

การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึก



วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาครุศาสตรมหาบัณฑิต
สาขาวิชาวิธีวิทยาการพัฒนานวัตกรรมการศึกษา ภาควิชาวิจัยและจิตวิทยาการศึกษา

คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย

ปีการศึกษา 2565

ลิขสิทธิ์ของจุฬาลงกรณ์มหาวิทยาลัย

DEVELOPMENT OF TEACHERS' EMOTIONAL ANALYSIS MODEL IN CLASSROOM VIA
SPEECH RECOGNITION USING DEEP LEARNING



A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Education in Methodology for Innovation Development in
Education

Department of Educational Research and Psychology

FACULTY OF EDUCATION

Chulalongkorn University

Academic Year 2022

Copyright of Chulalongkorn University

หัวข้อวิทยานิพนธ์	การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการ รู้จำคำพูดโดยใช้การเรียนรู้เชิงลึก
โดย	นายจิระเมศร์ รุจิกรหิรัญย์
สาขาวิชา	วิธีวิทยาการพัฒนานวัตกรรมการศึกษา
อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก	ผู้ช่วยศาสตราจารย์ ดร.สิวะโชติ ศรีสุทธิยากร

คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย อนุมัติให้หัวข้อวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่งของ
การศึกษาตามหลักสูตรปริญญาครุศาสตรมหาบัณฑิต

.....	คณบดีคณะครุศาสตร์
(รองศาสตราจารย์ ดร.ศิริเดช สุขิวะ)	
คณะกรรมการสอบวิทยานิพนธ์	
.....	ประธานกรรมการ
(รองศาสตราจารย์ ดร.ศจีมาจ ฦ วิเชียร)	
.....	อาจารย์ที่ปรึกษาวิทยานิพนธ์หลัก
(ผู้ช่วยศาสตราจารย์ ดร.สิวะโชติ ศรีสุทธิยากร)	
.....	กรรมการ
(ผู้ช่วยศาสตราจารย์ ดร.กนิษฐ์ ศรีเคลือบ)	

CHULALONGKORN UNIVERSITY

จิระเมศร์ รุจิกรทิริณย์ : การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึก (DEVELOPMENT OF TEACHERS' EMOTIONAL ANALYSIS MODEL IN CLASSROOM VIA SPEECH RECOGNITION USING DEEP LEARNING) อ.ที่ปรึกษาหลัก : ผศ. ดร.สิวะโชติ ศรีสุทธิยากร

งานวิจัย เรื่อง การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดด้วยการเรียนรู้เชิงลึกมีวัตถุประสงค์ (1) เพื่อพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก และ (2) เพื่อวิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนที่ได้พัฒนาขึ้น ข้อความที่ใช้ในการพัฒนาโมเดลมีจำนวนทั้งสิ้น 23,974 ข้อความ เก็บรวบรวมจากแหล่งข้อมูล 2 แหล่ง ได้แก่ วิดีทัศน์การสอนของครูในชั้นเรียนรายวิชาสังคมศึกษา ศาสนาและวัฒนธรรม จำนวน 11 วิดีทัศน์ที่ได้รับการแปลงเป็นข้อความผ่านกระบวนการรู้จำคำพูด และฐานข้อมูล Wisersight Sentiment Analysis ในการพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียน ผู้วิจัยใช้โมเดลการเรียนรู้ของเครื่อง 3 กลุ่ม ได้แก่ กลุ่มที่ 1 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง จำนวน 4 โมเดล กลุ่มที่ 2 โมเดลที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder และมีกรวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่องจำนวน 4 โมเดล และกลุ่มที่ 3 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้เชิงลึก จำนวน 2 โมเดล

ผู้วิจัยดำเนินการจัดเตรียมข้อความให้อยู่ในรูปแบบที่พร้อมสำหรับการนำไปวิเคราะห์ด้วยการสกัดคุณลักษณะจากข้อความด้วยวิธี TF-IDF และมีการลดจำนวนคุณลักษณะด้วยกระบวนการ Principle Component Analysis (PCA) แก้ไขปัญหาความไม่สมดุลกันของจำนวนข้อมูลในตัวแปรตามจึงใช้เทคนิค SMOTE และโมเดลทั้งสามกลุ่มมีการปรับแต่งไฮเปอร์พารามิเตอร์ของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยวิธีการตรวจสอบไขว้ (Cross validation) การเปรียบเทียบประสิทธิภาพของโมเดลพิจารณาจากค่าดัชนี ความถูกต้อง ความแม่นยำ และความไวในการจำแนกกลุ่ม ผลการวิจัยที่ได้ พบว่า

1. จากทั้ง 3 กลุ่ม พบว่า โมเดล LSTM ที่มีการปรับไฮเปอร์พารามิเตอร์มีค่าความถูกต้องของโมเดลที่ใช้ในการจำแนกอารมณ์ครูที่ดีที่สุด ร้อยละ 71 โดยมีความแม่นยำและความไวในการจำแนกกลุ่มทั้งสามประเภทโดยภาพรวมได้ดีที่สุด

2. โมเดลกลุ่มที่ 1 โมเดล Support Vector Machine ที่มีการกำหนดไฮเปอร์พารามิเตอร์ มีค่าความถูกต้องในการจำแนกอยู่ที่ 66% สำหรับโมเดลกลุ่มที่ 2 ที่ใช้โมเดล Multilingual Universal Sentence Encoder ในการสกัดคุณลักษณะควบคู่กับการจำแนกด้วยการเรียนรู้ของเครื่องของโมเดล Support Vector Machine และ โมเดล Logistic Regression ที่ปรับไฮเปอร์พารามิเตอร์แล้ว ทั้งสองโมเดลจำแนกมีค่าความถูกต้องใกล้เคียงกัน ประมาณร้อยละ 68 และโมเดลในกลุ่มที่ 3 พบว่า โมเดล LSTM มีค่าความถูกต้องในการจำแนกสูงที่สุด ร้อยละ 71 ซึ่งสูงที่สุดเมื่อเทียบกับทุกโมเดล

สาขาวิชา วิธีวิทยาการพัฒนานวัตกรรมทางการศึกษา ลายมือชื่อนิสิต

ปีการศึกษา 2565 ลายมือชื่อ อ.ที่ปรึกษาหลัก

6380027227 : MAJOR METHODOLOGY FOR INNOVATION DEVELOPMENT IN EDUCATION

KEYWORD: Teachers' Emotion, Machine Learning, Deep Learning, Sentiment Analysis, Speech Recognition

Jiramate Rujikornhirun : DEVELOPMENT OF TEACHERS' EMOTIONAL ANALYSIS MODEL IN CLASSROOM VIA SPEECH RECOGNITION USING DEEP LEARNING. Advisor: Asst. Prof. Siwachoat Srisuttiyakorn, Ph.D.

This study has 2 objectives. (1) To create a model for analysing teacher emotions in the classroom using machine learning and deep learning approaches to analyse the sentiment of text derived from speech recognition. (2) To assess the model's applicability for analysing teacher emotions in the classroom. A total of 23,974 text samples from two sources were used in the study. These contained 11 films of teachers teaching social studies, religion, and culture lessons that were transcribed using speech recognition technology and then turned into text. Additionally, data from the Wisersight Sentiment Analysis database was utilised.

Three categories of machine learning models were used by the researchers: Group 1 consists of four models that preprocess data before analysis and categorise teacher emotions using machine learning techniques; Group 2 consists of four models that extract features from text using autoencoders and categorise teacher emotions using deep learning techniques; and Group 3 consists of two models that preprocess data before analysis and categorise teacher emotions using deep learning techniques.

By using TF-IDF (Term Frequency-Inverse Document Frequency) to extract features from the text, the researchers prepared the text data for analysis. They also used Principal Component Analysis (PCA) to minimise the dimensionality of the feature set. They used the SMOTE approach to address the problem of unbalanced data. All three groups of models also underwent cross-validation hyperparameter tuning.

On the basis of accuracy, precision, recall, and F1-score, the models' performances were compared in the study. These are the conclusions:

1. It was discovered that, out of the three groups, LSTM models with tuned hyperparameters had the highest accuracy for classifying emotions, coming in at 71%. Overall, these models performed well in terms of accuracy and F1-score.

2. In Group 1, Support Vector Machine (SVM) models with tuned hyperparameters achieved an accuracy rate of 66% for emotion classification. In Group 2, which combined SVM and Logistic Regression models with tuned hyperparameters for feature extraction, both models demonstrated similar performance with an approximate accuracy rate of 68%. In Group 3, LSTM models outperformed other models with the highest accuracy rate of 71%.

CHULALONGKORN UNIVERSITY

Field of Study: Methodology for Innovation Development in Education Student's Signature

Academic Year: 2022 Advisor's Signature

กิตติกรรมประกาศ

ขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.สิวะโชติ ศรีสุทธิยากร อาจารย์ที่ปรึกษา ผู้ที่ให้ความรู้ในการเรียนและการทำวิจัย ตั้งแต่เริ่มต้นทำวิทยานิพนธ์ คอยให้คำแนะนำและช่วยเหลือเมื่อเจอข้อบกพร่องต่าง ๆ จนงานวิจัยสำเร็จ อาจารย์เป็นผู้สร้างแรงบันดาลใจและเปิดโลกทัศน์ในการเรียนรู้เกี่ยวกับสถิติและวิทยาการข้อมูล

ทางการศึกษาตั้งแต่สมัยเรียนระดับบัณฑิตศึกษา อาจารย์เป็นตัวอย่างครูผู้พัฒนาตนเอง ขวนขวายหาความรู้อยู่เสมอและไม่หยุดที่จะเรียนรู้เพราะหาก “อยากรู้อะไร ให้ถาม Google”

ขอบพระคุณ รองศาสตราจารย์ ดร.ศจีมาศ ณ วิเชียร และผู้ช่วยศาสตราจารย์ ดร.กนิษฐ์ ศรีเคลือบ ที่ให้ความกรุณาเป็นกรรมการสอบวิทยานิพนธ์ ให้คำแนะนำพร้อมทั้งข้อเสนอแนะในการปรับปรุงวิทยานิพนธ์ให้ดียิ่งขึ้น

ขอบพระคุณผู้ช่วยศาสตราจารย์ ดร.กนิษฐ์ ศรีเคลือบ อาจารย์ ดร.สุรศักดิ์ เก้าเอี้ยน อาจารย์ ดร. ประภาศิริ รัชชประภาพรกุล ผู้ช่วยศาสตราจารย์ ดร.ชยุตม์ ภิรมย์สมบัติ และคณะอาจารย์ในสาขาวิชาวิจัยและจิตวิทยาการศึกษาทุกท่านที่คอยให้ความรู้ คำแนะนำต่าง ๆ ในการศึกษา นอกจากความรู้ความสามารถที่อาจารย์ร่วมกันขัดเกลาและมอบให้แก่ข้าพเจ้าแล้วคณะอาจารย์ยังเป็นแบบอย่างที่ดีในการอุทิศตนเพื่อพัฒนาผู้เรียนอีกด้วย

ขอขอบคุณตัวอย่างทุก ๆ คนที่ได้ให้ความร่วมมือในการเก็บข้อมูลงานวิจัย ทุกคนได้มอบวิดิทัศน์ให้ด้วยความเต็มใจ นับเป็นแรงผลักดันที่ดีที่ทำให้ข้าพเจ้าอยากพัฒนาโมเดลให้คุ้มกับความปรารถนาดีที่ทุกคนมอบให้

ขอบคุณอนุรักษ์ พลากร โยธณัฐ พี่ประภาพรธรรม พี่กัญญิมาภรณ์ พี่ดวงฤทัย รวมถึงพี่ ๆ และเพื่อน ๆ ในสาขาทั้งปริญญาโทและปริญญาเอกที่คอยให้คำแนะนำ แลกเปลี่ยนความรู้ ร่วมทุกข์และร่วมสุขในการเรียน แม้ข้าพเจ้าจะอยู่คนละกลุ่มความเชี่ยวชาญเฉพาะแต่ข้าพเจ้าก็ได้รับการดูแลและได้คำแนะนำในการเรียนเป็นอย่างดี

ขอบคุณครอบครัวตัวกลมและเพื่อน ๆ ครุศาสตร์ ที่คอยเป็นกำลังใจในการเรียนครั้งนี้ แม้มันจะยากและเคยท้อแท้หลาย ๆ ครั้ง แต่เมื่อเห็นข้อความของเพื่อน ความท้อแท้สิ้นหวังเหล่านั้นก็บรรเทาลงเพราะเมื่อผ่านเพื่อนมาได้ อะไร ๆ ก็ไม่ใช่เรื่องยาก

ขอบคุณแม่ พี่ชาย บาบูน ถึงเช่า ถึงเงินและน้องตุ้มที่คอยให้การสนับสนุนและเป็นกำลังใจที่ดีในการเรียนเสมอ ขาวที่แม่ทำให้กินและการดูแลเอาใจใส่ของแม่ คำชมและกำลังใจจากทุกคน เสียงร้องโวยวายของแมวมันเป็นกำลังใจที่ดีมากสำหรับการเรียนที่ต้องใช้ความพยายามและความอดทนสูง ทุกครั้งที่ผิดหวังหรือพยายามทำอะไรสักอย่าง อย่างเต็มที่แล้วแต่มันยังไม่สำเร็จ การกินอาหารอร่อย ๆ หรือได้ลูบคางแมวดัว้วนก็ช่วยได้

ขอบคุณเฟิร์ส นักเรียนทุกคน พี่ ๆ เพื่อนร่วมงานและครูกลุ่มสาระการเรียนรู้คณิตศาสตร์โรงเรียนบดินทรเดชา (สิงห์ สิงหเสนี) ที่คอยผลักดัน คอยให้กำลังใจและเปิดโอกาสให้ข้าพเจ้าได้ทำวิทยานิพนธ์อย่างเต็มที่ในช่วงปิดภาคเรียนของโรงเรียนจนกระทั่งสามารถสำเร็จได้

ขอบคุณตัวเองที่อดทนและพยายามมากพอจนสามารถบรรลุเป้าหมายที่ตนเองตั้งไว้ได้

จิระเมศร์ รุจิกรหิรัญญ์

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ค
บทคัดย่อภาษาอังกฤษ.....	ง
กิตติกรรมประกาศ.....	จ
สารบัญ.....	ฉ
สารบัญตาราง.....	ช
สารบัญภาพ.....	ฌ
บทที่ 1 บทนำ.....	1
ความเป็นมาและความสำคัญของปัญหา.....	1
คำถามวิจัย.....	4
วัตถุประสงค์การวิจัย.....	4
ขอบเขตการวิจัย.....	4
คำจำกัดความที่ใช้ในการวิจัย.....	5
ประโยชน์ที่คาดว่าจะได้รับ.....	5
บทที่ 2 เอกสารและงานวิจัยที่เกี่ยวข้อง.....	6
ตอนที่ 1 อารมณ์ครูในชั้นเรียน.....	6
ตอนที่ 2 การประมวลผลภาษาธรรมชาติ (Natural Language Processing).....	9
ตอนที่ 3 โมเดลการเรียนรู้ของเครื่องและงานวิจัยที่เกี่ยวข้อง.....	10
บทที่ 3 วิธีดำเนินการวิจัย.....	20
ตอนที่ 1 ตัวแปร การเก็บรวบรวมข้อมูล และกระบวนการก่อนการพัฒนาโมเดลการวิเคราะห์อารมณ์ ของครูในชั้นเรียน.....	20

ตอนที่ 2 การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทาง ข้อความโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก และวิเคราะห์ความเหมาะสมของ โมเดลที่พัฒนาขึ้น	27
บทที่ 4 ผลการวิเคราะห์ข้อมูล.....	39
ตอนที่ 1 ผลการวิเคราะห์บรรยายสภาพข้อความและการสกัดคุณลักษณะจากข้อความก่อน การ วิเคราะห์จำแนกอารมณ์ด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก	39
ตอนที่ 2 ผลการวิเคราะห์การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ ความรู้สึกผ่านข้อความที่ได้จากการวิเคราะห์การรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่อง	46
ตอนที่ 3 ผลการวิเคราะห์การประเมินประสิทธิภาพ ความเหมาะสมของโมเดลที่พัฒนาขึ้นและ การนำไปใช้ในการจำแนกอารมณ์ครูในชั้นเรียน	53
บทที่ 5 สรุปผลการวิจัย อภิปรายผล ข้อเสนอแนะ	58
สรุปผลการวิจัย	59
อภิปรายผลการวิจัย	62
ข้อเสนอแนะ	63
บรรณานุกรม.....	65
ภาคผนวก.....	73
ภาคผนวก ก	74
ภาคผนวก ข	80
ประวัติผู้เขียน	104

สารบัญตาราง

หน้า

ตารางที่ 1 ตัวอย่างของสถานการณ์และข้อความที่ได้จากกระบวนการรู้จำคำพูดจากครูในชั้นเรียนและตัวอย่างข้อความที่ได้จากฐานข้อมูล Wisersight Sentiment Analysis จำแนกตามประเภทของข้อความ....	21
ตารางที่ 2 แสดงจำนวนและเวลาของวีดิทัศน์การจัดการเรียนการสอนของครูในแต่ละระดับชั้น.....	25
ตารางที่ 3 แสดงกลุ่มของโมเดล ชื่อและตัวอย่างของโมเดลที่ใช้ในการจำแนกอารมณ์ครูในชั้นเรียน....	29
ตารางที่ 4 แสดงประสิทธิภาพในการจำแนกประเภทของข้อความ โดยมีความแตกต่างกันอันเนื่องมาจากความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ (df_min) และการสังเคราะห์ข้อความด้วยวิธีการ SMOTE....	42
ตารางที่ 5 แสดงประสิทธิภาพในการจำแนกประเภทของข้อความ โดยมีความแตกต่างกันอันเนื่องมาจากความผันแปรของคุณลักษณะที่เกิดขึ้นภายในโมเดลการทำนาย (Explained Variance Ratio)	43
ตารางที่ 6 รายละเอียดของโมเดลทั้งหมดที่ใช้ในการวิเคราะห์จำแนกอารมณ์จากข้อความ พร้อมทั้งตัวอย่างของโมเดลในการเขียนรายงานผลการวิเคราะห์	46
ตารางที่ 7 แสดงโมเดลและรายละเอียดการปรับไฮเพอร์พารามิเตอร์ในโมเดลและประสิทธิภาพในการจำแนกประเภทข้อความที่ได้จากการทำ cross validation จำนวน 5 รอบ ของกลุ่มโมเดลที่ 1 และ 2..	47
ตารางที่ 8 แสดงค่า (1) loss (2) acc (3) Validation loss และ (4) Validation acc ในแต่ละรอบของการฝึกฝนด้วยโมเดล LSTM มีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ.....	49
ตารางที่ 9 แสดงค่า (1) loss (2) acc (3) Validation loss และ (4) Validation acc ในแต่ละรอบของการฝึกฝนด้วยโมเดล BERT มีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ.....	52
ตารางที่ 10 แสดงประสิทธิภาพในการจำแนกของโมเดลที่ได้ปรับไฮเพอร์พารามิเตอร์แล้วกับ ชุดข้อมูลทดสอบโดยเรียงค่าความถูกต้องจากมากไปน้อย	53

สารบัญภาพ

	หน้า
ภาพที่ 1 แสดงสถาปัตยกรรมของโมเดล Multilingual Universal Sentence Encoder	12
ภาพที่ 2 แสดงสถาปัตยกรรมของหน่วยโมเดล LSTM.....	15
ภาพที่ 3 แสดงสถาปัตยกรรมของหน่วยโมเดล BERT.....	16
ภาพที่ 4 แสดงเส้นทางการเตรียมข้อมูลก่อนการวิเคราะห์ด้วยโมเดลการเรียนรู้ของเครื่อง.....	31
ภาพที่ 5 แผนภูมิแสดงสัดส่วนร้อยละของจำนวนข้อความแต่ละประเภท	40
ภาพที่ 6 แผนภูมิแสดงร้อยละของจำนวนข้อความแต่ละประเภทจำแนกตามชุดข้อความสำหรับการฝึกฝน (training dataset) และชุดข้อความสำหรับการทดสอบ (test dataset).....	41
ภาพที่ 7 แผนภูมิแสดงจำนวนชุดข้อความเดิม (raw dataset) จำแนกตามประเภทของข้อความ และชุดข้อความที่ได้จากกระบวนการ SMOTE.....	44
ภาพที่ 8 แนวโน้มของค่า loss และค่าความถูกต้อง ทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดล โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบและ 3 รอบ	48
ภาพที่ 9 แนวโน้มของค่า loss และค่าความถูกต้อง ทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดล โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบและ 3 รอบ	51
ภาพที่ 10 แนวโน้มค่าความถูกต้องในการจำแนกประเภทของข้อความของโมเดลต่าง ๆ ทั้ง 10 โมเดล.....	54
ภาพที่ 11 แนวโน้มของดัชนีในการจำแนกประเภทของข้อความของโมเดลต่าง ๆ	55
ภาพที่ 12 จำนวนและสัดส่วนร้อยละของข้อความที่ครูแสดงอารมณ์ในชั้นเรียนในแต่ละประเภท....	56
ภาพที่ 13 แสดงกราฟของข้อความที่ครูแสดงอารมณ์คู่กับช่วงเวลาในคาบเรียน	57

บทที่ 1

บทนำ

ความเป็นมาและความสำคัญของปัญหา

บรรยากาศในการชั้นเรียนเป็นกระบวนการที่เกิดขึ้นทั้งหมดระหว่างครูกับนักเรียนและระหว่างนักเรียนกับนักเรียน รวมไปถึงความสัมพันธ์ระหว่างบุคคล การใช้น้ำเสียงในการสื่อสาร ลักษณะและการบริหารจัดการชั้นเรียนของครู มุมมองความคาดหวังของครูที่มีต่อนักเรียน (Schmuck, 1978 อ้างถึงใน Zedan, 2010) การควบคุมบรรยากาศในชั้นเรียนให้เหมาะแก่การเรียนรู้เป็นการสร้างความพร้อมและเสริมสร้างความพร้อมในการเรียนรู้แก่นักเรียน (Ames, 1992) ซึ่งสอดคล้องกับ Bardach et al. (2020), Wang et al. (2020) และ Alonso-Tapia et al. (2020) ที่พบว่า ความแตกต่างของบรรยากาศในชั้นเรียนนั้นมีบทบาทต่อการสร้างแรงบันดาลใจของผู้เรียน ผลสัมฤทธิ์ของนักเรียน คุณลักษณะของผู้เรียนที่มีต่อครู ในปัจจุบันครูถือว่าเป็นผู้อำนวยการความสะดวก หรือเป็นผู้แนะแนวทางให้นักเรียนให้สามารถพัฒนาตนเองได้อย่างเต็มศักยภาพ และเป็นส่วนประกอบที่สำคัญของบรรยากาศในการเรียนรู้ของนักเรียนและมีความใกล้ชิดกับนักเรียนเป็นอย่างมาก (Hammer, 2007; อ้างถึงใน Novi, 2015)

บรรยากาศในชั้นเรียนที่ดีเกิดขึ้นจากการได้รับการสนับสนุนทางวิชาการและทางอารมณ์จากครู การแสดงออกและพฤติกรรมของครู ความสัมพันธ์อันดีระหว่างครูและนักเรียน (Shewark et al. 2018) ซึ่งจะเห็นได้ว่า อารมณ์ของครูในชั้นเรียนมีความสำคัญมากต่อการสร้างบรรยากาศที่ดีในชั้นเรียน มีอิทธิพลต่อสุขภาพ ความเป็นอยู่ที่ดีของนักเรียน (Taxer และ Frenzel, 2015) รวมไปถึงการเรียนรู้และพัฒนาการในการเรียนรู้ของนักเรียน (Klusmann et al., 2016) ซึ่งอารมณ์ของครูในชั้นเรียนสามารถแสดงออกได้หลากหลายวิธี เช่น คำพูดที่ใช้ในการเรียนการสอน น้ำเสียง สีหน้าแวตา ลักษณะท่าทางในการสอน

เนื่องจากการใช้คำพูดของครูในชั้นเรียนเป็นการสื่อสารทางอารมณ์ที่มีความสะดวก และรวดเร็วที่สุด รวมทั้งยังส่งผลกระทบต่อบรรยากาศในชั้นเรียนของทั้งครูและนักเรียน การได้รับทราบอารมณ์ของครูในชั้นเรียนหรือการสนับสนุนทางด้านอารมณ์เป็นสิ่งที่เกี่ยวข้องสัมพันธ์กับสิ่งอื่น เช่น ความฉลาดทางอารมณ์ (Emotional Intelligence) ซึ่งเป็นความสามารถในการรับรู้ลึกซึ้งของตนเองและผู้อื่น รวมทั้งความสามารถในการควบคุมอารมณ์ของตนเอง ซึ่งสอดคล้องกับ Adnan Atoum (2018) ที่พบว่า การสนับสนุนทางอารมณ์ของครอบครัว ครู เพื่อน และสังคม มีความสัมพันธ์เชิงบวกกับความฉลาดทางอารมณ์อย่างมีนัยสำคัญ เช่นเดียวกับกับ Iruloh & Ukaegbu

(2015) ที่นอกจากจะพบว่ามีความสัมพันธ์กับความฉลาดทางอารมณ์แล้ว ยังพบว่ามีสัมพันธ์เชิงบวกกับความฉลาดทางด้านสังคม (Social Intelligence) อีกด้วย รวมถึงการสนับสนุนทางอารมณ์ ส่งเสริมสมรรถนะที่เกี่ยวข้องกับสังคมของนักเรียน (Burchinal et al. 2008; Curby et al. 2009; Mashburn et al. 2008; อ้างอิงใน Pakarenin et al. 2020) จะเห็นได้ว่า หากครูได้ทราบอารมณ์ของตนเองในชั้นเรียนขณะที่ทำการสอน คงจะเป็นประโยชน์ต่อครูในการจัดการเรียนการสอนและเป็นประโยชน์ต่อนักเรียนอย่างยิ่ง

ในปัจจุบันการจัดการเรียนการสอนของครู และรูปแบบในการรับมือของครูที่มีต่อนักเรียน การเปลี่ยนแปลงไป จากเดิมที่เป็นผู้ถ่ายทอดวิชาความรู้ให้กับนักเรียนโดยตรง ได้มีการปรับเปลี่ยนบทบาทไปเป็นผู้ให้คำปรึกษา ผู้ที่กำกับดูแล หรือเป็นผู้ที่เชื่อมโยงความรู้ที่นักเรียนได้เรียนรู้ในชั้นเรียนไปสู่ชีวิตจริง ในทางปฏิบัติ ความสัมพันธ์ระหว่างครูและนักเรียนจะอยู่ในรูปของแนวทางการสอนที่แตกต่างกันออกไป ควรมีการปรับให้เข้ากับวิธีการเรียนรู้ของนักเรียนอย่างแท้จริง (Judith, 1997) ในทำนองเดียวกันกับ การเรียนรู้และการรับทราบมุมมองด้านอารมณ์ของนักเรียนในรุ่นหลัง ซึ่งนักเรียนที่เติบโตมาในโลกที่เชื่อมต่อกันอย่างไร้พรมแดน มีแนวความคิด ประสบการณ์และการรับรู้ทางอารมณ์จากครูที่แตกต่างกัน ฉะนั้น การที่ครูจะใช้คำในลักษณะเดิมหรือวิธีการสื่อสารกับนักเรียน ด้วยถ้อยคำเดิมในการสื่ออารมณ์อาจไม่เหมาะสมกับยุคสมัยของนักเรียนที่เปลี่ยนแปลงไป ประกอบกับในปัจจุบันที่มีการนำความก้าวหน้าทางเทคโนโลยีมาประยุกต์ใช้ในการประเมินตำแหน่งและวิทยฐานะข้าราชการครู ซึ่งหนึ่งในลักษณะของงานที่ปฏิบัติตามมาตรฐานตำแหน่งระดับการปฏิบัติที่คาดหวัง ด้านการจัดบรรยากาศที่ส่งเสริมและพัฒนาผู้เรียน นั่นคือ จะมีการจัดบรรยากาศที่เหมาะสม สอดคล้องกับความแตกต่างผู้เรียนเป็นรายบุคคล สร้างแรงบันดาลใจ ส่งเสริมและพัฒนาผู้เรียนให้เกิดกระบวนการคิด ทักษะชีวิต และทักษะอื่น ๆ (สำนักงาน ก.ค.ศ. กระทรวงศึกษาธิการ, 2564) โดยประเมินจากวิดิทัศน์การสอนของครูในชั้นเรียน และมีคณะกรรมการประเมินวิทยฐานะของผู้ขอมี/เลื่อนวิทยฐานะเป็นผู้ประเมิน ซึ่งแม้ว่าจะได้รับการอบรมการประเมินวิทยฐานะ และมีเกณฑ์การให้คะแนนที่ครอบคลุมแล้ว แต่เนื่องจากใช้บุคคลที่มีความแตกต่างทางความคิดและประสบการณ์ อาจส่งผลต่อผลการประเมินมีความคลาดเคลื่อน เอนเอียงหรือแตกต่างกัน หากสามารถหาเครื่องมือที่สามารถนำมาจำแนกอารมณ์ของครูในชั้นเรียนก็จะสามารถช่วยอำนวยความสะดวกและมีมาตรฐานในการประเมินที่ไปในทิศทางเดียวกัน

การเรียนรู้ในปัจจุบันที่นักเรียนสามารถเข้าถึงสื่อเทคโนโลยีได้อย่างกว้างขวาง รู้จักสิทธิและเสรีภาพของตนเองมากขึ้น ทำให้การจัดการเรียนการสอนของครูในชั้นเรียนเป็นสิ่งที่ต้องปรับหรือเปลี่ยน

ให้เหมาะสมกับบริบทของนักเรียนที่เปลี่ยนแปลงไป แต่เนื่องจาก พรบ.คุ้มครองข้อมูลส่วนบุคคล พ.ศ.2562 (PDPA) ที่จะต้องคำนึงถึงหลักความเป็นส่วนตัวและเสรีภาพในการแสดงออกของนักเรียน หากนำวิถีทัศน์การเรียนการสอนของนักเรียนมาวิเคราะห์หรือเผยแพร่เกี่ยวกับอารมณ์ของครูในชั้นเรียนที่มีทั้งอารมณ์เชิงลบและอารมณ์เชิงบวก จึงขัดต่อพระราชบัญญัติดังกล่าว แต่หากเป็นเพียงการนำไฟล์เสียงของครูที่ใช้ในการเรียนการสอนมาถอดเป็นข้อความ จากนั้นนำข้อความที่ได้ไปวิเคราะห์อารมณ์จากเครื่องนั้นสามารถใช้เป็นเครื่องมือในการวัดอารมณ์ของครูในชั้นเรียนภายใต้เงื่อนไขของเสรีภาพและความเป็นส่วนตัวของผู้เรียนได้อย่างเหมาะสม

ครูยุคใหม่จำเป็นต้องเรียนรู้กับการปรับตัวกับการเปลี่ยนแปลงของข้อมูลข่าวสารและวิทยาการทางด้านเทคโนโลยีเพื่อช่วยพัฒนาการจัดการจัดการการเรียนรู้ให้กับนักเรียน (Haddix, 2015) ตามที่ Judith (1997) ได้กล่าวว่า เครื่องมือที่สำคัญที่จะทำให้บทบาทของครูและนักเรียนในชั้นเรียนเปลี่ยนไป คือ ความก้าวหน้าทางเทคโนโลยี จึงได้นำวิทยาการความรู้และเทคโนโลยีเกี่ยวกับการเรียนรู้ของเครื่อง (Machine learning) มาประยุกต์ให้เข้าบริบทของการประเมินการจัดการเรียนการสอนของครู โดยมุ่งเน้นไปที่การพัฒนาโมเดลการวิเคราะห์อารมณ์ของครูในชั้นเรียนผ่านการรู้คำพูดเป็นอารมณ์และความรู้สึกของครูในขณะทำการจัดการเรียนการสอน และเป็นตัวแปรที่มีความสอดคล้องกับการเรียนรู้ของเครื่องและการวิเคราะห์ความรู้สึก (Sentiment Analysis) ภายหลังกระบวนการรู้จำคำพูด (Speech Recognition) ที่ได้แปลงเสียงเป็นข้อความแล้ว

การวิเคราะห์ความรู้สึกเป็นการนำการประมวลภาษาธรรมชาติ (natural language processing) และภาษาศาสตร์คอมพิวเตอร์ (computational linguistics) มาประยุกต์ใช้ ในกระบวนการระบุและการตั้งสารสนเทศหรือคุณลักษณะอย่างใดอย่างหนึ่งออกมาจากข้อความหรือเสียงนั้นสามารถนำไปประยุกต์ใช้กับข้อมูลทั่ว ๆ ไป แต่จะมีประสิทธิภาพสูงกว่าหากนำไปใช้กับข้อมูลบางประเภท ซึ่งเทคนิคต่าง ๆ ที่ใช้ในการเรียนรู้ของเครื่องในการวิเคราะห์ความรู้สึกมีหลายเทคนิค และหากจะนำไปใช้งานจำเป็นที่จะต้องให้เครื่องเรียนรู้และมีการทดสอบ เปรียบเทียบประสิทธิภาพเพื่อให้มีความตรงภายในและความตรงภายนอก จึงนับเป็นความท้าทายในการคัดสรรเทคนิคในการวิเคราะห์การเรียนรู้เชิงลึกที่มีประสิทธิภาพสูงสุดเพื่อให้ได้โมเดลการวิเคราะห์อารมณ์ของครูในชั้นเรียน

คำถามวิจัย

1. โมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกมีลักษณะเป็นอย่างไร
2. ผลการวิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนที่ได้พัฒนาขึ้นเป็นอย่างไร

วัตถุประสงค์การวิจัย

1. เพื่อพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก
2. เพื่อวิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนที่ได้พัฒนาขึ้น

ขอบเขตการวิจัย

(1) ด้านตัวแปร

อารมณ์ครูในชั้นเรียน (Teacher's Emotions in Classroom) หมายถึง สภาวะอารมณ์ที่ครูแสดงออกในบทบาทของผู้สอนภายในห้องเรียน โดยส่วนใหญ่จะเกี่ยวข้องกับความรู้สึก พฤติกรรม และการปฏิสัมพันธ์ของครูกับผู้เรียน

(2) ด้านข้อมูลและแหล่งข้อมูล

ข้อมูลที่เก็บรวบรวมข้อมูลเป็นข้อมูลประเภทข้อความ โดยเก็บรวบรวมข้อมูลจาก 2 ส่วน โดยแต่ละส่วนมีรายละเอียด ดังนี้

ส่วนที่ 1 มาจากวิดีโอที่บันทึกได้จากการจัดการเรียนการสอนออนไลน์ (online) และออนไซต์ (onsite) ในรายวิชาของกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนาและวัฒนธรรม ชั้นมัธยมศึกษาตอนต้น ในปีการศึกษา 2564 - 2565 จากครูในโรงเรียนแห่งหนึ่งในสังกัดสำนักงานเขตพื้นที่การศึกษามัธยมศึกษา กรุงเทพมหานคร เขต 2 จำนวน 1 โรงเรียน ในแต่ละวิดีโอเป็นการบันทึกการจัดการเรียนการสอนในแต่ละคาบเรียน ซึ่งในแต่ละคาบเรียนใช้เวลาในการจัดการเรียนการสอนประมาณคาบเรียนละ 50 นาที ซึ่งเมื่อรวมเวลาที่ใช้ในการจัดการเรียนการสอนทั้งหมดเป็นข้อมูลที่มีความยาวประมาณ 8 ชั่วโมง 20 นาที

ส่วนที่ 2 มาจากฐานข้อมูล Wisersight Sentiment Analysis เป็นฐานข้อมูลที่ไว้ใช้สำหรับการวิเคราะห์อารมณ์จากข้อความบนสื่อสังคมออนไลน์ ซึ่งมีการจำแนกประเภทข้อความออกเป็น 4

ประเภท ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ ข้อความที่เป็นกลาง และข้อคำถาม รวม 26,737 ข้อความ แต่ได้มีการจัดกระทำข้อมูล โดยนำข้อความที่เป็นข้อคำถามออกเพื่อให้สอดคล้องกับบริบทที่จะศึกษา ซึ่งฐานข้อมูลดังกล่าวเป็นฐานข้อมูลที่ได้รับการสนับสนุนในการพัฒนาจากสถาบันวิจัยปัญญาประดิษฐ์ประเทศไทย จากความร่วมมือระหว่างสถาบันวิทยสิริเมธี และสำนักงานส่งเสริมเศรษฐกิจดิจิทัล (VISTEC - depa Thailand Artificial Intelligence Research Institute)

คำจำกัดความที่ใช้ในการวิจัย

อารมณ์ครูในชั้นเรียน (Teacher's Emotions in Classroom) หมายถึง สภาวะอารมณ์ที่ครูแสดงออกในบทบาทของผู้สอนภายในห้องเรียนผ่านคำพูด ซึ่งมีผลต่อการเรียนรู้ของนักเรียนได้ จำแนกออกเป็น 3 รูปแบบ ได้แก่ อารมณ์เชิงบวก อารมณ์ที่เป็นกลาง และอารมณ์เชิงลบ

ประโยชน์ที่คาดว่าจะได้รับ

ประโยชน์เชิงวิชาการ

1. สามารถวัดระดับอารมณ์ของครูในชั้นเรียนจากเสียงพูดของครูโดยใช้การเรียนรู้เชิงลึกได้
2. สร้างองค์ความรู้เกี่ยวกับประสิทธิภาพในการวิเคราะห์ความรู้สึกจากการเรียนรู้เชิงลึกทั้งการรู้จำคำพูดและการวิเคราะห์อารมณ์จากข้อความที่ได้จากการรู้จำคำพูด

ประโยชน์ในเชิงปฏิบัติ

1. สร้างเครื่องมือที่ครูสามารถใช้ในการให้ข้อมูลย้อนกลับแก่ตนเองได้เกี่ยวกับอารมณ์ของครูในชั้นเรียน
2. ผลการวิจัยสามารถนำไปใช้เป็นพื้นฐานของการสร้างแอปพลิเคชันที่ใช้ในการให้ข้อมูลย้อนกลับแก่ครูเกี่ยวกับอารมณ์ของครูในชั้นเรียนได้
3. สารสนเทศที่ได้จากการวิจัยช่วยให้ผู้ที่เกี่ยวข้องในการพัฒนาการศึกษา ผู้กำหนดนโยบาย ผู้บริหาร นักการศึกษา ครู สามารถนำไปใช้เป็นแนวทางในการสร้างนโยบายเพื่อส่งเสริมบรรยากาศในชั้นเรียนได้อย่างเหมาะสม

บทที่ 2

เอกสารและงานวิจัยที่เกี่ยวข้อง

แนวคิด ทฤษฎี และเอกสารที่เกี่ยวข้องเพื่อนำมาใช้ในการงานวิจัย การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึก แบ่งออกเป็น 3 ตอน ได้แก่ ตอนที่ 1 อารมณ์ครูในชั้นเรียน ตอนที่ 2 การประมวลผลภาษาธรรมชาติ (Natural Language Processing) และตอนที่ 3 โมเดลการเรียนรู้ของเครื่องและงานวิจัยที่เกี่ยวข้อง

ตอนที่ 1 อารมณ์ครูในชั้นเรียน

1.1 ความหมายของอารมณ์ครูในชั้นเรียน

อารมณ์ที่นักเรียนได้สัมผัสขณะอยู่ในชั้นเรียนได้รับอิทธิพลจากปัจจัยหลายประการ รวมถึงอารมณ์และการแสดงออกของครู (Pekrun, 2006) ในสภาพแวดล้อมระหว่างบุคคล อารมณ์จะให้ข้อมูลที่สำคัญเกี่ยวกับความรู้สึก ความตั้งใจ หรือแรงจูงใจของผู้อื่น จึงทำให้ผู้รับรู้สามารถตอบสนองและปรับพฤติกรรมของตนได้อย่างเพียงพอ (Van Kleef, 2010) โดยปกติแล้วบุคคลจะรับรู้อารมณ์ของคู่ปฏิสัมพันธ์ ซึ่งเป็นกระบวนการที่เรียกว่าการส่งผ่านทางอารมณ์ (Frenzel et al., 2018) ประสบการณ์ทางอารมณ์ของบุคคลในสภาพแวดล้อมทางสังคมจึงสัมพันธ์กันอย่างใกล้ชิด (Hatfield et al., 1993) มีงานวิจัยมากมายที่แสดงให้เห็นว่ากระบวนการดังกล่าวเกิดขึ้นภายในห้องเรียน (Frenzel et al., 2018) ความสัมพันธ์ที่ดีกับครูบนพื้นฐานของปฏิสัมพันธ์ทางอารมณ์เชิงบวกและความไว้วางใจซึ่งกันและกันนั้นเอื้อต่อการเรียนรู้ (Reyes et al., 2012) ดังนั้นลักษณะทางอารมณ์ทางสังคมของความสัมพันธ์ระหว่างครูกับนักเรียนจึงมีอยู่ในห้องเรียนจำนวนมาก (Kunter et al., 2013; Pianta & Hamre, 2009)

การสร้างและการจัดการบรรยากาศในห้องเรียนเชิงบวกนั้น ครูต้องใช้กลยุทธ์การสอนและการควบคุมอารมณ์ (Jennings & Greenberg, 2009) จากการศึกษาทดลองในห้องปฏิบัติการพบว่าบุคคลไม่ใช่เพียงแต่สามารถแยกความแตกต่างของอารมณ์ที่แท้จริงและไม่แท้จริงจากการแสดงออกทางสีหน้า (McLellan et al., 2010) แต่ยังสามารถรับรู้ทางอารมณ์ด้วยความถูกต้องที่มีอิทธิพลต่อปฏิกิริยาทางอารมณ์และพฤติกรรมของผู้รับ (Johnston et al., 2010) ตัวอย่างเช่น ครูต้องการให้นักเรียนดูกระตือรือร้นและมีเป้าหมายที่จะแสดงภาพลักษณ์ทางอารมณ์เชิงบวกในห้องเรียน (Sutton, 2004) ความถูกต้องทางอารมณ์สามารถเกิดขึ้นได้ในสถานการณ์ที่ครูประสบกับอารมณ์ที่ไม่ตรงกับ

การแสดงความรู้สึกและการแสดงออกสามารถสอดคล้องกันได้โดยใช้กลยุทธ์การแสดงเชิงลึก (Hülshager & Schewe, 2011) นั่นคือ 'ความพยายามที่จะปรับเปลี่ยนความรู้สึกให้เข้ากับการแสดงที่ต้องการ' (Grandey, 2003) ตัวอย่างกลยุทธ์การแสดงเชิงลึกที่ปรับเปลี่ยนได้ เช่น การประเมินซ้ำทางปัญญา (Gross, 1998) อย่างไรก็ตาม หากครูใช้กลวิธีการแสดงแบบผิวเผิน เช่น การชมหรือแกล้งแสดงอารมณ์เพื่อให้ภายนอกเป็นไปตามภาพแสดงอารมณ์ในอุดมคติโดยไม่เปลี่ยนความรู้สึกทางอารมณ์ (Lee et al., 2016) สิ่งนี้จะส่งผลให้เกิดสภาวะภายในอย่างต่อเนื่อง ความไม่ลงรอยกันทางอารมณ์มักเกิดขึ้นโดยครู (เช่น Keller, Chang et al., 2014) และอ้างถึงความคลาดเคลื่อนระหว่างอารมณ์ที่เกิดขึ้นกับอารมณ์ที่แสดงออกมาภายนอก (Abraham, 1998)

1.2 องค์ประกอบของอารมณ์ครูในชั้นเรียน

อารมณ์เป็นกระบวนการทางจิตและสรีรวิทยาที่ซับซ้อนซึ่งเกิดจากเหตุการณ์สำคัญในชีวิตของแต่ละคน (Eisma and Stroebe, 2021) ประสบการณ์ทางอารมณ์มีความสำคัญต่อปฏิกริยาทางอารมณ์ของนักเรียนในห้องเรียน จากการวิจัยที่ผ่านมาทำให้ทราบว่าอารมณ์ของครูมีความสำคัญอย่างยิ่งต่อสุขภาพและความเป็นอยู่ที่ดีในการทำงาน เช่น Keller, Chang et al., 2014; Philipp & Schüpbach, 2010 โดยทั่วไปอารมณ์ของครูจะเผยออกมาเมื่อมีปฏิสัมพันธ์กับสภาพแวดล้อม (Day and Gu, 2014) อารมณ์ที่แท้จริงจะเกิดขึ้นเมื่อองค์ประกอบทางอารมณ์สองส่วน ได้แก่ ความรู้สึกและการแสดงออกมีความสอดคล้องกัน หรือกล่าวคือ 'เมื่อการแสดงออกทางอารมณ์สะท้อนถึงประสบการณ์ทางอารมณ์ในปัจจุบัน' (Ashforth & Tomiuk, 2000) อารมณ์ที่แท้จริงมักเกี่ยวข้องกับความจริงใจและความเป็นธรรมชาติ (Salmela, 2005) และในระดับที่ลึกกว่านั้นเกิดจากการรวมค่านิยมและบรรทัดฐานทางวิชาชีพเข้าร่วมด้วย (Erickson, 1995)

1.3 เครื่องมือที่ใช้ในการวัดอารมณ์ครูในชั้นเรียน

การศึกษาเชิงปริมาณโดยใช้ข้อมูลแบบสอบถามรายงานตนเองตามแบบจำลองอารมณ์ของครู โดย Frenzel (2014) ใช้แบบจำลองที่ระบุเป้าหมายหลักสี่ประการในการสอนและพฤติกรรมของนักเรียนที่เกี่ยวข้อง (1) พฤติกรรมแห่งความสำเร็จ (2) พฤติกรรมที่สร้างแรงจูงใจ (3) พฤติกรรมทางสังคมและอารมณ์ (4) พฤติกรรมเชิงสัมพันธ์

ความฉลาดทางอารมณ์ประกอบด้วยสองด้าน คือ ความฉลาดทางอารมณ์ด้านความสามารถและความฉลาดทางอารมณ์ด้านลักษณะ โมเดลแรกกำหนดแนวคิดความฉลาดทางอารมณ์ด้าน

ความสามารถ เป็นรูปแบบหนึ่งของความสามารถทางปัญญาที่เกี่ยวข้องกับการทำความเข้าใจและแยกแยะสัญญาณและข้อมูลทางอารมณ์ ในขณะที่แบบที่สองมองว่าความฉลาดทางอารมณ์ด้านลักษณะ เป็นลักษณะบุคลิกภาพที่เกี่ยวข้องกับพฤติกรรมทั่วไป (Bar-On and Parker, 2000; Lu et al., 2016) โมเดลที่แตกต่างกันทั้งสองนี้นำไปสู่การวัดที่แตกต่างกัน (Davis and Nichols, 2016) การวิจัยจำนวนมากเกี่ยวกับความฉลาดทางอารมณ์ พบว่าความฉลาดทางอารมณ์สูงเกี่ยวข้องกับผลลัพธ์ชีวิตในเชิงบวก เช่น การพัฒนาความสัมพันธ์ทางสังคมในเชิงบวก การระบุสถานะทางอารมณ์ของผู้อื่น การปรับมุมมองของผู้อื่น การปรับปรุงการสื่อสาร และการจัดการพฤติกรรม (Miao et al., 2017)

แบบสอบถามรายงานตนเองเพื่อประเมินอารมณ์ทักษะการจัดการระเบียบและความสัมพันธ์ในผู้ใหญ่ ตัวอย่างเช่น แบบสอบถามการควบคุมอารมณ์ (ERQ; Gross and John, 2003) แบบสอบถามความสามารถระหว่างบุคคล (ICQ; Buhrmester et al., 1988) ประเมินระดับ ที่คนมองว่าตัวเองสามารถเริ่มต้นความสัมพันธ์ได้แสวงหาและให้การสนับสนุนทางอารมณ์ กล้าแสดงออก และแก้ไขข้อขัดแย้ง การรวมระดับสำหรับการควบคุมอารมณ์และทักษะการจัดการความสัมพันธ์ การใช้แบบสอบถามรายงานตนเองมีความเสี่ยงของความสัมพันธ์ที่สูงเกินจริงเนื่องจากความเอนเอียงของวิธีการทั่วไปเมื่อผู้เข้าร่วมรายงานเกี่ยวกับความสามารถทางสังคมและอารมณ์และความเป็นอยู่ที่ดีหรือผลอื่น ๆ ในเวลาเดียวกัน (Podsakoff et al., 2003)

1.4 อิทธิพลของอารมณ์ครูในชั้นเรียนที่มีต่อตัวแปรอื่น ๆ

ในหลายการวิจัยแสดงให้เห็นว่าอารมณ์ของครูเชื่อมโยงอย่างมากกับการมีปฏิสัมพันธ์เชิงบวกกับนักเรียน เช่น ความก้าวหน้าของผู้เรียน การแสดงความชื่นชมในผลงานของครู ทำให้เกิดการตอบสนองหรือแสดงพฤติกรรมออกมา เช่น ความสุขและความพึงพอใจ (Hargreaves 2000) ครูที่มีอารมณ์เชิงบวกในระหว่างการสอนจะสามารถเข้าถึงกลยุทธ์การสอนที่หลากหลายมากขึ้น และมีความยืดหยุ่น รวมถึงสร้างสรรค์ในการปรับตัวให้เข้ากับสถานการณ์ในห้องเรียนที่แตกต่างกัน โดยมีผลกระทบที่สอดคล้องกันสำหรับผลการเรียนของนักเรียน (Fredrickson's broadenand-build, 2001) แต่หากมีปฏิสัมพันธ์เชิงลบ ตามการศึกษาล่าสุดของ Chang (2013) แสดงให้เห็นว่าอารมณ์เชิงลบของครู เช่น ความโกรธและความหงุดหงิด มักเกี่ยวข้องกับพฤติกรรมที่ไม่เหมาะสมของนักเรียนหรือการขาดระเบียบวินัยในห้องเรียน (Tsouloupas et al. 2010) อารมณ์ของครูจึงมีความสัมพันธ์

กับความเป็นอยู่ที่ดีและคุณภาพของการสอน (Brackett et al. 2013; Day and Gu 2011; Frenzel 2014; Frenzel et al. 2011) อารมณ์เชิงบวกของครูมีแนวโน้มที่จะกระตุ้นอารมณ์เชิงบวกของนักเรียน (Becker et al. 2014; Frenzel et al. 2009) ดังนั้น อารมณ์เชิงบวกของครูอาจไม่เพียงจำเป็นสำหรับสุขภาวะของครู แต่อาจส่งผลต่อสุขภาวะของนักเรียนด้วย และส่งผลถึงการเรียนในชั้นเรียนเช่นกัน

ตอนที่ 2 การประมวลผลภาษาธรรมชาติ (Natural Language Processing)

2.1 กระบวนการรู้จำคำพูด

การรู้จำคำพูด (Speech Recognition) หมายถึง กระบวนการในการแปลงเสียงเป็นไฟล์ข้อความ โดยมีกระบวนการในการแปลงเสียงเป็นข้อความ ดังนี้

1. การกำหนดค่า API ของตนเอง
2. นำเข้า requests เพื่อนำเข้าข้อมูลทั้ง 4 องค์ประกอบ ได้แก่ นำเข้าไฟล์เสียงจากในเครื่อง (upload)

การถอดเสียงเป็นคำ (transcribe) ซึ่งในภาษาไทยจำเป็นที่จะต้องหาการตัดคำที่มีประสิทธิภาพ การกำหนดให้ API ทำงานต่อจนสำเร็จ (poll) การบันทึกข้อความที่ถอดได้ (save transcript)

สำหรับรูปแบบของเก็บข้อมูลเสียงมีรายละเอียด ดังนี้

- .mp3 : เป็นรูปแบบการเก็บข้อมูลของเสียงที่มีการบีบอัดเสียง ทำให้มีการสูญเสียข้อมูล ทำให้สารสนเทศที่ได้น้อยลงไปได้ด้วย แต่มีความสะดวก
- .flac : เป็นรูปแบบการเก็บข้อมูลที่มีการบีบอัดน้อย สารสนเทศที่ได้ก็จะสูญเสียน้อย ทำให้สามารถนำข้อมูลเดิมที่ได้มาสังเคราะห์ขึ้นใหม่ได้อย่างสมบูรณ์แบบข้อมูล
- .wav : เป็นรูปแบบการเก็บข้อมูลที่ไม่มีการบีบอัด เป็นรูปแบบการเก็บข้อมูลที่มีคุณภาพสูงที่สุด แต่ขนาดไฟล์ก็จะมีขนาดใหญ่ที่สุดเช่นกัน

โดยในปัจจุบันการใช้งานที่มีได้รับความนิยมสูงสุดเป็นการเก็บข้อมูลเสียงในรูปแบบของ .mp3 เพราะสะดวกและสามารถนำไฟล์ในลักษณะดังกล่าวมาแปลงเป็นไฟล์ในรูปแบบอื่น ๆ และใช้กับโมดูล เช่น speech_recognition หรือ pydub ในภาษาไพธอนเพื่อใช้ในกระบวนการรู้จำคำพูด ซึ่งมีผู้คิดค้นและพัฒนาไว้แล้ว

2.2 การสกัดคุณลักษณะด้วยวิธีการ TF-IDF

TF-IDF (Term Frequency-Inverse Document Frequency) เป็นเทคนิคที่ใช้สำหรับการค้นหาและการจัดกลุ่มเอกสาร (document) ที่มีความเกี่ยวข้องกับคำค้นหา (query) โดยใช้นับจำนวนครั้งที่คำนั้นปรากฏในแต่ละเอกสาร และการนับจำนวนของเอกสารที่มีคำนั้นปรากฏ เพื่อคำนวณค่าน้ำหนัก (weight) ของความสำคัญสำหรับแต่ละคำที่ปรากฏอยู่ในเอกสาร เทคนิคดังกล่าวใช้เครื่องมือทางสถิติในการประเมินความสอดคล้องระหว่างคำที่ปรากฏอยู่ในเอกสาร และเป็นที่นิยมในการศึกษาด้านภาษาศาสตร์และการประมวลผลทางภาษาศาสตร์ รวมถึงศาสตร์ทางชีวสารสนเทศศาสตร์ได้นำเทคนิคนี้ไปใช้ด้วยเช่นกัน เช่น การนับรูปแบบที่พบได้บ่อย ๆ ในสายลำดับดีเอ็นเอและจีโนมโดยรายละเอียดของสัญลักษณ์เป็น ดังนี้

TF (Term frequency) หมายถึง จำนวนครั้งที่คำนั้นปรากฏในเอกสาร

IDF (Inverse Document Frequency) หมายถึง การหาความถี่ของคำนั้นในเอกสารทั้งหมด

ดังนั้น ค่า TF-IDF เท่ากับผลคูณของค่า TF และค่า IDF ในแต่ละคำโดยใช้สมการดังนี้:

$$TF-IDF(\text{term}) = TF(\text{term}, \text{document}) \times IDF(\text{term})$$

โดยเมื่อค่าใดมีค่า TF-IDF สูง จะแสดงว่า คำนั้นสำคัญและสามารถใช้ช่วยจำแนกลักษณะที่แตกต่างกันของเอกสาร

ตอนที่ 3 โมเดลการเรียนรู้ของเครื่องและงานวิจัยที่เกี่ยวข้อง

3.1 โมเดลการเรียนรู้ของเครื่องที่ใช้ในงานวิจัย

Logistic Regression (LR) เป็นการวิเคราะห์ที่ใช้เพื่อทำนายตัวแปรตามที่มีค่าไม่ต่อเนื่อง (ตัวแปรแบบจัดประเภท) โดยใช้ชุดของตัวแปรอิสระที่กำหนดไว้ การทำนายดังกล่าวจะอธิบายข้อมูลและช่วยให้เข้าใจความสัมพันธ์ระหว่างตัวแปรอิสระและตัวแปรตาม โดยการทำนายความน่าจะเป็นของการเกิดเหตุการณ์จะใช้ฟังก์ชัน logit เพื่อหาค่า ดังนั้น การวิเคราะห์นี้เรียกว่า logit regression การนำค่า x เข้าไปโมเดลซึ่งมีความสัมพันธ์เชิงเส้น เพื่อคำนวณค่าผลลัพธ์ที่เป็นไปได้ p ซึ่งค่า p มีค่าอยู่ระหว่าง 0 และ 1 ซึ่งเป็นผลรวมเชิงเส้นของตัวแปรอิสระแต่ละตัว โดยมีค่าสัมประสิทธิ์ b_i ของตัวแปรอิสระที่ i โดยที่ $i = 1, 2, 3, \dots, k$ ตัวแปรอิสระแต่ละตัวทำหน้าที่กำหนดน้ำหนักของ

ตัวแปรนั้น ๆ ภายในโมเดล และค่าคงที่ b_0 ซึ่งค่าสัมประสิทธิ์ (b) สามารถคำนวณได้จากการเรียนรู้ในข้อมูลการฝึกฝน และค่า p สอดคล้องตามสมการ

$$P = \frac{e^{b_0 + b_1x_1 + \dots + b_kx_k}}{1 + e^{b_0 + b_1x_1 + \dots + b_kx_k}}$$

Naive Bayes (NB) เป็นอัลกอริทึมที่ใช้ในการจัดประเภทข้อความและเป็นอัลกอริทึมที่ง่ายที่สุดในการเรียนรู้เชิงเครื่อง ซึ่งใช้ทฤษฎีเบย์ในการสร้างโมเดล ด้วยวิธีนี้จะสามารถหาความน่าจะเป็นที่ตัวแปรเป้าหมายของตัวอย่างจะอยู่ในประเภทที่กำหนดได้ โดยมีสูตร ดังนี้

$$P(c|x) = \frac{P(x|c) P(c)}{P(x)}$$

โดยที่ $P(c|x)$ เป็นความน่าจะเป็นของตัวอย่าง x ที่อยู่ในคลาส c , $P(x|c)$ เป็นความน่าจะเป็นของการสร้างตัวอย่าง x โดยมีคลาสที่กำหนดไว้ว่าเป็นคลาส c , $P(c)$ เป็นความน่าจะเป็นของคลาส c และ $P(x)$ เป็นความน่าจะเป็นของตัวอย่าง x ในการเกิดขึ้น

Support Vector Machine (SVM) เป็นเทคนิคการแบ่งข้อมูลเป็นสองหรือมากกว่าสองชนิด โดยใช้เส้นแบบเชิงเส้นในพื้นที่ 2 มิติ ระบบแบบราบในพื้นที่ 3 มิติ และไฮเปอร์เพลนในพื้นที่หลายมิติ วิธีการนี้ที่ช่วยเมื่อต้องการหาชนิดที่แยกกันได้แบบเชิงเส้นสามารถนำมาใช้ในการจัดแบ่งข้อมูลแบบเส้นตรงไม่ได้โดยการเคลื่อนย้ายพื้นที่นำเข้าไปที่ไม่สามารถแบ่งแยกได้แบบเชิงเส้นไปยังพื้นที่สามมิติสูงขึ้นไปซึ่งสามารถแบ่งกันได้แบบเชิงเส้น

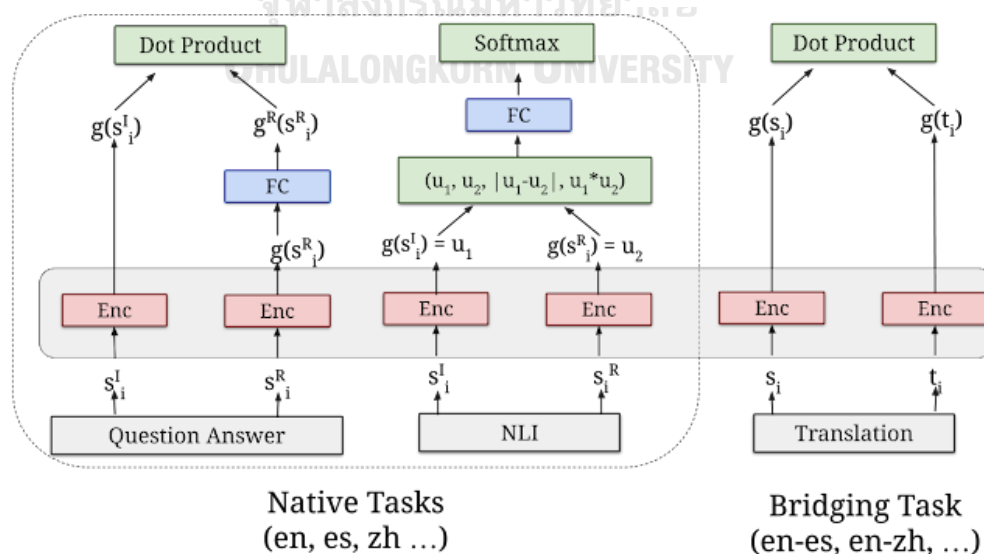
Random Forests (RF) คือ เทคนิคการเรียนรู้ที่ใช้ร่วมกัน (ensemble learning technique) สำหรับการเรียนรู้เชิงสถิติ (regression), การจัดกลุ่ม (classification) และงานอื่นๆ โดยการสร้างต้นไม้เล็กๆหลายต้น (decision trees) ขึ้นมาในช่วงการฝึก (training) แล้วนำผลคำนวณค่าเฉลี่ย (mean) สำหรับการทำนายเชิงสถิติหรือค่าโหวตสูงสุด (mode) สำหรับการจัดกลุ่มมาประกอบกัน แต่มีความเสี่ยงที่จะเกิดการ overfitting ถ้าไม่ตั้งค่ากำหนดค่าขอบเขต (hyperparameters) อย่างเหมาะสม ทุกต้นไม้ในชุด (forest) มีส่วน contributing ในการจัดแบ่งกลุ่ม โดยการยกศูนย์ใหม่ (classify) ข้อมูลใหม่จากคุณสมบัติของแต่ละสิ่งที่จะต้องจัดกลุ่ม แล้วหาต้นไม้ที่มีส่วนน้อย (votes) สูงสุด ซึ่งจากนั้น forest ก็จะทำให้การจัดกลุ่มของข้อมูลนั้นโดยใช้การลงคะแนน

3.2 โมเดลการเรียนรู้เชิงลึกที่ใช้ในงานวิจัย

Multilingual Universal Sentence Encoder

Multilingual Universal Sentence Encoder เป็นโมเดล Natural Language Processing (NLP) ที่ถูกสร้างขึ้นโดย Google ซึ่งถูกออกแบบมาเพื่อช่วยในการเข้าใจความหมายของประโยคภาษาธรรมชาติจากหลายภาษาต่างๆ โดยไม่จำเป็นต้องแปลเป็นภาษาอังกฤษก่อน โมเดลนี้สามารถเปรียบเทียบประโยคที่ประกอบไปด้วยคำทั้งหมดและความหมายของประโยคดั้งเดิมเพื่อค้นหาประโยคที่มีความหมายคล้ายกันได้ โดยมีการอบรมโมเดลด้วยข้อมูลและปรับปรุงอยู่เสมอ ทำให้โมเดลได้รับการพัฒนามากขึ้นอย่างต่อเนื่อง โดย Multilingual Universal Sentence Encoder สามารถนำมาใช้สำหรับหลายงานที่เกี่ยวข้องกับตัวอักษรเช่น การจัดลำดับข้อมูล การแบ่งกลุ่มข้อมูล หรือการค้นหาข้อมูลที่เกี่ยวข้องได้ทั้งในภาษาไทยและภาษาอื่นๆ

Multilingual Universal Sentence Encoder มีสถาปัตยกรรมที่ช่วยให้สามารถแปลงประโยคในภาษาต่าง ๆ เป็นเวกเตอร์เพื่อเปรียบเทียบและค้นหาความคล้ายคลึงกันได้ โดยมีการใช้โครงข่ายประสาทเชิงลึก (Deep neural network) ที่ฝังอยู่ใน Tensorflow framework โดยมี layers ต่าง ๆ มากมาย เช่น encoder layer ที่ใช้สำหรับแปลงประโยคเป็นเวกเตอร์แบบ embedding และ projection layer ที่ใช้สำหรับเปรียบเทียบความคล้ายคลึงกันของประโยค นอกจากนี้ Multilingual Universal Sentence Encoder ยังมีการใช้ transfer learning โดยใช้โมเดลที่ได้รับการฝึกฝนเรียบร้อยแล้ว (pre-trained) โดยข้อมูลที่นำมาฝึกฝน โมเดลนี้มีลักษณะเป็น text corpus ที่ประกอบด้วยภาษาต่าง ๆ ที่ต่างกันของโลก (Yang, Y. et al., 2019)



ภาพที่ 1 แสดงสถาปัตยกรรมของโมเดล Multilingual Universal Sentence Encoder

โครงข่ายประสาทเทียมแบบเกิดซ้ำ (Recurrent Neural Network)

หลายปีก่อนหน้านี้ ในช่วงแรกของการเกิดการเรียนรู้เชิงลึก (deep learning) มีการนำเทคโนโลยีรู้จำคำพูด (automatic speech recognition) มาประยุกต์ใช้อย่างผิวเผินด้วยสถาปัตยกรรมแบบจำลองฮิดเดนมาร์คอฟ (Hidden markov model: HMM) โดยที่ในแต่ละชั้นใช้การประมวลผลโดยการประมาณรูปร่างผสมของเกาส์ (Gaussian mixture model: GMM) ซึ่งความสำเร็จที่เกิดขึ้นต้องใช้การประมวลผลที่มีความซับซ้อนและต้องระมัดระวังความแปรปรวนที่เกิดขึ้นในกระบวนการ GMM-HMMs และคุณลักษณะของเสียงที่เหมาะสมกับการนำไปวิเคราะห์ผู้เชี่ยวชาญหลายท่านได้คาดการณ์ว่าจะมีเทคโนโลยีรู้จำคำพูดเกิดขึ้นใหม่ภายใต้การนำไปใช้งานและสภาพแวดล้อมที่หลากหลาย โดยนำการเรียนรู้เชิงลึกมาประยุกต์ใช้กับการรู้จำคำพูด โดยเริ่มจากการเลียนแบบระบบการรู้จำคำพูดของมนุษย์ (human speech recognition system) ที่มีทั้งพลวัตและลำดับขั้นของโครงสร้างในการสร้างคำพูด (speech production) และการรับรู้คำพูด (speech perception) โดยในช่วงแรกมีความพยายามที่จะนำเกณฑ์โครงสร้างการเรียนรู้เกี่ยวกับการรู้จำคำพูดแบบดั้งเดิมมาใช้ในเทคโนโลยีรู้จำคำพูดบนพื้นฐานของโครงข่ายประสาทเทียมเชิงลึก (deep neural network) แต่หลังจากนั้นไม่นานก็เกิดเป็นเทคโนโลยีรู้จำคำพูดขึ้นมาใหม่

ในช่วงเวลาถัดมา มีการนำกระบวนการ DNN-HMM มาใช้ในการรู้จำคำพูดแต่ไม่สามารถสร้างแบบจำลองเกี่ยวกับพลวัตของคำพูดได้อย่างมีประสิทธิภาพ ซึ่งมีข้อจำกัดในการประมวลผลคล้ายกับที่กล่าวมาข้างต้น เนื่องจากเป็นตระกูลแบบจำลองฮิดเดนมาร์คอฟเช่นเดียวกัน เช่น ความหลากหลายของความแปรปรวนของแบบจำลองฮิดเดนมาร์คอฟ โครงข่ายประสาทเทียมแบบเกิดซ้ำ (Recurrent Neural Network) เพิ่งได้รับการพัฒนามาในช่วงไม่กี่ปีที่ผ่านมาโดยการเรียนรู้เชิงลึก โดยผู้เชี่ยวชาญต้องการที่จะทำลายข้อจำกัดต่าง ๆ และสร้างแบบจำลองพลวัต สำหรับโครงข่ายประสาทเทียมแบบเกิดซ้ำ ตัวแทนภายในของคุณลักษณะคำพูดแบบพลวัต คือ การจำแนกโดยใช้คุณลักษณะของเสียงระดับต่ำ (low-level acoustic feature) ในแต่ละชั้นซ่อนตัว (hidden layer) เข้าด้วยกันด้วยคุณลักษณะที่ซ่อนตัวแบบเกิดซ้ำ (recurrent hidden layer) แต่ในทางกลับกัน กลับไม่มีตัวแทนภายในของคุณลักษณะคำพูดแบบพลวัตของ DNN-HMM โครงข่ายประสาทเทียมแบบเกิดซ้ำเป็นประเภทของโครงข่ายประสาทเทียมที่มีการเชื่อมโยงกันของหน่วยในวัฏจักร แม้ว่าคำว่า “recurrent” จะหมายถึงการเกิดซ้ำ หรือเกี่ยวข้องกับดำเนินการภายหลัง (time-delay operation) การใช้งานดำเนินการภายหลังในการกำหนดมิติชั่วคราว เพื่อช่วยในการจดจำโครงสร้างและการแสดงสภาพ

ภายใน โครงข่ายประสาทเทียมแบบเกิดซ้ำอนุญาตให้มีการแสดงประเภทของพฤติกรรมของพลวัตชั่วคราว แต่ในโครงข่ายประสาทเทียมเชิงลึกและ DNN-HMM นั้นไม่มี

โครงข่ายประสาทเทียมแบบเกิดซ้ำเป็นการเรียนรู้เชิงลึกที่มีการแผ่ของโครงข่ายประสาทเทียมแบบเกิดซ้ำที่สร้างขึ้นหลายชั้นในโครงข่ายซึ่งเท่ากับคำพูดที่นำเข้า กระบวนการล่าสุดที่ของการรู้จำคำพูดที่มีประสิทธิภาพในการเรียนรู้ของเครื่องอยู่ในระดับดีเยี่ยม นั่นคือ การใช้โครงข่ายประสาทเทียมแบบเกิดซ้ำแบบการจำระยะสั้น-ยาว (long-short-term memory : LSTM) ซึ่งเป็นรูปแบบที่มีการคิดค้นตั้งแต่ปีคริสต์ศักราช 1997 โดยผู้เชี่ยวชาญทางด้านโครงข่ายประสาทเทียม

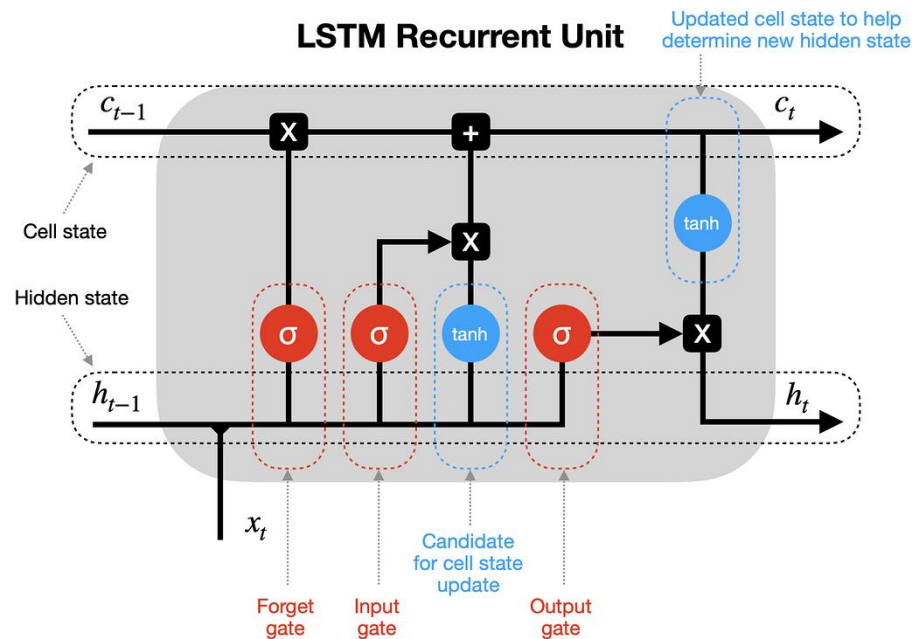
โมเดล LSTM (Long-Short Term Memory)

โมเดล LSTM (Long-Short Term Memory) เป็นโมเดลประเภท Recurrent Neural Network (RNN) ที่ถูกพัฒนาขึ้นมาเพื่อจัดการกับปัญหาของการเรียนรู้แบบ Sequential ซึ่งมักเกี่ยวข้องกับข้อมูลที่มีความเชื่อมโยงกันในเวลาที่ต่างกัน เช่น ตัวอย่างการทำนายภาพยนตร์ที่จะออกฉายในเดือนถัดไป หรือการทำนายราคาหุ้นในอนาคต

โมเดล LSTM ถูกออกแบบให้สามารถจดจำข้อมูลได้นานเป็นเวลายาว โดยใช้ Memory Cell ซึ่งจะเก็บข้อมูลที่สำคัญไว้ และสามารถสร้างและลบค่าที่จำเป็นได้ตลอดเวลา นอกจากนี้ โมเดล LSTM ยังมี Gate สองตัวคือ Forget Gate และ Update Gate ซึ่งสามารถคัดเลือกข้อมูลที่จะถูกส่งต่อได้ตามความสำคัญของข้อมูลเหล่านั้น ตามที่ Staudemeyer, R. C., & Morris, E. R. (2019).

ส่วนประกอบหลักของ LSTM (Long Short-Term Memory) ประกอบด้วย 4 ส่วนหลัก คือ

1. แผ่นเก็บข้อมูลหลัก (cell state) ซึ่งจะ เป็นแบบเวกเตอร์ที่เก็บค่าของเซลล์ในช่วงที่ผ่านมา โดยสามารถเปลี่ยนแปลงค่าได้ผ่านการลบหรือบวกค่า
2. forget gate จะทำหน้าที่คัดกรองข้อมูลที่ไม่จำเป็นออกจากแผ่นเก็บข้อมูลหลักในช่วงที่ผ่านมา
3. ประตูนำเข้า (input gate) จะถูกใช้สำหรับการเพิ่มข้อมูลเข้าไปในแผ่นเก็บข้อมูลหลัก โดยสามารถคัดกรองข้อมูลที่ไม่เกี่ยวข้องออกได้
4. ประตูออก (output gate) จะทำหน้าที่แยกข้อมูลที่จะเอาออกจากแผ่นเก็บข้อมูลหลัก และนำไปใช้ในการคำนวณต่อไป



ภาพที่ 2 แสดงสถาปัตยกรรมของหน่วยโมเดล LSTM

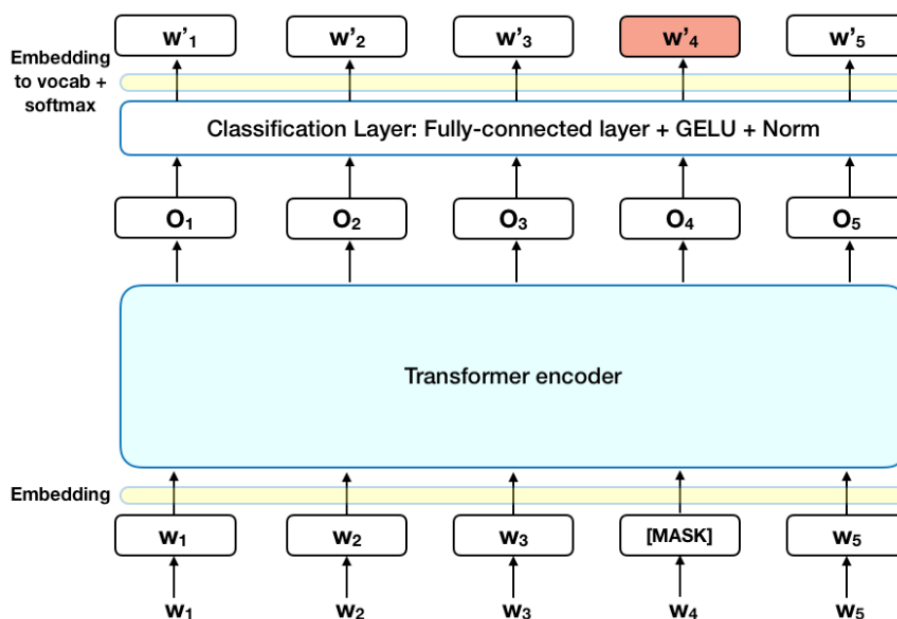
Bidirectional Encoder Representations from Transformers (BERT)

BERT ย่อมาจาก "Bidirectional Encoder Representations from Transformers" คือ โมเดลปัญญาประดิษฐ์ด้านภาษาธรรมชาติของ Google ซึ่งถูกพัฒนาโดยการใช้เทคโนโลยี Transformer ซึ่งเป็นโมเดลปัญญาประดิษฐ์ ชนิดหนึ่งที่ใช้ในการทำการประมวลภาษาธรรมชาติ (Natural Language Processing: NLP) และสามารถเรียนรู้แบบเข้ากันได้กับแต่ละคำในประโยค โดย BERT ได้รับความนิยมอย่างมากเนื่องจากสามารถทำงานด้วยความแม่นยำสูงและเป็นไปได้อย่างสมบูรณ์ทั้งในภาษาธรรมชาติและภาษาเชิงมาตรฐานชนิดอื่น ๆ ซึ่งทำให้มีประสิทธิภาพในการประมวลผลเสมือนมนุษย์ในการเข้าใจและให้คำตอบสำหรับคำถามหลากหลายของภาษาธรรมชาติได้อย่างดีที่สุดในปัจจุบัน ตามที่ Lowphansirikul et al. (2021)

ส่วนประกอบหลักของ BERT ประกอบด้วย:

1. Transformer Encoder: โมเดลประมวลผลข้อมูลที่ใช้ในการเรียนรู้และแปลงข้อมูลเป็นค่า Feature Vector ที่สามารถเก็บความสัมพันธ์ระหว่างข้อมูลได้ดี
2. Pre-trained Language Model: โมเดลการเรียนรู้ของภาษาที่ได้รับการสร้างขึ้นด้วยการใช้ corpus ของข้อมูลมหาศาล เพื่อเพิ่มประสิทธิภาพในการทำความเข้าใจภาษาของ BERT

3. Multi-Task Learning: การใช้โมเดล BERT ในหลายๆ งานที่ใช้หลายๆ ภาษาเพื่อเพิ่มประสิทธิภาพของการเรียนรู้
4. Fine-tuning: การปรับแต่งพารามิเตอร์ของโมเดลที่ถูกตั้งค่าไว้ล่วงหน้าแล้ว เพื่อให้โมเดลสามารถทำงานได้ดีกับงานที่ต้องการเชิงพร้อม โดยใช้ชุดข้อมูลที่เป็นเอกสารโดยเฉพาะ



ภาพที่ 3 แสดงสถาปัตยกรรมของหน่วยโมเดล BERT

BERT ใช้โมเดล Transformer ในการทำงาน โดยโมเดล Transformer เป็นโมเดลที่เรียนรู้ความสัมพันธ์ระหว่างคำในประโยค ในการใช้ BERT จะมีการทำ Pre-training ก่อน โดยมีขั้นตอนดังนี้

1. Masked Language Model (MLM) เป็นการฝึกโมเดลในการทำนายคำที่ถูกลบไปจากประโยค เพื่อให้โมเดลเรียนรู้ความสัมพันธ์ระหว่างคำในประโยค
2. Next Sentence Prediction (NSP) เป็นการฝึกโมเดลในการทำนายว่า ประโยคถัดไปจะเป็นอะไร โดยวัดผลจากการเปรียบเทียบค่าความน่าจะเป็นของประโยคถัดไป

จากการ Pre-training ข้างต้นนี้ จะสร้างโมเดล BERT ที่เข้าใจความสัมพันธ์ระหว่างคำในประโยคได้ดีขึ้น เมื่อนำไปใช้งานในการ NLP จะมีประสิทธิภาพสูงมากขึ้น

3.3 งานวิจัยที่เกี่ยวข้อง

ความก้าวหน้าในสาขาของการประมวลผลภาษาธรรมชาติ (NLP) ได้แสดงให้เห็นว่า การถ่ายโอนการเรียนรู้ (Transfer learning) การปรับแต่งพารามิเตอร์จากโมเดลที่มีผู้พัฒนาไว้แล้วนั้นมีประสิทธิภาพสูงกว่าการมาปรับแต่งพารามิเตอร์ใหม่ตั้งแต่ต้น โดยในงานวิจัยของ Ezen-Can, A. (2020) มุ่งเน้นไปที่การนำความก้าวหน้าทางเทคโนโลยีดังกล่าวไปใช้ในวงการศึกษา โดยในการทดลองพบว่า โมเดล LSTM มีประสิทธิภาพสูงกว่าโมเดล BERT สำหรับฐานข้อมูลขนาดเล็ก และใช้เวลาในการปรับแต่งพารามิเตอร์ใหม่ตั้งแต่ต้นน้อยกว่าการปรับแต่งพารามิเตอร์จากโมเดลที่มีผู้พัฒนาไว้แล้ว ประสิทธิภาพในการประมวลผลขึ้นอยู่กับประเภทและลักษณะของข้อมูลที่น่ามาวิเคราะห์ไม่ได้จำเป็นว่า การมีโมเดลที่ฝึกฝนมาเรียบร้อยแล้วและเป็นข้อมูลขนาดใหญ่แล้วจะทำให้ประสิทธิภาพในการวิเคราะห์สูงไปด้วย

AEQ (Achievement Emotions Questionnaire) คือ เครื่องมือวัดผลที่สามารถวัดและประเมินอารมณ์แห่งความสำเร็จ (Maik Bieleke, 2021) เครื่องมือนี้ได้กลายเป็นเครื่องมือที่ได้รับความนิยมและเป็นที่ยอมรับในด้านจิตวิทยาการศึกษาและอื่น ๆ จากการใช้นานกว่า 2,700 การอ้างอิงใน Google Scholar ของการเผยแพร่ครั้งแรก (Pekrun et al., 2002)

AEQ ประกอบด้วยสเกลมาตรวัด 24 ระดับ โดยประเมินอารมณ์ลักษณะ 9 ประการของความเพลิดเพลิน ความหวัง ความสำเร็จ ความเย่อหยิ่ง ความโล่งใจ ความโกรธ ความกังวล ความอับอาย ความสิ้นหวัง และความเบื่อหน่าย สเกลเหล่านี้จัดอยู่ในสามส่วนที่เกี่ยวข้องกับชั้นเรียน การเรียนรู้ และสภาพแวดล้อมทางวิชาการที่เกี่ยวข้องกับการทดสอบ รายการครอบคลุมประสบการณ์ทางอารมณ์ทั้งก่อน ระหว่าง หรือหลังการตั้งค่าที่เกี่ยวข้อง และที่พวกเขาจะวัด แต่เนื่องจากการย่อมาตราส่วนเฉพาะกิจนั้นไม่เพียงพอกับการตรวจสอบคุณภาพไซโครเมตริก และอาจไม่สามารถให้ผลลัพธ์ที่สรุปได้แน่นอน ในการวิจัยปัจจุบันจึงมีการพัฒนา AEQ-S อย่างเป็นระบบ โดยเป็นรูปแบบย่อของ AEQ และตรวจสอบคุณสมบัติทางไซโคเมตริก (Maik Bieleke, 2021) โดยจากผลการทดสอบจะเห็นได้ว่า AEQ จะมีความแม่นยำมากกว่าเพราะมีการใช้สเกลที่ละเอียดกว่า แต่ AEQ-S จะมีข้อดีตรงที่ใช้เวลาในการประมวลไม่นาน สามารถใช้คาดการณ์แนวโน้มได้ โดยตรวจสอบความสัมพันธ์ระหว่างมาตราส่วน AEQ และมาตราส่วนของ AEQ-S แม้ว่า จะคิดเป็นความแปรปรวนของข้อผิดพลาดร่วมกัน (Girard & Christensen, 2008; Levy, 1967) แต่ผลการวิจัยชี้ให้เห็นว่า AEQ-S สามารถทำซ้ำข้อมูลที่รับจาก AEQ

เครื่องมืออีกชนิด คือ long short-term memory with attention mechanism (LSTM-ATT) แบบจำลองถูกสร้างขึ้นบนพื้นฐานของ LSTM ร่วมกับกลไกความสนใจ ผลการจำแนกประเภทของ LSTM-ATT เกี่ยวข้องกับอารมณ์ทางวิชาการ 9 ประเภท ได้แก่ ความเพิดเพลิน ความหวัง ความปิติ ความผ่อนคลาย ความโกรธ ความอับอาย ความกังวล ความผิดหวัง และความเบื่อหน่าย ผลการวิจัยก่อนหน้านี้ยืนยันว่าการใช้โมเดลการฝึกอบรมเครือข่าย LSTM สามารถคาดการณ์อารมณ์ทางวิชาการได้ ในช่วงไม่กี่ปีที่ผ่านมาการให้ความสนใจถูกนำไปใช้กับงานวิเคราะห์อารมณ์ กลไกความสนใจคือรูปแบบการกระจายความสนใจของสิ่งที่ต้องการวัด สำหรับงานเฉพาะสามารถมุ่งเน้นความสนใจได้ในคุณสมบัติบางอย่างเพื่อเพิ่มน้ำหนักของส่วนที่สนใจและปรับปรุงอิทธิพลของส่วนอื่น ในขณะที่ส่วนที่ไม่ได้ให้ความสนใจจะสามารถละเว้นได้ การประยุกต์ใช้กลไกความสนใจในทางปฏิบัติสามารถแบ่งออกเป็นสองประเภท คือ ความสนใจเบา ๆ และความสนใจอย่างหนัก ซึ่งประสบการณ์ของอารมณ์ทางวิชาการสามารถเปลี่ยนแปลงได้หากการประเมินมีการเปลี่ยนแปลง (Schutz and Davis 2000)

จากการศึกษาในหลาย ๆ การศึกษาที่ทำการศึกษามาแสดงให้เห็นว่า มีความสัมพันธ์ระหว่างอารมณ์ทางวิชาการและการสนับสนุนจากครู โดยนักเรียนที่ได้รับความสนับสนุนจากครูมากกว่า มักจะมีค่า PAEs (positive academic emotions) ที่สูงขึ้น หรือค่า NAEs (negative academic emotions) ที่ต่ำลง โดยเฉพาะนักเรียนที่ได้รับความสนับสนุนจากครูมาก มักมีความสนุกสนาน ความสนใจ ความหวัง ความภูมิใจ หรือความหล่อหลอมใจ (PAEs) เพิ่มมากขึ้น หรือมีอาการความวิตกกังวล ซึ่งรวมถึงซึมเศร้า เกรงใจ ความอับอาย ความโกรธ ความห่วงใย ความเบื่อหน่าย หรือความหมดหวัง (NAEs) น้อยลง (Ahmed et al., 2010; King et al., 2012; Tian et al., 2013) ซึ่งขนาดผลกระทบที่ต่างกันอย่างมาก (Skinner et al., 2008; King et al., 2012; McMahan et al., 2013; Liu et al., 2016) นักเรียนมักได้รับอิทธิพลจากอารมณ์ของครู แต่ความเชื่อมโยงระหว่างอารมณ์ของครูและความรู้ ความเข้าใจหรือแรงจูงใจของครูมีความชัดเจนมากกว่า นอกจากนี้ยังมีการวิจัยมากมายเกี่ยวกับความสัมพันธ์ระหว่างอารมณ์ต่อผู้อื่น และพฤติกรรมช่วยเหลือ งานวิจัยที่เกี่ยวข้องโดยตรงกับการสอน โดย Reyna and Weiner (2001) ในสภาพแวดล้อมการเรียนรู้ออนไลน์ ครูผู้สอนและผู้สร้างหลักสูตรจำเป็นต้องเข้าใจว่าอารมณ์ทางวิชาการของนักเรียนได้พัฒนาในด้านใดเพื่อดำเนินการปรับปรุงความเป็นอยู่ที่ดีของนักเรียนในสภาพแวดล้อมการเรียนรู้ออนไลน์ จากข้อมูลอารมณ์ทางวิชาการ เราจะเห็นว่าในการกระจายของการจัดประเภทด้านความคิดเห็นของนักเรียนมีสัดส่วนมากที่สุดสำหรับครู รองลงมาคือหลักสูตร เราเห็นว่าคุณภาพของครูมีความสำคัญต่อความเป็นอยู่ที่ดีของ

นักเรียน จากการเผยแพร่งานวิชาการเกี่ยวกับการจำแนกอารมณ์เชิงวิชาการส่วนใหญ่กระจุกอยู่ที่ “ดีใจ” และ “ผิดหวัง” ขนาดการจำแนกอารมณ์เชิงวิชาการสามารถสนับสนุนงานวิจัยที่เกี่ยวข้องกับวิชาการได้ดีขึ้น การคำนวณอารมณ์และสามารถช่วยครูและนักพัฒนาหลักสูตรคาดการณ์ความต้องการของสาธารณะซึ่งสามารถทำได้ เพื่อให้ได้อารมณ์ทางวิชาการที่อยู่ในความคิดเห็นและของพวกเขาอย่างถูกต้องและรวดเร็วจำเป็นต้องพัฒนาวิธีการที่มีประสิทธิภาพ เพื่อแก้ปัญหาที่โดยอาศัยเทคโนโลยีการเรียนรู้เชิงลึก เราสร้างกรอบการจำแนกความคิดเห็นของนักเรียนและแบบจำลองการจำแนกอารมณ์ทางวิชาการ ด้วยเหตุนี้ ชุดข้อมูลที่ใช้ในการเรียนรู้ของเครื่องจึงถูกสร้างขึ้น จากนั้นกรอบการวิเคราะห์ของ A-CNN และ LSTM-ATT ได้รับการพัฒนา (Xiang Feng, Yaojia Wei, Xianglin Pan, Longhui Qiu and Yongmei Ma, 2020) อารมณ์ทางวิชาการที่เป็นบวกดีกว่าอารมณ์ทางวิชาการที่เป็นลบในการปรับปรุงผลการเรียน (Jing Tan, Jie Mao, Yizhang Jiang and Ming Gao, 2021) อารมณ์ทางวิชาการอาจมีความสำคัญต่อการพัฒนาแรงจูงใจที่แท้จริงและยั่งยืน (Yerkes, R.M.; Dodson, J.D. 1908) บทบาทของอารมณ์ทางวิชาการจึงเป็นจุดที่น่าสนใจ เพื่อพัฒนาให้เหมาะสมกับผู้เรียน (Hannula 2006) และอารมณ์ทางวิชาการส่งผลต่อกระบวนการเรียนรู้และประสิทธิภาพในการเรียน (Goetz et al. 2006; Pekrun et al. 2002)

บทที่ 3

วิธีดำเนินการวิจัย

การวิจัยครั้งนี้มีวัตถุประสงค์ 2 ประการ คือ 1) เพื่อพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากการวิเคราะห์การรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก และ 2) เพื่อวิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนที่ได้พัฒนาขึ้น

การวิจัยเรื่อง การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึกมีรายละเอียดของขั้นตอนการดำเนินการวิจัย แหล่งข้อมูล การเก็บรวบรวมข้อมูล การวิเคราะห์ข้อมูลทั้งกระบวนการรู้จำคำพูด และการวิเคราะห์ข้อความด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก โดยจำแนกออกเป็น 2 ตอน ได้แก่ ตอนที่ 1 ตัวแปร การเก็บรวบรวมข้อมูล และกระบวนการก่อนการพัฒนาโมเดลการวิเคราะห์อารมณ์ของครูในชั้นเรียน และตอนที่ 2 การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก และวิเคราะห์ความเหมาะสมของโมเดลที่พัฒนาขึ้นมีรายละเอียด ดังนี้

ตอนที่ 1 ตัวแปร การเก็บรวบรวมข้อมูล และกระบวนการก่อนการพัฒนาโมเดลการวิเคราะห์อารมณ์ของครูในชั้นเรียน

ขั้นตอนนี้ผู้วิจัยใช้การทบทวนเอกสารและงานวิจัยที่เกี่ยวข้องเกี่ยวกับอารมณ์ครูในชั้นเรียน องค์ประกอบของอารมณ์ครูในชั้นเรียน และเครื่องมือวัดอารมณ์ครูในชั้นเรียน เพื่อจะได้ลักษณะหรือขั้นตอนการวัดตัวแปรอารมณ์ครูในชั้นเรียนในสภาพปัจจุบัน

1) ตัวแปรวิจัย

อารมณ์ครูในชั้นเรียน (Teacher's Emotions in Classroom) เป็นอารมณ์เชิงลบ เชิงบวก หรือเป็นกลางที่สะท้อนหรือสกดคุณลักษณะจากข้อความที่ได้จากกระบวนการรู้จำคำพูดจากเสียงครูในชั้นเรียนและนำมาผ่านกระบวนการการประมวลผลภาษาธรรมชาติเพื่อนำไปวิเคราะห์จำแนกด้วยโมเดลการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

2) แหล่งข้อมูล

ในการดำเนินการวิจัยเพื่อพัฒนาโมเดลและวิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความนั้น ผู้วิจัยได้เก็บรวบรวมข้อมูล

ประเภทข้อความจาก 2 แหล่งข้อมูล ได้แก่ (1) ข้อความที่ได้จากกระบวนการรู้จำคำพูด (Speech Recognition) ซึ่งเป็นกระบวนการในการแปลงไฟล์เสียงเป็นข้อความ โดยไฟล์เสียงที่นำมาใช้ในการแปลงนั้นมาจากวีดิทัศน์การจัดการเรียนการสอนทั้งแบบออนไลน์ (online) และออนไซต์ (onsite) ในรายวิชาของกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม ในปีการศึกษา 2564 – 2565 จากครูในโรงเรียนแห่งหนึ่ง และ (2) ฐานข้อมูล Wiselight Sentiment Analysis เป็นฐานข้อมูลที่ใช้สำหรับการวิเคราะห์อารมณ์จากข้อความบนสื่อสังคมออนไลน์

3) นิยามเชิงปฏิบัติการของตัวแปรวิจัย

อารมณ์ครูในชั้นเรียน (Teacher's Emotions in Classroom) หมายถึง สภาวะอารมณ์ที่ครูแสดงออกในบทบาทของผู้สอนภายในห้องเรียนผ่านคำพูด ซึ่งมีผลต่อการเรียนรู้ของนักเรียนได้ จำแนกออกเป็น 3 รูปแบบ ได้แก่ อารมณ์เชิงบวก อารมณ์ที่เป็นกลางและอารมณ์เชิงลบ

งานวิจัยนี้มีการจำแนกอารมณ์ของครูในชั้นเรียนออกเป็น 3 ประเภท โดยมีตัวอย่างของการจำแนกประเภทดังตารางที่ 3.1

ตารางที่ 1 ตัวอย่างของสถานการณ์และข้อความที่ได้จากกระบวนการรู้จำคำพูดจากครูในชั้นเรียนและตัวอย่างข้อความที่ได้จากฐานข้อมูล Wiselight Sentiment Analysis จำแนกตามประเภทของข้อความ

ตัวอย่างของสถานการณ์ที่พบข้อความแสดงอารมณ์ของครูในชั้นเรียน	ตัวอย่างของข้อความที่ได้จากกระบวนการรู้จำคำพูดของครูในชั้นเรียน	ตัวอย่างข้อความที่ได้จากฐานข้อมูล Wiselight Sentiment Analysis
อารมณ์เชิงลบ		
<ul style="list-style-type: none"> - ข้อความที่แสดงถึงความไม่มั่นใจเนื้อหาหรือองค์ความรู้ของครูผู้สอน - ข้อความที่แสดงถึงความไม่พร้อมในการสอน ไม่ว่าจะเป็นการสอน สื่อ รวมถึง อินเทอร์เน็ต - ข้อความที่แสดงถึงความไม่พอใจ แสดงอารมณ์ 	<ul style="list-style-type: none"> - ปัจจุบันนะ ครูไม่แน่ใจว่าเลี้ยงดูบุตรเขาให้คนละเท่าไรนะก็น่าจะ 30,000 บาท - ปัจจุบันเท่าไรนักเรียน อัตราค่าจ้างขั้นต่ำเท่าไรรึปัจจุบันประกาศขึ้นหรือยังโดยประมาณเอา 300 อั้งแหละ - 300 นี่มันมันนานแล้วตั้งแต่สมัยรัฐบาลยิ่งลักษณ์มั้งถ้าครูจำไม่ผิดนะ - กระทรวงอุดมศึกษาดีจึทีลอะไรอย่างเงี้ยใช้ใหม่เดี๋ยวนี้นั้นมีกระทรวงดีจึทีลใช้ใหม่อะ - แบทจะขึ้นมาดูว่าดูเรื่องใกล้ตัวก่อนภาษีเง 	<ul style="list-style-type: none"> - สมน้ำหน้ารัฐบาลไทยบอกว่าประเทศไทยเป็นเมืองพุทธ คนทำบริษัทเปียร์ข้างไปจดทะเบียนที่สิงคโปร์ เก็บภาษีสบายเลย ส่วนประเทศไทยได้แต่นั่งดู - น่าเสียดาย - เริ่มเบื่อกับการไทน้อิน

ตัวอย่างของสถานการณ์ที่พบข้อความแสดงอารมณ์ของครูในชั้นเรียน	ตัวอย่างของข้อความที่ได้จากกระบวนการรู้จำคำพูดของครูในชั้นเรียน	ตัวอย่างข้อความที่ได้จากฐานข้อมูล Wisersight Sentiment Analysis
<p>คุณเฉียวหรือหงุดหงิด</p>	<p>OK แป๊บหนึ่งนะครับ</p> <ul style="list-style-type: none"> - แป๊บหนึ่งนักเรียนจะได้มองเห็นภาพว่ากฎหมายคืออะไรนะครับแล้วก็สภาพบังคับนั้นนะ คืออะไรเออแล้วมันอยู่ตรงไหนนี่เอาตรงนี้จะอยู่ตรงนี้นะครับ - นักเรียนแป๊บหนึ่งขออนุญาตแป๊บหนึ่งนะครับ - สวีตตี้คะคนรีบเข้านะคนอื่นรีบเตรียมตัวกันพร้อมแล้วอย่าให้เพื่อนต้องรอ - แต่ที่นี้อ่านให้ขนาดที่ครูพูดเนี่ยพรวินทำอะไรอยู่พัชรพรยังไม่พร้อมหรือ 44150 คนที่คุณโดนครูเตือนบ่อย ๆ เนี่ย แล้วมีการเตือนอยู่ในคลิปบ่อย ๆ - สรุปลือเท่าไรไม่ตอบครูอะ - แล้วคนที่ยังไม่พร้อมยังไม่เปิดกล้องนี่คืออะไรครับ ครูรออยู่สักพักแล้วคนที่ยังไม่ขยับนี่คืออะไรได้ยินครูไหมได้ยินครูไหมครับ 	<p>โฆษณา... ในรายการทีวีละ คือเยอะเกินแถมบางทีก็ดูไม่เนียน</p>
อารมณ์ที่เป็นกลาง		
<ul style="list-style-type: none"> - ข้อความที่เกี่ยวข้องกับเนื้อหาในรายวิชาที่ทำการสอนทั่วไป - ข้อความที่เกี่ยวข้องกับพฤติกรรมในชั้นเรียนที่ทำเป็นกิจวัตร เช่น การเช็คชื่อนักเรียน หรือ การเรียกชื่อ 	<ul style="list-style-type: none"> - ทำให้ยุโรปทั้งทวีปนะไม่มีไม่มีทะเลทรายเลยเป็นทวีปที่ไม่มีทะเลทรายนะครับแห้งแล้งสุดก็เป็นกิ่งแห้งแล้งกิ่งทะเลทรายเขตอบอุ่นแล้วก็ยุโรปไม่มีเขตไม่ได้ตั้งอยู่ในเขตร้อนเพราะเราจะเรียกสภาพกิ่งแห้งแล้งของยุโรปว่ากิ่งแห้งแล้งเขตอบอุ่นยังมีลักษณะของพืชที่ราบเรียบไม่สนิหระวังตกนะ - ปัจจัยที่ส่งผลต่อสภาพภูมิอากาศก็คือที่ตั้ง 	<ul style="list-style-type: none"> - A กับ B ต่างกันตรงราคาซ่อมบำรุง ราคาซ่อมที่ต่างกันน่าจะเป็นจุดที่เลือกนิยม B มากกว่า แต่ถ้ามีเงินซ่อมบำรุงก็จบ สำคัญที่สุดคือ อยู่ที่ความต้องการของเจ้าของ

ตัวอย่างของสถานการณ์ที่พบข้อความแสดงอารมณ์ของครูในชั้นเรียน	ตัวอย่างของข้อความที่ได้จากกระบวนการรู้จำคำพูดของครูในชั้นเรียน	ตัวอย่างข้อความที่ได้จากฐานข้อมูล Wisersight Sentiment Analysis
นักเรียน เพื่อตอบคำถาม	<p>นะครับลักษณะภูมิประเทศในการวางตัวของแนวเทือกเขาอะไรต่างๆอิทธิพลจากกระแสน้ำกระแสน้ำเมื่อกี้มันได้ที่กระแสน้ำนะ กระแสน้ำอุ่น 2 กระแสน้ำเย็นกับกระแสน้ำอุ่นละครับเดี๋ยวครูขยายใจให้สภาพภูมิอากาศนี้เรา</p> <ul style="list-style-type: none"> - วัฒนธรรมประเภทวัตถุธรรมก็คือมันแหละวัตถุก็คือสิ่งที่จับต้องได้ Notebook ที่เรียนใช้อยู่ก็เป็นวัตถุธรรมนะ iPhone สมาร์ทโฟนที่นักเรียนใช้อยู่ก็เป็นวัตถุธรรมนะครับ - คณะรัฐมนตรีเนี่ยประกอบการก็คือ 36 คน นะฮะ 36 คนนายก 1 รัฐมนตรีอื่นอีก35 คน - ผู้เยาว์สามารถทำพินัยกรรมได้เมื่ออายุ 15 ปีบริบูรณ์นะครับ - 10 มาใหม่ครับ ชนัญชัยนักเรียนครับ เวลาใกล้ถึงชื่อนักเรียนนักเรียนเปิดไม้ไผ่ได้เลย - สำหรับวันนี้มีใครมีประเด็นคำถามเพิ่มเติมไหมคะถ้าไม่มีใครมีประเด็นคำถามอะไรนะ ค่ะก็ ขอให้นักเรียนไปพักผ่อนแล้วเจอกันคาบหน้าคะ สำหรับวันนี้ก็สวัสดีค่ะสวัสดีค่ะ เด็กๆสวัสดีทุกๆคนนะจะไปพักผ่อนให้เรียบร้อยนะ 	- สวัสดิ์วันพุธ

ตัวอย่างของสถานการณ์ที่พบข้อความแสดงอารมณ์ของครูในชั้นเรียน	ตัวอย่างของข้อความที่ได้จากกระบวนการรู้จำคำพูดของครูในชั้นเรียน	ตัวอย่างข้อความที่ได้จากฐานข้อมูล Wisersight Sentiment Analysis
อารมณ์เชิงบวก		
<ul style="list-style-type: none"> - ข้อความที่เกี่ยวข้องกับการชมเชยการทำงาน ของนักเรียนหรือการตอบคำถาม - ข้อความที่เกี่ยวข้องกับการเสริมแรงหรือการให้กำลังใจในการเรียน ของนักเรียน - ข้อความที่ครูตอบรับพฤติกรรมบางอย่าง ของนักเรียนด้วยความตั้งใจ เช่น เมื่อนักเรียนถามเพราะมีข้อสงสัย ครูพยายามอธิบายเนื้อหาใหม่ให้กับนักเรียน 	<ul style="list-style-type: none"> - สำหรับวันนี้นักเรียนเก่งมากเลยปรบมือให้ตัวเองครับขอบคุณครับ - กล้องนี้คือความ create เป็นเลิศมากนะคะ โดยเฉพาะผลิตภัณฑ์นี้นะคะลูกค้าเหมือนแบบ เขาตั้งชื่อผลิตภัณฑ์ออกมาเนี่ยก็ดึงดูดลูกค้าแล้วนะลูกค้าให้สนใจคะ - ของเพื่อนตอบได้ดีเลยนะคะของนพรตอบได้ดีเลย - แอฟริกาได้ข้อมูลเยอะนี่ก็ได้ข้อมูลเยอะนะที่แต่ละกลุ่มนี้นะครับนักเรียนเก่งมากเลยนะครับได้ข้อมูลเยอะแยะเลยนะครับ - นักเรียนรู้แล้วเนี่ยสามารถเอาไปคำนวณภาษีให้กับคุณพ่อคุณแม่ได้นะ - ห้องนี้น่ารักนะอาจารย์เขาจะโต้ตอบตลอด - ที่เหลือแสนหนึ่งปะคะ 110,000 บาท ไข่ลูก 110,000 - ถูกต้องครับ ก็คือการผิดคำพูดโดยการขึ้นดำรงตำแหน่งนายกรัฐมนตรีของพลเอกสุจินดาคราประยูรนั่นเอง 	<ul style="list-style-type: none"> - แดงโดนใจดีจริง ๆ - ต้องไปลองกันนะ - ชอบคุณค่า - ทางหัวหน้างานได้โทรมาแล้วนะคะ ชอบคุณที่ทาง..... ใส่ใจปัญหาของลูกค้าและพร้อมจะรับผิดชอบและแก้ไขไปในทางที่ดีคะ - ผมรักมันนี่ ชัดเจนทราบแล้วเปลี่ยน - น่าสนใจไปมะ!!!

4) การเก็บรวบรวมข้อมูล

ในการดำเนินวิจัยเพื่อพัฒนาโมเดลและวิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความนั้น ผู้วิจัยได้เก็บรวบรวมข้อมูลประเภทข้อความจาก 2 แหล่งข้อมูล ได้แก่ (1) วิดีทัศน์ที่ได้จัดการเรียนการสอนออนไลน์ (online)

และออนไซต์ (onsite) ในรายวิชาของกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนาและวัฒนธรรม ในปี การศึกษา 2564 - 2565 จากครูในโรงเรียนแห่งหนึ่งในสังกัดสำนักงานเขตพื้นที่การศึกษามัธยมศึกษา กรุงเทพมหานคร เขต 2 จำนวน 1 โรงเรียน จำนวน 3 ท่าน ซึ่งเป็นครูในระดับชั้นมัธยมศึกษาตอนต้น และมีรายละเอียดการขอเก็บข้อมูลดังตารางที่ 2

ตารางที่ 2 แสดงจำนวนและเวลาของวิดิทัศน์การจัดการเรียนการสอนของครูในแต่ละระดับชั้น

ชั้นมัธยมศึกษาปีที่	ครูผู้สอน	วิดิทัศน์ที่	จำนวนวิดิทัศน์	รวมเวลา
1	A	1 - 3	3	2 ชั่วโมง 30 นาที
2	B	4 - 8	4	3 ชั่วโมง 20 นาที
3	C	9 - 11	3	2 ชั่วโมง 30 นาที

ในแต่ละวิดิทัศน์เป็นการบันทึกการจัดการเรียนการสอนในแต่ละคาบเรียน ซึ่งในแต่ละคาบเรียนใช้เวลาในการจัดการเรียนการสอนประมาณคาบเรียนละ 50 นาที โดยเมื่อรวมเวลาที่ใช้ในการจัดการเรียนการสอนทั้งหมดเป็นข้อมูลที่มีความยาวประมาณ 8 ชั่วโมง 20 นาที และ (2) ฐานข้อมูล Wisersight Sentiment Analysis เป็นฐานข้อมูลที่ไว้ใช้สำหรับการวิเคราะห์อารมณ์จากข้อความบนสื่อสังคมออนไลน์ ซึ่งมีการจำแนกประเภทข้อความออกเป็น 4 ประเภท ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ ข้อความที่เป็นกลาง และข้อคำถาม รวม 26,737 ข้อความ และได้มีการจัดกระทำข้อมูลโดยนำข้อความที่เป็นข้อคำถามออก เพื่อให้สอดคล้องกับบริบทที่ศึกษา

5) การจัดกระทำข้อมูลเพื่อเตรียมเข้าสู่กระบวนการรู้จำคำพูด

เมื่อได้ข้อมูลวิดิทัศน์การจัดการเรียนการสอนของครูมาเป็นที่เรียบร้อยแล้ว ผู้วิจัยได้นำวิดิทัศน์ต่าง ๆ มาจัดกระทำข้อมูลเพื่อเตรียมพร้อมสำหรับกระบวนการรู้จำคำพูด โดยมีรายละเอียดพอสังเขป ดังนี้

- (1) เมื่อได้ข้อมูลวิดิทัศน์การเรียนการสอนมานั้น ผู้วิจัยจะนำมาเฉพาะข้อมูลเสียงของวิดิทัศน์นั้น ๆ มาทำการแบ่งข้อมูลออกเป็นช่วง ๆ ทีละประโยค
- (2) โดยแต่ละช่วงที่แบ่งนั้นจะกำหนดให้มีความยาวไม่เกิน 1 นาที เนื่องจากมีข้อจำกัดของการเขียนโค้ดในกระบวนการรู้จำคำพูด โดยไฟล์เสียงที่ได้มาจะมีสกุลไฟล์เป็น .Mp4
- (3) จากนั้นทำการแปลงไฟล์เสียงที่ได้มาจากสกุลไฟล์ .Mp4 แปลงเป็นไฟล์สกุล .wave
- (4) ผู้วิจัยเก็บรวบรวมข้อมูลไฟล์สกุล .wave ทั้งหมดอย่างเป็นระบบ และอัปโหลดเพื่อเตรียมความพร้อมสำหรับการใช้งานบน Google Drive

6) กระบวนการรู้จำคำพูด (Speech Recognition)

ภายหลังจากที่ได้ไฟล์เสียงในสกุลที่ต้องการเป็นที่เรียบร้อยแล้ว ผู้วิจัยได้ทำการเขียนโค้ดเพื่อแปลงไฟล์เสียงเหล่านี้เป็นข้อความในกระบวนการรู้จำคำพูด เพื่อที่จะได้นำข้อความที่ได้ไปทำการวิเคราะห์ความรู้สึกต่อไป

สำหรับการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากกระบวนการรู้จำคำพูดให้นำข้อมูลเสียงที่ได้มาประมวลผลผ่านกระบวนการรู้จำคำพูด (Speech Recognition) โดยใช้โมดูล SpeechRecognition ซึ่งเป็นไลบรารีในภาษาไพธอน และอ่านค่าของไฟล์ .Mp3 และแบ่งเสียงเป็นช่วงเสียงที่มีความยาว 55000 ms โดยใช้ฟังก์ชัน `'AudioSegment.from_file()'` และ `'make_chunks()'` จากไลบรารี pydub เพื่อแปลงเสียงในแต่ละวินาทีเป็นข้อความ โดยมีรายละเอียดดังนี้

- (1) จัดเตรียมไฟล์เสียงโดยย้ายไฟล์ที่แปลงแล้วไปไว้ในโฟลเดอร์ที่ชื่อ src
- (2) ติดตั้งไลบรารี speech_recognition สำหรับการแปลงเสียงเป็นข้อความ
- (3) เริ่มต้นการแปลงข้อมูล โดยใช้ฟังก์ชัน listdir จากโมดูล os ประกอบกับการเขียนฟังก์ชันวนซ้ำ (for loop) เพื่ออ่านทีละไฟล์จากโฟลเดอร์ src
- (4) เครื่องจะทำการแปลงไฟล์เสียงเป็นข้อความและวนซ้ำทีละไฟล์จนครบทั้งโฟลเดอร์
- (5) เครื่องจะบันทึกข้อความแต่ละลงไฟล์เสียงในลงไฟล์ csv ที่ได้เตรียมไว้ตั้งแต่แรก โดยจะบันทึกไฟล์เสียงทีละแถว

7) การจัดประเภทของข้อความ

ผู้วิจัยทำการตรวจสอบประเภทของข้อความที่ได้จากกระบวนการรู้จำคำพูดแล้ว และได้ขอความอนุเคราะห์จากครูกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนาและวัฒนธรรมที่มีความเชี่ยวชาญชำนาญในเนื้อหาสาระและมีประสบการณ์ในการสอนรายวิชาต่าง ๆ ในกลุ่มสาระการเรียนรู้สังคมศึกษา ศาสนา และวัฒนธรรม ในระดับชั้นมัธยมศึกษาตอนต้นมากกว่า 10 ปี จำนวน 1 ท่าน ในโรงเรียนที่ทำการเก็บข้อมูลมาเป็นผู้จำแนกอารมณ์ของข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยแบ่งเป็น อารมณ์เชิงบวก อารมณ์เป็นกลาง และอารมณ์เชิงลบ จากนั้นผู้วิจัยได้ได้นำข้อความและการจัดประเภทของข้อความไปรวมไว้เป็นฐานข้อมูล และทำการจัดกระทำข้อมูล (Manipulation) ให้ข้อมูลทั้งสองคุณลักษณะพร้อมที่จะนำไปใช้งานในระยะต่อไปด้วยภาษาไพธอน

ตอนที่ 2 การพัฒนาโมเดลการวิเคราะห์อารมณ์ความรู้สึกในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก และวิเคราะห์ความเหมาะสมของโมเดลที่พัฒนาขึ้น

1) ข้อมูลที่นำมาใช้ในการวิเคราะห์ความรู้สึกด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกนั้นเป็นการวิเคราะห์ที่ควรใช้ข้อมูลขนาดใหญ่จำนวนมาก เนื่องจากคาดหวังว่าการที่มีข้อมูลจำนวนมากจะทำให้การสุ่มตัวอย่างที่ก่อให้เกิดความลำเอียงนั้นน้อยลง ส่งผลทำให้การวิเคราะห์ด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกสามารถทำได้อย่างมีประสิทธิภาพซึ่งย่อมส่งผลทางตรงต่อประสิทธิภาพและความถูกต้องในการจำแนกประเภทข้อความ ซึ่งสอดคล้องกับการศึกษาของ Ajiboye et al. (2015) ที่ได้ทำการศึกษาเกี่ยวกับขนาดอิทธิพลและประสิทธิภาพในการทำนายที่ขึ้นอยู่กับขนาดของข้อมูล ซึ่งพบว่า ข้อมูลชุดฝึกฝนที่มีขนาดใหญ่ที่สุดทำให้ประสิทธิภาพความถูกต้องในการทำนายสูงที่สุดและมีความคงเส้นคงวาของความถูกต้องสูงสุด ฉะนั้นนอกจากข้อความที่ได้จากกระบวนการรู้จำคำพูดที่ผู้วิจัยได้ทำการเก็บรวบรวมข้อมูลเองแล้ว ผู้วิจัยจึงได้เลือกนำฐานข้อมูล Wisersight Sentiment Analysis ซึ่งเป็นฐานข้อมูลที่ไว้ใช้สำหรับการวิเคราะห์อารมณ์จากข้อความบนสื่อสังคมออนไลน์มาร่วมในการสร้างชุดข้อมูลสำหรับการพัฒนาโมเดลนี้ด้วย

ฐานข้อมูล Wisersight Sentiment Analysis เป็นฐานข้อมูลที่ไว้ใช้สำหรับการวิเคราะห์อารมณ์จากข้อความบนสื่อสังคมออนไลน์ ซึ่งมีการจำแนกประเภทข้อความออกเป็น 4 ประเภท ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ ข้อความที่เป็นกลาง และข้อคำถาม รวม 26,737 ข้อความ ซึ่งฐานข้อมูลดังกล่าวเป็นฐานข้อมูลที่ได้รับการสนับสนุนในการพัฒนาจากสถาบันวิจัยปัญญาประดิษฐ์ประเทศไทย จากความร่วมมือระหว่างสถาบันวิทยสิริเมธี และสำนักงานส่งเสริมเศรษฐกิจดิจิทัล (VISTEC - depa Thailand Artificial Intelligence Research Institute) ซึ่งมีการเผยแพร่และสามารถนำฐานข้อมูลดังกล่าวมาวิเคราะห์ต่อยอดและพัฒนาได้ โดยเฉพาะอย่างยิ่งในการวัดผลโมเดลประเภทการจำแนกประเภทหลายกลุ่ม (Multi-class sequence classification) ซึ่งฐานข้อมูลดังกล่าวเป็นฐานข้อมูลที่มีความใกล้เคียงกับบริบทที่กำลังทำการศึกษามากที่สุดเมื่อเปรียบเทียบกับฐานข้อมูลอื่น ๆ ได้แก่ ฐานข้อมูล Wongnai Reviews และฐานข้อมูล English-Thai Generated Review ผู้วิจัยจึงได้เลือกนำฐานข้อมูล Wisersight Sentiment Analysis มารวมกับฐานข้อมูลที่ได้จากการกระบวนการรู้จำคำพูดในงานวิจัยครั้งนี้

เนื่องจากฐานข้อมูล Wiselight Sentiment Analysis เป็นฐานข้อมูลที่มีการจำแนกออกเป็น 4 ประเภท ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ ข้อความที่เป็นกลาง และข้อคำถาม ผู้วิจัยจึงได้ทำการนำข้อมูลประเภทข้อคำถามออกเนื่องจากไม่ได้อยู่ในบริบทที่กำลังศึกษา และได้ทำการจัดกระทำข้อมูลโดยนำไปรวมกับฐานข้อมูลที่ได้จากกระบวนการรู้จำคำพูดซึ่งมีการจำแนกประเภทข้อความไว้ 3 ประเภท ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ และข้อความที่เป็นกลาง ซึ่งมีจำนวนข้อความมากถึง 23,974 ข้อความ

2) การวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

โมเดลที่พัฒนาขึ้นสำหรับการวิเคราะห์อารมณ์ครูในชั้นเรียนในงานวิจัยนี้ จำแนกออกเป็น 3 กลุ่ม ได้แก่ กลุ่มที่ 1 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง จำนวน 4 โมเดล กลุ่มที่ 2 โมเดลที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder และมีการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่องจำนวน 4 โมเดล และกลุ่มที่ 3 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้เชิงลึก จำนวน 2 โมเดล ดังตารางที่ 3

ตารางที่ 3 แสดงกลุ่มของโมเดล ชื่อและตัวย่อของโมเดลที่ใช้ในการจำแนกอารมณ์ครูในชั้นเรียน

โมเดลที่	ประเภทของโมเดล			โมเดลที่ใช้ในการจำแนก	ตัวย่อของโมเดล
	กลุ่มที่ 1	กลุ่มที่ 2	กลุ่มที่ 3		
1	✓			Logistic Regression (LR)	LR
2	✓			Naive Bayes (NB)	NB
3	✓			Support Vector Machine (SVM)	SVM
4	✓			Random Forests (RF)	RF
5		✓		Logistic Regression (LR)	LR + MUSE
6		✓		Naive Bayes (NB)	NB + MUSE
7		✓		Support Vector Machine (SVM)	SVM + MUSE
8		✓		Random Forests (RF)	RF + MUSE
9			✓	Long short-term memory (LSTM)	LSTM
10			✓	Bidirectional Encoder Representations from Transformer (BERT)	BERT

หมายเหตุ กลุ่มที่ 2 เป็นโมเดลที่มีการสกัดคุณลักษณะด้วยการเรียนรู้เชิงลึก โดยใช้ Multilingual Universal Sentence Encoder (MUSE)

(1) การวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยโมเดลกลุ่มที่ 1 โมเดลที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง

- ขั้นตอนการวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยโมเดลกลุ่มที่ 1

ภายหลังจากที่ได้นำฐานข้อมูล Wisersight Sentiment Analysis มารวมกับฐานข้อมูลที่ได้จากกระบวนการรู้จำคำพูดที่ได้จากชั้นเรียน ผู้วิจัยได้นำข้อมูลดังกล่าวไปเข้าสู่การวิเคราะห์ความรู้สึกด้วยการเรียนรู้ของเครื่อง โดยใช้ Python version 3.6.1 และวิเคราะห์ข้อมูลบน Google colab โดยมีรายละเอียดดังนี้

- (1) ทำการโหลดฐานข้อมูลเข้าสู่เครื่อง และสำรวจข้อมูลต่าง ๆ โดยคร่าว รวมถึงมีการกำหนดชื่อคุณลักษณะให้เหมาะสม พร้อมใช้งาน

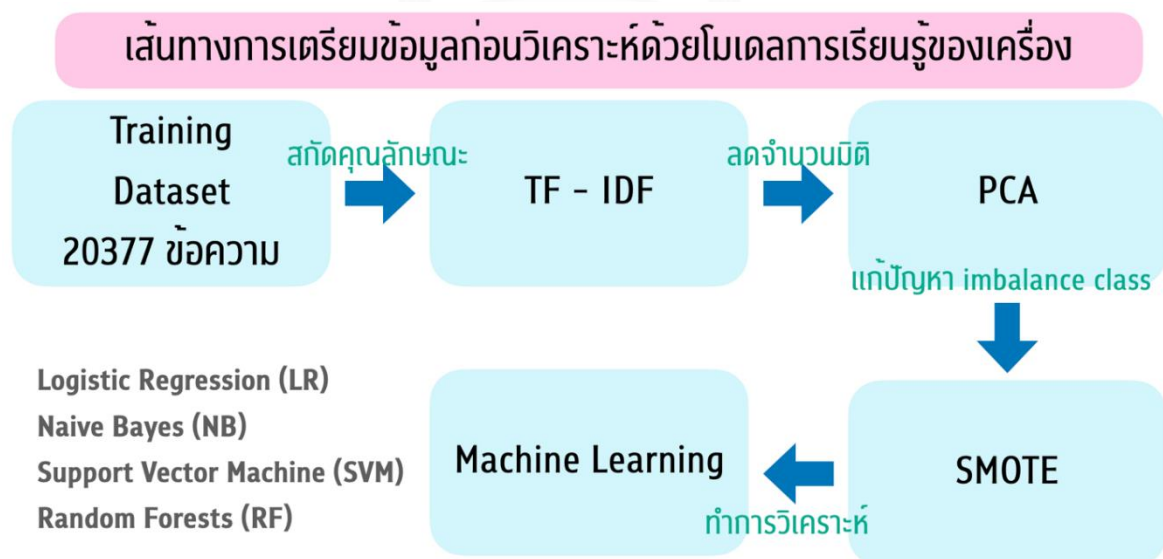
- (2) มีการเขียนฟังก์ชันสำหรับการจัดกระทำข้อความและการตัดคำในแต่ละข้อความ เพื่อที่จะสะดวกในการเรียกใช้งานในกระบวนการ pre-processing
- (3) แบ่งฐานข้อมูลออกเป็น 2 ส่วน ได้แก่ ชุดข้อมูลฝึกฝน (training dataset) และชุดข้อมูลทดสอบ (test dataset) โดยกำหนดให้สัดส่วนของชุดข้อมูลฝึกฝนต่อชุดข้อมูลทดสอบอยู่ที่ 85 : 15 ซึ่งมีข้อมูลชุดฝึกฝนคิดเป็น 20377 ข้อความ และข้อมูลชุดทดสอบ 3597 ข้อความ โดยมีการกำหนดค่าเริ่มต้นในการแบ่งข้อมูล คือ หมายเลข 123
- (4) เมื่อทำการ pre-processing ข้อความที่ได้มาจากฐานข้อมูลทั้งหมดเรียบร้อยแล้ว จากนั้นนำไปข้อมูลที่ได้ไปทำการสกัดคุณลักษณะ (Feature Extraction) ด้วยวิธีการ TF - IDF โดยเป็นการสร้างคุณลักษณะจากข้อความทั้งหมดในฐานข้อมูล พร้อมทั้งนับความถี่ของคำที่ปรากฏอยู่ในฐานข้อมูลทั้งหมด แล้วจึงนำมาคำนวณเพื่อหาน้ำหนักของคำที่ปรากฏในเอกสาร
- (5) จากนั้นเมื่อนำข้อมูลที่ได้จากการสกัดคุณลักษณะของข้อความไปวิเคราะห์ด้วยโมเดลต่าง ๆ โดยใช้โมเดลการวิเคราะห์การถดถอยโลจิสติก (Logistic Regression) คาดหมายว่าต้องใช้เวลาในการเรียนรู้ของเครื่องนานมาก เนื่องจากคำที่ปรากฏอยู่ในฐานข้อมูลทั้งหมดมีจำนวนมาก จึงเกิดปัญหาในการวิเคราะห์ข้อมูล ซึ่งการสกัดคุณลักษณะของข้อความด้วยเทคนิค TF - IDF ซึ่งมีพารามิเตอร์ตัวหนึ่งที่สำคัญ ได้แก่ ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ (min_df) เป็นพารามิเตอร์ที่ผู้วิจัยสามารถเลือกปรับได้ว่า ต้องการให้คำที่ปรากฏอยู่ในฐานข้อมูลทั้งหมดมีความถี่เท่าไร เนื่องจากในการวิเคราะห์ด้วยการเรียนรู้ของเครื่อง การที่บางคำที่มีความถี่น้อยมาก ๆ หรือเข้าใกล้ 0 นั้นอาจจะไม่จำเป็นต่อการเรียนรู้ของเครื่อง ซึ่งผู้วิจัยได้ทำการวิเคราะห์เปรียบเทียบเพื่อตรวจสอบคุณภาพของโมเดล
- (6) แม้ว่าจะกำหนดพารามิเตอร์ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความแล้ว แต่จำนวนคำหรือคุณลักษณะภายในโมเดลมีจำนวนมาก ซึ่งนับว่ายังคงมีจำนวนมาก ผู้วิจัยจึงลดจำนวนมิติของโมเดลด้วยการทำ Principle Component Analysis (PCA) และได้ทำการวิเคราะห์เปรียบเทียบเพื่อตรวจสอบคุณภาพของโมเดลว่าควรกำหนดให้ร้อยละความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลการจำแนกให้น้อยลงอาจจะไม่จำเป็นต้องร้อยละ 100 เท่าเดิม เพื่อลดจำนวนคุณลักษณะภายในโมเดลลง ใช้เวลาในการประมวลผลน้อยลง แต่ยังมีประสิทธิภาพในการจำแนกประเภทของโมเดลใกล้เคียงเดิม
- (7) เนื่องจากตัวแปรตามเป็นประเภทของข้อความซึ่งแบ่งออกเป็น 3 กลุ่ม ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ และข้อความที่เป็นกลาง ซึ่งแต่ละกลุ่มมีจำนวนข้อความที่

แตกต่างกันอยู่มากและไม่สมดุลกัน เนื่องจากอาร์มณของครูในชั้นเรียนที่แสดงออกมา นั้น ส่วนใหญ่เป็นข้อความที่เป็นกลาง ผู้วิจัยจึงแก้ปัญหาดังกล่าวด้วยการสังเคราะห์ ข้อความด้วยเทคนิค SMOTE (Chawla et al., 2002)

- (8) ผู้วิจัยใช้ไลบรารี sklearn ในการเรียนรู้ของเครื่องทั้ง 4 โมเดล ได้แก่ (1) Logistic Regression (2) Naive Bayes (3) Support Vector Machine และ (4) Random Forests ซึ่งในแต่ละโมเดลมีไฮเปอร์พารามิเตอร์จำนวนมาก ทำให้การปรับจูนเพื่อหาไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดทำได้ยาก ผู้วิจัยจึงเลือกใช้ฟังก์ชัน GridSearchCV ในการหาไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดในแต่ละโมเดล การจำแนก
- (9) เมื่อได้ไฮเปอร์พารามิเตอร์ที่เหมาะสมที่สุดในแต่ละโมเดลแล้วจึงนำไปทดสอบกับชุดข้อความทดสอบที่ได้แบ่งไว้แต่แรกเพื่อเปรียบเทียบประสิทธิภาพในการจำแนกประเภทข้อความของแต่ละโมเดล

● กระบวนการพัฒนาประสิทธิภาพของโมเดลกลุ่มที่ 1

ในการพัฒนาประสิทธิภาพของโมเดลการวิเคราะห์ความรู้สึกจากการเรียนรู้ของเครื่อง เนื่องจากจำนวนข้อความที่ใช้ในการวิเคราะห์มีจำนวนมาก โดยเฉพาะอย่างยิ่งการจำแนกประเภท ข้อมูลที่เป็นข้อความซึ่งมีจำนวนคำหรือคุณลักษณะในโมเดลเป็นจำนวนมาก ทำให้ประสิทธิภาพของโมเดลการเรียนรู้ของเครื่องในการจำแนกประเภทของข้อความอาจทำได้ไม่ดีเท่าที่ควร ผู้วิจัยจึงได้พัฒนาโมเดลโดยมีประเด็นในกระบวนการพัฒนาประสิทธิภาพของโมเดล ตามภาพที่ 4



ภาพที่ 4 แสดงเส้นทางการเตรียมข้อมูลก่อนการวิเคราะห์ด้วยโมเดลการเรียนรู้ของเครื่อง

การสกัดคุณลักษณะด้วยวิธีการ TF – IDF

เนื่องจากการสกัดคุณลักษณะด้วยวิธีการ TF – IDF เป็นการสร้างคุณลักษณะจากคำในข้อความทั้งหมดในฐานข้อมูล โดยนับความความถี่ของคำที่ปรากฏอยู่ในฐานข้อมูลทั้งหมด แล้วจึงนำมาคำนวณเพื่อหาน้ำหนักของคำที่ปรากฏในเอกสาร แต่เนื่องจากจำนวนข้อความในฐานข้อมูลมีจำนวนมากและในแต่ละข้อความมีหลายคำ ทำให้หากนำคำทั้งหมดในฐานข้อมูลมาสร้างเป็นคุณลักษณะเพื่อสร้างโมเดลจำแนก อาจจะทำให้เกิดปัญหา overfit ได้ ซึ่งเป็นสถานการณ์ที่ไม่พึงปรารถนาในการเรียนรู้ของเครื่องที่รูปแบบในการเรียนรู้ของเครื่องนั้นเข้าไปชุดข้อมูลฝึกฝนมากเกินไป ทำให้การนำโมเดลไปใช้ในจำแนกสำหรับข้อมูลทดสอบประสิทธิภาพในการทำนายอาจไม่ดีนัก ประกอบกับเวลาที่ใช้ในการเรียนรู้ของเครื่องในแต่ละโมเดลย่อมใช้เวลาในการวิเคราะห์ที่นานขึ้น เนื่องจากข้อมูลมีขนาดใหญ่ขึ้น คุณลักษณะหรือคำภายในโมเดลมีจำนวนมากย่อมส่งผลทางตรงต่อเวลาที่ใช้ในการวิเคราะห์

เทคนิค TF - IDF มีพารามิเตอร์ตัวหนึ่งที่สำคัญ ได้แก่ ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ (min_df) ซึ่งเป็นพารามิเตอร์ที่สามารถเลือกปรับได้ว่า ต้องการให้คำที่ปรากฏอยู่ในฐานข้อมูลทั้งหมดมีความถี่เท่าไร ถึงจะเหมาะสมกับโมเดลที่ผู้วิจัยต้องการ โดยที่ผู้วิจัยจะต้องชั่งน้ำหนักระหว่างความลำเอียงที่อาจจะเกิดขึ้นและความถูกต้องโดยทั่วไปของข้อมูลที่น่ามาใช้ในการสร้างโมเดลทำนาย โดยผู้วิจัยเริ่มจากการกำหนดให้ ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ เป็น 20, 80, 150 และ 200 ซึ่งจำนวนของคำหรือคุณลักษณะที่นำไปสร้างโมเดลการจำแนกก็มีแนวโน้มที่ลดลง ซึ่งการกำหนดความถี่ขั้นต่ำที่ปรากฏในชุดข้อความให้มีมากขึ้น จำนวนคำหรือคุณลักษณะในโมเดลก็จะมีขนาดที่น้อยลง เนื่องจากคำในฐานข้อมูลทั้งหมดมีปริมาณลดหลั่นกันไปตามการใช้งาน ไม่ได้เท่ากันทุกคำ ฉะนั้นจึงเป็นเหตุผลที่ทำให้ผู้วิจัยนำพารามิเตอร์ความถี่ขั้นต่ำที่ปรากฏอยู่ชุดข้อความมาเป็นหนึ่งในการกระบวนการพัฒนาประสิทธิภาพของโมเดล ซึ่งจะนำเสนอในผลการวิเคราะห์ข้อมูลต่อไป

การลดจำนวนมิติด้วยการทำ Principle Component Analysis

แม้ว่าการกำหนดพารามิเตอร์ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความแล้วนั้น แต่จำนวนคำหรือคุณลักษณะภายในโมเดลยังคงมีมากเมื่อเทียบกับข้อมูลในลักษณะอื่น ๆ ที่ไม่ใช่ข้อความ ผู้วิจัยจึงลดจำนวนมิติของโมเดลด้วยการทำ Principle Component Analysis (PCA) เนื่องจากเป็นกระบวนการที่มีวัตถุประสงค์ในการลดจำนวนมิติของข้อมูลลง โดยยังคงรักษาความผันแปรที่เกิดขึ้นภายในตัวแปรไว้ได้

ในการลดจำนวนมิติของข้อมูล และได้ทำการวิเคราะห์เปรียบเทียบเพื่อตรวจสอบคุณภาพของโมเดลว่าควรกำหนดให้ร้อยละความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลในน้อยลง เพื่อลดจำนวน

คุณลักษณะภายในโมเดลลง ใช้เวลาในการประมวลผลน้อยลง และประสิทธิภาพในการจำแนกประเภทของโมเดลไม่ได้แตกต่างจากเดิมมากนัก

วิธีสังเคราะห์ข้อมูลเพิ่ม (Synthetic Minority Oversampling TEchnique: SMOTE)

เนื่องจากตัวแปรตามของข้อมูลเป็นตัวแปรจัดประเภท ซึ่งแบ่งออกเป็น 3 กลุ่ม ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ และข้อความที่เป็นกลาง ซึ่งแต่ละกลุ่มมีจำนวนข้อความที่แตกต่างกันอยู่มากและไม่สมดุลกัน ผู้วิจัยจึงแก้ปัญหาดังกล่าวด้วยเทคนิค SMOTE (Chawla et al., 2002)

• การประเมินคุณภาพของโมเดลที่ใช้ในการวิเคราะห์

การประเมินความเหมาะสมของโมเดลการวิเคราะห์ความรู้สึกจากการเรียนรู้ของเครื่องผ่านทางข้อความที่ได้จากกระบวนการเรียนรู้จำคำพูด เนื่องจากเป็นโมเดลในการจำแนกอารมณ์ความรู้สึกในชั้นเรียน ผู้วิจัยใช้ Confusion Matrix ในการประเมินผลการวิเคราะห์ พิจารณาจากดัชนี Accuracy Precision Recall และ F1-measure เพื่อใช้ในการประเมินความเหมาะสมของโมเดล โดยดัชนีแต่ละตัวมีรายละเอียด ดังนี้

(1) Accuracy (acc) คือ ค่าความถูกต้องที่ได้จากการทำนาย คำนวณจากสัดส่วนของค่าที่โมเดลทำนายถูกต้องทั้งหมดเทียบกับค่าทั้งหมด ตามสูตร $\frac{TP+TN}{TP + TN + FP + FN}$ โดยอักษรย่อแต่ละตัวมีความหมาย ดังนี้

- TP (True Positive) คือ จำนวนข้อความที่โมเดลที่พัฒนาขึ้นสามารถทำนายได้ถูกต้องในประเภทของข้อความที่เราสนใจ เช่น เมื่อนำข้อความเชิงบวกไปให้เครื่องทำนายสามารถทำนายได้ว่าเป็นข้อความเชิงบวก
- TN (True Negative) คือ จำนวนข้อความที่โมเดลที่พัฒนาขึ้นสามารถทำนายได้ถูกต้องในประเภทของข้อความที่เราไม่ได้สนใจ เช่น เมื่อนำข้อความเชิงลบหรือเป็นกลางไปให้เครื่องทำนาย สามารถทำนายได้ว่าไม่เป็นข้อความเชิงบวก
- FP (False Positive) คือ จำนวนข้อความที่โมเดลที่พัฒนาขึ้นสามารถทำนายผิดในประเภทของข้อความที่เราสนใจ เช่น เมื่อนำข้อความเชิงบวกไปให้เครื่องทำนาย แต่เครื่องทำนายเป็นข้อความเชิงลบหรือเป็นกลาง
- FN (False Negative) คือ จำนวนข้อความที่โมเดลที่พัฒนาขึ้นสามารถทำนายผิดในประเภทของข้อความที่เราไม่ได้สนใจ เช่น เมื่อนำข้อความเชิงลบหรือเป็นกลางไปให้เครื่องทำนาย แต่ได้ผลการทำนายเป็นข้อความเชิงบวก

- (2) Precision คือ ค่าความแม่นยำ คำนวณจากสัดส่วนของค่าที่โมเดลทำนายเป็นกลุ่มที่กำลังพิจารณาถูกเทียบกับค่าที่โมเดลทำนายเป็นกลุ่มที่กำลังพิจารณาทั้งถูกและผิด ตามสูตร

$$\text{Precision} = \frac{TP}{TP + FP}$$

- (3) Recall คือ ความไว คำนวณจากสัดส่วนของค่าที่โมเดลทำนายเป็นกลุ่มที่กำลังพิจารณาถูกเทียบกับค่าเหตุการณ์จริงเป็นกลุ่มที่กำลังพิจารณา ตามสูตร

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

- (4) F1-measure คือ ค่าเฉลี่ยของความสามารถของโมเดลซึ่งเกิดจาก Precision และ Recall โดยคำนวณตามสูตร

$$F1 = 2 \times \frac{\text{precision} \cdot \text{recall}}{\text{precision} + \text{recall}}$$

(2) การวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยโมเดลกลุ่มที่ 2 โมเดลที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder และมีการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง

การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนโดยโมเดลที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder และมีการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง ผู้วิจัยได้เลือก Multilingual Universal Sentence Encoder มาเป็นโมเดลที่ใช้ในการสกัดคุณลักษณะของข้อความก่อนการนำไปวิเคราะห์จำแนกอารมณ์ด้วยการเรียนรู้ของเครื่องด้วยโมเดลทั้ง 4 โมเดล

- ขั้นตอนการวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยโมเดลกลุ่มที่ 2

Multilingual Universal Sentence Encoder (MUSE)

ในการวิเคราะห์เพื่อจำแนกความรู้สึกของข้อความโดยใช้โมเดล Multilingual Universal Sentence Encoder นั้น ผู้วิจัยใช้ไลบรารี tensorflow ในการแปลงข้อความที่เป็นภาษาไทยเข้ารหัสเป็นตัวเลขเพื่อใช้ในการสร้างโมเดลเพื่อวิเคราะห์ (encoder) ซึ่งสามารถสร้างเป็นข้อมูลที่มีคุณลักษณะ 512 คุณลักษณะ สำหรับข้อมูลชุดฝึกฝนมีจำนวนข้อมูล 20,377 หน่วยข้อมูล และสำหรับข้อมูลชุดทดสอบมีข้อมูล 3597 หน่วยข้อมูล ซึ่งกระบวนการในการวิเคราะห์และปรับไฮเพอร์พารามิเตอร์ในโมเดลจะมีลักษณะคล้ายคลึงกับการวิเคราะห์ด้วยการเรียนรู้ของเครื่อง ซึ่งสำหรับการวิเคราะห์เพื่อจำแนกความรู้สึกโดยใช้การเรียนรู้ของเครื่องผู้วิจัยใช้ไลบรารี sklearn

ผู้วิจัยได้ทำการพัฒนาโมเดลในการวิเคราะห์จำแนกอารมณ์ของครูในชั้นเรียนโดยใช้การเรียนรู้ของเครื่อง 4 โมเดล ได้แก่ Logistic Regression (LR) Naive Bayes (NB) Support Vector Machine (SVM) Random Forests (RF) โดยในแต่ละโมเดลจะมีไฮเพอร์พารามิเตอร์กำกับอยู่ ผู้วิจัยได้มีการค้นหาไฮเพอร์พารามิเตอร์ให้มีความเหมาะสมมากที่สุดด้วยการใช้ฟังก์ชัน GridSearchCV

จากกระบวนการข้างต้นจะเห็นได้ว่า ในการสกัดคุณลักษณะจากข้อความนั้นสามารถทำได้ โดยโมเดล MUSE และกระบวนการในการจำแนกอารมณ์ครูในชั้นเรียนจากคุณลักษณะที่สกัดมาได้ แล้วนั้นมาจากโมเดลการเรียนรู้ของเครื่องทั้ง 4 โมเดล ซึ่งความคล้ายคลึงกับโมเดลในกลุ่มที่ 1 ฉะนั้น ในการประเมินคุณภาพของโมเดลที่ใช้ในการวิเคราะห์จึงมีลักษณะเหมือนกันกับโมเดลในกลุ่มที่ 1

(3) การวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยโมเดลกลุ่มที่ 3 โมเดลกลุ่มที่มีการจัดทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้เชิงลึก

การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านข้อความ ที่ได้จากการวิเคราะห์การรู้จำคำพูด โดยใช้การเรียนรู้เชิงลึก ผู้วิจัยได้พัฒนาโมเดลที่ใช้ในการวิเคราะห์ 2 โมเดล ได้แก่ (1) Long short-term memory (LSTM) และ (2) Bidirectional Encoder Representations from Transformer (BERT) โดยในแต่ละโมเดลการวิเคราะห์เชิงลึกมีรายละเอียดของการสร้างโมเดล การปรับไฮเพอร์พารามิเตอร์ของโมเดลและประสิทธิภาพของโมเดล ดังนี้

• ขั้นตอนการวิเคราะห์อารมณ์ครูในชั้นเรียนด้วยโมเดลกลุ่มที่ 3

Long short-term memory (LSTM)

โมเดล Long short-term memory หรือ LSTM เป็นโมเดลที่มีความสามารถในการวิเคราะห์ความรู้สึกได้สูงซึ่งเหมาะสำหรับข้อมูลที่มีขนาดใหญ่ โดยผู้วิจัยได้วิเคราะห์ความรู้สึกโดยใช้โมเดลการเรียนรู้เชิงลึกโครงข่ายประสาทเทียมบนไลบรารี tensorflow เมื่อทำการตัดคำข้อมูลชุดฝึกฝน โดยกำหนดให้การปรับค่า Latency ให้มีความหน่วงมากหรือน้อย (Buffer size) เท่ากับ 10,000 sample และกำหนดจำนวนรายการข้อมูลที่จะให้ Optimiser ในหนึ่งครั้ง (Batch size) เท่ากับ 64

เมื่อนำข้อมูลชุดฝึกฝนให้เครื่องทำการเรียนรู้และสร้างเวกเตอร์ของข้อความทำให้สามารถสร้างจำนวนคลังคำศัพท์ที่ใช้สำหรับการเรียนรู้เชิงลึกครั้งนี้ 25,630 คำ จากนั้นนำข้อความในแต่ละคำไปจับคู่กับคำศัพท์ที่ได้เรียนรู้ไว้ในเบื้องต้น ข้อความในแต่ละแถวจะถูกแปลงเป็นตัวเลขในคลังคำศัพท์เป็นเวกเตอร์

ผู้วิจัยได้กำหนดขนาดของคุณลักษณะภายในโมเดลการเรียนรู้เชิงลึกไว้ที่ 512 คุณลักษณะ โดยมีรายละเอียดการพัฒนาโมเดลการเรียนรู้เชิงลึกแบบโครงข่ายประสาทเทียมแบบวนซ้ำรูปแบบหนึ่งที่ถูกพัฒนาบน TensorFlow โดยมีลำดับและโครงสร้างของแบบจำลองที่มี layer ต่าง ๆ สำหรับการวิเคราะห์ ดังนี้

- (1) encoder ช่วยแปลงประโยคหรือข้อความให้กลายเป็นตัวเลขที่เครื่องสามารถเข้าใจได้
- (2) Embedding layer ช่วยแปลงตัวเลขที่ได้จาก encoder เป็น distributed representation ที่ใช้ในการทำการประมวลผลภาษาธรรมชาติ (NLP) โดยมีการกำหนด hidden unit ของ layer ที่ออกมา โดยใช้ฟังก์ชัน output_dim และการกำหนดให้ฟังก์ชัน mask_zero เป็นจริง เป็นการใช้ masking เพื่อจัดการกับความยาวของ sequence ให้สามารถเปลี่ยนแปลงได้
- (3) Bidirectional LSTM layer ช่วยเพิ่มประสิทธิภาพในการเรียนรู้ของโมเดลด้วยการใช้ LSTM ที่ทำงานทั้งด้าน forward และ backward ในที่นี้ได้กำหนดขนาดไว้ที่ 256 โหนดสำหรับแต่ละ layer
- (4) Dense layer ช่วยลดขนาดของ output จาก LSTM และสร้าง representation ใหม่ โดยใช้ activation function เป็นแบบ ReLU ในที่นี้ลดขนาดของ layer ในแต่ละชั้นเหลือ 128 โหนด
- (5) Output layer ช่วยทำนายคำตอบโดยใช้ softmax activation function ซึ่งเป็นการแปลงค่าจาก output layer ให้อยู่ในรูปของความน่าจะเป็นของแต่ละกลุ่มย่อยที่จะคำนวณจาก input ที่ส่งมา

สำหรับการประมวลแบบจำลองใน Keras เพื่อใช้สำหรับการสร้างหรือปรับพารามิเตอร์ในโมเดลให้มีประสิทธิภาพสูงขึ้น ในโมเดล LSTM นี้ ผู้วิจัยได้มีการเลือกใช้ Loss Function ประเภท Categorical Entropy ซึ่งเป็นค่าเฉลี่ยของ Cross Entropy ที่เกิดจากการแจกแจงความน่าจะเป็น 2 แบบ ได้แก่ การแจกแจงความน่าจะเป็นที่อยากได้ กับการแจกแจงความน่าจะเป็นที่ถูกประมาณโดยโมเดลตามกลุ่มย่อยต่าง ๆ ซึ่งมีความเหมาะสมสำหรับข้อมูลที่ตัวแปรตามเป็นข้อมูลแบบจัดประเภทที่มีหลายกลุ่ม (Multi-Class Classification) การเลือกใช้ Loss Function ประเภทนี้ เป็นหนึ่งในวิธีการปรับตัวแบบให้สอดคล้องกับผลลัพธ์ที่ต้องการ ส่วน optimizer ที่ใช้ในการเรียนรู้คือ Adam ซึ่งเป็นวิธีการปรับแบบอัตโนมัติที่จะช่วยให้โมเดลเรียนรู้ได้เร็วขึ้น โดยเรากำหนด learning rate เท่ากับ 1×10^{-4} และเมตริกซ์ที่ใช้ในการระบุประสิทธิภาพของโมเดล คือ ค่าความถูกต้องที่เป็นการวัดความถูกต้องของกลุ่มย่อยที่โมเดลพยากรณ์ขึ้นมาใหม่กับกลุ่มย่อยที่แท้จริงตามที่ได้จำแนกไว้

Bidirectional Encoder Representations from Transformer (BERT)

Bidirectional Encoder Representations from Transformer เป็นโมเดลการเรียนรู้เชิงลึกที่พัฒนาขึ้นมาเพื่อใช้ในการประมวลผลภาษาธรรมชาติ (NLP) ภายใต้กรอบการทำงานของ Transformer ซึ่งเป็นวิธีการเรียนรู้เชิงลึกที่มีพื้นฐานมาจากการเรียนรู้เชิงลึกแบบโครงข่ายประสาทเทียมโดยสามารถเข้าใจความหมายของประโยคที่มีความซับซ้อนและมีการปรับเปลี่ยนไปตามบริบทของเนื้อหา ในปัจจุบันเป็นโมเดลที่ได้รับความนิยมในการวิเคราะห์และมีประสิทธิภาพสูง

กระบวนการในการวิเคราะห์จำแนกความรู้สึกจากข้อความที่ได้จากกระบวนการรู้จำคำพูด โดยการใช้การเรียนรู้เชิงลึกด้วยเทคนิค BERT ผู้วิจัยได้ใช้ไลบรารี tensorflow ประกอบกับโมดูล transformers แล้วดำเนินการวิเคราะห์จำแนกด้วยกระบวนการต่าง ๆ ดังนี้

- (1) ทำการ pre-processing ข้อความด้วยตัดคำหรือตัด stopword ออก
- (2) ใช้โมดูล sklearn.preprocessing เพื่อนำคำศัพท์ในแต่ละข้อความไปทำ encoder กับคลังคำศัพท์ โดยนำ tokenizer ของ pretrained โมเดลที่มีหลากหลายภาษา และเลือกใช้ “bert – base – multilingual - cased” เป็นคลังคำศัพท์สำหรับการ เพื่อแปลงคำศัพท์นั้น ๆ ให้เป็นตัวเลขสำหรับนำไปใช้ในการสร้างโมเดล
- (3) ทำการแบ่งข้อมูลออกเป็นชุดข้อมูลฝึกฝน ชุดข้อมูลสำหรับพัฒนาโมเดล และชุดข้อมูล โดยมีจำนวนข้อความในแต่ละชุดข้อมูลเป็น 17980 1499 และ 4495 ข้อความตามลำดับ
- (4) สร้างจำนวนคลังคำศัพท์ที่ใช้สำหรับการเรียนรู้เชิงลึกครั้งนี้ 119,547 คำ และได้กำหนดขนาดของคุณลักษณะภายในโมเดลการเรียนรู้เชิงลึกไว้ที่ 512 คุณลักษณะ
- (5) จากนั้นเป็นขั้นตอนของการเตรียมข้อมูลสำหรับการเรียนรู้เชิงลึกโดยใช้ชุดข้อมูล Tensorflow API ซึ่งแบ่งออกเป็น 3 ส่วน ดังนี้
 - ส่วนแรกเป็นการสร้างคุณลักษณะของชุดข้อมูลสำหรับการฝึกฝนโดยผ่านข้อมูลในรูปแบบ Dictionary ที่มี 2 ส่วนประกอบ ได้แก่ Key นั่นคือ ชื่อคุณลักษณะ และ Value คือ ค่าของคุณลักษณะนั้น ๆ
 - ส่วนที่สองเป็นการสร้างชุดข้อมูล Tensorflow โดยการนำค่าของคุณลักษณะมารวมกับและประเภทของข้อความมาจับคู่กันให้เป็นลักษณะของ tuple และนำมาแปลงให้เป็น Tensor slice ด้วยฟังก์ชัน `.from_tensor_slices()` ซึ่งจะได้ชุดข้อมูลที่เก็บคุณลักษณะและประเภทของข้อความมาอยู่ในรูปของ tensor slice
 - ส่วนที่สาม เป็นส่วนของการพัฒนาให้โมเดลมีความรวดเร็วในการวิเคราะห์มายิ่งขึ้น โดยการสุ่มลำดับของชุดข้อมูลในชุดฝึกฝน จากนั้นแบ่งข้อมูลออกเป็นกลุ่ม ๆ ให้แต่ละกลุ่มมีขนาดเท่ากับ 8 (batch)

ในการเตรียมข้อมูลสำหรับการชุดข้อมูลที่ใช้ในการพัฒนาโมเดล (validation dataset) และข้อมูลชุดทดสอบ (test dataset) นั้นก็ทำในลักษณะคล้ายคลึง แต่ตั้งชื่อชุดข้อมูลแตกต่างกัน

- (6) สร้างโมเดลในการจำแนกความรู้สึกของข้อความ โดยใช้โมเดล TFAutoModelForSequenceClassification ด้วยฟังก์ชัน from_pretrained() ซึ่งจะโหลดโมเดล “bert – base – multilingual - cased” มาใช้สำหรับการเป็น pretrained โมเดล และกำหนดจำนวนประเภทของประเภทของข้อความเป็น 3 นั่นคือข้อความที่เชิงบวก เชิงลบ และข้อความที่เป็นกลาง
- (7) หลังจากสร้างโมเดลแล้ว ผู้วิจัยทำการปรับไฮเพอร์พารามิเตอร์ในโมเดลด้วย Adam optimizer และ Sparse Categorical Cross-Entropy loss เพื่อจะได้สามารถใช้โมเดลนี้ในการฝึกฝนและพัฒนาโมเดลจากข้อมูลได้ ในการคำนวณผลลัพธ์ที่เป็นค่า accuracy จะใช้ Sparse Categorical Accuracy metric ซึ่งเป็นค่าที่บอกถึงความแม่นยำของโมเดลในการจำแนกประเภท
- (8) นำโมเดลที่มีการปรับไฮเพอร์พารามิเตอร์เรียบร้อยแล้ว จึงนำไปทดสอบกับข้อมูลชุดทดสอบและเปรียบเทียบประสิทธิภาพในการจำแนกความรู้สึกจากข้อความ

• การประเมินคุณภาพของโมเดลที่ใช้ในการวิเคราะห์

การประเมินความเหมาะสมของโมเดลการวิเคราะห์ความรู้สึกจากการเรียนรู้ของเชิงลึกจากข้อความที่ได้จากกระบวนการเรียนรู้จำคำพูด โดยทั่วไปแล้วจะมีดัชนีที่ใช้ในการเปรียบเทียบประสิทธิภาพของโมเดลที่คล้ายคลึงกันกับโมเดลในกลุ่มที่ 1 และ 2 โดยจะมีการประเมินคุณภาพของโมเดลในด้านความเข้ากันได้ดีมากเกินไปกับข้อมูลชุดฝึกฝนเพิ่มเติมด้วย (overfit) ซึ่งดัชนีที่จะมาใช้ในการพิจารณาควคู่กันในด้านนี้ คือ Loss และ accuracy ทั้งของชุดข้อมูลฝึกฝนและชุดข้อมูล validation ซึ่งค่า Loss มีรายละเอียด ดังนี้

Loss หมายถึง ค่าสูญเสียที่ใช้วัดประสิทธิภาพของโมเดลในการทำนายผลลัพธ์ เช่น ค่าความผิดพลาดระหว่างผลลัพธ์จริงและผลทำนาย (predicted output) โดย Loss function จะถูกใช้ในกระบวนการปรับแต่งพารามิเตอร์ของโมเดล เพื่อให้ Loss ต่ำที่สุด ซึ่งจากความหมายข้างต้น แม้ว่าผู้วิจัยจะต้องการค่า loss ต่ำที่สุด แต่ก็ต้องชั่งน้ำหนักระหว่างค่าความถูกต้องที่เกิดขึ้นด้วย โดยหากค่า loss ในข้อมูลชุดฝึกฝนมีค่าต่ำที่สุดแล้ว ค่า loss ในข้อมูลชุด validation มีค่าต่ำด้วยหรือไม่ เพราะหากไม่ลดต่ำด้วยนั้นแสดงให้เห็นถึงปัญหา overfit ในชุดข้อมูลฝึกฝน รวมถึงต้องมีการพิจารณาค่าความถูกต้องในชุดข้อมูลต่าง ๆ ประกอบด้วย เพื่อให้ได้พารามิเตอร์ที่เหมาะสมที่สุดในการปรับแต่งพารามิเตอร์

บทที่ 4

ผลการวิเคราะห์ข้อมูล

การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึก ผู้วิจัยได้จำแนกผลการวิเคราะห์ออกเป็น 3 ตอน ได้แก่ ตอนที่ 1 ผลการวิเคราะห์บรรยายสภาพข้อความและการสกัดคุณลักษณะจากข้อความก่อนการวิเคราะห์จำแนกอารมณ์ด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ตอนที่ 2 ผลการวิเคราะห์การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านข้อความที่ได้จากการวิเคราะห์การรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่อง และตอนที่ 3 ผลการวิเคราะห์การประเมินประสิทธิภาพ ความเหมาะสมของโมเดลที่พัฒนาขึ้นและการนำไปใช้ในการจำแนกอารมณ์ครูในชั้นเรียน


โมเดลที่พัฒนาขึ้นสำหรับการวิเคราะห์อารมณ์ครูในชั้นเรียนในงานวิจัยนี้ จำแนกออกเป็น 3 กลุ่ม ได้แก่ กลุ่มที่ 1 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง จำนวน 4 โมเดล กลุ่มที่ 2 โมเดลที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder และมีการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่องจำนวน 4 โมเดล และกลุ่มที่ 3 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้เชิงลึก จำนวน 2 โมเดล

ตอนที่ 1 ผลการวิเคราะห์บรรยายสภาพข้อความและการสกัดคุณลักษณะจากข้อความก่อนการวิเคราะห์จำแนกอารมณ์ด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

1. ผลการวิเคราะห์บรรยายสภาพข้อความที่นำมาจัดกระทำข้อมูลก่อนการสกัดคุณลักษณะ


ข้อความที่นำมาใช้ในการพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนมาจากแหล่งข้อมูล 2 แหล่ง ได้แก่ ข้อความที่ได้จากกระบวนการการรู้จำคำพูดจากวีดิทัศน์การเรียนการสอนของครูในชั้นเรียนจำนวน 11 คาบ ซึ่งแบ่งเป็นข้อความเชิงบวกร้อยละ 15.2 ข้อความเชิงลบร้อยละ 16.3 และข้อความที่เป็นกลางซึ่งมีมากที่สุดร้อยละ 68.5 และข้อความที่ได้จากฐานข้อมูล Wisersight Sentiment Analysis ซึ่งเป็นฐานข้อมูลที่ไว้ใช้สำหรับการวิเคราะห์อารมณ์จากข้อความ โดยผู้วิจัยได้ทำการจัดกระทำข้อมูลจากฐานข้อมูลซึ่งแบ่งเป็นข้อความเชิงบวกร้อยละ 18.3 ข้อความเชิงลบร้อยละ 26.1 และข้อความที่เป็นกลางร้อยละ 55.7 ซึ่งจะเห็นได้ว่าจำนวนข้อความในแต่ละประเภทมีลักษณะคล้ายคลึงกัน กล่าวคือ ข้อความที่เป็นกลางมีจำนวนมากที่สุด มากกว่าข้อความเชิงลบและข้อความเชิงบวก จากนั้นผู้วิจัยนำแหล่งข้อมูลทั้ง 2 แหล่งมารวมกัน โดยมีข้อความรวมกันทั้งสิ้น 23,974

ข้อความ โดยในจำนวนนี้แบ่งเป็น ข้อความเชิงบวก (positive) จำนวน ข้อความเชิงลบ (negative) ข้อความและข้อความที่เป็นกลาง (neutral) ข้อความ ตามที่แสดงในภาพที่ 5



(ก) สัดส่วนร้อยละของจำนวนข้อความแต่ละประเภทจากกระบวนการรู้จำคำพูดที่ได้จากวีดิทัศน์การสอนของครูในชั้นเรียน

(ข) สัดส่วนร้อยละของจำนวนข้อความแต่ละประเภทจากฐานข้อมูล Wisersight Sentiment Analysis



(ข) สัดส่วนร้อยละของจำนวนข้อความแต่ละประเภทจากทั้ง 2 แหล่งข้อมูล


ภาพที่ 5 แผนภูมิแสดงสัดส่วนร้อยละของจำนวนข้อความแต่ละประเภท

จากภาพที่ 5 จะเห็นได้ว่า ข้อความส่วนใหญ่เป็นข้อความที่เป็นกลาง ซึ่งมีมากถึงร้อยละ 55.89 ในขณะที่ข้อความเชิงลบและข้อความเชิงบวก มีร้อยละ 25.90 และ 18.21 ตามลำดับ

จากนั้นผู้วิจัยได้ทำการจำแนกข้อความดังกล่าวออกเป็น 2 ส่วน ได้แก่ ชุดข้อความสำหรับการฝึกฝน (Training dataset) และชุดข้อความสำหรับการทดสอบ (Test dataset) โดยกำหนด

สัดส่วนของชุดข้อความสำหรับการฝึกฝนต่อชุดข้อความสำหรับการทดสอบ คือ 85 : 15 และได้กำหนดตัวเลขเริ่มต้นในสุ่มกลุ่ม (random seed number) คือ 123

ชุดข้อความสำหรับการฝึกฝนมีทั้งหมด 20377 ข้อความ แบ่งเป็นข้อความที่เป็นกลาง ร้อยละ 56.01 ข้อความเชิงลบร้อยละ 25.71 และข้อความเชิงบวกร้อยละ 18.28 สำหรับชุดข้อความสำหรับการทดสอบมีทั้งหมด 3597 ข้อความ แบ่งเป็นข้อความที่เป็นกลาง ร้อยละ 55.21 ข้อความเชิงลบร้อยละ 26.99 และข้อความเชิงบวกร้อยละ 17.79 ตามภาพที่ 6 ซึ่งจะเห็นได้ว่าการแจกแจงของข้อความในแต่ละกลุ่มของประเภทของข้อความมีการแจกแจงที่ใกล้เคียงกัน



ภาพที่ 6 แผนภูมิแสดงร้อยละของจำนวนข้อความแต่ละประเภทจำแนกตามชุดข้อความสำหรับการฝึกฝน (training dataset) และชุดข้อความสำหรับการทดสอบ (test dataset)

2. ผลการวิเคราะห์การสกัดคุณลักษณะจากข้อความก่อนการวิเคราะห์จำแนกอารมณ์ด้วยการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

(1) ผลการวิเคราะห์การสกัดคุณลักษณะจากข้อความด้วยโมเดลกลุ่มที่ 1

ในการวิเคราะห์ข้อมูลเมื่อผู้วิจัยได้ทำการจัดกระทำข้อความในแต่ละประโยคในชุดข้อมูลโดยใช้เทคนิค TF-IDF ซึ่งเป็นเทคนิคที่ใช้การนับจำนวนคำที่ปรากฏในเอกสารและความถี่ของคำในเอกสารเพื่อคำนวณค่าความสำคัญ ซึ่งมีพารามิเตอร์ตัวหนึ่งที่สำคัญ ได้แก่ ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ (df_min) โดยผู้วิจัยได้ทำการกำหนดค่าดังกล่าว จากนั้นผู้วิจัยจึงนำไปวิเคราะห์ด้วยการเรียนรู้ของเครื่อง โดยโมเดล Logistic Regression แล้วได้ประสิทธิภาพในการจำแนกตามตารางที่ 4

ตารางที่ 4 แสดงประสิทธิภาพในการจำแนกประเภทของข้อความ โดยมีความแตกต่างกันอันเนื่องมาจากความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ (df_min) และการสังเคราะห์ข้อความด้วยวิธีการ SMOTE

df_min	จำนวนคำ	Average acc (Std acc)	Recall			เวลา (วินาที)
			Negative	Neutral	Positive	
ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ (df_min)						
20	4345	.672 (0.028)	.63	.88	.36	240
80	1054	.671 (0.024)	.62	.87	.34	63
150	515	.661 (0.024)	.60	.86	.28	26
200	375	.649 (0.022)	.54	.86	.25	21
ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความ และมีการสังเคราะห์ข้อความด้วยวิธีการ SMOTE						
20	4345	.672 (0.028)	.74	.65	.58	305
80	1054	.671 (0.024)	.71	.61	.59	75
150	515	.661 (0.024)	.70	.57	.58	32
200	375	.649 (0.022)	.68	.53	.60	25

จากการวิเคราะห์ตามตารางที่ 4 ผู้วิจัยได้พบว่าดัชนี Recall หรือดัชนีที่แสดงความไวในการจำแนกกลุ่ม ซึ่งคำนวณจากสัดส่วนของค่าที่โมเดลทำนายเป็นกลุ่มที่กำลังพิจารณาถูกเทียบกับค่าของเหตุการณ์ พบว่า ไม่ว่าความถี่ขั้นต่ำที่ปรากฏในชุดข้อความทั้งหมดจะเป็น 20 80 150 หรือ 200 ค่าความไวของกลุ่มข้อความเชิงบวกซึ่งมีค่าน้อยกว่า .4 และมีแนวโน้มลดต่ำลงเมื่อความถี่ขั้นต่ำที่ปรากฏในชุดข้อความสูงขึ้น อาจก่อให้เกิดจากปัญหาความไม่สมดุลกันของกลุ่มของตัวแปรตาม (imbalance class)

เนื่องจากได้ทำการวิเคราะห์ประสิทธิภาพในการจำแนกข้อความด้วยการสกัดคุณลักษณะด้วยวิธี TF – IDF พบว่า ประสิทธิภาพของความแม่นยำและความไวในการจำแนกกลุ่มข้อความเชิงบวกและข้อความเชิงลบมีค่าไม่เกิน .4 ทั้งสิ้น สะท้อนให้เห็นถึงปัญหาความไม่สมดุลกันของข้อมูลในกลุ่มที่มีจำนวนข้อความน้อยกว่าอย่างข้อความเชิงบวกและข้อความเชิงลบ ผู้วิจัยพบปัญหาดังกล่าวและได้นำวิธีการสังเคราะห์ข้อมูลในกลุ่มที่มีจำนวนข้อความน้อยให้มีจำนวนเทียบเท่ากับกลุ่มข้อความ

ที่เป็นกลางด้วยวิธีการ SMOTE จากนั้นนำไปวิเคราะห์ด้วยการเรียนรู้ของเครื่อง โดยโมเดล Logistic Regression แล้วได้ประสิทธิภาพในการจำแนกตามตารางที่ 4

จากตารางที่ 4 พบว่า ค่าความไวในการจำแนกกลุ่มข้อความเชิงบวกสูงขึ้น เมื่อกำหนดความถี่ขั้นต่ำที่ปรากฏในชุดข้อความเป็น 20 และ 80 มีประสิทธิภาพในการทำนายและความไวในการจำแนกกลุ่มใกล้เคียงกัน แต่เวลาที่ใช้ในการวิเคราะห์แตกต่างกันหลายเท่า ผู้วิจัยจึงกำหนดพารามิเตอร์ ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความเป็น 80 และมีการนำวิธีการ SMOTE ไปใช้ในการจัดกระทำข้อมูลเพื่อแก้ปัญหาข้อมูลที่ไม่สมดุลกันด้วย

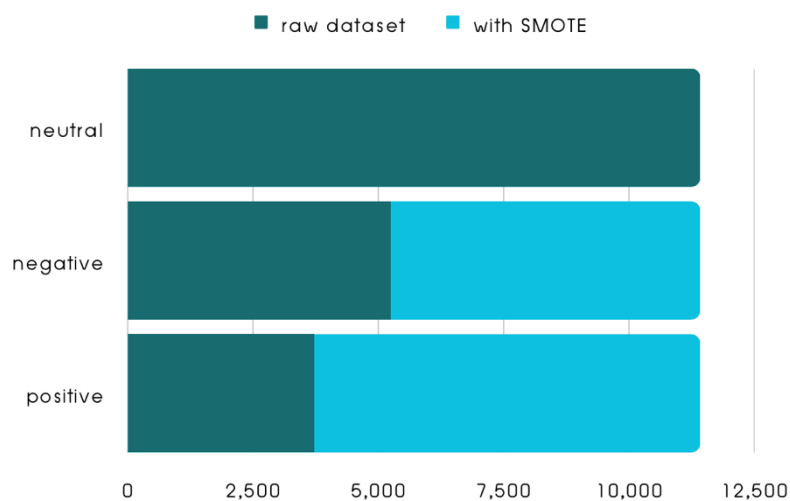
เมื่อผู้วิจัยได้กำหนดความถี่ขั้นต่ำที่ปรากฏในชุดข้อความนี้เป็น 80 พบว่า จำนวนคำหรือกลุ่มคำที่เป็นคุณลักษณะในการจำแนกกลุ่มภายในโมเดลมีทั้งสิ้น 1,054 คุณลักษณะ ซึ่งเมื่อนำไปสร้างเมทริกซ์คุณลักษณะจะพบว่ามีความหนาแน่นสูง และอาจก่อให้เกิดปัญหา Curse of dimension ซึ่งทำให้เกิดปัญหาในการประมวลผลและการสร้างโมเดล เนื่องจากมีการเพิ่มความหนาแน่นของข้อมูลเข้าไป และการสร้างโมเดลที่มีมิติสูงสามารถทำให้เกิดปัญหา overfitting ได้ง่ายขึ้น และทำให้เวลาที่ใช้ในการวิเคราะห์ข้อมูลยิ่งนานขึ้น เพื่อแก้ปัญหาดังกล่าวผู้วิจัยจึงนำทำการลดจำนวนคุณลักษณะภายในโมเดลลงแต่ยังพยายามรักษาความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลการจำแนกกลุ่มนี้ โดยใช้ Principal Component Analysis (PCA) ซึ่งมีการกำหนดร้อยละของความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลการจำแนกเป็นดังนี้ ร้อยละ 100 ร้อยละ 95 ร้อยละ 90 และร้อยละ 85 โดยมีรายละเอียดตามตารางที่ 5

ตารางที่ 5 แสดงประสิทธิภาพในการจำแนกประเภทของข้อความ โดยมีความแตกต่างกันอันเนื่องมาจากความผันแปรของคุณลักษณะที่เกิดขึ้นภายในโมเดลการทำนาย (Explained Variance Ratio)

Explained Variance Ratio	จำนวนองค์ประกอบ	Average acc (Std acc)	Recall			Acc	เวลา (วินาที)
			Negative	Neutral	Positive		
1	1054	.671 (0.024)	.71	.61	.59	.63	75
0.95	817	.669 (0.024)	.72	.61	.60	.64	55
0.9	681	.669 (0.025)	.71	.60	.60	.63	36
0.85	383	.668 (0.024)	.72	.56	.62	.62	24

จากตารางที่ 5 ผู้วิจัยเลือกร้อยละของความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลการจำแนกเป็น 90 ซึ่งมีจำนวนคุณลักษณะของคำหรือกลุ่มคำอยู่จำนวน 681 คุณลักษณะ เนื่องจากค่าเฉลี่ยความถูกต้องในการทำนายมีค่าใกล้เคียงกับชุดข้อมูลที่มีร้อยละความผันแปรของคุณลักษณะร้อยละ 100 รวมถึงค่าความไวในการจำแนกกลุ่มข้อความเชิงบวกมีค่าใกล้เคียงกันประมาณ .60 ซึ่งเห็นได้ชัดว่า เมื่อทำการลดจำนวนคุณลักษณะในโมเดลด้วยวิธี PCA แล้วประสิทธิภาพในการจำแนกประเภทของข้อความไม่ได้แตกต่างกันกับเมทริกซ์คุณลักษณะตั้งต้น

เมื่อผู้วิจัยได้กำหนดความถี่ขั้นต่ำที่ปรากฏในชุดข้อความนี้เป็น 80 ลดจำนวนคุณลักษณะภายในโมเดลลงด้วยวิธี PCA โดยกำหนดให้ร้อยละความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลการจำแนกเป็น 90 และมีการนำวิธีการ SMOTE ไปใช้ในการจัดกระทำข้อมูลเพื่อแก้ปัญหาข้อมูลที่ไม่สมดุลกันแล้ว ทำให้ชุดข้อมูลสำหรับการทดสอบมีจำนวน 34,239 ข้อความ โดยแบ่งเป็น ข้อความเชิงบวก ข้อความเชิงลบ และข้อความที่เป็นกลางจำนวนกลุ่มละ 11,413 ข้อความ เท่ากันทุกกลุ่มตามภาพที่ 7



ภาพที่ 7 แผนภูมิแสดงจำนวนชุดข้อความเดิม (raw dataset) จำแนกตามประเภทของข้อความ และชุดข้อความที่ได้จากกระบวนการ SMOTE

(2) ผลการวิเคราะห์การสกัดคุณลักษณะจากข้อความด้วยโมเดลกลุ่มที่ 2

ในการวิเคราะห์เพื่อจำแนกความรู้สึกของข้อความโดยใช้โมเดล Multilingual Universal Sentence Encoder นั้น ผู้วิจัยใช้ไลบรารี tensorflow ในการแปลงข้อความที่เป็นภาษาไทยเข้ารหัสเป็นตัวเลขเพื่อใช้ในการสร้างโมเดลเพื่อวิเคราะห์ (encoder) ซึ่งสามารถสร้างเป็นข้อมูลที่มี

คุณลักษณะ ภายในโมเดลการเรียนรู้เชิงลึกไว้ที่ 512 คุณลักษณะ สำหรับข้อมูลชุดฝึกฝนมีจำนวนข้อมูล 20,377 หน่วยข้อมูล และสำหรับข้อมูลชุดทดสอบมีข้อมูล 3597 หน่วยข้อมูล

(3) ผลการวิเคราะห์การสกัดคุณลักษณะจากข้อความด้วยโมเดลกลุ่มที่ 3

โมเดลที่ 9 Long short-term memory (LSTM)

โมเดล Long short-term memory หรือ LSTM เป็นโมเดลที่มีความสามารถในการวิเคราะห์ความรู้สึกได้สูงซึ่งเหมาะสำหรับข้อมูลที่มีขนาดใหญ่ โดยผู้วิจัยได้วิเคราะห์ความรู้สึกโดยใช้โมเดลการเรียนรู้เชิงลึกโครงข่ายประสาทเทียมบนไลบรารี tensorflow เมื่อทำการตัดคำข้อมูลชุดฝึกฝน โดยกำหนดให้การปรับค่า Latency ให้มีความหน่วงมากหรือน้อย (Buffer size) เท่ากับ 10,000 sample และกำหนดจำนวนรายการข้อมูลที่จะให้ Optimiser ในหนึ่งครั้ง (Batch size) เท่ากับ 64

เมื่อนำข้อมูลชุดฝึกฝนให้เครื่องทำการเรียนรู้และสร้างเวกเตอร์ของข้อความทำให้สามารถสร้างจำนวนคลังคำศัพท์ที่ใช้สำหรับการเรียนรู้เชิงลึกครั้งนี้ 25,630 คำ จากนั้นนำข้อความในแต่ละคำไปจับคู่กับคำศัพท์ที่ได้เรียนรู้ไว้ในเบื้องต้น ข้อความในแต่ละแถวจะถูกแปลงเป็นตัวเลขในคลังคำศัพท์เป็นเวกเตอร์

โมเดลที่ 10 Bidirectional Encoder Representations from Transformer (BERT)

Bidirectional Encoder Representations from Transformer เป็นโมเดลการเรียนรู้เชิงลึกที่พัฒนาขึ้นมาเพื่อใช้ในการประมวลผลภาษาธรรมชาติ (NLP) ภายใต้กรอบการทำงานของ Transformer ซึ่งกระบวนการในการวิเคราะห์จำแนกความรู้สึกจากข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึกด้วยเทคนิค BERT ผู้วิจัยได้ใช้ไลบรารี tensorflow ประกอบกับโมดูล transformers แล้วดำเนินการวิเคราะห์จำแนกด้วยกระบวนการต่าง ๆ ดังนี้

เริ่มต้นจากการ pre-processing ข้อความด้วยตัดคำหรือตัด stopword ออก จากนั้นนำคำศัพท์ในแต่ละข้อความไปทำ encoder กับคลังคำศัพท์ โดยนำ tokenizer ของ pretrained โมเดลที่มีหลากหลายภาษา และเลือกใช้ “bert – base – multilingual - cased” เป็นคลังคำศัพท์สำหรับการ เพื่อแปลงคำศัพท์นั้น ๆ ให้เป็นตัวเลขสำหรับนำไปใช้ในการสร้างโมเดล โดยสร้างจำนวนคลังคำศัพท์ที่ใช้สำหรับการเรียนรู้เชิงลึกครั้งนี้ 119,547 คำ และได้กำหนดขนาดของคุณลักษณะภายในโมเดลการเรียนรู้เชิงลึกไว้ที่ 512 คุณลักษณะ

ตอนที่ 2 ผลการวิเคราะห์การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านข้อความที่ได้จากการวิเคราะห์การรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่อง

ผู้วิจัยได้ทำการพัฒนาโมเดลในการวิเคราะห์อารมณ์ของครูในชั้นเรียนโดยใช้การเรียนรู้ของเครื่อง 10 โมเดล โดยมีรายละเอียดของโมเดลทั้งหมดที่ใช้ในการวิเคราะห์ ตามตารางที่ 6

ตารางที่ 6 รายละเอียดของโมเดลทั้งหมดที่ใช้ในการวิเคราะห์จำแนกอารมณ์จากข้อความ พร้อมทั้งตัวย่อของโมเดลในการเขียนรายงานผลการวิเคราะห์

โมเดลที่	กลุ่มของโมเดล	โมเดล Pretrained			โมเดลที่ใช้ในการจำแนก	ตัวย่อของโมเดล
		ไม่มี	Multilingual Universal Sentence Encoder (MUSE)	Bert – base - multilingual-cased		
1	1	✓			Logistic Regression (LR)	LR
2		✓			Naive Bayes (NB)	NB
3		✓			Support Vector Machine (SVM)	SVM
4		✓			Random Forests (RF)	RF
5	2		✓		Logistic Regression (LR)	LR + MUSE
6			✓		Naive Bayes (NB)	NB + MUSE
7			✓		Support Vector Machine (SVM)	SVM + MUSE
8			✓		Random Forests (RF)	RF + MUSE
9	3	✓			Long short-term memory (LSTM)	LSTM
10				✓	Bidirectional Encoder Representations from Transformer (BERT)	BERT

1. ผลการวิเคราะห์การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนของโมเดลในกลุ่มที่ 1 และ 2


เมื่อสกัดคุณลักษณะจากข้อความมาเรียบร้อยแล้ว โมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียน กลุ่มที่ 1 และ 2 มีความคล้ายคลึงกันตรงที่ใช้โมเดลการเรียนรู้ของเครื่องมาจำแนกอารมณ์ครูในชั้นเรียนเหมือนกัน ซึ่งภายหลังจากสกัดคุณลักษณะจากข้อความ ในแต่ละโมเดลการจำแนกอารมณ์จากข้อความมีไฮเพอร์พารามิเตอร์กำกับอยู่ ผู้วิจัยได้มีการค้นหาไฮเพอร์พารามิเตอร์ให้มีความเหมาะสมมากที่สุดด้วยการใช้ฟังก์ชัน GridSearchCV โดยโมเดลที่ (1) ถึง (8) มีรายละเอียดของไฮเพอร์พารามิเตอร์ และค่าเฉลี่ยของความแม่นยำในการทำนายเมื่อทำการ cross validation เป็นจำนวน 5 รอบ เป็นตามตารางที่ 7

ตารางที่ 7 แสดงโมเดลและรายละเอียดการปรับไฮเพอร์พารามิเตอร์ในโมเดลและประสิทธิภาพในการจำแนกประเภทข้อความที่ได้จากการทำ cross validation จำนวน 5 รอบ ของกลุ่มโมเดลที่ 1 และ 2

โมเดลที่	ตัวย่อของโมเดล	ไฮเพอร์พารามิเตอร์ที่ปรับ	ค่าเฉลี่ยความถูกต้องในการทำ CV 5 รอบ
1	LR	'C': 10, 'penalty': 'l2' และ 'solver': 'liblinear'	.677
2	NB	'alpha': 1	.606
3	SVM	'C': 1000 และ 'kernel': 'rbf'	.709
4	RF	'criterion': 'gini', 'max_depth': 8, 'max_features': 'sqrt' และ 'n_estimators': 2000	.634
5	LR + MUSE	'C': 1, 'penalty': 'l2' และ 'solver': 'liblinear'	.712
6	NB + MUSE	'alpha': 0.1	.602
7	SVM + MUSE	'C': 1000 และ 'kernel': 'rbf'	.716
8	RF + MUSE	'criterion': 'gini', 'max_depth': 8, 'max_features': 'auto', 'n_estimators': 20	.687


2. ผลการวิเคราะห์การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนของโมเดลในกลุ่มที่ 3 โมเดลที่ 9 Long short-term memory (LSTM)

ผลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้โมเดลโครงข่ายประสาทเทียมแบบวนซ้ำแบบ LSTM โดยกำหนดให้จำนวนรอบในการฝึกฝนโมเดลมีจำนวน 10 รอบ และกำหนดขนาดของการแสดงผลบนหน้าจอเป็น 2 ส่วน เมื่อโมเดลเริ่มทำการประมวลผล โดยผลการวิเคราะห์จะพิจารณาค่า loss และ accuracy ในแต่ละรอบการฝึกฝนของโมเดล ตามภาพที่ 8




(ก) แนวโน้มของค่า loss

โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบ



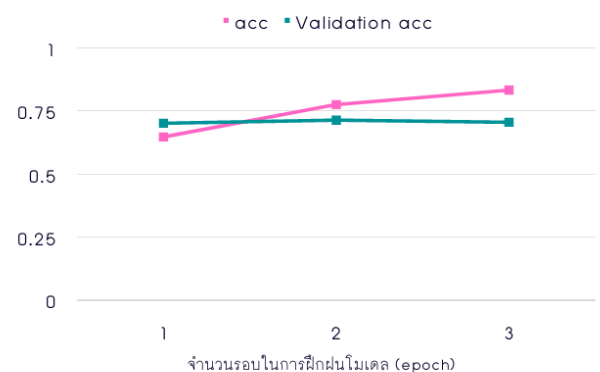
(ข) แนวโน้มของค่าความถูกต้อง

โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบ



(ค) แนวโน้มของค่า loss

โดยมีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ



(ง) แนวโน้มของค่าความถูกต้อง

โดยมีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ

ภาพที่ 8 แนวโน้มของค่า loss และค่าความถูกต้อง ทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดล

โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบและ 3 รอบ

ผลการวิเคราะห์อาร์มส์ครูในชั้นเรียนจากข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้โมเดลโครงข่ายประสาทเทียมแบบวนซ้ำแบบ LSTM โดยกำหนดให้จำนวนรอบในการฝึกฝนโมเดลมีจำนวน 10 รอบ และกำหนดขนาดของการแสดงผลบนหน้าจอเป็น 2 ส่วนเมื่อโมเดลเริ่มทำการประมวลผล โดยผลการวิเคราะห์จะพิจารณาค่า loss และ accuracy ในแต่ละรอบการฝึกฝนของโมเดล ตามภาพที่ 8

เมื่อพิจารณาแนวโน้มของค่า loss และค่าความถูกต้องที่ได้จากทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดล โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบ ตามภาพที่ 8 (ก) และ (ข) พบว่า ค่า loss สำหรับข้อมูลชุดฝึกฝนมีแนวโน้มลดลงเรื่อย ๆ เมื่อจำนวนรอบในการฝึกฝนเพิ่มมากขึ้น ซึ่งตรงกันข้ามกัน แต่สำหรับค่า loss ในชุดข้อมูลสำหรับการพัฒนาโมเดล (Validation dataset) นั้นกลับมีค่าสูงขึ้นเมื่อจำนวนรอบในการฝึกฝนมากขึ้น ซึ่งอาจก่อให้เกิดปัญหา overfitting กับข้อมูลภายในโมเดลชุดฝึกฝน และเมื่อพิจารณาค่าความถูกต้อง สำหรับชุดข้อมูลฝึกฝน พบว่า ค่าความถูกต้อง (acc) ที่มีแนวโน้มสูงขึ้นในแต่ละรอบของการฝึกฝนและสำหรับชุดข้อมูลสำหรับการพัฒนาโมเดลนั้น พบว่า เมื่อเพิ่มรอบในการฝึกฝนมากขึ้นทำให้ความถูกต้องของข้อมูลสำหรับการพัฒนาโมเดลลดลง ซึ่งเกิดปัญหา overfitting ตามที่คาดหมายไว้

ผู้วิจัยได้พัฒนาโมเดลในการวิเคราะห์ความรู้สึกของข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้โมเดลโครงข่ายประสาทเทียมแบบวนซ้ำแบบ LSTM โดยการลดจำนวนรอบในการฝึกฝนโมเดลเหลือจำนวน 3 รอบ โดยผลการวิเคราะห์จะพิจารณาค่า loss และ accuracy ในแต่ละรอบการฝึกฝนของโมเดล ตามตารางที่ 8

ตารางที่ 8 แสดงค่า (1) loss (2) acc (3) Validation loss และ (4) Validation acc ในแต่ละรอบของการฝึกฝนด้วยโมเดล LSTM มีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ

รอบของการฝึกฝนที่	loss	acc	Validation loss	Validation acc
1	.8232	.6473	.7161	.7014
2	.5612	.7753	.7113	.7139
3	.4249	.8327	.7692	.7053


จากตารางที่ 8 จะเห็นว่า เมื่อพิจารณาค่า loss ในรอบของการฝึกฝนแต่ละรอบจะเห็นว่า ค่า loss มีแนวโน้มลดลงโดยเริ่มจาก .8232 .5612 และ .4249 ในขณะที่ Validation loss หรือค่า loss ที่ทดสอบกับข้อมูลชุด validation มีค่าเป็น .7161 .7113 และ .7692 ซึ่งมีแนวโน้มของค่า loss ที่เริ่มลดลงแล้วกำลังจะเพิ่มขึ้น สำหรับค่าความถูกต้องมีแนวโน้มสูงขึ้นในแต่ละรอบของการฝึกฝน โดยเริ่มจาก .6473 .7753 และ .8327 ตามลำดับ และสำหรับค่าความถูกต้องของชุดพัฒนาโมเดลมีค่าใกล้เคียงกันทั้งสามรอบของการฝึกฝน ได้แก่ .7024 .7139 และ .7053 ตามลำดับ โดยสามารถพิจารณาแนวโน้มของค่า loss ทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดลได้ตามภาพที่ 8 (ค) และแนวโน้มของค่าความถูกต้องทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดลได้ตามภาพที่ 8 (ง)

เมื่อพิจารณาจากภาพที่ 8 (ก) และ (ข) จะเห็นว่า ค่า loss ของข้อมูลชุดฝึกฝน โมเดลมีแนวโน้มที่ลดลงแต่เพิ่มขึ้นในข้อมูลชุดพัฒนาโมเดล ซึ่งโมเดลมีแนวโน้มเข้าสู่การเป็น overfitting กับข้อมูลที่ใช้ในการฝึกฝน โดยเมื่อเปรียบเทียบกับการพัฒนาโมเดลโดยเพิ่มจำนวนรอบในการฝึกฝน 10 รอบ ที่พิจารณาก่อนหน้าจะพบว่า โมเดลดังกล่าวมีลักษณะ overfitting กับข้อมูลชุดฝึกฝนมากจนเกินไป ค่า loss ของข้อมูลชุดพัฒนาโมเดลมีแนวโน้มสูงขึ้นอย่างเห็นได้ชัด


ผู้วิจัยนำโมเดลที่ได้ทำการลดจำนวนรอบในการฝึกฝนโมเดลจาก 10 รอบ เหลือ 3 รอบ แล้วนำโมเดลไปจำแนกความรู้สึกกับข้อมูลชุดทดสอบ โดยผลการจำแนกอารมณ์จากข้อความจะแสดงในหัวข้อถัดไป

โมเดลที่ 10 Bidirectional Encoder Representations from Transformer (BERT)


ผลการวิเคราะห์ความรู้สึกของข้อความที่ได้จากกระบวนการรู้จำคำพูดโดยใช้โมเดลโครงข่ายประสาทเทียมโดยใช้เทคนิค BERT โดยกำหนดให้จำนวนรอบในการฝึกฝนโมเดลมีจำนวน 10 รอบ และกำหนดขนาดของการแสดงผลบนหน้าจอเป็น 2 ส่วนเมื่อโมเดลเริ่มทำการประมวลผล โดยผลการวิเคราะห์จะพิจารณาค่า loss และ accuracy ในแต่ละรอบการฝึกฝนของโมเดล ตามภาพที่ 9




(ก) แนวโน้มของค่า loss โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบ



(ข) แนวโน้มของค่าความถูกต้อง โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบ



(ค) แนวโน้มของค่า loss โดยมีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ



(ง) แนวโน้มของค่าความถูกต้อง โดยมีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ

ภาพที่ 9 แนวโน้มของค่า loss และค่าความถูกต้อง ทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดล โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบและ 3 รอบ

เมื่อพิจารณาแนวโน้มของค่า loss และค่าความถูกต้องที่ได้จากทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดล โดยมีจำนวนรอบในการฝึกฝนโมเดล 10 รอบ ตามภาพที่ 9 (ก) และ (ข) พบว่า สำหรับข้อมูลชุดฝึกฝนมีแนวโน้มลดลงเรื่อย ๆ เมื่อจำนวนรอบในการฝึกฝนเพิ่มมากขึ้น ซึ่งตรงกันข้ามกับ

ค่า loss ในชุดข้อมูลสำหรับการพัฒนาโมเดลนั้นกลับมีค่าสูงขึ้นเมื่อจำนวนรอบในการฝึกฝนมากขึ้น ซึ่งอาจก่อให้เกิดปัญหา overfitting กับข้อมูลภายในโมเดลชุดฝึกฝน ซึ่งตรงกันข้ามกับค่าความถูกต้องในข้อมูลชุดฝึกฝน ที่มีแนวโน้มสูงขึ้นในแต่ละรอบของการฝึกฝน และเมื่อพิจารณาค่าความถูกต้องของชุดข้อมูลสำหรับการพัฒนาโมเดล พบว่า เมื่อเพิ่มรอบในการฝึกฝนมากขึ้นทำให้ความถูกต้องของข้อมูลสำหรับการพัฒนาโมเดลลดลง ซึ่งเกิดปัญหา overfitting ตามที่คาดหมายไว้

ผู้วิจัยได้พัฒนาโมเดลในการวิเคราะห์ความรู้สึกของข้อความที่ได้จากกระบวนการรู้จำคำพูด โดยใช้โมเดล BERT โดยการลดจำนวนรอบในการฝึกฝนโมเดลเหลือจำนวน 3 รอบ โดยผลการวิเคราะห์จะพิจารณาค่า loss และ accuracy ในแต่ละรอบการฝึกฝนของโมเดล ตามตารางที่ 9

ตารางที่ 9 แสดงค่า (1) loss (2) acc (3) Validation loss และ (4) Validation acc ในแต่ละรอบของการฝึกฝนด้วยโมเดล BERT มีจำนวนรอบในการฝึกฝนโมเดล 3 รอบ

รอบของการฝึกฝนที่	loss	acc	Validation loss	Validation acc
1	0.8491	0.6146	0.7580	0.6525
2	0.7422	0.6742	0.7590	0.6832
3	0.6765	0.7035	0.7797	0.6632

จากตารางที่ 9 จะเห็นว่า เมื่อพิจารณาค่า loss ในรอบของการฝึกฝนแต่ละรอบจะเห็นว่า ค่า loss มีแนวโน้มลดลงโดยเริ่มจาก .8491 .7422 และ .6765 ในขณะที่ Validation loss หรือค่า loss ที่ทดสอบกับข้อมูลชุด validation มีค่าเป็น .7580 .7590 และ .7797 ซึ่งมีแนวโน้มของค่า loss เพิ่มขึ้น สำหรับค่าความถูกต้องมีแนวโน้มสูงขึ้นในแต่ละรอบของการฝึกฝน โดยเริ่มจาก .6143 .6742 และ .7035 ตามลำดับ และสำหรับค่าความถูกต้องของชุดพัฒนาโมเดลมีค่าใกล้เคียงกันทั้งสามรอบของการฝึกฝน ได้แก่ .6525 .6832 และ .6632 ตามลำดับ โดยสามารถพิจารณาแนวโน้มของค่า loss ทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดลได้ตามภาพที่ 9 (ค) และ แนวโน้มของค่าความถูกต้องทั้งข้อมูลชุดฝึกฝนและข้อมูลชุดพัฒนาโมเดลได้ตามภาพที่ 9 (ง)

เมื่อพิจารณาจากภาพที่ 9 (ก) จะเห็นว่า ค่า loss ของข้อมูลชุดฝึกฝน โมเดลมีแนวโน้มที่ลดลงแต่กลับเพิ่มขึ้นในข้อมูลชุดพัฒนาโมเดล ซึ่งโมเดลมีแนวโน้มเข้าสู่การเป็น overfitting กับข้อมูลที่ใช้ในการฝึกฝน โดยเมื่อเปรียบเทียบกับการพัฒนาโมเดลโดยเพิ่มจำนวนรอบในการฝึกฝน 10 รอบ

ที่พิจารณาก่อนหน้านั้น พบว่า โมเดลดังกล่าวมีลักษณะ overfitting กับข้อมูลชุดฝึกฝนมากเกินไป ค่า loss ของข้อมูลชุดพัฒนาโมเดลมีแนวโน้มสูงขึ้นอย่างเห็นได้ชัด

ผู้วิจัยนำโมเดลที่ได้ทำการลดจำนวนรอบในการฝึกฝนโมเดลจาก 10 รอบ เหลือ 3 รอบ แล้วนำโมเดลไปจำแนกความรู้สึกกับข้อมูลชุดทดสอบ โดยผลการจำแนกประเภทของข้อความจะแสดงในหัวข้อถัดไป

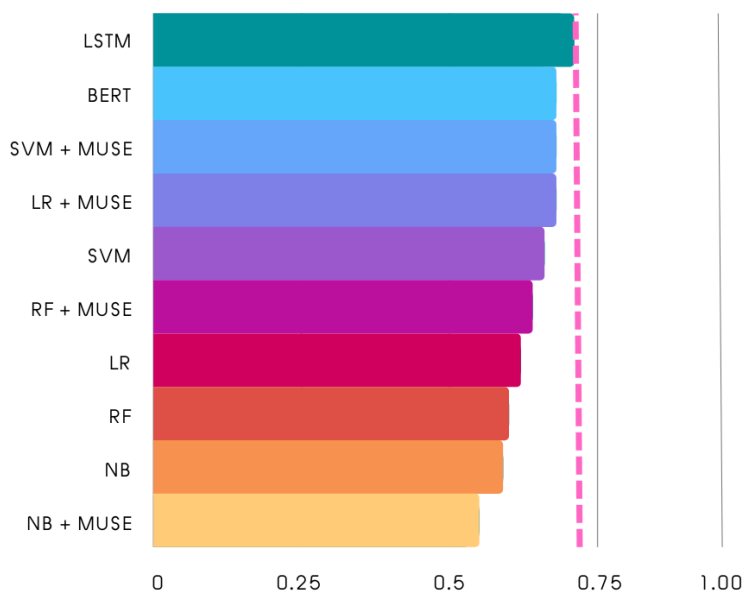
ตอนที่ 3 ผลการวิเคราะห์การประเมินประสิทธิภาพ ความเหมาะสมของโมเดลที่พัฒนาขึ้นและการนำไปใช้ในการจำแนกอารมณ์ครูในชั้นเรียน

1. ผลการวิเคราะห์การประเมินประสิทธิภาพ ความเหมาะสมของโมเดลที่พัฒนาขึ้น

ผู้วิจัยได้นำโมเดลที่พัฒนาในการวิเคราะห์ความรู้สึกที่ได้จากกระบวนการรู้จำคำพูดทั้ง 10 โมเดลมาเปรียบเทียบประสิทธิภาพและวิเคราะห์ความเหมาะสมของโมเดลที่พัฒนาขึ้น มีรายละเอียดตามตารางที่ 10


ตารางที่ 10 แสดงประสิทธิภาพในการจำแนกของโมเดลที่ได้ปรับไฮเพอร์พารามิเตอร์แล้วกับชุดข้อมูลทดสอบโดยเรียงค่าความถูกต้องจากมากไปน้อย

โมเดลที่	โมเดล	Accuracy	Precision			Recall			F1- measure		
			Neg	Neu	Pos	Neg	Neu	Pos	Neg	Neu	Pos
9	LSTM	.71	.72	.73	.56	.67	.82	.40	.69	.77	.47
10	BERT	.68	.71	.72	.48	.65	.77	.44	.68	.75	.46
7	SVM + MUSE	.68	.63	.85	.25	.66	.70	.64	.65	.77	.35
5	LR + MUSE	.68	.63	.84	.27	.66	.70	.60	.64	.76	.37
3	SVM	.66	.67	.69	.53	.67	.75	.43	.67	.72	.48
8	RF + MUSE	.64	.40	.93	.08	.70	.72	.75	.51	.75	.15
1	LR	.62	.71	.59	.59	.62	.77	.40	.66	.67	.48
4	RF	.60	.64	.65	.38	.54	.69	.41	.59	.67	.39
2	NB	.59	.67	.56	.54	.57	.75	.36	.62	.64	.43
6	NB + MUSE	.55	.00	1.00	.00	.00	.55	.00	.00	.71	.00




ภาพที่ 10 แนวโน้มค่าความถูกต้องในการจำแนกประเภทของข้อความของโมเดลต่าง ๆ
ทั้ง 10 โมเดล

จากตารางที่ 10 และภาพที่ 10 พบว่า โมเดลที่พัฒนาขึ้นจากทั้งกระบวนการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกความรู้สึกจากข้อความที่ได้จากกระบวนการรู้จำคำพูดนั้น โมเดล LSTM ที่มีการปรับไฮเพอร์พารามิเตอร์และมีจำนวนรอบในการฝึกฝนโมเดลเป็น 3 รอบนั้นมีค่าความถูกต้องของโมเดลที่ใช้ในการจำแนกความรู้สึกสูงที่สุด ร้อยละ 71 รองลงมาเป็นกลุ่มของโมเดลที่มี pretrained โมเดลในการเรียนรู้ ได้แก่ BERT SVM + MUSE และ LR + MUSE ซึ่งมีค่าความถูกต้องของโมเดลในการจำแนกอารมณ์ ประมาณร้อยละ 68 โดยโมเดล BERT จะมีความแตกต่างจากอีกสองโมเดลที่ค่าความแม่นยำในกลุ่มข้อความเชิงบวกและข้อความเชิงลบจะสูงกว่าอีกสองโมเดล แต่พบว่าความไวในการจำแนกกลุ่มข้อความเชิงบวกและข้อความเชิงลบกลับน้อยกว่าสำหรับโมเดล SVM + MUSE มีการปรับไฮเพอร์พารามิเตอร์ ดังนี้ 'C': 1000 และ 'kernel': 'rbf' และสำหรับโมเดล LR + MUSE มีการปรับไฮเพอร์พารามิเตอร์ดังนี้ 'C': 1, 'penalty': 'l2' และ 'solver': 'liblinear' และโมเดลที่มีค่าความถูกต้องในการจำแนกอารมณ์จากข้อความ ร้อยละ 66 ได้แก่ โมเดล SVM มีการปรับไฮเพอร์พารามิเตอร์ 'C': 1000 และ 'kernel': 'rbf'



(ก) Precision

(ข) Recall



(ค) F1-measure


ภาพที่ 11 แนวโน้มของดัชนีในการจำแนกประเภทของข้อความของโมเดลต่าง ๆ

จากภาพที่ 11 ความแม่นยำและความไวในการจำแนกกลุ่มทั้งสามประเภทโดยภาพรวมได้ดีที่สุด ได้แก่ LSTM รองลงมาเป็นโมเดล Multilingual Universal Sentence Encoder (MUSE) ที่มีการจำแนกความรู้สึกโดยใช้การเรียนรู้ของเครื่องของทั้งสองโมเดล คือ Logistic Regression (LR) และ Support Vector Machine (SVM) ที่มีค่าความถูกต้องในการจำแนกใกล้เคียงกับโมเดล BERT แต่แตกต่างกันที่ความแม่นยำ และความไวในการจำแนกกลุ่ม โมเดล BERT มีความสามารถในการจำแนกกลุ่มข้อความที่เป็นเชิงบวก และข้อความที่เป็นเชิงลบได้ดีกว่าโมเดล MUSE แต่โมเดล MUSE นั้นสามารถจำแนกข้อความที่เป็นกลางได้ดี และด้วยจำนวนข้อความที่เป็นกลางมีจำนวนมากสัดส่วนมากที่สุดเมื่อเทียบกับจำนวนข้อความทั้งหมด ทำให้ค่าความถูกต้องในการจำแนกของโมเดลเชิงลึกทั้งสองรูปแบบมีค่าใกล้เคียงกัน สำหรับโมเดลการเรียนรู้ของเครื่องที่ใช้ SVM ในการจำแนกประเภท ไม่มี pretrained โมเดล แม้ว่าการแก้ปัญหาความไม่สมดุลกันของจำนวนของข้อมูลในแต่ละประเภทจะทำให้ความแม่นยำ และความไวในการจำแนกมีค่าสูงขึ้นเมื่อเทียบโมเดลอื่น แต่ทำให้การจำแนกข้อความในกลุ่มที่เป็นกลางทำได้ไม่ดีนักค่าความถูกต้องของโมเดลการจำแนกด้วยการเรียนรู้ของเครื่องจึงมีประสิทธิภาพอยู่ในอันดับท้าย

จากตารางที่ 10 พบว่า สำหรับฐานข้อมูลชุดนี้ โมเดลการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงสุดในการวิเคราะห์จำแนกประเภทข้อความอย่าง SVM นั้นยังมีประสิทธิภาพน้อยกว่าโมเดลการเรียนรู้ของเครื่องที่ได้รับการฝึกฝนด้วย pretrained โมเดล โดยภาพรวม

2. การนำไปใช้ในการจำแนกอารมณ์ครูในชั้นเรียน

จากการพัฒนาโมเดลในการวิเคราะห์อารมณ์ของครูในชั้นเรียนผ่านการเรียนรู้เชิงลึกและได้ทำการตรวจสอบความเหมาะสมของโมเดลแล้วนั้น ผู้วิจัยได้นำวิดีโอทัศนของครูในชั้นเรียนที่สอนในรายวิชา ส 22231 หน้าที่พลเมือง 2 ระดับชั้นมัธยมศึกษาปีที่ 2 ในปีการศึกษา 2564 จำนวน 1 คาบ มาตัดเป็นประโยคสั้น ๆ ไม่เกิน 1 นาที จากนั้นนำไปเข้าสู่กระบวนการรู้จำคำพูดเพื่อแปลงเสียงเป็นข้อความแล้วจึงนำข้อความดังกล่าวมาจำแนกอารมณ์ครูในชั้นเรียนด้วยโมเดล LSTM (โมเดลที่ 9) ตามที่ได้พัฒนาขึ้น เพื่อสร้างข้อมูลย้อนกลับให้แก่ครูผู้สอนในชั้นเรียน โดยมีรายละเอียดของอารมณ์ครูในชั้นเรียน ดังภาพที่ 12

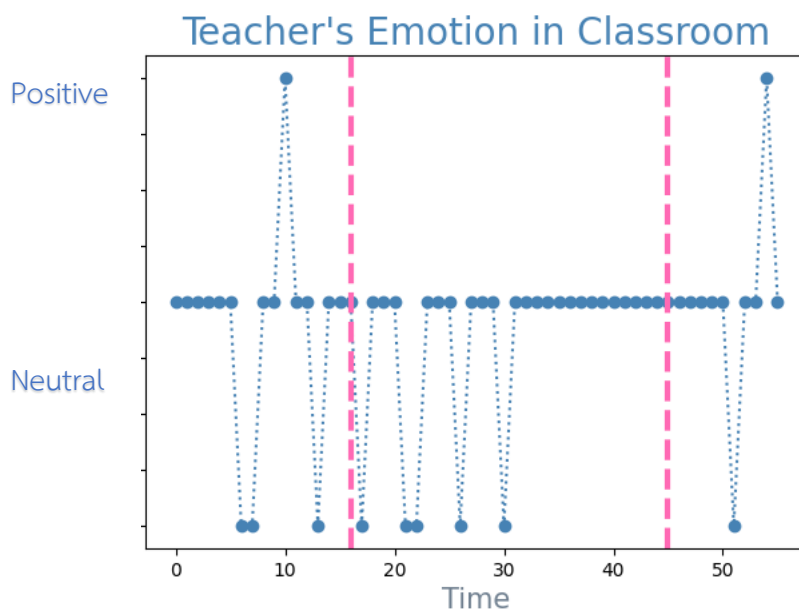


(ก) จำนวนของข้อความที่ครูแสดงอารมณ์ในชั้นเรียนในแต่ละประเภท

(ข) สัดส่วนร้อยละของข้อความที่ครูแสดงอารมณ์ในชั้นเรียนในแต่ละประเภท

ภาพที่ 12 จำนวนและสัดส่วนร้อยละของข้อความที่ครูแสดงอารมณ์ในชั้นเรียนในแต่ละประเภท

นอกจากนี้ ผู้วิจัยได้นำประเภทของข้อความที่ครูแสดงอารมณ์ไปทำเป็นกราฟคู่กับช่วงเวลาในคาบเรียนนั้น ๆ ดังภาพที่ 13



ภาพที่ 13 แสดงกราฟของข้อความที่ครูแสดงอารมณ์คู่กับช่วงเวลาในคาบเรียน

จากภาพที่ 13 จะเห็นได้ว่า เส้นประที่แบ่งเป็นการแบ่งช่วงของกิจกรรมการเรียนการสอนของครูผู้สอนในคาบเรียน โดยแบ่งเป็น 3 ชั้น ได้แก่ ชั้นนำ ชั้นสอน และชั้นสรุป

ในชั้นนำซึ่งอยู่ในช่วงต้นของคาบเรียน ครูผู้สอนมีการแสดงอารมณ์เป็นข้อความเชิงลบอยู่หลายครั้ง ซึ่งเมื่อเจาะลึกเข้าไปถึงสารสนเทศจากวิดีโอทัศนหรือข้อความที่ได้จากการรู้จำคำพูด พบว่าข้อความส่วนใหญ่เป็นการควบคุมชั้นเรียน สำหรับนักเรียนที่เพิ่งเข้ามาในชั้นเรียนออนไลน์ซึ่งทำให้อาจต้องมีการกำชับหรือกวดขันนักเรียนในเรื่องความพร้อมในการเรียน โดยเมื่อเข้าสู่ชั้นสอน ข้อความส่วนใหญ่เป็นข้อความที่เป็นกลาง เนื่องจากเป็นเนื้อหาสาระที่ครูสอนในชั้นเรียน รวมทั้งในช่วงท้ายของการเรียนในคาบเรียนนี้ที่เป็นชั้นสรุปนั้นม้อารมณ์ที่ครูแสดงออกมา เพื่อตอบสนองกับขั้นตอนในการตรวจสอบความรู้ของนักเรียนในคาบเรียน

บทที่ 5

สรุปผลการวิจัย อภิปรายผล ข้อเสนอแนะ

การวิจัยเรื่องการพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึก มีวัตถุประสงค์เพื่อ 1) เพื่อพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากการวิเคราะห์การรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก และ 2) เพื่อวิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนที่ได้พัฒนาขึ้น

แหล่งข้อมูลที่ใช้ในการดำเนินการวิจัยครั้งนี้เป็นข้อความที่ได้มาจาก 2 แหล่ง ได้แก่ (1) วิดีทัศน์ที่ได้จัดการเรียนการสอนทั้งแบบออนไลน์และแบบออนไซต์ ในรายวิชาสังคมศึกษาศาสนาและวัฒนธรรม ในปีการศึกษา 2564 และ 2565 จากครูระดับชั้นมัธยมศึกษาตอนต้นในโรงเรียนแห่งหนึ่งในสังกัดสำนักงานเขตพื้นที่การศึกษามัธยมศึกษา กรุงเทพมหานคร เขต 2 จำนวน 1 โรงเรียน จำนวน 3 ท่าน โดยนำเข้าสู่กระบวนการรู้จำคำพูดเพื่อแปลงไฟล์เสียงเป็นข้อความ และ (2) ฐานข้อมูล Wiselight Sentiment Analysis ซึ่งเป็นฐานข้อมูลข้อความที่ใช้ในการจำแนกความรู้สึกจากสังคมออนไลน์ เมื่อทำการจัดกระทำข้อมูลแล้ว แบ่งข้อความที่ได้ออกเป็น 3 ประเภท ได้แก่ ข้อความเชิงบวก ข้อความเชิงลบ และข้อความที่เป็นกลาง

โมเดลที่พัฒนาขึ้นสำหรับการวิเคราะห์อารมณ์ครูในชั้นเรียนในงานวิจัยนี้ จำแนกออกเป็น 3 กลุ่ม ได้แก่ กลุ่มที่ 1 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง จำนวน 4 โมเดล กลุ่มที่ 2 โมเดลที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder และมีการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่องจำนวน 4 โมเดล และกลุ่มที่ 3 โมเดลกลุ่มที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้เชิงลึก จำนวน 2 โมเดล

การวิเคราะห์ข้อมูลประกอบด้วย การวิเคราะห์สถิติเชิงบรรยาย เพื่อให้ได้ข้อมูลเกี่ยวกับลักษณะของตัวอย่างที่เก็บได้จากวีดิทัศน์การเรียนการสอนในชั้นเรียนและฐานข้อมูล โดยบอกจำนวนและร้อยละของสัดส่วนของข้อความในแต่ละประเภท สำหรับโมเดลกลุ่มที่ 1 เป็นโมเดลการเรียนรู้ของเครื่องในการวิเคราะห์เพื่อจำแนกประเภทของข้อความและสกัดคุณลักษณะด้วยเทคนิค TF-IDF ซึ่งเป็นการจัดกระทำข้อมูลที่เป็นข้อความออกมาให้กลายเป็นคุณลักษณะเพื่อใช้ในการวิเคราะห์จำแนก โดยมีการนำเทคนิคในการลดจำนวนมิติของคุณลักษณะอย่าง Principle

Component Analysis (PCA) และการแก้ปัญหาจำนวนประเภทของข้อมูลที่ไม่สมดุลกัน (imbalance dataset) ด้วยการทำ SMOTE สำหรับโมเดลกลุ่มที่ 2 ที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder ได้แก่ Multilingual Universal Sentence Encoder (MUSE) และมีการวิเคราะห์จำแนกอารมณ์ครูดด้วยการเรียนรู้ของเครื่อง และสำหรับโมเดลกลุ่มที่ 3 ที่มีการจัดกระทำข้อมูลก่อนการวิเคราะห์และทำการวิเคราะห์จำแนกอารมณ์ครูดด้วยการเรียนรู้เชิงลึก ได้แก่ Long short-term memory (LSTM) และ Bidirectional Encoder Representations from Transformer (BERT) มาใช้ในการเรียนรู้เพื่อจำแนกอารมณ์ของข้อความที่ได้จากกระบวนการรู้จำคำพูด

สรุปผลการวิจัย

ผลการวิจัยสามารถสรุปได้เป็น 2 ตอน ตามวัตถุประสงค์การวิจัย ได้แก่ ตอนที่ 1 การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูดในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากการวิเคราะห์การรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก และตอนที่ 2 วิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูดในชั้นเรียนที่ได้พัฒนาขึ้น

ตอนที่ 1 การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูดในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านทางข้อความที่ได้จากการวิเคราะห์การรู้จำคำพูดโดยใช้การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

1.1 การบรรยายลักษณะของข้อความที่นำมาจัดกระทำก่อนนำไปวิเคราะห์

ข้อความที่นำมาใช้ในการพัฒนาโมเดลการวิเคราะห์อารมณ์ครูดในชั้นเรียนสามารถจำแนกออกเป็น 2 ประเภท ได้แก่ ข้อความที่ได้จากฐานข้อมูล Wisersight Sentiment Analysis และนำมารวมกับข้อความที่ได้จากกระบวนการรู้จำคำพูดจากวีดิทัศน์การเรียนการสอนของครูดในชั้นเรียนจำนวน 11 คาบ โดยมีข้อความทั้งสิ้น 23974 ข้อความ โดยแบ่งเป็นข้อความเชิงบวก 18.21% ข้อความเชิงลบ 25.90% และข้อความที่เป็นกลางมีจำนวนมากที่สุด 55.89%

จากนั้นผู้วิจัยทำการแบ่งข้อมูลออกเป็น 2 ชุด ได้แก่ ข้อความสำหรับการฝึกฝนและข้อความสำหรับการทดสอบ โดยมีอัตราส่วนของจำนวนข้อความเป็น 85 : 15 ซึ่งข้อความทั้งสองชุดมีการแจกแจงของประเภทข้อความใกล้เคียงกัน

1.2 การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านข้อความโดยใช้โมเดลกลุ่มที่ 1

การสกัดคุณลักษณะของข้อความที่ปรากฏอยู่ในฐานข้อมูล ผู้วิจัยเลือกใช้เทคนิค TF – IDF ซึ่งเป็นเทคนิคในการนับจำนวนคำในเอกสารเพื่อนำมาคำนวณค่าความสำคัญ และเนื่องจากจำนวนคุณลักษณะที่สร้างขึ้นจากฐานข้อมูลมีจำนวนมาก จึงได้มีการกำหนดความถี่ขั้นต่ำที่ปรากฏในชุดข้อความเป็นค่าต่าง ๆ แล้วนำโมเดล Logistic Regression ที่ไม่ได้มีการปรับพารามิเตอร์ใด ๆ เป็นฐานในการเปรียบเทียบประสิทธิภาพเมื่อปรับค่าความถี่ขั้นต่ำของคำในเอกสาร ซึ่งพบว่า ค่าความไวในการจำแนกกลุ่มข้อความเชิงบวกมีค่าสูงขึ้น เมื่อกำหนดความถี่ขั้นต่ำที่ปรากฏในชุดข้อความเป็น 20 และ 80 แต่เมื่อพิจารณาถึงเวลาที่ใช้ในการจำแนกจึงกำหนดให้ความถี่ขั้นต่ำที่ปรากฏในชุดข้อความเป็น 80 ซึ่งใช้เวลาในการวิเคราะห์แตกต่างกันหลายเท่า ซึ่งทำให้คุณลักษณะภายในโมเดลลดลงแต่ยังคงมีขนาดใหญ่อยู่

นอกจากนี้มีการนำวิธีการ SMOTE ไปใช้ในการจัดกระทำข้อมูลเพื่อแก้ปัญหาข้อมูลที่ไม่สมดุลกันด้วย เนื่องจากจำนวนข้อความในแต่ละประเภทมีความไม่เท่าเทียมกันทำให้ประสิทธิภาพของความไวในการจำแนกกลุ่มข้อความเชิงบวก และข้อความเชิงลบมีค่าน้อย เนื่องจากจำนวนข้อความทั้งสองประเภทมีน้อยกว่าข้อความที่เป็นกลาง 2-3 เท่า

เนื่องจากคุณลักษณะภายในโมเดลมีจำนวนมาก ผู้วิจัยได้ทำการลดจำนวนมิติของคุณลักษณะภายในโมเดลโดยใช้ Principal Component Analysis (PCA) และเมื่อพิจารณาแล้วพบว่า ร้อยละของความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลการจำแนกเป็น 90 ซึ่งมีจำนวนคุณลักษณะของคำหรือกลุ่มคำอยู่จำนวน 681 คุณลักษณะนั้น มีค่าค่าเฉลี่ยความแม่นยำในการทำนายมีค่าใกล้เคียงกับร้อยละความผันแปรของคุณลักษณะที่เกิดขึ้นในโมเดลการจำแนกร้อยละ 100 จึงนำเทคนิคการลดจำนวนคุณลักษณะในโมเดลมาใช้

ผู้วิจัยได้ทำการพัฒนาโมเดลในการวิเคราะห์อารมณ์ของครูในชั้นเรียนโดยใช้การเรียนรู้ของเครื่อง 4 โมเดล ได้แก่ Logistic Regression (LR) Naive Bayes (NB) Support Vector Machine (SVM) Random Forests (RF) โดยเมื่อทำการปรับไฮเพอร์พารามิเตอร์ในแต่ละโมเดลการจำแนกพบว่า โมเดลที่มีความเหมาะสมที่สุดในการวิเคราะห์จำแนกด้วยการเรียนรู้ของเครื่องสำหรับชุดข้อมูลนี้ ได้แก่ โมเดล Support Vector Machine (SVM) ที่มีการกำหนดไฮเพอร์พารามิเตอร์ เป็นดังนี้ 'C': 1000 และ 'kernel': 'rbf' โดยที่มีค่าความถูกต้องในการจำแนกอยู่ที่ 66%

1.3 การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านข้อความโดยใช้โมเดลกลุ่มที่ 2

สำหรับโมเดลกลุ่มที่ 2 ที่มีการสกัดคุณลักษณะจากข้อความด้วยการเรียนรู้เชิงลึกโดยใช้ autoencoder ได้แก่ Multilingual Universal Sentence Encoder (MUSE) และมีการวิเคราะห์จำแนกอารมณ์ครูด้วยการเรียนรู้ของเครื่อง จำนวน 4 โมเดล

ในการวิเคราะห์เพื่อจำแนกความรู้สึกของข้อความโดยใช้โมเดล Multilingual Universal Sentence Encoder โดยเมื่อแปลงข้อความเป็นตัวเลขจากคลังคำศัพท์จากนั้นเก็บเป็นชุดข้อมูลอันหนึ่งแล้ว ได้นำข้อมูลดังกล่าวไปทำการวิเคราะห์ด้วยการเรียนรู้ของเครื่องในโมเดลต่าง ๆ 4 โมเดล และพบว่า โมเดลที่มีประสิทธิภาพในการจำแนกความรู้สึกจากข้อความภายหลังได้รับการปรับไฮเพอร์พารามิเตอร์มากที่สุด ได้แก่ โมเดล Support Vector Machine (SVM) ที่ปรับไฮเพอร์พารามิเตอร์ ดังนี้ 'C': 1000 และ 'kernel': 'rbf' และโมเดล Logistic Regression (LR) ที่ปรับไฮเพอร์พารามิเตอร์ ดังนี้ 'C': 1, 'penalty': 'l2' และ 'solver': 'liblinear' ซึ่งทั้งสองโมเดลจำแนกมีความถูกต้องใกล้เคียงกัน ประมาณร้อยละ 68

1.4 การพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนจากการวิเคราะห์ความรู้สึกผ่านข้อความโดยใช้โมเดลกลุ่มที่ 3

ผู้วิจัยได้พัฒนาโมเดลการเรียนรู้เชิงลึกที่ใช้ในการวิเคราะห์ 2 โมเดล ได้แก่ (1) Long short-term memory (LSTM) และ (2) Bidirectional Encoder Representations from Transformer (BERT) โดยในแต่ละโมเดลมีประสิทธิภาพในการจำแนกความรู้สึกของข้อความ ดังนี้

โมเดล Long short-term memory หรือ LSTM เป็นโมเดลที่มีความสามารถในการวิเคราะห์ความรู้สึกได้สูงซึ่งเหมาะสำหรับข้อมูลที่มีขนาดใหญ่ เมื่อกำหนดคุณลักษณะของโมเดลตามเงื่อนไขต่าง ๆ และให้เครื่องได้เรียนรู้กับข้อมูลชุดฝึกฝนและข้อมูลชุดสำหรับการพัฒนาโมเดล จากนั้นนำไปทดสอบกับข้อมูลชุดทดสอบ พบว่า เมื่อกำหนดจำนวนรอบในการเรียนรู้มากถึง 10 รอบทำให้เกิดปัญหา overfitting กับข้อมูลภายในโมเดลชุดฝึกฝน โดยเมื่อลดจำนวนรอบในการฝึกฝนให้น้อยลง ประสิทธิภาพในการจำแนกความรู้สึกสูงขึ้น และสำหรับโมเดล BERT ก็มีลักษณะคล้ายคลึงกัน โดยค่าความถูกต้องของโมเดล LSTM และโมเดล BERT มีค่าร้อยละ 71 และ 68 ตามลำดับ

ตอนที่ 2 วิเคราะห์ความเหมาะสมของโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนที่ได้พัฒนาขึ้น

โมเดลที่พัฒนาขึ้นจากทั้งกระบวนการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึกในการจำแนกความรู้สึกจากข้อความที่ได้จากกระบวนการรู้จำคำพูดนั้น โมเดล LSTM ที่มีการปรับไฮเพอร์

พารามิเตอร์และมีจำนวนรอบในการฝึกฝนโมเดลเป็น 3 รอบนั้นมีความถูกต้องของโมเดลที่ใช้ในการจำแนกความรู้สึกที่สูงที่สุด ร้อยละ 71 โดยมีความแม่นยำและความไวในการจำแนกกลุ่มทั้งสามประเภทโดยภาพรวมได้ดีที่สุด รองลงมาเป็นโมเดล Multilingual Universal Sentence Encoder (MUSE) ที่มีการจำแนกความรู้สึกโดยใช้การเรียนรู้ของเครื่องของทั้งสองโมเดล คือ Logistic Regression (LR) และ Support Vector Machine (SVM) ที่มีค่าความถูกต้องในการจำแนกใกล้เคียงกับโมเดล BERT แต่แตกต่างกันที่ความแม่นยำ และความไวในการจำแนกกลุ่ม โมเดล BERT มีความสามารถในการจำแนกกลุ่มข้อความที่เป็นเชิงบวก และข้อความที่เป็นเชิงลบได้ดีกว่าโมเดล MUSE แต่โมเดล MUSE นั้นสามารถจำแนกข้อความที่เป็นกลางได้ดีกว่า

อภิปรายผลการวิจัย

จากผลงานวิจัยการพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึกโดยสามารถพัฒนาโมเดลในการวิเคราะห์อารมณ์ครูในชั้นเรียนโดยใช้การเรียนรู้ของเครื่องด้วยเทคนิคและโมเดลการจำแนกต่าง ๆ ร่วมกับการวิเคราะห์ภาษาธรรมชาติ (NLP) ในการจัดกระทำข้อมูลก่อนการพัฒนาโมเดลการเรียนรู้ของเครื่องในการวิเคราะห์มีการลดทอนมิติของคุณลักษณะในการวิเคราะห์ข้อมูล เพราะลดความซับซ้อนและสิ้นเปลืองทรัพยากร นอกจากนี้ยังมีการใช้เทคนิค SMOTE ไปใช้ในการจัดกระทำข้อมูลเพื่อแก้ปัญหาข้อมูลที่ไม่สมดุลกัน ซึ่งส่งผลให้ความไวในการจำแนกกลุ่มมีประสิทธิภาพสูงขึ้น สอดคล้องกับงานวิจัยของ Pongthano, P., & Songpan, W. (2020) ที่พบว่า ค่าที่ทำนายถูกภายในโมเดลสูงขึ้น สามารถจำแนกความแตกต่างของกลุ่มจำแนกได้ดีขึ้น ส่งผลให้ค่าความแม่นยำทั้งโมเดลสูงขึ้นด้วย

โมเดลในการวิเคราะห์อารมณ์ครูในชั้นเรียนโดยใช้โมเดล SVM ที่มีการปรับไฮเพอร์พารามิเตอร์เรียบร้อยแล้วให้ประสิทธิภาพในการจำแนกเหมาะสมที่สุด โดยมีค่าความแม่นยำสูงสุด สอดคล้องกับ Shoffan et. al. (2021) ที่ได้ทำการเปรียบเทียบประสิทธิภาพในการวิเคราะห์อารมณ์เกี่ยวกับความวิตกกังวลโดยใช้ข้อมูลจากสื่อสังคมออนไลน์ผ่านการเรียนรู้ของเครื่องก็พบว่า โมเดล SVM ให้ประสิทธิภาพสูงสุดใน 3 สถานการณ์ และสอดคล้องกับงานวิจัยงาน Qi, Y., & Shabrina, Z. (2023). ที่ได้เปรียบเทียบประสิทธิภาพของการเรียนรู้ของเครื่องผสมกับการใช้เทคนิค Bag of Words และ TF-IDF พบว่า SVC ให้ประสิทธิภาพในการจำแนกได้สูงสุด

ในการวิเคราะห์อารมณ์จากข้อความในครั้งนี้ใช้ฐานข้อมูล Wisersight Sentiment Analysis เป็นฐานข้อมูลหลักซึ่งเป็นฐานข้อมูลที่ไว้ใช้สำหรับการวิเคราะห์อารมณ์จากข้อความโดยทั่วไป ไม่ได้จำเพาะกับข้อความที่แสดงอารมณ์ในชั้นเรียน ทำให้ประสิทธิภาพในการจำแนกประเภทข้อความไม่สูง

เท่าที่ควร ในอนาคตหากสามารถเพิ่มจำนวนข้อความสำหรับข้อมูลชุดฝึกฝนให้มีขนาดใหญ่มากขึ้น ย่อมจะทำให้ประสิทธิภาพความถูกต้องของการจำแนกในการเรียนรู้ของเครื่องสูงขึ้น สอดคล้องกับ Aji boye, A. R., Abdullah-Arshah, R., & Hongwu, Q. (2015)

เมื่อเปรียบเทียบประสิทธิภาพโดยภาพรวมของการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่อง พบว่า การเรียนรู้เชิงลึกมีประสิทธิภาพในการจำแนกความรู้สึกจากข้อความได้สูงกว่าการเรียนรู้ของเครื่อง สอดคล้องกับ Jain, K., & Kaushal, S. (2018) ที่ได้ทำการวิเคราะห์ความรู้สึกในหลาย ๆ กรณี แล้วพบว่าการเรียนรู้เชิงลึกให้ประสิทธิภาพและความแม่นยำในการจำแนกสูงกว่าการเรียนรู้ของเครื่อง และโมเดลที่มีประสิทธิภาพในการจำแนกสูงสุด ได้แก่ โมเดล LSTM ซึ่งสามารถจำแนกความรู้สึกจากข้อความได้โดยมีค่าความถูกต้องร้อยละ 71 ซึ่งดีกว่าโมเดล BERT สอดคล้องกับ Ezen-Can, A. (2020). ที่พบว่า ประสิทธิภาพในการจำแนกของโมเดล LSTM ดีกว่าโมเดล BERT ได้ขึ้นอยู่กับประเภทและลักษณะของข้อมูลที่น่ามาวิเคราะห์ไม่ได้จำเป็นว่า การมีโมเดลที่ฝึกฝนมาเรียบร้อยแล้ว และเป็นข้อมูลขนาดใหญ่แล้วจะทำให้ประสิทธิภาพในการวิเคราะห์สูงไปด้วย

ข้อเสนอแนะ

การวิจัยเรื่องการพัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การเรียนรู้เชิงลึก มีข้อเสนอแนะในการวิจัยโดยแบ่งประเด็นออกเป็น 2 ส่วน ได้แก่ ข้อเสนอแนะในการนำผลการวิจัยไปใช้และข้อเสนอแนะสำหรับการวิจัยครั้งต่อไป โดยมีรายละเอียด ดังนี้

ข้อเสนอแนะในการนำผลการวิจัยไปใช้

1. จากผลการวิจัยที่พบว่า โมเดลการเรียนรู้ของเครื่องที่มีประสิทธิภาพสูงสุดในการจำแนกประเภทข้อความ คือ โมเดล SVM โดยมีโมเดลอื่น ๆ มีประสิทธิภาพน้อยกว่านั้น สามารถนำไปพัฒนาองค์ความรู้เกี่ยวกับประสิทธิภาพในการวิเคราะห์ความรู้สึกจากการเรียนรู้เชิงลึกจากกระบวนการการวิเคราะห์อารมณ์จากข้อความที่ได้จากการรู้จำคำพูด
2. จากผลการวิจัยที่พบว่า โมเดลการเรียนรู้เชิงลึก LSTM มีประสิทธิภาพในการจำแนกความรู้สึกของข้อความได้สูงที่สุด โดยมีค่าความถูกต้องร้อยละ 71 สามารถนำไปพัฒนาองค์ความรู้เกี่ยวกับประสิทธิภาพในการวิเคราะห์ความรู้สึกที่สามารถเพิ่มความสามารถในการจำแนกกลุ่มข้อความเชิงบวกและข้อความเชิงลบให้มีประสิทธิภาพมากยิ่งขึ้น
3. จากผลการวิจัยที่ได้พัฒนาโมเดลในการจำแนกข้อความนั้น สามารถนำโมเดลที่พัฒนาขึ้นไปวิเคราะห์เพื่อหาคำหรือกลุ่มคำ จากคุณลักษณะที่สำคัญในโมเดลเพื่อนำเสนอว่า คำหรือกลุ่มคำแบบใดที่ส่งผลต่ออารมณ์เชิงลบหรืออารมณ์เชิงบวกที่เกิดขึ้นในชั้นเรียน ซึ่งสามารถ

นำไปขยายผลสู่ห้องเรียนว่าคำหรือกลุ่มคำในลักษณะนั้น ๆ เป็นคำที่ควรหลีกเลี่ยง หรือควรส่งเสริมให้มีการใช้ในห้องเรียน

ข้อเสนอแนะสำหรับการวิจัยครั้งต่อไป

1. จากผลการวิจัยที่พบว่าโมเดลการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องที่พัฒนาขึ้นมีประสิทธิภาพในการจำแนกประเภทได้ 71% สามารถจำแนกและนำความรู้เกี่ยวกับการเรียนรู้เชิงลึกไปใช้ในการพัฒนาโมเดลเพื่อเพิ่มประสิทธิภาพในการวิเคราะห์อารมณ์จากข้อความ
2. เนื่องจากมีการใช้ฐานข้อมูล Wisersight Sentiment Analysis ซึ่งเป็นฐานข้อมูลสำหรับการวิเคราะห์อารมณ์จากข้อความโดยทั่วไป อาจไม่ได้จำเพาะกับข้อความในชั้นเรียน ประกอบกับหากต้องเก็บรวบรวมข้อมูลที่มีขนาดใหญ่ใหม่ทั้งหมดแล้วนำมาพัฒนาโมเดลด้วยตนเองทำได้ยาก จึงอาจประยุกต์ใช้การเรียนรู้แบบ Semisupervised มาลดจำนวนข้อมูลและเพิ่มการใช้การเรียนรู้ของเครื่องในการลดข้อจำกัดด้านจำนวนข้อมูล
3. จากผลการวิจัยที่พบว่า โมเดลการเรียนรู้เชิงลึก BERT สามารถจำแนกกลุ่มข้อความที่เป็นเชิงบวกและข้อความที่เป็นเชิงลบได้ดีกว่าโมเดล MUSE ทั้ง ๆ ที่มีค่าความถูกต้องในการทำนายใกล้เคียงกัน โดยโมเดล MUSE สามารถจำแนกข้อความที่เป็นกลางได้ดีกว่า ในสถานการณ์จริงของชั้นเรียนอาจมุ่งเน้นและสนใจข้อความที่มีทิศทางมากกว่าไม่มีทิศทาง ฉะนั้นหากพัฒนาโมเดล BERT ให้มีประสิทธิภาพสูงขึ้นอาจช่วยทำให้จำแนกอารมณ์ข้อความที่มีทิศทางได้มีประสิทธิภาพมากยิ่งขึ้นควรพัฒนาโมเดลต่อไป
4. จากผลการวิจัยที่ได้พัฒนาโมเดลในการจำแนกประเภทข้อความ สามารถนำไปพัฒนาและสร้างเครื่องมือหรือแอปพลิเคชันที่ครูสามารถนำไปใช้ในการให้ข้อมูลย้อนกลับในการจัดการเรียนการสอนเกี่ยวกับอารมณ์ของครูในชั้นเรียนได้ โดยแอปพลิเคชันหรือแพลตฟอร์มออนไลน์ที่สร้างขึ้นควรเป็นระบบอัตโนมัติที่เมื่อใส่ไฟล์วีดิทัศน์การสอนของครูเข้าไปในระบบแล้วจะสามารถทราบอารมณ์ในแต่ละช่วงเวลาได้ ระบบดังกล่าวควรประกอบด้วยส่วนประกอบหลักอย่างน้อย 3 ส่วน ได้แก่ (1) ส่วนที่จัดกระทำข้อมูลในการแปลงไฟล์วีดิทัศน์เป็นไฟล์เสียงและถอดไฟล์เสียงเป็นข้อความด้วยกระบวนการรู้จำคำพูด (2) ส่วนที่ใช้ในการประมวลผลหรือจำแนกอารมณ์จากข้อความโดยใช้โมเดลที่พัฒนาขึ้น และ (3) ส่วนที่แสดงผลการจำแนกอารมณ์ในแต่ละช่วงเวลาของครูในคาบเรียนนั้น ๆ

บรรณานุกรม

ภาษาไทย

สำนักงาน ก.ค.ศ. กระทรวงศึกษาธิการ (2564). *คู่มือการดำเนินการตามหลักเกณฑ์และวิธีการประเมินตำแหน่งและวิทยฐานะข้าราชการครูและบุคลากรทางการศึกษา ตำแหน่งครู*. 80 - 81

ภาษาอังกฤษ

- Abraham, R. (1998). Emotional dissonance in organizations: Antecedents, consequences, and moderators. *Genetic, Social, and General Psychology Monographs*, 124(2), 229–246.
- Ajiboye, A. R., Abdullah-Arshah, R., & Hongwu, Q. (2015). Evaluating the effect of dataset size on predictive model using supervised learning technique.
- Alonso-Tapia, J., Quijada, A., Ruiz, M., Huertas, J. A., Ulate, M. A., & Biehl, M. L. (2020). A cross-cultural study of the validity of a battery of questionnaires for assessing school climate quality. *Psicología Educativa*, 26(2), 109–119. <https://doi.org/10.5093/psed2020a2>
- Ames, C. (1992). Achievement goals and the classroom motivational climate. In D. H. Schunk, & J. L. Meece (Eds.), *Students' perceptions in the classroom* (pp. 327–348). Lawrence Erlbaum.
- Ashforth, B. E., & Tomiuk, M. A. (2000). Emotional labor and authenticity: Views from service agents. In S. Fineman (Ed.), *Emotions in organizations* (2nd ed ed., pp. 184–203). Sage Publications.
- Atoum, A. Y., & Al-Shoboul, R. A. (2018). *Emotional support and its relationship to Emotional intelligence*. *Advances in Social Sciences Research Journal*, 5(1).
- Bardach, L., Yanagida, T., & Luftenegger, M. (2020). Studying classroom climate effects in the context of multi-level structural equation modeling: An application-focused theoretical discussion and empirical demonstration. *International Journal of Research & Method in Education*, 43, 348–363. <https://doi.org/10.1080/1743727X.2020.1791071>
- Bar-On, R. E., and Parker, J. D. (2000). *The Handbook of Emotional Intelligence: Theory,*

- Development, Assessment, and Application at Home, School, and in the Workplace. *The Handbook of Emotional Intelligence*. San Francisco, CA: Jossey-Bass.
- Becker, E. S., Goetz, T., Morger, V., & Ranellucci, J. (2014). The importance of teachers' emotions and instructional behavior for their students' emotions—an experience sampling analysis. *Teaching and Teacher Education*, 43, 15–26.
- Brackett, M. A., Floman, J. L., Ashton-James, C., Cherkasskiy, L., & Salovey, P. (2013). The influence of teacher emotion on grading practices: a preliminary look at the evaluation of student writing. *Teachers and Teaching: Theory and Practice*, 19, 634–646.
- Buhrmester, D., Furman, W., Wittenberg, M. T., and Reis, H. T. (1988). Five domains of interpersonal competence in peer relationships. *J. Personal. Soc. Psychol.* 55, 991–1008.
- Chang, M.-L. (2013). Toward a theoretical model to understand teacher emotions and teacher burnout in the context of student misbehavior: Appraisal, regulation and coping. *Motivation and Emotion*, 37(4), 799–817.
- Chawla, N. V., Bowyer, K. W., Hall, L. O., & Kegelmeyer, W. P. (2002). SMOTE: synthetic minority over-sampling technique. *Journal of artificial intelligence research*, 16: 321-357.
- Davis, S. K., and Nichols, R. (2016). Does emotional intelligence have a “dark” side? A review of the literature. *Front. Psychol.* 7:1316.
- Day, C., & Gu, Q. (2011). Teacher emotions: well being and effectiveness. In P. A. Schutz & M. Zembylas (Eds.), *Advances in teacher emotion research* (pp. 15–31). Heidelberg: Springer.
- Day, C., & Gu, Q. (2014). *Resilient teachers, resilient schools. Building and sustaining quality in testing times*. London: Routledge.
- Dong, Y., and Yu, G. L. (2007). The development and application of an academic emotions questionnaire. *Acta Psychol. Sin.* 39, 852–860. Available online at: <https://wenku.baidu.com/view/00b64751ad02de80d4d840f8.html>
- Eisma, M. C., and Stroebe, M. S. (2021). Emotion regulatory strategies in complicated grief: A systematic review. *Behav. Ther.* 52, 234–249.

- Erickson, R. J. (1995). The importance of authenticity for self and society. *Symbolic Interaction*, 18 (2), 121–144.
- Esparza, G. G., de-Luna, A., Zezzatti, A. O., Hernandez, A., Ponce, J., Álvarez, M., ... & de Jesus Nava, J. (2018). A sentiment analysis model to analyze students reviews of teacher performance using support vector machines. In *Distributed Computing and Artificial Intelligence, 14th International Conference* (pp. 157-164). Springer International Publishing.
- Ezen-Can, A. (2020). A Comparison of LSTM and BERT for Small Corpus. *arXiv preprint arXiv:2009.05451*.
- Fredrickson, B. L. (2001). The role of positive emotions in positive psychology: The broaden-and-build theory of positive emotions. *American Psychologist*, 56(3), 218–226.
- Frenzel, A. C., Goetz, T., Lüdtke, O., Pekrun, R., & Sutton, R. (2009). Emotional transmission in the classroom: exploring the relationship between teacher and student enjoyment. *Journal of Educational Psychology*, 101, 705–716.
- Frenzel, A. C., Goetz, T., Stephens, E. J., & Jacob, B. (2011). Antecedents and effects of teachers' emotional experiences: an integrated perspective and empirical test. In P. A. Schutz & M. Zembylas (Eds.), *Advances in teacher emotion research* (pp. 129–151).
- Frenzel, A. C. (2014). Teacher emotions. In L. Linnenbrink-Garcia & R. Pekrun (Eds.), *Handbook of emotions in education* (pp. 494–519).
- Frenzel, A. C., Becker-Kurz, B., Pekrun, R., Goetz, T., & Lüdtke, O. (2018). Emotion transmission in the classroom revisited: A reciprocal effects model of teacher and student enjoyment. *Journal of Educational Psychology*, 110(5), 628–639.
- Goetz, T., Pekrun, R., Hall, N., & Haag, L. (2006). Academic emotions from a social-cognitive perspective: Antecedents and domain specificity of students' affect in the context of Latin instruction. *British Journal of Educational Psychology*, 76(2), 289–308.
- Grandey, A. A. (2003). When “the show must go on”: Surface acting and deep acting as determinants of emotional exhaustion and peer-rated service delivery. *Academy of Management Journal*, 46(1), 80–96.

- Gross, J. J. (1998). Antecedent- and response-focused emotion regulation: Divergent consequences for experience, expression, and physiology. *Journal of Personality and Social Psychology*, 74(1), 224–237.
- Gross, J. J., and John, O. P. (2003). Individual differences in two emotion regulation processes: implications for affect, relationships, and well-being. *J. Personal. Soc. Psychol.* 85, 348–362.
- Hannula, M. S. (2006). Motivation in mathematics: Goals reflected in emotions. *Educational Studies in Mathematics*, 63(2), 165–178.
- Haddix, M. M. (2015). *Cultivating racial and linguistic diversity in literacy teacher education: Teacherslike me*. Routledge.
- Hargreaves, A. (2000). Mixed emotions: Teachers' perceptions of their interactions with students. *Teaching and Teacher Education*, 16(8), 811–826.
- Hatfield, E., Cacioppo, J. T., & Rapson, R. L. (1993). Emotional contagion. *Current Directions in Psychological Science*, 2(3), 96–99.
- Hülshager, U. R., & Schewe, A. F. (2011). On the costs and benefits of emotional labor: A metaanalysis of three decades of research. *Journal of Occupational Health Psychology*, 16(3), 361–389.
- Iruloh, N.B and Ukaegbu, M.H, (2015). Emotional, social, cognitive intelligence and social support network among youth. *British Journal of physical research*. 3(2): 35-41 จุฬาลงกรณ์มหาวิทยาลัย
- Jain, K., & Kaushal, S. (2018). A comparative study of machine learning and deep learning techniques for sentiment analysis. In *2018 7th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions)(ICRITO)* (pp. 483-487). IEEE.
- Jennings, P. A., & Greenberg, M. T. (2009). The prosocial classroom: Teacher social and emotional competence in relation to student and classroom outcomes. *Review of Educational Research*, 79 (1), 491–525.
- Jing Tan, Jie Mao, Yizhang Jiang and Ming Gao. (2021). The Influence of Academic Emotions on Learning Effects: A Systematic Review.
- Johnston, L., Miles, L., & Macrae, C. N. (2010). Why are you smiling at me? Social

- functions of enjoyment and non-enjoyment smiles. *The British Journal of Social Psychology*, 49(1), 107–127.
- Keller, M. M., Chang, M.-L., Becker, E., Goetz, T., & Frenzel, A. C. (2014). Teachers' emotional experiences and exhaustion as predictors of emotional labor in the classroom: An experience sampling study. *Frontiers in Psychology*, 5.
- Keller, M. M., Goetz, T., Becker, E., Morger, V., & Hensley, L. (2014). Feeling and showing: A new conceptualization of dispositional teacher enthusiasm and its relation to students' interest. *Learning and Instruction*, 33, 29–38.
- Kumar, A., & Jain, R. (2015). Sentiment analysis and feedback evaluation. In *2015 IEEE 3rd International Conference on MOOCs, Innovation and Technology in Education (MITE)* (pp. 433-436). IEEE.
- Kunter, M., Klusmann, U., Baumert, J., Richter, D., Voss, T., & Hachfeld, A. (2013). Professional competence of teachers: Effects on instructional quality and student development. *Journal of Educational Psychology*, 105(3), 805–820.
- Lee, M., Pekrun, R., Taxer, J. L., Schutz, P. A., Vogl, E., & Xie, X. (2016). Teachers' emotions and emotion management: Integrating emotion regulation theory with emotional labor research. *Social Psychology of Education*, 19(4), 843–863.
- Liu, W., Mei, J., Tian, L., and Huebner, E. S. (2016). Age and gender differences in the relation between school-related social support and subjective well-being in school among students. *Soc. Indic. Res.* 125, 1065–1083. doi: 10.1007/s11205-015-0873-1
- Lowphansirikul, L., Polpanumas, C., Jantrakulchai, N., & Nutanong, S. (2021). Wangchanberta: Pretraining transformer-based thai language models. *arXiv preprint arXiv:2101.09635*.
- Lu, J. M., Chen, N. Q., Xu, L., Chen, Y. X., and Wu, J. (2016). A survey of contemporary college students' emotional intelligence in China. *J. Psychol. Sci.* 39, 1302–1309.
- Maik Bieleke, Katarzyna Gogol, Thomas Goetz, Lia Daniels and Reinhard Pekrun. (2021). The AEQ-S: A Short Version of the Achievement Emotions Questionnaire. *Contemporary Educational Psychology*, 101940. Advance

- online publication. <https://doi.org/10.1016/j.cedpsych.2020.101940>.
- Miao, C., Humphrey, R. H., and Qian, S. (2017). A meta-analysis of emotional intelligence and work attitudes. *J. Occup. Organ. Psychol.* 90, 177–202.
- McLellan, T., Johnston, L., Dalrymple-Alford, J., & Porter, R. (2010). Sensitivity to genuine versus posed emotion specified in facial displays. *Cognition & Emotion*, 24(8), 1277– 1292.
- Pekrun, R., Goetz, T., Titz, W., and Perry, R. P. (2002). Academic emotions in students' self-regulated learning and achievement: a program of qualitative and quantitative research. *Educ. Psychol.* 37, 91–105. doi: 10.1207/S15326985EP3702_4
- Pekrun, R. (2006). The control-value theory of achievement emotions: Assumptions, corollaries, and implications for educational research and practice. *Educational Psychology Review*, 18(4), 315–341.
- Philipp, A., & Schüpbach, H. (2010). Longitudinal effects of emotional labor on emotional exhaustion and dedication of teachers. *Journal of Occupational Health Psychology*, 15(4), 194– 504.
- Podsakoff, P. M., MacKenzie, S. B., Lee, J.-Y., and Podsakoff, N. P. (2003). Common method biases in behavioral research: a critical review of the literature and recommended remedies. *J. Appl. Psychol.* 88, 879–903.
- Pongthanoo, P., & Songpan, W. (2020). Feature selection and reduction based on SMOTE and information gain for sentiment mining. In *2020 5th International Conference on Computer and Communication Systems (ICCCS)* (pp. 109-114). IEEE.
- Qi, Y., & Shabrina, Z. (2023). Sentiment analysis using Twitter data: a comparative application of lexicon-and machine-learning-based approach. *Social Network Analysis and Mining*, 13(1): 31.
- Reyes, M. R., Brackett, M. A., Rivers, S. E., White, M., & Salovey, P. (2012). Classroom emotional climate, student engagement, and academic achievement. *Journal of Educational Psychology*, 104(3), 700–712.
- Reyna, C., and Weiner B. (2001). Justice and utility in the classroom: An attributional analysis of the goals of teachers' punishment and intervention strategies. *J.*

- Educ. Psychol. 93: 309–319.
- Salmela, M. (2005). What Is emotional authenticity? *Journal for the Theory of Social Behaviour*, 35 (3), 209–230.
- Saifullah, S., Fauziah, Y., & Aribowo, A. S. (2021). Comparison of machine learning for sentiment analysis in detecting anxiety based on social media data. *arXiv preprint arXiv:2101.06353*.
- Schutz, P., & Davis, H. A. (2000). Emotions and self-regulation during test taking. *Educational Psychologist*, 35(4), 243–256.
- Skinner, E., Furrer, C., Marchand, G., & Kindermann, T. (2008). Engagement and disaffection in the classroom: Part of a larger motivational dynamic? *Journal of Educational Psychology*, 100 (4), 765–781
- Shewark, E. A., Zinsser, K. M., & Denham, S. A. (2018). Teachers' perspectives on the consequences of managing classroom climate. In *Child & Youth Care Forum* (Vol. 47, pp. 787-802). Springer US.
- Staudemeyer, R. C., & Morris, E. R. (2019). Understanding LSTM--a tutorial into long short-term memory recurrent neural networks. *arXiv preprint arXiv:1909.09586*.
- Sutton, R. E. (2004). Emotional regulation goals and strategies of teachers. *Social Psychology of Education*, 7(4), 379–398.
- Taxer, J. L., & Frenzel, A. C. (2015). Facets of teachers' emotional lives: A quantitative investigation of teachers' genuine, faked, and hidden emotions. *Teaching and Teacher Education*, 49, 78–88. <https://doi.org/10.1016/j.tate.2015.03.003>
- Tian, L., Liu, B., Huang, S., and Huebner, E. S. (2013). Perceived social support and school well-being among Chinese early and middle adolescents: the mediational role of self-esteem. *Soc. Indic. Res.* 113, 991–1008. doi: 10.1007/s11205-012-0123-8
- Tsouloupas, C. N., Carson, R. L., Matthews, R., Grawitch, M. J., & Barber, L. K. (2010). Exploring the association between teachers' perceived student misbehavior and emotional exhaustion: the importance of teacher efficacy beliefs and emotion regulation. *Educational Psychology*, 30(2), 173–189.
- Van Kleef, G. A. (2010). The emerging view of emotion as social information. *Social and Personality Psychology Compass*, 4(5), 331–343.

- Wang, M. T., Degol, J. L., Amemiya, J., Parr, A., & Guo, J. (2020). Classroom climate and children's academic and psychological wellbeing: A systematic review and meta-analysis. *Developmental Review*, 57, Article 100912. <https://doi.org/10.1016/j.dr.2020.100912>
- Xiang Feng, Yaojia Wei, Xianglin Pan, Longhui Qiu and Yongmei Ma. (2020). Academic Emotion Classification and Recognition Method for Large-scale Online Learning Environment—Based on A-CNN and LSTM-ATT Deep Learning Pipeline Method. *International Journal of Environmental Research and Public Health*.
- Yang, Y., Cer, D., Ahmad, A., Guo, M., Law, J., Constant, N., ... & Kurzweil, R. (2019). Multilingual universal sentence encoder for semantic retrieval. *arXiv preprint arXiv:1907.04307*.
- Yerkes, R.M.; Dodson, J.D. The relation of strength of stimulus to rapidity of habit-formation. *J. Comp. Neurol. Psychol.* 1908, 18, 459–482.
- Zedan, R. (2010). New dimensions in the classroom climate. *Learning Environments Research*, 13(1), 75-88.



ภาคผนวก

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY



Speech Recognition

install module

```
!pip install SpeechRecognition
!pip install moviepy==1.0.3
!pip install imageio==2.4.1
!pip install imageio-ffmpeg
!pip install --upgrade imageio-ffmpeg
!pip install pydub
!pip install pythainlp
```

```
import speech_recognition as sr
from csv import writer
from moviepy.editor import *
from pydub import AudioSegment
from pydub.utils import make_chunks
from time import sleep
import os

from google.colab import drive
drive.mount('/content/drive')

def save(text) :
    with open('/content/database/data_from_folder.csv', 'a',
newline='',encoding='utf-8') as file:
        writer_obj = writer(file)
        writer_obj.writerow([text])

def MP4ToMP3(mp4) :
    type = mp4.split(".")[1]
    mp3 = mp4.replace(type, ".wav")
    FILETOCONVERT = AudioFileClip(mp4)
    FILETOCONVERT.write_audiofile(mp3)
```

```

FILETOCONVERT.close()

direc = "/content/workspace" #only MP3
r = sr.Recognizer()
for filename in os.listdir(direc):
    f = os.path.join(direc, filename)
    if os.path.isfile(f):
        sound = AudioSegment.from_file(f, format="mp3")
        chunks = make_chunks(sound, 55000)

        for i, chunk in enumerate(chunks):
            chunk.export(f"/content/Temp/ (เก้าเอี่ยน).wav",
format="wav")

Text_Result = ""
direc = "Temp"
r = sr.Recognizer()
sleep(2)
for filename in os.listdir(direc):
    f = os.path.join(direc, filename)
    # checking if it is a file
    if os.path.isfile(f):
        with sr.AudioFile(f) as source:
            try:
                audio = r.record(source)
                text = r.recognize_google(audio ,language
= "th-TH")

                Text_Result += text
            except: pass
    os.remove(f)
    sleep(1)

```

```
print(Text_Result)

save(Text_Result)

sleep(2)

import pandas as pd

path = "/content/data_text/text01.csv"
df_text01 = pd.read_csv(path)
df_text01.info()

# collect data from file in 1 period
txt = ""
with open('/content/data_text/text01.csv', 'r') as file:
    csv_reader = csv.reader(file)

    next(csv_reader)

    for row in csv_reader:
        txt += row[1]

print(txt)

y = df_text.Class.value_counts()
mylabels = [ "Neutral", "Negative", "Positive"]
mycolors = ["#B0E0E6", "#FF6347", "#90EE90"]
myexplode = [0, 0.15, 0]

plt.pie(y, labels = mylabels, explode = myexplode, colors =
mycolors)

plt.show()
```



word cloud

```

!pip install wordCloud
import pythainlp
from pythainlp import word_tokenize
from pythainlp.corpus import get_corpus # for getting stopwords

import wordcloud
from wordcloud import WordCloud

import matplotlib.pyplot as plt
import numpy as np
import re

%matplotlib inline
%config InlineBackend.figure_format='retina'
print(f'wordcloud version: {wordcloud.__version__}')
print(f'pythainlp version: {pythainlp.__version__}')

words = word_tokenize(text)
print(words)

all_words = ' '.join(words).lower().strip()
all_word = re.sub('(\n|\s{2})', '', all_words)
all_words[:-1]

stopwords = pythainlp.corpus.thai_stopwords()
# print(stopwords)

stopwords=set(list(stopwords)).union({'นี่', 'อัน', 'แต่', 'ไม่', 'เออ', '
ไหม', 'นะ'})

print(stopwords)

```



```

path = 'THSarabunNew.ttf'


!wget https://www.f0nt.com/download/sipafonts/THSarabunNew.zip ;
unzip THSarabunNew.zip

wordcloud = WordCloud(
    font_path=path,
    regex= r"[n-ء']+",
    #regex = r"[n-ءa-zA-Z']+",
    min_font_size=1,
    background_color="white",
    max_words=1000,
    scale=3,
    font_step=5,
    contour_color='steelblue',
    collocations= False,
    stopwords = stopwords,
    width=2000, height=1000,
    # width=400,height=200,
    prefer_horizontal=1,
    # max_words=75,
    colormap='viridis', # default matplotlib colormap
    # colormap='winter',
    # colormap='gist_heat',
    # mask =mask
    ).generate(all_words)

plt.figure(figsize = (10, 9))
plt.imshow(wordcloud)
plt.axis('off')
plt.tight_layout(pad=0)
plt.show()

# neg - gist_heat, , total - plasma, pos- PuRd , neu - winter

```



ภาคผนวก ข
โค้ดสำหรับการวิเคราะห์อารมณ์จากข้อความด้วย
การเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก

จุฬาลงกรณ์มหาวิทยาลัย
CHULALONGKORN UNIVERSITY

Wisesight Sentiment Analysis Dataset

```
!wget https://github.com/PyThaiNLP/wisesight-
sentiment/archive/master.zip; unzip master.zip

!mv wisesight-sentiment-master/kaggle-competition/* .

!pip install tensorflow_text

!pip install
https://github.com/PyThaiNLP/pythainlp/archive/dev.zip

!pip install emoji

!ls
```

```
import locale

def getpreferredencoding(do_setlocale = True):
    return "UTF-8"

locale.getpreferredencoding = getpreferredencoding

import pandas as pd
import numpy as np
from pythainlp import word_tokenize
from tqdm import tqdm_notebook
import re
import emoji

#viz

from plotnine import *

import matplotlib.pyplot as plt
import seaborn as sns
```

Text Processor for Logistic Regression

```
def replace_url(text):

    URL_PATTERN = r"((?:https?:({1,3}|[a-z0-9%])|[a-
z0-9.\-
]+[.]?(?:com|net|org|edu|gov|mil|aero|asia|biz|cat|coop|info|int|j
obs|mobi|museum|name|post|pro|tel|travel|xxx|ac|ad|ae|af|ag|ai|al
|am|an|ao|aq|ar|as|at|au|aw|ax|az|ba|bb|bd|be|bf|bg|bh|bi|bj|bm|b
```

```

n|bo|br|bs|bt|bv|bw|by|bz|ca|cc|cd|cf|cg|ch|ci|ck|cl|cm|cn|co|cr|
cs|cu|cv|cx|cy|cz|dd|de|dj|dk|dm|do|dz|ec|ee|eg|eh|er|es|et|eu|fi
|fj|fk|fm|fo|fr|ga|gb|gd|ge|gf|gg|gh|gi|gl|gm|gn|gp|gq|gr|gs|gt|g
u|gw|gy|hk|hm|hn|hr|ht|hu|id|ie|il|im|in|io|iql|ir|is|it|je|jm|jo
|jp|ke|kg|kh|ki|km|kn|kp|kr|kw|ky|kz|la|lb|lc|li|lk|lr|ls|lt|lu|lv
|ly|ma|mc|md|me|mg|mh|mk|ml|mm|mn|mo|mp|mq|mr|ms|mt|mu|mv|mw|mx|m
y|mz|na|nc|ne|nf|ng|ni|nl|no|np|nr|nu|nz|om|pa|pe|pf|pg|ph|pk|pl|
pm|pn|pr|ps|pt|pw|py|qa|re|ro|rs|ru|rw|sa|sb|sc|sd|se|sg|sh|si|sj
|Ja|sk|sl|sm|sn|so|sr|ss|st|su|sv|sx|sy|sz|tc|td|tf|tg|th|tj|tk|t
l|tm|tn|to|tp|tr|tt|tv|tw|tz|ua|ug|uk|us|uy|uz|va|vc|ve|vg|vi|vn|
vu|wf|ws|ye|yt|yu|za|zm|zw)/) (?:[^\s()<>{}\\[\]]+|\([^\s()]*?\([^\s
s()+\)[^\s()]*?\)|\([^\s()+?\\)\)+(?:\[^\s()]*?\([^\s()+\)[^\s()
]*?)\)|\([^\s()+?\\)\)|[^\s`!()\[\]{};:'".,<>?«»"'"`'')|(?:(?<!@)[a-z0-
9]+(?:[.\-][a-z0-
9]+)*[.](?:com|net|org|edu|gov|mil|aero|asia|biz|cat|coop|info|in
t|jobs|mobi|museum|name|post|pro|tel|travel|xxx|ac|ad|ae|af|ag|ai
|al|am|an|ao|aq|ar|as|at|au|aw|ax|az|ba|bb|bd|be|bf|bg|bh|bi|bj|b
m|bn|bo|br|bs|bt|bv|bw|by|bz|ca|cc|cd|cf|cg|ch|ci|ck|cl|cm|cn|co|
cr|cs|cu|cv|cx|cy|cz|dd|de|dj|dk|dm|do|dz|ec|ee|eg|eh|er|es|et|eu
|fi|fj|fk|fm|fo|fr|ga|gb|gd|ge|gf|gg|gh|gi|gl|gm|gn|gp|gq|gr|gs|g
t|gu|gw|gy|hk|hm|hn|hr|ht|hu|id|ie|il|im|in|io|iql|ir|is|it|je|jm|
jo|jp|ke|kg|kh|ki|km|kn|kp|kr|kw|ky|kz|la|lb|lc|li|lk|lr|ls|lt|lu
|lv|ly|ma|mc|md|me|mg|mh|mk|ml|mm|mn|mo|mp|mq|mr|ms|mt|mu|mv|mw|m
x|my|mz|na|nc|ne|nf|ng|ni|nl|no|np|nr|nu|nz|om|pa|pe|pf|pg|ph|pk|
pl|pm|pn|pr|ps|pt|pw|py|qa|re|ro|rs|ru|rw|sa|sb|sc|sd|se|sg|sh|si
|sj|Ja|sk|sl|sm|sn|so|sr|ss|st|su|sv|sx|sy|sz|tc|td|tf|tg|th|tj|t
k|tl|tm|tn|to|tp|tr|tt|tv|tw|tz|ua|ug|uk|us|uy|uz|va|vc|ve|vg|vi|
vn|vu|wf|ws|ye|yt|yu|za|zm|zw)\b/(?(!@))"'"

```

```

return re.sub(URL_PATTERN, 'xxurl', text)

```

```

def replace_rep(text):
    def _replace_rep(m):
        c,cc = m.groups()
        return f'{c}xxrep'
    re_rep = re.compile(r'(\S)(\{2,})')
    return re_rep.sub(_replace_rep, text)

```

```

def ungroup_emoji(toks):
    res = []
    for tok in toks:
        if emoji.emoji_count(tok) == len(tok):
            for char in tok:

```

```

        res.append(char)
    else:
        res.append(tok)
return res

def process_text(text):
    #pre rules
    res = text.lower().strip()
    res = replace_url(res)
    res = replace_rep(res)

    #tokenize
    res = [word for word in word_tokenize(res) if word and not
re.search(pattern=r"\s+", string=word)]

    #post rules
    res = ungroup_emoji(res)
return res

```

Process Text Files to CSVs

```

with open('/content/train.txt') as f:
    texts = [line.strip() for line in f.readlines()]
f.close()

with open('/content/train_label.txt') as f:
    categories = [line.strip() for line in f.readlines()]
f.close()

all_df = pd.DataFrame({'category':categories, 'texts':texts})
all_df.to_csv('all_df.csv',index=False)
all_df.shape

```

```

all_df.head()

import pandas as pd

df_text = pd.read_csv('/content/data_total2.csv')

df_text = df_text.rename({'Unnamed: 0':'texts', 'Unnamed:
1':'old_cat','Me': 'category'}, axis=1)

df_text.info()

all_df.drop(all_df[all_df['category'] == 'q'].index, inplace =
True)

all_df.category.value_counts().plot.barh()
plt.show()
print(all_df.category.value_counts(), all_df.info())

total=pd.concat([all_df,df_text], ignore_index = True)
total.head()

total.category.value_counts().plot.barh()
plt.show()
print(total.category.value_counts())
total.to_csv('all_df.csv',index=True)

```

Load Data

```

all_df = pd.read_csv('/content/all_df.csv',encoding='utf-8')
all_df.category.value_counts().plot.barh()
plt.show()
all_df.info()

#prevalence
all_df.category.value_counts() / all_df.shape[0]

```

Train-validation Split

```

from sklearn.model_selection import train_test_split

train_df, valid_df = train_test_split(all_df, test_size=0.15,
random_state=1412)

train_df = train_df.reset_index(drop=True)
valid_df = valid_df.reset_index(drop=True)

#prevalence
print(train_df['category'].value_counts() / train_df.shape[0])

#prevalence
print(valid_df['category'].value_counts() / valid_df.shape[0])
Create Features
#dependent variables
y_train = train_df['category']
y_valid = valid_df['category']

#text faetures
from sklearn.feature_extraction.text import TfidfVectorizer
from sklearn.linear_model import LogisticRegression

#text faetures
tfidf = TfidfVectorizer(tokenizer=process_text,
ngram_range=(1,2), min_df=80, sublinear_tf=True)

tfidf_fit = tfidf.fit(all_df['texts'])

text_train = tfidf_fit.transform(train_df['texts'])
text_valid = tfidf_fit.transform(valid_df['texts'])
# text_test = tfidf_fit.transform(test_df['texts'])
text_train.shape, text_valid.shape

from sklearn.preprocessing import StandardScaler

```

```

scaler = StandardScaler()
scaler_fit = scaler.fit(all_df[['wc','uwc']].astype(float))
print(scaler_fit.mean_, scaler_fit.var_)

num_train =
scaler_fit.transform(train_df[['wc','uwc']].astype(float))

num_valid =
scaler_fit.transform(valid_df[['wc','uwc']].astype(float))

# num_test =
scaler_fit.transform(test_df[['wc','uwc']].astype(float))

num_train.shape, num_valid.shape

#concatenate text and word count features
X_train = np.concatenate([text_train.toarray()],axis=1)
X_valid = np.concatenate([text_valid.toarray()],axis=1)
X_train.shape, X_valid.shape
Xdf_train = pd.DataFrame(X_train)
Xdf_valid = pd.DataFrame(X_valid)

```

Reduce Dimension by PCA

```

import pandas as pd
import numpy as np
import matplotlib.pyplot as plt
import seaborn as sns

%matplotlib inline

%config InlineBackend.figure_format='retina'

from sklearn.decomposition import PCA
from sklearn.preprocessing import StandardScaler # z-score

import random
random.seed(123)

pca = PCA(n_components = 0.90)
pca.fit(Xdf_train)

```



```

pca.n_components_

# pd.DataFrame(pca.transform(Xdf_train)).info
X_train = pd.DataFrame(pca.transform(Xdf_train))
X_valid = pd.DataFrame(pca.transform(Xdf_valid))

X_train.head()
X_train.to_csv('X_train.csv',index=True)
X_valid.to_csv('X_valid.csv',index=True)

pca.explained_variance_
random.seed(123)
pca = PCA(n_components=681)
# pca = PCA(n_components=2)
pca.fit_transform(Xdf_train)
print(f'explained_variance (n_components={pca.n_components}) =
{pca.explained_variance_}') # Eigenvalues
print(f'explained_variance_ratio
(n_components={pca.n_components}) =
{pca.explained_variance_ratio_}')
print(f'sum explained_variance_ratio =
{np.sum(pca.explained_variance_ratio_)}')

def scree_plot(X, n_components, with_cumulative=False,
show_data_label=False, figsize=(10, 7)):
    '''
    PCA scree plot with cumulative
    '''
    scaler = StandardScaler()
    X_t=scaler.fit_transform(X)

    max_components = min(X.shape)
    x=np.arange(1, n_components+1)
    pca = PCA(n_components=max_components)

```

```

pca.fit_transform(X_t)
y1=pca.explained_variance_ratio_[:n_components]
y2=np.cumsum(pca.explained_variance_ratio_)[:n_components]

plt.figure(figsize=figsize)

if n_components > 1000:
    marker = None
else:
    marker = 'o'
if with_cumulative:
    plt.plot(x, y2, linestyle='--', marker=marker,
label='cumulative', color='salmon')

    plt.plot(x, y1, linestyle='-', marker=marker,
label='individual', color='deepskyblue')
    plt.title('explained variance ratio')
    plt.xlabel('# of components')
    plt.ylabel('proportion of variance explained')
    plt.legend()
    if with_cumulative:
        [plt.axhline(y=x1, color='.7', linestyle='--') for x1 in
[.8, .9, .95, 1]]
    plt.grid(axis='x')

if show_data_label:
    for n, v, cv in zip(np.nditer(x, flags=['refs_ok']),
                        np.nditer(y1, flags=['refs_ok']),
                        np.nditer(y2, flags=['refs_ok'])):
        # plt.text(n+.02, v+.02, f'{v*100:.2f}%',
fontsize=10)

    if with_cumulative:
        pass

```

```

# plt.text(n+.02, cv+.02, f'{cv*100:.2f}%',
fontsize=10)
random.seed(123)
screed_plot(Xdf_train, 681, False, False)

# imbalance dataset
from pandas import read_csv
from imblearn.over_sampling import SMOTE
from collections import Counter
from matplotlib import pyplot
from sklearn.preprocessing import LabelEncoder
from imblearn.over_sampling import ADASYN

# label encode the target variable
y = LabelEncoder().fit_transform(y_train)
# transform the dataset
# summarize distribution
counter = Counter(y)
for k,v in counter.items():
    per = v / len(y) * 100
    print('Class=%d, n=%d (%.3f%%)' % (k, v, per))
# plot the distribution
pyplot.bar(counter.keys(), counter.values())
pyplot.show()

X_train_res, y_train_res = SMOTE().fit_resample(X_train, y_train)

counter = Counter(y_train_res)
for k,v in counter.items():
    per = v / len(y) * 100
    print((k, v, per))
# plot the distribution

```

```

pyplot.bar(counter.keys(), counter.values())
pyplot.show()

```

```

y_train_res = pd.DataFrame(y_train_res)
X_train_res =pd.DataFrame(X_train_res)

```

Fit Model

```

# evaluate multinomial logistic regression model
from numpy import mean
from numpy import std
from sklearn.datasets import make_classification
from sklearn.model_selection import cross_val_score
from sklearn.model_selection import RepeatedStratifiedKFold
from sklearn.linear_model import LogisticRegression

# base
#fit logistic regression models
model = LogisticRegression(multi_class='multinomial',
solver='lbfgs')
cv = RepeatedStratifiedKFold(n_splits=10, n_repeats=3,
random_state=1)
n_scores = cross_val_score(model, X_valid, y_valid,
scoring='accuracy', cv=cv, n_jobs=-1)
model.fit(X_train,y_train)
model.score(X_valid,y_valid)
print('Mean Accuracy: %.3f (%.3f)' % (mean(n_scores),
std(n_scores)))

# pca model+ imbalance
#fit logistic regression models
model = LogisticRegression(multi_class='multinomial',
solver='lbfgs')
cv = RepeatedStratifiedKFold(n_splits=10, n_repeats=3,
random_state=1)

```

```

n_scores = cross_val_score(model, X_valid, y_valid,
scoring='accuracy', cv=cv, n_jobs=-1)

model.fit(X_train_res,y_train_res)

model.score(X_valid,y_valid)

print('Mean Accuracy: %.3f (%.3f)' % (mean(n_scores),
std(n_scores)))

```

GridSearchCV

```
# 1 SVM
```

```

model_params = {
    'svm': {
        'model': svm.SVC(gamma='auto'),
        'params' : {
            'C': [1000],
            # 'C': [2000,3000],
            # 'kernel': ['rbf']
            # 'C': [0.6,0.7,0.8,0.9,1]
            'kernel': ['rbf']
        }
    }
}

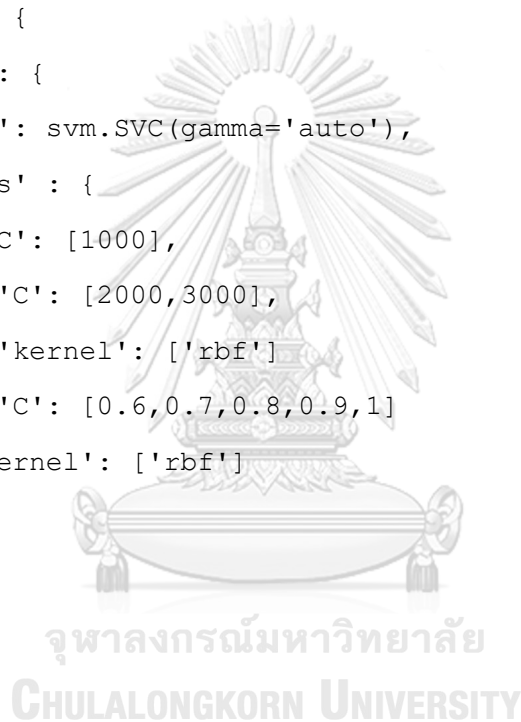
```

```
# 2 RF
```

```

model_params = {
    'random_forest': {
        'model': RandomForestClassifier(),
        'params' : {
            'n_estimators': [500],
            # 'n_estimators': [500],
            'max_features': ['auto', 'sqrt', 'log2'],
            'max_depth' : [8],
            # 'max_depth' : [4,5,6,7,8],
            'criterion' :['gini', 'entropy']
        }
    }
}

```



```

    }
    }}

# 3 logistic Reg
model_params = {
    'logistic_regression' : {
        'model': LogisticRegression(multi_class='auto'),
        'params' : {
            'C': [0.001, 0.1, 1, 10, 100],
            'penalty': ['l1', 'l2'],
            'solver': ['lbfgs', 'liblinear']
        }
    }
}

# 4 NB
model_params = {
    'naive_bayes_multinomial': {
        'model': MultinomialNB(),
        'params': {
            'alpha' : [0.1, 0.01, 0.001, 0.0001]
        }
    }
}

random.seed(123)

scores = []

for model_name, mp in model_params.items():
    clf = GridSearchCV(mp['model'], mp['params'], cv=5,
return_train_score=False)
    # clf.fit(X_train_res,y_train_res)
    clf.fit(X_train_res2,y_train_res)
    clf.score(X_valid2,y_valid)
    scores.append({
        'model': model_name,

```

```
        'best_score': clf.best_score_,
        'best_params': clf.best_params_
    })

df =
pd.DataFrame(scores, columns=['model', 'best_score', 'best_params'])

df

# SVC

random.seed(123)

parameters = {'kernel': ['rbf'], 'C': [1000]}

model = GridSearchCV(estimator=SVC(gamma = 'auto'),
param_grid=parameters, cv= 5, return_train_score=False)

model.fit(X_train_res2, y_train_res)

model.score(X_valid2, y_valid)

# RF

random.seed(123)

parameters = {'n_estimators': [2000], 'max_features': ['sqrt'],
'max_depth' : [8], 'criterion' :['gini']}

model = GridSearchCV(estimator=RandomForestClassifier(),
param_grid=parameters, cv= 5, return_train_score=False)

model.fit(X_train_res2, y_train_res)

model.score(X_valid2, y_valid)

# NB

random.seed(123)

parameters = {'alpha' : [0.1,1,10]}

model = GridSearchCV(estimator=MultinomialNB(),
param_grid=parameters, cv= 5, return_train_score=False)

model.fit(X_train_res2, y_train_res)

model.score(X_valid2, y_valid)
```

```

# LR

random.seed(123)

parameters = {'C': [10], 'penalty': ['l2'], 'solver' :
['liblinear']}

model =
GridSearchCV(estimator=LogisticRegression(multi_class='auto'),
param_grid=parameters, cv= 5, return_train_score=False)

model.fit(X_train_res2, y_train_res)

model.score(X_valid2, y_valid)

```

การตรวจสอบประสิทธิภาพของโมเดล

```

from sklearn.metrics import accuracy_score, precision_score,
recall_score, f1_score, confusion_matrix

from sklearn.model_selection import cross_val_score

from sklearn.metrics import classification_report

pred = model.predict(X_valid2)
print(confusion_matrix(pred,y_valid))

print(classification_report(pred,y_valid))

from sklearn.metrics import confusion_matrix,
ConfusionMatrixDisplay

cm = confusion_matrix(y_valid, pred)

disp = ConfusionMatrixDisplay(confusion_matrix = cm)

disp.plot()

```

Deep Learning

Multilingual Universal Sentence Encoder

```

import tensorflow_hub as hub

import tensorflow_text

import tensorflow as tf #tensorflow 2.1.0

```



```

enc = hub.load('https://tfhub.dev/google/universal-sentence-
encoder-multilingual/3')

valid_df2 = pd.DataFrame(valid_df['texts'])
train_df2 = pd.DataFrame(train_df['texts'])

X_trains = []
X_tests = []
bs = 10

for i in tqdm_notebook(range(y_valid.shape[0]//bs+1)):
X_tests.append(enc(valid_df2.texts[(i*bs):((i+1)*bs)]).numpy())

for i in tqdm_notebook(range(y_train.shape[0]//bs+1)):
X_trains.append(enc(train_df2.texts[(i*bs):((i+1)*bs)]).numpy())

X_test = np.concatenate(X_tests,0)
X_train = np.concatenate(X_trains,0)
X_train.shape, X_test.shape

from sklearn import svm
from sklearn.ensemble import RandomForestClassifier
from sklearn.linear_model import LogisticRegression
from sklearn.naive_bayes import GaussianNB
from sklearn.naive_bayes import MultinomialNB
from sklearn.tree import DecisionTreeClassifier
from sklearn.model_selection import GridSearchCV
import pandas as pd
import random

from sklearn.preprocessing import MinMaxScaler #fixed import

```

```

scaler = MinMaxScaler()
X_train2 = scaler.fit_transform(X_train)
X_test2 = scaler.transform(X_test)

```

การ tuning hyperparameters ด้วย GridSearchCV และการตรวจสอบประสิทธิภาพของโมเดลทำคล้ายกับการเรียนรู้ของเครื่อง

RNN LSTM

```

import tensorflow as tf

def process_text_rnn(text):
    #pre rules
    res = text.lower().strip()
    res = replace_url(res)
    res = replace_rep(res)

    #tokenize
    res = [word for word in word_tokenize(res) if word and not
re.search(pattern=r"\s+", string=word)]

    #post rules
    res = ungroup_emoji(res)

    return ' '.join(res)

BUFFER_SIZE = 10000
BATCH_SIZE = 64

text_train = [' '.join(x.split('|')) for x in
train_df['processed'].values.tolist()]
text_valid = [' '.join(x.split('|')) for x in
valid_df['processed'].values.tolist()]

word_count = []

```

```
for sent in text_train:
    for w in sent.split():
        word_count.append(w)

VOCAB_SIZE = len(set(word_count))

encoder =
tf.keras.layers.TextVectorization(max_tokens=VOCAB_SIZE)
encoder.adapt(text_train)

vocab = np.array(encoder.get_vocabulary())
vocab[:20]
y_train = train_df['category']
y_valid = valid_df['category']
y_class = ['neg', 'neu', 'pos']

from sklearn import preprocessing
from tensorflow.keras.utils import to_categorical

le = preprocessing.LabelEncoder()
le.fit(y_class)
y_train = le.transform(y_train)
y_val = le.transform(y_valid)
y_train = to_categorical(y_train)
y_val = to_categorical(y_val)
print(y_train.shape)

model = tf.keras.Sequential([
    encoder,
    tf.keras.layers.Embedding(
        input_dim=len(encoder.get_vocabulary()),
        output_dim=512,
        # Use masking to handle the variable sequence lengths
```

```

        mask_zero=True),
    tf.keras.layers.Bidirectional(tf.keras.layers.LSTM(256)),
    tf.keras.layers.Dense(128, activation='relu'),
    tf.keras.layers.Dense(y_train.shape[1], activation='softmax')
])

```

```

model.compile(loss='categorical_crossentropy',
              optimizer=tf.keras.optimizers.Adam(1e-4),
              metrics=['accuracy'])

```

```

lstm = model.fit(np.array(text_train), y_train,
                validation_data=(np.array(text_valid), y_val), epochs=10,
                verbose=2)

```

```

value = model.predict(np.array(text_valid))
y_val_pred = np.argmax(value,axis=1)
y_val_true = np.argmax(y_val,axis=1)
print(classification_report(y_val_true, y_val_pred))

```

BERT

```
!pip install transformers
```

```
!pip install datasets
```

```
!pip install --upgrade --force-reinstall --no-deps transformers
```

```
!pip install --upgrade --force-reinstall --no-deps datasets
```

```
!pip install --upgrade --force-reinstall --no-deps
huggingface_hub
```

```
!pip install --upgrade --force-reinstall --no-deps pyarrow
```

```
from datasets import load_dataset, DatasetDict
```

```
from transformers import
AutoTokenizer,TFAutoModelForSequenceClassification

import tensorflow as tf

import numpy as np

import matplotlib.pyplot as plt

import pandas as pd

DATA_PATH = "/content/all_df.csv"

pandas_df = pd.read_csv(DATA_PATH)
pandas_df.head()

pandas_df['texts_clean'] = pandas_df.texts.map(lambda x:
''.join(process_text(x)))
pandas_df.head()

df = pandas_df['category']
df = pd.DataFrame(df)

from sklearn.preprocessing import LabelEncoder

def label_encoder(dataframe, column):
    le = LabelEncoder()
    return le.fit_transform(dataframe[column]).astype(float)

for column in df:
    df[column] = label_encoder(df, column)

for i in df:
    df[i] = label_encoder(df,i).astype(float)

pandas_df['category'] = df['category']
```

```
from datasets import Dataset

ds = Dataset.from_pandas(pandas_df)

ds

train_test_valid = ds.train_test_split()

test_valid = train_test_valid['test'].train_test_split()

train_test_valid_dataset = DatasetDict({
    'train': train_test_valid['train'],
    'test': test_valid['test'],
    'valid': test_valid['train']
})

dataset = train_test_valid_dataset.remove_columns(['old_cat',
'Chat', 'Two', 'Unnamed: 0'])

dataset

tokenizer = AutoTokenizer.from_pretrained("bert-base-
multilingual-cased")
text = "Just checking tokenization"

output = tokenizer(text)

tokens = tokenizer.convert_ids_to_tokens(output['input_ids'])

print(f"Vocab size is : {tokenizer.vocab_size}")

print(f"Model max length is : {tokenizer.model_max_length}")

print(f"Model input names are: {tokenizer.model_input_names}")
```

```

def tokenize_function(train_dataset):
    return tokenizer(train_dataset['texts_clean'],
padding='max_length', truncation=True)

tokenized_dataset = dataset.map(tokenize_function, batched=True)

tokenized_dataset

train_dataset = tokenized_dataset['train']
eval_dataset = tokenized_dataset['valid']
test_dataset = tokenized_dataset['test']

train_set = train_dataset.remove_columns(['texts',
"texts_clean"]).with_format('tensorflow')

tf_eval_dataset = eval_dataset.remove_columns(['texts',
"texts_clean"]).with_format('tensorflow')

tf_test_dataset = test_dataset.remove_columns(['texts',
"texts_clean"]).with_format('tensorflow')

train_features = { x: train_set[x] for x in
tokenizer.model_input_names }

train_set_for_final_model =
tf.data.Dataset.from_tensor_slices((train_features,
train_set['category'] ))

train_set_for_final_model =
train_set_for_final_model.shuffle(len(train_set)).batch(8)

eval_features = {x: tf_eval_dataset[x] for x in
tokenizer.model_input_names}

val_set_for_final_model =
tf.data.Dataset.from_tensor_slices((eval_features,
tf_eval_dataset["category"]))

```

```

val_set_for_final_model = val_set_for_final_model.batch(8)

test_features = {x: tf_test_dataset[x] for x in
tokenizer.model_input_names}

test_set_for_final_model =
tf.data.Dataset.from_tensor_slices((test_features,
tf_test_dataset["category"]))

test_set_for_final_model =test_set_for_final_model.batch(8)

model =
TFAutoModelForSequenceClassification.from_pretrained("bert-base-
multilingual-cased", num_labels=3)

# model =
TFAutoModelForSequenceClassification.from_pretrained("/mnt/e0ccdb
db-22c3-4d9b-9413-fd976a2e99ae/M1/Code_Org/HF_Models/bert-base-
uncased", num_labels=3)

model.compile(
    optimizer=tf.keras.optimizers.Adam(learning_rate=5e-5),

    loss=tf.keras.losses.SparseCategoricalCrossentropy(from_logits=True),
    metrics=tf.metrics.SparseCategoricalAccuracy(),
)

random.seed(123)

history = model.fit(train_set_for_final_model,
validation_data=val_set_for_final_model, epochs=10)

from matplotlib import pyplot as plt
plt.plot(history.history['sparse_categorical_accuracy'])
plt.plot(history.history['val_sparse_categorical_accuracy'])
plt.title('model sparse categorical accuracy')
plt.ylabel('accuracy')
plt.xlabel('epoch')
plt.legend(['train', 'val'], loc='upper left')

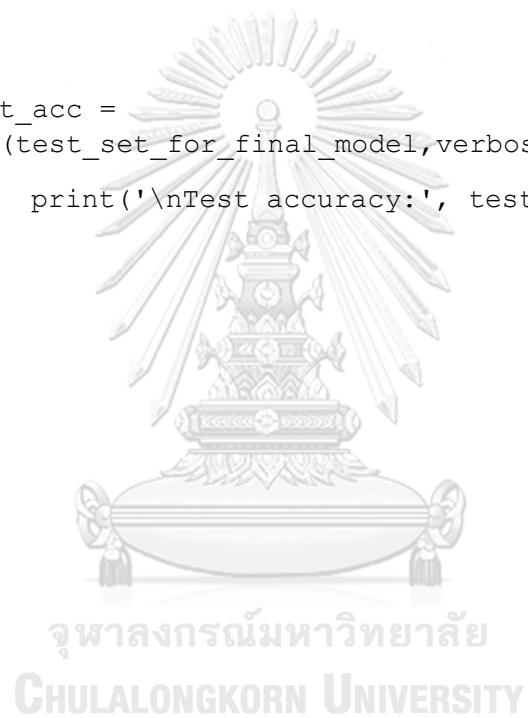
```



```
plt.show()

plt.plot(history.history['loss'])
plt.plot(history.history['val_loss'])
plt.title('model loss')
plt.ylabel('loss')
plt.xlabel('epoch')
plt.legend(['train', 'val'], loc='upper left')
plt.show()

test_loss, test_acc =
model.evaluate(test_set_for_final_model, verbose=2)
print('\nTest accuracy:', test_acc)
```



ประวัติผู้เขียน

ชื่อ-สกุล	จิระเมศร์ รุจิกรหิรัญย์
วัน เดือน ปี เกิด	21 พฤศจิกายน 2539
สถานที่เกิด	กรุงเทพมหานคร
วุฒิการศึกษา	- ปีการศึกษา 2562 ครุศาสตรบัณฑิต (เกียรตินิยมอันดับหนึ่ง) วิชาเอก คณิตศาสตร์ สาขามัธยมศึกษา (วิทยาศาสตร์) ภาควิชาหลักสูตรและการ สอน คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย - ปัจจุบัน กำลังศึกษาหลักสูตรมหาบัณฑิต สาขาวิชาวิธีวิทยาการพัฒน นวัตกรรมทางการศึกษา ภาควิชาวิจัยและจิตวิทยาการศึกษา คณะครุศาสตร์ จุฬาลงกรณ์มหาวิทยาลัย
ที่อยู่ปัจจุบัน	29 ถนนอ่อนนุช เขตวัฒนา แขวงพระโขนงเหนือ กทม. 10240
รางวัลที่ได้รับ	รางวัลการนำเสนอผลงานวิจัยยอดเยี่ยมในงานประชุมสัมมนาวิชาการ การ วัด การประเมินผล และวิจัยสัมพันธ์แห่งประเทศไทย ครั้งที่ 30 หัวข้อ "การ พัฒนาโมเดลการวิเคราะห์อารมณ์ครูในชั้นเรียนผ่านการรู้จำคำพูดโดยใช้การ เรียนรู้ของเครื่อง"