

การเปรียบเทียบประสิทธิภาพการวิเคราะห์ความพึงพอใจเกี่ยวกับ การจัดการเรียนการสอนด้วยกระบวนการวิเคราะห์ความรู้สึก โดยใช้เทคนิคการรวมกลุ่มเพื่อจำแนกข้อมูล

The Comparison of Efficiency on The Analysis of Satisfaction on Teaching Performance using Sentiment Analysis by Ensemble Technique

พิชญะ พรหมลา (Pichaya Promla)^{1*} ดร.จรัญ แสนราช (Dr.Charun Sanrach)**

(Received: May 23, 2019; Revised: October 8, 2019; Accepted: October 11, 2019)

บทคัดย่อ

ปัจจุบันสถาบันการศึกษาให้ความสำคัญกับการประเมินผลการจัดการเรียนรู้ของครูผู้สอนเป็นอย่างมาก นอกจากการประเมินทางตรงยังมีการประเมินทางอ้อมด้วยการสำรวจความพึงพอใจของผู้เรียน โดยใช้แบบสอบถาม ซึ่งการวิเคราะห์ข้อมูลคำถามปลายเปิดในแบบสอบถามนั้นสามารถทำได้ง่าย แต่คำถามปลายเปิดจะทำได้ยาก และซับซ้อน รวมทั้งอาจเกิดความไม่แม่นยำเนื่องจากอคติจากผู้วิเคราะห์ข้อมูลได้ ในงานวิจัยนี้ได้ใช้กระบวนการวิเคราะห์ความรู้สึกเพื่อวิเคราะห์ความคิดเห็นที่ได้จากแบบสอบถามจำนวน 1,577 ข้อความให้เป็นข้อความเชิงบวก และเปรียบเทียบประสิทธิภาพการจำแนกโดยใช้เทคนิคการรวมกลุ่มเพื่อจำแนกข้อมูล ได้แก่ Vote, Bagging และ Random Forest กับเทคนิควิธีมาตรฐาน ได้แก่ Decision Tree, Naïve Bayes และ K-NN พบว่าเทคนิควิธีการรวมกลุ่มเพื่อจำแนกข้อมูลแบบ Vote มีประสิทธิภาพมากที่สุด

ABSTRACT

Nowadays, the educational institutions emphasize the evaluation of the teaching performance of teachers. In addition to direct assessments, indirect assessments were conducted by surveying the satisfaction of learners using questionnaires. The analysis of closed-ended question data in the questionnaire can be easily done. But open-ended questions can be difficult, complex and may not be accurate due to bias from the data analyst. In this study, the sentiment analysis was used to analyze 1,577 comments classified to satisfaction polarity and compare the efficiency of classification by using ensemble techniques such as Vote, Bagging and Random Forest with standard techniques such as Decision Tree, Naïve Bayes and K-NN. The results showed that the Vote ensemble technique was the most effective.

คำสำคัญ: การวิเคราะห์ความรู้สึก เหมือนข้อความ เทคนิควิธีการรวมกลุ่มเพื่อจำแนกข้อมูล

Keywords: Sentiment analysis, Text mining, Ensemble technique

¹Corresponding author: pichaya.promla@gmail.com

*นักศึกษา หลักสูตรครุศาสตรบัณฑิต สาขาวิชาคอมพิวเตอร์ศึกษา คณะครุศาสตรบัณฑิต มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

**ผู้ช่วยศาสตราจารย์ ภาควิชาคอมพิวเตอร์ศึกษา คณะครุศาสตรบัณฑิต มหาวิทยาลัยเทคโนโลยีพระจอมเกล้าพระนครเหนือ

บทนำ

การประเมินผลการจัดการเรียนรู้ เป็นกระบวนการที่ทำให้ผู้สอนทราบถึงความสนใจ และปัญหาในการเรียนของผู้เรียน ผู้สอนสามารถนำไปใช้เป็นข้อมูลในการบริหารจัดการชั้นเรียน เลือกใช้วิธีการสอน [1] เพื่อให้ผู้เรียนเกิดความคงทน ความผูกพันในการเรียน แนวทางการประเมินผลการจัดการเรียนรู้สามารถทำได้ 2 วิธี คือ การประเมินผลทางตรง โดยประเมินจากผลงานของผู้เรียน เช่น ผลสัมฤทธิ์ทางการเรียน ชิ้นงาน รายงาน เป็นต้น และการประเมินผลทางอ้อม เช่น การสังเกตพฤติกรรมของผู้เรียน การเก็บข้อมูลย้อนกลับ (Feedback) จากการเรียน เป็นต้น

ปัจจุบันสถาบันการศึกษาให้ความสำคัญกับการประเมินผลการจัดการเรียนรู้ของครูผู้สอนเป็นอย่างมาก นอกจากการประเมินผลทางตรงที่ผู้สอนต้องทำการประเมินอยู่แล้วในชั้นเรียน ได้มีการประเมินผลทางอ้อมโดยใช้การสำรวจความพึงพอใจของผู้เรียนหลังจากเสร็จสิ้นการเรียนในแต่ละภาคเรียน ในการเก็บข้อมูลสถานศึกษาส่วนใหญ่ใช้แบบสอบถามที่ประกอบด้วยคำถามปลายปิดแบบประมาณค่า และคำถามปลายเปิดที่ผู้เรียนสามารถแสดงความคิดเห็นในประเด็นต่าง ๆ เพิ่มเติมได้ ซึ่งการวิเคราะห์ข้อมูลจะใช้วิธีการทางสถิติ เช่น ค่าเฉลี่ย ส่วนเบี่ยงเบนมาตรฐาน สำหรับคำถามปลายปิด ส่วนคำถามปลายเปิดจะทำได้ยาก และมีวิธีการที่ซับซ้อนกว่า รวมทั้งอาจเกิดความไม่แม่นยำเนื่องจากอคติจากผู้วิเคราะห์ข้อมูลได้

การทำเหมืองข้อความ (Text Mining) เป็นเทคนิควิธีทางคอมพิวเตอร์สำหรับค้นหาคำหรือความรู้ในข้อความจำนวนมากด้วยหลักการทางสถิติ เทคนิควิธีการเรียนรู้ของเครื่อง (Machine Learning) การประมวลผลเอกสาร (Document processing) การประมวลผลข้อความ (Text processing) และการประมวลผลภาษาธรรมชาติ (Natural Language Processing) ซึ่งองค์ความรู้ที่ได้จากการทำเหมืองข้อความมีหลากหลายแตกต่างกันออกไปตามวัตถุประสงค์ เช่น ข้อสรุปของเอกสารข้อความ ประเภทของเอกสารข้อความ เป็นต้น การวิเคราะห์ความรู้สึก (Sentiment Analysis) เป็นการทำเหมืองข้อความประเภทหนึ่งที่จะจำแนกความคิดเห็นของผู้ใช้ที่มีต่อสิ่งใดสิ่งหนึ่งออกเป็นข้อความรู้สึกลึก เช่น ความคิดเห็นเชิงบวก เป็นกลาง และเชิงลบ มีการศึกษาวิจัยอย่างกว้างขวางโดยส่วนใหญ่จะใช้วิเคราะห์ข้อมูลความคิดเห็นของผู้ใช้เกี่ยวกับสินค้าหรือบริการ [2-7] สำหรับทางด้านการศึกษาก็ได้มีการประยุกต์ใช้การวิเคราะห์ความรู้สึกเช่นเดียวกัน เช่น ในปีพ.ศ.2554 Kechaou, Ammar และ Alimi [8] ได้รายงานผลการเปรียบเทียบการวิเคราะห์ความรู้สึกจากข้อมูลความคิดเห็นของผู้เรียนที่มีต่อระบบอิเล็กทรอนิกส์ด้วยวิธีการคัดเลือกคุณลักษณะ (Feature Selection) แบบ Mutual Information (MI), Information Gain (IG) และ CHI statistics (CHI) ใช้วิธีการจำแนกประเภทด้วย Hidden Model Markov (HMM) ร่วมกับ Support Vector Machine (SVM) พบว่าการคัดเลือกคุณลักษณะด้วยวิธี IG มีประสิทธิภาพมากที่สุด รองลงมาเป็นวิธี MI และ CHI ตามลำดับ ต่อมาในปีพ.ศ.2559 Munezero, Montero, Mozgovoy และ Sutinen [9] ได้รายงานผลการวิจัยและพัฒนากระบวนการวิเคราะห์ความรู้สึกจากบันทึกการเรียนรู้ (Learning diary) ของผู้เรียน โดยวิเคราะห์ข้อมูลเป็นข้อความความคิดเห็นและอารมณ์ที่เกิดขึ้นเพื่อให้ผู้สอนใช้เป็นข้อมูลในการปรับวิธีการสอนให้ดึงดูดความสนใจของผู้เรียน พบว่าระบบที่พัฒนาขึ้นมีความเที่ยงตรง เชื่อถือได้ สามารถทำงานได้อย่างมีประสิทธิภาพ ในปีพ.ศ.2559 Balahadia, Fernando และ Juanatas [1] ได้นำเสนอรูปแบบระบบการประเมินประสิทธิภาพการทำงานของครูผู้สอนโดยใช้เทคนิควิธีการวิเคราะห์ความรู้สึกจากผลการประเมิน โดยใช้วิธีการจำแนกข้อมูลด้วยเทคนิควิธี Naïve Bayes และ ในปีพ.ศ. 2560 Rani และ Kuma [10] ได้รายงานการวิเคราะห์ความรู้สึกของผู้เรียนจากข้อมูลความคิดเห็นที่ได้จากการตอบแบบสอบถาม เพื่อหาข้อความรู้สึกลึก อารมณ์ และความพึงพอใจของผู้เรียน เนื่องจากการจำแนกข้อความความคิดเห็นเพียงอย่างเดียวยังได้ข้อมูลที่ไม่ครอบคลุมต่อการวิเคราะห์ผู้เรียน จากการศึกษาพบว่าข้อมูลที่ได้จากการวิเคราะห์สามารถเชื่อถือได้เมื่อเปรียบเทียบกับผลการประเมินทางตรงในชั้นเรียน

เนื่องจากข้อความเป็นข้อมูลที่ไม่มีโครงสร้าง (Unstructured data) ในกระบวนการทำเหมืองข้อความจึงต้องแปลงข้อมูลให้เป็นข้อมูลแบบมีโครงสร้างก่อนตามกระบวนการประมวลผลข้อความ (Text processing) โดยเริ่มจากการเตรียมข้อมูล (Preprocessing) ซึ่งประกอบด้วย การแก้ไขคำผิด (Text Cleaning) การแยกคำจากประโยคให้เป็นคำศัพท์ต่าง ๆ (Word Segmentation) การแปลงคำศัพท์ให้อยู่ในรูปของรากศัพท์ (Stemming) การกำจัดคำที่ไม่มี ความหมาย (Stop-word Removal) การสกัดหน่วยคำ (Feature Extraction) และการคัดเลือกคุณลักษณะ (Feature Selection) ในส่วนของการวิเคราะห์ความรู้สึกนั้นจะทำการจำแนกข้อความออกเป็นข้อารมณ์ด้วยเทคนิควิธีการจำแนกข้อมูล (Classification Technique) ต่าง ๆ เช่น Naïve Bayes, Support Vector Machine (SVM), Maximum Entropy [11] ได้มีการศึกษาวิจัยอย่างแพร่หลาย เช่น [12] ได้ศึกษาประสิทธิภาพของการวิเคราะห์ความรู้สึกจากเนื้อหาข่าวการเมืองภาษาไทย ด้วยเทคนิควิธี Naïve Bayes, Support Vector Machine (SVM) และ K-Nearest Neighbor (K-NN) พบว่าการจำแนกข้อมูลด้วย Naïve Bayes ให้ความแม่นยำมากที่สุด ใน [13] ได้รายงานผลการเปรียบเทียบประสิทธิภาพการจำแนกข้อความคิดเห็นเกี่ยวกับสินค้าจากเว็บไซต์ amazon.com ด้วยเทคนิควิธี Naïve Bayes, Support Vector Machine (SVM) และ Random Forest พบว่าในการวิเคราะห์ระดับประโยค Random Forest มีประสิทธิภาพมากที่สุด แต่ในระดับประเภตสินค้า Naïve Bayes และ Support Vector Machine (SVM) มีประสิทธิภาพมากกว่า

เทคนิควิธีการรวมกลุ่มเพื่อจำแนกข้อมูล (Ensemble) เป็นเทคนิคที่ใช้วิธีการสร้างตัวแบบการจำแนก (Model) ที่หลากหลายมาใช้จำแนกข้อมูล แล้วสรุปผลโดยดูจากผลการจำแนกส่วนมากของตัวแบบเหล่านั้น เทคนิควิธีการรวมกลุ่มจำแนกข้อมูลแบ่งออกเป็น 3 ประเภท ได้แก่ 1) Vote Ensemble เป็นการสร้างตัวแบบจากข้อมูลฝึกฝน (Training Data) ชุดเดียวกันด้วยเทคนิควิธีจำแนกข้อมูลที่แตกต่างกัน 2) Bootstrap Aggregating (Bagging) เป็นการสร้างตัวแบบการจำแนกจากเทคนิควิธีเดียวกัน แต่ใช้ข้อมูลฝึกฝนคนละชุดกัน และ 3) Random Forest เป็นการสร้างตัวแบบจากเทคนิควิธีเดียวกัน ใช้ข้อมูลฝึกฝนคนละชุดกัน และเลือกใช้คุณลักษณะของข้อมูลต่างกัน เทคนิควิธีการรวมกลุ่มเพื่อจำแนกข้อมูลจัดเป็นเทคนิควิธีที่มีประสิทธิภาพในการจำแนกสูง ดังจะเห็นได้จาก [14–16] ที่เปรียบเทียบประสิทธิภาพการใช้เทคนิควิธีการรวมกลุ่มเพื่อจำแนกข้อมูลกับเทคนิควิธีอื่น ๆ พบว่ามีประสิทธิภาพสูงกว่า


ในงานวิจัยนี้ผู้วิจัยจึงมีความสนใจที่จะทำการศึกษาเปรียบเทียบประสิทธิภาพการวิเคราะห์ความพึงพอใจของผู้เรียนที่มีต่อการจัดการเรียนการสอน ด้วยกระบวนการวิเคราะห์ความรู้สึกโดยใช้เทคนิคการรวมกลุ่มเพื่อจำแนกข้อมูล 3 ประเภทดังกล่าว สำหรับแปลผลความคิดเห็นและใช้เป็นข้อมูลให้ผู้สอนนำไปบริหารจัดการชั้นเรียนต่อไป

วัตถุประสงค์การวิจัย

เพื่อเปรียบเทียบประสิทธิภาพการวิเคราะห์ความพึงพอใจเกี่ยวกับการจัดการเรียนการสอน ด้วยกระบวนการวิเคราะห์ความรู้สึกโดยใช้เทคนิคการรวมกลุ่มเพื่อจำแนกข้อมูล

วิธีการวิจัย


ในงานวิจัยนี้แบ่งกระบวนการออกเป็น 3 ส่วน ได้แก่ การเตรียมข้อมูล (Preprocessing) การเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลรอบแรก (First Round Classification) และการเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลรอบสอง (Second Round Classification) แสดงดังภาพที่ 1



ภาพที่ 1 กระบวนการวิจัย

ชุดข้อมูลที่ใช้ในการวิจัย

ชุดข้อมูลที่ใช้ในการวิจัยครั้งนี้เป็นความคิดเห็นของนักเรียนนักศึกษาวิทยาลัยเทคนิคเลย ที่มีการจัดการเรียนการสอนในรายวิชาต่าง ๆ ตั้งแต่ปีการศึกษา 2560 จนถึงปีการศึกษา 2561 จำนวน 1,577 ข้อความ ได้จากฐานข้อมูลระบบประเมินการจัดการเรียนการสอนของวิทยาลัย ผู้วิจัยได้ทำการจำแนกข้อความออกเป็น 2 ข้อคือ ฟังพอใจจำนวน 1,037 ข้อความ และไม่ฟังพอใจจำนวน 540 ข้อความ ดังภาพที่ 2



ภาพที่ 2 ลักษณะชุดข้อมูลที่ใช้ในงานวิจัย

การเตรียมข้อมูล (Preprocessing)

ในขั้นตอนนี้ได้ทำการตรวจสอบและเตรียมข้อความ (Text Cleaning) โดยแก้ไขคำผิด กำจัดอักขระพิเศษ ข้อมูลซ้ำ ข้อความที่ไม่สมบูรณ์และชื่อเฉพาะต่าง ๆ จากนั้นทำการแยกคำศัพท์ออกจากประโยค (Word Segmentation) โดยใช้วิธีการตัดคำแบบเหมือนมากที่สุด (Maximum Matching) แล้วกำจัดคำที่ไม่มีความหมาย สกัดหน่วยคำและเลือก คำคุณลักษณะ (Feature Extraction and Selection) เมื่อผ่านกระบวนการดังกล่าวแล้ว สามารถสกัดคำได้จำนวน 1,542 คำ และเนื่องจากชุดข้อมูลมีลักษณะไม่สมดุลดังแสดงในภาพที่ 2 จึงได้ปรับสมดุลข้อมูลด้วยวิธีการสุ่มเพิ่ม ตัวอย่างกลุ่มน้อย (SMOTE) ในอัตราส่วน 190% จนได้ข้อมูลในแต่ละชั้นเท่ากัน คือชั้นละ 1,037 ข้อความ รวมเป็น 2,074 ข้อความ สำหรับใช้สร้างตัวแบบการจำแนกข้อมูลเพื่อเปรียบเทียบประสิทธิภาพต่อไป

การทดสอบเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลรอบแรก (First Round Classification)

การทดสอบจำแนกข้อมูลรอบแรกนี้เลือกใช้เทคนิควิธีมาตรฐานที่ได้รับความนิยม 3 วิธี ได้แก่ Decision Tree, Naïve Bayes และ K-Nearest Neighbor (K-NN) ทำการทดสอบด้วยซอฟต์แวร์ RapidMiner Studio Education ทดสอบ ประสิทธิภาพด้วยวิธีการ K – Fold Cross Validation โดยกำหนดค่า K เท่ากับ 10 ใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) ค่า F-measure แผนภูมิ ROC (Receiver operating characteristic curve) และ AUC (Area Under Curve) ในการเปรียบเทียบประสิทธิภาพ

การทดสอบเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลรอบสอง (Second Round Classification)

การทดสอบจำแนกข้อมูลรอบนี้ใช้เทคนิควิธีการรวมกลุ่มเพื่อจำแนกข้อมูลทั้ง 3 ประเภท ได้แก่ Vote, Bagging และ Random Forest สำหรับเทคนิควิธีการจำแนกข้อมูลที่จะใช้ในการรวมกลุ่มนั้น เลือกใช้เทคนิควิธี มาตรฐานจากการทดสอบรอบแรก โดยการรวมกลุ่มแบบ Vote ใช้เทคนิควิธีทั้ง 3 แบบ ส่วนการรวมกลุ่มแบบ Bagging ใช้เทคนิควิธี Naïve Bayes เนื่องจากมีประสิทธิภาพในการจำแนกมากที่สุดจากผลการทดสอบรอบแรก ส่วนการ รวมกลุ่มแบบ Random Forest ใช้เทคนิควิธี Decision Tree อยู่แล้ว ซอฟต์แวร์และชุดข้อมูลที่ใช้ในการทดสอบ รวมถึง การตั้งค่าพารามิเตอร์ต่าง ๆ ของแต่ละเทคนิค และการทดสอบประสิทธิภาพดำเนินการเช่นเดียวกับการทดสอบรอบแรก

ผลการวิจัย

การเปรียบเทียบประสิทธิภาพการจำแนกข้อมูลในงานวิจัยนี้ใช้ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) ค่า F-measure แผนภูมิ ROC (Receiver operating characteristic curve) และ AUC (Area Under Curve) โดยคำนวณได้จากสมการต่อไปนี้

$$\text{ความถูกต้อง (Accuracy)} = \frac{TP + TN}{TP + TN + FP + FN}$$

$$\text{ความแม่นยำ (Precision)} = \frac{TP}{TP + FP}$$

$$\text{ความระลึก (Recall)} = \frac{TP}{TP + FN}$$

$$\text{F-measure} = \frac{2 \times (\text{Precision} \times \text{Recall})}{(\text{Precision} + \text{Recall})}$$

$$\text{TN rate} = \frac{TN}{TN + FP}$$

$$\text{TP rate} = \frac{TP}{TP + FN}$$

$$\text{AUC} = \frac{\text{TP rate} + \text{TN rate}}{2}$$


ผลการทดสอบประสิทธิภาพการจำแนกข้อมูลรอบแรก (First Round Classification)

การทดสอบประสิทธิภาพการจำแนกข้อมูลความคิดเห็นของผู้เรียนที่มีต่อการจัดการเรียนการสอนในรอบแรก โดยใช้เทคนิควิธีการจำแนกแบบ Decision Tree, Naïve Bayes และ K-NN ได้ผลดังนี้

ตารางที่ 1 ผลการทดสอบประสิทธิภาพการจำแนกข้อมูลรอบแรก

Algorithm	Accuracy (%)	Precision (%)	Recall (%)	F-measure (%)
Decision Tree	83.56	84.40	83.55	83.97
Naïve Bayes	86.88	86.99	86.89	86.94
K-NN	81.24	85.27	81.25	83.21

จากตารางที่ 1 พบว่าตัวแบบที่สร้างจากเทคนิควิธี Decision Tree มีค่าความถูกต้อง 83.56% ค่าความแม่นยำ 84.40% ค่าความระลึก 83.55% F-measure 83.97% ตัวแบบที่สร้างจากเทคนิควิธี Naïve Bayes มีค่าความถูกต้อง 86.88% ค่าความแม่นยำ 86.99% ค่าความระลึก 86.89% F-measure 86.94% และตัวแบบที่สร้างจากเทคนิควิธี K-NN มีค่าความถูกต้อง 81.24% ค่าความแม่นยำ 85.24% ค่าความระลึก 81.25% F-measure 83.21% และเมื่อเปรียบเทียบประสิทธิภาพของตัวแบบด้วยแผนภูมิ ROC และค่า AUC ได้ผลดังนี้



ภาพที่ 3 แผนภูมิ ROC เปรียบประสิทธิภาพของตัวแบบการจำแนกข้อมูลในการทดสอบรอบแรก

จากภาพที่ 3 จะเห็นได้ว่าเส้นกราฟประสิทธิภาพของตัวแบบที่สร้างจากเทคนิควิธี Naïve Bayes มีแนวโน้มเข้าใกล้ค่า 1 มากที่สุด (AUC = 0.87) รองลงมาเป็นเส้นกราฟของตัวแบบที่สร้างจากเทคนิควิธี Decision Tree (AUC = 0.84) และเส้นกราฟของตัวแบบที่สร้างจากเทคนิควิธี K-NN (AUC=0.81) ตามลำดับ


ผลการทดสอบประสิทธิภาพการจำแนกข้อมูลรอบที่สอง (Second Round Classification)

การทดสอบประสิทธิภาพการจำแนกข้อมูลความคิดเห็นของผู้เรียนที่มีต่อการจัดการเรียนการสอนรอบที่ 2 ด้วยเทคนิควิธีการจำแนกแบบ Vote ensemble, Bagging และ Random Forest ได้ผลดังตารางที่ 2 พบว่าตัวแบบที่สร้างจากเทคนิควิธี Vote มีค่าความถูกต้อง 89.06% ค่าความแม่นยำ 90.01% ค่าความระลึก 89.06% F-measure 89.53% ตัวแบบที่สร้างจากเทคนิควิธี Bagging มีค่าความถูกต้อง 86.35% ค่าความแม่นยำ 86.47% ค่าความระลึก 86.35% F-measure 86.41% และตัวแบบที่สร้างจากเทคนิควิธี Random Forest มีค่าความถูกต้อง 79.95% ค่าความแม่นยำ 81.29%

ค่าความระลึก 79.96% F-measure 80.62% เมื่อเปรียบเทียบประสิทธิภาพของ ตัวแบบด้วยแผนภูมิ ROC และค่า AUC ได้ผลดังนี้

ตารางที่ 2 ผลการทดสอบประสิทธิภาพการจำแนกข้อมูลรอบที่ 2

Algorithm	Accuracy (%)	Precision (%)	Recall (%)	F-measure (%)
Vote	89.06	90.01	89.06	89.53
Bagging	86.35	86.47	86.35	86.41
Random Forest	79.95	81.29	79.96	80.62



ภาพที่ 4 แผนภูมิ ROC เปรียบประสิทธิภาพของตัวแบบการจำแนกข้อมูลในการทดสอบรอบที่ 2

จากภาพที่ 4 จะเห็นได้ว่าเส้นกราฟประสิทธิภาพของตัวแบบที่สร้างจากเทคนิควิธี Vote มีแนวโน้มเข้าใกล้ค่า 1 มากที่สุด (AUC = 0.89) รองลงมาเป็นเส้นกราฟของตัวแบบที่สร้างจากเทคนิควิธี Bagging (AUC = 0.86) และเส้นกราฟของตัวแบบที่สร้างจากเทคนิควิธี Random Forest (AUC=0.80) ตามลำดับ

อภิปรายและสรุปผลการวิจัย

เมื่อพิจารณาผลการทดสอบประสิทธิภาพตัวแบบที่สร้างจากเทคนิควิธีทั้ง 6 วิธี พบว่าตัวแบบที่สร้างจากเทคนิควิธี Vote มีประสิทธิภาพมากที่สุด รองลงมาเป็นตัวแบบที่สร้างจากเทคนิควิธี Naïve Bayes ตัวแบบที่สร้างจากเทคนิควิธี Bagging ตัวแบบที่สร้างจากเทคนิควิธี Decision Tree ตัวแบบที่สร้างจากเทคนิควิธี K-NN และตัวแบบที่สร้างจากเทคนิควิธี Random Forest ตามลำดับ แสดงรายละเอียดดังตารางที่ 3 และแผนภูมิ ROC ในภาพที่ 5

สาเหตุที่เทคนิควิธีแบบ Vote มีประสิทธิภาพมากที่สุด เนื่องจากเทคนิควิธีนี้จะเลือกผลลัพธ์จากตัวแบบต่าง ๆ ซึ่งสร้างชุดข้อมูลฝึก (training set) ชุดเดียวกันที่เหมือนกันมากที่สุดมาสรุปเป็นผลการจำแนกข้อมูล ทำให้ตัวแบบสำหรับจำแนกข้อมูลมีความหลากหลาย ครอบคลุม


เป็นที่น่าสังเกตว่าตัวแบบที่สร้างจากเทคนิควิธี K-NN ถึงแม้ว่าประสิทธิภาพโดยรวมเมื่อพิจารณาจากค่าความถูกต้อง ค่าความระลึก F-measure และ AUC จะมีประสิทธิภาพอยู่ในลำดับที่ 5 แต่มีความแม่นยำสูงกว่าตัวแบบที่สร้าง

จากเทคนิควิธี Decision Tree ในลำดับที่ 4 (K-NN 85.27% และ Decision Tree 84.40%) แสดงให้เห็นว่าการจำแนกข้อมูลด้วยเทคนิควิธีแบบ K-NN มีคุณภาพมากกว่า

เมื่อพิจารณาแผนภูมิ ROC ในภาพที่ 5 จะเห็นได้ว่าตัวแบบที่สร้างจากเทคนิควิธี Vote นอกจากจะมีประสิทธิภาพดีที่สุดแล้ว ยังสามารถให้ประสิทธิภาพได้ดีในปริมาณข้อมูลฝึกฝนที่น้อยกว่าตัวแบบอื่น ๆ แต่ทั้งนี้เมื่อปริมาณข้อมูลมากขึ้น ประสิทธิภาพของตัวแบบทั้งหมดมีแนวโน้มใกล้เคียงกัน

ตารางที่ 3 ผลการเปรียบเทียบประสิทธิภาพการจำแนกข้อมูล

Rank	Algorithm	Accuracy (%)	Precision (%)	Recall (%)	F-measure (%)	AUC
1	Vote	89.06	90.01	89.06	89.53	0.89
2	Naïve Bayes	86.88	86.99	86.89	86.94	0.87
3	Bagging	86.35	86.47	86.35	86.41	0.86
4	Decision Tree	83.56	84.40	83.55	83.97	0.84
5	K-NN	81.24	85.27	81.25	83.21	0.81
6	Random Forest	79.95	81.29	79.96	80.62	0.80



ภาพที่ 5 แผนภูมิ ROC เปรียบประสิทธิภาพของตัวแบบการจำแนกข้อมูล

จากผลการทดสอบแสดงให้เห็นชัดเจนว่าการวิเคราะห์ความพึงพอใจในการจัดการเรียนรู้จากความคิดเห็นของผู้เรียนด้วยเทคนิควิธีการแบบ Vote เหมาะสมที่สุด เพื่อนำผลการวิเคราะห์ไปใช้ในการจัดการเรียนการสอน และบริหารจัดการชั้นเรียนต่อไป อย่างไรก็ตามการวิจัยครั้งนี้เป็นการแปลผลความคิดเห็นเป็นข้อความพึงพอใจเพียงอย่างเดียว ซึ่งในข้อมูลความคิดเห็นของผู้เรียนประกอบไปด้วยข้อเสนอแนะและความพึงพอใจ หากมีการศึกษาเพื่อแยกข้อเสนอแนะและความพึงพอใจออกจากกันด้วยวิธีการต่าง ๆ เช่น การทำเหมืองความคิดเห็น (Opinion Mining) จะช่วยให้ผู้สอนได้ผลการวิเคราะห์ที่ครอบคลุมและเป็นประโยชน์มากขึ้น

เอกสารอ้างอิง

1. Balahadia FF, Fernando MCG, Juanatas IC. Teacher's performance evaluation tool using opinion mining with sentiment analysis. In: 2016 IEEE Region 10 Symposium (TENSYP). 2016. p. 95–98.
2. Ravi K, Ravi V. A survey on opinion mining and sentiment analysis: tasks, approaches and applications. Knowledge-Based Systems. 2015;89:14–46.
3. Hussein DME-DM. A survey on sentiment analysis challenges. Journal of King Saud University - Engineering Sciences. 2018;30(4):330–338.
4. Songpan W. The analysis and prediction of customer review rating using opinion mining. In: Proceeding of the 2017 IEEE 15th International Conference on Software Engineering Research, Management and Applications (SERA). 2017. p. 71–77.
5. Pinmuang N, Jaree T. Classify Thai opinions on online media using text mining. Journal of Science & Technology MSU [Internet]. 2018;37(3). Available from: http://journal.msu.ac.th/upload/articles/article2153_38473.pdf. Thai.
6. Ravisuda T, Nives J. Thai Sentiment Analysis of Product Review Online Using Support Vector Machine. Engineering Journal of Siam University. 2017;18(1). Thai.
7. Pattaraporn C, Wararat S, Somjit A, Saiyan S. Analysis of Affecting Factors to Customer Reviews using Opinion Mining. In: Proceeding of the Thirteenth National Conference on Computing and Information Technology. 2017. p. 44–50. Thai.
8. Kechaou Z, Ammar MB, Alimi AM. Improving e-learning with sentiment analysis of users' opinions. In: Proceeding of the 2011 IEEE Global Engineering Education Conference (EDUCON). 2011. p. 1032–1038.
9. Munezero M, Montero CS, Mozgovoy M, Sutinen E. Exploiting Sentiment Analysis to Track Emotions in Students' Learning Diaries. In: Proceedings of the 13th Koli Calling International Conference on Computing Education Research [Internet]. New York, NY, USA: ACM; 2013. p. 145–152. (Koli Calling '13). Available from: <http://doi.acm.org/10.1145/2526968.2526984>
10. Rani S, Kumar P. A Sentiment Analysis System to Improve Teaching and Learning. Computer. 2017 May;50(5): 36–43.
11. Barnaghi P, Ghaffari P, Breslin JG. Opinion mining and sentiment polarity on twitter and correlation between events and sentiment. In: Proceeding of the 2016 IEEE Second International Conference on Big Data Computing Service and Applications (BigDataService). IEEE; 2016. p. 52–57.
12. Sukhum K, Nitsuwat S, Haruechaiyasak C. Opinion detection in Thai political news columns based on subjectivity analysis. In: Proceeding of the 7th International Conference on Computing and Information Technology. 2011.
13. Fang X, Zhan J. Sentiment analysis using product review data. Journal of Big Data. 2015;2(1):5.



14. Puttida S, Charun S, Thanrat S. The Comparison of Data Classification Efficiency by using ENSEMBLE Technique for Analysis of Factors Affecting on the National Educational Test Results of Vocational Education (V-NET). In: Proceeding of the 13th National Conference on Computing and Information Technology. p. 674–679. Thai.
15. Araque O, Corcuera-Platas I, Sánchez-Rada JF, Iglesias CA. Enhancing deep learning sentiment analysis with ensemble techniques in social applications. *Expert Systems with Applications*. 2017;77:236–246.
16. Supathet S, Phayung M, Piyanoot V. Ensemble for Highly Imbalanced Text Classification base in Deep Learning with Feature Selection and Data Balancing Techniques. In: Proceeding of the 13th National Conference on Computing and Information Technology. p. 20–25.