

การวิเคราะห์ความคิดเห็นของนักเรียนต่อการจัดการเรียนการสอนโดยใช้เทคนิคการทำเหมืองข้อมูล

Analyzing students' opinions on teaching and learning management using data mining techniques

ธนัทไชยพงษ์ เพชรสงคราม¹ และ วงกต ศรีอุไร^{2*}

Tanutchaipong Phetsongkram¹ and Wongkot Sriurai^{2*}

Received: 9 September 2024 ; Revised: 6 December 2024 ; Accepted: 22 January 2025

บทคัดย่อ

ในมหาวิทยาลัยการจัดการเรียนการสอนมีส่วนสำคัญต่อการเรียนรู้ของนักศึกษา การรับฟังความคิดเห็นของนักศึกษามีความสำคัญต่อการปรับปรุงคุณภาพการจัดการเรียนการสอน ทำให้ผู้สอนสามารถปรับวิธีการสอน เนื้อหา หรือกิจกรรมให้เหมาะสมกับนักศึกษาได้ ในรายวิชาที่มีนักศึกษาจำนวนมาก การสรุปความคิดเห็นทั้งหมดเพื่อนำไปปรับปรุงการเรียนการสอนต้องใช้เวลาอันยาวนาน ดังนั้นงานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาแบบจำลองการวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอน โดยใช้เทคนิคการทำเหมืองข้อมูล วิธีการศึกษามี 5 ขั้นตอน คือ 1) การรวบรวมข้อมูลความคิดเห็นของนักศึกษาจำนวน 3,000 ข้อความ 2) การเตรียมข้อมูล โดยการกลั่นกรองข้อความ และการตัดคำพร้อมเลือกคำสำคัญด้วยเทคนิค TF-IDF 3) การสร้างแบบจำลองเพื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึม 4 วิธี ได้แก่ Support Vector Machine (SVM), K-Nearest Neighbors (K-NN), Naive Bayes และ Random Forest เพื่อใช้จำแนกความคิดเห็นเชิงบวกและเชิงลบ และจำแนกความคิดเห็นในด้านต่างๆ เช่น อาจารย์ผู้สอน เนื้อหารายวิชา และสิ่งสนับสนุนการเรียนรู้ 4) การวัดประสิทธิภาพของแบบจำลองด้วยค่า accuracy, precision, recall, และ F1-score 5) การประยุกต์ใช้แบบจำลอง จากผลการวิจัยพบว่าอัลกอริทึม SVM มีประสิทธิภาพในการจำแนกความคิดเห็นเชิงบวกและเชิงลบมากที่สุดโดยมีค่าเฉลี่ยของ accuracy, precision, recall, และ F1-score เท่ากับ 97.00%, 97.10%, 97.40% และ 97.30% ตามลำดับ สำหรับการจำแนกความคิดเห็นในด้านต่างๆ พบว่าอัลกอริทึม KNN มีประสิทธิภาพมากที่สุด โดยมีค่าเฉลี่ยของ accuracy, precision, recall, และ F1-score เท่ากับ 91.00%, 91.60%, 91.00% และ 91.10% ตามลำดับ แบบจำลองที่พัฒนาถูกนำไปสร้างเป็นเว็บแอปพลิเคชัน เพื่อวิเคราะห์ความคิดเห็นของนักศึกษาช่วยปรับปรุงคุณภาพการเรียนการสอนอย่างมีประสิทธิภาพ

คำสำคัญ: การวิเคราะห์ความคิดเห็น, การจัดการเรียนการสอน, การทำเหมืองข้อมูล

Abstract

In universities, the management of teaching and learning plays a crucial role in student learning. Gathering student feedback is important for improving the quality of teaching and learning, allowing instructors to adjust teaching methods, content, or activities to better suit students. In courses with a large number of students, summarizing all feedback for the purpose of improving teaching can be time-consuming. Therefore, this research aims to develop a model for analyzing student opinions on teaching and learning management using data mining techniques. The research methodology is divided into five steps: 1) Data collection of 3,000 student feedback messages. 2) Data preparation by filtering messages and performing word segmentation, along with selecting key terms using the TF-IDF technique.

¹ สาขาเทคโนโลยีสารสนเทศ, คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี, อุบลราชธานี 34190

² ภาควิชาคณิตศาสตร์ สถิติ และคอมพิวเตอร์, คณะวิทยาศาสตร์ มหาวิทยาลัยอุบลราชธานี, อุบลราชธานี 34190

¹ Major of Information Technology, Faculty of Science, Ubon Ratchathani University, Ubon Ratchathani, 34190

² Department of Mathematics Statistics and Computer, Faculty of Science, Ubon Ratchathani University, Ubon Ratchathani, 34190

^{2*} Corresponding author, e-mail: wongkot.s@ubu.ac.th

3) Modeling to compare the performance of four algorithms: Support Vector Machine (SVM), K-Nearest Neighbors (K-NN), Naive Bayes, and Random Forest for classifying positive and negative opinions and categorizing feedback on various aspects such as instructors, course content, and learning support resources. 4) Model performance evaluation using accuracy, precision, recall, and F1-score, and 5) Model application. The research findings indicate that the SVM algorithm has the highest performance in classifying positive and negative opinions, with average values of accuracy, precision, recall, and F1-score at 97.00%, 97.10%, 97.40%, and 97.30%, respectively. For categorizing feedback on various aspects, the KNN algorithm demonstrated the best performance, with average values of accuracy, precision, recall, and F1-score at 91.00%, 91.60%, 91.00%, and 91.10, respectively. The developed model has been deployed as a web application to analyze student feedback, effectively enhancing the quality of teaching and learning management.

Keywords: Opinion analysis, teaching and learning management, data mining

บทนำ

การจัดการเรียนการสอนในมหาวิทยาลัยมีความสำคัญต่อการเรียนรู้ของนักศึกษา การรับฟังความคิดเห็นของนักศึกษาช่วยปรับปรุงคุณภาพการสอนและทำให้ผู้สอนสามารถปรับวิธีการสอนให้เหมาะสมกับนักศึกษาได้ โดยเฉพาะในรายวิชาที่มีนักศึกษาจำนวนมาก การสรุปความคิดเห็นทั้งหมดเพื่อปรับปรุงการสอนอาจใช้เวลานานและอาจเกิดข้อผิดพลาดในการประมวลผลความคิดเห็น เช่น การจัดประเภทผิดพลาดหรือการตีความข้อความที่ไม่ถูกต้อง ซึ่งอาจเกิดจากการใช้เทคนิคที่ไม่เหมาะสมหรือการเลือกคำสำคัญผิดพลาด ความคิดเห็นของนักศึกษาเกี่ยวกับการจัดการเรียนการสอนส่วนใหญ่ถูกรวบรวมผ่านแบบสอบถาม การสัมภาษณ์ การวิเคราะห์ความคิดเห็นเหล่านี้ในระดับเชิงลึกเป็นเรื่องที่ท้าทาย เนื่องจากความคิดเห็นมีความหลากหลายและมีความซับซ้อน การใช้เทคนิคการทำเหมืองข้อมูล (Data Mining) เพื่อวิเคราะห์ความคิดเห็นสามารถช่วยให้การตีความข้อมูลเชิงคุณภาพเป็นข้อมูลเชิงปริมาณที่สามารถนำไปใช้ในการปรับปรุงการดำเนินงานได้ เช่น งานวิจัยของ วาฑิตย์ คำพรมมา และคณะ (2562) ได้พัฒนาแบบจำลองการวิเคราะห์ความรู้สึกแบบผสมสำหรับความคิดเห็นที่มีต่อโรงแรมในประเทศไทย โดยใช้ K-means และ K-Nearest Neighbors งานวิจัยนี้ได้รวบรวมความคิดเห็นจากเว็บไซต์ APT TUBE โดยนำความคิดเห็นมาวิเคราะห์ ด้วยเทคนิค K-means ซึ่งแบ่งออกเป็น 5 กลุ่มได้แก่ การเข้าถึง กิจกรรมและความบันเทิง อาหารและเครื่องดื่ม พนักงานผู้ให้บริการ และสถานที่ จากนั้นจึงนำข้อความแต่ละกลุ่มมาแยกประเภทด้วยเทคนิค K-Nearest Neighbors (K-NN) ผลการวิจัยพบว่า เทคนิคที่ให้ค่าความถูกต้องมากที่สุดคือ เทคนิค K-means ร่วมกับ K-NN ซึ่งให้ค่าความถูกต้องสูงที่สุดซึ่งมีค่าเท่ากับ 94.80% ส่วนงานวิจัยของ วสวัตดี อินทร์แปลง และจารี ทองคำ (2563) ได้ทำการศึกษาวิเคราะห์ความคิดเห็นต่อเกมมือถือพีจีด้วยเหมืองข้อความ

มุ่งเน้นที่ใช้เทคนิคการทำเหมืองข้อความ (Text Mining) เพื่อวิเคราะห์ความคิดเห็นของผู้เล่นเกมมือถือ Player Unknown's Battlegrounds ซึ่งเป็นเกมยอดนิยม การวิเคราะห์ความคิดเห็นอาจเผยให้เห็นข้อดีข้อเสียของเกม ความต้องการของผู้เล่น และปัญหาที่เกิดขึ้น เมื่อทำการทดสอบและวัดประสิทธิภาพของตัวแบบ พบว่าเทคนิค K-Nearest Neighbor ให้ผลลัพธ์ที่ดีที่สุดในการวิเคราะห์ความคิดเห็น โดยให้ค่าความแม่นยำ 99.75% ค่าความระลึก 100% และค่าความถูกต้อง 99.87% และในงานวิจัยของ Rahat *et al.* (2019) ได้ศึกษาเกี่ยวกับการวิเคราะห์ความคิดเห็น (Sentiment Analysis) โดยเน้นการใช้สื่อสังคมออนไลน์เป็นแหล่งข้อมูลในการรวบรวมความคิดเห็นของผู้คนเกี่ยวกับหัวข้อที่หลากหลาย เช่น การเมือง เศรษฐกิจ และมนุษยธรรม งานวิจัยนี้ได้นำวิธี Support Vector Machine (SVM) และ Naive Bayes มาเปรียบ เทียบประสิทธิภาพ เพื่อจำแนกความคิดเห็นว่าเป็นเชิงบวก เชิงลบ หรือเป็นกลาง ผลการวิจัยพบว่าวิธี SVM ให้ค่าความถูกต้องเท่ากับ 82.48% ซึ่งสูงกว่าวิธี Naive Bayes

จากความเป็นมาและการศึกษา งานวิจัยที่เกี่ยวข้องข้างต้นทำให้ผู้วิจัยมีแนวคิดที่จะพัฒนาแบบจำลองเพื่อวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอนของผู้สอน โดยผลการวิเคราะห์ความคิดเห็นจะทำให้ผู้สอนทราบว่านักศึกษามีความคิดเห็นอย่างไรต่อการจัดการเรียนการสอน จากนั้นนำแบบจำลองที่ได้ไปพัฒนาเป็นระบบต้นแบบวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอน โดยผลการวิเคราะห์ความคิดเห็นจะนำเสนอใน 2 ประเด็น ได้แก่ ความคิดเห็นดังกล่าวเป็นเชิงบวกหรือเชิงลบ และมีการแบ่งประเภทของความคิดเห็นว่าเป็นเชิงบวกด้านใดหรือเป็นเชิงลบด้านใด เพื่อที่ผู้สอนจะได้นำข้อมูลเหล่านี้ไปใช้ประโยชน์ในการปรับปรุงการสอน หรือจัดการเรียนการสอนให้ดียิ่งขึ้น

วัตถุประสงค์การวิจัย

เพื่อพัฒนาแบบจำลองวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอนโดยใช้เทคนิคเหมืองข้อมูล

ทฤษฎีที่เกี่ยวข้อง

1. การวิเคราะห์เหมืองความคิดเห็น

การวิเคราะห์เหมืองความคิดเห็น (Opinion Mining) เป็นสาขาย่อยของการวิเคราะห์ข้อมูลที่มุ่งเน้นการศึกษาความคิดเห็นของผู้ใช้ที่มีต่อประสบการณ์ต่างๆ โดยปกติจะทำการตรวจสอบความรู้สึก (Sentiment Analysis) หรือทัศนคติของผู้คนที่แสดงออกผ่านข้อความ ซึ่งอาจเป็นในรูปแบบของบทความ รีวิว ความคิดเห็นในสื่อสังคมออนไลน์ (กานดา แผ้ววัฒนากุล และปราโมทย์ ลือนาม, 2556) กระบวนการในการวิเคราะห์เหมืองความคิดเห็น ประกอบด้วย 6 ขั้นตอนดังนี้

1.1 การเก็บรวบรวมข้อมูล (Data Collection)

รวบรวมข้อมูลความคิดเห็นจากแหล่งต่าง ๆ เช่น รีวิวออนไลน์ ความคิดเห็นจากผู้ใช้ หรือโพสต์ในโซเชียลมีเดีย เป็นต้น

1.2 การเตรียมข้อมูล (Data Preparation)

ดำเนินการกลั่นกรองข้อมูลโดยการลบข้อมูลที่ไม่เกี่ยวข้องออก และแปลงข้อมูลให้อยู่ในรูปแบบที่เหมาะสมสำหรับการวิเคราะห์

1.3 การตัดคำ (Tokenization) แยกข้อความ

ออกเป็นหน่วยที่เล็กลงเพื่อให้สามารถวิเคราะห์ได้ง่าย

1.4 การกำจัดคำหยุด (Stop Words Removal)

ลบคำที่ไม่จำเป็นเพื่อให้การวิเคราะห์มุ่งเน้นไปที่คำที่สำคัญ

1.5 การวิเคราะห์ความรู้สึก (Sentiment Analysis)

ใช้เทคนิคการเรียนรู้ของเครื่องเพื่อวิเคราะห์และจำแนกความคิดเห็นเป็นเชิงบวกหรือเชิงลบ

1.6 การสร้างตัวแทนเอกสาร (Document Representation)

แปลงข้อมูลความคิดเห็นเป็นเวกเตอร์ที่สามารถนำไปใช้ในการสร้างแบบจำลองได้ เช่น การแทนค่าคำด้วยค่าความถี่ของคำ-ค่าส่วนกลับความถี่เอกสารที่เกิดคำ (Term Frequency – Inverse Document Frequency: TF-IDF) ซึ่ง TF-IDF เป็นวิธีการที่ใช้ในการสร้างตัวแทนเอกสาร เทคนิคนี้มีเป้าหมายหลักเพื่อวัดความสำคัญของคำในเอกสารภายในชุดข้อมูลของเอกสาร โดยพิจารณาทั้งความถี่ของคำในเอกสารนั้น ๆ และความถี่ของคำในชุดเอกสารทั้งหมด (กานดา แผ้ววัฒนากุล และปราโมทย์ ลือนาม, 2556; Chanakot & Sanrach, 2024) รายละเอียดสมการในการคำนวณดังนี้

$$tf_{ij} = \frac{n_{ij}}{\sum_k n_{kj}} \quad (1)$$

โดยที่ n_{ij} คือความถี่ของคำ t_i ในข้อความ D
 $\sum_k n_{kj}$ คือผลรวมของความถี่ของคำทั้งหมดที่ปรากฏในข้อความ D

$$idf_i = \log \frac{n_{ij}}{|\{j:t_i \in d_j\}|} \quad (2)$$

โดยที่ $|D|$ คือจำนวนคำทั้งหมดในชุดข้อมูล และ $|\{j:t_i \in d_j\}|$ คือจำนวนเอกสารที่คำ t_i ปรากฏในชุดข้อมูลทั้งหมด

$$TF - IDF = tf_{ij} \times idf_i \quad (3)$$

2. เทคนิค Support Vector Machine (SVM)

ซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine: SVM) เป็นเทคนิคการเรียนรู้ของเครื่องที่นิยมใช้ในการจัดประเภทและการถดถอย ซึ่งมีหลักการทำงานพื้นฐานคือการหาพื้นที่ที่ดีที่สุด (hyperplane) ที่แบ่งแยกกลุ่มข้อมูลออกจากกันด้วยระยะห่างที่มากที่สุด ซึ่งทำให้การจำแนกประเภทมีความแม่นยำสูง โดย SVM มีความสามารถในการจัดการกับข้อมูลที่ไม่เป็นเชิงเส้นได้ดีผ่านการใช้เคอร์เนลฟังก์ชัน (kernel function) เพื่อแปลงข้อมูลไปยังมิติที่สูงขึ้น (สุพัตรา วิริยะวิสุทธิสกุล และคณะ, 2559)

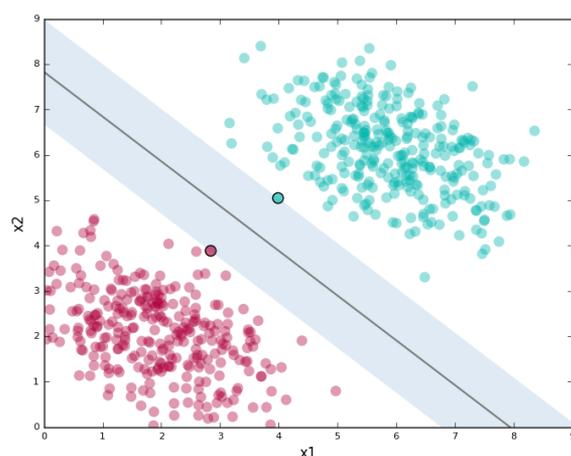


Figure 1 Example Support Vector Machine's Decision Plane

3. เทคนิค K-Nearest Neighbors (K-NN)

เพื่อนบ้านที่ใกล้ที่สุด (K-Nearest Neighbor: KNN) เป็นวิธีการเรียนรู้ของเครื่องที่ใช้สำหรับการจำแนก

ประเภทและการพยากรณ์ โดยพื้นฐานแล้ว KNN จะจำแนกข้อมูลโดยการพิจารณาค่าของ K เพื่อนบ้านที่ใกล้ที่สุด (nearest neighbors) ในพื้นที่ของคุณลักษณะข้อมูล เพื่อระบุประเภทของข้อมูลที่ต้องการจำแนกหรือคาดการณ์ค่า วิธีนี้ทำงานโดยการคำนวณระยะห่างระหว่างจุดข้อมูล และกำหนดประเภทหรือค่าตามจำนวนมากที่สุดของเพื่อนบ้านที่ใกล้ที่สุด วิธีการทำงานของ KNN สามารถคำนวณระยะห่างระหว่างข้อมูลโดยใช้วิธี ยูคลิดีเนียน (Euclidean distance) เพื่อวัดความคล้ายคลึงระหว่างจุดข้อมูลที่ไม่รู้ประเภทกับจุดข้อมูลที่มีประเภทอยู่แล้ว การคัดเลือกเพื่อนบ้าน ค้นหา K จุดข้อมูลที่ใกล้ที่สุด การตัดสินใจ กำหนดประเภทหรือค่าของจุดข้อมูลตามประเภทหรือค่าที่เป็นที่นิยมที่สุดในกลุ่ม K เพื่อนบ้านที่ใกล้ที่สุด (พิชญะ พรหมลา และจรัญ แสงราช, 2563)

4. เทคนิค Random Forest (RF)

Random Forest เป็นการสร้างชุดของ Decision Trees หลายๆ ต้น โดยใช้เทคนิคการสุ่มข้อมูล (randomness) ทั้งในกระบวนการสร้างข้อมูลฝึกและในกระบวนการเลือกคุณลักษณะ (features) เพื่อการแบ่งข้อมูลในแต่ละต้นไม้ในป่า โดยแต่ละ Decision Tree จะทำการทำนายผลและ Random Forest จะใช้การโหวต (voting) หรือการคำนวณค่าเฉลี่ยของผลลัพธ์ที่ได้จากแต่ละต้นไม้เพื่อให้ได้การทำนายสุดท้าย กระบวนการทำงาน Random Forest ประกอบไปด้วยขั้นตอนการสร้างชุดข้อมูลฝึกโดยการสุ่ม (Bootstrap Sampling) การสุ่มตัวอย่างข้อมูลจากชุดข้อมูลฝึก (training dataset) โดยการเลือกตัวอย่างแบบสุ่ม (sampling with replacement) จากข้อมูลทั้งหมด และสร้างชุดข้อมูลที่แตกต่างกันออกไปในแต่ละการสุ่ม การสร้าง Decision Trees สำหรับแต่ละชุดข้อมูลที่สุ่มมานั้น จะสร้าง Decision Tree โดยแต่ละต้นไม้จะทำการตัดสินใจจากคุณลักษณะต่างๆ ที่ถูกสุ่มเลือก ซึ่งเป็นกระบวนการที่แตกต่างจาก Decision Trees แบบธรรมดาที่เลือกคุณลักษณะที่ดีที่สุดในการตัดสินใจที่แต่ละ node การทำนายผลจากหลายต้นไม้ เมื่อทุกๆ ต้นไม้ในป่า Random Forest ทำการทำนายผลแล้ว จะมีการรวมผลจากทุกๆ ต้นไม้ โดยการโหวตสำหรับปัญหาการจำแนกประเภท หรือการคำนวณค่าเฉลี่ยสำหรับปัญหาการทำนายค่าเชิงปริมาณ (Rahat et al., 2019)

5. เทคนิค Naive Bayes

Naive Bayes เป็นเทคนิคการเรียนรู้ของเครื่องที่ใช้หลักการของทฤษฎีความน่าจะเป็น (probability theory) สำหรับการจำแนกประเภท (classification) โดยอาศัยการสมมติว่าคุณลักษณะ (features) ที่ใช้ในการทำนายแต่ละตัว

จะเป็นอิสระจากกัน (independent) ซึ่งเป็นสมมติฐานที่เรียกว่า naive assumption หรือ “สมมติฐานที่เรียบง่าย” หลักการของ Naive Bayes ใช้ ทฤษฎีของเบย์ (Bayes' Theorem) ซึ่งคำนวณความน่าจะเป็นหลัง (posterior probability) ของการจำแนกประเภท (class) ตามคุณลักษณะ (features) ที่มีทฤษฎีของเบย์สามารถเขียนได้เป็น

$$P(C|X) = \frac{P(X|C)P(C)}{P(X)} \tag{4}$$

โดยที่

$P(C|X)$ คือความน่าจะเป็นของการจำแนกประเภท

C เมื่อมีคุณลักษณะ X

$P(X|C)$ คือความน่าจะเป็นของคุณลักษณะ

X ภายใต้การจำแนกประเภท C

$P(C)$ คือความน่าจะเป็นของการจำแนกประเภท C

$P(X)$ คือความน่าจะเป็นของคุณลักษณะ X

Naive Bayes มีหลายประเภท ขึ้นอยู่กับการกระจายของข้อมูล Gaussian Naive Bayes เหมาะสำหรับการใช้งานกับข้อมูลที่มีค่าต่อเนื่อง (continuous data) โดยสมมติว่าข้อมูลในแต่ละคลาสมีการกระจายแบบปกติ (normal distribution) Multinomial Naive Bayes ใช้สำหรับข้อมูลที่เป็นจำนวนเต็ม เช่น จำนวนครั้งที่คำปรากฏในเอกสาร จำนวนครั้งที่เกิดเหตุการณ์เป็นต้น และ Bernoulli Naive Bayes ทำงานได้ดีกับข้อมูล Binary หรือ Boolean (Zhang et al., 2021)

6. การวัดประสิทธิภาพแบบจำลอง

การประเมินประสิทธิภาพแบบจำลองสามารถหาได้จาก Confusion Matrix ตารางที่ใช้เพื่อประเมินประสิทธิภาพของแบบจำลองการจำแนกประเภทข้อมูล โดยแสดงผลลัพธ์ที่คาดการณ์จากแบบจำลองเมื่อเปรียบเทียบกับค่าจริง (True values) (วาทิตย์ คำพรมมา และคณะ, 2562; Gaye & Wulamu, 2019)

Table 1 Confusion matrix

actual class	Predict class	
	class=Yes	class=No
class=Yes	TP	FN
class=No	FP	TN

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \tag{5}$$

$$Precision = \frac{TP}{TP + FP} \quad (6)$$

$$Recall = \frac{TP}{TP + FN} \quad (7)$$

$$F1 - score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

โดยที่

True Positives (TP) หมายถึง การทำนายและผลลัพธ์จริงตรงกัน คือทั้งสองอย่างเป็น Yes

True Negatives (TN) หมายถึง การทำนายเป็น No และผลลัพธ์จริงเป็น No

False Positives (FP) หมายถึง การทำนายเป็น Yes แต่ผลลัพธ์จริงเป็น No

False Negatives (FN) หมายถึง การทำนายเป็น No แต่ผลลัพธ์จริงเป็น Yes

วิธีการวิจัย

ในงานวิจัยนี้มีกระบวนการทำวิจัย 5 ขั้นตอน คือ (1) การเก็บรวบรวมข้อมูล (2) การเตรียมข้อมูล (3) การสร้างแบบจำลอง (4) การวัดประสิทธิภาพของแบบจำลอง และ (5) การประยุกต์ใช้แบบจำลอง มีรายละเอียดดังนี้

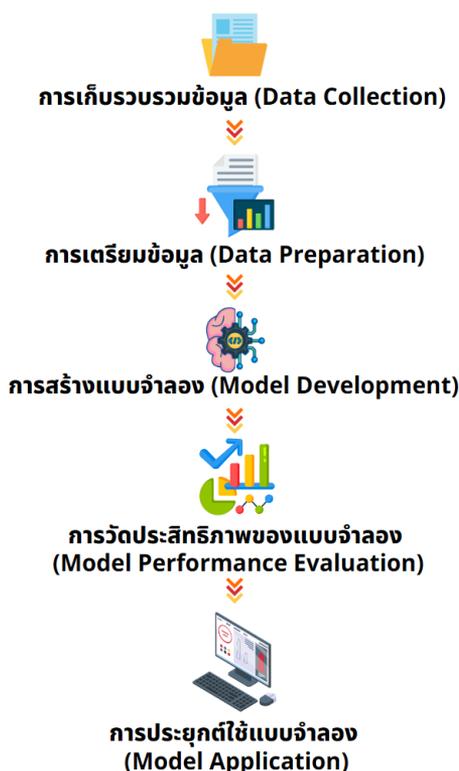


Figure 2 Research Process

การเก็บรวบรวมข้อมูล (Data Collection)

การเก็บรวบรวมข้อมูล เกี่ยวกับความคิดเห็นของนักศึกษาเกี่ยวกับการจัดการเรียนการสอนที่มหาวิทยาลัยอุบลราชธานี โดยข้อมูลถูกเก็บรวบรวมจากกองบริการการศึกษาในช่วงปีการศึกษา 2560-2564 รวมทั้งหมด 3,000 ความคิดเห็น ข้อมูลที่นำมาใช้ในการวิจัยได้ผ่านการขอจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยอุบลราชธานีเรียบร้อยแล้ว มีเลขที่การรับรอง UBU-REC-137/2567 โดยตัวอย่างของข้อมูลดัง Table 2

Table 2 Example of comment (CSV file)

No.	Comment
1	ผมว่าอาจารย์สอนดีมากเลยครับ / สอนเข้าใจง่าย
2	อยากให้เพิ่มในส่วนของวิชาการให้มาก ! กว่านี้
3	อยากให้เพิ่มในส่วนของวิชาการให้มากกว่านี้ +++
...	...

2. การเตรียมข้อมูล (Data Preparation)

2.1 การกลั่นกรองข้อมูล (Data Cleaning) เป็นขั้นตอนที่สำคัญในกระบวนการเตรียมข้อมูล (Data Preparation) เพื่อให้ข้อมูลที่ใช้ในการวิเคราะห์มีความถูกต้องและน่าเชื่อถือมากยิ่งขึ้น ในการกลั่นกรองข้อมูล มีการดำเนินการ คือ ปรับแก้ค่าที่ผิดพลาดในข้อความให้ถูกต้องตามพจนานุกรม กำจัดข้อมูลที่ไม่จำเป็น กำจัดตัวเลข ตัวอักษรภาษาอังกฤษ สัญลักษณ์ และช่องว่างที่ไม่จำเป็นออกจากข้อความ และกรองข้อมูลเฉพาะที่เป็นภาษาไทย หลังจากกระบวนการกลั่นกรองข้อมูลเรียบร้อยแล้ว จะเหลือความคิดเห็นจำนวน 2,254 ข้อความ จาก 3,000 ข้อความ ตัวอย่างของข้อมูลที่ผ่านการกลั่นกรองข้อมูลแล้ว ดัง Table 3

Table 3 Example of comments after deleting special character

original sentence	The last sentence deletes the special characters
ผมว่าอาจารย์สอนดีมากเลยครับ / สอนเข้าใจง่าย	ผมว่าอาจารย์สอนดีมากเลยครับสอนเข้าใจง่าย
อยากให้เพิ่มในส่วนของวิชาการให้มาก ! กว่านี้	อยากให้เพิ่มในส่วนของวิชาการให้มากกว่านี้
อยากให้เพิ่มในส่วนของวิชาการให้มากกว่านี้ +++	อยากให้เพิ่มในส่วนของวิชาการให้มากกว่านี้

2.2 การตัดคำและกำจัดคำหยุด (Stop Words Removal) หลังจากการกรองข้อมูลเสร็จสิ้น ข้อมูลจะได้รับการตัดคำและกำจัดคำหยุดโดยใช้เครื่องมือใน Visual Studio Code และโมดูล PyThaiNLP สำหรับการประมวลผลภาษาไทย ตัวอย่างผลลัพธ์จากกระบวนการนี้จะแสดงใน Table 4 และ Table 5

Table 4 Examples of words segmentation

No.	Review
1	ผม ว่า อาจารย์ สอน ดี มาก เลย ครับ สอน เข้าใจ ง่าย
2	อยาก ให้ เพิ่ม ใน ส่วน ของ วิชาการ ให้ มาก กว่า นี้
3	อุปกรณ์ สนับสนุน เรียน ไม่ดี แะ มาก

Table 5 Examples of stop words remove

No.	Review
1	อาจารย์ สอน ดี สอน เข้าใจ ง่าย
2	อยาก เพิ่ม วิชาการ
3	อุปกรณ์ สนับสนุน เรียน ไม่ดี แะ

2.3 การเลือกเฉพาะคำที่มีความหมาย หลังจากการตัดคำและกำจัดคำหยุดแล้ว จะได้คำทั้งหมดจำนวน 1,254 คำ จากนั้นจะนำคำแต่ละคำมาจัดประเภทตามพจนานุกรมโดยใช้พจนานุกรมอิเล็กทรอนิกส์ฉบับราชบัณฑิตยสถานและพจนานุกรมของ NECTEC ตัวอย่างกระบวนการนี้จะถูกแสดงใน Table 6

Table 6 Examples of words types

Rows	Word	Type	Notice
1	อาจารย์	n	คำนาม
2	สนุก	adv	คำวิเศษณ์
3	ชอบ	v	คำกริยา
4	ไม่ดี	adv	คำวิเศษณ์
5	สอน	v	คำกริยา

2.4 การจัดกลุ่มคำบ่งชี้คุณลักษณะ หลังจากได้ 1,254 คำ ในข้อ 2.3 แล้ว นำคำเหล่านี้มาผ่านการตัดคำเพิ่มเติม พบว่ามีคำที่เกี่ยวข้องกับ การจัดการเรียนการสอน จำนวน 295 คำ ซึ่งถือเป็นคำที่มีความหมายเฉพาะเจาะจงและสอดคล้องกับบริบทของงานวิจัย คำเหล่านี้ถูกตรวจสอบและจัดกลุ่มโดยผู้เชี่ยวชาญด้านภาษาไทยจำนวน 4 ท่าน เพื่อจัดหมวดหมู่คำบ่งชี้คุณลักษณะตามบริบทของการเรียนการสอน โดยแบ่งกลุ่มคำเป็นดังนี้

- คำบ่งชี้คุณลักษณะเชิงบวก จำนวน 59 คำ
- คำบ่งชี้คุณลักษณะเชิงลบ จำนวน 55 คำ
- คำบ่งชี้ด้านอาจารย์ผู้สอน จำนวน 43 คำ
- คำบ่งชี้ด้านเนื้อหาทฤษฎีวิชา จำนวน 51 คำ
- คำบ่งชี้ด้านสิ่งสนับสนุนการเรียนรู้ จำนวน 47 คำ
- คำที่ไม่บ่งชี้คุณลักษณะ จำนวน 40 คำ

งานวิจัยนี้ทำการตัดคำที่ไม่สามารถบ่งชี้คุณลักษณะได้ออกจำนวน 40 คำ เหลือเพียงคำที่สามารถบ่งชี้คุณลักษณะจำนวน 255 คำ

2.5 วิธีการสร้างตัวแทนเอกสาร

งานวิจัยนี้ใช้วิธีการ TF-IDF (Term Frequency-Inverse Document Frequency) เพื่อสร้างเวกเตอร์ตัวแทนเอกสาร โดยนับความถี่ของคำบ่งชี้แต่ละคำในเอกสาร จากนั้นคำนวณ TF-IDF และแทนค่าคำที่ไม่ปรากฏในเอกสารด้วยค่า 0

2.5.1 การเปรียบเทียบความถี่ของคำบ่งชี้เพื่อกำหนดประเภทความคิดเห็นเชิงบวก และเชิงลบ มีรายละเอียดดังนี้

ถ้าความถี่ของคำบ่งชี้ความคิดเห็นเชิงบวกมากกว่าความถี่ของคำบ่งชี้ความคิดเห็นเชิงลบ ให้คลาสเป็นความคิดเห็นเชิงบวก (Pos) ถ้าความถี่ของคำบ่งชี้ความคิดเห็นเชิงลบมากกว่าความถี่ของคำบ่งชี้ความคิดเห็นเชิงบวก ให้คลาสเป็นความคิดเห็นเชิงลบ (Neg) ตัวอย่างแสดงใน Table 7

Table 7 Examples of TF-IDF results with Class Pos or Neg

Rows	Boring	Easy to understand	Like	Angry	Class
1	0	0	0	0.066	Neg
2	0	0.211	0.102	0.079	Pos
3	0	0.181	0	0	Pos
4	0	0.090	0.020	0.099	Pos
5	0.249	0	0.046	0	Neg
6	0	0	0.033	0.082	Neg
7	0	0.158	0	0	Neg
8	0.057	0.974	0.044	0	Pos
9	0.083	0	0	0	Neg
10	0	0.140	0.092	0	Pos

จากใน Table 7 จากความคิดเห็นทั้งหมดจำนวน 3,000 ข้อความ แบ่งเป็นคลาส Pos จำนวน 1,292 ระเบียบ (record) และแบ่งเป็นคลาส Neg จำนวน 962 ระเบียบ ส่วน

ที่ไม่สามารถระบุได้ มีจำนวน 746 ระเบียบ ถูกตัดออก

2.5.2 การเปรียบเทียบความถี่ของคำบ่งชี้เพื่อ

กำหนดประเภทความคิดเห็นด้านอาจารย์ผู้สอน ด้านเนื้อหาวิชา และด้านสิ่งสนับสนุนการเรียนรู้อาจมีรายละเอียดดังนี้

ถ้าความถี่ของคำบ่งชี้ด้านอาจารย์ผู้สอนมากกว่าด้านเนื้อหาวิชาและด้านสิ่งสนับสนุนการเรียนรู้อาจมีรายละเอียดดังนี้ (Class A) ถ้าความถี่ของคำบ่งชี้ด้านเนื้อหาวิชามากกว่าด้านอาจารย์ผู้สอนและด้านสิ่งสนับสนุนการเรียนรู้อาจมีรายละเอียดดังนี้ (Class B) ถ้าความถี่ของคำบ่งชี้ด้านสิ่งสนับสนุนการเรียนรู้อาจมีรายละเอียดดังนี้ (Class C) ตัวอย่างแสดงใน Table 8

Table 8 Examples of TF-IDF results with Class A, B, and C

Rows	Teach	Teacher	Classroom	Content	Class
1	0	0	0	0.043	B
2	0	0	0.024	0	C
3	0.041	0.032	0	0	A
4	0	0	0.213	0	C
5	0.011	0	0	0.020	B
6	0.024	0.034	0	0	A
7	0.042	0	0	0.046	B
8	0.066	0.039	0	0	A
9	0	0	0.341	0	C
10	0	0.252	0	0.035	A

จากใน Table 8 จากความคิดเห็นทั้งหมดจำนวน 3,000 ข้อความ แบ่งเป็นคลาส A มีจำนวน 841 ระเบียบ คลาส B มีจำนวน 819 ระเบียบ และคลาส C มีจำนวน 594 ระเบียบ ข้อมูลจากใน Table 7 และ Table 8 ที่จะนำไปใช้ในการสร้างแบบจำลองวิเคราะห์ความคิดเห็นจะถูกบันทึกเป็นไฟล์ .CSV โดยแบ่งเป็นสองไฟล์ ไฟล์ที่ใช้สำหรับระบุคลาส Pos / Neg และไฟล์ที่ใช้สำหรับระบุด้านต่าง ๆ ดัง Figure 3

	CW	CX	CY	CZ	DA	DB	DC	DD	DE	DF	DG	DH	DI	DJ	DK	result
1	บรรณ	ไทย	อาชีพ	%	โต๊ะ	สแกน	พิมพ์	ช่าง	ช่างมือ	ไฟ	ค้นหา	โทร	ผู้ขาย	ผู้ขาย		neg
2	0.03294	0	0	0	0.165191	0	0	0	0	0	0	0	0.165191	0	0	neg
3	0	0.095533	0	0	0	0	0	0	0	0	0	0	0	0	0	pos
4	0	0	0.027727	0	0	0	0.038856	0	0	0	0.046998	0.13553	0	0	0	neg
5	0	0	0.026771	0	0	0	0.037516	0	0	0	0.045377	0.104685	0	0	0.059812	neg
6	0	0	0	0	0.123893	0.0717	0	0	0	0	0	0	0	0.123893	0	pos
7	0	0.211244	0	0.059812	0	0	0	0	0	0	0	0	0	0	0	pos
8	0	0.181066	0	0	0	0	0	0	0	0	0	0.023718	0	0.085768	0	pos
9	0	0.181066	0	0	0	0	0	0	0	0	0	0	0	0	0	pos
10	0	0.181066	0	0.085768	0	0.081052	0	0	0	0	0	0	0	0	0	pos
11	0	0	0.258783	0	0.061947	0.084736	0	0	0	0	0	0	0	0.061947	0	pos
12	0	0	0	0	0.206488	0.0717	0	0	0	0	0	0	0	0.206488	0	neg
13	0	0	0	0	0	0.051783	0	0	0	0	0	0	0	0	0	neg
14	0	0	0	0	0	0.054829	0	0.047469	0	0	0	0	0	0	0.041075	pos
15	0	0	0	0	0.11615	0	0	0	0	0	0	0	0	0.11615	0	neg
16	0	0.063373	0.141154	0	0	0	0	0	0	0	0	0	0	0	0	pos
17	0	0	0.129391	0	0	0	0	0	0	0.051795	0	0	0	0	0	pos
18	0	0	0	0.116557	0.095302	0	0	0	0	0	0	0	0	0.095302	0	neg
19	0	0	0	0	0	0	0	0	0	0	0	0	0	0	0	pos

Figure 3 File CSV which will be used for building a sentiment analysis model

3. การสร้างแบบจำลอง (Model Development)

การสร้างแบบจำลองในงานวิจัยนี้ใช้เครื่องมือคือโปรแกรม Visual Studio Code และภาษาการเขียนโปรแกรม Python โดยมีรายละเอียดดังนี้ สร้างแบบจำลองเปรียบเทียบประสิทธิภาพของอัลกอริทึม SVM, KNN, Naive Bayes และ Random Forest สำหรับการจำแนกความคิดเห็นเชิงบวกและเชิงลบ และจำแนกความคิดเห็นในด้านต่างๆ โดยเทคนิค SVM จะมีการปรับค่าพารามิเตอร์เพื่อเพิ่มประสิทธิภาพของแบบจำลอง โดยกำหนดค่าพารามิเตอร์ดังนี้ ค่า C: กำหนดค่าตั้งแต่ 500, 1000 และ 1500 ค่า Kernel: ใช้ค่า Linear งานวิจัยนี้เลือกใช้ Kernel คือ Linear เนื่องจากเหมาะกับข้อมูลที่ใช้งานมีความสัมพันธ์เชิงเส้น และไม่ต้องการความซับซ้อนเกินไปในการแยกแยะข้อมูล สำหรับการสร้างแบบจำลองด้วยเทคนิค KNN มีการปรับสเกลข้อมูลก่อนการใช้งานโดยใช้ StandardScaler มีการปรับค่าพารามิเตอร์ดังนี้ ค่า K ซึ่งเป็นจำนวนของเพื่อนบ้านที่ใช้ในการตัดสินใจ จะกำหนดค่าไว้ที่ 3, 4 และ 5 สำหรับการเลือก Weight ของ K-NN งานวิจัยนี้เลือกใช้ Distance Weight เนื่องจากข้อมูลในแต่ละคลาสมีจำนวนแตกต่างกัน การใช้ Distance Weight จะช่วยให้จุดข้อมูลที่ใกล้เคียงกันมีอิทธิพลในการทำนายมากขึ้น ซึ่งจะช่วยให้เพิ่มความแม่นยำในการจำแนกความคิดเห็นในแต่ละคลาส ส่วนของการสร้างแบบจำลอง Naive Bayes ใช้โมเดล MultinomialNB สำหรับข้อมูลจำแนกประเภท และการสร้างแบบจำลองด้วยเทคนิค Random Forest ใช้การตั้งค่าพารามิเตอร์ จำนวนต้นไม้ (n_estimators) กำหนดค่าที่ 100, 200 และ 300 ความลึกสูงสุดของต้นไม้ (max_depth) กำหนดใช้ค่าอัตโนมัติ ในกระบวนการนี้จะมีการทดสอบค่าพารามิเตอร์ต่างๆ เพื่อหาค่าที่เหมาะสมที่สุดสำหรับการสร้างแบบจำลองแต่ละเทคนิค และเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลองในการวิเคราะห์ความคิดเห็น

4. การวัดประสิทธิภาพของแบบจำลอง (Model Performance Evaluation)

การวิจัยนี้ใช้วิธีการแบ่งข้อมูลแบบ Split โดยมี การแบ่งชุดข้อมูลออกเป็น 2 ส่วน คือ ข้อมูลฝึกสอน (Training) 90% เพื่อใช้ในการสร้างแบบจำลอง และข้อมูลชุดทดสอบ (Testing) 10% โดยมีการวัดประสิทธิภาพของแบบจำลอง 4 ค่า ได้แก่ accuracy, precision, recall และ F1-score

5. การประยุกต์ใช้แบบจำลอง (Model Application)

การวิจัยครั้งนี้ได้นำแบบจำลองที่ให้ค่าประสิทธิภาพ ที่ดีที่สุดไปพัฒนาเป็นเว็บแอปพลิเคชัน เพื่อทดสอบการใช้งาน แบบจำลองสำหรับวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอนของอาจารย์ โดยผู้วิจัยใช้ Visual Studio Code Python พัฒนาในส่วนเว็บแอปพลิเคชัน

ผลการวิจัย

1. ผลการพัฒนาแบบจำลองวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอนโดยใช้เทคนิคการทำเหมืองข้อมูล

การวิจัยนี้ได้สร้างแบบจำลองเปรียบเทียบ ประสิทธิภาพของอัลกอริทึม SVM, KNN, Naive Bayes และ Random Forest สำหรับการจำแนกความคิดเห็นเชิงบวกและเชิงลบ และสำหรับจำแนกความคิดเห็นในด้านต่างๆ โดยจาก Table 9 ข้อมูลในตารางแสดงให้เห็นว่าแบบจำลอง SVM ให้ ประสิทธิภาพในการจำแนกความคิดเห็นเชิงบวกและเชิงลบ มากที่สุด โดยมีค่าพารามิเตอร์ C = 1500 มีค่า accuracy เท่ากับ 97.00% precision เท่ากับ 97.10%, recall เท่ากับ 97.40% และ F1-score เท่ากับ 97.30% จาก Table 10 ข้อมูลในตารางแสดงให้เห็นว่าแบบจำลอง KNN ให้ ประสิทธิภาพในการจำแนกความคิดเห็นในด้านต่างๆ โดยค่า พารามิเตอร์ K = 3 ให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า accuracy เท่ากับ 91.00% precision เท่ากับ 91.60% recall เท่ากับ 91.00% และ F1-score เท่ากับ 91.10% โดยผลลัพธ์ใน Table 9 และ Table 10 ค่า precision, recall, และ F1-score เป็นค่า

เฉลี่ยของทุกคลาส

Table 9 Comparison of Positive and Negative Sentiment Types

Model	Settings	Precision (%)	Recall (%)	Accuracy (%)	F1-Score (%)
SVM	C=500	95.40	95.30	95.20	95.10
	C=1000	93.60	98.40	95.40	95.40
	C=1500	97.10	97.40	97.00	97.30
KNN	K=3	95.90	95.90	95.90	95.90
	K=4	94.80	94.50	94.50	94.60
	K=5	94.70	94.50	94.50	94.50
Naive Bayes	MultinomialNB	76.30	58.80	58.80	46.40
Random Forest	n_estimators = 100	93.00	92.90	92.90	92.90
	n_estimators = 200	92.80	92.60	92.60	92.60
	n_estimators = 300	92.30	92.20	92.20	92.10

Table 10 Comparison of the Types of Feedback on Instructor, Course Content, and Learning Support

Model	Settings	Precision (%)	Recall (%)	Accuracy (%)	F1-score (%)
SVM	C=500	90.10	89.90	89.90	89.90
	C=1000	90.10	89.90	89.90	89.90
	C=1500	89.90	89.80	89.80	89.80
KNN	K=3	91.60	91.00	91.00	91.10
	K=4	90.00	89.50	89.50	88.20
	K=5	89.60	89.10	89.10	89.30

Table 10 Comparison of the Types of Feedback on Instructor, Course Content, and Learning Support (continue)

Naive Bayes	Multinomial NB	66.50	73.20	73.20	67.60
Random Forest	n_estimators = 100	81.20	81.10	81.10	80.90
	n_estimators = 200	81.40	81.40	81.40	81.20
	n_estimators = 300	81.80	81.80	81.80	81.60

2. ผลการนำแบบจำลองไปประยุกต์ใช้งาน

การวิจัยครั้งนี้ได้นำแบบจำลองที่ให้ประสิทธิภาพที่ดีที่สุดไปใช้งานโดยการพัฒนาเป็นเว็บแอปพลิเคชัน เพื่อวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอนของอาจารย์ มีประโยชน์หลายประการ ซึ่งสามารถช่วยเพิ่มประสิทธิภาพในการจัดการเรียนการสอน และส่งผลดีต่อการพัฒนาคุณภาพการศึกษา อาจารย์สามารถใช้ข้อมูลจากผลการวิเคราะห์ความคิดเห็นของนักศึกษาเพื่อปรับปรุงการสอนในด้านต่าง ๆ เช่น การจัดการเนื้อหา หรือการปรับปรุงวิธีการสอนให้ตรงตามความต้องการของนักศึกษา และการจำแนกความคิดเห็นเป็นเชิงบวกและเชิงลบช่วยให้เห็นภาพรวมของการตอบรับจากนักศึกษาโดยขั้นตอนการใช้งานแบ่งเป็น 2 ส่วน คือ 1) ให้ผู้ใช้กรอกข้อความที่ต้องการวิเคราะห์ความคิดเห็น จากนั้นคลิกที่ Submit เพื่อระบบจะทำการวิเคราะห์ข้อความ ใน Figure 4 และ 2) แสดงผลลัพธ์การวิเคราะห์ข้อความจะปรากฏที่ผลการวิเคราะห์ ใน Figure 5

ระบบวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอน

กรอกข้อความแสดงความคิดเห็น

SUBMIT

ผลการวิเคราะห์ : >>

Figure 4 A screen where users can enter comments, suggestions, or feedback

ระบบวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอน

อาจารย์ที่ทักสอนเข้าใจอาจารย์เป็นคนดีมากสอนเข้าใจขอบเขตอาจารย์เป็นคนตรงเวลาและมีเหตุผล

SUBMIT

ผลการวิเคราะห์ : >>

- มีความเข้าใจเป็นจุดสังเกตการตัดสินใจ (Positive)
- ด้านอาจารย์สอน

Figure 5 Display the results of the analysis of student feedback on teaching and learning management

3. ผลการประเมินความพึงพอใจการใช้เว็บแอปพลิเคชันวิเคราะห์ความคิดเห็นของนักศึกษา

จากการสัมภาษณ์อาจารย์ผู้สอนจำนวน 4 ท่าน เกี่ยวกับการใช้งานเว็บแอปพลิเคชันใน 2 ด้าน มีรายละเอียดดังนี้

ในด้านการวิเคราะห์ข้อมูลเพื่อจำแนกความคิดเห็นที่เป็นเชิงบวกและเชิงลบ และจำแนกความคิดเห็นในด้านต่าง ๆ อาจารย์ผู้สอนพึงพอใจในความแม่นยำของการวิเคราะห์ความคิดเห็น โดยกล่าวว่า เว็บแอปพลิเคชันสามารถจำแนกความคิดเห็นเชิงบวกและเชิงลบได้อย่างถูกต้องและรวดเร็ว และช่วยให้สามารถระบุด้านต่าง ๆ เช่น อาจารย์ผู้สอน เนื้อหารายวิชา และสิ่งสนับสนุนการเรียนรู้ได้อย่างชัดเจน ความคิดเห็นเพิ่มเติม คือ การจำแนกข้อมูลช่วยประหยัดเวลาในการวิเคราะห์ความคิดเห็นของนักศึกษาได้มาก และผลลัพธ์สามารถนำไปใช้ปรับปรุงการเรียนการสอนได้

ในด้านการใช้งาน อาจารย์ผู้สอนแสดงความคิดเห็นว่าเว็บแอปพลิเคชันใช้งานง่าย และมีคำแนะนำการใช้งานที่ชัดเจนในแต่ละขั้นตอน

สรุปผลการประเมินความพึงพอใจ อาจารย์ผู้สอนมีความพึงพอใจต่อเว็บแอปพลิเคชันในระดับมาก โดยเว็บแอปพลิเคชัน ช่วยเพิ่มประสิทธิภาพในการวิเคราะห์ความคิดเห็นของนักศึกษาและสนับสนุนการปรับปรุงการจัดการเรียนการสอนได้อย่างดี ทั้งนี้ขอเสนอแนะในการปรับปรุงการใช้งาน เช่น การเพิ่มความสามารถในการปรับแต่งการแสดงผลข้อมูลควรนำไปพิจารณาในอนาคตเพื่อเพิ่มความสะดวก และประสิทธิภาพในการใช้งานมากยิ่งขึ้น

สรุปผลการวิจัย

งานวิจัยนี้ได้พัฒนาแบบจำลองวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอนของอาจารย์ โดยใช้เทคนิคการเหมืองข้อมูล โดยการวิจัยแบ่งออกเป็นสองส่วนหลัก ในส่วนแรก ได้มีการสร้างแบบจำลองเพื่อจำแนกความคิดเห็นเชิงบวกและเชิงลบ และสร้างแบบจำลองเพื่อจำแนกความคิดเห็นในด้านต่าง ๆ เช่น อาจารย์ผู้สอน เนื้อหารายวิชา และสิ่งสนับสนุนการเรียนรู้ โดยเปรียบเทียบประสิทธิภาพใน 4 อัลกอริทึม ได้แก่ SVM, KNN, Naive Bayes และ Random Forest และในส่วนที่สองของการวิจัย ได้นำแบบจำลองที่มีประสิทธิภาพที่ดีที่สุดไปใช้ในการพัฒนาเว็บแอปพลิเคชัน เพื่อทดสอบการใช้งานแบบจำลองสำหรับวิเคราะห์ความคิดเห็นของนักศึกษาที่มีต่อการจัดการเรียนการสอนของอาจารย์

โดยผลการวิจัยมีรายละเอียดดังนี้ ส่วนแรก การสร้างแบบจำลองเพื่อจำแนกความคิดเห็นเชิงบวกและเชิงลบ และสร้างแบบจำลองเพื่อจำแนกความคิดเห็นในด้านต่าง ๆ เช่น

อาจารย์ผู้สอน เนื้อหารายวิชา และสิ่งสนับสนุนการเรียนรู้ พบว่าเทคนิค SVM มีประสิทธิภาพในการจำแนกความคิดเห็นเชิงบวกและเชิงลบที่ดีที่สุด โดยมีค่าเฉลี่ยของ accuracy, precision, recall, และ F1-score เท่ากับ 97.00%, 97.10%, 97.40% และ 97.30% สำหรับการจำแนกความคิดเห็นในด้านต่างๆ พบว่าอัลกอริทึม KNN มีประสิทธิภาพมากที่สุด โดยมีค่าเฉลี่ยของ accuracy, precision, recall, และ F1-score เท่ากับ 91.00%, 91.60%, 91.00%, และ 91.10% ส่วนที่สองการพัฒนาเว็บแอปพลิเคชันวิเคราะห์ความคิดเห็นของนักศึกษา พบว่าเว็บแอปพลิเคชันที่พัฒนาขึ้นสามารถวิเคราะห์ความคิดเห็นของนักศึกษาได้อย่างแม่นยำ และช่วยให้อาจารย์สามารถนำผลการวิเคราะห์ความคิดเห็นไปใช้ในการปรับปรุงการจัดการเรียนการสอนได้

จากผลการวิจัยทั้งหมดแสดงให้เห็นว่าแบบจำลองที่พัฒนาขึ้น ทั้งในส่วนของการจำแนกความคิดเห็นเชิงบวกและเชิงลบ รวมถึงการจำแนกความคิดเห็นในแต่ละด้านของการจัดการเรียนการสอน ทั้งสองส่วนที่พัฒนาขึ้นมีประสิทธิภาพในการวิเคราะห์ความคิดเห็นของนักศึกษา และสามารถนำไปประยุกต์ใช้งานจริงในการปรับปรุงการจัดการเรียนการสอนได้ ผลของการวิจัยมีความสอดคล้องกับงานวิจัยของ Munawaroh and Alamsyah (2020) ได้ศึกษาเปรียบเทียบประสิทธิภาพของอัลกอริทึม SVM, Naive Bayes, และ KNN สำหรับวิเคราะห์ความคิดเห็นสาธารณะเกี่ยวกับความรู้สึกต่อการฉีดวัคซีน COVID-19 บน Twitter ซึ่งผลการวิจัยแสดงให้เห็นว่าอัลกอริทึมข้างต้นมีความแม่นยำในการวิเคราะห์ความคิดเห็นมากกว่าร้อยละ 90

แนวทางการพัฒนาในอนาคตควรพัฒนาความสามารถในการวิเคราะห์ความคิดเห็นที่มีความซับซ้อน เช่น เพิ่มการวิเคราะห์ความคิดเห็นที่เป็นเชิงบวกหรือเชิงลบอย่างมาก (Extreme sentiments) หรือความคิดเห็นที่มีลักษณะเป็นกลาง (Neutral sentiment) โดยอาจปรับปรุงเทคนิคการจำแนกประเภทให้เหมาะสมกับข้อมูลที่มีความซับซ้อนมากขึ้น เช่น การใช้วิธีการวิเคราะห์เชิงลึก (Deep learning) การใช้โครงข่ายประสาทเทียม (Artificial Neural Networks) หรือเทคนิคการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) เพื่อเพิ่มประสิทธิภาพในการวิเคราะห์ความคิดเห็นเชิงลึก

เอกสารอ้างอิง

- กานดา แผ้ววัฒนากุล และปราโมทย์ ลื่อนาม. (2556). การวิเคราะห์เหมืองความคิดเห็นบนเครือข่ายสังคมออนไลน์. *วารสารการจัดการสมัยใหม่*, 11(2), 12–20.
- พิชัญญะ พรหมลา และจรัญ แสนราช. (2563). การเปรียบเทียบประสิทธิภาพการวิเคราะห์ความพึงพอใจเกี่ยวกับการจัดการเรียนการสอนด้วยกระบวนการวิเคราะห์ความรู้สึกโดยใช้เทคนิคการรวมกลุ่มเพื่อจำแนกข้อมูล. *วารสารวิจัย มข. (ฉบับบัณฑิตศึกษา)*, 20(4), 140–149.
- วสวัตดี อินทร์แปลง และจारी ทองคำ. (2563). การวิเคราะห์ความคิดเห็นต่อเกมมือถือที่จับจี้ด้วยเหมืองข้อความ. *วารสารวิทยาศาสตร์และเทคโนโลยีมหาวิทยาลัยมหาสารคาม*, 39(5), 524–531.
- วาทีตย์ คำพรมมา, จักรชัย โสอินทร์ และเพชร อิ่มทองคำ. (2562). แบบจำลองการวิเคราะห์ความรู้สึกแบบผสมสำหรับความคิดเห็นต่อโรงแรมในประเทศไทยโดยใช้ K-means และ K-NN. *Walailak Procedia*, 1–11.
- สุพัตรา วิริยะวิสุทธิสกุล, ปริญญา สงวนสัตย์, พิสิทธิ์ ชาญเกียรติ ก้อง และชูชาติ หฤไชยะศักดิ์. (2559). ระบบแจ้งเตือนโซเชียลมีเดียไทยสำหรับธุรกิจด้วยซอฟต์แวร์แมชชีน. *Panyapiwat Journal*, 8, 223–233.
- Chanakot, B., & Sanrach, C. (2024). A Thai-language chatbot analyzing mosquito-borne diseases using Jaccard similarity. *Bulletin of Electrical Engineering and Informatics*, 13(1), 648–655.
- Gaye, B., & Wulamu, A. (2019). Sentiment analysis of text classification algorithms using confusion matrix. In *Cyberspace Data and Intelligence, and Cyber-Living, Syndrome, and Health: International 2019 Cyberspace Congress, CyberDI and CyberLife* (pp. 231–241). Springer Singapore.
- Munawaroh, K., & Alamsyah. (2022). Performance comparison of SVM, Naive Bayes, and KNN algorithms for analysis of public opinion sentiment against COVID-19 vaccination on Twitter. *Journal of Advances in Information Systems and Technology*, 4(2), 113–125.
- Rahat, A. M., Kahir, A., & Masum, A. K. M. (2019). Comparison of Naive Bayes and SVM Algorithm based on sentiment analysis using review dataset. In *2019 8th International Conference System Modeling and Advancement in Research Trends (SMART)* (pp. 266–270). IEEE.

Zhang, Y., Yun, Y., An, R., Cui, J., Dai, H., & Shang, X. (2021). Educational data mining techniques for student performance prediction: Method review and comparison analysis. *Frontiers in Psychology, 12*, 1–19.