

การทำนายค่าสัญญาณอ่านกลับด้วยเทคนิคการเรียนรู้เครื่อง  
ในระบบการบันทึกข้อมูลแบบบิตแพทเทิร์นมีเดีย

THE READBACK SIGNAL PREDICTION BASED ON MACHINE LEARNING  
TECHNIQUE IN BIT PATTERNED MEDIA RECORDING SYSTEM

ไตรรัตน์ เต็มสันเทียะ

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลสารสนเทศ

คณะวิทยาศาสตร์และเทคโนโลยี

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

ปีการศึกษา 2564

ลิขสิทธิ์ของมหาวิทยาลัยราชภัฏวชิราวุฒิ

**THE READBACK SIGNAL PREDICTION BASED ON MACHINE LEARNING  
TECHNIQUE IN BIT PATTERNED MEDIA RECORDING SYSTEM**



**TRAIRATANA TERMSANTHIA**

**A THESIS SUBMITTED IN PARTIAL FULFILLMENT OF THE  
REQUIREMENTS OF DEGREE OF MASTER SCIENCE  
PROGRAM IN DATA SCIENCE**

**FACULTY OF SCIENCE AND TECHNOLOGY**

**RAJAMANGALA UNIVERSITY OF TECHNOLOGY THANYABURI**

**ACADEMIC YEAR 2021**

**COPYRIGHT OF RAJAMANGALA UNIVERSITY**

**OF TECHNOLOGY THANYABURI**

การทำนายค่าสัญญาณอ่านกลับด้วยเทคนิคการเรียนรู้เครื่อง  
ในระบบการบันทึกข้อมูลแบบบิตแพทเทิร์นมีเดีย

ไตรรัตน์ เต็มสันเทียะ

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลสารสนเทศ

คณะวิทยาศาสตร์และเทคโนโลยี

มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี

ปีการศึกษา 2564

ลิขสิทธิ์ของมหาวิทยาลัยราชมงคลธัญบุรี

หัวข้อวิทยานิพนธ์      การทำนายค่าสัญญาณอ่านกลับด้วยเทคนิคการเรียนรู้เครื่องในระบบการ  
บันทึกข้อมูลแบบบิตแพตเทิร์นมีเดีย  
The Readback Signal Prediction Based on Machine Learning  
Technique in Bit Patterned Media Recording System


ชื่อ-นามสกุล            นายไตรรัตน์ เต็มสันเทียะ

สาขาวิชา                วิทยาการข้อมูลสารสนเทศ


อาจารย์ที่ปรึกษา        ผู้ช่วยศาสตราจารย์อนุชา ตุงคัษฐาน, ปร.ด.

ปีการศึกษา              2564

คณะกรรมการสอบวิทยานิพนธ์

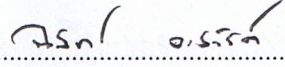
  
..... ประธานกรรมการ  
(อาจารย์พาสาม โพรุฮาน, ปร.ด.)

  
..... กรรมการ  
(ผู้ช่วยศาสตราจารย์อนุชา ตุงคัษฐาน, ปร.ด.)

  
..... กรรมการ  
(ผู้ช่วยศาสตราจารย์พิทยา พุ่มพวง, ปร.ด.)

  
..... กรรมการ  
(อาจารย์วิภารัตน์ นุชยาตรัส, ปร.ด.)

คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี อนุมัติวิทยานิพนธ์  
ฉบับนี้ เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาโทบริหารบัณฑิต

  
..... คณบดีคณะวิทยาศาสตร์  
(ผู้ช่วยศาสตราจารย์นิพัทธ์ จงสวัสดิ์, ปร.ด.)

วันที่ 4 เดือน กันยายน พ.ศ. 2564

หัวข้อวิทยานิพนธ์	การทำนายค่าสัญญาณอ่านกลับด้วยเทคนิคการเรียนรู้เครื่องในระบบการบันทึกข้อมูลแบบบิตแพทเทิร์นมีเดีย
ชื่อ-นามสกุล	นายไตรรัตน์ เต็มสันเทียะ
สาขาวิชา	วิทยาการข้อมูลสารสนเทศ
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์อนุชา ตุงศ์ฐาน, ปร.ด.
ปีการศึกษา	2564

### บทคัดย่อ

ความต้องการในการใช้พื้นที่สำหรับเก็บข้อมูลในรูปแบบดิจิทัลเพิ่มขึ้นอย่างต่อเนื่อง อุปกรณ์ที่เป็นหนึ่งในตัวเลือกที่มีประสิทธิภาพสูงที่สุดในการเก็บข้อมูลดิจิทัล นั้นคือ ฮาร์ดดิสก์ไดรฟ์ ซึ่งเป็นอุปกรณ์ที่ได้รับความนิยมในการใช้งานกันอย่างแพร่หลายในการเก็บข้อมูลเนื่องด้วยมีความจุสูง ราคาถูก และมีความคงทนถาวรในการใช้งาน ซึ่งในปัจจุบันเทคโนโลยีเดิมที่ใช้ในการบันทึกข้อมูลเข้าใกล้ขีดจำกัดทางการพัฒนาจาก “ข้อจำกัดทางซูเปอร์พาราแมกเนติก (Superparamagnetic limit)” จึงทำให้การเพิ่มหน่วยความจุด้วยการใช้เทคโนโลยีรูปแบบเดิมนั้นเกิดข้อจำกัด

เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กในรูปแบบบิตแพทเทิร์นมีเดียหรือพีพีเอ็มอาร์ เป็นหนึ่งในเทคโนโลยีที่มีความน่าสนใจในการพัฒนาเป็นอย่างมาก เนื่องจากสามารถเพิ่มประสิทธิภาพของ ความหนาแน่นเชิงพื้นที่ของสื่อบันทึกได้มากกว่าเทคโนโลยีแบบเดิมหลายเท่า แต่การบันทึกข้อมูลลงบนเทคโนโลยีนี้ต้องเผชิญหน้ากับปัญหาหลายอย่าง ทั้งการแทรกสอดสอดระหว่างสัญญาณ (ISI), การแทรกสอดระหว่างแทร็ก (ITI) การอ่านออกนอกแทร็กของหัวอ่าน และความผันผวนของตำแหน่ง โดยในปัจจุบันการประยุกต์ใช้เทคนิคกระบวนการเรียนรู้ของเครื่องเข้ามาแก้ปัญหาในบริบทที่ หลากหลายได้เป็นอย่างดี จึงทำให้การนำเอาเทคนิคเหล่านี้เข้ามาใช้อุปกรณ์ฮาร์ดแวร์ เพื่อเพิ่มสมรรถนะในการทำงานจึงเป็นเรื่องที่มีความน่าสนใจในการพัฒนา โดยการนำเทคนิคกระบวนการเรียนรู้ของเครื่องเข้ามาใช้ในระบบการบันทึกข้อมูลเชิงแม่เหล็กแบบพีพีเอ็มอาร์

วิทยานิพนธ์ฉบับนี้ได้นำเสนอการใช้เทคนิคกระบวนการเรียนรู้ของเครื่องนำมาสร้างโมเดลทำนายผลจากหลากหลายอัลกอริทึม สำหรับจำแนกประเภทข้อมูลบิตที่ออกจากช่องสัญญาณพีพีเอ็ม

อาร์จากการดำเนินงาน เราพบว่า การทดสอบโมเดลการทำนายผลที่ได้สร้างขึ้นทั้งหมด โมเดลที่สามารถทนทานต่อปัญหาในช่องสัญญาณนั้นคือ กระบวนการเรียนรู้เชิงลึก ซึ่งมีความแม่นยำและมีความถูกต้องจากการทดสอบสูงที่สุด

**คำสำคัญ :** กระบวนการเรียนรู้ของเครื่อง, เทคนิคการเรียนรู้เชิงลึก, การแทรกสอดแบบสองมิติ, การอ่านออกนอกเทร็ก, การบันทึกข้อมูลเชิงแม่เหล็กในรูปแบบบีพีเอ็มอาร์



<b>Thesis Title</b>	The Readback Signal Prediction Based on Machine Learning Technique in Bit Patterned Media Recording System
<b>Name-Surname</b>	Mr. Trairatana Termsanthia
<b>Program</b>	Information Technology and Data Science
<b>Thesis Advisor</b>	Assistant Professor Anucha Tungkasthan, Ph. D.
<b>Academic Year</b>	2021

## ABSTRACT

The demand for digital storage spaces is constantly increasing and one of the most efficient options for storing data is a hard disk drive. The hard disk drive has been widely used in data storage because of its large capacity, low price per unit, and durability. However, conventional magnetic recording technology is approaching limited development because of superparamagnetic limit problems. Increasing storage capacity using conventional technology has become untenable.

Bit-patterned media recording (BPMR) is one of the most exciting new technologies to be considered and developed because BPMR can increase areal density more than today's technology. BPMR technology depends on multiple factors that can degrade its performance, such as inter-symbol interference (ISI), inter-track interference (ITI), track misregistration (TMR), and position fluctuation. Artificial intelligence and machine learning have demonstrated the ability to work effectively in distinctive contexts. It is interesting to develop and apply machine learning process techniques in BPMR systems to improve system performance.

This study presents machine learning techniques for creating classification models from various algorithms to compute readback signals in the BPMR channel. From the result of the operation, it was found that all of prediction tests, the most

efficient model is deep learning. Deep learning yields in the highest accuracy associated with the lowest loss.

**Keywords :** Machine Learning (ML), Deep Learning, 2D interference, Track misregistration (TMR), Bit-pattern media recording (BPMR)





## กิตติกรรมประกาศ

การทำวิทยานิพนธ์ฉบับนี้จะสำเร็จได้ด้วยดีนั้น นอกจากตัวผู้วิจัยเองแล้ว ยังมีบุคคลสำคัญอีกหลายท่านที่มีส่วนสำคัญในการจัดทำวิทยานิพนธ์ฉบับนี้ขึ้นมา ผู้วิจัยขอใช้กิตติกรรมประกาศของวิทยานิพนธ์ขอแสดงความขอบพระคุณอย่างสูงมา ณ ที่นี้

ขอขอบพระคุณ อาจารย์ที่ปรึกษา ผู้เป็นแรงผลักดันสำคัญที่ทำให้วิทยานิพนธ์สำเร็จได้ โดยอาจารย์ให้ความรู้ คำแนะนำ และคำปรึกษาตั้งแต่ผู้วิจัยได้เริ่มเรียนต่อในระดับชั้นปริญญาโท นอกเหนือจากนี้อาจารย์ยังคงเป็นผู้ให้คำปรึกษาที่ดีตลอดระยะเวลาในการจัดทำวิทยานิพนธ์ฉบับนี้

ขอขอบพระคุณคณาจารย์ทุกท่านที่คอยให้ความรู้ แนวคิด คำแนะนำ และโอกาส ในการเรียนรู้สิ่งใหม่ ๆ โดยคณาจารย์ทุกท่านช่วยเพิ่มเติมความรู้ในส่วนที่จำเป็นสำหรับศาสตร์นี้ รวมทั้งคำแนะนำและคำปรึกษาที่ดีตลอดมา จนสามารถนำไปต่อยอดในการทำวิทยานิพนธ์ฉบับนี้

ขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ ที่กรุณาให้เกียรติเป็นคณะกรรมการให้แก่ผู้วิจัย รวมทั้งยังให้คำแนะนำและความรู้ที่สำคัญที่สามารถนำไปต่อยอดในการทำงานวิจัยได้

ขอขอบพระคุณ เพื่อน พี่ น้อง ปริญญาโททุกท่านสำหรับการให้กำลังใจซึ่งกันและกัน รวมทั้งคอยให้ความรู้ คำแนะนำ และคำติชม รวมไปถึงแนวคิดใหม่ ๆ ที่สามารถนำมาปรับใช้ในวิทยานิพนธ์

และท้ายสุดนี้ ขอขอบพระคุณครอบครัวและบุคคลอันเป็นที่รักของผู้วิจัย ที่คอยให้กำลังใจและสนับสนุนผู้วิจัยในทุก ๆ ด้าน ตลอดระยะเวลาที่ผู้วิจัยได้เริ่มต้นการศึกษาต่อในระดับปริญญาโท จนจบ การทำวิทยานิพนธ์ฉบับนี้ถือเป็นอีกหนึ่งประสบการณ์ที่มีคุณค่ามากต่อผู้วิจัย และสุดท้ายนี้ ผู้วิจัยคิดว่าจะนำสิ่งที่ได้รับส่งต่อเป็นแรงผลักดันให้กับบุคคลถัดไปที่อยู่ในเส้นทางของการทำวิทยานิพนธ์

ไตรรัตน์ เต็มสันเทียะ

## สารบัญ

หน้า

บทคัดย่อภาษาไทย.....	(1)
บทคัดย่อภาษาอังกฤษ.....	(3)
กิตติกรรมประกาศ.....	(5)
สารบัญ.....	(6)
สารบัญตาราง.....	(8)
สารบัญภาพ.....	(9)
คำอธิบายสัญลักษณ์และคำย่อ.....	(11)
บทที่ 1 บทนำ.....	13
1.1 ความเป็นมาและความสำคัญของปัญหา.....	13
1.2 ปัญหาและแนวทางการแก้ไขปัญหา.....	14
1.3 ความมุ่งหมายและจุดประสงค์ของงานวิจัย.....	15
1.4 ขอบเขตของงานวิจัย.....	15
1.5 วิธีการวิจัย.....	16
1.6 ข้อจำกัดของงานวิจัย.....	17
1.7 ประโยชน์ที่คาดว่าจะได้รับ.....	17
บทที่ 2 ทฤษฎีและงานวิจัยที่เกี่ยวข้อง.....	18
2.1 กระบวนการเรียนรู้ของเครื่อง.....	18
2.2 การจำแนกประเภท (Classification).....	21
2.3 การแบ่งชุดข้อมูล.....	22
2.4 โอเวอร์ฟิตติ้ง (Overfitting).....	23
2.5 อันเดอร์ฟิตติ้ง (Underfitting).....	24

## สารบัญ (ต่อ)

	หน้า
2.6 การวัดประสิทธิภาพ .....	24
2.7 ระบบการบันทึกข้อมูลเชิงแม่เหล็ก .....	27
2.8 ระบบการบันทึกข้อมูลเชิงแม่เหล็กแบบบิตแพทเทิร์นมีเดีย.....	31
2.9 ปัญหาในระบบการบันทึกข้อมูลแม่เหล็กแบบบิตแพทเทิร์นมีเดีย.....	33
2.10 ผลกระทบของการแทรกสอดแบบสองมิติในระบบ BPMR .....	39
2.11 การเข้ารหัสและถอดรหัสมอดูเลชัน 5/6.....	40
บทที่ 3 วิธีการดำเนินงาน.....	43
3.1 การจำลองช่องสัญญาณแบบ BPMR.....	43
3.2 การเก็บข้อมูลและจัดรูปแบบข้อมูล .....	45
3.3 การหาความสัมพันธ์ของข้อมูล.....	48
3.4 กระบวนการสร้างโมเดลการทำนายผล .....	50
บทที่ 4 ผลการวิเคราะห์ข้อมูล.....	52
4.1 การสร้างโมเดลสำหรับการทำนายผล.....	52
4.2 ผลลัพธ์จากการสร้างโมเดลและการวัดสมรรถนะ .....	53
บทที่ 5 สรุปผลการทดลองและข้อเสนอแนะ .....	58
5.1 สรุปผลการทดลอง.....	58
5.2 ข้อเสนอแนะ .....	58
บรรณานุกรม.....	60
ภาคผนวก.....	64
ประวัติผู้เขียน.....	69

## สารบัญตาราง

หน้า

ตารางที่ 2.1 เปรียบเทียบเทคโนโลยีการบันทึกข้อมูล .....	30
ตารางที่ 2.2 พารามิเตอร์จำลองหัวอ่านในสื่อบันทึกของระบบการบันทึกบีพีเอ็มอาร์ .....	32
ตารางที่ 2.3 แสดงค่าสัมประสิทธิ์ของสัญญาณ BPMR ที่ค่า AD ในแต่ละระดับ .....	35
ตารางที่ 2.4 ค่าสัมประสิทธิ์ของช่องสัญญาณ BPMR .....	38
ตารางที่ 2.5 เข้าคู่อรหัสมอดูเลชัน 5/6.....	41
ตารางที่ 3.1 รายละเอียดของตัวแปรที่ใช้ในสมการจำลองช่องสัญญาณแบบ BPMR .....	44
ตารางที่ 3.2 รายละเอียดชุดข้อมูลที่เก็บจากช่องสัญญาณการบันทึกรูปแบบ BPMR.....	48
ตารางที่ 3.3 ระดับความสัมพันธ์ของเพียร์สัน.....	50
ตารางที่ 3.4 การแบ่งจำนวนชุดข้อมูล สำหรับฝึกฝนและทดสอบโมเดล.....	51
ตารางที่ 3.5 โมเดลทั้งหมดที่ถูกใช้ในการฝึกฝนโมเดลการทำนายผล สัญญาณอ่านกลับจาก ช่องสัญญาณการบันทึกข้อมูลรูปแบบ BPMR.....	51
ตารางที่ 4.1 การเปรียบเทียบผลลัพธ์ค่าเฉลี่ยจากการวัดประสิทธิภาพการทำนายผล ด้วยค่าความ แม่นยำ (Accuracy) และฟังก์ชันการสูญเสีย (Loss Function) ของแต่ละโมเดล.....	54
ตารางที่ 4.2 ผลลัพธ์การทำนายที่ได้จากคอนฟิวชันเมตริก (Confusion Matrix) .....	55
ตารางที่ 4.3 เปรียบเทียบค่า Precision และ Recall ของแต่ละอัลกอริทึม .....	56

## สารบัญภาพ

หน้า

ภาพที่ 2.1 การจำแนกประเภทของกระบวนการเรียนรู้ของเครื่อง .....	19
ภาพที่ 2.2 ตัวอย่างกระบวนการเรียนรู้ของเครื่องแบบมีผู้ฝึกสอน .....	19
ภาพที่ 2.3 การจับกลุ่มข้อมูลจากข้อมูลเข้าสองมิติ .....	20
ภาพที่ 2.4 แผนภาพกระบวนการเรียนรู้แบบเสริมกำลัง .....	21
ภาพที่ 2.5 การแบ่งชุดข้อมูลของกระบวนการสร้างโมเดลในกระบวนการเรียนรู้ของเครื่อง .....	22
ภาพที่ 2.6 ตัวอย่างปัญหาของ overfitting ที่เกิดในกระบวนการเรียนรู้ของเครื่อง .....	23
ภาพที่ 2.7 ตัวอย่างปัญหาของ underfitting ที่เกิดในกระบวนการเรียนรู้ของเครื่อง .....	24
ภาพที่ 2.8 ความผิดพลาดชนิดที่ 1 และ 2 .....	25
ภาพที่ 2.9 อธิบายการวัดประสิทธิภาพของโมเดล .....	25
ภาพที่ 2.10 ลักษณะของเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวตั้ง .....	27
ภาพที่ 2.11 เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กที่มีความเป็นไปได้ในการใช้งานจริงในอนาคต .....	28
ภาพที่ 2.12 การคาดการณ์ความเป็นไปได้ในการเปลี่ยนแปลงของเทคโนโลยีการบันทึกข้อมูล .....	31
ภาพที่ 2.13 การเปรียบเทียบระหว่าง (a) สื่อบันทึกแบบละเอียด กับ (b) สื่อบันทึกแบบบีตแพทเทิร์นมีเดีย .....	32
ภาพที่ 2.14 แผนภาพบล็อกแบบง่ายสำหรับช่องสัญญาณการอ่านของระบบ BPMPR .....	33
ภาพที่ 2.15 ผลตอบสนองสัญญาณพัลส์เกาส์เซียนในแนวตามแตรีก (เส้นปะ) และในแนวขวางแตรีก (เส้นทึบ) .....	34
ภาพที่ 2.16 การเปรียบเทียบการทำงานของหัวอ่าน (ก) ลักษณะของหัวอ่านที่ทำงานปกติ (ข) ลักษณะของหัวอ่านที่ออกนอกตำแหน่ง .....	36
ภาพที่ 2.17 เปรียบเทียบประสิทธิภาพของระบบที่ได้รับผลกระทบจากที่ TMR แต่ละระดับ .....	37
ภาพที่ 2.18 การเปรียบเทียบการปลูกเซลล์บิตในตำแหน่งที่เหมาะสม (Ideal placement) กับ ตำแหน่งที่ทำให้เกิดผลกระทบ (Effective placement) .....	38
ภาพที่ 2.19 การจำแนกประเภทของลักษณะสัญญาณที่เกิดจากปัญหาการแทรกสอดแบบสองมิติ ..	39
ภาพที่ 2.20 กระบวนการเข้ารหัสมอดูเลชัน 5/6 .....	40
ภาพที่ 2.21 รูปแบบของการเข้ารหัสมอดูเลชัน ณ อัตราส่วนที่ 5/6 .....	42

## สารบัญญภาพ (ต่อ)

หน้า

ภาพที่ 3.1 รูปแบบช่องสัญญาณ BPMR ที่ใช้โมเดลการทำนายผล .....	45
ภาพที่ 3.2 รูปแบบช่องสัญญาณ BPMR ในแบบทั่วไปที่ใช้ อีควอไลเซอร์ และ ตัวตรวจจับ .....	45
ภาพที่ 3.3 การจำลองการทำงานของช่องสัญญาณ BPMR แบบหลายหัวอ่าน .....	46
ภาพที่ 3.4 การเก็บค่าบิตจากแบบจำลองช่องสัญญาณ BPMR แบบหลายหัวอ่าน .....	47
ภาพที่ 3.5 แผนภาพความร้อนความสัมพันธ์ของแต่ละตัวแปร .....	49
ภาพที่ 4.1 การเปรียบเทียบผลลัพธ์ในแต่ละโมเดลในรูปแบบคอนฟิวชันเมตริก (Confusion Matrix) .....	55
ภาพที่ 4.2 การวัดประสิทธิภาพการทำนายผลด้วยอัตราความผิดพลาดของบิตต่อกำลังสัญญาณ ....	57



## คำอธิบายสัญลักษณ์และคำย่อ

สัญลักษณ์	ความหมาย
PW50x	ความกว้างสัญญาณพัลส์ที่หัววงแหวน
PW50z	ความกว้างสัญญาณพัลส์ที่ขั้วแหวน
Tx	ระยะห่างระหว่างบิต
Tz	ระยะห่างระหว่างแทร็ค
C	ค่าคงที่ = $1/2.3548$
Ak	ค่าบิตก่อนเขียนลงสื่อบันทึก
Rk	ค่าบิตที่ได้รับสัญญาณรบกวน
Yk	ค่าบิตที่ได้รับสัญญาณรบกวน
a	ขนาดของไอแลนด์ที่มีลักษณะเปลี่ยนแปลงถี่เหลี่ยมจัตุรัส
$\vartheta$	ความสูงของไอแลนด์
d	ระยะความสูงของหัวอ่าน
g	ระยะช่องว่างระหว่างฉนวนกับตัวตรวจจับฟลักซ์แม่เหล็ก
t	ความกว้างของตัวตรวจจับฟลักซ์แม่เหล็ก
W	ความยาวของตัวตรวจจับฟลักซ์แม่เหล็ก
$\Delta_r$	ระยะที่หัวอ่านเคลื่อนที่ออกจากแทร็ค
$\Delta_z$	ความผันผวนของตำแหน่งบิตในทิศทางขั้วแหวน
$\Delta_x$	ความผันผวนของตำแหน่งบิตในทิศทางตามแทร็ค

## คำอธิบายสัญลักษณ์และคำย่อ (ต่อ)

คำย่อ	ความหมาย
BPMR	Bit patterned media recording
TMR	Track Mis-registration
SNR	Signal-to-noise ratio
BER	Bit error ratio
ITI	Inter track interference
ISI	Inter symbol interference
AC	Accuracy
TP	True Positive
TN	True Negative
FP	False Positive
FN	False Negative



# บทที่ 1

## บทนำ

วิทยานิพนธ์เล่มนี้ถูกจัดทำขึ้นเพื่อต้องการนำเสนอแนวทางใหม่ ๆ ในการทำนายผลของผลลัพธ์ข้อมูลบิตที่ออกจากช่องสัญญาณการอ่านกลับในระบบบันทึกข้อมูลเชิงแม่เหล็กแบบ “บิตแพทเทิร์นมีเดีย” โดยบทนำจะเกริ่นถึงความเป็นมาและความสำคัญของปัญหาที่เกิดขึ้นในระบบการบันทึกข้อมูลแบบเดิม วัตถุประสงค์ของการวิจัย ขอบเขตของการวิจัย ระเบียบวิธีการของการวิจัย และประโยชน์ที่คาดว่าจะได้รับ

### 1.1 ความเป็นมาและความสำคัญของปัญหา

ในปัจจุบันอุตสาหกรรมฮาร์ดดิสก์ในประเทศไทยนั้นได้มีอัตราการส่งออกเป็นอันดับต้น ๆ ของโลกโดยสัดส่วนที่ประเทศไทยได้ส่งออกฮาร์ดดิสก์ราว 243 ล้านชิ้นคิดเป็นสัดส่วน 82% ของการส่งออกฮาร์ดดิสก์ทั้งหมดของโลก หรือคิดเป็นมูลค่าส่งออกราว 12,466 ล้านดอลลาร์ฯ [1] ประเทศไทยยังเป็นฐานการผลิตฮาร์ดดิสก์ของบริษัทฮาร์ดดิสก์อีกด้วย เช่น ซีเกทเทคโนโลยี (Seagate Technology), เวสเทิร์นดิจิทัล (Western Digital), ฮิตาชิ โกลบอล สตอเรจ เทคโนโลยี (Hitachi GST), และโตชิบา สตอเรจ ดีไวท์ (Toshiba SDT) เป็นต้น อุตสาหกรรมฮาร์ดดิสก์เป็นอุตสาหกรรมต่อเนื่องจึงทำให้เกิดอุตสาหกรรมชิ้นส่วนประกอบที่เกี่ยวข้องกับฮาร์ดดิสก์เกิดขึ้นตามไปด้วย โดยก่อให้เกิดการจ้างงานในอุตสาหกรรมฮาร์ดดิสก์เกิดขึ้นเป็นจำนวนมาก ซึ่งทำให้อุตสาหกรรมฮาร์ดดิสก์เป็นอุตสาหกรรมที่สำคัญมาก และยังเป็นอีกหนึ่งอุตสาหกรรมที่สร้างรายได้มหาศาลให้แก่ในประเทศไทย

ในช่วงหลายปีที่ผ่านมาฮาร์ดดิสก์ไดรฟ์นั้นเป็นอุปกรณ์ที่ใช้สำหรับบันทึกข้อมูลในรูปแบบของดิจิทัล (Digital) ที่ได้รับความนิยมในการใช้สำหรับเก็บข้อมูลอย่างแพร่หลายทั้งภาคอุตสาหกรรม และครัวเรือน โดยเฉพาะอย่างยิ่งในปัจจุบันในยุคที่เทคโนโลยีมีความก้าวหน้าไปอย่างรวดเร็วจึงทำให้ข้อมูลประเภทมัลติมีเดีย (Multi-media) ส่วนใหญ่ที่เป็นข้อมูลแบบดิจิทัล เช่น ไฟล์เสียง ไฟล์รูป ไฟล์วิดีโอ และไฟล์เอกสาร จึงทำให้ขนาดของไฟล์ดิจิทัลเหล่านี้มีความละเอียดที่สูงกว่าในอดีตมากส่งผลให้มีความจำเป็นที่จะต้องใช้เวลาในการเก็บข้อมูลที่เพิ่มมากขึ้นตามไปด้วย ซึ่งฮาร์ดดิสก์ไดรฟ์ (HDD: Hard disk drive) เป็นอุปกรณ์ที่ใช้สำหรับจัดเก็บข้อมูลในรูปแบบดิจิทัลที่มีความจุที่สูง และมี

ราคาต่อหน่วยความจุที่ได้รับมีราคาต่ำกว่าเมื่อนำมาเปรียบเทียบกับอุปกรณ์สำหรับจัดเก็บข้อมูลชนิดอื่น ๆ จึงทำให้ฮาร์ดดิสก์ไดรฟ์เป็นตัวเลือกที่ได้รับความนิยมสำหรับนำมาใช้ในการจัดเก็บข้อมูล

สำหรับการบันทึกข้อมูลลงในฮาร์ดดิสก์ไดรฟ์นั้น ได้เริ่มต้นมาจากเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวนอน (LMR: Longitudinal Magnetic Recording) และได้พัฒนาต่อยอดจนมาเป็นเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวตั้ง (PMR: Perpendicular Magnetic Recording) โดยความหนาแน่นเชิงพื้นที่ประมาณ 1 Tbit/in<sup>2</sup> (เทราบิตต่อตารางนิ้ว) [2] และได้ถูกพัฒนาต่อยอดผนวกเข้ากับเทคโนโลยีอื่น ๆ จนมาเป็นการบันทึกมาอีกหลากหลายรูปแบบ แต่ในปัจจุบันเทคโนโลยีนี้ก็เข้าใกล้ “ซูเปอร์พาราแมกเนติก (Superparamagnetic limit)” ซึ่งทำให้เทคโนโลยีนี้ใกล้ถึงขีดจำกัดในการเพิ่มพื้นที่ความจุของฮาร์ดดิสก์ จึงได้มีการคิดค้นรูปแบบของเทคโนโลยีการบันทึกข้อมูลรูปแบบใหม่ที่กำลังจะเข้ามาแทนที่เทคโนโลยีการบันทึกข้อมูลแบบแนวตั้งเดิมที่มีอยู่เช่น เทคโนโลยีการบันทึกเชิงแม่เหล็กแบบการใช้ความร้อนเข้าช่วย (HAMR: Heat-Assisted Magnetic Recording), เทคโนโลยีเชิงแม่เหล็กแบบการใช้ไมโครเวฟเข้าช่วย (MAMR: Microwave-Assisted Magnetic Recording) และเทคโนโลยีการบันทึกเชิงแม่เหล็กแบบบิตแพทเทิร์นมีเดีย (BPMP: Bit-Patterned Media Recording) เป็นต้น โดยเทคโนโลยี บิตแพทเทิร์นมีเดียสามารถเพิ่มความหนาแน่นเชิงพื้นที่ได้ถึง 5 เทราบิตต่อตารางนิ้ว (Tbit/in<sup>2</sup>) ที่สามารถเพิ่มประสิทธิภาพของความหนาแน่นเชิงพื้นที่ได้มากกว่าเทคโนโลยีปัจจุบัน

## 1.2 ปัญหาและแนวทางการแก้ไขปัญหา

เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบบิตแพทเทิร์นมีเดีย หรือ “BPMP” นั้นข้อมูลหนึ่งบิตจะถูกบันทึกลงบนหนึ่งเกรนแม่เหล็ก (Magnetic grain) หรือเรียกอีกอย่างว่า “ไอส์แลนด์ (Island)” โดยแต่ละไอส์แลนด์จะมีขนาดที่ต่ำกว่า 15 นาโนเมตร และถูกแยกแต่ละไอส์แลนด์ด้วยสื่อที่ไม่มีสภาพความเป็นแม่เหล็ก (Non-magnetic) ซึ่งสิ่งที่ท้าทายในการพัฒนาระบบการบันทึกข้อมูลแบบ BPMP เมื่อขนาดของแต่ละไอส์แลนด์นั้น ในความเป็นจริงไม่ได้มีขนาดที่สมมาตรกันทั้งหมด จึงนำไปสู่ปัญหาของหัวอ่าน (Read-head) ที่ทำการอ่านค่าไม่ตรงกับตำแหน่งจึงทำให้เกิดการอ่านข้อมูลที่ผิดเพี้ยนไปจากเดิม [3] และการที่ไอส์แลนด์มีขนาดที่เล็กส่งผลให้เกิดสัญญาณรบกวนจากข้อมูลบิตรอบข้างมีความรุนแรง ซึ่งผลกระทบจากปัจจัยเหล่านี้เป็นปัญหาที่เกิดขึ้นในระบบการบันทึกข้อมูลแบบ BPMP ส่งผลต่อสมรรถนะโดยรวมของระบบให้ด้อยประสิทธิภาพลง จึงนำไปสู่การแก้ไขปัญหเหล่านี้ ในปัจจุบันเทคโนโลยีที่เข้ามามีบทบาทสำคัญอย่างปัญญาประดิษฐ์ (AI: Artificial intelligence) หรือแม้กระทั่งการใช้กระบวนการเรียนรู้ของเครื่อง (ML: Machine learning) เข้ามา

ช่วยในการแก้ไขปัญหาทางด้านต่าง ๆ ในบริบทที่หลากหลายกันอย่างแพร่หลาย และให้ผลลัพธ์เป็นที่น่าพึงพอใจ ดังนั้นการนำเอาเทคโนโลยีเหล่านี้มาประยุกต์ใช้กับปัญหาที่เกิดขึ้นในระบบการบันทึกข้อมูลเชิงแม่เหล็กจึงเป็นอีกหนึ่งตัวเลือกที่มีความน่าสนใจเป็นอย่างมาก

ปัจจุบันเทคโนโลยีการวิเคราะห์ข้อมูลด้วยคอมพิวเตอร์ได้เข้ามามีบทบาทอย่างมากในแง่ของการวางแผนและการสนับสนุนการตัดสินใจให้แม่นยำ และมีความถูกต้องมากยิ่งขึ้น ผู้วิจัยจึงนำเสนอแนวคิดในการนำกระบวนการ และเทคโนโลยีการวิเคราะห์ข้อมูลเข้ามาใช้ในการสร้างแบบจำลองเพื่อใช้ในการทำนายค่าบิตของข้อมูลที่ได้จากหัวอ่านในระบบการบันทึกข้อมูลแบบ BPMPR เพื่อลดผลกระทบที่เกิดจากสัญญาณอ่านกลับที่ผิดเพี้ยนโดยไม่ทำการฟิงพาอ์ควอลไลเซอร์ (Equalizer) และตัวตรวจจับ (Detector) งานวิจัยนี้ผู้วิจัยได้นำเสนอสิ่งที่ท้าทายไว้สองส่วน คือ การหารูปแบบโครงสร้างข้อมูลที่เหมาะสมต่อการเรียนรู้ของเครื่องจักร และ การสร้างแบบจำลองในการทำนายข้อมูลจากโครงสร้างที่กำหนดโดยใช้เทคนิคการเรียนรู้ของเครื่องจักรที่ครอบคลุมการทำนายผลในระดับของกำลังสัญญาณหลายระดับ

ดังนั้นวิทยานิพนธ์นี้จึงมุ่งเน้นในการออกแบบโมเดลสำหรับการทำนายผลค่าบิตจากการประยุกต์ใช้ความรู้ทางด้านวิทยาศาสตร์ข้อมูล (Data-science) โดยใช้กระบวนการเรียนรู้ของเครื่อง (Machine learning) มาใช้ในการวิเคราะห์ และออกแบบโมเดลการจำแนกประเภท (Classification) เพื่อใช้ในการทำนายผลข้อมูลบิตที่ถูกลดทอนสมรรถนะจากสัญญาณรบกวน เพื่อช่วยในการตัดสินใจ และ ลดผลกระทบที่เกิดจากสัญญาณอ่านกลับที่ผิดเพี้ยนที่ทำให้ระบบ BPMPR ด้อยประสิทธิภาพลง

### 1.3 ความมุ่งหมายและจุดประสงค์ของงานวิจัย

1.3.1 เพื่อศึกษาการทำงานของเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบ BPMPR

1.3.2 เพื่อศึกษาผลกระทบที่เกิดจากสัญญาณรบกวนที่ส่งผลต่อการอ่านข้อมูลที่ผิดพลาด

1.3.3 เพื่อศึกษากระบวนการทำงานของเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบ BPMPR

1.3.4 เพื่อประยุกต์ใช้ความรู้ทางด้านวิทยาศาสตร์ข้อมูลในเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็ก

1.3.5 นำเสนอวิธีการนำโมเดลมาใช้ในการทำนายผลข้อมูลในช่องสัญญาณ BPMPR

### 1.4 ขอบเขตของงานวิจัย

1.4.1 ศึกษาและสร้างแบบจำลองการทำงานของสัญญาณการบันทึกข้อมูลรูปแบบ BPMPR

1.4.2 ศึกษาและสร้างแบบจำลองการทำงานของสัญญาณการบันทึกข้อมูลรูปแบบ BPMPR ที่ได้รับการรบกวนจากสัญญาณรบกวน และการแทรกสอดของสัญญาณ

1.4.3 การสำรวจข้อมูลเบื้องต้นที่ได้จากการจำลองในข้อ 1.4.2 และการแปลงข้อมูลให้อยู่ในรูปแบบที่มีโครงสร้างเหมาะสม สามารถนำไปประมวลผลด้วยเทคนิคการเรียนรู้ของเครื่องได้

1.4.4 การสร้างแบบจำลองเพื่อการทำนายโดยอาศัยเทคนิคการเรียนรู้ของเครื่อง

1.4.5 การประเมินประสิทธิภาพของความแม่นยำและความถูกต้องของวิธีการที่นำเสนอ

## 1.5 วิธีการวิจัย

### 1.5.1 ขั้นตอนการวิจัย

1.1.1.1 สร้างแบบจำลองของช่องสัญญาณการบันทึกแบบ BPMPR ที่มีการเข้ารหัสข้อมูลด้วยวิธีการมอดูเลชันโค้ดที่ 5/6

1.1.1.2 สร้างแบบจำลองของช่องสัญญาณการบันทึกแบบ BPMPR ที่ได้รับผลกระทบจากการแทรกสอดแบบสองมิติ, การอ่านไม่ตรงตำแหน่ง และความผันผวนของตำแหน่งไอแลนด์

1.1.1.3 ทำการเก็บข้อมูลจากช่องสัญญาณการบันทึกแบบ BPMPR และจัดการข้อมูลให้พร้อมใช้สำหรับการฝึกฝนโมเดล

1.1.1.4 สร้างแบบจำลองโมเดลการทำนายผลข้อมูลบิตที่ออกจากช่อง จากชุดข้อมูล

1.1.1.5 เปรียบเทียบประสิทธิภาพโมเดลการทำนายผล ในรูปแบบของคอนฟิวชันเมตริก (Confusion Matrix) และอัตราความผิดพลาดของข้อมูล (BER: bit error ratio)

### 1.5.2 เครื่องมือและวัสดุที่ใช้

1.1.1.6 คอมพิวเตอร์

1.1.1.7 โปรแกรม MATLAB

1.1.1.8 โปรแกรมภาษาซี

1.1.1.9 โปรแกรมภาษา python

1.1.1.10 โปรแกรม anaconda

## 1.6 ข้อจำกัดของงานวิจัย

วิทยานิพนธ์เล่มนี้มุ่งเน้นไปในทางการใช้แบบจำลองทางคณิตศาสตร์ในการจำลองการทำงานของฮาร์ดดิสก์ไดรฟ์ที่มีช่องสัญญาณการบันทึกแบบบิตแพทเทิร์นมีเดีย (BPMR) ด้วยโปรแกรมคอมพิวเตอร์ MATLAB เพื่อทำการเก็บข้อมูลกลุ่มตัวอย่าง เนื่องจากการพัฒนาช่องสัญญาณ BPMR ในระดับฮาร์ดแวร์จริงเป็นไปได้ยากในหลายปัจจัย และทำการสร้างชุดโมเดลการทำนายผลช่องสัญญาณอ่านกลับที่นำมาใช้แทนที่ระบบแบบเดิม


## 1.7 ประโยชน์ที่คาดว่าจะได้รับ

1.7.1 สามารถนำไปประยุกต์ใช้ในช่องสัญญาณการบันทึกข้อมูลในรูปแบบ BPMR

1.7.2 ได้โมเดลการทำนายผลข้อมูลที่มีประสิทธิภาพ

1.7.3 เพื่อเป็นแนวทางสำหรับการประยุกต์ใช้กระบวนการเรียนรู้เครื่องกับระบบการบันทึกข้อมูลในรูปแบบ BPMR

1.7.4 เพื่อเป็นแนวทางในการพัฒนาโมเดลในการทำนายผลเพื่อรองรับกับเทคโนโลยี BPMR หรือการนำมาประยุกต์ใช้ในด้านอื่น ๆ



## บทที่ 2


### ทฤษฎีและงานวิจัยที่เกี่ยวข้อง

ในบทนี้จะกล่าวถึงวรรณกรรมที่เกี่ยวข้องกับงานวิจัย (Literature Review) และทฤษฎีที่เกี่ยวข้องกับวิทยานิพนธ์เล่มนี้ เพื่อเป็นการศึกษารายละเอียดของงานวิจัยที่เกี่ยวข้องกับการทำนายผลสัญญาณอ่านกลับจากการใช้วิธีการกระบวนการเรียนรู้ของเครื่อง และระบบการบันทึกข้อมูลเชิงแม่เหล็กรูปแบบ BPMPR โดยแต่ละหัวข้อมีรายละเอียดดังต่อไปนี้

#### 2.1 กระบวนการเรียนรู้ของเครื่อง


การเรียนรู้ของเครื่องพัฒนามาจากการศึกษาการรู้จำรูปแบบเกี่ยวกับการศึกษาและการสร้างอัลกอริทึมที่สามารถเรียนรู้ข้อมูลและคาดคะเนผลลัพธ์ของข้อมูลได้ อัลกอริทึมนั้นจะทำงานโดยอาศัยโมเดลที่สร้างมาจากชุดข้อมูลกลุ่มตัวอย่างขาเข้าเพื่อการทำนายหรือตัดสินใจในภายหลัง แทนที่จะทำงานตามลำดับเหมือนคำสั่งโปรแกรมคอมพิวเตอร์ กระบวนการเรียนรู้ของเครื่องมีความเกี่ยวข้องอย่างมากกับความรู้ทางสถิติศาสตร์ เนื่องจากทั้งสองสาขาศึกษาการและวิเคราะห์ข้อมูลเพื่อการทำนายเช่นเดียวกัน นอกจากนี้ยังมีความสัมพันธ์กับสาขาการหาค่าเหมาะสมที่สุดในทางคณิตศาสตร์ที่แง่ของวิธีการทางทฤษฎี และการประยุกต์ใช้ การเรียนรู้ของเครื่องสามารถนำไปประยุกต์ใช้งานได้หลากหลายในบริบทที่ต่างกัน ไม่ว่าจะเป็นการกรองอีเมลขยะ, การรู้จำตัวอักษร, เครื่องมือค้นหา, และคอมพิวเตอร์วิทัศน์ อาเธอร์ ซามูเอล นักวิทยาศาสตร์คอมพิวเตอร์ชาวอเมริกัน ได้ให้นิยามของการเรียนรู้ของเครื่องจักรไว้ในปี ค.ศ. 1959 ว่า "เป็นสาขาที่ให้คอมพิวเตอร์มีความสามารถในการเรียนรู้โดยไม่ต้องโปรแกรมให้ชัดเจน" [4]

ในปัจจุบันกระบวนการเรียนรู้ของเครื่องเป็นปัจจัยแห่งความสำเร็จในระบบดิจิทัลมาอย่างต่อเนื่อง จากการจำลองวิธีการเรียนรู้และวิธีคิดของมนุษย์ ทำให้คอมพิวเตอร์สามารถมีกระบวนการแก้ไขปัญหาได้อย่างประสิทธิภาพจนสามารถที่จะแก้ปัญหาที่มีความซับซ้อนได้ ปัจจุบันสามารถแบ่งประเภทของกระบวนการเรียนรู้ของเครื่องออกได้เป็น 3 ประเภท อันได้แก่ การเรียนรู้แบบมีผู้สอน, การเรียนรู้แบบไม่มีผู้สอน และการเรียนรู้แบบเสริมกำลัง [5]



ภาพที่ 2.1 การจำแนกประเภทของกระบวนการเรียนรู้ของเครื่อง

2.1.1 การเรียนรู้แบบมีผู้สอน (Supervised learning) เป็นกระบวนการเรียนรู้โดยใช้การฝึกฝนที่ประกอบไปด้วยชุดข้อมูลที่ประกอบไปด้วยข้อมูลกลุ่มตัวอย่าง และผลลัพธ์ที่ถูกต้องสำหรับใช้เป็นผลเฉลยในการเรียนรู้ เหมือนกับการให้โจทย์ปัญหาและวิธีการแก้ปัญหาให้นักเรียนและบอกให้นักเรียนหาคำตอบ




ภาพที่ 2.2 ตัวอย่างกระบวนการเรียนรู้ของเครื่องแบบมีผู้ฝึกสอน [6]

จากภาพที่ 2.2 ตัวอย่างกระบวนการเรียนรู้ของเครื่องแบบมีผู้ฝึกสอน “การมีผู้สอน” ในที่นี้หมายความว่า ในข้อมูลที่ใช้ฝึก (Training data) เราจะมีมนุษย์มาคอยแยกประเภทหรือบอกผลลัพธ์

(Label) ที่ควรจะเป็นไปได้ไว้ด้วย จากนั้นเราจะนำข้อมูลที่ใช้ฝึกฝนที่มีผลลัพธ์ ไปผ่านอัลกอริทึมสำหรับสร้างโมเดลที่ไว้ทำนายผลลัพธ์ เมื่อได้โมเดลสำหรับทำนายผลแล้วกระบวนการต่อไปจะทำการนำเข้าข้อมูลใหม่ที่เครื่องไม่เคยเห็นมาก่อนเพื่อทดสอบสมรรถนะของโมเดล โดยสามารถแบ่งประเภทออกได้ตามอัลกอริทึมได้ 2 ประเภทได้แก่ ประเภทการจัดหมวดหมู่ (Classification) และประเภทการถดถอย (Regression)

2.1.2 การเรียนรู้แบบไม่มีผู้สอน (Unsupervised learning) เป็นการเรียนรู้โดยที่ไม่ได้รับการดูแลหรือบอกวิธีคิดในการหาคำตอบให้กับคอมพิวเตอร์ แต่คอมพิวเตอร์จะรู้ว่าคอมพิวเตอร์คำตอบที่ถูกต้องคืออะไร โดยการเรียนรู้ในรูปแบบนี้คอมพิวเตอร์มีหน้าที่ในการหาวิธีแก้ปัญหาด้วยตัวเอง เหมือนกับการยกโจทย์ปัญหาให้นักเรียนได้ที่ไม่มีการสอนวิธีการแก้โจทย์ปัญหานั้นให้นักเรียน แต่ให้นักเรียนทำการหาวิธีแก้โจทย์ปัญหาเอง การเรียนรู้แบบนี้เราจะมีคำตอบของผลลัพธ์ที่ไม่แน่ชัด แต่จุดประสงค์ของการเรียนรู้ประเภทนี้ มักต้องการตามหาโครงสร้างของข้อมูลที่เราไม่รู้จัก (Unknown Structure) โดยสามารถแบ่งประเภทออกได้ตามอัลกอริทึมได้ 2 ประเภทได้แก่ การจับกลุ่ม (Clustering) และการลดมิติ (Dimension reduction)




ภาพที่ 2.3 การจับกลุ่มข้อมูลจากข้อมูลเข้าสองมิติ [5]

2.1.3 การเรียนรู้แบบเสริมกำลัง (Reinforcement learning) เป็นการเรียนรู้โดยคอมพิวเตอร์ที่สามารถปฏิสัมพันธ์กับสิ่งแวดล้อมที่เปลี่ยนไปตลอดเวลา โดยคอมพิวเตอร์จะต้องทำงานหรือปฏิบัติงานบางอย่าง เช่น การขับรถ โดยที่ไม่มี "ผู้สอน" คอยบอกอย่างจริงจังว่าวิธีการที่ทำอยู่นั้นถูกหรือผิด ดังภาพที่ 2.4 แผนภาพกระบวนการเรียนรู้แบบเสริมกำลัง เป้าหมายคือการ



พัฒนาตัวผู้กระทำ (Agent) ที่สามารถปรับปรุงประสิทธิภาพตามการปฏิสัมพันธ์กับสภาพแวดล้อม (Environment) โดยรับการเรียนรู้ตามสถานการณ์ (State) และเลือกการกระทำ (Action) บางอย่าง ที่ส่งผลต่อ environment โดยจะวัดประสิทธิภาพของผลลัพธ์ของการกระทำด้วยรางวัล (Reward) ที่ดีที่สุด ผ่านเรียนรู้จากความพยายามและข้อผิดพลาดที่เรียกว่า “trial-and-error” [7]



ภาพที่ 2.4 แผนภาพกระบวนการเรียนรู้แบบเสริมกำลัง [6]

## 2.2 การจำแนกประเภท (Classification)

การจำแนกประเภท คือกระบวนการในการทำนายผลคลาสที่ถูกกำหนดจากชุดของข้อมูลกลุ่มตัวอย่าง โดยที่คลาสนั้นรู้จักกันในชื่อ เป้าหมาย (Targets), ฉลาก (Labels), หรือ หมวดหมู่ (Categories) การจำแนกประเภทเป็นการสร้างแบบจำลองโดย กำหนดให้งานการประมาณฟังก์ชันของ  $f$  จากตัวแปรอินพุตของ  $x$  ไปยังตัวแปรเอาต์พุตแบบไม่ต่อเนื่องของ  $y$  การจำแนกประเภทจัดอยู่ในกลุ่มของการเรียนรู้แบบมีผู้สอน [8] โดยที่การจำแนกประเภทนั้นสามารถแบ่งออกได้เป็น 2 รูปแบบจากลักษณะในการเรียนรู้ได้แก่ การเรียนรู้แบบชี้เก็ย และการเรียนรู้แบบกระตือรือร้น

การเรียนรู้แบบชี้เก็ย เป็นการจัดเก็บชุดข้อมูลฝึกฝนและรอจนกว่าชุดข้อมูลทดสอบปรากฏขึ้น กล่าวคือการจำแนกประเภทในลักษณะนี้จะอาศัยข้อมูลที่มีความเกี่ยวข้องกันมากที่สุด หรือมีความสัมพันธ์ซึ่งกันและกัน หากนำมาเปรียบเทียบกับการเรียนรู้แบบกระตือรือร้นแล้ว การเรียนรู้แบบชี้เก็ยมักจะใช้เวลาในการเรียนรู้ต่ำกว่า แต่จะใช้เวลาในการทำนายผลมาก โมเดลที่อยู่ในประเภทนี้ได้แก่ k-nearest neighbor และ Case-based reasoning เป็นต้น


การเรียนรู้แบบกระตือรือร้น เป็นการสร้างแบบจำลองโมเดลการจำแนกประเภทโดยอาศัยชุดข้อมูลการฝึกฝน ก่อนที่จะรับข้อมูลสำหรับการนำมาทำนายผล โดยการเรียนรู้แบบกระตือรือร้นนั้น

มักจะใช้เวลาในการฝึกฝนมาก แต่ใช้เวลาการทำนายผลที่น้อย โมเดลที่อยู่ในประเภทนี้ได้แก่ Decision tree, Naive bayes และ Artificial neural networks เป็นต้น

โดยทั่วไปนั้นมีการจำแนกประเภทจะแบ่งประเภทได้ 4 ประเภทได้แก่

- Binary classification
- Multi-Class classification
- Multi-Label classification
- Imbalanced classification

### 2.3 การแบ่งชุดข้อมูล



ภาพที่ 2.5 การแบ่งชุดข้อมูลของกระบวนการสร้างโมเดลในกระบวนการเรียนรู้ของเครื่อง

ในกระบวนการเรียนรู้ของเครื่องนั้น โดยทั่วไปนั้นจะทำการสร้างโมเดลจากการเรียนรู้และคาดการณ์ผลลัพธ์จากการใช้ชุดข้อมูลที่ทำกรเรียนรู้ การที่โมเดลสามารถทำงานได้อย่างมีประสิทธิภาพกับข้อมูลที่ไม่เคยเห็นมาก่อนที่เรียกว่า “Generalization” นั้นเป็นสิ่งที่สำคัญเป็นอย่างมาก หากโมเดลนั้นสามารถทำงานได้เฉพาะกับข้อมูลที่เคยเห็นมาแล้วเพียงอย่างเดียว จะทำให้โมเดลนั้นสามารถหาผลลัพธ์ได้เพียงสิ่งที่โมเดลเคยเรียนรู้มาแล้วเท่านั้น ไม่สามารถหาผลลัพธ์ที่แตกต่างเพียงเล็กน้อยได้เมื่อนำมาใช้งานจริง [9]

ดังนั้นวิธีการที่ใช้ในกระบวนการสร้างแบบจำลองการทำนายผล มักจะทำการแบ่งชุดข้อมูลออกตามกระบวนการได้แก่ ชุดข้อมูลการฝึกฝน, ชุดข้อมูลการตรวจสอบ, และชุดข้อมูลทดสอบ


2.3.1 ชุดข้อมูลการฝึกฝน (Training Set) ชุดข้อมูลตัวอย่างที่ที่ใช้ในการเรียนรู้ และฝึกฝนแบบจำลอง

2.3.2 ชุดข้อมูลการตรวจสอบ (Validation Set) ชุดข้อมูลที่ใช้สำหรับการประเมินแบบจำลองที่เป็นกลางบนชุดข้อมูลการฝึกฝน เพื่อปรับไฮเปอร์พารามิเตอร์ของโมเดลให้มีความเหมาะสม

2.3.3 ชุดข้อมูลทดสอบ (Test Set) ชุดข้อมูลตัวอย่างเพื่อใช้ในการประเมินแบบจำลองในขั้นตอนสุดท้ายของการทดสอบประสิทธิภาพการทำงานของแบบจำลอง

## 2.4 โอเวอร์ฟิตติ้ง (Overfitting)

โอเวอร์ฟิตติ้งในทางสถิติ หมายถึงการวิเคราะห์ที่ใดที่ผูกติดกับข้อมูลที่มาจกจนเกินไป การวิเคราะห์นั้นจะไม่สามารถไปทำนายผลข้อมูลนอกเหนือจากนั้น หรือในอนาคตได้ [10] ซึ่งในทางกระบวนการเรียนรู้ของเครื่องนั้นเป็นข้อผิดพลาดของแบบจำลองที่เกิดขึ้นเมื่อฟังก์ชันที่ผูกติดกับชุดข้อมูลมากจนเกินไป โดยทั่วไปแล้วโอเวอร์ฟิตติ้งมักจะเกิดจากการที่ใส่พารามิเตอร์หรือปัจจัยที่ไม่มีความสัมพันธ์กันเข้ามาจนเกินไป ทำให้โมเดลมีความซับซ้อนเกินไปและเกิดโอเวอร์ฟิตติ้ง

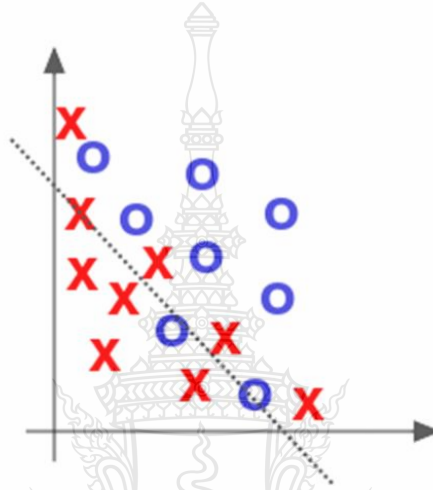


ภาพที่ 2.6 ตัวอย่างปัญหาของ overfitting ที่เกิดในกระบวนการเรียนรู้ของเครื่อง

จากภาพที่ 2.6 ตัวอย่างปัญหาของ overfitting ที่เกิดในกระบวนการเรียนรู้ของเครื่อง แสดงให้เห็นว่า เส้นสีโค้งสีดำคือการที่แบบจำลองทำงานได้อย่างเหมาะสม มีการใช้เส้นโค้งพาราโบลาในการแบ่งกลุ่มข้อมูล ถึงแม้จะมีการแบ่งผิดอยู่บ้าง แต่ก็ไม่เกิดโอเวอร์ฟิตติ้งหรืออันเดอร์ฟิตติ้ง ในขณะที่เส้นสีเขียวแสดงถึงการเกิดอันเดอร์ฟิตติ้ง เกิดจากโมเดลพยายามมากเกินไปที่จะแบ่งข้อมูลทดสอบให้ดี โดยการใส่เพิ่มพารามิเตอร์ เช่น degree of freedom มากเกินไป ทำให้โมเดลจะทำงานได้ดีเฉพาะกับข้อมูล training (in-sample) เท่านั้น แต่ถ้าทำการทดสอบกับข้อมูล testing (out-sample) โมเดลก็จะทำงานแย่มากในทันที

## 2.5 อันเดอร์ฟิตติ้ง (Underfitting)

อันเดอร์ฟิตติ้งนั้นมีความหมายที่ตรงกันข้ามกับโอเวอร์ฟิตติ้ง โดยอันเดอร์ฟิตติ้งนั้นจะเกิดขึ้นเมื่อโมเดลมีการเรียนรู้ที่ง่ายเกินไปทำให้การเรียนรู้โครงสร้างพื้นฐานของชุดข้อมูลที่นำมาฝึกฝนได้ไม่ดีมากพอ กล่าวคือแบบจำลองที่สร้างขึ้นไม่เหมาะสมกับความเป็นจริง เนื่องจากผลลัพธ์ในความเป็นจริงมีความซับซ้อนกว่ามาก ดังนั้นการทำนายผลจึงไม่มีความถูกต้อง แม้แต่ในการฝึกฝนก็ตาม



ภาพที่ 2.7 ตัวอย่างปัญหาของ underfitting ที่เกิดในกระบวนการเรียนรู้ของเครื่อง

จากภาพที่ 2.7 ตัวอย่างปัญหาของ underfitting ที่เกิดในกระบวนการเรียนรู้ของเครื่อง แสดงให้เห็นว่า ในการแบ่งข้อมูลนั้นเรียบง่ายและตรงไปตรงมา ในขณะที่รูปแบบของข้อมูลมีความซับซ้อนเกินกว่าที่จะสามารถแบ่งได้ด้วยเส้นตรงได้ จึงทำให้ผลลัพธ์ในการแบ่งข้อมูลทำได้แย่


## 2.6 การวัดประสิทธิภาพ

การวัดประสิทธิภาพนั้นเป็นการทดสอบโมเดลที่สร้างขึ้น มีความพร้อมในการใช้งานมากน้อยเพียงใด โดยเป็นตัวบ่งบอกว่าโมเดลที่สร้างขึ้นนั้นมีความแม่นยำเพียงใด ซึ่งในงานวิจัยชิ้นนี้โมเดลการทำนายผลที่ผู้วิจัยสร้างขึ้นนั้น จัดอยู่ในกลุ่มของโมเดลประเภทของการจำแนกประเภทแบบไบนารี (Binary Classification) ในทางกระบวนการเรียนรู้ของเครื่องนั้นการประเมินประสิทธิภาพของโมเดลเหล่านี้ สิ่งที่ใช้กันอย่างแพร่หลายจะถูกอธิบายด้วยหลักการค่าทางคณิตศาสตร์เหล่านี้

ความผิดพลาดชนิดที่ 1 และ 2 (Type 1 & Type 2 Error) ในทางสถิติเป็นการตัดสินใจที่มีความเกี่ยวพันกับความไม่แน่นอน ดังนั้นความเสี่ยงที่อาจจะเกิดขึ้นจึงไม่สามารถหลีกเลี่ยงไม่ได้ จึงจำเป็นต้องทดสอบสมมุติฐาน [11] ซึ่งความหมายของความผิดพลาดทั้งสองชนิดสามารถนิยามได้ดังต่อไปนี้

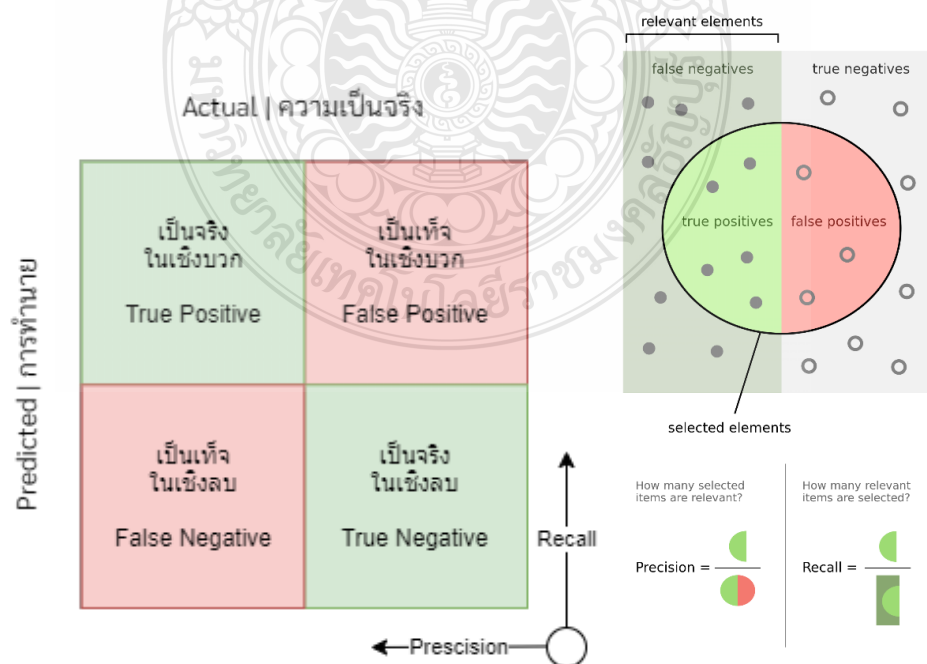
ความผิดพลาดชนิดที่ 1 (false positive) คือการที่ผู้วิจัยสรุปผิดโดยปฏิเสธสมมติฐานว่างทั้งที่แท้แล้วเป็นจริง กล่าวคือ “บอกว่ามี ความแตกต่างโดยที่ความแตกต่างไม่มีอยู่จริง”

ความผิดพลาดชนิดที่ 2 (false negative) คือการที่ผู้วิจัยไม่ได้ปฏิเสธสมมติฐานว่างที่ไม่เป็นจริง กล่าวคือ (บอกว่าจะไม่มี ความแตกต่างโดยที่ความแตกต่างนั้น มีอยู่จริง)



ภาพที่ 2.8 ความผิดพลาดชนิดที่ 1 และ 2

จากภาพที่ 2.8 ความผิดพลาดชนิดที่ 1 และ 2 นั้นแสดงให้เห็นว่าการเลือกช่วงความเชื่อมั่นนั้น มีอิทธิพลซึ่งกันและกัน โดยส่งผลต่อความน่าจะเป็นของชนิดของความผิดพลาดที่เกิดขึ้นเมื่อพยายามที่จะลดข้อผิดพลาดด้านใดด้านหนึ่งจะส่งผลให้อีกด้านหนึ่งเพิ่มขึ้น



ภาพที่ 2.9 อธิบายการวัดประสิทธิภาพของโมเดล

คอนฟิวชันเมตริก (Confusion matrix) เป็นการเมตริกสำหรับแสดงข้อเท็จจริง และผลลัพธ์ที่ถูกทำนายในแต่ละป้ายกำกับ (Labels) จากการจำแนกประเภท จากภาพที่ 2.9 อธิบายการวัดประสิทธิภาพของโมเดลในเมตริกแสดงถึงผลลัพธ์การทดสอบแบบไบนารี โดยในแต่ละแถวของเมตริกจะแสดงถึงความเป็นจริงของคลาส ในขณะที่แต่ละคอลัมน์จะแสดงถึงคลาสที่โมเดลทำนาย [12] คอนฟิวชันเมตริกจะประกอบไปด้วย

- True Positive (TP) หมายถึง โมเดลทำนายกรณีที่เป็นจริงได้ถูกต้อง
- True Negative (TN) หมายถึง โมเดลทำนายกรณีที่เป็นเท็จได้ถูกต้อง
- False Position (FP) หมายถึง โมเดลทำนายกรณีที่เป็นจริงแต่เป้าหมายเป็นเท็จ
- False Negative (FN) หมายถึง โมเดลทำนายกรณีที่เป็นเท็จแต่เป้าหมายเป็นจริง

ความแม่นยำ (Accuracy) นั้นเป็นตัวชี้วัดประสิทธิภาพของโมเดลในการประเมินแบบจำลองโมเดล ซึ่งการหาค่าความแม่นยำสามารถคำนวณได้จากการทำนายผลข้อมูลที่ถูกต้องการด้วยจำนวนจากชุดข้อมูลทั้งหมด ดังตัวอย่างของสมการที่ 1

$$AC = \frac{TP+TN}{N} = \frac{TP+TN}{TP+TN+FP+FN}, (1)$$

precision และ recall โดยค่าทั้งสองนี้มักถูกใช้คู่กันในการวัดประสิทธิภาพของโมเดลโดย Precision เป็นการนับความถูกต้องของการทำนายผลที่เป็นจริงในเชิงบวก (TP: True Positive) จากการทำนายที่เป็นจริงทั้งหมด (T: True) และ recall เป็นความน่าจะเป็นที่โมเดลสามารถตรวจจับความถูกต้องในข้อมูลทั้งหมด โดยค่า precision และ recall นั้นมักจะถูกรายงานออกมาด้วยกันโดยเราจะเรียกการผสมกันระหว่างค่า precision และ recall จะได้คือที่เรียกว่า F-score


$$Precision = \frac{TP}{TP+FP}, (2)$$

$$Recall = \frac{TP}{TP+FN}, (3)$$



## 2.7 ระบบการบันทึกข้อมูลเชิงแม่เหล็ก

อุปกรณ์บันทึกข้อมูลเชิงแม่เหล็กหรือที่รู้จักกันในชื่อการบันทึกข้อมูลลงบนฮาร์ดดิสก์ไดรฟ์ในปัจจุบันรูปแบบของเทคโนโลยีถูกใช้ในฮาร์ดดิสก์ไดรฟ์ทั่วไปนั้น เป็นการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวตั้ง (PMR: Perpendicular Magnetic Recording) ที่เป็นเทคโนโลยีที่พัฒนาต่อออกมาจากเทคโนโลยีการบันทึกเชิงแม่เหล็กแบบแนวนอน (LMR: Longitudinal Magnetic Recording) ซึ่งการทำงานของระบบการบันทึกข้อมูลแบบแนวตั้งนั้น จะทำการเขียนข้อมูลลงบนสื่อที่ใช้บันทึกในทิศทางของหัวแม่เหล็กที่จะอยู่ในลักษณะตั้งฉากกับสื่อที่ใช้บันทึก ดังที่แสดงในภาพที่ 2.10 ลักษณะของเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวตั้ง




ภาพที่ 2.10 ลักษณะของเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวตั้ง

ซึ่งโดยทั่วไปนั้นเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวตั้งนั้นมีความหนาแน่นเชิงพื้นที่ (Areal density) สูงสุดที่ประมาณ  $612 \text{ Gbit/in}^2$  ซึ่งการทำให้ความหนาแน่นเชิงพื้นที่นั้นเพิ่มมากขึ้นสามารถทำได้โดยการลดขนาดของเกรนแม่เหล็ก (Magnetic grain) หรือลดจำนวนแม่เหล็กในการบันทึกข้อมูล 1 บิต ให้มีขนาดที่เล็กลง (ณ ความหนาแน่นเชิงพื้นที่เท่ากับ  $250 \text{ Gbit/in}^2$  โดยใช้เกรนแม่เหล็กโดยประมาณ 65 เกรนต่อการบันทึกข้อมูลใน 1 บิต) [13] การลดขนาดเกรนแม่เหล็กนั้นจะส่งผลโดยตรงกับค่าอัตราส่วนของกำลังสัญญาณต่อกำลังสัญญาณรบกวน (SNR: Signal-to-noise ratio) มีค่าที่ลดลงและส่งผลให้อัตราการผิดพลาดของค่าบิต (BER: Bit-Error rate) ที่ได้จาก

ช่องสัญญาณการอ่านกลับเพิ่มขึ้น ดังนั้นหากต้องการลดข้อผิดพลาดจาก BER สามารถทำได้โดยการลดระยะห่างของหัวอ่านกับสื่อบันทึก ซึ่งทำได้ยากโดยในปัจจุบันระยะห่างนี้อยู่ในระดับนาโนเมตรแล้ว

โดยเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบแนวตั้ง ในปัจจุบันประสบกับปัญหาข้อจำกัดทางการเพิ่มความหนาแน่นเชิงพื้นที่ เนื่องจากความไม่เสถียรเชิงอุณหภูมิจนของสื่อบันทึกข้อมูล ซึ่งปรากฏการณ์นี้เรียกว่า “ขีดจำกัดทางซูเปอร์พาราแมกเนติก (Superparamagnetic limit)” ในทางปฏิบัติการเพิ่มความหนาแน่นเชิงพื้นที่ของเทคโนโลยีการบันทึกข้อมูลแบบแนวตั้ง นั้นนอกจากการลดขนาดหรือการลดจำนวนของเกรนแม่เหล็กแล้ว ที่สำคัญควรคำนึงถึงความเสถียรของอุณหภูมิของสื่อที่ใช้ในการบันทึกด้วย



ภาพที่ 2.11 เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบที่มีความเป็นไปได้ในการใช้งานจริงในอนาคต

เนื่องด้วยปัญหาเหล่านี้จึงทำให้เหล่านักวิจัยคิดค้นเทคโนโลยีรูปแบบใหม่สำหรับการบันทึกข้อมูล เพื่อเพิ่มประสิทธิภาพของฮาร์ดดิสก์ไดรฟ์ให้ดียิ่งขึ้น จากภาพที่ 2.11 เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบที่มีการคิดค้นไว้ 4 เทคโนโลยีด้วยกันที่มีข้อดีและข้อด้อยที่แตกต่างกัน [2] อันได้แก่



2.7.1 เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบบิตแพทเทิร์นมีเดีย (BPMP: Bit Patterned Magnetic Recording) เป็นการจัดเก็บข้อมูลทุกหนึ่งบิตจะถูกบันทึกลงไปยังสื่อที่เป็นแม่เหล็กขนาดเล็กที่เรียกว่า “ไอแลนด์” ที่มีขนาดเล็กได้ถึง 10 นาโนเมตรที่ทำการปลูกลงไปยังแผ่นแม่เหล็กอย่างมีระเบียบ และทำการขึ้นแต่ละไอแลนด์ด้วยสื่อที่ไม่มีสภาพความเป็นแม่เหล็ก ทำให้สามารถบันทึกข้อมูลบิตได้มากกว่าแบบแนวตั้งที่ใช้อยู่ในทั่วไปหลายเท่า แต่เทคโนโลยีนี้ยังต้องเผชิญกับปัญหาการแทรกสอดรุนแรง เนื่องจากขนาดของไอแลนด์ยิ่งที่มีขนาดเล็กและเรียงตัวกันอย่างหนาแน่นมากเท่าไร จะทำให้ข้อมูลบิตมีความแออัดจนทำให้สามารถเกิดการรบกวนกันเองของสัญญาณบิตที่อ่านขึ้นมาจากช่องสัญญาณได้

2.7.2 เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบความร้อนเข้าช่วย (HAMR: Heat-Assisted Magnetic Recording) ข้อมูลในแต่ละบิตจะถูกจัดเก็บด้วยสื่อสนามพลังงานแอนไอโซโทรปี โดยการให้ความร้อนแก่พื้นที่นั้น ๆ ในระดับนาโนเมตรชั่วคราว ซึ่งมีปัญหาในการสร้างและติดตั้งเลเซอร์ (laser) สำหรับให้ความร้อนกับสื่อบันทึก, ปัญหาการระบายความร้อนหลังจากการเขียน และการติดตั้งเลเซอร์ส่งผลกระทบต่อตรงกับการเขียนข้อมูล เนื่องจากต้องใช้พลังงานสูงในการเปลี่ยนทิศทางสภาพความเป็นแม่เหล็ก

2.7.3 เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบไมโครเวฟเข้าช่วย (MAMR: Microwave-Assisted Magnetic Recording) จะใช้เทคโนโลยีการบันทึกข้อมูลจากหัวอ่านที่เกิดการหมุนของคลื่นไมโครเวฟเพื่อใช้ในการบันทึกข้อมูล ในทางปฏิบัติเทคโนโลยีต้องเผชิญกับปัญหาเกี่ยวกับเครื่องกำเนิดความถี่ของสัญญาณไมโครเวฟ

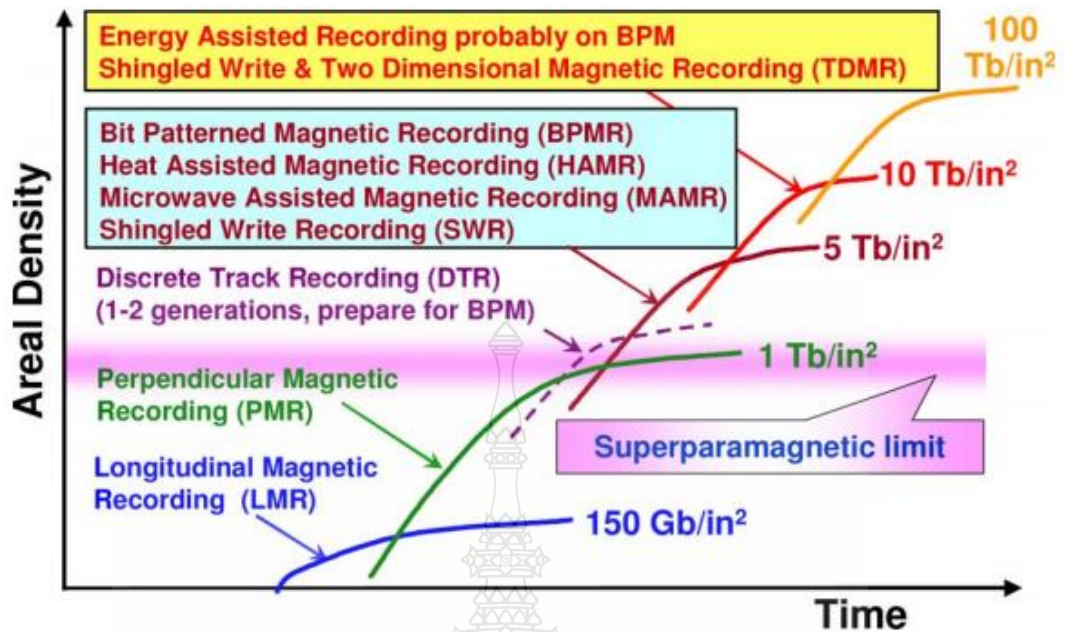
2.7.4 เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบ SWR (Shingled Write Recording) และ เทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กแบบ TDMR (Two-Dimension Magnetic Recording) ต้องใช้ระบบประมวลผลสัญญาณที่มีความซับซ้อนมากขึ้นที่ช่องสัญญาณการอ่านกลับ เทคนิคการเขียนแบบใหม่ที่มีความซับซ้อนสูงและใช้หน่วยความจำสำรองเป็นจำนวนมาก

จากตารางที่ 2.1 เปรียบเทียบเทคโนโลยีการบันทึกข้อมูล แสดงให้เห็นเทคโนโลยีการบันทึกข้อมูลในทั้ง 4 รูปแบบนั้นมีข้อดีและข้อเสีย [2] รวมไปถึงข้อจำกัดทางการพัฒนาที่แตกต่างกันออกไป โดยในวิทยานิพนธ์เล่มนี้ผู้วิจัยได้ให้ความสนใจเทคโนโลยีการบันทึกข้อมูลเชิงแม่เหล็กรูปแบบ BPMP เป็นพิเศษเนื่องจากความสามารถในการเพิ่มความหนาแน่นเชิงพื้นที่ได้สูง และสามารถจำลองการทำงานช่องสัญญาณ BPMP ได้โดยไม่ต้องพึ่งพาตัวฮาร์ดแวร์

ตารางที่ 2.1 เปรียบเทียบเทคโนโลยีการบันทึกข้อมูล [2]

		BPMR	HAMR	MAMR	SW/TDMR
หัวอ่าน (Head)	$T_{ww}(MP)$	Small	Large		
	Assist	-	Near Field	Microwave	-
สื่อบันทึก (Media)	Write ability	Easy-to-write	Hard-to-write		
	Magnetic Feature	Exchange Coupled	Low $T_c$ Rapid cool	Low Damping Constant	Conventional Granular
Servo/Mechanical	TMR	-	Extension		Large TMR
	Adaptive	-	Extension		
Spacing (challenges)		Planarization	Protrusion	Extension	
Signal Processing		One Dimension			Two Dimension
Architecture		Synchronous Writing	Assist Methodology Optimization		New Format Architecture
Challenge	Technology	Synchronous Writing	High Temperature Reliability	Microwave Oscillator	New Format Architecture
	cost	Lithography	Optics	-	Extra Memory

จากภาพที่ 2.12 การคาดการณ์ความเป็นไปได้ในการเปลี่ยนแปลงของเทคโนโลยีการบันทึกข้อมูล เทคโนโลยี BPMR มีประสิทธิภาพสูงที่คาดการณ์ว่าสามารถเพิ่มความหนาแน่นเชิงพื้นที่ได้ถึง 10 Tbit/in<sup>2</sup> (เทราบิตต่อตารางนิ้ว) งานวิจัยที่เกี่ยวข้องกับการใช้เทคโนโลยีการบันทึกข้อมูลในรูปแบบใหม่ การบันทึกข้อมูลเชิงแม่เหล็กแบบ BPMR เป็นเทคโนโลยีที่สามารถนำมาใช้งานได้จริงและให้ประสิทธิภาพของระบบการบันทึกข้อมูลได้มากยิ่งขึ้น [14] ดังนั้นเทคโนโลยีการบันทึกข้อมูลแบบ BPMR จึงได้รับความสนใจในหมู่นักวิจัยเป็นอย่างมาก [15, 16, 17, 18] แสดงถึงแนวโน้มของความหนาแน่นเชิงพื้นที่ของเทคโนโลยีการบันทึกข้อมูลในรูปแบบต่าง ๆ ซึ่งเทคโนโลยีการบันทึกข้อมูลแบบ BPMR นั้นสามารถเพิ่มความจุเชิงพื้นที่ของสื่อบันทึกข้อมูลได้ถึง 5 Tbit/in<sup>2</sup>



ภาพที่ 2.12 การคาดการณ์ความเป็นไปได้ในการเปลี่ยนแปลงของเทคโนโลยีการบันทึกข้อมูล [2]


## 2.8 ระบบการบันทึกข้อมูลเชิงแม่เหล็กแบบบิตแพทเทิร์นมีเดีย

แนวคิดในการสร้างแบบจำลองของเทคโนโลยีการบันทึกข้อมูลแบบ BPMR นั้นค่อนข้างเข้าใจง่ายโดยเฉพาะอย่างยิ่งเมื่อนำมาเปรียบเทียบกับระบบการบันทึกข้อมูลแบบแนวตั้งเดิมดังภาพที่

2.13 การเปรียบเทียบระหว่าง (a) สื่อบันทึกแบบละเอียด กับ (b) สื่อบันทึกแบบบิตแพทเทิร์นมีเดีย ในการบันทึกข้อมูลของสื่อบันทึกแบบละเอียดจะทำการบันทึกข้อมูลลงบนเกรนแม่เหล็กที่มีการจัดเรียงตัวในลักษณะที่ไม่เป็นระเบียบจึงทำให้การบันทึกข้อมูลบิตในแต่ละครั้งใช้พื้นที่ในการบันทึกข้อมูลบิตมากเมื่อเทียบกับเทคโนโลยีการบันทึกข้อมูลแบบ BPMR โดยหลักการทำงานของเทคโนโลยีการบันทึกข้อมูลแบบ BPMR มีข้อได้เปรียบที่สามารถให้ความจุที่สูงมากกว่า และยังมีความซับซ้อนที่น้อยกว่าการใช้สื่อบันทึกแบบละเอียด โดยการบันทึกข้อมูลลงในสื่อบันทึกนั้นจะทำการจัดระเบียบการบันทึกข้อมูลดังภาพที่ 2.13 การเปรียบเทียบระหว่าง (a) สื่อบันทึกแบบละเอียด กับ (b)

สื่อบันทึกแบบบิตแพทเทิร์นมีเดีย โดยมีสื่อที่ใช้ในบันทึกข้อมูลจะจัดเรียงตัวกันอย่างเป็นระเบียบนี้จะเรียกว่าไอแลนด์ (Island) เพื่อใช้สำหรับการบันทึกข้อมูลในแต่ละบิตโดยทั่วไปจะมีขนาดน้อยกว่า 20 – 10 นาโนเมตร และจะถูกขึ้นด้วยส่วนที่ไม่มีสภาพความเป็นแม่เหล็ก (Non-magnetic) ที่เป็นบริเวณรอบ ๆ ไอแลนด์เพื่อทำการแยกไอแลนด์ออกจากกัน ซึ่งในปัจจุบันเทคโนโลยีการบันทึกแบบ

BPMR สามารถเพิ่มความหนาแน่นเชิงพื้นที่ได้มากกว่าแบบแนวตั้ง และราคาที่ถูก จึงเป็นประเด็นที่นักวิจัยให้ความสนใจในการพัฒนาเทคโนโลยีเหล่านี้



ภาพที่ 2.13 การเปรียบเทียบระหว่าง (a) สื่อบันทึกแบบละเอียด กับ (b) สื่อบันทึกแบบบิตแพทเทิร์นมีเดีย [10]

จากรูปสามารถสร้างสมการช่องสัญญาณของระบบการบันทึกข้อมูลเชิงแม่เหล็กในรูปแบบ BPMR ด้วยสมการดังนี้ โดยที่การจำลองช่องสัญญาณพัลส์ 2 มิติแบบเกาส์เซียนของช่องสัญญาณ BPMR แบบกริดมุมฉาก จึงสามารถเขียนเป็นสมการได้ดังนี้


$$P(z, x) = A \exp \left\{ -\frac{1}{2} \left[ \left( \frac{x}{PW_x} \right)^2 + \left( \frac{z}{PW_z} \right)^2 \right] \right\}, \quad (4)$$

ตารางที่ 2.2 พารามิเตอร์จำลองหัวอ่านในสื่อบันทึกของระบบการบันทึกพีเอ็มอาร์

พารามิเตอร์	สัญลักษณ์
Square island	$a$
Thickness	$d$
Fly height	$d$
Along-track $PW_{50}$	$PW_x$
Cross-track $PW_{50}$	$PW_z$
Gap to gap width	$g$

พารามิเตอร์	สัญลักษณ์
Thickness of MR head	$t$
Width of the MR head	$W$

โดยปกติแล้วประเภทของระบบ BPMP นั้นแบ่งออกเป็น 2 ประเภทด้วยกันคือ ระบบ BPMP แบบหมุน (Spinning – disk system) และระบบแบบโพรบ (Probe – based system) [8] ในที่นี้จะกล่าวถึงเฉพาะการประมวลสัญญาณในระบบ BPMP แบบหมุน ซึ่งมีลักษณะการทำงานที่คล้ายกับระบบการบันทึกข้อมูลแบบที่ใช้กันทั่วไป (นั่นคือแบบแนวตั้งและแนวนอน) ดังนั้นช่องสัญญาณอ่านของระบบ BPMP จึงสามารถจำลองเป็นแผนภาพบล็อกแบบง่ายได้ดังภาพที่ 2.14 แผนภาพบล็อกแบบง่ายสำหรับช่องสัญญาณการอ่านของระบบ BPMP ภาพที่ 3.2 รูปแบบช่องสัญญาณ BPMP ในแบบทั่ว ซึ่งประกอบหลักได้แก่ ช่องสัญญาณ (Channel), อีควอไลเซอร์แบบผลตอบสนองบางส่วน (Partial-respond equalizer), และการใช้วงจรตรวจ (Detector)




ภาพที่ 2.14 แผนภาพบล็อกแบบง่ายสำหรับช่องสัญญาณการอ่านของระบบ BPMP

## 2.9 ปัญหาในระบบการบันทึกข้อมูลแม่เหล็กแบบบิตแพทเทิร์นมีเดีย

เนื่องจากระยะห่างระหว่างแทร็กของข้อมูลมีระยะห่างที่ใกล้เคียงกันเป็นอย่างมาก (ระดับนาโนเมตร) เพราะฉะนั้นในกระบวนการอ่านข้อมูล สัญญาณอ่านกลับ (Readback signal) จะถูกรบกวนจากการแทรกสอด โดยเรียกปัญหาเหล่านี้ว่าการแทรกสอดแบบ 2 มิติ ซึ่งประกอบด้วยได้ด้วยการแทรกสอดระหว่างสัญลักษณ์ (ISI: Inter-symbol interference) และการแทรกสอดระหว่างแทร็ก (ITI: Inter-track interference) [3, 14, 19, 20] นอกจากนี้ยังมีปัญหาที่เกิดจากการอ่านของหัวอ่านที่ไม่ตรงแทร็ก (TMR: track mis-registration) ซึ่งเป็นปัญหาที่ส่งผลกระทบต่อประสิทธิภาพของระบบ

2.9.1 การแทรกสอดระหว่างสัญลักษณ์ (ISI: Inter-symbol interference) คือปรากฏการณ์สัญญาณพัลส์ลำดับที่  $k$  ที่ส่งออกจากต้นทาง ไปรบกวนหรือแทรกสอดกับสัญลักษณ์ที่อยู่ติด ๆ กัน (นั่นคือสัญญาณพัลส์ลำดับที่  $k-i$  เมื่อ  $i$  เป็นเลขจำนวนเต็มที่ไม่เท่ากับ 0) เช่นสัญญาณพัลส์ลำดับที่ 5

จะไปรบกวนสัญญาณพัลส์ลำดับที่ 4 ที่อยู่ก่อนหน้าวิธีการสังเกตว่าช่องสัญญาณสื่อสาร (Data communication channel) ที่ใช้งานก่อให้เกิด ISI หรือไม่ สามารถทำได้โดยการส่งสัญญาณพัลส์หนึ่งพัลส์เข้าไปในช่องสัญญาณ ถ้าสัญญาณพัลส์ที่ด้านขาออกของช่องสัญญาณมีมากกว่าหนึ่งพัลส์ แสดงว่า ช่องสัญญาณนี้ก่อให้เกิด ISI [21]



ภาพที่ 2.15 ผลตอบสนองของสัญญาณพัลส์เกาส์เซียนในแนวตามแตรีก (เส้นปะ) และในแนวขวางแตรีก (เส้นทึบ)

2.9.2 การแทรกสอดระหว่างแตรีก (ITI: Inter track interference) ในระบบการบันทึกข้อมูลแบบ BPMP เกิดจากการได้รับผลกระทบจากแตรีกข้างเคียง (Adjacent track) การแทรกสอดระหว่างแตรีกคือ ปรากฏการณ์สัญญาณพัลส์แตรีกโดยรอบไปรบกวนหรือแทรกสอดกับสัญญาณพัลส์แตรีกหลักที่อยู่ติดกันซึ่งในระบบ BPMP นั้น ITI จะมีผลกระทบที่รุนแรงมากกว่า ISI ในภาพที่ 2.15 ผลตอบสนองของสัญญาณพัลส์เกาส์เซียนในแนวตามแตรีก (เส้นปะ) และในแนวขวางแตรีก (เส้นทึบ) เมื่อทำการชักตัวอย่างข้อมูลจากผลตอบสนองสัญญาณพัลส์ในแนวตามแตรีกและในแนวขวางแตรีกจะเห็นว่าค่าของข้อมูลที่ได้จากการชักตัวอย่างในแนวขวางแตรีกจะมากกว่าเสมอ ซึ่งแสดงให้เห็นว่าผลกระทบจาก ITI จะมีความรุนแรงมากกว่า ISI โดยความรุนแรงของการแทรกสอดระหว่างแตรีกนั้นจะมีความรุนแรงขึ้นอยู่กับความหนาแน่นเชิงพื้นที่ (AD: Areal density) ยิ่งความหนาแน่นเชิงพื้นที่ที่มีความหนาแน่นมากเพียงใด นั้นหมายถึงการเรียงตัว และขนาดของไอแลนด์จะมีขนาดเล็ก และชิดกันมากยิ่งขึ้นทำให้ค่าบิตที่อ่านจากแตรีกหลัก (Main track) ได้รับสัญญาณรบกวนจากแตรีก


ข้างเคียง (Adjacent track) ซึ่งค่าระดับของความหนาแน่นเชิงพื้นที่ในระดับที่แตกต่างกัน เมื่อทำการอ่านข้อมูลบิตจากช่องสัญญาณจะได้ค่าสัมประสิทธิ์ของช่องสัญญาณ BPMR จากแตร็กโดยรอบที่แตกต่างกันตามความหนาแน่นเชิงพื้นที่ของช่องสัญญาณ [17, 20]

ตารางที่ 2.3 แสดงค่าสัมประสิทธิ์ของสัญญาณ BPMR ที่ค่า AD ในแต่ละระดับ

AD (Tb/in <sup>2</sup> )	Tx = T <sub>z</sub> (nm)	2D channel coefficients		
2 Tb/in <sup>2</sup>	18 nm	0.0213	0.2321	0.0213
		0.0919	1.0000	0.0919
		0.0213	0.2321	0.0213
2.5 Tb/in <sup>2</sup>	16 nm	0.0478	0.3154	0.0478
		0.1517	1.0000	0.1517
		0.0478	0.3154	0.0478
3 Tb/in <sup>2</sup>	14.5 nm	0.0824	0.3876	0.0824
		0.2125	1.0000	0.2125
		0.0824	0.3876	0.0824

2.9.3 แตร็กมิสเรจิสเตรชัน (TMR: Track Mis-registration) ในระบบการบันทึกข้อมูลเชิงแม่เหล็กรูปแบบ BPMR นอกจากปัญหาการแทรกสอดแบบสองมิติแล้วนั้นยังมีอีกหนึ่งปัญหาที่ส่งผลกระทบต่อประสิทธิภาพของช่องสัญญาณเป็นอย่างมากนั่นคือ การอ่านนอกแตร็ก หรือแตร็กมิสเรจิสเตรชัน (TMR: Track Mis-registration) [22, 23] ซึ่งเป็นปัญหาสำคัญในระบบ BPMR ดังตัวอย่างภาพที่ 2.16 การเปรียบเทียบการทำงานของหัวอ่าน (ก) ลักษณะของหัวอ่านที่ทำงานปกติ (ข) ลักษณะของหัวอ่านที่ออกนอกตำแหน่ง แสดงให้เห็นถึงตำแหน่งที่เหมาะสมที่สุดของหัวอ่านที่อยู่บนสื่อบันทึกเมื่อ  $\Delta_r$  คือออฟเซ็ทของหัวอ่านหรือระยะห่างระหว่าง ตำแหน่งกลางของหัวอ่านกับตำแหน่งกลางของแตร็กไอซ์แลนด์ กล่าวคือจุดศูนย์กลางของหัวอ่านควรอยู่ ณ จุดกึ่งกลางของแตร็กหลักและเคลื่อนที่ขนานไปกับแนวตามแตร็กเพื่อให้สัญญาณอ่านกลับที่ด้านขาออกของหัวอ่านมีคุณภาพดีที่สุด





ภาพที่ 2.16 การเปรียบเทียบการทำงานของหัวอ่าน (ก) ลักษณะของหัวอ่านที่ทำงานปกติ (ข) ลักษณะของหัวอ่านที่ออกนอกตำแหน่ง

อย่างไรก็ตามในทางปฏิบัตินั้นมีโอกาสที่การเคลื่อนที่ของหัวอ่านจะเคลื่อนที่ออกจากตำแหน่งที่ควรจะเป็น โดยที่หัวอ่านเคลื่อนที่ไปแนวแตรีกด้านบน (upward offset) หรือด้านล่าง (downward offset) ดังภาพที่ 2.16 การเปรียบเทียบการทำงานของหัวอ่าน (ก) ลักษณะของหัวอ่านที่ทำงานปกติ (ข) ลักษณะของหัวอ่านที่ออกนอกตำแหน่งจะเรียกปรากฏการณ์ในลักษณะนี้ว่า “แตรีกมีสเรจิสเตรชัน” (TMR : track mis-registration) หรือออฟเซ็ทของหัวอ่าน (Readhead offset)  $\Delta_T$  ซึ่งถูกกำหนดโดย [22] และสมการที่ใช้สำหรับคำนวณหาค่า TMR สามารถคำนวณได้โดยสมการดังต่อไปนี้

$$TMR (\%) = \frac{\Delta_T}{T_z} \times 100, (5)$$

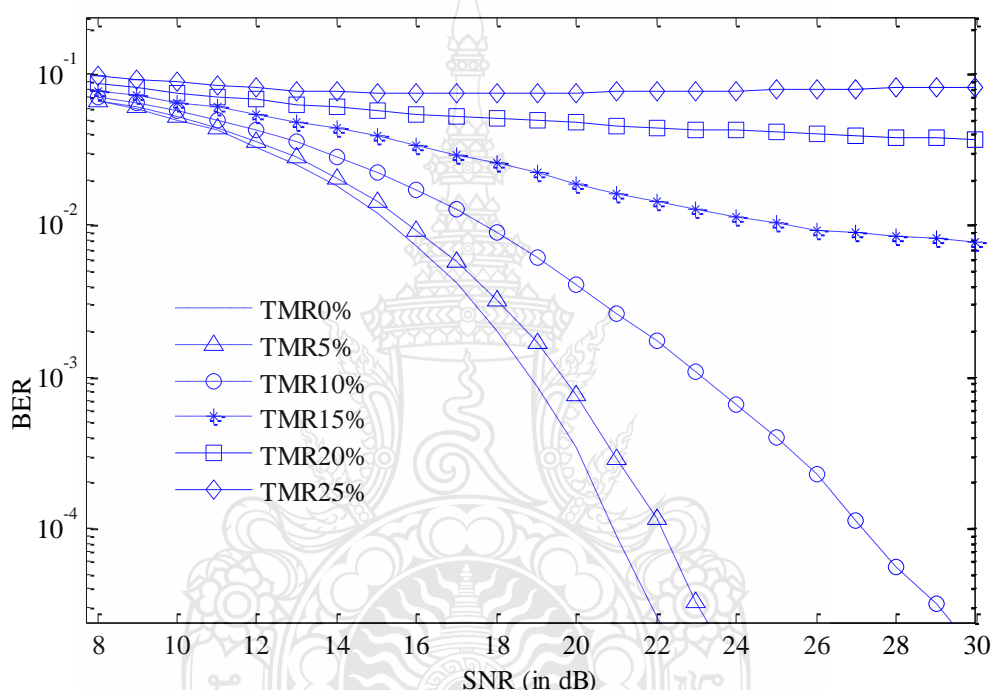
จากสมการที่ (5) เป็นสมการที่ใช้ในการคำนวณระดับของค่า TMR ที่เกิดขึ้นในระบบ BPMR และเมื่อ TMR เกิดขึ้น ผลตอบสนองของสัญญาณพัลส์เกาส์เซียนที่ได้รับผลกระทบจาก TMR จะสามารถสร้างเป็นสมการได้ดังต่อไปนี้

$$P(z, x) = A \exp \left\{ -\frac{1}{2c^2} \left[ \left( \frac{x}{PW_x} \right)^2 + \left( \frac{z + \Delta_T}{PW_z} \right)^2 \right] \right\}, (6)$$

เมื่อระบบได้รับผลกระทบจาก TMR ในแต่ละระดับสัญญาณอ่านกลับของระบบก็จะผิดเพี้ยนไปจากสัญญาณจริง โดยที่ค่าแอมพลิจูดจะลดลงเมื่อระบบได้รับผลกระทบจากระดับ TMR ที่สูงขึ้น และเมื่อ



ทำการทดสอบสมรรถนะของระบบ BPMPR ที่ได้รับผลกระทบจากปัญหา TMR ในความรุนแรงแต่ละระดับจะได้ว่า TMR ในระดับสูงจะให้สมรรถนะที่แย่ที่สุดนั่นหมายถึงระดับของ TMR ที่เพิ่มขึ้นส่งผลกระทบต่อประสิทธิภาพของระบบ BPMPR เป็นอย่างมากดังแสดงภาพที่ 2.17 เปรียบเทียบประสิทธิภาพของระบบที่ได้รับผลกระทบจากที่ TMR แต่ละระดับ เมื่อแกน X คืออัตราส่วนค่ากำลังเฉลี่ยของสัญญาณที่ต้องการต่อค่ากำลังเฉลี่ยของสัญญาณรบกวน (SNR: Signal-to-noise ratio) มีหน่วยเป็นเดซิเบล (dB) และแกน y คืออัตราบิตผิดพลาด (BER: Bit-error rate)




ภาพที่ 2.17 เปรียบเทียบประสิทธิภาพของระบบที่ได้รับผลกระทบจากที่ TMR แต่ละระดับ

โดยปกติในระบบ BPMPR ที่ไม่ได้รับผลกระทบจาก TMR ค่าสัมประสิทธิ์ที่ได้จากการชักตัวอย่างของผลตอบสนองสัญญาณพัลส์เกาส์เซียนแบบสองมิติมันจะมีลักษณะเป็นแบบสมมาตร (Symmetric) และหากมีปัญหาการอ่านนอกแตร็ก TMR เกิดขึ้นในระบบก็จะส่งผลทำให้ค่าสัมประสิทธิ์ที่ได้จากการชักตัวอย่างของผลตอบสนองสัญญาณพัลส์เกาส์เซียนแบบสองมิติอยู่ในรูปไม่สมมาตร (Asymmetric) ซึ่งแสดงตัวอย่างค่าสัมประสิทธิ์ของช่องสัญญาณ BPMPR ได้ดังตัวอย่างจากตารางที่ 2.4 ค่าสัมประสิทธิ์ของช่องสัญญาณ BPMPR [24] ซึ่งเป็นการแสดงถึงค่าสัมประสิทธิ์ที่ได้รับจากการอ่านค่าบิตในช่องสัญญาณที่เกิดปัญหา TMR ตั้งแต่ระดับ 0 จนถึง 25 เมื่อหัวอ่านหลุดออกจากตำแหน่งที่ควรจะเป็น จากตัวอย่างโดยหัวอ่านได้เคลื่อนที่ไปตามแนวของแตร็กด้านบน (Upward offset) จึงทำให้เกิดความการลดทอนประสิทธิภาพของช่องสัญญาณลง

ตารางที่ 2.4 ค่าสัมประสิทธิ์ของช่องสัญญาณ BPMR [24]

TMR (%)	2D channel coefficients	TMR (%)	2D channel coefficients
0 %	0.0824 <b>0.3876</b> 0.0824	15 %	0.1094 <b>0.5151</b> 0.1094
	0.2125 1.0000 0.2125		0.2125 1.0000 0.2125
	0.0824 <b>0.3876</b> 0.0824		0.0620 <b>0.2917</b> 0.0620
5 %	0.0905 <b>0.4261</b> 0.0905	20%	0.1203 <b>0.5663</b> 0.1203
	0.2125 1.0000 0.2125		0.2125 1.0000 0.2125
	0.0749 <b>0.3525</b> 0.0749		0.0564 <b>0.2653</b> 0.0564
10 %	0.0996 <b>0.4685</b> 0.0996	25 %	0.1323 <b>0.6226</b> 0.1323
	0.2125 1.0000 0.2125		0.2125 1.0000 0.2125
	0.0681 <b>0.3207</b> 0.0681		0.0513 <b>0.2413</b> 0.0513

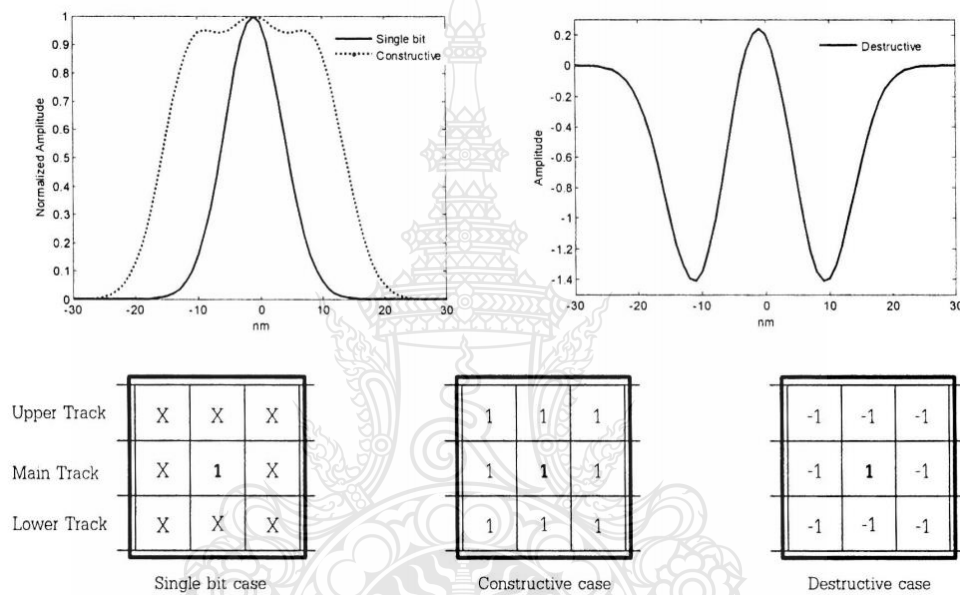
2.9.4 ความผันผวนของตำแหน่ง (Location fluctuation) เทคโนโลยีการบันทึกเชิงแม่เหล็ก รูปแบบ BPMR นั้นต่างจากการบันทึกเชิงแม่เหล็กแบบทั่วไปที่สื่อการบันทึกต้องการความแม่นยำเป็นอย่างมาก ในแต่ละไอซ์แลนด์ที่มีระยะห่างน้อยกว่า 25 นาโนเมตร จะทำให้เกิดความละเอียดในการวางตำแหน่งที่สูง จึงเป็นการยากที่ทำให้ทุกไอซ์แลนด์มีระยะห่างเท่ากันอย่างสม่ำเสมอ, ความผันผวนของขนาด (Size fluctuation) ของแต่ละไอซ์แลนด์, ความผันผวนของความสูง (Height fluctuation) ของแต่ละไอซ์แลนด์, ความผันผวนของรูปร่าง (Shape fluctuation) ของแต่ละไอซ์แลนด์ และความผันผวนของสภาพความเป็นแม่เหล็กอิ่มตัว (Saturation magnetization) เนื่องจากแต่ละไอซ์แลนด์มีขนาดไม่แน่นอนจึงทำให้สภาพความเป็นแม่เหล็กของแต่ละไอซ์แลนด์มีความอิ่มตัวไม่เท่ากัน มักจากเกิดขึ้นจากปัญหาทางการผลิตที่ควบคุมตำแหน่งการปลูกตำแหน่งของไอซ์แลนด์ และการเขียนข้อมูลบิตลงบนไอซ์แลนด์ที่มีขนาดเล็กจึงทำได้ยาก



ภาพที่ 2.18 การเปรียบเทียบการปลูกเซลล์บิตในตำแหน่งที่เหมาะสม (Ideal placement) กับตำแหน่งที่ทำให้เกิดผลกระทบ (Effective placement) [14]

## 2.10 ผลกระทบของการแทรกสอดแบบสองมิติในระบบ BPMP

ผลกระทบของการแทรกสอดแบบสองมิติในระบบ BPMP ซึ่งเป็นปัญหาที่สืบเนื่องมาจากผลตอบสนองของสัญญาณพัลส์ของแตรีกข้างเคียง ที่เป็นผลกระทบมาจากการเข้ามาแทรกสอดกับผลของสัญญาณพัลส์ในแตรีกหลัก ผลกระทบของ ITI และ ISI ที่มีต่อสัญญาณอ่านกลับจากช่องสัญญาณในระบบ BPMP ที่แสดงถึงผลกระทบของการแทรกสอดแบบสองมิติ จากภาพที่ 2.19 การจำแนกประเภทของลักษณะสัญญาณที่เกิดจากปัญหาการแทรกสอดแบบสองมิติ




ภาพที่ 2.19 การจำแนกประเภทของลักษณะสัญญาณที่เกิดจากปัญหาการแทรกสอดแบบสองมิติ

ในช่องสัญญาณที่ปราศจากสัญญาณรบกวน (Noiseless) ซึ่งประกอบไปด้วย กรณีที่ 1 การบันทึกข้อมูลเพียงบิตเดียว (Single bit case) กรณีที่ 2 การบันทึกที่บิตรอบข้างมีสถานะที่เหมือนกันแบบส่งเสริม (Constructive case) และกรณีที่ 3 การบันทึกแบบบิตรอบข้างมีสถานะที่ตรงข้ามกันกับบิตที่ถูกอ่านแบบลดทอน (Destructive case) ซึ่งในกรณีใดกรณีที่เป็นแบบส่งเสริมและแบบลดทอนนั้นสามารถตรวจสอบได้จากสัญญาณการอ่านกลับ (Readback signal) เมื่อทำการเทียบกับบิตข้อมูลเดี่ยว [15], [19], [25] จะสังเกตได้ว่า ในกรณีที่เกิดการแทรกสอดแบบสองมิติในช่องสัญญาณในลักษณะของรูปแบบที่ส่งเสริมกันนั้นค่าของแอมพลิจูด (Amplitude) ของสัญญาณอ่านกลับของบิตกลางจะมีระดับที่เพิ่มสูงขึ้น เช่น ในกรณีที่บิตกลางที่ทำการอ่านนั้นเป็นบิตข้อมูล “1” และถูกล้อมรอบไปด้วย “1” ซึ่งในกรณีนี้ถือได้ว่าเป็นกรณีที่ดีที่สุด (Best case) ในขณะที่เดียวกันหากบิตกลางที่ทำการอ่านนั้นเป็นบิตข้อมูล “1” แล้วถูกล้อมรอบไปด้วย “-1” ค่าของแอมพลิจูดของบิตตรง

กลางจะต่ำ โดยจะเรียกเหตุการณ์ในลักษณะเช่นนี้ว่า การแทรกสอดแบบลดทอนส่งผลกระทบกับประสิทธิภาพของระบบ ดังนั้นในส่วนขอเทคนิคการลดผลกระทบจากรูปแบบที่เกิดการลดทอนกันของสัญญาณในวิทยานิพนธ์เล่มนี้ผู้วิจัยได้ให้ความสนใจกับวิธีการเข้ารหัสมอดูเลชัน ซึ่งจะถูกกล่าวถึงในหัวข้อถัดไป

## 2.11 การเข้ารหัสและถอดรหัสมอดูเลชัน 5/6

จากผลกระทบของการแทรกสอดแบบสองมิติที่มีผลต่อสัญญาณอ่านกลับในระบบ BPMR เมื่อข้อมูลบิตที่ทำการบันทึกลงไปยังช่องสัญญาณเกิดการลดทอนในลักษณะหรือรูปแบบที่มีความรุนแรงจนทำให้ประสิทธิภาพของช่องของสัญญาณบันทึกในระบบ BPMR ต่ำลง โดยที่รูปแบบของข้อมูลบิตที่ถูกบันทึกลงไปในช่วงสัญญาณรอบข้างมีสถานะที่ตรงข้ามกันกับบิตที่ถูกอ่าน จะก่อให้เกิดการลดทอนของค่าแอมพลิจูดของสัญญาณอ่านกลับขึ้น ดังนั้นสิ่งที่ควรหลีกเลี่ยงไม่ให้เกิดในช่องสัญญาณก่อนทำการบันทึกข้อมูลในสื่อบันทึก [26] ในทางปฏิบัติไม่ควรบันทึกข้อมูลที่อยู่ในรูปแบบลดทอนลงในสื่อบันทึก เพราะจะทำให้ปัญหาการแทรกสอดแบบสองมิติมีความรุนแรงที่มาก และส่งผลทำให้สัญญาณการอ่านกลับนั้นถูกลดทอน ส่งผลให้ระบบ BPMR มีประสิทธิภาพที่ลดลง โดยแนวทางในการแก้ไขปัญหาของการแทรกสอดแบบสองมิติในกรณีที่เราร้ายที่สุด เมื่อข้อมูลบิตที่ทำการบันทึกลงในช่องสัญญาณเกิดการบันทึกแบบบิตรอบข้างมีสถานะที่ตรงข้ามกันกับบิตที่ถูกอ่านเกิดขึ้นสามารถแก้ไขได้โดยการใช้วิธีการเข้ารหัสและถอดรหัสมอดูเลชัน ซึ่งในวิทยานิพนธ์เล่มนี้จะทำการจำลองการทำงานของระบบ BPMR ที่ทำการเข้ารหัสสัญญาณด้วยวิธีการมอดูเลชันในอัตราส่วนที่ 5/6 [16], [17], [27] โดยทำงานของการเข้ารหัสข้อมูลจากภาพที่ 2.20 กระบวนการเข้ารหัสมอดูเลชัน 5/6 ทำการนำเข้าข้อมูลบิตอินพุตจำนวน 5 บิต มาทำการเข้ารหัส (Mapping) ในแต่ละคำรหัส (Codeword) โดยข้อมูลบิตขาออกจะมีจำนวน 6 บิตที่มีจำนวนทั้งสิ้น 32 รูปแบบที่มีการแทรกสอดของสัญญาณน้อยที่สุด จากจำนวนความเป็นไปได้จากการเข้ารหัสมอดูเลชันที่เกิดขึ้นได้ทั้งหมด 64 รูปแบบ เพื่อทำการหลีกเลี่ยงการบันทึกข้อมูลรูปแบบที่ก่อให้เกิดการแทรกสอดแบบสองมิติที่มีความรุนแรง



ภาพที่ 2.20 กระบวนการเข้ารหัสมอดูเลชัน 5/6

ตารางที่ 2.5 เข้าคู่รหัสสมอดูเลขชั้น 5/6

5 bits input data					Codewords
$a_k$	$a_{k+1}$	$a_{k+2}$	$a_{k+3}$	$a_{k+4}$	
-1	-1	-1	-1	-1	$X^1$
-1	-1	-1	-1	1	$X^9$
-1	-1	-1	1	-1	$X^{10}$
-1	-1	-1	1	1	$X^{18}$
-1	-1	1	-1	-1	$X^2$
-1	-1	1	-1	1	$X^3$
-1	-1	1	1	-1	$X^{11}$
-1	-1	1	1	1	$X^{19}$
-1	1	-1	-1	-1	$X^4$
-1	1	-1	-1	1	$X^{12}$
-1	1	-1	1	-1	$X^{25}$
-1	1	-1	1	1	$X^{20}$
-1	1	1	-1	-1	$X^{17}$
-1	1	1	-1	1	$X^{13}$
-1	1	1	1	-1	$X^5$
-1	1	1	1	1	$X^{21}$

5 bits input data					Codewords
$a_k$	$a_{k+1}$	$a_{k+2}$	$a_{k+3}$	$a_{k+4}$	
1	-1	-1	-1	-1	$X^{29}$
1	-1	-1	-1	1	$X^6$
1	-1	-1	1	-1	$X^{28}$
1	-1	-1	1	1	$X^{27}$
1	-1	1	-1	-1	$X^{26}$
1	-1	1	-1	1	$X^{16}$
1	-1	1	1	-1	$X^{24}$
1	-1	1	1	1	$X^{14}$
1	1	-1	-1	-1	$X^{22}$
1	1	-1	-1	1	$X^{30}$
1	1	-1	1	-1	$X^{31}$
1	1	-1	1	1	$X^7$
1	1	1	-1	-1	$X^{15}$
1	1	1	-1	1	$X^{23}$
1	1	1	1	-1	$X^8$
1	1	1	1	1	$X^{32}$

สำหรับการเข้ารหัสสมอดูเลขชั้นแบบ 5/6 นั้นจะทำการกำหนดข้อมูลอินพุตมาจำนวนทั้งหมดจำนวน 5 บิตคือ  $[a_k, a_{k+1}, a_{k+2}, a_{k+3}, a_{k+4}]$  เพื่อนำไปจับคู่กับตารางการเข้ารหัสสมอดูเลขชั้นที่อัตราส่วน 5/6 โดยชุดข้อมูลการเข้ารหัสได้มาจากการเลือกชุดข้อมูลที่ดีที่สุดทั้งหมดจำนวนทั้งหมด 32 รูปแบบ จากจำนวนทั้งหมดใน 64 รูปแบบที่สามารถเกิดขึ้นได้ เพื่อใช้ในการบันทึกข้อมูลลงในระบบจากภาพที่ 2.21 รูปแบบของการเข้ารหัสสมอดูเลขชั้น ณ อัตราส่วนที่ 5/6 จะแสดงถึงตัวอย่างการเลือกรูปแบบของการเข้ารหัสที่จะนำมาใช้ในการจับคู่กับตารางการเข้ารหัสก่อนเขียนลงบนช่องสัญญาณ

$X_1$ -1 -1 -1 -1 -1 -1	$X_2$ -1 -1 -1 -1 1 -1	$X_3$ -1 1 1 -1 -1 1	$X_4$ -1 -1 -1 1 -1 -1	$X_5$ -1 1 -1 1 1 1	$X_6$ 1 -1 -1 -1 -1 1	$X_7$ 1 -1 1 1 1 1	$X_8$ 1 1 -1 1 1 -1
$X_9$ -1 -1 -1 -1 -1 1	$X_{10}$ -1 -1 -1 -1 1 1	$X_{11}$ -1 1 -1 -1 1 -1	$X_{12}$ -1 -1 -1 1 -1 1	$X_{13}$ -1 1 1 1 1 -1	$X_{14}$ 1 1 1 -1 1 1	$X_{15}$ 1 1 -1 1 -1 -1	$X_{16}$ 1 1 -1 1 1 1
$X_{17}$ -1 -1 1 -1 -1 -1	$X_{18}$ -1 -1 1 -1 1 1	$X_{19}$ -1 1 1 -1 1 -1	$X_{20}$ -1 -1 -1 1 1 1	$X_{21}$ -1 1 1 1 1 1	$X_{22}$ 1 -1 -1 1 -1 -1	$X_{23}$ 1 1 1 1 -1 -1	$X_{24}$ 1 1 1 1 1 -1
$X_{25}$ -1 -1 1 -1 -1 1	$X_{26}$ -1 1 -1 -1 -1 -1	$X_{27}$ -1 1 1 -1 1 1	$X_{28}$ -1 1 -1 1 1 -1	$X_{29}$ 1 -1 -1 -1 -1 -1	$X_{30}$ 1 -1 -1 1 -1 1	$X_{31}$ 1 1 1 1 -1 1	$X_{32}$ 1 1 1 1 1 1

ภาพที่ 2.21 รูปแบบของการเข้ารหัสสมอดูเลขชั้น ณ อัตราส่วนที่ 5/6

สำหรับการถอดรหัสเอาต์พุตที่ออกจากวงจรตรวจหาวิเทอร์บีจะถูกจัดเรียงใหม่ แล้วหลังจากทำการหาระยะทางยูคลิด (Euclidean distance) ก่อนที่จะถูกทำการถอดรหัสเพื่อนำไปตรวจสอบในตารางที่ 2.5 เข้าคู่รหัสสมอดูเลขชั้น 5/6 เพื่อแก้ปัญหาข้อมูลที่ได้จากวงจรวิเทอร์บีอาจไม่ตรงกับตารางค้นหา โดยการแก้ไขปัญหานั้นเนื่องมาจากข้อมูลที่ออกจากวงจรตรวจหาวิเทอร์บีอาจจะมีอยู่ในตารางค้นหา ซึ่งระยะทางยูคลิดสามารถหาได้จากสมการ

$$d(x_{j,k}, \hat{x}_j) = \sqrt{\sum_{i=0}^5 (x_{i,k} - \hat{x}_i)^2}, (7)$$

เมื่อ  $\hat{x}_k$  คือค่ารหัสที่ได้จากการตรวจหาในวงจรตรวจหาวิเทอร์บีและ  $x_{j,k}$  คือค่ารหัสลำดับที่  $j$  จากในตารางที่ 2.5 เข้าคู่รหัสสมอดูเลขชั้น 5/6 ในการถอดรหัสจะเลือกค่าถอดรหัสในลำดับที่  $j$  ที่ทำให้ค่า  $d(x_{j,k}, \hat{x}_j)$  มีค่าต่ำที่สุด

## บทที่ 3

### วิธีการดำเนินงาน

ในงานวิจัยนี้จะทำการประยุกต์ใช้กระบวนการเรียนรู้ของเครื่องเข้ามาประยุกต์ในการสร้างแบบจำลองการทำนายค่าบิตในช่องสัญญาณอ่านกลับของระบบการบันทึกข้อมูลเชิงแม่เหล็กแบบ BPMPR เพื่อเป็นตัวช่วยในการตัดสินใจสำหรับค่าบิตที่อ่านได้จากช่องสัญญาณโดยตรง ซึ่งการออกแบบงานวิจัยในแต่ละส่วนมีรายละเอียดดังต่อไปนี้

#### 3.1 การจำลองช่องสัญญาณแบบ BPMPR

ระบบการบันทึกข้อมูลแบบ BPMPR เป็นระบบการบันทึกข้อมูลที่เป็นอีกหนึ่งตัวเลือกที่จะเข้ามาแทนที่เทคโนโลยีการบันทึกข้อมูลแบบทั่วไป เนื่องจากการบันทึกข้อมูลแบบแนวตั้งนั้นเผชิญกับปัญหาข้อจำกัดทางซูเปอร์พาราแมกเนติก แต่อย่างไรก็ตามระบบการบันทึกข้อมูลแบบ BPMPR ต้องเผชิญกับปัญหาการแทรกสอดระหว่างแทร็ก ITI, การแทรกสอดระหว่างสัญลักษณ์ ISI, ปัญหาการอ่านไม่ตรงแทร็ก TMR และข้อผิดพลาดจากการเข้าจังหวะการเขียน เป็นต้น

เนื่องจากในปัจจุบันการนำเอากระบวนการเรียนรู้ของเครื่องเข้ามาผนวกกับการเรียนรู้เพื่อนำมาแก้ปัญหาในด้านต่าง ๆ นั้นให้ผลลัพธ์ที่น่าพึงพอใจ รวมไปถึงได้มีงานวิจัยที่นำเอากระบวนการเรียนรู้ของเครื่องนั้นเข้ามาประยุกต์ใช้ในสื่อบันทึกข้อมูลเชิงแม่เหล็กเพื่อเพิ่มประสิทธิภาพในด้านต่าง ๆ ได้อย่างมีประสิทธิภาพ [28], [29] อย่างไรก็ตามจากงานวิจัย [16] แบบจำลองช่องสัญญาณ BPMPR สามารถที่จะนำข้อมูลที่ออกจากช่องสัญญาณการอ่านกลับมาใช้ในการวิเคราะห์สำหรับการทำนายผลล่วงหน้าได้ ดังนั้นในงานวิทยานิพนธ์เล่มนี้จึงได้นำเสนอการประยุกต์กระบวนการเรียนรู้ของเครื่องในรูปแบบต่าง ๆ เข้ามาใช้ร่วมกับระบบการบันทึกข้อมูลแบบ BPMPR เพื่อใช้สำหรับการสร้างโมเดลการทำนายผลค่าบิตที่ออกจากช่องสัญญาณอ่านกลับ ซึ่งประกอบไปด้วยการเขียนโปรแกรมเพื่อจำลองการทำงานของช่องสัญญาณในระบบการบันทึกข้อมูลแบบ BPMPR, การเก็บข้อมูลจากช่องสัญญาณอ่านกลับเพื่อนำมาใช้ในการวิเคราะห์, การจัดรูปแบบชุดข้อมูลให้พร้อมสำหรับการนำไปใช้ และการสร้างโมเดลสำหรับการทำนายผล

การจำลองช่องสัญญาณแบบ BPMPR ผู้วิจัยได้ทำการสร้างช่องสัญญาณแบบหลายหัวอ่านและมีการเข้ารหัสมอดูเลชันที่ระดับ 5/6 ในช่องสัญญาณ BPMPR โดยอ้างอิงจากงานวิจัย [16] เพื่อ

สร้างช่องสัญญาณแบบ BPMPR สำหรับจำลองการทำงานที่ความหนาแน่น 3 Tbit/in<sup>2</sup> โดยสร้างจากสมการดังต่อไปนี้

$$r_{l,k} = \sum_n \sum_m h_{m,n} X_{l-m,k-n} + n_{l,k}, \quad (8)$$

$$h_{m,n} = A \exp \left\{ -\frac{1}{2c^2} \left[ \left( \frac{X+\Delta_X}{PW_X} \right)^2 + \left( \frac{Z+\Delta_Z+\Delta_Z}{PW_Z} \right)^2 \right] \right\}, \quad (9)$$


ตารางที่ 3.1 รายละเอียดของตัวแปรที่ใช้ในสมการจำลองช่องสัญญาณแบบ BPMPR

ตัวแปร	รายละเอียด	ค่า
$PW50_x$	ความกว้างสัญญาณพัลส์ที่หว่างแทร็ค	19.8 nm
$PW50_z$	ความกว้างสัญญาณพัลส์ที่ข้ามแทร็ค	24.8 nm
$T_x$	ระยะห่างระหว่างบิต	19.8 nm
$T_z$	ระยะห่างระหว่างแทร็ค	24.8 nm
$C$	ค่าคงที่	1/2.3548
$TMR$	หัวอ่านไม่ตรง offset	0 - 25
$SNR$	กำลังสัญญาณต่อกำลังสัญญาณรบกวน	5 - 25
$A_k$	ค่าบิตก่อนเขียนลงสื่อบันทึก	-1 และ 1
$R_k$	ค่าบิตที่ได้รับสัญญาณรบกวน	ค่าสัมประสิทธิ์
$Y_k$	ค่าบิตที่ได้รับสัญญาณรบกวน	ค่าสัมประสิทธิ์

ช่องสัญญาณที่ทำการนำเสนอ นั้น จะทำการแทนที่ของส่วนการประมวลผลสัญญาณที่ออกจากช่องสัญญาณ BPMPR แบบเดิมที่ต้องพึ่งพาการใช้งาน อีควอลไลเซอร์ (Equalizer) และตัวตรวจจับ (Detector) ดังภาพที่ 3.2 รูปแบบช่องสัญญาณ BPMPR ในแบบทั่วไปที่ใช้ อีควอลไลเซอร์ และ ตัวตรวจจับ เปลี่ยนไปใช้การทำนายผลของสัญญาณด้วยโมเดลการทำนายผล ดังภาพที่ 3.1 รูปแบบช่องสัญญาณ BPMPR ที่ใช้โมเดลการทำนายผลในระบบ BPMPR แบบหมุน (Spinning – disk system)



[30] ในที่นี้จะกล่าวถึงเฉพาะ การประมวลสัญญาณในระบบ BPMPR แบบหมุน ซึ่งมีลักษณะการทำงานที่ คล้ายกับระบบการบันทึกข้อมูลแบบที่ใช้กันทั่วไป (นั่นคือแบบแนวตั้งและแนวนอน)



ภาพที่ 3.1 รูปแบบช่องสัญญาณ BPMPR ที่ใช้ โมเดลการทำนายผล ภาพที่ 3.2 รูปแบบช่องสัญญาณ BPMPR ในแบบทั่วไปที่ใช้ อีควอลไลเซอร์ และ ตัวตรวจจับ

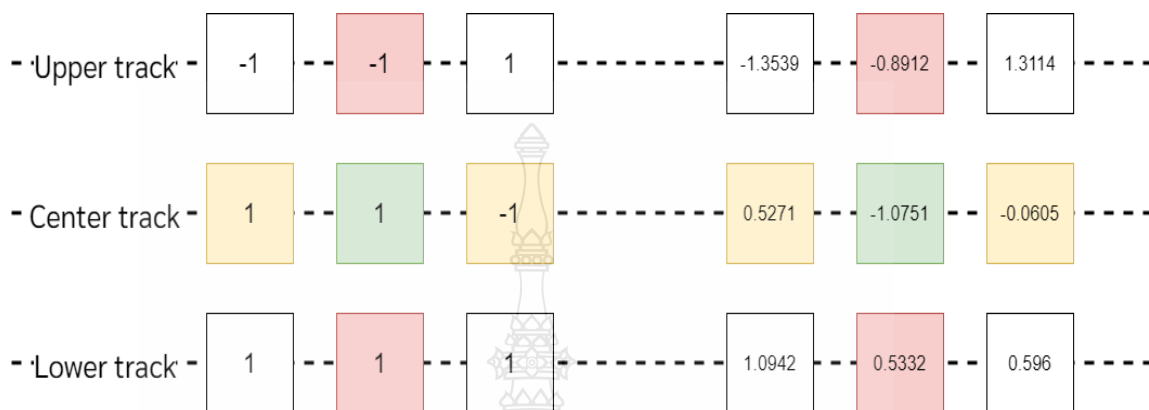
ดังนั้นช่องสัญญาณอ่านกลับของระบบ BPMPR จึงสามารถจำลองเป็นแผนภาพบล็อกแบบง่ายได้ดังภาพที่ 3.2 รูปแบบช่องสัญญาณ BPMPR ในแบบทั่วไปที่ใช้ อีควอลไลเซอร์ และ ตัวตรวจจับ ซึ่งประกอบด้วยช่องสัญญาณ (Channel), อีควอลไลเซอร์แบบผลตอบสนองบางส่วน (Partial-response equalizer), การมอดูเลชันโค้ดที่ระดับ 5/6 (Modulation code 5/6) และการใช้วงจรตรวจหาวิเทอร์บี (Viterbi detector) [21] ซึ่งแบบการจำลองระบบนั้นได้ใช้แบบจำลองสัญญาณอ่านกลับนั้นที่นำเสนอแนวคิดของ S. Nabavi ที่ศึกษาการประมาณค่าผลตอบสนองสัญญาณพัลส์ของระบบ BPMPR ในรูปแบบผลตอบสนองของสัญญาณพัลส์แบบสองมิติ [3] และการประมาณค่าผลตอบสนองของสัญญาณพัลส์ของระบบ BPMPR นั้น สัญญาณอ่านกลับที่ได้จากหัวอ่านจะเกิดจากการซ้อนทับแบบเชิงเส้น (Linear superposition) ของผลตอบสนองของสัญญาณพัลส์ของแทร็กหลัก (Main track) และแทร็กข้างเคียง (Adjacent track) หรืออาจกล่าวได้ว่าสัญญาณอ่านกลับที่ได้จากหัวอ่านมีผลกระทบที่เกิดจากการแทรกสอดแบบสองมิติ (2D interference) ซึ่งก็คือการแทรกสอดของสัญลักษณ์ (ISI: Inter-symbol interference) และการแทรกสอดระหว่างแทร็ก (ITI: Inter-track interference) การแทรกสอดแบบสองมิตินี้ มีผลทำให้สมรรถนะของระบบ BPMPR ต่ำลงอย่างมาก

### 3.2 การเก็บข้อมูลและจัดรูปแบบข้อมูล

ข้อมูลที่สร้างจากแบบจำลองแบบหลายหัวอ่านจะมีลักษณะในการทำงาน ดังแสดงในภาพที่

3.3 การจำลองการทำงานของช่องสัญญาณ BPMPR แบบหลายหัวอ่าน หัวอ่านที่จำลองขึ้นในระบบมี

ทั้งหมดสามหัวอ่าน ได้แก่ แทร็กบน (Upper track), แทร็กกลาง (Center track) และ แทร็กล่าง (Lower track) โดยข้อมูลก่อนที่จะถูกเขียนลงบนสื่อบันทึกจะถูกจัดเก็บเพื่อนำมาเป็นผลเฉลย และทำการเก็บข้อมูลจากช่องสัญญาณที่ถูกอ่านกลับมาเพื่อนำมาเป็นชุดสำหรับฝึกฝน




ภาพที่ 3.3 การจำลองการทำงานของช่องสัญญาณ BPMPR แบบหลายหัวอ่าน

โดยจะทำการสร้างชุดข้อมูลที่ประกอบไปด้วยตัวเลข -1 หมายถึงบิต 0 และ 1 หมายถึงบิต 1 โดยจะแยกตามค่าอัตราส่วนของกำลังสัญญาณต่อกำลังสัญญาณรบกวน (SNR: Signal-to-noise ratio) ที่ตั้งแต่ว่าระดับที่ 5 จนถึง 25 dB ซึ่งจะทำให้เพิ่มขึ้นทีละ 5 dB ในแต่ละครั้งของการจำลองช่องสัญญาณ และค่าหัวอ่านไม่ตรงแทร็ก (TMR: Track Mis-registration) มีค่าตั้งแต่บวกหรือลบที่ 0 จนถึง 25 ซึ่งจะทำให้เพิ่มขึ้นทีละ 5 เปอร์เซ็นต์ ในแต่ละครั้ง โดยจะทำการเก็บข้อมูลแยกตามประเภท SNR และ TMR ประเภทละ 100 บล็อก

การเก็บข้อมูลด้วยกลุ่มตัวอย่างจำนวนน้อยเกินไปจะส่งผลให้เราไม่สามารถอนุมานถึงภาพใหญ่ที่ต้องการได้อย่างแท้จริง อีกทั้งเมื่อกลุ่มตัวอย่างมีจำนวนน้อย แต่กลับบอกผลลัพธ์ในรูปของเปอร์เซ็นต์ อาจได้ผลลัพธ์ไม่น่าเชื่อถือ ดังนั้นในวิทยานิพนธ์เล่มนี้ จะทำการเก็บข้อมูลบิตจากช่องสัญญาณ BPMPR ให้มากที่สุดเท่าที่เป็นไปได้ เพื่อให้กลุ่มตัวอย่างของชุดข้อมูลมีขนาดใหญ่พอในการวิเคราะห์ และสร้างแบบจำลองโมเดลการทำนายผลสัญญาณอ่านกลับข้อมูลบิตที่มีประสิทธิภาพ

การสร้างชุดข้อมูลสำหรับฝึกฝนของโมเดลทำนายผลนั้น ดังภาพที่ 3.4 การเก็บค่าบิตจากแบบจำลองช่องสัญญาณ BPMPR แบบหลายหัวอ่าน โดยจะทำการจำลองการอ่านค่าบิตแบบ 3 หัวอ่านโดยหัวอ่านตัวที่หนึ่งทำหน้าที่ในการอ่านแทร็กด้านบน, หัวอ่านตัวที่สองทำหน้าที่ในการอ่านแทร็กกลาง และหัวอ่านตัวที่สามทำหน้าที่ในการอ่านแทร็กล่าง โดยจะทำการอ่านข้อมูลเป็นรูปแบบแนวยาวเรียงทีละ 3 แทร็ก จากปัญหาการอ่านข้อมูลจากช่องสัญญาณแบบ BPMPR ที่มีความหนาแน่น

สูง การอ่านข้อมูลบิตในแต่ละแตร็กจะได้รับสัญญาณรบกวนจากบิตข้างเคียง [19], [23] ที่ส่งผลทำให้สัญญาณอ่านกลับของข้อมูลบิตที่ได้รับนั้นด้อยประสิทธิภาพลง



ภาพที่ 3.4 การเก็บค่าบิตจากแบบจำลองช่องสัญญาณ BPMPR แบบหลายหัวอ่าน

ในการเก็บข้อมูลบิตเพื่อนำมาสร้างเป็นชุดข้อมูลนั้น ผู้วิจัยเลือกที่จะเก็บข้อมูลโดยรอบของบิตที่เป็นตำแหน่งหลักขณะที่หัวอ่านทำการอ่านข้อมูลบิตทั้งหมด 8 บิต เนื่องจากบิตโดยรอบสามารถส่งผลรบกวนการอ่านค่าบิตของหัวอ่านได้ โดยมีสัญญาณการแทรกสอดของสัญญาณแบบสองมิติ โดยค่าที่ได้จะอยู่ในลักษณะของเมตริกขนาด  $3 \times 3$  ที่แบ่งแต่ละตำแหน่งตั้งแต่ตำแหน่งที่ 1 จนถึง 9 (P1-P9) โดยทำการเก็บข้อมูลบิตจากช่องสัญญาณการบันทึกในรูปแบบ BPMPR โดยที่ P5 แสดงถึงตำแหน่งหลักที่หัวอ่านทำการอ่านข้อมูลอยู่ ณ ขณะนั้น

จำนวนแถว	จำนวนคอลัมน์
1222200	12

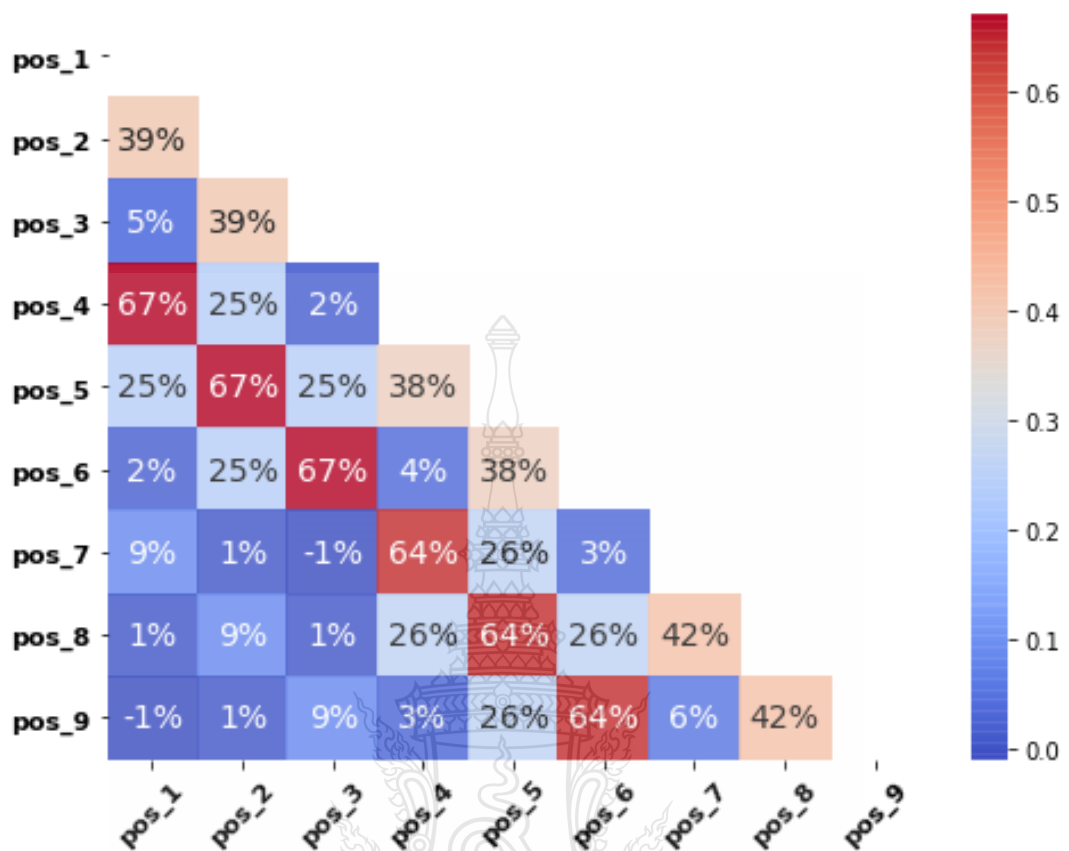
จากตารางที่ 3.2 รายละเอียดชุดข้อมูลที่เก็บจากช่องสัญญาณการบันทึกในรูปแบบ BPMPR ผู้วิจัยได้ทำการเก็บข้อมูลจากช่องสัญญาณโดยแบ่งการเก็บชุดข้อมูลกลุ่มตัวอย่างตามระดับของกำลังสัญญาณ (SNR : Noise-to-Signal Ratio) ตั้งแต่ระดับที่มีค่า 5 จนถึง 25 พร้อมทั้งจำแนกตามปัญหาการอ่านออกนอกแตร็ก (TMR: Track Mis-registration) ที่ระดับ 0 จนถึง  $\pm 25$  เปอร์เซนต์ที่มีความผันผวนของตำแหน่งไอแลนด์ (Position fluctuation) ตั้งแต่ 0 จนถึง 5 เปอร์เซนต์

ตารางที่ 3.2 รายละเอียดชุดข้อมูลที่เก็บจากช่องสัญญาณการบันทึกรูปแบบ BPMP

Labels	Description	Value
SNR	กำลังสัญญาณต่อกำลังสัญญาณรบกวน	มีค่าตั้งแต่ 5 ถึง 25 เพิ่มขึ้นทีละ 5
TMR	ค่าหัวอ่านไม่ตรงแท็กรีก	มีค่าตั้งแต่ 0 ถึง $\pm 25$ เพิ่มขึ้นทีละ 5
Position 1	ตำแหน่งบิตด้านซ้ายบนของบิตหลัก	ค่าสัมประสิทธิ์
Position 2	ตำแหน่งบิตด้านบนของบิตหลัก	ค่าสัมประสิทธิ์
Position 3	ตำแหน่งบิตด้านขวาบนของบิตหลัก	ค่าสัมประสิทธิ์
Position 4	ตำแหน่งบิตด้านซ้ายของบิตหลัก	ค่าสัมประสิทธิ์
Position 5	ตำแหน่งของบิตหลัก	ค่าสัมประสิทธิ์
Position 6	ตำแหน่งบิตด้านขวาของบิตหลัก	ค่าสัมประสิทธิ์
Position 7	ตำแหน่งบิตด้านซ้ายล่างของบิตหลัก	ค่าสัมประสิทธิ์
Position 8	ตำแหน่งบิตด้านล่างของบิตหลัก	ค่าสัมประสิทธิ์
Position 9	ตำแหน่งบิตด้านขวาล่างของบิตหลัก	ค่าสัมประสิทธิ์
Target	ค่าบิตหนักก่อนบันทึก	ค่าบิต -1 และ 1

### 3.3 การหาความสัมพันธ์ของข้อมูล

การหาความสัมพันธ์ของข้อมูลจากการสร้างแผนภาพความร้อน (Heatmap) โดยสร้างตามค่าสหสัมพันธ์ (Correlation) ของชุดข้อมูล เพื่อทำการศึกษาความสัมพันธ์ระหว่างแต่ละตัวแปรในจุดข้อมูล จากการสังเกตการณ์จากแผนภาพที่สร้างขึ้น ดังแสดงในภาพที่ 3.5 แผนภาพความร้อนความสัมพันธ์ของแต่ละตัวแปร จะสามารถระบุถึงความสัมพันธ์ของตัวแปรที่มีความสัมพันธ์ที่ส่งเสริมกันอันได้แก่ ตำแหน่งที่ 2 (Position 2) กับ ตำแหน่งที่ 8 (Position 8) มีผลกับตำแหน่งที่ 5 (Position 5) โดยมีค่าสหสัมพันธ์อยู่ที่ 0.63 ทำให้สามารถระบุได้ว่าตำแหน่งที่ 2 และ 8 มีผลกับการผกผันของข้อมูลในตำแหน่งที่ 5 ทั้งนี้ การที่ตัวแปรทั้งสองตัว มีค่าสหสัมพันธ์แสดงออกถึงความสัมพันธ์กันนั้น หมายความว่า ตัวแปรทั้งสองมีแนวโน้มจะไปในทางเดียวกัน



ภาพที่ 3.5 แผนภาพความร้อนความสัมพันธ์ของแต่ละตัวแปร

การหาความสัมพันธ์ระหว่างข้อมูลบิตในตำแหน่งหลัก (POS\_5) กับข้อมูลบิตในตำแหน่งโดยรอบ วิเคราะห์ข้อมูลด้วยใช้ค่าสัมประสิทธิ์สหสัมพันธ์ของเพียร์สัน (Pearson product moment correlation coefficient) ซึ่งเป็นการศึกษาความสัมพันธ์เชิงเส้น (Linear relationship) ระหว่างตัวแปรสองตัว มีข้อตกลงเบื้องต้น คือ ตัวแปรทั้งสองต้องเป็นตัวแปรต่อเนื่อง อยู่ในมาตราอันตรภาคชั้น (Interval scale) ขึ้นไป และมีการแจกแจงปกติสองตัวแปร (Bivariate normal distribution) โดยค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สัน จะมีค่าอยู่ระหว่าง -1 ถึง +1 ถ้า เข้าใกล้  $\pm 1$  หมายความว่า ตัวแปรทั้งสองมีความสัมพันธ์กันอยู่ในระดับมาก ถ้าสัมประสิทธิ์สหสัมพันธ์มีค่าเข้าใกล้ 0 หมายความว่า ตัวแปรทั้งสองมีความสัมพันธ์กันในระดับน้อยหรือไม่สัมพันธ์กันเลย เครื่องหมายบวก ( $\pm$ ) จะแสดงทิศทางของความสัมพันธ์ว่ามีทิศทางเป็นแบบใด ตัวอย่างโดยเกณฑ์การแปลผลระดับความสัมพันธ์มีดังนี้

ตารางที่ 3.3 ระดับความสัมพันธ์ของเพียร์สัน

ค่าสัมประสิทธิ์สหสัมพันธ์ของเพียร์สัน	ความหมายของระดับความสัมพันธ์
$\pm 0.81 - \pm 1.00$	มีความสัมพันธ์อยู่ในระดับสูงมาก
$\pm 0.61 - \pm 0.81$	มีความสัมพันธ์อยู่ในระดับสูง
$\pm 0.41 - \pm 0.60$	มีความสัมพันธ์อยู่ในระดับปานกลาง
$\pm 0.21 - \pm 0.40$	มีความสัมพันธ์อยู่ในระดับต่ำ
$\pm 0.00 - \pm 0.20$	มีความสัมพันธ์อยู่ในระดับสูงต่ำมาก

โดยที่ค่าสัมประสิทธิ์สหสัมพันธ์จะมีค่าระหว่าง  $-1 < r < 1$

ค่า  $r$  เป็นลบ แสดงว่า  $X$  และ  $Y$  มีความสัมพันธ์กันในทิศทางตรงกันข้าม

ค่า  $r$  เป็นบวก แสดงว่า  $X$  และ  $Y$  มีความสัมพันธ์กันในทิศทางเดียวกัน

ค่า  $r$  เป็นศูนย์ แสดงว่า  $X$  และ  $Y$  ไม่มีความสัมพันธ์กันเลย

### 3.4 กระบวนการสร้างโมเดลการทำนายผล

การเลือกคุณลักษณะสำคัญเพื่อนำมาฝึกฝน ที่ระบบการบันทึกข้อมูลแบบ BPMPR นั้นต้องเผชิญกับปัญหาการแทรกสอดระหว่างแทร็ก และการแทรกสอดระหว่างสัญลักษณ์ที่มีความรุนแรง ซึ่งส่งผลกับการอ่านค่าบิตของแทร็กหลัก (Main track) จากปัจจัยเหล่านี้การเลือกคุณลักษณะที่มีความสัมพันธ์ซึ่งกันและกัน ผู้วิจัยได้ทำการเลือกแทร็กข้างเคียง (Adjacent track) ที่ล้อมรอบระหว่างแทร็กหลักอยู่มาใช้เป็นค่าคุณสมบัติในการเรียนรู้ในชุดฝึกฝนโมเดล ซึ่งประกอบไปด้วยค่าสัมประสิทธิ์จากตำแหน่งที่ 1 – 9 และเลือกผลเฉลยของตำแหน่งหลักเป็นคอลัมน์ target ในกระบวนการเรียนรู้ผู้วิจัยได้ทำการสร้างโมเดลการจำแนกประเภท (Classification model) โดยจะทำการสร้างโมเดลการเรียนรู้ขึ้นมาจำนวนหนึ่งจากหลากหลายอัลกอริทึม และทำการเปรียบเทียบโมเดลต่าง ๆ จากการเรียนรู้และฝึกฝนของโมเดลที่มีรูปแบบแตกต่างกัน โดยจะทำการแบ่งข้อมูลเป็น 2 ส่วนได้แก่ ชุดข้อมูลที่ใช้สำหรับฝึกฝน (Training set) แบ่งเป็น 70 เปอร์เซ็นต์จากชุดข้อมูลทั้งหมด และชุดข้อมูลสำหรับทดสอบ (Test Set) ถูกแบ่งเป็น 30 เปอร์เซ็นต์จากชุดข้อมูลทั้งหมด ดังแสดงในตารางที่ 3.4 การแบ่ง

จำนวนชุดข้อมูล สำหรับฝึกฝนและทดสอบโมเดล แล้วทำการแทนที่ข้อมูลทั้งหมดในคอลัมน์ Target จาก -1 เป็น 0 ในการเลือกโมเดลการจำแนกประเภทที่นำมาใช้ในการฝึกฝน ผู้วิจัยได้ทำการแบ่งการฝึกฝนโมเดลการจำแนกประเภททั้งหมดดังต่อไปนี้

**ตารางที่ 3.4** การแบ่งจำนวนชุดข้อมูล สำหรับฝึกฝนและทดสอบโมเดล

จำนวนข้อมูลที่ให้ฝึกฝน	จำนวนข้อมูลที่ให้ทดสอบ
855540	366660

**ตารางที่ 3.5** โมเดลทั้งหมดที่ใช้ในการฝึกฝนโมเดลการทำนายผล สัญญาณอ่านกลับจากช่องสัญญาณการบันทึกข้อมูลรูปแบบ BPMR

โมเดล
K-Neighbors Classifier
Decision Tree Classifier
Random Forest Classifier
Ada Boost Classifier
Gradient Boosting Classifier
Gaussian NB
Linear Discriminant Analysis
Quadratic Discriminant Analysis
Logistic Regression
GX Boosting
Deep Learning

## บทที่ 4

### ผลการวิเคราะห์ข้อมูล

ในบทนี้ผู้วิจัยจะทำการกล่าวถึงการประยุกต์ใช้โมเดล เพื่อการทำนายผลลัพธ์ของค่าเอาต์พุต ที่ออกจากช่องสัญญาณในระบบ BPMPR โดยการนำชุดข้อมูลที่ได้จากการจำลองการทำงานของระบบ การบันทึกข้อมูลแบบ BPMPR มาใช้ในการฝึกฝนชุดโมเดล และทำการเปรียบเทียบสมรรถนะของ โมเดลต่าง ๆ โดยทำการแบ่งเนื้อหาออกเป็น 2 ส่วน โดยงานส่วนที่ 1.) การประยุกต์ใช้เทคนิค กระบวนการเรียนรู้ของเครื่องในการสร้างโมเดลสำหรับการทำนายผลข้อมูลบิตที่ได้รับผลกระทบหรือ ลดทอนคุณภาพสัญญาณ 2.) การวัดผลลัพธ์ความถูกต้องในการทำนายผลข้อมูลบิตของแต่ละโมเดลและ เปรียบเทียบสมรรถนะของโมเดล

#### 4.1 การสร้างโมเดลสำหรับการทำนายผล

ในวิทยานิพนธ์เล่มนี้จะทำนายผลค่าบิตที่ออกจากช่องสัญญาณรูปแบบ BPMPR ที่มีความหนาแน่นเชิงพื้นที่ 3 Tbit/in<sup>2</sup> เนื่องจากชุดข้อมูลที่ได้รับเกิดจากการจำลองโดยใช้สมการทำให้ชุด ข้อมูลที่มีอยู่มีคุณภาพสูงและพร้อมใช้งาน จนไม่จำเป็นต้องทำการกระบวนการทำความสะอาดข้อมูล (Data cleaning) และจากการหาความสัมพันธ์ของชุดข้อมูลในแต่ละปัจจัย เพื่อหาความสัมพันธ์กับ ปัจจัยที่มีความน่าสนใจเพื่อนำมาใช้ในการอธิบายปัจจัยที่ส่งผลกับสมรรถนะของช่องสัญญาณ BPMPR ซึ่งจากสมมติฐานผู้วิจัยได้แนบไปยังปัญหาการแทรกสอดแบบสองมิติที่เกิดขึ้นในช่องสัญญาณที่มีความหนาแน่นสูงจะส่งผลกระทบต่อความรุนแรงของการแทรกสอดที่เพิ่มขึ้นในช่องสัญญาณ จนทำให้แทรกโดยรอบส่งผลกระทบต่อกระบวนการอ่านข้อมูลบิตในตำแหน่งเป้าหมาย เพราะฉะนั้นแทรกโดยรอบที่ ส่งผลให้ข้อมูลในแทรกหลักเกิดความผิดพลาดโดยมีนัยสำคัญบางอย่าง จากชุดข้อมูลที่มีอยู่นั้น เมื่อทำการแบ่งชุดข้อมูลในการฝึกฝนและทดสอบ ผู้วิจัยได้ทำการแบ่งการฝึกฝนโมเดลการจำแนกประเภทโดยใช้อัลกอริทึมที่หลากหลาย ในการหาโมเดลที่สามารถทำงานได้มีประสิทธิภาพที่ดีที่สุด จากทั้งหมดโดยมีโมเดลดังต่อไปนี้ K-Neighbors Classifier, Decision Tree Classifier, Random Forest Classifier, Ada Boost Classifier, Gradient Boosting Classifier, Gaussian NB, Linear Discriminant Analysis, Quadratic Discriminant Analysis, Logistic Regression, GX Boosting และ Deep Learning รวมทั้งสิ้น 11 โมเดล เพื่อนำโมเดลเหล่านี้มาการทำนายผลค่าสัญญาณที่อ่านกลับที่ออกจากช่องสัญญาณรูปแบบ BPMPR โดยจะทำการวิเคราะห์สมรรถนะการทำงานของแต่



ละโมเดล และทำการปรับแต่งการฝึกฝนโมเดลด้วยวิธีการใช้ไฮเปอร์พารามิเตอร์ (Hyperparameters) เพื่อหาค่าที่ใช้ในการปรับแต่งการทำงานของโมเดลที่ดีที่สุดเท่าที่จะสามารถเป็นไปได้ จากผลการดำเนินงานทำให้ทราบว่าโมเดลบางกลุ่มที่ไม่สามารถให้ผลลัพธ์ของประสิทธิภาพในการทำนายผลที่ดีที่สุดได้ แม้จะทำการปรับแต่งการฝึกฝนด้วยการใช้ไฮเปอร์พารามิเตอร์เข้ามาช่วยในการฝึกฝนโมเดลก็ตามก็ยังไม่สามารถให้ผลลัพธ์ที่น่าพึงพอใจได้ และโมเดลบางกลุ่มที่สามารถให้ผลลัพธ์ของการทำนายผลที่ประสิทธิภาพดียิ่งขึ้นจากการปรับแต่งด้วยการใช้วิธีการไฮเปอร์พารามิเตอร์

#### 4.2 ผลลัพธ์จากการสร้างโมเดลและการวัดสมรรถนะ

การสร้างโมเดลการเรียนรู้ขึ้นมาจำนวนหนึ่งและทำการเปรียบเทียบทั้งหมด จากการเรียนรู้และฝึกฝนของโมเดลที่มีรูปแบบเรียนรู้ของอัลกอริทึมที่แตกต่างกัน โดยผลลัพธ์การทำนายผลของแต่ละโมเดลการจำแนกประเภท (Classification Model) นั้นมีลักษณะการทำนายผลเป็นแบบไบนารี (Binary Classification) โดยสามารถให้ผลลัพธ์ของคำตอบได้เพียง “จริง” หรือ “เท็จ” เท่านั้น จากการศึกษาจากแบบจำลองช่องสัญญาณ BPMPR ที่ใช้โมเดลการทำนายผล ที่ได้รับผลกระทบจากการแทรกสอดแบบสองมิติ, การอ่านของหัวอ่านที่ไม่ตรงตำแหน่ง, และสัญญาณรบกวนจากความผันผวนของตำแหน่งบิตโดยรอบ ในช่องสัญญาณ BPMPR ที่ความหนาแน่นเชิงพื้นที่ 3 Tbit/in<sup>2</sup> และมีการเข้ารหัสสัญญาณมอดูเลชันโค้ดที่อัตราส่วน 5/6 โดยในงานวิทยานิพนธ์เล่มนี้ทางผู้ทำการวัดประสิทธิภาพการทำนายผลของแบบจำลองโมเดลการทำนายผลที่สร้างขึ้นด้วยกัน 2 วิธี ได้แก่ การวัดประสิทธิภาพด้วยค่าความแม่นยำร่วมกับฟังก์ชันการสูญเสีย (Accuracy & Loss function) และการวัดประสิทธิภาพด้วยอัตราความผิดพลาดของข้อมูลบิต (Bit-error ratio) ต่อกำลังสัญญาณ (Signal-to-noise ratio) เพื่อให้แน่ใจว่าโมเดลการทำนายผลข้อมูลบิตในช่องสัญญาณ BPMPR ที่สร้างขึ้นมีแนวโน้มของความถูกต้องในการวัดประสิทธิภาพของแต่ละโมเดลเป็นไปในทิศทางเดียวกัน

การประเมินความสามารถของโมเดลโดยมักใช้การแสดงผลที่อยู่ในรูปของ เมตริกทางตัวเลข หรือ ภาพกราฟิก ในงานวิทยานิพนธ์เล่มนี้เลือกใช้การแสดงผลการประเมินสมรรถนะของโมเดลด้วยการใช้เมตริกทางตัวเลขด้วยคอนฟิวชันเมตริก (Confusion matrix) ในการวัดประสิทธิภาพของความแม่นยำร่วมกับฟังก์ชันการสูญเสีย ดังภาพที่ 4.1 การเปรียบเทียบผลลัพธ์ในแต่ละโมเดลในรูปแบบคอนฟิวชันเมตริก (Confusion Matrix) ซึ่งประกอบไปด้วยโมเดลทั้งหมดดังต่อไปนี้ K-Neighbors Classifier, Decision Tree Classifier, Random Forest Classifier, Ada Boost Classifier, Gradient Boosting Classifier, Gaussian NB, Linear Discriminant Analysis, Quadratic Discriminant Analysis, Logistic Regression, GX Boosting, และ Deep Learning

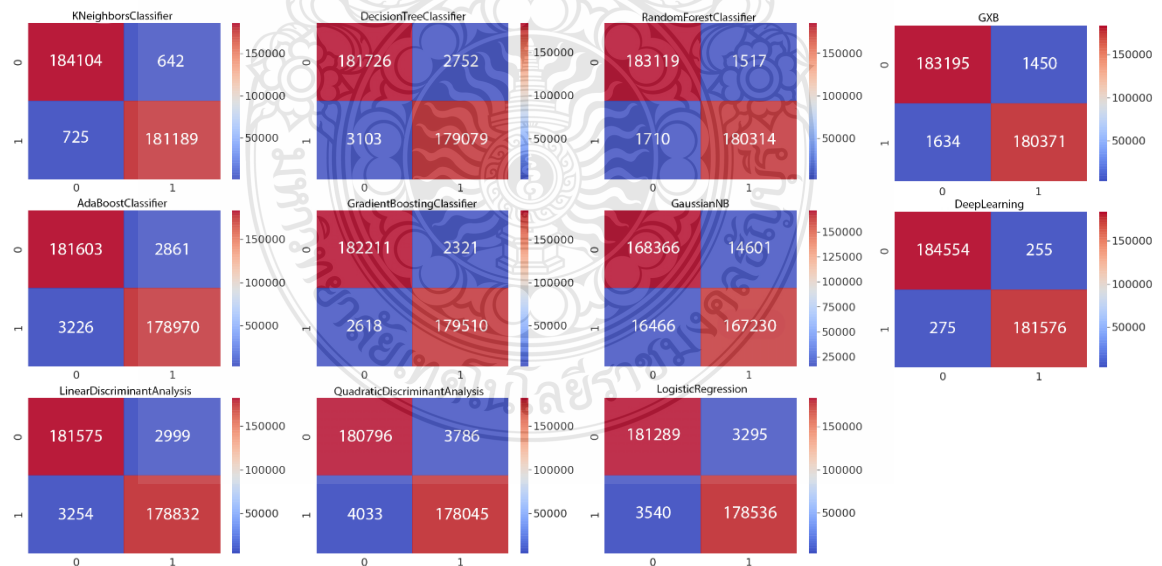
**ตารางที่ 4.1** การเปรียบเทียบผลลัพธ์ค่าเฉลี่ยจากการวัดประสิทธิภาพการทำนายผล ด้วยค่าความแม่นยำ (Accuracy) และฟังก์ชันการสูญเสีย (Loss function) ของแต่ละโมเดล

โมเดล	Accuracy	Loss
K-Neighbors Classifier	99.6324	0.0403
Decision Tree Classifier	98.4029	0.5507
Random Forest Classifier	99.1294	0.0325
Ada Boost Classifier	98.3434	0.6071
Gradient Boosting Classifier	98.6538	0.0447
Gaussian NB	91.5276	0.2224
Linear Discriminant Analysis	98.5764	0.0561
Quadratic Discriminant Analysis	97.8791	0.0574
Logistic Regression	98.8359	0.0631
GX Boosting	99.4675	0.0841
Deep Learning	99.9126	0.0029

ตั้งผลลัพธ์ของตารางที่ 4.1 การเปรียบเทียบผลลัพธ์ค่าเฉลี่ยจากการวัดประสิทธิภาพการทำนายผล ด้วยค่าความแม่นยำ (Accuracy) และฟังก์ชันการสูญเสีย (Loss function) ของแต่ละโมเดล จากการพิจารณาพบว่าโมเดลที่สามารถทำงานได้ดีที่สุด โดยที่ให้ค่าความแม่นยำที่มากที่สุด และมีค่าฟังก์ชันการสูญเสียน้อยที่สุด ได้แก่ โมเดลแบบ Deep learning ที่มีค่าความแม่นยำอยู่ที่ 99.91 และค่าของฟังก์ชันการสูญเสียอยู่ที่ 0.0029 จากการทดสอบการทำนายผลจากชุดข้อมูลทดสอบนั้น ผลลัพธ์จากตารางที่ 4.1 การเปรียบเทียบผลลัพธ์ค่าเฉลี่ยจากการวัดประสิทธิภาพการทำนายผล ด้วยค่าความแม่นยำ (Accuracy) และฟังก์ชันการสูญเสีย (Loss function) ของแต่ละโมเดล ได้แสดงให้เห็นถึงการทำนายผลที่ผิดพลาดที่น้อยที่สุด เมื่อทำการเปรียบกับโมเดลที่ทำการทดสอบทั้งหมด

ตารางที่ 4.2 ผลลัพธ์การทำนายที่ได้จากคอนฟิวชันเมตริก (Confusion Matrix)

Classifier	True	False	True	False
	Positive	Positive	Negative	Negative
KNeighbors Classifier	184104	642	181189	725
Decision Tree Classifier	181726	2752	179079	3103
Random Forest Classifier	183119	1517	180314	1710
AdaBoost Classifier	181603	2861	178970	3226
Gradient Boosting Classifier	182211	2321	179510	2618
Gaussian NB	168366	14601	167230	16466
Linear Discriminant Analysis	181575	2999	178832	3254
Quadratic Discriminant Analysis	180796	3786	178045	4033
Logistic Regression	181289	3295	178536	3540
GX Boosting	183195	1450	180371	1634
Deep Learning	184554	255	181576	275




ภาพที่ 4.1 การเปรียบเทียบผลลัพธ์ในแต่ละโมเดลในรูปแบบคอนฟิวชันเมตริก (Confusion Matrix)

ตารางที่ 4.3 เปรียบเทียบค่า Precision และ Recall ของแต่ละอัลกอริทึม

โมเดล	Precision		Recall	
	Bit 0	Bit 1	Bit 0	Bit 1
KNeighbors Classifier	0.9965	0.9960	0.9960	0.9964
Decision Tree Classifier	0.9851	0.9829	0.9832	0.9848
Random Forest Classifier	0.9917	0.9906	0.9907	0.9916
AdaBoost Classifier	0.9844	0.9822	0.9826	0.9842
Gradient Boosting Classifier	0.9874	0.9856	0.9858	0.9872
Gaussian NB	0.9201	0.9103	0.9109	0.9197
Linear Discriminant Analysis	0.9837	0.9821	0.9823	0.9835
Quadratic Discriminant Analysis	0.9794	0.9778	0.9781	0.9791
Logistic Regression	0.9821	0.9805	0.9808	0.9818
GX Boosting	0.9921	0.9910	0.9911	0.9920
Deep Learning	0.9986	0.9986	0.9984	0.9985

การส่งข้อมูลหรือการรับข้อมูลทางดิจิทัล จำนวนข้อมูลบิตที่ผิดพลาดจากการรับส่งข้อมูลจากช่องทางการสื่อสารที่ได้รับผลกระทบหรือการรบกวนจากสัญญาณรบกวนภายในช่องสัญญาณ, การบิดเบือนของสัญญาณ หรือแม้แต่ข้อผิดพลาดของการเข้ารหัสที่ไม่ต่อเนื่องกันในช่องสัญญาณ ในการทดสอบด้วยอัตราความผิดพลาดของบิต (BER: Bit-error ratio) ต่อกำลังสัญญาณนั้น เป็นการวัดอัตราความผิดพลาดของข้อมูลบิตต่อจำนวนข้อมูลบิตที่ทำการส่งทั้งหมดในช่วงระยะเวลาที่ทำการวัดผล โดยส่วนใหญ่การวัดผลลัพธ์ของอัตราความผิดพลาดของบิตต่อกำลังสัญญาณในการบันทึกข้อมูลเชิงแม่เหล็กในรูปแบบ BPMPR ช่องสัญญาณที่ให้ค่าความผิดพลาดของ BER ต่ำกว่า  $10^{-4}$  ที่ใช้กำลังสัญญาณ (SNR: signal-to-noise ratio) ที่ต่ำที่สุดในหน่วยเดซิเบล จากการเลือกโมเดลเข้ามาใช้ในการเปรียบเทียบประสิทธิภาพโดยเลือกมาจากโมเดลทั้งหมดเพียงบางส่วนจากโมเดลทั้งหมด ได้แก่ K-Neighbors Classifier, Decision Tree Classifier, Random Forest Classifier, Ada Boost

Classifier, Gradient Boosting Classifier ,Gaussian NB, GXB และ Deep learning นำมาสร้างเป็นแผนภาพการเปรียบเทียบแบบจำลองโมเดลการทำนายผลดังภาพที่ 4.2 การวัดประสิทธิภาพการทำนายผลด้วยอัตราความผิดพลาดของบิตต่อกำลังสัญญาณ โดยมีแกนแนวนอน (X) คือระดับของ SNR และแกนแนวตั้ง (Y) คือระดับของค่า BER จากการพิจารณาแบบภาพพบว่าโมเดลที่สามารถให้ประสิทธิภาพในการทำงานได้ดีที่สุดนั้นคือ Deep learning (เส้นประสีเหลือง) โดยสามารถให้ค่า BER ที่  $10^{-4}$  โดยใช้ค่ากำลังสัญญาณ SNR เพียง 11 เดซิเบล ( dB: Decibel)



ภาพที่ 4.2 การวัดประสิทธิภาพการทำนายผลด้วยอัตราความผิดพลาดของบิตต่อกำลังสัญญาณ

## บทที่ 5

### สรุปผลการทดลองและข้อเสนอแนะ

การนำเอากระบวนการเรียนรู้ของเครื่อง (Machine learning) เข้ามาช่วยในการทำนายผลสัญญาณอ่านกลับของช่องสัญญาณแบบ BPMPR นั้น จากการทดสอบโมเดลการจำแนกประเภทของสัญญาณอ่านกลับที่ได้รับผลกระทบจากการแทรกสอดแบบสองมิติ (2D interference) อันได้แก่ การแทรกสอดระหว่างสัญลักษณ์ (ISI), การแทรกสอดระหว่างแทร็ก (ITI), การอ่านของหัวอ่านที่ไม่ตรงตำแหน่งหรือแทร็กมิสเรจิสเตรชัน (TMR), และสัญญาณรบกวนจากความผันผวนของตำแหน่งบิตโดยรอบ (Position fluctuation) ซึ่งส่งผลทำให้ความสามารถของช่องสัญญาณรูปแบบ BPMPR ด้วยประสิทธิภาพ โดยการนำเอาโมเดลการทำนายผลเข้ามาใช้แทนที่อีควอลไลเซอร์ และตัวตรวจจับแบบเดิม สามารถทำนายผลในสภาพแวดล้อมที่มีการรบกวนของสัญญาณรบกวนได้เป็นอย่างดี

#### 5.1 สรุปผลการทดลอง

การนำกระบวนการเรียนรู้ของเครื่องเข้ามาช่วยในการสร้างโมเดลการทำนายผล เข้ามาใช้แทนที่ อีควอลไลเซอร์ และตัวตรวจจับของระบบการบันทึกข้อมูลเชิงแม่เหล็กแบบเดิมนั้น เบื้องต้นสามารถทำนายผลสัญญาณอ่านกลับข้อมูลบิตที่ออกจากช่องสัญญาณได้มีประสิทธิภาพพอสมควร โดยโมเดลที่สามารถให้ผลลัพธ์ความถูกต้องดีที่สุด เมื่อเปรียบเทียบกับทุกโมเดลนั้นคือ Deep Learning ที่ให้ค่า BER (Bit error rate) ต่ำกว่า  $10^{-4}$  ที่ระดับ SNR (Signal-to-noise ratio) ต่ำกว่า 11 dB และให้ความแม่นยำของโมเดลในการทดสอบโมเดลอยู่ที่สูงที่สุดมากกว่า 99.91 เปอร์เซ็นต์ โดยที่มีการลดทอนประสิทธิภาพของระบบจากสภาพแวดล้อมที่มีสัญญาณรบกวนต่าง ๆ เพิ่มเข้ามาในช่องสัญญาณ

#### 5.2 ข้อเสนอแนะ

ในหัวข้อนี้จะกล่าวถึงประเด็นต่าง ๆ ที่ผู้วิจัยพบเจอในขณะที่ทำการศึกษาและพัฒนาโมเดลการทำนายผลค่าบิตที่ออกจากช่องสัญญาณ BPMPR ว่ามีประเด็นใดบ้างที่จะต้องคำนึงถึง และปัญหาต่าง ๆ ที่พบในการสร้างโมเดลการจำแนกประเภทที่ยังไม่ได้ทำการค้นหาคำตอบ หากมีผู้วิจัยท่านอื่นต้องการที่จะศึกษาในด้านนี้เพิ่มเติม

1. จากข้อมูลที่ได้เก็บรวบรวมจากช่องสัญญาณ BPMR เราได้จำแนกเก็บข้อมูลที่มักเกิดปัญหาในช่องสัญญาณแบบ BPMR เพียงส่วนหนึ่งเท่านั้น อันได้แก่ การแทรกสอดระหว่างสัญลักษณ์ (ISI), การแทรกสอดระหว่างแตรีก (ITI), การอ่านของหัวอ่านที่ไม่ตรงตำแหน่ง (TMR), และสัญญาณรบกวนจากความผันผวนของตำแหน่งบิตโดยรอบ (Position fluctuation) ซึ่งปัญหาเหล่านี้ยังไม่ครอบคลุมปัญหาที่เกิดขึ้นในช่องสัญญาณแบบ BPMR ทั้งหมด ทั้งนี้ยังมีอีกหลากหลายปัจจัยที่สามารถส่งผลกระทบต่อประสิทธิภาพการทำงานของช่องสัญญาณ BPMR ได้

2. จากการสร้างโมเดลทำนายผล และทำนายเปรียบเทียบโมเดลทั้งหมด Deep learning คือโมเดลที่สามารถทำงานได้มีประสิทธิภาพมากที่สุด แต่เนื่องจากโมเดลที่ผู้วิจัยได้สร้างขึ้นนั้น มีขนาดของ Hidden layers ที่อาจจะเยอะเกินความจำเป็น ซึ่งผู้วิจัยทำการฝึกฝนโมเดลจากการกำหนดค่า Hyper parameter เพื่อทำการหาค่าที่ดีที่สุด ซึ่งใช้เวลาในการเรียนรู้ที่นานเกินความจำเป็น และค่าเหล่านี้ที่ผู้วิจัยได้กำหนดในการฝึกฝนโมเดลเหล่านี้ก็อาจจะยังไม่ได้เป็นค่าที่ดีที่สุด

3. จากการตรวจสอบข้อมูลการที่โมเดลได้ทำการทำนายผล ผู้วิจัยพบว่าปัญหาที่ส่งผลให้โมเดลทำนายผลไม่ถูกต้อง นั้นมักเกิดจากปัญหาการอ่านของหัวอ่านที่ไม่ตรงตำแหน่ง ที่มีค่าความผิดเพี้ยนของหัวอ่านตั้งแต่  $\pm 20$  เฟอร์เซ็นต์ ในระดับของกำลังสัญญาณ SNR ที่ต่ำกว่า 15 เดซิเบล เป็นต้นไป จะส่งผลกระทบต่อการทำนายผลของโมเดลเป็นอย่างมาก

4. การทำนายผลของโมเดลส่วนใหญ่ในช่องสัญญาณ BPMR ที่เราได้จำลองขึ้นมา นั้นเราได้ทำการเพิ่มการเข้ารหัสสัญญาณก่อนที่จะเขียนลงบนช่องสัญญาณ BPMR ด้วยการใช้การเข้ารหัสมอดูเลชันโค้ดที่ระดับ 5/6 หากสังเกตจากชุดข้อมูลที่เราทำการเก็บข้อมูลจากช่องสัญญาณจะพบว่ามีอัตราส่วนของข้อมูลเป็นลบมากกว่าบวกเล็กน้อย และรูปแบบการเข้ารหัสที่เราได้เลือกใช้นั้นก็มีข้อมูลที่เป็นลบมากกว่าบวกเล็กน้อยเช่นกัน ซึ่งจากปัญหาเหล่านี้จากส่งผลให้โมเดลทำนายผลมีแนวโน้มในการให้หน้าหนักการทำนายผลข้อมูลบิตที่เป็นลบมากกว่าบวก

## บรรณานุกรม

- [1] ศูนย์วิจัยกสิกรไทย, “แนวโน้มอุตสาหกรรมฮาร์ดดิสก์ไดรฟ์ (Hard Disk Drive) ปี 2562,” 21 กุมภาพันธ์ 2019. [ออนไลน์]. Available: [https://kasikornbank.com/international-business/th/Thailand/IndustryBusiness/Pages/201902\\_Thailand\\_HDD\\_outlook2019.aspx](https://kasikornbank.com/international-business/th/Thailand/IndustryBusiness/Pages/201902_Thailand_HDD_outlook2019.aspx). [วันที่เข้าถึง 20 มิถุนายน 2021].
- [2] Y. Shiroishi, K. Fukuda, I. Tagawa, H. Iwasaki, S. Takenoiri, H. Tanaka, H. Mutoh and N. Yoshikawa, "Future Options for HDD Storage," *IEEE Transactions on Magnetics*, vol. 45, pp. 3816-3822, 2009.
- [3] S. Nabavi, Signal Processing for bit-patterned media channels with inter-track interference., ProQuest, 2008.
- [4] A. L. Samuel, "Some Studies in Machine Learning Using the Game of Checkers," *IBM Journal of Research and Development*, pp. 210 - 229, 1959.
- [5] P. Louridas and C. Ebert, "Machine Learning," *IEEE Software*, vol. 33, no. 5, pp. 110-115, 2016.
- [6] S. Raschka, Python Machine Learning, Packt Publishing, 2019.
- [7] N. Noparat, “การเรียนรู้แบบเสริมกำลัง (Reinforcement Learning),” 4 พฤศจิกายน 2020. [ออนไลน์]. Available: <https://bigdata.go.th/big-data-101/introduction-to-reinforcement-learning/>. [วันที่เข้าถึง 17 กรกฎาคม 2021].
- [8] S. Asiri, "Machine Learning Classifiers," 11 January 2018. [Online]. Available: <https://towardsdatascience.com/machine-learning-classifiers-a5cc4e1b0623>. [Accessed 1 November 2020].



## บรรณานุกรม (ต่อ)

- [9] T. Shah, "About Train, Validation and Test Sets in Machine Learning," 6 December 2017. [Online]. Available: <https://towardsdatascience.com/train-validation-and-test-sets-72cb40cba9e7>. [Accessed 17 July 2021].
- [10] "Overfitting," [ออนไลน์]. Available: <https://en.wikipedia.org/wiki/Overfitting>. [Accessed 1 November 2020].
- [11] P. Bhandari, "Type I and Type II errors," 7 January 2021. [Online]. Available: <https://www.scribbr.com/statistics/type-i-and-type-ii-errors/>. [Accessed 10 July 2021].
- [12] S. Bhattacharya, "Model Evaluation Techniques for Classification models," 6 December 2018. [Online]. Available: <https://medium.com/@saikatbhattacharya/model-evaluation-techniques-for-classification-models-eac30092c38b>. [Accessed 20 July 2021].
- [13] J. Hu, T. M. Duman, E. M. Kurtas and M. F. Erden, "Bit-Patterned Media With Written-In Errors: Modeling, Detection, and Theoretical Limits," *IEEE Transactions on Magnetics*, vol. 43, no. 8, pp. 3517-3524, 2007.
- [14] T. R. Albrecht, H. A. Arora and V. Ayanoor-Vitikkate, "Bit-Patterned Magnetic Recording: Theory, Media Fabrication, and Recording Performance," *IEEE Transactions on Magnetics*, vol. 51, no. 5, 2015.
- [15] A. Arrayangkool, C. Warisarn and P. Kovintavewat, "A constructive inter-track interference coding scheme for bit-patterned media recording system," *Journal of Applied Physics*, vol. 15, no. 17, 2014.
- [16] C. Warisarn, W. Busyatras and M. L. M. M. , "Soft-information flipping approach in multi-head multi-track BPMP systems," *AIP Advances*, vol. 8, no. 5, 2018.

## บรรณานุกรม (ต่อ)

- [17] C. Warisan, A. Arrayangkool and P. Kovintaviwat, "An ITI-Mitigating 5/6 Modulation Code for Bit-Patterned Media Recording," *IEICE Transactions on Electronics*, vol. E98.C, no. 6, pp. 528-533, 2015.
- [18] C. Buajong and C. Warisarn, "Multitrack reading scheme with single reader in BPMR systems," *2017 International Electrical Engineering Congress (iEECON)*, Pattaya, Thailand, 2017.
- [19] A. Arrayangkool, C. Warisarn, L. M. M. Myint and P. Kovintavewat, "A Simple Recorded-Bit Patterning Scheme for Bit-Patterned Media Recording," in *2013 10th International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology*, Krabi, Thailand, 2013.
- [20] W. Chang and J. R. Cruz, "Inter-Track Interference Mitigation for Bit-Patterned Magnetic Recording," *IEEE Transactions on Magnetics*, vol 46, no. 11, pp. 3899 - 3908, 2010.
- [21] G. Forney, "Maximum-likelihood sequence estimation of digital sequences in the presence of intersymbol interference," *IEEE Transactions on Information Theory*, vol. 18, no. 3, pp. 363 - 378, 1972.
- [22] S. Nabavi, B. V. K. V. Kumar and J. A. Bain, "Mitigating the Effects of Track Mis-Registration in Bit-Patterned Media," *2008 IEEE International Conference on Communications, Beijing*, pp. 2061-2065, 2008.
- [23] C. Warisarn, "Mitigating the Effects of Track Mis-Registration in Single-Reader/Two-Track Reading BPMR Systems," *IEEE Transactions on Magnetics*, vol. 55, no. 7, pp. 1-6, 2019.

## บรรณานุกรม (ต่อ)

- [24] W. Busyatras, C. Warisarn, M. L. M. M. and P. Kovintavewat, "A TMR Mitigation Method Based on Readback Signal in Bit-Patterned Media Recording," *IEICE Transactions on Electronics*, vol E98.C, no. 8, pp. 892-898, 2015.
- [25] ก. บัวหิ่ง, ว. บุษยาตรัส และ ช. วริสาร, "อิทธิพลของสัญญาณรบกวนสื่อบันทึกต่อการเข้ารหัสมอดูเลชันแบบสองมิติสำหรับระบบ BPMP ที่ใช้สื่อบันทึกแบบเยื้อง," ใน *งานประชุมทางวิชาการระดับชาติครั้งที่ 9 มหาวิทยาลัยราชภัฏนครศรีธรรมราช*, จังหวัดนครปฐม, 2017.
- [26] ส. กุลการชาย, ช. วริสาร และ ป. โควินท์ทวิวัฒน์, การประเมินผลสัญญาณสำหรับการจัดเก็บข้อมูลดิจิทัล เล่ม 4 วงจรภาครับขั้นสูงสำหรับ BPMP และ TDMP, บริษัท เพชรเกษม พรีนติ้ง กรุ๊ป จำกัด, 2017.
- [27] K. Buahing, W. Busyatras and C. Warisarn, "A Rate-5/6 2D Modulation Code for Single-Reader/Two-Track Reading in BPMP Systems.," in *2018 IEEE International Magnetism Conference (INTERMAG)*, Singapore, 2018.
- [28] A. Sayyafan, B. J. Belzer and K. Sivakumar, "Deep Neural Network Based Media Noise Predictors for Use in High-Density Magnetic Recording Turbo-Detectors," *IEEE Transactions on Magnetism*, vol. 55, no. 12, pp. 1-6, 2019.
- [29] K. Luo, S. Wang, G. Xie, W. Chen and P. Lu, "Read Channel Modeling and Neural Network Block Predictor for Two-Dimensional Magnetic Recording," *IEEE Transactions on Magnetism*, vol. 56, no. 1, 2019.
- [30] C. Ross, "Patterned Magnetic Recording Media," *Annual Review of Materials Research*, vol. 31, no. 1, pp. 203-235, 2001.



ภาคผนวก

# The Readback Signal Prediction based on Machine Learning Technique in Bit Patterned Media Recording System

Trairatana Termsanthia\*, Pitaya Poompuang, Anucha Tungkasthan and Wiparat Busyatras

*Faculty of Science and Technology*

*Rajamangala University of Technology Thanyaburi, Thailand*

*trairatana\_t@mail.rmutt.ac.th\*, p\_pitaya@rmutt.ac.th, anucha\_t@rmutt.ac.th,*

*wiparat\_b@rmutt.ac.th*

## Abstract

*The Bit patterned media recording (BPMR) system is the new challenge technology for the magnetic recording systems to be produced in the future. The readback signal of the BPMR system included 2D interference as inter-track interference (ITI) and inter-symbol interference (ISI) to decrease system performance. Therefore, the data of these readback signals were interesting for finding the new model technique from machine learning to analyze about characteristics of the actual readback signal without ISI and ITI. Previous work used the machine learning technique to describe the readback signal of the Two-dimensional magnetic recording (TDMR) system. The TDMR is one of the new challenging technology for magnetic recording systems also. Therefore, in this work, we would like to use the machine learning technique such as K-Neighbors, Decision Tree, Random Forest, AdaBoost, Logistic Regression, Deep Learning, etc. A classification model is used to predict the actual readback signal output without 2D interference, track misregistration (TMR) and position jitter problems in the BPMR system. The new models can predict and perform accuracy percentage more than 90% from all models in the simulation result, especially in Deep Learning, can achieve higher accuracy than 99% and lower loss.*

**Keywords:** Machine Learning (ML), Deep Learning, 2D interference, Track misregistration (TMR), Bit-pattern media recording (BPMR)

## 1. Introduction

Currently, the machine learning technique is applied for data analytic to improve the performance system. As same as in the magnetic recording system that included ISI and ITI problem in the system. The Bit patterned media

recording (BPMR) is the new challenge technology for the magnetic recording system produced in the future [1-3]. In [4-5] proposed, a Two-dimensional (2D) magnetic recording (TDMR) can be analyzed with a machine learning technique to improve the performance system.

Therefore, in this proposed method, we found data of readback signal in the BPMR system included 2D interference, TMR and position jitter. It is exciting to become analyze and apply the machine learning technique in the BPMR system. In the machine learning technique, we focus on several algorithms that can perform the classification model to predict the target of readback signal data and offer the label or classification as a binary result, +1 and -1. Then, this work begins with studying the readback signal of the BPMR system for preparing the data process and using these data for sending to several algorithms as our focus. Finally, we compared the model of each algorithm and described it in accuracy percentage. We founded all algorithm accuracy more than 90%, and these results of this proposed method can be used in the BPMR system for improved performance in the future.

This paper is organized as follows. In Section II, the BPMR channel model is described. Section III explains the proposed method with data preparation. The simulation results are given in Section IV. Finally, Section V concludes this paper.

## 2. BPMR channel model

For the readback signal output, we generate the discrete-time BPMR channel model equation [6-8] as depicted in Fig. 1. The binary input sequence is encoded by 5/6 modulation code to reduce the initial 2D interference problem. We used multiple read-head (3T/3H) to readable the primary bit and surrounded bits signal from the

BPMR channel, which was all track corrupted by additive white Gaussian noise (AWGN). the readback signal of the data bit can be computing as

$$r_{l,k} = \sum_n \sum_m h_{m,n} x_{l-m,k-n} + n_{l,k}, \quad (1)$$

where  $x_{l,k}$  's are the recorded bits,  $h_{m,n}$  's are the 2D channel coefficients,  $m$  and  $n$  represent the time indices of bit in the across-track and the along-track directions, and  $n_{l,k}$  is an additive white Gaussian noise (AWGN) with zero mean and variance  $\sigma^2$ . BPMR channel coefficients  $h_{m,n}$  can be generated by sampling a 2D Gaussian pulse response at the integer multiples of the bit period,  $T_x$ , and the track period,  $T_z$ ,  $\Delta_T$  is the track misregistration (TMR),  $\Delta_X$  and  $\Delta_Z$  are along- and across-track location fluctuation or position jitter according to


$$h_{m,n} = P(nT_z + \Delta_T + \Delta_Z, mT_x + \Delta_X). \quad (2)$$

In practically, the BPMR channel coefficients  $h_{m,n}$  can be generated by sampling a 2D Gaussian pulse response at the integer multiples of the bit period,  $T_x$ , and the track period,  $T_z$ , according to


$$P(z, x) = A \exp \left\{ -\frac{1}{2c^2} \left[ \left( \frac{x + \Delta_X}{PW_x} \right)^2 + \left( \frac{z + \Delta_T + \Delta_Z}{PW_z} \right)^2 \right] \right\}, \quad (3)$$

where  $A = 1$  is assumed to be the peak amplitude of the pulse response,  $PW_x$  is the  $PW_{50}$  of the along-track pulse,  $PW_z$  is the  $PW_{50}$  of the across-track pulse,  $PW_{50}$  is the pulse width at half its maximum,  $c = 1/2.3548$  is a constant to account for the relationship between  $PW_{50}$  and the standard deviation of a Gaussian.

This paper focuses only on the data of the readback signal  $r_{l,k}$  for  $l \in \{0, \pm 1\}$  from the BPMR channel model before sending it to a 2D Viterbi detector algorithm. In the value of  $r_{l,k}$  is coefficient value for representing estimated binary bit as +1 and -1. This proposed method uses the coefficient of  $r_{l,k}$  for preparing the data before sending it to several algorithms of machine learning [9-11].



**Fig. 1.** A BPMR channel model diagram with the rate 5/6 modulation code scheme.



**Fig. 2.** The proposed method diagram with prediction models.

### 3. Proposed method

In this proposed method, the data of the readback signal is prepared and used for creating the prediction models as Fig. 2. In the data preparation, we prepare the dataset from the bit readback signal,  $r_{l,k}$  of the BPMR channel. It embedded the signal-to-noise ratio (SNR) level between 5 to 25 decibels (dB), TMR level between -25 to 25 percentage and position jitters to 0 to 5 percentage. In (4) and Table 1 explain the position of data preparation. For example, with preparing data of  $x_{l,k}$  and  $r_{l,k}$  with SNR = 5, TMR = 0% can be prepared data as


$$r_{l,k} = \begin{bmatrix} 1.2590^{P1} & 1.3623^{P2} & -0.9293^{P3} & \dots \\ -1.0125^{P4} & -0.0409^{P5} & -1.6620^{P6} & \dots \\ -1.9078^{P7} & -0.3522^{P8} & 1.0118^{P9} & \dots \end{bmatrix} \dots \quad (4)$$

$$x_{l,k} = \begin{bmatrix} 1 & 1 & -1 & \dots \\ -1 & 1 & -1 & \dots \\ -1 & 1 & 1 & \dots \end{bmatrix} \dots$$

**Table 1: Dataset schema**

Dataset of BPMR			
Label	Description	Value	Example
SNR	Signal-to-noise Ratio	5,10,15,20,25 in dB	5 dB
TMR	Track mis-registration	$\pm$ {0,5,10,15,20,25} in %	0 %
POS_1	Bits position 1	coefficient	1.2590
POS_2	Bits position 2	coefficient	1.3623
POS_3	Bits position 3	coefficient	-0.9293
POS_4	Bits position 4	coefficient	-1.0125
POS_5	Bits position 5	coefficient	-0.0409
POS_6	Bits position 6	coefficient	-1.6620
POS_7	Bits position 7	coefficient	-1.9078
POS_8	Bits position 8	coefficient	-0.3522
POS_9	Bits position 9	coefficient	1.0118
Target	Native Bits	-1 or 1	1

The dataset schema showed in Table 1; we create the dataset by collecting data from the bit's read back signal of the multi-read heads. The dataset consists of 9 coefficients in each position, and we would like to predict the centre bit value at position 5. In the data of all, we generate the dataset of around 2,500 sectors for the training classification model. Then, we generate the dataset of around 1,000 sectors for testing the classification model. A 1 sector equals 4096 bits. In this proposed system method, the dataset testing schema is the same as the training dataset.




**Fig. 3.** A heat map correlation matrix to compare the correlation of each variable.

We plotted heatmap correlation matrices for exploring the correlation of each feature, as showed in Fig 3. We focused on features that highly correlated with bit position 5. Based on our finding, the heatmap indicated ITI and ISI position is the highest correlation with the primary position or data bit position 5 and represent the percentage of heatmap as 67% to 38%, respectively. When we prepared the data, we used these data. We sent them to the supervised model as K-Neighbors, Decision Tree, Random Forest, AdaBoost, Gradient Boosting, Gaussian NB, Logistic Regression, XGBOOST and Deep Learning to generate the new model to predict the estimated recording bit  $\hat{x}_{l,k}$ .

#### 4. Simulation result

This work proposed a new way to detect the estimate record bit from the readback signal in the BPMR system. The prediction models were created through various machine learning algorithms. In this work, we focus on a binary classification model of supervised learning. The binary classification is the task of classifying the set elements into two groups that mean the output on our prediction model can be only two answers, -1 or 1. We created multiple classification models for comparing the performance. The results of comparing models are shown in Table 2. In the simulation result, we found that the accuracy percentage of all models performs high accuracy in predicting over 90%. Especially in the Deep Learning algorithm can offer an accuracy percentage of around 99% with lower loss. However, this technique proposed only predicts the probability of the readback signal. It can not confirm the performance in a practical use system. However, we calculate the BER performances from the processing of Fig. 2 by comparing between  $x_{l,k}$  and  $\hat{x}_{l,k}$  without a complete conventional system as Fig. 1. This research can offer high performance at the Deep Learning model as Fig. 4. In this work, the coefficients of the data set included all SNR, TMR and position jitters levels for training the classification models. Interestingly, this work can perform the high accuracy percentage performance of all models, especially in the Deep Learning of a neural network.





**Fig. 4.** BER performance comparison of different models separated by SNR levels that added TMR with position jitter problems.

**Table 2: Accuracy percentage**

Accuracy percentage by models		
Models	Accuracy	Loss
KNeighbors Classifier	99.6324	0.0403
DecisionTree Classifier	98.4029	0.5507
RandomForest Classifier	99.1294	0.0325
AdaBoost Classifier	98.3434	0.6071
GradientBoosting Classifier	98.6538	0.0447
GaussianNB	91.5276	0.2224
XGB	99.4675	0.0841
LogisticRegression	98.8359	0.0631
Deep Learning	99.9126	0.0029

## 5. Conclusion

This work considers the 2D-interference, TMR and position jitter problem, especially TMR and 2D-interference known as ITI and ISI, affected the performance of the respective classification model. We use the readback signal from the 5/6 encoding on the BPMR system to reduce the ITI and ISI problem severity and improve classification model performance. Finally, the Deep Learning of a neural network is the most accurate predictive model.

## Acknowledgement

This work was supported by the Faculty of Science and Technology RajaMangala University of Technology Thanyaburi (RMUTT), Thailand.

## References

- [1] S. Nabavi, Signal processing for bit-patterned media channels with inter-track, Carnegie Mellon University, Pittsburg: PhD thesis, 2008.
- [2] Y. Shiroishi et al., "Future Options for HDD Storage," IEEE Transactions on Magnetics, vol. 45, no. 10, pp. 3816-3822, 2009.
- [3] T. R. Albrecht et al., "Bit Patterned Magnetic Recording: Theory, Media Fabrication, and Recording Performance," IEEE Transactions on Magnetics, vol. 51, no. 1, pp. 1-42, 2015.
- [4] K. Luo et al., "Read Channel Modeling and Neural Network Block Predictor for Two-Dimensional Magnetic Recording," in IEEE Transactions on Magnetics, vol. 56, no. 1, pp. 1-5, Jan. 2020.
- [5] Y. Qin and J. -G. Zhu, "Automatically Resolving Intertrack Interference With Convolution Neural Network Detection Channel in TDMR," in IEEE Transactions on Magnetics, vol. 57, no. 2, pp. 1-6, Feb. 2021.
- [6] R. Radhakrishnan, N. Varnica and M. Öberg, "Estimation of areal density gains of TDMR system with 2D detector," in 2014 International Symposium on Information Theory and its Applications, 2014.
- [7] C. Warisarn, W. Busyatras and L. M. M. Myint, "Soft-information flipping approach in multi-head multi-track BPMR systems," in 62nd Annual Conference on Magnetism and Magnetic Materials and Collection, 2017.
- [8] K. Buahing, W. Busyatras and C. Warisarn, "A Rate-5/6 2D Modulation Code for Single-Reader/Two-Track Reading in BPMR Systems.," in 018 IEEE International Magnetics Conference (INTERMAG), 2018.
- [9] A. Arrayangkool et al., "A Simple Recorded-Bit Patterning Scheme for Bit-Patterned Media Recording," in International Conference on Electrical Engineering/Electronics, Computer, Telecommunications and Information Technology, ECTI-CON, 2013.
- [10] Y. Dong and R. H. Victora, "Micromagnetic Specification for Bit Patterned Recording at 4 Tbit/in<sup>2</sup>," IEEE Transactions on Magnetics, vol. 47, no. 10, pp. 2652-2655, 2011.
- [11] A. Sayyafan, B. J. Belzer, K. Sivakumar, J. Shen, K. S. Chan and A. James, "Deep Neural Network Based Media Noise Predictors for Use in High-Density Magnetic Recording Turbo-Detectors," in IEEE Transactions on Magnetics, vol. 55, no. 12, pp. 1-6, Dec. 2019.



## ประวัติผู้เขียน

ชื่อ - นามสกุล	นายไตรรัตน์ เต็มสันเทียะ
วัน เดือน ปี	22 พฤษภาคม 2540
ที่อยู่	114/355 หมู่ที่ 1 ต.ลำผักกูด อ.ธัญบุรี จ.ปทุมธานี 12110
ประวัติการศึกษา	สำเร็จการศึกษาระดับมัธยมปลาย จากโรงเรียนสารสาสน์วิเทศรังสิต เมื่อปี พ.ศ. 2558 สำเร็จการศึกษาระดับปริญญาตรี วิทยาศาสตร์บัณฑิต จากมหาวิทยาลัยเทคโนโลยีราชมงคลธัญบุรี เมื่อปี พ.ศ. 2562
ประวัติการทำงาน	
พ.ศ. 2562 - ปัจจุบัน	ตำแหน่งวิศวกรซอฟต์แวร์
อีเมล	trairatana_t@mutt.ac.th
ผลงานวิจัย	

ไตรรัตน์ เต็มสันเทียะ, “The Readback Signal Prediction based on Machine Learning Technique in Bit Patterned Media Recording System”, The 36th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC 2021), ระหว่างวันที่ 28 – 30 มิถุนายน 2564, โรงแรมแกรนด์ ไฮแอท เอเซีย สาธารณรัฐเกาหลี