

การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น

นางสาวอุไรวรรณ มีแสง

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตรมหาบัณฑิต
สาขาวิชาระบบสารสนเทศเพื่อการจัดการ
บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
ปีการศึกษา 2568

ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น

นางสาวอุไรวรรณ มีแสง

การค้นคว้าอิสระนี้เป็นส่วนหนึ่งของการศึกษาหลักสูตร
วิทยาศาสตรมหาบัณฑิต
สาขาวิชาระบบสารสนเทศเพื่อการจัดการ
บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
ปีการศึกษา 2568
ลิขสิทธิ์ของมหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



ใบรับรองการค้นคว้าอิสระ

บัณฑิตวิทยาลัย มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

เรื่อง การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น

โดย นางสาวอุไรวรรณ มีแสง

ได้รับอนุมัติให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาระบบสารสนเทศเพื่อการจัดการ

คณบดีคณะเทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัล

.....

(ผู้ช่วยศาสตราจารย์ ดร.สุนันฑา สดสี)

คณะกรรมการสอบการค้นคว้าอิสระ

..... ประธาน

(รองศาสตราจารย์ ดร.ศิรปัฐช์ บุญครอง)

..... อาจารย์ที่ปรึกษา

(ผู้ช่วยศาสตราจารย์ ดร.ธนพล เจนสุทธิเวชกุล)

..... กรรมการ

(ผู้ช่วยศาสตราจารย์ ดร.ณัฐวี อุตกฤษฎ์)

ชื่อ : นางสาวอุไรวรรณ มีแสง
ชื่อการค้นคว้าอิสระ : การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น
สาขาวิชา : ระบบสารสนเทศเพื่อการจัดการ
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ
อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก : ผู้ช่วยศาสตราจารย์ ดร.ธนพล เจนสุทธิเวชกุล
ปีการศึกษา : 2568

บทคัดย่อ

การศึกษาวิจัยนี้ มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบประสิทธิภาพของแบบจำลองการจำแนกข้อมูล ได้แก่ SVM, XGBoost, Naïve Bayes, Random Forest และ Neural Network ในการพยากรณ์ผลสัมฤทธิ์ทางการเรียน 5 ระดับ โดยเก็บข้อมูลจากนักเรียนระดับชั้น ปวช. ใน 5 สาขายอดนิยม ด้วยวิธีการสุ่มแบบเจาะจง โดยใช้ Google Tools ในการจัดเก็บและเตรียมข้อมูล และนำมาวิเคราะห์ด้วยโปรแกรม RapidMiner โดยแบ่งเป็นข้อมูลสำหรับฝึกฝน 70% และทดสอบ 30% ประเมินประสิทธิภาพด้วยค่าความแม่นยำ ค่าความเที่ยงตรง ค่าระลึก และค่า F1-Score ผลการวิจัยพบว่า XGBoost มีประสิทธิภาพในการพยากรณ์สูงสุด โดยมีค่าความแม่นยำอยู่ที่ 85.47% รองลงมาคือ Random Forest มีค่าความแม่นยำ 85.05% และ SVM มีค่าความแม่นยำ 78.12% ตามลำดับ ในขณะที่ Naïve Bayes และ Neural Network มีค่าความแม่นยำต่ำกว่าสมมติฐานที่ตั้งไว้ เมื่อพิจารณาน้ำหนักความสำคัญของปัจจัยที่มีผลต่อการพยากรณ์ พบว่าปัจจัยด้านผลการเรียนในวิชาคณิตศาสตร์ (ค่าน้ำหนัก 0.83) และวิชาภาษาอังกฤษ (ค่าน้ำหนัก 0.11) เป็นปัจจัยหลักที่ส่งผลมากที่สุด ขณะที่ปัจจัยด้านบุคลิกภาพ 5 องค์ประกอบ พบว่ามีเพียงด้านความไม่มั่นคงทางอารมณ์ (Neuroticism) เท่านั้นที่มีอิทธิพลต่อ การพยากรณ์ (ค่าน้ำหนัก 0.07) ทั้งนี้ผลการวิจัยสามารถนำไปประยุกต์ใช้ในการพัฒนาเครื่องมือ เพื่อประเมินศักยภาพของนักเรียน เพื่อเลือกสาขาวิชาที่สอดคล้องกับบุคลิกภาพเฉพาะบุคคล ซึ่งจะช่วยลดปัญหาการเลือกเรียนผิดสาขาและเพิ่มโอกาสประสบความสำเร็จในสายอาชีพต่อไป

(มีจำนวนทั้งสิ้น 94 หน้า)

คำสำคัญ : เทคนิคการจำแนก, บุคลิกภาพ 5 องค์ประกอบ, การพยากรณ์ผลสัมฤทธิ์ทางการเรียน, XGboost, ความไม่มั่นคงทางอารมณ์

_____ อาจารย์ที่ปรึกษาการค้นคว้าอิสระหลัก

Name : Miss Uraiwan Meesang

Independent Study Title : Predicting Academic Achievement of Vocational Certificate Using the Big Five Personality Factors and Core Subject Grades in Lower Secondary School

Major Field : Management Information Systems
King Mongkut's University of Technology North Bangkok

Independent Study Advisor : Assistant Professor Dr. Tanapon Jensuttiwetchakul

Academic Year : 2025

ABSTRACT

This research aimed to develop and compare data classification models—namely SVM, XGBoost, Naïve Bayes, Random Forest, and Neural Network—for predicting academic achievement across five levels. The sample consisted of 500 vocational students from five popular majors, selected via purposive sampling. Data were collected using Google tools and analyzed with RapidMiner software. The dataset was partitioned into a 70% training set and a 30% testing set, with model performance evaluated using Accuracy, Precision, Recall, and F1-Score. The results revealed that the XGBoost algorithm yielded the highest predictive accuracy at 85.47%, followed by Random Forest (85.05%) and SVM (78.12%). Conversely, Naïve Bayes and Neural Network yielded lower accuracies due to the complexity of the multi-class prediction target. Feature importance analysis indicated that previous academic performance in Mathematics and English were the primary influential factors. Among the Big Five personality traits, only Neuroticism demonstrated an influence on the prediction. Ultimately, these findings can be applied to develop an educational guidance tool, assisting students in selecting suitable majors to mitigate mismatched educational choices and enhance prospects for future careers.

(Total 94 Pages)

Keywords: Data Classification, Big Five Personality Factors, Academic Achievement Prediction, XGBoost Algorithm, Neuroticism

_____ Advisor

กิตติกรรมประกาศ

การศึกษาค้นคว้าอิสระฉบับนี้สำเร็จลุล่วงได้ด้วยความกรุณาและความช่วยเหลืออย่างดียิ่งจาก ผู้ช่วยศาสตราจารย์ ดร. ธนพล เจนสุทธิเวชกุล อาจารย์ที่ปรึกษา ที่ได้สละเวลาอันมีค่าในการให้คำปรึกษา ตรวจทานโครงร่าง และข้อเสนอแนะที่เป็นประโยชน์ต่อการดำเนินงานวิจัยฉบับนี้ ทำให้การศึกษาค้นคว้าอิสระมีเนื้อหาที่ครบถ้วนสมบูรณ์

ขอกราบขอบพระคุณคณาจารย์ในภาควิชาการจัดการเทคโนโลยีสารสนเทศ คณะเทคโนโลยีสารสนเทศและนวัตกรรมดิจิทัลทุกท่าน ที่ได้ถ่ายทอดองค์ความรู้ ประสบการณ์ และคำแนะนำ ตลอดระยะเวลาการศึกษา อันเป็นพื้นฐานสำคัญที่ทำให้ผู้วิจัยสามารถนำองค์ความรู้มาประยุกต์ใช้ในการศึกษาค้นคว้าอิสระได้อย่างมีประสิทธิภาพ

ขอขอบคุณคณะผู้บริหาร และคณะครูวิทยาลัยเทคนิคราชบุรี โดยเฉพาะอย่างยิ่งหัวหน้าสาขาวิชาช่างยนต์ ช่างกลโรงงาน ช่างไฟฟ้า การบัญชี และเทคโนโลยีธุรกิจดิจิทัล ที่ให้การสนับสนุนและอำนวยความสะดวกในการเก็บรวบรวมข้อมูลจากนักเรียนกลุ่มเป้าหมาย ทำให้ผู้วิจัยได้รับข้อมูลที่ครบถ้วนและเพียงพอต่อการวิเคราะห์

สุดท้ายนี้ คุณค่าและประโยชน์อันพึงมีจากการศึกษาค้นคว้าอิสระฉบับนี้ ผู้วิจัยขอมอบให้เพื่อเป็นความกตัญญูกตเวทีแด่บิดา มารดา ครูอาจารย์ และผู้มีพระคุณทุกท่าน ที่ได้ให้การสนับสนุนและเป็นกำลังใจสำคัญแก่ผู้วิจัยเสมอมา

อุไรวรรณ มีแสง

สารบัญ

หน้า

บทคัดย่อภาษาไทย ..... ข
บทคัดย่อภาษาอังกฤษ ..... ค
กิตติกรรมประกาศ ..... ง
สารบัญ ..... จ
สารบัญตาราง ..... ช
สารบัญรูปภาพ ..... ซ
บทที่ 1 บทนำ 1
1.1 ความเป็นมาและความสำคัญของปัญหา 1
1.2 วัตถุประสงค์ของงานวิจัย 2
1.3 คำถามงานวิจัย 3
1.4 สมมติฐาน 3
1.5 ขอบเขตงานวิจัย 3
1.6 ประโยชน์ที่คาดว่าจะได้รับ 5
1.7 นิยามคำศัพท์ 5
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง 7
2.1 หลักสูตรประกาศนียบัตรวิชาชีพ (ปวช.) พุทธศักราช 2567 7
2.2 ทฤษฎีบุคลิกภาพ 5 องค์ประกอบ (Big Five Personality Factors) 10
2.3 เทคนิคการจำแนกข้อมูล (Classification Techniques) 12
2.4 เทคนิคการปรับข้อมูลไม่สมดุลกัน (Imbalanced Data) 19
2.5 การวัดประสิทธิภาพของแบบจำลองพหุคลาส (Multi Class Metrics) 21
2.6 ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation) 23
2.7 ค่าน้ำหนักความสำคัญ (Weight By Gini Index) 24
2.8 งานวิจัยที่เกี่ยวข้อง (Related Research) 25
บทที่ 3 วิธีดำเนินงานวิจัย 42
3.1 กรอบแนวคิดของงานวิจัย 42
3.2 การเก็บรวบรวมข้อมูล 43
3.3 การเตรียมข้อมูล 48
3.4 การสร้างและพัฒนาแบบจำลอง (Model Construction) 50

สารบัญ (ต่อ)

หน้า

3.5 การประเมินผลประสิทธิภาพ (Performance Evaluation) 56
3.6 การนำผลวิจัยไปใช้ (Deployment) 57
บทที่ 4 ผลการวิจัย 60
4.1 การเปรียบเทียบปัจจัยที่ผลต่อการพยากรณ์ผลสัมฤทธิ์ทางการเรียน ระดับชั้น ปวช. 60
4.2 การเปรียบเทียบประสิทธิภาพอัลกอริทึมที่ใช้พยากรณ์ผลสัมฤทธิ์ทางการเรียน ในระดับปวช. 62
4.3 ต้นแบบระบบทำนายผลสัมฤทธิ์ทางการเรียน (Grade Prediction) 65
บทที่ 5 สรุปผล อภิปรายผล และข้อเสนอแนะ 69
5.1 สรุปผลการวิจัย 69
5.2 อภิปรายผลการวิจัย 70
5.3 ข้อเสนอแนะ 72
บรรณานุกรม 73
ภาคผนวก 80
ภาคผนวก ก ตัวอย่างเครื่องมือสำหรับเก็บรวบรวมข้อมูล 81
ภาคผนวก ข แบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียน จากโปรแกรม Rapid Miner Studio 84
ภาคผนวก ค การสร้างหน้าส่วนติดต่อผู้ใช้ด้วยภาษาไพทอน 90
ประวัติผู้เขียน 94

สารบัญตาราง

ตารางที่ หน้า

2-1 เกณฑ์การแปลความหมายตามแนวคิดของ Best 24
2-2 สรุปงานวิจัยที่เกี่ยวข้อง 29
3-1 แสดงคำถามฉบับภาษาอังกฤษและภาษาไทย 44
3-2 เกณฑ์การประเมิน 47
3-3 สัดส่วนของตัวแปรเป้าหมายก่อนการปรับสมดุลให้ชุดข้อมูล 49
3-4 แสดงจำนวนการปรับสมดุลให้กับชุดข้อมูลด้วยเทคนิคการสุ่ม 49
3-5 แสดงร้อยละการปรับสมดุลให้กับชุดข้อมูลด้วยเทคนิคการสุ่มเพิ่ม 50
3-6 แสดงผลการทดสอบอัลกอริทึม Support Vector Machine ที่ดีที่สุด 55
3-7 แสดงผลการทดสอบอัลกอริทึม Naïve bays ที่ดีที่สุด 55
3-8 แสดงผลการทดสอบอัลกอริทึม Neural Network ที่ดีที่สุด 55
3-9 แสดงผลการทดสอบอัลกอริทึม Random forest ที่ดีที่สุด 56
3-10 แสดงผลการทดสอบอัลกอริทึม XGBoost ที่ดีที่สุด 56
4-1 แสดงน้ำหนักความสำคัญของปัจจัยที่นำมาวิเคราะห์ 60
4-2 ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Matrix) 61
4-3 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม XGBoost 62
4-4 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม Random forest 63
4-5 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม SVM 63
4-6 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม Naïve bays 64
4-7 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม Neural Network 64
4-8 ค่าประสิทธิภาพของเทคนิคการจำแนก แยกตามอัลกอริทึม 65

สารบัญรูปภาพ

ภาพที่ หน้า

2-1 กระบวนการทำงานของอัลกอริทึม Naïve bayes 14
2-2 การทำงานของอัลกอริทึม Random Forest 15
2-3 การทำงานของอัลกอริทึม Artificial Neural Network 16
2-4 การทำงานของอัลกอริทึม Support Vector Machine 17
2-5 กระบวนการทำงานของอัลกอริทึม Extreme Gradient Boosting 18
2-6 เทคนิคการสุ่มเพิ่มข้อมูล 19
2-7 เทคนิคการสุ่มลดข้อมูล 20
2-8 เทคนิคการสุ่มแบบผสม 20
3-1 กรอบแนวคิดและขั้นตอนการดำเนินงานวิจัย 42
3-2 การนำเข้าและกำหนดบทบาทข้อมูล 51
3-3 ตัวอย่างการใช้ตัวดำเนินการภายในแบบจำลอง 51
3-4 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Random Forest 52
3-5 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Naïve Bays 53
3-6 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Neural Network 53
3-7 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล XGBoost 53
3-8 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Support Vector Machine 53
3-9 การใช้ตัวดำเนินการ Cross Validation 54
3-10 แบบร่างหน้าเว็บไซต์ส่วนข้อมูลผลการเรียน 57
3-11 แบบร่างหน้าเว็บไซต์ส่วนของแบบประเมินบุคลิกภาพ 5 องค์ประกอบ 58
3-12 แบบร่างหน้าเว็บไซต์ส่วนของการทำนาย 58
4-1 การกรอกข้อมูลการเรียนของระบบทำนายผลสัมฤทธิ์ทางการเรียน 65
4-2 การประเมินบุคลิกภาพของระบบทำนายผลสัมฤทธิ์ทางการเรียน 66
4-3 การทำนายของระบบทำนายผลสัมฤทธิ์ทางการเรียน 66
4-4 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนดีเยี่ยม 67
4-5 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนดี 67
4-6 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนพอใช้ 67
4-7 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนอ่อน 67
4-8 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนไม่ผ่านเกณฑ์ 68

สารบัญรูปภาพ (ต่อ)

ภาพที่ **หน้า**

4-9 การกดพยากรณ์ผลการเรียนใหม่อีกครั้ง 68
ก-1 ตัวอย่างคิวอาร์โค๊ดสำหรับจัดเก็บข้อมูลสาขาวิชาช่างยนต์ 82
ก-2 ตัวอย่าง Google Form สำหรับเก็บข้อมูล 83
ข-1 ผลลัพธ์ของแบบจำลอง Correlation Matrix 85
ข-2 ประสิทธิภาพของแบบจำลอง Naïve bays 85
ข-3 ประสิทธิภาพของแบบจำลอง Neural Network 86
ข-4 ประสิทธิภาพของแบบจำลอง Random Forest 87
ข-5 ประสิทธิภาพแบบจำลอง SVM 88
ข-6 ประสิทธิภาพแบบจำลอง XGBoost 89
ค-1 คำสั่งเรียกใช้ไลบรารี และโหลดไฟล์ข้อมูลเพื่อนำไปโมเดลเรียนรู้ 91
ค-2 คำสั่งกำหนดค่าพารามิเตอร์ให้สอดคล้องกับแบบจำลองที่ได้จาก Rapid Miner 91
ค-3 ค่าประสิทธิภาพของแบบจำลองที่สร้างด้วยคำสั่งไพทอน 92
ค-4 คำสั่งสร้างหน้าส่วนติดต่อผู้ใช้งาน 92
ค-5 คำสั่งส่งค่าที่ได้รับจากผู้ใช้ไปให้แบบจำลองพยากรณ์ผลสัมฤทธิ์ 93
ค-6 คำสั่งรันหน้าเว็บไซต์ผ่านช่องทางผ่าน Firewall ของ Google 93

มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

บทที่ 1
บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา

ในยุคปัจจุบันที่ภูมิทัศน์ของการศึกษาและตลาดแรงงานผันผวนอย่างรวดเร็ว การตัดสินใจเลือกเส้นทางการศึกษาจึงเป็นเรื่องที่ท้าทายและซับซ้อนอย่างยิ่ง โดยเฉพาะสำหรับกลุ่มนักเรียนที่มุ่งหวังจะศึกษาต่อในระดับอาชีวศึกษา ซึ่งเน้นการพัฒนาทักษะเฉพาะทางเพื่อตอบสนองความต้องการของตลาดแรงงานโดยตรง นักเรียนกลุ่มนี้มักเผชิญกับเงื่อนไขที่ต้องการความมั่นใจว่าเมื่อสำเร็จการศึกษาแล้วจะต้องมีงานทำที่สอดคล้องกับความถนัดของตนเอง ทว่าในความเป็นจริง นักเรียนจำนวนมากกลับถูกชี้นำให้เลือกสาขาวิชาที่กำลังเป็นที่นิยมในตลาด มากกว่าการตัดสินใจบนพื้นฐานของความสนใจและความถนัดส่วนบุคคล แนวโน้มนี้สอดคล้องกับผลการวิจัยของ อรรถกฤต อินทะโย (2560) ที่ได้ชี้ให้เห็นว่า นักเรียนส่วนใหญ่ที่เลือกเรียนสายอาชีพนั้นได้รับอิทธิพลจากการชักจูงของรุ่นพี่ ผู้ปกครอง หรือบุคคลอื่น ๆ ที่ประสบความสำเร็จในการประกอบอาชีพ รวมถึงปัจจัยด้านความสะดวกสบายในการเดินทางและค่าใช้จ่ายที่ประหยัดได้ จึงเป็นปัจจัยสำคัญในการตัดสินใจเลือกเรียนสายอาชีพในสถานศึกษาอาชีวศึกษา อย่างไรก็ตามปัญหาที่น่ากังวลยังคงปรากฏให้เห็นจากข้อมูลการสำรวจการศึกษาของกระทรวงศึกษาธิการ (2565) ซึ่งระบุว่า มีผู้เรียนออกกลางคันในภาคเรียนที่ 2/2565 สูงถึง 52,808 คน โดยแบ่งเป็นนักเรียนภาคบังคับ (อายุ 7-15 ปี) จำนวน 31,827 คน และนักเรียนระดับอาชีวศึกษาจำนวน 20,981 คน ตัวเลขนี้สะท้อนให้เห็นถึงอัตราการออกกลางคันที่สูงอย่างมีนัยสำคัญ สำหรับการศึกษาหลักสูตรอาชีวศึกษาหากนักเรียนได้เลือกสาขาวิชาไปแล้ว หากผู้เรียนไม่สามารถปรับตัวหรือรับมือกับความเข้มงวดของตัวชี้วัดมาตรฐานการศึกษาในระดับนี้ได้จะต้องประสบกับปัญหาการออกกลางคันหรือพักการเรียน

จากการศึกษางานวิจัยเกี่ยวกับการวิเคราะห์และพยากรณ์เพื่อการแนะแนวการศึกษาที่ผ่านมา พบว่า งานวิจัยส่วนใหญ่มักมุ่งเน้นไปที่การจับคู่ความสนใจของผู้เรียนกับสาขาวิชาที่ "เหมาะสม" โดยอิงจากข้อมูลด้านวิชาการหรือความชอบทั่วไป มากกว่าการมองไปที่มิติสำคัญของ "ความสำเร็จ" ที่เป็นผลมาจากความสามารถและบุคลิกภาพที่สอดคล้องกับลักษณะของสาขาวิชา ทำให้คำแนะนำที่ได้รับอาจไม่สมบูรณ์และไม่สามารถช่วยให้นักเรียนประเมินศักยภาพที่แท้จริงของตนเองได้อย่างรอบด้าน ทั้งนี้พรสรัญ รุ่งเจริญกิจกุล (2565) ได้กล่าวไว้ว่า “การมีบุคลิกภาพที่ประสบความสำเร็จต้องพัฒนาจากคุณลักษณะภายใน เพื่อจะได้เป็นพื้นฐานที่มั่นคงในการพัฒนาทักษะด้านอื่นๆ ที่จำเป็นต่อบทบาทและหน้าที่การทำงานต่อไป” แสดงให้เห็นว่าบุคลิกภาพเป็นองค์ประกอบที่ส่งผลต่อพฤติกรรมการเรียนรู้ และการปรับตัวในสภาพแวดล้อมต่างๆ โดยตรง ซึ่งเป็นปัจจัยสำคัญที่ควรนำมาพิจารณาในการพยากรณ์ผลสัมฤทธิ์ทางการเรียน เพื่อนำไปประกอบการตัดสินใจเลือกสาขาวิชาเรียนในระดับอาชีวศึกษา และอุดมศึกษาให้มีความแม่นยำมากยิ่งขึ้น

ด้วยเหตุนี้ ผู้วิจัยจึงมีแนวคิดที่จะศึกษาและพัฒนาแบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียนของนักเรียนระดับประกาศนียบัตรวิชาชีพ (ปวช.) ของวิทยาลัยเทคนิคราชบุรี ใน 5 สาขายอดนิยม ได้แก่ สาขาวิชาช่างยนต์ ช่างไฟฟ้า ช่างกลโรงงาน การบัญชี และเทคโนโลยีธุรกิจดิจิทัล

โดยบูรณาการข้อมูลบุคลิกภาพ 5 องค์ประกอบ (Big Five Personality Factors) ซึ่งประกอบด้วย การเปิดรับประสบการณ์ การมีจิตสำนึก ความเปิดตัว ความเป็นมิตร และความไม่มั่นคงทางอารมณ์ เข้ากับข้อมูลผลการเรียนในระดับมัธยมศึกษาตอนต้น เพื่อใช้เป็นเครื่องมือประเมินความพร้อมและแนะแนวทางแก่นักเรียนก่อนการตัดสินใจเลือกเข้าศึกษาต่อ ผู้วิจัยได้ออกแบบการพัฒนาแบบจำลองเพื่อเปรียบเทียบประสิทธิภาพอย่างรอบด้าน โดยจัดกลุ่มอัลกอริทึมจากระดับพื้นฐานไปสู่ความซับซ้อนระดับสูง เริ่มจากการใช้อัลกอริทึมกลุ่มความน่าจะเป็นที่เรียบง่ายที่สุดอย่างนาอีฟเบย์ (Naïve Bayes) เป็นเกณฑ์มาตรฐาน เพื่อนำไปเปรียบเทียบกับเทคนิคการเรียนรู้เชิงลึก (Deep Learning) อย่างโครงข่ายประสาทเทียม (Neural Network) นอกจากนี้ยังเปรียบเทียบอัลกอริทึมที่มีโครงสร้างการทำงานแบบเดี่ยวอย่างเวกเตอร์สนับสนุน (Support Vector Machine :SVM) กับกลุ่มการเรียนรู้แบบกลุ่ม (Ensemble Learning) ที่มีความทันสมัยและทรงประสิทธิภาพอย่างทฤษฎีป่าสุ่ม (Random Forest) และการบูสต์แบบไล่ระดับ (Extreme Gradient Boosting : XGBoost) เพื่อพิสูจน์เชิงประจักษ์ว่าอัลกอริทึมกลุ่มใดจะมีความเหมาะสมที่สุดกับชุดข้อมูลบุคลิกภาพและการศึกษาในบริบทนี้

จากการเลือกใช้กลุ่มอัลกอริทึมดังกล่าว สอดคล้องกับ Albreiki, Zaki และ Alashwal (2021) ที่พบว่าเทคนิคเหล่านี้ได้รับความนิยมและมีประสิทธิภาพสูงในการทำนายผลการเรียน โดยงานวิจัยดังกล่าวระบุว่า Neural Network มีความแม่นยำสูงถึงร้อยละ 79 เหนือกว่า Naïve Bayes และ SVM ในขณะที่ Random Forest ให้ประสิทธิภาพดีที่สุดในการทำนายระดับความเสี่ยงของผู้เรียน อย่างไรก็ตาม งานวิจัยในอดีตส่วนใหญ่เป็นการทดสอบบนชุดข้อมูลขนาดใหญ่ที่อาศัยเพียงข้อมูลวิชาการและประชากรศาสตร์เท่านั้น จุดที่แตกต่างและเป็นความท้าทายสำคัญของงานวิจัยนี้คือการนำอัลกอริทึมระดับสูงเหล่านี้ มาทดสอบกับชุดข้อมูลขนาดจำกัดในระดับอาชีวศึกษาที่มีการผนวกร่วมกับข้อมูลบุคลิกภาพ 5 องค์ประกอบ ซึ่งไม่พบว่ามีการนำมาใช้วิเคราะห์ร่วมกันมาก่อน นับว่าเป็นจุดเริ่มต้นในการบูรณาการที่เพิ่มมิติการวิเคราะห์เชิงบุคลิกภาพเข้าไปเพื่อยกระดับความแม่นยำในการพยากรณ์ให้สมบูรณ์มากยิ่งขึ้น โดยจะทำการประเมินประสิทธิภาพของแบบจำลองด้วยค่าความแม่นยำ (Accuracy) ค่าความเที่ยงตรง (Precision) ค่าระลึก (Recall) และค่าความสมดุลระหว่างความเที่ยงตรงและค่าระลึก (F1-Score) เพื่อค้นหาแบบจำลองที่เสถียรและแม่นยำที่สุด

ดังนั้น การวิจัยในครั้งนี้จึงมีความสำคัญอย่างยิ่งในการสร้างเครื่องมือเชิงรุกที่ช่วยให้นักเรียนสามารถประเมินศักยภาพของตนเองได้อย่างลึกซึ้งยิ่งขึ้น ไม่เพียงแค่เลือกสาขาที่สนใจ แต่ยังรวมถึงการพยากรณ์โอกาสที่จะประสบความสำเร็จในสาขานั้นๆ โดยอิงจากคุณลักษณะเฉพาะตัว เพื่อให้การตัดสินใจเลือกเส้นทางการศึกษา และนำไปสู่การเรียนรู้อย่างมีความสุขและมีผลสัมฤทธิ์ทางการเรียนที่ดี เพื่อช่วยเพิ่มโอกาสการจ้างงานให้กับนักเรียนในอนาคต

1.2 วัตถุประสงค์ของงานวิจัย

1.2.1 เพื่อพัฒนาแบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น โดยใช้เทคนิคการจำแนกข้อมูล

1.2.2 เพื่อเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น โดยใช้เทคนิคการจำแนกข้อมูล

1.3 คำถามงานวิจัย

ลักษณะทางบุคลิกภาพสามารถพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพ (ปวช.) ของสาขาที่เลือกเรียนได้หรือไม่

1.4 สมมติฐาน

1.4.1 แบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับชั้นประกาศนียบัตรวิชาชีพ (ปวช.) ที่พัฒนาขึ้น โดยบูรณาการข้อมูลบุคลิกภาพ 5 องค์ประกอบ และเกรดวิชาหลักมัธยมศึกษาตอนต้น มีประสิทธิภาพการพยากรณ์ค่าความถูกต้อง (Accuracy) มากกว่าร้อยละ 75

H_0 : $\mu \leq$ ร้อยละ 75

H_1 : $\mu >$ ร้อยละ 75

เมื่อ μ แทน ค่าความแม่นยำของแบบจำลองที่นำมาใช้พยากรณ์ผลสัมฤทธิ์ทางการเรียน

1.4.2 แบบจำลองในกลุ่มการเรียนรู้แบบกลุ่ม (Ensemble Learning) มีประสิทธิภาพในการพยากรณ์ผลสัมฤทธิ์ทางการเรียนสูงที่สุด เมื่อเปรียบเทียบกับแบบจำลองทั้งหมดที่ใช้ในการศึกษาครั้งนี้

1.5 ขอบเขตงานวิจัย

งานวิจัยนี้ทำการศึกษาเพื่อเปรียบเทียบประสิทธิภาพของแต่ละอัลกอริทึมที่ใช้สำหรับการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพ ด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น โดยเทคนิคการจำแนกข้อมูล ผู้วิจัยได้กำหนดขอบเขตของการวิจัย ดังนี้

1.5.1 ขอบเขตด้านตัวแปรที่ใช้ในการวิจัย

1.5.1.1 ตัวแปรอิสระหรือตัวแปรต้น (Independent Variable)

1.5.1.1.1 ค่าเฉลี่ยจากการทำแบบทดสอบบุคลิกภาพ 5 องค์ประกอบ ได้แก่

ก) ด้านการเปิดรับประสบการณ์ (Openness to Experience)

ข) ด้านการมีจิตสำนึก (Conscientiousness)

ค) ด้านความเปิดตัว (Extraversion)

ง) ด้านความเป็นมิตร (Agreeableness)

จ) ด้านความไม่มั่นคงทางอารมณ์ (Neuroticism)

1.5.1.1.2 เกรดวิชาพื้นฐานในระดับมัธยมศึกษาตอนต้น ได้แก่

ก) วิชาคณิตศาสตร์

ข) วิชาวิทยาศาสตร์

ค) วิชาภาษาอังกฤษ

1.5.1.1.3 สาขาวิชายอดนิยมที่สนใจ 1 สาขาวิชา ได้แก่ ช่างยนต์ ช่างไฟฟ้า ช่างกลโรงงาน การบัญชี และเทคโนโลยีธุรกิจดิจิทัล

1.5.1.2 ตัวแปรตาม (Dependent Variable)

1.5.1.2.1 ผลสัมฤทธิ์ทางการเรียนในระดับชั้นประกาศนียบัตรวิชา (ปวช.) แบ่งออกเป็น 5 ระดับ ดังนี้

ก) เกรด 0 ผลสัมฤทธิ์ ไม่ผ่านเกณฑ์
ข) เกรด 1 ผลสัมฤทธิ์ อ่อน
ค) เกรด 2 ผลสัมฤทธิ์ พอใช้
ง) เกรด 3 ผลสัมฤทธิ์ ดี
จ) เกรด 4 ผลสัมฤทธิ์ ดีเยี่ยม

1.5.2 ประชากรและกลุ่มตัวอย่าง

1.5.2.1 ประชากรที่ใช้ในการศึกษาครั้งนี้ ได้แก่ นักเรียนระดับชั้นประกาศนียบัตรวิชาชีพ (ปวช.) สาขาวิชาช่างกลโรงงาน ช่างไฟฟ้า ช่างยนต์ เทคโนโลยีธุรกิจดิจิทัล และการบัญชี วิทยาลัยเทคนิคราชบุรี ที่ลงทะเบียนเรียนในภาคเรียนที่ 2 ปีการศึกษา 2568 จำนวนทั้งสิ้น 1,481 คน (ข้อมูล ณ วันที่ 10 มิถุนายน 2568) แสดงจำนวนตามสาขาวิชา ดังนี้

1.5.2.1.1 สาขาวิชาช่างกลโรงงาน จำนวน 197 คน
1.5.2.1.2 สาขาวิชาช่างไฟฟ้า จำนวน 411 คน
1.5.2.1.3 สาขาวิชาช่างยนต์ จำนวน 375 คน
1.5.2.1.4 สาขาวิชาการบัญชี จำนวน 224 คน
1.5.2.1.5 สาขาวิชาเทคโนโลยีธุรกิจดิจิทัล จำนวน 274 คน

1.5.2.2 กลุ่มตัวอย่างที่ใช้ในการศึกษาครั้งนี้ ได้แก่ นักเรียนระดับชั้นประกาศนียบัตรวิชาชีพ (ปวช.) ชั้นปีที่ 2-3 จากสาขาวิชาช่างกลโรงงาน ช่างไฟฟ้า ช่างยนต์ เทคโนโลยีธุรกิจดิจิทัล และการบัญชี วิทยาลัยเทคนิคราชบุรี ที่ลงทะเบียนเรียนในภาคเรียนที่ 2 ปีการศึกษา 2568 สาขาวิชาละ 100 คน จำนวนทั้งสิ้น 500 คน โดยใช้วิธีการสุ่มแบบเจาะจง (Purposive Sampling)

1.5.3 ขอบเขตด้านอัลกอริทึมในการพยากรณ์

1.5.3.1 อัลกอริทึมนาอีฟเบย์ (Naïve Bayes)
1.5.3.2 อัลกอริทึมทฤษฎีป่าสุ่ม (Random Forest)
1.5.3.3 อัลกอริทึมโครงข่ายประสาทเทียม (Neural Network)
1.5.3.4 อัลกอริทึมการบูสต์แบบไล่ระดับ (Extreme Gradient Boosting: XGBoost)
1.5.3.5 อัลกอริทึมเวกเตอร์สนับสนุน (Support Vector Machine: SVM)

1.5.4 เครื่องมือที่ใช้ในการวิจัย

1.5.4.1 โปรแกรม Rapid Miner สำหรับการสร้างแบบจำลองโมเดล

1.5.4.2 โปรแกรม Google sheet สำหรับตรวจสอบความถูกต้อง จัดเรียงและจัดรูปแบบข้อมูลก่อนนำไปใช้ในการวิจัย

1.5.4.3 โปรแกรม Google Form สำหรับเก็บรวบรวมข้อมูล

1.5.4.4 โปรแกรมภาษา Python

1.5.4.5 เว็บไซต์ Google Colab

1.5.5 สถิติที่ใช้ในการวิจัยครั้งนี้ ประเมินประสิทธิภาพของอัลกอริทึม Naïve bayes, Random Forest, Neural Network, Support Vector Machine และ XGboost และความสัมพันธ์ของตัวแปร ได้แก่

1.5.5.1 ค่าความแม่นยำ (Accuracy)

1.5.5.2 ค่าความเที่ยงตรง (Precision)

1.5.5.3 ค่าระลึก (Recall)

1.5.5.4 ค่าความสมดุลระหว่างความเที่ยงตรงและค่าระลึก (F1-Score)

1.5.5.5 ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation)

1.5.5.6 น้ำหนักความสำคัญ (Weight By Gini Index)

1.5.6 ขอบเขตด้านระยะเวลา

ระยะเวลาในการดำเนินงานวิจัย ตั้งแต่ 23 มิถุนายน 2568 ถึง วันที่ 31 มีนาคม 2569

1.6 ประโยชน์ที่คาดว่าจะได้รับ

1.6.1 เพื่อนำเสนอผลที่ได้จากอัลกอริทึมที่มีประสิทธิภาพที่ดีที่สุด และเหมาะสมกับชุดข้อมูลมาใช้ในการพยากรณ์ผลสัมฤทธิ์ทางการเรียนระดับชั้นประกาศนียบัตรวิชาชีพ (ปวช.)

1.6.2 สามารถนำอัลกอริทึมที่ได้ไปใช้เป็นเครื่องมือสำหรับพัฒนาระบบที่เกี่ยวข้องกับการวิเคราะห์พฤติกรรมเพื่อแนะแนวการศึกษาต่อในระดับประกาศนียบัตรวิชาชีพ ที่ผสมผสานบุคลิกภาพเข้ามาใช้ในการพยากรณ์ ซึ่งอาจจะมีส่วนช่วยลดปัญหาการเลือกเรียนผิดสาขาวิชา

1.7 นิยามคำศัพท์

1.7.1 บุคลิกภาพ 5 องค์ประกอบ (Big Five Personality Factors) คือ รูปแบบการจัดกลุ่มบุคลิกภาพของมนุษย์ที่ได้รับการยอมรับจากนักจิตวิทยา เนื่องจากสามารถอธิบายถึงโครงสร้างของบุคลิกภาพของบุคคลในระดับสากลได้ ซึ่งประกอบด้วย 5 มิติ ได้แก่ การเปิดรับประสบการณ์ (Openness to Experience) การมีจิตสำนึก (Conscientiousness) การเปิดตัว (Extraversion) ความเป็นมิตร (Agreeableness) และความไม่มั่นคงทางอารมณ์ (Neuroticism) ในการประเมินจะต้องอาศัยเครื่องมือที่เรียกว่า แบบวัดบุคลิกภาพ

1.7.2 แบบวัดบุคลิกภาพ (Big Five Inventory: BFI) คือ เครื่องมือทางจิตวิทยาสำหรับประเมินบุคลิกภาพ 5 ด้าน ที่ได้รับการพัฒนาและปรับปรุงในปี 2008 ของ John, Naumann และ Soto ซึ่งมีการตรวจสอบความน่าเชื่อถือและความถูกต้องการวัดอย่างต่อเนื่อง ประกอบด้วย 44 คำถาม

1.7.3 เทคนิคการจำแนกข้อมูล (Classification Techniques) คือ เทคนิคหนึ่งในการเรียนรู้ของเครื่อง (Machine learning) สำหรับทำเหมืองข้อมูล โดยมีวัตถุประสงค์เพื่อให้แบบจำลองเรียนรู้จากชุดข้อมูลที่นำเข้าไป วิเคราะห์และให้ผลลัพธ์เพื่อตอบคำถามที่กำหนดในรูปแบบของค่าที่ไม่ต่อเนื่อง

1.7.4 หลักสูตรประกาศนียบัตรวิชาชีพ (ปวช.) คือ หลักสูตรการศึกษาที่อยู่ในการกำกับดูแลของสำนักงานคณะกรรมการการอาชีวศึกษา กระทรวงศึกษาธิการ โดยมุ่งเน้นการพัฒนาความรู้ความสามารถ และทักษะการปฏิบัติทางวิชาชีพเฉพาะด้านแบ่งเป็นสาขาวิชา เพื่อตอบสนองกับความต้องการของตลาดแรงงาน ใช้ระยะเวลา 3 ปีการศึกษา ผู้จบการศึกษาจะมีคุณวุฒิเทียบเท่ากับมัธยมศึกษาตอนปลาย

1.7.5 สาขาวิชา คือ การศึกษาในแขนงเฉพาะทาง ตามหลักสูตรประกาศนียบัตรวิชาชีพ (ปวช.)

1.7.6 ยอดนิยม คือ ความชื่นชอบ, ยอมรับนับถือ หรือให้ความสนใจมากที่สุด

1.7.7 เกรดวิชาหลักมัธยมศึกษาตอนต้น หมายถึง ข้อมูลระดับผลการเรียนเดิมระดับชั้นมัธยมศึกษาตอนต้น (ม.1-ม.3) ในรายวิชาคณิตศาสตร์ วิทยศาสตร์ และภาษาอังกฤษ ของกลุ่มตัวอย่างที่นำมาใช้เป็นชุดข้อมูลสำหรับการวิเคราะห์

บทที่ 2
เอกสารและงานวิจัยที่เกี่ยวข้อง

การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพ ด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น โดยใช้เทคนิคการจำแนกข้อมูล ผู้วิจัยได้สืบค้นศึกษาทฤษฎี กระบวนการ เอกสารทางวิชาการ และงานวิจัยที่เกี่ยวข้อง เพื่อนำมาประยุกต์ใช้ในการวิจัย ดังนี้

2.1 หลักสูตรประกาศนียบัตรวิชาชีพ (ปวช.) พุทธศักราช 2567

2.2 ทฤษฎีบุคลิกภาพ 5 องค์ประกอบ (Big 5 Personality Factors)

2.3 เทคนิคการจำแนกข้อมูล (Classification Techniques)

2.4 เทคนิคการปรับข้อมูลที่ไม่สมดุลกัน (Imbalanced Data)

2.5 การวัดประสิทธิภาพของแบบจำลองพหุคลาส (Multi Class Metrics)

2.6 ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation)

2.7 ค่าน้ำหนักความสำคัญ (Weight by Gini Index)

2.8 งานวิจัยที่เกี่ยวข้อง (Related Research)

2.1 หลักสูตรประกาศนียบัตรวิชาชีพ (ปวช.) พุทธศักราช 2567

หลักสูตรประกาศนียบัตรวิชาชีพ (ปวช.) พุทธศักราช 2567 เป็นหลักสูตรที่ปรับปรุงใหม่สำหรับผู้ที่จบการศึกษาระดับมัธยมศึกษาตอนต้น หรือเทียบเท่า เพื่อพัฒนาทักษะวิชาชีพให้สูงขึ้น โดยสอดคล้องกับยุทธศาสตร์ชาติ แผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ และความต้องการของตลาดแรงงาน และข้อเสนอจากคณะอนุกรรมการร่วมภาครัฐและภาคเอกชน โดยหลักสูตรเป็นไปตามกรอบคุณวุฒิแห่งชาติ (National Qualifications Framework: NQF) และกรอบคุณวุฒิอ้างอิงอาเซียน (ASEAN Qualifications Reference Framework : AQRF) ซึ่งอยู่ภายใต้การควบคุมดูแลของสำนักงานคณะกรรมการการอาชีวศึกษา กระทรวงศึกษาธิการ โดยมีสาระสำคัญของหลักสูตรดังนี้

2.1.1 หลักการของหลักสูตร

2.1.1.1 เป็นหลักสูตรระดับประกาศนียบัตรวิชาชีพ (ปวช.) สำหรับผู้ที่จบมัธยมศึกษาตอนต้นหรือเทียบเท่า

2.1.1.2 เน้นการจัดการศึกษาด้านวิชาชีพและการยกระดับการศึกษาวิชาชีพ

2.1.1.3 สอดคล้องกับแผนพัฒนาเศรษฐกิจและสังคมแห่งชาติ แผนการศึกษาแห่งชาติกรอบคุณวุฒิแห่งชาติ กรอบคุณวุฒิอ้างอิงอาเซียน มาตรฐานการศึกษาของชาติ และกรอบคุณวุฒิอาชีวศึกษาแห่งชาติ

2.1.1.4 เน้นการเรียนรู้ด้วยการปฏิบัติเพื่อพัฒนาสมรรถนะกำลังคนระดับฝีมือ คุณธรรม จริยธรรม จรรยาบรรณวิชาชีพ และกิจนิสัยที่เหมาะสมในการทำงาน

2.1.1.5 เปิดโอกาสให้ผู้เรียนเลือกเรียนได้หลายรูปแบบ เน้นสมรรถนะเฉพาะด้านด้วยการปฏิบัติจริง

2.1.1.6 อนุญาตให้โอนผลการเรียน เทียบโอนความรู้และประสบการณ์ และเทียบโอนสมรรถนะบุคคลตามมาตรฐานอาชีพได้

2.1.1.7 ส่งเสริมความร่วมมือในการจัดการศึกษาและพัฒนาวิชาชีพระหว่างสถาบันการอาชีวศึกษา สถานศึกษากับหน่วยงานภาครัฐและเอกชน และองค์กรวิชาชีพ ทั้งในและต่างประเทศ

2.1.1.8 เปิดโอกาสให้สถานศึกษา สถานประกอบการ ชุมชน และท้องถิ่นมีส่วนร่วมในการพัฒนาหลักสูตรให้ตรงตามความต้องการของตลาดแรงงานและสอดคล้องกับบริบทเชิงพื้นที่

2.1.2 จุดมุ่งหมายของหลักสูตร

2.1.2.1 พัฒนาให้ผู้เรียนมีพฤติกรรม ลักษณะนิสัย ค่านิยม จรรยาบรรณวิชาชีพที่ดี มีความรับผิดชอบ มีจิตสาธารณะ รักษ์สิ่งแวดล้อม และดำรงชีวิตตามปรัชญาเศรษฐกิจพอเพียง

2.1.2.2 เพื่อให้มีความรู้เกี่ยวกับข้อเท็จจริง หลักการ ทฤษฎี และแนวปฏิบัติที่เกี่ยวข้องกับสาขาวิชาที่เรียน

2.1.2.3 เพื่อให้มีทักษะการเลือกและประยุกต์ใช้วิธีการ เครื่องมือ วัสดุพื้นฐาน ทักษะการสื่อสารและเทคโนโลยีดิจิทัล การเรียนรู้ตลอดชีวิต การคิดวิเคราะห์ การแก้ปัญหา และสุขภาวะและความปลอดภัย

2.1.2.4 เพื่อให้สามารถปฏิบัติงานตามแบบแผน ปรับตัวกับการเปลี่ยนแปลง ให้คำแนะนำพื้นฐาน วางแผนและแก้ไขปัญหา และประยุกต์ใช้ความรู้และทักษะทางวิชาชีพ

2.1.2.5 เพื่อให้ตระหนักและมีส่วนร่วมในการแก้ไขปัญหาเศรษฐกิจ สังคม การเมือง สิ่งแวดล้อม และมีความรักชาติ ศาสนา พระมหากษัตริย์

2.1.3 หลักเกณฑ์การใช้หลักสูตร

2.1.3.1 ด้านการเรียนการสอน ผู้เรียนสามารถลงทะเบียนเรียนได้หลายวิธีและนำผลมาประเมินร่วมกันได้ รวมถึงการโอนและเทียบโอนผลการเรียนรู้ เน้นการปฏิบัติจริง เพื่อพัฒนาสมรรถนะเฉพาะด้านในระดับฝีมือ

2.1.3.2 การจัดการศึกษาและเวลาเรียน โดยรูปแบบการศึกษาในระบบ และรูปแบบการศึกษาระบบทวิภาคี ใช้ระบบทวิภาค โดย 1 ปีการศึกษาแบ่งเป็น 2 ภาคเรียน และใน 1 ภาคเรียนมีระยะเวลาการจัดการศึกษารวมการวัดผล ไม่น้อยกว่า 18 สัปดาห์ หรือเทียบเคียงได้ไม่น้อยกว่า 18 สัปดาห์

2.1.3.3 การคิดหน่วยกิต กำหนดหน่วยกิตรวม 100 - 110 หน่วยกิต โดยมีเกณฑ์การคิดหน่วยกิต ดังนี้

2.1.3.3.1 วิชาทฤษฎี 18 ชั่วโมงต่อภาคเรียน นับเป็น 1 หน่วยกิต

2.1.3.3.2 วิชาปฏิบัติในห้องปฏิบัติการ 36 ชั่วโมงต่อภาคเรียน นับเป็น 1 หน่วยกิต

2.1.3.3.3 วิชาปฏิบัติในโรงฝึกงานหรือภาคสนาม 54 ชั่วโมงต่อภาคเรียน นับเป็น 1 หน่วยกิต

2.1.3.3.4 วิชาฝึกอาชีพทวิภาคี ไม่น้อยกว่า 54 ชั่วโมงต่อภาคเรียน นับเป็น 1 หน่วยกิต

2.1.3.3.5 วิชาฝึกประสบการณ์สมรรถนะวิชาชีพ ไม่น้อยกว่า 80 ชั่วโมงต่อภาคเรียน นับเป็น 1 หน่วยกิต

2.1.3.3.6 วิชาโครงงานพัฒนาสมรรถนะวิชาชีพ ไม่น้อยกว่า 54 ชั่วโมงต่อภาคเรียน นับเป็น 1 หน่วยกิต

2.1.4 โครงสร้างหลักสูตร แบ่งเป็น 3 หมวดวิชาและกิจกรรมเสริมหลักสูตร

2.1.4.1 หมวดวิชาสมรรถนะแกนกลาง ไม่น้อยกว่า 20 หน่วยกิต ประกอบด้วยกลุ่มภาษาและการสื่อสาร กลุ่มการคิดและการแก้ปัญหา ประกอบด้วยวิทยาศาสตร์ และคณิตศาสตร์ และกลุ่มสังคมและการดำรงชีวิต ประกอบด้วย สังคมศึกษา สุขศึกษาและพลศึกษา

2.1.4.2 หมวดวิชาสมรรถนะวิชาชีพ ไม่น้อยกว่า 70 หน่วยกิต ประกอบด้วยกลุ่มสมรรถนะวิชาชีพพื้นฐาน และกลุ่มสมรรถนะวิชาชีพเฉพาะ รวมโครงงาน 4 หน่วยกิต

2.1.4.3 หมวดวิชาเลือกเสรี ไม่น้อยกว่า 10 หน่วยกิต โดยสามารถเลือกวิชานอกสาขาวิชาได้ตามเหมาะสมหรือเป็นประโยชน์ต่อการเรียนรู้ในยุคสมัยปัจจุบัน

2.1.4.4 กิจกรรมเสริมหลักสูตร อย่างน้อยสัปดาห์ละ 2 ชั่วโมงทุกภาคเรียน หรือ 36 ชั่วโมงต่อภาคเรียน โดยไม่นำมานับเป็นหน่วยกิต เน้นการส่งเสริมคุณธรรม จริยธรรม ระเบียบวินัย จิตอาสา ความเป็นพลเมืองไทยและพลโลก การอนุรักษ์สิ่งแวดล้อม กีฬา และดำรงตนตามหลักปรัชญาเศรษฐกิจพอเพียง โดยผู้เรียนทุกคนต้องเข้าร่วม

2.1.5 การจัดแผนการเรียน กำหนดอัตราส่วนทฤษฎีต่อปฏิบัติในหมวดวิชาสมรรถนะวิชาชีพประมาณ 20:80 การลงทะเบียนเรียนภาคปกติแบบเต็มเวลาไม่เกิน 22 หน่วยกิต แบบไม่เต็มเวลาไม่เกิน 12 หน่วยกิต และภาคฤดูร้อนไม่เกิน 12 หน่วยกิต

2.1.6 การสำเร็จการศึกษา ต้องสำเร็จการศึกษาไม่ต่ำกว่าระดับมัธยมศึกษาตอนต้น ได้หน่วยกิต ครบถ้วนตามโครงสร้าง ได้ค่าระดับคะแนนเฉลี่ยสะสมไม่ต่ำกว่า 2.00 จากระบบ 4 ระดับ ผ่านเกณฑ์การประเมินมาตรฐานวิชาชีพ และผ่านกิจกรรมเสริมหลักสูตรทุกภาคเรียน

2.1.7 การพัฒนารายวิชาในหลักสูตร สถานศึกษาสามารถพัฒนารายวิชาเพิ่มเติมได้ทั้งในหมวดวิชาสมรรถนะแกนกลาง และหมวดวิชาสมรรถนะวิชาชีพ โดยต้องร่วมกับสถานประกอบการหรือองค์กรที่เกี่ยวข้อง

2.1.8 การพัฒนา ปรับปรุง อนุมัติ และประกาศใช้หลักสูตร สถานศึกษาต้องรายงานการพัฒนาหรือปรับปรุงรายวิชาให้ สอศ. ทราบ และมีการประเมินผลการใช้หลักสูตรทุก 5 ปี การอนุมัติหลักสูตรเป็นหน้าที่ของ สอศ. และประกาศใช้โดยกระทรวงศึกษาธิการ

2.1.9 การประกันคุณภาพของหลักสูตรและการจัดการเรียนการสอน มีองค์ประกอบการประกันคุณภาพอย่างน้อย 4 ด้าน ได้แก่ หลักสูตรที่ยึดโยงกับมาตรฐานอาชีพ ครู ทรัพยากรและการสนับสนุน วิธีการจัดการเรียนรู้ การวัดและประเมินผล และผู้สำเร็จการศึกษา

จากรายละเอียดของหลักสูตรประกาศนียบัตรวิชาชีพที่กล่าวมานี้ เป็นปัจจัยสำคัญที่ผู้วิจัยนำมาพิจารณาประกอบการคัดเลือกกลุ่มตัวอย่างให้สอดคล้องกับวัตถุประสงค์การวิจัย และกำหนดขอบเขตการศึกษาเป็นนักเรียนวิทยาลัยเทคนิคราชบุรี โดยคัดเลือกจากสาขาวิชาที่มีจำนวนนักเรียนสูงสุด 5 สาขาวิชา ได้แก่ สาขาวิชาช่างกลโรงงาน ช่างยนต์ ช่างไฟฟ้า การบัญชี และเทคโนโลยีธุรกิจดิจิทัล เพื่อเป็นกลุ่มตัวอย่างที่ใช้ในการทดสอบอัลกอริทึมที่ใช้ในการจำแนกข้อมูล

2.2 ทฤษฎีบุคลิกภาพ 5 องค์ประกอบ (Big Five Personality Factors)

ทฤษฎีบุคลิกภาพ 5 องค์ประกอบ เป็นแบบจำลองที่ใช้อธิบายบุคลิกภาพของมนุษย์ แบ่งเป็น 5 องค์ประกอบ ได้แก่

2.2.1 ด้านการเปิดรับประสบการณ์ (Openness) บุคคลที่มีคะแนนสูงในด้านนี้มักจะมีความคิดสร้างสรรค์ช่างจินตนาการ มีความอยากรู้อยากเห็น และเปิดรับประสบการณ์ใหม่ ในทางตรงข้ามผู้ที่มีคะแนนต่ำในด้านนี้มักจะชอบความเคยชินยึดติดกับสิ่งเดิม และไม่ชอบการเปลี่ยนแปลง

2.2.2 ด้านการมีจิตสำนึก (Conscientiousness) บุคคลที่มีคะแนนสูงในด้านนี้ มักจะเป็นคนที่มีระเบียบ มีความรับผิดชอบ มีวินัย และมีความมุ่งมั่นในการทำงาน ตรงข้ามกับผู้ที่มีคะแนนต่ำในด้านนี้ซึ่งมักจะขาดความรับผิดชอบ ไม่เป็นระเบียบ และไม่ค่อยมีความมุ่งมั่น

2.2.3 ด้านการเปิดตัว (Extraversion) บุคคลที่มีคะแนนสูงในด้านนี้ มักจะชอบเข้าสังคม ชอบสังสรรค์ ชอบเป็นจุดสนใจ และมีความกระตือรือร้น ในขณะที่ผู้ที่มีคะแนนต่ำในด้านนี้ มักจะชอบอยู่คนเดียว สันโดษ และไม่ชอบการเข้าสังคม

2.2.4 ด้านความเป็นมิตร (Agreeableness) บุคคลที่มีคะแนนสูงในด้านนี้ มักจะเป็นคนที่มีความเป็นมิตรผู้อื่น ชอบช่วยเหลือผู้อื่น มีความอ่อนโยน และเข้ากับคนง่าย ในทางตรงข้ามผู้ที่มีคะแนนต่ำในด้านนี้ มักจะมีความเห็นแก่ตัว ไม่ค่อยเห็นอกเห็นใจผู้อื่น และอาจไม่ค่อยชอบเข้าสังคม

2.2.5 ด้านความไม่มั่นคงทางอารมณ์ (Neuroticism) บุคคลที่มีคะแนนสูงในด้านนี้ มักจะมีความวิตกกังวล เครียดง่าย ซึมเศร้า และอารมณ์แปรปรวน ตรงข้ามกับผู้ที่มีคะแนนต่ำในด้านนี้ ซึ่งมักจะมีความมั่นคงทางอารมณ์ ควบคุมอารมณ์ได้ดี และไม่ค่อยวิตกกังวล

สำหรับการวัดและประเมินบุคลิกภาพ 5 องค์ประกอบ (Big Five Personality Factors) ในการศึกษาค้นคว้าอิสระครั้งนี้ ผู้วิจัยเลือกใช้แบบวัดบุคลิกภาพ (Big Five Inventory : BFI) เป็นเครื่องมือหลักในการเก็บรวบรวมข้อมูล โดยอ้างอิงแนวคิดและการพัฒนาเครื่องมือของ

John, Naumann และ Soto (2008) จากงานวิจัยเรื่อง Paradigm shift to the integrative Big Five trait taxonomy ซึ่งได้นำต้นฉบับเดิมมาปรับปรุงแบบวัดให้มีความสมบูรณ์และเป็นปัจจุบัน ได้รับการยอมรับระดับสากลว่ามีคุณสมบัติทางจิตมิติ (Psychometric Properties) ที่ดีเยี่ยม มีค่าความเชื่อมั่น (Reliability) และความตรง (Validity) สูง เมื่อเทียบกับแบบวัดบุคลิกภาพชนิดอื่น อีกทั้งยังมีความเหมาะสมในการนำไปใช้กับบริบทที่หลากหลาย โดยแบบวัดฉบับมาตรฐานที่ผู้วิจัยนำมาประยุกต์ใช้ประกอบด้วยข้อคำถามจำนวน 44 ข้อ สำหรับรายละเอียดของข้อคำถาม และเกณฑ์การให้คะแนนและการแปลความหมาย ผู้วิจัยได้นำเสนอไว้ในบทที่ 3 วิธีดำเนินการวิจัยเพื่อแสดงถึงความชัดเจนในกระบวนการเก็บรวบรวมข้อมูล

2.2.6 การตีความคะแนน (Interpretation of Scores) โดยมีเกณฑ์คะแนนเฉลี่ย ดังนี้

2.2.6.1 ค่าคะแนนเฉลี่ยช่วง 3.67 – 5.00 แสดงว่าบุคคลนั้นมีลักษณะของมิติบุคลิกภาพนั้นสูง

2.2.6.2 ค่าคะแนนเฉลี่ยช่วง 2.34 – 3.66 แสดงว่าบุคคลนั้นมีลักษณะของมิตินั้นในระดับปานกลางไม่โดดเด่นไปทางใดทางหนึ่ง

2.2.6.3 ค่าคะแนนเฉลี่ยช่วง 1.00 – 2.33 แสดงว่ามีบุคคลนั้นมีลักษณะของมิติบุคลิกภาพนั้นต่ำ

การวิเคราะห์ความสัมพันธ์ระหว่างองค์ประกอบของบุคลิกภาพกับผลลัพธ์ทางการศึกษา พบว่าด้านความมีมโนธรรม (Conscientiousness) มีความสัมพันธ์ทางตรงกับพฤติกรรมความรับผิดชอบ ระเบียบวินัย และความรอบคอบในการทำงาน ซึ่งถือเป็นปัจจัยทำนายสำคัญต่อผลสัมฤทธิ์ทางการเรียน

ในขณะที่บุคคลที่มีระดับ ด้านความไม่มั่นคงทางอารมณ์ (Neuroticism) ต่ำ สะท้อนถึงความมั่นคงทางอารมณ์ (Emotional Stability) ที่สูง ส่งผลให้มีทักษะในการจัดการความวิตกกังวลและความเครียด ซึ่งเอื้อต่อการมีสมาธิในการเรียนและการสอบ สำหรับด้านความเปิดกว้างต่อประสบการณ์ (Openness to Experience) นั้นสัมพันธ์กับความใฝ่รู้และการปรับตัวต่อองค์ความรู้

ที่มีความซับซ้อน อันเป็นพื้นฐานของการเรียนรู้ตลอดชีวิต และสุดท้าย ด้านความเป็นมิตร (Agreeableness) ส่งผลเชิงบวกต่อพฤติกรรมการมีส่วนร่วมในชั้นเรียนและประสิทธิภาพในการทำงานกลุ่ม

ทั้งนี้ในบทความของการพัฒนาบุคลิกภาพเพื่อความสำเร็จ ของพรสรัญ รุ่งเจริญกิจกุล (2565) ได้นำเสนอแนวคิดโดยอ้างอิงหลักการทางจิตวิทยาจาก Psycho-Cybernetics ของ Maxwell Maltz ซึ่งชี้ให้เห็นว่า หัวใจสำคัญของการพัฒนาบุคลิกภาพมิใช่เพียงการปรับปรุงรูปลักษณ์ภายนอก แต่ขึ้นอยู่กับการสร้าง ภาพลักษณ์ภายในใจ (Self-Image) ให้เข้มแข็งและสอดคล้องกับความเป็นจริง เพื่อให้บุคคลสามารถตอบสนองต่อสถานการณ์ต่างๆ ได้อย่างมีประสิทธิภาพ โดยองค์ประกอบของบุคลิกภาพที่ประสบความสำเร็จสามารถจำแนกตามอักษรย่อ SUCCESS ได้แก่ 7 ด้าน ดังนี้

1.) การมีเป้าหมายที่ชัดเจน (S - Sense of Direction) การกำหนดเป้าหมายที่มีความหมายต่อตนเองเพื่อสร้างแรงจูงใจและทิศทางในการดำเนินชีวิต

2.) ความเข้าใจบนพื้นฐานความจริง (U - Understanding) การรับรู้ข้อมูลและสถานการณ์ตามความเป็นจริง ปราศจากอคติ และมีความเข้าใจในมุมมองของผู้อื่น

3.) ความกล้าหาญ (C - Courage) ความกล้าในการเผชิญความเสี่ยงอย่างมีวิจารณญาณ และสามารถเปลี่ยนความคิดไปสู่การลงมือปฏิบัติจริง

4.) ความเป็นมิตร (C - Compassion) การให้เกียรติและเคารพในศักดิ์ศรีของผู้อื่นในฐานะเพื่อนมนุษย์

5.) การเห็นคุณค่าในตนเอง (E - Esteem) การตระหนักรู้และยอมรับในคุณค่าที่แท้จริงของตนเอง โดยไม่ยึดติดกับวัตถุภายนอก

6.) ความเชื่อมั่นในตนเอง (S - Self-Confidence) การสั่งสมความมั่นใจผ่านประสบการณ์ความสำเร็จในอดีตและการเรียนรู้จากความผิดพลาด

7.) การยอมรับตนเอง (S - Self-Acceptance) การยอมรับในข้อบกพร่องและความไม่สมบูรณ์ของตนเอง โดยแยกแยะระหว่างคุณค่าของตัวตนกับพฤติกรรมที่ผิดพลาด

จากบทความนี้แสดงให้เห็นว่าการพัฒนาคุณลักษณะภายในทั้ง 7 ด้านนี้ ถือเป็นรากฐานสำคัญที่ช่วยเสริมสร้างความมั่นคงทางจิตใจและเตรียมความพร้อมสำหรับการพัฒนาทักษะทางวิชาชีพในลำดับต่อไป

2.3 เทคนิคการจำแนกข้อมูล (Classification Techniques)

เทคนิคการจำแนกข้อมูล (Classification Techniques) เป็นหนึ่งในการเรียนรู้ของเครื่อง (Machine Learning) ที่ช่วยในการทำเหมืองข้อมูล อยู่ในกลุ่มของการเรียนรู้แบบมีผู้สอน (Supervised Learning) โดยกำหนดวัตถุประสงค์ เพื่อให้โมเดลสามารถเรียนรู้จากข้อมูลที่นำเข้า

และให้ผลลัพธ์ที่ตอบคำถามตามวัตถุประสงค์ได้ ซึ่งคำตอบที่ได้จากจำแนก (Classification) จะอยู่ในรูปแบบค่าที่ไม่ต่อเนื่อง (Discrete Value) ทำให้สามารถตอบคำถามที่กำหนดคำตอบไว้ล่วงหน้าได้ เช่น ใช่ หรือ ไม่ใช่ เป็นต้น

พื้นฐานของเทคนิคการจำแนกข้อมูลจะถูกนำมาใช้ในการแยกประเภทข้อมูล เพื่ออธิบายข้อมูลนั้น ผ่านการทำนายลักษณะของข้อมูลแต่ละตัวว่าตรงกับประเภทไหน ด้วยการสอนโมเดลด้วยชุดข้อมูลตัวอย่าง เช่น การแยกว่าเป็นผู้ป่วยมะเร็งหรือไม่จากข้อมูลอาการ การวิเคราะห์ประสิทธิภาพการรักษา หรือ การตรวจสอบเพื่ออนุมัติบัตรเครดิต อัลกอริทึมที่ใช้ในการจำแนกข้อมูลมีให้เลือกใช้หลากหลาย ในที่นี้จะขอยกตัวอย่างแบบจำลองที่จะนำมาใช้ในการวิจัยเท่านั้น มีรายละเอียดดังต่อไปนี้

2.3.1 อัลกอริทึมเนฟเบส์ (Naïve Bayes) เป็นวิธีการจำแนกประเภทข้อมูล (Classification Algorithm) ที่พัฒนาขึ้นบนพื้นฐานของทฤษฎีความน่าจะเป็นของเบย์ (Bayes' Theorem) ซึ่งถูกนำเสนอครั้งแรกโดย Thomas Bayes (1763) อัลกอริทึมนี้ทำงานภายใต้สมมติฐานหลักเรื่อง "ความเป็นอิสระอย่างมีเงื่อนไข" ซึ่งกำหนดให้คุณลักษณะแต่ละตัวมีความเป็นอิสระต่อกันอย่างสมบูรณ์เมื่อกำหนดคลาสเป้าหมาย กล่าวคือการปรากฏของค่าคุณลักษณะหนึ่งจะไม่ส่งผลต่อความน่าจะเป็นของอีกคุณลักษณะหนึ่ง (Han et al., 2012; Mitchell, 1997)

หลักการคำนวณของนาอีฟเบย์มุ่งเน้นการหาค่าความน่าจะเป็นสูงสุดภายหลัง (Maximum A Posteriori: MAP) เพื่อใช้ในการตัดสินใจทำนายคลาสของข้อมูลใหม่ โดยอาศัยความสัมพันธ์ระหว่างความน่าจะเป็นก่อนหน้า (Prior Probability) และความน่าจะเป็นของเหตุการณ์ (Likelihood) มีกระบวนการทำงาน ประกอบด้วย 4 ขั้นตอนสำคัญ ดังนี้ (Han et al., 2012; Mitchell, 1997)

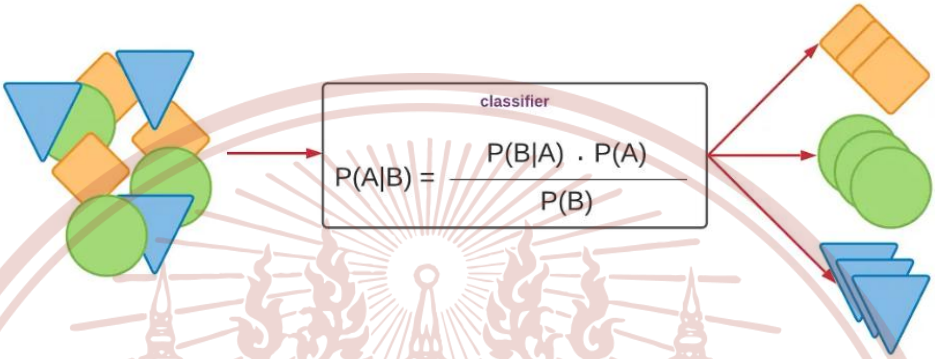
2.3.1.1 การคำนวณความน่าจะเป็นก่อนหน้า (Prior Probability Estimation) ดำเนินการคำนวณหาอัตราส่วนความน่าจะเป็นของแต่ละคลาสเป้าหมาย $P(C_i)$ จากชุดข้อมูลฝึกสอน (Training Data) ทั้งหมด

2.3.1.2 การคำนวณค่าไลคลิฮูด (Likelihood Estimation) คำนวณค่าความน่าจะเป็นแบบมีเงื่อนไข $P(X|C_i)$ ของแต่ละคุณลักษณะที่จะเกิดขึ้นในแต่ละคลาส เพื่อประเมินโอกาสที่ข้อมูลนำเข้าจะอยู่ในคลาสนั้น ๆ

2.3.1.3 การคำนวณความน่าจะเป็นภายหลัง (Posterior Probability Calculation) นำค่าความน่าจะเป็นก่อนหน้า (Prior) และค่าไลคลิฮูด (Likelihood) มาคำนวณตามสูตรของเบย์ เพื่อหาค่าความน่าจะเป็นของการเป็นคลาส C_i เมื่อกำหนดคุณลักษณะ ให้ X ดังสมการที่ 2-1

$$P(C_i|X) = \frac{P(X|C_i)\,P(C_i)}{P(X)} \qquad (2\text{-}1)$$

2.3.1.4 กฎการตัดสินใจ (Decision Rule) ทำการเปรียบเทียบค่าความน่าจะเป็นภายหลัง (Posterior) ของทุกคลาส และเลือกคลาสที่มีค่าความน่าจะเป็นสูงที่สุด (Maximum Likelihood) เป็นคำตอบสุดท้ายสำหรับการพยากรณ์



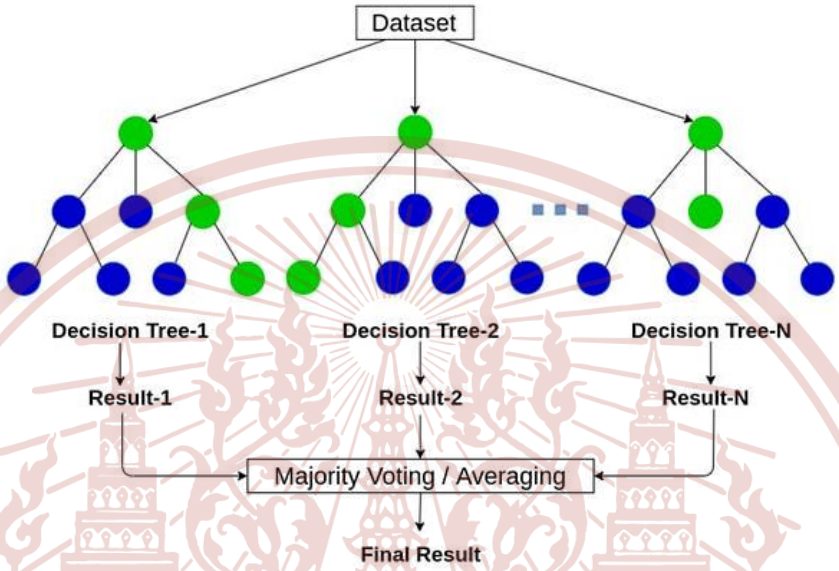
ภาพที่ 2-1 กระบวนการทำงานของอัลกอริทึม Naïve bayes (Ajay mehta,2023)

จากการศึกษาพบว่า นาอีฟเบย์มีจุดเด่นด้านประสิทธิภาพการประมวลผลที่รวดเร็ว (Computational Efficiency) และใช้ทรัพยากรต่ำจึงเหมาะสมอย่างยิ่งกับชุดข้อมูลขนาดใหญ่ (Large Scale Data) และข้อมูลที่มีมิติสูง (High-Dimensional Data) เช่น งานจำแนกหมวดหมู่ข้อความ (Text Classification) นอกจากนี้ยังมีความสามารถในการจัดการกับปัญหาข้อมูลสูญหาย (Missing Data) ได้โดยการละเว้นคุณลักษณะที่หายไปในการคำนวณ และสามารถสร้างแบบจำลองที่มีประสิทธิภาพได้แม้ใช้ข้อมูลฝึกสอนจำนวนจำกัด (Small Training Data)

อย่างไรก็ตามอัลกอริทึมนาอีฟเบย์ก็ยังคงมีข้อจำกัดในสมมติฐานเรื่อง ความเป็นอิสระของคุณลักษณะ ซึ่งในข้อมูลจริงคุณลักษณะต่างๆ มักมีความสัมพันธ์กัน (Correlation) ทำให้ค่าความน่าจะเป็นที่คำนวณได้อาจคลาดเคลื่อนไปจากความเป็นจริง นอกจากนี้อาจประสบปัญหาความน่าจะเป็นศูนย์ (Zero-Frequency Problem) ในกรณีที่พบคุณลักษณะในชุดข้อมูลทดสอบที่ไม่เคยปรากฏในชุดข้อมูลฝึกสอน ส่งผลให้ค่าความน่าจะเป็นรวมกลายเป็นศูนย์ ซึ่งปัญหานี้สามารถแก้ไขได้ด้วยเทคนิค Laplace Smoothing หรือการบวกค่าคงที่เล็กน้อยเข้าไปในความน่าจะเป็น (Han et al., 2012)

2.3.2 อัลกอริทึมทฤษฎีป่าสุ่ม (Random Forest) เป็นเทคนิคการเรียนรู้ของเครื่องแบบกลุ่ม (Ensemble Learning) ประเภท Bagging (Bootstrap Aggregating) ที่ถูกเสนอโดย Breiman (2001) หลักการทำงานพื้นฐานคือการสร้างแบบจำลองต้นไม้ตัดสินใจ (Decision Trees) จำนวนมาก โดยแต่ละต้นจะเรียนรู้จากชุดข้อมูลย่อยที่ถูกสุ่มขึ้นมา และทำการตัดสินใจร่วมกันเพื่อหาผลลัพธ์สุดท้าย วิธีการนี้ช่วยแก้ปัญหาความแปรปรวนสูง (High Variance) และลดโอกาสการเกิดภาวะ

การเรียนรู้เกิน (Overfitting) ที่มักพบในต้นไม้ตัดสินใจเดี่ยว (Single Decision Tree) มีกระบวนการทำงาน ประกอบด้วย 3 ขั้นตอนสำคัญ ดังนี้ (Han et al., 2012; Breiman, 2001)



ภาพที่ 2-2 การทำงานของอัลกอริทึม Random Forest (Gittamade Suengsiri, 2022)

2.3.2.1 การสุ่มตัวอย่างแบบบูตสแตรป (Bootstrap Sampling) ทำการสุ่มตัวอย่างข้อมูลจากชุดข้อมูลฝึกสอนหลักแบบใส่คืน (Sampling with Replacement) เพื่อสร้างชุดข้อมูลย่อยจำนวน k ชุด

2.3.2.2 การสร้างต้นไม้ตัดสินใจ (Tree Construction) สำหรับแต่ละชุดข้อมูลย่อย โดยในแต่ละโหนดของการแตกกิ่ง จะทำการสุ่มเลือกคุณลักษณะจำนวนหนึ่งขึ้นมาพิจารณา แทนที่จะใช้คุณลักษณะทั้งหมด

2.3.2.3 การประมวลผลผลลัพธ์ (Aggregation)

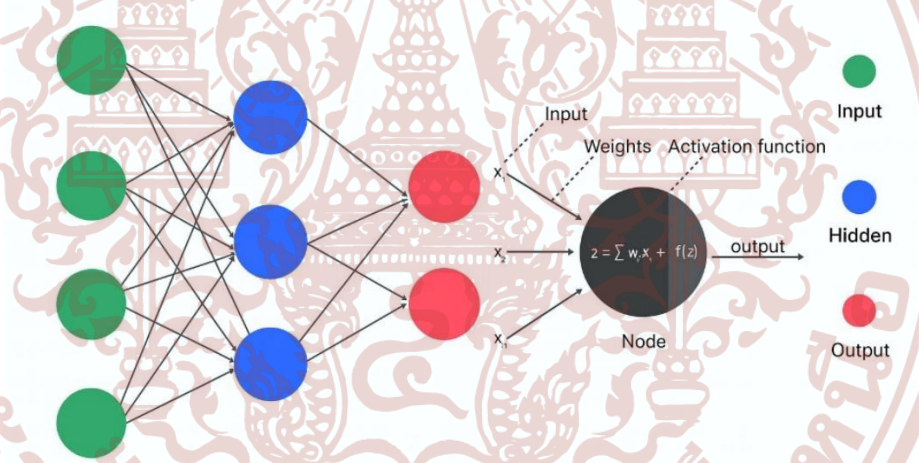
2.3.2.3.1 สำหรับงานจำแนกประเภท (Classification) ใช้วิธีการลงคะแนนเสียงข้างมาก (Majority Voting) จากผลลัพธ์ของต้นไม้ทุกต้น

2.3.2.3.2 สำหรับงานพยากรณ์ค่า (Regression) ใช้วิธีการหาค่าเฉลี่ย (Averaging) ของผลลัพธ์ทั้งหมด

อัลกอริทึมทฤษฎีป่าสุ่ม (Random Forest) ได้รับการยอมรับว่าเป็นหนึ่งในอัลกอริทึมที่มีความแม่นยำสูง สามารถจัดการกับข้อมูลที่มีมิติสูงและข้อมูลที่มีความสัมพันธ์ซับซ้อน (Non-linear) ได้ดี มีความทนทานต่อสัญญาณรบกวน (Noise) และข้อมูลสูญหาย (Missing Values) นอกจากนี้ยังสามารถให้ค่าความสำคัญของตัวแปร ซึ่งเป็นประโยชน์ต่อการคัดเลือกปัจจัยที่มีผลต่อการพยากรณ์

อย่างไรก็ตามยังคงมีข้อจำกัดอยู่ เนื่องจากต้องสร้างต้นไม้จำนวนมาก ทำให้ใช้ทรัพยากรหน่วยความจำและเวลาในการประมวลผลสูงกว่าอัลกอริทึมพื้นฐาน อีกทั้งแบบจำลองมีความซับซ้อนสูง เปรียบเสมือนกล่องดำ (Black Box) ทำให้ยากต่อการอธิบายกระบวนการตัดสินใจภายใน เมื่อเปรียบเทียบกับต้นไม้ตัดสินใจเดี่ยว

2.3.3 อัลกอริทึมโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) เป็นแบบจำลองทางคณิตศาสตร์ที่ได้รับแรงบันดาลใจจากโครงสร้างและการทำงานของเซลล์ประสาทในสมองมนุษย์ (Biological Neurons) พัฒนาขึ้นเพื่อเลียนแบบกระบวนการเรียนรู้และจดจำรูปแบบที่ซับซ้อน โครงสร้างพื้นฐานประกอบด้วยหน่วยประมวลผลย่อยที่เรียกว่า "นิวรอน (Neuron)" เชื่อมต่อกันเป็นชั้น ๆ (Layers) โดยมีการส่งสัญญาณระหว่างกันผ่านค่าน้ำหนัก (Weights) (วิริทธิ์พล เกษมสุข, 2565; Haykin, 2009) มีกระบวนการทำงาน ประกอบด้วย 3 ขั้นตอนสำคัญ ดังนี้ (Rumelhart et al., 1986)



ภาพที่ 2-3 การทำงานของอัลกอริทึม Artificial Neural Network (Shishir Kaphle, 2026)

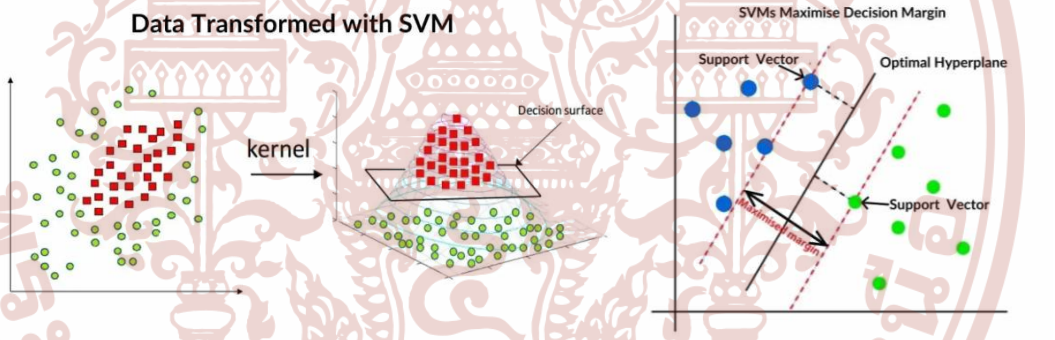
2.3.3.1 การป้อนข้อมูลไปข้างหน้า (Feedforward) ข้อมูลนำเข้าจะถูกส่งผ่านชั้นอินพุต (Input Layer) ไปยังชั้นซ่อน (Hidden Layer) และชั้นเอาต์พุต (Output Layer) โดยแต่ละนิวรอนจะคำนวณผลรวมถ่วงน้ำหนักและผ่านฟังก์ชันกระตุ้น (Activation Function) เช่น Sigmoid หรือ ReLU

2.3.3.2 การคำนวณค่าความผิดพลาด (Error Calculation) เปรียบเทียบผลลัพธ์ที่ได้กับค่าเป้าหมายจริงเพื่อหาค่าความสูญเสีย (Loss)

2.3.3.3 การแพร่กระจายกลับ (Backpropagation) นำค่าความผิดพลาดมาคำนวณย้อนกลับเพื่อปรับปรุงค่าน้ำหนัก (Weight Update) ของแต่ละจุดเชื่อมต่อ โดยใช้วิธีการลดระดับความชัน (Gradient Descent) เพื่อให้ความผิดพลาดลดลงในรอบถัดไป

อัลกอริทึมโครงข่ายประสาทเทียม (Artificial Neural Network: ANN) มีความสามารถสูงในการเรียนรู้รูปแบบความสัมพันธ์ที่ไม่เป็นเชิงเส้น (Non-linear Relationship) และซับซ้อนมากได้ดี เหมาะสำหรับงานที่กฎเกณฑ์ไม่ชัดเจน เช่น การจดจำภาพ เสียง หรือการพยากรณ์ข้อมูลที่มีความผันผวนสูง แต่ต้องใช้ข้อมูลจำนวนมากในการฝึกสอนและใช้ทรัพยากรการประมวลผลสูง นอกจากนี้ยังมีปัญหาเรื่องความยากในการตีความผลลัพธ์ และความเสี่ยงที่จะติดอยู่ในจุดดีที่สุดเฉพาะที่ รวมถึงปัญหาระยะเวลาในการฝึกสอนที่ยาวนาน

2.3.4 อัลกอริทึมเวกเตอร์สนับสนุน (Support Vector Machine: SVM) เป็นอัลกอริทึมการเรียนรู้แบบมีผู้สอนที่เสนอโดย Vapnik (1995) มีพื้นฐานมาจากทฤษฎีการเรียนรู้ทางสถิติ (Statistical Learning Theory) หลักการสำคัญคือการค้นหาระนาบเกิน (Hyperplane) ที่ดีที่สุดในการแบ่งแยกกลุ่มข้อมูลออกจากกัน โดยพยายามทำให้ระยะห่างระหว่างระนาบกับข้อมูลตัวอย่างที่อยู่ใกล้ที่สุด (Support Vectors) ของแต่ละคลาสมีค่ามากที่สุด (Maximum Margin) มีกระบวนการทำงาน ประกอบด้วย 2 ขั้นตอนสำคัญ ดังนี้



ภาพที่ 2-4 การทำงานของอัลกอริทึม Support Vector Machine (Kyriaki et.al, 2024)

2.3.4.1 การแปลงมิติข้อมูล (Kernel Trick) หากข้อมูลไม่สามารถแบ่งแยกเชิงเส้นได้ในมิติเดิม อัลกอริทึมจะใช้ฟังก์ชันเคอร์เนล (Kernel Function) เพื่อแปลงข้อมูลไปยังปริภูมิที่มีมิติสูงขึ้น

2.3.4.2 การค้นหาระนาบที่เหมาะสม (Hyperplane Optimization) คำนวณหาระนาบที่สามารถแบ่งแยกคลาสข้อมูลโดยมีระยะขอบกว้างที่สุด เพื่อลดความเสี่ยงในการทำนายผิดพลาดกับข้อมูลใหม่

อัลกอริทึมเวกเตอร์สนับสนุน (Support Vector Machine: SVM) มีประสิทธิภาพสูงในปริภูมิที่มีมิติสูง (High-dimensional spaces) และมีความแม่นยำสูง แม้จะมีจำนวนตัวอย่างฝึกสอนน้อยกว่าจำนวนมิติ มีความทนทานต่อปัญหาการเรียนรู้เกินไป เนื่องจากเน้นการหาระยะขอบสูงสุด (Cortes & Vapnik, 1995) แต่ไม่เหมาะสมกับชุดข้อมูลที่มีขนาดใหญ่มาก เนื่องจากใช้เวลาใน

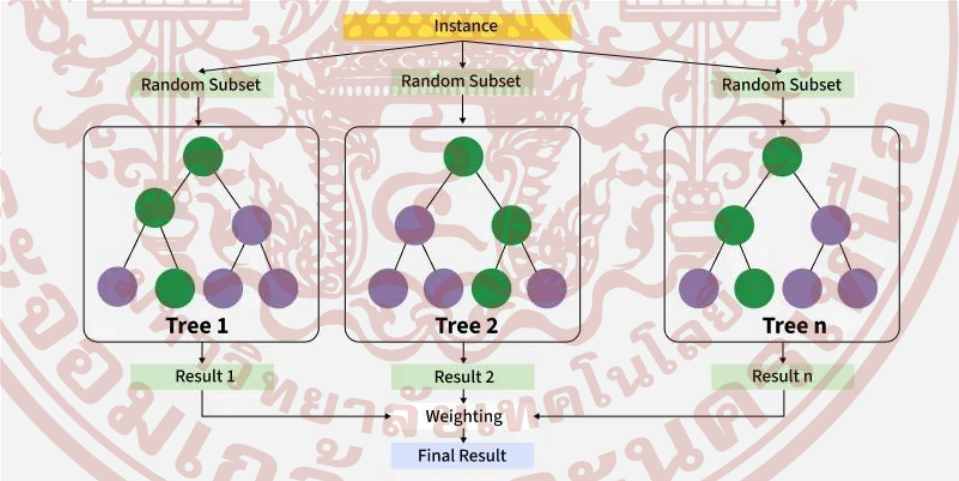
การฝึกสอนนาน และมีประสิทธิภาพลดลงหากข้อมูลมีสัญญาณรบกวน (Noise) มาก หรือมีการซ้อนทับกันของคลาสสูง อีกทั้งการเลือกฟังก์ชันเคอร์เนลและการปรับจูนพารามิเตอร์ต้องอาศัยความเชี่ยวชาญ

2.3.5 อัลกอริทึมการบูสต์ไล่ระดับ (Extreme Gradient Boosting: XGBoost) เป็นอัลกอริทึมในกลุ่ม Gradient Boosting Framework ที่พัฒนาโดย Chen และ Guestrin (2016) ออกแบบมาเพื่อเพิ่มประสิทธิภาพความเร็วและประสิทธิภาพการทำงานที่ดีกว่า Gradient Boosting แบบดั้งเดิม โดยเน้นการสร้างแบบจำลองอย่างต่อเนื่อง และมีการเพิ่มเทอมมาตรฐาน (Regularization Term) ในฟังก์ชันวัตถุประสงค์เพื่อควบคุมความซับซ้อนของโมเดล มีกระบวนการทำงาน ประกอบด้วย 3 ขั้นตอนสำคัญ ดังนี้

2.3.5.1 การสร้างแบบจำลองตั้งต้นทำนายอย่างง่าย

2.3.5.2 การคำนวณและปรับปรุง โดยสร้างโมเดลใหม่ขึ้นมาเพื่อทำนายค่าความผิดพลาด ของโมเดลก่อนหน้า โดยใช้วิธี Gradient Descent เพื่อลดค่าความเสียหาย

2.3.5.3 การรวมผลลัพธ์ (Ensemble) จากโมเดลย่อยทั้งหมด มารวมกันเป็นโมเดลสุดท้ายที่มีความแม่นยำสูง



ภาพที่ 2-5 กระบวนการทำงานของอัลกอริทึม Extreme Gradient Boosting (GeeksforGeek, 2025)

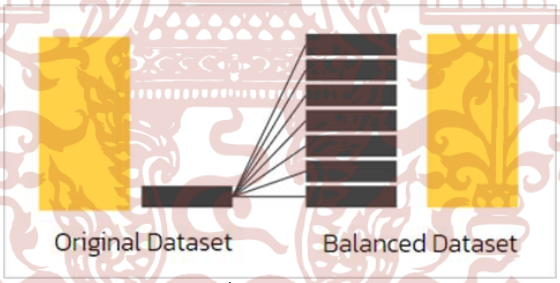
อัลกอริทึมการบูสต์ไล่ระดับ (Extreme Gradient Boosting: XGBoost) มีประสิทธิภาพสูงมากในปัจจุบัน สามารถประมวลผลแบบขนาน (Parallel Processing) ทำให้ทำงานรวดเร็ว มีระบบจัดการกับข้อมูลสูญหายในตัว (Built-in Handling of Missing Values) และมีกลไกป้องกันการเรียนรู้มากเกินไปได้อย่างดีเยี่ยม แต่มีข้อจำกัดตรงที่มีไฮเปอร์พารามิเตอร์ (Hyperparameters)

จำนวนมากที่ต้องปรับจูน ซึ่งอาจมีความซับซ้อนสำหรับผู้เริ่มต้น และอาจเกิดปัญหาการเรียนรู้มากเกินไปได้ หากข้อมูลฝึกสอนมีสัญญาณรบกวนมากเกินไปและไม่ได้ปรับจูนพารามิเตอร์อย่างเหมาะสม

2.4 เทคนิคการปรับข้อมูลไม่สมดุลกัน (Imbalanced Data)

ปัญหาข้อมูลไม่สมดุลกัน (Class Imbalance) คือ ภาวะที่การกระจายตัวของกลุ่มข้อมูลในแต่ละคลาสมีความแตกต่างกันอย่างมีนัยสำคัญ โดยคลาสที่มีจำนวนข้อมูลมากกว่าเรียกว่า คลาสส่วนใหญ่ (Majority Class) และคลาสที่มีจำนวนข้อมูลน้อยกว่าเรียกว่า คลาสส่วนน้อย (Minority Class) ปัญหานี้ส่งผลกระทบโดยตรงต่อประสิทธิภาพของอัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) ทำให้แบบจำลองมีแนวโน้มที่จะเกิดความลำเอียง (Bias) โดยทำนายเข้าหาคลาสส่วนใหญ่และละเลยคลาสส่วนน้อย ซึ่งมักเป็นคลาสที่มีความสำคัญ (Udu et al., 2025) การแก้ไขปัญหาข้อมูลไม่สมดุลกันนั้นมีหลายหลายวิธี ในที่นี้จะขอกล่าวถึงวิธีการแก้ไขปัญหาระดับข้อมูล ที่นิยมนำมาใช้แบ่งออกเป็น 3 วิธี ดังนี้

2.4.1 การสุ่มเพิ่มข้อมูล (Over-Sampling) เพื่อเพิ่มข้อมูลในคลาสขนาดเล็ก ให้มีขนาดใกล้เคียงหรือเท่ากับคลาสขนาดใหญ่ สามารถทำได้ 2 วิธี คือ



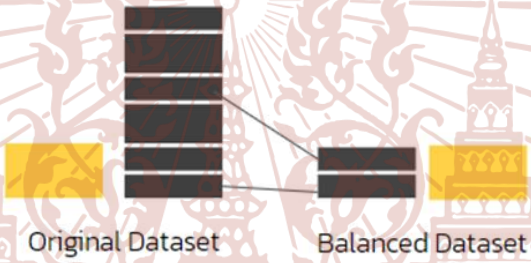
ภาพที่ 2-6 เทคนิคการสุ่มเพิ่มข้อมูล (รัชนก พิยาพาณิชยกุล, 2566)

2.4.1.1 การสุ่มเพิ่มข้อมูลแบบดั้งเดิม (Random Over-Sampling: ROS) เป็นเทคนิคการจัดการข้อมูลที่ไม่สมดุลโดยมุ่งเน้นการเพิ่มจำนวนตัวอย่างในคลาสส่วนน้อย (Minority Class) ด้วยวิธีการสุ่มเลือกข้อมูลซ้ำจากชุดข้อมูลเดิม (Random Sampling with Replacement) เพื่อให้สัดส่วนของข้อมูลมีความสมดุล อย่างไรก็ตาม วิธีการนี้มีข้อจำกัดสำคัญคืออาจก่อให้เกิดปัญหาความซ้ำซ้อนของข้อมูล (Data Redundancy) เนื่องจากการใช้ข้อมูลชุดเดิมซ้ำ ๆ ซึ่งเพิ่มความเสี่ยงให้แบบจำลองเกิดภาวะการเรียนรู้เกิน (Overfitting) โดยโมเดลอาจจดจำรายละเอียดของข้อมูลฝึกสอนมากเกินไปจนไม่สามารถพยากรณ์ข้อมูลชุดใหม่ได้อย่างมีประสิทธิภาพ

2.4.1.2 เทคนิคการสังเคราะห์ข้อมูลส่วนน้อย (Synthetic Minority Over-sampling Technique: SMOTE) เป็นเทคนิคการเพิ่มจำนวนข้อมูลที่ได้รับการพัฒนาเพื่อแก้ไขข้อจำกัดของวิธี ROS โดยอาศัยหลักการสร้างข้อมูลสังเคราะห์ชุดใหม่ (Synthetic Instances) ขึ้นมาจากการคำนวณเชิงเส้น

ระหว่างข้อมูลตัวอย่างและข้อมูลเพื่อนบ้านใกล้เคียง (k-Nearest Neighbors) แทนการคัดลอกข้อมูลซ้ำ กระบวนการนี้ช่วยให้การกระจายตัวของข้อมูลในคลาสส่วนน้อยมีความหนาแน่นและความหลากหลายมากขึ้น (Better Distribution) อีกทั้งยังช่วยรักษาคุณลักษณะสำคัญของข้อมูล (Feature Preservation) ซึ่งส่งผลให้ขอบเขตการตัดสินใจของแบบจำลองมีความชัดเจนและช่วยลดโอกาสในการเกิดภาวะการเรียนรู้เกิน (Overfitting) ได้อย่างมีประสิทธิภาพ

2.4.2 การลดจำนวนตัวอย่างข้อมูล (Under-Sampling) เป็นเทคนิคการจัดการความไม่สมดุลของข้อมูลโดยมุ่งเน้นการลดทอนจำนวนตัวอย่างในกลุ่มข้อมูลคลาสส่วนใหญ่ (Majority Class) เพื่อปรับสัดส่วนให้มีความใกล้เคียงหรือเท่ากับกลุ่มข้อมูลคลาสส่วนน้อย (Minority Class)



ภาพที่ 2-7 เทคนิคการสุ่มลดข้อมูล (รัชนก พิยาพาณิชยกุล, 2566)

การลดจำนวนตัวอย่างข้อมูลนิยมใช้เทคนิคโทเมกลิงก์ (Tomek Links: T-Links) ซึ่งเป็นวิธีการคัดกรองและทำความสะอาดข้อมูล (Data Cleaning) โดยพิจารณาจากคู่ของตัวอย่างข้อมูลต่างคลาสที่มีระยะห่างระหว่างกันน้อยที่สุด (Nearest Neighbors) หรือที่เรียกว่า Tomek Links กระบวนการทำงานจะดำเนินการลบตัวอย่างข้อมูลที่เป็นคลาสส่วนใหญ่ในคู่นั้นออก เพื่อขยายระยะห่างระหว่างคลาส (Class Separation) ให้กว้างขึ้น ส่งผลให้เส้นแบ่งการตัดสินใจ (Decision Boundary) มีความชัดเจนลดความซ้อนทับกันของข้อมูล (Overlapping) และช่วยเพิ่มประสิทธิภาพในการจำแนกประเภทข้อมูล



ภาพที่ 2-8 เทคนิคการสุ่มแบบผสม (รัชนก พิยาพาณิชยกุล, 2566)

2.4.3 การสุ่มแบบผสมผสาน (Hybrid Sampling) เป็นกระบวนการจัดการความไม่สมดุลของข้อมูลโดยการบูรณาการระหว่างวิธีการลดจำนวนตัวอย่างข้อมูล (Under-sampling) และการเพิ่มจำนวนตัวอย่างข้อมูล (Over-sampling) เข้าด้วยกัน เพื่อปรับดุลยภาพของข้อมูลในแต่ละคลาสให้มีความใกล้เคียงกันหรือเท่ากัน โดยเทคนิคที่นำมาประยุกต์ใช้ ได้แก่ เทคนิคสโมทโทเมกลิงก์ (SMOTE-

Tomek) เป็นเทคนิคการจัดการข้อมูลแบบผสมผสาน (Hybrid Approach) ที่รวมประสิทธิภาพของอัลกอริทึม SMOTE และ Tomek Links เข้าด้วยกัน โดยมีขั้นตอนการทำงานเริ่มต้นจากการสร้างข้อมูลสังเคราะห์เพิ่มให้กับกลุ่มข้อมูลคลาสส่วนน้อย (Minority Class) ด้วยเทคนิค SMOTE เพื่อปรับสัดส่วนข้อมูลให้มีความสมดุล จากนั้นจึงดำเนินการประยุกต์ใช้เทคนิค Tomek Links เพื่อตรวจสอบและกำจัดข้อมูลที่อยู่บริเวณรอยต่อระหว่างคลาส (Class Boundary) หรือข้อมูลที่เป็นสัญญาณรบกวน (Noise) ออก กระบวนการนี้ช่วยลดปัญหาการซ้อนทับกันของข้อมูล (Overlapping) และทำให้ขอบเขตการตัดสินใจ (Decision Boundary) ระหว่างกลุ่มข้อมูลมีความชัดเจนยิ่งขึ้น ส่งผลให้แบบจำลองมีประสิทธิภาพในการจำแนกประเภทที่ดียิ่งขึ้น

จากการศึกษาพบว่า เทคนิคการเพิ่มข้อมูลสังเคราะห์ (SMOTE) นิยมนำมาใช้กรณีที่ชุดข้อมูลมีขนาดเล็ก (Small Dataset) การใช้วิธีลดจำนวนข้อมูล (Undersampling) อาจทำให้สูญเสียสารสนเทศที่สำคัญไป ดังนั้น เทคนิคการเพิ่มจำนวนข้อมูล (Oversampling) จึงเป็นทางเลือกที่เหมาะสมกว่าวิธีอื่น (Chuanjun Zhao et al., 2024) จึงเป็นที่มาของการเลือกใช้เทคนิคนี้ในงานวิจัย เนื่องจากข้อมูลมีปริมาณน้อย และไม่สมดุลกัน

2.5 การวัดประสิทธิภาพของแบบจำลองพหุคลาส (Multi Class Metrics)

เนื่องจากงานวิจัยนี้ มีตัวแปรเป้าหมายเป็นผลสัมฤทธิ์ทางการเรียนที่มีหลายระดับ (Multi-class) การคำนวณค่าประสิทธิภาพจึงใช้หลักการ One-vs-Rest (OvR) หรือการพิจารณาทีละคลาสเทียบกับคลาสที่เหลือทั้งหมด โดยกำหนดให้ K คือจำนวนคลาสทั้งหมด และ i แทนคลาสที่กำลังพิจารณา (i = 1, 2, ..., K) แสดงสมการสำหรับแบบจำลองแบบพหุคลาส

2.5.1 ค่าความแม่นยำ (Accuracy) คือ สัดส่วนของจำนวนข้อมูลที่แบบจำลองทำนายได้ถูกต้องทั้งหมดของคลาสบวกและคลาสลบต่อจำนวนข้อมูลทั้งหมด เป็นค่าพื้นฐานที่แสดงภาพรวมความสามารถของแบบจำลอง อย่างไรก็ตามค่าความแม่นยำอาจให้ผลลวงได้ในกรณีที่ชุดข้อมูลมีความไม่สมดุลสูง (Imbalanced Dataset) เนื่องจากแบบจำลองอาจทำนายเข้าข้างคลาสส่วนใหญ่ (Majority Class) (Ali et al., 2023) ดังสมการที่ 2-2

$$Accuracy = \frac{\sum_{i=1}^{k} TP_i}{N} \quad (2\text{-}2)$$

2.5.2 ค่าความเที่ยงตรง (Precision) หรือค่าความน่าจะเป็นที่ผลการทำนายเชิงบวกจะถูกต้อง คือ สัดส่วนของจำนวนข้อมูลที่ทำนายว่าเป็นคลาสเป้าหมาย (Positive) ได้อย่างถูกต้องต่อจำนวนข้อมูลที่ทำนายว่าเป็นคลาสเป้าหมายทั้งหมด ค่านี้มีความสำคัญเมื่อผู้วิจัยต้องการลดความผิดพลาดประเภท False Positive (Grandini et al., 2020) มีขั้นตอนดังนี้

2.5.2.1 หาความเที่ยงตรง (Precision) ของแต่ละคลาส

$$Precision = \frac{TP_i}{TP_i+FP_i} \quad (2\text{-}3)$$

2.5.2.2 หาค่าเฉลี่ยแบบให้ความสำคัญทุกคลาสเท่ากัน (Macro Precision)

$$Precision_{macro} = \frac{1}{K}\sum_{i=1}^{K} Precision_i \quad (2\text{-}4)$$

2.5.3 ค่าระลึก (Recall) เป็นสัดส่วนของจำนวนข้อมูลคลาสเป้าหมายที่ทำนายถูก ต่อจำนวนข้อมูลที่เป็นคลาสเป้าหมายตามจริงทั้งหมด ค่านี้มีความสำคัญสูงสุดในงานวิจัยที่ต้องการค้นหาคลาสเป้าหมายให้ได้มากที่สุดและไม่ต้องการให้เกิด False Negative (Sarker, 2021) มีขั้นตอนดังนี้

2.5.3.1 หาค่าระลึก (Recall) ของแต่ละคลาส

$$Recall = \frac{TP_i}{TP_i+FN_i} \quad (2\text{-}5)$$

2.5.3.2 หาค่าเฉลี่ยรวมแบบให้ความสำคัญทุกคลาสเท่ากัน (Macro Recall)

$$Recall_{Macro} = \frac{1}{K}\sum_{i=1}^{K} Recall_i \quad (2\text{-}6)$$

2.5.4 ค่าความสมดุลระหว่างความเที่ยงตรงและค่าระลึก (F1-Score) คือ ค่าเฉลี่ยฮาร์โมนิก (Harmonic Mean) ระหว่างค่าความเที่ยงตรง (Precision) และค่าระลึก (Recall) เป็นดัชนีชี้วัดที่มีความสำคัญอย่างยิ่งสำหรับการวัดผลโมเดลที่จัดการกับข้อมูลไม่สมดุล (Imbalanced Data) เนื่องจากค่า F1-Score จะมีค่าสูงได้ก็ต่อเมื่อทั้งค่า Precision และ Recall มีค่าสูงพร้อมกัน ซึ่งช่วยป้องกันกรณีที่โมเดลมีความลำเอียงไปทางใดทางหนึ่ง (Tharwat, 2021) มีขั้นตอนดังนี้

2.5.4.1 หา F1-score ของแต่ละคลาส

$$F1_i = 2 \times \frac{Precision_i \times Recall_i}{Precision_i + Recall_i} \quad (2\text{-}7)$$

2.5.4.2 หาค่าเฉลี่ยรวมแบบให้ความสำคัญทุกคลาสเท่ากัน (Macro F1-score)

$$F1_{Macro} = \frac{1}{K}\sum_{i=1}^{K} F1_i \quad (2\text{-}8)$$

2.5.5 นิยามตัวแปร จากสมการคำนวณกรณีที่มีจำนวนคลาสทั้งหมด K คลาส โดยที่ K มีค่ามากกว่า 2 ขึ้นไป กำหนดให้ความหมายตัวแปร ดังนี้

i	แทน	คลาสที่กำลังพิจารณา (i = 1.....K)
TP_i	แทน	จำนวนข้อมูลที่ทำนายคลาส i ถูกต้อง

FP_i	แทน	จำนวนที่ทำนายผิดว่าเป็นคลาส i
FN_i	แทน	จำนวนที่เป็นคลาส i แต่ทำนายผิดเป็นคลาสอื่น
N	แทน	จำนวนข้อมูลทั้งหมด
N_i	แทน	จำนวนข้อมูลจริงที่มีอยู่ในคลาส i

2.6 ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation)

2.6.1 ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) เป็นค่าทางสถิติที่ใช้วัดระดับความสัมพันธ์ระหว่างตัวแปร 2 ตัวแปร ว่ามีความสัมพันธ์กันในทิศทางใดและมีขนาดความสัมพันธ์มากน้อยเพียงใด โดยค่าสัมประสิทธิ์สหสัมพันธ์จะมีค่าอยู่ระหว่าง -1.00 ถึง +1.00 ซึ่งค่าดังกล่าวจะบ่งบอกถึงทิศทางและระดับของความสัมพันธ์ ดังนี้ (บัญชา ช่วยสี, 2567)

2.6.1.1 ค่าเข้าใกล้ +1.00 หมายถึง ตัวแปรมีความสัมพันธ์กันในทิศทางเดียวกัน (Positive Correlation) กล่าวคือ เมื่อตัวแปรหนึ่งเพิ่มขึ้น อีกตัวแปรหนึ่งก็จะเพิ่มขึ้นตามไปด้วย

2.6.1.2 ค่าเข้าใกล้ -1.00 หมายถึง ตัวแปรมีความสัมพันธ์กันในทิศทางตรงกันข้าม (Negative Correlation) กล่าวคือ เมื่อตัวแปรหนึ่งเพิ่มขึ้น อีกตัวแปรหนึ่งจะลดลง

2.6.1.3 ค่าเข้าใกล้ 0 หมายถึง ตัวแปรทั้งสองไม่มีความสัมพันธ์กันหรือมีความสัมพันธ์กันน้อยมาก (Zero Correlation)

ในการวิจัยทางสังคมศาสตร์และการเหมืองข้อมูล (Data Mining) นิยมใช้ สัมประสิทธิ์สหสัมพันธ์แบบเพียร์สัน (Pearson Product Moment Correlation Coefficient) แทนด้วยสัญลักษณ์ r ซึ่งเหมาะสำหรับข้อมูลที่มีมาตรวัดแบบอันตรภาค (Interval Scale) หรืออัตราส่วน (Ratio Scale) (บัญชา ช่วยสี, 2567; Best, 1981)

2.6.2 สูตรการหาค่าสัมประสิทธิ์สหสัมพันธ์แบบเพียร์สัน (บัญชา ช่วยสี, 2567; Yamane, 1973) ดังสมการที่ 2-9

$$r = \frac{n(\sum xy) - (\sum x)(\sum y)}{\sqrt{[n\sum x^2 - (\sum x)^2][n\sum y^2 - (\sum y)^2]}} \quad (2\text{-}9)$$

เมื่อกำหนดให้ r แทน ค่าสัมประสิทธิ์สหสัมพันธ์

n แทน จำนวนกลุ่มตัวอย่าง

x แทน ข้อมูลตัวแปรตัวที่ 1

y แทน ข้อมูลตัวแปรตัวที่ 2

2.6.3 การแปลความหมาย (Interpretation Criteria) ในการแปลผลระดับความสัมพันธ์ เกณฑ์ของ Best ได้กำหนดเกณฑ์การแปลความหมายค่าสัมประสิทธิ์สหสัมพันธ์ไว้ดังนี้ (บัญชา ช่วยสี, 2567; John W. Best, 1981)

ตารางที่ 2-1 เกณฑ์การแปลความหมายตามแนวคิดของ Best

ค่าสัมประสิทธิ์สหสัมพันธ์	ความหมาย
0.80-1.00	มีความสัมพันธ์กันในระดับสูงมาก
0.60-0.79	มีความสัมพันธ์กันในระดับสูง
0.40-0.59	มีความสัมพันธ์กันในระดับปานกลาง
0.20-0.39	มีความสัมพันธ์กันในระดับต่ำ
0 – 0.19	มีความสัมพันธ์กันในระดับต่ำมากหรือไม่มี

2.7 ค่าน้ำหนักความสำคัญ (Weight By Gini Index)

การกำหนดค่าน้ำหนักความสำคัญของคุณลักษณะด้วยดัชนีจินี (Gini Index) เป็นเทคนิคที่นิยมใช้ควบคู่กับอัลกอริทึมต้นไม้ตัดสินใจ (Decision Tree) และป่าสุ่ม (Random Forest) หลักการพื้นฐานคือ การวัดค่าการลดลงของความไม่บริสุทธิ์ (Mean Decrease in Impurity: MDI) ของข้อมูลในกระบวนการสร้างแบบจำลอง เมื่อมีการเลือกคุณลักษณะใดมาเป็นเกณฑ์ในการแบ่งกลุ่มข้อมูล (Splitting Node) อัลกอริทึมจะคำนวณว่าคุณลักษณะนั้นสามารถจำแนกกลุ่มข้อมูลให้มีความบริสุทธิ์ (Pure) มากขึ้นเพียงใด โดยวัดจากค่าดัชนีจินีที่ลดลง (Gini Decrease) หากคุณลักษณะใดส่งผลให้ค่าความไม่บริสุทธิ์ลดลงมาก จะถือว่าคุณลักษณะนั้นมีค่าน้ำหนักความสำคัญสูงต่อการพยากรณ์ (Sarker, 2021)

การคำนวณด้วยดัชนีจินี (Gini Index) เริ่มจากการหาค่าดัชนีจินี (Gini Impurity) ของโหนดตั้งต้น ซึ่งบ่งบอกถึงความน่าจะเป็นของการจำแนกผิดพลาดหากสุ่มข้อมูลขึ้นมา โดยมีสมการดังนี้ (Laber & Murtaza, 2023) ดังสมการที่ 2-10

$$Gini(D) = 1 - \sum_{i=1}^{K}(P_i)^2 \qquad (2\text{-}10)$$

โดยที่ $Gini(D)$ แทน ค่าความไม่บริสุทธิ์ของชุดข้อมูล D

K แทน จำนวนคลาสเป้าหมาย

P_i แทน สัดส่วนความน่าจะเป็นของข้อมูลที่อยู่ในคลาส i

เมื่อนำคุณลักษณะ A มาใช้ในการแบ่งโหนด ค่าความสำคัญจะวัดจากผลต่างของค่าจินี (Gini Gain) หรือค่าความไม่บริสุทธิ์ที่ลดลง ดังสมการที่ 2-11

$$\Delta Gini(A) = Gini\ (Parent) - \sum_{j=1}^{M}\frac{N_j}{N}\ Gini\ (Child_j) \qquad (2\text{-}11)$$

โดยที่ $\Delta Gini(A)$ แทน ค่าน้ำหนักความสำคัญของคุณลักษณะ D

$Gini\ (Parent)$ แทน ค่าความไม่บริสุทธิ์ของโหนดก่อนแบ่ง

$Gini\ (Child_j)$ แทน ค่าความไม่บริสุทธิ์ของโหนดลูกที่ j หลังการแบ่ง

N แทน จำนวนข้อมูลทั้งหมดในโหนดพ่อ

N_j แทน จำนวนข้อมูลในโหนดลูกที่ j

2.8 งานวิจัยที่เกี่ยวข้อง (Related Research)

สืบพงษ์ พงษ์สวัสดิ์ และ พงศ์กร จันทราช (2568) ได้ทำการศึกษาวิจัย เรื่อง การประยุกต์เทคนิคเหมืองข้อมูลเพื่อพยากรณ์ผลการประเมินบทความจากวารสารนวัตกรรมสังคมและการเรียนรู้ตลอดชีวิต ผลการวิจัยพบว่าเทคนิค Naive Bayes Decision Tree และ K-Nearest Neighbors ในการสร้างแบบจำลองทำนาย พบว่า Naive Bayes มีประสิทธิภาพต่ำที่สุด (20.66%) ในขณะที่ Nearest Neighbors มีความแม่นยำโดยรวมดีที่สุด (82.46%) แต่ Decision Tree ให้ผลลัพธ์ที่สม่ำเสมอมากกว่าผลการวิจัยนี้สามารถนำไปใช้ในการพัฒนาระบบสนับสนุนการประเมินบทความ และเป็นแนวทางสำหรับผู้เขียนในการปรับปรุงคุณภาพบทความเพื่อเพิ่มโอกาสในการตีพิมพ์

พิมพ์ประภา พาลพ่าย และ วชิระ พรหมวงศ์ (2567) ได้ทำการศึกษาวิจัย เรื่อง การใช้เทคนิคเหมืองข้อมูลเพื่อพยากรณ์ผลการเรียนจากพฤติกรรมการเรียนรู้ของนักศึกษาระดับปริญญาโท มหาวิทยาลัยสุโขทัยธรรมาธิราชบนระบบการเรียนออนไลน์ STOU eLearning ผลการวิจัยพบว่าโปรแกรมพยากรณ์นักศึกษาสอบผ่านและไม่ผ่านทั้งสิ้น 39 คน โดยพยากรณ์ว่ามีนักศึกษาสอบผ่านจำนวน 29 คน และ สอบไม่ผ่านจำนวน 4 คน ซึ่งในความจริงมีนักศึกษาสอบผ่าน 31 คน และไม่ผ่าน 8 คน ดังนั้น ความถูกต้องของการพยากรณ์ผลการเรียนจากพฤติกรรมการเรียนรู้ประสิทธิภาพ เท่ากับร้อยละ 84.62

ชลิตา ชีววิริยะนนท์ และ นนทศักดิ์ จันทร์ชุม (2567) ได้ทำการศึกษาวิจัย เรื่องการพัฒนาตัวแบบทำนายทักษะการคิดเชิงคำนวณของนักเรียนชั้นมัธยมศึกษาตอนต้น โดยใช้เทคนิคแมชชีนเลิร์นนิง ผลการวิจัยพบว่า ตัวแบบทำนายที่พัฒนาด้วยเทคนิคต้นไม้ตัดสินใจสามารถทำนายผลระดับทักษะการคิดเชิงคำนวณได้อย่างมีประสิทธิภาพสูงที่สุดมีค่าประสิทธิภาพอยู่ที่ 74.95% และตัวแบบ จากเทคนิคนาอีฟเบย์ แล เทคนิคเพื่อนบ้านใกล้สุดมีค่าความถูกต้อง เท่ากับ60.05% และ 68.48% ตามลำดับ

วงกต ศรีอุไร อนุสรณ์ บันเทิง และ คมกฤษณ์ มุธาพร (2567) ได้ทำการศึกษาวิจัย เรื่อง การพัฒนาระบบแนะนำการเลือกวิชาเอกของสาขาเทคโนโลยีสารสนเทศการสื่อสารโดยใช้เทคนิคต้นไม้ตัดสินใจ ผลการวิจัยพบว่า การทดสอบประสิทธิภาพแบบจำลองด้วยวิธี 10-fold cross validation

พบว่าแบบจำลองที่พัฒนาด้วยอัลกอริทึม C4.5 ให้ประสิทธิภาพดีที่สุด มีค่าความถูกต้องเท่ากับ 93.20% ค่าความแม่นยำเท่ากับ 93.33% และค่าระลึกเท่ากับ 93.32%

ปณิธิ ทองมอญ (2566) ได้ทำการศึกษาวิจัย เรื่อง การวิเคราะห์กฎความสัมพันธ์และการทำนายความสำเร็จในการเรียนรายวิชาในระบบหลักสูตรออนไลน์บแบบเปิดเพื่อมวลชน ผลการวิจัยพบว่า การวิเคราะห์จำแนกกลุ่ม พบว่า Random forest มีประสิทธิภาพสูงสุดเท่ากับ 74.89 % ค่าจำเพาะ 49.20% ค่าเที่ยงตรง 76.62% ในส่วนของเทคนิค Naïve bayes มีค่าความแม่นยำดีกว่าทุกเทคนิค ในขณะที่ Logistic Regression ไม่มีค่าใดสูงกว่าเทคนิคใดเลย

กันต์ ศิระพรธนารัชต์ และ ชุติพนธ์ ศรีสวัสดิ์ (2566) ได้ทำการศึกษาวิจัย เรื่อง การใช้เทคนิคเหมืองข้อมูลเพื่อพยากรณ์การสำเร็จการศึกษา พบว่าการลดลิมิตเมื่อพิจารณาจากค่า Information Gain จากชุดข้อมูล IG5 คู่กับตัวแบบจำลอง Random forest ให้ประสิทธิภาพโดยรวมเหมาะสมที่สุด ซึ่งมีค่าความถูกต้อง เท่ากับ 96.03% ค่าเฉลี่ย F1-score เท่ากับ 88.65%

พิริยพงศ์ หริ่งรอด (2566) ได้ทำการศึกษาวิจัย เรื่อง การพัฒนาโมเดลทำนายความสำเร็จในการเรียนของนักเรียนโดยประยุกต์ใช้การเรียนรู้แบบเอนเซมเบิล จากการพิจารณาค่า F1-Score ,recall และ Precision โดยผลจากการศึกษาพบว่าโมเดล RF และ XBGoost เป็นโมเดลที่มีค่าประสิทธิภาพสูงที่สุดใกล้เคียงกัน (F1-score = 0.904 , recall =0.891, และ precision =0.920)

กนิษฐา อินธิชิต ภควัฒน์ ปิยวงศ์ และ สุภาพร สุขใส (2565) ได้ทำการศึกษาวิจัย เรื่องการพัฒนาแอปพลิเคชันช่วยตัดสินใจในการเลือกเรียนสาขาวิชาคอมพิวเตอร์ในมหาวิทยาลัยราชภัฏศรีสะเกษบนระบบปฏิบัติการแอนดรอยด์ โดยใช้เทคนิคต้นไม้ตัดสินใจ ใช้เทคนิค Decision tree และโปรแกรม RapidMiner และ แพ็คเกต C4.5

ธนพร คล้ายทอง และ ชุติพนธ์ ศรีสวัสดิ์ (2565) ได้ทำการศึกษาวิจัย เรื่องการพยากรณ์การตกออกของนักศึกษาระดับปริญญาตรี มหาวิทยาลัยราชภัฏพิบูลสงคราม ด้วยเทคนิคเหมืองข้อมูล พบว่า แบบจำลองทดสอบประสิทธิภาพของโมเดลด้วยวิธีการ 5-Fold Cross-Validation และ 10-Fold Cross-Validation ซึ่งวัดประสิทธิภาพแบบจำลองด้วยค่าความถูกต้อง (Accuracy) และค่าความผิดพลาด (Mean Absolute Error: MAE) ผลการทดสอบประสิทธิภาพพบว่าแบบจำลองที่ใช้เทคนิคต้นไม้ตัดสินใจได้ค่าสูงที่สุดในการแบ่งข้อมูลทดสอบ 10-Fold Cross-Validation ให้ค่าความถูกต้อง (Accuracy) 97.81% และค่าความผิดพลาด (MAE) เท่ากับ 0.026

ศิรินทรา เสือพิทักษณ์ บุญมี นิสสัยดี และ วิภาวรรณ บัวทอง (2564) ได้ทำการศึกษาวิจัย เรื่อง การเปรียบเทียบเทคนิคการจำแนกประเภทข้อมูลสำหรับทำนายแนวโน้มการสำเร็จการศึกษาของนักเรียน พบว่าการเปรียบเทียบประสิทธิภาพของอัลกอริทึมทั้ง 3 ชนิด แสดงให้เห็นว่าเทคนิคการทำเหมืองข้อมูลแบบจำแนกประเภทข้อมูลโดยใช้อัลกอรึทึมต้นไม้ตัดสินใจให้ค่าการประเมินประสิทธิภาพของแบบจำลองดีที่สุด ซึ่งผลการประเมินแบบจำลองด้วยวิธีการตรวจสอบแบบข้าม

จำนวน 5 กลุ่ม และการตรวจสอบแบบข้ามจำนวน 10 กลุ่ม ให้ผลลัพธ์เท่ากัน คือค่าความถูกต้อง ร้อยละ 87.40 ค่าความแม่นยำร้อยละ 87.50 ค่าเรียกคืน ร้อยละ 87.40 และค่าประเมินผลโดยรวม ร้อยละ 86.70

Xiaojiao Wen (2024) ได้ทำการศึกษาวิจัย เรื่อง Student Grade Prediction and Classification based on Term Frequency – Inverse Document Frequency with Random Forest ผลลัพธ์ที่ได้ทดสอบแบบจำลอง TF-IDF-RF มีประสิทธิภาพดีกว่าเมื่อเทียบกับ KNN ที่มีอยู่เดิม โดยให้ผลลัพธ์ด้านความแม่นยำ (accuracy) 99.5%, ความเที่ยงตรง (precision) 95.2% การระลึก (recall) 96.4% และ F1-score 95.8% ตามลำดับ

Ali Alnoman (2024) ได้ทำการศึกษาวิจัย เรื่อง Regression-based Student Performance Prediction Using the Grades of English, Math, and Programming Courses ผลการวิจัยพบว่า การถดถอยพหุนามจะหาเส้นโค้งที่เหมาะสมที่สุดกับจุดข้อมูล โดยระบุความสัมพันธ์ระหว่างข้อมูลแกน x (เกรดวิชา) และข้อมูลแกน y (แต้มเฉลี่ยสะสม) ใช้การถดถอยพหุนามระดับ 3 ให้ประสิทธิภาพที่ดี โดยหลีกเลี่ยงการเกิด overfitting และ underfitting ในการประเมินประสิทธิภาพการทำนาย ค่า R-squared ประมาณ 0.85 เมื่อใช้ค่าเฉลี่ยของวิชาภาษาอังกฤษ คณิตศาสตร์ และการเขียนโปรแกรม เมื่อเทียบกับประสิทธิภาพที่ต่ำกว่าเมื่อใช้ค่าเฉลี่ยของการรวมกันของวิชาใดๆ สองวิชาเหล่านี้ และประสิทธิภาพที่ต่ำกว่ายิ่งกว่าเมื่อใช้วิชาเดียว

Mirna Nachouki et al. (2023) ได้ทำการศึกษาวิจัย เรื่อง Student course grade prediction using the random forest algorithm: Analysis of predictors' importance ผลการวิจัยพบว่าการทดสอบประสิทธิภาพโมเดล Random Forest มีค่า RMSSE เท่ากับ 9.25 ค่า MAE 7.11 และค่าความแม่นยำ 90.33 %

Soheila Farokhi et al. (2023) ได้ทำการศึกษาวิจัย เรื่อง Enhancing the Performance of Automated Grade Prediction in MOOC using Graph Representation Learning การทดสอบประสิทธิภาพโมเดล ที่มีประสิทธิภาพสูงสุดคือ Gradient Boosting มีค่า Accuracy 0.84 ค่า F1- Score 0.86 รองลงมาคือ Random Forest มีค่า Accuracy 0.80 ค่า F1- Score 0.86 และ XGBoost มีค่า Accuracy 0.78 ค่า F1- Score 0.85 ตามลำดับ

Noviyanti T M Sagala et al. (2022) ได้ทำการศึกษาวิจัย เรื่อง Predicting Computer Science Student's Performance using Logistic Regression ผลการวิจัยพบว่าแบบจำลอง Logistic Regression ที่พัฒนาขึ้นมีประสิทธิภาพการทำนายที่ดี อัตราความแม่นยำ (accuracy rate) 91% อัตราการระลึก (recall rate) 98% อัตราความเที่ยงตรง (precision rate) 85%

Mizanur Rahman, Md Imtiaz Ahmed and Mohammed Shakhawat Hossain (2021) ได้ทำการศึกษาวิจัย เรื่อง Analysis of Student's Achievement through Educational Data

Mining ผลการวิจัยพบว่า 1.) Decision Tree ให้ผลลัพธ์ ดีที่สุด ในการจำแนกกลุ่มนักศึกษา โดยมีความแม่นยำสูงสุด 2.) Random Forest ทำงานได้ดีเช่นกัน รองจาก Decision Tree 3.) K-Means Clustering มีประโยชน์ในการจัดกลุ่มนักศึกษาโดยไม่ต้องพึ่งป้าย (unsupervised) 4.) Regression Models (Linear/Logistic) ให้ผลพอใช้ แต่ไม่แม่นยำเท่าการวิเคราะห์แบบต้นไม้

Balqis Albreki, Nazar Zaki and Hany Alashwal (2021) ได้ทำการศึกษาวิจัย เรื่อง A Systematic Literature Review of Student' Performance Prediction Using Machine Learning Techniques ผลการวิจัยพบว่า 1.) ANN มีอัตราความแม่นยำสูงกว่า 79% และเหนือกว่าเทคนิค ที่พิจารณา เช่น Decision Trees, Support Vector Machines และ Naïve Bayes 2.) Naive Bayes มีรายงานว่าค่าความแม่นยำสูงถึง 76.65% ในการทำนายความสำเร็จของนักเรียน 3.) Linear Regression: เมื่อใช้เพื่อกำหนดคะแนนเฉพาะให้กับกิจกรรม สามารถทำนายได้ด้วยความแม่นยำ 76% 4.) CART มีประสิทธิภาพเหนือกว่าอัลกอริทึม LGR และ AdaBoost โดยมีความแม่นยำมากกว่า 95% 5.) Random Forest พบว่าให้ประสิทธิภาพที่ดีที่สุดเมื่อเทียบกับ Support Vector Machine (SVM), Logistic Regression, AdaBoost และ Decision Tree ในการทำนายนักเรียนที่มีความเสี่ยง

Hassan Zeineddine, Udo Braendle and Assaad Farah (2021) ได้ทำการศึกษาวิจัย เรื่อง Enhancing prediction of student success: Automated machine learning approach ผลการวิจัยพบว่า โมเดล Ensemble ที่ได้จาก AutoML มีความแม่นยำโดยรวมอยู่ที่ 75.9% ซึ่งสูงกว่าความแม่นยำสูงสุดที่ตั้งไว้ แยกเป็นเทคนิคได้ดังนี้ 1.) ANN มีค่าความแม่นยำที่ 75.9% 2.) Naive bayes 76.7% 3.) Support Vector Machine มีค่าความแม่นยำ 73.8% 4.) K-NN มีค่าความแม่นยำที่ 71.0 % 5.) Logistic Regression มีค่าความแม่นยำ 70.8% 6.) Decision Tree มีค่าความแม่นยำ 69.2% 7.) K-Mean มีค่าความแม่นยำ 74.2% 8.) Decision Tree มีค่าความแม่นยำ 76.7%

Yunxia et al. (2021) ได้ทำการศึกษาวิจัย เรื่อง Student Performance Prediction Based on Behavior Process Similarity ผลวิจัยพบว่า การทดสอบประสิทธิภาพของแบบจำลองการทำนายผลการเรียนของนักเรียน โดยใช้วิธีการ Cross-validation แบบ 5-fold เมื่อพิจารณาคุณลักษณะทั่วไป (อัตราการเข้าชั้นเรียน, ผลการบ้าน, ผลการปฏิบัติในชั้นเรียน) ร่วมกับตัวชี้วัดความคล้ายคลึงทั้งหมดที่กำหนดไว้ (Activity similarity, Flow similarity, Activity time similarity, Flow time similarity) แบบจำลองที่ใช้ Naive Bayes classifier มีค่า F1-score อยู่ที่ 96.07% ซึ่งแสดงให้เห็นว่าวิธีการทำนายที่เสนอมีความถูกต้องแม่นยำสูง

Hanan Abdullah Mengash (2020) ได้ทำการศึกษาวิจัย เรื่อง Using Data Mining Techniques to Predict Student Performance to Support Decision Making in University

Admission Systemsการวิจัยแสดงให้เห็นว่าคะแนนสอบ Scholastic Achievement Admission Test เป็นเกณฑ์การรับเข้าที่สามารถทำนายผลการเรียนของนักศึกษาในอนาคตได้อย่างแม่นยำที่สุด และในการทดสอบโมเดลในการวิเคราะห์พบว่าเทคนิคโครงข่ายประสาทเทียม (Artificial Neural Network) มีอัตราความแม่นยำสูงกว่า 79% ซึ่งทำให้เหนือกว่าเทคนิคการจำแนกประเภทอื่นๆ

ผู้วิจัยได้ทำการสรุปงานวิจัยที่เกี่ยวข้องแสดงได้ดังตารางที่ 2-2

ตารางที่ 2-2 สรุปงานวิจัยที่เกี่ยวข้อง

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
1	การประยุกต์เทคนิคเหมืองข้อมูลเพื่อพยากรณ์ผลการประเมินบทความจากวารสารนวัตกรรมและการเรียนรู้ตลอดชีวิต	2568	**ใช้เทคนิค** - Naïve Bayes - Decision tree - K-Nearest Neighbors เพื่อประเมินคุณภาพงานเขียนบทความ **เครื่องมือ** - โปรแกรมภาษา Python แพ็คเกต Anaconda ไลบรารี Scikit-learn	ผลการวิจัยพบว่า Naive Bayes มีประสิทธิภาพต่ำที่สุด (20.66%) ในขณะที่ Nearest Neighbors มีความแม่นยำโดยรวมดีที่สุด (82.46%) แต่ Decision Tree ให้ผลลัพธ์ที่สม่ำเสมอมากกว่า
2	การใช้เทคนิคเหมืองข้อมูลเพื่อพยากรณ์ผลการเรียนจากพฤติกรรมการเรียนรู้ของนักศึกษาระดับปริญญาโท มหาวิทยาลัยสุโขทัยธรรมาธิราชบนระบบการเรียนออนไลน์ STOU E-Learning	2567	**ใช้เทคนิค** Decision tree เพื่อพยากรณ์ว่าสอบผ่านหรือ ไม่ผ่าน **เครื่องมือ** RapidMiner	ผลการวิจัยพบว่า โปรแกรมพยากรณ์สอบผ่านและไม่ผ่านทั้งสิ้น 39 คน โดยพยากรณ์ว่าสอบผ่านจำนวน 29 คน และ สอบไม่ผ่านจำนวน 4 คน ซึ่งในความจริงสอบผ่าน 31 คน และไม่ผ่าน 8 คน ดังนั้น ความถูกต้องของการพยากรณ์ผลการเรียนจากพฤติกรรมการเรียนรู้ประสิทธิภาพ เท่ากับร้อยละ 84.62

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
3	การพัฒนาตัวแบบทำนายทักษะการคิดเชิงคำนวณของนักเรียนชั้นมัธยมศึกษาตอนต้นโดยใช้เทคนิคแมชชีนเลิร์นนิง	2567	**ใช้เทคนิค** - Naïve Bayes - Decision tree - K-Nearest Neighbors **เครื่องมือ** -โปรแกรมภาษา Python แพ็คเกต Anaconda ไลบรารี Scikit-learn	ผลการวิจัยพบว่า ตัวแบบทำนายที่พัฒนาด้วยเทคนิคต้นไม้ตัดสินใจสามารถทำนายผลระดับทักษะการคิดเชิงคำนวณได้อย่างมีประสิทธิภาพสูงที่สุด มีค่าความถูกต้อง 74.95% และตัวแบบจากเทคนิคนาอีฟเบย์ และ เทคนิคเพื่อนบ้านใกล้สุด มีค่าความถูกต้อง เท่ากับ 60.05% และ 68.48% ตามลำดับ
4	การพัฒนาระบบแนะนำการเลือกวิชาเอกของสาขาเทคโนโลยีสารสนเทศและการสื่อสารโดยใช้เทคนิคตต้นไม้ตัดสินใจ	2566	**ใช้เทคนิค** - Decision Tree **เครื่องมือ** - ภาษา PHP แพ็คเกต Iterative Dichotomiser 3, C4.5 และ CART	ผลการวิจัยพบว่า การทดสอบประสิทธิภาพแบบจำลองด้วยวิธี 10-fold cross validation พบว่าแบบจำลองที่พัฒนาด้วยอัลกอริทึม C4.5 ให้ประสิทธิภาพดีที่สุด มีค่าความถูกต้องเท่ากับ 93.20% ค่าความแม่นยำเท่ากับ 93.33% และค่าระลึกเท่ากับ 93.32%

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
5	การวิเคราะห์กฎความสัมพันธ์และการทำนายความสำเร็จในการเรียนรายวิชาในระบบหลักสูตรออนไลน์แบบเปิดเพื่อมวลชน	2566	**ใช้เทคนิคการหาความสัมพันธ์** - FP – Growth - NEclatClosed - FPMAX **การจำแนก** - Logistic Regression - Naïve Bayes - Random Forest เพื่อดูว่าการลงทะเบียนตามความสัมพันธ์นั้นมีโอกาสสำเร็จหรือไม่สำเร็จ **เครื่องมือ** - โปรแกรม RStudio ver.2023.09. build 494 ร่วมกับ โปรแกรม Exploratory Desktop ver.9.3 - โปรแกรม R แพ็คเกจ caret 1	ผลการวิจัยพบว่า 1.) การวิเคราะห์และเปรียบเทียบกฎความสัมพันธ์ พบว่าอัลกอริทึมที่เหมาะสมกับชุดข้อมูล คือ FPMAX มีค่าสนับสนุนข้อมูลของผู้ใช้บริการทั้งหมดและที่เรียนสำเร็จอย่างน้อย 1 วิชา อยู่ที่ 0.005 และชุดข้อมูลของผู้ใช้บริการที่ยังเรียนไม่สำเร็จรายวิชาใด อยู่ที่ 0.001 สร้างความสัมพันธ์ได้ 217 กฎ เมื่อปรับแต่งกฎแล้วเหลือ 27 กฎ มีค่า confident อยู่ในช่วง 0.53 - 0.83 และค่า lift อยู่ในช่วง 26.46 - 52.59 เท่า 2.) การวิเคราะห์จำแนกกลุ่ม พบว่า Random forest มีประสิทธิภาพสูงสุดเท่ากับ 74.89 % ค่าจำเพาะ 49.20%vค่าเที่ยงตรง 76.62% ในส่วนของเทคนิค Naïve bayes มีค่าความดีกว่าทุกเทคนิค ในขณะที่ Logistic Regression ไม่มีค่าใดสูงกว่าเทคนิคใดเลย

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
6	การใช้เทคนิคเหมืองข้อมูล เพื่อพยากรณ์การสำเร็จการศึกษา	2566	**ใช้เทคนิค** - Decision tree - Random Forest - Naïve Bayes	ผลการวิจัยพบว่า การทดลองการลดลิมิตเมื่อพิจารณาจากค่า Information Gain จากชุดข้อมูล IG5 คู่กับตัวแบบจำลอง Random forest ให้ประสิทธิภาพโดยรวมเหมาะสมที่สุดซึ่งมีค่าความถูกต้อง เท่ากับ 96.03% ค่าเฉลี่ย F1-score เท่ากับ 88.65%
7	การพัฒนาโมเดลทำนายความสำเร็จในการเรียนของนักเรียนโดยประยุกต์ใช้การเรียนรู้แบบเอนเซมเบิล	2566	**ใช้เทคนิค** -Elastic-net Regularized generalized linear model (GLM) - Random Forest - XGBoost - ANN และการเรียนรู้แบบเอนเซมเบิลด้วยเทคนิค Stacking ผ่านแพ็กเกจ tidymodels โดยกำหนด Model engine ของ GLM RF XGBoost และ ANN เป็น glmnet, ranger, xgboost และ nnet ตามลำดับ และกำหนด mode เป็น classification	ผลการวิจัยพบว่า โมเดล RF และ XBGoost เป็นโมเดลที่มีค่าประสิทธิภาพสูงที่สุดใกล้เคียงกัน (F1-score = .904 , recall =.891, และ precision =.920) ความพึงพอใจที่มีต่อการใช้แดชบอร์ดในภาพรวม นักเรียนส่วนใหญ่มีความพึงพอใจในระดับมากถึงมากที่สุดต่อการใช้งานแดชบอร์ดที่

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
8	การพัฒนาแอปพลิเคชันช่วยตัดสินใจในการเลือกเรียนสาขาวิชาคอมพิวเตอร์ในมหาวิทยาลัยราชภัฏศรีสะเกษบนระบบปฏิบัติการแอนดรอยด์โดยใช้เทคนิคต้นไม้ตัดสินใจ	2565	**ใช้เทคนิค** - Decision tree **เครื่องมือที่ใช้** - โปรแกรม RapidMiner และ แพ็คเกต C4.5 - Android Studio **ใช้เทคนิค** - Decision tree **เครื่องมือที่ใช้** - โปรแกรม RapidMiner และ แพ็คเกต C4.5 - Android Studio	ผลการวิจัยพบว่า 1.) แอปพลิเคชันสามารถวิเคราะห์ข้อมูลที่ผู้ใช้ตอบแบบทดสอบแล้วเก็บมาเป็นคะแนนและนำคะแนนไปเปรียบเทียบสาขาวิชาที่เหมาะสมกับผู้ใช้และแสดงผลในรูปแบบข้อความ เรียงลำดับสาขาวิชาตามคะแนนที่ได้สูงสุด 3 อันดับแรก 2.) ผลการประเมินความเหมาะสมโดยผู้เชี่ยวชาญพบว่าแอปพลิเคชันมีความเหมาะสมอยู่ในระดับมาก 3.) ผลการประเมินความพึงพอใจโดยผู้ใช้งานทั่วไปพบว่า ผู้ใช้มีความพึงพอใจแอปพลิเคชันช่วยตัดสินใจในการเลือกเรียนสาขาวิชาคอมพิวเตอร์ในมหาวิทยาลัยราชภัฏศรีสะเกษบนระบบปฏิบัติการแอนดรอยด์อยู่ในระดับมากที่สุด

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
9	การพยากรณ์การตกออกของนักศึกษาระดับปริญญาตรี มหาวิทยาลัยราชภัฏพิบูลสงครามด้วยเทคนิคเหมืองข้อมูล	2565	**ใช้เทคนิค** - Decision Tree - Naïve bayes - Rule Induction - Filter Approach โดยใช้ค่า Information Gain ถูกนำมาประยุกต์ใช้เพื่อการวิเคราะห์หาปัจจัยที่มีผลต่อการตกออกของนักศึกษา **เครื่องมือที่ใช้** - AppServ สำหรับการจำลองเครื่องแม่ข่าย ภาษา PHP สำหรับการเขียน Script โปรแกรม RapidMiner Studio 9.9 สำหรับสร้างต้นแบบพยากรณ์ และMySQL สำหรับจัดการฐานข้อมูล	ผลการวิจัยพบว่า การวิเคราะห์ปัจจัยที่เกี่ยวข้องกับการตกออก จำนวน 10 ปัจจัย ได้แก่ เกรดเฉลี่ยรวม ปีที่เข้าศึกษา สาขาวิชา หลักสูตร อาชีพมารดา อาชีพ บิดา คณะ ระดับการศึกษา ภาค และความถนัด/ความสามารถพิเศษ ด้วยวิธีการ 5-Fold Cross-Validation และ 10-Fold Cross-Validation และวัดประสิทธิภาพด้วยค่าความถูกต้อง และค่าความผิดพลาด พบว่าแบบจำลองที่ใช้เทคนิคต้นไม้ตัดสินใจได้ค่าสูงที่สุดในการแบ่งข้อมูลทดสอบ 10-Fold Cross-Validation ให้ค่าความถูกต้อง 97.81% และค่าความผิดพลาดเท่ากับ 0.026 ผู้วิจัยจึงได้ศึกษาออกแบบ และพัฒนาระบบในรูปแบบเว็บแอปพลิเคชัน ผลการประเมินระบบจากการสุ่มตัวอย่างข้อมูลมาทดสอบในระบบ ค่าเฉลี่ยรวมของการทำนายถูกต้องของระบบคิดเป็นร้อยละ 86.29%

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
10	การเปรียบเทียบเทคนิคการจำแนกประเภทข้อมูลสำหรับทำนายแนวโน้มการสำเร็จการศึกษาของนักเรียน	2564	**ใช้เทคนิค** - Naïve bayes - Decision tree - K-Nearest Neighbors	ผลการวิจัยพบว่า การเปรียบเทียบประสิทธิภาพ แสดงให้เห็นว่า อัลกอริทึมต้นไม้ตัดสินใจ ให้ค่าการประเมินประสิทธิภาพของแบบจำลองดีที่สุด ซึ่งผลการประเมินแบบจำลองด้วยวิธีการ5-Fold Cross-Validation และ 10-Fold Cross-Validation ให้ผลลัพธ์เท่ากัน คือ ค่าความถูกต้อง ร้อยละ 87.40 ค่าความแม่นยำร้อยละ 87.50 ค่าเรียกคืน ร้อยละ 87.40 และค่าประเมินผลโดยรวม ร้อยละ 86.70
11	Student Grade Prediction and Classification based on Term Frequency – Inverse Document Frequency with Random Forest	2024	**ใช้เทคนิค** **การจำแนกข้อมูล** - K-Nearest Neighbors - Term Frequency-Inverse Document Frequency with Random Forest (TF-IDF-RF)	ผลการวิจัยพบว่า ผลลัพธ์ที่ได้ทดสอบแบบจำลอง TF-IDF-RF มีประสิทธิภาพดีกว่าเมื่อเทียบกับ KNN ที่มีอยู่เดิม โดยให้ผลลัพธ์ด้านความแม่นยำ 99.5%, ความเที่ยงตรง 95.2%, การระลึก 96.4% และ F1-score 95.8% ตามลำดับ

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
12	Regression-based Student Performance Prediction Using the Grades of English, Math, and Programming Courses	2024	**ใช้เทคนิค** - polynomial regression	ผลการวิจัยพบว่า การถดถอยพหุนามจะหาเส้นโค้งที่เหมาะสมที่สุดกับจุดข้อมูล โดยระบุความสัมพันธ์ระหว่างแกน x เกรดวิชา และข้อมูลแกน y แต้มเฉลี่ยสะสมใช้การถดถอยพหุนามระดับ 3 ให้ประสิทธิภาพดีที่สุด ค่า R-squared 0.85 เมื่อใช้ค่าเฉลี่ยของวิชาภาษาอังกฤษ คณิตศาสตร์ และการเขียนโปรแกรม เมื่อเทียบกับประสิทธิภาพที่ต่ำกว่าเมื่อใช้ค่าเฉลี่ยของการรวมกันของวิชาใดๆ สองวิชาเหล่านี้ และประสิทธิภาพที่ต่ำกว่ายิ่งกว่าเมื่อใช้วิชาเดียว
13	Student course grade prediction using the random forest algorithm: Analysis of predictors' importance	2023	**ใช้เทคนิค** - Random Forest **เครื่องมือ** ไลบรารี Scikit-learn ด้วยภาษา Python	ผลการวิจัยพบว่า การทดสอบประสิทธิภาพโมเดล Random Forest มีค่า RMSSE เท่ากับ 9.25 ค่า MAE 7.11 และค่าความแม่นยำ 90.33 %

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
14	Enhancing the Performance of Automated Grade Prediction in MOOC using Graph Representation Learning	2023	**ใช้เทคนิค** - XGBoost - Random Forest - Gradient Boosting	ผลการวิจัยพบว่า Gradient Boosting มีประสิทธิภาพสูงสุด ค่าความแม่นยำ 0.84 ค่า F1- Score 0.86 รองลงมาคือ Random Forest มีค่าความแม่นยำ 0.80 ค่า F1- Score 0.86 และ XGBoost มีค่าความแม่นยำ 0.78 ค่า F1- Score 0.85 ตามลำดับ
15	Predicting Computer Science Student's Performance using Logistic Regression	2022	**ใช้เทคนิค** - Logistic Regression เพื่อทำนายผลการเรียนของนักเรียนว่าเป็น "ปกติ" หรือ "ไม่ปกติ" โดยใช้ข้อมูลประชากร ข้อมูลกิจกรรม และข้อมูลผลสัมฤทธิ์ทางการเรียนของนักเรียน	ผลการวิจัยพบว่า แบบจำลอง Logistic Regression ที่พัฒนาขึ้นมีประสิทธิภาพการทำนายที่ดี อัตราความแม่นยำ (accuracy rate): 91% อัตราการระลึก (recall rate): 98% อัตราความเที่ยงตรง (precision rate): 85%

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
16	Analysis of Student's Achievement through Educational Data Mining	2021	**ใช้เทคนิค** - Decision Tree - Random Forest - Linear Regression - Logistic Regression - K-Means Clustering	ผลการวิจัยพบว่า 1.) Decision Tree ให้ผลลัพธ์ดีที่สุดในการจำแนกกลุ่มนักศึกษา โดยมีความแม่นยำสูงสุด 2.) Random Forest ทำงานได้ดีเช่นกัน รองจาก Decision Tree 3.) K-Means Clustering มีประโยชน์ในการจัดกลุ่มนักศึกษาโดยไม่ต้องพึ่ง label (unsupervised) 4.) Regression Models (Linear/Logistic) ให้ผลพอใช้ แต่ไม่แม่นยำเท่าการวิเคราะห์แบบต้นไม้
17	A Systematic Literature Review of Student' Performance Prediction Using Machine Learning Techniques	2021	วิจัยนี้เป็นการศึกษาประสิทธิภาพของโมเดลที่ใช้ในการวิเคราะห์ข้อมูลได้แก่ -Artificial Neural Network - Naïve bayes - Linear regression - CART (C4.5 Classification and Regression Tree) -Random Forest	ผลการวิจัยพบว่า 1.) ANN มีความแม่นยำสูงกว่า 79% และเหนือกว่าทุกเทคนิคที่พิจารณา 2.) Naive Bayes มีรายงานว่าค่าความแม่นยำสูงถึง 76.65% ในการทำนายความสำเร็จของนักเรียน 3.) Linear Regression เมื่อใช้เพื่อกำหนดคะแนนเฉพาะให้กับกิจกรรม ความแม่นยำ 76%

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
17 (ต่อ)	A Systematic Literature Review of Student' Performance Prediction Using Machine Learning Techniques	2021		4.) CART มีประสิทธิภาพเหนือกว่าอัลกอริทึม LGR และ AdaBoost โดยมีความแม่นยำมากกว่า 95% 5.) Random Forest พบว่าให้ประสิทธิภาพที่ดีที่สุดเมื่อเทียบกับ Support Vector Machine (SVM), Logistic Regression, AdaBoost และ Decision Tree ในการทำนายนักเรียนที่มีความเสี่ยง
18	Enhancing prediction of student success: Automated machine learning approach	2021	**ใช้เทคนิค** - Artificial Neural Network (ANN) - K-Nearest Neighbors - K-Means Clustering - Naïve Bayes - SVM - Logistic Regression - Decision Tree	ผลการวิจัยพบว่า แบบจำลองที่ได้จาก AutoML มีความแม่นยำโดยรวมอยู่ที่ 75.90% ซึ่งสูงกว่าที่ตั้งไว้ ดังนี้ 1.) ANN 75.9% 2.) Naïve bayes 72% 3.) SVM 73.8% 4.) K-NN 71.0 % 5.) Logistic Regression 70.8% 6.) Decision Tree 69.2% 7.) K-Mean 48.5%

ตารางที่ 2-2 (ต่อ)

ที่	ชื่อเรื่อง	พ.ศ.	อัลกอริทึม	ผลการวิจัย
19	Student Performance Prediction Based on Behavior Process Similarity	2020	**ใช้เทคนิค** - Naive Bayes - Support Vector Machine (SVM)	ผลวิจัยพบว่าประสิทธิภาพของแบบจำลองการทำนายผลการเรียนของนักเรียนโดยใช้วิธีการ 5-fold Cross-validation เมื่อพิจารณาคุณลักษณะทั่วไปร่วมกับตัวชี้วัดความคล้ายคลึงทั้งหมดที่กำหนดไว้ แบบจำลองที่ใช้ Naive Bayes classifier มีค่า F1-score อยู่ที่ 96.07% ซึ่งแสดงให้เห็นว่าวิธีการทำนายที่เสนอมีความถูกต้องแม่นยำสูง
20	Using Data Mining Techniques to Predict Student Performance to Support Decision Making in University Admission Systems	2020	**ใช้เทคนิค** - SVM - Decision - Naïve bayes	ผลการวิจัยพบว่า การวิจัยแสดงให้เห็นว่าคะแนนสอบเป็นเกณฑ์การรับเข้าที่สามารถทำนายผลการเรียนของนักศึกษาในอนาคตได้อย่างแม่นยำที่สุด และในการทดสอบโมเดลในการวิเคราะห์พบว่าเทคนิคโครงข่ายประสาทเทียม (Artificial Neural Network) มีอัตราความแม่นยำสูงกว่า 79% ซึ่งทำให้เหนือกว่าเทคนิคการจำแนกประเภทอื่นๆ

จากการศึกษาทฤษฎี กระบวนการ เอกสารทางวิชาการ และงานวิจัยที่เกี่ยวข้องข้างต้น แสดงให้เห็นว่ามีผู้วิจัยจำนวนมากได้นำเทคนิคการจำแนกข้อมูลมาใช้ในการวิเคราะห์พยากรณ์ความสำเร็จ โดยมีอัลกอริทึมที่นิยมนำมาใช้ในการวิจัย ดังนี้

1) อัลกอริทึม Naïve bayes ประยุกต์ใช้จำนวน 10 งานวิจัย
2) อัลกอริทึม Decision Tree ประยุกต์ใช้จำนวน 12 งานวิจัย
3) อัลกอริทึม Radom Forest ประยุกต์ใช้จำนวน 7 งานวิจัย
4) อัลกอริทึม Logistic Regression ประยุกต์ใช้จำนวน 6 งานวิจัย
5) อัลกอริทึม K-Nearest Neighbors ประยุกต์ใช้จำนวน 5 งานวิจัย
6) อัลกอริทึม Support Vector Machine : SVM ประยุกต์ใช้ 3 งานวิจัย
7) อัลกอริทึม Neural Network ประยุกต์ใช้จำนวน 3 งานวิจัย
8) อัลกอริทึม XGBoost ประยุกต์ใช้จำนวน 2 งานวิจัย
9) อัลกอริทึม GLM ประยุกต์ใช้จำนวน 1 งานวิจัย

ซึ่งผลการวิจัยในการใช้อัลกอริทึมดังกล่าว พบว่ามีค่าความแม่นยำสูงแตกต่างกันไปตามลักษณะของข้อมูลที่นำมาวิเคราะห์ ผู้วิจัยจึงได้ทำออกแบบการพัฒนาโดยเลือกใช้อัลกอริทึม Naive bayes ที่ได้รับความนิยมนำสูงสุด มาเป็นพื้นฐานสำหรับเปรียบเทียบกับแบบจำลองที่มีความซับซ้อนอย่าง Neural Network ที่เป็นแบบจำลองกลุ่มการเรียนรู้เชิงลึก (Deep Learning) และแบบจำลองแบบกลุ่ม คือ Random Forest XGBoost และแบบจำลองแบบเดี่ยวอย่าง Support Vector Machine ที่มีความทันสมัย เพื่อนำมาทดสอบการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับชั้นประกาศนียบัตรวิชาชีพ (ปวช.) จากบุคลิกภาพ 5 องค์ประกอบ และเกรดวิชาหลักมัธยมศึกษาตอนต้นในครั้งนี้ เพื่อพิสูจน์ว่าแบบจำลองใดจะมีความเหมาะสมกับชุดข้อมูลมากที่สุด

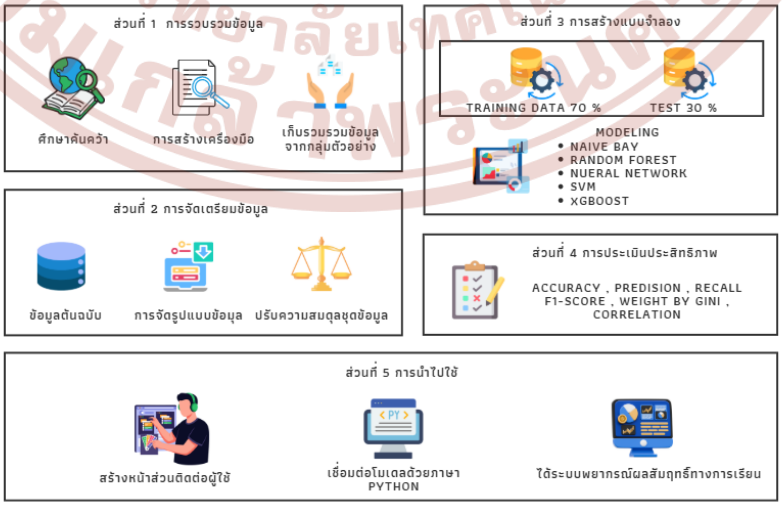
บทที่ 3
วิธีดำเนินงานวิจัย

การวิจัยเรื่อง การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น ผู้วิจัยกำหนดวิธีดำเนินการวิจัยตามขั้นตอน ได้แก่

3.1 กรอบแนวคิดของงานวิจัย
3.2 การเก็บรวบรวมข้อมูล
3.3 การเตรียมข้อมูล (Data Preprocessing)
3.4 การสร้างและพัฒนาแบบจำลอง (Model Construction)
3.5 การประเมินผลประสิทธิภาพ (Performance Evaluation)
3.6 การนำผลวิจัยไปใช้ (Deployment)
3.7 แผนการดำเนินงานวิจัย

3.1 กรอบแนวคิดของงานวิจัย

จากการศึกษาค้นคว้าทฤษฎี และงานวิจัยที่เกี่ยวข้องกับเทคนิคการจำแนกข้อมูล และนำมาปรับประยุกต์ใช้กับงานวิจัยเรื่อง การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น เพื่อพัฒนาแบบจำลองและเปรียบเทียบประสิทธิภาพของแต่ละอัลกอริทึมที่นำมาใช้ในงานวิจัย โดยมีรายละเอียดการดำเนินงานวิจัยเป็นไปตามกรอบแนวคิด แสดงดังภาพที่ 3-1



ภาพที่ 3-1 กรอบแนวคิดและขั้นตอนการดำเนินงานวิจัย

จากภาพที่ 3-1 กรอบแนวคิดและขั้นตอนการดำเนินงานวิจัย แบ่งออกเป็น 5 ส่วน โดยมีรายละเอียด ดังนี้

ส่วนที่ 1 การรวบรวมข้อมูล ผู้วิจัยได้ทำการศึกษา ค้นคว้ารวบความข้อมูลเกี่ยวกับเทคนิคเหมืองข้อมูล (Data Mining) และเอกสารงานวิจัยที่เกี่ยวข้องกับประเด็นที่สนใจ มากำหนดโครงสร้างของงานวิจัย และสร้างเครื่องมือเพื่อเก็บข้อมูลจากกลุ่มตัวอย่างโดยใช้ Google Form

ส่วนที่ 2 การจัดเตรียมข้อมูล ผู้วิจัยได้ตรวจสอบความสมบูรณ์ของข้อมูล กำหนดตัวแปร จัดรูปแบบข้อมูล แทนค่า และปรับความสมดุลข้อมูลก่อนนำไปใช้กับแบบจำลอง

ส่วนที่ 3 การสร้างแบบจำลอง ผู้วิจัยได้เลือกใช้โปรแกรม RapidMiner Studio เป็นเครื่องมือหลักในการประมวลผลและพัฒนาแบบจำลอง โดยเลือกใช้อัลกอริทึมที่มีประสิทธิภาพในการจำแนกข้อมูลจำนวน 5 รูปแบบ ได้แก่ Naïve Bayes, Random Forest, Neural Network, XGBoost และ Support Vector Machine (SVM)

ทั้งนี้ เพื่อให้กระบวนการสร้างและประเมินผลแบบจำลองมีความน่าเชื่อถือ ผู้วิจัยได้กำหนดสัดส่วนการแบ่งชุดข้อมูลออกเป็น 2 ส่วน คือ ชุดข้อมูลสำหรับฝึกสอน (Training Data) จำนวนร้อยละ 70 และชุดข้อมูลสำหรับทดสอบ (Testing Data) จำนวนร้อยละ 30 รายละเอียดการแบ่งข้อมูลแสดงในหัวข้อที่ 3.5.4

ส่วนที่ 4 การประเมินประสิทธิภาพ ผู้วิจัยได้นำผลการพัฒนาอัลกอริทึมมาเปรียบเทียบประสิทธิภาพการทำงาน โดยใช้ค่าความแม่นยำ (Accuracy) ค่าความเที่ยงตรง (Precision) ค่าระลึก (Recall) และค่าเฉลี่ยฮาร์โมนิก (F1-Score) ทั้งนี้ยังเปรียบเทียบน้ำหนักความสำคัญ (Weight by Gini Index) และค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Matrix) และสรุปรายงานผลการพัฒนาแบบจำลองในรูปแบบรายงาน

ส่วนที่ 5 การนำไปใช้งาน ผู้วิจัยได้ออกแบบหน้าต่างการใช้งาน และสร้างอัลกอริทึมด้วยค่าพารามิเตอร์ที่ดีที่สุดด้วยภาษาไพทอน และสร้างเป็นต้นแบบระบบพยากรณ์ผลสัมฤทธิ์ทางการเรียนระดับชั้นปวช. ใน 5 สาขายอดนิยม ได้แก่ ช่างยนต์ ช่างกลโรงงาน ช่างไฟฟ้า การบัญชี และเทคโนโลยีธุรกิจดิจิทัล

3.2 การเก็บรวบรวมข้อมูล

สำหรับกระบวนการเก็บรวบรวมข้อมูล เพื่อนำมาใช้กำหนดเค้าโครงร่างงานวิจัยเรื่องแบบจำลองเพื่อพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น ด้วยเทคนิคการจำแนกข้อมูล แบ่งออกเป็น 3 ขั้นตอน ดังนี้

3.2.1 การศึกษา ค้นคว้างานวิจัยที่เกี่ยวข้องกับเทคนิคการจำแนกข้อมูล จำนวน 20 เรื่อง แบ่งเป็นในประเทศ 10 เรื่อง และจากต่างประเทศ 10 เรื่อง รวมถึงทฤษฎีบุคลิกภาพ 5 องค์ประกอบ (Big 5 Personality Factors) เพื่อนำมาใช้เป็นแนวทางในวางกรอบแนวคิดและกำหนดเครื่องมือที่จะนำมาใช้ในงานวิจัย

3.2.2 การสร้างเครื่องมือ ผู้วิจัยได้เลือกใช้ แบบวัดบุคลิกภาพ Big Five Inventory (BFI) ฉบับปรับปรุงปีพ.ศ. 2551 ของ John, Naumann และ Soto จำนวน 44 ข้อ เนื่องจากเป็นเครื่องมือที่ได้รับการยอมรับในระดับสากลว่ามีคุณสมบัติทางจิตมิติที่เหมาะสมและมีข้อคำถามครอบคลุมองค์ประกอบของบุคลิกภาพทั้ง 5 ด้านอย่างครบถ้วน โดยผู้วิจัยได้นำข้อคำถามต้นฉบับภาษาอังกฤษมาแปลและเรียบเรียงเป็นภาษาไทย ดังรายละเอียดปรากฏใน ตารางที่ 3-1

ทั้งนี้ โครงสร้างของแบบวัดดังกล่าวได้กำหนดให้มีประโยคนำ (Instruction Stem) ที่สำคัญเพื่อใช้ร่วมกับข้อคำถามทุกข้อ คือ “I see myself as someone who...” ซึ่งมีความหมายในภาษาไทยว่า “ฉันมองว่าตนเองเป็นบุคคลที่มีลักษณะ..."

ตารางที่ 3-1 แสดงคำถามฉบับภาษาอังกฤษและภาษาไทย

ที่	ต้นฉบับภาษาอังกฤษ	คำแปลภาษาไทย	กลับค่าการประเมิน
ด้านความเป็นมิตร (Agreeableness)			
1	Tends to find fault with others	ฉันมักจะคอยจับผิดผู้อื่น	✓
2	Is helpful and unselfish with others	ฉันชอบช่วยเหลือผู้อื่นและไม่เห็นแก่ตัว	
3	Starts quarrels with others	ฉันชอบเริ่มบทสนทนาที่ขัดแย้งหรือหาเรื่องผู้อื่น	✓
4	Has a forgiving nature	ฉันเป็นคนที่มีจิตใจให้อภัยผู้อื่น	
5	Is generally trusting	โดยทั่วไปฉันมักจะไว้วางใจผู้อื่น	
6	Can be cold and aloof	บางครั้งฉันก็ดูเย็นชาและห่างเหิน	✓
7	Is considerate and kind to almost everyone	ฉันมีความเกรงใจและโอบอ้อมอารีทุกคน	
8	Is sometimes rude to others	บางครั้งฉันก็แสดงกิริยาหยาบคายต่อผู้อื่น	✓
9	Likes to cooperate with others	ฉันชอบที่จะร่วมมือทำงานกับผู้อื่น	

ตารางที่ 3-1 (ต่อ)

ที่	ต้นฉบับภาษาอังกฤษ	คำแปลภาษาไทย	กลับค่าการประเมิน
ด้านการมีจิตสำนึก (Conscientiousness)			
10	Does a thorough job	ฉันทำงานอย่างละเอียดรอบคอบ	
11	Can be somewhat careless	บางครั้งฉันก็ทำงานสะเพร่าหรือไม่ระมัดระวัง	✓
12	Is a reliable worker	ฉันเป็นคนทำงานที่ไว้ใจได้	
13	Tends to be disorganized	ฉันมักจะไม่มีระเบียบในการทำงาน	✓
14	Tends to be lazy	ฉันมักจะเป็นคนขี้เกียจ	✓
15	Perseveres until the task is finished	ฉันมีความมุ่งมั่นทำจนกว่างานจะสำเร็จ	
16	Does things efficiently	ฉันทำงานได้อย่างมีประสิทธิภาพ	
17	Makes plans and follows through with them	ฉันมีการวางแผนและปฏิบัติตามแผนนั้นเสมอ	
18	Is easily distracted	ฉันเป็นคนที่วอกแวกหรือเสียสมาธิได้ง่าย	✓
ด้านการเปิดตัว (Extraversion)			
19	Is talkative	ฉันเป็นคนช่างพูด	
20	Is reserved	ฉันเป็นคนเงียบขรึม เก็บตัว	✓
21	Is full of energy	ฉันเต็มไปด้วยพลังงานและความกระตือรือร้น	
22	Generates a lot of enthusiasm	ฉันสร้างความกระตือรือร้นให้เกิดขึ้นได้มาก	
23	Tends to be quiet	ฉันมักจะเป็นคนเงียบๆ	✓
24	Has an assertive personality	ฉันมีบุคลิกภาพที่กล้าแสดงออก	
25	Is sometimes shy, inhibited	บางครั้งฉันก็ขี้อาย หรือเก็บกด	✓
26	Is outgoing, sociable	ฉันเป็นคนชอบเข้าสังคม	

ตารางที่ 3-1 (ต่อ)

ที่	ต้นฉบับภาษาอังกฤษ	คำแปลภาษาไทย	กลับค่าการประเมิน
ด้านความไม่มั่นคงทางอารมณ์ (Neuroticism)			
27	Is depressed, blue	ฉันมีอารมณ์ซึมเศร้า หรือหดหู่	
28	Is relaxed, handles stress well	ฉันเป็นคนผ่อนคลาย จัดการความเครียดได้ดี	✓
29	Can be tense	ฉันมักจะมีอารมณ์ตึงเครียด	
30	Worries a lot	ฉันเป็นคนขี้กังวล	
31	Is emotionally stable, not easily upset	ฉันมีอารมณ์มั่นคง ไม่หงุดหงิดง่าย	✓
32	Can be moody	ฉันเป็นคนอารมณ์แปรปรวนง่าย	
33	Remains calm in tense situations	ฉันยังคงความสงบเยือกเย็นได้ในสถานการณ์ตึงเครียด	✓
ด้านการเปิดรับประสบการณ์ (Openness)			
34	Gets nervous easily	ฉันเป็นคนที่ประหม่าหรือตื่นเต้นได้ง่าย	
35	Is original, comes up with new ideas	ฉันมีความคิดริเริ่มสร้างสรรค์ คิดสิ่งใหม่ๆ เสมอ	
36	Is curious about many different things	ฉันมีความอยากรู้อยากเห็นในหลายๆ เรื่อง	
37	Is ingenious, a deep thinker	ฉันเป็นคนฉลาดหลักแหลมและคิดอะไรลึกซึ้ง	
38	Has an active imagination	ฉันมีจินตนาการกว้างไกล	
39	Is inventive	ฉันเป็นนักประดิษฐ์คิดค้น ชอบสร้างสรรค์สิ่งใหม่	
40	Values artistic, aesthetic experiences	ฉันให้คุณค่ากับศิลปะและความงดงาม	
41	Prefers work that is routine	ฉันชอบทำงานที่เป็นกิจวัตรซ้ำๆ เดิม ๆ	✓

ตารางที่ 3-1 (ต่อ)

ที่	ต้นฉบับภาษาอังกฤษ	คำแปลภาษาไทย	กลับค่าการประเมิน
ด้านการเปิดรับประสบการณ์ (Openness)			
42	Likes to reflect, play with ideas	ฉันชอบการคิดไตร่ตรองและเล่นกับความคิดต่างๆ	
43	Has few artistic interests	ฉันมีความสนใจในศิลปะน้อย	✓
44	Is sophisticated in art, music, or literature	ฉันมีความรู้ความเข้าใจที่ลึกซึ้งในศิลปะ ดนตรี หรือวรรณกรรม	

ที่มา : John, Naumann, & Soto, 2008

หมายเหตุ : หากมี ✓ กำกับอยู่ในช่องกลับค่าการประเมิน ผู้แปลจะต้องกลับค่าการประเมินโดยนำ 6 มาลบกับคะแนนที่ประเมิน

ผู้ตอบคำถามจะให้คะแนนตามระดับความเห็นด้วยหรือไม่เห็นด้วยกับประเด็นของคำถาม 5 ระดับ ตามแนวคิดของลิเคิร์ท (likert Scale) ดังตารางที่ 3-2

ตารางที่ 3-2 เกณฑ์การประเมิน

ระดับคะแนน	ความหมาย
1	ไม่เห็นด้วยอย่างยิ่ง
2	ไม่เห็นด้วย
3	ไม่แน่ใจ /ปานกลาง
4	เห็นด้วย
5	เห็นด้วยอย่างยิ่ง

หลังจากการแปลชุดคำถามเรียบร้อยแล้ว ผู้วิจัยได้ดำเนินการพัฒนาเครื่องมือสำหรับเก็บรวบรวมข้อมูลในรูปแบบออนไลน์ (Online Questionnaire) ผ่านระบบ Google Forms โดยกำหนดข้อคำถามให้สอดคล้องกับตัวแปรต้นที่กำหนด ประกอบด้วย เกรดเฉลี่ยสะสม (GPA) ในรายวิชาคณิตศาสตร์ วิทยาศาสตร์ ภาษาอังกฤษ และสาขาวิชาที่สนใจ

3.2.3 ผู้วิจัยได้ดำเนินการจัดทำหนังสือขอความอนุเคราะห์เพื่อขอความร่วมมือในการเก็บรวบรวมข้อมูล และนำเสนอต่อหัวหน้าแผนกวิชาที่เกี่ยวข้องจำนวน 5 สาขาวิชา ได้แก่ สาขาวิชาช่างกลโรงงาน ช่างไฟฟ้ากำลัง ช่างยนต์ เทคโนโลยีธุรกิจดิจิทัล และการบัญชี เพื่อขออนุญาต

นำแบบสอบถามรูปแบบออนไลน์ (Google Forms) ที่ผู้วิจัยสร้างขึ้น ไปใช้ในการเก็บรวบรวมข้อมูลจากกลุ่มตัวอย่าง

3.3 การเตรียมข้อมูล

สำหรับกระบวนการเตรียมข้อมูล (Data Preprocessing) เพื่อนำมาใช้ในการสร้างแบบจำลองเพื่อพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น ด้วยเทคนิคการจำแนกข้อมูล แบ่งออกเป็น 3 ขั้นตอน

3.3.1 การตรวจสอบและทำความสะอาดข้อมูล (Data Cleaning) ผู้วิจัยได้ดำเนินการตรวจสอบความถูกต้องและความสมบูรณ์ของข้อมูล (Data Validation) โดยทำการคัดกรองและตรวจสอบรายการข้อมูล (Records) เพื่อค้นหาข้อมูลที่ขาดหาย (Missing Values) หรือข้อมูลที่มีความผิดปกติ (Outliers/Noise) หากตรวจพบข้อมูลที่มีความไม่สมบูรณ์หรือไม่ชัดเจน ผู้วิจัยจะดำเนินการคัดข้อมูลดังกล่าวออกจากชุดข้อมูล (Data Removal) เพื่อให้มั่นใจว่าชุดข้อมูลที่นำไปใช้นั้นมีคุณภาพและมีความน่าเชื่อถือสูงสุด

3.3.2 การแปลงข้อมูล (Data Transformation) ผู้วิจัยได้ดำเนินการจัดรูปแบบและแปลงข้อมูลให้อยู่ในลักษณะที่เหมาะสมกับข้อกำหนดของอัลกอริทึมที่ใช้ในการพยากรณ์ (Algorithm Compatibility) ตามขอบเขตการวิจัยที่กำหนดไว้ รวมถึงการกำหนดรหัสตัวแปร (Variable Coding) และการนิยามค่าของข้อมูล (Data Dictionary) เพื่อเตรียมพร้อมสำหรับการนำเข้าสู่กระบวนการวิเคราะห์ โดยมีรายละเอียดการกำหนดค่าตัวแปรดังนี้

3.3.2.1 Id รูปแบบจำนวนเต็ม แทน ลำดับของข้อมูล

3.3.2.2 Subject รูปแบบจำนวนเต็ม แทน สาขาวิชา โดยมีรหัสย่อย คือ

- 3.3.2.2.1 รหัส 1 ไฟฟ้า
- 3.3.2.2.2 รหัส 2 ช่างกลโรงงาน
- 3.3.2.2.3 รหัส 3 ช่างยนต์
- 3.3.2.2.4 รหัส 4 เทคโนโลยีธุรกิจดิจิทัล
- 3.3.2.2.5 รหัส 5 การบัญชี

3.3.2.3 Math รูปแบบจำนวนเต็ม แทน เกรดเฉลี่ยวิชาคณิตศาสตร์

3.3.2.4 Science รูปแบบจำนวนเต็ม แทน เกรดเฉลี่ยวิชาวิทยาศาสตร์

3.3.2.5 Eng รูปแบบจำนวนเต็ม แทน เกรดเฉลี่ยวิชาภาษาอังกฤษ

3.3.2.6 A รูปแบบทศนิยม แทน ค่าเฉลี่ยด้านเป็นมิตร

3.3.2.7 O รูปแบบทศนิยม แทน ค่าเฉลี่ยด้านเปิดรับประสบการณ์

3.3.2.8 C รูปแบบทศนิยม แทน ค่าเฉลี่ยด้านการมีจิตสำนึก

3.3.2.9 E รูปแบบทศนิยม แทน ค่าเฉลี่ยด้านการเปิดตัว

3.3.2.10 N รูปแบบทศนิยม แทน ค่าเฉลี่ยด้านความไม่มั่นคงทางอารมณ์

3.3.2.11 Grade รูปแบบอักขระ แทน ผลสัมฤทธิ์ทางการเรียน โดยมีรหัสย่อย คือ

3.3.2.11.1 รหัส F เกรดเฉลี่ย ต่ำกว่า 1 ไม่ผ่านเกณฑ์

3.3.2.11.2 รหัส D เกรดเฉลี่ย 1.00 – 1.99 ผลสัมฤทธิ์อ่อน

3.3.2.11.3 เกรด C เกรดเฉลี่ย 2.00 – 2.99 ผลสัมฤทธิ์พอใช้

3.3.2.11.4 เกรด B เกรดเฉลี่ย 3.00 – 3.99 ผลสัมฤทธิ์ดี

3.3.2.11.5 เกรด A เกรดเฉลี่ย 4.00 ผลสัมฤทธิ์ดีเยี่ยม

3.3.3 การจัดการข้อมูลที่ไม่สมดุล (Handling Imbalanced Data) เนื่องจากชุดข้อมูลที่รวบรวมได้นั้น มีปริมาณน้อยและมีความไม่สมดุลของข้อมูล (Imbalanced Data) โดยสัดส่วนของกลุ่มตัวอย่างในแต่ละคลาสมีความแตกต่างกันอย่างมีนัยสำคัญ ดังรายละเอียดปรากฏในตารางที่ 3-3

ตารางที่ 3-3 สัดส่วนของตัวแปรเป้าหมายก่อนการปรับสมดุลให้ชุดข้อมูล

A	B	C	D	F	Total
9	329	148	11	3	500
1.8	65.8	29.6	2.2	0.6	100

เพื่อลดความคลาดเคลื่อนและเพิ่มประสิทธิภาพในการสร้างโมเดล ผู้วิจัยจึงได้ดำเนินการปรับสมดุลของชุดข้อมูล (Data Balancing) ด้วยเทคนิคการสร้างข้อมูลสังเคราะห์สำหรับคลาสส่วนน้อย (Synthetic Minority Oversampling Technique: SMOTE) โดยอาศัยการประมวลผลผ่านโปรแกรม RapidMiner Studio เพื่อปรับสัดส่วนข้อมูลให้มีความเหมาะสมสำหรับการวิเคราะห์ ผู้วิจัยได้ทำการการสุ่มเพิ่มข้อมูลเพื่อปรับสมดุลให้กับชุดข้อมูลทั้งหมด 4 ครั้ง มีรายละเอียดดังตารางที่ 3-4 และตารางที่ 3-5

ตารางที่ 3-4 แสดงจำนวนการปรับสมดุลให้กับชุดข้อมูลด้วยเทคนิคการสุ่ม

ครั้งที่	ค่า K	จำนวนคลาส					ผลรวม
		A	B	C	D	F	
ก่อนปรับค่า		9	329	148	11	3	500
1	1	9	329	148	11	329	826
2	3	329	329	148	11	329	1146

ตารางที่ 3-4 (ต่อ)

ครั้งที่	ค่า K	จำนวนคลาส					ผลรวม
		A	B	C	D	F	
3	5	329	329	148	329	329	1464
4	9	329	329	329	329	329	1645

ตารางที่ 3-5 แสดงร้อยละการปรับสมดุลให้กับชุดข้อมูลด้วยเทคนิคการสุ่มเพิ่ม

ครั้งที่	ค่า K	ค่าผลลัพธ์คิดเป็นร้อยละ					ผลรวม
		A	B	C	D	F	
ก่อนปรับค่า		1.8	65.8	29.6	2.2	0.6	100
1	1	1.1	39.8	17.9	1.3	39.8	100
2	3	28.7	28.7	12.9	1.0	28.7	100
3	5	22.5	22.5	10.1	22.5	22.5	100
4	9	20	20	20	20	20	100

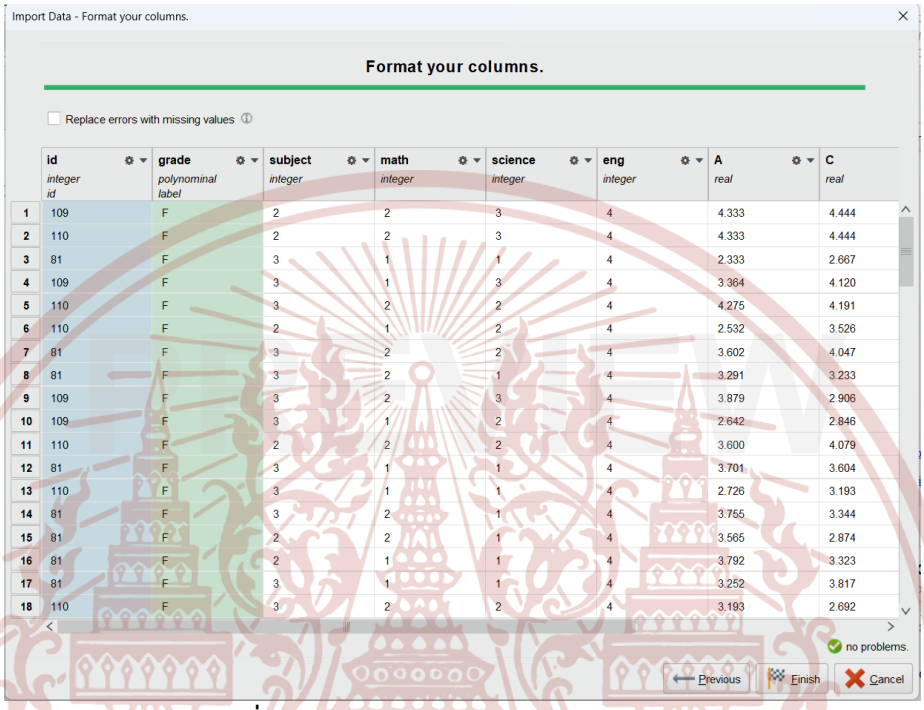
ทั้งนี้ ผู้วิจัยได้นำการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) มาใช้เพื่อตรวจสอบปัญหาภาวะร่วมเส้นตรงพหุคูณ (Multicollinearity) ระหว่างตัวแปรอิสระ ได้แก่ ผลการเรียนเดิมและบุคลิกภาพ 5 องค์ประกอบ โดยหากพบตัวแปรที่มีความซ้ำซ้อนกันสูงจะพิจารณาคัดออก (Feature Selection) เพื่อลดสัญญาณรบกวน (Noise) และป้องกันแบบจำลองเกิดการเรียนรู้เกิน (Overfitting)

3.4 การสร้างและพัฒนาแบบจำลอง (Model Construction)

การพัฒนาแบบจำลองเพื่อพยากรณ์ผลสัมฤทธิ์ทางการเรียนระดับปวช. โดยอาศัยปัจจัยด้านบุคลิกภาพ 5 องค์ประกอบ ร่วมกับเทคนิคการจำแนกข้อมูล (Classification Techniques) ผู้วิจัยได้เลือกใช้อัลกอริทึมจำนวน 5 ชนิด ได้แก่ XGBoost, Random Forest, Support Vector Machine, Naïve Bayes และ Neural Network โดยดำเนินการผ่านโปรแกรม RapidMiner Studio แบ่งออกเป็น

3.4.1 การนำเข้าและกำหนดบทบาทข้อมูล (Data Import and Role Definition) ผู้วิจัยดำเนินการนำเข้าชุดข้อมูลที่ผ่านกระบวนการปรับสมดุล (Data Balancing) เรียบร้อยแล้วในรูปแบบไฟล์นามสกุล .xls ด้วยตัวดำเนินการ Read Excel จากนั้นทำการกำหนดบทบาทของตัวแปร (Set

Role) โดยกำหนดให้ตัวแปร id ทำหน้าที่เป็นรหัสระบุแถว (id) และกำหนดให้ตัวแปร Grade ทำหน้าที่เป็นตัวแปรเป้าหมาย (Label) สำหรับการพยากรณ์ ดังภาพที่ 3-2

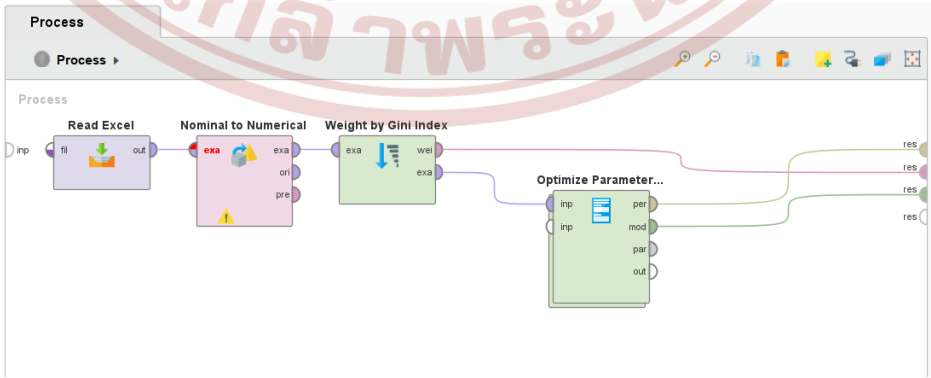


	id integer id	grade polynominal label	subject integer	math integer	science integer	eng integer	A real	C real
1	109	F	2	2	3	4	4.333	4.444
2	110	F	2	2	3	4	4.333	4.444
3	81	F	3	1	1	4	2.333	2.667
4	109	F	3	1	3	4	3.364	4.120
5	110	F	3	2	2	4	4.275	4.191
6	110	F	2	1	2	4	2.532	3.526
7	81	F	3	2	2	4	3.602	4.047
8	81	F	3	2	1	4	3.291	3.233
9	109	F	3	2	3	4	3.879	2.906
10	109	F	3	1	2	4	2.642	2.846
11	110	F	2	2	2	4	3.600	4.079
12	81	F	3	1	1	4	3.701	3.604
13	110	F	3	1	1	4	2.726	3.193
14	81	F	3	2	1	4	3.755	3.344
15	81	F	2	2	1	4	3.565	2.874
16	81	F	2	1	1	4	3.792	3.323
17	81	F	3	1	1	4	3.252	3.817
18	110	F	3	2	2	4	3.193	2.692

ภาพที่ 3-2 การนำเข้าและกำหนดบทบาทข้อมูล

3.4.2 การแปลงสภาพข้อมูล (Data Transformation) ดำเนินการแปลงข้อมูลจากตัวแปรชนิดนามบัญญัติ (Nominal) ให้เป็นตัวแปรชนิดตัวเลข (Numerical) เพื่อให้สอดคล้องกับข้อกำหนดของอัลกอริทึมในการคำนวณ โดยใช้ตัวดำเนินการ Nominal to Numerical ดังภาพที่ 3-3

3.4.3 การคำนวณค่าน้ำหนักความสำคัญ (Feature Weighting) ผู้วิจัยทำการวิเคราะห์และคำนวณค่าน้ำหนักความสำคัญของตัวแปรที่มีผลต่อการจำแนกข้อมูล โดยใช้ตัวดำเนินการ Weight by Gini Index เพื่อคัดเลือกคุณลักษณะที่เหมาะสมที่สุดสำหรับการสร้างแบบจำลอง ดังภาพที่ 3-3



ภาพที่ 3-3 ตัวอย่างการใช้ตัวดำเนินการภายในแบบจำลอง

3.4.4 การหาค่าพารามิเตอร์ที่มีดีที่สุด ผู้วิจัยได้ใช้ตัวดำเนินการ Optimize Parameters (Grid) เพื่อค้นหาค่าที่เหมาะสมที่สุดสำหรับแต่ละแบบจำลอง โดยทำการวนซ้ำเพื่อทดสอบชุดตัวแปรตามขอบเขตที่กำหนดไว้ ดังภาพที่ 3-3 โดยค่าพารามิเตอร์หลักที่นำมาทดสอบในงานวิจัยครั้งถูกกำหนดขึ้นโดยอ้างอิงจากความสำคัญในการควบคุมพฤติกรรมของแบบจำลองตามที่ระบุไว้ในงานวิจัยที่เกี่ยวข้อง ดังนี้

3.4.4.1 อัลกอริทึม Support Vector Machine กำหนดให้ปรับค่าประเภทของเคอร์เนล (Kernel Type)

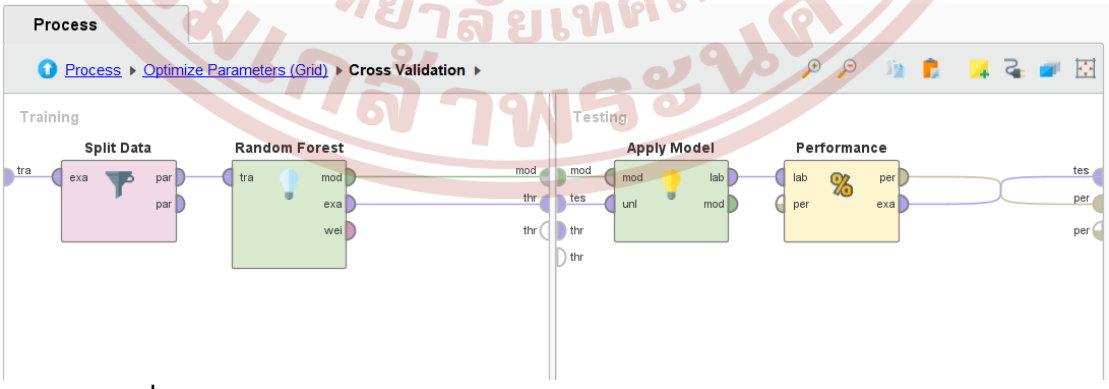
3.4.4.2 อัลกอริทึม Naïve Bayes กำหนดให้ปรับค่าการแก้ไขของลาพลาส (Laplace Correction)

3.4.4.3 อัลกอริทึม Neural Network กำหนดให้ปรับค่าอัตราการเรียนรู้ (Learning Rate), รอบการฝึกฝน (Training Cycles) และค่าโมเมนตัม (Momentum)

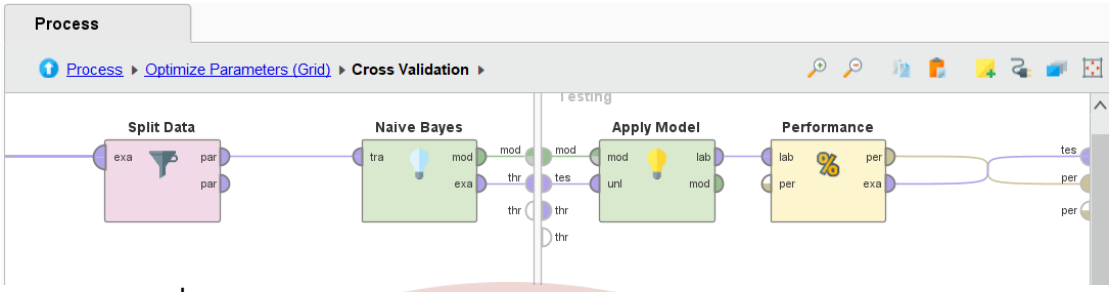
3.4.4.4 อัลกอริทึม Random Forest กำหนดให้ปรับค่าความลึกสูงสุดของต้นไม้ (Max Depth) และจำนวนต้นไม้ (Number of Trees)

3.4.4.5 อัลกอริทึม XGBoost กำหนดให้ปรับค่าความลึกสูงสุด (Max Depth) และอัตราการเรียนรู้ (Learning Rate)

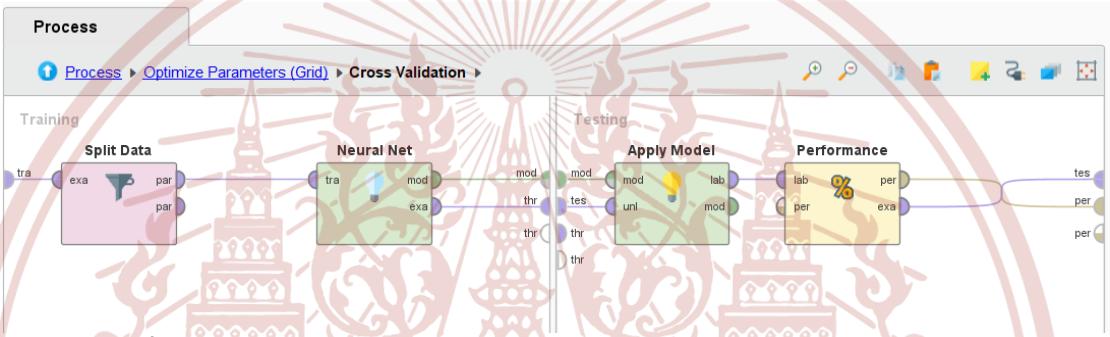
3.4.5 การทดสอบประสิทธิภาพแบบจำลอง (Model Evaluation) ผู้วิจัยได้ดำเนินการแบ่งชุดข้อมูล เพื่อใช้ในการสร้างและประเมินประสิทธิภาพของแบบจำลอง โดยใช้ตัวดำเนินการ Split Data ในโปรแกรม RapidMiner Studio โดยกำหนดสัดส่วนการแบ่งข้อมูลเป็นร้อยละ 70 ต่อ 30 ด้วยวิธีการสุ่มแบบแบ่งชั้นภูมิ (Stratified Sampling) เพื่อให้ข้อมูลมีการกระจายตัวของระดับผลสัมฤทธิ์ทางการเรียนเกรด 0-4 ในชุดข้อมูลฝึกสอนและชุดข้อมูลทดสอบมีสัดส่วนที่สอดคล้องกับข้อมูลทั้งหมด โดยมีรายละเอียดการแบ่งข้อมูล ดังภาพที่ 3-4 ถึง 3-8



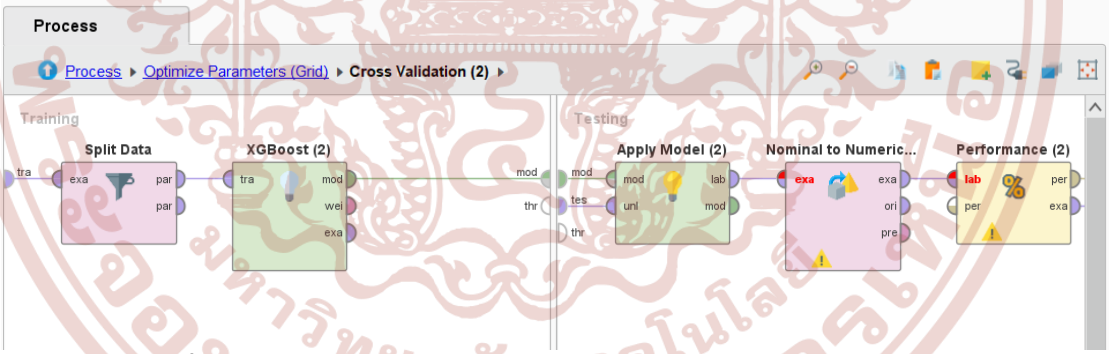
ภาพที่ 3-4 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Random Forest



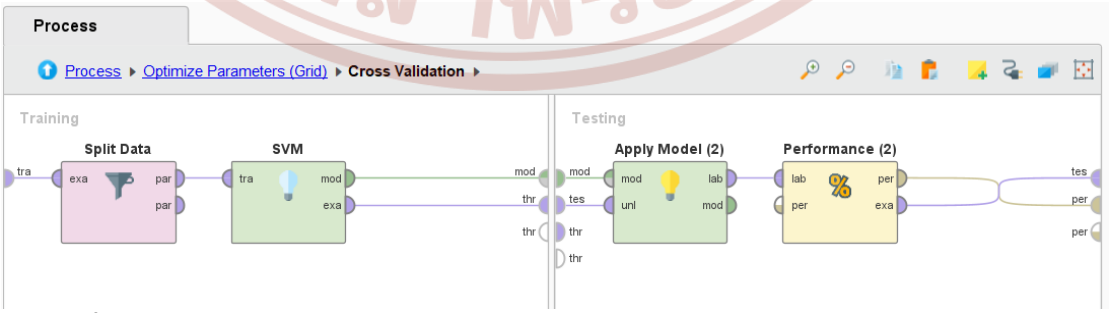
ภาพที่ 3-5 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Naïve Bays



ภาพที่ 3-6 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Neural Network



ภาพที่ 3-7 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล XGBoost



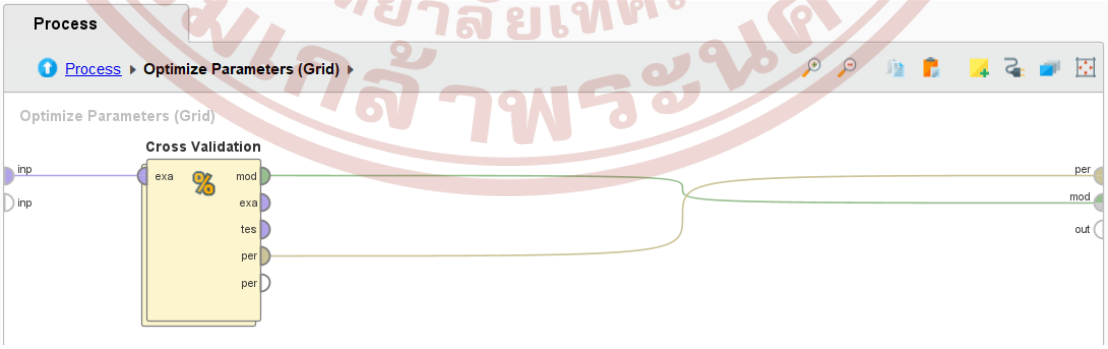
ภาพที่ 3-8 การแบ่งข้อมูลด้วยตัวดำเนินการ Split Data ในโมเดล Support Vector Machine

3.4.5.1 ชุดข้อมูลฝึกสอน (Training Set) จำนวนร้อยละ 70 ใช้สำหรับกระบวนการเรียนรู้ (Learning Process) ของอัลกอริทึม โดยแบบจำลองจะนำข้อมูลชุดนี้ไปวิเคราะห์หาความสัมพันธ์ระหว่างปัจจัยนำเข้าซึ่งประกอบด้วย ค่าเฉลี่ยบุคลิกภาพด้านเป็นมิตร ด้านเปิดรับประสบการณ์ ด้านการมีจิตสำนึก ด้านการเปิดตัว ด้านการไม่มั่นคง เกรดวิชาคณิตศาสตร์ วิทยาศาสตร์ และภาษาอังกฤษ กับผลสัมฤทธิ์ทางการเรียน เพื่อสร้างเป็นกฎหรือสมการสำหรับการพยากรณ์

3.4.5.2 ชุดข้อมูลทดสอบ (Testing Set) จำนวนร้อยละ 30 ใช้สำหรับกระบวนการประเมินประสิทธิภาพ (Evaluation Process) ซึ่งเป็นชุดข้อมูลที่แบบจำลองไม่เคยเห็นมาก่อน (Unseen Data) โดยนำมาใช้ทดสอบเพื่อวัดความแม่นยำในการพยากรณ์ว่าแบบจำลองสามารถทำนายผลลัพธ์ได้ถูกต้องเพียงใดเมื่อนำไปใช้งานจริง

นอกจากนี้ เพื่อให้แบบจำลองมีประสิทธิภาพสูงสุดและลดปัญหาการเรียนรู้จำเพาะ (Overfitting) ในขั้นตอนการฝึกสอนด้วยชุดข้อมูลร้อยละ 70 ผู้วิจัยได้ประยุกต์ใช้เทคนิคการตรวจสอบความถูกต้องแบบไขว้ (k-fold Cross Validation) โดยกำหนดจำนวนรอบการตรวจสอบเป็น 10 รอบ เนื่องจากเป็นค่าที่ได้รับการยอมรับในการวิจัย ร่วมกับกระบวนการปรับจูนพารามิเตอร์

โดยตัวดำเนินการจะแบ่งชุดข้อมูลฝึกสอนออกเป็น 10 ส่วนย่อยเท่า ๆ กัน จากนั้นระบบจะทำการวนรอบการทดสอบจำนวน 10 รอบ โดยในแต่ละรอบจะใช้ข้อมูล 9 ส่วน สำหรับการสร้างแบบจำลอง และใช้ข้อมูล 1 ส่วนที่เหลือสำหรับการทดสอบ แล้วจึงนำผลลัพธ์หาค่าเฉลี่ยประสิทธิภาพ (Average Performance) เพื่อค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุดสำหรับแต่ละอัลกอริทึม ก่อนที่จะนำแบบจำลองที่ดีที่สุดไปทดสอบประสิทธิภาพครั้งสุดท้ายกับชุดข้อมูลทดสอบ (Testing Set) ที่แยกไว้ ดังภาพที่ 3-9



ภาพที่ 3-9 การใช้ตัวดำเนินการ Cross Validation

3.4.6 ผลจากการดำเนินการสุ่มทดสอบเพื่อค้นหาค่าพารามิเตอร์ที่ดีที่สุดสำหรับแต่ละอัลกอริทึม ด้วยตัวดำเนินการ Optimize Parameters (Grid) ปรากฏผลการทดสอบดังตารางที่

ตารางที่ 3-6 แสดงผลการทดสอบอัลกอริทึม Support Vector Machine ที่ดีที่สุด

ลำดับที่	รูปแบบเคอร์เนล (Kernel Type)	ค่าความแม่นยำ (Accuracy)
1	Linear	0.685
2	poly (Polynomial)	0.769
3	rbf (Radial Basis Function)	0.782
4	sigmoid	0.196
5	precomputed	0.046

จากตารางที่ 3-6 พบว่าการกำหนดค่า Kernel Type เป็นแบบ Radial Basis Function (rbf) ในการทดสอบรอบที่ 3 ให้ประสิทธิภาพสูงสุด โดยมีค่าความแม่นยำ (Accuracy) อยู่ที่ 0.782 รองลงมาคือแบบ Polynomial (poly) ที่ค่าความแม่นยำ 0.769 และแบบ Linear ที่ค่าความแม่นยำ 0.685 ตามลำดับ ในขณะที่รูปแบบ Sigmoid และ Precomputed ให้ค่าความแม่นยำต่ำที่สุด

ตารางที่ 3-7 แสดงผลการทดสอบอัลกอริทึม Naïve bays ที่ดีที่สุด

ลำดับที่	ค่าพารามิเตอร์ Laplace Correction	ค่าความแม่นยำ (Accuracy)
1	False	0.692
2	True	0.688

จากตารางที่ 3-7 พบว่าการทดสอบลำดับที่ 2 เมื่อกำหนดค่าพารามิเตอร์ Laplace Correction เป็น False จะให้ประสิทธิภาพสูงสุด โดยมีค่าความแม่นยำ (Accuracy) อยู่ที่ 0.692 หรือร้อยละ 69.20 ซึ่งสูงกว่าการกำหนดค่าเป็น True ในลำดับการทดสอบที่ 1 ที่ให้ค่าความแม่นยำเพียง 0.688

ตารางที่ 3-8 แสดงผลการทดสอบอัลกอริทึม Neural Network ที่ดีที่สุด

ลำดับที่	อัตราการเรียนรู้ (Learning Rate)	จำนวนรอบการฝึกฝน (Training Cycles)	ค่าโมเมนตัม (Momentum)	ค่าความแม่นยำ (Accuracy)
181	0.400	51	0.100	0.668

หมายเหตุ : Optimize parameters (Grid) (1331 rows, 5 columns)

จากตารางที่ 3-8 พบว่าการทดสอบลำดับที่ 181 ให้ประสิทธิภาพในการพยากรณ์สูงสุด โดยมีค่าความแม่นยำ (Accuracy) อยู่ที่ 0.668 ซึ่งเกิดจากการกำหนดค่าพารามิเตอร์ที่เหมาะสมได้แก่ ค่า

อัตราการเรียนรู้ (Learning Rate) เท่ากับ 0.400 จำนวนรอบการฝึกฝน (Training Cycles) เท่ากับ 51 รอบ และค่าโมเมนตัม (Momentum) เท่ากับ 0.100 จากการทดสอบทั้งสิ้น 1,331 ครั้ง

ตารางที่ 3-9 แสดงผลการทดสอบอัลกอริทึม Random forest ที่ดีที่สุด

ลำดับที่	ความลึกสูงสุดของต้นไม้ (Maximal Depth)	จำนวนต้นไม้ (Number of Trees)	ค่าความแม่นยำ (Accuracy)
104	39	90	0.853

หมายเหตุ : Optimize parameters (Grid) (121 rows, 4 columns)

จากตารางที่ 3-9 พบว่าการทดสอบลำดับที่ 104 ให้ประสิทธิภาพในการพยากรณ์สูงสุด โดยมีค่าความแม่นยำ (Accuracy) อยู่ที่ 0.853 ซึ่งเกิดจากการกำหนดค่าพารามิเตอร์ที่เหมาะสมได้แก่ ค่าความลึกสูงสุดของต้นไม้ (Maximal Depth) เท่ากับ 39 และจำนวนต้นไม้ (Number of Trees) เท่ากับ 90 ต้น จากการทดสอบทั้งสิ้น 121 ครั้ง

ตารางที่ 3-10 แสดงผลการทดสอบอัลกอริทึม XGBoost ที่ดีที่สุด

ลำดับที่	ความลึกสูงสุดของต้นไม้ (Maximal Depth)	อัตราการเรียนรู้ (Learning Rate)	ค่าความแม่นยำ (Accuracy)
44	100	0.300	0.855

หมายเหตุ : Optimize parameters (Grid) (121 rows, 4 columns)

จากตารางที่ 3-10 พบว่าการทดสอบลำดับที่ 44 ให้ประสิทธิภาพในการพยากรณ์สูงสุด โดยมีค่าความแม่นยำ (Accuracy) อยู่ที่ 0.855 ซึ่งเกิดจากการกำหนดค่าพารามิเตอร์ที่เหมาะสมได้แก่ ค่าความลึกสูงสุดของต้นไม้ (Max Depth) เท่ากับ 100 และค่าอัตราการเรียนรู้ (Learning Rate) เท่ากับ 0.300 จากการทดสอบทั้งสิ้น 121 ครั้ง

3.4.7 การนำอัลกอริทึมไปใช้ทดสอบด้วยตัวดำเนินการ Apply Model

3.4.8 การประเมินสิทธิภาพอัลกอริทึมที่สร้างขึ้น ด้วยตัวดำเนินการ Performance เลือกค่าความแม่นยำ (Accuracy) ค่าความเที่ยงตรง (Precision) และค่าระลึก (Recall)

3.5 การประเมินผลประสิทธิภาพ (Performance Evaluation)

3.5.1 การเปรียบเทียบประสิทธิภาพของแบบจำลอง (Model Performance Comparison) ผู้วิจัยดำเนินการเปรียบเทียบประสิทธิภาพของอัลกอริทึมทั้ง 5 ชนิด ได้แก่ Naïve Bayes, Random

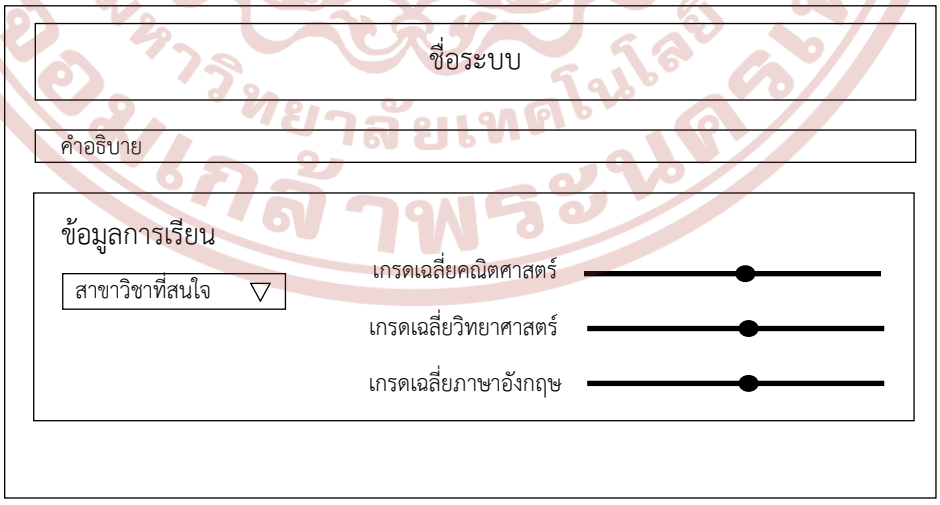
Forest, SVM, XGBoost และ Neural Network โดยพิจารณาจากดัชนีชี้วัดประสิทธิภาพ (Performance Metrics) ที่สำคัญ ได้แก่ ค่าความแม่นยำ (Accuracy) ค่าความเที่ยงตรง (Precision) และค่าระลึก (Recall) รวมถึงการคำนวณค่าคะแนนเอฟวัน (F1-Score) และนำเสนอผลการเปรียบเทียบข้อมูลในรูปแบบตาราง

3.5.2 การวิเคราะห์ความสัมพันธ์ระหว่างตัวแปร (Correlation Analysis) ผู้วิจัยดำเนินการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Coefficient) เพื่อตรวจสอบระดับความสัมพันธ์ระหว่างตัวแปร โดยเริ่มจากกระบวนการคัดเลือกตัวแปรคุณลักษณะ (Feature Selection) ด้วยตัวดำเนินการ Select Attribute จากนั้นจึงประยุกต์ใช้ตัวดำเนินการ Correlation Matrix เพื่อประมวลผลและวิเคราะห์โครงสร้างความสัมพันธ์ระหว่างตัวแปรดังกล่าว

3.6 การนำผลวิจัยไปใช้ (Deployment)

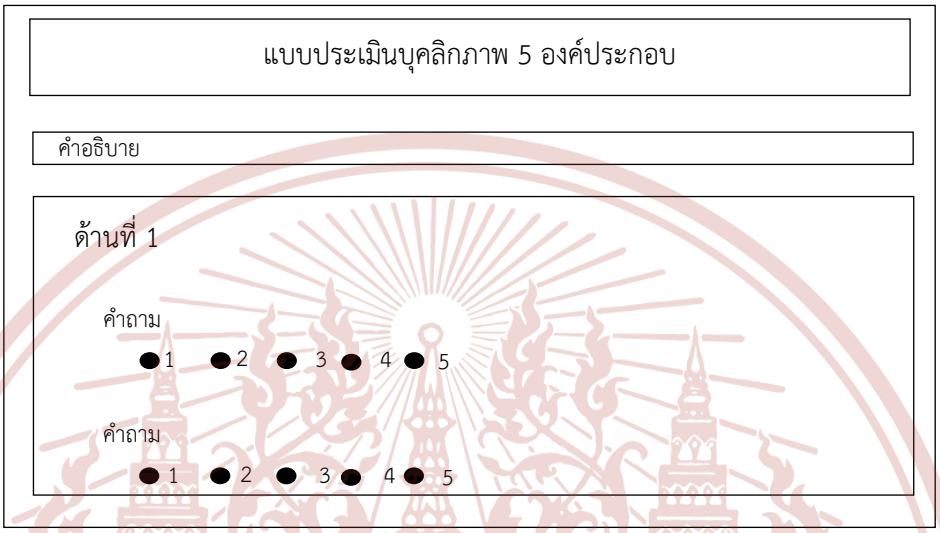
ผู้วิจัยได้ดำเนินการพัฒนาต้นแบบระบบทำนายผลสัมฤทธิ์ทางการเรียน (Grade Prediction) โดยอ้างอิงจากผลการทดลองที่พบว่าอัลกอริทึม XGBoost ให้ค่าประสิทธิภาพสูงสุด แต่เนื่องด้วยข้อจำกัดของโปรแกรม Rapid miner Studio ไม่สามารถส่งออกไฟล์โมเดลให้มาทำงานร่วมกับภาษาไพทอนได้โดยตรง ผู้วิจัยจึงได้ดำเนินการนำค่าพารามิเตอร์ที่เหมาะสมที่สุด (Optimal Hyperparameters) จากการทดลอง มาสร้างแบบจำลองใหม่ (Model Recreation) ด้วยภาษาไพทอน เพื่อสร้างต้นแบบของระบบ โดยแบ่งขั้นตอนการดำเนินงานออกเป็น 3 ส่วนหลัก ดังนี้

3.6.1 การออกแบบส่วนติดต่อผู้ใช้ (Graphical User Interface Design: GUI) ผู้วิจัยได้ออกแบบส่วนติดต่อผู้ใช้ให้มีความเรียบง่ายและเป็นมิตรกับผู้ใช้งาน (User-friendly) โดยมีโครงร่างดังภาพที่ 3-10 ถึง ภาพที่ 3-12



ภาพที่ 3-10 แบบร่างหน้าเว็บไซต์ส่วนข้อมูลผลการเรียน

จากภาพที่ 3-10 ส่วนของสาขาวิชาที่สนใจ เลือกใช้เครื่องมือแบบเลื่อนลง (Dropdown) และแบบสไลด์ (Slide) สำหรับปรับระดับเกรดเฉลี่ยสะสมวิชาพื้นฐาน



ภาพที่ 3-11 แบบร่างหน้าเว็บไซต์ส่วนของแบบประเมินบุคลิกภาพ 5 องค์ประกอบ

จากภาพที่ 3-11 ส่วนแบบประเมินบุคลิกภาพ 5 องค์ประกอบ จะแบ่งออกเป็น 5 ส่วน ตามทฤษฎีอ้างอิง และเลือกใช้เครื่องมือทางเลือกเดียว (Radio button) สำหรับทำแบบประเมินระดับความเห็นด้วย 5 ระดับตามแนวคิดของลิเคิร์ท



ภาพที่ 3-12 แบบร่างหน้าเว็บไซต์ส่วนของการทำนาย

จากภาพที่ 3-12 หลังจากที่ผู้ใช้ทำแบบประเมิน และกดที่ปุ่มเพื่อทำนาย หน้าจอจะแสดงผลการทำนาย แบ่งออกเป็น 5 ระดับ 5 โทนสี ได้แก่

1.) สีแดง ผลการทำนายแสดงว่าผลสัมฤทธิ์ ไม่ผ่านเกณฑ์

2.) สีส้ม ผลการทำงานแสดงว่าผลสัมฤทธิ์ อ่อน

3.) สีเหลือง ผลการทำนายแสดงว่าผลสัมฤทธิ์ ปานกลาง

4.) สีเขียว ผลการทำนายแสดงว่าผลสัมฤทธิ์ ดี

5.) สีฟ้า ผลการทำนายแสดงว่าผลสัมฤทธิ์ ดีเยี่ยม

3.6.2 การพัฒนาชุดคำสั่งและสร้างแบบจำลอง (Development and Coding) ผู้วิจัยดำเนินการเขียนชุดคำสั่ง (Source Code) ด้วยภาษาไพทอนผ่านทาง Google Colab โดยมีการเรียกใช้งานไลบรารีสำคัญ ดังนี้

3.6.2.1 Streamlit สำหรับสร้างส่วนติดต่อผู้ใช้ในรูปแบบเว็บไซต์ที่สามารถโต้ตอบกับผู้ใช้ได้ทันที

3.6.2.2 Pandas สำหรับการจัดการโครงสร้างข้อมูล (Dataframe) และเตรียมข้อมูลนำเข้า

3.6.2.3 XGBoost สำหรับสร้างและประมวลผลโมเดลการพยากรณ์ด้วยอัลกอริทึม XGBoost ตามค่าพารามิเตอร์ที่กำหนด

3.6.2.4 Scikit-learn สำหรับการเตรียมข้อมูลก่อนเข้าสู่โมเดล ได้แก่ การแบ่งชุดข้อมูล (train_test_split) และการแปลงข้อมูลเชิงกลุ่มเป็นตัวเลข (LabelEncoder) เพื่อให้โมเดลสามารถคำนวณได้อย่างถูกต้อง

3.6.2.5 OS สำหรับจัดการระบบไฟล์และการเข้าถึงไดเรกทอรีภายในระบบปฏิบัติการ

3.6.3 ผลลัพธ์การพัฒนาต้นแบบ (Prototype Realization) จากการดำเนินการตามขั้นตอนข้างต้น ทำให้ได้ต้นแบบระบบพยากรณ์ผลสัมฤทธิ์ทางการเรียนที่สามารถทำงานได้จริง

ซึ่งรองรับการป้อนข้อมูลปัจจัยนำเข้า และประมวลผลผ่านโมเดล XGBoost ที่สร้างขึ้นใหม่ด้วยภาษา Python เพื่อแสดงผลลัพธ์การพยากรณ์แก่ผู้ใช้งานได้อย่างถูกต้องและแม่นยำตามเกณฑ์ที่กำหนด

บทที่ 4
ผลการวิจัย

การวิจัยครั้งนี้มีวัตถุประสงค์ เพื่อพัฒนาแบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพ ด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น โดยใช้เทคนิคการจำแนกข้อมูล และทำการเปรียบเทียบประสิทธิภาพของอัลกอริทึม 5 ชนิด ได้แก่ Naïve bays, Random forest, Neural Network, SVM และ XGboost โดยผู้วิจัยแบ่งการนำเสนอผลการวิจัยออกเป็น 2 ประเด็น ได้แก่

4.1 การเปรียบเทียบปัจจัยที่ผลต่อการพยากรณ์ผลสัมฤทธิ์ทางการเรียนระดับชั้นปวช.

4.2 การเปรียบเทียบประสิทธิภาพอัลกอริทึมที่ใช้พยากรณ์ผลสัมฤทธิ์ทางการเรียน

4.3 ต้นแบบระบบทำนายผลสัมฤทธิ์ทางการเรียน (Grade Prediction)

4.1 การเปรียบเทียบปัจจัยที่ผลต่อการพยากรณ์ผลสัมฤทธิ์ทางการเรียนระดับชั้น ปวช.

ตารางที่ 4-1 แสดงน้ำหนักความสำคัญของปัจจัยที่นำมาวิเคราะห์

ปัจจัย	สาขาวิชาที่เลือกเรียน	เกรดวิชาคณิตศาสตร์	เกรดวิชาวิทยาศาสตร์	เกรดวิชาภาษาอังกฤษ	ด้านความเป็นมิตร (A)	ด้านการเปิดรับประสบการณ์ (O)	ด้านการมีจิตสำนึก (C)	ด้านการเปิดตัว (E)	ด้านความไม่มั่นคงทางอารมณ์ (N)
น้ำหนัก	0.062	**0.83**	0.095	0.111	0.014	0.017	0.016	0.038	0.077

จากตารางที่ 4-1 แสดงผลการวิเคราะห์น้ำหนักความสำคัญของตัวแปรต้น (Feature Weights) ด้วยเทคนิค Gini Index ซึ่งเป็นการวัดระดับความสามารถในการจำแนกข้อมูลของแต่ละปัจจัยอย่างเป็นอิสระต่อกัน โดยมีค่าอยู่ระหว่าง 0 ถึง 1 พบว่าตัวแปรต้นที่มีอิทธิพลต่อผลการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับชั้นปวช. ด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้นมากที่สุด คือ เกรดวิชาคณิตศาสตร์ ค่าน้ำหนักอยู่ที่ 0.83 รองลงมาคือเกรดวิชาภาษาอังกฤษ ค่าน้ำหนักอยู่ที่ 0.111 เกรดวิชาวิทยาศาสตร์ ค่าน้ำหนักอยู่ที่ 0.095 ด้านความไม่มั่นคงทางอารมณ์ ค่าน้ำหนักอยู่ที่ 0.077 สาขาวิชาที่เลือกเรียน ค่าน้ำหนักอยู่ที่ 0.062 ด้านการเปิดตัว ค่าน้ำหนักอยู่ที่

0.038 ด้านการเปิดรับประสบการณ์ ค่าน้ำหนักอยู่ที่ 0.017 ด้านการมีจิตสำนึก ค่าน้ำหนักอยู่ที่ 0.016 และด้านความเป็นมิตร ค่าน้ำหนักอยู่ที่ 0.014 เรียงตามลำดับ

ตารางที่ 4-2 ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Matrix)

ตัวแปร	Subject	Math	Science	Eng	A	C	E	N	O
Subject	1	**0.209**	**0.318**	0.140	-0.076	**-0.253**	-0.053	**0.332**	0.022
Math	**0.209**	1	**0.665**	**0.218**	**0.256**	0.050	-0.196	**0.365**	**0.305**
Science	**0.318**	**0.665**	1	**0.379**	0.135	0.032	-0.150	**0.303**	**0.301**
Eng	0.140	**0.218**	**0.379**	1	0.006	0.133	0.119	-0.177	0.150
A	-0.076	**0.256**	0.135	0.006	1	**0.480**	0.074	-0.108	**0.423**
C	**-0.253**	0.050	0.032	0.133	**0.480**	1	**0.208**	**-0.420**	**0.371**
E	-0.053	-0.196	-0.150	0.119	0.074	**0.208**	1	**-0.271**	**0.242**
N	**0.332**	**0.365**	**0.303**	-0.177	-0.108	**-0.420**	**-0.271**	1	0.033
O	0.022	**0.305**	**0.301**	0.150	**0.423**	**0.371**	**0.242**	0.033	1

จากตารางที่ 4-2 แสดงผลการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ระหว่างตัวแปร ด้วยเทคนิค Correlation Matrix พบว่าความสัมพันธ์ระหว่างปัจจัยที่นำมาวิเคราะห์ผลสัมฤทธิ์ทางการเรียนในระดับชั้นปวช. ด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น ตามเกณฑ์ของ John W. Best (1981) ดังนี้

ปัจจัยที่มีความสัมพันธ์กันในระดับสูง ได้แก่ เกรดวิชาคณิตศาสตร์ (Math) กับเกรดวิชาวิทยาศาสตร์ (Science) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.665

ปัจจัยที่มีความสัมพันธ์กันในระดับปานกลาง ได้แก่ ด้านความเป็นมิตร (A) และด้านการมีจิตสำนึก (C) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.480 รองลงมาคือ ด้านความเป็นมิตร (A) กับด้านการเปิดรับประสบการณ์ (O) ค่าสัมประสิทธิ์สหสัมพันธ์ 0.423 ตามลำดับ

ปัจจัยที่มีความสัมพันธ์กันในระดับต่ำ ได้แก่ เกรดวิชาวิทยาศาสตร์ (Science) กับ เกรดวิชาภาษาอังกฤษ (Eng) มีค่าสัมประสิทธิ์สัมพันธ์ 0.379 ด้านการมีจิตสำนึก (C) กับด้านการเปิดรับประสบการณ์ (O) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.371 เกรดวิชาคณิตศาสตร์ (Math) กับ ความไม่

มั่นคงทางอารมณ์ (N) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.365 สาขาวิชา (Subject) กับ ด้านความไม่มั่นคงทางอารมณ์ (N) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.332 สาขาวิชา (Subject) กับเกรดวิชาวิทยาศาสตร์ มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.318 เกรดวิชาคณิตศาสตร์ (Math) กับด้านการเปิดรับประสบการณ์ (O) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.305 เกรดวิชาวิทยาศาสตร์ (Science) กับ ความไม่มั่นคงทางอารมณ์ (N) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.303 เกรดวิชาวิทยาศาสตร์ (Science) กับด้านการเปิดรับประสบการณ์ (O) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.301 เกรดวิชาคณิตศาสตร์ (Math) กับ ด้านความเป็นมิตร (A) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.256 ด้านการเปิดตัว (E) กับ ด้านการเปิดรับประสบการณ์ (O) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.242 เกรดวิชาคณิตศาสตร์ (Math) กับ เกรดวิชาภาษาอังกฤษ (Eng) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.218 สาขาวิชา (Subject) กับเกรดวิชาคณิตศาสตร์ (Math) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.209 และ ด้านการมีจิตสำนึก (C) กับด้านการเปิดตัว (E) มีค่าสัมประสิทธิ์สหสัมพันธ์ 0.208 เรียงตามลำดับ

และปัจจัยที่มีความสัมพันธ์กันในเชิงลบ ได้แก่ ด้านการมีจิตสำนึก (C) กับด้านความไม่มั่นคงทางอารมณ์ (N) มีค่าสัมประสิทธิ์สัมพันธ์ -0.420 ด้านการเปิดตัว (E) กับด้านความไม่มั่นคงทางอารมณ์ (N) มีค่าสัมประสิทธิ์สัมพันธ์ -0.271 และ ด้านการมีจิตสำนึก (C) กับสาขาวิชา (Subject) ค่าสัมประสิทธิ์สหสัมพันธ์ -0.253 เรียงตามลำดับ

4.2 การเปรียบเทียบประสิทธิภาพอัลกอริทึมที่ใช้พยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับปวช.

ตารางที่ 4-3 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม XGBoost

	True A	True B	True C	True D	True F	Class precision
Pred. A	304	17	6	3	0	92.12%
Pred. B	8	230	58	9	0	75.41%
Pred. C	11	64	246	19	0	72.35%
Pred. D	6	14	16	298	1	88.96%
Pred. F	0	4	3	0	328	97.91%
Class recall	92.40%	69.91%	74.77%	90.58%	99.70%	

จากตารางที่ 4-3 แสดงประสิทธิภาพแยกตามผลการพยากรณ์ พบว่าผลการพยากรณ์ที่มีประสิทธิภาพมากที่สุด คือ ผลสัมฤทธิ์ F ค่าระลึกอยู่ที่ 99.70% ค่าความเที่ยงตรง 97.91% รองลงมาคือ ผลสัมฤทธิ์ A ค่าระลึกอยู่ที่ 92.40% ค่าความเที่ยงตรง 92.12% ผลสัมฤทธิ์ D ค่าระลึกอยู่ที่ 90.58% ค่าความเที่ยงตรง 88.96% ผลสัมฤทธิ์ C ค่าระลึกอยู่ที่ 74.77% ค่าความเที่ยงตรง 72.35% และ ผลสัมฤทธิ์ B ค่าระลึกอยู่ที่ 69.91% ค่าความเที่ยงตรง 75.41% เรียงตามลำดับ ดังรายละเอียดปรากฏในภาพผลการทดสอบจากโปรแกรมในภาคผนวก ข ภาพที่ ข-6

ตารางที่ 4-4 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม Random forest

	True A	True B	True C	True D	True F	Class precision
Pred. A	305	21	7	0	0	91.59%
Pred. B	12	231	62	8	1	73.57%
Pred. D	6	16	27	305	0	86.16%
Pred. F	0	4	3	0	328	97.91%
Class recall	92.71%	70.21%	69.91%	92.71	99.70%	

จากตารางที่ 4-4 แสดงประสิทธิภาพแยกตามผลการพยากรณ์ พบว่าผลการพยากรณ์ที่มีประสิทธิภาพมากที่สุด คือ ผลสัมฤทธิ์ F ค่าระลึกอยู่ที่ 99.70% ค่าความเที่ยงตรง 97.91% รองลงมาคือ ผลสัมฤทธิ์ A ค่าระลึกอยู่ที่ 92.71% ค่าความเที่ยงตรง 91.59% ผลสัมฤทธิ์ D ค่าระลึกอยู่ที่ 92.71% ค่าความเที่ยงตรง 86.16% ผลสัมฤทธิ์ B ค่าระลึกอยู่ที่ 70.21% ค่าความเที่ยงตรง 73.57% และ ผลสัมฤทธิ์ C ค่าระลึกอยู่ที่ 69.91% ค่าความเที่ยงตรง 74.43% เรียงตามลำดับ ดังรายละเอียดปรากฏในภาพผลการทดสอบจากโปรแกรมในภาคผนวก ข ภาพที่ ข-4

ตารางที่ 4-5 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม SVM

	True A	True B	True C	True D	True F	Class precision
Pred. A	292	36	6	0	0	87.43%
Pred. B	11	152	55	6	0	67.86%
Pred. C	16	119	235	46	0	56.49%
Pred. D	10	17	24	277	0	84.45%
Pred. F	0	5	9	0	329	95.92%
Class recall	88.75%	46.20%	71.43%	84.19%	100.00%	

จากตารางที่ 4-5 แสดงประสิทธิภาพแยกตามผลการพยากรณ์ พบว่าผลการพยากรณ์ที่มีประสิทธิภาพมากที่สุด คือ ผลสัมฤทธิ์ F ค่าระลึกอยู่ที่ 100% ค่าความเที่ยงตรง 95.92% รองลงมาคือ ผลสัมฤทธิ์ A ค่าระลึกอยู่ที่ 88.75% ค่าความเที่ยงตรง 87.43% ผลสัมฤทธิ์ D ค่าระลึกอยู่ที่ 84.19% ค่าความเที่ยงตรง 84.45% ผลสัมฤทธิ์ C ค่าระลึกอยู่ที่ 71.43% ค่าความเที่ยงตรง 56.49% และ ผลสัมฤทธิ์ B ค่าระลึกอยู่ที่ 46.20% ค่าความเที่ยงตรง 67.86% เรียงตามลำดับ ดังรายละเอียดปรากฏในภาพผลการทดสอบจากโปรแกรมในภาคผนวก ข ภาพที่ ข-5

ตารางที่ 4-6 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม Naïve bays

	True A	True B	True C	True D	True F	Class precision
Pred. A	286	64	24	5	0	75.46%
Pred. B	17	127	63	12	0	57.99%
Pred. C	11	73	115	29	0	50.44%
Pred. D	14	45	111	283	0	62.47%
Pred. F	1	20	16	0	329	89.89%
Class recall	86.93%	38.60%	34.95%	86.02%	100.00%	

จากตารางที่ 4-6 แสดงประสิทธิภาพแยกตามผลการพยากรณ์ พบว่าผลการพยากรณ์ที่มีประสิทธิภาพมากที่สุด คือ ผลสัมฤทธิ์ F ค่าระลึกอยู่ที่ 100% ค่าความเที่ยงตรง 89.89% รองลงมาคือ ผลสัมฤทธิ์ A ค่าระลึกอยู่ที่ 86.93% ค่าความเที่ยงตรง 75.46% ผลสัมฤทธิ์ D ค่าระลึกอยู่ที่ 86.02% ค่าความเที่ยงตรง 62.47% ผลสัมฤทธิ์ B ค่าระลึกอยู่ที่ 38.60% ค่าความเที่ยงตรง 57.99% และ ผลสัมฤทธิ์ C ค่าระลึกอยู่ที่ 34.95% ค่าความเที่ยงตรง 50.44% เรียงตามลำดับ ดังรายละเอียดปรากฏในภาพผลการทดสอบจากโปรแกรมในภาคผนวก ข ภาพที่ ข-2

ตารางที่ 4-7 แสดงค่าความคลาดเคลื่อน (Confusion Matrix) ของอัลกอริทึม Neural Network

	True A	True B	True C	True D	True F	Class precision
Pred. A	266	69	18	4	0	74.51%
Pred. B	32	102	66	6	1	49.28%
Pred. C	8	75	100	28	0	47.39%
Pred. D	22	70	137	290	1	55.77%
Pred. F	1	13	8	1	327	93.43%
Class recall	80.85%	31.00%	30.40%	88.15%	99.39%	

จากตารางที่ 4-7 แสดงประสิทธิภาพแยกตามผลการพยากรณ์ พบว่าผลการพยากรณ์ที่มีประสิทธิภาพมากที่สุด คือ ผลสัมฤทธิ์ F ค่าระลึกอยู่ที่ 99.39% ค่าความเที่ยงตรง 93.43% รองลงมาคือ ผลสัมฤทธิ์ D ค่าระลึกอยู่ที่ 88.15% ค่าความเที่ยงตรง 55.77% ผลสัมฤทธิ์ A ค่าระลึกอยู่ที่ 80.85% ค่าความเที่ยงตรง 74.51% ผลสัมฤทธิ์ B ค่าระลึกอยู่ที่ 31.00% ค่าความเที่ยงตรง 49.28% และ ผลสัมฤทธิ์ C ค่าระลึกอยู่ที่ 30.40% ค่าความเที่ยงตรง 47.39% เรียงตามลำดับ ดังรายละเอียดปรากฏในภาพผลการทดสอบจากโปรแกรมในภาคผนวก ข ภาพที่ ข-3

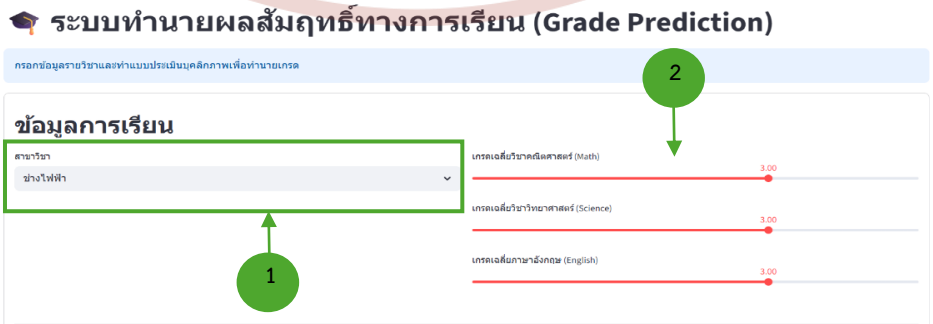
ตารางที่ 4-8 ค่าประสิทธิภาพของเทคนิคการจำแนก แยกตามอัลกอริทึม

อัลกอริทึม	ความแม่นยำ (Accuracy)	ความเที่ยงตรง (Precision)	ค่าระลึก (Recall)	ความสมดุล (F1-Score)
XGBoost	85.47%	85.51%	85.46%	85.48%
Random Forest	85.05%	85.05%	85.06%	85.05%
SVM	78.12%	78.80%	78.12%	78.46%
Naïve bays	69.30%	67.63%	69.30%	68.45%
Neural Network	65.96%	62.15%	65.97%	63.99%

จากตารางที่ 4-8 แสดงผลการเปรียบเทียบประสิทธิภาพอัลกอริทึมที่ใช้ในการพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับชั้นปวช. ด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น พบว่าอัลกอริทึม XGBoost มีประสิทธิภาพสูงที่สุด มีค่าความแม่นยำ 85.47% ค่าความเที่ยงตรง 85.51% ค่าระลึก 85.46% ค่าความสมดุล 85.48% รองลงมาคืออัลกอริทึม Random Forest มีค่าความแม่นยำ 85.05% ค่าความเที่ยงตรง 85.05% ค่าระลึก 85.06% ค่าความสมดุล 85.05% อัลกอริทึม SVM มีค่าความแม่นยำ 78.12% ค่าความเที่ยงตรง 78.80% ค่าระลึก 78.12% ค่าความสมดุล 78.46% อัลกอริทึม Naïve bays มีค่าความแม่นยำ 69.30% ค่าความเที่ยงตรง 67.63% ค่าระลึก 69.30% ค่าความสมดุล 68.45% และอัลกอริทึม Neural Network มีค่าความแม่นยำ 65.96% ค่าความเที่ยงตรง 62.15% ค่าระลึก 65.97% ค่าความสมดุล 63.99% เรียงตามลำดับ

4.3 ต้นแบบระบบทำนายผลสัมฤทธิ์ทางการเรียน (Grade Prediction)

ต้นแบบระบบทำนายผลสัมฤทธิ์ทางการเรียน (Grade Prediction) ถูกพัฒนาขึ้นด้วยภาษาไพทอน โดยใช้ไลบรารี Streamlit เพื่อสร้างหน้าจอการใช้งานและรันผ่าน Firewall ของ Google ผู้ใช้จะต้องกรอกไอพีแอดเดรสของเครื่องที่รันแบบจำลองอยู่ผ่าน Tunnel ที่ระบบสร้างให้เพื่อใช้งาน หลังจากนั้นระบบทำนายผลสัมฤทธิ์ทางการเรียน แสดงหน้าเว็บไซต์ ให้ผู้ใช้งานกรอกข้อมูลการเรียนและ ข้อมูลแบบประเมินบุคลิกภาพ และนำมาจัดเรียงเพื่อส่งเข้ากลับมายังแบบจำลองที่พัฒนาไว้และนำผลลัพธ์กลับมาแสดงที่หน้าเว็บไซต์ มีวิธีการใช้งาน ดังนี้



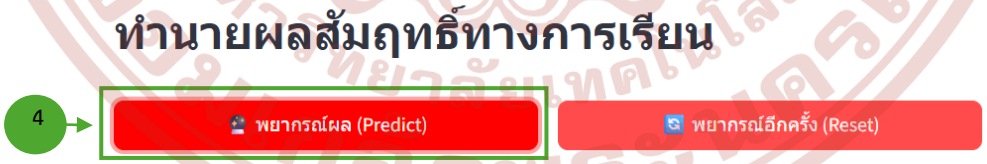
ภาพที่ 4-1 การกรอกข้อมูลการเรียนของระบบทำนายผลสัมฤทธิ์ทางการเรียน

จากภาพที่ 4-1 ผู้ใช้งานระบบทำนายผลสัมฤทธิ์ทางการเรียน จะต้องเลือกสาขาวิชาที่สนใจจาก 5 ตัวเลือก ได้แก่ ช่างไฟฟ้า ช่างกลโรงงาน ช่างยนต์ การบัญชี และเทคโนโลยีธุรกิจดิจิทัล หลังจากนั้น กรอกข้อมูลเกรดเฉลี่ยสะสมวิชาคณิตศาสตร์ วิทยาศาสตร์ และภาษาอังกฤษโดยการเลื่อนสไลด์บาร์ ตามความจริง



ภาพที่ 4-2 การประเมินบุคลิกภาพของระบบทำนายผลสัมฤทธิ์ทางการเรียน

เมื่อผู้ใช้งานกรอกข้อมูลการเรียนเรียบร้อยแล้ว ให้เลื่อนหน้าจอลงมาเพื่อทำแบบประเมินบุคลิกภาพ 5 องค์ประกอบ ได้แก่ ด้านความเป็นมิตร (Agreeableness) ด้านการมีจิตสำนึก (Conscientiousness) ด้านความไม่มั่นคงทางอารมณ์ (Neuroticism) ด้านการเปิดประสบการณ์ (Openness) และด้านการเปิดตัว (Extraversion) หลังจากที่ผู้ใช้งานทำแบบประเมินครบทั้ง 5 ด้านเรียบร้อยแล้ว ให้กดปุ่มเพื่อทำนายตามภาพที่ 4-3



ภาพที่ 4-3 การทำนายของระบบทำนายผลสัมฤทธิ์ทางการเรียน

เมื่อผู้ใช้งานกดปุ่ม “พยากรณ์ผล (Predict)” ระบบจะทำนายผลสัมฤทธิ์ทางการเรียนและแสดงผลการทำนาย พร้อมคะแนนเฉลี่ยการทำแบบประเมินแต่ละด้าน โดยการแสดงผลการทำนายจะแบ่งออกเป็น 5 ระดับ 5 โทนสี ตามที่ได้ระบุไว้ในบทที่ 3 วิธีการดำเนินงานวิจัย ตามภาพที่ 4-4 และภาพที่ 4-8



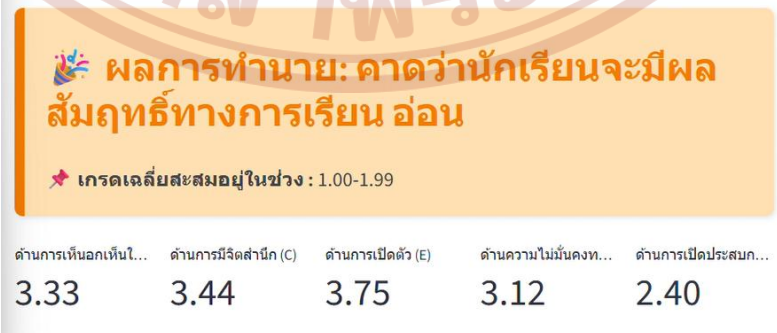
ภาพที่ 4-4 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนดีเยี่ยม



ภาพที่ 4-5 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนดี



ภาพที่ 4-6 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนพอใช้

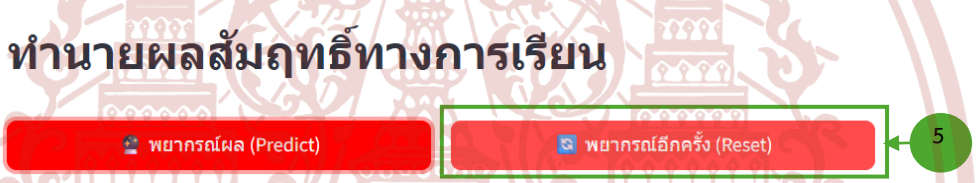


ภาพที่ 4-7 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนอ่อน



ภาพที่ 4-8 ตัวอย่างผลการทำนายผลสัมฤทธิ์ทางการเรียนไม่ผ่านเกณฑ์

นอกจากนี้ผู้ใช้งานยังสามารถกดปุ่ม “พยากรณ์อีกครั้ง (Reset)” เพื่อล้างข้อมูลและทำแบบประเมินใหม่อีกครั้งได้ ดังภาพที่ 4-9



ภาพที่ 4-9 การกดพยากรณ์ผลการเรียนใหม่อีกครั้ง

บทที่ 5
สรุปผล อภิปรายผล และข้อเสนอแนะ

การศึกษาเรื่อง "การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับชั้นประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น" เพื่อพัฒนาแบบจำลองและเปรียบเทียบประสิทธิภาพของอัลกอริทึมในการพยากรณ์ผลสัมฤทธิ์ทางการเรียน ซึ่งสามารถสรุปผลการวิจัย อภิปรายผล และนำเสนอข้อเสนอแนะ ดังนี้

5.1 สรุปผลการวิจัย

5.2 อภิปรายผลการวิจัย

5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

จากการดำเนินการเก็บรวบรวมข้อมูลจากกลุ่มตัวอย่างนักเรียนระดับชั้นประกาศนียบัตรวิชาชีพ (ปวช.) จำนวน 500 คน และทำการปรับสมดุลข้อมูล (Data Balancing) ด้วยเทคนิค SMOTE ผู้วิจัยได้นำข้อมูลเข้าสู่กระบวนการสร้างและทดสอบแบบจำลอง 5 อัลกอริทึม ได้แก่ XGBoost, Random Forest, Support Vector Machine : SVM, Naïve Bayes และ Neural Network ผลการวิจัยสรุปได้ดังนี้

5.1.1 ผลการเปรียบเทียบประสิทธิภาพของแบบจำลอง ผลการทดสอบประสิทธิภาพของแบบจำลอง พบว่าแบบจำลอง XGBoost ให้ประสิทธิภาพสูงสุด โดยมีค่าความแม่นยำ (Accuracy) เท่ากับ ร้อยละ 85.47 รองลงมาคือ Random Forest ร้อยละ 85.05 และ SVM ร้อยละ 78.12 ตามลำดับ ซึ่งทั้ง 3 แบบจำลองนี้มีค่าความแม่นยำสูงกว่าเกณฑ์ร้อยละ 75 ที่กำหนดไว้ ในขณะที่แบบจำลอง Naïve Bayes มีค่าความแม่นยำ (Accuracy) ร้อยละ 69.30 และ Neural Network ร้อยละ 65.96 มีค่าความแม่นยำต่ำกว่าเกณฑ์ที่กำหนด

5.1.2 ปัจจัยที่ส่งผลต่อการพยากรณ์ผลสัมฤทธิ์ทางการเรียน จากการวิเคราะห์น้ำหนักความสำคัญ (Weight by Gini Index) พบว่าปัจจัยด้านผลการเรียนเดิม (GPA) มีอิทธิพลต่อการพยากรณ์มากที่สุด โดยเฉพาะเกรดวิชาคณิตศาสตร์ (0.83) รองลงมาคือเกรดวิชาภาษาอังกฤษ และเกรดวิชาวิทยาศาสตร์ ตามลำดับ ในขณะที่ปัจจัยด้านบุคลิกภาพ (Big 5 Personality Factors) พบว่าด้าน ความไม่มั่นคงทางอารมณ์ (Neuroticism) มีค่าน้ำหนักสูงสุดในกลุ่มตัวแปรบุคลิกภาพ (0.077) ตามด้วยด้านการเปิดตัว (Extraversion) และด้านการเปิดรับประสบการณ์ (Openness)

5.1.3 ผลการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Matrix) แสดงให้เห็นว่าผลการเรียนวิชาคณิตศาสตร์และวิทยาศาสตร์มีความสัมพันธ์กันในระดับสูง อย่างไรก็ตาม ผู้วิจัยพิจารณาคงตัวแปรทั้งสองไว้อย่างมีนัยสำคัญ เนื่องจากเป็นวิชาพื้นฐานที่มีความสำคัญยิ่งต่อสมรรถนะทางอุตสาหกรรมในบริบทของนักเรียนอาชีวศึกษา ทั้งนี้อัลกอริทึมที่นำมาใช้ในการวิจัย โดยเฉพาะอย่างยิ่งกลุ่มโครงสร้างต้นไม้และเทคนิคการเรียนรู้แบบกลุ่ม ได้แก่ XGBoost และ Random Forest มีกลไกภายในที่ทนทานต่อปัญหาภาวะร่วมเส้นตรงพหุคูณ (Multicollinearity) แบบจำลองสามารถ

รับมือกับตัวแปรอิสระที่มีความสัมพันธ์กันเองสูงได้ โดยไม่ส่งผลกระทบเชิงลบต่อประสิทธิภาพหรือความแม่นยำโดยรวมในการพยากรณ์

ด้วยเหตุผลดังกล่าว ข้อมูลผลการเรียนวิชาพื้นฐานทั้ง 3 รายวิชา และปัจจัยด้านบุคลิกภาพทั้ง 5 องค์ประกอบ จึงถูกนำไปใช้เป็นตัวแปรนำเข้า ทั้งหมดสำหรับการประมวลผลเพื่อพยากรณ์ผลสัมฤทธิ์ทางการเรียนในขั้นตอนต่อไป

5.2 อภิปรายผลการวิจัย

จากสรุปผลการวิจัย ผู้วิจัยมีประเด็นสำคัญที่นำมาอภิปรายผลร่วมกับแนวคิด ทฤษฎี และงานวิจัยที่เกี่ยวข้อง ดังนี้

5.2.1 ประสิทธิภาพของอัลกอริทึมแบบกลุ่ม (Ensemble Learning) ผลการวิจัยแสดงให้เห็นว่าอัลกอริทึมการเรียนรู้แบบกลุ่ม (Ensemble Learning) ได้แก่ XGBoost และ Random Forest มีประสิทธิภาพในการพยากรณ์สูงที่สุดและใกล้เคียงกัน โดยมีค่าความแม่นยำอยู่ที่ 85.47% และ 85.05% ซึ่งสอดคล้องกับสมมติฐานการวิจัย ทั้งนี้เนื่องจากเทคนิคเหล่านี้มีกระบวนการสร้างแบบจำลองหลายตัว (Decision Trees) มาช่วยกันตัดสินใจ ทำให้สามารถลดความแปรปรวน (Variance) และป้องกันปัญหาการเรียนรู้เกิน (Overfitting) ได้ดีกว่าโมเดลเดี่ยว สอดคล้องกับงานวิจัยของ พิริยพงศ์ หริ่งรอด (2566) ที่พบว่าโมเดล Random Forest และ XGBoost ให้ค่าประสิทธิภาพสูงสุดในการทำนายความสำเร็จของนักเรียน และสอดคล้องกับงานวิจัยของ Soheila Farokhi et al. (2566) ที่พบว่า Gradient Boosting และ Random Forest มีค่าความแม่นยำสูงในลำดับต้น ๆ เมื่อเทียบกับเทคนิคอื่น

นอกจากนี้ สาเหตุสำคัญที่ทำให้อัลกอริทึม XGBoost (Extreme Gradient Boosting) มีประสิทธิภาพสูงสุดเป็นอันดับหนึ่งในงานวิจัยนี้ สามารถอธิบายชี้ชัดได้ด้วยทฤษฎีและโครงสร้างการทำงานของอัลกอริทึมที่สอดคล้องกับลักษณะชุดข้อมูลของงานวิจัย ใน 3 ประเด็นหลัก ดังนี้

5.2.1.1 ความสามารถในการจัดการข้อมูลขนาดเล็ก เนื่องจากข้อมูลที่ใช้ในงานวิจัยมีปริมาณจำกัด ซึ่งแสดงให้เห็นว่าทฤษฎีการเรียนรู้ของเครื่อง (Machine Learning) แบบจำลองกลุ่มโครงสร้างต้นไม้ อย่าง XGBoost สามารถหาจุดตัดของข้อมูล เพื่อสร้างขอบเขตการตัดสินใจได้อย่างมีประสิทธิภาพกว่าทฤษฎีการเรียนรู้เชิงลึก (Deep Learning) อย่าง Neural Network ที่ต้องอาศัยข้อมูลปริมาณมหาศาลในการฝึกฝน

5.2.1.2 กลไกการเรียนรู้แบบแก้ข้อผิดพลาด (Boosting Mechanism) ของอัลกอริทึม XGBoost เป็นเทคนิคที่ทำงานโดยการสร้างต้นไม้ตัดสินใจขึ้นมาตามลำดับ โดยต้นไม้ต้นใหม่จะพยายามเรียนรู้และลดข้อผิดพลาดที่เกิดจากการทำนายของต้นไม้ต้นก่อนหน้า กลไกนี้มีประโยชน์อย่างยิ่งในการจำแนกกลุ่มข้อมูลแบบพหุคลาส (multi-class) ที่มีความคลุมเครือและซ้อนทับกัน (Overlapping) เช่น การแบ่งแยกระหว่างกลุ่มเกรด B และ C ทำให้โมเดลสามารถจำแนกคลาสที่แยกยากได้อย่างแม่นยำขึ้น

5.2.1.3 กลไกป้องกันการเรียนรู้เกิน (Overfitting) เมื่อใช้ข้อมูลสังเคราะห์ เนื่องจากงานวิจัยนี้มีการใช้เทคนิค SMOTE ในการปรับสมดุลข้อมูล ซึ่งมักนำไปสู่ความเสี่ยงที่แบบจำลองจะเกิดภาวะการเรียนรู้เกิน (Overfitting) จากการจดจำข้อมูลสังเคราะห์ที่สร้างขึ้นใหม่ อย่างไรก็ตาม

แบบจำลอง XGBoost ได้รับการออกแบบมาให้มีกลไกควบคุมความซับซ้อน แบบ Lasso และแบบ Ridge ในสมการคณิตศาสตร์ของตัวแบบซึ่งช่วยปรับค่าต้นไม้ไม่ให้มีโครงสร้างซับซ้อนเกินไป ส่งผลให้ XGBoost มีความทนทานต่อข้อมูลที่มีสัญญาณรบกวนสูง และสามารถรักษาระดับความแม่นยำเมื่อนำไปทดสอบกับชุดข้อมูลทดสอบได้ดีกว่าอัลกอริทึมอื่น

5.2.2 ประสิทธิภาพของการจำแนกกลุ่มผลสัมฤทธิ์ (Classification Performance) เมื่อพิจารณาประสิทธิภาพรายคลาส พบว่าแบบจำลองสามารถทำนายกลุ่ม "ไม่ผ่านเกณฑ์" ได้แม่นยำที่สุด ทุกอัลกอริทึมมีค่าระลึก (Recall) มากกว่า 80% ขึ้นไป เนื่องมาจากลักษณะข้อมูลของกลุ่มนี้มีรูปแบบคะแนนวิชาพื้นฐานที่ต่ำกว่ากลุ่มอื่นอย่างชัดเจน ทำให้แบบจำลองสามารถขีดเส้นแบ่งการตัดสินใจได้ง่าย ในขณะที่การทำนายกลุ่ม "ดี" และ "พอใช้" มีความแม่นยำลดลง ซึ่งเป็นผลมาจากปัญหาการซ้อนทับของข้อมูล เนื่องจากช่วงคะแนนเฉลี่ยของสองกลุ่มนี้มีความใกล้เคียงกัน และคุณลักษณะทางบุคลิกภาพไม่มีความแตกต่างกันอย่างมีนัยสำคัญ ทำให้โอกาสที่แบบจำลองจะทำนายคลาดเคลื่อนระหว่างสองคลาสนี้สูง ซึ่งเป็นความท้าทายทั่วไปในการจำแนกข้อมูลแบบพหุคลาส (Multi-class Classification) ดังที่ Sarker (2021) ได้กล่าวถึงข้อจำกัดในการจำแนกข้อมูลที่มีความคลุมเครือระหว่างคลาส

5.2.3 ปัจจัยที่มีอิทธิพลต่อการพยากรณ์ผลสัมฤทธิ์ทางการเรียนผลการวิจัยพบว่า ผลการเรียนเดิมในรายวิชาพื้นฐาน ได้แก่ วิชาคณิตศาสตร์, วิทยาศาสตร์ และภาษาอังกฤษ เป็นปัจจัยที่มีค่าน้ำหนักความสำคัญสูงสุด สอดคล้องกับงานวิจัยของ Ali Alnoman (2567) ที่พบว่าเกรดวิชาพื้นฐานสามารถระบุความสัมพันธ์และทำนายผลการเรียนสะสมได้อย่างมีประสิทธิภาพ เนื่องจากเป็นตัวบ่งชี้พื้นฐานความรู้และความรับผิดชอบทางการเรียนในอดีต

ในส่วนของปัจจัยด้านบุคลิกภาพ ผลการวิจัยพบว่า ความไม่มั่นคงทางอารมณ์ (Neuroticism) เป็นปัจจัยที่มีค่าน้ำหนักสูงสุด ทั้งนี้อาจเนื่องมาจากบริบทการเรียนในหลักสูตรอาชีวศึกษาเน้นการฝึกปฏิบัติจริงในโรงฝึกงาน ซึ่งต้องเผชิญกับสภาวะความกดดันและความเสี่ยงมากกว่าการเรียนในหลักสูตรการศึกษาขั้นพื้นฐานที่จะเน้นด้านทฤษฎีเป็นหลัก ส่งผลให้นักเรียนที่มีความมั่นคงทางอารมณ์สูง สามารถควบคุมสติและจัดการกับปัญหาเฉพาะหน้าได้ดี และมีผลสัมฤทธิ์ทางการเรียนที่สูงกว่า ซึ่งสอดคล้องกับแนวคิดการวัดบุคลิกภาพของ John, Naumann และ Soto (2008) ที่ระบุว่าความมั่นคงทางอารมณ์เป็นปัจจัยสำคัญในการปรับตัวต่อสภาพแวดล้อมที่ตึงเครียด

5.2.4 ความสัมพันธ์ระหว่างตัวแปร (Correlation Discussion) จากการวิเคราะห์ค่าสัมประสิทธิ์สหสัมพันธ์ (Correlation Matrix) พบประเด็นที่น่าสนใจ ดังนี้

5.2.4.1 ความสัมพันธ์ระหว่างวิชาพื้นฐาน แสดงให้เห็นว่าเกรดวิชาคณิตศาสตร์และวิทยาศาสตร์มีความสัมพันธ์กันในระดับสูง (ค่าสัมประสิทธิ์สัมพันธ์ = 0.665) ตามเกณฑ์ของ John W. Best (1981) อย่างไรก็ตาม ผู้วิจัยยังคงตัวแปรทั้งสองไว้โดยไม่ตัดออก เนื่องจากค่าสัมประสิทธิ์ยังไม่เกินเกณฑ์วิกฤตที่ก่อให้เกิดปัญหาความซ้ำซ้อนของตัวแปร และทั้งสองรายวิชาเป็นพื้นฐานที่มีความสำคัญทางด้านช่างอุตสาหกรรม

5.2.4.2 ความสัมพันธ์ของบุคลิกภาพ พบว่าด้านความไม่มั่นคงทางอารมณ์ (Neuroticism) มีความสัมพันธ์เชิงลบกับด้านการมีจิตสำนึก (Conscientiousness) (ค่าสัมประสิทธิ์สัมพันธ์ = -0.420) และผลสัมฤทธิ์ทางการเรียน ซึ่งผลลัพธ์นี้ สอดคล้องกับทฤษฎีบุคลิกภาพ

5 องค์ประกอบ ที่กล่าวว่าบุคคลที่มีความวิตกกังวลสูงมักจะมีปัญหาในการควบคุมตนเองและจัดการระเบียบวินัย ซึ่งเป็นอุปสรรคต่อความสำเร็จทางการเรียน

5.2.5 การทดสอบสมมติฐาน จากสมมติฐานที่ตั้งไว้ว่า "ประสิทธิภาพการพยากรณ์ด้วยแบบจำลองจะต้องมีค่าความถูกต้องมากกว่า 75%" ผลการวิจัยชี้ให้เห็นว่า ยอมรับสมมติฐานบางส่วน กล่าวคือ แบบจำลอง XGBoost, Random Forest และ SVM สามารถทำนายได้ถูกต้องมากกว่าร้อยละ 75 ตามเกณฑ์ที่กำหนด ในขณะที่ Naïve Bayes และ Neural Network ไม่ผ่านเกณฑ์ดังกล่าว ซึ่งอาจเนื่องมาจากข้อจำกัดของ Neural Network ที่ต้องการปริมาณข้อมูลขนาดใหญ่ (Large Dataset) ในการฝึกฝนเพื่อให้ได้ผลลัพธ์ที่ดี ในขณะที่งานวิจัยนี้มีชุดข้อมูลเพียง 500 ชุด จึงทำให้โมเดลแบบโครงสร้างต้นไม้ (Tree-based) ทำงานได้ดีกว่า

5.3 ข้อเสนอแนะ

5.3.1 ข้อเสนอแนะสำหรับการนำไปใช้

5.3.1.1 การนำโมเดลไปประยุกต์ใช้ในสถานศึกษาควรเลือกใช้อัลกอริทึม XGBoost หรือ Random Forest ในการพัฒนาระบบสารสนเทศเพื่อการแนะแนวศึกษาต่อ เนื่องจากให้ผลลัพธ์แม่นยำที่สุด

5.3.1.2 ผลการวิจัยที่พบว่า เกรดวิชาคณิตศาสตร์และบุคลิกภาพด้านความมั่นคงทางอารมณ์มีผลต่อการพยากรณ์ ครูแนะแนวควรให้ความสำคัญเป็นพิเศษกับนักเรียนที่มีผลการเรียนวิชาคณิตศาสตร์ต่ำ หรือมีคะแนนความไม่มั่นคงทางอารมณ์สูง เพื่อให้คำปรึกษาและวางแผนการเรียนล่วงหน้าก่อนเข้าศึกษาต่อ

5.3.2 ข้อเสนอแนะสำหรับการวิจัยครั้งต่อไป

5.3.1.1 ผู้วิจัยควรพิจารณาเพิ่มตัวแปรอื่นที่อาจส่งผลต่อผลสัมฤทธิ์ทางการเรียนให้มีความสอดคล้องกับนักเรียน และสภาพแวดล้อมในยุคปัจจุบัน เพื่อให้แบบจำลองมีความครอบคลุมมากขึ้น

5.3.1.2 ผู้วิจัยควรเก็บรวบรวมข้อมูลให้มีจำนวนมากขึ้น เพื่อทดสอบประสิทธิภาพของแบบจำลอง Neural Network หรือ Deep Learning ซึ่งอาจให้ผลลัพธ์ที่ดีขึ้น เมื่อมีข้อมูลปริมาณมาก

5.3.1.3 ผู้วิจัยควรศึกษาเปรียบเทียบกับเทคนิคการจำแนกข้อมูลใหม่ตามยุคสมัย เพื่อหาทางเลือกที่มีประสิทธิภาพในการประมวลผลที่รวดเร็วยิ่งขึ้น

บรรณานุกรม

ภาษาไทย

กันต์ ศิระพรธนารัชต์ และชุติพนธ์ ศรีสวัสดิ์. (2567). [วารสารออนไลน์]. การใช้เทคนิคเหมืองข้อมูลเพื่อพยากรณ์การสำเร็จการศึกษา Forecasting Graduation By Data Mining Techniques. วารสารเทคโนโลยีสารสนเทศ มจพ.. ฉบับที่1 ปีที่ 21 : 33-34

กนิษฐา อินธิชิต ภควัฒน์ ปิยวงษ์ และสุภาพร. (2565). [วารสารออนไลน์]. การพัฒนาแอปพลิเคชันช่วยตัดสินใจในการเลือกเรียนสาขาวิชาคอมพิวเตอร์ในมหาวิทยาลัยราชภัฏศรีสะเกษบนระบบปฏิบัติการแอนดรอยด์ โดยใช้เทคนิคต้นไม้ตัดสินใจ. วารสารวิชาการ การจัดการเทคโนโลยี มหาวิทยาลัยราชภัฏมหาสารคาม. ฉบับที่2 ปีที่ 9 : 97-107

ชลิตา ชีววิริยะนนท์ และนนทศักดิ์ จันทร์ชุม. (2567). [วารสารออนไลน์]. การพัฒนาตัวแบบทำนายทักษะการคิดเชิงคำนวณของนักเรียนชั้นมัธยมศึกษาตอนต้น โดยใช้เทคนิคแมชชีนเลิร์นิง Journal of Inclusive and Innovative Education. Vol. 8 No.1: 120 – 134

ไทยพีบีเอส. (2566). [ออนไลน์]. ศธ.เปิดข้อมูลเทอม 2/2565 นักเรียนออกกลางคัน 52,808 คน. [สืบค้นเมื่อวันที่ 15 กรกฎาคม 2568]. จาก https://www.thaipbs.or.th/news.content/326968

ธนพร คล้ายทอง และชุติพนธ์ ศรีสวัสดิ์. (2566). [วารสารออนไลน์]. “การพยากรณ์การตกออกของนักศึกษาระดับปริญญาตรี มหาวิทยาลัยราชภัฏพิบูลสงคราม ด้วยเทคนิคเหมืองข้อมูล”. วารสารวิทยาการสารสนเทศและเทคโนโลยีประยุกต์. ฉบับที่ 1 ปีที่ 5 : 1-17

บัญชา ช่วยสี. (2567). [ออนไลน์]. Notebook บทความชุด AI For Youth ชุดบทความสำหรับการก้าวเข้าสู่โลกของ AI และ Machine Learning แบบค่อยเป็น ค่อยไป ไม่เน้นความยาก. [สืบค้นวันที่ 13 มิถุนายน 2568]. จาก https://medium.com/@LCdr.Dr.Buncha/aiforyouth-correlation-พื้นฐาน-eff91a4ac1b0

ปณิธิ ทองมอญ. (2566). [วิทยานิพนธ์ออนไลน์]. การวิเคราะห์กฎความสัมพันธ์และการทำนายความสำเร็จในการเรียนรายวิชาในระบบหลักสูตร. วิทยานิพนธ์หลักสูตรปริญญาครุศาสตรมหาบัณฑิต สาขาวิชาวิธีวิทยาการพัฒนานวัตกรรมทางการศึกษา ภาควิชาวิจัยและจิตวิทยาการศึกษา คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย. [สืบค้นวันที่ 12 มิถุนายน 2568]. จาก https://digital.car.chula.ac.th/chulaetd/12176/

พรสรัญ รุ่งเจริญกิจกุล. (2565). [ออนไลน์]. บุคลิกภาพที่ประสบความสำเร็จ พัฒนาได้อย่างไร. [สืบค้นวันที่ 17 กรกฎาคม 2568] จากhttps://moneyandbanking.co.th/2022/15543/

บรรณานุกรม (ต่อ)

พิมพ์ประภา พาลพ่าย และ วชิระ พรหมวงศ์. (2567). [วารสารออนไลน์]. การใช้เทคนิคเหมืองข้อมูลเพื่อพยากรณ์ผลการเรียนจากพฤติกรรมการเรียนรู้ของนักศึกษาระดับปริญญาโท มหาวิทยาลัยสุโขทัยธรรมาธิราชบนระบบการเรียนออนไลน์. วารสารการวัดประเมินผลสถิติและการวิจัยทางสังคมศาสตร์. ฉบับที่ 1 ปีที่ 5 : 111-126

พิริยพงษ์ หริ่งรอด. (2566). [วิทยานิพนธ์ออนไลน์]. การพัฒนาโมเดลทำนายความสำเร็จในการเรียนของนักเรียนโดยประยุกต์ใช้การเรียนรู้แบบเอนเซมเบิล. วิทยานิพนธ์หลักสูตรปริญญาครุ-ศาสตรมหาบัณฑิต สาขาวิชาวิธีวิทยาการพัฒนานวัตกรรมทางการศึกษา ภาควิชาวิจัยและจิตวิทยาการศึกษา คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย. [สืบค้นวันที่ 14 มิถุนายน 2568]. จาก https://digital.car.chula.ac.th/chulaetd/12529/

รัชนก พิยาพาณิชยกุล. (2566). [ออนไลน์]. ปัญหาข้อมูลไม่สมดุล (Imbalanced Data in Classification Mode). [สืบค้นวันที่ 21 มิถุนายน 2568]. จาก https://nicloundsolutions.ntplc.co.th/knowledge/imbalanced-data-classification/

วงกต ศรีอุไร อนุสรณ์ บันเทิง และคมกฤษณ์ มุธาพร. (2567). [วิทยานิพนธ์ออนไลน์]. การพัฒนาระบบแนะนำการเลือกวิชาเอกของสาขาเทคโนโลยีสารสนเทศและการสื่อสาร โดยใช้เทคนิคต้นไม้ตัดสินใจ. ภาควิชาคณิตศาสตร์ สถิติ คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี . [สืบค้นวันที่ 13 มิถุนายน 2568]. จาก https://li01.tci-.php/scimusijournal/article/view/261234

วิริทธิ์พล เกษมสุข. (2565). [วิทยานิพนธ์ออนไลน์]. การพัฒนาระบบโครงข่ายประสาทเทียมสำหรับทำนายจำนวนวันหยุดงานจากการเกิดอุบัติเหตุจากการทำงาน. สาขาวิชาอาชีวอนามัยและปลอดภัย คณะสาธารณสุขศาสตร์ มหาวิทยาลัยบูรพา. [สืบค้นวันที่ 13 มิถุนายน 2568]. จาก https://digital_collect.lib.buu.ac.th/dcms/files/62920128.pdf

ศิรินทรา เสือพิทักษ์ บุญมี นิสสัยดี และวิภาวรรณ บัวทอง. (2564). [วารสารออนไลน์]. การเปรียบเทียบเทคนิคการจำแนกประเภทข้อมูลสำหรับทำนายแนวโน้มการสำเร็จการศึกษาของนักเรียน. วารสารวิชาการชายน์เทค มรภ.ภูเก็ต. ฉบับที่ 2 ปีที่ 5 : 42-50

สำนักงานคณะกรรมการการอาชีวศึกษา. (2567). [ออนไลน์]. หลักสูตรประกาศนียบัตร พุทธศักราช 2567. [สืบค้นวันที่ 17 กรกฎาคม 2568] จาก https://bsq.vec.go.th/Portals/9/Course/20/2567/20000Principlesv2.pdf

บรรณานุกรม (ต่อ)

สืบพงษ์ พงษ์สวัสดิ์ พงศ์กร จันทราช. (2568). [วิทยานิพนธ์ออนไลน์]. การประยุกต์เทคนิคเหมืองข้อมูลเพื่อพยากรณ์ผลประเมินบทความจากวารสารนวัตกรรมสังคมและการเรียนรู้ตลอดชีวิต. วิทยานิพนธ์หลักสูตรวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูลและนวัตกรรมดิจิทัลม มหาวิทยาลัยฟาร์อีสเทอร์. [สืบค้นวันที่ 12 มิถุนายน 2568]. จาก https://benjamit.thonburi-u.ac.th/ojs/bmv15/article/view/81

อรรถกฤต อินทะโย. (2560). [ออนไลน์]. ปัจจัยที่ส่งผลต่อการเลือกเรียนสายอาชีพในสถานศึกษาอาชีวศึกษาของนักเรียนในจังหวัดเชียงราย. การประชุมนำเสนอผลงานวิจัยระดับบัณฑิตศึกษา.ครั้งที่ 12.: 933-941

บรรณานุกรม (ต่อ)

ภาษาอังกฤษ

Albreiki, B., Zaki, N., & Alashwal, H. (2021). A systematic literature review of student' performance prediction using machine learning techniques. Education Sciences, 11(9), 552. From https://doi.org/10.3390/educsci11090552

Ali Alnoman. (2023). [Online]. Regression -based Student Performance Prediction Using the Grades of English, Math, and Programming Courses. Department of Computer Science and Engineering American University of Ras Al Khaimah, UAE. [Retrieved 12 June 2024]. From https://ieeexplore.ieee.org/abstract/document/10878152

Balqis Albreiki, Nazar Zaki and Hany Alashwal. (2021). [Online]. A Systematic Literature Review of Student 'Performance Prediction Using Machine Learning Techniques. Department of Computer Science and Software Engineering, College of Information Technology, United Arab Emirates University. [Retrieved 12 June 2024]. From https://www.mdpi.com/2227-7102/11/9/552

BAO Yunxia et al. (2020). [Journal]. Student Performance Prediction Based on Behavior Process Similarity. Chinese Journal of Electronics. Vol.29 No.6 : 1111-1118

Breiman, L. (2001). Random forests. Machine Learning, 45(1), 5–32. [Retrieved 12 June 2024]. From https://doi.org/10.1023/A:1010933404324

Chen, T., & Guestrin, C. (2016). XGBoost: A scalable tree boosting system. In Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining (pp. 785–794). Association for Computing Machinery. From https://doi.org/10.1145/2939672.2939785

Chuanjun Zhao, Zhihe Yan, Xuzhuang Sun and Meiling Wu. (2024). Enhancing aspect category detection in imbalanced online reviews: An Integrated approach using Select-SMOTE and LightGBM. International Journal of Intelligent Networks 5, 364-372. Article 100534.https://doi.org /10.1016/j.mlwa.2024.100534

Han, J., Kamber, M., & Pei, J. (2012). Data Mining: Concepts and Techniques (3rd ed.). Waltham, MA: Morgan Kaufmann.

บรรณานุกรม (ต่อ)

Hanan abdullah mengash. (2020). [Online]. Using Data Mining Techniques to Predict Student Performance to Support Decision Making in University Admission Systems. Information Systems Department, College of Computer and Information Sciences, Princess Nourah bint Abdulrahman University, Riyadh. [Retrieved 12 June 2024]. From https://ieeexplore.ieee.org/abstract /document/9042216

Hassan Zeineddine, Udo Braendle and Assaad Farah. (2021). [Online]. Enhancing prediction of student success: Automated machine learning approach. AUD/IBM Center of Excellence for Smarter Logistics, American University in Dubai. [Retrieved 12 June 2024]. From https://www.sciencedirect. com/science/article/abs/pii/S0045790620307552

GeeksforGeeks. (2026). [Online]. XGBoost. [Retrieved 12 June 2024]. From https://www.geeksforgeeks.org/machine-learning/xgboost/

Gittamade Suengsiri. (2022). [Online]. Red Wine Quality Machine Learning. [Retrieved 12 June 2024]. From https://medium.com/@gittamadesuengsiri/red-wine-quality-machine-learning-a5f61b68701

Grandini, M., Bagli, E., & Visani, G. (2020). Metrics for Multi-Class Classification: an Overview. arXiv preprint arXiv:2008.05756.

John, O. P., Naumann, L. P., & Soto, C. J. (2008). Paradigm shift to the integrative Big-Five trait taxonomy: History, measurement, and conceptual issues. In O. P. John, R. W. Robins, & L. A. Pervin (Eds.), Handbook of personality: Theory and research (pp. 114–158). Guilford Press.

Kyriaki A. Tychola, Theofanis Kalampokass and George A. Papakostas. (2023). [Online]. Quantum Machine Learning. [Retrieved 12 June 2024]. From https://www.mdpi.com/2079-9292/12/11/2379

Laber, J., & Murtaza, S. S. (2023). A Comparative Analysis of Feature Selection Methods for Software Defect Prediction. 2023 IEEE International Conference on Software Analysis, Evolution and Reengineering (SANER).

บรรณานุกรม (ต่อ)

Mani Teja. (2024). [Online]. Understanding the Naive Bayes Classification Algorithm. [Retrieved 12 June 2024]. From https://medium.com/@manitejaladi/understanding-the-naive-bayes-classification-algorithm-b515b2cd63dc

Mirna Nachouki, et al. (2023). [Online]. Student course grade prediction using the random forest algorithm analysis of predictors 'importance. Artificial Intelligence Research Centre, Department of Information Technology, Ajman University, UAE . [Retrieved 12 June 2024]. From https://www.sciencedirect.com/science/article/pii/S2211949323000170

Mizanur Rahman, Md Imtiaz Ahmed and Mohammed Shakhawat Hossain. (2021). [Online]. Analysis of Student's Achievement Through Educational Data Mining. Computer science and Engineering Daffodil Institute of IT Dhaka, Bangladesh. [Retrieved 12 June 2024]. From https://ieeexplore.ieee.org/abstract/document/9678406

Noviyanti TM Sagala, et al. (2565). [Online]. Predicting Computer Science Student's Performance Using Logistic Regression. Statistics Department School of Computer Science Bina Nusantara University Jakarta, Indonesia. [Retrieved 12 June 2024]. จาก https://ieeexplore.ieee.org/abstract/docum ent/10

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. Nature, 323 (6088), 533–536. https://doi.org/10.1038/323533a0

Sarker, I. H. (2021). Machine Learning: Algorithms, Real-World Applications and Research Directions. SN Computer Science, 2(3), 160.

Shishir Kaphle. (2026). [Online]. Neural Network Architecture. [Retrieved 12 June 2024]. From https://www.linkedin.com/posts/shishir-kaphle78_day-6-of-my-machine-learning-and-deep-learning-activity-7402203191813115904-3b8l/

Soheila Farokhi, et al. (2023). [Online]. Enhancing the Performance of Automated Grade Prediction in MOOC using Graph Representation Learning. Data Science and Applications Lab, Utah State University. [Retrieved 12 June 2024]. From https://ieeexplore.ieee.org/abstract/ document/10302642

Tharwat, A. (2021). Classification assessment metric roles in machine learning applications. AI Communications, 34 (1), 27-55.

บรรณานุกรม (ต่อ)

Udu, G., et al. (2025). Emerging SMOTE and GAN Variants for Data Augmentation in Imbalance Machine Learning Tasks: A Review. IEEE Access, 13.

Xiaojiao Wen. (2024). [Online]. Student Grade Prediction and classification based on Term Frequency – Inverse Document Frequency With Random Forest. Yunnan College of Medicine and health General Education College Kunming, China. [Retrieved 12 June 2024]. From https://ieeexplore.ieee.org/abstract/document/10796287



ภาคผนวก

ภาคผนวก ก

ตัวอย่างเครื่องมือสำหรับเก็บรวบรวมข้อมูล

แบบสอบถามนี้มีวัตถุประสงค์เพื่อรวบรวมข้อมูลสำคัญที่เกี่ยวข้องกับ **ข้อมูลส่วนบุคคลเบื้องต้น, บุคลิกภาพ, และผลการเรียน** ของท่าน ซึ่ง**ข้อมูลเหล่านี้จะถูกนำไปใช้ในการพัฒนาแบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียนระดับประกาศนียบัตรวิชาชีพ (5 สาขายอดนิยม)** การวิจัยนี้มุ่งหวังที่จะสร้างเครื่องมือที่เป็นประโยชน์สำหรับนักเรียนและสถานศึกษาในการประเมินศักยภาพและตัดสินใจเลือกเส้นทางการศึกษาที่เหมาะสมและนำไปสู่ความสำเร็จในอนาคต

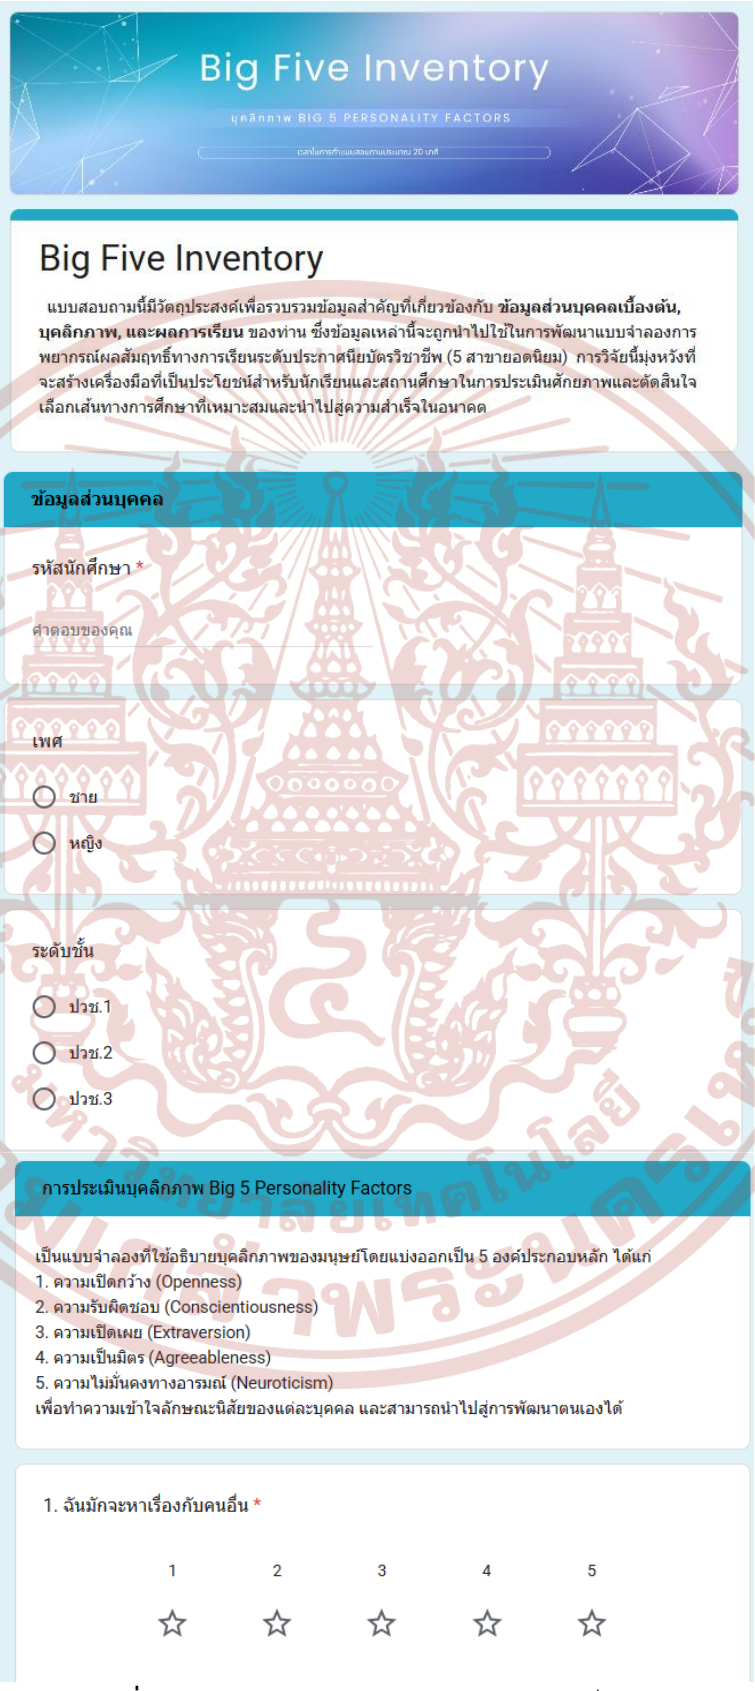
หมายเหตุ : เกรดเฉลี่ยปัจจุบัน, คณิตศาสตร์, วิทยาศาสตร์ และอังกฤษ หากจำไม่ได้ให้ประมาณระบุ 1-4 โดยไม่ต้องระบุทศนิยม

คำถามมีทั้งหมด 49 ข้อ ขอความร่วมมือให้นักเรียนประเมินตามความจริงมากที่สุด และขอขอบคุณมา ณ ที่นี้ สำหรับการสละเวลาในการทำแบบสอบถาม ข้อมูลของท่านจะเป็นประโยชน์ในการพัฒนาระบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียนให้ดียิ่งขึ้นต่อไป

ขอบคุณค่ะ

SCAN ME
Automotive Mechanic

ภาพที่ ก-1 ตัวอย่างคิวอาร์โค๊ดสำหรับจัดเก็บข้อมูลสาขาวิชาช่างยนต์



ภาพที่ ก-2 ตัวอย่าง Google Form สำหรับเก็บข้อมูล

ภาคผนวก ข

แบบจำลองการพยากรณ์ผลสัมฤทธิ์ทางการเรียน

จากโปรแกรม Rapid Miner Studio

Attributes	subject	math	science	eng	A	C	E	N	O
subject	1	0.209	0.318	0.140	-0.076	-0.253	-0.053	0.332	0.022
math	0.209	1	0.665	0.218	0.256	0.050	-0.196	0.365	0.305
science	0.318	0.665	1	0.379	0.135	0.032	-0.150	0.303	0.301
eng	0.140	0.218	0.379	1	0.006	0.133	0.119	-0.177	0.150
A	-0.076	0.256	0.135	0.006	1	0.480	0.074	-0.108	0.423
C	-0.253	0.050	0.032	0.133	0.480	1	0.208	-0.420	0.371
E	-0.053	-0.196	-0.150	0.119	0.074	0.208	1	-0.271	0.242
N	0.332	0.365	0.303	-0.177	-0.108	-0.420	-0.271	1	0.033
O	0.022	0.305	0.301	0.150	0.423	0.371	0.242	0.033	1

ภาพที่ ข-1 ผลลัพธ์ของแบบจำลอง Correlation Matrix

accuracy: 69.30% +/- 3.15% (micro average: 69.30%)

	true A	true B	true C	true D	true F	class precision
pred. A	286	64	24	5	0	75.46%
pred. B	17	127	63	12	0	57.99%
pred. C	11	73	115	29	0	50.44%
pred. D	14	45	111	283	0	62.47%
pred. F	1	20	16	0	329	89.89%
class recall	86.93%	38.60%	34.95%	86.02%	100.00%	

weighted_mean_recall: 69.30% +/- 3.15% (micro average: 69.30%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	286	64	24	5	0	75.46%
pred. B	17	127	63	12	0	57.99%
pred. C	11	73	115	29	0	50.44%
pred. D	14	45	111	283	0	62.47%
pred. F	1	20	16	0	329	89.89%
class recall	86.93%	38.60%	34.95%	86.02%	100.00%	

weighted_mean_precision: 67.63% +/- 3.75% (micro average: 67.25%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	286	64	24	5	0	75.46%
pred. B	17	127	63	12	0	57.99%
pred. C	11	73	115	29	0	50.44%
pred. D	14	45	111	283	0	62.47%
pred. F	1	20	16	0	329	89.89%
class recall	86.93%	38.60%	34.95%	86.02%	100.00%	

ภาพที่ ข-2 ประสิทธิภาพของแบบจำลอง Naïve bays

accuracy: 65.96% +/- 2.95% (micro average: 65.96%)

	true A	true B	true C	true D	true F	class precision
pred. A	266	69	18	4	0	74.51%
pred. B	32	102	66	6	1	49.28%
pred. C	8	75	100	28	0	47.39%
pred. D	22	70	137	290	1	55.77%
pred. F	1	13	8	1	327	93.43%
class recall	80.85%	31.00%	30.40%	88.15%	99.39%	

weighted_mean_precision: 62.15% +/- 6.17% (micro average: 64.08%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	266	69	18	4	0	74.51%
pred. B	32	102	66	6	1	49.28%
pred. C	8	75	100	28	0	47.39%
pred. D	22	70	137	290	1	55.77%
pred. F	1	13	8	1	327	93.43%
class recall	80.85%	31.00%	30.40%	88.15%	99.39%	

weighted_mean_recall: 65.97% +/- 2.94% (micro average: 65.96%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	266	69	18	4	0	74.51%
pred. B	32	102	66	6	1	49.28%
pred. C	8	75	100	28	0	47.39%
pred. D	22	70	137	290	1	55.77%
pred. F	1	13	8	1	327	93.43%
class recall	80.85%	31.00%	30.40%	88.15%	99.39%	

ภาพที่ ข-3 ประสิทธิภาพของแบบจำลอง Neural Network

accuracy: 84.62% +/- 2.34% (micro average: 84.62%)

	true A	true B	true C	true D	true F	class precision
pred. A	302	21	4	0	0	92.35%
pred. B	14	233	74	11	0	70.18%
pred. C	5	53	224	14	0	75.68%
pred. D	8	17	24	304	0	86.12%
pred. F	0	5	3	0	329	97.63%
class recall	91.79%	70.82%	68.09%	92.40%	100.00%	

weighted_mean_precision: 84.77% +/- 2.39% (micro average: 84.39%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	302	21	4	0	0	92.35%
pred. B	14	233	74	11	0	70.18%
pred. C	5	53	224	14	0	75.68%
pred. D	8	17	24	304	0	86.12%
pred. F	0	5	3	0	329	97.63%
class recall	91.79%	70.82%	68.09%	92.40%	100.00%	

weighted_mean_recall: 84.62% +/- 2.34% (micro average: 84.62%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	302	21	4	0	0	92.35%
pred. B	14	233	74	11	0	70.18%
pred. C	5	53	224	14	0	75.68%
pred. D	8	17	24	304	0	86.12%
pred. F	0	5	3	0	329	97.63%
class recall	91.79%	70.82%	68.09%	92.40%	100.00%	

ภาพที่ ข-4 ประสิทธิภาพของแบบจำลอง Random Forest

accuracy: 78.12% +/- 2.65% (micro average: 78.12%)

	true A	true B	true C	true D	true F	class precision
pred. A	292	36	6	0	0	87.43%
pred. B	11	152	55	6	0	67.86%
pred. C	16	119	235	46	0	56.49%
pred. D	10	17	24	277	0	84.45%
pred. F	0	5	9	0	329	95.92%
class recall	88.75%	46.20%	71.43%	84.19%	100.00%	

weighted_mean_recall: 78.12% +/- 2.65% (micro average: 78.12%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	292	36	6	0	0	87.43%
pred. B	11	152	55	6	0	67.86%
pred. C	16	119	235	46	0	56.49%
pred. D	10	17	24	277	0	84.45%
pred. F	0	5	9	0	329	95.92%
class recall	88.75%	46.20%	71.43%	84.19%	100.00%	

weighted_mean_precision: 78.80% +/- 2.99% (micro average: 78.43%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	292	36	6	0	0	87.43%
pred. B	11	152	55	6	0	67.86%
pred. C	16	119	235	46	0	56.49%
pred. D	10	17	24	277	0	84.45%
pred. F	0	5	9	0	329	95.92%
class recall	88.75%	46.20%	71.43%	84.19%	100.00%	

ภาพที่ ข-5 ประสิทธิภาพแบบจำลอง SVM

accuracy: 85.47% +/- 1.64% (micro average: 85.47%)

	true A	true B	true C	true D	true F	class precision
pred. A	304	17	6	3	0	92.12%
pred. B	8	230	58	9	0	75.41%
pred. C	11	64	246	19	0	72.35%
pred. D	6	14	16	298	1	88.96%
pred. F	0	4	3	0	328	97.91%
class recall	92.40%	69.91%	74.77%	90.58%	99.70%	

weighted_mean_recall: 85.46% +/- 1.65% (micro average: 85.47%), weights: 1, 1, 1, 1, 1

	true A	true B	true C	true D	true F	class precision
pred. A	304	17	6	3	0	92.12%
pred. B	8	230	58	9	0	75.41%
pred. C	11	64	246	19	0	72.35%
pred. D	6	14	16	298	1	88.96%
pred. F	0	4	3	0	328	97.91%
class recall	92.40%	69.91%	74.77%	90.58%	99.70%	

weighted_mean_precision: 85.51% +/- 1.77% (micro average: 85.35%), weights: 1, 1, 1, 1, 1

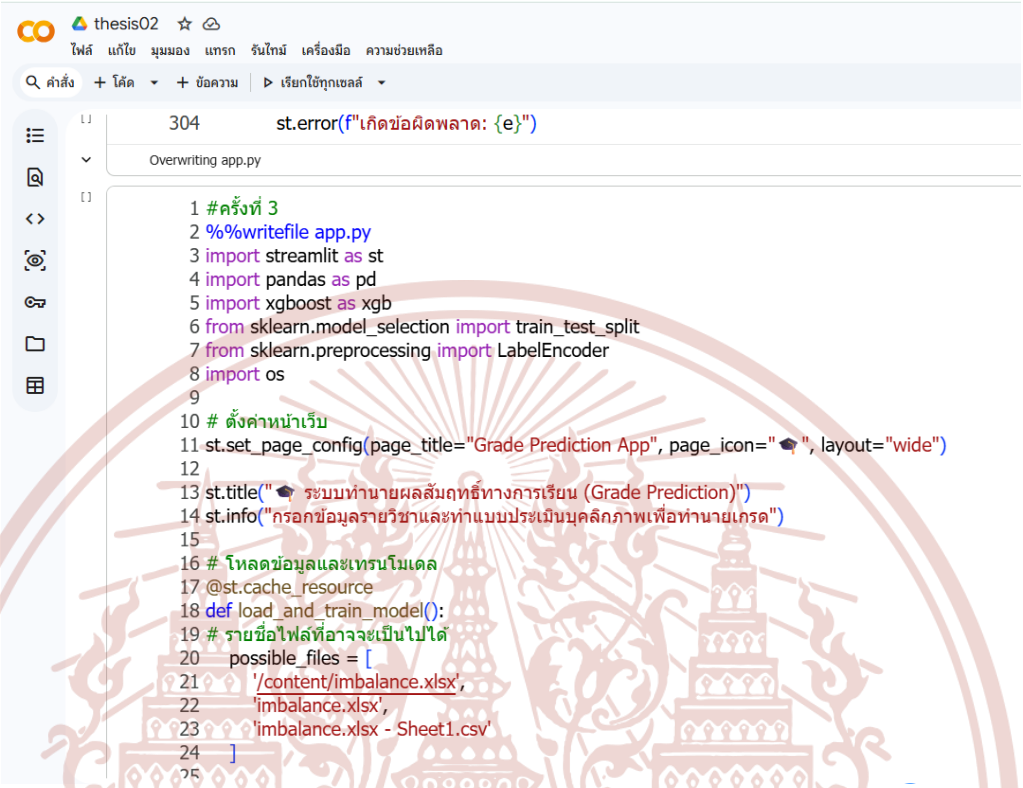
	true A	true B	true C	true D	true F	class precision
pred. A	304	17	6	3	0	92.12%
pred. B	8	230	58	9	0	75.41%
pred. C	11	64	246	19	0	72.35%
pred. D	6	14	16	298	1	88.96%
pred. F	0	4	3	0	328	97.91%
class recall	92.40%	69.91%	74.77%	90.58%	99.70%	

ภาพที่ ข-6 ประสิทธิภาพแบบจำลอง XGBoost

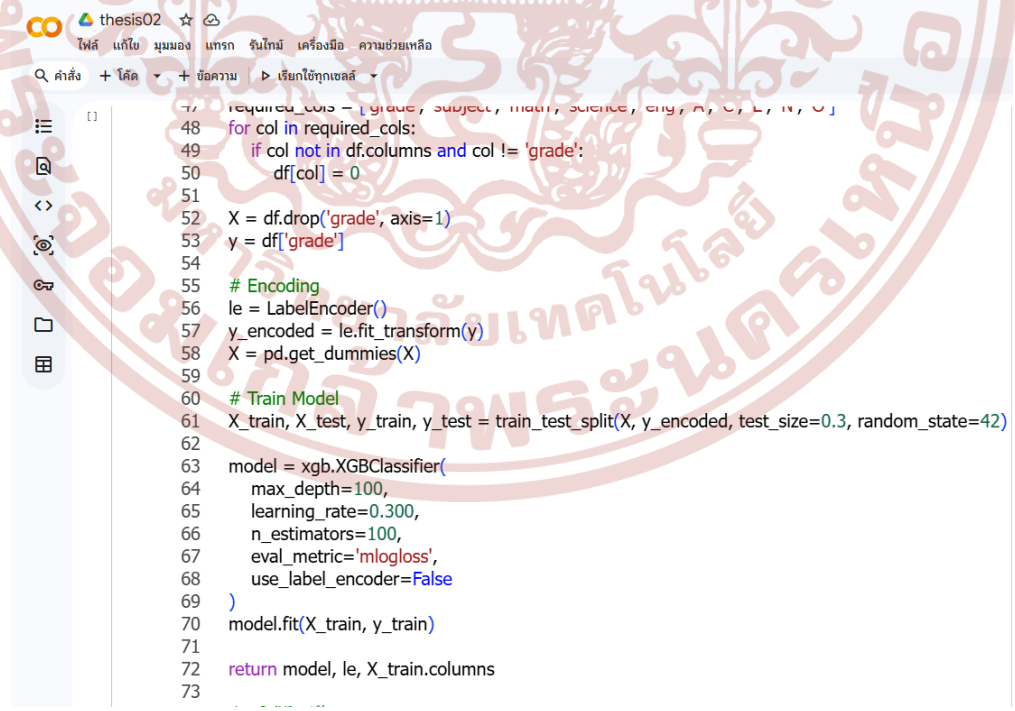
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ภาคผนวก ค
การสร้างหน้าส่วนติดต่อผู้ใช้ด้วยภาษาไพทอน

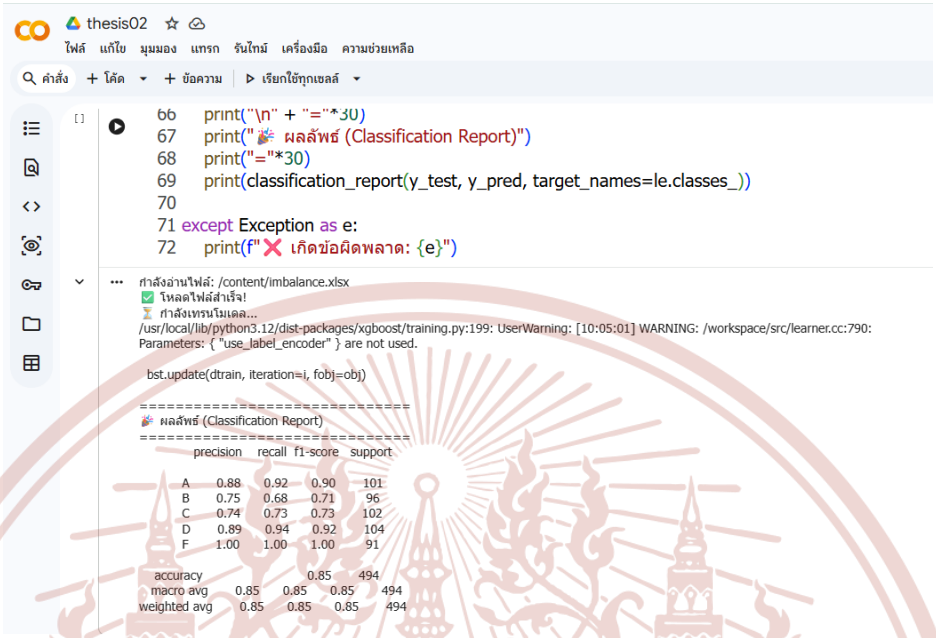
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ



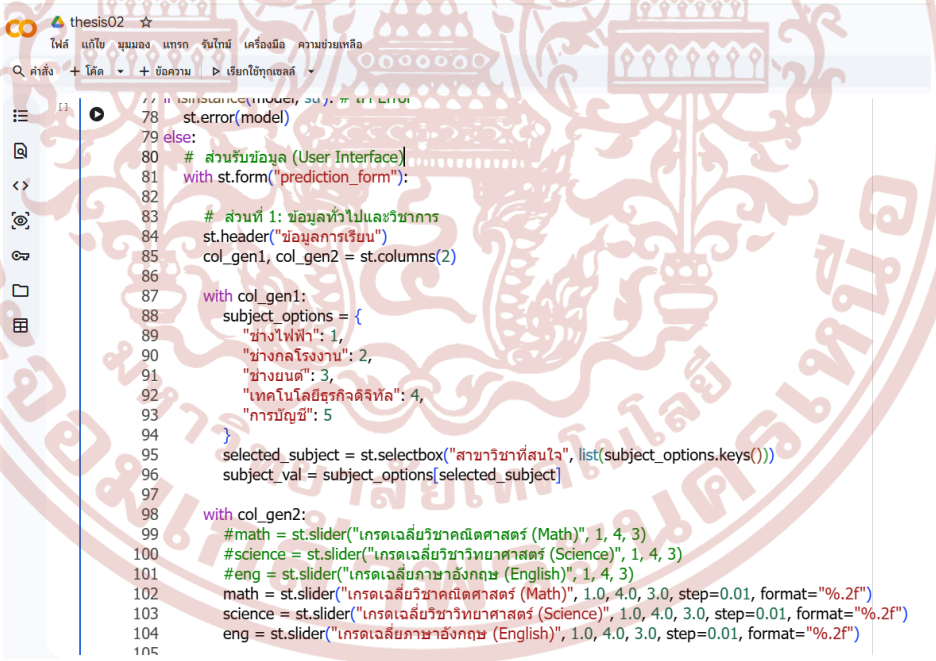
ภาพที่ ค-1 คำสั่งเรียกใช้ไลบรารี และโหลดไฟล์ข้อมูลเพื่อนำไปโมเดลเรียนรู้



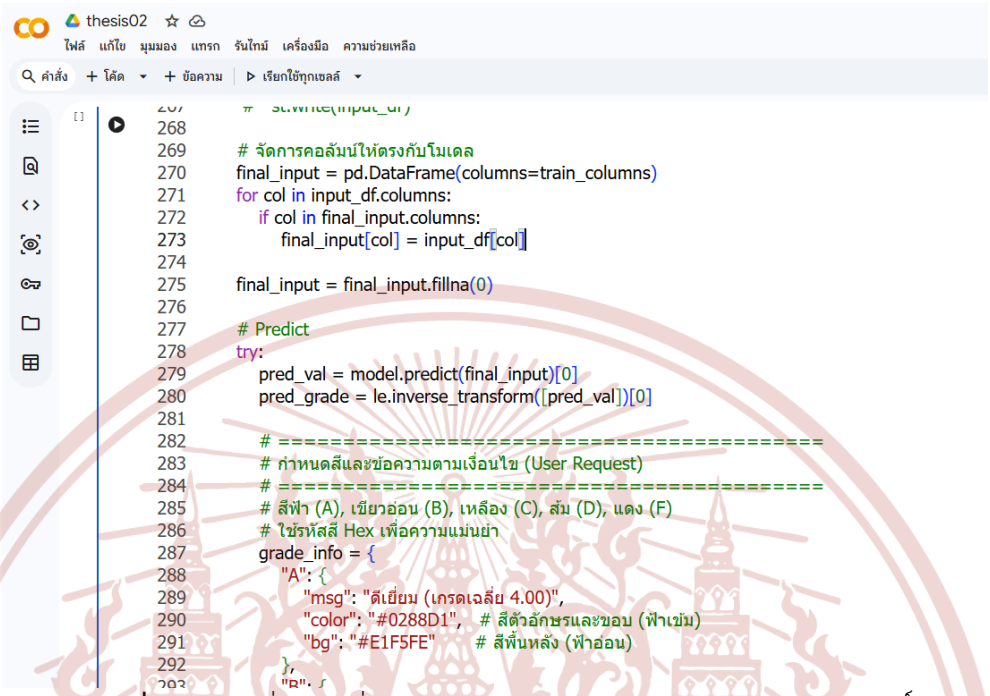
ภาพที่ ค-2 คำสั่งกำหนดค่าพารามิเตอร์ให้สอดคล้องกับแบบจำลองที่ได้จาก Rapid Miner



ภาพที่ ค-3 ค่าประสิทธิภาพของแบบจำลองที่สร้างด้วยคำสั่งไพทอน



ภาพที่ ค-4 คำสั่งสร้างหน้าส่วนติดต่อผู้ใช้งาน



ภาพที่ ค-5 คำสั่งส่งค่าที่ได้รับจากผู้ใช้ไปให้แบบจำลองพยากรณ์ผลสัมฤทธิ์



ภาพที่ ค-6 คำสั่งรันหน้าเว็บไซต์ผ่านช่องทางผ่าน Firewall ของ Google

ประวัติผู้เขียน

ชื่อ นางสาวอุไรวรรณ มีแสง

ชื่อการค้นคว้าอิสระ การพยากรณ์ผลสัมฤทธิ์ทางการเรียนในระดับประกาศนียบัตรวิชาชีพด้วยบุคลิกภาพ 5 องค์ประกอบและเกรดวิชาหลักมัธยมศึกษาตอนต้น

สาขาวิชา ระบบสารสนเทศเพื่อการจัดการ
มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

ประวัติ อีเมล m.uraiwan.som@gmail.com
ที่อยู่ 88/107 หมู่บ้านแกรนด์การ์เด้นเพลส 1 ตำบลบ้านไร่
อำเภอเมืองราชบุรี จังหวัดราชบุรี 70000

ประวัติการศึกษา
ระดับปริญญาตรี มหาวิทยาลัยเทคโนโลยีราชมงคลพระนคร
บธ.บ (ระบบสารสนเทศ)

ประสบการณ์ทำงาน
2565 - ปัจจุบัน ข้าราชการครู วิทยาลัยเทคนิคราชบุรี
2560 - 2565 ครูพิเศษสอน วิทยาลัยเทคนิคราชบุรี