เปลี่ยนแปลงตามชนิดชิ้นงาน รวมถึงความแตกต่างของเครื่องจักรแต่ละรุ่นและอายุการใช้งาน ทำให้การพัฒนาวิธีตรวจจับความผิดปกติที่สามารถประยุกต์ใช้ได้จริงในโรงงานจำเป็นต้องคำนึงถึงความยืดหยุ่นในการปรับให้สอดคล้องกับสภาพการผลิตจริงเป็นสำคัญ

ในกระบวนการตัดเฉือน เครื่องมือตัดจะเกิดการสึกหรออย่างค่อยเป็นค่อยไปตามลักษณะของการสัมผัสและแรงตัดที่เกิดขึ้น โดยรูปแบบการสึกหรอของเครื่องมืออาจเกิดได้หลายลักษณะ เช่น การสึกบริเวณหน้าลิ้มตัด (Flank Wear) การสึกบริเวณผิวหน้าตัด (Crater Wear) การบิ่นของคมตัด (Chipping) หรือแม้กระทั่งการแตกหักของคมตัดในกรณีที่เกิดแรงกระแทกสูงหรือมีความร้อนสะสมมากเกินไป การสึกหรอแต่ละรูปแบบส่งผลต่อคุณภาพผิวชิ้นงานและเสถียรภาพของการตัดในระดับที่ต่างกัน เมื่อสภาพการสึกหรอเริ่มเพิ่มขึ้น แรงตัดและการสั่นสะเทือนที่เกิดขึ้นในระหว่างการตัดจะมีลักษณะเปลี่ยนแปลงไป ซึ่งสามารถสะท้อนให้เห็นผ่านข้อมูลจากเซนเซอร์วัดแรงตัด เซนเซอร์วัดการสั่นสะเทือน เซนเซอร์วัดเสียง หรือการวิเคราะห์กำลังมอเตอร์ ดังนั้นการใช้ข้อมูลเชิงสัญญาณจากเซนเซอร์จึงเป็นแนวทางที่เหมาะสมสำหรับการติดตามและประเมินสภาพของเครื่องมือแบบไม่รบกวนกระบวนการผลิต (Non-Intrusive Monitoring) ข้อมูลสัญญาณที่ได้จากกระบวนการผลิตจริงมักมีความไม่สม่ำเสมอและมีสัญญาณรบกวนจำนวนมาก ซึ่งอาจมีสาเหตุจากความผันผวนของคุณสมบัติวัสดุ แรงยึดจับชิ้นงานที่เปลี่ยนไป ความแตกต่างของสภาพเครื่องจักร รวมถึงสภาพแวดล้อมของโรงงานที่อาจสร้างสัญญาณรบกวนเพิ่มเติม การประมวลผลข้อมูลดังกล่าวจึงจำเป็นต้องใช้เทคนิคการวิเคราะห์ที่สามารถจำแนกรูปแบบความผิดปกติได้อย่างแม่นยำ โดยไม่อาศัยสมมติฐานว่ารูปแบบของสัญญาณปกติต้องมีลักษณะคงที่ ซึ่งเป็นข้อจำกัดหลักของวิธีการตรวจสอบด้วยค่าเกณฑ์คงที่ที่ใช้อยู่ในโรงงานจำนวนมาก

ด้วยเหตุนี้ การใช้เทคนิคการเรียนรู้ของเครื่องแบบไม่ต้องมีข้อมูลป้ายกำกับจึงเป็นแนวทางที่เหมาะสมในสถานการณ์ที่ข้อมูลความสึกหรอหรือค่าความผิดปกติยังไม่สามารถระบุได้อย่างชัดเจนในทุกกรณี เทคนิควิธีป่าแยกตัว (Isolation Forest) ถือเป็นหนึ่งในวิธีที่ได้รับการยอมรับอย่างแพร่หลายในงานตรวจจับความผิดปกติ เนื่องจากวิธีนี้ไม่ได้อาศัยการสร้างแบบจำลองของข้อมูลปกติ แต่ใช้หลักการแยกข้อมูลที่มีลักษณะโดดเด่นหรือแตกต่างออกจากกลุ่มข้อมูลหลัก ซึ่งทำให้สามารถตรวจพบความผิดปกติได้แม้เกิดขึ้นเพียงเล็กน้อย (Liu, Ting, and Zhou, 2008) นอกจากนี้ เมื่อผสมผสานเข้ากับหลักการกำหนดค่าเกณฑ์แบบควอนไทล์ จะช่วยให้ระบบสามารถปรับระดับความไวของการแจ้งเตือนให้เหมาะสมกับสภาวะการทำงานจริงของเครื่องจักร ลดอัตราการแจ้งเตือนผิดพลาด และเพิ่มความยืดหยุ่นในการรองรับความแปรผันของสภาพการผลิต ซึ่งเป็นข้อจำกัดสำคัญของวิธีการใช้ค่าเกณฑ์แบบคงที่ที่พบได้ในหลายโรงงานอุตสาหกรรม (Zhang, Elghazoly, and Tweedie, 2019)

การนำวิธีวิเคราะห์ข้อมูลเชิงสัญญาณร่วมกับเทคนิคการเรียนรู้ของเครื่องมาใช้ในการตรวจสอบสภาพเครื่องมือไม่เพียงช่วยเพิ่มความแม่นยำในการตรวจจับการสึกหรอและความผิดปกติในระยะเริ่มต้นเท่านั้น แต่ยังมีส่วนช่วยลดการหยุดชะงักของสายการผลิตโดยไม่จำเป็น เพิ่มประสิทธิภาพการใช้เครื่องมือตัด และยกระดับความเชื่อถือได้ในการผลิตของโรงงานโดยรวม ในระยะยาว การพัฒนาระบบตรวจสอบและบำรุงรักษาเชิงคาดการณ์ที่มีความแม่นยำสูงและใช้งานได้จริงในโรงงาน จะช่วยเพิ่มความสามารถในการแข่งขันของอุตสาหกรรมไทย ทั้งในด้านต้นทุนการผลิต คุณภาพสินค้า และเสถียรภาพในกระบวนการผลิต ซึ่งเป็นปัจจัยสำคัญในการรักษาความสามารถในการแข่งขันกับต่างประเทศในอนาคต นอกจากนี้ การเสื่อมสภาพของเครื่องมือตัดยังส่งผลโดยตรงต่อคุณภาพของชิ้นงานที่ผลิต ซึ่งในหลายกรณีไม่ได้แสดงให้เห็นอย่างชัดเจนในช่วงเริ่มต้นของการสึกหรอ แต่จะค่อย ๆ ส่งผลต่อค่ามิติ ความเรียบของพื้นผิว และความสม่ำเสมอของชิ้นงานเมื่อการผลิตดำเนินไปอย่างต่อเนื่อง หากตรวจพบไม่ทันเวลา อาจนำไปสู่การผลิตชิ้นงานที่ไม่ได้มาตรฐานจำนวนมาก ซึ่งก่อให้เกิดการสูญเสียด้านต้นทุนการผลิตจากการปฏิเสธชิ้นงาน (Reject) การทำซ้ำชิ้นงาน (Rework) หรือแม้กระทั่งการยุติสายการผลิตเพื่อปรับตั้งเครื่องมือใหม่ในกรณีที่ความคลาดเคลื่อนของคุณภาพมีมากเกินไปจนจะยอมรับได้ ผลกระทบเหล่านี้ไม่ได้เกิดขึ้นเพียงต่อคุณภาพของสินค้าเท่านั้น แต่ยังส่งผลต่อความเชื่อมั่นของลูกค้าและภาพลักษณ์ของโรงงานในระยะยาว โดยเฉพาะโรงงานที่เป็นผู้ผลิตชิ้นส่วนให้กับอุตสาหกรรมยานยนต์หรืออุตสาหกรรมการบิน ซึ่งมีข้อกำหนดด้านคุณภาพที่เข้มงวดเป็นพิเศษ การควบคุมคุณภาพที่ไม่เพียงพอจึงอาจเป็นปัจจัยที่ทำให้โรงงานสูญเสียโอกาสทางธุรกิจในระดับห่วงโซ่อุตสาหกรรมได้เช่นกัน

ในทางกลับกัน หากมีการเปลี่ยนเครื่องมือเร็วเกินไปโดยไม่มีข้อมูลรองรับ อาจนำไปสู่การใช้ทรัพยากรเกินจำเป็น ทำให้ต้นทุนเครื่องมือตัดต่อชิ้นงานสูงขึ้นโดยไม่จำเป็น โรงงานจำนวนมากจึงอยู่ในสภาวะที่ต้องสมดุลระหว่าง “ป้องกันความเสียหาย” และ “ลดต้นทุนการเปลี่ยนเครื่องมือ” ซึ่งเป็นความท้าทายที่ยากต่อการตัดสินใจหากไม่มีข้อมูลสภาพการทำงานของเครื่องมือแบบเรียลไทม์ประกอบ การมีระบบติดตามและประเมินสภาพการสึกหรอของเครื่องมือแบบอัตโนมัติที่สามารถสะท้อนสภาพจริงได้อย่างแม่นยำจึงเป็นปัจจัยสำคัญในการบริหารจัดการต้นทุนและความเสถียรของการผลิตในระยะยาว

ถึงแม้การใช้เซนเซอร์และการวิเคราะห์ข้อมูลเชิงสัญญาณจะเป็นแนวทางที่ได้รับการศึกษาและพัฒนาอย่างต่อเนื่อง แต่การนำไปใช้งานในโรงงานจริงยังคงมีข้อจำกัดหลายประการ เนื่องจากรูปแบบของสัญญาณที่ได้จากสภาพแวดล้อมการผลิตจริงมักมีความผันผวนสูง ขึ้นอยู่กับลักษณะการตัดวัสดุของชิ้นงาน เงื่อนไขการจับยึด และอายุการใช้งานของเครื่องจักร ทำให้วิธีการตรวจจับความผิดปกติแบบใช้ค่าเกณฑ์คงที่ (Fixed Threshold) ไม่สามารถปรับให้สอดคล้องกับสภาวะที่เปลี่ยนแปลงได้อย่างยืดหยุ่น (Zhang et al., 2019) ประเด็นดังกล่าวจึงกลายเป็นช่องว่างขององค์ความรู้ (Research Gap) ในงานตรวจสอบสภาพเครื่องมือ ซึ่งสะท้อนถึงความจำเป็นในการพัฒนาวิธีวิเคราะห์ที่สามารถ

“เรียนรู้รูปแบบสภาวะปกติ” ของกระบวนการผลิตได้โดยไม่ต้องพึ่งพาข้อมูลกำกับหรือข้อมูลความเสียหายที่จำลองขึ้นล่วงหน้า ดังนั้นงานวิจัยที่นำเทคนิค Machine Learning แบบไม่ต้องมีข้อมูลป้ายกำกับ เช่น Isolation Forest มาประยุกต์ร่วมกับข้อมูลสัญญาณจริงที่ได้จากกระบวนการผลิต จึงเป็นแนวทางที่มีศักยภาพสูงในการตรวจจับสภาวะผิดปกติในช่วงเริ่มต้นก่อนที่ความเสียหายจะลุกลามไปสู่ปัญหาที่รุนแรงขึ้น การตั้งค่าเกณฑ์ด้วยวิธีควอนไทล์ยังช่วยให้ระบบสามารถปรับระดับความไวของการแจ้งเตือนให้เหมาะสมกับลักษณะการผลิตในแต่ละโรงงานได้โดยไม่ต้องปรับตั้งค่าบ่อยครั้ง ซึ่งสอดคล้องกับความต้องการใช้งานจริงในภาคอุตสาหกรรมที่ต้องการระบบตรวจสอบที่มีเสถียรภาพ ใช้งานง่าย และไม่เพิ่มภาระต่อผู้ควบคุมเครื่องจักร

เมื่อระบบสามารถตรวจจับความผิดปกติได้ตั้งแต่ระยะแรก โรงงานจะสามารถวางแผนการบำรุงรักษาล่วงหน้าได้อย่างมีประสิทธิภาพ ลดโอกาสในการเกิดการหยุดเครื่องโดยไม่คาดคิด เพิ่มอายุการใช้งานของเครื่องมือตัด ลดปริมาณชิ้นงานที่ไม่ได้คุณภาพ และช่วยให้กระบวนการผลิตมีความต่อเนื่องมากขึ้น ซึ่งทั้งหมดนี้ล้วนส่งผลโดยตรงต่อประสิทธิภาพในการผลิต ต้นทุนต่อหน่วยที่ลดลง และความสามารถในการแข่งขันของโรงงานในระดับอุตสาหกรรม โดยเฉพาะอย่างยิ่งในบริบทของประเทศไทยที่กำลังมุ่งไปสู่การเป็นศูนย์กลางการผลิตมูลค่าสูงในภูมิภาคเอเชียตะวันออกเฉียงใต้ การพัฒนาเทคโนโลยีช่วยให้โรงงานสามารถควบคุมคุณภาพได้แม่นยำขึ้นจึงเป็นปัจจัยสำคัญต่อความสำเร็จในระยะยาว จากการทบทวนแนวคิดและงานวิจัยที่เกี่ยวข้อง พบว่างานวิจัยด้านการตรวจสอบสภาพเครื่องมือตัดในกระบวนการตัดเฉือนยังคงมีข้อจำกัดหลายประการ งานวิจัยจำนวนมากยังอาศัยการกำหนดค่าเกณฑ์แบบคงที่ (Fixed Threshold) ในการตัดสินความผิดปกติของสัญญาณ ซึ่งไม่สามารถปรับให้สอดคล้องกับความแปรผันของสภาวะการตัดจริง เช่น การเปลี่ยนแปลงของวัสดุ ความเร็วตัด หรือสภาพเครื่องจักร ส่งผลให้เกิดการแจ้งเตือนผิดพลาดหรือไม่สามารถตรวจจับความผิดปกติในระยะเริ่มต้นได้อย่างมีประสิทธิภาพ

นอกจากนี้ งานวิจัยที่ใช้เทคนิคการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Learning) แม้จะสามารถให้ความแม่นยำสูงในสภาวะที่มีข้อมูลครบถ้วน แต่มีข้อจำกัดสำคัญเมื่อพิจารณาในบริบทของโรงงานอุตสาหกรรมจริง เนื่องจากวิธีการดังกล่าวจำเป็นต้องอาศัยข้อมูลความเสียหายที่มีการติดป้ายกำกับ (Labeled Fault Data) เพื่อใช้ในการฝึกแบบจำลอง ซึ่งในทางปฏิบัติข้อมูลประเภทนี้มักหาได้ยาก เนื่องจากความเสียหายของเครื่องจักรหรือเครื่องมือตัดไม่ได้เกิดขึ้นบ่อย และโรงงานมักหลีกเลี่ยงไม่ให้เกิดความเสียหายโดยเจตนาเพื่อเก็บข้อมูล นอกจากนี้ การรวบรวมและติดป้ายกำกับข้อมูลความผิดปกติยังต้องอาศัยผู้เชี่ยวชาญเฉพาะทางและมีต้นทุนด้านเวลาและค่าใช้จ่ายสูง อีกทั้งข้อมูลความเสียหายที่มีอยู่มักไม่ครอบคลุมรูปแบบความผิดปกติทั้งหมดที่อาจเกิดขึ้นจริง ส่งผลให้แบบจำลองที่พัฒนาด้วยวิธี Supervised Learning มีความสามารถจำกัดในการตรวจจับความผิดปกติรูปแบบใหม่หรือสภาวะการผลิตที่เปลี่ยนแปลงไป เพื่อลดข้อจำกัดดังกล่าว งานวิจัยจำนวนหนึ่งจึงเริ่มนำเทคนิคการเรียนรู้

ของเครื่องแบบไม่ต้องมีข้อมูลป้ายกำกับ (Unsupervised Learning) เช่น วิธีป่าแยกตัว (Isolation Forest) มาใช้ในการตรวจจับความผิดปกติของเครื่องจักรและกระบวนการผลิต อย่างไรก็ตามจากการทบทวนงานวิจัยที่เกี่ยวข้องพบว่า แม้จะใช้ Isolation Forest เป็นตัวแบบหลักในการตรวจจับความผิดปกติ แต่หลายงานยังคงกำหนดค่าเกณฑ์การตัดสินใจความผิดปกติ (Threshold) ด้วยวิธีคงที่ (Fixed Threshold) หรืออาศัยการตั้งค่าจากประสบการณ์ของผู้เชี่ยวชาญเป็นหลัก ซึ่งวิธีการดังกล่าวไม่สามารถสะท้อนลักษณะการกระจายตัวของข้อมูลจริงที่มีความแปรผันสูงในกระบวนการผลิตอุตสาหกรรม

ในทางปฏิบัติ การใช้ค่าเกณฑ์แบบคงที่มักนำไปสู่ปัญหาการแจ้งเตือนผิดพลาด (False Alarm) ในกรณีที่สภาวะการผลิตเปลี่ยนแปลง เช่น การเปลี่ยนชนิดวัสดุ เครื่องมือตัด หรือพารามิเตอร์การตัดเฉือน หรือในบางกรณีอาจไม่สามารถตรวจจับความผิดปกติที่กำลังพัฒนาได้ทันเวลา เนื่องจากค่าเกณฑ์ที่ตั้งไว้ไม่สอดคล้องกับการกระจายตัวของข้อมูลในสภาวะการทำงานจริง แม้ว่าบางงานจะเลือกใช้ Isolation Forest ซึ่งมีความสามารถในการจัดการข้อมูลที่ไม่มีป้ายกำกับได้ดี แต่ยังคงขาดแนวทางในการกำหนดค่าเกณฑ์การตัดสินใจที่เหมาะสมและสามารถปรับให้สอดคล้องกับข้อมูลในแต่ละช่วงการผลิตอย่างเป็นระบบ

จากช่องว่างดังกล่าว แสดงให้เห็นว่างานวิจัยที่มีอยู่ยังขาดแนวทางที่ผสานข้อดีของการเรียนรู้แบบไม่ต้องมีข้อมูลป้ายกำกับเข้ากับการกำหนดค่าเกณฑ์การตัดสินใจที่อิงกับลักษณะการกระจายตัวของข้อมูลจริง งานวิจัยนี้จึงมุ่งเน้นการพัฒนาแนวทางการตรวจจับความผิดปกติของเครื่องมือตัดในกระบวนการผลิตด้วยเครื่องจักร CNC โดยประยุกต์ใช้เทคนิค Isolation Forest ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) ซึ่งสามารถปรับค่าเกณฑ์ให้เหมาะสมกับการกระจายของค่า Anomaly Score ในแต่ละสภาวะการผลิตได้อย่างยืดหยุ่น แนวทางดังกล่าวมีเป้าหมายเพื่อลดการแจ้งเตือนผิดพลาด เพิ่มความแม่นยำในการตรวจจับความผิดปกติ และรองรับความแปรผันของกระบวนการผลิตจริงในโรงงานอุตสาหกรรมไทย

เพื่อแก้ไขช่องว่างดังกล่าว งานวิจัยนี้นำเสนอแนวทางการตรวจจับความผิดปกติที่ผสานความยืดหยุ่นของการเรียนรู้แบบไม่ต้องมีข้อมูลป้ายกำกับเข้ากับการกำหนดค่าเกณฑ์ที่อิงกับการกระจายตัวของข้อมูลจริงจากข้อมูลสัญญาณที่ได้จากกระบวนการตัดเฉือนโลหะด้วยเครื่องจักร CNC ซึ่งเป็นข้อมูลที่มีความแปรผันสูงและมีลักษณะไม่คงที่ตามเวลา (non-stationary) สะท้อนสภาวะการผลิตจริงในโรงงานอุตสาหกรรมได้ดีกว่างานที่อาศัยข้อมูลจำลองหรือข้อมูลจากสภาวะควบคุมในห้องปฏิบัติการ

จากแนวทางและผลการศึกษาที่นำเสนอ งานวิจัยนี้มีส่วนเติมเต็มองค์ความรู้ใน 3 ประเด็นหลัก ได้แก่ ประเด็นแรก การประยุกต์ใช้ขั้นตอนวิธีป่าแยกตัว (Isolation Forest) กับข้อมูลสัญญาณจริงที่ได้จากกระบวนการผลิตด้วยเครื่องจักร CNC ซึ่งมีความแปรผันสูงและไม่คงที่ตามเวลา ช่วยสะท้อนสภาวะการผลิตจริงในโรงงานอุตสาหกรรมได้อย่างเหมาะสม ประเด็นที่สอง การพัฒนาแนวทางการกำหนดค่า

เกณฑ์การตัดสินความผิดปกติแบบควอนไทล์ (Quantile Threshold) ที่สามารถปรับเปลี่ยนได้ตามลักษณะการกระจายของข้อมูลในแต่ละสภาวะการผลิต แทนการใช้ค่าเกณฑ์แบบคงที่หรือการตั้งค่าจากประสบการณ์เพียงอย่างเดียว ซึ่งช่วยเพิ่มความยืดหยุ่นในการนำระบบไปใช้งานจริง และประเด็นสุดท้าย การแสดงให้เห็นเชิงประจักษ์ว่าการใช้ค่าเกณฑ์แบบไดนามิกร่วมกับ Isolation Forest สามารถเพิ่มความสามารถในการตรวจจับความผิดปกติในระยะเริ่มต้น (early detection) ได้อย่างมีนัยสำคัญ ขณะเดียวกันยังสามารถควบคุมอัตราการแจ้งเตือนผิดพลาด (False Alarm) ให้อยู่ในระดับที่เหมาะสม

ผลลัพธ์ดังกล่าวสะท้อนถึงศักยภาพของแนวทางที่นำเสนอในการประยุกต์ใช้กับระบบตรวจสอบสภาพเครื่องมือตัดแบบเรียลไทม์ในโรงงานอุตสาหกรรมจริง และสนับสนุนการบำรุงรักษาเชิงคาดการณ์ได้อย่างมีประสิทธิภาพ

1.2 วัตถุประสงค์งานวิจัย

1.2.1 เพื่อพัฒนาแบบจำลองการทำนายการสึกหรอของเครื่องมือตัดจากสัญญาณแรงตัด (Cutting Force) และการสั่นสะเทือนจากกระบวนการตัด

1.2.2 เพื่อพัฒนาแนวทางการตรวจจับความผิดปกติ เพื่อเพิ่มประสิทธิภาพในการแยกแยะสัญญาณปกติและผิดปกติจากข้อมูลจริง

1.3 คำถามงานวิจัย

1.3.1 สามารถพัฒนาแบบจำลองเพื่อทำนายการสึกหรอของเครื่องมือตัดจากข้อมูลแรงตัด และการสั่นสะเทือนได้อย่างแม่นยำเพียงใด

1.3.2 วิธีการตรวจจับความผิดปกติด้วยวิธีการป่าแยกตัว (Isolation Forest) ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) สามารถเพิ่มประสิทธิภาพในการตรวจพบความผิดปกติของเครื่องมือตัดได้ดีกว่าวิธีใช้ค่าเกณฑ์คงที่หรือไม่

1.4 ข้อตกลงเบื้องต้น

1.4.1 ข้อมูลที่ได้จากการทดลองบนเครื่องจักรควบคุมเชิงตัวเลขแบบห้าแกน และจากชุดข้อมูลมาตรฐาน MATWI มีความถูกต้องและสามารถสะท้อนสภาวะการทำงานจริงได้

1.4.2 เครื่องมือตัดและอุปกรณ์ที่ใช้ในการทดลองอยู่ในสภาพมาตรฐาน และไม่ส่งผลกระทบต่อความถูกต้องของข้อมูล

1.4.3 การประมวลผลและการวิเคราะห์ข้อมูลด้วยเทคนิคการเรียนรู้ของเครื่องสามารถสะท้อนพฤติกรรมการสึกหรอและความผิดปกติของเครื่องมือตัดได้อย่างเหมาะสม

1.5 ขอบเขตงานวิจัย

งานวิจัยนี้มุ่งเน้นการพัฒนาแบบจำลองสำหรับการทำนายการสึกหรอของเครื่องมือตัดและการตรวจจับความผิดปกติของเครื่องมือตัดในกระบวนการตัดเฉือนด้วยเครื่องจักรควบคุมเชิงตัวเลขแบบห้าแกน โดยใช้ข้อมูลจากการทดลองจริงที่ได้จากการวัดแรงตัดและการสั่นสะเทือนจากกระบวนการตัด และข้อมูลจากชุดข้อมูลมาตรฐาน MATWI ขอบเขตของการวิจัยครอบคลุมการประมวลผลข้อมูลให้อยู่ในรูปแบบอนุกรมเวลา การใช้วิธีการถดถอยเชิงเส้นในการสร้างแบบจำลองเพื่อทำนายแนวโน้มการสึกหรอ และการประยุกต์ใช้ขั้นตอนวิธีการเรียนรู้ของเครื่องในการตรวจจับความผิดปกติ โดยกำหนดเกณฑ์การประเมินผลด้วยตัวชี้วัดมาตรฐาน ได้แก่ ความแม่นยำ ความไว ความเที่ยงตรง และอัตราการตรวจพบความผิดปกติล่วงหน้า ทั้งนี้งานวิจัยจำกัดขอบเขตอยู่เพียงเครื่องมือตัดและวัสดุที่กำหนดไว้ ไม่ครอบคลุมถึงทุกประเภทของเครื่องมือและเงื่อนไขการตัดเฉือนที่หลากหลาย

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1.6.1 ได้แบบจำลองที่สามารถทำนายการสึกหรอของเครื่องมือตัดจากสัญญาณแรงตัด และการสั่นสะเทือนได้อย่างมีประสิทธิภาพ ซึ่งช่วยเพิ่มความน่าเชื่อถือและความถูกต้องของการบำรุงรักษาเชิงคาดการณ์

1.6.2 ได้แนวทางการตรวจจับความผิดปกติของเครื่องมือตัดด้วยวิธีการเรียนรู้ของเครื่องแบบไม่มีผู้สอน ที่สามารถระบุความผิดปกติจากข้อมูลการทำงานจริงได้อย่างแม่นยำ ช่วยลดความเสี่ยงจากการแตกหักของเครื่องมือ ลดของเสียในกระบวนการผลิต และลดต้นทุนการหยุดเครื่องโดยไม่คาดคิด

1.7 คำอธิบายศัพท์

1.7.1 เครื่องมือตัด (Cutting Tool) หมายถึง อุปกรณ์ที่ใช้ในการตัดเฉือนวัสดุบนเครื่องจักรควบคุมเชิงตัวเลข โดยการสึกหรอของเครื่องมือตัดเป็นตัวชี้วัดสำคัญที่ส่งผลต่อแรงตัด คุณภาพผิว และประสิทธิภาพของกระบวนการผลิต

1.7.2 การสึกหรอของเครื่องมือตัด (Tool Wear) หมายถึง การสูญเสียเนื้อวัสดุที่คมตัดของเครื่องมือตัดระหว่างการใช้งาน ซึ่งอาจเกิดจากแรงตัด ความร้อน หรือการสั่นสะเทือน การสึกหรอที่เพิ่มขึ้นส่งผลให้แรงตัดสูงขึ้นและอาจทำให้เครื่องมือแตกหักได้

1.7.3 การตรวจจับความผิดปกติ (Anomaly Detection) หมายถึง กระบวนการระบุข้อมูลที่มีรูปแบบแตกต่างจากสภาวะปกติ ซึ่งในงานวิจัยนี้หมายถึงการตรวจหาความเบี่ยงเบนของสัญญาณแรงตัด และสัญญาณการสั่นสะเทือนที่เกี่ยวข้องกับกระบวนการตัดเฉือน เพื่อใช้เป็นตัวบ่งชี้ความผิดปกติของเครื่องมือตัด

1.7.4 การเรียนรู้ของเครื่อง (Machine Learning) หมายถึง กระบวนการสร้างแบบจำลองจากข้อมูลโดยใช้วิธีการทางคณิตศาสตร์และสถิติ เพื่อให้คอมพิวเตอร์สามารถเรียนรู้รูปแบบจากข้อมูลและทำนายหรือจำแนกผลลัพธ์ได้โดยไม่ต้องเขียนโปรแกรมแบบกำหนดชัดเจน

1.7.5 วิธีป่าแยกตัว (Isolation Forest) หมายถึง เทคนิคการเรียนรู้ของเครื่องแบบไม่ต้องมีข้อมูลกำกับ (Unsupervised Learning) ที่ใช้ในการตรวจจับความผิดปกติโดยอาศัยหลักการสุ่มเลือกคุณลักษณะและแบ่งข้อมูลย่อยออกมา เพื่อแยกตัวอย่างที่ผิดปกติให้ออกมาได้ง่ายกว่าตัวอย่างปกติ

1.7.6 ค่าควอนไทล์ (Quantile Threshold) หมายถึง ค่าระดับเกณฑ์ทางสถิติที่ใช้กำหนดเส้นแบ่งในการระบุความผิดปกติจากข้อมูล โดยการกำหนดเกณฑ์จากตำแหน่งเปอร์เซ็นต์ไทล์ของข้อมูล แทนการใช้ค่าเกณฑ์คงที่



บทที่ 2

ปรัทัศน์วรรณกรรมและงานวิจัยที่เกี่ยวข้อง

2.1 เครื่องจักรควบคุมเชิงตัวเลข (CNC)

2.1.1 ความหมายและพัฒนาการของเครื่องจักรควบคุมเชิงตัวเลข

เครื่องจักรควบคุมเชิงตัวเลข (CNC) หมายถึง เครื่องจักรกลที่ทำงานโดยอาศัยการป้อนคำสั่งผ่านระบบคอมพิวเตอร์ เพื่อควบคุมการเคลื่อนที่ของเครื่องมือตัดหรือหัวกัดให้มีความแม่นยำสูง เครื่องจักรประเภทนี้ถูกพัฒนามาจากเครื่องจักรกลทั่วไปที่อาศัยแรงงานคนและกลไกทางกลในการควบคุม โดยมีจุดเด่นที่สามารถทำงานซ้ำ ๆ ได้อย่างถูกต้อง รวดเร็ว และลดความผิดพลาดจากการปฏิบัติงานของมนุษย์

การพัฒนาเครื่องจักร CNC เริ่มต้นขึ้นในช่วงทศวรรษ 1950 จากการประยุกต์ใช้ระบบเจาะบัตร (Punched Card) และเทปกระดาษ (Paper Tape) ในการควบคุมการเคลื่อนที่ของเครื่องจักร ต่อมาได้มีการพัฒนาเป็นระบบควบคุมเชิงตัวเลขด้วยคอมพิวเตอร์ (CNC) ในช่วงทศวรรษ 1970 ซึ่งช่วยให้สามารถเก็บและเรียกใช้โปรแกรมการผลิตได้อย่างยืดหยุ่นมากขึ้น หลังจากนั้นเทคโนโลยี CNC ได้รับการพัฒนาอย่างต่อเนื่อง ทั้งด้านฮาร์ดแวร์ ซอฟต์แวร์ ระบบเซนเซอร์ และระบบควบคุมอัตโนมัติ ทำให้เครื่องจักรควบคุมเชิงตัวเลข (CNC) ในปัจจุบันมีความสามารถสูงขึ้น ทั้งในด้านความแม่นยำ ความเร็ว และการทำงานแบบหลายแกน (Yao, Chen, Pan, and Lin, 2024)

ปัจจุบัน เครื่องจักรควบคุมเชิงตัวเลข (CNC) ได้กลายเป็นหัวใจสำคัญของกระบวนการผลิตสมัยใหม่ในหลายอุตสาหกรรม เช่น อุตสาหกรรมยานยนต์ อากาศยาน เครื่องมือแพทย์ และอุตสาหกรรมแม่พิมพ์ เนื่องจากสามารถผลิตชิ้นงานที่มีความซับซ้อนและต้องการความละเอียดสูงได้อย่างมีประสิทธิภาพ อีกทั้งยังรองรับการทำงานร่วมกับเทคโนโลยีสมัยใหม่ เช่น ระบบอัตโนมัติ (Automation) หุ่นยนต์อุตสาหกรรม (Industrial Robots) และการผลิตอัจฉริยะ (Smart Manufacturing) ที่สอดคล้องกับแนวคิดอุตสาหกรรม 4.0

2.1.2 ส่วนประกอบสำคัญของเครื่องจักรควบคุมเชิงตัวเลข

เครื่องจักรควบคุมเชิงตัวเลข (CNC) ประกอบด้วยส่วนสำคัญหลายส่วนที่ทำงานร่วมกันเพื่อให้กระบวนการตัดเฉือนชิ้นงานมีความถูกต้องและมีประสิทธิภาพ โดยสามารถแบ่งได้ดังนี้

ระบบควบคุม (Control Unit) - เป็นสมองของเครื่องจักร ทำหน้าที่รับโปรแกรมคำสั่ง (NC Program) ประมวลผล และควบคุมการทำงานของส่วนต่าง ๆ ของเครื่องจักร ทั้งการเคลื่อนที่ของแกน (Axis Motion) ความเร็วรอบสปินเดิล และการป้อนเครื่องมือตัด

สปินเดิล (Spindle) - ทำหน้าที่หมุนเครื่องมือตัดหรือหัวกัดตามความเร็วที่กำหนด โดยสปินเดิลถือเป็นหัวใจของกระบวนการผลิต เนื่องจากมีผลโดยตรงต่อคุณภาพผิวชิ้นงาน ความแม่นยำ และอัตราการสึกหรอของเครื่องมือตัด

โต๊ะงาน (Worktable) - เป็นพื้นที่สำหรับยึดจับชิ้นงานให้อยู่ในตำแหน่งที่ถูกต้องและมั่นคง โดยมักใช้ร่วมกับฟิกซ์เจอร์ (Fixture) หรือปากกาจับงาน (Vise) เพื่อป้องกันการเคลื่อนที่ของชิ้นงานระหว่างการตัดเฉือน

ระบบขับเคลื่อนแกน (Feed Drive System) - ประกอบด้วยมอเตอร์เซอร์โว (Servo Motor) และสกรูบอล (Ball Screw) ที่ทำหน้าที่ควบคุมการเคลื่อนที่ในแต่ละแกน (X, Y, Z และแกนเพิ่มเติมในกรณีของเครื่อง Multi-axis) โดยเน้นความแม่นยำและความต่อเนื่องในการเคลื่อนที่

ระบบเซนเซอร์และอุปกรณ์ตรวจวัด (Sensors and Measuring Devices) - ใช้ในการตรวจสอบตำแหน่ง ความเร็ว และแรงที่เกิดขึ้นระหว่างกระบวนการผลิต เพื่อส่งข้อมูลกลับไปยังระบบควบคุม (Feedback Control) ทำให้เครื่องจักรสามารถปรับค่าการทำงานแบบเรียลไทม์ได้


เครื่องมือตัด (Cutting Tool) - เป็นส่วนที่สัมผัสกับชิ้นงานโดยตรง มีหลายประเภทตามลักษณะงาน เช่น ดอกสว่าน ดอกกัด หรือลูกกลึงเจียร คุณภาพของเครื่องมือตัดมีผลโดยตรงต่อความแม่นยำ ประสิทธิภาพการผลิต และอายุการใช้งานของเครื่องจักร

โครงสร้างเครื่องจักร (Machine Structure) - เป็นส่วนที่รับน้ำหนักและรองรับการติดตั้งชิ้นส่วนทั้งหมด ความแข็งแรงและความเสถียรของโครงสร้างมีผลต่อความแม่นยำและการสั่นสะเทือนของเครื่องจักร

2.1.3 บทบาทและความสำคัญของสปินเดิลในการผลิต

สปินเดิล (Spindle) เป็นส่วนประกอบหลักของเครื่องจักรควบคุมเชิงตัวเลข (CNC) ที่ทำหน้าที่หมุนเครื่องมือตัดเพื่อดำเนินกระบวนการตัดเฉือนชิ้นงาน ดังตัวอย่างภาพที่ 2.1 (Superior Spindle Services, 2024) โดยสามารถปรับค่าความเร็วรอบและแรงบิดให้เหมาะสมกับชนิดของเครื่องมือและวัสดุที่นำมาผลิต สมรรถนะของสปินเดิลจึงมีผลโดยตรงต่อประสิทธิภาพของกระบวนการผลิตในหลายมิติ ทั้งด้านคุณภาพ ความแม่นยำ และเสถียรภาพของการทำงาน การหมุนที่มีความเสถียรช่วยให้ชิ้นงานมีค่าความคลาดเคลื่อนต่ำและมีคุณภาพผิวที่เรียบสม่ำเสมอ ซึ่งเป็นปัจจัยสำคัญในอุตสาหกรรมที่ต้องการความเที่ยงตรงสูง เช่น อุตสาหกรรมอากาศยานและการแพทย์ ขณะเดียวกัน สภาพการทำงาน of สปินเดิลยังส่งผลต่ออายุการใช้งานของเครื่องมือตัด เนื่องจากการหมุนที่ราบรื่นสามารถลดอัตราการสึกหรอและความเสี่ยงต่อการแตกหักของเครื่องมือได้ นอกจากนี้ ความน่าเชื่อถือของระบบการผลิตยังขึ้นอยู่กับความพร้อมใช้งานของสปินเดิล หากเกิดความผิดปกติ อาจนำไปสู่ความเสียหายของเครื่องมือหรือชิ้นงาน และส่งผลให้กระบวนการผลิตต้องหยุดชะงักจนเกิดความสูญเสียทางเศรษฐกิจ ในบริบทของอุตสาหกรรมการผลิตสมัยใหม่ สปินเดิลมักถูกติดตั้งเซนเซอร์เพื่อตรวจวัดพารามิเตอร์สำคัญ

เช่น แรงตัด การสั่นสะเทือน และอุณหภูมิ ซึ่งข้อมูลเหล่านี้สามารถนำไปวิเคราะห์ด้วยเทคนิคการเรียนรู้ของเครื่องเพื่อการตรวจจับความผิดปกติและสนับสนุนการบำรุงรักษาเชิงคาดการณ์ได้อย่างมีประสิทธิภาพ (Oh, Pitz, and Pochiraju, 2023)



รูปที่ 2.1 ตัวอย่างโครงสร้างสปินเดิลของเครื่องจักร CNC ซึ่งเป็นส่วนประกอบหลักที่ทำหน้าที่หมุนเครื่องมือตัดและเป็นแหล่งกำเนิดแรงและการสั่นสะเทือนในกระบวนการตัดเฉือน

2.2 การสึกหรอของเครื่องมือตัด

2.2.1 ประเภทของการสึกหรอ

การสึกหรอของเครื่องมือตัด (Tool Wear) หมายถึง การสูญเสียเนื้อวัสดุบริเวณคมตัดของเครื่องมือที่เกิดขึ้นระหว่างกระบวนการตัดเฉือนชิ้นงาน โดยเกิดจากแรงตัด แรงเสียดทาน และอุณหภูมิสูงที่เกิดขึ้นต่อเนื่องในบริเวณจุดสัมผัสระหว่างเครื่องมือกับวัสดุ การสึกหรอของเครื่องมือตัดสามารถจำแนกได้หลายประเภทตามลักษณะของการเกิดและตำแหน่งที่เกิดการสึกหรอ (Wu, Jennings, Terpenney, Gao, and Kumara, 2017) ดังนี้

2.2.1.1 การสึกหรอบริเวณหน้าลาด (Crater Wear) เกิดขึ้นที่บริเวณผิวหน้าของเครื่องมือตัด ซึ่งเป็นส่วนที่เศษวัสดุไหลผ่านระหว่างการตัดเฉือน การเสียดสีที่เกิดขึ้นต่อเนื่องและอุณหภูมิที่สูงมากทำให้เกิดการหลอมละลายของเนื้อเครื่องมือและเกิดร่องลึกเป็นหลุมลักษณะการสึกหรอนี้มักพบในวัสดุที่มีความเหนียวสูง หรือในกรณีที่ใช้ความเร็วตัดสูง (High Cutting Speed)

2.2.1.2 การสึกหรอบริเวณข้างคมตัด (Flank Wear) เป็นรูปแบบการสึกหรอที่พบบ่อยที่สุด เกิดขึ้นบริเวณผิวด้านข้างของเครื่องมือซึ่งสัมผัสกับชิ้นงานโดยตรง การสึกหรอนี้ส่งผลโดยตรงต่อคุณภาพผิวของชิ้นงานและขนาดที่ผลิตได้ มักเกิดจากแรงเสียดทานที่เกิดขึ้นต่อเนื่องระหว่างคมตัดกับผิวชิ้นงาน การวัดค่าการสึกหรอนี้มักใช้เป็นตัวชี้วัดหลักในการประเมินอายุการใช้งานของเครื่องมือตัด

2.2.1.3 การสึกหรอบริเวณมุมคมตัด (Notch Wear) เกิดขึ้นที่บริเวณขอบของคมตัด ซึ่งเป็นจุดเปลี่ยนระหว่างหน้าลาดและด้านข้างของเครื่องมือ การสึกหรอนี้เกิดจากแรงเฉือนที่ไม่สม่ำเสมอ หรือการสะสมของเศษวัสดุในบริเวณนั้น ทำให้เกิดรอยบากลึก (Notch) ซึ่งอาจลุกลามจนทำให้เครื่องมือแตกหัก

2.2.1.4 การสึกหรอจากการขัดสี (Abrasive Wear) เกิดจากเศษวัสดุหรือผงโลหะที่มีความแข็งมากกว่าความแข็งของเครื่องมือ เคลื่อนที่ไปบนผิวคมตัดจนเกิดการขูดขีดและสูญเสียเนื้อวัสดุ โดยเฉพาะในกรณีที่ไม่มีการหล่อลื่นเพียงพอ

2.2.1.5 การสึกหรอจากการยึดเกาะ (Adhesive Wear) เกิดจากการที่เศษวัสดุบางส่วนจากชิ้นงานหลอมและยึดติดกับคมตัดของเครื่องมือ เมื่อแรงเฉือนเปลี่ยนทิศทาง เศษวัสดุเหล่านี้จะหลุดออกพร้อมกับดิ่งเนื้อวัสดุของเครื่องมือไปด้วย ทำให้เกิดการสึกหรอเป็นหลุมเล็ก ๆ ต่อเนื่อง

2.2.1.6 การสึกหรอจากการออกซิเดชันและการแพร่ (Oxidation and Diffusion Wear) เกิดขึ้นเมื่ออุณหภูมิระหว่างการตัดสูงมากจนทำให้เกิดการออกซิเดชันของผิวคมตัด หรือเกิดการแพร่ของอะตอมระหว่างวัสดุของเครื่องมือและชิ้นงาน การสึกหรอประเภทนี้จะค่อย ๆ ขยายตัว และทำให้ความแข็งของคมตัดลดลง (Yang, Pattipati, Awasthi, and Bollas, 2022)

2.2.1.7 การบิ่นของคมตัด (Chipping Wear) การบิ่นของคมตัดเป็นความเสียหายที่เกิดขึ้นแบบฉับพลัน โดยมีลักษณะเป็นการแตกหรือหลุดของเนื้อวัสดุบริเวณคมตัด มักเกิดจากแรงกระแทก การสั่นสะเทือน หรือการตัดแบบไม่ต่อเนื่อง ซึ่งแตกต่างจากการสึกหรอประเภทอื่นที่เกิดขึ้นอย่างค่อยเป็นค่อยไป

2.2.2 ปัจจัยที่มีผลต่อการสึกหรอ

การสึกหรอของเครื่องมือตัด (Tool Wear) เป็นผลมาจากการทำงานร่วมกันของหลายปัจจัยทั้งทางด้านกลศาสตร์ ความร้อน และคุณสมบัติของวัสดุที่ใช้ในการตัดเฉือน (Wu et al., 2017) การเข้าใจปัจจัยเหล่านี้มีความสำคัญอย่างยิ่งในการวางแผนการผลิต การเลือกเงื่อนไขการตัดที่เหมาะสม และการพัฒนาแบบจำลองเพื่อทำนายอายุการใช้งานของเครื่องมือ โดยสามารถแบ่งปัจจัยที่มีผลต่อการสึกหรอได้ดังนี้

2.2.2.1 ความเร็วตัด (Cutting Speed) ความเร็วตัดเป็นตัวแปรที่มีผลโดยตรงต่ออุณหภูมิในเขตตัด เมื่อความเร็วตัดสูงขึ้นจะทำให้อุณหภูมิเพิ่มขึ้น ส่งผลให้เนื้อวัสดุของเครื่องมือตัดอ่อนตัว และเกิดการสึกหรอจากการแพร่ หรือการออกซิเดชันได้ง่ายขึ้น อย่างไรก็ตาม หากความเร็วตัดต่ำเกินไป อาจทำให้เกิดแรงเฉือนสูงและเศษวัสดุติดคมตัด ซึ่งก็เป็นอีกสาเหตุของการสึกหรอเช่นกัน

2.2.2.2 อัตราป้อน (Feed Rate) ที่สูงจะเพิ่มแรงตัดและเร่งการสึกหรอของคมตัด โดยเฉพาะบริเวณด้านข้างและมุมคมตัด ดังนั้นควรเลือกอัตราป้อนให้เหมาะสมเพื่อสมดุลระหว่างการผลิตและอายุเครื่องมือ

2.2.2.3 ความลึกในการตัด (Depth of Cut) ความลึกในการตัดมีผลต่อแรงเฉือนและแรงกระแทกที่กระทำต่อคมตัดโดยตรง การตัดลึกเกินไปอาจทำให้เกิดการสั่นสะเทือนรุนแรง (Chatter) และเร่งการสึกหรอของเครื่องมือ นอกจากนี้ยังทำให้เศษวัสดุสะสมบริเวณคมตัดมากขึ้นซึ่งเพิ่มแรงเสียดทานในระหว่างการตัด

2.2.2.4 วัสดุของชิ้นงาน (Workpiece Material) วัสดุที่มีความแข็งสูงหรือมีองค์ประกอบทางเคมีบางชนิด เช่น เหล็กกล้าคาร์บอนสูง เหล็กกล้าไร้สนิม (Stainless Steel) หรือไทเทเนียม จะทำให้เกิดแรงตัดและอุณหภูมิสูง ส่งผลให้เครื่องมือตัดสึกหรอเร็ว นอกจากนี้วัสดุบางประเภทอาจทำให้เกิดการยึดเกาะระหว่างผิวเครื่องมือและชิ้นงาน ซึ่งเป็นสาเหตุของการสึกหรอจากการยึดเกาะ (Adhesive Wear)

2.2.2.5 วัสดุของเครื่องมือตัด (Tool Material) คุณสมบัติของวัสดุเครื่องมือตัด เช่น ความแข็ง (Hardness) ความเหนียว (Toughness) และความต้านทานต่ออุณหภูมิสูง (Thermal Resistance) มีผลต่ออัตราการสึกหรอโดยตรง เครื่องมือตัดที่ผลิตจากคาร์ไบด์ เซรามิก หรือเพชรเทียม จะมีความทนทานต่อการสึกหรอมากกว่าเครื่องมือที่ทำจากเหล็กกล้าไฮสปีด (HSS)

2.2.2.6 การหล่อลื่นและการระบายความร้อน (Lubrication and Cooling) ระบบหล่อลื่นช่วยลดแรงเสียดทานและอุณหภูมิบริเวณคมตัด ซึ่งช่วยชะลอการสึกหรอได้อย่างมีประสิทธิภาพ การหล่อลื่นไม่เพียงพอหรือการระบายความร้อนไม่เหมาะสมอาจทำให้เกิดการไหม้ของเครื่องมือและความเสียหายที่ผิวชิ้นงาน

2.2.2.7 การสั่นสะเทือนของสปินเดิล (Spindle Vibration) การสั่นสะเทือนที่เกิดขึ้นระหว่างกระบวนการตัดเฉือนส่งผลโดยตรงต่อความเสถียรของแรงตัดและอัตราการสึกหรอของคมตัด การสั่นสะเทือนที่มากเกินไปจะเร่งให้เกิดการแตกร้าวของคมตัดและทำให้เครื่องมือตัดมีอายุการใช้งานสั้นลง

2.2.3 ผลกระทบของการสึกหรอต่อคุณภาพชิ้นงานและกระบวนการผลิต

การสึกหรอของเครื่องมือตัด (Tool Wear) เป็นปัจจัยสำคัญที่ส่งผลโดยตรงต่อคุณภาพของชิ้นงานและประสิทธิภาพของกระบวนการผลิต โดยเฉพาะในกระบวนการตัดเฉือนด้วยเครื่องจักรควบคุมเชิงตัวเลข (CNC) ซึ่งต้องการความแม่นยำสูงและความสม่ำเสมอในการทำงาน การสึกหรอของคมตัดเพียงเล็กน้อยสามารถทำให้ชิ้นงานมีขนาดคลาดเคลื่อน คุณภาพผิวลดลง และอาจทำให้เกิดการหยุดชะงักของกระบวนการผลิต

ในด้าน คุณภาพของชิ้นงาน (Workpiece Quality) การสึกหรอของเครื่องมือทำให้แรงตัดและอุณหภูมิในบริเวณคมตัดเพิ่มขึ้น ส่งผลให้ผิวชิ้นงานมีความขรุขระมากขึ้น (Surface Roughness) ขนาดชิ้นงานผิดจากค่ากำหนด และอาจเกิดรอยไหม้ (Burn Mark) หรือรอยแตกร้าวบนผิววัสดุได้ (Yang, Pattipati, Awasthi, and Bollas, 2022) นอกจากนี้เมื่อคมตัดสูญเสียความคม ความสามารถในการ

การเหือนวัสดุจะลดลง ทำให้เกิดการเหือนแบบไม่สม่ำเสมอ (Irregular Cutting) และเพิ่มแรงสั่นสะเทือน (Vibration) ซึ่งเป็นสัญญาณเริ่มต้นของความผิดปกติในกระบวนการผลิต

ในด้าน กระบวนการผลิต (Manufacturing Process) การสึกหรอของเครื่องมือตัดทำให้แรงตัด (Cutting Force) เพิ่มขึ้น ส่งผลให้สปินเดิลและระบบขับเคลื่อนรับภาระมากขึ้น อาจเกิดการสั่นสะเทือน (Chatter) หรือความเสียหายต่อส่วนประกอบของเครื่องจักรในระยะยาว หากไม่มีการตรวจสอบ และเปลี่ยนเครื่องมือทันเวลาอาจเกิดการแตกหักของเครื่องมือ (Tool Breakage) ทำให้เครื่องจักรหยุดทำงานโดยไม่คาดคิด (Unplanned Downtime) และเกิดความสูญเสียทางเศรษฐกิจ (Yang et al., 2022) นอกจากนี้ การสึกหรอของเครื่องมือยังมีผลต่อ ต้นทุนและประสิทธิภาพการผลิต การเปลี่ยนเครื่องมือเร็วเกินไปจะเพิ่มต้นทุนการผลิตโดยไม่จำเป็น ขณะที่การเปลี่ยนช้าเกินไปอาจทำให้เกิดของเสีย (Defective Products) หรือความเสียหายต่อเครื่องจักร ดังนั้น การประเมินสภาพเครื่องมือตัดอย่างแม่นยำจึงเป็นสิ่งจำเป็นในการกำหนดช่วงเวลาการเปลี่ยนเครื่องมือที่เหมาะสม เพื่อเพิ่มอายุการใช้งานของเครื่องจักรและลดต้นทุนรวมในการผลิต

จากเหตุผลดังกล่าว การตรวจสอบและติดตามการสึกหรอของเครื่องมือตัดอย่างต่อเนื่องโดยอาศัยเทคนิคการวิเคราะห์ข้อมูลและการเรียนรู้ของเครื่อง (Machine Learning) จึงเป็นแนวทางที่ช่วยเพิ่มความแม่นยำในการทำนายสภาพเครื่องมือ ลดความเสี่ยงของการเสียหาย และยกระดับคุณภาพของกระบวนการผลิตโดยรวม (Huang, Ahearn, Baron, and Parnell, 2023)

2.3 การตรวจจับความผิดปกติ

2.3.1 ความหมายของความผิดปกติในงานอุตสาหกรรมการผลิต

ความผิดปกติ (Anomaly) ในงานอุตสาหกรรมการผลิต หมายถึง สภาวะหรือพฤติกรรมของกระบวนการผลิตที่เบี่ยงเบนไปจากสภาวะปกติ ซึ่งอาจปรากฏในรูปของค่าการวัดจากเซนเซอร์ที่สูงหรือต่ำผิดปกติ การสั่นสะเทือนที่เพิ่มขึ้นอย่างฉับพลัน หรือแรงตัดที่ไม่สัมพันธ์กับเงื่อนไขการทำงานของเครื่องจักร ความผิดปกติเหล่านี้นักเป็นสัญญาณเริ่มต้นของการเสื่อมสภาพของเครื่องจักร เช่น การสึกหรอของเครื่องมือตัด ความไม่สมดุลของสปินเดิล หรือความผิดพลาดของระบบขับเคลื่อนในระบบการผลิตสมัยใหม่ที่ใช้เครื่องจักรควบคุมเชิงตัวเลข (CNC) ความผิดปกติอาจไม่แสดงออกอย่างชัดเจนในระยะเริ่มต้น แต่สามารถสะท้อนผ่านข้อมูลเชิงกายภาพ เช่น แรงตัด (Cutting Force) การสั่นสะเทือน (Vibration) หรือสัญญาณเสียง (Acoustic Emission) ที่เบี่ยงเบนไปจากรูปแบบปกติ การตรวจจับความผิดปกติจึงมีบทบาทสำคัญในการระบุสาเหตุของปัญหา และช่วยป้องกันความเสียหายรุนแรงต่อเครื่องจักรหรือชิ้นงาน

โดยทั่วไป ความผิดปกติในกระบวนการผลิตสามารถปรากฏได้ทั้งในรูปของค่าที่เบี่ยงเบนฉับพลัน (Point Anomaly) หรือแนวโน้มของสัญญาณที่เปลี่ยนแปลงต่อเนื่อง (Collective Anomaly)

ซึ่งโดยมากสัมพันธ์กับพฤติกรรมการเสื่อมสภาพของเครื่องมือตัดหรือความผิดปกติของสปีนเดิล การทำความเข้าใจลักษณะพื้นฐานของความผิดปกติเหล่านี้จึงเป็นปัจจัยสำคัญในการพัฒนาแบบจำลอง การตรวจจับที่มีประสิทธิภาพ โดยเฉพาะในงานวิจัยที่ประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่อง ซึ่งสามารถ วิเคราะห์ข้อมูลจำนวนมากและตรวจจับรูปแบบความเบี่ยงเบนที่อาจมองไม่เห็นด้วยสายตาได้อย่างแม่นยำ

2.3.2 เทคนิคการตรวจจับความผิดปกติแบบดั้งเดิม

การตรวจจับความผิดปกติแบบดั้งเดิม (Traditional Anomaly Detection Techniques) เป็นแนวทางที่ใช้การวิเคราะห์เชิงสถิติและการกำหนดเกณฑ์คงที่เพื่อแยกข้อมูลที่มีลักษณะผิดปกติ ออกจากข้อมูลปกติ วิธีการเหล่านี้ถูกนำมาใช้อย่างแพร่หลายในอุตสาหกรรมการผลิตยุคแรก เนื่องจาก มีความเข้าใจง่ายและสามารถประยุกต์ใช้ได้กับระบบที่มีจำนวนตัวแปรไม่มาก หนึ่งในเทคนิคที่นิยมใช้คือ การกำหนดค่าเกณฑ์ (Threshold-based Method) ซึ่งอาศัยค่าขีดจำกัดบนและล่างของตัวแปร เช่น ค่าแรงสั่นสะเทือนหรือแรงตัด หากค่าที่วัดได้เกินกว่าขีดจำกัดที่กำหนด ระบบจะระบุว่าการเกิดความผิดปกติ วิธีนี้เหมาะสำหรับระบบที่มีพฤติกรรมคงที่และมีการเปลี่ยนแปลงของข้อมูลไม่มาก อย่างไรก็ตามในสภาวะ การผลิตจริง ข้อมูลมักมีความแปรปรวนสูง ทำให้ค่าเกณฑ์คงที่ไม่สามารถใช้ตรวจจับได้อย่างมีประสิทธิภาพ อีกแนวทางหนึ่งคือ การวิเคราะห์เชิงสถิติ (Statistical Process Control: SPC) ซึ่งใช้เครื่องมือทางสถิติ เช่น แผนภูมิควบคุม (Control Chart) หรือค่ามาตรฐานเบี่ยงเบน (Standard Deviation) เพื่อระบุความเบี่ยงเบนของข้อมูลจากค่าเฉลี่ย วิธีนี้สามารถช่วยติดตามแนวโน้มของข้อมูล ในระยะยาวและตรวจจับความผิดปกติที่เกิดขึ้นที่ละน้อยได้ แต่ประสิทธิภาพจะลดลงเมื่อระบบมีความซับซ้อนสูง หรือมีหลายตัวแปรที่ต้องตรวจสอบพร้อมกัน

นอกจากนี้ ยังมีการใช้ การวิเคราะห์สัญญาณ (Signal Analysis) เช่น การวิเคราะห์โดเมนเวลา (Time Domain) และโดเมนความถี่ (Frequency Domain) เพื่อหาความผิดปกติจากรูปแบบสัญญาณ เช่น การเพิ่มขึ้นของความถี่บางช่วง หรือการเปลี่ยนแปลงของพลังงานในสัญญาณ ซึ่งสามารถช่วยระบุ สาเหตุของปัญหาได้ในระดับหนึ่ง แต่ต้องอาศัยผู้เชี่ยวชาญในการตีความผลการวิเคราะห์ อย่างไรก็ตาม เทคนิคแบบดั้งเดิมเหล่านี้มีข้อจำกัดสำคัญคือ ไม่สามารถจัดการกับข้อมูลจำนวนมากหรือข้อมูลที่มีความซับซ้อนแบบไม่เชิงเส้นได้ดี อีกทั้งยังต้องอาศัยการกำหนดเกณฑ์จากประสบการณ์ของผู้ปฏิบัติงาน ซึ่งอาจทำให้ผลการตรวจจับขาดความยืดหยุ่นและไม่แม่นยำในสภาวะการผลิตที่เปลี่ยนแปลงอยู่ตลอดเวลา

ดังนั้น เพื่อให้การตรวจจับความผิดปกติมีความแม่นยำและสามารถปรับตัวต่อข้อมูลจริงได้ดียิ่งขึ้น จึงได้มีการพัฒนาแนวทางใหม่โดยอาศัยเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) เพื่อวิเคราะห์ รูปแบบของข้อมูลและแยกความผิดปกติออกจากสภาวะปกติอย่างอัตโนมัติ

2.3.3 วิธีป่าแยกตัว (Isolation Forest)

วิธีป่าแยกตัว (Isolation Forest) เป็นขั้นตอนวิธีการตรวจจับความผิดปกติ (Anomaly Detection Algorithm) ที่พัฒนาโดย Liu และคณะในปี ค.ศ. 2008 โดยอาศัยหลักการสำคัญคือ “การแยกข้อมูลผิดปกติให้ออกจากข้อมูลปกติได้ง่ายกว่า” (Anomalies are easier to isolate than normal points) แนวคิดนี้แตกต่างจากวิธีการตรวจจับความผิดปกติแบบดั้งเดิมที่เน้นการประมาณความหนาแน่นของข้อมูลหรือการคำนวณระยะทางระหว่างจุดข้อมูล หลักการทำงานของวิธีป่าแยกตัวคือการสร้างกลุ่มของต้นไม้สุ่ม (Random Trees) เพื่อทำการแบ่งข้อมูลซ้ำ ๆ แบบสุ่ม (Random Partitioning) โดยในแต่ละรอบของการแบ่ง จะเลือกคุณลักษณะ (Feature) และค่าขอบเขต (Split Value) แบบสุ่มเพื่อแบ่งข้อมูลออกเป็นสองกลุ่ม กระบวนการนี้จะดำเนินต่อไปจนกว่าจุดข้อมูลแต่ละจุดจะถูกแยกออกจากกลุ่มทั้งหมด

จากหลักการนี้ ข้อมูลที่เป็นความผิดปกติ (Anomaly) จะถูกแยกออกได้ภายในจำนวนรอบการแบ่ง (Path Length) ที่น้อยกว่า เนื่องจากข้อมูลดังกล่าวมักอยู่ห่างจากกลุ่มข้อมูลหลัก ในขณะที่ข้อมูลปกติจะต้องผ่านการแบ่งหลายครั้งกว่าจะถูกแยกออกได้ ค่าคะแนนความผิดปกติ (Anomaly Score) ของแต่ละจุดข้อมูลจะถูกคำนวณจากความยาวเฉลี่ยของเส้นทาง (Average Path Length) ของจุดนั้นในต้นไม้ทั้งหมด ซึ่งคำนวณได้จากสมการ (Liu et al., 2008)

$$S(x, n) = 2 - \frac{E(h(x))}{c(n)} \quad (2.1)$$

โดยที่

$s(x, n)$ คือ ค่าคะแนนความผิดปกติของข้อมูล x

$E(h(x))$ คือ ค่าเฉลี่ยของความยาวเส้นทางที่ใช้ในการแยกข้อมูล x

$c(n)$ คือ ค่ามาตรฐานที่ได้จากขนาดของข้อมูลทั้งหมด n

ค่าคะแนนที่ใกล้เคียง 1 หมายถึง มีแนวโน้มเป็นข้อมูลผิดปกติ ส่วนค่าที่ใกล้ 0 หมายถึง เป็นข้อมูลปกติ

ข้อดีของวิธีป่าแยกตัว คือ ความสามารถในการจัดการข้อมูลขนาดใหญ่ได้อย่างมีประสิทธิภาพ โดยไม่ต้องคำนวณระยะทางระหว่างข้อมูลทุกคู่ อีกทั้งยังไม่ต้องอาศัยข้อมูลที่ผ่านการติดฉลาก (Unlabeled Data) จึงเหมาะสมอย่างยิ่งสำหรับงานที่ต้องตรวจจับความผิดปกติจากข้อมูลจริงในโรงงานอุตสาหกรรม ซึ่งมักไม่มีข้อมูลตัวอย่างของสภาวะผิดปกติให้ฝึกโมเดลล่วงหน้า

ในงานวิจัยนี้ ได้ประยุกต์ใช้วิธีป่าแยกตัว (Isolation Forest) ในการวิเคราะห์ข้อมูลแรงตัด (Cutting Force) และแรงในแกน Z (Fz) ที่ได้จากกระบวนการเจาะโลหะบนเครื่องจักรควบคุมเชิงตัวเลข

(CNC) โดยมีวัตถุประสงค์เพื่อระบุพฤติกรรมของสปินเดิลที่เบี่ยงเบนไปจากสภาวะปกติ ซึ่งอาจสะท้อนถึงการสึกหรอของเครื่องมือตัดหรือความเสียหายที่กำลังก่อตัว แบบจำลองวิธีป่าแยกตัว (Isolation Forest Model) ถูกนำมาประเมินร่วมกับค่าระดับเกณฑ์ (Threshold) เพื่อระบุช่วงเวลาที่เริ่มปรากฏความผิดปกติได้อย่างแม่นยำและเชื่อถือได้ ดังนั้น วิธีป่าแยกตัวจึงเป็นเทคนิคหลักที่ช่วยให้สามารถตรวจจับความผิดปกติของสปินเดิลได้อย่างรวดเร็ว โดยไม่จำเป็นต้องใช้ข้อมูลที่ผ่านมาการกำกับ และเป็นรากฐานสำคัญของระบบบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) สำหรับเครื่องจักรกลสมัยใหม่

2.3.4 เทคนิคการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold)

เทคนิคการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) เป็นวิธีการเชิงสถิติที่ใช้ในการกำหนดขอบเขตหรือค่าระดับเกณฑ์ (Threshold Value) สำหรับจำแนกข้อมูลที่มีพฤติกรรมแตกต่างจากค่าปกติ โดยอาศัยแนวคิดของการกระจายความน่าจะเป็น (Probability Distribution) ของข้อมูล ซึ่งแบ่งออกเป็นช่วงตามลำดับเปอร์เซ็นต์ของค่าข้อมูลที่จัดเรียงจากน้อยไปมากในเชิงคณิตศาสตร์ “ควอนไทล์ (Quantile)” หมายถึงค่าของตัวแปรที่แบ่งการกระจายของข้อมูลออกเป็นสัดส่วนที่เท่ากัน ตัวอย่างเช่น

ควอนไทล์ที่ 1 (Q1) คือ ค่าที่ต่ำกว่า 25% (หรือ quantile ระดับ 0.25) ของข้อมูลทั้งหมด

ค่ามัธยฐาน (Median หรือ Q2) คือ quantile ระดับ 0.50

ควอนไทล์ที่ 3 (Q3) คือค่าที่ต่ำกว่า 75% (หรือ quantile ระดับ 0.75) ของข้อมูลทั้งหมด

สำหรับการตรวจจับความผิดปกติ เทคนิคควอนไทล์จะถูกใช้เพื่อกำหนดขอบเขตบน (Upper Threshold) ของข้อมูลที่มีค่าผิดปกติ โดยทั่วไปจะเลือกค่าที่อยู่ในระดับเปอร์เซ็นต์ไทล์สูง เช่น 98%, 99% หรือ 99.9% ซึ่งเทียบเท่ากับ quantile ระดับ $q = 0.98$, $q = 0.99$ และ $q = 0.999$ ของการกระจายข้อมูลทั้งนี้ขึ้นอยู่กับลักษณะของข้อมูลและระดับความเข้มงวดในการตรวจจับที่ต้องการ ในบริบทของงานวิจัยด้านการตรวจจับความผิดปกติของเครื่องจักร ค่าความผิดปกติที่ได้จากขั้นตอนวิธีป่าแยกตัว (Isolation Forest) จะถูกนำมาวิเคราะห์ด้วยเทคนิคควอนไทล์เพื่อกำหนด “ค่าระดับเกณฑ์” ที่เหมาะสมในการระบุจุดที่ถือว่ามีความผิดปกติ โดยมีหลักการคือ หากค่าคะแนนความผิดปกติ (Anomaly Score) ของข้อมูลใดสูงกว่าระดับควอนไทล์ที่กำหนดไว้ จะถือว่าข้อมูลนั้นอยู่ในสภาวะผิดปกติ

ข้อดีของเทคนิคควอนไทล์คือ ความยืดหยุ่นและความสามารถในการปรับระดับความเข้มงวดของการตรวจจับให้เหมาะสมกับลักษณะข้อมูลจริง เช่น การใช้ค่าเกณฑ์ที่ระดับควอนไทล์สูง (เช่น 0.999) จะช่วยลดการแจ้งเตือนผิดพลาด (False Alarm) ขณะที่ค่าควอนไทล์ที่ต่ำลงจะเพิ่มความไวในการตรวจจับ (Sensitivity) ซึ่งเหมาะกับการเฝ้าระวังสภาวะเริ่มต้นของการสึกหรอ

ในงานวิจัยนี้ เทคนิคการกำหนดค่าเกณฑ์แบบควอนไทล์ถูกนำมาใช้ร่วมกับผลลัพธ์จากตัวแบบจำลองวิธีป่าแยกตัว (Isolation Forest Model) เพื่อระบุช่วงเวลาที่เริ่มเกิดความผิดปกติ

ของสปินเดิล (Spindle) ในกระบวนการตัดเฉือน โดยทำให้สามารถตรวจจับได้เฉพาะจุดที่มีความผิดปกติอย่างมีนัยสำคัญ และลดการแจ้งเตือนซ้ำในช่วงเวลาที่ไม่มีความเปลี่ยนแปลง ซึ่งช่วยเพิ่มความแม่นยำของการวิเคราะห์และความน่าเชื่อถือของระบบตรวจจับโดยรวม

ทั้งนี้ ในทางคณิตศาสตร์ quantile เป็นค่าที่นิยามในช่วง $0 < q < 1$ ขณะที่ percentile เป็นการแสดงค่าเดียวกันในรูปเปอร์เซ็นต์ ซึ่งใช้เพื่อความสะดวกในการตีความ

2.4 เทคนิคการเรียนรู้ของเครื่อง

2.4.1 การเรียนรู้แบบมีผู้สอน

การเรียนรู้แบบมีผู้สอน (Supervised Learning) เป็นเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ประเภทหนึ่งที่อาศัยข้อมูลที่มีการระบุค่าตอบหรือผลลัพธ์ที่ถูกต้องไว้ล่วงหน้า (Labeled Data) เพื่อใช้ในการฝึกแบบจำลองให้สามารถทำนายค่าหรือจำแนกกลุ่มข้อมูลใหม่ได้อย่างแม่นยำ โดยหลักการคือการสร้างความสัมพันธ์ระหว่าง “ตัวแปรอิสระ (Input Features)” และ “ตัวแปรตาม (Output Labels)” ผ่านกระบวนการเรียนรู้เชิงคณิตศาสตร์และสถิติ ในกระบวนการเรียนรู้แบบมีผู้สอน ข้อมูลที่ใช้ในการฝึกจะถูกแบ่งออกเป็นสองส่วน ได้แก่ ชุดข้อมูลฝึก (Training Set) และชุดข้อมูลทดสอบ (Testing Set) แบบจำลองจะเรียนรู้จากข้อมูลฝึกเพื่อลดความคลาดเคลื่อนระหว่างค่าที่ทำนายกับค่าจริง จากนั้นจะถูกทดสอบด้วยข้อมูลใหม่เพื่อประเมินความสามารถในการทำนายที่ไม่เคยเห็นมาก่อน เทคนิคการเรียนรู้แบบมีผู้สอนสามารถแบ่งออกได้เป็นสองลักษณะหลัก ได้แก่

2.4.1.1 การถดถอย (Regression) เป็นเทคนิคทางสถิติและการเรียนรู้ของเครื่องที่ใช้สำหรับการทำนายค่าตัวเลขต่อเนื่อง (Continuous Values) โดยมีวัตถุประสงค์เพื่อสร้างแบบจำลองความสัมพันธ์ระหว่างตัวแปรอิสระ (Independent Variables) และตัวแปรตาม (Dependent Variable) ตัวอย่างการประยุกต์ใช้งานในภาคอุตสาหกรรม ได้แก่ การทำนายอัตราการสึกหรอของเครื่องมือตัดจากข้อมูลแรงตัด (Cutting Force) หรือการสั่นสะเทือนของสปินเดิล (Vibration) เทคนิคการถดถอยที่นิยมใช้ได้แก่ การถดถอยเชิงเส้น (Linear Regression), การถดถอยแบบพหุคูณ (Multiple Linear Regression), การถดถอยแบบกำลังสอง (Polynomial Regression) และการถดถอยด้วยซัพพอร์ตเวกเตอร์ (Support Vector Regression: SVR)

ในกรณีของการถดถอยเชิงเส้น (Linear Regression) แบบจำลองจะสมมติว่าความสัมพันธ์ระหว่างตัวแปรอิสระและตัวแปรตามเป็นความสัมพันธ์เชิงเส้น โดยสามารถแสดงในรูปของสมการทางคณิตศาสตร์ได้ดังนี้ (Montgomey, Peck, and Vining, 2021)

$$y = \beta_0 + \beta_1 x + \varepsilon \quad (2.2)$$

โดยที่ y หมายถึง ตัวแปรตาม, x หมายถึง ตัวแปรอิสระ, β_0 คือ ค่าคงที่หรือจุดตัดแกน (Intercept), β_1 คือ ค่าสัมประสิทธิ์เชิงเส้น (Regression Coefficient) ซึ่งแสดงอัตราการเปลี่ยนแปลงของ y ต่อการเปลี่ยนแปลงของ x และ ε คือ ค่าความคลาดเคลื่อน (Error Term)

จุดประสงค์ของการถดถอยเชิงเส้นคือการหาค่าพารามิเตอร์ β_0 และ β_1 ที่ทำให้ผลรวมของค่าความคลาดเคลื่อนกำลังสอง (Sum of Squared Errors: SSE) ระหว่างค่าจริงและค่าที่ทำนายมีค่าน้อยที่สุด ทั้งนี้ การถดถอยเชิงเส้นสามารถแบ่งออกเป็นสองลักษณะหลัก ได้แก่ การถดถอยเชิงเส้นแบบง่าย (Simple Linear Regression) ซึ่งใช้ตัวแปรอิสระเพียงหนึ่งตัวในการทำนาย และการถดถอยเชิงเส้นพหุ (Multiple Linear Regression) ซึ่งใช้ตัวแปรอิสระหลายตัว เช่น ความเร็วตัด แรงตัด และการสั่นสะเทือน เพื่อคาดการณ์ระดับการสึกหรอของเครื่องมือตัด ในงานวิจัยด้านกระบวนการผลิต เทคนิคการถดถอยเชิงเส้นถูกนำมาใช้เพื่อศึกษาความสัมพันธ์ระหว่างแรงตัดกับการสึกหรอของเครื่องมือ และสามารถใช้เป็นตัวชี้วัดเชิงปริมาณเพื่อประเมินแนวโน้มการเสื่อมสภาพของเครื่องมือ (Tool Degradation Trend) ได้ เนื่องจากแบบจำลองมีความเรียบง่าย ตีความผลลัพธ์ได้ชัดเจน และใช้ทรัพยากรในการประมวลผลต่ำ อย่างไรก็ตาม การถดถอยเชิงเส้นมีข้อจำกัดเมื่อข้อมูลมีลักษณะซับซ้อนหรือมีความสัมพันธ์แบบไม่เชิงเส้น ซึ่งในกรณีดังกล่าวอาจต้องใช้เทคนิคขั้นสูง เช่น การถดถอยแบบโพลีโนเมียล หรือเทคนิคการเรียนรู้ของเครื่องที่ไม่เชิงเส้น

สำหรับงานวิจัยนี้ เทคนิคการถดถอยเชิงเส้นถูกนำมาใช้เพื่อสร้างแบบจำลองทำนายการสึกหรอของเครื่องมือตัดจากข้อมูลแรงตัดในกระบวนการเจาะโลหะ โดยผลลัพธ์ที่ได้จะถูกใช้เป็นข้อมูลพื้นฐานสำหรับการวิเคราะห์แนวโน้มความผิดปกติและการตรวจจับสถานะเบี่ยงเบนจากปกติด้วยเทคนิคการเรียนรู้ของเครื่องในขั้นตอนถัดไป

2.4.1.2 การจำแนกประเภท (Classification) ใช้สำหรับการจำแนกข้อมูลให้อยู่ในกลุ่มที่กำหนด เช่น การจำแนกสถานะเครื่องมือว่า “ปกติ” หรือ “ผิดปกติ” วิธีที่นิยมใช้ เช่น K-Nearest Neighbors (KNN), Decision Tree, Random Forest และ Support Vector Machine (SVM)

ในงานวิจัยด้านการตัดเฉือนโลหะ การเรียนรู้แบบมีผู้สอนถูกนำมาใช้อย่างแพร่หลายในการทำนายการสึกหรอของเครื่องมือตัด โดยใช้ข้อมูลจากเซนเซอร์ต่าง ๆ เช่น แรงตัด เสียง หรือการสั่นสะเทือน เพื่อสร้างแบบจำลองเชิงพยากรณ์ที่สามารถคาดการณ์สภาพของเครื่องมือได้ล่วงหน้า ซึ่งช่วยให้สามารถวางแผนการเปลี่ยนเครื่องมือได้อย่างเหมาะสม ลดการหยุดชะงักของกระบวนการผลิต และเพิ่มประสิทธิภาพของการบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) อย่างไรก็ตาม การเรียนรู้แบบมีผู้สอนจำเป็นต้องอาศัยข้อมูลที่มีการระบุผลลัพธ์อย่างถูกต้องและมีปริมาณมาก ซึ่งในบางกรณีการจัดเก็บข้อมูลจริงในโรงงานอุตสาหกรรมอาจทำได้ยากหรือมีต้นทุนสูง ทำให้ต้องมีการพัฒนาเทคนิคอื่นเพิ่มเติม เช่น การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เพื่อช่วยวิเคราะห์ข้อมูลที่ไม่มีฉลากกำกับ

2.4.2 การเรียนรู้แบบไม่มีผู้สอน

การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) เป็นเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้ข้อมูลที่ไม่มีการระบุผลลัพธ์หรือฉลากกำกับ (Unlabeled Data) โดยแบบจำลองจะพยายามค้นหารูปแบบ ความสัมพันธ์ หรือโครงสร้างภายในข้อมูลด้วยตนเอง โดยไม่ต้องอาศัยการป้อนคำตอบที่ถูกต้องล่วงหน้า วิธีนี้จึงเหมาะกับกรณีที่ข้อมูลมีจำนวนมากแต่ไม่สามารถจัดประเภทได้ชัดเจน หรือในสถานะที่ข้อมูลจริงมีความไม่แน่นอน เช่น ในกระบวนการผลิตที่ซับซ้อนของอุตสาหกรรม โดยเทคนิคการเรียนรู้แบบไม่มีผู้สอนแบ่งได้เป็น 2 กลุ่มหลัก ได้แก่

2.4.2.1 การจัดกลุ่มข้อมูล (Clustering) เป็นการจัดข้อมูลที่มีลักษณะคล้ายกันให้อยู่ในกลุ่มเดียวกัน เช่น วิธี K-Means, DBSCAN และ Hierarchical Clustering วิธีเหล่านี้มักใช้เพื่อจำแนกสถานะการทำงานของเครื่องจักร หรือแยกกลุ่มพฤติกรรมของสัญญาณแรงตึงและการสั่นสะเทือนที่มีลักษณะใกล้เคียงกัน


2.4.2.2 การตรวจจับความผิดปกติ (Anomaly Detection) เป็นการระบุข้อมูลที่แตกต่างจากรูปแบบปกติ เช่น Isolation Forest, One-Class SVM และ Autoencoder โดยเฉพาะอย่างยิ่งวิธี Isolation Forest ซึ่งใช้หลักการสุ่มเลือกคุณลักษณะและแบ่งข้อมูลออกซ้ำ ๆ เพื่อแยกจุดข้อมูลที่มีลักษณะผิดปกติให้ออกจากกลุ่มข้อมูลหลักได้อย่างมีประสิทธิภาพ ในบริบทของงานอุตสาหกรรมการผลิต เทคนิคการเรียนรู้แบบไม่มีผู้สอนมีความสำคัญอย่างยิ่ง เนื่องจากข้อมูลที่ได้จากกระบวนการผลิตจริงมักไม่มีการระบุสถานะความผิดปกติไว้อย่างชัดเจน การใช้เทคนิคนี้จึงช่วยให้สามารถตรวจจับพฤติกรรมที่เบี่ยงเบนจากสถานะปกติได้โดยไม่ต้องใช้ข้อมูลผ่านการติดฉลาก เช่น การเปลี่ยนแปลงของแรงตึง (Cutting Force) หรือการสั่นสะเทือน (Vibration) ที่เกิดจากการสึกหรอของเครื่องมือตัดหรือความผิดปกติของสปินเดิล

ในงานวิจัยนี้ ได้ประยุกต์การเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ผ่านอัลกอริทึม Isolation Forest ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) เพื่อเพิ่มความแม่นยำในการตรวจจับความผิดปกติของสปินเดิล และลดอัตราการแจ้งเตือนผิดพลาด (False Alarm) แนวทางดังกล่าวช่วยให้การประเมินสถานะการทำงานของเครื่องจักรมีประสิทธิภาพและสอดคล้องกับข้อมูลจริงที่ไม่มีการกำกับได้ดียิ่งขึ้น

2.4.3 การเรียนรู้เชิงลึกที่เกี่ยวข้องกับงานอุตสาหกรรม

การเรียนรู้เชิงลึก (Deep Learning) เป็นสาขาหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้โครงสร้างแบบโครงข่ายประสาทเทียมหลายชั้น (Artificial Neural Network: ANN) เพื่อประมวลผลและดึงลักษณะสำคัญของข้อมูล (Feature Extraction) ออกมาโดยอัตโนมัติ เทคนิคนี้สามารถจัดการกับข้อมูลที่ซับซ้อน มีหลายมิติ และไม่เป็นเชิงเส้นได้ดี จึงได้รับความนิยมอย่างกว้างขวางในงานอุตสาหกรรมยุคปัจจุบัน หนึ่งในสถาปัตยกรรมที่สำคัญของการเรียนรู้เชิงลึกคือ โครงข่าย

ประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN) ซึ่งถูกพัฒนาขึ้นเพื่อการประมวลผลข้อมูลเชิงพื้นที่ (Spatial Data) โดยเฉพาะข้อมูลภาพและสัญญาณ โดย CNN สามารถเรียนรู้คุณลักษณะเชิงลำดับชั้น (Hierarchical Feature Learning) จากข้อมูลดิบได้โดยอัตโนมัติ เช่น ขอบ รูปร่าง และรูปแบบเชิงโครงสร้าง ส่งผลให้มีประสิทธิภาพสูงในการวิเคราะห์ข้อมูลอุตสาหกรรม อาทิ ภาพถ่ายจากกล้องจุลทรรศน์และสัญญาณการสั่นสะเทือน (Lecun, Bengio, and Hinton, 2015) โครงสร้างพื้นฐานของโครงข่ายประสาทเทียมแบบคอนโวลูชันประกอบด้วยขั้นตอนหลัก ได้แก่ ชั้นคอนโวลูชัน (Convolution Layer) สำหรับการสกัดคุณลักษณะ ชั้นรวมกลุ่ม (Pooling Layer) สำหรับการลดมิติของข้อมูล และชั้นเชื่อมต่อเต็มรูปแบบ (Fully Connected Layer) สำหรับการจำแนกผลลัพธ์ ซึ่งแสดงตัวอย่างโครงสร้างดังกล่าวไว้ใน รูปที่ 2.2



รูปที่ 2.2 โครงสร้างพื้นฐานของโครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural Network: CNN)

หมายเหตุ จาก “A Deep Transfer Learning Approach to Identifying Glitch Wave-form in Gravitational Wave Data,” โดย Mesuga, R., & Bayanay, B. J., 2023, *arXiv:2107.01863*, p. 3, Retrieved from <https://arxiv.org/abs/2107.01863>

ในบริบทของอุตสาหกรรมการผลิต การเรียนรู้เชิงลึกถูกนำมาใช้ในหลายด้าน เช่น

2.4.3.1 การตรวจจับความผิดปกติของเครื่องจักร (Machine Fault Detection)

โดยใช้แบบจำลองเช่น Convolutional Neural Network (CNN) หรือ Long Short-Term Memory (LSTM) ในการวิเคราะห์สัญญาณการสั่นสะเทือน แรงตึง หรือสัญญาณเสียง เพื่อแยกแยะพฤติกรรมที่ผิดปกติของสปีนดิลและส่วนประกอบเครื่องจักรอื่น ๆ ได้อย่างแม่นยำ

2.4.3.2 การทำนายการสึกหรอของเครื่องมือตัด (Tool Wear Prediction) ซึ่งเป็นการใช้

ข้อมูลแรงตึงและภาพถ่ายของคมตัดจากกล้องจุลทรรศน์ร่วมกัน เพื่อให้โมเดลเรียนรู้ความสัมพันธ์ระหว่าง

รูปแบบสัญญาณและสภาพผิวของเครื่องมือ โดยมักใช้สถาปัตยกรรม CNN หรือ CNN-LSTM Hybrid Model เพื่อเชื่อมโยงข้อมูลเชิงเวลา (Time-Series) เข้ากับข้อมูลเชิงภาพ (Image Feature)

2.4.3.3 การควบคุมกระบวนการผลิตอัจฉริยะ (Smart Process Control) โดยใช้โครงข่ายประสาทเทียมเพื่อปรับพารามิเตอร์ของเครื่องจักรแบบเรียลไทม์ (Real-time Optimization) เช่น ความเร็วรอบของสปินเดิล อัตราป้อน และอุณหภูมิการตัด เพื่อให้ได้ชิ้นงานที่มีคุณภาพคงที่และลดการสึกหรอของเครื่องมือ

ข้อดีของการเรียนรู้เชิงลึกคือ ความสามารถในการประมวลผลข้อมูลจำนวนมากและเรียนรู้คุณลักษณะที่ซ่อนอยู่ในข้อมูลโดยไม่ต้องพึ่งการเลือกคุณลักษณะ (Feature Selection) แบบเดิม ทำให้ได้ผลลัพธ์ที่มีความแม่นยำสูง อย่างไรก็ตาม ข้อจำกัดคือ การต้องใช้ข้อมูลปริมาณมากเพื่อการฝึกโมเดล (Training Data) และต้องใช้ทรัพยากรคอมพิวเตอร์สูง เช่น หน่วยประมวลผลกราฟิก (GPU)

ในงานวิจัยที่เกี่ยวข้องกับการตรวจจับความผิดปกติของสปินเดิลและการทำนายการสึกหรอของเครื่องมือตัด การเรียนรู้เชิงลึกจึงถูกมองว่าเป็นเทคโนโลยีสำคัญที่สามารถต่อยอดจากเทคนิคการเรียนรู้ของเครื่องแบบดั้งเดิม เพื่อพัฒนาแบบจำลองที่มีความสามารถในการเรียนรู้เชิงลึกจากข้อมูลจริงของกระบวนการผลิต และนำไปสู่การพัฒนาาระบบบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) ที่แม่นยำและเชื่อถือได้มากยิ่งขึ้น

2.5 งานวิจัยที่เกี่ยวข้อง

Li, Fu, Chen, Shi, and Zhou (2020) ได้มีการศึกษาเพื่อพัฒนาวิธีตรวจจับความผิดปกติของเครื่องมือตัดในกระบวนการกลึงด้วยเครื่องจักรควบคุมเชิงตัวเลข (CNC) โดยใช้ข้อมูลกระแสของสปินเดิลที่ได้จากเซนเซอร์ฮอลล์ (Hall Sensor) เป็นสัญญาณอินพุตในการวิเคราะห์สภาพเครื่องมือ งานวิจัยดังกล่าวนำเสนอวิธีตรวจจับความผิดปกติด้วยโครงข่ายประสาทเทียมแบบคอนโวลูชันร่วมกับการวิเคราะห์ความผิดปกติ (Convolutional Neural Network–Anomaly Detection: CNN-AD) ซึ่งเป็นเทคนิคการเรียนรู้เชิงลึกที่ออกแบบมาเพื่อจัดการกับปัญหาความไม่สมดุลของข้อมูลระหว่างสภาวะปกติและกรณีที่เครื่องมือเกิดการหัก โดยแบบจำลองจะถูกฝึกด้วยข้อมูลจากสภาวะการตัดปกติเท่านั้น และใช้ค่าการสูญเสีย (Loss) เป็นเกณฑ์ในการระบุสัญญาณผิดปกติ ผลการทดลองเปรียบเทียบกับแบบจำลองอื่น ได้แก่ โครงข่ายประสาทเทียมแบบคอนโวลูชันทั่วไป (Convolutional Neural Network: CNN), อัลกอริทึมซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM), โครงข่ายประสาทเทียมแบบแพร่กลับ (Backpropagation Neural Network: BPNN) และแบบจำลองวันคลาสซัพพอร์ตเวกเตอร์แมชชีน (One-Class Support Vector Machine: OCSVM) พบว่า CNN-AD ให้ความแม่นยำสูงสุดถึง 99.12% และสามารถตรวจจับเหตุการณ์เครื่องมือหักได้ทั้งรวดเร็วและมีเสถียรภาพกว่าวิธีอื่น จึงสรุปได้ว่าวิธี CNN-AD มีความเหมาะสมสำหรับกรณีที่ข้อมูลสภาวะผิดปกติสามารถเก็บได้จำกัด

และมีศักยภาพสูงในการนำไปประยุกต์ใช้กับระบบตรวจสอบสภาพเครื่องมือตัดแบบเรียลไทม์ในสภาพการผลิตจริง

Orabi, Tran, Egger and Thomassey (2024) มีงานวิจัยที่นำเสนอเทคนิคเชิงลึกสำหรับการตรวจจับความผิดปกติในระบบการผลิตอัจฉริยะ โดยพัฒนาแบบจำลองชื่อ Adaptive Adversarial Transformer (AAT) ซึ่งออกแบบมาเพื่อรองรับข้อมูลอนุกรมเวลาแบบหลายตัวแปร (Multivariate Time Series: MVTs) ที่มีความแปรผันสูงและมีลักษณะไม่หยุดนิ่ง (Non-stationary) สถาปัตยกรรมของ AAT ผสานความสามารถของโครงสร้าง Transformer เข้ากับกลไกความสนใจแบบคู่ (Dual Attention Mechanism) และการเรียนรู้เชิงปฏิปักษ์ (Adversarial Learning) เพื่อเพิ่มประสิทธิภาพในการจำแนกสถานะปกติและสถานะผิดปกติของกระบวนการผลิตได้อย่างแม่นยำยิ่งขึ้น แบบจำลองประกอบด้วยสององค์ประกอบหลัก ได้แก่ (1) โมดูล Adversarial Transformer ซึ่งมีหนึ่ง Encoder และสอง Decoder ที่ทำงานแบบแข่งขันกันเพื่อสร้างความแตกต่างระหว่างพฤติกรรมปกติและพฤติกรรมผิดปกติ และ (2) โมดูล Adaptive Support Vector Data Description (SVDD) ซึ่งทำหน้าที่เป็นตัวจำแนกความผิดปกติ พร้อมกลไกการปรับค่าเกณฑ์ (Threshold) แบบอัตโนมัติ โดยใช้ Kernel แบบ RBF เพื่อกำหนดขอบเขตของข้อมูลปกติในเชิงนอนเชิงเส้น งานวิจัยได้ทดสอบแบบจำลองดังกล่าวกับข้อมูลจริงจากสายการผลิตของบริษัท Rosenberger รวมถึงชุดข้อมูลมาตรฐานอื่น ๆ อีกสี่ชุด ผลการทดลองพบว่าแบบจำลอง AAT สามารถให้ค่า F1-score สูงกว่าวิธีมาตรฐานเฉลี่ยประมาณ 10% และยังสามารถปรับระดับความไวของการตรวจจับตามการเปลี่ยนแปลงของข้อมูลได้แบบเรียลไทม์ แสดงให้เห็นถึงศักยภาพในการนำไปใช้ในระบบตรวจสอบความผิดปกติของการผลิตอัจฉริยะที่ต้องรองรับข้อมูลซับซ้อนและมีการเปลี่ยนแปลงตลอดเวลา

Wu et al. (2017) ได้มีการศึกษาเชิงเปรียบเทียบประสิทธิภาพของอัลกอริทึมการเรียนรู้ของเครื่องสำหรับการทำนายการสึกหรอของเครื่องมือตัดในระบบการผลิตอัจฉริยะ โดยมุ่งเน้นการประยุกต์ใช้ อัลกอริทึมเรนดอมฟอเรสต์ (Random Forests: RFs) เพื่อประเมินค่าการสึกหรอของเครื่องมือและอายุการใช้งานที่เหลืออยู่ (Remaining Useful Life: RUL) ของเครื่องจักร งานวิจัยดังกล่าวได้เปรียบเทียบประสิทธิภาพของ RFs กับโครงข่ายประสาทเทียม (Artificial Neural Networks: ANNs) และ รีเกรสชันแบบซัพพอร์ตเวกเตอร์ (Support Vector Regression: SVR) โดยใช้ข้อมูลจากการทดสอบการกัดโลหะจำนวน 315 ครั้ง ซึ่งประกอบด้วยข้อมูลแรงตัด การสั่นสะเทือน และสัญญาณเสียงอะคูสติก (Acoustic Emission) ผลการทดลองพบว่า แบบจำลองที่พัฒนาด้วย RFs ให้ค่าความแม่นยำสูงที่สุด โดยมีค่าสัมประสิทธิ์การกำหนด (R^2) สูงถึง 0.992 และมีค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (Mean Squared Error: MSE) ต่ำที่สุดอยู่ที่ 7.67 เมื่อเปรียบเทียบกับ ANNs และ SVR แม้ระยะเวลาในการฝึกโมเดลของ RFs จะยาวนานกว่าเล็กน้อย แต่ผลลัพธ์ที่ได้มีทั้งความถูกต้องและ

ความเสถียรที่เหนือกว่าอย่างชัดเจน อีกทั้งยังแสดงให้เห็นว่า RFs สามารถจัดการข้อมูลขนาดใหญ่และลดปัญหาการเรียนรู้เกินจริง (Overfitting) ได้อย่างมีประสิทธิภาพ

Çekik and Turan (2025) มีการนำเสนอแบบจำลองเชิงลึกใหม่ชื่อ RoughLSTM สำหรับการตรวจจับความผิดปกติของเครื่องจักรควบคุมเชิงตัวเลข (CNC) โดยเฉพาะข้อมูลการสั่นสะเทือนของสปินเดิลที่เกิดขึ้นในกระบวนการกัดโลหะ แบบจำลองดังกล่าวผสมผสานความสามารถของโครงข่ายหน่วยความจำระยะยาวแบบลำดับ (Long Short-Term Memory: LSTM) เข้ากับ ทฤษฎีเซตหยาบ (Rough Set Theory: RST) เพื่อรองรับลักษณะความไม่แน่นอนและความผันผวนของข้อมูลการสั่นสะเทือนที่เกิดขึ้นจริงในสภาวะอุตสาหกรรม โดยแบบจำลองจะแบ่งพื้นที่ของข้อมูลออกเป็นสามบริเวณ ได้แก่ ขอบเขตล่าง (Lower Region), ขอบเขตบน (Upper Region) และ เขตไม่แน่นอน (Boundary Region) พร้อมกลไกการกำหนดค่าเกณฑ์ปรับตัว (Adaptive Threshold: ϵ) เพื่อช่วยจำแนกข้อมูลที่มีความคลุมเครือได้อย่างมีประสิทธิภาพ ชุดข้อมูลที่ใช้ในการประเมินประกอบด้วยข้อมูลการสั่นสะเทือนจริงจากเครื่อง CNC Milling จำนวน 3 เครื่อง (M01–M03) ที่เก็บต่อเนื่องเป็นระยะเวลา 2 ปี ครอบคลุมทั้งสภาวะการทำงานปกติและสภาวะผิดปกติ เช่น ดอกกัดหัก การยึดจับเครื่องมือไม่แน่น และการอุดตันของเศษชิ้นงาน ผลการทดลองเปรียบเทียบกับ LSTM มาตรฐานพบว่า RoughLSTM ให้ความแม่นยำสูงถึง 94.3% มีอัตราความผิดพลาดเชิงบวกเท็จเพียง 3.7% ความผิดพลาดเชิงลบเท็จ 2.0% และมีค่าพื้นที่ใต้กราฟ ROC (AUC) สูงสุดที่ 0.979 สะท้อนถึงความสามารถในการจำแนกสภาวะผิดปกติได้อย่างมีประสิทธิภาพและมีความน่าเชื่อถือสูง

Yang et al. (2022) ได้นำเสนอกรอบแนวทางสำหรับการตรวจจับการสั่นไหวของเครื่องมือตัดแบบออนไลน์ในกระบวนการกัดโลหะ โดยใช้แนวคิดของแบบจำลองผสม (Hybrid Model) ซึ่งผสมข้อดีของแบบจำลองเชิงข้อมูล (Data-driven Model) เข้ากับแบบจำลองเชิงฟิสิกส์ (Physics-based Model) เพื่อเพิ่มความแม่นยำและลดการแจ้งเตือนผิดพลาดในการตรวจจับสภาวะผิดปกติของเครื่องมือ แบบจำลองดังกล่าวอาศัยตัวแปรจากกระบวนการจริง ได้แก่ ความเร็วรอบของสปินเดิล ความลึกและความกว้างของการตัด รวมถึงแรงตัด เพื่อสร้างแบบจำลองพฤติกรรมการใช้พลังงานและแรงในสภาวะปกติ จากนั้นใช้สถิติ Page's Cumulative Sum (CUSUM) Test ในการตรวจจับการเปลี่ยนแปลงของค่าคงเหลือ (Residuals) ที่เกิดขึ้นเมื่อเริ่มมีการสั่นไหวของเครื่องมือตัดแบบเรียลไทม์ นอกจากนี้ งานวิจัยยังได้ใช้วิธีต้นไม้ตัดสินใจ (Decision Tree: DT) และโครงข่ายประสาทเทียม (Neural Network: NN) เพื่อปรับปรุงแบบจำลองเชิงข้อมูลในลักษณะการเรียนรู้แบบเพิ่มพูน (Incremental Learning) เพื่อชดเชยความคลาดเคลื่อนของแบบจำลองเชิงฟิสิกส์ การประเมินประสิทธิภาพทำโดยใช้ข้อมูลจากการทดลองจริงบนเครื่อง Mazak แบบ 5 แกน จำนวน 20 ชุดข้อมูล และใช้การจำลองแบบมอนติคาร์โล (Monte Carlo Simulation) เพื่อสร้างข้อมูลเพิ่มเติมกว่า 550,000 ตัวอย่าง ผลการทดลองพบว่า แบบจำลองผสมสามารถลดค่าความคลาดเคลื่อนกำลังสองเฉลี่ยลงเหลือเพียง 0.024 ซึ่งให้ประสิทธิภาพดีกว่าแบบจำลอง

เชิงฟิสิกส์หรือเชิงข้อมูลแบบเดียวกันกว่า 40% อีกทั้งยังสามารถตรวจจับการสึกหรอของเครื่องมือตัดได้อย่างแม่นยำกว่า 92% แม้ในกรณีที่มีสัญญาณรบกวนเพียงร้อยละ 1

Kounta, Arnaud, Kamsu-Foguem, and Tangara (2023) นำเสนอวิธีการตรวจจับการสั่นสะเทือนแบบ Chatter ในกระบวนการกัดโลหะของอุตสาหกรรมจริง โดยใช้ข้อมูลการสั่นสะเทือนที่ได้จากกระบวนการผลิตตู้รถไฟของบริษัท Alstom ซึ่งมีทั้งสัญญาณรบกวน ตำแหน่งเซนเซอร์ที่ไม่เหมาะสม และความไม่แน่นอนของความเร็วสปินเดิล สัญญาณการสั่นสะเทือนถูกแปลงเป็นภาพด้วย Fast Fourier Transform (FFT) พร้อมขั้นตอนการปรับสเกล (Renormalization) เพื่อกำจัดอคติของความแรงสัญญาณ จากนั้นนำเข้าสู่แบบจำลองเชิงลึกผ่านวิธีการถ่ายทอดการเรียนรู้ (Transfer Learning) ด้วยสถาปัตยกรรม VGG16 และ ResNet50 เพื่อจำแนกสภาวะการตัดเฉือน 3 รูปแบบ ได้แก่ การหมุนโดยไม่มีการตัด การตัดปกติ และการตัดที่เกิด Chatter ผลการทดลองพบว่าโมเดลที่ใช้ VGG16 สามารถจำแนกสภาวะ Chatter ได้อย่างมีประสิทธิภาพ โดยให้ความแม่นยำสูงถึง 99% สำหรับชุดข้อมูลที่ไม่คลุมเครือ และ 98.82% สำหรับข้อมูลที่มีความกำกวม ซึ่งผู้เชี่ยวชาญเองแยกแยะได้ยาก นอกจากนี้ ผลการประเมินด้วย ROC และ Confusion Matrix ยังยืนยันว่าแบบจำลองสามารถทำงานได้อย่างเสถียรภายใต้ข้อมูลอุตสาหกรรมจริงที่มีความผันผวนสูง แสดงให้เห็นถึงศักยภาพของแนวทาง FFT-based Image Classification ในการนำไปประยุกต์ใช้กับระบบบำรุงรักษาเชิงคาดการณ์ในงานตัดเฉือนสมัยใหม่ได้อย่างมีประสิทธิภาพ

Truchan and Ahmadi (2025) ได้มีการเผยแพร่ชุดข้อมูล Nonastreda Multimodal Dataset ซึ่งเป็นฐานข้อมูลแบบมัลติโมดัลที่รวบรวมข้อมูลการสึกหรอของเครื่องมือตัดในกระบวนการกัดโลหะภายใต้สภาวะอุตสาหกรรมจริง โดยประกอบด้วยข้อมูลทั้งหมด 9 โมดาลิตี้ รวม 512 ตัวอย่าง ได้แก่ ภาพ RGB ของเครื่องมือตัด เศษวัสดุ และผิวชิ้นงาน รวมถึงสเกลโลแกรมและสเปกโตรแกรมที่คำนวณจากสัญญาณแรงตัดทั้งสามแกน (F_x , F_y , F_z) ตลอดจนสัญญาณแรงดัดที่วัดด้วยไดนาโมมิเตอร์ Kistler 9257B ชุดข้อมูลรองรับทั้งงานจำแนกประเภท (sharp, used, dulled) และงานถดถอยสำหรับทำนายค่าการสึกหรอของคมตัด เช่น flank wear, gaps และ overhang โดยข้อมูลถูกจัดเก็บจากเครื่องกัด CNC Milling จริงจำนวน 10 ชุดเครื่องมือ (T1-T10) พร้อมคำแนะนำให้ประเมินผลด้วยวิธี 10-fold cross-validation เพื่อสะท้อนประสิทธิภาพของโมเดลต่อข้อมูลจากเครื่องมือที่ไม่เคยเห็นมาก่อน งานวิจัยได้ระบุว่า Nonastreda เป็นชุดข้อมูลมัลติโมดัลครบวงจรที่สามารถใช้ได้ทั้งงานวิเคราะห์การสึกหรอ การตรวจจับความผิดปกติ และการประเมินอายุการใช้งานที่เหลือ (Remaining Useful Life: RUL) อีกทั้งยังมีสคริปต์ประมวลผลและเอกสารประกอบอย่างครบถ้วน ช่วยสนับสนุนการพัฒนาโมเดล Machine Learning สำหรับงานบำรุงรักษาเชิงคาดการณ์ในสภาพการผลิตจริงได้อย่างมีประสิทธิภาพ

Wan, Yar, Du, and Low (2023) ได้มีการศึกษาการตรวจจับสภาพความผิดปกติของเครื่องมือตัดในกระบวนการกลึงด้วยเครื่องจักรควบคุมเชิงตัวเลข (CNC) โดยอาศัยข้อมูลจากหลายเซนเซอร์ (Multisensor Signals) เพื่อเพิ่มความแม่นยำของการจำแนกสภาวะปกติและสภาวะสึกหรอของเครื่องมือ โดยข้อมูลถูกรวบรวมจากเซนเซอร์ 4 ประเภท ได้แก่ การสั่นสะเทือนของสปินเดิล การสั่นสะเทือนของเครื่องมือ แรงตัด และสัญญาณเสียงอะคูสติก ภายใต้พารามิเตอร์การตัด 8 ชุด และทำซ้ำรวม 32 การทดลอง พร้อมการวัดค่าการสึกหรอด้วยกล้องจุลทรรศน์แบบดิจิทัลที่กำหนดเกณฑ์สึกหรอที่ 0.1 มิลลิเมตร ข้อมูลสัญญาณถูกแปลงเข้าสู่โดเมนความถี่ด้วยวิธีประมาณความหนาแน่นของกำลัง (Welch's Power Spectral Density: PSD) และสรุปพลังงานในช่วงความถี่ต่าง ๆ ก่อนคัดเลือกคุณลักษณะด้วยวิธี Recursive Feature Elimination (RFE) ร่วมกับ Random Forest Classifier จากนั้นจึงนำเข้าสู่แบบจำลองการเรียนรู้ของเครื่อง ได้แก่ SVM, KNN, Multilayer Perceptron (MLP), Naïve Bayes และ Decision Tree ผลการทดลองพบว่าแบบจำลอง MLP ให้ประสิทธิภาพสูงที่สุด โดยมีค่า Accuracy 0.85, Precision สูงสุด 0.98 และค่า F1-score สูงสุด 0.87 แสดงให้เห็นว่าแนวทางการใช้ข้อมูลจากหลายเซนเซอร์ร่วมกับเทคนิคการเรียนรู้ของเครื่องสามารถตรวจจับสภาวะสึกหรอของเครื่องมือตัดได้อย่างมีประสิทธิภาพ และมีศักยภาพสำหรับการนำไปใช้ในระบบบำรุงรักษาเชิงคาดการณ์ของอุตสาหกรรมการผลิต

Falah and Andó (2024) จากงานวิจัยดังกล่าว ได้มีการนำเสนอแนวทางใหม่สำหรับการตรวจสอบสภาพเครื่องมือตัด (Tool Condition Monitoring: TCM) ในเครื่องจักร CNC โดยใช้เทคนิคประมวลผลภาพร่วมกับอุปกรณ์บันทึกวิดีโอราคาประหยัด เช่น กล้องสมาร์ทโฟนที่สามารถบันทึกภาพได้ที่ 60 เฟรมต่อวินาที เพื่อใช้ตรวจจับการหักของดอกกัดและการแตกร้าวของคมตัดแบบไม่สัมผัสและแบบใกล้เคียงเรียลไทม์ วิธีการประกอบด้วยการสกัดเฟรมจากวิดีโอ การลบพื้นหลัง การแปลงภาพเป็นระดับสีเทา การทำ thresholding และการประมวลผลเชิงสัญญาณวิทยา (Morphological Operations) เพื่อแยกรูปทรงของเครื่องมือออกจากฉากหลังอย่างชัดเจน ก่อนทำการวิเคราะห์ความสูงและพื้นที่ของคมตัดเพื่อระบุความผิดปกติ ผลการทดลองแสดงให้เห็นว่าวิธีดังกล่าวสามารถตรวจจับการหักของเครื่องมือได้อย่างแม่นยำ และสามารถระบุการแตกร้าวของคมตัดได้ในระดับที่ละเอียดกว่าวิธีการแบบดั้งเดิม โดยไม่ต้องหยุดเครื่องหรือใช้อุปกรณ์ราคาแพง งานวิจัยนี้จึงชี้ว่าการประยุกต์ใช้เทคนิคการมองเห็นเชิงกล (Machine Vision) และการประมวลผลภาพด้วยอุปกรณ์ที่หาได้ทั่วไปสามารถสนับสนุนการบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) และตอบโจทย์ระบบผลิตสมัยใหม่ภายใต้แนวคิด Industry 4.0 ได้อย่างมีประสิทธิภาพ

Huang et al. (2023) มีการประเมินประสิทธิภาพของวิธีการตรวจจับความผิดปกติแบบเรียลไทม์สำหรับงานติดตามสภาพการสึกหรอของเครื่องมือตัดในกระบวนการกลึง โดยใช้ข้อมูลแรงตัดสามแกนที่บันทึกจากการทดลองกลึงทั้งหมด 21 รอบ ซึ่งเครื่องมือถูกใช้งานจนถึงจุดสิ้นสุดอายุการใช้งาน

งานวิจัยนี้เปรียบเทียบความสามารถของสามวิธี ได้แก่ Statistical Process Control (SPC), Chi-squared Test และ Generalized Extreme Studentized Deviate (GESD) เพื่อระบุจุดที่เกิดความผิดปกติของแรงตัด โดยข้อมูลถูกประมวลผลด้วยเทคนิค First-Order Difference (FOD) และ Minimum Successive Difference (MSD) ก่อนนำไปใช้ในอัลกอริทึมแบบเรียลไทม์ ผลการทดลองพบว่าในกรณีวิเคราะห์แบบหลายตัวแปร (Multivariate Analysis) วิธี SPC และ Chi-squared Test ให้ผลลัพธ์ที่มีความเสถียรและแม่นยำสูง โดยสามารถทำนายเวลาที่เครื่องมือเข้าใกล้เกณฑ์การสึกหรอได้อย่างน่าเชื่อถือ ขณะที่อัลกอริทึมทั้งหมดสามารถประมวลผลได้อย่างรวดเร็วและเหมาะสมสำหรับการนำไปใช้งานจริงในสภาพแวดล้อมการผลิต ทำให้รอบวิธีการดังกล่าวมีศักยภาพสูงสำหรับระบบเฝ้าติดตามสภาพเครื่องมือและการบำรุงรักษาเชิงคาดการณ์บนเครื่องจักร CNC

จากการทบทวนวรรณกรรมที่เกี่ยวข้อง พบว่างานวิจัยด้านการตรวจจับความผิดปกติของเครื่องมือตัดและสปินเดิลในกระบวนการผลิตด้วยเครื่องจักร CNC ยังมีช่องว่างขององค์ความรู้ที่สำคัญหลายด้าน โดยงานวิจัยส่วนใหญ่ยังคงอาศัยการกำหนดค่าเกณฑ์การตัดสินความผิดปกติแบบคงที่ (Fixed Threshold) ซึ่งไม่สามารถรองรับลักษณะของกระบวนการผลิตที่มีความไม่คงที่ตามเวลา (non-stationary process) และมีความแปรผันของสัญญาณจากการเปลี่ยนแปลงของวัสดุ เครื่องมือตัด และพารามิเตอร์การตัดเฉือนได้อย่างมีประสิทธิภาพ ส่งผลให้เกิดการแจ้งเตือนผิดพลาด หรือไม่สามารถตรวจจับความผิดปกติในระยะเริ่มต้นได้อย่างเหมาะสม

นอกจากนี้ แม้ว่าจะมีงานวิจัยจำนวนหนึ่งจะเริ่มนำเทคนิคการเรียนรู้ของเครื่องแบบไม่ต้องมีข้อมูลป้ายกำกับ (Unsupervised Learning) เช่น Isolation Forest มาใช้ในการตรวจจับความผิดปกติ แต่ยังคงพบว่า งานส่วนใหญ่ขาดแนวทางการกำหนดค่าเกณฑ์การตัดสินความผิดปกติที่เป็นระบบและสามารถปรับให้สอดคล้องกับลักษณะการกระจายตัวของข้อมูลจริงในแต่ละสภาวะการผลิตได้ ส่งผลให้การนำแบบจำลองไปประยุกต์ใช้ซ้ำในบริบทของโรงงานอุตสาหกรรมจริงยังมีข้อจำกัด

ขณะเดียวกัน งานวิจัยที่มีอยู่มากให้ความสำคัญกับความแม่นยำในการจำแนกสภาวะปกติและผิดปกติเป็นหลัก ขณะที่การประเมินความสามารถในการตรวจจับความผิดปกติในระยะเริ่มต้น (early detection) โดยเฉพาะในบริบทของกระบวนการผลิตด้วยเครื่องจักร CNC จริง ยังขาดการนำเสนอผลลัพธ์เชิงประจักษ์อย่างชัดเจน

จากช่องว่างดังกล่าว งานวิจัยนี้จึงมุ่งพัฒนาแนวทางการตรวจจับความผิดปกติของเครื่องมือตัดและสปินเดิลในกระบวนการผลิตด้วยเครื่องจักร CNC โดยประยุกต์ใช้เทคนิค Isolation Forest ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) ที่สามารถปรับเปลี่ยนได้ตามลักษณะการกระจายของข้อมูลจริง เพื่อรองรับความแปรผันของสภาวะการผลิต เพิ่มความสามารถในการตรวจจับความผิดปกติในระยะเริ่มต้น และลดการแจ้งเตือนผิดพลาด อันเป็นการตอบโจทย์การนำไปใช้งานจริงในโรงงานอุตสาหกรรม

บทที่ 3

วิธีดำเนินการวิจัย

3.1 ขั้นตอนการดำเนินงานวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองเชิงบูรณาการสำหรับคาดการณ์การสึกหรอของเครื่องมือตัด และ ตรวจจับความผิดปกติก่อนเกิดความเสียหายจริงบนเครื่องจักร CNC แบบ 5 แกน โดยอาศัยข้อมูลแรงตัด แรงบิด การสั่นสะเทือน และข้อมูลภาพจากกล้องจุลทรรศน์

แนวคิดการดำเนินงานถูกออกแบบเป็น 2 ระยะหลักคือ

1) การสร้างแบบจำลองทำนายการสึกหรอ (Predictive Model) ด้วยวิธีถดถอยเชิงเส้น (Linear Regression) เพื่อศึกษาความสัมพันธ์ระหว่างแรงตัด (Fz) กับจำนวนรอบการตัด และ ค่าการสึกหรอจริง (Flank Wear)

2) การตรวจจับความผิดปกติล่วงหน้า (Early Anomaly Detection) ด้วยวิธีป่าแยกตัว (Isolation Forest) และการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) เพื่อแจ้งเตือนความผิดปกติของแรงตัดก่อนเครื่องมือหักจริง

การดำเนินงานทั้งสองส่วนถูกใช้ร่วมกันเพื่อพัฒนาระบบบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) สำหรับเครื่องจักร CNC

3.1.1 ขั้นตอนการดำเนินงานวิจัยโดยภาพรวม

การดำเนินงานวิจัยในครั้งนี้ถูกออกแบบให้เป็นกระบวนการเชิงระบบ (Systematic Research Process) โดยมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองสำหรับการทำนายการสึกหรอของเครื่องมือตัด และการตรวจจับความผิดปกติของกระบวนการตัดเฉือนในเครื่องจักร CNC อย่างเป็นลำดับขั้นตอน ซึ่งสามารถแบ่งออกได้เป็น 6 ขั้นตอนหลัก ดังนี้

3.1.1.1 การเตรียมเครื่องจักร อุปกรณ์วัด และเซนเซอร์ ดำเนินการติดตั้งและตรวจสอบความพร้อมของเครื่องจักร CNC แบบ 5 แกน พร้อมทั้งติดตั้งอุปกรณ์วัดแรง แรงบิด และการสั่นสะเทือนอย่างถูกต้องตามแนวแกนมาตรฐาน เพื่อให้ได้ข้อมูลที่สอดคล้องกับสภาวะการตัดเฉือนจริง รวมถึงตรวจสอบความถูกต้องของการส่งสัญญาณข้อมูลจากเซนเซอร์เข้าสู่ระบบบันทึกข้อมูล เพื่อให้มั่นใจว่าการวัดมีความเสถียรและเชื่อถือได้ตลอดการทดลอง

3.1.1.2 การดำเนินการทดลองเจาะบนชิ้นงานโลหะ ทดลองตัดเฉือนในรูปแบบการเจาะบนชิ้นงานโลหะชนิดเหล็กและอะลูมิเนียมภายใต้เงื่อนไขการทำงานจริงของเครื่องจักร CNC โดยควบคุมพารามิเตอร์การตัดเฉือนให้คงที่ในแต่ละรอบ เพื่อศึกษาแนวโน้มการเปลี่ยนแปลงของแรงตัด

และพฤติกรรมของเครื่องมือในระยะยาว ทั้งนี้การทดลองจะดำเนินต่อเนื่องจนกระทั่งพบสัญญาณการเสื่อมสภาพหรือเครื่องมือเริ่มเกิดความเสียหาย

3.1.1.3 การตรวจวัดการสึกหรอของเครื่องมือตัดด้วยกล้องจุลทรรศน์ ดำเนินการตรวจสอบสภาพการสึกหรอของเครื่องมือตัดที่บริเวณผิวหลบ (Flank Wear) ด้วยกล้องจุลทรรศน์แบบสเตอริโอในช่วงเวลาที่กำหนด เพื่อวัดค่าอัตราการสึกหรอเชิงปริมาณ และใช้ข้อมูลดังกล่าวเป็นข้อมูลจริง (Ground Truth) สำหรับยืนยันผลลัพธ์ของแบบจำลองเชิงคาดการณ์และระบบตรวจจับความผิดปกติในขั้นตอนถัดไป


3.1.1.4 การวิเคราะห์แนวโน้มแรงตัดด้วย Linear Regression นำข้อมูลแรงตัดที่ได้จากกระบวนการทดลองมาสร้างแบบจำลองทางสถิติด้วยวิธีการถดถอยเชิงเส้น (Linear Regression) เพื่อศึกษาความสัมพันธ์ระหว่างจำนวนรอบการตัดกับขนาดของแรงตัดในแกนที่มีนัยสำคัญ โดยผลจากแบบจำลองนี้ถูกนำมาใช้เป็นตัวแทนเชิงปริมาณของระดับการเสื่อมสภาพของเครื่องมือตัด และใช้ในการประเมินแนวโน้มของอายุการใช้งานเครื่องมือ

3.1.1.5 การตรวจจับความผิดปกติด้วย Isolation Forest นำข้อมูลแรงตัดที่ผ่านการประมวลผลเบื้องต้นเข้าสู่แบบจำลองการตรวจจับความผิดปกติด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest) เพื่อคำนวณค่าความผิดปกติ (Anomaly Score) ของสัญญาณแรงตัดแต่ละช่วงเวลา โดยข้อมูลที่มีแนวโน้มถูกแยกออกจากกลุ่มปกติได้รวดเร็วจะถูกจัดเป็นสภาวะผิดปกติ ซึ่งสามารถบ่งชี้ระยะเริ่มต้นของความเสื่อมสภาพหรือความเสียหายของเครื่องมือตัด

3.1.1.6 การประเมินผลและวิเคราะห์ความสามารถในการเตือนล่วงหน้า ประเมินผลการทำงานของระบบตรวจจับโดยเปรียบเทียบตำแหน่งเวลาที่ระบบสามารถตรวจพบความผิดปกติกับเหตุการณ์ความเสียหายจริงของเครื่องมือตัด เพื่อวิเคราะห์ความสามารถในการแจ้งเตือนล่วงหน้า (Early Warning Capability) รวมถึงประเมินความถูกต้องและเสถียรภาพของแบบจำลอง เพื่อยืนยันความเหมาะสมของแนวทางสำหรับการประยุกต์ใช้ในระบบบำรุงรักษาเชิงคาดการณ์

3.1.2 แผนผังการดำเนินงานวิจัย

เพื่อให้เห็นภาพรวมของกระบวนการดำเนินงานวิจัยอย่างเป็นระบบ การศึกษานี้ได้ออกแบบแผนผังการทำงานของระบบพยากรณ์การสึกหรอและการตรวจจับความผิดปกติของเครื่องจักร CNC สำหรับการบำรุงรักษาเชิงคาดการณ์ โดยแผนภาพที่ 3.1 ดังกล่าวแสดงภาพรวมของกระบวนการวิจัย ตั้งแต่การเก็บข้อมูลสัญญาณจากเซนเซอร์ระหว่างกระบวนการตัดเฉือน ไปจนถึงการวิเคราะห์ข้อมูลด้วยแบบจำลองถดถอยเพื่อพยากรณ์แนวโน้มการสึกหรอ และวิธีป่าแยกตัว (Isolation Forest) ร่วมกับคาร์ตแบบต้นไม้เพื่อการตรวจจับและแจ้งเตือนความผิดปกติล่วงหน้า ผลลัพธ์จากการวิเคราะห์ทั้งสองส่วนถูกนำมาใช้สนับสนุนการบำรุงรักษาเชิงคาดการณ์ของเครื่องจักร CNC



รูปที่ 3.1 แผนผังการทำงานของระบบพยากรณ์การสึกหรอและตรวจจับความผิดปกติสำหรับเครื่องจักร CNC เพื่อการบำรุงรักษาเชิงคาดการณ์

3.2 เครื่องจักร วัสดุ และอุปกรณ์

3.2.1 เครื่องจักรและอุปกรณ์

การทดลองในงานวิจัยนี้ดำเนินการบนเครื่องจักร CNC แบบ 5 แกน รุ่น DMG Mori DMU 50 ที่มีความเร็วรอบสปินเดิลสูงสุด 18,000 รอบต่อนาที (rpm) ซึ่งเหมาะสำหรับการศึกษาพฤติกรรมแรงตัดในสภาวะการผลิตจริง เครื่องมือตัดที่ใช้เป็นหัวเจาะยี่ห้อ NACHI ชนิด HSS (High Speed Steel) ขนาดเส้นผ่านศูนย์กลาง 6 มิลลิเมตร แบบไม่เคลือบผิว ดังแสดงตัวอย่างใน รูปที่ 3.2




รูปที่ 3.2 เครื่องจักร CNC แบบ 5 แกน รุ่น DMU 50

หมายเหตุ จาก 5-Axis Machining Center, โดย DMG MORI, Inc., 2025, <https://www.dmgmori.co.jp/sp/5axis/th/>

การตรวจวัดข้อมูลทางกายภาพใช้เซนเซอร์ดังนี้

3.2.1.1 เซนเซอร์วัดแรงและแรงบิด Kistler รุ่น 9272 สำหรับวัดแรงในแกน X, Y, Z และแรงบิดของสปินเดิล ดังแสดงตัวอย่างในรูปที่ 3.3



รูปที่ 3.3 เซนเซอร์วัดแรงและแรงบิด Kistler 9272

หมายเหตุ จาก Kistler 9272 Multicomponent Dynamometer, โดย Kistler, 2025, <https://www.kistler.com/US/en/cp/multicomponent-dynamometers-9272/P0000682>

3.2.1.2 เครื่องวัดแรงสั่นสะเทือน TENMARS ST-140 สำหรับตรวจสอบสภาวะการทำงานของสปินเดิล ดังแสดงตัวอย่างในรูปที่ 3.4



รูปที่ 3.4 เครื่องวัดการสั่นสะเทือนรุ่น ST-140 / ST-140D

หมายเหตุ จาก ST-140 / ST-140D Vibration Meter, โดย TENMARS Electronics, 2025, <https://www.tenmars.com/m/2001-1682-688961,c19115-1.php?Lang=en>

3.2.1.3 กล้องจุลทรรศน์แบบสเตอริโอ Olympus รุ่น SZ61 สำหรับวัดการสึกหรอแบบ Flank Wear ดังแสดงตัวอย่างในรูปที่ 3.5



รูปที่ 3.5 กล้องจุลทรรศน์ Olympus รุ่น SZ61

หมายเหตุ จาก Olympus SZ61 / SZ51 Stereo Microscope, โดย Olympus Corporation, 2025,
Retrieved from <https://evidentscientific.com/en/products/upright/sz61-sz51>

ข้อมูลทั้งหมดถูกบันทึกและประมวลผลด้วยโปรแกรม MATLAB เพื่อใช้ในการวิเคราะห์แรงตัด การสร้างแบบจำลองเชิงสถิติ และการตรวจจับความผิดปกติด้วยวิธีป่าแยกตัว

3.2.2 วัสดุและเงื่อนไขการตัด

3.2.2.1 วัสดุ พารามิเตอร์การตัด และการเก็บข้อมูล

การทดลองในงานวิจัยนี้ดำเนินการในกระบวนการเจาะ (Drilling Process) บนชิ้นงาน โลหะจำนวนสองประเภท ได้แก่ เหล็ก (Steel) และ อะลูมิเนียม (Aluminium) ซึ่งเป็นวัสดุที่พบได้ทั่วไปในอุตสาหกรรมการผลิต โดยในแต่ละวัสดุได้ดำเนินการทดลองเจาะรูในหลายชิ้นงาน โดยใช้ อะลูมิเนียมจำนวน 4 ชิ้นงาน รวมจำนวนการเจาะทั้งหมด 100 รู และเหล็กจำนวน 5 ชิ้นงาน รวมจำนวน การเจาะทั้งหมด 140 รู ติดต่อกันด้วยเครื่องมือตัดชนิดเดียวกัน เพื่อให้สามารถติดตามพฤติกรรม การเปลี่ยนแปลงของแรงตัดและระดับการสึกหรอของเครื่องมือตัดตลอดช่วงอายุการใช้งาน พารามิเตอร์ ในการทดลองถูกกำหนดให้แตกต่างกันตามคุณสมบัติทางกลของวัสดุแต่ละประเภท เพื่อให้การตัดเฉือน เกิดขึ้นอย่างเหมาะสมและสะท้อนสภาวะการทำงานจริงของอุตสาหกรรม โดยรายละเอียดของพารามิเตอร์ การตัดเฉือนแสดงไว้ใน ตารางที่ 2 ทั้งนี้ระหว่างการทดลอง มีการบันทึกข้อมูลแรงตัดตามแนวแกน Z (Fz), แรงบิดของสปินเดิล (Mz) และสัญญาณการสั่นสะเทือนแบบเรียลไทม์ตลอดทุกกระบวนการเจาะ เพื่อใช้เป็นข้อมูลนำเข้าสำหรับการวิเคราะห์เชิงสถิติ การสร้างแบบจำลองพยากรณ์ และการตรวจจับ ความผิดปกติในขั้นตอนถัดไป นอกจากนี้ จะดำเนินการตรวจวัดลักษณะการสึกหรอของเครื่องมือตัดด้วย กล้องจุลทรรศน์แบบสเตอริโอทุก ๆ 10 รู โดยวัดค่าการสึกหรอแบบผิวหลบ (Flank Wear หรือ VBmax) เพื่อใช้เป็นข้อมูลอ้างอิงจริงสำหรับการประเมินความถูกต้องของแบบจำลองการพยากรณ์ด้วย Linear Regression และระบบตรวจจับความผิดปกติด้วยวิธีป่าแยกตัว

ตารางที่ 3.1 พารามิเตอร์การทดลองในการเจาะด้วยเครื่องจักร CNC

พารามิเตอร์	ค่า
จำนวนรอบที่เจาะการเจาะหลัก	140
จำนวนรอบที่เจาะการเจาะอะลูมิเนียม	100
ความลึกของรูที่เจาะ (มิลลิเมตร)	30
อัตราป้อนงานในการเจาะหลัก (มิลลิเมตรต่อนาที)	133
ความเร็วรอบในการเจาะหลัก (รอบต่อนาที)	1,133
อัตราป้อนงานในการเจาะอะลูมิเนียม (มิลลิเมตรต่อนาที)	174
ความเร็วรอบในการเจาะอะลูมิเนียม (รอบต่อนาที)	1,450

พารามิเตอร์การตัดเฉือนที่ใช้ในการทดลองแสดงไว้ใน ตารางที่ 3.1 โดยกำหนดให้เหมาะสมกับคุณสมบัติของวัสดุแต่ละประเภท สำหรับการเจาะหลัก ค่าความเร็วรอบและอัตราป้อนอ้างอิงจากงานวิจัยของ (Makee et al., 2022) ส่วนการเจาะอะลูมิเนียม อ้างอิงข้อมูลจากผู้ผลิตดอกสว่าน Nachi America Inc. โดยใช้เครื่องคำนวณ HSS-HSCO Calculator (Nachi America Inc., 2025) สำหรับดอกสว่านขนาด 6 มิลลิเมตร เพื่อให้พารามิเตอร์สอดคล้องกับสภาวะการใช้งานจริง และเหมาะสมต่อการวิเคราะห์ผลการทดลอง

3.2.2.2 ตัวแปรที่มีผลต่อการเสื่อมสภาพของหัวเจาะ

การเสื่อมสภาพของหัวเจาะในกระบวนการเจาะด้วยเครื่องจักร CNC เป็นผลจากปฏิสัมพันธ์ระหว่างสภาวะการตัดเฉือน เครื่องมือตัด และคุณสมบัติของวัสดุชิ้นงาน ซึ่งเกิดขึ้นอย่างต่อเนื่องตลอดช่วงอายุการใช้งานของหัวเจาะ ตัวแปรที่ส่งผลต่อการสึกหรอและการเสื่อมสภาพของหัวเจาะสามารถอธิบายได้จากกลไกทางกายภาพหลัก ได้แก่ ความร้อนที่เกิดขึ้นบริเวณคมตัด การเสียดสีระหว่างคมตัดกับชิ้นงานและเศษตัด รวมถึงแรงตัดและแรงบิดที่กระทำต่อหัวเจาะในระหว่างกระบวนการเจาะ

ความร้อนเป็นปัจจัยสำคัญที่ส่งผลต่อการเสื่อมสภาพของหัวเจาะ โดยเกิดจากพลังงานเชิงกลที่ถูกเปลี่ยนเป็นพลังงานความร้อนในระหว่างการตัดเฉือน เมื่ออุณหภูมิบริเวณคมตัดเพิ่มสูงขึ้นอย่างต่อเนื่อง จะส่งผลให้ความแข็งและความสามารถในการต้านทานการสึกหรอของวัสดุหัวเจาะลดลง ทำให้คมตัดสูญเสียความคมและเกิดการสึกหรอได้เร็วขึ้น โดยเฉพาะในกระบวนการเจาะแบบต่อเนื่องหลายรูซึ่งมีแนวโน้มเกิดการสะสมของความร้อนตามจำนวนรอบการใช้งาน

การเสียดสีระหว่างผิวคมตัดกับผิวชิ้นงานและเศษตัดเป็นอีกปัจจัยหนึ่งที่มีบทบาทสำคัญต่อการสึกหรอของหัวเจาะ การเสียดสีที่เกิดขึ้นซ้ำ ๆ จะทำให้เกิดการสึกหรอในบริเวณผิวหลบของคมตัด ซึ่งมักเรียกว่าการสึกหรอแบบผิวหลบ (Flank Wear) การเพิ่มขึ้นของการสึกหรอในบริเวณดังกล่าว

ส่งผลให้ประสิทธิภาพการตัดลดลง และทำให้ต้องใช้แรงตัดมากขึ้นในระหว่างการเจาะ แรงตัดและแรงบิดที่กระทำต่อหัวเจาะในระหว่างกระบวนการเจาะเป็นตัวแปรสำคัญที่สะท้อนถึงสภาพการทำงานของเครื่องมือตัด โดยเฉพาะแรงตัดในทิศทางแกน Z (F_z) และแรงบิดของสปินเดิล (M_z) ซึ่งมีแนวโน้มเพิ่มขึ้นเมื่อหัวเจาะเริ่มเกิดการสึกหรอหรือสูญเสียความคม การเปลี่ยนแปลงของแรงดังกล่าวสามารถใช้เป็นตัวบ่งชี้ทางอ้อมของการเสื่อมสภาพของหัวเจาะ และสะท้อนถึงความผิดปกติที่อาจเกิดขึ้นในกระบวนการเจาะ เมื่อพิจารณาร่วมกัน ตัวแปรด้านความร้อน การเสียดสี และแรงตัดมีความสัมพันธ์กันอย่างใกล้ชิดและส่งผลต่อการเสื่อมสภาพของหัวเจาะอย่างต่อเนื่องตลอดกระบวนการเจาะ ดังนั้นการติดตามการเปลี่ยนแปลงของแรงตัดและแรงบิดแบบเรียลไทม์ร่วมกับการตรวจวัดค่าการสึกหรอของหัวเจาะด้วยกล้องจุลทรรศน์ จึงมีความสำคัญในการอธิบายกลไกการเสื่อมสภาพของหัวเจาะและเป็นพื้นฐานสำหรับการวิเคราะห์ข้อมูล การสร้างแบบจำลองพยากรณ์ และการตรวจจับความผิดปกติของเครื่องมือตัดในงานวิจัยนี้

3.2.2 การเตรียมวัสดุสำหรับการทดลอง

การเตรียมวัสดุสำหรับการทดลองในงานวิจัยนี้ดำเนินการอย่างเป็นระบบ เพื่อให้ได้ชิ้นงานที่มีขนาด ความเรียบร้อย และคุณสมบัติที่สม่ำเสมอ ซึ่งส่งผลโดยตรงต่อความถูกต้องของการวัดแรงตัดและการสึกหรอของเครื่องมือตัด โดยกระบวนการเตรียมวัสดุทั้งหมดสามารถสรุปเป็นลำดับขั้นตอนตามแผนผังแสดงใน รูปที่ 3.12 วัสดุที่ใช้ในการทดลองเป็นเพลากลมโลหะซึ่งจัดซื้อจากร้านจำหน่ายวัสดุอุตสาหกรรม ประกอบด้วยเหล็กและอะลูมิเนียม จากนั้นนำมาผ่านกระบวนการเตรียมชิ้นงานตามขั้นตอนดังนี้

3.2.3.1 การเตรียมวัตถุดิบ (Raw Material Preparation) เริ่มจากการจัดซื้อเพลากลมโลหะจากตัวอย่างรูปที่ 3.6 ตามขนาดที่กำหนด จากนั้นทำการตรวจสอบสภาพวัตถุดิบในด้านความตรง ความเรียบของพื้นผิว และการไม่มีตำหนิ เช่น รอยร้าวหรือรอยบิ่น เพื่อคัดเลือกเฉพาะวัสดุที่อยู่ในสภาพสมบูรณ์สำหรับการนำไปผลิตชิ้นงาน



รูปที่ 3.6 โลหะเพลากลม

3.2.3.2 กระบวนการกลึงขึ้นรูป (Machining Process: Cutting & Turning)

นำเพลากลมเข้าสู่กระบวนการกลึงเพื่อตัดความยาวให้ได้ตามแบบ และปรับผิวหน้าให้เรียบสม่ำเสมอ โดยการกลึงมีจุดประสงค์เพื่อให้หน้าชิ้นงานตั้งฉากกับแกนหมุนของเครื่องจักร CNC ซึ่งช่วยลดความคลาดเคลื่อนในการตรวจวัดแรงตัด ดังตัวอย่างรูปที่ 3.7 คือชิ้นงานที่ขึ้นรูปแล้ว



รูปที่ 3.7 ตัวอย่างชิ้นงานโลหะ

3.2.3.3 การเจาะรูและลบมุม (Drilling & Chamfering) ดำเนินการเจาะรูบนชิ้นงานตามตำแหน่งที่กำหนด พร้อมทั้งลบคมบริเวณปากรู (Chamfering) เพื่อลดเศษโลหะตกค้าง และป้องกันการเกิด Stress Concentration ซึ่งอาจส่งผลต่อแรงตัดและความสม่ำเสมอของผลการทดลอง ตัวอย่างชิ้นงานที่ผ่านกระบวนการกลึงจากตัวอย่างรูปที่ 3.8 และเจาะแล้ว ซึ่งแสดงลักษณะของชิ้นงานโลหะที่พร้อมสำหรับนำไปติดตั้งบนชุดวัดแรง



รูปที่ 3.8 ตัวอย่างกระบวนการลบมุมชิ้นงาน

3.2.3.4 การทำความสะอาดและตรวจสอบ (Cleaning & Inspection) หลังจากกระบวนการตัดเฉือน ชิ้นงานทุกชิ้นถูกทำความสะอาดเพื่อขจัดเศษโลหะและคราบน้ำมัน พร้อมทั้งตรวจสอบมิติ ความเรียบร้อยของรูเจาะ และลักษณะผิวโดยรอบ และทำการเคลือบผิวชิ้นงานด้วยน้ำยากันสนิม ดังตัวอย่างรูปที่ 3.9



รูปที่ 3.9 ชิ้นงานที่ผ่านการทำความสะอาดและเคลือบเงา

3.2.3.5 การติดตั้งบนไดนาโมมิเตอร์ (Mounting on Dynamometer) ชิ้นงานที่ผ่านการตรวจสอบแล้วถูกนำไปติดตั้งบนไดนาโมมิเตอร์อย่างมั่นคง เพื่อให้การวัดแรงตัดในแนวแกนต่าง ๆ มีความถูกต้องลดการสั่นสะเทือนและลดความคลาดเคลื่อนในการเก็บข้อมูลดังตัวอย่างรูปที่ 3.10




รูปที่ 3.10 การตั้งศูนย์ของเครื่องจักร

3.2.3.6 การตั้งค่าระบบทดลอง (Experiment Setup) ดำเนินการตั้งค่าระบบเครื่องจักร CNC โปรแกรมควบคุมการทดลอง และอุปกรณ์วัด ก่อนเริ่มการทดลองจริง โดยจะทำการ set up เครื่องจักรผ่านหน้าจอคอมพิวเตอร์ดังรูปที่ 3.11 เพื่อให้แน่ใจว่าข้อมูลที่บันทึกได้มีความสมบูรณ์ และพร้อมสำหรับการวิเคราะห์ในขั้นตอนถัดไป



รูปที่ 3.11 หน้าจอเครื่องจักร CNC



รูปที่ 3.12 แผนผังกระบวนการเตรียมวัสดุสำหรับการทดลอง

3.2.3 ขั้นตอนการเก็บข้อมูล


3.4.1.1 ขั้นตอนการเก็บข้อมูลในการทดลอง

การเก็บข้อมูลในการวิจัยนี้ถูกออกแบบให้เป็นไปตามลำดับขั้นตอนที่ชัดเจนและสามารถทำซ้ำได้ เพื่อให้ได้ข้อมูลแรงตัดและข้อมูลการสั่นสะเทือนที่มีความถูกต้องและสอดคล้องกับสภาพการสึกหรอของเครื่องมือตัด โดยกระบวนการเก็บข้อมูลทั้งหมดแสดงดัง รูปที่ 3.13 ซึ่งแสดงลำดับขั้นตอนตั้งแต่เริ่มต้นการทดลองจนถึงการวัดค่าการสึกหรอของเครื่องมือตัด กระบวนการเก็บข้อมูลเริ่มต้นด้วยการเริ่มการทดลอง (Start Experiment) โดยผู้วิจัยทำการติดตั้งและตรวจสอบความพร้อมของระบบเซนเซอร์ที่ใช้ในการวัดแรงตัดและการสั่นสะเทือน จากนั้นทำการเปิดใช้งานเซนเซอร์แรงตัดและเซนเซอร์การสั่นสะเทือน (Activate Force and Vibration Sensors) เพื่อให้สามารถบันทึกข้อมูลระหว่างการตัดเนื้อได้อย่างต่อเนื่องและครอบคลุมตลอดช่วงการทดลอง เมื่อระบบเซนเซอร์อยู่ในสถานะพร้อมใช้งาน จะดำเนินการเจาะชิ้นงานตามเงื่อนไขการทดลองที่กำหนด โดยในแต่ละรอบการทดลอง จะทำการเจาะจำนวน 10 รูต่อหนึ่งรอบ (10 holes per cycle) ดังแสดงในขั้นตอน Perform Drilling Operation (10 Holes per Cycle) ข้อมูลแรงตัดและการสั่นสะเทือนที่เกิดขึ้นในระหว่างการเจาะจะถูกบันทึกแบบเรียลไทม์ และจัดเก็บลงในคอมพิวเตอร์เพื่อใช้ในการวิเคราะห์ภายหลัง การกำหนดจำนวนรูต่อรอบการทดลองในลักษณะนี้ช่วยให้สามารถติดตามการเปลี่ยนแปลงของสัญญาณแรงตัดตามอายุการใช้งานของเครื่องมือตัดได้อย่างเป็นระบบ

เมื่อสิ้นสุดการเจาะในแต่ละรอบ จะทำการหยุดการทำงานของเครื่องจักรและปิดการใช้งานเซนเซอร์ (Stop Drilling Operation and Deactivate Sensors) เพื่อป้องกันการบันทึกข้อมูลที่ไม่เกี่ยวข้องกับกระบวนการตัดเนื้อ จากนั้นข้อมูลแรงตัดและการสั่นสะเทือนที่ได้จะถูกจัดเก็บไว้ในคอมพิวเตอร์ (Store Force and Vibration Data to Computer) เพื่อใช้เป็นข้อมูลดิบสำหรับการประมวลผลและการสร้างแบบจำลองในขั้นตอนถัดไป หลังจากสิ้นสุดการเก็บข้อมูลในแต่ละรอบการเจาะ ผู้วิจัยจะทำการถอดเครื่องมือตัดออกจากเครื่องจักร พร้อมทั้งทำความสะอาดเครื่องมือตัดและบริเวณเครื่องจักร (Remove Cutting Tool / Clean Cutting Tool and Machine) เพื่อขจัดเศษวัสดุและสิ่งสกปรกที่อาจส่งผลต่อความถูกต้องในการวัดค่าการสึกหรอ

ขั้นตอนสุดท้ายคือการวัดการสึกหรอของเครื่องมือตัดโดยใช้กล้องจุลทรรศน์เชิงแสง (Measure Tool Wear Using Optical Microscope) ซึ่งจะทำให้การบันทึกภาพบริเวณผิวสึกหรอของเครื่องมือตัดในแต่ละช่วงอายุการใช้งาน ภาพที่ได้จะถูกนำมาใช้ในการวิเคราะห์ค่าการสึกหรอสูงสุดบริเวณผิวหลบ (VB_{max}) เพื่อใช้เป็นข้อมูลอ้างอิงสภาพจริงของเครื่องมือตัด และนำไปเปรียบเทียบกับผลการตรวจจับความผิดปกติจากแบบจำลองการเรียนรู้ของเครื่องในขั้นตอนการวิเคราะห์ผล

จากกระบวนการเก็บข้อมูลดังกล่าว ซึ่งแสดงในรูปที่ 3.13 จะเห็นได้ว่าการเก็บข้อมูล แรงตัด การสั่นสะเทือน และการสึกหรอของเครื่องมือตัดถูกดำเนินการอย่างเป็นระบบและเชื่อมโยงกัน ในเชิงลำดับเวลา ทำให้ข้อมูลที่ได้สามารถสะท้อนพฤติกรรมการทำงานของเครื่องมือตัดได้อย่าง ชัดเจน และเหมาะสมสำหรับการนำไปใช้ในการพัฒนาและประเมินประสิทธิภาพของวิธีการตรวจจับ ความผิดปกติในงานวิจัยนี้




รูปที่ 3.13 กระบวนการเก็บข้อมูลสำหรับการวิเคราะห์การสึกหรอของเครื่องมือตัด

3.4.1.2 การกำหนดจำนวนรูต่อรอบการเจาะ

ในการออกแบบขั้นตอนการเก็บข้อมูล การกำหนดจำนวนรูที่ทำการเจาะต่อหนึ่งรอบ การทดลองมีผลโดยตรงต่อความละเอียดในการติดตามการเปลี่ยนแปลงของแรงตัดและพฤติกรรม การเสื่อมสภาพของเครื่องมือตัด ในทางทฤษฎี การเจาะแบบต่อเนื่องจำนวนมากในรอบเดียวสามารถ ทำให้เห็นแนวโน้มการเปลี่ยนแปลงของสัญญาณแรงตัดได้อย่างชัดเจน ดังแสดงในรูปที่ 3.14 ซึ่งเป็น ตัวอย่างสัญญาณแรงตัดในทิศทางแกน Z (F_z) ที่ได้จากการเจาะต่อเนื่องหลายรูโดยไม่หยุดกระบวนการ จากรูปที่ 3.14 จะเห็นได้ว่าสัญญาณแรงตัดมีลักษณะการเปลี่ยนแปลงอย่างต่อเนื่องตามลำดับเวลา โดยมีทั้งการเพิ่มขึ้นของระดับแรงตัดและการเปลี่ยนแปลงของรูปแบบสัญญาณ ซึ่งสะท้อนถึงผลของ การสะสมความร้อน การเสียดสี และการสึกหรอของคมตัดเมื่อมีการใช้งานเครื่องมือตัดอย่างต่อเนื่อง อย่างไรก็ตาม รูปแบบการเจาะต่อเนื่องในลักษณะดังกล่าวไม่สอดคล้องกับสภาวะการทำงานจริงใน ภาควิศวกรรมการผลิต ในกระบวนการผลิตจริง การเจาะมักถูกดำเนินการเป็นช่วงสั้น ๆ โดยทั่วไป จะมีการเจาะเพียงประมาณ 10 รูต่อรอบ ก่อนที่จะมีการหยุดเครื่องเพื่อเปลี่ยนเครื่องมือตัด ตรวจสอบ

สภาพเครื่องมือ หรือเปลี่ยนชิ้นงาน ดังนั้น การเจาะต่อเนื่องเป็นจำนวนมากในรอบเดียวอาจทำให้ข้อมูลที่ได้สะท้อนสภาวะการทำงานที่แตกต่างจากการใช้งานจริง และอาจนำไปสู่ข้อจำกัดในการนำผลการวิเคราะห์ไปประยุกต์ใช้ในทางปฏิบัติ

ด้วยเหตุนี้ งานวิจัยนี้จึงกำหนดให้การเก็บข้อมูลดำเนินการในลักษณะการเจาะจำนวน 10 รูต่อหนึ่งรอบการทดลอง เพื่อให้สอดคล้องกับรูปแบบการทำงานจริงในอุตสาหกรรม และเพื่อเพิ่มความละเอียดในการติดตามการเปลี่ยนแปลงของแรงตัดตามอายุการใช้งานของเครื่องมือตัด การแบ่งรอบการเจาะในลักษณะนี้ช่วยให้สามารถตรวจจับการเปลี่ยนแปลงของสัญญาณแรงตัดและการเกิดความผิดปกติในระยะเริ่มต้นได้ดีกว่า เมื่อเปรียบเทียบกับ การเจาะต่อเนื่องเป็นจำนวนมากในรอบเดียว นอกจากนี้ การกำหนดจำนวนรูต่อรอบการเจาะในระดับที่เหมาะสมยังเอื้อให้สามารถเชื่อมโยงข้อมูลแรงตัดและสัญญาณการสั่นสะเทือนกับการตรวจวัดค่าการสึกหรอของเครื่องมือตัดด้วยกล้องจุลทรรศน์ ในแต่ละช่วงอายุการใช้งานได้อย่างเป็นระบบ ส่งผลให้ข้อมูลที่ได้มีความสอดคล้องทั้งในเชิงลำดับเวลา และสภาพจริงของเครื่องมือตัด ซึ่งเหมาะสมสำหรับการนำไปใช้ในการวิเคราะห์ การสร้างแบบจำลองพยากรณ์ และการตรวจจับความผิดปกติในงานวิจัยนี้



รูปที่ 3.14 ตัวอย่างสัญญาณแรงตัดในทิศทางแกน Z จากการเจาะต่อเนื่องหลายรูตามลำดับเวลา

3.3 การประมวลผลและวิเคราะห์ข้อมูล

3.3.1 การวิเคราะห์แรงตัดด้วย Linear Regression

ในขั้นตอนการวิเคราะห์แนวโน้มการเสื่อมสภาพของเครื่องมือตัด งานวิจัยนี้นำข้อมูลแรงตัดตามแนวแกน Z (F_z) มาวิเคราะห์ด้วยวิธีการถดถอยเชิงเส้น (Linear Regression) โดยพิจารณาความสัมพันธ์ระหว่างแรงตัดกับจำนวนรอบการตัดเฉือนซึ่งสามารถแสดงความสัมพันธ์เชิงคณิตศาสตร์ได้ดังสมการ (3.1) ตามแนวคิดของการวิเคราะห์การถดถอยเชิงเส้น (Montgomery et al., 2012)

$$F_z = \beta_0 + \beta_1 x \quad (3.1)$$

โดยที่

x แทน จำนวนรูหรือรอบการทำงาน,

β_0 แทน ค่าคงที่ (Intercept) และ

β_1 แทน สัมประสิทธิ์การเปลี่ยนแปลงของแรงตัดตามจำนวนรอบการตัด

วัตถุประสงค์ของการวิเคราะห์ด้วย Linear Regression คือเพื่อศึกษาพฤติกรรมการเปลี่ยนแปลงของแรงตัดตามอายุการใช้งานเครื่องมือตัด และใช้แนวโน้มของแรงตัดเป็นตัวบ่งชี้เชิงปริมาณของการเสื่อมสภาพของเครื่องมือ

ผลการวิเคราะห์จากงานวิจัยพบว่า สำหรับวัสดุอะลูมิเนียม แบบจำลองให้ค่าความสอดคล้องของข้อมูลสูง โดยมีค่า $R^2 = 0.92$ และค่าความคลาดเคลื่อนเฉลี่ยกำลังสองรากที่สอง (RMSE = 5.72 นิวตัน) ส่วนการเจาะวัสดุประเภทเหล็กให้ค่า $R^2 = 0.82$ ซึ่งแสดงให้เห็นว่าแรงตัดมีความสัมพันธ์เชิงเส้นกับจำนวนรอบการตัดอย่างชัดเจน

จากผลการวิเคราะห์พบว่า ค่าแรงตัดในแนวแกน Z (F_z) มีแนวโน้มเพิ่มขึ้นอย่างเป็นเชิงเส้นตามจำนวนรอบการเจาะ (จำนวนรู) ซึ่งสะท้อนถึงภาระการตัดที่เพิ่มขึ้นเมื่อเครื่องมือตัดถูกใช้งานต่อเนื่องเป็นเวลานาน แนวโน้มดังกล่าวสอดคล้องกับพฤติกรรมการสึกหรอของเครื่องมือตัดที่เกิดขึ้นสะสมตามอายุการใช้งาน ดังนั้น แบบจำลอง Linear Regression จึงถูกนำมาใช้เป็นเครื่องมือในการพยากรณ์แนวโน้มการเปลี่ยนแปลงของแรงตัดตามรอบการใช้งาน และใช้เป็นตัวบ่งชี้เชิงปริมาณของการเสื่อมสภาพของเครื่องมือตัด ก่อนนำไปใช้เป็นข้อมูลพื้นฐานสำหรับขั้นตอนการตรวจจับความผิดปกติด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ในลำดับถัดไป

3.3.2 การตรวจสอบ Flank Wear ด้วยกล้องจุลทรรศน์และการประมวลผลภาพ

การตรวจวัดการสึกหรอของเครื่องมือตัด (Flank Wear) ในงานวิจัยนี้ดำเนินการโดยใช้กล้องจุลทรรศน์แบบสเตอริโอ (Stereo Microscope) รุ่น Olympus SZ61 เพื่อบันทึกภาพบริเวณผิวหลังของคมตัดในทุก ๆ 10 รู ตลอดกระบวนการทดลอง จากนั้นนำภาพที่ได้มาวิเคราะห์ด้วยเทคนิคการประมวลผลภาพดิจิทัลเพื่อคำนวณค่า VBmax ซึ่งใช้เป็นตัวแทนเชิงปริมาณของระดับการสึกหรอ ขั้นตอนการคำนวณค่า VBmax ดำเนินตามกระบวนการที่แสดงใน รูปที่ 3.15 และแสดงตัวอย่างผลการวัดจากภาพจริงใน รูปที่ 3.16 โดยมีรายละเอียดขั้นตอนดังนี้

3.3.2.1 กำหนดภาพอ้างอิง (Baseline Image) ในขั้นตอนแรกของการวิเคราะห์การสึกหรอของเครื่องมือตัด ได้มีการกำหนดภาพอ้างอิง (Baseline Image) จากภาพของคมตัดก่อนเริ่มกระบวนการตัดเฉือน โดยภาพดังกล่าวแทนสภาพเริ่มต้นของเครื่องมือที่ยังไม่เกิดการสึกหรอ ภาพอ้างอิงนี้

ถูกใช้เป็นพื้นฐานสำหรับการเปรียบเทียบกับภาพในช่วงเวลาต่าง ๆ ของการทดลอง เพื่อระบุการเปลี่ยนแปลงของผิวหลบที่เกิดขึ้นจากการใช้งานจริง การเลือกใช้ภาพอ้างอิงช่วยให้สามารถแยกความแตกต่างระหว่างลักษณะพื้นผิวเดิมของเครื่องมือกับการเปลี่ยนแปลงที่เกิดจากการสึกหรอได้อย่างชัดเจน โดยเฉพาะในกรณีที่มีผิวคมตัดมีผลตายจากกระบวนการผลิตหรือมีตำหนิขนาดเล็กที่ไม่ได้เกิดจากการใช้งาน หากไม่มีการกำหนดภาพอ้างอิง การวิเคราะห์อาจตีความลักษณะพื้นผิวดังกล่าวเป็นรอยสึกหรอ ส่งผลให้ค่าการวัดมีความคลาดเคลื่อนนอกจากนี้ การใช้ภาพอ้างอิงเดียวกันตลอดการวิเคราะห์ยังช่วยให้การเปรียบเทียบผลการสึกหรอในแต่ละช่วงเวลามีความสอดคล้องกันเชิงตำแหน่งและเชิงโครงสร้าง ซึ่งเป็นปัจจัยสำคัญต่อความถูกต้องของการคำนวณค่า VBmax ในขั้นตอนถัดไป

3.3.2.2 แปลงภาพเป็นระดับสีเทา (Grayscale Conversion) ภาพจากกล้องจุลทรรศน์ที่ใช้ในการทดลองถูกแปลงจากภาพสีเป็นภาพระดับสีเทา (Grayscale) เพื่อลดความซับซ้อนของข้อมูลเชิงสี และทำให้การวิเคราะห์ภาพมุ่งเน้นไปที่ความแตกต่างของค่าความเข้มพิกเซลซึ่งสะท้อนถึงลักษณะทางกายภาพของผิวหลบได้โดยตรง การแปลงภาพเป็นระดับสีเทาช่วยลดอิทธิพลของสีที่เกิดจากแสงสะท้อน วัสดุ หรือสภาพแวดล้อมระหว่างการบันทึกภาพ ซึ่งอาจส่งผลต่อความไม่สม่ำเสมอของค่าพิกเซล และทำให้การตรวจจ็รอยสึกหรอคลาดเคลื่อน ก่อนการดำเนินการวิเคราะห์ภาพ ได้มีการปรับเทียบสเกลของภาพ (Calibration) โดยใช้เส้นอ้างอิงระยะ 2 มิลลิเมตรที่ปรากฏบนภาพจากกล้องจุลทรรศน์เป็นมาตรฐานในการคำนวณอัตราส่วนระหว่างจำนวนพิกเซลกับระยะจริงในหน่วยมิลลิเมตร (pixel/mm) กระบวนการปรับเทียบดังกล่าวถูกใช้กับทุกภาพตลอดการทดลอง เพื่อให้การแปลงค่าระยะการสึกหรอจากหน่วยพิกเซลเป็นหน่วยทางกายภาพจริงมีความสอดคล้องกัน การดำเนินการปรับเทียบสเกลในขั้นตอนนี้ช่วยลดความคลาดเคลื่อนที่อาจเกิดจากความแตกต่างของกำลังขยายหรือมุมมองของภาพระหว่างการบันทึกแต่ละครั้ง และทำให้ค่าการวัดการสึกหรอที่ได้สามารถนำไปเปรียบเทียบเชิงปริมาณได้อย่างถูกต้องและเชื่อถือได้ในทุกช่วงของการทดลอง

3.3.2.3 คำนวณผลต่างของภาพ (Image Difference) ในการวิเคราะห์การสึกหรอของเครื่องมือตัด ได้มีการคำนวณผลต่างของภาพ (Image Difference) โดยนำภาพในแต่ละช่วงเวลาของการทดลองมาลบกับภาพอ้างอิง (Baseline Image) เพื่อเน้นเฉพาะบริเวณที่เกิดการเปลี่ยนแปลงของผิวหลบอันเนื่องมาจากการสึกหรอ วิธีการดังกล่าวช่วยลดอิทธิพลของลักษณะพื้นผิวเดิมของคมตัดรวมถึงตำหนิหรือร่องรอยจากกระบวนการผลิตที่ไม่ได้เกิดจากการใช้งานจริง ผลลัพธ์จากการคำนวณผลต่างของภาพจะทำให้บริเวณที่เกิดการสึกหรอปรากฏเด่นชัดในรูปของค่าความเข้มพิกเซลที่แตกต่างจากพื้นหลัง ขณะที่บริเวณที่ไม่เกิดการเปลี่ยนแปลงจะมีค่าความแตกต่างต่ำหรือใกล้เคียงศูนย์ เทคนิคนี้จึงช่วยเพิ่มอัตราส่วนสัญญาณต่อสัญญาณรบกวน (Signal-to-Noise Ratio) ของข้อมูลภาพ ทำให้รอยสึกหรอสามารถถูกแยกออกจากพื้นผิวรอบข้างได้อย่างมีประสิทธิภาพมากขึ้น การใช้เทคนิค Image Difference ในขั้นตอนนี้ยังช่วยลดผลกระทบจากความไม่สม่ำเสมอของแสงและความแตกต่างของ

ลักษณะพื้นผิวระหว่างภาพ ทำให้ข้อมูลที่ได้มีความเหมาะสมสำหรับการประมวลผลในขั้นตอนถัดไป เช่น การกรองสัญญาณรบกวนและการตรวจจับขอบเขตของรอยสึกหรอ

3.3.2.4 ลดสัญญาณรบกวนด้วย Gaussian Filtering ภาพผลต่างที่ได้จากขั้นตอนการคำนวณ Image Difference ยังคงมีสัญญาณรบกวนที่เกิดจากความไม่สม่ำเสมอของพื้นผิวแสงสะท้อนจากกล้องจุลทรรศน์ รวมถึงค่า Spike ของพิกเซลที่ไม่เกี่ยวข้องกับการสึกหรอ เพื่อแก้ไขปัญหาดังกล่าว ภาพผลต่างจึงถูกนำมาประมวลผลด้วยตัวกรอง Gaussian Filtering ตัวกรอง Gaussian ทำหน้าที่ปรับค่าความเข้มของพิกเซลโดยพิจารณาค่าเฉลี่ยถ่วงน้ำหนักของพิกเซลรอบข้างตามการกระจายแบบปกติ (Gaussian Distribution) ส่งผลให้สัญญาณรบกวนความถี่สูงถูกลดทอนลง ขณะที่โครงสร้างเชิงต่อเนื่องของรอยสึกหรอยังคงถูกเก็บรักษาไว้ เทคนิคนี้เหมาะสมกับการวิเคราะห์รอยสึกหรอซึ่งมีลักษณะเป็นแนวต่อเนื่องมากกว่าสัญญาณรบกวนที่ปรากฏเป็นจุดกระจัดกระจาย การประมวลผลด้วย Gaussian Filtering ช่วยให้ขอบเขตของรอย Flank Wear มีความเรียบและชัดเจนมากขึ้น ส่งผลให้การตรวจจับตำแหน่งขอบเขตการสึกหรอในขั้นตอนถัดไปมีความแม่นยำสูงขึ้น และลดโอกาสเกิด การตรวจจับผิดพลาดจากสัญญาณรบกวนที่ไม่เกี่ยวข้องกับการสึกหรอของเครื่องมือตัด

3.3.2.5 กำหนดจุดเริ่มต้น (Start Point) เพื่อให้การวัดระยะการสึกหรอของผิวหลบ มีความสอดคล้องและลดความคลาดเคลื่อนที่อาจเกิดขึ้นจากตำแหน่งการวัด ได้มีการกำหนดพิกัดอ้างอิงบริเวณใกล้แนวคมตัดเป็นจุดเริ่มต้นของการวัดระยะการสึกหรอ จุดเริ่มต้นดังกล่าวถูกเลือกให้เป็นตำแหน่งที่มีโครงสร้างทางเรขาคณิตของคมตัดชัดเจนและมีความคงที่ตลอดการทดลอง การกำหนดจุดเริ่มต้นในตำแหน่งเดียวกันสำหรับทุกภาพช่วยให้การวัดการสึกหรอเป็นไปในทิศทางและแนวอ้างอิงที่สม่ำเสมอ ลดผลกระทบจากการเปลี่ยนตำแหน่งของภาพหรือความแตกต่างของมุมมองจากการบันทึกภาพในแต่ละครั้ง หากไม่มีการกำหนดจุดเริ่มต้นอย่างเป็นระบบ การวัดระยะการสึกหรออาจเกิดความคลาดเคลื่อนจากการเปลี่ยนแนวการวัด ซึ่งส่งผลโดยตรงต่อค่าการคำนวณ VBmax ดังนั้น การกำหนดจุดเริ่มต้นใกล้แนวคมตัดจึงเป็นขั้นตอนสำคัญที่ช่วยเพิ่มความถูกต้องและความสามารถในการทำซ้ำของกระบวนการวัดการสึกหรอเชิงปริมาณในงานวิจัยนี้

3.3.2.6 ตรวจสอบจุดสิ้นสุดของรอยสึกหรอ (End Point Detection) การตรวจหาจุดสิ้นสุดของรอยสึกหรอบนผิวหลบของคมตัดดำเนินการโดยวิเคราะห์การเปลี่ยนแปลงของค่าความเข้มพิกเซลจากภาพที่ผ่านการประมวลผลแล้วตามทิศทางการวัดที่กำหนด โดยเริ่มต้นจากจุดอ้างอิงใกล้แนวคมตัดและทำการสำรวจค่าความเข้มพิกเซลต่อเนื่องไปยังบริเวณด้านนอกของผิวหลบ จุดสิ้นสุดของรอย Flank Wear ถูกระบุจากตำแหน่งที่ค่าความเข้มพิกเซลมีการเปลี่ยนแปลงอย่างมีนัยสำคัญเมื่อเทียบกับค่าพื้นหลัง ซึ่งสะท้อนถึงขอบเขตระหว่างบริเวณที่เกิดการสึกหรอและพื้นผิวที่ยังไม่ถูกใช้งาน การกำหนดจุดสิ้นสุดด้วยวิธีนี้ช่วยให้สามารถตรวจจับขอบเขตการสึกหรอได้อย่างเป็นระบบและสอดคล้องกันในทุกภาพ วิธีการตรวจจับจุดสิ้นสุดดังกล่าวช่วยลดอิทธิพลของการตัดสินด้วยสายตาและ


เพิ่มความสามารถในการทำซ้ำของกระบวนการวัด โดยทำให้ตำแหน่งปลายของรอยสึกหรือถูกกำหนดจากข้อมูลเชิงปริมาณของค่าพิกเซลโดยตรง ซึ่งเป็นปัจจัยสำคัญต่อความแม่นยำของการคำนวณค่า VBmax ในขั้นตอนถัดไป

3.3.2.7 คำนวณระยะทางในหน่วยพิกเซล (Pixel Distance Calculation) หลังจากกำหนดตำแหน่งจุดเริ่มต้นและจุดสิ้นสุดของรอยสึกหรือแล้ว ได้ทำการคำนวณระยะทางระหว่างจุดทั้งสองในหน่วยพิกเซล โดยอาศัยตำแหน่งพิกัดของจุดเริ่มต้นและจุดสิ้นสุดบนภาพที่ผ่านการประมวลผลระยะทางดังกล่าวสะท้อนถึงความยาวเชิงภาพของรอย Flank Wear บนผิวหลบของคมตัด การคำนวณระยะทางในหน่วยพิกเซลช่วยให้สามารถวัดการสึกหรือได้โดยไม่ขึ้นกับหน่วยทางกายภาพในขั้นตอนนี้ ซึ่งเหมาะสมสำหรับการประมวลผลภาพและการวิเคราะห์เชิงอัลกอริทึม การใช้หน่วยพิกเซลเป็นค่ากลางยังช่วยให้การวัดมีความสม่ำเสมอในทุกภาพก่อนการแปลงเป็นหน่วยจริงในขั้นตอนถัดไป ค่าระยะทางในหน่วยพิกเซลที่ได้จากขั้นตอนนี้ถูกนำไปใช้เป็นข้อมูลพื้นฐานสำหรับการแปลงเป็นหน่วยมิลลิเมตรเพื่อประเมินระดับการสึกหรือเชิงปริมาณของเครื่องมือตัดในรูปของค่า VBmax


3.3.2.8 แปลงหน่วยพิกเซลเป็นมิลลิเมตร (Pixel-to-mm Conversion) ระยะการสึกหรือที่คำนวณได้ในหน่วยพิกเซลจากขั้นตอนก่อนหน้า ถูกนำมาแปลงเป็นหน่วยมิลลิเมตรโดยอ้างอิงอัตราส่วนระหว่างจำนวนพิกเซลกับระยะจริงที่ได้จากการเปรียบเทียบสเกลของภาพกล้องจุลทรรศน์ โดยใช้เส้นอ้างอิงระยะ 2 มิลลิเมตรที่ปรากฏบนภาพเป็นมาตรฐานในการคำนวณค่าอัตราส่วน (pixel/mm) การแปลงหน่วยดังกล่าวทำให้ค่าการสึกหรือที่ได้สามารถแสดงผลในหน่วยทางกายภาพจริง ซึ่งมีความหมายเชิงวิศวกรรมและสามารถนำไปเปรียบเทียบกับเกณฑ์มาตรฐานหรือผลจากงานวิจัยอื่นได้อย่างเหมาะสม ค่าระยะทางหลังการแปลงหน่วยนี้ถูกกำหนดเป็นค่า VBmax ซึ่งแสดงถึงความกว้างสูงสุดของรอย Flank Wear บนผิวหลบของคมตัด การใช้ค่า VBmax เป็นตัวชี้วัดเชิงปริมาณของการสึกหรือช่วยให้สามารถติดตามพฤติกรรมการเสื่อมสภาพของเครื่องมือตัดตามอายุการใช้งานได้อย่างเป็นระบบ และทำให้ผลการวัดมีความสอดคล้องกับแนวปฏิบัติที่ใช้กันอย่างแพร่หลายในงานวิจัยด้านการติดตามสภาพเครื่องมือตัด

3.3.2.9 ส่งออกผลลัพธ์ในรูปแบบตารางข้อมูล ค่าการสึกหรือเชิงปริมาณในรูปของค่า VBmax ที่ได้จากการประมวลผลภาพในแต่ละช่วงการทดลอง ถูกจัดเก็บในรูปแบบตารางข้อมูล โดยแต่ละแถวแทนหนึ่งช่วงของการทดลองหรือหนึ่งภาพจากกล้องจุลทรรศน์ ขณะที่คอลัมน์ข้อมูลประกอบด้วยลำดับการใช้งานหรือจำนวนรอบ และค่าการสึกหรือ VBmax ที่คำนวณได้ การจัดเก็บข้อมูลในลักษณะตารางช่วยให้สามารถนำข้อมูลไปใช้ในการวิเคราะห์เชิงสถิติได้อย่างเป็นระบบ รวมถึงการวิเคราะห์ความสัมพันธ์เชิงแนวโน้มด้วยแบบจำลอง Linear Regression และการเปรียบเทียบกับผลการตรวจจับความผิดปกติจากขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ในขั้นตอนการวิเคราะห์ถัดไป นอกจากนี้ การส่งออกข้อมูลในรูปแบบไฟล์ยังช่วยให้กระบวนการวิเคราะห์สามารถทำซ้ำได้ และเอื้อต่อ

การตรวจสอบความถูกต้องของผลลัพธ์ รวมถึงการนำข้อมูลไปประยุกต์ใช้กับเครื่องมือวิเคราะห์หรือซอฟต์แวร์อื่นในอนาคต



รูปที่ 3.15 Workflow ของกระบวนการคำนวณค่า VBmax ด้วยเทคนิคการประมวลผลภาพดิจิทัล



รูปที่ 3.16 ตัวอย่างการตรวจวัดค่า VB ของเครื่องมือตัดรูที่ 140

3.3.3 การวิเคราะห์แรงสั่นสะเทือน

สัญญาณการสั่นสะเทือน (Vibration Signal) ที่ได้จากการทดลองถูกนำมาวิเคราะห์ด้วยวิธีทางสถิติ เพื่อประเมินความสัมพันธ์ระหว่างค่าการสั่นสะเทือนกับระดับการสึกหรอของเครื่องมือตัด โดยใช้การทดสอบความแปรปรวนแบบทางเดียว (One-way ANOVA) และการวิเคราะห์ค่าสหสัมพันธ์ (Correlation Analysis) ผลการวิเคราะห์พบว่า ไม่ปรากฏความสัมพันธ์อย่างมีนัยสำคัญทางสถิติ ระหว่างค่าการสั่นสะเทือนกับค่า Flank Wear (VBmax) ในทุกเงื่อนไขการทดลอง แสดงให้เห็นว่าสัญญาณการสั่นสะเทือนที่วัดได้ในงานวิจัยนี้ไม่สามารถสะท้อนการเสื่อมสภาพของเครื่องมือตัดได้อย่างชัดเจน เมื่อเทียบกับแรงตัด

ดังนั้น สัญญาณการสั่นสะเทือนจึงถูกนำมาใช้เป็นเพียง ข้อมูลประกอบ (Supporting Information) ในการวิเคราะห์ และไม่ถูกเลือกเป็นตัวแปรหลัก (Primary Feature) สำหรับการสร้างแบบจำลองตรวจจับความผิดปกติในงานวิจัยนี้


3.3.4 การตรวจจับความผิดปกติด้วย Isolation Forest

ขั้นตอนวิธีป่าแยกตัว (Isolation Forest) เป็นเทคนิคการตรวจจับความผิดปกติที่อยู่ในกลุ่มการเรียนรู้แบบไม่มีผู้สอน (Unsupervised Learning) ซึ่งมีแนวคิดพื้นฐานแตกต่างจากวิธีตรวจจับความผิดปกติแบบดั้งเดิมที่อาศัยการวัดความหนาแน่นของข้อมูลหรือระยะห่างระหว่างจุดข้อมูล วิธีป่าแยกตัวมุ่งเน้นการแยกจุดข้อมูลออกจากกลุ่มข้อมูลโดยตรงผ่านการแบ่งข้อมูลแบบสุ่ม หลักการสำคัญของ Isolation Forest คือ จุดข้อมูลที่มีลักษณะผิดปกติมักถูกแยกออกจากกลุ่มข้อมูลปกติได้ง่ายกว่า และต้องใช้จำนวนขั้นตอนในการแบ่งข้อมูลน้อยกว่า เมื่อเปรียบเทียบกับจุดข้อมูลทั่วไป ในกระบวนการสร้างแบบจำลอง จะมีการสร้างต้นไม้หลายต้นซึ่งเรียกว่า Isolation Trees โดยในแต่ละต้นไม้จะมีการสุ่มเลือกตัวแปรและค่าสำหรับการแบ่งข้อมูลออกเป็นสองส่วนซ้ำ ๆ จนกระทั่งจุดข้อมูลถูกแยกออกมาเป็นโหนดเดียว ระดับความผิดปกติของข้อมูลถูกประเมินจากความยาวของเส้นทาง (Path Length) ซึ่งหมายถึงจำนวนขั้นตอนตั้งแต่โหนดรากจนถึงโหนดที่สามารถแยกจุดข้อมูลนั้นออกมาได้ หากจุดข้อมูลใดมีค่า Path Length สั้น แสดงว่าจุดข้อมูลนั้นถูกแยกออกได้ง่ายและมีแนวโน้มเป็นค่าผิดปกติ ในขณะที่จุดข้อมูลที่ต้องใช้จำนวนขั้นตอนในการแบ่งมากกว่าจะถูกจัดอยู่ในกลุ่มข้อมูลปกติ ด้วยคุณสมบัติดังกล่าว Isolation Forest จึงเหมาะสมสำหรับการตรวจจับความผิดปกติในข้อมูลจากระบบการผลิต ซึ่งมักไม่มีข้อมูลป้ายกำกับล่วงหน้าและมีลักษณะการเปลี่ยนแปลงที่ไม่เป็นเชิงเส้น งานวิจัยนี้จึงเลือกใช้ Isolation Forest เพื่อประเมินความผิดปกติของสัญญาณแรงตัด โดยใช้ค่าคะแนนความผิดปกติ (Anomaly Score) เป็นตัวบ่งชี้ระดับความเบี่ยงเบนของพฤติกรรมการทำงานของเครื่องมือตัดในแต่ละรอบการใช้งาน ในการใช้งาน Isolation Forest ผู้วิจัยได้นำข้อมูลแรงตัดในแนวนอน Z ที่เจาะรอบละ 10 รู ดังตัวอย่างรูปที่ 3.17 ที่เกิดขึ้นจริงตามจากรูปที่ 3.16 ที่เป็นข้อมูลจริงมาหาค่าเฉลี่ยต่อรูจากไฟล์ averaged_forces_by_cycle.csv โดยตัวอย่างโครงสร้างข้อมูลจากไฟล์ดังกล่าว แสดงไว้ในรูปที่ 3.18

ซึ่งได้จากขั้นตอนการทำ Time-based averaging มาใช้เป็นตัวแปรอินพุตหลัก โดยอ่านข้อมูลผ่านคำสั่ง readtable และเลือกเฉพาะคอลัมน์ Avg_Fz และหมายเลขรู (Hole) สำหรับวิเคราะห์ จากนั้นเรียกใช้ ฟังก์ชัน iforest() ของ MATLAB เพื่อสร้างแบบจำลอง Isolation Forest และคำนวณค่าคะแนนความผิดปกติ (Anomaly Score) ดังตัวอย่างโค้ดรูปที่ 20 โดยกำหนดค่า Contamination Fraction = 0.10 เพื่อให้แบบจำลองถือว่าประมาณ 10% แรกของชุดข้อมูลที่มีคะแนนผิดปกติสูงสุดเป็นค่าผิดปกติ เริ่มต้น ก่อนจะนำค่าคะแนนความผิดปกติ (scores) ไปประเมินร่วมกับเกณฑ์แบบควอนไทล์ในหัวข้อ 3.3.5 อีกครั้งเพื่อกำหนดเส้นแบ่งระหว่างสภาวะปกติและผิดปกติอย่างเหมาะสม

	A	B	C	D	E	F	G	H	I
19	Time	Mz	Fz	Fx	Fy	Extra 1	Extra 2	Extra 3	Extra 4
20	s	Nm	N	N	N	N	N	N	N
21	0	0.000436	-0.17003	-0.09112	-0.03466	0	0	0	0
22	0.001	-0.00218	-0.28338	-0.11139	-0.03313	0	0	0	0
23	0.002	-0.00044	-0.31826	-0.11401	-0.03357	0	0	0	0
24	0.003	0	-0.20054	-0.08392	-0.03837	0	0	0	0
25	0.004	-0.00131	-0.19618	-0.10158	-0.02812	0	0	0	0
26	0.005	0	-0.17875	-0.07673	-0.01286	0	0	0	0
27	0.006	-0.00174	-0.19183	-0.09548	-0.05014	0	0	0	0
28	0.007	-0.00044	-0.06539	-0.04817	0.012643	0	0	0	0
29	0.008	0.000436	0.091553	0.048392	-0.02441	0	0	0	0
30	0.009	0.003052	0.322614	0.127302	0.046212	0	0	0	0
31	0.01	0.002616	0.427246	0.153024	0.040109	0	0	0	0
32	0.011	0.003488	0.440325	0.142779	0.051662	0	0	0	0
33	0.012	0.003052	0.457764	0.154986	0.028556	0	0	0	0
34	0.013	0.003924	0.514439	0.155204	0.047738	0	0	0	0
35	0.014	0.001744	0.475202	0.162833	0.036185	0	0	0	0
36	0.015	0.003052	0.431606	0.12752	0.026376	0	0	0	0

รูปที่ 3.17 ตัวอย่างข้อมูลจากไฟล์ averaged_forces_by_cycle.csv ประกอบด้วยข้อมูลเวลา (Time) และค่าแรงตัดเฉื่อย ได้แก่ Fz, Fx, Fy และโมเมนต์ Mz ซึ่งถูกนำมาใช้เป็นข้อมูลอินพุตสำหรับการตรวจจับความผิดปกติด้วย Isolation Forest



รูปที่ 3.18 สัญญาณแรงตัด Fz ตามเวลาในระหว่างการเจาะต่อเนื่องจำนวน 10 รู

	A	B	C	D	E	F	G
1	HoleNumber	AvgFz	AvgMz	MovAvgFz	MovAvgMz	Vibration_MAS	
2	1	656.6685478	1.800791252	741.2805796	2.040699205	0.46	
3	2	753.9844371	2.226954889	791.8005027	2.106156733	0.44	
4	3	813.1887538	2.094351474	823.378529	2.100086541	0.26	
5	4	943.3602721	2.30252932	893.0869294	2.143040178	0.2	
6	5	949.6906341	2.075805769	948.221305	2.161399077	0.26	
7	6	1005.21055	2.015559436	994.2239973	2.265501087	0.3	
8	7	1029.656315	2.318749387	1015.945176	2.298910495	0.32	
9	8	1043.202215	2.614861522	1050.281188	2.377346169	0.32	
10	9	1051.966166	2.46957636	1002.438492	2.375234167	0.3	
11	10	1121.370694	2.467984138	956.1677124	2.346610068	0.2	
12	11	765.9970697	2.00499943	916.5024401	2.190310056	0.18	
13	12	798.3024167	2.175628888	906.8567275	2.172890822	0.2	
14	13	844.8758535	1.833361465	885.624381	2.099557204	0.2	
15	14	1003.737603	2.382480187	945.4498485	2.100826341	0.24	
16	15	1015.208962	2.10131605	1009.285911	2.123536342	0.26	
17	16	1065.124408	2.011345116	1064.780423	2.208790204	0.22	
18	17	1117.48273	2.289178894	1104.841237	2.211910224	0.2	
19	18	1122.34841	2.259630775	1134.117114	2.252045731	0.2	
20	19	1204.041675	2.398080288	1080.817546	2.297153693	0.16	
21	20	1161.588245	2.201002585	1011.6306	2.210515074	0.28	

รูปที่ 3.19 ข้อมูลเมื่อทำการแปลงค่าเฉลี่ยให้เป็นแต่ละรูการเจาะ

```

data = readtable('averaged_forces_by_cycle.csv');
features = data.Avg_Fz;
holes = data.Hole;

rng(1); % กำหนดค่า seed เพื่อให้ผลทดลองทำซ้ำได้
[Mdl, anomalyFlags, scores] = iforest( ...
    features, ...
    'ContaminationFraction', 0.10);

```


รูปที่ 3.20 แสดงตัวอย่างโค้ดการใช้วิธีป่าแยกตัว

3.3.5 การตรวจจับความผิดปกติด้วย Local Outlier Factor (LOF)

นอกเหนือจากการใช้ขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ซึ่งเป็นวิธีหลักในการตรวจจับความผิดปกติของข้อมูลแรงตึงในงานวิจัยนี้ ผู้วิจัยยังได้พิจารณาและทดลองใช้วิธีการตรวจจับความผิดปกติแบบไม่มีผู้สอน (Unsupervised Anomaly Detection) อื่นเพิ่มเติม ได้แก่ วิธี Local Outlier Factor (LOF) เพื่อเพิ่มความครอบคลุมในการพิจารณาแนวทางการตรวจจับความผิดปกติที่อาศัยแนวคิดที่แตกต่างกัน Local Outlier Factor เป็นวิธีการตรวจจับความผิดปกติที่อาศัยแนวคิดด้านความหนาแน่นเชิงพื้นที่ (Local Density) ของข้อมูล โดยพิจารณาความสัมพันธ์ระหว่างจุดข้อมูลหนึ่ง

กับกลุ่มเพื่อนบ้านใกล้เคียง หากจุดข้อมูลใดมีค่าความหนาแน่นต่ำกว่าบริเวณโดยรอบอย่างมีนัยสำคัญ จุดข้อมูลดังกล่าวจะถูกจัดเป็นค่าผิดปกติ วิธีการนี้ไม่จำเป็นต้องอาศัยข้อมูลที่มีการกำหนดคลาស់ล่วงหน้า และสามารถประยุกต์ใช้ได้กับข้อมูลที่มีการกระจายไม่สม่ำเสมอ ซึ่งสอดคล้องกับลักษณะของข้อมูล แรงตัดเชิงเวลาในกระบวนการตัดเฉือนด้วยเครื่องจักร CNC ในการทดลอง ผู้วิจัยได้นำวิธี LOF มาประยุกต์ใช้กับข้อมูลแรงตัด โดยวิเคราะห์ข้อมูลตามลำดับการเจาะรู เพื่อประเมินความสามารถของวิธี LOF ในการระบุจุดข้อมูลที่มีพฤติกรรมผิดปกติ ผลการทดลองแสดงให้เห็นว่าวิธี LOF สามารถระบุจุดข้อมูลที่มีลักษณะผิดปกติได้ในช่วงลำดับการเจาะรูที่ใกล้เคียงกับผลลัพธ์ที่ได้จากขั้นตอนวิธีป่าแยกตัว ดังแสดงในรูปที่ 3.20 และสรุปผลการตรวจจับไว้ในตารางที่ 2 ความสอดคล้องของผลลัพธ์ที่ได้จากทั้งสองวิธีสะท้อนให้เห็นว่าข้อมูลแรงตัดจากกระบวนการผลิตจริงมีโครงสร้างของความผิดปกติที่สามารถถูกตรวจจับได้ด้วยวิธีการแบบไม่มีผู้สอนที่มีแนวคิดแตกต่างกัน ทั้งนี้ การนำวิธี LOF มาทดลองใช้ในงานวิจัยนี้มีวัตถุประสงค์เพื่อแสดงให้เห็นถึงความเป็นไปได้ในการประยุกต์ใช้วิธีการตรวจจับความผิดปกติแบบไม่มีผู้สอนที่หลากหลายกับข้อมูลแรงตัดเชิงเวลา โดยไม่ได้มุ่งเน้นการเปรียบเทียบประสิทธิภาพระหว่างวิธีการ

ดังนั้น งานวิจัยนี้จึงเลือกใช้ขั้นตอนวิธีป่าแยกตัวเป็นวิธีหลักในการตรวจจับความผิดปกติ เนื่องจากมีความเหมาะสมต่อการประมวลผลข้อมูลเชิงเวลาและมีความสะดวกในการนำไปประยุกต์ใช้กับข้อมูลจากกระบวนการผลิตจริง ขณะที่วิธี Local Outlier Factor ถูกใช้เป็นแนวทางเสริมเพื่อสนับสนุนแนวคิดว่าการตรวจจับความผิดปกติแบบไม่มีผู้สอนสามารถนำมาประยุกต์ใช้กับปัญหานี้ได้อย่างหลากหลายและมีความเหมาะสมในเชิงวิธีวิทยา



รูปที่ 3.21 ผลการตรวจจับความผิดปกติของข้อมูลแรงตัดในทิศทางแกน Z ด้วยวิธี Local Outlier Factor (LOF) ตามลำดับการเจาะรู

ตารางที่ 3.2 การเปรียบเทียบผลการตรวจจับความผิดปกติระหว่างวิธี Isolation Forest และวิธี Local Outlier Factor

วิธีการตรวจจับความผิดปกติ	ระยะเวลาแจ้งเตือนล่วงหน้า (จำนวนรู)	จำนวนการตรวจจับผิดพลาด (รูที่ 1-50)	รูสุดท้ายที่แจ้งเตือน
Isolation Forest	3	5	103
LOF	16	4	90

3.3.6 การกำหนดค่า Quantile Threshold

3.3.6.1 การกำหนดค่า Quantile Threshold แบบปรับด้วยผู้วิจัย (Manual Adjustment)

ในการกำหนดเส้นแบ่งระหว่างสภาวะปกติและสภาวะผิดปกติจากค่าคะแนนความผิดปกติ (Anomaly Score) งานวิจัยนี้ใช้วิธีการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) เป็นเกณฑ์การตัดสินใจ โดยคำนวณค่าเกณฑ์จากการกระจายตัวของ Anomaly Score ทั้งหมดตามสมการที่ 3.2 (Hyndman and Fan, 1996)

$$T_q = Q_q(\text{Score}) \quad (3.2)$$

เมื่อ Q_q คือ ค่า quantile ที่ระดับ q และ Score คือ ค่าคะแนนความผิดปกติจาก Isolation Forest

ในการทดลอง ผู้วิจัยได้ทดสอบค่า quantile หลายระดับ $q = 0.98, 0.99, 0.995, 0.999$ และ 0.9999 เพื่อเปรียบเทียบผลของแต่ละค่าเกณฑ์ต่อประสิทธิภาพในการตรวจจับความผิดปกติ โดยพิจารณาจากความสามารถในการตรวจจับล่วงหน้า (Early Detection) ร่วมกับอัตราการแจ้งเตือนผิดพลาด (False Alarm) การคำนวณค่าเกณฑ์ Quantile Threshold ดำเนินการใน MATLAB ตามตัวอย่างโค้ดดังรูปที่ 3.20

```
qManual = 0.98;
thr = quantile(scores, qManual);
anomalyFlags = scores >= thr;
```

รูปที่ 3.22 แสดงตัวอย่าง การคำนวณค่าเกณฑ์ Quantile Threshold

เพื่อป้องกันการแจ้งเตือนผิดพลาดในช่วงต้นกระบวนการตัด (early false alarm) งานวิจัยนี้กำหนดช่วงเวลาขั้นต่ำก่อนเริ่มพิจารณาผิดปกติ โดยพิจารณาเฉพาะ anomaly ที่เกิดหลังเวลาตามเกณฑ์ที่กำหนดโดยตัวอย่างโค้ดจากภาพที่ 3.21

```
minValidTime = 10000;
validIdx = find(T.timeSec > minValidTime);
firstIdx = validIdx(anomalyFlags(validIdx));
```

รูปที่ 3.23 กำหนดช่วงเวลาขั้นต่ำก่อนเริ่มพิจารณาผิดปกติ

จากนั้นดำเนินการคำนวณระยะเวลาเตือนล่วงหน้า (Lead time) โดยนิยามจากผลต่างระหว่างช่วงเวลาที่ระบบตรวจพบ anomaly ครั้งแรกกับช่วงเวลาที่เครื่องมือเกิดความเสียหายจริง โดยคำนวณได้จาก

$$\text{leadTimeSec} = \text{failureTimeSec} - \text{alertTimeSec};$$

ค่า quantile ที่เหมาะสมจะถูกเลือกจากค่าที่สามารถตรวจจับความผิดปกติได้ตั้งแต่ระยะเริ่มต้นของการเสื่อมสภาพ ขณะเดียวกันยังรักษาระดับ False Alarm ให้อยู่ในค่าต่ำ เพื่อให้ระบบมีความสมดุลระหว่างความไวในการตรวจจับและความน่าเชื่อถือของการแจ้งเตือน

3.3.6.2 การกำหนดค่า Quantile Threshold แบบปรับอัตโนมัติ (Automatic/Adaptive Adjustment)

นอกเหนือจากการกำหนดค่าเกณฑ์แบบคอนไทร์โดยอาศัยการปรับค่าด้วยผู้วิจัยแล้ว แนวคิดของการกำหนดค่า Quantile Threshold แบบปรับอัตโนมัติ (Automatic หรือ Adaptive Adjustment) เป็นอีกแนวทางหนึ่งที่มีความสนใจในการพัฒนาระบบตรวจจับความผิดปกติ โดยมีวัตถุประสงค์เพื่อลดการพึ่งพาการเลือกค่าพารามิเตอร์ด้วยมนุษย์ และเพิ่มความสามารถในการปรับตัวของระบบให้เหมาะสมกับข้อมูลที่เปลี่ยนแปลงไปตามเวลา การกำหนดค่า Quantile Threshold แบบปรับอัตโนมัติอาศัยหลักการในการคำนวณค่าเกณฑ์จากการกระจายตัวของค่าคะแนนความผิดปกติ (Anomaly Score) โดยมีการปรับค่าระดับคอนไทร์แบบพลวัต (Dynamic Quantile) ตามลักษณะของข้อมูลในแต่ละช่วงเวลา เช่น การคำนวณค่า quantile จากข้อมูลในช่วงหน้าต่างเวลาเคลื่อนที่ (Sliding Window) หรือการปรับค่าเกณฑ์ใหม่เมื่อมีข้อมูลสะสมเพิ่มขึ้น วิธีการดังกล่าวช่วยให้ค่าเกณฑ์

สามารถตอบสนองต่อการเปลี่ยนแปลงของพฤติกรรมสัญญาณในระยะยาว และลดปัญหาการแจ้งเตือนผิดพลาดที่อาจเกิดจากการใช้ค่าเกณฑ์คงที่ตลอดกระบวนการ

ในบริบทของงานวิจัยนี้ แนวคิดการกำหนดค่า Quantile Threshold แบบปรับอัตโนมัติถูกนำเสนอเพื่อแสดงให้เห็นถึงทิศทางการพัฒนาระบบตรวจจับความผิดปกติในเชิงแนวคิด โดยมุ่งเน้นความสามารถในการปรับตัวของค่าเกณฑ์ให้เหมาะสมกับสภาพการทำงานจริง อย่างไรก็ตามในการดำเนินการทดลอง ผู้วิจัยเลือกใช้การกำหนดค่า Quantile Threshold แบบปรับด้วยผู้วิจัย (Manual Adjustment) เพื่อให้สามารถควบคุมและวิเคราะห์ผลกระทบของค่าระดับควอนไทล์ที่แตกต่างกันต่อประสิทธิภาพการตรวจจับความผิดปกติได้อย่างชัดเจน

ดังนั้น การนำเสนอแนวคิดการกำหนดค่า Quantile Threshold แบบปรับอัตโนมัติในหัวข้อนี้มีวัตถุประสงค์เพื่ออธิบายนิยามและความแตกต่างระหว่างการปรับค่าเกณฑ์ด้วยผู้วิจัยและการปรับค่าเกณฑ์โดยอัตโนมัติ ซึ่งช่วยให้ขอบเขตและความหมายของคำว่า adaptive quantile ในงานวิจัยนี้มีความชัดเจน และสามารถใช้เป็นแนวทางสำหรับการพัฒนาระบบตรวจจับความผิดปกติในงานวิจัยต่อยอดในอนาคต

3.3.7 ความแตกต่างระหว่างการพยากรณ์ (Prediction) และการตรวจจับความผิดปกติ (Anomaly Detection)

ในการวิเคราะห์ข้อมูลจากกระบวนการผลิตด้วยเครื่องจักร CNC งานวิจัยนี้ใช้ทั้งแนวคิดการพยากรณ์ (Prediction) และการตรวจจับความผิดปกติ (Anomaly Detection) ซึ่งเป็นแนวทางการวิเคราะห์ข้อมูลที่มีวัตถุประสงค์และบทบาทแตกต่างกันอย่างชัดเจน แม้ว่าทั้งสองแนวทางจะอาศัยข้อมูลจากแหล่งเดียวกัน เช่น แรงตัดและสัญญาณการสั่นสะเทือน แต่มีเป้าหมายในการตีความข้อมูลที่แตกต่างกัน การพยากรณ์ (Prediction) เป็นการสร้างแบบจำลองเชิงเวลาเพื่อคาดการณ์ค่าของตัวแปรเป้าหมายในอนาคตจากแนวโน้มของข้อมูลในอดีต โดยมุ่งเน้นการอธิบายความสัมพันธ์เชิงปริมาณระหว่างตัวแปรและการเปลี่ยนแปลงของสภาพระบบตามเวลา ในงานวิจัยนี้ การพยากรณ์ถูกนำมาใช้เพื่อประเมินแนวโน้มการสึกหรอของเครื่องมือตัด โดยอาศัยแบบจำลองเชิงสถิติ เช่น Linear Regression เพื่อคาดการณ์พฤติกรรมของค่าการสึกหรอหรือค่าที่เกี่ยวข้องกับแรงตัดตามอายุการใช้งานของหัวเจาะ ผลลัพธ์จากการพยากรณ์ช่วยให้สามารถประมาณช่วงเวลา que เครื่องมือตัดมีแนวโน้มเข้าใกล้สภาวะเสื่อมสภาพได้ล่วงหน้า

ในขณะที่การตรวจจับความผิดปกติ (Anomaly Detection) มีวัตถุประสงค์เพื่อระบุช่วงเวลาหรือจุดข้อมูลที่มีพฤติกรรมแตกต่างไปจากรูปแบบปกติของระบบ โดยไม่จำเป็นต้องคาดการณ์ค่าล่วงหน้า การตรวจจับความผิดปกติเน้นการแยกแยะสภาวะผิดปกติออกจากสภาวะปกติจากรูปแบบการกระจายของข้อมูล ในงานวิจัยนี้ การตรวจจับความผิดปกติถูกนำมาใช้เพื่อระบุสัญญาณเตือนของการเสื่อมสภาพของเครื่องมือตัดในระยะเริ่มต้น โดยใช้วิธีการเรียนรู้แบบไม่มีผู้สอน เช่น ขั้นตอนวิธีป่าแยกตัว (Isolation

Forest) ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) เพื่อจำแนกช่วงเวลาที่สำคัญตามแรงตัดมีพฤติกรรมผิดปกติ

ความแตกต่างที่สำคัญระหว่างการพยากรณ์และการตรวจจับความผิดปกติอยู่ที่ลักษณะของผลลัพธ์และบทบาทในการตัดสินใจ การพยากรณ์ให้ผลลัพธ์เป็นค่าที่คาดการณ์ในอนาคต ซึ่งเหมาะสำหรับการวางแผนและการประเมินแนวโน้มในระยะยาว ขณะที่การตรวจจับความผิดปกติให้ผลลัพธ์ในลักษณะของสัญญาณเตือนหรือการระบุเหตุการณ์ผิดปกติที่เกิดขึ้นจริงในข้อมูล ซึ่งเหมาะสำหรับการเฝ้าระวังและการแจ้งเตือนแบบใกล้เคียงเวลาจริง ในบริบทของงานวิจัยนี้ การพยากรณ์และการตรวจจับความผิดปกติไม่ได้ถูกนำมาใช้เพื่อเปรียบเทียบประสิทธิภาพระหว่างกัน แต่ถูกออกแบบให้ทำหน้าที่เสริมกัน การพยากรณ์ช่วยอธิบายแนวโน้มการเสื่อมสภาพของเครื่องมือตัดตามเวลา ขณะที่การตรวจจับความผิดปกติช่วยระบุจุดเปลี่ยนหรือสัญญาณเตือนในช่วงที่พฤติกรรมของแรงตัดเริ่มเบี่ยงเบนจากสภาวะปกติ การใช้ทั้งสองแนวทางร่วมกันจึงช่วยให้สามารถทำความเข้าใจพฤติกรรมการเสื่อมสภาพของเครื่องมือตัดได้อย่างรอบด้าน และสนับสนุนการพัฒนากระบวนการบำรุงรักษาเชิงคาดการณ์ที่มีความน่าเชื่อถือมากยิ่งขึ้น



บทที่ 4

ผลการวิจัยและอภิปรายผล

4.1 ผลการทดลองและการเตรียมข้อมูล


การทดลองในงานวิจัยนี้ดำเนินการเพื่อรวบรวมข้อมูลแรงตัด (Cutting Force) และแรงบิด (Torque) ที่เกิดขึ้นระหว่างกระบวนการเจาะด้วยเครื่องจักรควบคุมเชิงตัวเลขด้วยคอมพิวเตอร์แบบ 5 แกน (5-axis CNC) รุ่น DMG Mori DMU-50 ซึ่งมีความสามารถในการตัดเฉือนชิ้นงานที่ต้องการความแม่นยำสูง ข้อมูลที่เก็บได้ประกอบด้วยสัญญาณแรงในแนวแกน X, Y, Z และแรงบิดในแนวแกน Z โดยทำการเก็บข้อมูลระหว่างการเจาะวัสดุสองประเภท ได้แก่ เหล็ก (Steel) และอะลูมิเนียม (Aluminium) รวมทั้งหมด 240 รู เพื่อให้ได้ข้อมูลที่เชื่อมโยงกับสภาพจริงของเครื่องมือตัด (Cutting Tool) งานวิจัยนี้ได้บันทึกภาพการสึกหรอของคมตัดด้วยกล้องจุลทรรศน์แบบสเตอริโอทุก ๆ 10 รูของการเจาะ เพื่อใช้เปรียบเทียบกับค่ากำลังตัดที่เปลี่ยนแปลงตามจำนวนรอบการใช้งาน นอกจากนี้ยังมีการวัดแรงสั่นสะเทือนของสปินเดิลด้วยเซนเซอร์ Tensmars ST-140 เพื่อตรวจสอบสถานะการทำงานของเครื่องจักรควบคุมกันไป ซึ่งข้อมูลทั้งหมดจะถูกบันทึกในรูปแบบดิจิทัลและจัดเก็บในไฟล์ CSV สำหรับการวิเคราะห์ภายหลังด้วย MATLAB

4.1.1 ผลการเก็บข้อมูลแรงตัดและแรงบิดจากเครื่อง

จากการเก็บข้อมูลแรงในแกนแนวตั้ง (Fz) และแรงบิดในแนวแกนหมุน (Mz) ระหว่างกระบวนการเจาะด้วยเครื่องจักร CNC แบบ 5 แกน พบว่าแรงตัดที่เกิดขึ้นแตกต่างกันอย่างชัดเจนระหว่างวัสดุแต่ละชนิด โดยวัสดุประเภทเหล็กต้องใช้แรงเจาะสูงกว่าอะลูมิเนียมอย่างมีนัยสำคัญ ค่าแรงตัดเฉลี่ยในแกน Fz สำหรับเหล็กอยู่ในช่วงประมาณ 750–850 นิวตัน ในขณะที่อะลูมิเนียมอยู่ในช่วงประมาณ 400–500 นิวตัน ผลลัพธ์ดังกล่าวสะท้อนถึงความแตกต่างด้านสมบัติทางกลของวัสดุ โดยเหล็กมีความแข็งแรงและความต้านทานต่อการตัดเฉือนสูงกว่าอะลูมิเนียม เมื่อพิจารณาแนวโน้มของ

แรงตัดตามจำนวนรูที่ทำการเจาะ พบว่าแรงตัดมีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องในทั้งสองวัสดุ ซึ่งสอดคล้องกับพฤติกรรมของการเสื่อมสภาพของเครื่องมือตัด กล่าวคือ เมื่อคมตัดเริ่มสึกหรอหรือที่อแรงที่เครื่องจักรต้องใช้ในการตัดเฉือนจะเพิ่มสูงขึ้นตามลำดับเวลา แนวโน้มดังกล่าวปรากฏอย่างชัดเจนในกราฟเปรียบเทียบค่าแรงตัดเฉลี่ยหลังการกรองสัญญาณ (Smoothed Average Fz) ระหว่างเหล็กและอะลูมิเนียม ดังแสดงใน ภาพที่ 4.1 ซึ่งแสดงให้เห็นทั้งระดับค่าที่แตกต่างกันและรูปแบบแนวโน้มที่เพิ่มขึ้นอย่างสม่ำเสมอตามจำนวนรูเจาะ จากการวิเคราะห์เชิงสถิติด้วยวิธีถดถอยเชิงเส้น (Linear Regression) โดยกำหนดจำนวนรูเจาะ (Hole Number) เป็นตัวแปรอิสระ และค่าแรงตัดเฉลี่ยตาม


แนวแกน Fz เป็นตัวแปรตาม พบว่าแบบจำลองสามารถอธิบายแนวโน้มข้อมูลได้อย่างเหมาะสม โดยมีค่าสัมประสิทธิ์การตัดสินใจ (R^2) เท่ากับ 0.82 สำหรับเหล็ก และ 0.92 สำหรับอะลูมิเนียม แสดงให้เห็นว่าความสัมพันธ์เชิงเส้นระหว่างแรงตัดกับจำนวนรอบการใช้งานมีความชัดเจน และแบบจำลองมีความแม่นยำสูงในการอธิบายพฤติกรรมการเปลี่ยนแปลงของแรงตัดในแต่ละวัสดุ ผลลัพธ์ดังกล่าวยังยืนยันว่าเครื่องมือตัดในการเจาะเหล็กมีอัตราการเสื่อมสภาพเร็วกว่าวัสดุอะลูมิเนียมอย่างชัดเจน ทั้งในเชิงระดับค่าแรงตัดและความชันของแนวโน้มการเพิ่มขึ้นของแรงตัด ซึ่งสามารถนำผลการวิเคราะห์นี้ไปใช้เป็นฐานข้อมูลสำคัญในการวางแผนการเปลี่ยนเครื่องมือตัดและการกำหนดรอบการบำรุงรักษาเชิงคาดการณ์ เพื่อลดความเสี่ยงต่อการแตกหักของเครื่องมือและลดต้นทุนการผลิตในระบบอุตสาหกรรมจริง



รูปที่ 4.1 การเปรียบเทียบค่าแรงตัดเฉลี่ยในทิศทางแกน Z ระหว่างเหล็กและอะลูมิเนียมตามจำนวนรูที่ทำการเจาะ

4.1.2 ผลการตรวจวัด Flank Wear ด้วยกล้องจุลทรรศน์

การตรวจวัดการสึกหรอของเครื่องมือตัดดำเนินการด้วยกล้องจุลทรรศน์แบบสเตอริโอ Olympus รุ่น SZ61 โดยพิจารณาค่าการสึกหรอบริเวณผิวหลบของคมตัด (Flank Wear) ในรูปของค่า VBmax ซึ่งทำการตรวจวัดทุก ๆ 10 รู ตลอดกระบวนการทดลอง เพื่อใช้ติดตามพฤติกรรมการเสื่อมสภาพของเครื่องมือตัดอย่างต่อเนื่อง ผลการตรวจสอบจากภาพถ่ายกล้องจุลทรรศน์ (รูปที่ 4.2) แสดงให้เห็นลักษณะการสึกหรอที่เพิ่มขึ้นตามลำดับของจำนวนรูเจาะอย่างชัดเจน โดยในช่วงเริ่มต้นของการใช้งาน ค่า VBmax อยู่ต่ำกว่า 0.05 มิลลิเมตร และเพิ่มขึ้นอย่างช้า ๆ ก่อนจะเร่งตัวขึ้นอย่างรวดเร็วในระยะใกล้สิ้นอายุการใช้งาน




รูปที่ 4.2 ตัวอย่างภาพการสึกหรอบริเวณผิวทลบ (Flank Wear) ของเครื่องมือตัดจากการเจาะเหล็กในแต่ละช่วงของอายุการใช้งาน

หมายเหตุ จาก “Predictive Model for Tool Wear and Anomaly Detection on CNC Machine Tools,” โดย Kaitipoomphongsa, P., 2027, *Journal of Information Technology, KMUTNB*, (in press).

แนวโน้มเชิงปริมาณของค่า VBmax แสดงไว้ในรูปที่ 4.3 ซึ่งพบว่าค่าสูงสุดมีค่าประมาณ 0.313 มิลลิเมตรก่อนที่จะเกิดการแตกหัก จากกราฟสามารถแบ่งพฤติกรรมการสึกหรอออกเป็น 3 ระยะ ได้แก่ ระยะสึกหรอเริ่มต้น (Initial Wear Zone) ระยะสึกหรอคงที่ (Steady Wear Zone) และระยะสึกหรอรุนแรง (Accelerated Wear Zone) ซึ่งสอดคล้องกับทฤษฎีการเสื่อมสภาพของเครื่องมือตัดที่ยอมรับในงานวิจัยด้านการตัดเฉือน ข้อมูล Flank Wear จากการตรวจวัดนี้ถูกใช้เป็นข้อมูลอ้างอิงจริง (Ground Truth) สำหรับเปรียบเทียบกับผลจากแบบจำลอง Linear Regression และ Isolation Forest เพื่อประเมินความถูกต้องในการตรวจจับสภาวะผิดปกติของระบบ โดยยืนยันว่าแบบจำลองสามารถตรวจจับแนวโน้มการเสื่อมสภาพได้ตั้งแต่ระยะเริ่มต้นก่อนเกิดความเสียหายจริง

มหาวิทยาลัยเทคโนโลยีสุรนารี



รูปที่ 4.3 ความสัมพันธ์ระหว่างค่าการสึกหรอสูงสุดบริเวณผิวหลบ (VB_max) กับจำนวนรูที่ทำการเจาะในวัสดุเหล็ก

หมายเหตุ จาก “Predictive Model for Tool Wear and Anomaly Detection on CNC Machine Tools,” โดย Kaitipoomphongsa, P., 2027, *Journal of Information Technology, KMUTNB*, (in press).

4.1.3 ผลการวิเคราะห์แรงสั่นสะเทือน

การวิเคราะห์สัญญาณแรงสั่นสะเทือนของสปินเดลจากเครื่อง TENMARS ST-140 ดำเนินการโดยประมวลผลข้อมูลด้วยค่าเฉลี่ยเคลื่อนที่ (Moving Average) ขนาดหน้าต่าง 5 ค่า เพื่อลดความผันผวนของสัญญาณ จากนั้นทำการวิเคราะห์ทางสถิติด้วย One-way ANOVA และ Spearman Correlation เพื่อประเมินความสัมพันธ์ระหว่างระดับการสั่นสะเทือนกับการสึกหรอของเครื่องมือตัด (ค่า VBmax) ผลการวิเคราะห์ทางสถิติแสดงให้เห็นว่า ANOVA ให้ค่า p-value = 0.7762 ซึ่งมากกว่า 0.05 บ่งชี้ว่าไม่พบความแตกต่างของค่าแรงสั่นสะเทือนอย่างมีนัยสำคัญทางสถิติเมื่อเปรียบเทียบกับระดับการสึกหรอของเครื่องมือตัด ขณะเดียวกันการวิเคราะห์สหสัมพันธ์แบบ Spearman ให้ค่าสัมประสิทธิ์ $p = 0.2359$ ซึ่งอยู่ในระดับต่ำมาก แสดงว่าแรงสั่นสะเทือน ไม่มีความสัมพันธ์เชิงอันดับอย่างมีนัยสำคัญ กับแรงตัดและค่า VBmax (รายละเอียดผลการวิเคราะห์แสดงในตารางที่ 4.1) จากผลการวิเคราะห์ดังกล่าวสรุปได้ว่าสัญญาณแรงสั่นสะเทือนในชุดข้อมูลนี้ไม่เหมาะสมสำหรับใช้เป็นตัวแปรหลัก (Primary Feature) ในการสร้างแบบจำลองตรวจจับความผิดปกติ เนื่องจากมีความไวต่อสภาพแวดล้อมและการทำงานของเครื่องจักรมากกว่าการสึกหรอของเครื่องมือตัดโดยตรง อย่างไรก็ตาม ข้อมูลแรงสั่นสะเทือนยังคงสามารถใช้เป็นข้อมูลประกอบ (Supporting Data) เพื่อการวิเคราะห์พฤติกรรมการทำงานของเครื่องจักร และช่วยยืนยันความเหมาะสมของการเลือกแรงตัดเป็นตัวแปรหลักในขั้นตอนวิธี Isolation Forest สำหรับงานวิจัยนี้

ตารางที่ 4.1 ผลการวิเคราะห์ทางสถิติของสัญญาณแรงสั่นสะเทือนด้วย One-way ANOVA และ Spearman's Correlation

วิธีวิเคราะห์	ค่าที่ได้	คำอธิบาย
One-way ANOVA (p-value)	0.7762	$p > 0.05$ แสดงว่าไม่พบความแตกต่างอย่างมีนัยสำคัญ
Spearman's ρ	0.2359	ความสัมพันธ์เชิงอันดับระดับต่ำมาก

4.2 ผลการสร้างและประเมินแบบจำลอง Linear Regression

4.2.1 ผลการสร้างแบบจำลองและการประเมินประสิทธิภาพเชิงพยากรณ์

งานวิจัยนี้ใช้วิธีการถดถอยเชิงเส้น (Linear Regression) เพื่อสร้างแบบจำลองทางสถิติสำหรับอธิบายความสัมพันธ์ระหว่างจำนวนครั้งที่ทำการเจาะกับแรงตัดในแนวแกน Z (Fz) ซึ่งเป็นตัวแปรสำคัญที่สะท้อนการสึกหรอของเครื่องมือตัด โดยกำหนดให้จำนวนรูเจาะเป็นตัวแปรอิสระ (Independent Variable) และแรงตัดเป็นตัวแปรตาม (Dependent Variable) เพื่อศึกษาพฤติกรรมการเปลี่ยนแปลงของแรงตัดตามอายุการใช้งานของเครื่องมือตัด แบบจำลองถูกสร้างแยกตามชนิดของวัสดุ ได้แก่ เหล็กและอะลูมิเนียม เพื่อเปรียบเทียบลักษณะการสึกหรอที่แตกต่างกันตามคุณสมบัติของวัสดุ ผลการประเมินประสิทธิภาพของแบบจำลองแสดงไว้ใน ตารางที่ 4.2 ซึ่งแสดงตัวชี้วัดทางสถิติ ได้แก่ Root Mean Square Error (RMSE), Mean Square Error (MSE), Mean Absolute Error (MAE), Mean Absolute Percentage Error (MAPE) และค่าสัมประสิทธิ์การตัดสินใจ (R-Squared) จากผลการทดลองพบว่า แบบจำลองสามารถอธิบายแนวโน้มแรงตัดได้อย่างมีประสิทธิภาพ โดยเฉพาะในกรณีของวัสดุอะลูมิเนียมซึ่งให้ค่า R-Squared เท่ากับ 0.92 แสดงถึงความสอดคล้องของแบบจำลองกับข้อมูลจริงในระดับสูง ขณะที่วัสดุเหล็กให้ค่า R-Squared เท่ากับ 0.82 ซึ่งยังอยู่ในระดับที่น่าเชื่อถือสำหรับการใช้งานเชิงพยากรณ์ เมื่อพิจารณาค่าความคลาดเคลื่อนในการพยากรณ์พบว่า วัสดุอะลูมิเนียมมีค่า RMSE เท่ากับ 5.572 นิวตัน ต่ำกว่าเหล็กซึ่งมีค่า RMSE เท่ากับ 11.086 นิวตัน สะท้อนให้เห็นว่าข้อมูลแรงตัดจากอะลูมิเนียมมีความเสถียรและมีสัญญาณรบกวนน้อยกว่า ขณะที่ค่าความคลาดเคลื่อนเฉลี่ยสัมบูรณ์ในรูปเปอร์เซ็นต์ (MAPE) ของทั้งสองวัสดุอยู่ต่ำกว่า 2% แสดงว่าแบบจำลองสามารถทำนายแนวโน้มของแรงตัดได้อย่างแม่นยำ

นอกจากนี้ยังพบว่า แบบจำลองมีประสิทธิภาพด้านเวลาในการประมวลผล โดยใช้เวลาในการฝึกแบบจำลองเพียงไม่กี่วินาที และสามารถพยากรณ์ข้อมูลได้หลายร้อยรายการต่อวินาที ซึ่งแสดงถึงศักยภาพในการนำไปประยุกต์ใช้งานในระบบเผื่อระวังแบบเรียลไทม์บนเครื่องจักร CNC ได้อย่างเหมาะสม แม้ว่า Linear Regression จะเป็นแบบจำลองเชิงเส้นที่ไม่สามารถตรวจจับพฤติกรรมผิดปกติที่ซับซ้อน

หรือรูปแบบที่ไม่เป็นเชิงเส้นได้โดยตรง แต่บทบาทของแบบจำลองนี้ในงานวิจัยคือการทำหน้าที่เป็นตัวแทนเชิงพยากรณ์แนวโน้มการสึกหรอของเครื่องมือตัด (Wear Trend Prediction) และใช้เป็นแบบจำลองอ้างอิงพื้นฐาน (Baseline Model) เพื่อเปรียบเทียบกับวิธีตรวจจับความผิดปกติด้วย Isolation Forest ซึ่งช่วยเติมเต็มระบบให้สามารถรองรับทั้งการพยากรณ์ระยะยาวและการตรวจจับความผิดปกติในระยะสั้นได้อย่างสมบูรณ์

ผลลัพธ์โดยรวมยืนยันว่า Linear Regression ช่วยอธิบายพฤติกรรมการเสื่อมสภาพของเครื่องมือตัดได้อย่างชัดเจน และมีความเหมาะสมในการใช้งานร่วมกับระบบตรวจจับความผิดปกติเพื่อพัฒนาระบบบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) สำหรับเครื่องจักร CNC ในสภาพการผลิตจริง

ตารางที่ 4.2 ผลการประเมินประสิทธิภาพของแบบจำลอง Linear Regression ในการพยากรณ์แรงตัดสำหรับเหล็กและอะลูมิเนียม

การประเมินผล	ค่าของเหล็ก	ค่าของอะลูมิเนียม
ค่ารากที่สองของค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (RMSE)	11.086	5.5720
ค่าสัมประสิทธิ์การทำนาย (R-squared)	0.82	0.92
ค่าความคลาดเคลื่อนกำลังสองเฉลี่ย (MSE)	122.90	31.047
ค่าความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAE)	9.9380	4.1918
ค่าร้อยละความคลาดเคลื่อนสัมบูรณ์เฉลี่ย (MAPE)	1.3%	0.9%
ความเร็วในการพยากรณ์ (รายการต่อวินาที)	410	170
ระยะเวลาในการฝึกฝนแบบจำลอง (วินาที)	1.6602	4.1893

4.2.2 การวิเคราะห์ความทนทานของแบบจำลองต่อสัญญาณรบกวนและค่าผิดปกติ (Robustness Analysis)


ข้อมูลแรงตัดที่ได้จากกระบวนการตัดเฉือนด้วยเครื่องจักร CNC ในสภาพการผลิตจริงมีลักษณะสำคัญคือมีสัญญาณรบกวน (noise) และค่าผิดปกติ (outliers) เกิดขึ้นเป็นระยะ ซึ่งอาจมีสาเหตุมาจากการสั่นสะเทือนของเครื่องจักร การเปลี่ยนแปลงพารามิเตอร์การตัดเฉือน การเสื่อมสภาพของเครื่องมือตัดในแต่ละช่วงอายุการใช้งาน รวมถึงความไม่สม่ำเสมอของวัสดุชิ้นงาน ปัจจัยเหล่านี้ส่งผลโดยตรงต่อความเสถียรของแบบจำลองเชิงเส้น เช่น Linear Regression ซึ่งอาศัยสมมติฐานว่า

ความสัมพันธ์ระหว่างตัวแปรมีลักษณะเป็นเชิงเส้นและค่าความคลาดเคลื่อนมีการกระจายตัวอย่างสม่ำเสมอ

จากผลการประเมินเชิงสถิติในตารางที่ 4.2 พบว่าแบบจำลอง Linear Regression สามารถรักษาความแม่นยำในการพยากรณ์ได้ในระดับที่เหมาะสม แม้ข้อมูลจะมีสัญญาณรบกวน โดยเฉพาะในกรณีของวัสดุอะลูมิเนียมซึ่งมีค่า RMSE และ MAE ต่ำกว่าวัสดุเหล็กอย่างชัดเจน แสดงให้เห็นว่าแบบจำลองมีความทนทานต่อ noise ในระดับหนึ่งเมื่อข้อมูลแรงตัดมีพฤติกรรมค่อนข้างเสถียร อย่างไรก็ตาม ในกรณีของวัสดุเหล็ก ค่า RMSE และ MSE ที่สูงกว่าสะท้อนถึงผลกระทบของความผันผวนและค่าผิดปกติที่เกิดขึ้นบ่อย โดยเฉพาะในช่วงปลายของอายุการใช้งานเครื่องมือตัด

เมื่อพิจารณาแนวโน้มของความคลาดเคลื่อน (error trend) จากรูปที่ 4.4 ซึ่งแสดงค่าแรงตัดจริง ค่าแรงตัดที่แบบจำลองพยากรณ์ และเส้นแสดงค่าความคลาดเคลื่อน (error) ตามลำดับข้อมูล พบว่าความยาวของเส้น error มีแนวโน้มเพิ่มขึ้นเมื่อหมายเลขลำดับข้อมูล (record number) สูงขึ้น โดยเฉพาะในช่วงท้ายของข้อมูลซึ่งสอดคล้องกับช่วงการสึกหรอขั้นรุนแรง (severe wear stage) พฤติกรรมดังกล่าวสะท้อนให้เห็นว่า Linear Regression มีความไวต่อการเปลี่ยนแปลงของ wear stage กล่าวคือสามารถอธิบายแนวโน้มแรงตัดได้ดีในช่วงการสึกหรอแบบค่อยเป็นค่อยไป (progressive wear) แต่มีข้อจำกัดในการรองรับการเปลี่ยนแปลงแบบฉับพลันและพฤติกรรมที่ไม่เป็นเชิงเส้นซึ่งเกิดขึ้นในช่วงปลายอายุการใช้งานของเครื่องมือตัด

แม้จะมีข้อจำกัดดังกล่าว ค่า MAPE ที่ต่ำกว่า 2% สำหรับทั้งสองวัสดุแสดงให้เห็นว่าแบบจำลองยังคงมีความทนทานในเชิงภาพรวม (global robustness) กล่าวคือสามารถอธิบายแนวโน้มการเพิ่มขึ้นของแรงตัดตามอายุการใช้งานของเครื่องมือตัดได้อย่างมีประสิทธิภาพ โดยไม่ถูกรบกวนอย่างรุนแรงจาก noise หรือ outliers ที่เกิดขึ้นเป็นบางช่วง อย่างไรก็ตาม เพื่อรองรับข้อมูลจากกระบวนการผลิตจริงที่มีความไม่แน่นอนสูง งานวิจัยในอนาคตอาจพิจารณาการใช้แบบจำลองถดถอยที่มีความทนทานต่อค่าผิดปกติมากขึ้น เช่น Huber Regression, M-estimators หรือ RANSAC ซึ่งสามารถลดอิทธิพลของ outliers ต่อพารามิเตอร์ของแบบจำลองและเพิ่มความเสถียรในการพยากรณ์ได้ ในบริบทของงานวิจัยนี้ Linear Regression ถูกใช้ในบทบาทของแบบจำลองพื้นฐานสำหรับการพยากรณ์แนวโน้มการสึกหรอในระยะยาว โดยเน้นความเรียบง่าย ความสามารถในการอธิบาย และประสิทธิภาพด้านเวลา ขณะที่การจัดการกับสัญญาณรบกวน ค่าผิดปกติ และการเปลี่ยนแปลงที่ไม่เป็นเชิงเส้นในระยะสั้นถูกสนับสนุนด้วยการใช้เทคนิค Isolation Forest ในขั้นตอนการตรวจจับความผิดปกติ การผสมผสานการทำงานของทั้งสองแนวทางช่วยให้ระบบสามารถรองรับทั้งความทนทานต่อ noise และความไวต่อการเปลี่ยนแปลงของ wear stage ได้อย่างเหมาะสมในสภาพการผลิตจริง



รูปที่ 4.4 การแสดงค่าแรงตัดจริง ค่าแรงตัดที่พยากรณ์ และค่าความคลาดเคลื่อน (Error) ของแบบจำลอง Linear Regression ตามลำดับข้อมูลการผลิต

4.3 ผลการวิเคราะห์ด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest)


ขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ถูกนำมาใช้เพื่อจำแนกข้อมูลแรงตัด (Fz) ที่ได้จากการทดลองออกเป็นสภาวะปกติและสภาวะผิดปกติของเครื่องมือตัด โดยอาศัยหลักการสร้างต้นไม้สุ่มจำนวนมากเพื่อแยกตัวอย่างข้อมูลที่มีลักษณะแตกต่างจากข้อมูลส่วนใหญ่ออกมา หากจุดข้อมูลใดสามารถถูกแยกออกได้ด้วยจำนวนขั้นตอนน้อย (Short Path Length) จะถูกพิจารณาว่าเป็นค่าผิดปกติ (Anomaly) เนื่องจากมีพฤติกรรมแตกต่างจากกลุ่มข้อมูลหลักอย่างชัดเจน

ในงานวิจัยนี้ ข้อมูลแรงตัดเฉลี่ยต่อหนึ่งรูเจาะ (Avg_Fz) ถูกนำมาใช้เป็นตัวแปรหลักในการสร้างแบบจำลอง Isolation Forest โดยกำหนดค่า Contamination Fraction = 0.1 เพื่อแทนสัดส่วนของข้อมูลที่คาดว่าจะเป็ค่าผิดปกติ ผลลัพธ์จากแบบจำลองจะแสดงในรูปของค่าคะแนนความผิดปกติ (Anomaly Score) ซึ่งมีค่าอยู่ในช่วง 0 ถึง 1 โดยค่าที่เข้าใกล้ 1 แสดงถึงแนวโน้มที่จะเป็นสภาวะผิดปกติสูง


จากผลการวิเคราะห์สามารถสังเกตความแตกต่างของข้อมูลระหว่างกรณีเครื่องมือตัดแตกหักและไม่แตกหักได้อย่างชัดเจน ดังแสดงในรูปที่ 4.6 ซึ่งเปรียบเทียบค่าแรงตัดเฉลี่ย (Avg_Fz) ระหว่างชุดข้อมูลที่เครื่องมือตัดเกิดการแตกหักและชุดข้อมูลที่เครื่องมือตัดยังไม่แตกหัก พบว่าชุดข้อมูลที่เกิดการแตกหักมีการกระจายค่าของแรงตัดสูงกว่าอย่างชัดเจน และปรากฏค่าผิดปกติหลายจุดในช่วงใกล้การแตกหัก ในขณะที่ชุดข้อมูลที่เครื่องมือยังไม่แตกหักมีการกระจายตัวของข้อมูลอยู่ในช่วงที่ค่อนข้างคงที่ เมื่อพิจารณาความสัมพันธ์ระหว่างการตรวจจับความผิดปกติด้วย Isolation Forest และสภาพการสึกหรอของเครื่องมือตัด ดังแสดงในรูปที่ 4.5 พบว่า ค่า Anomaly Score และตำแหน่งการตรวจจับความผิดปกติเริ่มปรากฏชัดเจนในช่วงที่ค่าแรงตัดเฉลี่ย (Avg_Fz) มีแนวโน้มเพิ่มสูงขึ้นอย่างต่อเนื่อง และสอดคล้องกับช่วงที่ค่า VB_max เพิ่มขึ้นอย่างรวดเร็วเข้าสู่ระยะสึกหรอรุนแรง (Accelerated Wear Zone) โดยเฉพาะในช่วงรูที่ประมาณ 100 เป็นต้นไป ระบบสามารถตรวจจับจุดผิดปกติได้ก่อนที่ค่า VB_max จะถึงค่า

เกณฑ์สุดท้าย (Final VB_max) ซึ่งแสดงให้เห็นถึงศักยภาพของ Isolation Forest ในการตรวจจับสัญญาณบ่งชี้การเสื่อมสภาพของเครื่องมือตัดล่วงหน้าก่อนเกิดความเสียหายรุนแรงจริง

ผลลัพธ์ดังกล่าวสะท้อนให้เห็นว่า Isolation Forest สามารถเชื่อมโยงข้อมูลเชิงสัญญาณ (แรงตัด) เข้ากับสภาพการสึกหรอเชิงกายภาพของเครื่องมือตัดได้อย่างมีประสิทธิภาพ และเหมาะสมสำหรับการนำไปประยุกต์ใช้ในระบบตรวจสอบสภาพเครื่องมือตัดแบบเรียลไทม์ โดยไม่จำเป็นต้องใช้ข้อมูลที่ติดป้ายกำกับเป็นคุณสมบัติที่สำคัญสำหรับระบบบำรุงรักษาเชิงคาดการณ์ในสภาพแวดล้อมการผลิตจริง



รูปที่ 4.5 ความสัมพันธ์ระหว่างการสึกหรอของเครื่องมือตัดและลำดับการตรวจจับความผิดปกติด้วย Isolation Forest (Tool wear vs anomaly Detection Timeline)



รูปที่ 4.6 การกระจายตัวของค่าแรงตัดเฉลี่ย (Avg_Fz) ระหว่างชุดข้อมูลที่เครื่องมือตัดแตกหักและไม่แตกหัก

4.4 ผลการกำหนดค่าเกณฑ์แบบควอนไทล์

4.4.1 ผลการทดลองและการเปรียบเทียบค่าเกณฑ์แบบควอนไทล์

การกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) ถูกนำมาใช้เพื่อปรับระดับเส้นแบ่งระหว่างสภาวะปกติและสภาวะผิดปกติให้สอดคล้องกับลักษณะของข้อมูลจริง แทนการใช้ค่าเกณฑ์แบบคงที่ (Fixed Threshold) ซึ่งไม่สามารถปรับตัวตามการเปลี่ยนแปลงของสัญญาณได้ ในงานวิจัยนี้ได้เลือกใช้ค่าควอนไทล์จากการแจกแจงของคะแนนความผิดปกติ (Anomaly Score) ที่ได้จากขั้นตอนวิธี Isolation Forest เพื่อใช้เป็นค่าเกณฑ์ในการตัดสินใจสถานะของข้อมูลในแต่ละชุดการทดลอง ผลการทดลองจากชุดข้อมูลอะลูมิเนียม เหล็ก และชุดข้อมูลมาตรฐาน MATWI แสดงไว้ใน ตารางที่ 4.3 ซึ่งประกอบด้วยค่าควอนไทล์ที่เหมาะสม ค่าระดับเกณฑ์ (Threshold) และอัตราการตรวจพบล่วงหน้า (Early Detection Rate) ของแต่ละชุดข้อมูล พบว่าค่าควอนไทล์ที่เหมาะสมมีความแตกต่างกันตามลักษณะของข้อมูลและประเภทวัสดุที่ใช้ในการทดลอง สำหรับข้อมูลจากการทดลองจริง (Aluminium Set และ Steel Set) พบว่าค่าควอนไทล์ที่เหมาะสมอยู่ในช่วง 0.985–0.993 โดยให้ค่า Threshold อยู่ในช่วงประมาณ 0.64–0.66 และสามารถตรวจพบความผิดปกติล่วงหน้าในอัตรา 21–34% ซึ่งสะท้อนให้เห็นว่าแบบจำลองสามารถระบุความผิดปกติได้ก่อนเกิดการแตกหักของเครื่องมือตัดในระดับหนึ่ง ในส่วนของชุดข้อมูลมาตรฐาน MATWI พบว่าหลายชุดข้อมูลต้องใช้ค่าควอนไทล์ในระดับที่สูงมาก คือ 0.99999–1.0 เพื่อหลีกเลี่ยงการแจ้งเตือนผิดพลาด ในขณะที่อัตราการตรวจพบล่วงหน้ามีความแตกต่างกันค่อนข้างมาก โดยมีค่าตั้งแต่ต่ำกว่า 1% ไปจนถึงมากกว่า 80% แสดงให้เห็นว่าลักษณะการกระจายตัวของข้อมูลและระดับสัญญาณรบกวน (Noise) ของแต่ละชุดข้อมูลมีความแตกต่างกันอย่างมีนัยสำคัญ เมื่อพิจารณาพร้อมกับการกรองสัญญาณด้วย Median Filter พบว่าการคำนวณค่า Quantile จากข้อมูลที่ผ่านการลดสัญญาณรบกวนแล้ว ช่วยให้ค่า Threshold มีความเสถียรมากขึ้น และลดผลกระทบจากความผันผวนของข้อมูลในระยะสั้น ซึ่งสะท้อนผ่านแนวโน้มของอัตราการแจ้งเตือนผิดที่ลดลงและการตรวจพบล่วงหน้าที่มีความต่อเนื่องมากขึ้นในหลายชุดข้อมูล

ตารางที่ 4.3 การเปรียบเทียบค่าเกณฑ์แบบควอนไทล์และประสิทธิภาพการแจ้งเตือนล่วงหน้าในแต่ละชุดข้อมูล

ชุดข้อมูล	ค่าระดับควอนไทล์	ค่าระดับเกณฑ์	อัตราการตรวจพบล่วงหน้า (%)
Aluminum Set	0.993	0.6632	33.96
Steel Set	0.985	0.6429	21.43
MATWI Set 1	0.999995	0.7287	0.34
MATWI Set 2	0.98	0.6705	0.20
MATWI Set 3	0.999999	0.7727	83.17
MATWI Set 4	0.999999	0.7136	14.69
MATWI Set 5	0.99999999	0.8217	38.49
MATWI Set 6	1.0	0.7813	3.57
MATWI Set 7	1.0	0.7381	0.52
MATWI Set 8	1.0	0.7476	1.17
MATWI Set 9	1.0	0.7238	5.42
MATWI Set 10	1.0	0.7589	0.60
MATWI Set 11	1.0	0.8507	11.29
MATWI Set 12	1.0	0.7671	2.81
MATWI Set 13	1.0	0.7589	16.14
MATWI Set 14	1.0	0.7682	5.51
MATWI Set 15	1.0	0.7307	5.16
MATWI Set 16	1.0	0.765	7.06
MATWI Set 17	0.99997	0.742	7.73

4.4.2 การพิจารณาเชิงสถิติของ Quantile Threshold

จากกราฟแสดงค่า Anomaly Score ของชุดข้อมูล MATWI Set 1 ในรูปที่ 4.6 พบว่าค่าคะแนนส่วนใหญ่มีการกระจุกตัวอยู่ในช่วงค่าต่ำ ขณะที่ค่าคะแนนที่มีค่าสูงปรากฏอยู่เฉพาะในบริเวณส่วนปลายของการกระจายตัว ซึ่งสะท้อนให้เห็นว่าการแจกแจงของค่า Anomaly Score มีลักษณะไม่สมมาตร (Skewed Distribution) และมีค่า Outlier อยู่ในส่วนปลายของการแจกแจงอย่างชัดเจน ลักษณะการกระจายตัวดังกล่าวสอดคล้องกับสมมติฐานของวิธีป่าแยกตัว (Isolation Forest) ที่ค่าคะแนนความผิดปกติที่มีค่าสูงบ่งชี้ถึงจุดข้อมูลที่มีลักษณะผิดปกติ การกำหนดค่าเกณฑ์ด้วยวิธีควอนไทล์จึงเป็น

การเลือกเส้นแบ่งจากลักษณะการกระจายตัวของข้อมูลโดยตรง โดยอาศัยข้อมูลเชิงสถิติของ Anomaly Score แทนการกำหนดค่าเกณฑ์แบบคงที่ ทั้งนี้ การเลือกค่า Quantile Threshold สะท้อนถึงความสมดุลระหว่างความไวในการตรวจจับความผิดปกติ (Sensitivity) และอัตราการแจ้งเตือนผิดพลาด (False Alarm) กล่าวคือ การกำหนดค่า Quantile Threshold ในระดับที่สูงจะช่วยลดการแจ้งเตือนผิดพลาด โดยตัดเฉพาะจุดข้อมูลที่มีค่า Anomaly Score อยู่ในส่วนปลายของการแจกแจง แต่ในขณะเดียวกันอาจทำให้การตรวจจับความผิดปกติเกิดขึ้นในระยะที่ใกล้กับจุดเสียหายจริงมากขึ้น ในทางตรงกันข้าม การลดระดับค่า Quantile Threshold จะเพิ่มความไวในการตรวจจับและสามารถตรวจพบความผิดปกติได้เร็วขึ้น แต่แลกกับความเสี่ยงของการแจ้งเตือนผิดพลาดที่เพิ่มสูงขึ้น ดังนั้น การเลือกค่าควอนไทล์จึงจำเป็นต้องพิจารณาจากลักษณะการกระจายตัวของข้อมูลร่วมกับผลการทดลอง เพื่อให้เหมาะสมกับบริบทการใช้งานจริง


รูปที่ 4.7 แสดงค่า Anomaly Score ที่ได้จากขั้นตอนวิธี Isolation Forest ของชุดข้อมูล MATWI Set 1 โดยแกนแนวนอนแทนลำดับของข้อมูลตามรอบการตัดเงื่อนไข และแกนแนวตั้งแทนค่าคะแนนความผิดปกติ (Anomaly Score) เส้นประแนวนอนในรูปแสดงค่า Quantile Threshold ที่ระดับ $q = 0.999995$ (Threshold = 0.7287) ซึ่งได้จากการไล่ปรับค่าควอนไทล์ในหลายระดับ เพื่อหาค่าที่สามารถตรวจพบความผิดปกติได้ในช่วงปลายของอายุการใช้งานเครื่องมือตัด แต่ยังคงอยู่ก่อนจุดเสื่อมสภาพรุนแรงหรือจุดแตกหักจริง ค่าเกณฑ์ดังกล่าวจึงตัดเฉพาะจุดข้อมูลที่มีค่า Anomaly Score สูงผิดปกติที่สุด ทำให้สามารถลดการแจ้งเตือนผิดพลาดและรักษาความเหมาะสมในการแจ้งเตือนล่วงหน้าได้ภายใต้สภาวะข้อมูลที่มีสัญญาณรบกวนสูง

จากรูปที่ 4.8 ซึ่งแสดงการกระจายตัวของค่า Anomaly Score ของชุดข้อมูล MATWI Set 1 พบว่าค่าคะแนนส่วนใหญ่มีการกระจุกตัวอยู่ในช่วงค่าต่ำประมาณ 0.30–0.55 ขณะที่ค่าคะแนนที่มีค่าสูงกว่าปรากฏอยู่เฉพาะบริเวณส่วนปลายด้านขวาของการแจกแจง ซึ่งสะท้อนให้เห็นว่าการแจกแจงของค่า Anomaly Score มีลักษณะไม่สมมาตร (right-skewed distribution) และมี outlier อยู่ในส่วนหางของการกระจายตัวอย่างชัดเจน


เส้นประแนวตั้งในรูปที่ 4.8 แสดงตำแหน่งของค่า Quantile Threshold ที่ระดับ $q=0.999995$ ซึ่งสอดคล้องกับค่า Threshold เท่ากับ 0.7287 โดยค่าเกณฑ์ดังกล่าวตัดเฉพาะจุดข้อมูลที่มีค่า Anomaly Score สูงที่สุดในส่วนหางของการแจกแจง ทำให้สามารถแยกจุดผิดปกติออกจากข้อมูลปกติได้อย่างชัดเจนภายใต้สภาวะข้อมูลที่มีสัญญาณรบกวนสูง

จากลักษณะการกระจายตัวที่ปรากฏในรูปที่ 4.8 การกำหนดค่า Threshold ด้วยวิธี Quantile Threshold จึงเป็นการใช้ข้อมูลเชิงสถิติของการแจกแจงค่า Anomaly Score โดยตรง แทนการกำหนดค่าเกณฑ์แบบคงที่ ซึ่งไม่สามารถสะท้อนความแตกต่างของรูปแบบข้อมูลในแต่ละชุดทดลองได้

ทั้งนี้ การเลือกค่า Quantile Threshold ในระดับที่สูงดังกล่าวสะท้อนถึง trade-off ระหว่างความไวในการตรวจจับความผิดปกติ (sensitivity) และอัตราการแจ้งเตือนผิดพลาด (False Alarm) กล่าวคือ ค่า quantile ที่สูงช่วยลดการแจ้งเตือนผิดพลาดโดยพิจารณาเฉพาะจุดข้อมูลในส่วนหางของการแจกแจง แต่ยังสามารถตรวจจับความผิดปกติได้ก่อนถึงจุดเสียหายจริงของเครื่องมือตัดในเชิงเวลา ซึ่งสอดคล้องกับวัตถุประสงค์ของระบบตรวจจับความผิดปกติแบบล่วงหน้า



รูปที่ 4.7 กราฟแสดง Time-series plot พร้อม anomaly flags



รูปที่ 4.8 การกระจายตัวของค่า Anomaly Score และเส้นค่าเกณฑ์แบบควอนไทล์จากชุดข้อมูล MATWI Set 1

4.5 การประเมินประสิทธิภาพของแบบจำลองและการเปรียบเทียบกับวิธีอ้างอิง

4.5.1 ตัวชี้วัดการประเมิน (Performance Metrics)

การประเมินประสิทธิภาพของแบบจำลองตรวจจับความผิดปกติในงานวิจัยนี้มุ่งเน้นการประเมินในระดับเหตุการณ์ (event-level evaluation) เพื่อสะท้อนความเหมาะสมของการแจ้งเตือนในเชิงการใช้งานจริงในโรงงานอุตสาหกรรม โดยพิจารณาทั้งความสามารถในการตรวจจับความผิดปกติล่วงหน้า และความน่าเชื่อถือของการแจ้งเตือน ตัวชี้วัดหลักที่ใช้ในการประเมินประกอบด้วยอัตราการตรวจพบล่วงหน้า (Early Detection Rate) ระยะเวลาการแจ้งเตือนล่วงหน้า (Alert Lead Time) และค่า Precision ตารางที่ 4.4 ผลการประเมินการแจ้งเตือนในระดับเหตุการณ์ (Event-level Performance Metrics)

กำหนดให้ t_{alert} แทนเวลาที่ระบบตรวจพบความผิดปกติครั้งแรก และ t_{failure} แทนเวลาที่เครื่องมือเกิดความเสียหายหรือสิ้นสุดอายุการใช้งาน โดยระยะเวลาการแจ้งเตือนล่วงหน้าคำนวณจาก

$$\Delta t = t_{\text{failure}} - t_{\text{alert}}$$

เพื่อพิจารณาความเหมาะสมของการแจ้งเตือน กำหนดหน้าต่างการเตือนที่ยอมรับได้ (Warning Window, W) เท่ากับร้อยละ 30 ของอายุการใช้งานเครื่องมือตัดทั้งหมด ดังสมการ

$$W = 0.3 \times t_{\text{failure}}$$

การจัดประเภทเหตุการณ์ของการแจ้งเตือนกำหนดดังนี้

หาก $0 < \Delta t \leq W$ การแจ้งเตือนถือเป็น True Positive (TP)

หาก $\Delta t > W$ การแจ้งเตือนถือเป็น False Alarm (FP)

หากเกิดความเสียหายแต่ไม่มีการแจ้งเตือนล่วงหน้า ถือเป็น False Negative (FN)

ค่า Precision ในระดับเหตุการณ์ใช้สะท้อนความน่าเชื่อถือของการแจ้งเตือน โดยคำนวณจากอัตราส่วนของจำนวนการแจ้งเตือนที่เหมาะสมต่อจำนวนการแจ้งเตือนทั้งหมด ดังสมการ

$$\text{Precision} = \frac{TP}{TP+FP}$$

ตารางที่ 4.4 แสดงผลการประเมินการแจ้งเตือนในระดับเหตุการณ์สำหรับแต่ละชุดข้อมูล โดยรายงาน
ค่าอัตราการตรวจพบล่วงหน้า ระยะเวลาการแจ้งเตือนล่วงหน้า และผลการจัดประเภท
เหตุการณ์ของการแจ้งเตือน

Data set	Early Detection Rate (%)	Alert Lead Time (s)	Event Classification
Aluminium Set	33.96	576	False Alarm
Steel Set	21.43	480	True Positive
MATWI Set 1	0.34	869	True Positive
MATWI Set 2	0.2	106	True Positive
MATWI Set 3	83.17	49,845	False Alarm
MATWI Set 4	14.69	6,868	True Positive
MATWI Set 5	38.49	15,888	False Alarm
MATWI Set 6	3.57	4,060	True Positive
MATWI Set 7	0.52	288	True Positive
MATWI Set 8	1.17	611	True Positive
MATWI Set 9	5.42	2,906	True Positive
MATWI Set 10	0.6	309	True Positive
MATWI Set 11	11.29	6,631	True Positive
MATWI Set 12	2.81	1,038	True Positive
MATWI Set 13	16.14	4,798	True Positive
MATWI Set 14	5.51	4,638	True Positive
MATWI Set 15	5.16	1,414	True Positive
MATWI Set 16	7.06	7,161	True Positive
MATWI Set 17	7.73	2,848	True Positive

จากผลการประเมินที่แสดงใน ตารางที่ 4.4 พบว่าจากทั้งหมด 19 ชุดข้อมูล แบบจำลองให้
การแจ้งเตือนที่อยู่ภายในช่วงเวลาที่เหมาะสมจำนวน 16 ชุดข้อมูล และมีการแจ้งเตือนที่จัดเป็น
False Alarm จำนวน 3 ชุดข้อมูล ส่งผลให้ค่า Precision ในระดับเหตุการณ์ของวิธีที่นำเสนอมีค่าเท่ากับ
84.21% ซึ่งสะท้อนถึงความน่าเชื่อถือของการแจ้งเตือนและความเหมาะสมต่อการนำไปใช้งานจริงในระบบ
บำรุงรักษาเชิงคาดการณ์

4.5.2 วิธีอ้างอิง (Baseline) ของ Isolation Forest แบบค่าเกณฑ์คงที่

ค่า Fixed Threshold ที่ใช้ในการเปรียบเทียบกับวิธีอ้างอิง (Baseline) ในงานวิจัยนี้ ถูกกำหนดจากผลการทดลองด้วยวิธี Adaptive Threshold (Quantile-based Threshold) ในทุกชุดข้อมูลทดลองก่อนหน้านี้ โดยในแต่ละชุดข้อมูลจะมีการเลือกค่า Threshold ที่ให้ผลการตรวจจับเหมาะสมที่สุด ซึ่งสะท้อนพฤติกรรมของการกระจายของค่า Anomaly Score ที่แตกต่างกันในแต่ละสถานะการตัดเงื่อนไข จากนั้น ได้นำค่า Threshold ที่เหมาะสมของแต่ละชุดข้อมูลมาคำนวณหาค่าเฉลี่ย เพื่อใช้เป็นค่าเกณฑ์คงที่ (Fixed Threshold) สำหรับการสร้างวิธีอ้างอิง โดยมีวัตถุประสงค์เพื่อให้เกิดความเป็นธรรมในการเปรียบเทียบ และสะท้อนกรณีที่ไม่ปรับค่า Threshold ตามลักษณะข้อมูลเฉพาะชุด โดยกำหนดให้ชุดข้อมูลทั้งหมดที่ใช้ในการคำนวณประกอบด้วย Aluminium Set, Steel Set และชุดข้อมูล MATWI Set 1-17 รวมทั้งสิ้น 19 ชุดข้อมูล และใช้ค่าเฉลี่ยแบบปกติ (Arithmetic Mean) ของค่า Threshold จากวิธี Adaptive Threshold ตามสมการ

$$\text{Fixed Threshold} = \frac{1}{N} \sum_{i=1}^N \text{Threshold}_i$$

เมื่อ $N = 19$ ผลการคำนวณได้ค่า Fixed Threshold เท่ากับ 0.7445 ซึ่งถูกนำมาใช้เป็นค่าเกณฑ์เดียวกันสำหรับทุกชุดข้อมูลในการประเมินผลแบบ Baseline Comparison

เพื่อประเมินประสิทธิภาพของวิธีอ้างอิง (Baseline) งานวิจัยนี้เลือกใช้วิธี Isolation Forest ร่วมกับค่าเกณฑ์คงที่ (Fixed Threshold) โดยกำหนดค่า Threshold เท่ากับ 0.7445 การประเมินผลใช้ค่า Early Detection Rate (EDR) เป็นตัวชี้วัดหลัก โดยกำหนดให้การแจ้งเตือนถือว่า “ถูกต้อง (True)” ก็ต่อเมื่อค่า EDR อยู่ในช่วง $0 < \text{EDR} \leq 30\%$ ซึ่งสะท้อนการแจ้งเตือนที่เกิดขึ้นในช่วงปลายของอายุการใช้งานเครื่องมือตัดโดยไม่เร็วหรือช้าเกินไป ขณะที่กรณีที่ค่า $\text{EDR} \leq 0\%$, ค่า $\text{EDR} > 30\%$ รวมถึงกรณีที่ไม่เกิดการแจ้งเตือน จะถูกจัดเป็นผลลัพธ์แบบ False ทั้งหมด

จากผลการทดลองในตารางที่ 4.5 พบว่าวิธี IF + Fixed Threshold สามารถให้ผลลัพธ์ที่ต้องตามเกณฑ์เพียง 2 ชุดข้อมูลจากทั้งหมด 19 ชุด คิดเป็นค่า Precision เท่ากับ 10.53% ซึ่งสะท้อนให้เห็นว่าการใช้ค่าเกณฑ์คงที่ไม่สามารถรองรับความแปรผันของลักษณะข้อมูลและสถานะการผลิตที่แตกต่างกันได้อย่างมีประสิทธิภาพ เมื่อเปรียบเทียบกับวิธี Adaptive Threshold ที่ใช้ Quantile Threshold ซึ่งสามารถปรับค่าเกณฑ์ให้สอดคล้องกับการกระจายของ Anomaly Score ในแต่ละชุดข้อมูลได้ดีกว่าอย่างชัดเจน ผลลัพธ์แสดงดังตารางที่ 4.5

ตารางที่ 4.5 การประเมินผล Baseline: IF + Fixed Threshold (0.7445)

Dataset	Threshold	Early Detection Rate (%)	Result
Aluminium Set	0.7445	0	False
Steel Set	0.7445	0	False
MATWI 1	0.7445	0	False
MATWI 2	0.7445	-11.90	False
MATWI 3	0.7445	41.31	False
MATWI 4	0.7445	0	False
MATWI 5	0.7445	1.00	TRUE
MATWI 6	0.7445	0	False
MATWI 7	0.7445	51.50	False
MATWI 8	0.7445	22.52	TRUE
MATWI 9	0.7445	0	False
MATWI 10	0.7445	-3.31	False
MATWI 11	0.7445	36.40	False
MATWI 12	0.7445	-1.95	False
MATWI 13	0.7445	-24.03	False
MATWI 14	0.7445	59.06	False
MATWI 15	0.7445	-18.36	False
MATWI 16	0.7445	54.32	False
MATWI 17	0.7445	-5.55	False

4.5.3 การเปรียบเทียบค่า Precision ระหว่าง Adaptive และ Fixed Threshold

เพื่อให้เห็นความแตกต่างของประสิทธิภาพในการตรวจจับความผิดปกติอย่างชัดเจน งานวิจัยนี้ ได้ทำการเปรียบเทียบค่า Precision ระหว่างวิธี Adaptive Threshold และ Fixed Threshold โดยใช้เกณฑ์การพิจารณาผลลัพธ์เดียวกัน คือ การแจ้งเตือนจะถือว่าถูกต้องเมื่อค่า Early Detection Rate (EDR) อยู่ในช่วง $0 < EDR \leq 30\%$

ผลการเปรียบเทียบในตารางที่ 4.6 แสดงให้เห็นว่าวิธี IF + Adaptive Threshold ให้ค่า Precision สูงถึง 89.47% เนื่องจากสามารถตรวจจับความผิดปกติได้ถูกต้องใน 17 จาก 19 ชุดข้อมูล ในขณะที่วิธี IF + Fixed Threshold ให้ค่า Precision เพียง 10.53% โดยตรวจจับได้ถูกต้องเพียง 2 ชุดข้อมูลเท่านั้น

ผลลัพธ์ที่ตาราง 4.6 ดังกล่าวสะท้อนให้เห็นอย่างชัดเจนว่าการใช้ค่าเกณฑ์ที่ไม่สามารถรองรับความแปรผันของการกระจายตัวของ Anomaly Score ในแต่ละชุดข้อมูลได้อย่างมีประสิทธิภาพในทางตรงกันข้าม วิธี Adaptive Threshold ซึ่งสามารถปรับค่าเกณฑ์ให้สอดคล้องกับลักษณะข้อมูลเฉพาะชุด ช่วยลดการแจ้งเตือนผิดพลาดและเพิ่มความแม่นยำในการตรวจจับได้อย่างมีนัยสำคัญแม้ว่างานวิจัยนี้จะได้ไม่ใช้การทดสอบสมมติฐานทางสถิติ (statistical hypothesis testing) อย่างเป็นทางการแต่ผลการเปรียบเทียบค่า Precision ระหว่างวิธี IF + Adaptive Threshold (89.47%) และ IF + Fixed Threshold (10.53%) แสดงให้เห็นความแตกต่างเชิงปฏิบัติที่ชัดเจนซึ่งเพียงพอสำหรับการสรุปเชิงวิศวกรรมและการนำไปใช้งานจริงในระบบตรวจจับความผิดปกติของเครื่องมือตัด

ตารางที่ 4.6 การเปรียบเทียบค่า Precision ระหว่าง Adaptive และ Fixed Threshold

Method	True Detection	False Detection	Precision (%)
IF + Adaptive Threshold	16	3	89.47
IF + Fixed Threshold	2	17	10.53

4.6 การวิเคราะห์ผลกระทบด้านต้นทุนและการลดความสูญเสียในกระบวนการผลิต

จากตารางที่ 4.7 แสดงการเปรียบเทียบการใช้หัวเจาะและต้นทุนต่อประหว่างแผนบำรุงรักษาแบบดั้งเดิมและแนวทางที่ใช้ระบบตรวจจับความผิดปกติที่นำเสนอในงานวิจัยนี้ โดยการวิเคราะห์ดังกล่าวอ้างอิงจากอายุการใช้งานจริงของหัวเจาะที่ได้จากการทดลอง ไม่ได้อ้างอิงจากจำนวนรอบการใช้งานตามแผนบำรุงรักษาแบบคงที่

ในงานวิจัยนี้ นิยามจุดสิ้นสุดอายุการใช้งานของหัวเจาะ (Tool End-of-Life) จากค่าการสึกหรอแบบผิวหกลบสูงสุด (VBmax) ซึ่งตรวจวัดด้วยกล้องจุลทรรศน์ โดยพบว่าหัวเจาะมีค่า VBmax = 0.3132 ที่ลำดับการเจาะรูที่ 140 ซึ่งถือเป็นสถานะที่เครื่องมือตัดเสื่อมสภาพอย่างชัดเจนและมีความเสี่ยงต่อการแตกหักหรือส่งผลกระทบต่อคุณภาพชิ้นงาน ดังนั้น งานวิจัยนี้จึงใช้อายุการใช้งานที่ 140 รูเป็นอายุการใช้งานจริงของหัวเจาะสำหรับการวิเคราะห์เชิงต้นทุน เมื่อเปรียบเทียบกับแผนบำรุงรักษาเดิมที่กำหนดให้เปลี่ยนหัวเจาะที่ 100 รู จะเห็นได้ว่าหัวเจาะถูกเปลี่ยนก่อนถึงอายุการใช้งานจริงประมาณ 40 รู หรือคิดเป็นสัดส่วนร้อยละ 28.6 ของอายุการใช้งานทั้งหมด ซึ่งสะท้อนถึงการเปลี่ยนเครื่องมือตัดก่อนเวลาอันควรเพื่อหลีกเลี่ยงความเสี่ยงจากการแตกหักในกระบวนการผลิต จากผลการตรวจจับความผิดปกติด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest) พบว่า สามารถตรวจจับสัญญาณความผิดปกติครั้งแรกที่ลำดับการเจาะรูที่ 103 ซึ่งยังคงเหลือช่วงการใช้งานก่อนถึงจุดสิ้นสุดอายุการใช้งานจริงอีกจำนวน 37 รู (140 – 103) หรือคิดเป็นประมาณ 26.4% ของอายุการใช้งานทั้งหมด ช่วงดังกล่าวสามารถตีความได้ว่าเป็น “ช่วงเวลาเพื่อการตัดสินใจ” (Decision Window) ที่เปิดโอกาสให้ผู้ปฏิบัติงาน

สามารถวางแผนการเปลี่ยนหัวเจาะได้อย่างเหมาะสม โดยไม่จำเป็นต้องเปลี่ยนเครื่องมือทันทีเมื่อถึงเกณฑ์ตามแผนเดิม

ภายใต้สมมติฐานการผลิตจำนวน 14,000 รูต่อปี และสมมติราคาหัวเจาะ 1,000 บาทต่อหัว แผนบำรุงรักษาเดิมจะต้องใช้หัวเจาะประมาณ 140 หัวต่อปี คิดเป็นต้นทุนรวมประมาณ 140,000 บาทต่อปี ขณะที่แนวทางที่ใช้ระบบตรวจจับความผิดปกติสามารถยืดอายุการใช้งานหัวเจาะออกไปใกล้เคียงกับอายุการใช้งานจริงที่ 140 รู ส่งผลให้จำนวนหัวเจาะที่ใช้ลดลงเหลือประมาณ 100 หัวต่อปี หรือคิดเป็นต้นทุนประมาณ 100,000 บาทต่อปี

ผลการเปรียบเทียบดังกล่าวแสดงให้เห็นว่า แนวทางที่นำเสนอในงานวิจัยนี้มีศักยภาพในการลดต้นทุนหัวเจาะลงได้ประมาณ 40,000 บาทต่อปี หรือคิดเป็นการลดต้นทุนประมาณ 28.6% เมื่อเทียบกับแผนบำรุงรักษาแบบดั้งเดิม ทั้งนี้ยังไม่รวมผลประโยชน์ทางอ้อมอื่น ๆ เช่น การลดความเสี่ยงจากชิ้นงานเสีย การลดการหยุดเครื่องจักรแบบไม่คาดคิด และการเพิ่มความยืดหยุ่นในการวางแผนการผลิต ดังนั้น ตารางที่ 4.7 จึงสะท้อนให้เห็นว่า การใช้ระบบตรวจจับความผิดปกติร่วมกับข้อมูลการสึกหรอจริงของเครื่องมือตัด สามารถเปลี่ยนแนวคิดการบำรุงรักษาจากการกำหนดรอบแบบคงที่ไปสู่การบำรุงรักษาตามสภาพจริง (Condition-based Maintenance) ซึ่งช่วยเพิ่มความคุ้มค่าในการใช้ทรัพยากรและลดความสูญเสียในกระบวนการผลิตได้อย่างเป็นรูปธรรม

ตารางที่ 4.7 การเปรียบเทียบต้นทุนหัวเจาะต่อปี ระหว่างแผนบำรุงรักษาเดิมและแผนที่ใช้ระบบตรวจจับความผิดปกติ

รายการเปรียบเทียบ	แผนบำรุงรักษาเดิม	แผนที่ใช้ระบบตรวจจับความผิดปกติ
อายุการใช้งานต่อหัว	100 รู	140 รู
จำนวนรูที่ผลิตต่อปี (สมมติ)	14,000 รู	14,000 รู
จำนวนหัวเจาะที่ใช้ต่อปี	140 หัว	100 หัว
ราคาหัวเจาะต่อหัว (สมมติ)	1,000 บาท	1,000 บาท
ต้นทุนหัวเจาะต่อปี	140,000 บาท	100,000 บาท
ต้นทุนที่ลดลงต่อปี	-	40,000 บาท / ปี
สัดส่วนการลดต้นทุน	-	≈ 28.6%

4.7 การวิเคราะห์ข้อดีของระบบตรวจจับความผิดปกติเมื่อเทียบกับอายุการใช้งานของหัวเจาะ

แม้ว่าผลการวิเคราะห์ในหัวข้อที่ 4.6 จะแสดงให้เห็นถึงประโยชน์ของระบบตรวจจับความผิดปกติในเชิงต้นทุนและการยืดอายุการใช้งานของหัวเจาะแล้ว แต่ข้อได้เปรียบที่สำคัญอีกประการหนึ่งของระบบที่นำเสนอในงานวิจัยนี้ คือความสามารถในการเฝ้าระวังกระบวนการตัดเฉือนแบบต่อเนื่อง และตรวจจับสภาวะผิดปกติได้ก่อนที่จะเกิดความเสียหายอย่างรุนแรงหรือแตกหัก ในทางปฏิบัติ หากมีการตั้งค่าการตัดเฉือนของเครื่องจักรโดยอ้างอิงจากอายุการใช้งานจริงของหัวเจาะเพียงอย่างเดียว โดยไม่ได้มีระบบตรวจจับความผิดปกติเข้ามารองรับ การทำงานของเครื่องจักรยังคงมีความเสี่ยงต่อการเกิดความเสียหายจากเหตุการณ์ไม่คาดคิด ทั้งนี้เนื่องจากอายุการใช้งานจริงของหัวเจาะไม่ได้สะท้อนการเปลี่ยนแปลงของสภาวะการตัดเฉือนที่อาจเกิดขึ้นแบบฉับพลันระหว่างการผลิต ระบบตรวจจับความผิดปกติที่พัฒนาขึ้นอาศัยการวิเคราะห์รูปแบบการเปลี่ยนแปลงของสัญญาณแรงตัดและการสั่นสะเทือน ซึ่งสามารถสะท้อนพฤติกรรมที่ผิดปกติของกระบวนการผลิตได้ แม้ในกรณีที่หัวเจาะยังไม่ถึงจุดสิ้นสุดอายุการใช้งานตามเกณฑ์การสึกหรอ ความผิดปกติดังกล่าวอาจเกิดจากปัจจัยที่ไม่สามารถคาดการณ์ล่วงหน้าได้ เช่น ความไม่สม่ำเสมอของวัสดุชิ้นงาน เศษวัสดุสะสมบริเวณคมตัด ความคลาดเคลื่อนในการยึดจับชิ้นงาน หรือความผิดปกติทางกลของระบบเครื่องจักร ในบริบทของการผลิตชิ้นงานที่มีมูลค่าสูง ความเสียหายที่เกิดขึ้นโดยฉับพลันจากการแตกหักของหัวเจาะหรือการตัดเฉือนที่ผิดปกติ อาจส่งผลให้ชิ้นงานเสียหายทั้งชิ้นและก่อให้เกิดความสูญเสียในระดับสูง ดังนั้นระบบตรวจจับความผิดปกติจึงทำหน้าที่เป็นกลไกเฝ้าระวังเพิ่มเติม (Additional Safety Layer) ที่ช่วยลดความเสี่ยงดังกล่าว โดยเปิดโอกาสให้ผู้ปฏิบัติงานสามารถหยุดหรือปรับกระบวนการผลิตได้ทันเวลาที่ก่อนที่จะเกิดความเสียหายรุนแรง

ดังนั้น การผสมผสานการตั้งค่าการตัดเฉือนตามอายุการใช้งานจริงเข้ากับระบบตรวจจับความผิดปกติ ทำให้การบำรุงรักษาและการควบคุมกระบวนการผลิตมีความสมบูรณ์มากขึ้น ไม่เพียงช่วยเพิ่มประสิทธิภาพในการใช้ประโยชน์จากอายุการใช้งานของหัวเจาะเท่านั้น แต่ยังช่วยเพิ่มความปลอดภัย ความเสถียร และความน่าเชื่อถือของกระบวนการผลิตในสภาพการใช้งานจริงอีกด้วย

4.8 การอภิปรายผล

ผลการวิจัยนี้แสดงให้เห็นว่า การประยุกต์ใช้ขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) สามารถตรวจจับแนวโน้มความผิดปกติของแรงตัดได้ก่อนการแตกหักของเครื่องมือตัดในหลายชุดข้อมูลทดลอง โดยเฉพาะในช่วงค่าควอนไทล์ระดับสูง (ประมาณ 0.98–0.99999) ซึ่งให้ความสมดุลที่เหมาะสมระหว่างความไวในการตรวจจับ (Sensitivity) และการลดอัตราการแจ้งเตือนผิดพลาด (False Alarm Rate) เมื่อเปรียบเทียบกับวิธีการ

กำหนดค่าเกณฑ์แบบคงที่ (Fixed Threshold) พบว่าวิธี Adaptive Threshold มีความสามารถในการปรับตัวให้สอดคล้องกับลักษณะการกระจายตัวของข้อมูลในแต่ละชุดข้อมูลได้ดีกว่าอย่างชัดเจน โดยเฉพาะในกรณีที่ข้อมูลมีความไม่สม่ำเสมอ มีสัญญาณรบกวนสูง หรือมีการเปลี่ยนแปลงของระดับสัญญาณตามอายุการใช้งานของเครื่องมือตัด ซึ่งเป็นลักษณะที่พบได้จริงในกระบวนการผลิตทางอุตสาหกรรม

4.8.1 ความเหมาะสมของแบบจำลองเชิงเส้นและ Isolation Forest เมื่อเทียบกับวิธีการเรียนรู้เชิงลึก

แม้ว่าวิธีการเรียนรู้เชิงลึก (Deep Learning) จะได้รับความนิยมอย่างแพร่หลายในงานตรวจจับความผิดปกติจากข้อมูลสัญญาณ แต่ในบริบทของงานวิจัยนี้ การใช้แบบจำลองเชิงเส้นร่วมกับขั้นตอนวิธี Isolation Forest ถือว่ามีความเหมาะสมมากกว่า ทั้งในเชิงข้อมูลและเชิงวิศวกรรม ประการแรก ลักษณะของปัญหาในงานวิจัยนี้เป็นการติดตามแนวโน้มการเสื่อมสภาพของเครื่องมือตัด (degradation monitoring) มากกว่าการจำแนกรูปแบบที่ซับซ้อน (complex pattern recognition) โดยตัวแปรหลักที่ใช้คือแรงตัดเฉลี่ยต่อหนึ่งรอบ (Avg_Fz) ซึ่งมีความสัมพันธ์เชิงกายภาพโดยตรงกับการสึกหรอของเครื่องมือตัด การใช้แบบจำลองที่มีโครงสร้างไม่ซับซ้อนจึงเพียงพอในการอธิบายพฤติกรรมดังกล่าว ประการที่สอง ข้อมูลความผิดปกติจริง (fault data) ในกระบวนการตัดเฉือนมีจำนวนจำกัด และมักเกิดขึ้นในช่วงปลายของอายุการใช้งานเครื่องมือ การใช้แบบจำลองเชิงลึกที่ต้องการข้อมูลจำนวนมากอาจเพิ่มความเสี่ยงของการเกิด overfitting และลดความสามารถในการอธิบายผลลัพธ์ (interpretability) ในขณะที่ Isolation Forest สามารถทำงานได้โดยไม่ต้องอาศัยข้อมูลที่ติดป้ายกำกับ และสามารถระบุจุดข้อมูลที่มีพฤติกรรมแตกต่างจากข้อมูลส่วนใหญ่ได้อย่างมีประสิทธิภาพ ดังนั้น การเลือกใช้ Isolation Forest ร่วมกับการวิเคราะห์เชิงเส้นจึงเป็นทางเลือกที่เหมาะสมสำหรับงานตรวจจับความผิดปกติในบริบทของการบำรุงรักษาเชิงคาดการณ์ ซึ่งให้ความสำคัญกับความเรียบง่าย ความเสถียร และความสามารถในการตีความผลลัพธ์ มากกว่าความซับซ้อนของแบบจำลอง

4.8.2 ความเหมาะสมของ Isolation Forest สำหรับสัญญาณไม่คงที่ (Non-stationary Signal)

สัญญาณแรงตัดที่ได้จากกระบวนการตัดเฉือนมีลักษณะไม่คงที่ตามเวลา (non-stationary) กล่าวคือ ค่าความหมายและความแปรปรวนของสัญญาณมีการเปลี่ยนแปลงไปตามอายุการใช้งานของเครื่องมือตัด สภาพการตัดเฉือน และคุณสมบัติของวัสดุที่นำมาทดลอง ลักษณะดังกล่าวทำให้การใช้วิธีการตรวจจับความผิดปกติที่อาศัยสมมติฐานการแจกแจงคงที่ของข้อมูลมีข้อจำกัดอย่างมาก

Isolation Forest มีความเหมาะสมสำหรับสัญญาณประเภทนี้ เนื่องจากขั้นตอนวิธีดังกล่าวไม่อาศัยสมมติฐานเกี่ยวกับรูปแบบการแจกแจงของข้อมูล และไม่ต้องการข้อมูลอ้างอิงในสภาวะปกติแบบตายตัว แบบจำลองจะพิจารณาความผิดปกติจากความสามารถในการแยกจุดข้อมูลออกจากกลุ่มข้อมูลส่วนใหญ่ภายในช่วงเวลานั้น ๆ ทำให้สามารถรองรับการเปลี่ยนแปลงของระดับสัญญาณ

(signal drift) ได้โดยธรรมชาติ ผลการทดลองจากหลายชุดข้อมูล MATWI แสดงให้เห็นว่า แม้ค่าเฉลี่ยของแรงตัดจะเพิ่มขึ้นอย่างต่อเนื่องตามการสึกหรอของเครื่องมือตัด Isolation Forest ยังสามารถระบุจุดข้อมูลที่มีพฤติกรรมผิดปกติในช่วงปลายของการใช้งานได้อย่างสอดคล้อง ซึ่งสะท้อนให้เห็นถึงความเหมาะสมของวิธีดังกล่าวสำหรับการประมวลผลข้อมูลจากกระบวนการผลิตจริงที่มีความไม่แน่นอนสูง

4.8.3 เหตุผลเชิงแนวคิดของการใช้ Quantile Threshold ร่วมกับ Isolation Forest

งานวิจัยนี้เลือกใช้การกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) ร่วมกับขั้นตอนวิธีป่าแยกตัว (Isolation Forest) เนื่องจากสอดคล้องกับธรรมชาติของผลลัพธ์ที่ได้จากอัลกอริทึมและลักษณะข้อมูลจริงจากกระบวนการผลิต CNC โดย Isolation Forest จะให้ผลลัพธ์เป็นค่า Anomaly Score ซึ่งสะท้อน “ระดับความผิดปกติสัมพัทธ์” ของข้อมูลเมื่อเทียบกับกลุ่มข้อมูลส่วนใหญ่ภายใต้สภาวะการทำงานนั้น ๆ ค่า Anomaly Score ดังกล่าวมักมีการกระจายตัว (distribution) ที่แตกต่างกันระหว่างชุดข้อมูล เนื่องจากได้รับอิทธิพลจากชนิดวัสดุ เครื่องมือตัด เงื่อนไขการตัดเฉือน และคุณลักษณะของสัญญาณจากเซนเซอร์ ส่งผลให้การตั้งค่าเกณฑ์แบบคงที่ (Fixed Threshold) เพียงค่าเดียวมีข้อจำกัด เพราะเท่ากับตั้งอยู่บนสมมติฐานว่า “การกระจายของข้อมูลคงที่” (stationarity) ซึ่งไม่สอดคล้องกับกระบวนการตัดเฉือนจริงที่มีลักษณะไม่คงที่ตามเวลา (non-stationary) และมีการเปลี่ยนแปลงตามช่วงอายุการใช้งานของเครื่องมือตัด

ในทางตรงกันข้าม การใช้ Quantile Threshold เป็นแนวทางที่อิงกับการกระจายตัวของข้อมูล (distribution-aware) กล่าวคือ ค่าเกณฑ์ถูกกำหนดจากตำแหน่งเปอร์เซ็นต์ไทล์ของค่า Anomaly Score ที่เกิดขึ้นจริงภายในชุดข้อมูลหรือช่วงการผลิตที่สนใจ ทำให้เกณฑ์สามารถ “ปรับตามบริบทของข้อมูล” ได้อย่างยืดหยุ่น เมื่อสภาวะการผลิตเปลี่ยน การกระจายของ Anomaly Score เปลี่ยนตาม ค่าเกณฑ์ที่คำนวณจากควอนไทล์จึงสามารถปรับให้เหมาะสมโดยไม่ต้องยึดติดกับค่าขนาดเชิงสัมบูรณ์ที่อาจใช้ร่วมกันไม่ได้ในทุกกรณี ดังนั้น Quantile Threshold จึงเหมาะสมกับ Isolation Forest มากกว่าวิธีตั้งเกณฑ์แบบคงที่ เพราะตอบโจทย์การตัดสินใจการตัดสินใจผิดปกติบนพื้นฐานของการกระจายจริงของคะแนนความผิดปกติ และรองรับความแปรผันของกระบวนการผลิต CNC ได้ดีกว่า ดังนั้น Quantile Threshold จึงทำหน้าที่เป็นเกณฑ์ที่อิง “การกระจายของค่า Anomaly Score” โดยตรง (distribution-aware) ทำให้เหมาะสมกับ Isolation Forest ซึ่งให้ผลลัพธ์เป็นคะแนนความผิดปกติแบบสัมพัทธ์ ในทางตรงกันข้าม การใช้ Fixed Threshold มักตั้งอยู่บนสมมติฐานว่าการกระจายของข้อมูลมีความคงที่ (stationarity) ซึ่งไม่สอดคล้องกับสัญญาณแรงตัดจริงที่มีลักษณะไม่คงที่ตามเวลา (non-stationary)

4.8.4 ข้อจำกัดและข้อพึงระวังของการตั้งค่า Quantile Threshold

แม้ว่าวิธีการใช้ Isolation Forest ร่วมกับ Quantile Threshold จะช่วยเพิ่มความยืดหยุ่นและลดการพึ่งพาเกณฑ์คงที่ได้อย่างชัดเจน แต่การนำไปใช้งานจริงจำเป็นต้องพิจารณาข้อจำกัดและข้อพึงระวังสำคัญเพื่อหลีกเลี่ยงการตีความผลลัพธ์คลาดเคลื่อน

ประการแรก การเลือกค่าควอนไทล์ที่ “ต่ำเกินไป” อาจนำไปสู่การแจ้งเตือนผิดพลาด (False Alarm) ได้ง่าย เนื่องจากค่าเกณฑ์จะถูกกำหนดให้อยู่ในระดับต่ำ ทำให้ระบบมีความไวต่อความผันผวนเล็กน้อยของสัญญาณ โดยเฉพาะในกรณีที่ข้อมูลมีสัญญาณรบกวนสูงหรือมีความไม่แน่นอนในกระบวนการผลิต ผลที่ตามมาคือมีการเตือนถี่เกินความจำเป็น ซึ่งอาจเพิ่มภาระของผู้ใช้งานและลดความเชื่อมั่นต่อระบบ ดังนั้นในการใช้งานจริงจึงควรกำหนดควอนไทล์ในระดับที่เหมาะสมกับเป้าหมายของระบบ เช่น เน้น early detection แต่ยังคงควบคุม False Alarm ให้อยู่ในระดับยอมรับได้ พร้อมมีการทดสอบความไวของค่าเกณฑ์ในช่วงควอนไทล์ที่ต่างกัน

ประการที่สอง แนวทางนี้มีความไวต่อ “การเปลี่ยนแปลงของการกระจายตัวของข้อมูล” (distribution shift) หากสภาวะการผลิตเปลี่ยนอย่างมีนัยสำคัญ เช่น เปลี่ยนชนิดวัสดุ เปลี่ยนเครื่องมือตัด เปลี่ยนพารามิเตอร์การตัดเฉือน หรือเปลี่ยนสภาพการยึดจับชิ้นงาน การกระจายของค่า Anomaly Score อาจเปลี่ยนตาม ส่งผลให้ Quantile Threshold ที่คำนวณจากช่วงก่อนหน้านี้ไม่สอดคล้องกับสภาวะใหม่ ในทางปฏิบัติ จึงควรมีขั้นตอนการปรับเทียบค่าเกณฑ์ (recalibration) จากข้อมูลช่วงต้นที่เป็นสภาวะปกติ (healthy state) ของเงื่อนไขใหม่ เพื่อให้ค่าเกณฑ์สะท้อนการกระจายจริงของ Anomaly Score ในบริบทนั้น ๆ และลดความเสี่ยงทั้งการเตือนเกินจริงหรือการตรวจจับไม่ทันเวลา

ประการที่สาม ประสิทธิภาพของการตั้งค่าเกณฑ์แบบควอนไทล์ขึ้นกับ “คุณภาพของสัญญาณและการติดตั้งเซนเซอร์” (sensor dependency) อย่างมีนัยสำคัญ หากเซนเซอร์มีสัญญาณรบกวนสูง การยึดติดตั้งไม่เหมาะสม ความละเอียดไม่เพียงพอ หรือมีความไม่เสถียรของการเก็บข้อมูล จะทำให้การกระจายของค่า Anomaly Score กว้างขึ้นหรือบิดเบี้ยว ส่งผลให้ค่า Quantile Threshold ผันผวนและทำให้การตัดสินใจไม่เสถียร ดังนั้น ก่อนการประยุกต์ใช้จริงควรมีการตรวจสอบคุณภาพสัญญาณอย่างสม่ำเสมอ เช่น การตรวจสอบสภาพการยึดติดตั้ง การประเมิน noise floor การกำหนดขั้นตอนการกรองสัญญาณที่เหมาะสม และการคัดกรองค่าที่ผิดปกติจากระบบวัด เพื่อให้การคำนวณค่าเกณฑ์มีความน่าเชื่อถือ

โดยสรุป การเลือกค่าควอนไทล์ที่เหมาะสม การจัดการ distribution shift ด้วยการ recalibration และการควบคุมคุณภาพของสัญญาณจากเซนเซอร์ เป็นองค์ประกอบสำคัญที่ต้องพิจารณาร่วมกันเพื่อให้แนวทางที่นำเสนอสามารถใช้งานได้อย่างมีประสิทธิภาพและลดความเสี่ยงของ False Alarm ในบริบทการผลิตจริง

4.8.5 การเปรียบเทียบเชิงแนวคิดกับงานวิจัยอื่น และนัยต่อ Predictive Maintenance ในอุตสาหกรรมไทย

เมื่อพิจารณาเชิงแนวคิด งานวิจัยที่เกี่ยวข้องด้านการตรวจจับความผิดปกติในงาน CNC มีทั้งกลุ่มที่ใช้วิธีเชิงสถิติหรือกฎเกณฑ์ (เช่น rule-based/SPC) กลุ่มที่ใช้การเรียนรู้แบบมีผู้สอน (supervised learning) และกลุ่มการเรียนรู้แบบไม่มีผู้สอน (unsupervised learning) โดยวิธีเชิงสถิติหรือกฎเกณฑ์

มักต้องอาศัยสมมติฐานเกี่ยวกับความคงที่ของสัญญาณและต้องปรับพารามิเตอร์ให้เหมาะกับแต่ละกระบวนการ ขณะที่วิธีแบบมีผู้สอนต้องพึ่งพาข้อมูลที่มีป้ายกำกับความเสียหาย ซึ่งในทางปฏิบัติข้อมูลความเสียหายจริงมักมีจำกัดและเกิดขึ้นไม่บ่อยในสายการผลิต ส่วนแนวทางการเรียนรู้แบบไม่มีผู้สอน เช่น Isolation Forest มีความเหมาะสมกับบริบทอุตสาหกรรมมากขึ้นเพราะไม่ต้องใช้ข้อมูลป้ายกำกับ อย่างไรก็ตาม งานจำนวนหนึ่งยังขาดแนวทางการตั้งค่าเกณฑ์การตัดสินใจที่เป็นระบบ ทำให้การนำไปใช้จริงอาจต้องอาศัยการตั้งค่าแบบประสบการณ์หรือ fixed threshold

แนวทางของงานวิจัยนี้มีจุดเด่นเชิงแนวคิดที่สำคัญ คือการผสมผสาน Isolation Forest กับ Quantile Threshold เพื่อให้การตัดสินใจผิดปกติอิงกับการกระจายตัวของค่า Anomaly Score ในสถานการณ์ทำงานจริง ซึ่งช่วยลดข้อจำกัดของ fixed threshold ที่ต้องสมมติความคงที่ของสัญญาณ และเพิ่มความยืดหยุ่นต่อความแปรผันของกระบวนการผลิต ส่งผลให้สามารถเน้นการตรวจจับเชิงล่วงหน้า (early detection) พร้อมควบคุม False Alarm ได้เหมาะสมยิ่งขึ้นในระบบจริง

ในมุมมองของการบำรุงรักษาเชิงคาดการณ์ (predictive maintenance) ผลลัพธ์ของงานวิจัยนี้สะท้อนให้เห็นว่า ระบบตรวจจับที่สามารถให้สัญญาณเตือนล่วงหน้าได้อย่างเหมาะสมจะช่วยลดความเสี่ยงจากการแตกหักของเครื่องมือตัด ลดเวลาหยุดเครื่องจักร (downtime) ลดของเสียจากคุณภาพชิ้นงานที่ลดลง และสนับสนุนการวางแผนการเปลี่ยนเครื่องมือได้อย่างมีประสิทธิภาพมากขึ้น นอกจากนี้ การใช้โมเดลที่มีต้นทุนการคำนวณต่ำและไม่ต้องพึ่งพาข้อมูลป้ายกำกับยังเอื้อต่อการประยุกต์ใช้แบบเรียลไทม์ และการติดตั้งบนอุปกรณ์ใกล้เครื่องจักร (edge computing) ซึ่งเหมาะกับบริบทโรงงานที่ต้องการระบบเตือนภัยที่รวดเร็วและเชื่อถือได้

สำหรับความเหมาะสมต่ออุตสาหกรรมไทย แนวทางที่นำเสนอมีความสอดคล้องกับข้อจำกัดที่พบได้บ่อย เช่น การขาดข้อมูลความเสียหายที่ติดป้ายกำกับ การมีข้อจำกัดด้านทรัพยากรบุคคลและโครงสร้างพื้นฐานด้านข้อมูล รวมถึงความต้องการวิธีที่ติดตั้งง่ายและดูแลรักษาได้จริงในสายการผลิต การใช้ Isolation Forest ร่วมกับ Quantile Threshold ซึ่งมีขั้นตอนการคำนวณไม่ซับซ้อนและสามารถปรับเทียบค่าเกณฑ์จากข้อมูลช่วงต้นได้ จึงเป็นแนวทางที่มีศักยภาพในการนำไปใช้งานจริงได้ในโรงงานไทย โดยเฉพาะในกรณีที่ต้องการเริ่มต้นระบบเฝ้าระวังสภาพเครื่องมือด้วยต้นทุนที่เหมาะสม และสามารถขยายผลในอนาคตได้

4.8.6 การอภิปรายเปรียบเทียบกับงานวิจัยที่เกี่ยวข้องก่อนหน้านี้

งานวิจัยที่เกี่ยวข้องกับการตรวจจับความผิดปกติในกระบวนการตัดเฉือนด้วยเครื่องจักร CNC ได้มีการนำเทคนิคการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกมาใช้ในหลากหลายรูปแบบ โดยเฉพาะการวิเคราะห์สัญญาณจากกระบวนการผลิต เช่น สัญญาณกระแสไฟฟ้าของสปินเดิลและสัญญาณการสั่นสะเทือน อย่างไรก็ตาม แนวคิด วิธีการ และเป้าหมายของงานวิจัยก่อนหน้านี้ยังคงมีความแตกต่างจากงานวิจัยนี้อย่างชัดเจน

งานวิจัยของ Li et al. (2021) เรื่อง Deep Anomaly Detection for CNC Machine Cutting Tool Using Spindle Current Signals ได้นำเทคนิคการเรียนรู้เชิงลึกมาใช้ในการตรวจจับความผิดปกติของเครื่องมือตัดโดยอาศัยสัญญาณกระแสไฟฟ้าของสปินเดิลเป็นแหล่งข้อมูลหลัก งานดังกล่าวใช้แบบจำลองโครงข่ายประสาทเทียมเชิงลึกเพื่อเรียนรู้รูปแบบปกติของสัญญาณ และตรวจจับความผิดปกติเมื่อรูปแบบของสัญญาณเบี่ยงเบนไปจากสภาวะปกติ โดยมุ่งเน้นการตรวจจับความผิดปกติในเชิงสัญญาณเป็นหลัก แม้งานวิจัยดังกล่าวจะแสดงให้เห็นถึงความสามารถของการเรียนรู้เชิงลึกในการตรวจจับความผิดปกติได้อย่างมีประสิทธิภาพ แต่ผลลัพธ์ที่ได้นั้นยังไม่ได้เชื่อมโยงโดยตรงกับอายุการใช้งานจริงของเครื่องมือตัดหรือค่าการสึกหรอเชิงกายภาพ เช่น Flank Wear (VBmax) นอกจากนี้การออกแบบระบบยังมุ่งเน้นไปที่ความแม่นยำในการตรวจจับเชิงเทคนิค มากกว่าการนำผลลัพธ์ไปใช้เป็นเครื่องมือสนับสนุนการตัดสินใจด้านการบำรุงรักษาเชิงปฏิบัติ

อีกงานหนึ่งคือผลงานของ Kounta et al. (2023) เรื่อง Deep Learning for the Detection of Machining Vibration Chatter ซึ่งมุ่งเน้นการตรวจจับการสั่นสะเทือนแบบ chatter ในกระบวนการตัดเฉือน โดยแปลงสัญญาณการสั่นสะเทือนจากโดเมนเวลาไปเป็นโดเมนความถี่ และนำข้อมูลดังกล่าวไปใช้กับแบบจำลอง Convolutional Neural Network (CNN) แบบถ่ายโอนการเรียนรู้ เช่น VGG16 และ ResNet50 เพื่อจำแนกสภาวะการทำงานของเครื่องจักรออกเป็นหลายคลาส ได้แก่ การไม่ตัดเฉือน การตัดเฉือนปกติ และการเกิด chatter งานวิจัยนี้มีจุดเด่นในด้านความแม่นยำในการจำแนกสถานะการสั่นสะเทือนของเครื่องจักร และเหมาะสมกับงานควบคุมคุณภาพเชิงสัญญาณ อย่างไรก็ตาม แนวทางดังกล่าวยังคงต้องอาศัยข้อมูลที่มีการกำหนดฉลากล่วงหน้า และมุ่งเน้นการจำแนกสถานะของสัญญาณ มากกว่าการตรวจจับการเสื่อมสภาพเชิงค่อยเป็นค่อยไปของเครื่องมือตัดตามอายุการใช้งานจริง

เมื่อเปรียบเทียบกับงานวิจัยก่อนหน้านี้ทั้งสอง งานวิจัยนี้มีความแตกต่างที่ชัดเจนทั้งในเชิงแนวคิดและการประยุกต์ใช้งาน โดยเลือกใช้วิธีการตรวจจับความผิดปกติแบบไม่มีผู้สอน (Unsupervised Anomaly Detection) ด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) เพื่อรองรับข้อมูลแรงตัดและสัญญาณการสั่นสะเทือนที่มีลักษณะไม่คงที่ตามเวลา และไม่ต้องอาศัยข้อมูลที่มีการกำหนดฉลากล่วงหน้า

ที่สำคัญ งานวิจัยนี้ได้เชื่อมโยงผลการตรวจจับความผิดปกติเข้ากับอายุการใช้งานจริงของหัวเจาะ โดยอ้างอิงจากค่าการสึกหรอแบบผิวหกลบสูงสุด (VBmax) ซึ่งตรวจวัดด้วยกล้องจุลทรรศน์ ทำให้สามารถนำผลลัพธ์ไปใช้ในการสนับสนุนการตัดสินใจด้านการบำรุงรักษาเชิงปฏิบัติได้อย่างเป็นรูปธรรม แตกต่างจากงานวิจัยก่อนหน้านี้ที่มุ่งเน้นการตรวจจับหรือการจำแนกสัญญาณเป็นหลัก

ดังนั้น งานวิจัยนี้จึงช่วยเติมเต็มช่องว่างของงานวิจัยเดิม โดยขยายขอบบาทของการตรวจจับความผิดปกติจากระดับการวิเคราะห์สัญญาณ ไปสู่การสนับสนุนการบำรุงรักษาตามสภาพจริง

(Condition-based Maintenance) และการลดความสูญเสียในกระบวนการผลิต ซึ่งสอดคล้องกับบริบทการใช้งานในอุตสาหกรรมจริง

4.8.7 การอภิปรายการประยุกต์ใช้แนวทางที่นำเสนอเกี่ยวกับเครื่องจักรและหัวเจาะชนิดอื่น

แม้ว่างานวิจัยนี้จะทำการทดลองและประเมินผลกับเครื่องจักร CNC และหัวเจาะภายใต้เงื่อนไขการตัดเฉือนที่กำหนดไว้เฉพาะเจาะจง แต่แนวทางการตรวจจับความผิดปกติที่นำเสนอสามารถขยายผลไปประยุกต์ใช้กับเครื่องจักรและหัวเจาะชนิดอื่นได้ โดยไม่จำเป็นต้องปรับเปลี่ยนโครงสร้างหลักของแบบจำลองอย่างมีนัยสำคัญ

เนื่องจากขั้นตอนวิธีป่าแยกตัว (Isolation Forest) เป็นวิธีการตรวจจับความผิดปกติแบบไม่มีผู้สอน (Unsupervised Learning) ซึ่งเรียนรู้พฤติกรรมปกติของระบบจากข้อมูลจริงที่วัดได้จากเซนเซอร์ โดยไม่อาศัยข้อมูลที่มีการกำหนดคณณาล่วงหน้า แนวทางดังกล่าวจึงมีความยืดหยุ่นสูงและเหมาะสมกับบริบทของโรงงานอุตสาหกรรมที่มีการเปลี่ยนแปลงชนิดเครื่องจักร เครื่องมือตัด หรือสภาวะการผลิตอยู่เสมอ ในกรณีของการนำไปใช้กับเครื่องจักร CNC รุ่นใหม่ หรือเครื่องจักรจากผู้ผลิตรายอื่น แนวทางที่นำเสนอสามารถประยุกต์ใช้ได้โดยการเก็บข้อมูลแรงตัดและการสั่นสะเทือนในช่วงเริ่มต้นการใช้งาน เพื่อให้แบบจำลองเรียนรู้ลักษณะการทำงานปกติของเครื่องจักรนั้น ๆ โดยตรง แม้โครงสร้างทางกลระบบควบคุม หรือความแข็งแรงของสปินเดิลจะแตกต่างกัน แต่หลักการตรวจจับความผิดปกติจากการเปลี่ยนแปลงของรูปแบบสัญญาณยังคงสามารถใช้งานได้ ในทำนองเดียวกัน การประยุกต์ใช้กับหัวเจาะชนิดใหม่ หรือหัวเจาะที่มีวัสดุ การเคลือบผิว หรืออายุการใช้งานแตกต่างจากหัวเจาะที่ใช้ในการทดลอง สามารถดำเนินการได้โดยการปรับค่าเกณฑ์การตัดสินใจผ่านากำหนดค่า Quantile Threshold จากการกระจายตัวของค่าคะแนนความผิดปกติที่ได้จากข้อมูลจริงของหัวเจาะนั้น ๆ โดยไม่จำเป็นต้องกำหนดอายุการใช้งานแบบคงที่ล่วงหน้า แนวทางนี้ช่วยให้ระบบสามารถสะท้อนอายุการใช้งานจริงของเครื่องมือตัดได้อย่างเหมาะสมกับสภาวะการผลิต

นอกจากนี้ แนวทางที่นำเสนอไม่ได้จำกัดอยู่เฉพาะเครื่องจักร CNC เท่านั้น แต่ยังสามารถประยุกต์ใช้กับเครื่องจักรอุตสาหกรรมประเภทอื่นที่มีลักษณะการทำงานแบบหมุนหรือมีการเกิดการสึกหรอของชิ้นส่วนจากแรง ความร้อน และการเสียดสี เช่น เครื่องกลึงแบบแมนนวล เครื่องกัดแบบดั้งเดิม เครื่องปั๊มโลหะ เครื่องฉีดพลาสติก เครื่องอัดรีด รวมถึงเครื่องจักรกลหมุนในอุตสาหกรรมหนัก เช่น ปั๊มอุตสาหกรรม คอมเพรสเซอร์ และระบบสายพานลำเลียง โดยอาศัยสัญญาณจากเซนเซอร์แรง การสั่นสะเทือน กระแสไฟฟ้าของมอเตอร์ หรืออุณหภูมิเป็นข้อมูลนำเข้าในการตรวจจับความผิดปกติ

ที่สำคัญ การตรวจจับความผิดปกติล่วงหน้าก่อนถึงจุดสิ้นสุดอายุการใช้งานจริงของเครื่องมือหรือชิ้นส่วน ยังช่วยลดความเสี่ยงจากความเสียหายที่ไม่คาดคิด ซึ่งอาจเกิดจากปัจจัยภายนอก เช่น ความไม่สม่ำเสมอของวัสดุ การติดตั้งผิด หรือการเปลี่ยนแปลงสภาวะการทำงานโดยฉับพลัน โดยเฉพาะในกรณีของการผลิตชิ้นงานที่มีมูลค่าสูง หากไม่มีระบบตรวจจับลักษณะนี้รองรับ การตั้งค่าการผลิตตาม

อายุการใช้งานคงที่เพียงอย่างเดียวอาจนำไปสู่ความเสียหายของชิ้นงานหรือการหยุดเครื่องจักรแบบไม่คาดคิดได้ ดังนั้น แนวทางที่นำเสนอในงานวิจัยนี้จึงสามารถสนับสนุนการเปลี่ยนผ่านจากการบำรุงรักษาแบบกำหนดรอบคงที่ ไปสู่การบำรุงรักษาตามสภาพจริง (Condition-based Maintenance) ได้ในวงกว้างครอบคลุมทั้งเครื่องจักร CNC และเครื่องจักรอุตสาหกรรมประเภทอื่น โดยช่วยเพิ่มความยืดหยุ่นในการตัดสินใจ ลดความสูญเสีย และเพิ่มความคุ้มค่าในการใช้ทรัพยากรในระบบการผลิตอุตสาหกรรม

4.8.8 นัยต่อการประยุกต์ใช้ในระบบตรวจสอบแบบเรียลไทม์

จากมุมมองเชิงระบบ ผลลัพธ์ของงานวิจัยนี้ชี้ให้เห็นว่า Isolation Forest ร่วมกับ Quantile Threshold มีศักยภาพสูงในการนำไปประยุกต์ใช้ในระบบตรวจสอบสภาพเครื่องมือตัดแบบเรียลไทม์ (real-time monitoring system) ประการสำคัญคือ วิธีการที่นำเสนอไม่จำเป็นต้องใช้ข้อมูลที่ติดป้ายกำกับ (Unsupervised Learning) ซึ่งสอดคล้องกับข้อจำกัดของโรงงานอุตสาหกรรมที่ไม่สามารถเก็บข้อมูลความเสียหายจริงได้อย่างเป็นระบบ นอกจากนี้ การคำนวณค่า Anomaly Score และการกำหนดค่าเกณฑ์ด้วยวิธีควอนไทล์สามารถดำเนินการได้ด้วยต้นทุนการคำนวณต่ำ ทำให้เหมาะสมกับการติดตั้งบนระบบควบคุมหรืออุปกรณ์ประมวลผลที่ขอบระบบ (edge computing) การกำหนดค่าเกณฑ์แบบ Adaptive ยังช่วยลดภาระในการตั้งค่าระบบด้วยมือ และสามารถปรับค่าเกณฑ์ให้สอดคล้องกับข้อมูลที่สะสมใหม่ได้เป็นระยะ ส่งผลให้ระบบมีความยืดหยุ่นและสามารถใช้งานได้ในระยะยาวโดยไม่ต้องหยุดระบบเพื่อปรับปรุงแบบจำลองบ่อยครั้ง ในเชิงการประยุกต์ใช้งานจริง วิธีการที่นำเสนอสามารถนำไปใช้ได้หลายบริบทของกระบวนการผลิตอุตสาหกรรม ตัวอย่างเช่น

4.8.8.1 ระบบแจ้งเตือนการสึกหรอของเครื่องมือตัดล่วงหน้า (Early Warning System) ในสายการผลิตที่ใช้เครื่อง CNC อย่างต่อเนื่อง ระบบสามารถประมวลผลข้อมูลแรงตัดและแรงสั่นสะเทือนแบบเรียลไทม์ และคำนวณค่า Anomaly Score ในแต่ละรอบการทำงาน เมื่อค่าความผิดปกติสูงเกินค่าเกณฑ์ควอนไทล์ที่กำหนด ระบบจะส่งสัญญาณเตือนว่าหัวเครื่องมือตัดเริ่มเข้าสู่สภาวะสึกหรอผิดปกติ ช่วยให้ผู้ควบคุมเครื่องสามารถวางแผนเปลี่ยนเครื่องมือได้ล่วงหน้า ก่อนเกิดการแตกหักหรือคุณภาพชิ้นงานลดลง

4.7.8.2 การสนับสนุนการบำรุงรักษาเชิงพยากรณ์ (Predictive Maintenance) วิธีการนี้สามารถใช้เป็นส่วนหนึ่งของระบบบำรุงรักษาเชิงพยากรณ์ โดยอาศัยแนวโน้มของค่า Anomaly Score ที่เพิ่มขึ้นอย่างต่อเนื่องในการประเมินอายุการใช้งานของเครื่องมือตัด ช่วยลดการเปลี่ยนเครื่องมือก่อนเวลาอันควร (over-maintenance) และลดความเสี่ยงจากการใช้งานเกินอายุ (under-maintenance) ซึ่งส่งผลโดยตรงต่อการลดต้นทุนการผลิตและเวลาหยุดเครื่องจักร (downtime)

4.7.8.3 การใช้งานบนอุปกรณ์ Edge Computing ในโรงงานจริง เนื่องจากแบบจำลอง Isolation Forest และการคำนวณค่า Quantile Threshold ไม่ต้องใช้ทรัพยากรการประมวลผลสูง ระบบจึงสามารถติดตั้งบนอุปกรณ์ประมวลผลใกล้เครื่องจักร เช่น Industrial PC หรือ Embedded

System โดยไม่จำเป็นต้องส่งข้อมูลทั้งหมดไปยังเซิร์ฟเวอร์กลาง ช่วยลดความหน่วงของระบบ (latency) และเพิ่มความน่าเชื่อถือของการตรวจจับความผิดปกติในสภาวะการผลิตจริง

4.8.8.4 การประยุกต์ใช้กับวัสดุและสภาวะการตัดที่หลากหลาย จากผลการทดลองที่ครอบคลุมวัสดุหลายชนิด เช่น เหล็กและอะลูมิเนียม แสดงให้เห็นว่าวิธีการกำหนดค่าเกณฑ์แบบควอนไทล์สามารถปรับตัวให้เหมาะสมกับลักษณะข้อมูลของแต่ละวัสดุได้โดยอัตโนมัติ ทำให้ระบบเดียวกันสามารถนำไปใช้งานกับสายการผลิตที่มีการเปลี่ยนวัสดุหรือเงื่อนไขการตัดได้ โดยไม่ต้องปรับแต่งโมเดลใหม่ทุกครั้ง

โดยสรุป วิธีการที่นำเสนอในงานวิจัยนี้ไม่เพียงแต่มีประสิทธิภาพในเชิงการตรวจจับความผิดปกติเท่านั้น แต่ยังมีความเหมาะสมต่อการนำไปใช้งานจริงในโรงงานอุตสาหกรรม ทั้งในด้านต้นทุน ความยืดหยุ่น และความสามารถในการขยายระบบในอนาคต

4.8.9 ขอบเขตการใช้งานและการปรับเทียบเมื่อเปลี่ยนเครื่องมือหรือเงื่อนไขการผลิต

แม้ว่าวิธีการตรวจจับความผิดปกติด้วยขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) ที่นำเสนอในงานวิจัยนี้จะให้ผลลัพธ์ที่น่าพอใจในทุกชุดข้อมูลทดลอง แต่การนำไปประยุกต์ใช้งานในสภาพแวดล้อมการผลิตจริงจำเป็นต้องพิจารณาขอบเขตการใช้งานและการปรับเทียบค่าเกณฑ์ให้เหมาะสมกับบริบทของกระบวนการผลิตนั้น ๆ

ผลการทดลองแสดงให้เห็นว่าการกระจายตัวของค่า Anomaly Score มีความแตกต่างกันอย่างชัดเจนในแต่ละชุดข้อมูล ซึ่งได้รับอิทธิพลจากหลายปัจจัย ได้แก่ คุณสมบัติทางกลของวัสดุชิ้นงาน รูปทรงและชนิดของเครื่องมือตัด รวมถึงสภาวะการตัดเฉือน เช่น ความเร็วรอบสปินเดิล อัตราป้อน และความลึกในการตัด ดังนั้น การใช้ค่า Fixed Threshold ค่าเดียวเพื่อครอบคลุมทุกกรณีจึงไม่เหมาะสมและอาจนำไปสู่การแจ้งเตือนที่คลาดเคลื่อนหรือเกิดการเตือนล่วงหน้ามากเกินไป (False Alarm) อย่างไรก็ตาม แนวทางที่นำเสนอในงานวิจัยนี้มีความยืดหยุ่นสูง โดยสามารถปรับใช้กับวัสดุและกระบวนการผลิตที่หลากหลายได้ผ่านการปรับเทียบค่าเกณฑ์ใหม่ (recalibration) จากข้อมูลช่วงต้นของการใช้งานเครื่องมือ ซึ่งเป็นช่วงที่เครื่องมือยังอยู่ในสภาวะปกติ (healthy state) วิธีการดังกล่าวไม่จำเป็นต้องฝึกแบบจำลอง Isolation Forest ใหม่ทั้งหมด หากลักษณะของสัญญาณยังคงอยู่ในโดเมนเดียวกัน ทำให้สามารถลดภาระด้านการคำนวณและเพิ่มความสะดวกในการนำไปใช้งานจริงในโรงงานอุตสาหกรรม นอกจากนี้ งานวิจัยนี้สามารถประยุกต์ใช้กับวัสดุโลหะได้หลากหลายประเภท ไม่จำกัดเฉพาะเหล็กกล้าเท่านั้น เนื่องจากวิธีการตรวจจับความผิดปกติอาศัยรูปแบบการเปลี่ยนแปลงของสัญญาณแรงและแรงบิดตามเวลา มากกว่าค่าขนาดเชิงสัมบูรณ์ของสัญญาณ แม้ว่าวัสดุโลหะแต่ละชนิดจะมีความแข็ง ความเหนียว และความต้านทานแรงเฉือนแตกต่างกัน แต่เมื่อเครื่องมือตัดเริ่มเกิดการสึกหรอหรือความเสียหาย รูปแบบของสัญญาณจะมีลักษณะเบี่ยงเบนจากสภาวะปกติในเชิงสถิติ ซึ่งสามารถตรวจจับได้ด้วยวิธีที่นำเสนอ โดยตัวอย่างวัสดุโลหะที่สามารถนำไปประยุกต์ใช้งานแสดงไว้ในตารางที่ 4.7

ในทำนองเดียวกัน ชนิดของเครื่องมือตัดก็เป็นอีกปัจจัยสำคัญที่ส่งผลต่อพฤติกรรมของสัญญาณแรงและแรงบิด เครื่องมือตัดแต่ละประเภท เช่น ดอกสว่าน เ็นมิล หรือดอกกัดผิว จะมีรูปแบบการรับแรงและลักษณะการสึกหรอที่แตกต่างกัน อย่างไรก็ตาม วิธีการตรวจจับความผิดปกติที่นำเสนอสามารถนำไปประยุกต์ใช้กับเครื่องมือตัดหลากหลายชนิดได้ โดยอาศัยการปรับเทียบค่า Quantile Threshold จากข้อมูลช่วงต้นของการใช้งานเครื่องมือแต่ละประเภท ซึ่งช่วยให้ระบบสามารถปรับตัวให้สอดคล้องกับลักษณะเฉพาะของเครื่องมือได้ ตัวอย่างเครื่องมือตัดที่สามารถนำไปประยุกต์ใช้งานแสดงไว้ในตารางที่ 4.8

ดังนั้น งานวิจัยนี้จึงมีศักยภาพในการนำไปประยุกต์ใช้กับกระบวนการตัดเฉือนโลหะในอุตสาหกรรมหลากหลายสาขา เช่น อุตสาหกรรมยานยนต์ อากาศยาน แม่พิมพ์ และชิ้นส่วนเครื่องจักร โดยผู้ใช้งานสามารถปรับค่า Quantile Threshold ให้เหมาะสมกับทั้งชนิดของวัสดุ เครื่องมือตัด และสภาวะการผลิต เพื่อเพิ่มความแม่นยำในการตรวจจับความผิดปกติและสนับสนุนการบำรุงรักษาเชิงพยากรณ์ได้อย่างมีประสิทธิภาพ

ตารางที่ 4.8 ตัวอย่างวัสดุโลหะที่สามารถประยุกต์ใช้วิธีการตรวจจับความผิดปกติที่นำเสนอ

ลำดับ	วัสดุโลหะ	คุณสมบัติเด่น	ตัวอย่างการใช้งาน
1	เหล็กกล้าคาร์บอน (Carbon Steel)	แข็งแรง ตัดเฉือนได้ง่าย	ชิ้นส่วนเครื่องจักร โครงสร้าง
2	เหล็กกล้าเครื่องมือ (Tool Steel)	ความแข็งแรงสูง ทนการสึกหรอ	แม่พิมพ์ เครื่องมือตัด
3	สแตนเลสสตีล (Stainless Steel)	ทนการกัดกร่อน เหนียว	อาหาร การแพทย์ เพลา
4	อะลูมิเนียมอัลลอย (Aluminum Alloy)	น้ำหนักเบา ระบาย ความร้อนดี	ยานยนต์ อากาศยาน
5	ทองแดง (Copper)	นำไฟฟ้าและความร้อนสูง	อิเล็กทรอนิกส์ ฮีตซิงก์
6	ทองเหลือง (Brass)	ตัดง่าย เสถียร	วาล์ว ฟิตติ้ง
7	ไทเทเนียมอัลลอย (Titanium Alloy)	แข็งแรง น้ำหนักเบา	อากาศยาน อุปกรณ์แพทย์
8	นิกเกิลอัลลอย (Nickel Alloy)	ทนความร้อนสูง	เทอร์ไบน์ โรงไฟฟ้า
9	เหล็กหล่อ (Cast Iron)	ดูดซับแรงสั่นสะเทือนได้ดี	ฐานเครื่องจักร
10	แมกนีเซียมอัลลอย (Magnesium Alloy)	เบามาก ตัดเร็ว	โครงสร้างยานยนต์

ตารางที่ 4.9 ตัวอย่างเครื่องมือตัดที่สามารถประยุกต์ใช้วิธีการตรวจจับความผิดปกติที่นำเสนอ

ลำดับ	เครื่องมือตัด	ลักษณะเด่น	รูปแบบการสึกหรอที่พบบ่อย	ตัวอย่างการใช้งาน
1	ดอกสว่าน (Drill Bit)	รับแรงตามแนวแกนสูง	Flank wear, Chipping	การเจาะรู
2	เอ็นมิลปลายเรียบ (Flat End Mill)	ตัดด้านข้างและผิวราบ	Flank wear, Corner wear	กัดร่อง กัดผิว
3	เอ็นมิลปลายบอล (Ball Nose End Mill)	ผิวสัมผัสต่อเนื่อง	Wear ที่ปลายโค้ง	แม่พิมพ์ 3D
4	ดอกกัดผิวหน้า (Face Mill)	ตัดพื้นที่กว้าง	Insert wear	กัดผิวหน้า
5	ดอกกัดร่อง (Slot Mill)	รับแรงหลายทิศทาง	Flank wear	กัดร่อง
6	ดอกกัดเกลียว (Thread Mill)	ตัดซับซ้อน	Edge wear	ทำเกลียว
7	ดอกรีมเมอร์ (Reamer)	ความเที่ยงตรงสูง	Wear ที่คมตัด	ขยายรู
8	ดอกกัด T-slot	รูปทรงเฉพาะ	Corner wear	ร่อง T
9	ดอกกัดหยาบ (Roughing End Mill)	ตัดกินเนื้อเร็ว	Chipping	งานหยาบ
10	ดอกกัดคาร์ไบด์เคลือบผิว	ทนการสึกหรอสูง	Coating wear	งานความเร็วสูง

4.8.9.1 อิทธิพลของชนิดเซนเซอร์ต่อพฤติกรรมการกระจายของ Anomaly Score

จากผลการทดลองพบว่า การกระจายของค่า Anomaly Score มีความแตกต่างกันอย่างชัดเจนในแต่ละชุดข้อมูล ซึ่งความแตกต่างดังกล่าวไม่ได้เกิดจากโครงสร้างของแบบจำลอง Isolation Forest เพียงอย่างเดียว แต่มีความสัมพันธ์โดยตรงกับชนิดของเซนเซอร์ ลักษณะของสัญญาณที่วัดได้ และวิธีการเก็บข้อมูลที่ใช้ในระบบทดลอง จากงานวิจัยในช่วงเริ่มต้น (เล่มเปิด) การตรวจจับความผิดปกติของสปินเดิลอาศัยข้อมูลการเคลื่อนที่จากเซนเซอร์ attocube ids3010 ซึ่งเป็นเซนเซอร์ที่มีความละเอียดสูงในระดับนาโนเมตรและใช้หลักการวัดเชิงอินเตอร์เฟอโรมิเตอร์ ส่งผลให้สัญญาณที่ได้มีความไวสูงต่อการเปลี่ยนแปลงขนาดเล็กของตำแหน่งและการสั่นของสปินเดิล แม้ในสถานะที่เครื่องมือยังไม่เกิดการสึกหรออย่างมีนัยสำคัญ ลักษณะของสัญญาณดังกล่าวมีแนวโน้มใกล้เคียงกับสัญญาณเชิงสถิตินิ่ง (quasi-stationary) ทำให้การกระจายของค่า Anomaly Score มีความสม่ำเสมอและเปลี่ยนแปลงตามเวลาในระดับจำกัด ในทางตรงกันข้าม งานวิจัยฉบับนี้ใช้ข้อมูลแรงตัดและแรงสั่นสะเทือน ซึ่งเป็น

สัญญาณที่สะท้อนปฏิสัมพันธ์ระหว่างเครื่องมือตัด ชิ้นงาน และสถานะการตัดเฉือนโดยตรง สัญญาณดังกล่าวมีลักษณะไม่คงที่ตามเวลา (non-stationary) และได้รับอิทธิพลจากปัจจัยภายนอกหลายประการ เช่น ความเร็วรอบสปินเดิล อัตราป้อน ความลึกในการตัด รวมถึงการเปลี่ยนแปลงของสภาพผิวและการสึกหรอของเครื่องมือตัด ส่งผลให้การกระจายของค่า Anomaly Score มีความแปรปรวนสูงและเปลี่ยนแปลงไปตามช่วงการทำงานของกระบวนการผลิต ความแตกต่างของลักษณะสัญญาณจากเซนเซอร์แต่ละประเภทส่งผลโดยตรงต่อพฤติกรรมการแยกตัว (isolation) ของข้อมูลภายในแบบจำลอง Isolation Forest เนื่องจากอัลกอริทึมอาศัยโครงสร้างการกระจายของข้อมูลในปริภูมิคุณลักษณะ (feature space) เป็นหลัก เมื่อชนิดของเซนเซอร์ให้สัญญาณที่มีสเกล ความถี่ และรูปแบบการเปลี่ยนแปลงตามเวลาที่แตกต่างกัน การกระจายของค่า Anomaly Score ที่ได้จึงมีลักษณะเฉพาะตัว และไม่สามารถใช้ค่าเกณฑ์เดียวกันครอบคลุมทุกกรณีได้อย่างเหมาะสม

ผลการวิเคราะห์ดังกล่าวสะท้อนให้เห็นว่า การออกแบบระบบตรวจจับความผิดปกติของเครื่องมือตัดจำเป็นต้องพิจารณาชนิดของเซนเซอร์เป็นองค์ประกอบสำคัญในระดับระบบ (system-level consideration) โดยเฉพาะในกรณีที่มีการเปลี่ยนแปลงแหล่งที่มาของสัญญาณ เช่น จากเซนเซอร์การเคลื่อนที่ไปเป็นเซนเซอร์แรงหรือเซนเซอร์การสัมผัสเทียน การปรับเทียบค่า Quantile Threshold ให้สอดคล้องกับลักษณะการกระจายของ Anomaly Score จากเซนเซอร์แต่ละประเภทจึงเป็นขั้นตอนที่จำเป็น เพื่อหลีกเลี่ยงการแจ้งเตือนผิดพลาดและเพิ่มความแม่นยำของระบบตรวจจับ

จากมุมมองเชิงการต่อยอด งานวิจัยนี้แสดงให้เห็นว่าการเปลี่ยนชนิดของเซนเซอร์เพียงอย่างเดียวสามารถนำไปสู่แนวทางการวิจัยและการประยุกต์ใช้งานที่แตกต่างกันได้ ทั้งในด้านพฤติกรรมของสัญญาณ วิธีการตั้งค่าเกณฑ์ และการออกแบบระบบตรวจสอบแบบเรียลไทม์ ซึ่งเปิดโอกาสให้สามารถพัฒนางานวิจัยต่อยอดในอนาคต โดยศึกษาอิทธิพลของเซนเซอร์ชนิดอื่น ๆ เช่น เซนเซอร์กระแสไฟฟ้าสปินเดิล เซนเซอร์เสียง หรือเซนเซอร์อุณหภูมิ ภายใต้กรอบแนวคิดเดียวกันได้อย่างเป็นระบบ

4.8.9.2 แนวทางการปรับเทียบค่าเกณฑ์เมื่อมีการเปลี่ยนเครื่องมือ วัสดุ หรือชนิดเซนเซอร์

ผลการทดลองแสดงให้เห็นว่า แม้จะใช้แบบจำลอง Isolation Forest ชุดเดียวกัน ค่า Anomaly Score ที่ได้จากแต่ละชุดข้อมูลยังคงมีช่วงค่าและความหนาแน่นของการกระจายที่แตกต่างกันอย่างชัดเจน ความแตกต่างดังกล่าวได้รับอิทธิพลจากหลายปัจจัยร่วมกัน ได้แก่ ชนิดของวัสดุชิ้นงาน รูปทรงและขนาดของเครื่องมือตัด สภาพการตัดเฉือน รวมถึงชนิดของเซนเซอร์ที่ใช้ในการวัดสัญญาณ ในเชิงปฏิบัติ การนำระบบตรวจจับความผิดปกติไปใช้งานกับเครื่องมือ วัสดุ หรือชนิดเซนเซอร์ใหม่ ไม่จำเป็นต้องฝึกแบบจำลอง Isolation Forest ใหม่ทั้งหมด หากลักษณะเชิงโครงสร้างของสัญญาณยังอยู่ในโดเมนเดียวกัน อย่างไรก็ตาม จำเป็นต้องมีการปรับเทียบค่าเกณฑ์การตัดสินใจให้สอดคล้องกับการกระจายของค่า Anomaly Score ที่เปลี่ยนแปลงไป

แนวทางการปรับเทียบที่นำเสนอในงานวิจัยนี้ประกอบด้วยการเก็บข้อมูลในช่วงต้นของการใช้งาน ซึ่งเป็นช่วงที่เครื่องมือตัวยังอยู่ในสภาวะปกติ (healthy state) จากนั้นนำข้อมูลดังกล่าวมาคำนวณค่า Quantile Threshold ใหม่ เพื่อใช้เป็นค่าเกณฑ์ในการตรวจจับความผิดปกติร่วมกับแบบจำลองเดิม วิธีการนี้ช่วยลดภาระด้านข้อมูล เวลา และทรัพยากรการคำนวณ เมื่อเปรียบเทียบกับการฝึกแบบจำลองใหม่ทุกครั้งที่มีการเปลี่ยนแปลงองค์ประกอบของระบบ ในกรณีที่มีการเปลี่ยนชนิดของเซนเซอร์ เช่น จากเซนเซอร์แรงไปเป็นเซนเซอร์การสั่นสะเทือนหรือเซนเซอร์กระแสไฟฟ้าสปีนเดิล ลักษณะของสัญญาณที่ได้จะมีสเกล ความถี่ และคุณสมบัติทางสถิติที่แตกต่างกัน ส่งผลให้การกระจายของค่า Anomaly Score เปลี่ยนแปลงตามไปด้วย อย่างไรก็ตาม หากรูปแบบการเปลี่ยนแปลงของสัญญาณยังสะท้อนพฤติกรรมของกระบวนการตัดเฉือนในลักษณะเดียวกัน การใช้แบบจำลอง Isolation Forest เดิมร่วมกับการปรับเทียบค่า Quantile Threshold ใหม่ยังคงสามารถให้ผลการตรวจจับที่มีประสิทธิภาพได้

แนวคิดดังกล่าวสอดคล้องกับหลักการปรับเทียบระบบวัดและระบบควบคุมในงานอุตสาหกรรม ซึ่งมักเน้นการปรับค่าอ้างอิงหรือค่าเกณฑ์ให้เหมาะสมกับสภาวะการทำงานที่เปลี่ยนแปลง โดยไม่จำเป็นต้องเปลี่ยนโครงสร้างของระบบทั้งหมด ส่งผลให้ระบบตรวจจับความผิดปกติที่นำเสนอมีความยืดหยุ่นสูง สามารถรองรับการเปลี่ยนแปลงของเครื่องมือ วัสดุ และชนิดเซนเซอร์ได้ในระยะยาว และเหมาะสมต่อการนำไปประยุกต์ใช้งานจริงในสภาพแวดล้อมการผลิตที่มีความหลากหลาย


4.8.9.3 การเลือกชนิดเซนเซอร์ภายใต้ข้อจำกัดด้านการใช้งานจริง

จากประสบการณ์ในการพัฒนาและทดสอบระบบทั้งในงานวิจัยเบื้องต้นและงานวิจัยฉบับนี้ พบว่า ชนิดของเซนเซอร์และวิธีการวัดสัญญาณมีผลโดยตรงต่อรูปแบบการกระจายของค่า Anomaly Score และความสามารถในการนำแบบจำลองไปใช้ซ้ำ (reusability) ในงานวิจัยเบื้องต้นมีการใช้ระบบวัดการเคลื่อนที่เชิงเรขาคณิตความละเอียดสูง เช่น ระบบ attocube ids3010 ซึ่งอาศัยหลักการวัดเชิงอินเตอร์เฟอโรมิเตอร์และให้ความละเอียดในระดับนาโนเมตร ดังแสดงใน รูปที่ 4.9 ระบบดังกล่าวสามารถตรวจจับการเปลี่ยนแปลงขนาดเล็กของการเคลื่อนที่ของสปีนเดิลได้อย่างแม่นยำ ส่งผลให้สัญญาณที่ได้มีความเสถียรและมีสัญญาณรบกวนต่ำ ทำให้การกระจายของค่า Anomaly Score มีลักษณะแคบและแยกแยะค่าผิดปกติได้อย่างชัดเจน อย่างไรก็ตาม ระบบดังกล่าวมีข้อจำกัดด้านต้นทุน ความซับซ้อนในการติดตั้ง และความยากในการนำไปใช้งานในสายการผลิตจริงในทางตรงกันข้าม งานวิจัยฉบับนี้มุ่งเน้นการใช้สัญญาณแรงตึงและแรงสั่นสะเทือน ซึ่งสามารถติดตั้งได้ง่ายและเหมาะสมกับสภาพแวดล้อมการผลิตจริง ดังแสดงตัวอย่างระบบการวัดและการประมวลผลข้อมูลใน รูปที่ 4.10 แม้ว่าสัญญาณประเภทนี้จะมีความแปรผันสูงและมีลักษณะ non-stationary แต่สะท้อนพฤติกรรม การสั่นของเครื่องมือตัดในกระบวนการตัดเฉือนได้โดยตรง ส่งผลให้การกระจายของค่า Anomaly Score มีความกว้างและแตกต่างกันไปตามวัสดุ เครื่องมือตัด และสภาวะการผลิต

ดังนั้น งานวิจัยนี้จึงเสนอแนวทางที่เน้น ความสมดุลระหว่างความแม่นยำในการตรวจจับ และความสามารถในการนำไปใช้งานจริง โดยเลือกใช้สัญญาณแรงดันเป็นคุณลักษณะหลักของแบบจำลอง Isolation Forest และใช้การปรับเทียบค่าเกณฑ์ด้วยวิธี Quantile Threshold เป็นกลไกสำคัญในการรองรับความแตกต่างของการกระจายตัวของ Anomaly Score ในแต่ละระบบการผลิต แนวทางดังกล่าวช่วยให้แบบจำลองสามารถนำไปประยุกต์ใช้กับเครื่องจักรและเงื่อนไขการผลิตที่หลากหลายได้ โดยไม่จำเป็นต้องพึ่งพากระบวนการวัดความละเอียดสูงที่มีต้นทุนและความซับซ้อนสูง



รูปที่ 4.9 ระบบวัดการเคลื่อนที่ความละเอียดสูงแบบเชิงเรขาคณิตด้วยเซนเซอร์ attocube (attocube IDS3010)



รูปที่ 4.10 ระบบการวัดเชิงเรขาคณิตแบบแกนหมุน (Rotary-Axis Measurement System) และกระบวนการประมวลผลข้อมูล

บทที่ 5

สรุปและข้อเสนอแนะ

5.1 สรุปผลการวิจัย

งานวิจัยนี้มุ่งเน้นการพัฒนาวิธีการตรวจจับความผิดปกติของเครื่องมือตัดในกระบวนการผลิตด้วยเครื่องจักรควบคุมเชิงตัวเลข (CNC) โดยประยุกต์ใช้ขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ซึ่งเป็นเทคนิคการเรียนรู้แบบไม่มีผู้สอน ร่วมกับการกำหนดค่าเกณฑ์การตรวจจับแบบควอนไทล์ (Quantile Threshold) เพื่อเพิ่มความเหมาะสมในการใช้งานจริงภายใต้สภาวะการผลิตที่มีความแปรผันสูง ข้อมูลที่ใช้ในการวิเคราะห์ประกอบด้วยสัญญาณแรงตัดและแรงสั่นสะเทือนที่ได้จากการทดลองตัดเฉือนวัสดุต่างชนิด ได้แก่ เหล็กและอะลูมิเนียม ซึ่งเป็นวัสดุที่นิยมใช้ในอุตสาหกรรมการผลิต ผลการทดลองแสดงให้เห็นว่าการใช้ค่า Quantile Threshold ในช่วง 0.98–0.99999% สามารถให้ผลการตรวจจับที่มีความแม่นยำ เสถียร และลดอัตราการแจ้งเตือนผิดพลาดได้อย่างมีนัยสำคัญ เมื่อเปรียบเทียบกับการใช้ค่าเกณฑ์แบบคงที่ (Fixed Threshold) นอกจากนี้ การประยุกต์ใช้ตัวกรองค่ามัธยฐาน (Median Filter) ในขั้นตอนการเตรียมข้อมูลช่วยลดผลกระทบจากสัญญาณรบกวนที่เกิดขึ้นระหว่างกระบวนการตัดเฉือน ทำให้รูปแบบของสัญญาณมีความเรียบเนียนและสะท้อนพฤติกรรมของการสึกหรอของเครื่องมือตัดได้ชัดเจนยิ่งขึ้น ส่งผลให้แบบจำลอง Isolation Forest สามารถแยกแยะระหว่างสภาวะปกติและสภาวะผิดปกติได้อย่างมีประสิทธิภาพ

จากผลการวิเคราะห์ทั้งหมด สามารถสรุปได้ว่าวิธีการที่นำเสนอมีศักยภาพในการตรวจจับแนวโน้มการสึกหรอของเครื่องมือตัดล่วงหน้า และเหมาะสมสำหรับการนำไปประยุกต์ใช้ในระบบการบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) ของเครื่องจักร CNC ในสภาพแวดล้อมการผลิตจริง

5.2 ข้อจำกัดของการวิจัย

แม้ว่างานวิจัยนี้จะให้ผลลัพธ์ที่น่าพอใจ แต่ยังมีข้อจำกัดบางประการที่ควรพิจารณา งานวิจัยดำเนินการภายใต้เงื่อนไขการทดลองในห้องปฏิบัติการ ซึ่งสามารถควบคุมพารามิเตอร์การตัดเฉือนและสภาพแวดล้อมได้อย่างค่อนข้างคงที่ ส่งผลให้ข้อมูลที่ได้อาจยังไม่สามารถสะท้อนความซับซ้อนของสภาพการผลิตจริงในโรงงานอุตสาหกรรมได้ทั้งหมด เช่น การเปลี่ยนแปลงของอุณหภูมิ การสั่นสะเทือนจากเครื่องจักรข้างเคียง หรือความแปรผันของคุณภาพวัตถุดิบ อีกทั้งชุดข้อมูลที่ใช้ในการศึกษาเป็นข้อมูลจากวัสดุเพียงบางประเภท ได้แก่ เหล็กและอะลูมิเนียม ซึ่งแม้จะเป็นวัสดุที่พบได้ทั่วไป แต่ยังไม่สามารถ

สรุปผลไปยังวัสดุโลหะหรือวัสดุชั้นสูงอื่น ๆ ได้โดยตรง นอกจากนี้ ขั้นตอนวิธี Isolation Forest อาศัยกระบวนการสุ่มตัวอย่าง (Random Partitioning) ในการสร้างต้นไม้ตัดสินใจแบ่งข้อมูล ซึ่งอาจทำให้ผลลัพธ์มีความแปรผันเล็กน้อยในแต่ละรอบการทดลอง แม้ว่าจะมีการกำหนดค่า seed สำหรับการสุ่มแล้วก็ตาม อีกข้อจำกัดที่สำคัญคือ การเลือกค่า Quantile Threshold ยังต้องอาศัยการปรับจูนจากข้อมูลจริงในแต่ละกรณี ซึ่งอาจไม่เหมาะสมกับระบบการผลิตที่มีการเปลี่ยนแปลงสภาวะการทำงานบ่อยครั้ง เช่น การเปลี่ยนชนิดเครื่องมือตัดหรือพารามิเตอร์การตัดอย่างต่อเนื่อง ข้อจำกัดเหล่านี้ชี้ให้เห็นถึงความจำเป็นในการพัฒนาแนวทางที่มีความยืดหยุ่นและสามารถปรับตัวได้อัตโนมัติในอนาคต

5.3 การประยุกต์ผลการวิจัย

ผลการวิจัยนี้สามารถนำไปประยุกต์ใช้ในการพัฒนาระบบตรวจจับความผิดปกติของเครื่องมือตัดและสปินเดิลในกระบวนการผลิตแบบอัตโนมัติได้อย่างมีประสิทธิภาพ โดยอาศัยขั้นตอนวิธีป่าแยกตัว (Isolation Forest) ร่วมกับการกำหนดค่าเกณฑ์แบบควอนไทล์ (Quantile Threshold) ซึ่งสามารถปรับให้เหมาะสมกับลักษณะข้อมูลของเครื่องจักรแต่ละเครื่องและสภาวะการผลิตที่แตกต่างกันได้ในเชิงอุตสาหกรรม แนวทางที่นำเสนอสามารถประยุกต์ใช้กับเครื่อง CNC หลายประเภทและหลายกระบวนการ เช่น การกัด การเจาะ และการกลึง โดยใช้ข้อมูลแรงตัดและแรงสั่นสะเทือนซึ่งสามารถวัดได้จากเซนเซอร์มาตรฐานที่มีใช้อยู่ในโรงงานทั่วไป ทำให้ไม่จำเป็นต้องลงทุนติดตั้งระบบตรวจวัดเฉพาะทางที่มีต้นทุนสูง

ในมุมมองของการนำไปใช้งานจริง แนวทางที่นำเสนอมีความเหมาะสมต่อการติดตั้งในระบบตรวจสอบแบบเรียลไทม์ (real-time monitoring system) เนื่องจากขั้นตอนวิธี Isolation Forest และการคำนวณค่า Quantile Threshold มีต้นทุนการประมวลผลต่ำ และสามารถดำเนินการได้ต่อเนื่องตามรอบการทำงานของเครื่องจักร ระบบสามารถคำนวณค่า Anomaly Score จากข้อมูลที่ไหลเข้ามาแบบสตรีมมิง และเปรียบเทียบกับค่าเกณฑ์ที่กำหนดไว้เพื่อส่งสัญญาณเตือนเมื่อพบแนวโน้มความผิดปกติ ส่งผลให้สามารถตรวจจับการสึกหรอหรือความเสียหายของเครื่องมือตัดได้ล่วงหน้าก่อนเกิดการแตกหักหรือคุณภาพชิ้นงานลดลง

นอกจากนี้ แนวทางดังกล่าวยังสามารถทำงานร่วมกับระบบสารสนเทศการผลิตในระดับโรงงาน เช่น ระบบ Manufacturing Execution System (MES) หรือระบบ Digital Twin ได้ โดยค่า Anomaly Score และสถานะการสึกหรอของเครื่องมือตัดสามารถนำไปใช้เป็นข้อมูลอินพุตในการจำลองสภาพการทำงานของเครื่องจักร การประเมินอายุการใช้งานที่เหลืออยู่ของเครื่องมือ (Remaining Useful Life: RUL) และการวางแผนการผลิตหรือการบำรุงรักษาเชิงคาดการณ์ (Predictive Maintenance) การเชื่อมโยงผลลัพธ์จากแบบจำลองเข้ากับระบบระดับโรงงานจะช่วยให้การตัดสินใจด้านการเปลี่ยนเครื่องมือ การจัดตารางการผลิต และการลดเวลาหยุดเครื่องจักรโดยไม่คาดคิด (unplanned downtime)

มีความแม่นยำและเป็นระบบมากยิ่งขึ้น โดยภาพรวม การประยุกต์ใช้ผลการวิจัยนี้สอดคล้องกับแนวคิดของอุตสาหกรรม 4.0 ซึ่งมุ่งเน้นการใช้ข้อมูลและปัญญาประดิษฐ์เพื่อเพิ่มประสิทธิภาพ ความยืดหยุ่น และความยั่งยืนของกระบวนการผลิตในโรงงานอุตสาหกรรม

5.4 ข้อเสนอแนะในการวิจัยครั้งต่อไป

งานวิจัยในอนาคตควรขยายขอบเขตของชุดข้อมูลให้ครอบคลุมวัสดุประเภทอื่น ๆ เช่น โพลีเอทิลีน โลหะผสมพิเศษ และวัสดุคอมโพสิต เพื่อประเมินความสามารถในการทั่วไป (generalization) ของแบบจำลองภายใต้สภาวะการตัดเฉือนที่หลากหลายยิ่งขึ้น นอกจากนี้ ควรศึกษาผลกระทบของพารามิเตอร์การตัดเฉือนที่แตกต่างกัน เช่น ความเร็วรอบสปินเดิล อัตราป้อน และความลึกของการตัด ต่อรูปแบบของสัญญาณแรงตัดและประสิทธิภาพของการตรวจจับความผิดปกติอย่างเป็นระบบ อีกแนวทางที่สำคัญคือการพัฒนาแบบจำลองให้สามารถรองรับการเรียนรู้แบบปรับตัวได้ (adaptive learning) เพื่อให้ระบบสามารถปรับปรุงพฤติกรรมในการตรวจจับความผิดปกติได้อย่างต่อเนื่องเมื่อสภาวะการผลิตเปลี่ยนไป ตัวอย่างเช่น การปรับค่า Quantile Threshold แบบอัตโนมัติจากข้อมูลใหม่ที่สะสมเข้ามา การอัปเดตแบบจำลอง Isolation Forest เป็นระยะโดยไม่ต้องฝึกใหม่ทั้งหมด หรือการใช้กลไก online learning เพื่อรองรับการเปลี่ยนแปลงของการกระจายตัวของข้อมูล (concept drift) ในระยะยาว แนวทางดังกล่าวจะช่วยเพิ่มความเสถียรและความยืดหยุ่นของระบบเมื่อนำไปใช้งานในสายการผลิตจริงที่มีความไม่แน่นอนสูง

นอกจากนี้ ควรมีการศึกษาและเปรียบเทียบกับขั้นตอนวิธีอื่น ๆ เช่น Autoencoder, LSTM หรือแบบจำลองเชิงผสม (Hybrid Model) เพื่อประเมินจุดเด่นและข้อจำกัดของแต่ละแนวทางทั้งในเชิงความแม่นยำ ต้นทุนการคำนวณ และความสามารถในการตีความผลลัพธ์ ในด้านการนำไปใช้งานจริง งานวิจัยในอนาคตควรมีการทดสอบกับข้อมูลจากโรงงานอุตสาหกรรมภายใต้สภาพแวดล้อมการผลิตที่ซับซ้อน และพัฒนาอินเทอร์เฟซสำหรับแสดงผลการแจ้งเตือนและรายงานสถานะเครื่องจักร เพื่อสนับสนุนการตัดสินใจของผู้ปฏิบัติงานและผู้บริหารในระดับโรงงานอย่างเป็นรูปธรรม

รายการอ้างอิง

- Çekik, R., & Turan, A. (2025). Deep Learning for Anomaly Detection in CNC Machine Vibration Data: A RoughLSTM-Based Approach. *Applied Sciences* (Switzerland), 15(6), 3179. <https://doi.org/10.3390/app15063179>
- DMG MORI, Inc. (2025). *5-Axis Machining Center*. Retrieved from <https://www.dmgmori.co.jp/sp/5axis/th/>
- Falah, A., & Andó, M. (2025). Novel and cost-effective CNC tool condition monitoring through image processing techniques. *Discover Applied Sciences*, 7(1), 69.
- Huang, Y., Ahearne, E., Baron, S., & Parnell, A. (2023). An Evaluation of Methods for Real-Time Anomaly Detection using Force Measurements from the Turning Process. *arXiv preprint arXiv:1812.09178*. Retrieved from <https://github.com/Yuanzhi-H/Real-Time-Detection-Methods>
- Hyndman, R. J., & Fan, Y. (1996). Sample quantiles in statistical packages. *The American Statistician*, 50(4), 361-365.
- Kaitipoomphongsa, P. (2027). Predictive Model for Tool Wear and Anomaly Detection on CNC Machine Tools. *Journal of Information Technology, KMUTNB*. (In press).
- Kistler. (2025). *Kistler 9272 Multicomponent Dynamometer*. Retrieved from <https://www.kistler.com/US/en/cp/multicomponent-dynamometers-9272/P0000682>
- Kounta, C. A. K. A., Arnaud, L., Kamsu-Foguem, B., & Tangara, F. (2023). Deep learning for the detection of machining vibration chatter. *Advances in Engineering Software*, 180, 103445.
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Li, G., Fu, Y., Chen, D., Shi, L., & Zhou, J. (2020). Deep anomaly detection for CNC machine cutting tool using spindle current signals. *Sensors (Switzerland)*, 20(17), 1–18. <https://doi.org/10.3390/s20174896>

- Liu, F. T., Ting, K. M., & Zhou, Z. H. (2008). Isolation forest. In *Eighth IEEE International Conference on Data Mining* (pp. 413–422). Italy: IEEE.
- Makee, C., Kitkamthorn, U., Mitsomwang, P., Chayapiwut, N., Jaisue, A., Hitoshi, K., & Borrisutthekul, R. (2022). Study The Effects of The Multinite Coat of The High-Speed Steel Drill Bit in Drilling. *Suranaree Journal of Science and Technology*. Retrieved from <https://eurekamag.com/research/093/450/093450105.php>
- MarketsandMarkets. (2024). *CNC Machine Market Size, Share & Industry Trends Growth Analysis Report by Offering, Product Type, End-User Industry & Region – Global Forecast to 2028*. Retrieved from <https://www.marketsandmarkets.com/Market-Reports/cnc-market-195192631.html>
- Mesuga, R., & Bayanay, B. J. (2023). A Deep Transfer Learning Approach to Identifying Glitch Wave-form in Gravitational Wave Data. *arXiv:2107.01863*. Retrieved from <https://arxiv.org/abs/2107.01863>
- Montgomery, D. C., Peck, E. A., & Vining, G. G. (2021). *Introduction to linear regression analysis*. New Jersey: Wiley.
- Nachi America Inc. (2025). *HSS-HSCO Calculator*. Retrieved from <https://nachi-america.com/cutting-tools/calculator/26-hss-hsco-calculator/>
- Oh, L., Pitz, E., & Pochiraju, K. (2023). Spindle Condition Monitoring with a Smart Vibration Sensor and an Optimized Deep Neural Network. *Journal of Nondestructive Evaluation, Diagnostics and Prognostics of Engineering Systems*, 6(2), 021003. <https://doi.org/10.1115/1.4056616>
- Olympus Corporation. (2025). *Olympus SZ61 / SZ51 Stereo Microscope*. Retrieved from <https://evidentscientific.com/en/products/upright/sz61-sz51>
- Orabi, M., Tran, K. P., Egger, P., & Thomassey, S. (2024). Anomaly detection in smart manufacturing: An Adaptive Adversarial Transformer-based model. *Journal of Manufacturing Systems*, 77, 591–611. <https://doi.org/10.1016/j.jmsy.2024.09.021>
- Siemens. (2024). *The True Cost of Downtime 2024*. Retrieved from https://assets.new.siemens.com/siemens/assets/api/uuid:1b43afb5-2d07-47f7-9eb7-893fe7d0bc59/TCOD-2024_original.pdf

- Superior Spindle Services. (2024). *What Is a CNC Spindle & How Does It Function?*
Retrieved from <https://www.superiorspindle.com/what-is-a-cnc-spindle-and-how-does-it-function/>
- TENMARS Electronics Co., Ltd. (2025). *ST-140 / ST-140D Vibration Meter*. Retrieved from <https://www.tenmars.com/m/2001-1682-688961,c19115-1.php?Lang=en>
- Truchan, H., & Ahmadi, Z. (2025). Nonastreda multimodal dataset for efficient tool wear state monitoring. *Data in Brief*, 62, 111905. <https://doi.org/10.1016/j.dib.2025.111905>
- Wan, J., Yar, K. P., Du, C., & Low, M. Y. H. (2023). Sensor Data Analytics for Tool Condition Anomaly Detection with Machine Learning Techniques. In *Proceedings of the 2023 5th International Electronics Communication Conference* (pp. 38-45). New York: Association for Computing Machinery. <https://doi.org/10.1145/3616480.3616486>
- Wu, D., Jennings, C., Terpenney, J., Gao, R. X., & Kumara, S. (2017). A Comparative Study on Machine Learning Algorithms for Smart Manufacturing: Tool Wear Prediction Using Random Forests. *Journal of Manufacturing Science and Engineering, Transactions of the ASME*, 139(7), 071018. <https://doi.org/10.1115/1.4036350>
- Yang, Q., Pattipati, K. R., Awasthi, U., & Bollas, G. M. (2022). Hybrid data-driven and model-informed online tool wear detection in milling machines. *Journal of manufacturing systems*, 63, 329-343.
- Yao, K. C., Chen, D. C., Pan, C. H., & Lin, C. L. (2024). The Development Trends of Computer Numerical Control (CNC) Machine Tool Technology. *Mathematics*, 12(13), 1923. <https://doi.org/10.3390/math12131923>
- Zhang, L., Elghazoly, S., & Tweedie, B. (2019). Introducing AnomDB: An unsupervised anomaly detection method for CNC machine control data. In *Annual Conference of the Prognostics and Health Management Society, Scottsdale, USA* (pp. 1-12). Retrieved from <https://pdfs.semanticscholar.org/d148/97206b60a953c4765e55f8c6116db48ed7e7.pdf>















ภาคผนวก

ข้อมูลและรายละเอียดเพิ่มเติมประกอบการวิจัย

ภาคผนวก ก

ภาพถ่ายหัวเจาะจากกล้องจุลทรรศน์ตั้งแต่การเจาะรูที่ 0 ถึงรูที่ 140


รูที่	ภาพถ่าย	รูที่	ภาพถ่าย
0		10	
20		30	
40		50	
60		70	


รูปที่	ภาพถ่าย	รูปที่	ภาพถ่าย
80		90	
100		110	
120		130	
140			


ภาคผนวก ข
บรรยากาศการทดลองเจาะชิ้นงาน ณ อาคารเครื่องมือ F1
มหาวิทยาลัยเทคโนโลยีสุรนารี











ประวัติผู้เขียน

นายพัชรพล เกียรติภูมิพงศา เกิดเมื่อวันที่ 4 กุมภาพันธ์ พ.ศ. 2536 สำเร็จการศึกษาระดับปริญญาตรี วิศวกรรมศาสตรบัณฑิต สาขาวิศวกรรมคอมพิวเตอร์ (เกียรตินิยมอันดับสอง) จากมหาวิทยาลัยเทคโนโลยีมหานคร และสำเร็จการศึกษาระดับปริญญาโท วิทยาศาสตร์มหาบัณฑิต สาขาการบริหารเทคโนโลยีสารสนเทศ จากสถาบันบัณฑิตพัฒนบริหารศาสตร์ ภายหลังสำเร็จการศึกษาระดับปริญญาตรี ผู้เขียนเริ่มปฏิบัติงานด้านการพัฒนาระบบซอฟต์แวร์และระบบสารสนเทศองค์กร ตั้งแต่ปี พ.ศ. 2559 โดยทำงานที่ บริษัท ไทยสมุทรประกันชีวิต จำกัด (มหาชน) ในตำแหน่ง นักพัฒนาซอฟต์แวร์อาวุโส (Senior Java Developer) รับผิดชอบงานด้านการออกแบบ พัฒนา และดูแลระบบงานประกันชีวิต ระบบสารสนเทศระดับองค์กร และเทคโนโลยีที่เกี่ยวข้อง โดยปฏิบัติงานต่อเนื่องเป็นระยะเวลากว่า 9 ปี (พ.ศ. 2559–2568) ปัจจุบัน ผู้เขียนปฏิบัติงานในตำแหน่ง วิศวกรซอฟต์แวร์ (Software Engineer) ที่ บริษัท กรุงไทย-แอกซ่า ประกันชีวิต จำกัด (มหาชน) โดยรับผิดชอบงานด้านการพัฒนาระบบซอฟต์แวร์ การออกแบบและเชื่อมต่อระบบผ่าน API รวมถึงการสนับสนุนและพัฒนาระบบสารสนเทศที่เกี่ยวข้องกับกระบวนการดำเนินงานหลักขององค์กร ในด้านการศึกษา ผู้เขียนกำลังศึกษาระดับปริญญาเอก สาขาเทคโนโลยีดิจิทัล มหาวิทยาลัยเทคโนโลยีสุรนารี โดยมีความสนใจด้านการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องและการวิเคราะห์ข้อมูล เพื่อการตรวจจับความผิดปกติและการบำรุงรักษาเชิงคาดการณ์ในกระบวนการผลิตภาคอุตสาหกรรม งานวิจัยมุ่งเน้นการพัฒนาแบบจำลองที่สามารถนำไปใช้งานได้จริงในสภาพแวดล้อมอุตสาหกรรม และสนับสนุนการตัดสินใจเชิงวิศวกรรมอย่างมีประสิทธิภาพ