

A COMPARATIVE STUDY ON UNCERTAINTY REGRESSION MODEL FOR A WRITE CURRENT TEST TIME REDUCTION IN HARD DRIVE MANUFACTURING PROCESSES

Pattaradit DAMRONGSAK^{1*}, Anupap SOMBOONSAVATDEE^{2*} and Somchai NUANPRASERT³

1 Faculty of Commerce and Accountancy, Chulalongkorn University, Thailand;
6480464626@student.chula.ac.th (Corresponding Author)

2 Faculty of Commerce and Accountancy, Chulalongkorn University, Thailand;
anupap@cbs.chula.ac.th (Corresponding Author)

3 Data Science Group, Seagate Technology (Thailand) Ltd. (Korat), Thailand

ARTICLE HISTORY

Received: 2 June 2023

Revised: 21 June 2023

Published: 3 July 2023

ABSTRACT

Hard drives (HDD) are highly accurate magnetic recording devices, therefore it is costly and time-consuming to measure the optimal write current for HDD. The HDD's performance could be badly affected if the write current is invalid. The adaptive test condition is a method of adapting traditional test methods by adjusting the test in response to the pattern of parameters, to improve traditional measurement of the optimal write current test for time reduction. The purpose of this research is to study and compare different approaches to using uncertainty regression models for reducing the measurement range of the optimal write current test for test time reduction by calculating the prediction interval at an acceptable confidence level using the recalibrated data uncertainty. NGBoost, XGB-Distribution, and CatBoost are among the uncertainty regression models used. Then, each model is performed in order to determine which one maximizes the test time reduction at the accepted confidence level. The primary result, CatBoost is maximum the write current test time reduction at an acceptable level of confidence that the prediction interval covers 0.9 proportion of test sets.

Keywords: Manufacturing processes, Hard drives, Uncertainty, Machine learning, Test time reduction

CITATION INFORMATION: Damrongsak, P., Somboonsavatdee, A., & Nuanprasert, S. (2023). A Comparative Study on Uncertainty Regression Model for a Write Current Test Time Reduction in Hard Drive Manufacturing Processes. *Procedia of Multidisciplinary Research*, 1(7), 31

การศึกษาเปรียบเทียบตัวแบบจำลองการถดถอยโดยความไม่แน่นอนเพื่อลดเวลาในกระบวนการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดของฮาร์ดไดรฟ์

ภัทรดิศ ดำรงค์ศักดิ์¹, อนุภาพ สมบูรณ์สวัสดิ์² และ สมชาย นวลประเสริฐ³

1 คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย; 6480464626@student.chula.ac.th (ผู้ประพันธ์บรรณกิจ)

2 คณะพาณิชยศาสตร์และการบัญชี จุฬาลงกรณ์มหาวิทยาลัย; anupap@cbs.chula.ac.th (ผู้ประพันธ์บรรณกิจ)

3 กลุ่มวิทยาศาสตร์ข้อมูล บริษัท ซีเกท เทคโนโลยี (ประเทศไทย) จำกัด (โคราช)

บทคัดย่อ

ฮาร์ดไดรฟ์เป็นอุปกรณ์บันทึกข้อมูลแม่เหล็กที่มีความแม่นยำสูง ดังนั้นจึงมีค่าใช้จ่ายสูง และเสียเวลาในการวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดฮาร์ดไดรฟ์ หากจ่ายกระแสไฟฟ้าเขียนไม่เหมาะสมจะส่งผลกระทบต่อประสิทธิภาพการทำงานของฮาร์ดไดรฟ์ ซึ่งเราใช้วิธีการเงื่อนไขการทดสอบแบบปรับตัว เป็นเทคนิคที่ปรับวิธีการทดสอบแบบดั้งเดิมตามรูปแบบข้อมูลพารามิเตอร์ เพื่อปรับปรุงวิธีการทดสอบปัจจุบัน และลดเวลาการทดสอบ งานวิทยานิพนธ์นี้มีวัตถุประสงค์เพื่อศึกษาและเปรียบเทียบวิธีการใช้ตัวแบบจำลองการถดถอยโดยความไม่แน่นอนสำหรับการลดช่วงการวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุด สำหรับการลดเวลาการทดสอบวัดค่ากระแสไฟฟ้าเขียน โดยการคำนวณช่วงความเชื่อมั่นของผลทำนายที่ระดับความเชื่อมั่นที่ยอมรับได้ โดยใช้ค่าความไม่แน่นอนของข้อมูลที่ผ่านวิธีปรับการเทียบมาตรฐาน แล้วนำมาลดช่วงวัดที่ได้จากการทดสอบฮาร์ดไดรฟ์ จากนั้นนำช่วงเชื่อมั่นของผลทำนายนั้นมาลดช่วงการวัดค่ากระแสไฟฟ้าเขียน โดยการศึกษา และเปรียบเทียบใช้ตัวแบบจำลองการถดถอยโดยความไม่แน่นอน ได้แก่ NGBoost, XGB-Distribution และ CatBoost ซึ่งผลลัพธ์ของงานวิทยานิพนธ์คือ CatBoost สามารถลดเวลาในการทดสอบวัดค่ากระแสไฟฟ้าเขียนสูงสุดในช่วงความเชื่อมั่นของผลทำนาย ณ ระดับความเชื่อมั่นที่ยอมรับได้ ซึ่งครอบคลุมสัดส่วน 0.9 ของทุกชุดการทดสอบ

คำสำคัญ: กระบวนการผลิต, ฮาร์ดไดรฟ์, ความไม่แน่นอน, การเรียนรู้ของเครื่อง, การลดเวลาในการทดสอบ

ข้อมูลอ้างอิง: ภัทรดิศ ดำรงค์ศักดิ์, อนุภาพ สมบูรณ์สวัสดิ์ และ สมชาย นวลประเสริฐ. (2566). การศึกษาเปรียบเทียบตัวแบบจำลองการถดถอยโดยความไม่แน่นอนเพื่อลดเวลาในกระบวนการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดของฮาร์ดไดรฟ์. *Procedia of Multidisciplinary Research*, 1(7), 31

บทนำ

ฮาร์ดไดรฟ์ (HDD) คือ อุปกรณ์จัดเก็บข้อมูลดิจิทัลแบบไม่ลบเลือนที่จัดเก็บข้อมูลบนดิสก์แม่เหล็กที่หมุนได้ แล้วฮาร์ดไดรฟ์นั้นยังคงเป็นอุปกรณ์การบันทึกที่ระบบแม่เหล็กหลักในการจัดเก็บข้อมูลจำนวนมากเนื่องจากมีประสิทธิภาพสูง ความน่าเชื่อถือสูง และคุ้มค่า ซึ่งเป็นส่วนหนึ่งของสังคมยุคใหม่ (พรชัย เปลี่ยมทรัพย์ พรชัย ทรัพย์นิธิ และกัณวัฒน์ เสนานาญ, 2553)

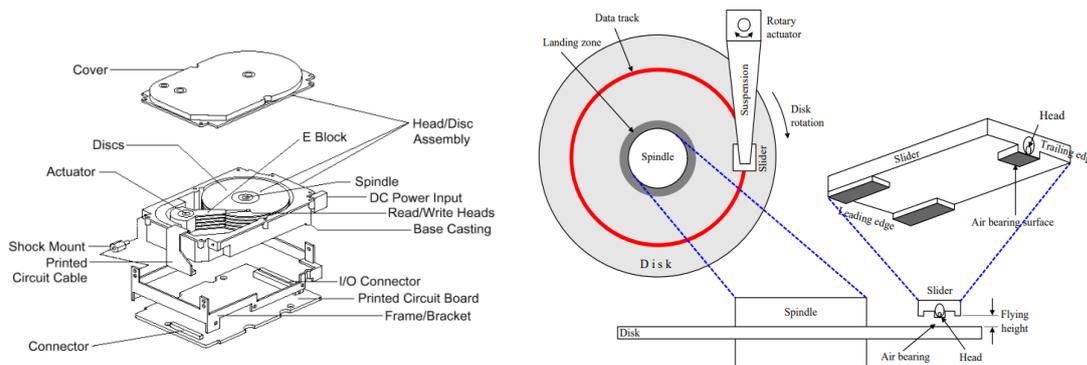
ในกระบวนการผลิตฮาร์ดไดรฟ์โดยทั่วไป หลังประกอบฮาร์ดไดรฟ์เรียบร้อยแล้วจะถูกนำไปสู่กระบวนการทดสอบประสิทธิภาพการทำงาน (Drive Test Process) จากนั้นเพื่อวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดสำหรับฮาร์ดไดรฟ์ จากช่วงการวัดค่าที่ได้จากกระบวนการทดสอบประสิทธิภาพการทำงาน ซึ่งเราเรียกรูปแบบนี้ว่า การทดสอบวัดค่ากระแสไฟฟ้าเขียน (Write Current Test) ซึ่งมีค่าใช้จ่ายสูง และเสียเวลา เนื่องจากฮาร์ดไดรฟ์เป็นอุปกรณ์การบันทึกที่ระบบแม่เหล็กแม่นยำสูง (พรชัย เปลี่ยมทรัพย์ พรชัย ทรัพย์นิธิ และกัณวัฒน์ เสนานาญ, 2553; Guo, Lim & Chu, 2019) หากจ่ายกระแสไฟฟ้าเขียนไม่เหมาะสมจะส่งผลกระทบต่อประสิทธิภาพการทำงานของฮาร์ดไดรฟ์ และช่วงในการวัดเดิมนั้นมีระยะที่กว้าง จึงต้องการค้นหาวิธีที่จะสามารถลดเวลาในการทดสอบวัดค่ากระแสไฟฟ้าเขียน โดยเรียกรูปแบบนี้ว่า “Non-Adaptive Test”

ดังนั้นการใช้เทคนิคการประมาณค่าแบบจุดของตัวแบบจำลองการถดถอย จึงไม่เหมาะสม เพราะความเสี่ยงที่ตัวประมาณจุดอาจไม่ใช่ค่ากระแสการไฟฟ้าเขียนที่เหมาะสมที่สุด เงื่อนไขการทดสอบแบบปรับตัว (Adaptive Test Condition) เป็นเทคนิคที่ปรับวิธีการทดสอบแบบดั้งเดิม ตามรูปแบบข้อมูลพารามิเตอร์ เพื่อปรับปรุงวิธีการทดสอบปัจจุบันและลดเวลาการทดสอบ (Boards ITRS, 2015) โดยทั่วไปแล้ววิธีของเงื่อนไขการทดสอบแบบปรับตัวมีอยู่ด้วยกัน 3 วิธี 1) การเลือกชุดทดสอบที่เหมาะสมที่สุด (Optimal Test Set) 2) การตรวจจับตัวอย่างที่มีข้อบกพร่อง (Detecting Defective Samples) 3) การลดช่วงค้นหาในการทดสอบของพารามิเตอร์ (Reducing Search Space of Parameter)

งานวิจัยนี้เสนอการใช้ Adaptive Test Condition โดยใช้แนวทางที่ 3 เพื่อลดพื้นที่การค้นหาสำหรับการลดเวลาทดสอบในการผลิตฮาร์ดไดรฟ์ โดยนำช่วงความเชื่อมั่นของผลทำนายที่ได้มาจากความไม่แน่นอนของข้อมูล (Data Uncertainty) ที่ผ่านวิธีปรับการเทียบมาตรฐาน (Recalibration) แล้วนำมาลดช่วงวัดที่ได้จากการทดสอบฮาร์ดไดรฟ์ โดยจะปรับขอบล่างของช่วงจากการจ่ายกระแสไฟฟ้าเขียนเดิมมาเป็นขอบล่างของช่วงความเชื่อมั่นของผลทำนาย ถ้าขอบล่างของช่วงความเชื่อมั่นของผลทำนายมีค่ามากกว่าขอบล่างของช่วงจากการจ่ายกระแสไฟฟ้าเขียนเดิม และจะปรับขอบบนของช่วงจากการจ่ายกระแสไฟฟ้าเขียนเดิมมาเป็นขอบบนของช่วงความเชื่อมั่นของผลทำนาย ถ้าขอบบนของช่วงความเชื่อมั่นของผลทำนายมีค่าน้อยกว่าขอบบนของช่วงจากการจ่ายกระแสไฟฟ้าเขียนเดิม หากช่วงความกว้างในการวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดลดลงจากเดิม แล้วเวลาที่ใช้ในการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดจะลดลงด้วย

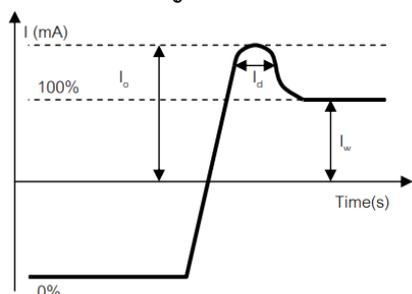
การทบทวนวรรณกรรม

ฮาร์ดไดรฟ์ คืออุปกรณ์จัดเก็บข้อมูลดิจิทัลแบบไม่ลบเลือนที่จัดเก็บข้อมูลบนดิสก์แม่เหล็กที่หมุนได้ ซึ่งการบันทึกที่ระบบแม่เหล็กซึ่งใช้ในการผลิตฮาร์ดไดรฟ์นั้น คือ การจัดเก็บข้อมูลบิตให้อยู่ในรูปของการเปลี่ยนแปลงระดับสภาพความเป็นแม่เหล็กในสื่อบันทึก ซึ่งลักษณะการบันทึกข้อมูลสำหรับการเก็บข้อมูลดิจิทัลที่มีสองสถานะ คือ บิต “1” และ บิต “0” หรือเรียกกันว่า “ข้อมูลไบนารี (Binary Data)” (พรชัย เปลี่ยมทรัพย์ พรชัย ทรัพย์นิธิ และกัณวัฒน์ เสนานาญ, 2553)



รูปที่ 1 (ซ้าย) โครงสร้างภายในของฮาร์ดไดรฟ์ และ รูปที่ 2 (ขวา) โครงสร้างภายในของฮาร์ดไดรฟ์ จากหนังสือการประมวลสัญญาณสำหรับการจัดเก็บข้อมูลดิจิทัล เล่ม 1: พื้นฐานช่องสัญญาณอ่าน (หน้า 8), โดย รศ.ดร.ปิยะ โควินท์ทวิวัฒน์, 2550, เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ

โครงสร้างภายในฮาร์ดไดรฟ์ จากรูปที่ 1 ซึ่งมีหลักการทำงานโดยทั่วไปดังนี้ สัญญาณจะผ่านเข้าออกทางหัวอ่าน และหัวเขียน (Read/Write Heads) โดยชิ้นส่วนอุปกรณ์อิเล็กทรอนิกส์ต่างๆ จะอยู่บนแผงควบคุมวงจรไฟฟ้า (Printed Circuit Board) ที่ติดอยู่กับฝาครอบด้านล่างของฮาร์ดไดรฟ์ โดยที่ตัวไดรฟ์ (Drives) จะถูกปิดผนึกอย่างดีเพื่อป้องกันสิ่งเปื้อน (Contamination) ซึ่งอุปกรณ์อิเล็กทรอนิกส์เหล่านี้จะทำหน้าที่ควบคุมสัญญาณที่รับ และส่งจากหัวแม่เหล็ก, มอเตอร์สปินเดิล (Spindle Motor) และตัวควบคุมการเคลื่อนไหว (Actuator) โดยตัวควบคุมการเคลื่อนไหวจะทำหน้าที่ควบคุมการเคลื่อนที่ของปีกนก (Suspension) รูปที่ 2 โดยตัวควบคุมการเคลื่อนไหวจะเคลื่อนที่ไปรอบจุดหมุนที่กำหนด เพื่อที่จะควบคุมการวางตำแหน่งของหัวแม่เหล็กไปยังบริเวณต่างๆ ในแนวรัศมีที่เรียกว่า “โซน (Zone)” บนจานบันทึกที่เรียกว่า “ดิสก์ (Disk)” ซึ่งหัวแม่เหล็กนี้จะบินอยู่เหนือพื้นผิวของแผ่นดิสก์เป็นระยะทางที่น้อยมาก (น้อยกว่า 10^{-6} นิ้ว) ในขณะที่มอเตอร์สปินเดิลจะหมุนแผ่นดิสก์ด้วยความเร็วที่คงที่ในระหว่างที่ตัวไดรฟ์ทำงานอยู่ เมื่อตัวไดรฟ์หยุดทำงาน หรือเข้าสู่ภาวะหลับ (Sleep Mode) สปินเดิลจะหยุดหมุน (พรชัย เปลีี่ยมทรัพย์ พรชัย ทรัพย์นิธิ และกัณวัฒน์ เสนานาญ, 2553; Al Mamun, Guo & Bi. 2017; รศ.ดร.ปิยะ โควินท์ทวิวัฒน์, 2550)



รูปที่ 3 สัญญาณกระแสเขียนที่วงจรถ่วง Preamplifier จาก ผลกระทบของกระแสเขียนต่อสมรรถนะของระบบบันทึกข้อมูลเชิงแม่เหล็กแนวตั้ง, เรื่องเติมการประชุมทางวิชาการของมหาวิทยาลัยเกษตรศาสตร์ ครั้งที่ 48, โดย พรชัย เปลีี่ยมทรัพย์ และคณะ, 2553, กรุงเทพฯ, หน้า 302-309 (527 หน้า)

รูปที่ 3 สัญญาณกระแสเขียนที่วงจรถ่วง Preamplifier บ้อนให้กับหัวเขียนโดยที่แกน นอนคือแกนของเวลาและแกนตั้งคือแกนของกระแส วงจรถ่วง Preamplifier จะแปลงบิตข้อมูลให้อยู่ในรูปของกระแส เขียนและส่งผ่านไปยังขดลวดของหัวเขียน ทำให้เกิดการเหนี่ยวนำเป็นสนามแม่เหล็กเขียนบริเวณช่องว่าง (Gap) ระหว่างสื่อบันทึกกับหัวบันทึกในการบันทึกข้อมูล สัญญาณกระแสเขียนจะมีพารามิเตอร์ที่เกี่ยวข้อง 3 ตัวแปรได้แก่ แอมพลิจูดของกระแส (Write Current Amplitude: I_w) ส่วนพุ่งเกินกระแส (Current Overshoot: I_0) และ เวลาของส่วนพุ่งเกินกระแส (Current Duration:

พิจารณาให้ M แทนจำนวนของตัวแบบจำลอง Ensembles ของตัวแบบจำลองความน่าจะเป็นแต่ละตัว $\{P(y|x; \theta^{(m)})\}_{m=1}^M$ จากตัวอย่างสุ่ม Posterior $P(\theta|\mathcal{D})$ ซึ่งแต่ละตัวแบบ $P(y|x, \theta^{(m)})$ มีความไม่แน่นอนของข้อมูลแตกต่างกัน จะแสดงเอนโทรปีของการแจกแจงของการทำนาย และความไม่แน่นอนในผลทำนาย เกิดจากความไม่แน่นอนของตัวแบบจำลอง ซึ่งแสดงออกมาเป็นระดับของการกระจายของตัวแบบจำลองใน Ensemble ให้ $P(\theta|\mathcal{D})$ เป็น Predictive Posterior ของ Ensembles ที่ได้มาจากค่าคาดหวังของตัวแบบจำลองใน Ensemble

$$P(y|x, \mathcal{D}) = \mathbb{E}_{p(\theta|\mathcal{D})}[P(y|x; \theta)] \approx \frac{1}{M} \sum_{m=1}^M P(y|x; \theta^{(m)}), \theta^{(m)} \sim P(\theta, \mathcal{D})$$

เอนโทรปีของ Predictive Posterior เป็นค่าประมาณ ความไม่แน่นอนรวม(Total Uncertainty) ซึ่งคำนวณจากสมการ

$$\mathcal{H}[P(y|x, \mathcal{D})] = \mathbb{E}_{P(y|x, \mathcal{D})}[-\ln P(y|x, \mathcal{D})]$$

ความไม่แน่นอนรวม คือผลรวมระหว่าง ความไม่แน่นอนของข้อมูล และความไม่แน่นอนของตัวแบบจำลอง โดยความไม่แน่นอนสามารถพิจารณาจาก สารสนเทศร่วม(Mutual Information) ระหว่าง พารามิเตอร์ θ และ ผลทำนายของ y

Model uncertainty Total uncertainty Expected Data uncertainty

$$\begin{aligned} \mathcal{J}[y, \theta|x, \mathcal{D}] &= \mathcal{H}[P(y|x, \mathcal{D})] - \mathbb{E}_{P(\theta|\mathcal{D})}[\mathcal{H}[P(y|x; \theta)]] \\ &\approx \mathcal{H}\left[\frac{1}{M} \sum_{m=1}^M P(y|x; \theta^{(m)})\right] - \frac{1}{M} \sum_{m=1}^M \mathcal{H}[P(y|x; \theta^{(m)})] \end{aligned}$$

จากสมการด้านบนเป็นการแสดงถึงความแตกต่างระหว่างเอนโทรปีของ Predictive Posterior และค่าคาดหวังของเอนโทรปีของแต่ละตัวแบบจำลองใน Ensemble ซึ่งแตกต่างที่ขนาดของ Ensemble ที่หลากหลาย และค่าประมาณของความไม่แน่นอนของตัวแบบจำลอง อย่างไรก็ตาม เมื่อพิจารณาตัวแบบจำลองความถดถอยความน่าจะเป็น (Probabilistic Regression Model) ของ Ensemble $\{P(y|x; \theta^{(m)})\}_{m=1}^M$ นอกเหนือจากความต่อเนื่องของ $y \in \mathbb{R}$ ไม่สามารถที่จะติดตามค่าประมาณของเอนโทรปีของ Predictive Posterior (ที่แตกต่างกัน) และสารสนเทศร่วม (Mutual Information) ดังนั้นในกรณีนี้ ค่าประมาณของความไม่แน่นอนสามารถหาได้จากกฎของความแปรปรวนทั้งหมด (Malinin, Prokhorenkova & Ustimenko, 2020)

Model uncertainty Total uncertainty Expected Data uncertainty

$$\mathbb{V}_{P(y|x, \mathcal{D})}[y] = \mathbb{V}_{P(\theta|\mathcal{D})}[\mathbb{E}_{P(y|x, \theta)}[y]] + \mathbb{E}_{P(\theta|\mathcal{D})}[\mathbb{V}_{P(y|x, \theta)}[y]]$$

ในวิจัยนี้เราใช้ตัวแบบจำลองการถดถอยโดยความไม่แน่นอนในการศึกษาเปรียบเทียบกับนั้นเป็นอัลกอริทึมการเรียนรู้ของ Machine Learning แบบ Gradient Boosting with a Bayesian framework ซึ่งเราจะกำหนดการแจกแจงความน่าจะเป็นของ Prior $P(\theta)$ เป็นการแจกแจงแบบปกติ (Normal Distribution) สำหรับตัวแปรตาม โดยมี 3 เหตุผลที่กำหนดการแจกแจงความน่าจะเป็นของ Prior เป็นการแจกแจงแบบปกติ 1) ความสะดวกในการคำนวณ คือ การแจกแจงแบบปกตินั้นใช้กันอย่างแพร่หลายในสถิติแบบเบย์ (Bayesian Statistics) เนื่องจากคุณสมบัติทางคณิตศาสตร์ทำให้การคำนวณ และการอนุมานเป็นไปได้ง่ายขึ้น 2) ความยืดหยุ่น คือ ถึงแม้ว่าการแจกแจงแบบปกติอาจจะไม่สามารถแสดงถึงการแจกแจงที่แท้จริงของตัวแปรตามได้อย่างแม่นยำ แต่ก็สามารถกำหนดรูปแบบพื้นฐานของ Prior ที่ยืดหยุ่นและหลากหลายได้ 3) ง่ายต่อการตีความ คือ การแจกแจงแบบปกติเป็นรูปแบบการแจกแจงความน่าจะเป็นที่เป็นที่รู้จักและใช้งานกันอย่างแพร่หลายในเชิงสถิติ ซึ่งทำให้ง่ายต่อการตีความผลลัพธ์ และสรุปความหมาย ซึ่งค่าเฉลี่ยและค่าความแปรปรวนของการแจกแจงแบบปกติ นั้นเข้าใจง่าย และแสดงข้อมูลพฤติกรรมของตัวแปรตาม

สำหรับตัวแบบจำลองความถดถอยความน่าจะเป็นของ Ensemble ซึ่งปรับพารามิเตอร์ของการแจกแจงแบบปกติ และโดยที่แต่ละแบบจำลองให้ค่าเฉลี่ยและส่วนเบี่ยงเบนมาตรฐาน สามารถคำนวณความแปรปรวนทั้งหมดได้ดังนี้

$$\mathbb{V}_P(y|x, \mathcal{D})[y] \approx \frac{1}{M} \sum_{m=1}^M \left[\left(\sum_{m=1}^M \frac{\mu_m}{M} \right) - \mu_m \right] + \frac{1}{M} \sum_{m=1}^M \sigma_m^2$$

โดยที่ $\{\mu_m, \sigma_m\} = f(x; \theta^{(m)})$ อย่างไรก็ตาม แม้ว่าวิธีการวัดค่าเหล่านี้สามารถการคำนวณ และอ้างอิงกับค่าโมเมนต์อันดับหนึ่ง และอันดับสอง แต่อาจพลาดรายละเอียดของความไม่แน่นอนที่โมเมนต์อันดับสูงขึ้น นอกจากนี้ การวัดเหล่านี้ไม่สามารถปรับเปลี่ยนขนาดได้อิสระ ซึ่งอาจทำให้เกิดปัญหาเมื่อมีค่าการคาดการณ์ที่มีขนาดที่แตกต่างกันระหว่างข้อมูลในโดเมนและข้อมูลนอกโดเมน (Duan, Anand, Ding, Thai, Basu, Ng & Schuler, 2020; Malinin, Prokhorenkova & Ustimenko, 2020) โดยตัวแบบจำลองการถดถอยโดยความไม่แน่นอน ที่ใช้ศึกษาเปรียบเทียบมีด้วยกัน 3 ตัวแบบจำลอง 1) NGBoost (Natural Gradient Boosting) เป็นอัลกอริทึมสำหรับการทำนายความน่าจะเป็นทั่วไปโดยใช้วิธี Gradient Boosting เพื่อประมาณพารามิเตอร์ของการ แจกแจงความน่าจะเป็นแบบมีเงื่อนไข ซึ่งตัวแบบจำลองการถดถอยความน่าจะเป็นจะส่งการแจกแจงความน่าจะเป็นของผลลัพธ์ ซึ่งช่วยให้สามารถประมาณค่าความไม่แน่นอนเชิงคาดการณ์ได้แบบมีเงื่อนไขได้ โดยการถดถอยความน่าจะเป็นนั้นขึ้นอยู่กับพารามิเตอร์ของการแจกแจงแบบมีเงื่อนไขเป้าหมายสำหรับอัลกอริทึม Boosting หลายพารามิเตอร์ θ ซึ่งในการพยากรณ์การถดถอยความน่าจะเป็นโดยใช้ฟังก์ชันการสูญเสีย (Loss Function) ซึ่งต้องมีเกณฑ์คะแนนที่ต้องเปรียบเทียบการประมาณการแจกแจงความน่าจะเป็นของข้อมูล โดยใช้เกณฑ์คะแนนที่เหมาะสม (Proper Scoring Rule) \mathcal{S} โดยใช้ข้อมูลการแจกแจงความน่าจะเป็นที่ถูกพยากรณ์ P และค่าสังเกต y แล้วกำหนด $\mathcal{S}(P; y)$ ให้กับการพยากรณ์เพื่อให้การแจกแจงจริงของผลลัพธ์ได้คะแนนที่ดีที่สุดโดยคาดหวัง ต่อเมื่อ เป็นไปตามเงื่อนไข

$$\mathbb{E}_{y \sim Q}[\mathcal{S}(Q, y)] \leq \mathbb{E}_{y \sim Q}[\mathcal{S}(P, y)] \quad \forall P, Q$$

กำหนดให้ Q เป็นการแจกแจงจริงของผลลัพธ์ของ y และ P เป็นการแจกแจงอื่นๆ โดยที่เราใช้การแจกแจงพารามेटริก (Parametric Distribution) ในการทำงาน จึงเราสามารถระบุแต่ละการแจกแจงพารามิเตอร์ และเกณฑ์คะแนนเป็น $\mathcal{S}(\theta, y)$ (Duan, Anand, Ding, Thai, Basu, Ng & Schuler, 2020) 2) XGBoost-Distribution (eXtreme Gradient Boosting Distribution) โดยมีตัวแบบจำลอง XGBoost เป็นพื้นฐานอัลกอริทึมการ Gradient Boosting กับต้นไม้ตัดสินใจ โดยการหาค่าที่เหมาะสมที่สุดใช้เทคนิค Weighted Quantile Sketch เพื่อค้นหาจุดแบ่งช่วงที่เป็นไปได้ในข้อมูลอย่างมีประสิทธิภาพ นอกจากนี้ยังรองรับการแบ่งการสร้างต้นไม้แบบพร้อมกันเพื่อเพิ่มความเร็วในการฝึก ซึ่งกระจายการคำนวณในหลายหน่วยประมวลผล (CPU cores) เพื่อความสำเร็จและความแม่นยำสูงในงานจำแนกหรือทำนาย ในขณะที่สามารถจัดการกับความซับซ้อนของโมเดลและปัญหาการเหลื่อมเชื่อถือได้อย่างดี โดยให้ความสำคัญของตัวแปร การคำนวณความสำคัญของตัวแปรใช้ความถี่ของการใช้ตัวแปรในการแบ่งช่วงข้อมูลระหว่างต้นไม้ทั้งหมดในตัวแบบจำลอง และการปรับปรุงเฉลี่ยในฟังก์ชันสูญเสีย โดยฟังก์ชันสูญเสียของ XGBoost-Distribution ที่ใช้ในการพยากรณ์การถดถอยความน่าจะเป็น คือ Proper Scoring rule \mathcal{S} ซึ่งเป็นฟังก์ชันการสูญเสียเดียวกับ NGBoost (Christian, 2020) 3) Catboost (Gradient Boosting with categorical features support) เป็นอัลกอริทึมที่ใช้วิธี Gradient Boosting ที่ขึ้นกับวิธีต้นไม้การตัดสินใจ การเรียนรู้ของเครื่องจาก Yandex เปิดให้ใช้งานแบบโอเพนซอร์ส ซึ่งจุดเด่นของ CatBoost คือการใช้อัลกอริทึมที่พิเศษในการจัดการคุณลักษณะทางสถิติแบบหมวดหมู่ หรือเรียกว่า Ordered Target Statistics (OTS) เพื่อทำการเตรียมข้อมูลทางสถิติสำหรับคุณลักษณะทางสถิติแบบหมวดหมู่ โดยการคำนวณสถิติสำหรับแต่ละหมวดหมู่ การใช้วิธีนี้ช่วยให้จัดการคุณลักษณะทางสถิติแบบหมวดหมู่ได้อย่างมีประสิทธิภาพโดยไม่ต้องทำการเตรียมข้อมูลหรือการเข้ารหัสแบบหมวดหมู่เป็นหมายเลขให้ยาว รวมถึงโครงสร้างต้นไม้ที่สมมาตร (Symmetric Trees) ซึ่งมีโครงสร้างเดียวกันในส่วนของกิ่งทางซ้ายและกิ่งทางขวา สิ่งนี้ช่วยให้สามารถประมวลผลได้เร็วขึ้น และฝึกได้อย่างรวดเร็ว นอกจากนี้มีความสามารถในการปรับขนาดได้อย่างยอดเยี่ยม ซึ่งถูกออกแบบให้มีความเร็วและสามารถปรับขนาดได้ รวมถึงการรองรับฟังก์ชันสูญเสียพิเศษสำหรับงานที่แตกต่างกัน โดยฟังก์ชันสูญเสียพิเศษสำหรับการพยากรณ์การถดถอยความน่าจะเป็นดังนี้

$$\begin{aligned}
& - \sum_{i=1}^N \log N(t_i | a_{i,0}, e^{2a_{i,1}}) \\
& = \frac{1}{2} \log(2\pi) + \sum_{i=1}^N \left(a_{i,1} + \frac{1}{2} e^{-2a_{i,1}} (t_i - a_{i,0})^2 \right)
\end{aligned}$$

เมื่อ t คือตัวแปรตาม โดย a_0 เป็นการประมาณเชิงสถิติ 2 มิติของการพยากรณ์ตัวแปรตาม และ a_1 เป็นการพยากรณ์เชิงสถิติ $\log \sigma$ และ $N(y|\mu, \sigma^2) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-\frac{(y-\mu)^2}{2\sigma^2}}$ เป็นฟังก์ชันความหนาแน่นความน่าจะเป็นที่เป็นไปตามการแจกแจงปกติ (Malinin, Prokhorenkova & Ustimenko, 2020; Ray, 2017)

เมื่อเราได้ค่าความไม่แน่นอนของข้อมูลจากการเรียนรู้แต่ละตัวแบบจำลองมาเราจะมาทำการประเมิน และปรับปรุงค่าความไม่แน่นอนของข้อมูลด้วยวิธีการ การเทียบมาตรฐานสำหรับแบบจำลองการถดถอย (Calibration Regression) และการปรับเทียบมาตรฐานสำหรับแบบจำลองการถดถอย (Recalibration Regression) โดยสมมติให้ $\mathcal{Y} = \{0,1\}$ เรา จะกำหนดชุดข้อมูลให้ $x_t, y_t \in \mathcal{X} \times \mathcal{Y}$ สำหรับ $t = 1, 2, \dots, T$ โดยตัวแปรสุ่ม \mathcal{X} และตัวแปรสุ่ม \mathcal{Y} ที่มีการแจกแจงเดียวกันและเป็นอิสระกันต่อกัน (i.i.d.) ที่ถูกสุ่มมาจากการแจกแจงความน่าจะเป็น \mathbb{P} เราจะให้ตัวพยากรณ์ (Forecaster) $H: \mathcal{X} \rightarrow (\mathcal{Y} \rightarrow [0,1])$ เพื่อสร้างการแจกแจงความน่าจะเป็น $F_t(y)$ ซึ่งเป็นฟังก์ชันการแจกแจงความน่าจะเป็นสะสม (CDF) เมื่อ Y เป็นตัวแปรต่อเนื่อง ที่เน้นการให้เป้าหมาย y_t โดยมีเงื่อนไขว่า x_t เป็นตัวกำหนด ซึ่งวิธีการเทียบมาตรฐาน (Calibration) และการปรับเทียบมาตรฐาน (Recalibration) เพื่อแก้ไขปัญหาของแบบจำลองการถดถอยที่ให้ค่าประมาณ $\mathcal{Y} = \mathbb{R}$ และนำอัลกอริทึมที่ได้มาใช้กับตัวแบบจำลองความไม่แน่นอน ซึ่ง Forecaster H ในแต่ละ t สร้าง CDF แล้ว F_t ซึ่งพยากรณ์ y_t เมื่อ $F_t^{-1}(p)$ กำหนดให้เป็นค่าที่ต่ำที่สุดของ y ที่ $p \leq F_t(y)$ แล้ว ให้ฟังก์ชัน $F_t^{-1}: [0,1] \rightarrow \mathcal{Y}$ แสดงฟังก์ชันควอนไทล์ (Quantile)

การเทียบมาตรฐานสำหรับแบบจำลองการถดถอย คือ การวัดระดับความเชื่อมั่นของการทำนาย โดยว่าผลลัพธ์จริง y_t อยู่ช่วงความเชื่อมั่นของผลทำนายที่กำหนดไว้หรือไม่ โดยมีเป้าหมายเพื่อให้มีการทำนายค่าที่ตรงกับช่วงความเชื่อมั่นนั้นๆ ในระดับความเชื่อมั่นที่กำหนดไว้ โดย ตัวพยากรณ์ (Forecaster) H จะถูกพิจารณาว่า Calibrated ถ้า ฟังก์ชันการแจกแจงความน่าจะเป็นสะสมเชิงประจักษ์ และเชิงทำนาย (CDFs) มีความสอดคล้องกับค่าจริง เมื่อขนาดของชุดข้อมูลเข้าสู่ความไม่จำกัด นิยามได้ดังนี้ (Al Mamun, Guo & Bi, 2017)

$$\frac{\sum_{t=1}^T \mathbb{I}\{y_t \leq F_t^{-1}(p)\}}{T} \rightarrow p \text{ for all } p \in [0,1]$$

เมื่อ พิจารณา x_t และ y_t เป็นตัวอย่างที่สุ่มมาแบบอิสระกันและ i.i.d. ระหว่างแปรสุ่ม X และ Y ตามลำดับ โดยการแจกแจงความน่าจะเป็น \mathbb{P} ดังนั้นมีเงื่อนไขเพียงพอสำหรับ Calibration คือ

$$\mathbb{P}(Y \leq F_X^{-1}(p)) = p \text{ for all } p \in [0,1]$$

โดยที่ $F_X = H(X)$ หมายถึง การพยากรณ์ที่ X จากนั้น ด้วยการใช้เทคนิคแบบเบย์ เช่น เครือข่ายประสาทแบบเบย์ (Bayesian Neural Networks) หรือกระบวนการเกาส์เซียน (Gaussian Processes) สร้างการพยากรณ์ด้วยเทคนิคเชิงความน่าจะเป็น F_t โดยที่ เราจะเลือก m ระดับความเชื่อมั่น $0 \leq p_1 < p_2 < \dots < p_m \leq 1$ และคำนวณความถี่เชิงประจักษ์สำหรับแต่ละค่า p_j เพื่อแสดงผลการสอดคล้องกันของการพยากรณ์

$$\hat{p}_j = \frac{|\{y_t | F_t(y_t) < p_j, t = 1, 2, \dots, T\}|}{T}$$

สุดท้ายแล้ว สำหรับเกณฑ์คะแนนที่วัดประสิทธิภาพของการทำนายตัวแบบ เราจะใช้ ความผิดพลาดของการเทียบมาตรฐาน (Miscalibration Area)

$$cal(F_1, y_1, \dots, F_T, y_T) = \sum_{j=1}^m (p_j - \hat{p}_j)^2$$

การปรับเทียบมาตรฐานสำหรับแบบจำลองการถดถอย คือ กระบวนการนี้เกี่ยวกับการประมาณค่าความน่าจะเป็นที่แท้จริง $\mathbb{P}(Y \leq F_X^{-1}(p))$ ของตัวแปรสุ่ม Y ที่อยู่ภายในบริเวณ $(-\infty, F_X^{-1}(p)]$ สำหรับระดับความเชื่อมั่นใดๆ โดยสามารถกำหนดให้ทุกๆ การพยากรณ์ F_t เป็น $G \circ F_t$ โดยที่ $G(p) := \mathbb{P}(Y \leq F_X^{-1}(p))$ จะได้ Forecaster ที่มี Calibrated อย่างสมบูรณ์แบบ (Well-calibration) ซึ่ง วัตถุประสงค์ของ Recalibration คือการประมาณการแจกแจงความน่าจะเป็นทั้งหมดโดยใช้ชุดข้อมูล $\{(x_t, y_t)\}_{t=1}^T$ ซึ่งสามารถทำการปรับขั้นตอนของแบบจำลองการถดถอยกลับให้เข้ากับชุด Recalibration $\{F_t(y_t), \hat{P}(F_t(y_t))\}_{t=1}^T$:

$$\hat{P}(p) = \frac{|\{y_t | F_t(y_t) < p, t = 1, 2, \dots, T\}|}{T}$$

โดยที่ $\hat{P}(p)$ เป็นสัดส่วนของจุดข้อมูลที่ y_t ต่ำกว่า Quantile ลำดับที่ p ของ F_t ซึ่งในวิจัยนี้ ใช้การถดถอยแบบไอโซโทนิก เป็นซึ่งเป็นวิธี Non-Parametric และสามารถประมาณค่าการแจกแจงที่แท้จริงได้อย่างแม่นยำ เมื่อมีข้อมูลที่ เป็น i.i.d. เพียงพอ ซึ่งวิธีนี้อธิบายถึงการเปลี่ยนแปลงของฟังก์ชันจริง $\mathbb{P}(Y \leq F_X^{-1}(p))$ ซึ่งเพิ่มขึ้นแบบโมโนโทนิก จะได้ Forecaster ที่มี Calibrated เป็น Well-Calibration (Al Mamun, Guo & Bi, 2017)

หลังจากที่เรากล่าวถึงทฤษฎีที่ใช้กันไปแล้ว สำหรับแนวคิดสำหรับแก้ปัญหาการทดสอบกระแสเขียน จากสิทธิบัตร U.S. Patent 10,339,448 ซึ่งกล่าวว่า การทดสอบกระแสเขียนเกี่ยวข้องกับการส่งตัวฮาร์ดไดรฟ์ไปยังช่วงค่ากระแสเขียน และการวัดพารามิเตอร์บางอย่างสำหรับแต่ละค่ากระแสเขียน เช่น ความสามารถในการเลื่อนตำแหน่ง (Tracks-Per-Inch Capability) ความสามารถในการบันทึกข้อมูล (Bits-Per-Inch Capability) ลักษณะการรบกวนระหว่างแทร็กที่อยู่ใกล้เคียง (Adjacent-Track Interference Characteristics) และอื่นๆ โดยอิงจากพารามิเตอร์ที่วัดได้ จากพารามิเตอร์ที่วัดได้ เลือกกระแสเขียนที่เหมาะสมที่สุดที่จะใช้ในการทำงานของฮาร์ดไดรฟ์ การทดสอบกระแสเขียนนี้มักทำหลังจากเก็บรวบรวมข้อมูลจำนวนมากเกี่ยวกับฮาร์ดไดรฟ์จากการทดสอบก่อนหน้า ซึ่งอาจรวมถึงค่าความต้านทานขององค์ประกอบแม่เหล็ก-ต้านทานแม่เหล็กในหัวอ่าน/เขียน (Read/Write head's Magneto-Resistive Element) และค่ากระแสความร้อนของอ่านข้อมูล (Reader Heat Current) เพื่อกำหนดชุดค่ากระแสเขียนที่จะทดสอบให้มีจำนวนเล็กน้อย ในงานนี้ใช้โครงข่ายประสาทเทียม (Artificial Neural Network) ถูกฝึกสอน โดยใช้ตัวอย่างที่รวมถึงข้อมูลการทดสอบก่อนหน้าที่เกี่ยวข้องกับแต่ละฮาร์ดไดรฟ์ โครงข่ายประสาทเทียมคำนวณรูปแบบที่กำหนดช่วงของค่ากระแสเขียนที่ควรทดสอบ เพื่อตั้งค่ากระแสเขียนของแต่ละฮาร์ดไดรฟ์ จากนั้นฮาร์ดไดรฟ์แบบสองของชุดที่สองจะถูกส่งผ่านการทดสอบกระแสเขียนแบบจำกัด เพื่อตั้งค่ากระแสเขียนที่ใช้งานในแต่ละฮาร์ดไดรฟ์ ในบางกรณีที่ระบุไว้ในงานนี้ ชุดแรกของฮาร์ดไดรฟ์ที่ใช้ในการฝึกสอนจะเป็นส่วนน้อยของจำนวนรวมของฮาร์ดไดรฟ์ที่ผลิตขึ้น และจะต้องเป็นตัวแทนของฮาร์ดไดรฟ์ที่จะทดสอบในภายหลัง ข้อมูลการฝึกสอนสามารถใช้ในการพยากรณ์ปรับช่วงสำหรับแต่ละรุ่นฮาร์ดไดรฟ์ หรือชุดเดี่ยวของฮาร์ดไดรฟ์ โครงข่ายประสาทเทียมสามารถถูกฝึกสอนใหม่ เมื่อมีการเปลี่ยนแปลงกระบวนการผลิตบางส่วนซึ่งอาจส่งผลต่อความเป็นตัวแบบจำลองที่ใช้ของข้อมูลการฝึกสอนเดิมสำหรับฮาร์ดไดรฟ์ที่ผลิตภายใต้กระบวนการที่แตกต่างกัน (Guo, Lim & Chu, 2019) ถึงแม้ว่าอย่างไรก็ตามแนวคิดในการแก้ปัญหาการทดสอบกระแสเขียนนี้ ยังไม่ผลลัพธ์ หรืองานวิจัยที่ชี้ให้เห็นว่าแนวคิดนี้สามารถแก้ปัญหาในการทดสอบกระแสเขียนได้ โดยในงานวิจัยนี้เราใช้ เงื่อนไขการทดสอบแบบปรับตัว (Adaptive Test Condition) เป็นเทคนิคที่ปรับเปลี่ยนการทดสอบไปตามรูปแบบ และความสัมพันธ์ของพารามิเตอร์ เพื่อเพิ่มประสิทธิภาพในการทดสอบ (Boards ITRS, 2015) โดย Adaptive Test Condition ที่ใช้ปรับปรุงการลดเวลาในการทดสอบมีอยู่ด้วยกัน 3 วิธี ดังนี้ (1) การเลือกชุดทดสอบที่เหมาะสมที่สุด (Optimal Test Set): การค้นหาชุดทดสอบที่ดีที่สุดเพื่อปรับปรุงประสิทธิภาพในการตรวจวินิจฉัยและลดเวลาทดสอบ โดยการเลือกพารามิเตอร์ (p^*) จากทั้งหมดของพารามิเตอร์ (p) ที่สำคัญสำหรับการวินิจฉัย ซึ่งกำหนดรูปแบบจากการทดสอบ จากพารามิเตอร์ที่มีสัมพันธ์กัน และการวิเคราะห์ข้อมูลที่เกี่ยวข้อง (Madge, Benware, Turakhia, Daasch, Schuermyer & Ruffler, 2004; Benner & Boroffice, 2001; Song, Liang, Ni, Huang, Lu, Wan & Yan, 2020; Chen, & Orailoglu, 2008) (2) การตรวจจับตัวอย่างที่มีข้อบกพร่อง (Detecting Defective Samples): การ

ตรวจจับข้อบกพร่องเพื่อลดจำนวนตัวอย่างที่ต้องทดสอบก่อนเข้าสู่กระบวนการทดสอบถัดไป โดยวิธีการตัดสินใจจากแบบจำลองที่ได้จากข้อมูลการทดสอบพารามิเตอร์ และพารามิเตอร์อื่นๆ ที่มีความสัมพันธ์กัน (Yeh, Kuo, Wu, Huang & Chen, 2005; Letchumanan, Tan, Gan, & Wong, 2018; Jone, Yeh, Yeh & Das, 2001; Wu, Tang, & Lin, 1996)

(3) การลดช่วงค้นหาในการทดสอบของพารามิเตอร์ (Reducing Search Space of Parameter): โดยนำวิธีการทางสถิติใช้กับพารามิเตอร์ที่เกี่ยวข้องกับการทดสอบพารามิเตอร์นั้น แล้วนำผลวิเคราะห์ที่ได้มาลดพื้นที่การทดสอบค้นหา (Suresh, Ozev & Sinanoglu, 2016)

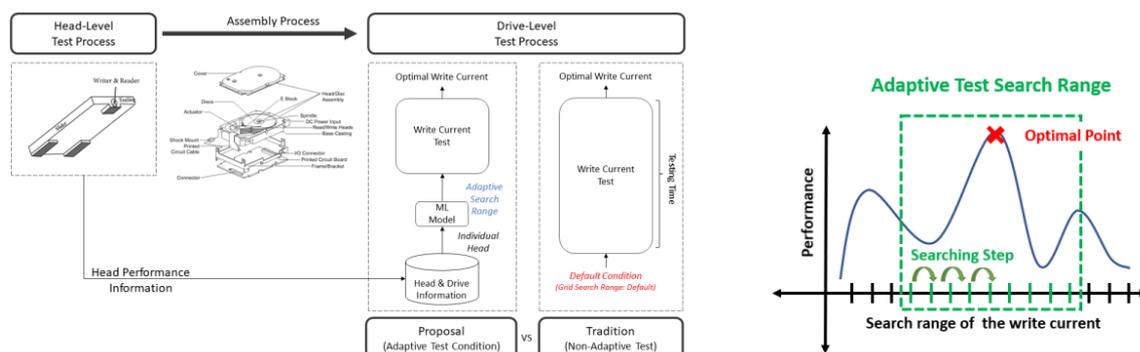
สมมติฐานการวิจัย

วิธี Adaptive Test Condition สามารถลดเวลาในการวัดค่ากระแสไฟฟ้าเขียนของฮาร์ดไดรฟ์วิธี Non-Adaptive test ลงได้ โดยนำช่วงความเชื่อมั่นของผลทำนายที่ได้มาจากความไม่แน่นอนของข้อมูลที่ผ่านวิธีปรับการเทียบมาตรฐานแล้วนำมาลดช่วงวัดที่ได้จากการทดสอบฮาร์ดไดรฟ์แล้ว เวลาที่ใช้ในการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดจะลดลงด้วย และต้องครอบคลุมสัดส่วน 0.9 ของทุกชุดการทดสอบ

โดยมีข้อกำหนดเบื้องต้นดังนี้

- 1) ข้อมูลที่ใช้สำหรับการเรียนรู้ของตัวแบบจำลองการถดถอยโดยความไม่แน่นอน และทดสอบในวิทยานิพนธ์นี้ ตัวแปรอิสระที่ใช้ประกอบไปด้วย ข้อมูลประสิทธิภาพของแต่ละส่วนประกอบฮาร์ดไดรฟ์ก่อนประกอบเป็นฮาร์ดไดรฟ์ ข้อมูลประสิทธิภาพของฮาร์ดไดรฟ์หลังประกอบ และข้อมูลช่วงกระแสไฟฟ้าเขียนที่วัดได้จากการทดสอบฮาร์ดไดรฟ์หลังประกอบ
- 2) การแบ่งสัดส่วนชุดข้อมูลในสำหรับเรียนรู้ และสำหรับการทดสอบ เป็นร้อยละ 75 และ 25 ตามลำดับ จากชุดข้อมูลสปีดาร์ที่ 01, 02, 03, 04 ชุดประเมินการทดสอบ จากชุดข้อมูลสปีดาร์ที่ 07, 08, 09 แบ่งเป็นสปีดาร์ละ 1 ชุด รวมเป็น 3 ชุด
- 3) ในวิจัยนี้จะทำการปรับสเกลข้อมูลเชิงปริมาณ และแปลงข้อมูลเชิงคุณภาพ ในการแสดงดำเนินการ และผลลัพธ์ เพื่อหลีกเลี่ยงตัวอย่างข้อมูลที่ไม่สามารถเผยแพร่ได้ และมีข้อจำกัดงานวิจัยดังนี้
 - 1) ไม่สามารถใช้ตัวแบบจำลองการถดถอยทั่วไป ที่ให้ผลลัพธ์แค่ค่าประมาณแบบจุด เนื่องจากมีความเสี่ยงสูงที่ค่าประมาณแบบจุดที่ได้ตัวแบบจำลองการถดถอยทั่วไป อาจจะไม่ใช้กระแสไฟฟ้าเขียนที่เหมาะสมที่สุด
 - 2) ไม่สามารถใช้ตัวแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) เนื่องจาก ฮาร์ดแวร์ของเครื่องทดสอบฮาร์ดไดรฟ์ที่ติดตั้งตัวแบบจำลองนั้น ไม่สามารถรองรับความต้องการของตัวแบบจำลองการเรียนรู้เชิงลึก
 - 3) ไม่สามารถเพิ่มตัวแปรอิสระนอกเหนือจากที่กำหนดได้ เนื่องจากมีค่าใช้จ่ายในการเก็บข้อมูลแต่ละการทดสอบ

กรอบแนวคิดการวิจัย



รูปที่ 5 กรอบแนวคิดการใช้วิธี Adaptive Test Condition ในการลดเวลาในการทดสอบวัดค่ากระแสไฟฟ้าเขียน

วิธีดำเนินการวิจัย

การวิจัยครั้งนี้เป็นศึกษาการเปรียบเทียบวิธีตัวแบบจำลองการถดถอยโดยความไม่แน่นอน เพื่อลดเวลาในการวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดของฮาร์ดไดรฟ์ ระหว่างวิธี CatBoost, XGBoost-Distribution และ NGBoost โดยใช้ข้อมูลประสิทธิภาพของส่วนประกอบฮาร์ดไดรฟ์ ข้อมูลประสิทธิภาพหลังประกอบเป็นฮาร์ดไดรฟ์ และข้อมูลช่วงกระแสไฟฟ้าเขียนที่วัดได้ที่ได้จากการทดสอบฮาร์ดไดรฟ์ แล้วนำค่าความไม่แน่นอนของข้อมูลที่ได้จากการเรียนรู้ของตัวแบบมา Recalibrated เพื่อให้เหมาะสม แล้วนำไปคำนวณช่วงความเชื่อมั่นของผลทำนายแต่ละระดับช่วงเชื่อมั่น แล้วจึงนำมาเปรียบเทียบความสามารถในการลดเวลาในการทดสอบกระแสไฟฟ้าเขียน โดยใช้เกณฑ์ *AvgTTR* คือ การประมาณเวลาที่ลดลงจากการทดสอบกระแสไฟฟ้าเขียน โดยเกณฑ์คะแนนนี้ใช้ในการเปรียบเทียบตัวแบบจำลองการถดถอยโดยความไม่แน่นอน โดยต้องครอบคลุมสัดส่วนชุดตัวอย่างอย่างน้อย 0.9 เป็นเกณฑ์ชี้วัดความสามารถในการลดเวลาการทดสอบหลัก โดยมีสมการดังนี้

$$AvgTTR = n_{head} \times n_{zone} \times \left(\frac{\sum_{i=1}^n \Delta range_i}{n} \times RunTime \right)$$

$$\text{โดย } cl_{min} = \arg \min_{\alpha \in [0,1)} \{P(y_i \in [\hat{L}_{cl_i}, \hat{U}_{cl_i}]) > 0.9\}$$

$$(\hat{U}_{cl_{min_i}}, \hat{L}_{cl_{min_i}}) = \{\hat{y}_i \in \hat{Y}, \sigma_i \in \sigma | (\hat{y}_i - Z_{cl_{min}} \sigma_i, \hat{y}_i + Z_{cl_{min}} \sigma_i)\}$$

$$U_{update_i} = \begin{cases} \min_{i \in n} (U_i, \hat{U}_{cl_{min_i}}), & y_i \in [\hat{L}_{cl_{min_i}}, \hat{U}_{cl_{min_i}}] \\ U_i, & \text{other} \end{cases}$$

$$L_{update_i} = \begin{cases} \max(L_i, \hat{L}_{cl_{min_i}}), & y_i \in [\hat{L}_{cl_{min_i}}, \hat{U}_{cl_{min_i}}] \\ L_i, & \text{other} \end{cases}$$

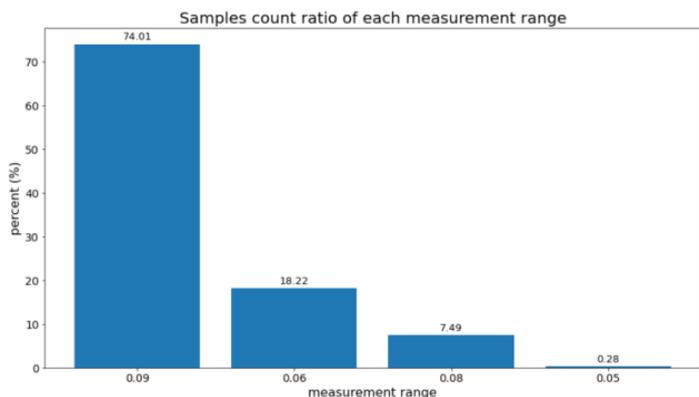
$$\Delta range_i = (U_i - L_i) - (U_{update_i} - L_{update_i})$$

เมื่อ	n	คือ จำนวนตัวอย่าง
	n_{head}	คือ จำนวนหัวเขียน
	n_{zone}	คือ จำนวนโซนบนแผ่นดิสก์ของฮาร์ดไดรฟ์
	$RunTime$	คือ เวลาเฉลี่ยในการวัดค่าระยะ 1 หน่วย
	σ_i	คือ ค่าความไม่แน่นอนของข้อมูล σ จากตัวแบบจำลองการถดถอยโดยความไม่แน่นอนที่ผ่านการปรับการเทียบมาตรฐาน ลำดับที่ i
	cl	คือ ระดับความเชื่อมั่น
	U_i	คือ ขอบเขตบนของช่วงการวัดค่ากระแสไฟฟ้าเขียนวัดได้จากการทดสอบฮาร์ดไดรฟ์ ลำดับที่ i
	L_i	คือ ขอบเขตล่างของช่วงการวัดค่ากระแสไฟฟ้าเขียนวัดได้จากการทดสอบฮาร์ดไดรฟ์ ลำดับที่ i
	\hat{U}_{cl_i}	คือ ขอบเขตบนของช่วงการวัดค่ากระแสไฟฟ้าเขียนที่ได้จากตัวแบบจำลองการถดถอยโดยความไม่แน่นอน ลำดับที่ i ณ ระดับความเชื่อมั่นที่ cl
	\hat{L}_{cl_i}	คือ ขอบเขตล่างของช่วงการวัดค่ากระแสไฟฟ้าเขียนที่ได้จากตัวแบบจำลองการถดถอยโดยความไม่แน่นอน ลำดับที่ i ณ ระดับความเชื่อมั่นที่ cl

cl_{min}	คือ ระดับความเชื่อมั่นที่น้อยที่สุดที่อยู่ในช่วง $[0,1]$ ที่ทำให้ ความน่าจะเป็นที่ $y_i \in [\hat{L}_{cl_i}, \hat{U}_{cl_i}]$ ณ ระดับความเชื่อมั่นที่ cl มีมากกว่า 0.9
$\hat{U}_{cl_{min}_i}$	คือ ขอบเขตบนของช่วงการวัดค่ากระแสไฟฟ้าเขียนที่ได้จากตัวแบบจำลองการถดถอย โดยความไม่แน่นอน ลำดับที่ i ณ ระดับความเชื่อมั่นที่ cl_{min}
$\hat{L}_{cl_{min}_i}$	คือ ขอบเขตบนของช่วงการวัดค่ากระแสไฟฟ้าเขียนที่ได้จากตัวแบบจำลองการถดถอย โดยความไม่แน่นอน ลำดับที่ i ณ ระดับความเชื่อมั่นที่ cl_{min}
U_{update_i}	คือ ถ้า $y_i \in [\hat{L}_{cl_{min}_i}, \hat{U}_{cl_{min}_i}]$ ณ ระดับความเชื่อมั่นที่ cl_{min} แล้ว ขอบเขตบนของช่วงการวัดค่ากระแสไฟฟ้าเขียนที่น้อยที่สุด ระหว่าง U_i และ $\hat{U}_{cl_{min}_i}$ ถ้า ไม่จะเท่ากับ U_i
L_{update_i}	คือ ถ้า $y_i \in [\hat{L}_{cl_{min}_i}, \hat{U}_{cl_{min}_i}]$ ณ ระดับความเชื่อมั่นที่ cl_{min} แล้ว ขอบเขตบนของช่วงการวัดค่ากระแสไฟฟ้าเขียนที่มากที่สุด ระหว่าง L_i และ $\hat{L}_{cl_{min}_i}$ ถ้า ไม่จะเท่ากับ L_i
$\Delta range_i$	คือ ผลต่างระหว่างระยะความกว้างของช่วงการวัดค่า $[L_i, U_i]$ และระยะความกว้างของช่วงการวัดค่า $[L_{update_i}, U_{update_i}]$ ลำดับที่ i
$AvgTTR$	คือ เวลาในการวัดค่าค้นหากระแสไฟฟ้าเขียนที่เหมาะสมที่สุด ที่ลดลงได้โดยเฉลี่ยต่อ ฮาร์ดไดรฟ์ (นาทีก)

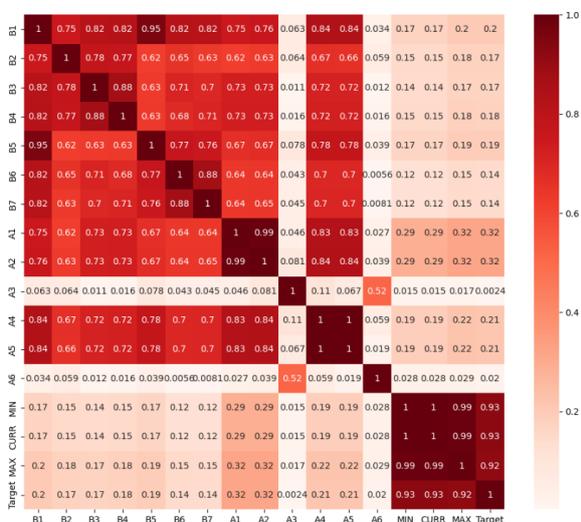
และเกณฑ์ที่ใช้ในการพิจารณารองคือ MAE และ RMSE โดยถ้า ค่า $AvgTTR$ ของแต่ตัวแบบจำลองการถดถอย โดยความไม่แน่นอนใด มีความสามารถลดเวลาการทดสอบกระแสไฟฟ้าเขียนมากที่สุด(นาทีก) กว่าตัวแบบจำลองอื่น แล้ว ถือว่า ตัวแบบจำลองนั้น มีประสิทธิภาพในการลดเวลาการทดสอบสูงสุด แต่ถ้า ค่า $AvgTTR$ ของแต่ละตัวแบบจำลองการถดถอยโดยความไม่แน่นอน มีความสามารถลดเวลาการทดสอบกระแสไฟฟ้าเขียนใกล้เคียงกันที่สุด (นาทีก) ต่างกันไม่เกิน 2 นาทีก ต้องนำเกณฑ์ที่ใช้ในการพิจารณารอง มาพิจารณาว่าตัวแบบใดมีค่า MAE และ RMSE น้อยที่สุด จะถือว่า เป็นแบบจำลองนั้น มีประสิทธิภาพในการลดเวลาการทดสอบสูงสุด

ข้อมูลที่ใช้ในการฝึกตัวแบบจำลองการถดถอยโดยความไม่แน่นอนนั้น ต้องขอขอบคุณ บริษัทซีเกทเทคโนโลยี (ประเทศไทย) จำกัด (โคราช) ที่ให้การสนับสนุนสถานที่ฝึกงาน และข้อมูลในการทำวิจัย ซึ่งนำเข้าข้อมูลตัวอย่างเป็นข้อมูลในกระบวนการผลิตฮาร์ดไดรฟ์ เลือกเฉพาะข้อมูลตัวอย่างฮาร์ดไดรฟ์ที่ผลิตจากวัสดุประเภท A โดยแต่ละหน่วยตัวอย่างมีหน่วยเป็น แต่ละฮาร์ดไดรฟ์ต่อหัวเขียนต่อโซน ซึ่งมีจำนวนตัวอย่าง 2,382,696 โซน เราจะดำเนินการตัดทิ้งหน่วยตัวอย่างที่มีข้อมูลสูญหายทั้งหมด เนื่องจากหน่วยตัวอย่างนั้นเกิดจากการเก็บข้อมูลที่ผิดพลาด และกระบวนการทดสอบ หลังจากตัดทิ้งหน่วยตัวอย่างที่มีข้อมูลสูญหายทั้งหมดแล้ว ชุดข้อมูลนี้จะเหลือจำนวนตัวอย่าง 2,348,460 โซน โดยมีตัวแปรอิสระ และตัวแปรตาม มีดังนี้ (1) week คือ สัปดาห์ที่ทดสอบหลังประกอบฮาร์ดไดรฟ์ เป็นข้อมูลประเภท เวลา (Date Time) (2) B1, B2, B3, B4, B5, B6 และ B7 คือ ข้อมูลการทดสอบของแต่ละส่วนประกอบฮาร์ดไดรฟ์ก่อนประกอบเป็นฮาร์ดไดรฟ์ เป็นข้อมูลเชิงปริมาณ (Quantitative Data) (3) A1, A2, A3, A4, A5 และ A6 คือ ข้อมูลการทดสอบของฮาร์ดไดรฟ์หลังประกอบ เป็นข้อมูลเชิงปริมาณ (4) MIN, CURR และ MAX คือ ข้อมูลช่วงการวัดค่ากระแสไฟฟ้าเขียนที่วัดได้ที่ได้จากการทดสอบฮาร์ดไดรฟ์ เป็นข้อมูลเชิงปริมาณ (5) Zone คือ ข้อมูลโซนของแผ่นดิสก์บนฮาร์ดไดรฟ์ เป็นข้อมูลเชิงคุณภาพ (Qualitative Data) และ ตัวแปรตาม Target คือค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดของฮาร์ดไดรฟ์ เป็นข้อมูลเชิงปริมาณ (Quantitative Data) จากนั้นเราจะทำการการวิเคราะห์ข้อมูลของชุดข้อมูล



รูปที่ 6 แสดงอัตราส่วนของจำนวนตัวอย่างของแต่ละช่วงความกว้างเราจะตรวจสอบช่วงความกว้างสำหรับการวัดค่ากระแสไฟฟ้าเขียน จากการทดสอบฮาร์ดไดรฟ์ โดยคำนวณช่วงความกว้างสำหรับการวัดค่ากระแสไฟฟ้าเขียนจากผลต่างระหว่าง MAX และ MIN

โดยเราจะตรวจสอบช่วงความกว้างการวัดค่ากระแสไฟฟ้าเขียนจากการทดสอบฮาร์ดไดรฟ์ โดยคำนวณช่วงความกว้างสำหรับการวัดค่ากระแสไฟฟ้าเขียนจากผลต่างระหว่าง MAX และ MIN จากภาพ 6 เราพบว่ามียู่ 4 ช่วงความกว้าง



รูปที่ 7 ความสัมพันธ์ระหว่างตัวแปรอิสระโดยวิธี Pearson

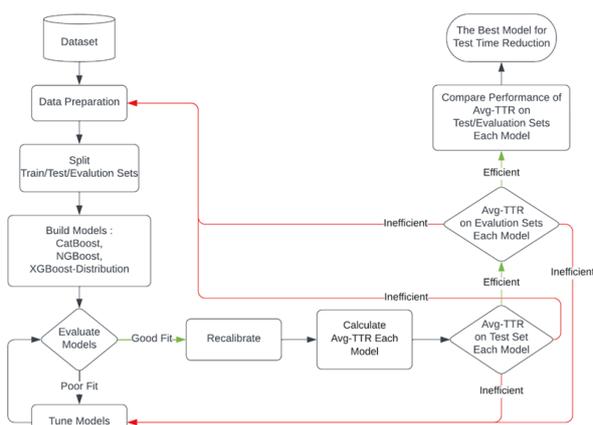
สุดท้ายแล้วเราจะตรวจสอบว่า แต่ละตัวแปรอิสระนั้นมีปัญหาความสัมพันธ์ระหว่างตัวแปรอิสระโดยวิธี Pearson จากรูปที่ 7 เราพบว่ามียู่ปัญหาความสัมพันธ์ระหว่างตัวแปรอิสระค่อนข้างสูงระหว่าง B1-B7, A1-A2, A4-A5 และ MIN-MAX จากนั้นเราจะทำการเตรียมการชุดข้อมูลให้พร้อมสำหรับเรียนรู้ตัวแบบจำลอง ซึ่งผู้วิจัยตัดสินใจที่จะตัดหน่วยตัวอย่างที่มีช่วงความกว้างในการวัดค่าที่ 0.05 ทั้ง เนื่องจากช่วงความกว้างในการวัดนี้มีจำนวนน้อยจนการแจกแจงของตัวแปรตามไม่ชัดเจน แล้วจำนวนตัวอย่างของข้อมูลชุดนี้จะเหลือ 2,341,932 โชน แล้วผู้วิจัยจะทำการนำตัวแปรอิสระที่มีค่าความสัมพันธ์ระหว่างตัวแปรมากกว่าหรือเท่ากับ 0.95 ออก นอกจากตัวแปรอิสระ MIN, CURR, MAX เนื่องจากเป็นตัวแปรอิสระที่ผู้วิจัยตั้งใจให้ตัวแบบจำลองการถดถอยโดยความไม่แน่นอนเรียนรู้ขอบเขตช่วงการวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุด ซึ่งตัวแปรอิสระตัดออก ได้แก่ B5, A2, A5 ออก

ตารางที่ 1 จำนวนตัวอย่างแต่ละสัปดาห์ที่ทดสอบหลังประกอบฮาร์ดแวร์

สัปดาห์ที่ทดสอบหลังประกอบฮาร์ดแวร์	จำนวนตัวอย่าง
01	294,512
02	302,442
03	303,659
04	309,863
05	3,348
06	1,512
07	300,218
08	301,489
09	297,806

เราจะทำการแบ่งชุดฝึกและชุดทดสอบจากตารางที่ 1 โดยใช้ชุดตัวอย่างสัปดาห์ที่ทดสอบหลังประกอบฮาร์ดแวร์ที่ 01, 02, 03 และ 04 ซึ่งมีจำนวน 1,210,476 โชน โดยแบ่งเป็นอัตราส่วนร้อยละ 75 และ 25 ตามลำดับ ซึ่งแต่ละชุดประกอบไปด้วย ตัวแปรอิสระ และตัวแปรตาม จากนั้นนำตัวแปรอิสระที่เป็นข้อมูลเชิงปริมาณ มาปรับสเกลโดย Standard Scaler วิธี z-score และข้อมูลเชิงคุณภาพ มาเข้ารหัสตัวเลขโดย Label Encoder จากไลบรารี sklearn.preprocessing แล้วใช้ชุดตัวอย่างสัปดาห์ที่ทดสอบหลังประกอบฮาร์ดแวร์ที่ 07, 08 และ 09 แบ่งเป็นสัปดาห์ละ 1 ชุด รวมมีชุดประเมินการทดสอบ 3 ชุด จากนั้นนำตัวแปรอิสระที่เป็นข้อมูลเชิงปริมาณ มาปรับสเกล และข้อมูลเชิงคุณภาพ มาเข้ารหัสตัวเลขโดย อ้างอิงจากชุดฝึกและชุดทดสอบ ส่วนชุดตัวอย่างสัปดาห์ที่ทดสอบหลังประกอบฮาร์ดแวร์ที่ไม่ได้นำมาเรียนรู้ หรือทดสอบ เนื่องจากเป็นสัปดาห์ที่ทดสอบอยู่ในช่วงไม่ปกติ

Comparative Study Process



รูปที่ 8 วิธีดำเนินการวิจัย

จากรูปที่ 8 เมื่อเราเตรียมข้อมูลพร้อมสำหรับการเรียนรู้เสร็จเรียบร้อยแล้ว ซึ่งเราฝึกตัวแบบจำลองการถดถอยโดยความไม่แน่นอนบน CPU 80 core แล้วนำมาประเมินประสิทธิภาพของตัวแบบจำลองก่อนที่เราทำการเปรียบเทียบค่า *AvgTTR* ของแต่ละตัวแบบจำลอง โดยเราจะนำเกณฑ์คะแนน MAE และ RMSE มาบ่งบอกประสิทธิภาพของตัวแบบจำลอง โดยจะประเมินแต่ละตัวแบบจำลองว่าเป็นตัวแบบจำลองที่มีประสิทธิภาพในการพยากรณ์ (Good Fit) ก็ต่อเมื่อ ค่าเกณฑ์คะแนนของชุดฝึก และทุกชุดตัวอย่างทดสอบ ถ้า มีค่า MAE น้อยกว่าหรือเท่ากับ 0.025 และ ค่า RSME น้อยกว่าหรือเท่ากับ 0.03 แล้ว ค่า MAE และ RSME ของชุดฝึก และทุกชุดตัวอย่างทดสอบ แต่ละชุดมีค่า

แตกต่างกันไม่เกิน ± 0.0005 หากตัวแบบจำลองไม่มีประสิทธิภาพในการพยากรณ์ (Poor Fit) จะทำการดำเนินการไฮเปอร์พารามิเตอร์ค่าที่เหมาะสมที่สุด เพื่อให้ค่า $AvgTTR$ ได้มากที่สุดสำหรับการลดเวลาทดสอบกระแสไฟฟ้าเขียนแต่ละตัวแบบจำลอง จนกว่าจะได้ตัวแบบจำลองที่มีประสิทธิภาพในการพยากรณ์

หลังจากที่เราได้ตัวแบบจำลองการถดถอยโดยความไม่แน่นอนที่มีประสิทธิภาพในการพยากรณ์ แล้วเราจะนำค่าความไม่แน่นอนของข้อมูลแต่ละตัวแบบจำลองมาประเมิน Calibrated เป็นว่า Well-Calibration หรือไม่ ถ้า ตัวแบบจำลองใด Calibrated ของค่าความไม่แน่นอนของข้อมูลไม่เป็น Well-Calibration เราจะทำการ Recalibrated ความไม่แน่นอนของข้อมูลที่ได้มาจากแต่ละตัวแบบจำลองการถดถอยโดยความไม่แน่นอนนั้น

สุดท้ายแล้วจึงนำค่าความไม่แน่นอนของข้อมูลแต่ละตัวแบบจำลองมาคำนวณ $AvgTTR$ เพื่อเปรียบเทียบประสิทธิภาพในการลดเวลาการทดสอบกระแสไฟฟ้าเขียน กับชุดทดสอบจนได้ จนได้ค่า $AvgTTR$ ที่ดีที่สุดของแต่ละตัวแบบจำลองการถดถอยโดยความไม่แน่นอน แล้วนำตัวแบบมาทดสอบการพยากรณ์เพื่อลดเวลาการทดสอบกระแสไฟฟ้าเขียน กับชุดประเมินการทดสอบ 3 ชุด ว่าตัวแบบจำลองใดลดเวลาลงได้มากที่สุด เพื่อนำไปใช้ในเทคนิค Adaptive Test Condition

ผลการวิจัย

งานวิจัยนี้เป็นการศึกษาเปรียบเทียบตัวแบบจำลองการถดถอยโดยความไม่แน่นอน เพื่อลดเวลาในกระบวนการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดของฮาร์ดไดรฟ์ ซึ่งมีตัวแบบจำลองการถดถอยโดยความไม่แน่นอนที่ใช้การลดเวลาการทดสอบกระแสไฟฟ้าเขียนมีทั้งหมด 3 วิธี โดยได้ผลวิจัยดังนี้

ตารางที่ 2 ผลลัพธ์เกณฑ์คะแนน MAE และ RSME ของชุดฝึก และทุกชุดตัวอย่างทดสอบ แต่ละตัวแบบจำลองการถดถอยโดยความไม่แน่นอน

ชุดตัวอย่างทดสอบ	เกณฑ์คะแนน	ตัวแบบจำลองการถดถอยโดยความไม่แน่นอน		
		NGBoost	XGBoost-Distribution	CatBoost
ชุดฝึก	MAE	0.0234	0.0233	0.0233
	RMSE	0.0286	0.0284	0.0285
ชุดทดสอบ	MAE	0.0235	0.0234	0.0234
	RMSE	0.0287	0.0286	0.0286
ชุดประเมินการทดสอบ สัปดาห์ที่ 07	MAE	0.0231	0.0231	0.0230
	RMSE	0.0285	0.0285	0.0284
ชุดประเมินการทดสอบ สัปดาห์ที่ 08	MAE	0.0231	0.0230	0.0230
	RMSE	0.0284	0.0283	0.0283
ชุดประเมินการทดสอบ สัปดาห์ที่ 09	MAE	0.0231	0.0230	0.0230
	RMSE	0.0284	0.0284	0.0283

*หมายเหตุ: ในวิจัยนี้จะทำการปรับสเกลข้อมูลเชิงปริมาณ เพื่อปกป้องความลับของบริษัท

ผลลัพธ์การประเมินแบบจำลองการถดถอยโดยความไม่แน่นอน จากตารางที่ 2 ผลลัพธ์เกณฑ์คะแนน MAE และ RSME ของชุดฝึก และทุกชุดตัวอย่างทดสอบแต่ละตัวแบบจำลองจะเห็นว่า ทุกตัวแบบจำลองการถดถอยโดยความไม่แน่นอน มีค่า MAE น้อยกว่า 0.025 และ ค่า RSME น้อยกว่า 0.03 ในชุดฝึก และทุกชุดตัวอย่างทดสอบ อีกทั้งแต่ละชุดมีค่าแตกต่างกันไม่เกิน ± 0.0005

ตารางที่ 3 ผลลัพธ์เกณฑ์คะแนนผลจริงที่ได้จากการพยากรณ์ของตัวแบบจำลองความไม่แน่นอน ก่อน Recalibration

ตัวแบบจำลองการถดถอยโดยความไม่แน่นอน	MA (Miscalibration Area)
NGBoost	0.0361
XGBoost-Distribution	0.0380
CatBoost	0.4032

*หมายเหตุ: ในวิจัยนี้จะทำการปรับสเกลข้อมูลเชิงปริมาณ เพื่อปกป้องความลับของบริษัท

จากตารางที่ 3 จะแสดงให้เห็นว่า CatBoost มีค่า MA เท่ากับ 0.4032 บ่งบอกถึงปัญหาที่แสดง Calibrated ที่เรียกว่า Overconfidence กล่าวคือ สัดส่วนของช่วงความเชื่อมั่นของผลทำนายครอบคลุมผลจริงมากกว่าสัดส่วน ณ ระดับความเชื่อมั่นจริงนั้นๆ แต่ในทางตรงกันข้าม NGBoost มีค่า MA เท่ากับ 0.0361 และ XGBoost-Distribution มีค่า MA เท่ากับ 0.0380 ซึ่งแทบจะไม่มีปัญหา หรือเรียกได้ว่าแสดง Calibrated เป็น Well-calibration กล่าวคือ สัดส่วนของช่วงความเชื่อมั่นของผลทำนายครอบคลุมผลจริงเท่ากับ หรือใกล้เคียงสัดส่วน ณ ระดับความเชื่อมั่นจริงนั้นๆ

ตารางที่ 4 ผลลัพธ์เกณฑ์คะแนนผลจริงที่ได้จากการพยากรณ์ของตัวแบบจำลองความไม่แน่นอน หลัง Recalibration

ตัวแบบจำลองการถดถอยโดยความไม่แน่นอน	MA (Miscalibration Area)
NGBoost	0.0345
XGBoost-Distribution	0.0358
CatBoost	0.0652

*หมายเหตุ: ในวิจัยนี้จะทำการปรับสเกลข้อมูลเชิงปริมาณ เพื่อปกป้องความลับของบริษัท

ตารางที่ 4 จะพบว่า หลัง Recalibrated ความไม่แน่นอนของข้อมูลที่ได้มาจากแต่ละตัวแบบจำลองการถดถอยโดยความไม่แน่นอน ซึ่งค่า MA ของแต่ละตัวแบบจำลอง NGBoost มีค่าเท่ากับ 0.0345 และ XGBoost-Distribution มีค่าเท่ากับ 0.0358 ลดลงจากเดิมเล็กน้อย แต่ ค่า MA ของตัวแบบจำลอง CatBoost ลดลงอย่างมากจากเดิม 0.4032 เหลือเพียง 0.0652 ซึ่งแก้ไขปัญหา Overconfidence แล้ว ดังนั้นทุกค่าความไม่แน่นอนของข้อมูลของตัวแบบจำลองที่ผ่านการ Recalibration นั้นทำให้แสดง Calibrated เป็น Well-calibration อย่างไรก็ตามแม้ Recalibration ค่า MA ของ CatBoost ยังคงสูงกว่า XGBoost-Distribution และ NGBoost

ตารางที่ 5 ผลลัพธ์เกณฑ์คะแนนผลจริงที่ได้จากการพยากรณ์ และการลดเวลาการทดสอบของตัวแบบจำลองความไม่แน่นอน แต่ละชุดตัวอย่างทดสอบ

ชุดตัวอย่างทดสอบ	เกณฑ์คะแนน	ตัวแบบจำลองการถดถอยโดยความไม่แน่นอน		
		NGBoost	XGBoost-Distribution	CatBoost
ชุดทดสอบ	MAE	0.0235	0.0234	0.0234
	RMSE	0.0287	0.0286	0.0286
	MA	0.0345	0.0358	0.0652
	<i>AvgTTR</i>	27.97	28.35	32.13
ชุดประเมินการทดสอบ สัปดาห์ที่ 07	MAE	0.0231	0.0231	0.0230
	RMSE	0.0285	0.0285	0.0284
	MA	0.0316	0.0329	0.0638
	<i>AvgTTR</i>	28.46	28.95	33.6
ชุดประเมินการทดสอบ สัปดาห์ที่ 08	MAE	0.0231	0.0230	0.0230
	RMSE	0.0284	0.0283	0.0283
	MA	0.0337	0.0347	0.0663
	<i>AvgTTR</i>	29.56	29.91	34.19
ชุดประเมินการทดสอบ สัปดาห์ที่ 09	MAE	0.0231	0.0230	0.0230
	RMSE	0.0284	0.0284	0.0283
	MA	0.0332	0.0336	0.0647
	<i>AvgTTR</i>	29.42	29.76	33.14

*หมายเหตุ: ในวิจัยนี้จะทำการปรับสเกลข้อมูลเชิงปริมาณ เพื่อปกป้องความลับของบริษัท

ตารางที่ 5 แสดงการเปรียบเทียบ ค่าเกณฑ์คะแนน *AvgTTR*, MAE และ RMSE ของแต่ละตัวแบบจำลองการถดถอยโดยความไม่แน่นอนของชุดทดสอบ และชุดประเมินการทดสอบสัปดาห์ที่ 07, 08 และ 09 จะเห็นได้ชัดว่าเกณฑ์คะแนน MAE และ RMSE ไม่แตกต่างกันอย่างมีนัยสำคัญสำหรับแต่ละตัวแบบจำลองในชุดตัวอย่างทดสอบ หลังจากที่ Recalibrated ความไม่แน่นอนของข้อมูลสำหรับแต่ละตัวแบบจำลอง ซึ่ง NGBoost มีค่า MA น้อยที่สุด รองลงมาคือ XGBoost-Distribution แต่ CatBoost มีค่า MA ความแตกต่างเกือบสองเท่ากับตัวแบบจำลองอื่น โดยรวมแล้ว CatBoost มีความสามารถในการลดเวลาทดสอบมากที่สุด เนื่องจากมีค่า *AvgTTR* มากที่สุดในทุกชุดตัวอย่างทดสอบ เมื่อเปรียบเทียบกับตัวแบบจำลองอื่น

สรุปและอภิปรายผลการวิจัย

สรุปของการศึกษานี้มีเป้าหมาย เพื่อใช้ตัวแบบจำลองการถดถอยโดยความไม่แน่นอน (Uncertainty Regression Models) เพื่อลดเวลาทดสอบของการทดสอบกระแสไฟฟ้าเขี่ยนที่ใช้ในกระบวนการผลิตฮาร์ดดิสก์ ซึ่งถ้าใช้ตัวแบบจำลองการถดถอยทั่วไปอาจมีปัญหาด้านประสิทธิภาพ การใช้วิธี Adaptive Test Condition ที่ใช้ตัวแบบจำลองการถดถอยโดยความไม่แน่นอน เพื่อลดช่วงการวัดของการทดสอบกระแสไฟฟ้าเขี่ยน ซึ่งหลังจากที่ฝึกแต่ละตัวแบบจำลอง และทำการดำเนินการไฮเปอร์พารามิเตอร์ค่าเหมาะสมที่สุด เพื่อให้ค่า *AvgTTR* ได้มากที่สุดสำหรับการลดเวลาทดสอบกระแสไฟฟ้าเขี่ยน จนสุดท้ายแล้วจากตารางที่ 2 แสดงผลลัพธ์การประเมินตัวแบบจำลองว่า NGBoost,

XGBoost-Distribution และ CatBoost เป็นตัวแบบจำลองที่มีประสิทธิภาพในการพยากรณ์ (Good Fit) สามารถอภิปรายผลได้ ดังนี้

1) ตารางที่ 3 พบว่า ก่อนทำการ Recalibrated ค่าความไม่แน่นอนของข้อมูลใหม่ให้อยู่ในระดับที่เหมาะสม โดยต้องสามารถครอบคลุมค่าที่แท้จริงตามสัดส่วนของระดับความเชื่อมั่น หลังจากทำการ Recalibrated ความไม่แน่นอนของข้อมูลของแต่ละตัวแบบจำลองแล้ว จากตารางที่ 4 จะแสดงให้เห็นว่าค่าความไม่แน่นอนของข้อมูลของ CatBoost หลังจาก Recalibrated ค่าความไม่แน่นอนของข้อมูลของแต่ละตัวแบบจำลอง Calibrated เป็น Well-Calibration ดังนั้นก่อนจะนำค่าความไม่แน่นอนของข้อมูลที่ได้จากตัวแบบจำลองไปใช้คำนวณช่วงเชื่อมั่นของผลทำนาย ควร Recalibration ค่าความไม่แน่นอนของข้อมูลก่อน เพื่อสัดส่วนของช่วงความเชื่อมั่นของผลทำนายครอบคลุมผลจริงเท่ากับ หรือใกล้เคียงสัดส่วน ณ ระดับความเชื่อมั่นจริงนั้นๆ

2) การศึกษาเปรียบเทียบความสามารถของตัวแบบจำลองการถดถอยโดยความไม่แน่นอนที่นำไปใช้ในเทคนิค Adaptive Test Condition นั้น จากตารางที่ 5 แสดงให้เห็นว่าตัวแบบจำลองการถดถอยโดยค่าความไม่แน่นอน CatBoost มีผลลัพธ์การลดเวลาการทดสอบมากที่สุดในทุกชุดตัวอย่างการทดสอบ ที่ช่วงความเชื่อมั่นของผลทำนายครอบคลุมผลจริงอย่างน้อย 0.9 จากทุกตัวแบบจำลองการถดถอยโดยความไม่แน่นอน อย่าง NGBoost และ XGBoost-Distribution ที่มีผลลัพธ์การลดเวลาการทดสอบใกล้เคียงกันทุกในชุดตัวอย่างการทดสอบ แต่ในขณะเดียวกัน ค่า MAE และ RMSE ในทุกชุดตัวอย่างการทดสอบของแต่ละตัวแบบจำลองการถดถอยโดยความไม่แน่นอนนั้นกลับมีค่าใกล้เคียงกัน ซึ่งแสดงให้เห็นชัดว่า อัลกอริทึม และฟังก์ชันการสูญเสียของ CatBoost มีประสิทธิภาพสูงสุดในเงื่อนไขที่กำหนดในงานวิจัยนี้สำหรับ นำไปใช้ในเทคนิค Adaptive Test Condition ในการลดเวลาการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดของฮาร์ดไดรฟ์

ข้อเสนอแนะที่ได้รับจากการวิจัย

จากผลการศึกษาเปรียบเทียบตัวแบบจำลองการถดถอยโดยความไม่แน่นอนเพื่อลดเวลาในกระบวนการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุดของฮาร์ดไดรฟ์ ผู้วิจัยมีข้อเสนอแนะ ดังนี้

1) ในวิจัยนี้ศึกษาในกรณีของการทดสอบวัดค่ากระแสไฟฟ้าเขียนเหมาะสมที่สุดของฮาร์ดไดรฟ์ บนวัสดุประเภท A เท่านั้น หากเป็นวัสดุชนิดอื่นที่ใช้เป็นสื่อบันทึก ซึ่งผลลัพธ์ของความสามารถในการลดเวลาการทดสอบอาจมีความสามารถในการลดเวลาการทดสอบวัดค่ากระแสไฟฟ้าเขียนที่เหมาะสมที่สุด เนื่องจากข้อมูลที่ได้จากวัสดุอื่นอาจมีการแจกแจงที่แตกต่างจากวัสดุประเภท A

2) สำหรับตัวแบบจำลองการถดถอยโดยความไม่แน่นอนที่ใช้ในวิจัยนี้ ที่มีข้อจำกัดในการศึกษาเปรียบเทียบ เฉพาะการเรียนรู้แบบเครื่องจักร (Machine Learning) เท่านั้น หากใช้แบบจำลองการเรียนรู้แบบเชิงลึก (Deep Learning) ที่สามารถในการเรียนรู้ข้อมูลที่มีความซับซ้อนได้ ซึ่งอาจจะสามารถประมาณค่าความไม่แน่นอนได้อย่างแม่นยำมากขึ้น

3) ในการศึกษาและเปรียบเทียบในงานวิจัยนี้มีเงื่อนไขที่ช่วงความเชื่อมั่นของผลทำนาย ณ ระดับความเชื่อมั่นที่ยอมรับได้ ต้องครอบคลุมสัดส่วนผลจริง อย่างน้อย 0.9 ซึ่งในกระบวนการผลิตนั้นเราสามารถที่จะเลือกระดับความเชื่อมั่นที่ยอมรับได้ ที่สามารถครอบคลุมสัดส่วนผลจริง ตามที่กระบวนการผลิตนั้นต้องการได้

ข้อเสนอแนะในการวิจัยครั้งต่อไป

1) การศึกษาเปรียบเทียบในอนาคตของตัวแบบจำลองการถดถอยโดยความไม่แน่นอน จะนำค่าความไม่แน่นอนของตัวแบบจำลอง (Model Uncertainty) มาประยุกต์ใช้ในการวินิจฉัยหน่วยตัวอย่างว่า อยู่นอกโดเมนของข้อมูลหรือไม่ กล่าวคือ จะสามารถระบุได้ว่าการพยากรณ์ของหน่วยตัวอย่างนั้นมีความน่าเชื่อถืออย่างน้อยเพียงใด นั่นจะเป็นประโยชน์ในกระบวนการผลิต อีกทั้งยังสามารถเตือนว่า การแจกแจง และโดเมนของข้อมูลกำลังเกิดการเปลี่ยนแปลง เพื่อเตรียมดำเนินการฝึกการเรียนรู้ของตัวแบบจำลองได้อย่างรวดเร็ว

- 2) เนื่องจากในงานวิจัยนี้มีข้อจำกัดเรื่องที่ไม่สามารถเพิ่มตัวแปรอิสระ นอกเหนือจากที่ระบุไว้ได้ เนื่องจากมีค่าใช้จ่ายที่สูง หากเราสามารถเพิ่มตัวแปรที่มีอิทธิต่อการพยากรณ์ของกระแสไฟฟ้าเขียนได้ ตัวแบบจำลองการถดถอยโดยความไม่แน่นอนอาจมีประสิทธิภาพในการประมาณค่าความไม่แน่นอนมากขึ้นจากเดิม
- 3) แนวทางที่ได้จากการศึกษาการศึกษาเปรียบเทียบตัวแบบจำลองการถดถอยโดยความไม่แน่นอนในงานวิจัยนี้ เราสามารถไปประยุกต์ใช้กับกระแสเขียนอื่นนอกจากกระแสไฟฟ้าเขียน หรือการทดสอบพารามิเตอร์ที่มีลักษณะต้องวัดค่าช่วงที่มีความกว้างที่ทำให้เกิด ค่าใช้จ่ายที่สูง และเสียเวลา
- 4) งานวิจัยนี้ไม่ได้มีขอบเขตแค่ในกระบวนการผลิตฮาร์ดไดรฟ์เท่านั้น แต่สามารถเป็นแนวทางในการแก้ไขโจทย์ปัญหาในอุตสาหกรรมอิเล็กทรอนิกส์ หรือผลิตภัณฑ์อื่นๆ ที่ต้องการการลดช่วงการวัดค่าที่แม่นยำในขณะทดสอบ

เอกสารอ้างอิง

- พรชัย เปลี่ยมทรัพย์, พรชัย ทวีพันธ์ และกัณวัฒน์ เสนานานู. (2553). *ผลกระทบของกระแสเขียนต่อสมรรถนะของระบบบันทึกข้อมูลเชิงแม่เหล็กแนวตั้ง*. เรื่องเติมการประชุมทางวิชาการของมหาวิทยาลัยเกษตรศาสตร์ ครั้งที่ 48, 302-309.
- รศ.ดร.ปิยะ โควินท์ทวีวัฒน์. (2550). การประมวลสัญญาณสำหรับการจัดเก็บข้อมูลดิจิทัล เล่ม 1: พื้นฐานช่องสัญญาณอ่าน: *เทคโนโลยีอิเล็กทรอนิกส์และคอมพิวเตอร์แห่งชาติ*. 6-8.
- Al Mamun, A., Guo, G., & Bi, C. (2017). *Hard disk drive: mechatronics and control*. CRC press.
- Benner, S., & Boroffice, O. (2001). *Optimal production test times through adaptive test programming*. In Proceedings International Test Conference 2001 (Cat. No. 01CH37260), IEEE, 908-915.
- Boards ITRS. (2015). The International Technology Roadmap for Semiconductors 2.0 (ITRS). *Semiconductor Industry Association*, 21-31.
- Chen, M., & Orailoglu, A. (2008). *Test cost minimization through adaptive test development*. In 2008 IEEE International Conference on Computer Design, IEEE, 234-239.
- Christian, D. (2020). *Xgboost-distribution*. Available at: <https://xgboost-distribution.readthedocs.io/en/latest/readme.html>.
- Duan, T., Anand, A., Ding, D. Y., Thai, K. K., Basu, S., Ng, A., & Schuler, A. (2020). *Ngboost: Natural gradient boosting for probabilistic prediction*. In International Conference on Machine Learning, PMLR, 2690-2700.
- Guo, C., Lim, T., & Chua, T. (2019). *Methods and devices for reducing device test time*. U.S. Patent No. 10,339,448. Washington, DC: U.S. Patent and Trademark Office.
- Jone, W. B., Yeh, W. S., Yeh, C., & Das, S. R. (2001). An adaptive path selection method for delay testing. *IEEE Transactions on Instrumentation and Measurement*, 50(5), IEEE, 1109-1118.
- Kuleshov, V., Fenner, N., & Ermon, S. (2018). *Accurate uncertainties for deep learning using calibrated regression*. In International conference on machine learning, PMLR, 2796-2804.
- Letchumanan, S., Tan, T. H. H., Gan, Y. P., & Wong, S. L. (2018). *Adaptive test method on production system-level testing (SLT) to optimize test cost, resources and defect parts per million (DPPM)*. In 2018 International Symposium on VLSI Design, Automation and Test (VLSI-DAT), IEEE, 1-3.
- Madge, R., Benware, B., Turakhia, R., Daasch, R., Schuermyer, C., & Ruffler, J. (2004). *In search of the optimum test set-adaptive test methods for maximum defect coverage and lowest test cost*. In 2004 International Conference on Test, IEEE, 203-212.

- Malinin, A., Prokhorenkova, L., & Ustimenko, A. (2020). *Uncertainty in gradient boosting via ensembles*. arXiv preprint arXiv:2006.10562.
- Ray, S. (2017). *CatBoost: A machine learning library to handle categorical (CAT) data automatically*. Available at: <https://catboost.ai/en/docs/>
- Song, T., Liang, H., Ni, T., Huang, Z., Lu, Y., Wan, J., & Yan, A. (2020). Pattern reorder for test cost reduction through improved SVMRANK algorithm. *IEEE Access* 8, 147965-147972.
- Suresh, C. K., Ozev, S., & Sinanoglu, O. (2016). Adaptive Reduction of the Frequency Search Space for Multi-Vdd Digital Circuits Using Variation Sensitive Ring Oscillators. *IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems*, 36(6), IEEE, 1043-1053.
- Wu, W. J., Tang, C. Y., & Lin, M. Y. (1996). *Methods for memory test time reduction*. In IEEE International Workshop on Memory Technology, Design and Testing, IEEE, 64-71.
- Yeh, J. C., Kuo, S. F., Wu, C. W., Huang, C. T., & Chen, C. H. (2005). *A systematic approach to reducing semiconductor memory test time in mass production*. In 2005 IEEE International Workshop on Memory Technology, Design, and Testing (MTDT'05), IEEE. 97-102.

Data Availability Statement: The raw data supporting the conclusions of this article will be made available by the authors, without undue reservation.

Conflicts of Interest: The authors declare that the research was conducted in the absence of any commercial or financial relationships that could be construed as a potential conflict of interest.

Publisher's Note: All claims expressed in this article are solely those of the authors and do not necessarily represent those of their affiliated organizations, or those of the publisher, the editors and the reviewers. Any product that may be evaluated in this article, or claim that may be made by its manufacturer, is not guaranteed or endorsed by the publisher.



Copyright: © 2023 by the authors. This is a fully open-access article distributed under the terms of the Attribution-NonCommercial-NoDerivatives 4.0 International (CC BY-NC-ND 4.0).