

การพัฒนาตัวแบบทำนายความสำเร็จในการเรียนของนักเรียนโดยประยุกต์ใช้ การเรียนรู้แบบเอนเซมเบิล

พริยพงศ์ หรั่งรอด¹, ประภาศิริ รัชชประภาพรกุล^{*2} และ สิวะโชติ ศรีสุทธิยากร³

จุฬาลงกรณ์มหาวิทยาลัย แขวงวังใหม่ เขตปทุมวัน กรุงเทพฯ 10330

Received: 10 June 2024; Revised: 04 October 2024; Accepted: 12 December 2024

บทคัดย่อ

งานวิจัยนี้มีการประยุกต์ใช้การเรียนรู้แบบเอนเซมเบิลซึ่งเป็นการรวมหลาย ๆ ตัวแบบเข้าด้วยกัน เพื่อวิเคราะห์การเรียนรู้ของนักเรียน โดยมีวัตถุประสงค์ 1) พัฒนาตัวแบบทำนายความสำเร็จในการเรียนของนักเรียนชั้นมัธยมศึกษาปีที่ 4 ภาคเรียนที่ 2 ปีการศึกษา 2566 โรงเรียนสาธิตมหาวิทยาลัยศรีนครินทรวิโรฒ ประสานมิตร (ฝ่ายมัธยม) ที่เรียนในรายวิชาคณิตศาสตร์เพิ่มเติม 2(1) ค31208 จำนวน 397 คน โดยใช้พฤติกรรมในการเรียนของนักเรียนซึ่งเป็นพฤติกรรมที่ผู้สอนสามารถเก็บรวบรวมและสังเกตได้จากการจัดกิจกรรมการเรียนรู้ ประกอบด้วย 5 ด้าน ได้แก่ ความสามารถในการเรียน ความรับผิดชอบ การมีส่วนร่วมในชั้นเรียน ความขยันหมั่นเพียร และความมุ่งมั่นตั้งใจ เป็นตัวแปรทำนาย และ 2) วิเคราะห์ปัจจัยที่มีความสำคัญต่อความสำเร็จในการเรียนของนักเรียน โดยเปรียบเทียบประสิทธิภาพของตัวแบบในการจำแนกข้อมูล 5 วิธี ได้แก่ Elastic-net regularized generalized linear model (GLM), Random Forest (RF), Gradient Boosting with XGBoost (XGBoost), Artificial Neural Network (ANN) และการเรียนรู้แบบเอนเซมเบิลด้วยเทคนิค Stacking (stack) จากการพิจารณาค่า F1 score, recall และ precision โดยผลจากการศึกษาพบว่าตัวแบบ RF และ XGBoost เป็นตัวแบบที่มีค่าประสิทธิภาพสูงที่สุดใกล้เคียงกัน (F1 score = .904, recall = .891, และ precision = .920) นอกจากนี้ความสามารถในการเรียนโดยมีตัวแปรแทนคือคะแนนสอบย่อยเฉลี่ยเป็นปัจจัยที่มีความสำคัญต่อความสำเร็จในการเรียนของนักเรียนมากที่สุด (importance = 153.818) และตัวแปรแทนของความรับผิดชอบในด้านสัดส่วนของการนำหนังสือเข้าชั้นเรียน เป็นปัจจัยที่มีความสำคัญต่อความสำเร็จในการเรียนของนักเรียนน้อยที่สุด (importance = 1.660)

คำสำคัญ: ความสำเร็จในการเรียน, พฤติกรรมในการเรียนของนักเรียน, การเรียนรู้ของเครื่อง

* Corresponding author. E-mail: prapasiri.r@chula.ac.th

¹ ภาควิชาวิจัยและจิตวิทยาการศึกษา คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

² ภาควิชาวิจัยและจิตวิทยาการศึกษา คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

³ ผู้ช่วยศาสตราจารย์ ภาควิชาวิจัยและจิตวิทยาการศึกษา คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

Developing a predictive model for student learning success by applying ensemble learning

Phiriyaphong Ringrod¹, Prapasiri Ratchaprapapornkul^{*2} and Siwachoat Srisuttiyakorn³

Chulalongkorn University, Wang Mai, Pathumwan, Bangkok 10330

Received: 10 June 2024; Revised: 04 October 2024; Accepted: 12 December 2024

Abstract

This research applies ensemble learning, which combines multiple models to analyze student learning. The objectives are: 1) to develop a model for predicting the academic success of 397 M.4 students in the second semester of the academic year 2023 at Srinakharinwirot University Prasarnmit Demonstration School (secondary), who are enrolled in the mathematics course 2(1) M31208. The prediction uses student learning behaviors observable by teacher during learning activities, comprising five aspects of learning behavior: learning ability, responsibility, class participation, diligence, and determination; and 2) to analyze the factors that significantly impact students' academic success. The study compares the performance of five classification models: Elastic-net regularized generalized linear model (GLM), Random Forest (RF), Gradient Boosting with XGBoost (XGBoost), Artificial Neural Network (ANN), and ensemble learning with Stacking (stack), evaluating them using F1 score, recall, and precision. The results indicate that the RF and XGBoost models have the highest performance (F1 score = .904, recall = .891, and precision = .920). Additionally, learning ability, represented by average quiz scores, is identified as the most significant factor for academic success (importance = 153.818), while responsibility, represented by the proportion of bringing books to class, is the least significant factor (importance = 1.660).

Keywords: student learning success, students' learning behaviors, machine learning

* Corresponding author. E-mail: prapasiri.r@chula.ac.th

¹ Department of Educational Research and Psychology, Faculty of Education, Chulalongkorn University

² Department of Educational Research and Psychology, Faculty of Education, Chulalongkorn University

³ Assistant Professor in Department of Educational Research and Psychology, Faculty of Education, Chulalongkorn University

1. บทนำ

การวิเคราะห์การเรียนรู้ (learning analytics) คือ การวัด รวบรวม วิเคราะห์ และรายงานข้อมูลเกี่ยวกับนักเรียน เพื่อช่วยในการทำความเข้าใจสภาพการเรียนรู้ที่เกิดขึ้นและยังเป็นส่วนช่วยในการปรับปรุงผลการเรียนของนักเรียน การวิเคราะห์การเรียนรู้โดยทั่วไปมีการวิเคราะห์ข้อมูลจากหลายแหล่ง เช่น ระบบจัดการการเรียนรู้ และพฤติกรรมการเรียนรู้ของนักเรียน เป็นต้น นอกจากนี้การวิเคราะห์การเรียนรู้ยังมีการใช้โมเดลทำนายเพื่อทำนายผลสัมฤทธิ์ทางการเรียน อัตราการออกกลางคัน หรือความเสี่ยงในการเรียน เป็นต้น ซึ่งการประยุกต์ใช้การวิเคราะห์การเรียนรู้จะช่วยให้ผู้สอนทราบถึงนักเรียนที่ต้องการความช่วยเหลือและสามารถให้การสนับสนุนได้อย่างทันที อีกทั้งยังช่วยสนับสนุนผู้สอนเกี่ยวกับการจัดการเรียนรู้ และการวิเคราะห์การเรียนรู้ยังช่วยให้นักเรียนเข้าใจการเรียนรู้ของตนเองมากยิ่งขึ้น [1, 2]

ผลสัมฤทธิ์ของนักเรียน โดยทั่วไปถูกวัดและประเมินจากคะแนนสอบ คะแนนจากการบ้าน งานที่ได้รับมอบหมาย หรือกิจกรรมการเรียนรู้ที่นักเรียนมีส่วนร่วม รวมทั้งการประเมินจากพฤติกรรมหรือคุณลักษณะอันพึงประสงค์ที่ถูกสังเกตโดยผู้สอนและใช้ประเมินผลเมื่อสิ้นสุดภาคการศึกษา ซึ่งเป็นสิ่งที่บ่งบอกถึงการบรรลุวัตถุประสงค์ทางการเรียนของนักเรียน แต่ไม่สามารถทำให้ผู้สอนทราบถึงข้อมูลเชิงลึกและความต้องการของนักเรียนในระหว่างที่เรียนได้ ทำให้ผู้สอนไม่สามารถจัดการการเรียนรู้และแก้ปัญหาให้นักเรียนได้ทัน [3] ประกอบกับการจัดการเรียนรู้ในชั้นเรียนที่ผู้สอนมีจำนวนนักเรียนที่ต้องรับผิดชอบเป็นจำนวนมาก กล่าวคือผู้สอนหนึ่งคนมีจำนวนนักเรียนในชั้นมัธยมศึกษาตอนปลายที่ต้องดูแลต่อหนึ่งห้องเรียนจำนวนประมาณ 30 คน [4] อีกทั้งในด้านภาระงานของผู้สอนที่เน้นไปในด้านของการทำงานเอกสารหรือการทำงานที่ได้รับมอบหมายอื่น ๆ ของโรงเรียน จึงทำให้ผู้สอนไม่สามารถพัฒนาการจัดการเรียนรู้หรือดูแลนักเรียนเป็นรายบุคคลได้อย่างทั่วถึง ทั้งยังไม่ทราบถึงพฤติกรรมของนักเรียนที่ผู้สอนควรให้ความสนใจเป็นพิเศษก่อนที่นักเรียนจะเกิดปัญหา [5] การนำการวิเคราะห์การเรียนรู้มาประยุกต์ใช้จะช่วยให้ผู้สอนสามารถติดตามดูแลนักเรียน

ได้อย่างต่อเนื่องเพราะผู้สอนต้องเก็บรวบรวมข้อมูลของนักเรียนจากการจัดการเรียนรู้ทั้งทางตรงและทางอ้อมอยู่เสมอ [6]

การทำนายผลสัมฤทธิ์ทางการเรียนของนักเรียนมีบทบาทในการแจ้งเตือนเพื่อให้สามารถดำเนินการในการแก้ไขได้ทันเวลา ประกอบกับยังช่วยให้ผู้สอนสามารถจัดการเรียนรู้ที่ช่วยสนับสนุนนักเรียนให้ประสบผลสำเร็จได้ [7] ซึ่งในปัจจุบันด้วยการพัฒนาของเทคโนโลยีที่ดีขึ้นทำให้การจัดเก็บข้อมูลที่ได้จากชั้นเรียนมีจำนวนมากขึ้น จึงมีการนำการเรียนรู้ของเครื่อง (machine learning) มาใช้ในการสร้างตัวแบบการทำนายความสำเร็จในการเรียนของนักเรียน (predictive model) โดยพิจารณาจากพฤติกรรมการเรียนรู้ของนักเรียน [8] และมีการศึกษาการใช้เทคโนโลยีการเรียนรู้ของเครื่องเพื่อทำนายผลการเรียนของนักเรียนจากคะแนนในแต่ละรายวิชา [9] พบว่าตัวแบบที่พัฒนาขึ้นมีประสิทธิภาพในการทำนายผลการเรียนยังไม่ดีเท่าที่ควรเนื่องจากใช้ข้อมูลจากคะแนนเพียงอย่างเดียวเป็นตัวแปรทำนายอาจไม่เพียงพอต่อการคาดการณ์ผลการเรียนของนักเรียน จึงจำเป็นต้องเพิ่มข้อมูลอื่น ๆ ประกอบ เช่น ข้อมูลการเข้าเรียน ข้อมูลพฤติกรรมการเรียน ความรับผิดชอบของนักเรียน ทักษะและความถนัดในการเรียน เป็นต้น นอกจากนี้มีการศึกษาการใช้คะแนนสอบ รวมกับข้อมูลภูมิหลังและพฤติกรรมการเข้าเรียนของนักเรียนในการทำนายเกรดของนักเรียนผ่านการใช้การเรียนรู้ของเครื่อง [10] ซึ่งพบว่าประสิทธิภาพการทำนายของตัวแบบมีประสิทธิภาพค่อนข้างดี

อัลกอริทึมการเรียนรู้แบบเดี่ยวหรือแบบพื้นฐาน (single classifiers) ที่นิยมใช้ในการสร้างตัวแบบทำนาย คือ Decision Tree, Bayesian Classifier, Neural Network, Support Vector Machine, K-Nearest Neighbor, Logistic Regression และ Linear Regression [11–13] โดยในทางปฏิบัติมักใช้หลาย ๆ อัลกอริทึมเพื่อเปรียบเทียบประสิทธิภาพในการทำนายก่อนเลือกใช้ อัลกอริทึมที่ให้ประสิทธิภาพดีที่สุด นอกจากนี้อัลกอริทึมการเรียนรู้แบบเอนเซมเบิล (ensemble learning) ถูกนำมาใช้เพื่อเพิ่มประสิทธิภาพในการทำนายให้มีประสิทธิภาพที่ดีกว่าเดิม [14–15] ซึ่งอัลกอริทึมการเรียนรู้แบบเอนเซมเบิลนี้

เป็นการเรียนรู้แบบการรวมกลุ่มที่มีการใช้ตัวแบบจำแนก (classifier) มากกว่าหนึ่งตัวในการเรียนรู้ โดยแต่ละตัวมีกระบวนการทำงานของตนเองและทุกตัวกระทำบนชุดข้อมูลเดียวกัน เมื่อได้ผลการจำแนกแล้วจึงนำผลลัพธ์เหล่านั้นมาผ่านกระบวนการรวม (combination หรือ vote) และสุดท้ายนำไปตัดสิน [16]

การศึกษาครั้งนี้จึงมุ่งที่จะประยุกต์ใช้การเรียนรู้แบบเอนเซมเบิลเพื่อวิเคราะห์การเรียนรู้ของนักเรียน โดยมีวัตถุประสงค์ 1) พัฒนาตัวแบบทำนายความสำเร็จในการเรียนของนักเรียนชั้นมัธยมศึกษาปีที่ 4 ภาคเรียนที่ 2 ปีการศึกษา 2566 โรงเรียนสาธิตมหาวิทยาลัยศรีนครินทรวิโรฒ ประสานมิตร (ฝ่ายมัธยม) ที่เรียนในรายวิชาคณิตศาสตร์เพิ่มเติม 2(1) ค31208 โดยใช้พฤติกรรมในการเรียนของนักเรียนซึ่งเป็นพฤติกรรมที่ผู้สอนสามารถเก็บรวบรวมและสังเกตได้จากการจัดกิจกรรมการเรียนรู้เป็นตัวแปรทำนาย และ 2) วิเคราะห์ตัวแปรที่มีความสำคัญต่อความสำเร็จในการเรียนของนักเรียน

2. การทบทวนวรรณกรรม

2.1 การเรียนรู้ของเครื่อง

การเรียนรู้ของเครื่องเป็นวิธีที่ทำให้คอมพิวเตอร์มีความสามารถในการเรียนรู้โดยไม่ต้องมีการเขียนโปรแกรมไว้อย่างชัดเจน กล่าวคือ การเรียนรู้ของเครื่องเป็นการเรียนรู้จากข้อมูลที่มีอยู่ [17] โดยพื้นฐานการเรียนรู้ของเครื่องสามารถแบ่งได้ 3 ประเภท ได้แก่ การเรียนรู้โดยมีผู้สอน (supervised learning) การเรียนรู้โดยไม่มีผู้สอน (unsupervised learning) และการเรียนรู้แบบเสริมกำลัง (reinforcement learning) [18] โดยในบทความนี้ผู้วิจัยจะกล่าวถึงการเรียนรู้โดยมีผู้สอนเท่านั้น ซึ่งการเรียนรู้โดยมีผู้สอน เป็นรูปแบบการเรียนรู้ที่ชุดข้อมูลฝึกหัด (training dataset) มีป้ายกำกับลักษณะของข้อมูลนั้น ๆ [19] ประกอบด้วย Elastic-net regularized generalized linear model (GLM), Random Forest (RF), Gradient Boosting with XGBoost (XGBoost), Artificial Neural Network (ANN) และการเรียนรู้แบบเอนเซมเบิล (ensemble learning) ด้วยเทคนิค Stacking (stack)

2.1.1 Elastic-net regularized generalized linear model เป็นเทคนิคที่รวมการถดถอยเชิงเส้นแบบ ridge (ridge regression) และ lasso (lasso regression) เข้าด้วยกัน เพื่อปรับปรุงความแม่นยำในการทำนายเมื่อเปรียบเทียบกับการใช้วิธีกำลังสองน้อยที่สุด (ordinary least squares) กล่าวคือมีการใช้ทั้ง L1 penalty และ L2 penalty ในการสร้างตัวแบบทำนายที่สามารถหลีกเลี่ยงหรือลดทอนผลกระทบที่เกิดจากปัญหาความสัมพันธ์ระหว่างตัวแปร (multicollinearity) อีกทั้งยังสามารถคัดเลือกตัวแปรอิสระเข้าสู่ตัวแบบได้ด้วย [20–21]

2.1.2 Random Forest เป็นเทคนิคการเรียนรู้แบบเอนเซมเบิลชนิดหนึ่ง [22] ที่มีประสิทธิภาพอย่างมากสำหรับปัญหาการจำแนกประเภท (classification) และการถดถอย (regression) ซึ่งเป็นวิธีการที่รวมต้นไม้ตัดสินใจที่สุ่ม (randomized decision trees) หลาย ๆ ต้นเข้าด้วยกัน จากนั้นรวมผลของค่าทำนายในแต่ละต้นด้วยค่าเฉลี่ย โดยเทคนิคนี้เป็นเทคนิคที่สามารถทำงานได้ดีในสถานการณ์ที่จำนวนตัวแปรมากกว่าจำนวนค่าสังเกตหรือใช้ในงานที่มีข้อมูลขนาดใหญ่ได้ด้วย อีกทั้งยังใช้ในการหาตัวแปรที่มีผลต่อค่าทำนายได้ (variable importance) [23]

2.1.3 Gradient Boosting with XGBoost (XGBoost) เป็นเทคนิคการเรียนรู้แบบเอนเซมเบิล กล่าวคือเป็นการใช้การเรียนรู้ของต้นไม้ตัดสินใจ (decision trees) หลาย ๆ ตัวแบบมาต่อกัน เพื่อสร้างตัวแบบที่มีประสิทธิภาพ โดยนำค่าผิดพลาดที่เกิดขึ้นจากตัวแบบก่อนหน้ามาปรับปรุงในการสร้างตัวแบบถัดไป ซึ่งการทำเช่นนี้ทำให้ได้ตัวแบบที่มีความแม่นยำและเสถียรมากขึ้น ซึ่งตัวแบบจะถูกสร้างขึ้นจนกระทั่งไม่สามารถเพิ่มประสิทธิภาพของตัวแบบได้อีก [24]

2.1.4 Artificial Neural Network (ANN) เป็นเทคนิคที่ได้รับแรงบันดาลใจมาจากสมองของสิ่งมีชีวิต ซึ่งประกอบด้วยหน่วยเดี่ยว (single unit) หลายร้อยหน่วย และเซลล์ประสาทเทียม (artificial neuron) ซึ่งเชื่อมต่อกันด้วยค่าสัมประสิทธิ์ (weight) ที่ประกอบกันเป็นโครงสร้างประสาท สิ่งเหล่านี้เรียกว่าองค์ประกอบการประมวลผล (processing elements) โดยองค์ประกอบการประมวลผล

แต่ละอันประกอบด้วยค่าสัมประสิทธิ์ของการนำเข้า ฟังก์ชันการถ่ายโอน (transfer function) และผลลัพธ์ [25]

2.1.5 การเรียนรู้แบบเอนเซมเบิล (ensemble learning) ด้วยเทคนิค Stacking เป็นเทคนิคการเรียนรู้ที่รวมตัวแบบการเรียนรู้แบบเดี่ยวที่ได้รับการปรับแต่งไฮเปอร์พารามิเตอร์ที่แตกต่างกันหลากหลายตัวแบบ (heterogeneous models) ซึ่งต่างกับเทคนิค bagging หรือ boosting ที่ใช้ตัวแบบเดียวกัน (homogeneous models) เพื่อวัตถุประสงค์ที่ให้ค่าทำนายที่ถูกต้องกว่าค่าทำนายที่ได้จากตัวแบบการเรียนรู้แบบเดี่ยว โดยผลลัพธ์ของตัวแบบจะถูกรวมโดยใช้ meta-classifier ซึ่งปัญหาของการใช้เทคนิค Stacking คือการรวมกันของตัวแบบกับ meta-classifier ที่เหมาะสม ซึ่งปัญหานี้หากใช้จำนวนอัลกอริทึมไม่มากจะสามารถแก้ไขได้โดยง่าย แต่อย่างไรก็ตามเมื่อจำนวนอัลกอริทึมมากขึ้นการกำหนดค่าที่เหมาะสมจะทำได้ยาก [26]

2.2 พฤติกรรมการเรียนรู้ของนักเรียนและผลสัมฤทธิ์ทางการเรียน

ผลสัมฤทธิ์ทางการเรียน คือ ความสำเร็จหรือความก้าวหน้าที่เกิดจากการเรียนรู้ การพัฒนาทักษะของนักเรียนหรือผลจากการกระทำของนักเรียน ซึ่งเป็นการเปลี่ยนแปลงที่ได้จากประสบการณ์ผ่านการเรียนรู้ด้วยตนเองหรือจากการเรียนรู้ในชั้นเรียน ที่สามารถวัดได้จากการทดสอบหรือการประเมินของผู้สอน [27]

จากการศึกษาพบว่า มีหลายปัจจัยที่ส่งผลต่อผลสัมฤทธิ์ทางการเรียนของนักเรียน เช่น พฤติกรรมการเรียนรู้ของนักเรียน ซึ่งหมายถึง พฤติกรรมที่แสดงออกอย่างสม่ำเสมอ แสดงถึงความพอใจและมุ่งมั่นที่จะศึกษาหาความรู้ให้บรรลุผล พฤติกรรมดังกล่าวอาจพิจารณาจากความตั้งใจ ความเอาใจใส่ในการเรียน ความมุ่งมั่นที่จะแสวงหาความรู้ และพัฒนาด้านตนเองโดยไม่ย่อท้อต่ออุปสรรค มีความคิดริเริ่ม ขยัน อดทน รับผิดชอบพึ่งตนเอง และมีความภาคภูมิใจในผลการเรียนของตนเอง [28] โดยพบว่า มีพฤติกรรมหลายอย่างที่เป็นปัจจัยที่ส่งผลต่อผลสัมฤทธิ์ทางการเรียนของนักเรียน เช่น คะแนนสอบของนักเรียน [9] ความขยันหมั่นเพียร ความเป็นระเบียบ

ซึ่งเป็นความถี่และความสม่ำเสมอในการปฏิบัติกิจกรรมการเรียนรู้ต่าง ๆ โดยนักเรียนที่มีความขยันมากจะยังมีอันดับของผลการเรียนที่ดีขึ้น อีกทั้งหากมีระเบียบวินัยมากจะยังมีผลการเรียนที่ดีขึ้นด้วย [29] การมีส่วนร่วมในชั้นเรียน ซึ่งเป็นพฤติกรรมที่มีส่วนร่วมทั้งทางพฤติกรรมและจิตใจของนักเรียนในกิจกรรมการเรียนรู้ โดยวัดจากความตั้งใจเรียนในชั้นเรียน การตอบคำถามในชั้นเรียน การมีปฏิสัมพันธ์กับผู้สอน หรือการมีส่วนร่วมในการอภิปรายในชั้นเรียน โดยนักเรียนที่มีส่วนร่วมในชั้นเรียนไม่ว่าจะเป็นนักเรียนคนใดก็ตามซึ่งไม่จำกัดเพศและเชื้อชาติ พบว่าการมีส่วนร่วมในชั้นเรียนมีผลเชิงบวกต่อผลสัมฤทธิ์ทางการเรียนของนักเรียน [30] และความมุ่งมั่นตั้งใจในการเรียนของนักเรียน ซึ่งเป็นความพยายามในการทำสิ่งต่าง ๆ โดยไม่ย่อท้อต่ออุปสรรคและมีความกระตือรือร้นต่องานที่ได้รับมอบหมาย โดยนักเรียนที่มีความมุ่งมั่นตั้งใจเรียนจะมีผลการเรียนที่ดีกว่านักเรียนที่มีความมุ่งมั่นตั้งใจเรียนน้อยกว่า อีกทั้งความมุ่งมั่นตั้งใจในการเรียนยังสามารถใช้เป็นตัวแปรในการทำนายผลสัมฤทธิ์ทางการเรียนของนักเรียนได้ [31] เป็นต้น นอกจากนี้ในปัจจัยด้านอื่น ๆ เช่น เพศของนักเรียนซึ่งเพศที่แตกต่างกันของนักเรียนส่งผลต่อผลสัมฤทธิ์ทางการเรียนของนักเรียนต่างกันโดยนักเรียนเพศหญิงมีผลสัมฤทธิ์ทางการเรียนที่สูงกว่านักเรียนเพศชายในด้านความสามารถทางภาษา [32] แต่ในด้านการเรียนในรายวิชาคณิตศาสตร์กลับพบว่านักเรียนเพศชายมีผลสัมฤทธิ์ทางการเรียนในรายวิชาคณิตศาสตร์สูงกว่านักเรียนเพศหญิงโดยเฉพาะในระดับมัธยมศึกษาและอุดมศึกษา [33] ปัจจัยด้านความสัมพันธ์ในครอบครัว ซึ่งครอบครัวที่ผู้ปกครองเอาใจใส่และสนับสนุนในเรื่องการเรียนรู้ของนักเรียน ส่งเสริมนักเรียนอย่างเต็มความสามารถ คอยให้กำลังใจ และเชื่อมั่นในตัวนักเรียนเป็นปัจจัยที่ส่งผลเชิงบวกต่อผลสัมฤทธิ์ทางการเรียนของนักเรียน ในปัจจัยด้านผู้สอน ถ้าผู้สอนมีวิธีการสอนที่เหมาะสมกับนักเรียน จะทำให้นักเรียนเข้าใจบทเรียนได้ดียิ่งขึ้น โดยหากผู้สอนมีการจัดเตรียมสื่อการเรียนรู้ที่เหมาะสมกับเนื้อหาหรือสื่อที่มีความทันสมัยที่นักเรียนเข้าถึงได้จะช่วยส่งเสริมผลสัมฤทธิ์ทางการเรียนของนักเรียนได้ดียิ่งขึ้นด้วยหรือปัจจัยด้านความรู้พื้นฐานของนักเรียน

ก็เป็นปัจจัยที่ส่งผลต่อผลสัมฤทธิ์ทางการเรียนของนักเรียน กล่าวคือความรู้พื้นฐานเดิมของนักเรียนจะมีผลต่อความเข้าใจ ความชอบ หรือความสนใจในรายวิชานั้น ๆ ส่งผลให้นักเรียนมีแรงจูงใจและตั้งใจเรียน จึงทำให้ผลสัมฤทธิ์ทางการเรียนของนักเรียนดีขึ้น [34]

อีกทั้งยังพบว่าปัจจัยหรือตัวแปรทำนายที่นำมาใช้ในการทำนายผลการเรียนของนักเรียนโดยทั่วไปจะเป็นปัจจัยหรือตัวแปรที่สามารถพัฒนาและปรับปรุงได้ เช่น คะแนนสอบของนักเรียน [35] การมีส่วนร่วมในชั้นเรียนและการทำงานที่ได้รับมอบหมาย [36] เป็นต้น การศึกษาครั้งนี้จึงเลือกใช้ตัวแปรทำนายซึ่งเป็นพฤติกรรมในการเรียนของนักเรียนที่ผู้สอนสามารถเก็บรวมและสังเกตได้ รวมทั้งยังเป็นพฤติกรรมที่นักเรียนสามารถปรับปรุงและพัฒนาได้ มาทำนายความสำเร็จในการเรียนของนักเรียน

3. วิธีดำเนินการวิจัย

3.1 การเก็บรวบรวมข้อมูลและการเตรียมข้อมูล

ในการวิจัยครั้งนี้มีตัวแปรตามคือ ความสำเร็จในการเรียนของนักเรียน โดยใช้การแปลงผลการเรียนวิชา

คณิตศาสตร์เพิ่มเติมของนักเรียนแต่ละคนเป็นตัวแปรจัดประเภท 3 กลุ่มได้แก่

1) **กลุ่มตก** หมายถึง นักเรียนมีผลการเรียนไม่เกิน 1.5

2) **กลุ่มผ่าน** หมายถึงนักเรียนมีผลการเรียนสูงกว่า 1.5 แต่น้อยกว่า 3.5

3) **กลุ่มสำเร็จ** หมายถึง นักเรียนมีผลการเรียนตั้งแต่ 3.5 ขึ้นไป

และมีตัวแปรอิสระหรือตัวแปรทำนายคือ ตัวแปรแทน (proxy variable) ของพฤติกรรมในการเรียนของนักเรียน โดยแบ่งพฤติกรรมในชั้นเรียนของนักเรียนออกเป็น 5 ด้าน ได้แก่ 1) ความสามารถในการเรียนของนักเรียน 2) ความรับผิดชอบ 3) การมีส่วนร่วมในชั้นเรียน 4) ความขยันหมั่นเพียร และ 5) ความมุ่งมั่นตั้งใจ โดยตัวอย่างในการศึกษาครั้งนี้จะเก็บข้อมูลจากนักเรียนชั้นมัธยมศึกษาปีที่ 4 ภาคเรียนที่ 2 ปีการศึกษา 2566 โรงเรียนสาธิตมหาวิทยาลัยศรีนครินทรวิโรฒ ประสานมิตร (ฝ่ายมัธยม) ที่เรียนในรายวิชาคณิตศาสตร์เพิ่มเติม 2(1) ค31208 จำนวน 397 คน สำหรับคำอธิบายของตัวแปรแทนพฤติกรรมในการเรียนของนักเรียนแสดงในตารางที่ 1

ตารางที่ 1 ตัวแปรแทนพฤติกรรมในการเรียนของนักเรียน

พฤติกรรมในการเรียน ของนักเรียน	ตัวแปรแทน	คำอธิบาย
ความสามารถ ในการเรียน	1) คะแนนสอบย่อยเฉลี่ย	คะแนนเฉลี่ยที่ได้จากผลการสอบทำยบทเรียนของนักเรียน
ความรับผิดชอบ	1) สัดส่วนของการเข้าเรียนตรงต่อเวลา	จำนวนครั้งที่เข้าเรียนตรงต่อเวลาเทียบกับจำนวนครั้งที่เข้าเรียนทั้งหมด
	2) สัดส่วนของการนำหนังสือเข้าชั้นเรียน	จำนวนครั้งของการนำหนังสือมาเรียนในคาบเรียนเทียบกับจำนวนครั้งที่เข้าเรียนทั้งหมด
	3) สัดส่วนของการส่งงานตรงต่อเวลา	จำนวนครั้งของการส่งงานตรงต่อเวลาเทียบกับจำนวนงานที่ได้รับมอบหมายทั้งหมด
	4) สัดส่วนของการทำงานสำเร็จ	จำนวนครั้งของการทำงานที่ได้รับมอบหมายอย่างครบถ้วนและสมบูรณ์เทียบกับจำนวนงานที่ได้รับมอบหมายทั้งหมด
การมีส่วนร่วม ในชั้นเรียน	1) สัดส่วนของการตอบคำถามในชั้นเรียน	จำนวนครั้งของการตอบคำถามของนักเรียนเทียบกับจำนวนครั้งที่มีการถามคำถามในชั้นเรียนทั้งหมด

ตารางที่ 1 ตัวแปรแทนพฤติกรรมในการเรียนของนักเรียน (ต่อ)

พฤติกรรมในการเรียน ของนักเรียน	ตัวแปรแทน	คำอธิบาย
	2) ความล่าช้าในการตอบคำถาม ในชั้นเรียน (นาทิจ)	ระยะเวลาเฉลี่ยของการเข้าสู่ระบบตอบคำถามในชั้นเรียน หลังจากได้รับคำถาม
	3) เวลาที่ใช้ตอบคำถาม ในชั้นเรียน (นาทิจ)	ระยะเวลาเฉลี่ยที่ใช้ตั้งแต่เข้าสู่ระบบตอบคำถามจนถึงเวลา ส่งคำตอบ
	4) สัดส่วนของการตอบคำถาม ในชั้นเรียนถูกต้อง	จำนวนครั้งที่นักเรียนตอบถูกเทียบกับจำนวนครั้งที่ ตอบคำถามทั้งหมด
ความขยันหมั่นเพียร	1) สัดส่วนของการเข้าชั้นเรียน	จำนวนครั้งของการเข้าชั้นเรียนเทียบกับจำนวนคาบเรียน ทั้งหมด
	2) การทำแบบฝึกหัดเพิ่มเติม	ความถี่ของการทำแบบฝึกหัดที่ได้รับมอบหมายเพิ่มเติม (ทุกครั้ง, บางครั้ง, ไม่ทำเลย)
ความมุ่งมั่นตั้งใจ	1) สัดส่วนของการออกนอก ห้องเรียน	จำนวนครั้งของการออกนอกห้องเรียนขณะเรียนเทียบกับ จำนวนครั้งที่เข้าเรียนทั้งหมด
	2) ระยะเวลาทำงานเฉลี่ย (นาทิจ)	ระยะเวลาเฉลี่ยตั้งแต่การเข้าสู่ระบบการทำงาน ที่ได้รับมอบหมายจนถึงเวลาที่ส่งงาน
	3) สัดส่วนของการเริ่มทำงาน เฉลี่ย	ค่าเฉลี่ยของสัดส่วนระหว่างเวลาที่เข้าสู่ระบบการทำงาน ที่ได้รับมอบหมายต่อระยะเวลาในการทำงาน ที่ได้รับมอบหมายทั้งหมดที่กำหนดโดยผู้สอน

ในการเตรียมข้อมูล จะแบ่งชุดข้อมูลฝึกหัดออกเป็น 2 ส่วน ได้แก่ training data และ test data ด้วยอัตราส่วน 70 : 30 หลังจากสำรวจข้อมูลเบื้องต้นพบว่าตัวแปรสัดส่วน การเริ่มทำงานเฉลี่ยและระยะเวลาทำงานเฉลี่ยมีค่าสูญหาย จึงดำเนินการแก้ปัญหาค่าสูญหายด้วยการทดแทนค่าสูญหาย (missing value imputation) โดยใช้ bootstrap aggregating trees imputation technique ผ่านแพ็คเกจ recipes และพบว่าการกระจายของตัวแปรต่อเนื่องหลายตัว มีลักษณะไม่สมมาตรจึงดำเนินการแปลงค่าของตัวแปรให้มีการแจกแจงที่สมมาตร โดยใช้ ordered quantile normalization technique ผ่านแพ็คเกจ bestNormalize และเมื่อพิจารณาถึงตัวแปรความสำเร็จในการเรียน ของนักเรียนซึ่งเป็นตัวแปรจัดประเภท พบว่ามีปัญหาความไม่ สมดุลของข้อมูล โดยมีอัตราส่วน กลุ่มตก : กลุ่มผ่าน : กลุ่มสำเร็จ เท่ากับ 190 : 143 : 54 หลังจากแปลงค่าตัวแปร จัดประเภทให้เป็น ตัวแปรหุ่น (dummy variable)

ผ่านแพ็คเกจ recipes ได้ดำเนินการแก้ปัญหาความไม่สมดุล ของข้อมูล โดยใช้ Synthetic Minority Oversampling Technique (SMOTE) ผ่านแพ็คเกจ themis เมื่อแก้ปัญหา ความไม่สมดุลของข้อมูลเรียบร้อยแล้วพบว่า อัตราส่วนของ กลุ่มตก : กลุ่มผ่าน : กลุ่มสำเร็จ เท่ากับ 190 : 190 : 190

3.2 ตัวแบบในการทำนายความสำเร็จในการเรียน ของนักเรียน

ในการศึกษาครั้งนี้ได้ใช้อัลกอริทึมทั้งหมด 5 อัลกอริทึม ได้แก่ GLM, RF, XGBoost, ANN และ stack เพื่อทำนายความสำเร็จในการเรียนของนักเรียน โดย stack เป็นการรวมตัวแบบทั้ง 4 ด้วยแพ็คเกจ stacks

3.3 การสร้างตัวแบบ

ผู้วิจัยดำเนินการสร้างตัวแบบในการทำนาย ความสำเร็จในการเรียนของนักเรียน ผ่านแพ็คเกจ tidymodels โดยมีการกำหนด model engine ของตัวแบบ

GLM, RF, XGBoost และ ANN เป็น glmnet, ranger, xgboost และ nnet ตามลำดับ จากนั้นกำหนด mode ของทุกตัวแบบเป็น classification

สำหรับการปรับแต่งไฮเปอร์พารามิเตอร์จะกำหนดเซตของจำนวนที่ใช้ในการปรับแต่งไฮเปอร์พารามิเตอร์เท่ากับ 30 เซต ซึ่งได้จากการกำหนด 10-Fold Cross-Validation และกำหนดจำนวนครั้งของการแบ่งชุดข้อมูลออกเป็นชุดย่อย ๆ อีกจำนวน 3 ครั้ง (repeats = 3) และกำหนดจำนวนชุดไฮเปอร์พารามิเตอร์ที่ใช้ในการพัฒนาตัวแบบทั้งหมด 15 ชุด (grid = 15) จากการสุ่มตัวอย่างด้วย Latin Hypercube grid search โดยกำหนดการปรับแต่งไฮเปอร์พารามิเตอร์ของแต่ละตัวแบบดังตารางที่ 2

ทั้งนี้ ผู้วิจัยกำหนดให้ปรับแต่งไฮเปอร์พารามิเตอร์ทุกตัวของทุกตัวแบบ ยกเว้น trees (trees) ซึ่งเป็นไฮเปอร์พารามิเตอร์ของตัวแบบ RF กับ XGBoost โดยกำหนดให้มีค่าเป็น 1,000 และ iterations before stopping (stop_iter) ซึ่งเป็นไฮเปอร์พารามิเตอร์ของตัวแบบ XGBoost กำหนดให้มีค่าเป็น 10

3.4 การเปรียบเทียบตัวแบบ

การเปรียบเทียบประสิทธิภาพของตัวแบบกับข้อมูลชุด test data จะพิจารณาจากค่า F1 score, recall และ precision โดยผลที่ได้จากการเปรียบเทียบประสิทธิภาพในการทำนายของตัวแบบหลังการปรับแต่งไฮเปอร์พารามิเตอร์กับข้อมูลชุด test data เป็นดังรูปที่ 1 และ 2


จากรูปที่ 1 ประสิทธิภาพการทำนายของตัวแบบในการทำนายความสำเร็จในการเรียนของนักเรียนกลุ่มนี้ในภาพรวมพบว่าตัวแบบ RF และ XGboost เป็นตัวแบบ

ที่มีค่าประสิทธิภาพสูงที่สุดและใกล้เคียงกัน (F1 score = .904, recall = .891, และ precision = .920)


จากรูปที่ 2 ประสิทธิภาพของตัวแบบในการทำนายความสำเร็จในการเรียนของนักเรียนกลุ่มนี้จำแนกรายกลุ่มเมื่อพิจารณาค่า F1 score, recall และ precision พบว่าตัวแบบ RF และ XGBoost มีค่า F1 score, recall และ precision ใกล้เคียงกัน อีกทั้งยังมีค่าสูงกว่าตัวแบบอื่น ๆ เป็นส่วนใหญ่

ตารางที่ 2 การปรับแต่งไฮเปอร์พารามิเตอร์


ตัวแบบ	ไฮเปอร์พารามิเตอร์	
GLM	penalty	ปรับแต่ง
	mixture	ปรับแต่ง
RF	mtry	ปรับแต่ง
	trees	1,000
	min_n	ปรับแต่ง
XGBoost	tree_depth	ปรับแต่ง
	trees	1,000
	learn_rate	ปรับแต่ง
	mtry	ปรับแต่ง
	loss_reduction	ปรับแต่ง
	sample_size	ปรับแต่ง
	stop_iter	10
ANN	hidden_units	ปรับแต่ง
	penalty	ปรับแต่ง
	epochs	ปรับแต่ง



รูปที่ 1 ประสิทธิภาพการทำนายของตัวแบบในภาพรวม



รูปที่ 2 ประสิทธิภาพการทำนายของตัวแบบจำแนกรายกลุ่ม



รูปที่ 3 Feature Importance

3.5 การวิเคราะห์ปัจจัยที่มีความสำคัญต่อความสำเร็จในการเรียนของนักเรียน

จากรูปที่ 3 พบว่า คะแนนสอบย่อยเฉลี่ยเป็นปัจจัยที่มีความสำคัญต่อความสำเร็จมากที่สุด (importance = 153.818) และปัจจัยอื่น 3 อันดับแรก ได้แก่ สัดส่วนของการตอบคำถามในชั้นเรียน (importance = 16.773) สัดส่วนของการเข้าชั้นเรียน (importance = 16.279) และระยะเวลาทำงานเฉลี่ย (importance = 9.910) เป็นปัจจัย

ที่มีความสำคัญต่อความสำเร็จรองลงมาตามลำดับ นอกเหนือจากปัจจัยที่กล่าวไปข้างต้น จะพบว่าสัดส่วนของการนำหนังสือเข้าชั้นเรียน (importance = 1.660) เป็นปัจจัยที่มีความสำคัญต่อความสำเร็จน้อยที่สุด

4. สรุปและอภิปรายผล

จากการพัฒนาตัวแบบทำนายความสำเร็จในการเรียนของนักเรียน พบว่าตัวแบบประเภทเอนเซมเบิล

มีประสิทธิภาพสูงกว่าตัวแบบการเรียนรู้แบบเดี่ยว โดยที่ RF และ XGBoost เป็นตัวแบบที่มีประสิทธิภาพสูงที่สุด ซึ่งสูงกว่า stack อันเนื่องมาจากความซับซ้อนของการปรับแต่งไฮเปอร์พารามิเตอร์ที่ RF กับ XGBoost สามารถทำได้ง่ายกว่า stack จึงทำให้ stack มีประสิทธิภาพต่ำกว่า สำหรับ GLM และ ANN เป็นตัวแบบที่มีประสิทธิภาพต่ำกว่าทั้ง 3 ตัวแบบข้างต้น เนื่องจากเป็นตัวแบบการเรียนรู้แบบเดี่ยว ประกอบกับความสัมพันธ์ระหว่างตัวแปรต้นกับตัวแปรตามของข้อมูลที่สามารถส่งผลให้ GLM มีประสิทธิภาพต่ำกว่า อีกทั้งจำนวนข้อมูลซึ่งส่งผลต่อประสิทธิภาพของ ANN ก็เป็นสิ่งที่ทำให้ตัวแบบนี้มีประสิทธิภาพต่ำกว่า

จากการวิเคราะห์ปัจจัยที่ความสำคัญต่อความสำเร็จในการเรียนของนักเรียนซึ่งพบว่าคะแนนสอบย่อยเฉลี่ยเป็นปัจจัยที่มีความสำคัญต่อความสำเร็จของนักเรียนมากที่สุด เนื่องจากคะแนนสอบย่อยเฉลี่ยได้มาจากค่าเฉลี่ยของคะแนนสอบท้ายบทเรียนแต่ละบท ซึ่งนักเรียนที่มีความเข้าใจในบทเรียนแต่ละบท จะมีคะแนนสอบที่สูงและจะทำให้สามารถทำคะแนนสอบกลางภาคและปลายภาคได้ดีด้วย คะแนนสอบย่อยเฉลี่ยจึงเป็นปัจจัยที่สำคัญที่สามารถระบุได้ว่านักเรียนคนนั้นจะสำเร็จหรือไม่ และสัดส่วนของการตอบคำถามในชั้นเรียนกับสัดส่วนของการเข้าชั้นเรียน เป็นปัจจัยที่มีความสำคัญต่อความสำเร็จของนักเรียนรองลงมา เนื่องจากการเข้าเรียนของนักเรียนจะทำให้นักเรียนได้เรียนรู้เนื้อหาหรือจุดเน้นต่าง ๆ จากผู้สอน ประกอบกับการมีส่วนร่วมในชั้นเรียนของนักเรียนยังเป็นเรื่องที่บ่งบอกถึงการมีสมาธิอยู่กับการเรียนตลอดเวลา แต่หากนักเรียนไม่เข้าเรียนหรือไม่มีส่วนร่วมในชั้นเรียนก็อาจทำให้นักเรียนไม่สามารถติดตามเนื้อหาที่เรียนได้อย่างต่อเนื่องหรือไม่ได้จดจ่ออยู่กับการเรียนเท่าที่ควร นอกเหนือจากปัจจัยดังกล่าวข้างต้นยังพบว่าสัดส่วนของการเข้าเรียนตรงเวลาและการทำแบบฝึกหัดเพิ่มเติมเป็นปัจจัยที่มีความสำคัญต่อความสำเร็จในการเรียนของนักเรียนด้วยแต่มีความสำคัญในลำดับท้าย ๆ เนื่องจากระยะเวลาที่นักเรียนเข้าห้องเรียนสายมักจะน้อยและไม่มากนักเรียนจำนวนน้อยที่เข้าห้องเรียนสาย อีกทั้งหากนักเรียนเข้าเรียนหลังจากที่การสอนเริ่มไปแล้ว นักเรียนยังสามารถดูคลิปวิดีโอที่ทางโรงเรียน

มีการจัดเตรียมไว้เพื่อช่วยให้นักเรียนติดตามเนื้อหาได้อย่างต่อเนื่อง ส่วนการทำแบบฝึกหัดเพิ่มเติม แม้ว่าจะช่วยพัฒนาผลการเรียนของนักเรียนหากมีการมอบหมายในปริมาณที่ไม่มากต่อครั้งแต่มอบหมายอย่างบ่อยครั้ง [37] ในทางกลับกันมีการมอบหมายงานที่เน้นปริมาณและใช้เวลาในการทำที่มากซึ่งส่งเสริมให้นักเรียนได้เกิดการฝึกฝนและทบทวนได้ไม่มาก จึงทำให้ปัจจัยทั้งสองนี้มีความสำคัญต่อความสำเร็จของนักเรียนที่น้อย อีกทั้งสัดส่วนของการทำงานสำเร็จและสัดส่วนของการส่งงานตรงต่อเวลา ซึ่งมีความสำคัญต่อความสำเร็จในการเรียนในระดับที่ค่อนข้างน้อย เมื่อเทียบกับคะแนนสอบย่อยเฉลี่ย เนื่องจากการทำงานที่เน้นปริมาณที่มากมักเป็นส่วนหนึ่งของคะแนนช่วยที่ผู้สอนแต่ละท่านใช้ประเมิน จึงทำให้ปัจจัยทั้งสองนี้จึงไม่ใช่ปัจจัยหลักที่มีความสำคัญต่อความสำเร็จของนักเรียน สำหรับสัดส่วนของการนำหนังสือเข้าชั้นเรียนซึ่งเป็นปัจจัยที่มีความสำคัญต่อความสำเร็จในการเรียนของนักเรียนน้อยที่สุด เนื่องจากห้องเรียนในปัจจุบันหากนักเรียนไม่ได้นำหนังสือเข้ามาเรียนนักเรียนสามารถใช้แท็บเล็ตหรืออุปกรณ์อื่น ๆ แทนการใช้หนังสือเรียนได้

5. ข้อเสนอแนะ

ผู้สอนควรจัดการเรียนรู้ที่มีการทดสอบย่อยระหว่างบทเรียน นอกจากนี้ผู้สอนควรพิจารณาเกี่ยวกับปริมาณงานที่มอบหมายหรือการบ้านให้มีความเหมาะสมกับระยะเวลาและเนื้อหา ทั้งนี้เพื่อให้สามารถติดตามความก้าวหน้าของนักเรียนได้อย่างมีประสิทธิภาพ อีกทั้งยังช่วยให้ผู้สอนได้รับข้อมูลที่จำเป็นในการปรับปรุงและพัฒนากระบวนการจัดการเรียนรู้ ประกอบกับเป็นการส่งเสริมให้นักเรียนได้ทบทวนอย่างต่อเนื่อง ซึ่งจะทำให้นักเรียนมีผลการเรียนที่ดีขึ้นและประสบความสำเร็จในการเรียนรู้ในระยะยาวได้

6. กิตติกรรมประกาศ

ขอขอบคุณผู้สอนชั้นมัธยมศึกษาปีที่ 4 ภาคเรียนที่ 2 ปีการศึกษา 2566 โรงเรียนสาธิตมหาวิทยาลัยศรีนครินทรวิโรฒ ประสานมิตร (ฝ่ายมัธยม) ซึ่งเป็นผู้สอน

ในรายวิชาคณิตศาสตร์เพิ่มเติม 2(1) ค31208 และช่วย
ดำเนินการเก็บรวบรวมข้อมูลของนักเรียน

7. เอกสารอ้างอิง

- [1] B. Dietz and J. E. Hurn, "Using learning analytics to predict (and improve) student success: A faculty perspective," *Journal of Interactive Online Learning*, vol. 12, pp. 17-26, 01/01 2013.
- [2] R. Hasan, S. Palaniappan, S. Mahmood, A. Abbas, K. U. Sarker, and M. U. Sattar, "Predicting student performance in higher education institutions using video learning analytics and data mining techniques," *Applied Sciences*, vol. 10, no. 11, p. 3894, 2020. [Online]. Available: <https://www.mdpi.com/2076-3417/10/11/3894>. [Accessed 19 May 2024].
- [3] A. Breen, "Q&A: Why classroom-level data is a powerful tool for teachers," [Online]. Available: <https://education.virginia.edu/news-stories/qa-why-classroom-level-data-powerful-tool-teachers>. [Accessed 26 May 2024].
- [4] สำนักงานคณะกรรมการการศึกษาขั้นพื้นฐาน. "ข้อมูลทางการศึกษา ประจำปี 2567." [ออนไลน์] http://www.bopp.go.th/?page_id=1828. [วันที่เข้าถึง 1 ตุลาคม 2567].
- [5] KKP Research, "ทำไมคุณภาพการศึกษาไทย แย่ลงทุกปี ?," *เกียรตินาคินภัทร*, 12 ธ.ค. 2566. [ออนไลน์]. <https://advicecenter.kkpfg.com/th/kkp-research/thai-education-quality>. [วันที่เข้าถึง 1 ต.ค. 2567].
- [6] FeedbackFruits, "How learning analytics can improve student success: Best strategies," FeedbackFruits Blog. [online] . <https://feedbackfruits.com/blog/leverage-learning-analytics-for-strategic-decisions-and-student-success>. [Accessed 1 October 2024].
- [7] C. Liu, H. Wang, Y. Du, and Z. Yuan, "A predictive model for student achievement using spiking neural networks based on educational data," *Applied Sciences*, vol. 12, no. 8, pp. 1–20, 2022.
- [8] X. Li, Y. Zhang, H. Cheng, M. Li, and B. Yin, "Student achievement prediction using deep neural network from multi-source campus data," *Complex & Intelligent Systems*, vol. 8, no. 6, pp. 5143–5156, 2022.
- [9] ขวัญตา ศิลป์บุญญพานิช, "การใช้เทคโนโลยีการเรียนรู้ของเครื่อง เพื่อทำนายผลการเรียนของนักเรียน," *วิทยาศาสตร์มหาบัณฑิต, สาขาวิชาเทคโนโลยีสารสนเทศ, มหาวิทยาลัยศรีนครินทรวิโรฒ, กรุงเทพมหานคร*, 2562.
- [10] N. Venkat, S. Srivastava, and L. Garg, "Predicting Student Grades using Machine Learning," [Online]. Available: https://www.researchgate.net/publication/329514879_Predicting_Student_Grades_using_Machine_Learning. [Accessed 19 May 2024].
- [11] N. Sghir, A. Adadi, and M. Lahmer, "Recent advances in predictive learning analytics: a decade systematic review (2012–2022)," *Education and Information Technologies*, vol. 28, no. 7, pp. 8299–8333, 2023.
- [12] A. Korchi, F. Messaoudi, A. Abatal, and Y. Manzali, "Machine learning and deep learning-based students' grade prediction," *Operations Research Forum*, vol. 4, no. 4, p. 87, 2023.
- [13] T. K. Dang and H. H. X. Nguyen, "A hybrid approach using decision tree and multiple linear regression for predicting students' performance based on learning progress and behavior," *SN Computer Science*, vol. 3, no. 5, p. 393, 2022.

- [14] A. Surawatchayotin and W. Paireekreng, "The predictive model of higher education guidance using integrated techniques for imbalanced data of learner groups," *Journal of Information Science and Technology.*, vol. 11, no. 1, pp. 65–79, 2023.
- [15] I. K. Nti, A. F. Adekoya, and B. A. Weyori, "A comprehensive evaluation of ensemble learning for stock-market prediction.," *Journal of Big Data.*, vol. 7, no. 1, p. 20, 2020.
- [16] อศวิณ สุรวัชโยธิน และ วัชรภัทร ไพรีเกรง, "การสร้างตัวแบบการทำนายในการเลือกศึกษาต่อในระดับอุดมศึกษา โดยใช้เทคนิคแบบบูรณาการในการแก้ปัญหการจำแนกข้อมูลไม่สมดุลของกลุ่มผู้เรียน ,” *วารสารวิทยาการและเทคโนโลยีสารสนเทศ.*, ปีที่ 11, ฉบับที่ 1, น. 65–79, 2564.
- [17] B. Mahesh, *Machine Learning Algorithms -A Review.* 2019.
- [18] S. Rajendran, S. Chamundeswari, and A. A. Sinha, "Predicting the academic performance of middle- and high-school students using machine learning algorithms," *Social Sciences & Humanities Open.*, vol. 6, no. 1, p. 100357, 2022.
- [19] A. Salah Hashim, W. Akeel Awadh, and A. Khalaf Hamoud, "Student Performance Prediction Model based on Supervised Machine Learning Algorithms," *IOP Conference Series: Materials Science and Engineering.*, vol. 928, no. 3, p. 032019, 2020.
- [20] C. Hans, "Elastic net regression modeling with the orthant normal prior," *Journal of the American Statistical Association.*, vol. 106, no. 496, pp. 1383-1393, 2011.
- [21] L. Giba, "Elastic net regression explained, step by step," [Online]. Available: https://machinelearningcompass.com/machine_learning_models. [Accessed 2 June 2024].
- [22] L. Chen, "Basic ensemble learning (random forest, adaboost, gradient boosting)-step by step explained," [Online]. Available: <https://towardsdatascience.com/basic-ensemble-learning-random-forest-adaboost-gradient-boosting-step-by-step-explained-95d49d1e2725>. [Accessed 2 June 2024].
- [23] G. Biau and E. Scornet, "A random forest guided tour," *TEST.*, vol. 25, no. 2, pp. 197-227. 2015.
- [24] อรุณี ศรีดี, "การประยุกต์ใช้การเรียนรู้ด้วยเครื่องเพื่อตรวจจับงานเสียที่เกิดขึ้นในกระบวนการทดสอบฮาร์ดดิสก์ไดรฟ์," *วิทยาศาสตร์มหาบัณฑิต, สาขาวิชาวิทยาศาสตร์คอมพิวเตอร์, จุฬาลงกรณ์มหาวิทยาลัย, กรุงเทพฯ.*, 2564.
- [25] S. Agatonovic-Kustrin and R. Beresford, "Basic concepts of artificial neural network (ANN) modeling and its application in pharmaceutical research," *Journal of Pharmaceutical and Biomedical Analysis.*, vol. 22, no. 5, pp. 717-727, 2000.
- [26] M. P. Sesmero, A. I. Ledezma, and A. Sanchis, "Generating ensembles of heterogeneous classifiers using Stacked Generalization," *WIREs Data Mining and Knowledge Discovery.*, vol. 5, no. 1, pp. 21-34, 2015.
- [27] ศรีสุภา วรคามิน, "การพัฒนาผลสัมฤทธิ์ทางการเรียนและสมรรถนะการรวมพลังทำงานเป็นทีมด้วยการจัดการเรียนรู้โดยใช้กิจกรรมเป็นฐานในรายวิชาคณิตศาสตร์ของนักเรียนชั้นมัธยมศึกษาปีที่ 4," *ศึกษาศาสตร์มหาบัณฑิต, สาขาวิชาหลักสูตรและการสอน, มหาวิทยาลัยธุรกิจบัณฑิต, กรุงเทพฯ.*, 2565.
- [28] ผ่องใส เพ็ชรรักษ์, อาทร จิตสุนทรชัยกุล และ ศิริรัตน์ แจ่มรักษ์สกุล, "การศึกษาถึงการศึกษาพฤติกรรมการเรียนที่มีผลต่อผลสัมฤทธิ์ทางการเรียน

- ของนักศึกษา สาขาวิชาการจัดการอุตสาหกรรม คณะบริหารธุรกิจ มหาวิทยาลัยธุรกิจบัณฑิตย์” [ออนไลน์]. แหล่งที่มา: <https://dric.nrct.go.th/index.php?/Search/SearchDetail/291094>. [วันที่เข้าถึง 19 พฤษภาคม 2567].
- [29] H. Yao, D. Lian, Y. Cao, Y. Wu, and T. Zhou, "Predicting academic performance for college students: a campus behavior perspective," *ACM Transactions on Intelligent Systems and Technology.*, vol. 10, no. 3, p. Article 24, 2019.
- [30] S.-Y. Park, "Student engagement and classroom variables in improving mathematics achievement," *Asia Pacific Education Review.*, vol. 6, no. 1, pp. 87-97, 2005.
- [31] J. R. Wolf and R. Jia, "The Role Of Grit In Predicting Student Performance In Introductory Programming Courses: An Exploratory Study," in *Proceeding of the Southern Association for Information Systems Conference*, Hilton Head Island, SC, USA, 2015.
- [32] I. Tsaousis and M. H. Alghamdi, "Examining academic performance across gender differently: Measurement invariance and latent mean differences using bias-corrected bootstrap confidence intervals," *Frontiers in Psychology*, vol. 13, 2022.
- [33] ปัทมา ภูระหงษ์, "ผลการจัดกิจกรรมการเรียนรู้โดยใช้หลักการประเมินแบบเสริมพลังที่มีต่อผลสัมฤทธิ์ทางการเรียนวิชาคณิตศาสตร์และเจตคติต่อวิชาคณิตศาสตร์ของนักเรียนชั้นมัธยมศึกษาปีที่ 3," *วารสารวิชาการศรีปทุม ชลบุรี*, vol. 9, no. 3, pp. 96-102, 2553. [ออนไลน์]. Available: https://www.chonburi.spu.ac.th/journal/books_earch/upload/1242-96.pdf. [วันที่เข้าถึง 19 พฤษภาคม 2567].
- [34] พิชญ์ภักชญ์ ปานเผือก, "ปัจจัยที่ส่งผลกระทบต่อผลสัมฤทธิ์ทางการเรียนของนักเรียนชั้นมัธยมศึกษา: ศึกษาเฉพาะกรณี นักเรียนในโรงเรียนขยายโอกาสสังกัดสำนักงานเขตภาษีเจริญ กรุงเทพมหานคร," คณะรัฐศาสตร์ มหาวิทยาลัยธรรมศาสตร์, การค้นคว้าอิสระ, 2560.
- [35] M. Yağcı, "Educational data mining: prediction of students' academic performance using machine learning algorithms," *Smart Learning Environments*, vol. 9, no. 1, p. 11, 2022/03/03 2022, doi: 10.1186/s40561-022-00192-z.
- [36] F. Ouyang, M. Wu, L. Zheng, L. Zhang, and P. Jiao, "Integration of artificial intelligence performance prediction and learning analytics to improve student learning in online engineering course," *International Journal of Educational Technology in Higher Education.*, vol. 20, no. 1, p. 4, 2023/01/17 2023, doi: 10.1186/s41239-022-00372-4.
- [37] N. McJames, A. Parnell, and A. O'Shea, "Little and often: Causal inference machine learning demonstrates the benefits of homework for improving achievement in mathematics and science," *Learning and Instruction.*, vol. 93, p. 101968, 2024/10/01/ 2024, doi: <https://doi.org/10.1016/j.learninstruc.2024.101968>.