




การตรวจจับภาวะซึมเศร้าจากข้อความบนสื่อสังคมออนไลน์ด้วยวิธีการเรียนรู้เชิงลึก
TEXT-BASED DEPRESSION DETECTION ON SOCIAL MEDIA USING DEEP LEARNING



จตุรวิทย์ อัจหาญ

บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ

2566

การตรวจจับภาวะซึมเศร้าจากข้อความบนสื่อสังคมออนไลน์ด้วยวิธีการเรียนรู้เชิงลึก



สารนิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตร
วิทยาศาสตร์มหาบัณฑิต สาขาวิชาวิทยาการข้อมูล
คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒ
ปีการศึกษา 2566
ลิขสิทธิ์ของมหาวิทยาลัยศรีนครินทรวิโรฒ

TEXT-BASED DEPRESSION DETECTION ON SOCIAL MEDIA USING DEEP LEARNING



JATURAWIT ARDHARN

A Master's Project Submitted in Partial Fulfillment of the Requirements

for the Degree of MASTER OF SCIENCE

(Data Science)

Faculty of Science, Srinakharinwirot University

2023

Copyright of Srinakharinwirot University

สารนิพนธ์

เรื่อง

การตรวจจับภาวะซีมีเศร้าจากข้อความบนสื่อสังคมออนไลน์ด้วยวิธีการเรียนรู้เชิงลึก

ของ

จตุรวิทย์ อัจหาญ

ได้รับอนุมัติจากบัณฑิตวิทยาลัยให้นับเป็นส่วนหนึ่งของการศึกษาตามหลักสูตร

ปริญญาวิทยาศาสตรมหาบัณฑิต สาขาวิชาวิทยาการข้อมูล

ของมหาวิทยาลัยศรีนครินทรวิโรฒ

(รองศาสตราจารย์ นายแพทย์ฉัตรชัย เอกปัญญาสกุล)

คณบดีบัณฑิตวิทยาลัย

คณะกรรมการสอบปากเปล่าสารนิพนธ์

ที่ปรึกษาหลัก

ประธาน

(ผู้ช่วยศาสตราจารย์ ดร.วิรุฑธ เจริญเรืองกิจ)

(อาจารย์ ดร.ธรรมศักดิ์ เขียวนิเวศน์)

กรรมการ

(อาจารย์ ดร.โสภณ มงคลลักษณ์)

ชื่อเรื่อง	การตรวจจับภาวะซึมเศร้าจากข้อความบนสื่อสังคมออนไลน์ด้วยวิธีการเรียนรู้เชิงลึก
ผู้วิจัย	จตุรวิทย์ อาจหาญ
ปริญญา	วิทยาศาสตร์มหาบัณฑิต
ปีการศึกษา	2566
อาจารย์ที่ปรึกษา	ผู้ช่วยศาสตราจารย์ ดร. วีรยุทธ เจริญเรืองกิจ

สื่อสังคมออนไลน์ได้กลายเป็นแพลตฟอร์มที่มีอิทธิพลต่อการแสดงออกทางอารมณ์เพิ่มมากขึ้นในปัจจุบัน โดยเฉพาะอย่างยิ่งในช่วงการแพร่ระบาดของโควิด-19 ที่มีจำกัดการไปมาหาสู่กันและกระตุ้นทำให้มีการใช้งานอินเทอร์เน็ตเพิ่มมากขึ้น ในขณะเดียวกัน โรคซึมเศร้าเป็นปัญหาด้านสุขภาพจิตที่มีเพิ่มมากขึ้นและสื่อสังคมออนไลน์สามารถเป็นสิ่งเร้าที่นำไปสู่ความคิดฆ่าตัวตายได้ นอกจากนี้ ผู้ที่มีภาวะซึมเศร้านักจะใช้สื่อสังคมออนไลน์ในการแสดงออกทางอารมณ์ของตนเอง หากสามารถตรวจจับภาวะซึมเศร้าได้จากข้อความบนสื่อสังคมออนไลน์เหล่านี้ได้ อาจช่วยให้เข้าใจสภาวะทางอารมณ์ของผู้ที่มีภาวะซึมเศร้าได้อย่างลึกซึ้ง ซึ่งจะนำไปสู่การให้การช่วยเหลือที่เหมาะสม งานวิจัยนี้จึงมีวัตถุประสงค์เพื่อพัฒนาวิธีการตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์โดยการใช้อัลกอริทึมโครงข่ายประสาทเทียม 3 วิธีการ ดังนี้ 1. Bidirectional long short-term memory (BiLSTM) 2. Thai Bidirectional Encoder Representations from Transformers (Thai-BERT) 3. WangchanBERTa กับเทคนิคการประมวลผลภาษาธรรมชาติ ผู้วิจัยประเมินประสิทธิภาพของอัลกอริทึมเหล่านี้โดยการใช้ชุดข้อมูลทวิตเตอร์ที่เป็นข้อความภาษาไทยจำนวน 3,100 ข้อความ และระบุประเภทโดยนักจิตวิทยา ซึ่งอัลกอริทึม WangchanBERTa ที่ใช้เทคนิคการตัดคำด้วย Newmm ให้ประสิทธิภาพที่ดีที่สุดให้ค่า F1-score เท่ากับ 74.2% Recall เท่ากับ 74.2% Precision เท่ากับ 74.7% และ Accuracy เท่ากับ 74.2% จากผลลัพธ์พบว่าอัลกอริทึมโครงข่ายประสาทเทียมมีประสิทธิภาพในการตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์ได้และการเลือกเทคนิคการตัดคำสามารถส่งผลกระทบต่อประสิทธิภาพของอัลกอริทึม นอกจากนี้ ผู้วิจัยได้มีการวิเคราะห์ชุดข้อมูลและข้อจำกัดที่อาจส่งผลกระทบต่อประสิทธิภาพของโมเดล

คำสำคัญ : ภาวะซึมเศร้า, สื่อสังคมออนไลน์, การประมวลผลภาษาธรรมชาติ, การจำแนกข้อความ, การเรียนรู้เชิงลึก

Title	TEXT-BASED DEPRESSION DETECTION ON SOCIAL MEDIA USING DEEP LEARNING
Author	JATURAWIT ARDHARN
Degree	MASTER OF SCIENCE
Academic Year	2023
Thesis Advisor	Assistant Professor Dr. Werayuth Charoenruengkit

Social media has become an increasingly influential platform for emotional expression, particularly during the COVID-19 pandemic, which has restricted physical mobility and fueled a surge in internet usage. However, depression is a growing mental health concern, and social media can be a breeding ground for suicidal ideation. Furthermore, Individuals experiencing depression frequently communicate their emotional state through social media posts. The potential to detect depression markers within these messages could offer valuable insights into their emotional well-being, paving the way for the provision of appropriate support. This study aimed to develop a method for depression detection in Thai social media text using three neural network algorithms: BiLSTM, Thai-BERT, and WangchanBERTa with three Thai word tokenizer techniques: Newmm, Attacut, and BPE. The performance of these algorithms were evaluated using a dataset of 3,100 Thai text messages which were scraped from Twitter and labeled by psychologists. WangchanBERTa with the Newmm tokenizer achieved the best performance, with an F1-score of 74.2%, Recall of 74.2%, Precision of 74.7%, and Accuracy of 74.2%. These results suggest that neural network algorithms can be effectively used to detect depression in Thai social media text, and that the choice of tokenizer can significantly impact performance.

Keyword : Depression, Social media, Natural language processing, Text classification, Deep learning

กิตติกรรมประกาศ

สารนิพนธ์นี้สำเร็จลุล่วงได้ด้วยความสะดวกตากรุณาช่วยเหลือ และความเอาใจใส่อย่างดียิ่งตลอดจนการให้คำแนะนำ และข้อคิดเห็นที่เป็นประโยชน์อย่างยิ่งสำหรับการปรับปรุงข้อบกพร่องจากคณะกรรมการผู้ควบคุมสารนิพนธ์ ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างยิ่ง

ขอกราบขอบพระคุณ บัณฑิตวิทยาลัย มหาวิทยาลัยศรีนครินทรวิโรฒ สำหรับทุนสนับสนุนการเข้าร่วมประชุมและการนำเสนอผลงานของนิสิตบัณฑิตศึกษา ทำให้มีโอกาสเผยแพร่การนำเสนอผลงานวิจัยและได้เข้าร่วมฟังผลงานของนักวิจัยในสาขาที่ศึกษา

ขอกราบขอบพระคุณ ผู้ช่วยศาสตราจารย์ ดร.วีรยุทธ เจริญเรืองกิจ ที่ได้ให้ความเมตตากรุณาเป็นที่ปรึกษาและให้ความช่วยเหลือชี้แนะแนวทางในสิ่งที่เป็นประโยชน์ต่อการศึกษาและการทำสารนิพนธ์นี้ด้วยความเอาใจใส่ตลอดมา ผู้วิจัยขอกราบขอบพระคุณเป็นอย่างสูงไว้ ณ โอกาสนี้

ขอกราบขอบพระคุณ ดร.ธรรมศักดิ์ เขียวนิเวศน์ และดร.โสภณ มงคลลักษณ์ ที่ได้กรุณาเป็นคณะกรรมการสอบฉบับนี้ และให้ข้อเสนอแนะในการปรับปรุงแก้ไขข้อบกพร่องในสารนิพนธ์ฉบับนี้จนเสร็จสมบูรณ์

ขอกราบขอบพระคุณอาจารย์และกรรมการบริหารหลักสูตรสาขาวิชาวิทยาการข้อมูล คณะวิทยาศาสตร์ มหาวิทยาลัยศรีนครินทรวิโรฒทุกท่าน ที่ได้กรุณาประสิทธิ์ประสาทความรู้ต่าง ๆ ให้แก่ผู้วิจัย ตลอดจนให้ความช่วยเหลือในการทำวิจัยครั้งนี้

ขอขอบคุณ คุณสุวโรจน์ มหาศิริอัครยศ รองศาสตราจารย์ ดร.ทวีติย์ เสนีวงศ์ ณ อยุธยา และผู้ช่วยศาสตราจารย์ ดร.ณัฐสุดา เต้พันธ์ สำหรับข้อมูลตัวอย่างที่ใช้ในงานวิจัยครั้งนี้

ขอขอบคุณพี่ ๆ และเพื่อน ๆ สาขาวิชาวิทยาการข้อมูล รวมถึงบุคคลอีกหลายท่านที่ไม่ได้กล่าวนามไว้ ณ ที่นี้ที่ได้ให้ความช่วยเหลือและเป็นกำลังใจให้กับผู้วิจัยมาโดยตลอด

สุดท้ายนี้ ผู้วิจัยขอโน้มรำลึกคุณของบิดามารดาและครูอาจารย์ ที่อบรมสั่งสอนให้ความรู้ เป็นกำลังใจให้การสนับสนุนผู้วิจัยด้วยดีตลอดมา

จตุรวิทย์ อาจหาญ

สารบัญ

	หน้า
บทคัดย่อภาษาไทย	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ	ช
สารบัญตาราง.....	ญ
สารบัญรูปภาพ	ฎ
บทที่ 1.....	1
บทนำ.....	1
ภูมิหลัง.....	1
ความมุ่งหมายของงานวิจัย	3
ขอบเขตของการวิจัย.....	3
กรอบแนวคิดในการวิจัย.....	4
ประโยชน์ที่คาดว่าจะได้รับจากการวิจัย	5
นิยามศัพท์เฉพาะ	5
บทที่ 2.....	8
ทบทวนวรรณกรรม	8
1. หลักการทฤษฎีที่เกี่ยวข้อง	8
1.1 ความรู้เกี่ยวกับโรคซึมเศร้า (Depressive Disorder).....	8
1.2 การประมวลผลภาษาธรรมชาติ (Natural Language Processing)	10
1.3 การจำแนกประเภทข้อความ (Text Classification)	11
1.4 การเรียนรู้ของเครื่อง (Machine Learning) สำหรับการจำแนกประเภทข้อความ.....	13

1.5 การเรียนรู้เชิงลึก (Deep Learning) สำหรับการจำแนกประเภทข้อความ	14
1.6 การจัดการกับข้อมูลที่ไม่สมดุล (Imbalanced Data)	17
1.7 การตัดคำ (Word Tokenization) สำหรับภาษาไทย.....	20
1.8 การสร้างคุณลักษณะของข้อมูล (Feature Extraction)	21
1.9 การวัดประสิทธิภาพของแบบจำลอง (Model Evaluation)	21
2. งานวิจัยที่เกี่ยวข้อง.....	24
บทที่ 3.....	32
วิธีการดำเนินการวิจัย	32
3.1 กระบวนการทำงานของแบบจำลอง (Workflow Process of Model)	32
3.2 การเก็บข้อมูล (Data Acquisition).....	33
3.3 การระบุประเภทข้อมูล (Data Labeling).....	34
3.4 การทำความสะอาดข้อมูล (Data Cleansing)	35
3.5 การเตรียมข้อมูล (Data Preprocessing).....	35
3.6 การสำรวจข้อมูลเบื้องต้น (Exploratory Data Analysis)	36
3.7 สร้างคุณลักษณะของข้อมูลข้อความ (Feature Engineering)	41
3.8 การแบ่งข้อมูลสำหรับชุดฝึกฝนและชุดทดสอบ	42
3.9 การสร้างแบบจำลองการจำแนก (Classification Model).....	43
3.9.1 การสร้างแบบจำลองด้วยอัลกอริทึม BiLSTM	43
3.9.2 การสร้างแบบจำลองด้วยอัลกอริทึม Thai-BERT.....	44
3.9.3 การสร้างแบบจำลองด้วยอัลกอริทึม WangchanBERTa.....	46
3.10 การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)	47
บทที่ 4.....	49
ผลการดำเนินการวิจัย.....	49

บทที่ 5..... 54

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ..... 54


 5.1 สรุปผลการวิจัย 54

 5.2 อภิปรายผล..... 55

 5.3 ข้อเสนอแนะ 56

บรรณานุกรม 58

ประวัติผู้เขียน..... 63



สารบัญตาราง

	หน้า
ตาราง 1 แสดงชุดข้อมูลที่ใช้ในการวิจัย	4
ตาราง 2 แสดงจำนวนข้อมูลแบ่งตามชุดข้อมูล	29
ตาราง 3 ตารางคลังข้อมูลที่จัดประเภทตามอาการของภาวะซึมเศร้า	34
ตาราง 4 คลังข้อมูลที่แบ่งชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ	42
ตาราง 5 ตารางแสดงค่าพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองด้วยอัลกอริทึม BiLSTM	43
ตาราง 6 ตารางแสดงผลลัพธ์สรุปของอัลกอริทึม BiLSTM ที่ได้จากการใช้พารามิเตอร์ข้างต้น ...	44
ตาราง 7 ตารางแสดงค่าพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองด้วยอัลกอริทึม Thai-BERT	46
ตาราง 8 ตารางแสดงค่าพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองด้วยอัลกอริทึม WangchanBERTa	47
ตาราง 9 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลองด้วยการใช้ตัวตัดคำเริ่มต้น	49
ตาราง 10 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลองด้วยการใช้ตัวตัดคำที่แตกต่างกัน	50
ตาราง 11 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลอง WangchanBERTa โดยแบ่งตามอาการของภาวะซึมเศร้า	53
ตาราง 12 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลอง Thai-BERT โดยแบ่งตามอาการของภาวะซึมเศร้า	53

สารบัญรูปภาพ

	หน้า
ภาพประกอบ 1 แสดงการทำงานของหน่วย LSTM	14
ภาพประกอบ 2 แสดงการทำงานของ Bi-directional LSTM	15
ภาพประกอบ 3 แสดงการทำงานของ BERT	16
ภาพประกอบ 4 ตาราง Confusion Matrix ขนาด 2x2	22
ภาพประกอบ 5 แสดง Workflow กระบวนการสร้างแบบจำลอง	32
ภาพประกอบ 6 ตัวอย่างข้อมูลที่ใช้สร้างแบบจำลอง	34
ภาพประกอบ 7 ข้อความที่เป็นข้อมูลดิบเป็นภาษาวัยรุ่น	35
ภาพประกอบ 8 แสดงจำนวนข้อมูลแต่ละ Label	36
ภาพประกอบ 9 แสดงจำนวนของข้อมูลหลังการใช้เทคนิค SMOTE-Cosine.....	37
ภาพประกอบ 10 แสดงตัวอย่างข้อความหลังการใช้เทคนิค SMOTE-Cosine	37
ภาพประกอบ 11 สถิติแสดงจำนวนในการนับคำ	38
ภาพประกอบ 12 แสดงข้อความที่มีจำนวนคำที่ยาวที่สุดในชุดข้อมูล	38
ภาพประกอบ 13 แสดงความยาวของคำในแต่ละประเภทของอาการภาวะซึมเศร้า	38
ภาพประกอบ 14 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า แบบ Anhedonic.....	39
ภาพประกอบ 15 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า แบบ Other	40
ภาพประกอบ 16 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า แบบ Suicidal Ideation.....	40
ภาพประกอบ 17 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า แบบ Guilty Feelings	41

ภาพประกอบ 18 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า แบบ Sleep Problems..... 41


ภาพประกอบ 19 การแปลงคุณลักษณะของอาการของภาวะซึมเศร้า 42

ภาพประกอบ 20 แสดงตัวอย่างการสร้างคุณลักษณะโดยวิธี Word Embedding ใช้ thai2vec . 42

ภาพประกอบ 21 แสดง Confusion Matrix ระหว่างแบบจำลอง WangchanBERTa และ Thai-BERT โดยใช้เทคนิคการตัดคำ Newmm..... 51

ภาพประกอบ 22 แสดงกราฟ ROC Curve ของอัลกอริทึม WangchanBERTa โดยใช้เทคนิคการตัดคำ Newmm 51

ภาพประกอบ 23 แสดงกราฟ ROC Curve ของอัลกอริทึม Thai-BERT โดยใช้เทคนิคการตัดคำ Newmm..... 52



บทที่ 1

บทนำ

ภูมิหลัง

ปัจจุบันปฏิเสธไม่ได้ว่า สื่อสังคมออนไลน์ (Social Media) เข้ามามีบทบาทมากในสังคม และกลายเป็นส่วนหนึ่งของชีวิตประจำวัน ซึ่งมีอิทธิพลสำคัญอย่างมากต่อพฤติกรรมทางสังคมของมนุษย์ รวมไปถึงการเป็นเครื่องมือที่แสดงออกทางอารมณ์ ความคิดและความรู้สึกของมนุษย์ ในยุคนี้ ในช่วงสถานการณ์การแพร่ระบาดของโรคติดเชื้อไวรัส COVID-19 ที่ไม่สามารถเดินทางออกจากบ้านได้หรือการเดินทางออกจากบ้านมีความเสี่ยงต่อการติดโรค แต่มนุษย์ยังต้องการมีปฏิสัมพันธ์ระหว่างกัน ทำให้มีการใช้งานอินเทอร์เน็ตเพิ่มสูงมากขึ้น จากรายงานผลการสำรวจพฤติกรรมกรรมการอินเทอร์เน็ตของประชากรไทยประจำปี 2564 โดยสำนักงานพัฒนาธุรกรรมทางอิเล็กทรอนิกส์ กระทรวงดิจิทัลเพื่อเศรษฐกิจและสังคม พบว่า ระยะเวลาที่คนไทยใช้อินเทอร์เน็ตโดยเฉลี่ยต่อวันอยู่ที่ 10 ชั่วโมง 36 นาที นอกจากนี้จำนวนชั่วโมงการใช้งานและพฤติกรรมการใช้งาน มีพฤติกรรมใหม่ ๆ ที่เกิดขึ้น ทั้งรูปแบบการซื้อของออนไลน์ หรือการชำระเงินออนไลน์ (สำนักงานพัฒนาธุรกรรมทางอิเล็กทรอนิกส์ กระทรวงดิจิทัลเพื่อเศรษฐกิจและสังคม, 2021)

ในช่วงหลายปีที่ผ่านมา “โรคซึมเศร้า” เป็นหนึ่งในโรคทางจิตเวชที่เป็นที่กล่าวถึงกันมาก ในปีค.ศ.2021 จากรายงานขององค์การอนามัยโลก (World Health Organization, 2021) ปัญหาภาวะซึมเศร้าเป็นปัญหาทางด้านสุขภาพจิตที่ทุกคนสามารถเป็นได้ ซึ่งมีประชากรมากกว่า 280 ล้านคนทั่วโลก เติญกับปัญหาภาวะซึมเศร้าทำให้เป็นปัญหาที่เป็นภาระของโลกในปัจจุบัน ผู้ที่เผชิญกับปัญหาภาวะซึมเศร้าหนักหน่อจากการดำเนินชีวิตประจำวันที่จะต้องประสบกับการผันผวนของอารมณ์ในแต่ละวันแล้ว ยังจะต้องเผชิญกับปัญหาที่เกิดจากโรคเรื้อรังอื่น ๆ ที่เป็นผลมาจากการทำหน้าที่ของร่างกายที่เปลี่ยนแปลงไป ในปี พ.ศ. 2558 กรมสุขภาพจิต กระทรวงสาธารณสุข มีนโยบายในการตรวจคัดกรอง บำบัดรักษา และติดตามเฝ้าระวังโรคซึมเศร้าอย่างต่อเนื่อง จากรายงานการเข้าถึงบริการของผู้ป่วยโรคซึมเศร้าสะสมรายจังหวัดและเครือข่ายบริการภาพรวมของประเทศ พ.ศ.2564 มีคนไทยที่เป็นผู้ป่วยโรคซึมเศร้าและยังไม่สามารถเข้าถึงบริการคิดเป็นร้อยละ 20 ของผู้ป่วยโรคซึมเศร้าทั้งหมด (สำนักงานปลัดกระทรวงสาธารณสุข, 2021)

ผลกระทบจากปัญหาภาวะซึมเศร้าที่น่ากลัวที่สุดคือ การนำไปสู่ภาวะการฆ่าตัวตาย (Suicide) ในระยะหลังมานี้ ชาวการฆ่าตัวตายที่มีส่วนเกี่ยวข้องกับโรคซึมเศร้ามีเกิดขึ้นอย่างต่อเนื่อง คนส่วนใหญ่มักเข้าใจผิด คิดว่าโรคซึมเศร้าเป็นเพียงอาการหรือสภาวะทางจิตใจที่

เปลี่ยนไปชั่วขณะที่เกิดจากจิตใจที่ได้รับการกระทบกระเทือนและสามารถรักษาให้หายได้ด้วยการให้กำลังใจ แต่ในความเป็นจริงแล้วโรคซึมเศร้ามีความรุนแรงกว่าที่คิดและสามารถเกิดขึ้นได้กับทุกเพศทุกวัย แต่หากผู้ที่เผชิญปัญหาภาวะซึมเศร้า (depression) เป็นระยะเวลานานอาจทำให้เกิดเป็นโรคซึมเศร้า (depressive disorder) ได้ (Spijker และคนอื่น ๆ, 2002) เมื่อผู้ที่เป็นภาวะซึมเศร้าไม่ได้รับการรักษาเป็นเวลานาน จะเพิ่มความเสี่ยงของการเป็นซ้ำ และอาจกลายเป็นโรคซึมเศร้าเรื้อรังได้ (Lewinsohn, Rohde, Seeley, Klein, และ Gotlib, 2000) และการเผยแพร่ข้อความหรือเนื้อหาที่เกี่ยวข้องกับความรุนแรงรวมถึงการฆ่าตัวตาย สามารถส่งผลและมีอิทธิพลโดยตรงในเรื่องของการเรียนรู้ในสังคมของเด็กและวัยรุ่นที่ยังรู้เท่าไม่ถึงการณ์และไม่สามารถแก้ไขปัญหาได้ดีพอ ซึ่งการใช้งานสื่อสังคมออนไลน์มีส่วนในการแสดงออกทางพฤติกรรมค่อนข้างมาก เนื่องจากผู้ใช้งานคิดว่าเป็นทางออกในการแก้ปัญหาที่ดีที่สุด (Komsan Kiatrungrit, 2016)

แพลตฟอร์มสื่อสังคมออนไลน์หลายแพลตฟอร์ม เช่น บล็อก (Blogs) ฟอรัมสนทนา (Forum) และเครือข่ายสังคม (Social network) ได้กลายเป็นเครื่องมือที่มีประสิทธิภาพในการระบุและตรวจสอบสุขภาพจิตของผู้ที่มีอาการซึมเศร้า ซึ่งผู้ที่มีอาการซึมเศร้าเหล่านี้มักจะใช้โพสต์สื่อสังคมออนไลน์เพื่อแสดงความรู้สึกหรือข้อความช่วยเหลือของพวกเขา ความสามารถในการระบุสัญญาณและอาการที่แสดงอาการของโรคซึมเศร้าจะสามารถช่วยผู้ป่วยที่ต้องการความช่วยเหลืออย่างไรก็ตาม งานนี้เป็นความท้าทายสำคัญสำหรับองค์กรทางการแพทย์ที่สนับสนุนผู้ป่วยที่มีสัญญาณและอาการซึมเศร้า มีงานวิจัยที่ศึกษาก่อนหน้าได้แสดงให้เห็นถึงประสิทธิภาพการใช้อัลกอริทึมการประมวลผลภาษาธรรมชาติ (Natural Language Processing, NLP) ในการระบุและแยกข้อความที่เกี่ยวข้องกับภาวะซึมเศร้าหรือสุขภาพจิตอื่น ๆ เช่น ใช้ Convolution Neural Network (CNN), Recurrent Neural Network (RNN) และ Long Short-Term Memory (LSTM) ในการจำแนกโพสต์เกี่ยวกับโรคซึมเศร้าในเว็บบอร์ด Reddit (Tadesse, Lin, Xu, และ Yang, 2019) หรือใช้เทคนิค Transfer Learning ด้วย ULMFiT บน CNN เพื่อตรวจจับความเสี่ยงของโรคซึมเศร้าและการทำร้ายตัวเองจากโพสต์ใน Reddit (Yates, Cohan, และ Goharian, 2017)

ในการประมวลผลภาษาธรรมชาติ (NLP) ภาษาไทยจะมีความยากมากกว่าภาษาอังกฤษเนื่องจากไม่มีขอบเขตของคำหรือข้อความไทยไม่มีช่องว่างระหว่างคำ (white space) ซึ่งคุณลักษณะนี้เป็นคุณลักษณะที่สำคัญที่ทำให้การตัดคำ (word segmentation) หรือข้อความ (sentence segmentation) มีความหมาย หากมีการตัดคำหรือข้อความที่ผิดจะทำให้ผู้อ่านหรือผู้รับสารเข้าใจความหมายผิดไปหรืออาจไม่เข้าใจความหมาย ประเด็นสำคัญอีกอย่าง

หนึ่งของการทำการประมวลผลภาษาธรรมชาติคือทรัพยากรที่มีอยู่จำกัดของ NLP สำหรับภาษาไทยนั้นมีขนาดเล็กกว่าเมื่อเทียบกับภาษาต่าง ๆ เช่น ภาษาอังกฤษ รวมถึงการสนับสนุนของชุมชนทางภาษาไทยมีน้อยกว่าภาษาอื่น ๆ

จากที่กล่าวมาข้างต้นจะเห็นได้ว่า พฤติกรรมการใช้สื่อสังคมออนไลน์มีเพิ่มมากขึ้นทุกปี และส่งผลกระทบต่อสุขภาพจิต ซึ่งผลกระทบที่มีความรุนแรง เช่น การทำร้ายตัวเองหรือการฆ่าตัวตาย เป็นผลกระทบที่เกิดขึ้นจากภาวะซึมเศร้า หากเราสามารถวิเคราะห์หรือทำนายภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์ได้จะสามารถช่วยป้องกันผลกระทบจากโรคซึมเศร้าได้ ผู้วิจัยจึงต้องการสร้างโมเดลการเรียนรู้เชิงลึก (Deep Learning) เพื่อตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยของผู้ใช้งานบนสื่อสังคมออนไลน์ โดยประยุกต์ใช้เทคนิคการประมวลผลภาษาธรรมชาติ (Natural Language Processing, NLP) ร่วมกับการสร้างแบบจำลองสำหรับการจำแนก (Classification Model) โดยเลือกใช้โมเดลการเรียนรู้เชิงลึก (Deep Learning) ที่เกี่ยวข้องกับภาษาไทย และนำผลลัพธ์การทำนายมาเปรียบเทียบกับประสิทธิภาพของแต่ละโมเดลว่าโมเดลไหนที่มีประสิทธิภาพดีที่สุดในการตรวจจับภาวะซึมเศร้าจากข้อความที่เป็นภาษาไทย รวมถึงทำการวิเคราะห์ข้อผิดพลาดของโมเดลเพื่อตรวจสอบข้อจำกัดของโมเดลและชุดข้อมูลตามผลลัพธ์ของการทำนาย

ความมุ่งหมายของงานวิจัย

ในการวิจัยครั้งนี้ผู้วิจัยได้ตั้งความมุ่งหมายไว้ดังนี้

1. เพื่อศึกษาและประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกร่วมกับเทคนิคการประมวลผลภาษาธรรมชาติ สำหรับการสร้างแบบจำลองการตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยของผู้ใช้งานสื่อสังคมออนไลน์
2. เพื่อศึกษาและเปรียบเทียบของโมเดลการเรียนรู้เชิงลึกที่เกี่ยวข้องกับภาษาไทยที่สามารถตรวจจับภาวะซึมเศร้าจากข้อความของผู้ใช้งานสื่อสังคมออนไลน์ที่มีประสิทธิภาพได้
3. เพื่อศึกษาและเปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกที่เกี่ยวข้องกับภาษาไทยโดยใช้เทคนิคในการตัดคำ (word tokenization) ที่แตกต่างกัน

ขอบเขตของการวิจัย

1. ข้อมูลที่ใช้สำหรับการทำวิจัย เป็นข้อมูลจากงานวิจัย “Predicting Signs of Depression from Twitter Messages” (S. Mahasiriakalayot, T. Senivongse, และ Taephant, 2022) ชุดข้อมูลนี้ได้ดึงข้อมูลจากทวิตเตอร์ (Twitter) ระหว่างเดือนมกราคม - เมษายน 2021 โดย

ใช้ Tweepy Library ดึงข้อความภาษาไทยที่มีแฮชแท็ก (Hashtag) คำว่า #ซึมเศร้า #โรคซึมเศร้า #ภาวะซึมเศร้า และ #ฆ่าตัวตาย จำนวนทั้งหมด 3,100 ข้อความ และทำการระบุประเภทข้อมูล (Label) ชุดข้อมูลด้วยนักจิตวิทยาการปรึกษาของคณะจิตวิทยา จุฬาลงกรณ์มหาวิทยาลัย โดยการแบ่งประเภทอาการของภาวะซึมเศร้า 5 อาการ อ้างอิงจากผลของงานวิจัยของ ดร. กลกรณ์ วงศ์ภาติกะเสรี และคณะ (Wongpatikaseree, Yomaboot, Katchapakirin, และ Kaewpitakun, 2020) ตามตาราง 1

ตาราง 1 แสดงชุดข้อมูลที่ใช้ในการวิจัย

ลำดับ	อาการของภาวะซึมเศร้า	จำนวน
1	Anhedonic	1,274
2	Other	1,050
3	Suicidal Ideation	551
4	Guilty Feelings	185
5	Sleep Problems	40

2. เทคนิคการเรียนรู้เชิงลึกที่ใช้สำหรับการสร้างแบบจำลองการจำแนก 3 เทคนิค โดยอ้างอิงจากงานวิจัย ได้แก่

2.1 Bidirectional LSTM (BiLSTM) อ้างอิงสถาปัตยกรรมของโมเดลจากงานวิจัยของ (S. Mahasiriakalayot และคนอื่น ๆ, 2022)

2.2 Thai BERT อ้างอิงสถาปัตยกรรมของโมเดลจากงานวิจัยของ (Hämäläinen, Patpong, Alnajjar, Partanen, และ Rueter, 2021)

2.3 WangchanBERTa อ้างอิงสถาปัตยกรรมของโมเดลจากงานวิจัยของ (Lowphansirikul, Polpanumas, Jantrakulchai, และ Nutanong, 2021)

3. ใช้วิธีการวัดประสิทธิภาพของโมเดล (Model Evaluation) ด้วยตัววัดประสิทธิภาพ 4 ค่า ได้แก่ Accuracy, Precision, Recall และ F1 score

กรอบแนวคิดในการวิจัย

การพัฒนาแบบจำลองเพื่อตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยของผู้ใช้งานสื่อสังคมออนไลน์ จะแบ่งออกเป็น 3 ขั้นตอนหลัก ดังนี้

ขั้นตอนแรก ทำการนำเข้าสู่ข้อมูลเพื่อทำการเตรียมข้อมูล และทำความสะอาดข้อมูลในส่วนของคุณลักษณะอื่น ๆ ที่ไม่ใช่ข้อความ (Data Preprocessing) โดยหลังจากการทำความสะอาดข้อมูลจะทำการวิเคราะห์และสำรวจข้อมูลในมุมมองต่าง ๆ (Exploratory Data Analysis, EDA)

ขั้นตอนที่สอง มุ่งเน้นไปที่การเตรียมข้อความ ทำความสะอาดข้อมูลที่เป็นข้อความ (Text Pre-processing) การตัดคำ (Word Tokenization) การจัดการกับข้อมูลที่ไม่สมดุล (Imbalanced Data) และเปลี่ยนคำให้กลายเป็นเวกเตอร์ที่เป็นตัวแทนความหมายของคำ (Word Embedding) ก่อนที่จะนำเข้าแบบจำลอง

ขั้นตอนสุดท้าย จะมุ่งเน้นไปที่การพัฒนาแบบจำลองการตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทย ซึ่งเป็นปัญหาแบบ Multiclass Classification ประกอบด้วย 5 ประเภท คือ Suicidal Ideation, Anhedonic, Sleep Problems, Guilty Feelings และ Other โดยใช้เทคนิคการเรียนรู้เชิงลึก (Deep Learning) ที่เป็นโมเดลที่เรียนรู้มาก่อนแล้ว (Pre-trained model) โดยมี 3 โมเดลที่แตกต่างกัน ประกอบด้วย 1) Bidirectional LSTM (BiLSTM) 2) Thai BERT และ 3) WangchanBERTa โดยจะทำการแบ่งข้อมูลแบบชั้นภูมิ (Stratified sampling) ออกเป็นชุดข้อมูล Training Data 90% และชุดข้อมูล Testing Data 10% ของข้อมูลทั้งหมด ซึ่งชุดข้อมูล Testing Data ใช้สำหรับทดสอบประสิทธิภาพของโมเดล และในการวัดประสิทธิภาพการทำนายของแบบจำลองทดสอบโดยการใช้ Confusion Matrix คำนวณค่า Accuracy, Precision, Recall และ F1 score

ประโยชน์ที่คาดว่าจะได้รับการวิจัย

1. สามารถนำแบบจำลองที่ได้จากงานวิจัยครั้งนี้ ไปใช้ในการตรวจจับภาวะซึมเศร้าจากข้อความของผู้ใช้สื่อสังคมออนไลน์ได้
2. สามารถนำแบบจำลองไปพัฒนาเป็นโปรแกรมตอบโต้ข้อความอัตโนมัติ (Chatbot) เพื่อประยุกต์ใช้ในการรักษาผู้ป่วยโรคซึมเศร้าได้

นิยามศัพท์เฉพาะ

งานวิจัยนี้ได้กำหนดนิยามเฉพาะที่ปรากฏในงานวิจัย ดังต่อไปนี้

1. **ภาวะซึมเศร้า หรือ Depression** หมายถึง อาการทางอารมณ์ที่เกิดขึ้นเมื่อบุคคลต้องเผชิญกับการสูญเสียบางอย่างในชีวิต ไม่ว่าจะเป็นการสูญเสียที่เกิดขึ้นจริงหรือเป็นเพียงแต่ความกังวลถึงเหตุการณ์ในอนาคต นอกจากนี้ยังรวมถึงความรู้สึกผิดหวังและท้อแท้ที่เกิด

จากการไม่สามารถบรรลุเป้าหมายที่ตั้งใจไว้ หรือการเปลี่ยนแปลงของชะตาชีวิตที่ไม่คาดคิด แม้ว่าภาวะนี้จะทำให้เกิดความสับสนวุ่นวายในจิตใจพอสมควร แต่ในแง่ของการวินิจฉัยทางการแพทย์แล้ว ภาวะซึมเศร้าอาจส่งผลกระทบต่อสภาพจิตใจและการใช้ชีวิตประจำวัน รวมถึงการทำงานหรือการเรียนด้วย ทั้งนี้ ผู้ที่ได้รับการวินิจฉัยว่ามีภาวะซึมเศร้าจะต้องได้รับการประเมินด้วยวิธีการต่างๆ และมีการจำแนกระดับความรุนแรงของอาการด้วย หากภาวะซึมเศร้านั้นอยู่ในระดับที่รุนแรงมากและไม่ได้รับการดูแลอย่างเหมาะสม ก็มีโอกาสที่ภาวะดังกล่าวจะลุกลามกลายเป็นโรคซึมเศร้าได้ในที่สุด (ธรรณินทร์ กองสุข และคนอื่น ๆ, 2008)

2. โรคซึมเศร้า หรือ Major Depressive Disorder (MDD) หมายถึง ความผิดปกติทางจิตเวชที่เกิดจากการทำงานที่บกพร่องของสารสื่อประสาทในสมอง ส่งผลให้เกิดการเปลี่ยนแปลงทางอารมณ์อย่างมีนัยสำคัญ แม้ว่าสาเหตุที่แท้จริงของโรคนี้ยังไม่ได้รับการพิสูจน์ยืนยันอย่างแน่ชัด แต่จากการศึกษาเบื้องต้นพบว่า ความผิดปกติของสารเคมีในสมองที่เกี่ยวข้องกับการควบคุมและการแสดงออกทางอารมณ์ที่ไม่สมดุลนั้น เป็นปัจจัยสำคัญที่ทำให้การทำงานของสมองเกิดความบกพร่องขึ้น นอกจากนี้ยังมีหลักฐานที่บ่งชี้ว่าพันธุกรรมอาจมีบทบาทในการเกิดโรคนี้ด้วย โดยปัจจัยอื่นๆ เช่น บุคลิกภาพและความเครียดในการดำเนินชีวิตประจำวันก็สามารถกระตุ้นให้เกิดอาการของโรคซึมเศร้าได้เช่นกัน (สุวรรณนา อรุณพงศ์ไพศาล และ สรยุทธ วาสิกนันทน์, 2015) การระบุว่าเป็นโรคซึมเศร้าจะต้องอาศัยเกณฑ์มาตรฐานในการวินิจฉัยโรคและต้องได้รับการวินิจฉัยจากแพทย์เท่านั้น

บทที่ 2

ทบทวนวรรณกรรม

ในการวิจัยครั้งนี้ ผู้วิจัยได้ศึกษาทฤษฎีและงานวิจัยที่เกี่ยวข้อง และได้นำเสนอตามหัวข้อต่อไปนี้

1. หลักการทฤษฎีที่เกี่ยวข้อง

- 1.1 ความรู้เกี่ยวกับโรคซึมเศร้า (Depressive Disorder)
- 1.2 การประมวลผลภาษาธรรมชาติ (Natural Language Processing)
- 1.3 การจำแนกประเภทข้อความ (Text Classification)
- 1.4 การเรียนรู้ของเครื่อง (Machine Learning)
- 1.5 การเรียนรู้เชิงลึก (Deep Learning) สำหรับการจำแนกประเภทข้อความ
- 1.6 การจัดการกับข้อมูลที่ไม่สมดุล (Imbalanced Data)
- 1.7 การตัด (Word Tokenization) สำหรับภาษาไทย
- 1.8 การสร้างคุณลักษณะของข้อมูล (Feature Engineering)
- 1.9 การวัดประสิทธิภาพของแบบจำลอง (Model Evaluation)

2. งานวิจัยที่เกี่ยวข้อง

1. หลักการทฤษฎีที่เกี่ยวข้อง

1.1 ความรู้เกี่ยวกับโรคซึมเศร้า (Depressive Disorder)

โรคซึมเศร้า (Depressive Disorder) เป็นความผิดปกติทางจิตเวชที่มีอาการหลักคือ ภาวะอารมณ์เศร้าหดหู่ เบื่อหน่าย หรือสูญเสียความสุขและความสนใจในกิจกรรมต่าง ๆ อย่างต่อเนื่องนานกว่า 2 สัปดาห์ จนส่งผลกระทบต่อการใช้ชีวิตประจำวันอย่างมีนัยสำคัญ ตามเกณฑ์การวินิจฉัยของ DSM-5 (Diagnostic and Statistical Manual of Mental Disorders, Fifth Edition) โรคซึมเศร้ามีหลายระดับความรุนแรง ตั้งแต่ระดับน้อย ปานกลาง ไปจนถึงรุนแรงมาก และมีหลายรูปแบบย่อย เช่น โรคซึมเศร้าเรื้อรัง (Persistent Depressive Disorder) โรคซึมเศร้าหลังคลอด (Postpartum Depression) โรคซึมเศร้าตามฤดูกาล (Seasonal Affective Disorder) เป็นต้น

อาการของโรคซึมเศร้ามีความหลากหลาย ซึ่งสามารถแบ่งออกเป็นกลุ่มใหญ่ ๆ ดังนี้

- 1.1.1 อาการด้านอารมณ์ เช่น รู้สึกเศร้า หดหู่ ท้อแท้ สิ้นหวัง ไม่มีความสุข รู้สึกผิด ไร้ค่า น้อยใจ โกรธง่าย
- 1.1.2 อาการด้านความคิด เช่น มองโลกในแง่ร้าย ขาดสมาธิ ความจำแย่งลง ตัดสินใจลำบาก คิดลุ่มลึกความพยายาม คิดอยากตาย
- 1.1.3 อาการด้านร่างกาย เช่น นอนไม่หลับหรือหลับมากเกินไป เบื่ออาหาร น้ำหนักลด อ่อนเพลีย เคลื่อนไหวช้าลงหรือกระสับกระส่าย ปวดศีรษะ ปวดเมื่อยกล้ามเนื้อ
- 1.1.4 อาการด้านพฤติกรรม เช่น แยกตัว ไม่สนใจสังคม ไม่ทำกิจกรรมที่เคยชอบ ประสิทธิภาพการทำงานตก มีพฤติกรรมเสี่ยง เช่น ดื่มสุรา สูบบุหรี่ ใช้สารเสพติด

ทั้งนี้อาการของโรคซึมเศร้าจะแตกต่างกันไปในแต่ละบุคคล ทั้งด้านชนิดของอาการ ความรุนแรง ระยะเวลา และผลกระทบที่เกิดขึ้น ซึ่งต้องอาศัยการสังเกตและประเมินอย่างรอบด้าน จากบุคลากรทางการแพทย์

ในการตรวจคัดกรองโรคซึมเศร้า มีเครื่องมือที่สามารถช่วยในการตรวจคัดกรองได้ เบื้องต้นมากมายซึ่งหนึ่งในเครื่องมือ นั้น เป็นเครื่องมือที่เกี่ยวข้องกับงานวิจัยนี้คือ แบบทดสอบ TMHQ หรือ Thai Mental Health Questionnaire เป็นแบบสอบถามที่ใช้ในการคัดกรองและประเมินภาวะสุขภาพจิตของคนไทย พัฒนาขึ้นโดย ผศ.ดร.สุชีรา ภัทรายุตวรรตน์ และคณะ จากภาควิชาจิตเวชศาสตร์ คณะแพทยศาสตร์ศิริราชพยาบาล มหาวิทยาลัยมหิดล (Phattharayuttawat, Ngamthipwattana, และ Sukhatungkha, 1999) โดยมีพื้นฐานมาจากเกณฑ์การวินิจฉัยโรคทางจิตเวชของ DSM-IV (Diagnostic and Statistical Manual of Mental Disorders, 4th Edition) ซึ่งเป็นคู่มือการวินิจฉัยโรคทางจิตเวชที่ใช้กันอย่างแพร่หลายในระดับสากล

แบบทดสอบ TMHQ เป็นแบบสอบถามให้ผู้ทำประเมินอาการของตนเอง มีข้อคำถามทั้งหมด 70 ข้อ ครอบคลุมอาการทางจิตเวช 5 ด้านได้แก่ Somatization (กลุ่มอาการทางกาย), Depression (กลุ่มอาการซึมเศร้า), Anxiety (กลุ่มอาการวิตกกังวล), Psychotic (กลุ่มอาการโรคจิต) และ Social Function (การทำหน้าที่ทางสังคม) มีงานวิจัยของ ดร. กลกรณ์ วงศ์ ภาติกะเสวี และคณะ (Wongpatikaseree และคนอื่น ๆ, 2020) พัฒนาระบบตรวจจับภาวะซึมเศร้าจากพฤติกรรมการใช้สื่อสังคมออนไลน์และแบบสอบถามสุขภาพจิตของคนไทย (TMHQ)

ที่ปรับปรุงใหม่ให้มีประสิทธิภาพมากขึ้น โดยปรับเปลี่ยนจากข้อคำถามเดิมที่มีจำนวนทั้งหมด 70 ข้อ ปรับลดเหลือ 20 ข้อ และใช้เทคนิค Exploratory Factor Analysis (EFA) ในการจัดกลุ่มข้อคำถาม โดยพบว่าสามารถแบ่งอาการของภาวะซึมเศร้าได้เป็น 4 อาการ ได้แก่ Anhedonic (ความสุขลดลง เบื่อหน่าย) Suicidal ideation (ความคิดอยากตาย) Guilty feeling (ความรู้สึกผิด) และ Sleep problems (ปัญหาการนอน) นำมาทดลองใช้อัลกอริทึม 4 ชนิด ได้แก่ Naive Bayes, Support Vector Machine (SVM), Random Forest และ Long Short-Term Memory (LSTM) พบว่า LSTM ให้ผลการทำนายที่ดีที่สุด โดยมีค่า accuracy 93.2%, precision 0.91, recall 0.96, F1-score 0.94 ซึ่งสูงกว่าการใช้แค่ข้อมูลจาก TMHQ อย่างเดียว (accuracy 84.5%) ในงานวิจัยนี้จึงนำอาการของภาวะซึมเศร้าจากงานวิจัยข้างต้นมาระบุเป็นประเภทของข้อความภาษาไทยจากทวิตเตอร์

1.2 การประมวลผลภาษาธรรมชาติ (Natural Language Processing)

การประมวลผลภาษาธรรมชาติ เป็นเทคนิคหนึ่งในปัญญาประดิษฐ์ที่เกี่ยวข้องกับความเข้าใจภาษาที่มนุษย์ใช้ เพื่อสร้างโมเดลหรือแบบจำลองการสื่อสารของมนุษย์ด้วยกันมาเป็นการสื่อสารระหว่างมนุษย์กับคอมพิวเตอร์ ทำให้คอมพิวเตอร์สามารถเข้าใจภาษา จำแนกประเภทเนื้อหา หรือแม้แต่สร้างเนื้อหาใหม่ในรูปแบบภาษาที่มนุษย์ใช้

การสื่อสารประกอบด้วยจากคนสองฝั่ง คือ ผู้ส่งสารและผู้รับสาร ในส่วนของผู้ส่งสารจะนำเอาความคิดหรือความรู้ของตนเองมาถ่ายทอดเป็นสารในภาษาที่ฝ่ายผู้รับสารเข้าใจ การทำงานโดยรวมของฝั่งผู้ส่งสารเรียกว่า การสร้างภาษาธรรมชาติ (Natural Language Generation) เมื่อผู้รับสารได้รับสารก็จะวิเคราะห์สารที่ได้ว่าประกอบไปด้วยคำ และเมื่อรวมกันเป็นประโยคแล้วมีความหมายว่าอย่างไร จากนั้นก็นำไปตีความและบันทึกไว้ในสมองเก็บเป็นความรู้ เพื่อใช้ในการสื่อสารครั้งต่อไป การทำงานโดยรวมของฝั่งผู้รับสารเรียกว่า การทำความเข้าใจภาษาธรรมชาติ (Natural Language Understanding - NLU)

ดังนั้น การสื่อสารจำเป็นต้องใช้หลักการประมวลผลภาษาธรรมชาติ ซึ่งประกอบด้วย 2 ส่วนที่สำคัญ คือ การสร้างภาษาธรรมชาติ และการทำความเข้าใจภาษาธรรมชาติ ซึ่งทั้งสองส่วนนั้น เป็นการดำเนินการที่เดินหน้าและย้อนกลับของขั้นตอน 4 ขั้นตอน ได้แก่

1. การวิเคราะห์ระดับคำ (Lexical Analysis) เป็นการทำให้คอมพิวเตอร์รู้ว่าเสียงพูดหรือข้อความนั้นมีค่าโดยอยู่บ้าง ยกตัวอย่างเช่น ถ้าเราสั่งงานคอมพิวเตอร์ โดยบอกว่า ให้

แบ่งประโยคออกเป็นส่วน ๆ โดยพิจารณาจาก ช่องว่าง ถ้าต้องการยืนยันว่าเป็นคำในภาษาอังกฤษหรือไม่ สามารถทำได้โดยนำไปค้นหาในพจนานุกรม ถ้าปรากฏอยู่แสดงว่าเป็นคำที่ถูกต้อง ถ้าค้นแล้วไม่พบ จะไม่นับเป็นคำ

2. การวิเคราะห์ระดับไวยากรณ์ (Syntactic Analysis) เป็นการวิเคราะห์คำแต่ละคำที่ได้จากการวิเคราะห์ของคำ เมื่อนำมาเรียงต่อกันแล้วถูกต้องตามหลักไวยากรณ์ของภาษาที่เรากำลังสนใจอยู่หรือไม่

3. การวิเคราะห์ระดับความหมาย (Semantic Analysis) เป็นการวิเคราะห์หารูปแบบที่เหมาะสมในการแทนความหมายให้คอมพิวเตอร์เข้าใจ และเชื่อมโยงความสัมพันธ์ของแต่ละส่วนอย่างมีเหตุผล เราจะสามารถทราบได้ว่าคำแต่ละคำที่อยู่ในประโยคนั้น มีหน้าที่เป็นคำประเภทใดบ้าง เช่น คำนามทั่วไป คำกริยา คำนามเฉพาะ เป็นต้น

4. การวิเคราะห์ระดับการใช้งาน (Pragmatics Analysis) การวิเคราะห์ระดับของการใช้งาน จำเป็นต้องมีความรู้เบื้องหลังเกี่ยวกับโดเมนที่กำลังสื่อสารกัน รวมทั้งจำเป็นที่จะต้องพิจารณาความหมายของประโยคที่อยู่โดยรอบ หลักการสำคัญสำหรับการวิเคราะห์ในระดับการใช้งาน ได้แก่ การเชื่อมโยงเกี่ยวเนื่อง (Text Coherence) การวิเคราะห์สรรพนามอ้างอิง (Reference Resolution) และการวิเคราะห์สิ่งอ้างอิงร่วม (Anaphora Resolution)

ปัญหาที่สำคัญอย่างหนึ่งในการประมวลผลภาษาธรรมชาติ คือ ความกำกวม (Ambiguity) ซึ่งความกำกวมเป็นสาเหตุที่ทำให้เกิดความเข้าใจผิดในการสื่อความหมาย ความกำกวมสามารถเกิดขึ้นได้ในการประมวลผลทุกระดับ เช่น การวิเคราะห์ระดับคำ คำว่า “หวงแหน” กับคำว่า “จอกแหน” มีคำว่า “แหน” ที่อยู่ในทั้งสองคำ เขียนเหมือนกัน ออกเสียงแตกต่างกัน และมีความหมายที่แตกต่างกัน เราจะเรียกคำพวกนี้ว่า “คำพ้องรูป” (Homograph) ในทางตรงกันข้าม คำว่า “ซาบซึ้ง” กับคำว่า “รับทราบ” อ่านออกเสียงเหมือนกัน เขียนแตกต่างกัน และความหมายแตกต่างกัน เราจะเรียกคำพวกนี้ว่า “คำพ้องเสียง” (Homophone) ซึ่งกรณีนี้สามารถแก้ปัญหาได้ด้วยการเอาคำที่อยู่รอบ ๆ มาพิจารณา ซึ่งอาจเป็นคำที่อยู่ติดกัน n ตัว (n-gram) หรือคำที่เกิดขึ้นภายในขอบเขตเดียวกัน เช่น ประโยคย่อหน้า หรือเอกสารเดียวกัน (Word co-occurrence)

1.3 การจำแนกประเภทข้อความ (Text Classification)

Text Classification หรือ การจำแนกประเภทข้อความ เป็นหนึ่งในปัญหาหลักในการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) ซึ่งมีจุดประสงค์เพื่อจัดกลุ่มหรือจัดหมวดหมู่ข้อความหรือเอกสารตามประเภทที่กำหนดไว้ ตัวอย่างการประยุกต์ใช้งาน เช่น

การกรองอีเมลที่เป็นสแปม (Spam Email Classification) การแบ่งหมวดหมู่ข่าวตามประเภท (News Classification) การจำแนกความคิดเห็นเชิงบวกหรือลบจากการวิวลินคำ (Sentiment Analysis) หรือการตรวจจับข้อความที่ไม่เหมาะสมหรืออันตรายบนโซเชียลมีเดีย

การจำแนกประเภทข้อความมักอาศัยเทคนิคของการเรียนรู้ของเครื่อง (Machine Learning) ซึ่งเป็นสาขาของปัญญาประดิษฐ์ (Artificial Intelligence, AI) ที่ทำให้คอมพิวเตอร์สามารถเรียนรู้รูปแบบและหาความสัมพันธ์จากข้อมูล เพื่อใช้ในการทำนายหรือตัดสินใจได้ กระบวนการเริ่มจากการรวบรวมข้อมูลข้อความหรือเอกสารจำนวนมาก พร้อมกับป้ายกำกับ (label) หรือหมวดหมู่ของข้อความแต่ละชิ้น ข้อมูลนี้จะถูกแบ่งออกเป็นชุดข้อมูลฝึกสอน (Training set) และชุดข้อมูลทดสอบ (Test set)

ในขั้นตอนการสร้างโมเดลสำหรับจำแนกข้อความ อัลกอริทึมในการเรียนรู้ของเครื่อง เช่น Naïve Bayes, Logistic Regression, Support Vector Machine (SVM), หรือ Neural Network จะถูกนำมาใช้ โดยเริ่มจากการเรียนรู้และวิเคราะห์รูปแบบในข้อมูลฝึกสอน เพื่อสร้างโมเดลที่สามารถแยกแยะลักษณะสำคัญ และจัดกลุ่มข้อความตามหมวดหมู่ที่ต้องการได้

ทั้งนี้ ข้อมูลข้อความดิบ (Raw Data) มักจะมีความซับซ้อนและไม่มีโครงสร้าง ดังนั้น จำเป็นต้องมีการเตรียมข้อมูล ซึ่งรวมถึงการทำความสะอาดข้อมูล, การ tokenization หรือการแบ่งข้อความออกเป็นคำหรือกลุ่มคำ, การกำจัดคำฟุ่มเฟือยที่ไม่มีความหมาย (stop words), การลดรูปคำ (stemming) หรือการหารากศัพท์ เพื่อลดขนาดของคลังคำศัพท์, และการแปลงคำหรือข้อความให้อยู่ในรูปเวกเตอร์ของตัวเลข (Text vectorization) ซึ่งจะทำให้อัลกอริทึมการเรียนรู้ของเครื่องสามารถประมวลผลและเข้าใจความหมายของข้อความได้

หลังจากฝึกสอนโมเดลด้วยชุดข้อมูลฝึกสอนแล้ว จะต้องมีการทดสอบประสิทธิภาพของโมเดล (Model Evaluation) ด้วยชุดข้อมูลทดสอบ โดยบ่อนข้อความทดสอบเข้าไปในโมเดล แล้ววัดความถูกต้องและความแม่นยำของผลการทำนายหมวดหมู่ หากประสิทธิภาพยังไม่ดีพอ อาจต้องมีการปรับค่าพารามิเตอร์ของโมเดล เทคนิคที่ใช้ หรือเลือกใช้อัลกอริทึมตัวอื่น

เมื่อได้โมเดลที่ให้ประสิทธิภาพดีแล้ว ก็สามารถนำมาใช้ในการจัดหมวดหมู่ข้อความหรือเอกสารใหม่ ๆ ที่ไม่ทราบประเภทได้ การจำแนกประเภทข้อความโดยใช้เครื่องมือ Machine Learning มีประสิทธิภาพมากกว่าการใช้นมนุษย์ทำด้วยตนเอง โดยเฉพาะอย่างยิ่งเมื่อต้องจัดการกับข้อมูลขนาดใหญ่ ๆ

ในปัจจุบันมีการนำเทคนิค การเรียนรู้เชิงลึก (Deep Learning) เข้ามาใช้ในการจำแนกประเภทข้อความมากขึ้น เนื่องจากให้ผลลัพธ์ที่ดีกว่าอัลกอริทึมแบบดั้งเดิม (Machine Learning) แต่ก็ต้องอาศัยข้อมูลจำนวนมากและทรัพยากรที่สูงกว่าเช่นกัน

1.4 การเรียนรู้ของเครื่อง (Machine Learning) สำหรับการจำแนกประเภทข้อความ

การเรียนรู้ของเครื่อง (Machine Learning) เป็นสาขาย่อยของปัญญาประดิษฐ์ (Artificial Intelligence) ที่เน้นการพัฒนาอัลกอริทึมหรือโมเดลที่สามารถเรียนรู้รูปแบบและความสัมพันธ์จากข้อมูล เพื่อใช้ในการทำนายหรือตัดสินใจได้โดยอัตโนมัติ ซึ่งเทคนิคการเรียนรู้ของเครื่องมีบทบาทสำคัญมากในการจำแนกประเภทข้อความ (Text Classification) โดยจะช่วยให้การจัดกลุ่มข้อความทำได้อย่างอัตโนมัติและมีประสิทธิภาพ ไม่ว่าจะเป็นการคัดกรอง การสรุปใจความ หรือการวิเคราะห์เนื้อหา ซึ่งสามารถประยุกต์ใช้ได้กับงานในหลากหลายสาขา เช่น การสืบค้นข้อมูล การจัดหมวดหมู่เอกสาร การวิเคราะห์ความคิดเห็นลูกค้า หรือการตรวจจับสแปมและข้อความที่ไม่เหมาะสม

อย่างไรก็ตาม การจำแนกประเภทด้วยการเรียนรู้ของเครื่องก็ยังคงมีความท้าทายหลายประการ เช่น การได้มาซึ่งข้อมูลฝึกสอนที่มีคุณภาพและจำนวนมากพอ การเลือกคุณลักษณะของข้อมูลที่ใช้ในการฝึกสอน การกำหนดพารามิเตอร์ที่เหมาะสม การแก้ไขปัญหาข้อมูลที่ไม่สมดุล (imbalanced) ระหว่างแต่ละประเภท เป็นต้น ทั้งนี้ กระบวนการทางภาษาศาสตร์เชิงคำนวณ (computational linguistics) เช่น การวิเคราะห์โครงสร้างไวยากรณ์และความหมายของประโยค ก็มีส่วนช่วยให้การเรียนรู้ของเครื่องเข้าใจบริบทและความหมายที่แฝงอยู่ในข้อความได้ดียิ่งขึ้น ไม่เพียงแต่พิจารณาแต่ละคำแยกจากกัน

อัลกอริทึมการเรียนรู้ของเครื่อง (Machine Learning) ยอดนิยมนหลายตัวในการจำแนกประเภทข้อความ ได้แก่

1.4.1 Naive Bayes อาศัยทฤษฎีความน่าจะเป็นพื้นฐาน มีความเรียบง่ายและรวดเร็ว เหมาะกับข้อมูลขนาดใหญ่

1.4.2 Support Vector Machines (SVM) ใช้หลักการหาเส้นหรือระนาบที่สามารถแบ่งข้อมูลออกได้ดีที่สุด ทำงานได้ดีกับข้อมูลมิติสูง

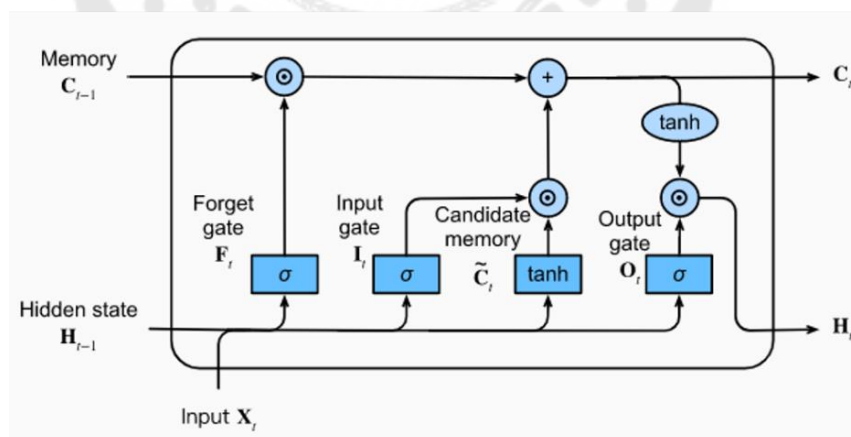
1.4.3 Logistic Regression ใช้ความสัมพันธ์เชิงเส้นในการทำนายความน่าจะเป็นของการเป็นสมาชิกในแต่ละกลุ่ม

1.4.4 Decision Trees & Random Forest สร้างต้นไม้ตัดสินใจจากข้อมูล โดยพิจารณาจากคุณลักษณะต่าง ๆ ของข้อมูล เหมาะกับข้อมูลที่มีความสัมพันธ์ไม่เป็นเชิงเส้น

1.5 การเรียนรู้เชิงลึก (Deep Learning) สำหรับการจำแนกประเภทข้อความ

1.5.1 Bidirectional LSTM (BiLSTM)


Hochreiter และ Schmidhuber ได้นำเสนอถึง Recurrent Neural Network (RNN) ชนิดใหม่ที่มีชื่อว่า Long Short-Term Memory (LSTM) (Hochreiter และ Schmidhuber, 1997) ซึ่งได้นำมาช่วยในการแก้ไขปัญหา Vanishing Gradient ที่ถูกพบเมื่อใช้วิธี RNN กับข้อมูลที่มีความยาว เช่น ข้อความที่เป็นประโยคยาว ๆ โดย LSTM ประกอบด้วย input gate, output gate และ forget gate ซึ่งจะเป็นสิ่งที่ควบคุมการไหลของข้อมูล โดยที่เมื่อ LSTM ได้รับข้อมูลมาจากชั้น input เป็นครั้งแรก LSTM จะเข้าสู่ input gate และเข้าสู่ output gate เพื่อตัดสินใจว่าจะเก็บค่าที่ได้ไว้แล้วจะวนซ้ำใน LSTM หรือแสดงผลข้อมูล หากเลือกที่จะวนซ้ำจะนำข้อมูลกลับมาเพื่อเข้าสู่ forget gate ซึ่งจะตัดสินใจว่าจะลบค่าที่เก็บไว้ทิ้งหรือยังคงเก็บค่าไว้ หากเก็บไว้จะไปปรองการอัปเดตจาก input gate ซึ่งจะตัดสินใจว่าจะอัปเดตค่านั้นหรือไม่ และจะอัปเดตด้วยค่าอะไร แล้วส่งค่านั้นไป output gate เพื่อตัดสินใจว่าจะนำข้อมูลนั้นออกไปแสดงหรือจะนำข้อมูลกลับไปวนซ้ำอีกรอบ ดังนั้น LSTM จึงสามารถเรียนรู้จากข้อมูลที่เป็นลำดับและเก็บหรือลบข้อมูลทิ้งถ้าข้อมูลนั้นไม่จำเป็นตามภาพประกอบที่ 1



ภาพประกอบ 1 แสดงการทำงานของหน่วย LSTM

ที่มา: An Intuitive Explanation of LSTM (Ottavio, 2022)

แต่เมื่อพิจารณาจากการทำงานการประมวลผลภาษาธรรมชาติแล้ว LSTM จะได้รับบริบทจากซ้ายไปขวาเท่านั้น ทำให้มีประสิทธิภาพที่ไม่ดีพอ จึงมีการเสนอใช้โมเดล Bi-directional RNNs (BRNNs) ขึ้นมา เพื่อที่ทำงานได้สองทิศทาง สามารถดูบริบททั้งซ้ายและขวาได้ และใช้กับข้อมูลที่มีความยาวมากขึ้นกว่าเดิมได้ ทำให้มีประสิทธิภาพมากขึ้น โดยการรวมการทำงานกันของ BRNNs และ LSTM ทำให้เกิดเป็นโมเดล Bi-LSTM ขึ้นมา ตามภาพประกอบ 2



ภาพประกอบ 2 แสดงการทำงานของ Bi-directional LSTM

ที่มา: Bidirectional LSTM ("Bidirectional LSTM," 2020)

จากภาพประกอบ 2 สามารถอธิบายองค์ประกอบหลักของโครงสร้างของ Bi-directional LSTM ได้ดังนี้

Input Layer: เลเยอร์อินพุตที่รับข้อมูลอินพุตเข้ามาในโมเดล โดยอินพุตอาจเป็นตัวเลข เวกเตอร์ หรือตัวแทนข้อความต่าง ๆ

Forward LSTM Layer: เลเยอร์ LSTM ที่ประมวลผลข้อมูลจากซ้ายไปขวา โดยใช้เซลล์ LSTM ในการเรียนรู้ความสัมพันธ์ระยะยาวในข้อมูล

Backward LSTM Layer: เลเยอร์ LSTM ที่ประมวลผลข้อมูลจากขวาไปซ้ายในทิศทางตรงกันข้ามกับ Forward LSTM ทำให้สามารถเรียนรู้บริบทจากทั้งสองทิศทาง

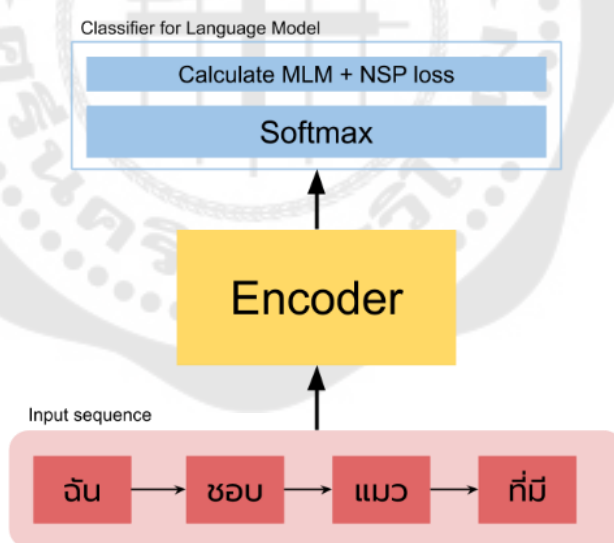
Concatenation: นำเอาเอาต์พุตของ Forward และ Backward LSTM มาต่อกันเพื่อให้ได้ข้อมูลที่ครอบคลุมบริบทจากทั้งสองทิศทางมากขึ้น

Output Layer: เลเยอร์เอาต์พุตสุดท้ายที่ทำนายผลลัพธ์สุดท้ายของโมเดล โดยอาจเป็นค่าความน่าจะเป็น คลาส หรือเวกเตอร์ที่ใช้ในการทำงานต่อไป

โมเดล BiLSTM ถือเป็นสถาปัตยกรรมที่มีประสิทธิภาพในการเรียนรู้ลำดับและความสัมพันธ์ของข้อมูลในสองทิศทาง ทำให้เหมาะสำหรับงานประมวลผลภาษา เช่น การแก้คำ การวิเคราะห์ความรู้สึก การแปลภาษา เป็นต้น

1.5.2 Bidirectional Encoder Representations from Transformers (BERT)

Jacob Devlin และ คณะ ได้นำเสนองานวิจัย “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding” (Devlin, Chang, Lee, และ Toutanova, 2018) ชื่อเต็ม ๆ ของ BERT หรือ Bidirectional Encoder Representations from Transformers จะเห็นได้ว่า BERT เป็นอีกหนึ่งโมเดลที่ต่อยอดจาก Transformer โดย BERT ถูกออกแบบให้เลือกใช้เฉพาะส่วนที่เป็น encoder ซึ่งทำหน้าที่แปลงคำในประโยคให้เปลี่ยนไปเป็นเวกเตอร์ เพื่อให้ encoder สามารถทำหน้าที่เป็น Language Model ได้ BERT จึงเพิ่มโมเดลอีก 1 ตัว ต่อจาก encoder ที่มีอยู่เดิม เพื่อทำหน้าที่เป็น Classifier นำเวกเตอร์ที่ได้จาก encoder ไปคำนวณต่อให้ได้คำตอบในรูปแบบคล้าย ๆ กับ Language Model ทั่ว ๆ ไป ตามภาพประกอบ 3



ภาพประกอบ 3 แสดงการทำงานของ BERT

ที่มา: ทำความเข้าใจ BERT (Pakawat Nakwijit, 2020)

ดังนั้น ในภาพรวมแล้ว BERT ไม่ต่างจาก Transformer Encoder มากนัก ส่วนต่างที่ชัดที่สุด อาจจะเป็นเรื่องของขนาด โดย BERT ขยายขนาดให้มีจำนวน attention head มาก

ขึ้น มีจำนวน layer มากขึ้น และ เพิ่มขนาด embedding vector ทั้งนี้ เพื่อให้มั่นใจว่าโมเดลสามารถเรียนรู้คุณสมบัตินทางภาษาให้ได้มากที่สุด

1.5.3 Thai BERT

Thaikeras ได้สร้างโมเดล BERT-th ขึ้นมา โดยฝึกฝนบนสถาปัตยกรรม BERT และถูกฝึกฝนด้วยชุดข้อมูลจาก Wikipedia ภาษาไทย ขนาด 515 MB ซึ่งเมื่อเทียบกับโมเดลภาษาไทยในปัจจุบันถือว่าใช้ข้อมูลที่ฝึกฝนมีขนาดเล็กมาก ทำให้โมเดลรับข้อความได้ยาวที่สุดเพียง 128 คำย่อย (ประมาณ 90 คำ) ส่งผลให้โมเดลไม่สามารถแสดงศักยภาพได้อย่างเต็มที่ สามารถเข้าถึงได้ที่ <https://github.com/ThAIKeras/bert>

1.5.4 WangchanBERTa

สถาบันวิจัยปัญญาประดิษฐ์ประเทศไทย (Thailand Artificial Intelligence Research Institute) ได้เผยแพร่โมเดล WangchanBERTa ซึ่งเป็นโมเดลทางภาษาไทยสำหรับงานประมวลผลภาษารวมชาติ โดยฝึกฝนบนสถาปัตยกรรม RoBERTa และได้ทำการเทรนโมเดลภาษา (language model) บนชุดข้อมูลในภาษาไทยที่ได้จากแหล่งต่างๆ เช่น ข่าว, วิกีพีเดีย, ข้อความในโซเชียลมีเดีย และข้อมูลที่ได้จากการ crawl เว็บไซต์ในอินเทอร์เน็ต ซึ่งมีขนาดข้อมูลรวม 78.5 GB และได้วัดประสิทธิภาพของโมเดลภาษาที่ finetune แล้ว ได้ผลคะแนน micro-averaged F1 score สูงที่สุดบน 5 ชุดข้อมูล จากทั้งหมด 6 ชุดข้อมูล โดยเป็นชุดข้อมูลทดสอบในโจทย์การจำแนกข้อความ (text classification) และการจำแนกคำ (token classification) เมื่อเทียบกับ baseline model และโมเดลภาษาแบบหลายภาษา (multilingual language model) ที่มีอยู่ในปัจจุบัน (mBERT และ XLMR) โดยตัวตัดคำย่อย (Tokenization) ใช้ SentencePiece ในการแบ่งคำและใช้เวลาฝึกฝนโมเดล 3 เดือน ทำให้โมเดล WangchanBERTa ถือเป็นโมเดลภาษาไทยที่ใหญ่ที่สุด และเป็น State-of-The-Art ณ ขณะนี้

1.6 การจัดการกับข้อมูลที่ไม่สมดุล (Imbalanced Data)

ในการจำแนกประเภทข้อมูล เราต้องเจอกับปัญหาข้อมูลไม่สมดุล (Imbalanced Data) อยู่บ่อยครั้ง โดยเกิดขึ้นเมื่อจำนวนข้อมูลในแต่ละกลุ่มหรือคลาสมีความแตกต่างกันมาก เช่น อาจมีข้อมูลในคลาสหนึ่งมากกว่าอีกคลาสหนึ่งถึง 100 เท่า ซึ่งทำให้โมเดลที่สร้างขึ้นมีแนวโน้มที่จะเอนเอียงไปทำนายเฉพาะคลาสส่วนใหญ่ได้ดีกว่า (Majority Class) ในขณะที่ทำนาย

คลาสส่วนน้อยได้ไม่ดีนัก (Minority Class) ซึ่งมักเป็นคลาสที่เราให้ความสนใจมากกว่า เช่น การตรวจจับการฉ้อโกง การวินิจฉัยโรคที่พบน้อย หรือการทำนายการเกิดภัยพิบัติ เป็นต้น

เทคนิคในการจัดการกับข้อมูลไม่สมดุล สามารถจำแนกได้เป็น 3 กลุ่มหลัก ๆ ได้แก่

1.6.1 การปรับขนาดข้อมูลให้สมดุลด้วยวิธี Resampling ซึ่งมีทั้งแบบ Oversampling คือการเพิ่มจำนวนข้อมูลในคลาสส่วนน้อยให้มากขึ้น และแบบ Undersampling คือการลดจำนวนข้อมูลในคลาสส่วนใหญ่ลง เทคนิคที่น่าสนใจ เช่น SMOTE, ADASYN, Random Undersampling เป็นต้น

1.6.2 การปรับค่าน้ำหนัก (Cost) ของการทำนายผิดพลาดในแต่ละคลาส ซึ่งให้ความสำคัญกับค่าใช้จ่ายในการทำนายคลาสส่วนน้อยผิดมากกว่าการทำนายคลาสส่วนใหญ่ผิด เช่น การใช้ Class Weights, Cost-Sensitive Learning เป็นต้น

1.6.3 การใช้อัลกอริทึมการเรียนรู้ที่ออกแบบมาเพื่อให้เหมาะกับข้อมูลไม่สมดุล โดยเฉพาะ เช่น Decision Tree ที่ใช้ Hellinger Distance, SVM ที่ใช้ Different Error Costs เป็นต้น

ในบรรดาวิธีการเหล่านี้ เทคนิคการ Oversampling ด้วยวิธี SMOTE (Synthetic Minority Over-sampling Technique) เป็นหนึ่งในวิธีการที่ได้รับความนิยมมากที่สุด โดย SMOTE ถูกนำเสนอครั้งแรกโดย Chawla และคณะ (Chawla, Bowyer, Hall, และ Kegelmeyer, 2011) ซึ่งอาศัยหลักการสร้างตัวอย่างเสมือน (Synthetic Samples) ขึ้นมาเพิ่มเติมในคลาสส่วนน้อย โดยพิจารณาจาก k จำนวนตัวอย่างใกล้เคียงที่สุด (k -Nearest Neighbors) ซึ่งกระบวนการทำงานโดยสรุปมีดังนี้

- สำหรับตัวอย่างแต่ละตัวในคลาสส่วนน้อย (minority class) ให้ทำการหา k ตัวอย่างใกล้เคียงที่สุดในคลาสเดียวกัน
- เลือกตัวอย่างเพื่อนบ้านแบบสุ่ม จำนวน m ตัวจากทั้งหมด k ตัว (โดยทั่วไป m มักเท่ากับ 1)
- สร้างตัวอย่างเสมือนใหม่ขึ้นมา โดยการสุ่มจุดบนเส้นตรงที่ลากระหว่างตัวอย่างตั้งต้นกับตัวอย่างเพื่อนบ้านที่เลือกไว้
- กำหนดคลาสของตัวอย่างเสมือนใหม่ให้เป็นคลาสเดียวกับตัวอย่างตั้งต้น
- ทำซ้ำจนกว่าจะได้จำนวนตัวอย่างตามที่ต้องการ หรือจนกว่าอัตราส่วนของข้อมูลระหว่างคลาสจะสมดุลพอดี

เทคนิค SMOTE มีข้อดี คือ ช่วยเพิ่มความหลากหลายของตัวอย่างในคลาสส่วนน้อย โดยไม่ได้ทำซ้ำกับข้อมูลที่มีอยู่เดิม ทำให้โมเดลมีความสามารถในการนำไปใช้กับข้อมูลใหม่ได้ดีขึ้น อีกทั้งยังอาศัยข้อมูลเดิมเป็นหลักในการสร้าง ซึ่งแตกต่างจากวิธี Oversampling ที่ไปเพิ่มข้อมูลซ้ำซ้ำข้อมูลโดยตรง อย่างไรก็ตาม SMOTE ก็มีข้อจำกัด เช่น

- SMOTE ไม่ได้พิจารณาข้อมูลในคลาสอื่น ๆ ในการสร้างตัวอย่างเสมือน จึงอาจเกิดการ overlap ระหว่างคลาสได้ โดยเฉพาะเมื่อข้อมูลมีมิติสูงหรือมีตัวอย่างรบกวน (noise) เยอะ
- การเลือกจำนวน k มีผลอย่างมากต่อความสมจริงของตัวอย่างเสมือน โดยถ้า k มากเกินไป อาจได้ตัวอย่างที่ไม่เป็นตัวแทนที่ดี แต่ถ้า k น้อยเกินไป ความหลากหลายของข้อมูลที่สร้างก็จะไม่มากนัก
- SMOTE สร้างตัวอย่างเสมือนจากข้อมูลในคลาสส่วนน้อยทุกจุดเท่ากัน ซึ่งในความเป็นจริง บางจุดอาจมีความสำคัญมากกว่า และควรถูกเลือกในการสร้างตัวอย่างมากกว่า

ในบางครั้งในการสร้างข้อมูลใหม่ด้วยเทคนิค SMOTE อาจมีการผิดพลาดระหว่างคลาสได้ ทางผู้วิจัยจึงศึกษารูปแบบอื่นของ SMOTE จึงพบว่ามิงงานวิจัยหลายงานที่มีการพัฒนาเทคนิคนี้ โดยเทคนิคที่ผู้วิจัยนำมาใช้ในงานวิจัยนี้คือเทคนิค SMOTE-Cosine จากงานวิจัยเรื่อง “SMOTE-Out, SMOTE-Cosine, and Selected-SMOTE: An enhancement strategy to handle imbalance in data level” (Koto, 2014) เทคนิค SMOTE-Cosine เป็นเทคนิคสำหรับจัดการปัญหา Class Imbalance ในชุดข้อมูลที่พัฒนาต่อยอดมาจากเทคนิค SMOTE (Synthetic Minority Over-sampling Technique) โดยใช้หลักการของ Cosine Similarity ในการสร้างข้อมูลสังเคราะห์เพิ่มเติมในคลาสส่วนน้อย (Minority Class) แทนการใช้ระยะทางแบบ Euclidean Distance แบบดั้งเดิม ขั้นตอนการทำงานของ SMOTE-Cosine มีดังนี้

1. คำนวณ Cosine Similarity: สำหรับข้อมูลแต่ละตัวอย่างใน Minority Class ให้คำนวณค่า Cosine Similarity กับข้อมูลตัวอย่างอื่นๆ ในคลาสเดียวกัน โดย Cosine Similarity จะวัดความคล้ายคลึงระหว่างเวกเตอร์สองตัวโดยพิจารณาจากทิศทางและมุมระหว่างกัน ค่าที่ได้จะอยู่ในช่วง -1 ถึง 1

2. เลือกข้อมูลข้างเคียง: สำหรับข้อมูลแต่ละตัวอย่าง ให้เลือกข้อมูลข้างเคียง (nearest neighbors) จำนวน k ตัวที่มีค่า Cosine Similarity สูงสุด โดยค่า k เป็นพารามิเตอร์ที่กำหนดไว้ล่วงหน้า

3. สร้างข้อมูลสังเคราะห์: สุ่มเลือกข้อมูลข้างเคียงหนึ่งตัวจาก k ตัวที่เลือกไว้ในขั้นตอนก่อน จากนั้นสร้างข้อมูลสังเคราะห์ที่ใหม่ขึ้นมาโดยการ interpolate ระหว่างข้อมูลตัวอย่างเดิมกับข้อมูลข้างเคียงที่สุ่มเลือก ทำซ้ำขั้นตอนนี้จนได้จำนวนข้อมูลสังเคราะห์ที่ต้องการ

4. รวมข้อมูล: นำข้อมูลสังเคราะห์ที่สร้างขึ้นใหม่ไปรวมกับข้อมูล Minority Class เดิม แล้วจึงรวมกับข้อมูล Majority Class เพื่อสร้างชุดข้อมูลใหม่ที่มีความสมดุลมากขึ้น

ข้อดีของ SMOTE-Cosine คือการใช้ Cosine Similarity ในการวัดความคล้ายคลึง ทำให้สามารถจัดการกับข้อมูลที่มีมิติสูงได้ดีกว่าวิธีวัดระยะทางแบบ Euclidean ที่ใช้ใน SMOTE แบบดั้งเดิม การสร้างข้อมูลสังเคราะห์โดยพิจารณาจาก Cosine Similarity ช่วยรักษาความสัมพันธ์และรูปแบบของข้อมูลได้ดีขึ้น นำไปสู่ประสิทธิภาพที่ดีขึ้นของโมเดลในการเรียนรู้ และจัดการกับปัญหา Class Imbalance

1.7 การตัดคำ (Word Tokenization) สำหรับภาษาไทย

ในภาษาอังกฤษ คำในประโยคจะถูกแบ่งด้วยช่องว่างระหว่างคำ (White space) ทำให้ง่ายในการตัดคำ ในทางกลับกัน เทคนิคในการตัดคำเป็นเทคนิคที่สำคัญในกระบวนการประมวลผลภาษาธรรมชาติสำหรับภาษาไทย เนื่องจากคำในประโยคไม่มีช่องว่างระหว่างคำ ทำให้คำอยู่ติดกันซึ่งเป็นการยากสำหรับการตัดคำ หากตัดคำผิดไปอาจทำให้ความหมายเปลี่ยนไปหรือไม่มีความหมายเลย เช่น คำว่า “ตากลม” ถ้าหากตัดคำเป็น “ตา|กลม” ก็จะมีความหมายว่า “ตาที่มีลักษณะกลม” แต่หากตัดคำเป็น “ตากล|ม” ความหมายที่ได้จะแตกต่างจากก่อนหน้าเป็น “การฝั่งลมให้แห้ง” ในงานวิจัยนี้จะนำเทคนิคการตัดคำมาใช้ 3 เทคนิค ดังนี้

1.7.1 เทคนิค Newmm

เป็นอัลกอริทึมการตัดคำที่เป็นค่าเริ่มต้นของ PyThaiNLP ซึ่งเป็นการจับคู่สูงสุดตามพจนานุกรม (dictionary-based maximum matching) กับคำภาษาไทยและใช้การจัดกลุ่มตัวอักษรไทย (Phatthiyaphaibun และคนอื่น ๆ, 2023)

1.7.2 เทคนิค Attacut

เป็นไลบรารีการตัดคำใน Python ที่พัฒนาโดยโครงการ PyThaiNLP สำหรับภาษาไทย ได้รับการออกแบบมาเพื่อนำเสนอวิธีการที่รวดเร็วและแม่นยำในการแบ่งข้อความภาษาไทยเป็นคำ ชื่อ "Attacut" มาจากคำว่า "Attacut-cut" โดยที่ "cut" หมายถึงการแบ่งส่วนหรือตัดคำของข้อความ ไลบรารีนี้สร้างขึ้นจากเทคนิคการเรียนรู้เชิงลึกและใช้สถาปัตยกรรมโครงข่าย

ประสาทเทียมเพื่อทำนายขอบเขตคำในประโยคภาษาไทย (Chormai, Prasertsom, และ Rutherford, 2019)

1.7.3 เทคนิค Byte Pair Encoding (BPE)

BPE เป็นเทคนิคการบีบอัดข้อมูลที่ปรับให้เหมาะกับการสร้างการตัดคำย่อย (sub word) ใน NLP ใช้เพื่อแสดงคำเป็นลำดับของหน่วยคำย่อยเพื่อจัดการกับความท้าทายเกี่ยวกับคำศัพท์ และมีการใช้กันอย่างแพร่หลายในงานประมวลผลภาษาธรรมชาติต่าง ๆ รวมถึงการแปลด้วยเครื่อง (Machine translation) การสรุปข้อความ (Text summarization) และการวิเคราะห์ความรู้สึก (Sentiment analysis) (Sennrich, Haddow, และ Birch, 2015)

1.8 การสร้างคุณลักษณะของข้อมูล (Feature Extraction)

เป็นกระบวนการใช้ความรู้ Domain Knowledge ในการสร้างคุณลักษณะใหม่ขึ้นมา ตัดคุณลักษณะที่ไม่เกี่ยวข้องออกไป เพื่อให้ทำให้อัลกอริทึมเรียนรู้ได้ดีขึ้น รวมถึงการสร้างคุณลักษณะใหม่จากคุณลักษณะเดิม อาจนำคุณลักษณะเดิมมาคำนวณเพื่อให้เป็นคุณลักษณะใหม่ การเติมข้อมูลที่ขาด (Imputation) การจัดการข้อมูลโดด (Handling Outlier) การแปลงข้อมูล (Log Transform) การใช้งานข้อมูลวันที่ (Extracting Date) การแปลงข้อมูล category เป็นหลาย column (One-Hot Encoding / Word Embedding) การจัดกลุ่มของข้อมูล (Group Operations) และการ Scaling (Normalize, Standardize)

1.9 การวัดประสิทธิภาพของแบบจำลอง (Model Evaluation)

การนำโมเดลไปใช้งานจริงจำเป็นต้องมีการวัดประสิทธิภาพของตัวโมเดลก่อน ซึ่งเป็นกระบวนการที่ใช้เพื่อประเมินประสิทธิภาพของแบบจำลองที่ได้สร้างขึ้น โดยทั่วไปแล้วมีหลายวิธีในการวัดประสิทธิภาพของแบบจำลองที่สามารถใช้ได้ตามลักษณะของข้อมูลและวัตถุประสงค์ของงานวิจัยหรือการพัฒนาโมเดล เช่น การใช้ค่าประสิทธิภาพ (performance metrics) เพื่อวัดประสิทธิภาพของแบบจำลอง เช่น accuracy, precision, recall, F1-score, และ ROC-AUC เป็นต้น นอกจากนี้ยังมีการใช้กระบวนการอื่น ๆ เช่น cross-validation หรือการใช้ข้อมูลทดสอบ (test data) เพื่อประเมินประสิทธิภาพของแบบจำลองในสถานะที่เหมือนจริงมากขึ้น การวัดประสิทธิภาพของแบบจำลองเป็นขั้นตอนสำคัญในการปรับปรุงและพัฒนาแบบจำลองให้มีประสิทธิภาพมากยิ่งขึ้นในการแก้ไขปัญหาที่มีอยู่หรือในการนำไปใช้งานจริงในสถานการณ์ที่

แท้จริง ซึ่งโดยทั่วไปปัญหาการจำแนกประเภท (Classification) จะใช้ตาราง Confusion Matrix เป็นตารางสำคัญในการวัดความสามารถของการเรียนรู้ของแบบจำลอง ตามภาพประกอบ 4

		Actual Values	
		Positive (1)	Negative (0)
Predicted Values	Positive (1)	TP	FP
	Negative (0)	FN	TN

ภาพประกอบ 4 ตาราง Confusion Matrix ขนาด 2x2

โดยที่ค่า TP, TN, FP และ FN อธิบายดังนี้

True Positive (TP) คือ สิ่งที่ไม่เคยทำนายว่า “จริง” และมีค่าเป็น “จริง”

True Negative (TN) คือ สิ่งที่ไม่เคยทำนายว่า “ไม่จริง” และมีค่าเป็น “ไม่จริง”

False Positive (FP) คือ สิ่งที่ไม่เคยทำนายว่า “จริง” แต่มีค่าเป็น “ไม่จริง”

False Negative (FN) คือ สิ่งที่ไม่เคยทำนายว่า “ไม่จริง” แต่มีค่าเป็น “จริง”

ซึ่งสามารถนำมาคำนวณเป็นค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) และค่า F1 score หรือค่า F-measure ดังนี้

Accuracy

คือ ค่าที่บอกว่าโมเดลสามารถทำนายได้ถูกต้องขนาดไหน เป็นการวัดโดยพิจารณารวมทุกคลาส ดังสมการ 1

$$Accuracy = \frac{(TP+TN)}{(TP+TN+FP+FN)} \quad 1)$$

Precision (ค่าความแม่นยำ)

คือ เป็นการวัดความแม่นยำของโมเดล โดยพิจารณาแยกทีละคลาส เป็นการเปรียบเทียบ การทำนายที่ถูกต้องว่า “จริง” และเกิดขึ้น “จริง” (TP) กับการทำนายว่า “จริง” แต่สิ่งที่เกิดขึ้นคือ “ไม่จริง” ดังสมการ 2

$$Precision = \frac{TP}{(TP+FP)} \quad 2)$$

Recall

คือ เป็นการวัดความถูกต้องของโมเดล โดยพิจารณาแยกทีละคลาส จะวัดความถูกต้องของการทำนายว่าเป็น “จริง” เทียบกับจำนวนครั้งของเหตุการณ์ที่ทำนายและเกิดขึ้นว่าเป็น “จริง” ดังสมการ 3

$$Recall = \frac{TP}{(TP+FN)} \quad 3)$$

F1 score

คือ เป็นค่าเฉลี่ยแบบฮาร์โมนิก (Harmonic Mean) ระหว่าง precision และ recall ซึ่งจะใช้เพื่อเป็น single metric ที่วัดความสามารถของโมเดล ดังสมการ 4

$$F1\ score = 2 \times \frac{Precision \times Recall}{(Precision + Recall)} \quad 4)$$

ในการประเมินประสิทธิภาพของโมเดลการเรียนรู้ของเครื่อง เมตริกที่นิยมใช้กัน ได้แก่ F1-score, Precision, Recall และ Accuracy ที่กล่าวข้างต้น โดยสามารถคำนวณค่าเหล่านี้แบบ Macro, Micro และ Weighted Average ซึ่งมีความแตกต่างกัน ดังนี้

Macro Average: จะคำนวณค่า Precision, Recall และ F1-score สำหรับแต่ละคลาสแยกกัน โดยถือว่าทุกคลาสมีความสำคัญเท่ากัน จากนั้นหาค่าเฉลี่ยของ Precision, Recall และ F1-score ของทุกคลาส โดย Macro Average ให้น้ำหนักเท่ากันกับทุกคลาส ไม่ว่าคลาสนั้นจะมีจำนวนตัวอย่างข้อมูลมากหรือน้อย

Micro Average: รวมผลลัพธ์ของทุกคลาสเข้าด้วยกันแล้วคำนวณค่า Precision, Recall และ F1-score จากผลรวมนั้น Micro Average คำนวณจากจำนวนรวมของ True Positive (TP), False Positive (FP) และ False Negative (FN) ของทุกคลาสรวมกัน วิธีนี้ให้ความสำคัญ

กับคลาสที่มีจำนวนตัวอย่างข้อมูลมากกว่า เนื่องจากคลาสที่มีข้อมูลมากจะมีผลต่อค่า TP, FP, FN มากกว่า หรือพูดอีกนัยหนึ่งว่า Micro Average คือค่า Accuracy นั่นเอง

Weighted Average: จะคำนวณค่า Precision, Recall และ F1-score สำหรับแต่ละคลาสแยกกันเหมือน Macro Average แต่ในการหาค่าเฉลี่ยของแต่ละเมตริก จะให้น้ำหนักกับแต่ละคลาสตามสัดส่วนของจำนวนตัวอย่างข้อมูล (Support) ในคลาสนั้น ๆ โดย Weighted Average คำนึงถึงทั้งประสิทธิภาพของโมเดลในแต่ละคลาสและจำนวนตัวอย่างข้อมูลของแต่ละคลาส (Support)

โดยสรุป หากชุดข้อมูลมีจำนวนตัวอย่างของแต่ละคลาสที่ใกล้เคียงกัน Macro Average จะเหมาะสม แต่ถ้าชุดข้อมูลมีความไม่สมดุลของจำนวนตัวอย่างในแต่ละคลาสอย่างมาก Micro Average หรือ Weighted Average อาจเหมาะสมกว่า ทั้งนี้ขึ้นอยู่กับเป้าหมายและบริบทของปัญหาด้วยว่าต้องการให้ความสำคัญกับคลาสใดมากกว่ากัน การพิจารณาเลือกใช้เมตริกในการประเมินต้องคำนึงถึงลักษณะของข้อมูลและสิ่งที่ต้องการวัดเป็นหลัก

2. งานวิจัยที่เกี่ยวข้อง

การทบทวนวรรณกรรมของงานวิจัยนี้ ได้ทำการศึกษาค้นคว้างานวิจัยที่เกี่ยวข้องกับการตรวจจับภาวะซึมเศร้าจากข้อความบนสื่อสังคมออนไลน์ และงานวิจัยที่เกี่ยวข้องกับการพัฒนาเทคนิคการประมวลผลภาษาธรรมชาติสำหรับภาษาไทย

2.1 บทความวิจัยเรื่อง Deep Learning for Depression Detection of Twitter Users (Husseini Orabi, Buddhitha, Husseini Orabi, และ Inkpen, 2018)

งานวิจัยนี้มีการนำเสนอ 2 ส่วน ได้แก่ การทำ word embedding optimization โดยจะมุ่งเน้นในการระบุอาการซึมเศร้าจากการโพสต์ของผู้ใช้งานทวิตเตอร์ ซึ่งจะมีการปรับปรุงในชุดข้อมูล CLPsych2015 และทำการทดสอบในชุดข้อมูล Bell Let's Talk

การเปรียบเทียบประสิทธิภาพของโมเดล โดยจะใช้โมเดลการเรียนรู้เชิงลึกที่ใช้ในงานการประมวลผลภาษาธรรมชาติ ซึ่งจะใช้เทคนิค word embedding ที่แตกต่างกัน และมีการจูนไฮเปอร์พารามิเตอร์

จากผลการทดลองพบว่า โมเดล CNN มีประสิทธิภาพในการตรวจจับอาการซึมเศร้าของผู้ใช้งานทวิตเตอร์จากการโพสต์ได้ดีกว่าโมเดล RNN และโมเดลที่มีการทำ optimized มีประสิทธิภาพที่ดีกว่าโมเดลที่ไม่มีการทำ optimized และเทคนิค CBOW embedding มีประสิทธิภาพน้อยที่สุดเมื่อเทียบกับเทคนิคอื่น ๆ รวมถึงเทคนิคการสุ่ม ซึ่งก่อนขั้นตอนการเทรน

โมเดล เทคนิค CBOW และ skip-gram นั้น มีประสิทธิภาพที่ไม่ดีตามที่คาดหวัง อาจเป็นเพราะชุดข้อมูล CLPsych2015 นั้น มีจำนวนข้อมูลที่เยอะมากประมาณ 22 ล้านคำ

2.2 บทความวิจัยเรื่อง Identifying depression in the National Health and Nutrition Examination Survey data using a deep learning algorithm (Oh Jihoon, Yun Kyongsik, Maoz Uri, Kim Tae-Suk, และ Jeong-Ho, 2019)

งานวิจัยนี้มุ่งเน้นการประเมินของโมเดลการเรียนรู้เชิงลึก ด้วยข้อมูลทางระบาดวิทยา ข้อมูลด้านประชากร วิถีชีวิต และปัจจัยอื่น ๆ ที่เกี่ยวข้องกับอาการซึมเศร้า โดยจะทำการเปรียบเทียบโมเดลการเรียนรู้เชิงลึกกับโมเดลการเรียนรู้ของเครื่อง เช่น support vector machine และ logistic regression ใช้ชุดข้อมูลเดียวกัน ซึ่งเป็นชุดข้อมูลสำรวจทางโภชนาการและสุขภาพแห่งชาติของสหรัฐอเมริกา (NHANES) จำนวน 19,725 คน และของเกาหลีใต้ (K-NHANES) จำนวน 4,949 คน

ผลการทดลองพบว่า โครงข่ายประสาทเทียมเชิงลึก สามารถระบุอาการซึมเศร้าได้เป็นอย่างดี จากปัจจัยการระบาดวิทยา ข้อมูลสุขภาพอื่น ๆ ในชุดข้อมูล NHANES และ K-NHANES และยังสามารถทำนายชุดข้อมูลใหม่ ๆ ได้อย่างแม่นยำ ทั้งในแง่ของเวลาและเชื้อชาติ นอกจากนี้ งานวิจัยยังสามารถอธิบายความหมายทางคลินิกของการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก ในการตรวจหาความชุกและความก้าวหน้าของโรค ตลอดจนปัจจัยเสี่ยงอื่น ๆ ในอาการซึมเศร้าและความเจ็บป่วยทางจิตอื่น ๆ

ข้อจำกัดในงานวิจัยนี้ได้แก่ 1) งานวิจัยนี้มองว่า อาการซึมเศร้าเป็นตัวแปรไบนารี (Binary variable) ดังนั้น จึงไม่สามารถประเมินความสัมพันธ์ระหว่างปัจจัยต่าง ๆ กับความรุนแรงของอาการซึมเศร้าได้ 2) ชุดข้อมูล NHANES และ K-NHANES เป็นการสำรวจแบบตัดขวาง จึงไม่สามารถทำการวัดการพยากรณ์โรคหรือการเกิดอาการซึมเศร้าในอนาคตของประชากรได้ 3) ประสิทธิภาพของอัลกอริทึมการเรียนรู้เชิงลึกและการเรียนรู้ของเครื่องลดลงตามปัจจัยด้านเชื้อชาติ จึงมีความเป็นไปได้ที่การสำรวจข้อมูลอาจมีการไม่เข้าใจคำถามหรือมีความแตกต่างของเชื้อชาติและวัฒนธรรม

2.3 บทความวิจัยเรื่อง Explainable Depression Detection with Multi-Modalities Using a Hybrid Deep Learning Model on Social Media (Zogan, Wang, Jameel, และ Xu, 2020)

งานวิจัยนี้ใช้โมเดลไฮบริด หรือ MDHAN ในการเพิ่มประสิทธิภาพในการจำแนกอาการซึมเศร้าของผู้ใช้งานบนสังคมออนไลน์ โดยใช้ multi-modal และ word-embedding และเปรียบเทียบประสิทธิภาพกับโมเดลอื่น ๆ ด้วย โดยทำการสกัดคุณลักษณะจากพฤติกรรมและระยะเวลาในการโพสต์ของผู้ใช้งาน ซึ่งใช้ชุดข้อมูลจริงทั้งที่มีอาการซึมเศร้าและไม่มีอาการซึมเศร้า นำมาประยุกต์ใช้ในโมเดล และพบว่าโมเดลโครงข่ายแบบไฮบริด สามารถปรับปรุงประสิทธิภาพในการจำแนกอาการซึมเศร้าของผู้ใช้งานบนสื่อสังคมออนไลน์ได้อย่างมีประสิทธิภาพกว่าโมเดลอื่น ๆ และเป็นหลักฐานเพียงพอที่จะอธิบายการทำนายได้

2.4 บท ความ วิจัย เรื่อง X-A-BiLSTM : a Deep Learning Approach for Depression Detection in Imbalanced Data (Q. Cong และคนอื่น ๆ, 2018)

งานวิจัยนี้นำเสนอโมเดลการเรียนรู้เชิงลึก (X-A-BiLSTM) เพื่อตรวจจับอาการซึมเศร้าของผู้ใช้งานบนสื่อสังคมออนไลน์ โดยมุ่งเน้นในการแก้ไขปัญหาข้อมูลไม่สมดุลกันในโลกของจริง โดยนำเสนอโมเดล X-A-BiLSTM ในการแก้ปัญหาดังกล่าว ซึ่งโมเดลนี้ ประกอบไปด้วย 2 องค์ประกอบ ได้แก่ องค์ประกอบที่หนึ่งคือ XGBoost ที่ช่วยลดปัญหาข้อมูลไม่สมดุลกัน โดยใช้ค่าเฉลี่ยในระบบของต้นไม้ และองค์ประกอบที่สองคือ Attention-BiLSTM เพื่อช่วยเพิ่มความสามารถในการจำแนกของโมเดลได้ดีขึ้น ซึ่งผลลัพธ์ในชุดข้อมูล RSDD พบว่า มีประสิทธิภาพจำแนกอาการซึมเศร้าที่ดีกว่าโมเดลที่ทันสมัยก่อน ๆ

2.5 บท ความ วิจัย เรื่อง Context-Aware Deep Learning for Multi-Modal Depression Detection (Lam, Dongyan, และ Lin, 2019)

งานวิจัยนี้มุ่งเน้นวิธีการอัตโนมัติในการตรวจจับอาการซึมเศร้าจากการสัมภาษณ์ทางคลินิก โดยใช้หลักการเรียนรู้ของเครื่อง ซึ่งเป็นโมเดลที่ผ่านการฝึกด้วยชุดข้อมูลที่หลากหลาย ได้นำเสนอแนวทางในการรวมเอาขั้นตอนการเสริมข้อมูลตามการสร้างแบบจำลองหัวข้อ โดยใช้การทรานฟอร์ม และโครงข่ายประสาทแบบคอนโวลูชัน 1 มิติ สำหรับการทำ feature modeling ผลการทดลองพบว่า สำหรับข้อมูลชนิดเสียง 1D CNN มีค่า F1 0.67 และ 0.63 สำหรับข้อมูลชนิดข้อความที่นำไป transform แล้ว มีค่า F1 0.78 และ 0.76 และสำหรับข้อมูลชนิดที่มีความหลากหลาย มีค่า F1 0.87 และ 0.77 ซึ่งการรวมตัวกันของโมเดลมีประสิทธิภาพที่ดีกว่าแยกกัน

ผู้ทำวิจัยเชื่อว่า ประสิทธิภาพของโมเดลที่เพิ่มขึ้นนั้น เกิดจากการที่โมเดลได้รับการฝึกด้วยข้อมูลที่มากขึ้น ซึ่งทำให้การกระจายคลาสที่ไม่สม่ำเสมอมีความสมดุล

2.6 บทความวิจัยเรื่อง Text-based Depression Detection on Social Media Posts: A Systematic Literature Review (William และ Suhartono, 2021)

งานศึกษาชิ้นนี้ เป็นงานศึกษาการทบทวนงานวรรณกรรมอย่างเป็นระบบ ซึ่งมีขั้นตอนตั้งแต่กำหนดปัญหา กระบวนการประเมิน และการแปลผลจากแหล่งข้อมูล เพื่อหาคำตอบสำหรับชุดคำถามวิจัย โดยการวิเคราะห์นั้นมาจาก คำตอบที่เป็นข้อความของผู้ที่มีปัญหาหรือป่วยทางจิตใจ เพื่อให้เห็นความเป็นไปได้ที่จะตรวจจับอาการซึมเศร้าในสังคมตั้งแต่เนิ่น ๆ จากลักษณะการใช้งานสื่อสังคมออนไลน์ของผู้ใช้งาน

ผู้ทำวิจัยตัดสินใจเลือกชุดคำถามวิจัยเพื่อเป็นแนวทางสำหรับกระบวนการวิจัยทั้งหมด โดยผู้ทำวิจัยมีจุดมุ่งหมายเพื่อตอบคำถาม “สิ่งที่อาจส่งผลกระทบต่อการใช้งานสื่อสังคมออนไลน์ เพื่อใช้เป็นวิธีการในการตรวจจับอาการซึมเศร้าตั้งแต่เนิ่น ๆ” มีการกำหนดชุดคำถามการวิจัยดังนี้

RQ1 - อะไรคือความท้าทายในการทำการตรวจจับอาการซึมเศร้าจากข้อความ

RQ2 - วิธีการอะไรที่มีประสิทธิภาพที่สุดใน การตรวจจับอาการซึมเศร้าจากข้อความ ผลการศึกษาพบว่า มีประเด็นน่าเป็นห่วงอยู่ 3 ประเด็น ได้แก่ (1) ด้านจริยธรรม (2)

ขาดข้อมูลหรือไม่เพียงพอ (1) ความตระหนักในสภาพจิตใจของตนเอง และจากการศึกษาวิจัยพบอีกว่า งานวิจัยที่ค้นคว้าส่วนใหญ่ใช้วิธีการในการตรวจจับอาการซึมเศร้าจากข้อความ (1) classifiers (2) support vector machine (3) probabilistic classifier ซึ่งวิธีนี้จะใช้กันมากที่สุด และเป็นที่น่าสนใจว่าวิธีการ BiLSTM+Attention นั้นพิสูจน์แล้วว่าได้ผลดีที่สุด

2.7 บทความวิจัยเรื่อง การเปรียบเทียบประสิทธิภาพโครงสร้างเหมือนข้อมูลเพื่อจำแนกโรคซึมเศร้าจากพฤติกรรมการใช้โซเชียลมีเดียบนทวิตเตอร์ (ดำรงเดช เติมนิรมย์, ฉัตรเกล้า เจริญผล, และ จริยา จิรานุกูล, 2016)

งานวิจัยนี้มีจุดประสงค์ของการจำแนกโรคซึมเศร้าจากพฤติกรรมการใช้โซเชียลมีเดียบนทวิตเตอร์ โดยมีการเปรียบเทียบการจำแนกระหว่างแบบหนึ่งระดับและแบบสองระดับ การจำแนกหนึ่งระดับจะใช้งานอัลกอริทึม Bayes และอัลกอริทึม SVM จำแนกข้อความทั่วไปและข้อความที่บ่งถึงลักษณะอาการซึมเศร้าตามแบบสอบถาม DSM-V ได้แก่ อาการซึมเศร้า ความสนใจลดลง น้ำหนักลดลงหรือเพิ่มขึ้นอย่างผิดปกติ นอนไม่หลับหรือนอนหลับมากกว่าปกติ อ่อนเพลีย รู้สึกตนเองไร้ค่า สมาธิสั้น เคลื่อนไหวช้าและคิดฆ่าตัวตาย

การจำแนกสองระดับจะใช้งานอัลกอริทึม SVM เพื่อจำแนกข้อความทั่วไปกับข้อความบ่งบอกถึงโรคซึมเศร้า ต่อมาใช้งานอัลกอริทึม Bayes เปรียบเทียบกับอัลกอริทึม Random Forest เพื่อจำแนก 9 อาการที่บ่งบอกถึงโรคซึมเศร้าตามแบบสอบถาม DSM-V โดยใช้ข้อมูล 2 ชุด ชุดเรียนรู้และชุดทดสอบที่มาจากทวิตเตอร์ของดาราต่างประเทศ

จากผลการทดลองทั้งหมดสรุปได้ว่าเทคนิคการคัดเลือกคุณลักษณะด้วย Information Gain มีผลทำให้เวลาในการสร้างแบบจำลองลดน้อยลงอย่างมาก โดยเฉพาะอัลกอริทึมที่ใช้เวลานานอย่าง Random Forest ลดเวลาการทำงานได้ถึง 270.06 นาที อีกทั้งการลดคุณลักษณะให้ได้จุดเหมาะสมทำให้ประสิทธิภาพของการทดสอบแบบจำลองเพิ่มขึ้นและในการเลือกใช้อัลกอริทึมเพื่อจำแนกโรคซึมเศร้าจากพฤติกรรมทวิตเตอร์ การใช้งานที่ดีที่สุดคือการจำแนกหนึ่งระดับด้วยอัลกอริทึม Bayes เนื่องจากให้ผลลัพธ์ในการทดสอบกับชุดข้อมูลในโลกความจริง (Real world data) ได้ความถูกต้องที่ดีที่สุดคือ Accuracy 76.67% และได้ค่า Boundary ความน่าจะเป็นที่เหมาะสมแก่การทำ Vote Ensemble ที่ 0.4

2.8 บทความวิจัยเรื่อง Predicting Signs of Depression from Twitter Messages (S. Mahasiriakalayot และคนอื่น ๆ, 2022)

งานวิจัยนี้เป็นการทำนายสัญญาณของการเกิดภาวะซึมเศร้าจากข้อความภาษาไทยในทวิตเตอร์โดยการดำเนินการวิจัยมี 4 ขั้นตอน ได้แก่ 1) เก็บรวบรวมข้อมูลจากทวิตเตอร์โดยใช้ library Tweepy ระหว่างเดือนมกราคม - เมษายน 2564 เก็บรวบรวมโดยใช้ Hashtag #ซึมเศร้า (#depression) #โรคซึมเศร้า (#depressive disorder) #ภาวะซึมเศร้า (#depression) และ #ฆ่าตัวตาย (#suicide) จำนวน 3,100 ข้อความ 2) ทำการเตรียมข้อมูลโดยการ Labeling จะให้ผู้เชี่ยวชาญทางด้านจิตวิทยา จากคณะจิตวิทยา จุฬาลงกรณ์มหาวิทยาลัย ในการทำ Data Labeling โดยมีจำนวน 5 คลาส ได้แก่ Suicidal Ideation, Anhedonic, Sleep Problems, Guilty Feeling และ Other (not a sign of depression) และทำความสะอาดของข้อมูลโดยใช้ Library PyThaiNLP และในส่วนของการตัดคำใช้ Attacut ในการตัดคำ เนื่องจากข้อมูลมีจำนวนไม่เท่ากัน Imbalance จึงใช้เทคนิค SMOTE ในการแก้ปัญหา 3) สร้างโมเดลการเรียนรู้ของเครื่องจำนวน 3 โมเดล ได้แก่ LSTM, GRU และ SVM และทำการเปรียบเทียบประสิทธิภาพของแต่ละโมเดล 4) ทำการพัฒนาเว็บแอปพลิเคชันเพื่อทดสอบและพัฒนาโมเดล

ผลการวิจัยพบว่าโมเดล LSTM + ReLU ให้ประสิทธิภาพและความถูกต้องที่ดีจึงนำมาพัฒนาเป็นเว็บแอปพลิเคชันในการทดลองใช้โมเดล

2.9 บทความวิจัยเรื่อง Detecting Depression in Thai Blog Posts: a Dataset and a Baseline (Hämäläinen และคนอื่น ๆ, 2021)

งานวิจัยนี้มีวัตถุประสงค์ในการสร้างชุดข้อมูลโรคซึมเศร้าที่เป็นภาษาไทยและเปรียบเทียบแบบจำลองการเรียนรู้เชิงลึก (Deep Learning) จำนวน 4 แบบจำลอง ชุดข้อมูลที่ทางผู้วิจัยเก็บรวบรวมจากเว็บบล็อกบนอินเทอร์เน็ตในระหว่างปี ค.ศ. 2015 - 2019 มีจำนวน 472 โพสต์ที่มีการวิเคราะห์จากนักภาษาศาสตร์ว่าผู้เขียนเป็นโรคซึมเศร้า และทางผู้วิจัยรวบรวมชุดข้อมูลจากเว็บบล็อกที่ผู้เขียนไม่เป็นโรคซึมเศร้า จำนวน 472 โพสต์ และทำการตัดประโยคและคำด้วยเครื่องมือ PyThaiNLP แบ่งข้อมูลออกเป็นชุดข้อมูล train, valid และ test ตามตาราง 2

ตาราง 2 แสดงจำนวนข้อมูลแบ่งตามชุดข้อมูล

Label	Train	Valid	Test
Depressed	12,837	1,712	2,567
Non-depressed	12,240	1,632	2,448

แบบจำลองที่ใช้มี 4 แบบจำลอง โดยแบ่งเป็น 1) LSTM 2) LSTM + w2v 3) Multilingual BERT และ 4) Thai BERT และใช้ Thai2vec เป็น Word Embedding ผลการทดลองพบว่า แบบจำลอง Thai BERT มีประสิทธิภาพดีที่สุด มีค่า overall accuracy เท่ากับ 77.53% และเมื่อแบ่งตาม Label พบว่า แบบจำลอง Thai BERT มีค่า accuracy สูงที่สุด 79.70% ใน depression และแบบจำลอง LSTM + w2v มีค่า accuracy สูงที่สุด 77.00% ใน no depression

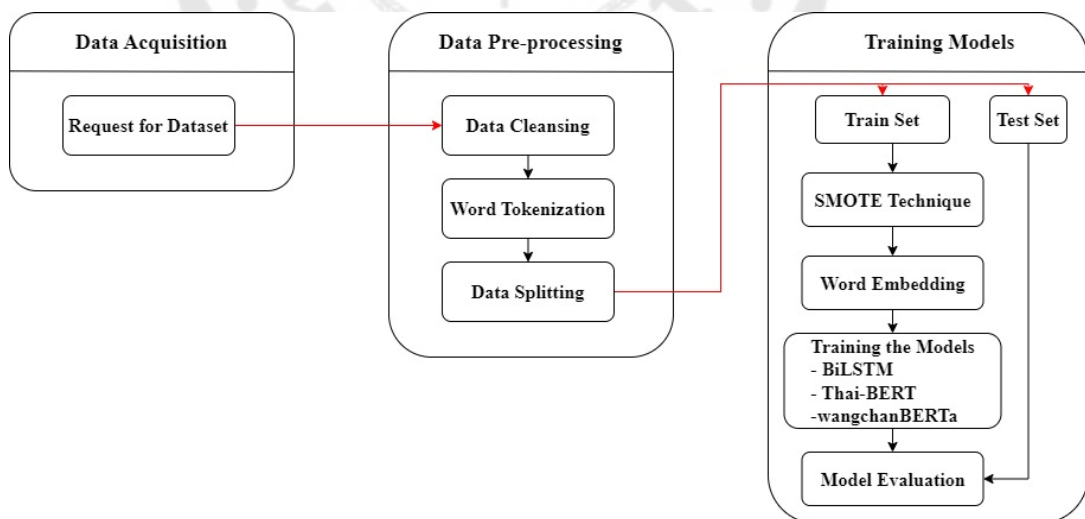
บทที่ 3

วิธีการดำเนินการวิจัย

ในการวิจัยครั้งนี้ ผู้วิจัยได้ดำเนินการตามขั้นตอนดังนี้

- 3.1 กระบวนการทำงานของแบบจำลอง (Workflow Process of Model)
- 3.2 การเก็บรวบรวมข้อมูล (Data Acquisition)
- 3.3 การระบุประเภทข้อมูล (Data Labeling)
- 3.4 การทำความสะอาดข้อมูล (Data Cleansing)
- 3.5 การเตรียมข้อมูล (Data Preprocessing)
- 3.6 การสำรวจข้อมูลเบื้องต้น (Exploratory Data Analysis)
- 3.7 สร้างคุณลักษณะของข้อมูลข้อความ (Feature Engineering)
- 3.8 การแบ่งข้อมูลสำหรับชุดฝึกฝนและชุดทดสอบ (Train-Test Split)
- 3.9 การสร้างแบบจำลองการจำแนก (Classification Model)
- 3.10 การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)

3.1 กระบวนการทำงานของแบบจำลอง (Workflow Process of Model)



ภาพประกอบ 5 แสดง Workflow กระบวนการสร้างแบบจำลอง

จากภาพประกอบ 5 แสดงกระบวนการทำงานของการสร้างแบบจำลองและเปรียบเทียบประสิทธิภาพของอัลกอริทึมที่เลือกมา ขั้นตอนการทำงานเริ่มจากการขอข้อมูลจากงานวิจัยที่

เกี่ยวข้อง นำข้อความที่เป็นภาษาไทยเข้าสู่กระบวนการ Data pre-processing และสำรวจข้อมูล (Exploratory Data Analysis - EDA) โดยจะวิเคราะห์สัดส่วนของข้อมูลแต่ละ Class แสดงผลออกมาในรูปแบบ Visualization และขั้นตอนต่อมาจะทำความสะอาดข้อความ (Text Preprocessing) และสำรวจข้อความ (Exploratory Text Analysis) เพื่อทำความสะอาดข้อมูล เช่น การเปลี่ยนคำให้ถูกต้อง (Misspelled words) และทำการตัดคำ (Word tokenization) โดยกระบวนการข้างต้น ใช้ไลบรารี PyThaiNLP และดูความถี่ของคำ (Word frequency) รวมถึงนับจำนวนความยาวของประโยค แสดงออกมาในรูปแบบ Visualization โดยใช้ไลบรารี Wordcloud และทำการแปลงข้อมูลของอาการของภาวะซึมเศร้าให้เป็นตัวเลข และเนื่องจากชุดข้อมูลที่นำมาใช้เป็นชุดข้อมูลที่ไม่สมดุล (Imbalanced Data) จึงใช้เทคนิค Synthetic Minority Over-sampling TEchnique (SMOTE) ในการทำให้ข้อมูลมีความสมดุลกันในแต่ละ class รวมถึงแปลงข้อมูลที่เป็นข้อความหลังจากการทำ SMOTE แล้วให้เป็นตัวเลขให้น้ำหนักของคำโดยใช้ Word Embedding (thai2vec) เพื่อให้อัลกอริทึมสามารถประมวลผลได้ ขั้นตอนถัดไปจะเป็นการแบ่งชุดข้อมูลเพื่อใช้ในการฝึกสอนเป็น Training และ Test Data ในอัตราส่วน 90:10 ตามลำดับ

เมื่อเตรียมข้อมูลข้างต้นเรียบร้อยแล้ว จะเข้าสู่กระบวนการสร้างแบบจำลองในการจำแนกโดยใช้เทคนิคการเรียนรู้เชิงลึก 3 อัลกอริทึมที่แตกต่างกัน ประกอบด้วย BiLSTM, Thai BERT และ WangchanBERTa จากนั้นทำการลองและปรับจูนพารามิเตอร์ของแบบจำลองเพื่อให้ได้ผลลัพธ์ที่มีประสิทธิภาพที่ดีที่สุด ในชุดข้อมูลนี้ของแต่ละแบบจำลอง

ขั้นตอนสุดท้ายจะนำแบบจำลองที่สร้างมาทำการทดสอบประสิทธิภาพและเปรียบเทียบผลของแต่ละอัลกอริทึม โดยใช้ Confusion Matrix, Accuracy, Precision, Recall และ F-measure โดยนำชุดข้อมูลทดสอบ (Test Data) มาทำการทดสอบและประเมินประสิทธิภาพของแบบจำลองการตรวจจับภาวะซึมเศร้าจากข้อความบนสื่อสังคมออนไลน์

3.2 การเก็บข้อมูล (Data Acquisition)

ข้อมูลที่ใช้ในงานวิจัยนี้ เป็นข้อมูลจากงานวิจัย “Predicting Signs of Depression from Twitter Messages” (S. Mahasiriakalayot และคนอื่น ๆ, 2022) ชุดข้อมูลนี้ได้ดึงข้อมูลจากทวีตเตอร์ (Twitter) ระหว่างเดือนมกราคม - เมษายน 2021 โดยใช้ไลบรารี Tweepy ในการดึงข้อความภาษาไทยที่มีแฮชแท็ก (Hashtag) คำว่า #ซึมเศร้า #โรคซึมเศร้า #ภาวะซึมเศร้า และ #ฆ่าตัวตาย จำนวนทั้งหมด 3,100 ข้อความ ซึ่งข้อมูลทั้งหมดได้รับการคุ้มครองความเป็นส่วนตัวของข้อมูล เพื่อให้แน่ใจว่ารายชื่อของผู้ใช้งานที่ทำการดึงข้อมูลมาจะไม่ถูกเปิดเผยชื่อ และผู้วิจัยได้ปฏิบัติตามหลักปฏิบัติในการจัดการข้อมูลตามหลักจริยธรรม โดยชื่อผู้ใช้งาน (username) ที่เกี่ยวข้องกับ

แต่ละทวิตจะถูกแทนที่ด้วยนามแฝง (pseudonym) ก่อนที่จะส่งข้อมูลในขั้นตอนต่อไป หลังจากนั้นทำการ label ชุดข้อมูลด้วยนักจิตวิทยาการปรึกษาของคณะจิตวิทยา จุฬาลงกรณ์มหาวิทยาลัย โดย label แบ่งตามอาการของภาวะซึมเศร้า 5 อาการ อ้างอิงจากงานวิจัย เรื่อง “Social Behavior Analysis and Thai Mental Health Questionnaire (TMHQ) Optimization for Depression Detection System” (Wongpatikaseree และคนอื่น ๆ, 2020) ตามตาราง 3 และตัวอย่างของชุดข้อมูลที่ใช้สร้างแบบจำลอง แสดงตามภาพประกอบ 6

ตาราง 3 ตารางคลังข้อมูลที่จัดประเภทตามอาการของภาวะซึมเศร้า

ลำดับ	อาการของภาวะซึมเศร้า	จำนวน
1	Anhedonic	1,274
2	Other	1,050
3	Suicidal Ideation	551
4	Guilty Feelings	185
5	Sleep Problems	40

text	label
ไม่คิดว่าคนเราเรื่องอย่างฉันจะมาถึงจุดนี้ เรากลายเป็นคนที่ไม่รู้ความรู้สึกแบบนี้เมื่อไหร่กันนะ	Anhedonic
วันนี้เหนื่อยไหมคะคนเก่ง ไหวไหม โอเคหรือเปล่า ยืนมือมาหน่อยได้ไหมคะ ยืนมือมากอดกัน ไม่เป็นไร	Anhedonic
สุดท้ายคนตายคือคนที่ถูกลืม พวกเขาจะค่อยๆหายไปจากความทรงจำ	Suicidal Ideation
หวังว่าตัวเองจะมีความสุข หวังว่าตัวเองจะมีอิสระ หวังแค่นั้นแหละ หวังที่เป็นไปไม่ได้สักอย่าง	Anhedonic
ต่อหน้าทุกคนคุณเป็นคนดี พอลับหลังทุกคนคุณก็คือนางมารร้ายคนนึง	Other
มีแค่มือเส้นนี้ก็ไปได้แล้ว	Suicidal Ideation
ฉันยังมีค่าอยู่ไหม	Anhedonic
เหมือนความรู้สึกแย่มาก่าลังกลับมาอีกแล้ว ความสุขของผมกำลังหายไป หรือจริงๆแล้วผมไม่เคยมีความสุข	Anhedonic
พ่อแม่ร้ายแค้น เป็นคำที่หนูควรพูดไม่ใช่ พ่อพูดกับหนู หนูเป็นแบบนี้เพราะ ใคร	Other
ผมเจ็บปวด	Anhedonic
ถึงไม่ได้ดีอะไรมาก แต่สิ่งที่ไม่เคยหายไปเลยคือความรู้สึกอยากตาย	Suicidal Ideation
เกรดไม่ใช่ทุกอย่างของชีวิต แต่เกรดเป็นสิ่งต้องยื่นเข้ามาหลาย	Other
ขอกำลังใจจากทุกคนได้ไหมคะ	Other
อย่าลืมกินยาบ่อยนักสิ	Anhedonic
ท้อ รู้สึกแย้ไปหมด	Anhedonic

ภาพประกอบ 6 ตัวอย่างข้อมูลที่ใช้สร้างแบบจำลอง

3.3 การระบุประเภทข้อมูล (Data Labeling)

ชุดข้อมูลที่ใช้ในงานวิจัยเป็นข้อมูลที่ถูกใช้ในงานวิจัยมาก่อน โดยชุดข้อมูลนี้มีนักจิตวิทยาการปรึกษาของคณะจิตวิทยา จุฬาลงกรณ์มหาวิทยาลัย ทำการระบุประเภทของข้อมูล

ในการระบุประเภทข้อมูลทางผู้วิจัยและนักจิตวิทยาการศึกษามีเกณฑ์ในการคัดเลือกและระบุประเภทข้อมูลดังนี้

3.1 ทางผู้วิจัยก่อนหน้าได้ทำการเปลี่ยน username ของผู้โพสต์เป็นนามแฝง ก่อนจะนำข้อมูลไปให้นักจิตวิทยาการปรึกษาทำการระบุประเภทข้อมูล เพื่อป้องกันข้อมูลส่วนบุคคล

3.2 นักจิตวิทยาการปรึกษาจะทำการระบุประเภทข้อมูลตามอาการของภาวะซึมเศร้า 4 อาการ ได้แก่ Suicidal Ideation (ความคิดอยากฆ่าตัวตาย) Anhedonic (ภาวะสิ้นยินดี) Sleep Problems (ปัญหาการนอนหลับ) และ Guilty Feelings (ความรู้สึกผิด) หากข้อความไม่จัดอยู่ใน 4 อาการของภาวะซึมเศร้าข้างต้น นักจิตวิทยาการปรึกษาจะจัดข้อความนั้นให้อยู่ในกลุ่มของ Other (ไม่มีอาการของภาวะซึมเศร้าหรืออาการอื่น ๆ) จากเกณฑ์การคัดเลือกดังกล่าว มีจำนวนข้อความทั้งหมด 3,100 ข้อความ

3.4 การทำความสะอาดข้อมูล (Data Cleansing)

ในขั้นตอนนี้จะเป็นการทำความสะอาดข้อมูล สามารถแบ่งขั้นตอนออกได้เป็นดังนี้

1. ข้อมูลดิบ (Raw Data) มีข้อความที่มีคำศัพท์เป็นภาษาวัยรุ่นที่ไม่มีในพจนานุกรมภาษาไทย ทำให้ผู้อ่านบางคนตีความหมายผิดไป จึงทำการเปลี่ยนคำศัพท์ที่เป็นภาษาวัยรุ่นให้เป็นคำศัพท์ที่อยู่ในพจนานุกรมภาษาไทย เช่น “คอต” เปลี่ยนเป็น “โคตร” และ “เรย” เปลี่ยนเป็น “เลย” ดังภาพประกอบ 7

กำลังใจ 🎵 🎸 🎶	Other	#highhot #ซึมเศร้า
คอต ดิง! เลยตอนนี่ 🤔	Anhedonic	#ตัวคนเดียว #ซึมเศร้า
ล้มล้มมันมานาน หรือ ไม่เคยล้มล้มมันเรย 😞 🤔	Other	#ซึมเศร้า

ภาพประกอบ 7 ข้อความที่เป็นข้อมูลดิบเป็นภาษาวัยรุ่น

2. จัดการกับสัญลักษณ์ต่าง ๆ ที่ไม่มีความหมาย โดยการเปลี่ยนเป็นข้อความว่าง

3.5 การเตรียมข้อมูล (Data Preprocessing)

ขั้นตอนการเตรียมข้อมูล สามารถแบ่งขั้นตอนออกได้เป็นดังนี้

1. ทำการสำรวจข้อมูลโดยพบว่า มี Emoji อยู่ในข้อความ จึงทำการแยก Emoji ออกจากข้อความ เพื่อเก็บไว้ใช้พิจารณาในภายหลัง ซึ่งในงานวิจัยนี้จะดูเฉพาะส่วนที่ข้อความ

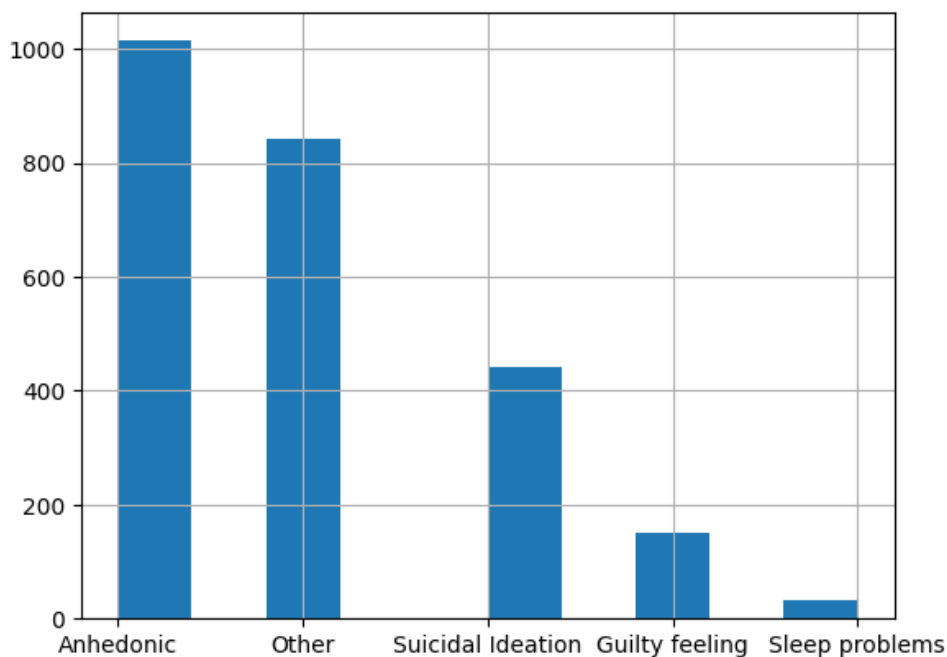
2. การลบอักขระพิเศษ URLs และ Hashtag ต่าง ๆ

3. ทำการตัดคำ (Word tokenization) (Newmm Attacut และBPE) และจัดการกับคำที่เขียนผิด เรียงผิดหรือใช้ผิดอักษร (Normalization) เช่น "แ" พิมพ์เป็น "เ" หรือ "ต้น" เป็นต้น โดยใช้ไลบรารี PyThaiNLP

3.6 การสำรวจข้อมูลเบื้องต้น (Exploratory Data Analysis)

ขั้นตอนการสำรวจข้อมูล สามารถแบ่งขั้นตอนออกได้เป็นดังนี้

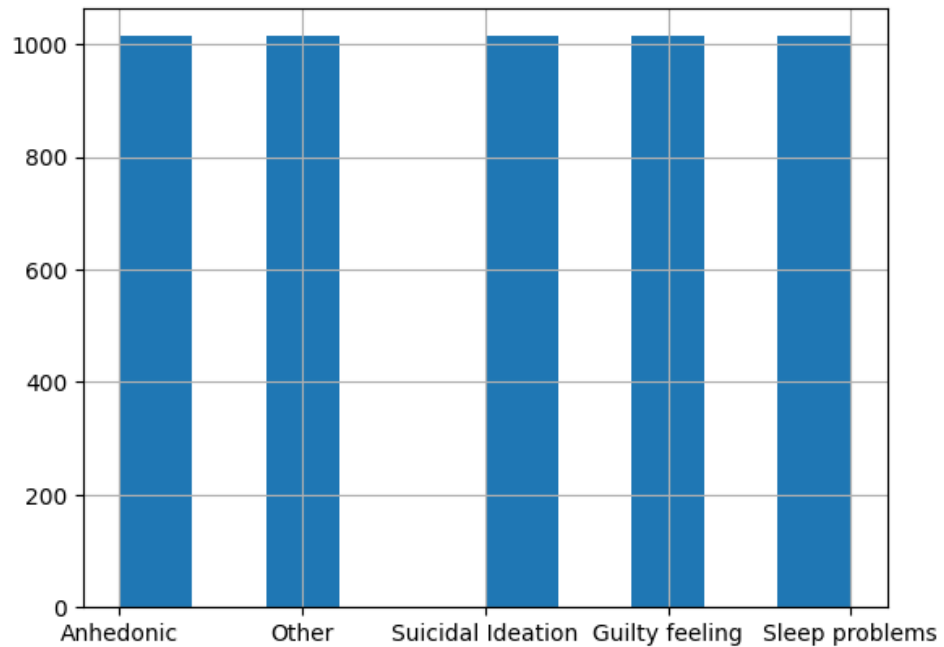
1. ทำการสำรวจข้อมูลดูจำนวนข้อมูลในแต่ละอาการของภาวะซึมเศร้า หากมีจำนวนที่แตกต่างกันมากหรือเป็นชุดข้อมูลที่ไม่สมดุล (Imbalanced Data) จะต้องทำการเพิ่มหรือลดจำนวนข้อมูลให้ใกล้เคียงกัน ดังภาพประกอบ 8



ภาพประกอบ 8 แสดงจำนวนข้อมูลแต่ละ Label

จากภาพประกอบ 8 พบว่า จำนวนข้อมูลในแต่ละอาการของภาวะซึมเศร้า มีจำนวนที่แตกต่างกันมาก (Imbalance Data)

2. ใช้เทคนิค SMOTE-Cosine ทำให้ชุดข้อมูลมีจำนวนข้อความในแต่ละอาการของภาวะซึมเศร้ามีจำนวนเท่ากัน และทำการนับจำนวนข้อความ ดังภาพประกอบ 9 และตัวอย่างข้อความหลังจากการทำเทคนิค SMOTE-Cosine ดังภาพประกอบ 10



ภาพประกอบ 9 แสดงจำนวนของข้อมูลหลังการใช้เทคนิค SMOTE-Cosine

	text	label
0	อยากตายไปวันนี้จัง ใกล้เคียงวันเกิดเราแล้ว ขอของ...	Suicidal Ideation
1	เหมือนเป็นโรคซึมเศร้า	Anhedonic
2	อยากมีเพื่อนบ้างจัง ห่อและเหนียวมากนะ	Anhedonic
3	มีแต่คนบอกว่าเรานะ สมบูรณ์แบบแล้ว มีครอบครัวท...	Anhedonic
4	ทำไมเรามันไร้ค่าแบบนี้	Guilty feeling
...
5730	นอนไม่ค่อยหลับติดต่อกันมาหลายคืนแล้ว ร่างกายเร...	Sleep problems
5731	นอนไม่ค่อยหลับติดต่อกันมาหลายคืนแล้ว ร่างกายเร...	Sleep problems
5732	นอนไม่ค่อยหลับติดต่อกันมาหลายคืนแล้ว ร่างกายเร...	Sleep problems
5733	ร่างกายเพลียมากวะ ง่วงนอน แต่ไม่อยากหลับกลัวฝ...	Sleep problems
5734	นอนไม่ค่อยหลับติดต่อกันมาหลายคืนแล้ว ร่างกายเร...	Sleep problems

5735 rows × 2 columns

ภาพประกอบ 10 แสดงตัวอย่างข้อความหลังการใช้เทคนิค SMOTE-Cosine

จากภาพประกอบ 10 พบว่า ข้อความที่ได้หลังจากการทำเทคนิค SMOTE-Cosine ข้อความที่เพิ่มใหม่มีการระบุประเภทของข้อความถูกต้องตามข้อมูลเดิม โดยจำนวนข้อมูลที่ใช้ในขั้นตอนการฝึกฝน มีจำนวน 5,735 ข้อความ

จากการนับความยาวของคำในแต่ละประโยค พบว่า จำนวนคำในประโยคที่ยาวที่สุด มีจำนวน 91 คำ ดังภาพประกอบ 11 และตัวอย่างของประโยคที่ยาวที่สุด ดังภาพประกอบ 12

```
df["length"].describe()
```

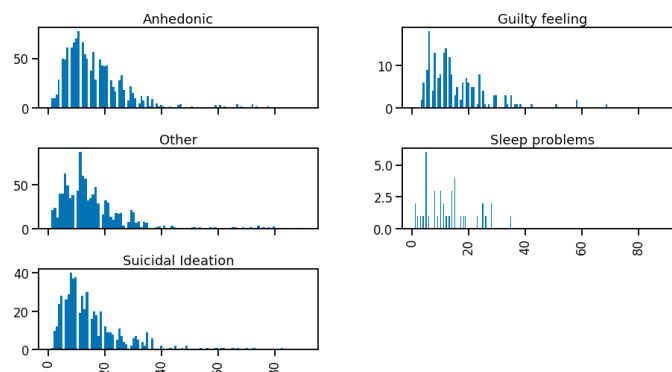
```
count    3100.000000
mean     16.095484
std      12.073826
min       1.000000
25%      8.000000
50%     13.000000
75%     20.000000
max      91.000000
Name: length, dtype: float64
```

ภาพประกอบ 11 สถิติแสดงจำนวนในการนับคำ

No.	Date / Time	Name	text	label	Hashtag	นามแทน	emoji	sentence	length
2224	2021-04-03 17:44:37	AAe	คำว่า "สู้ชนะ" มันคืออะไรที่ชนะ แต่มันก็ไม่ได้ไปสักทีเสีย สำหรับคนที่ เป็น #โรคซึมเศร้า แล้ว มันแย่มากสำหรับทุกคน เพราะพวกเขาต้องดูแลตัวเองโดยตลอด ต่อสู้กับโรคพวกนี้ พวกมันเป็นสิ่งที่เรากลากออกทุก คนว่า "พวกคุณเข้มแข็งมากเลยนะ" และ "เราสู้ไปด้วยกันนะ" (เรารู้สึกว่าพวกคุณนะ)	Other	#โรคซึมเศร้า	supportive tweet	☺	คำว่า สู้ชนะ มันคืออะไรที่ชนะ แต่มันก็ไม่ได้ไปสักทีเสีย สำหรับคนที่ เป็นโรคซึมเศร้า แล้ว มันแย่มากสำหรับทุกคน เพราะพวกเขาต้องดูแลตัวเองโดยตลอด ต่อสู้กับโรคพวกนี้ พวกมันเป็นสิ่งที่เรากลากออกทุก คนว่า "พวกคุณเข้มแข็งมากเลยนะ" และ "เราสู้ไปด้วยกันนะ" (เรารู้สึกว่าพวกคุณนะ)	91

ภาพประกอบ 12 แสดงข้อความที่มีจำนวนคำที่ยาวที่สุดในชุดข้อมูล

3. ทำการสำรวจความยาวของคำในแต่ละประโยคในแต่ละอาการของภาวะซึมเศร้า พบว่า ความยาวของคำในแต่ละประโยคแต่ละอาการของภาวะซึมเศร้า มีความยาวที่ใกล้เคียงกัน ดังภาพประกอบ 13



ภาพประกอบ 13 แสดงความยาวของคำในแต่ละประเภทของอาการภาวะซึมเศร้า

ภาพประกอบ 15 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า

แบบ Other

จากภาพประกอบ 15 จะเห็นว่าคำที่มีความถี่มากที่สุดและเกี่ยวข้องกับข้อความที่เป็นอาการของภาวะซึมเศร้า Other คือ ยิ้ม ชีวิต เก่ง เป็นต้น



ภาพประกอบ 16 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า


แบบ Suicidal Ideation

จากภาพประกอบ 16 จะเห็นว่าคำที่มีความถี่มากที่สุดและเกี่ยวข้องกับข้อความที่เป็นอาการของภาวะซึมเศร้า Suicidal Ideation คือ ตาย ความตาย หาย เป็นต้น



ภาพประกอบ 17 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า
แบบ Guilty Feelings

จากภาพประกอบ 17 จะเห็นว่าคำที่มีความถี่มากที่สุดและเกี่ยวข้องกับข้อความที่เป็นอาการของภาวะซึมเศร้า Guilty Feelings คือ รู้สึก ขอโทษ ดี เกลียด เป็นต้น



ภาพประกอบ 18 แสดงตัวอย่าง Word Cloud ที่ปรากฏในอาการของภาวะซึมเศร้า
แบบ Sleep Problems

จากภาพประกอบ 18 จะเห็นว่าคำที่มีความถี่มากที่สุดและเกี่ยวข้องกับข้อความที่เป็นอาการของภาวะซึมเศร้า Sleep Problems คือ นอน นอนไม่หลับ ฝันร้าย เป็นต้น

3.7 สร้างคุณลักษณะของข้อมูลข้อความ (Feature Engineering)

ในขั้นตอนการสร้างคุณลักษณะของข้อมูลข้อความ สามารถแบ่งขั้นตอนออกได้เป็นดังนี้

1. ทำการแปลงคุณลักษณะของข้อมูลที่ไม่ใช่ข้อความ ให้อยู่ในรูปแบบที่สามารถนำไปใช้งานกับ Deep Learning ได้ โดยทำการแปลงอาการของภาวะซึมเศร้า ที่เป็น Anhedonic แทนด้วย 0 Other แทนด้วย 1 Suicidal Ideation แทนด้วย 2 Guilty Feelings แทนด้วย 3 และ Sleep Problems แทนด้วย 4 ดังภาพประกอบ 19

```
train["label"] = train["label"].map({"Anhedonic": 0, "Other": 1, "Suicidal Ideation": 2, "Guilty feeling": 3, "Sleep problems": 4})
test["label"] = test["label"].map({"Anhedonic": 0, "Other": 1, "Suicidal Ideation": 2, "Guilty feeling": 3, "Sleep problems": 4})
```

ภาพประกอบ 19 การแปลงคุณลักษณะของอาการของภาวะซึมเศร้า

2. ทำการสร้างคุณลักษณะของข้อมูลที่เป็นข้อความที่เป็นข้อความที่ตัดคำมาแล้วให้เป็นตัวเลข โดยวิธี Word Embedding ใช้ thai2vec เพื่อเตรียมข้อมูลก่อนจะนำเข้าแบบจำลองเพื่อเรียนรู้ ดังภาพประกอบ 20

	0	1	2	3	4	5	6	7	8	9	...	290	291	292	293	294
ที่	0.308956	-0.097699	0.116745	0.215612	0.015768	-0.064163	0.062168	0.039649	0.864940	0.846904	...	-0.142418	0.033241	0.171581	-0.624864	-0.009358
และ	0.010751	-0.618971	0.129665	0.035460	-0.007560	0.027607	0.397824	0.026543	0.254075	0.168328	...	-0.105786	0.180930	-0.101630	0.070885	-0.037263
เป็น	-0.015736	-0.258926	0.052953	0.153728	-0.005985	-0.021081	0.041088	0.057312	1.633230	0.442729	...	-0.009408	-0.252576	-0.305512	0.372542	0.049151
ของ	-0.189711	-0.174774	0.171124	-0.186771	0.054294	-0.114150	-1.109456	-0.094466	-0.447015	0.042377	...	-0.168676	-0.148738	0.680404	0.097702	0.020270
มี	-0.156962	-0.231863	0.080312	0.323157	0.215695	0.055145	0.420794	0.016842	0.256759	0.832864	...	-0.044267	-0.147186	-0.105424	0.907078	0.009299
ได้	-0.428813	-0.031194	0.041922	-0.036608	-0.008106	0.076470	-0.782270	0.033361	0.606864	0.440520	...	0.024458	-0.025031	0.103389	-0.078255	0.034323
.....	-0.287710	0.064193	0.205076	0.146356	-0.071343	-0.039451	-1.845461	0.163763	1.018096	0.272786	...	0.051024	-0.532856	-0.131856	-0.090323	-0.058895
การ	0.239587	-0.303620	0.079953	-0.453045	-0.528826	-0.161692	0.235725	-0.099673	0.691668	0.536159	...	-0.110436	-0.297495	-0.217414	0.045158	0.066647
(-0.120522	-0.355783	0.168180	-0.377733	-0.158624	-0.047249	0.361140	0.161460	0.913314	0.345037	...	0.116285	-0.318218	-0.356664	0.519889	0.130475
)	-0.086848	-0.155231	0.133015	-0.039913	0.183761	0.115142	-1.940854	-0.066565	-2.399744	0.146722	...	0.019406	-0.181474	0.099863	0.516092	0.201697

10 rows × 300 columns

ภาพประกอบ 20 แสดงตัวอย่างการสร้างคุณลักษณะโดยวิธี Word Embedding ใช้ thai2vec

3.8 การแบ่งข้อมูลสำหรับชุดฝึกฝนและชุดทดสอบ

ข้อมูลที่ผ่านกระบวนการแปลงคุณลักษณะของข้อความ ข้อมูลจะถูกแบ่งออกเป็นสองส่วน เพื่อใช้ในการสร้างแบบจำลองในการจำแนก และทดสอบประสิทธิภาพของแบบจำลองโดยทำการแบ่งชุดข้อมูลตัวอย่างแบบชั้นภูมิ (Stratified sampling) เป็นชุดข้อมูลฝึกฝน 90 เปอร์เซ็นต์ และชุดข้อมูลทดสอบ 10 เปอร์เซ็นต์ ตามตาราง 4

ตาราง 4 คลังข้อมูลที่แบ่งชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ

ลำดับ	อาการของภาวะซึมเศร้า	ชุดข้อมูลฝึกฝน	ชุดข้อมูลทดสอบ
1	Anhedonic	1,146	128
2	Other	945	105
3	Suicidal Ideation	496	55
4	Guilty Feelings	167	18
5	Sleep Problems	36	4

3.9 การสร้างแบบจำลองการจำแนก (Classification Model)

การสร้างแบบจำลองการเรียนรู้เชิงลึกเพื่อใช้ในการงานการจำแนกประเภทในงานวิจัยนี้ อัลกอริทึมที่เราสนใจใช้ในงานวิจัยและเปรียบเทียบประสิทธิภาพของแบบจำลองมี 3 ประเภท ดังนี้ 1) BiLSTM 2) Thai-BERT 3) WangchanBERTa โดยจะทำการปรับค่า พารามิเตอร์ตามแต่ละแบบจำลองดังนี้

3.9.1 การสร้างแบบจำลองด้วยอัลกอริทึม BiLSTM

อัลกอริทึม BiLSTM เป็นโครงข่ายประสาทเทียมที่ต่อยอดมาจาก Recurrent Neural Network (RNN) และดีกว่า Long Short-Term Memory networks (LSTM) เป็นการปรับปรุงของ LSTM โดยที่มีทั้ง forward และ backward states ที่สามารถเรียนรู้ลำดับข้อมูลได้ในทั้งสองทิศทาง ในขณะที่ LSTM เพียงเรียนรู้ลำดับข้อมูลเพียงทิศเดียว (forward) ซึ่ง RNN มีปัญหาที่เรียกว่า vanishing gradient problem ที่ทำให้มีปัญหาในการเรียนรู้ระยะไกลในลำดับข้อมูล ในขณะที่ LSTM และ BiLSTM ได้รับการออกแบบมาเพื่อแก้ปัญหานี้ ดังนั้น BiLSTM มีประสิทธิภาพในการเรียนรู้ลำดับข้อมูลที่ยาวได้ดีกว่า RNN ในส่วนของ LSTM มีเซลล์หน่วยที่ช่วยในการจดจำและลืมข้อมูล ซึ่งทำให้เหมาะสำหรับงานที่ต้องการความสามารถในการจดจำระยะยาว แต่ว่า BiLSTM มีข้อดีที่สามารถดึงข้อมูลจากทั้งสองทิศทางทำให้เหมาะสำหรับงานที่ต้องการความเข้าใจลำดับของข้อมูลทั้งก่อนและหลังเหตุการณ์ ซึ่งในบางกรณีอาจเหมาะสำหรับงาน NLP ที่ต้องการการเข้าใจความหมายของประโยคที่อ้างถึงบทความทั้งหมด โดยพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองมีดังนี้ ตามตาราง 5 และตารางผลลัพธ์สรุปของแบบจำลองที่ได้จากการใช้พารามิเตอร์ ตามตาราง 6

ตาราง 5 ตารางแสดงค่าพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองด้วยอัลกอริทึม BiLSTM

ชื่อพารามิเตอร์	ค่าพารามิเตอร์
Layer 1	Bidirectional, 128 units
Dropout	0.2
Layer 2	Bidirectional, 64 units
Dropout	0.2
Dense Layer	32 units
Activation Function	ReLU
L2 Regularization	0.001

Dense Layer	5 units
Activation Function	SoftMax
Optimizers	Adam
Learning Rate	1e-5
Epoch	100

ตาราง 6 ตารางแสดงผลลัพธ์สรุปของอัลกอริทึม BiLSTM ที่ได้จากการใช้พารามิเตอร์ข้างต้น

Layer (Type)	Output Shape	Param#
input_1 (InputLayer)	[(None, 98)]	0
embedding (Embedding)	(None, 98, 300)	15407700
bidirectional (Bidirectional)	(None, 98, 256)	439296
bidirectional_1 (Bidirectional)	(None, 128)	164352
dense (Dense)	(None, 32)	4128
dense_1 (Dense)	(None, 5)	165
Total params: 16,015,641		
Trainable params: 16,015,641		
Non-trainable params: 0		

แบบจำลองการตรวจจับภาวะซึมเศร้าด้วยคุณลักษณะ Word Embedding โดยทำการสร้างคุณลักษณะของข้อความขึ้นมาจากจำนวนคำศัพท์ที่เราได้ทำการกำหนดขึ้นและจำนวนมิติของ Word Embedding เมื่อได้คุณลักษณะของข้อมูลแล้วจะทำการแปลงให้อยู่ในรูปของคุณลักษณะที่สามารถนำมาสร้างแบบจำลองได้ จากนั้นทำการทดสอบประสิทธิภาพของแบบจำลองและบันทึกผล

3.9.2 การสร้างแบบจำลองด้วยอัลกอริทึม Thai-BERT

อัลกอริทึม Thai-BERT ทางเราได้เรียกใช้ผ่าน Simple Transformer และ Hugging Face ซึ่งเป็นเครื่องมือสำหรับการทำงานกับโมเดล Transformer ในการประมวลผลข้อมูลที่เกี่ยวข้องกับการเรียนรู้เชิงลึก (deep learning) โดยเฉพาะในงานที่เกี่ยวข้องกับปัญหาที่เกี่ยวข้อง

กับภาษาธรรมชาติ เช่น การแปลภาษา หรือ สร้างสรรค์ข้อความ (text generation) เป็นต้น โดยพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองมีดังนี้ ตามตาราง 7



ตาราง 7 ตารางแสดงค่าพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองด้วยอัลกอริทึม Thai-BERT

ชื่อพารามิเตอร์	ค่าพารามิเตอร์
reprocess_input_data	True
train_batch_size	8
use_early_stopping	True
early_stopping_metric	mmc
early_stopping_patience	5
weight_decay	0.1
adam_epsilon	1e-8
learning_rate	1e-5
max_seq_length	91
num_train_epochs	20

3.9.3 การสร้างแบบจำลองด้วยอัลกอริทึม WangchanBERTa

อัลกอริทึม WangchanBERTa ทางเราได้เรียกใช้ผ่าน Simple Transformer และ Hugging Face เช่นเดียวกันกับ อัลกอริทึม Thai-BERT โดยพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองมีดังนี้ ตามตาราง 8

ตาราง 8 ตารางแสดงค่าพารามิเตอร์ที่ใช้ในการสร้างแบบจำลองด้วยอัลกอริทึม

WangchanBERTa

ชื่อพารามิเตอร์	ค่าพารามิเตอร์
reprocess_input_data	True
train_batch_size	8
use_early_stopping	True
early_stopping_metric	mmc
early_stopping_patience	5
weight_decay	0.1
adam_epsilon	1e-8
learning_rate	1e-5
max_seq_length	91
num_train_epochs	20

3.10 การประเมินประสิทธิภาพของแบบจำลอง (Model Evaluation)

นำแบบจำลองที่ได้มาทดสอบกับข้อมูลทดสอบแบบจำลองการจำแนกข้อความ และนำมาเปรียบเทียบประสิทธิภาพของแต่ละแบบจำลองที่สามารถให้ค่าประสิทธิภาพที่สูงที่สุด โดยพิจารณาจาก Confusion Matrix ซึ่งมี 4 ค่า ได้แก่ Accuracy, Precision, Recall และ F1-score

เนื่องจากชุดข้อมูลที่นำมาใช้ในงานวิจัยมีจำนวนน้อยและไม่สมดุล (Imbalanced Data) ทั้งในชุดฝึกฝนและชุดทดสอบ ทางเราจึงพิจารณาให้ความสำคัญของจำนวนแต่ละอาการของภาวะซึมเศร้าให้เท่าเทียม และเราจึงพิจารณาการใช้ Macro-averaging, Micro-averaging, หรือ Weighted-averaging เพื่อปรับค่าความสำคัญของแต่ละกลุ่มให้เหมาะสมกับการประเมินผลของโมเดล จากตาราง 5 คลังข้อมูลที่แบ่งชุดข้อมูลฝึกฝนและชุดข้อมูลทดสอบ แสดงให้เห็นว่าจำนวนในชุดทดสอบบางอาการของภาวะซึมเศร้ามีจำนวนที่น้อยกว่าบางอาการในจำนวนหลายเท่าตัว ดังนั้น เราจึงพิจารณาใช้ Weighted-averaging ที่คำนวณค่า Precision, Recall, F1-score คำนวณโดยนำน้ำหนักของแต่ละกลุ่มตัวอย่างมาในการคำนวณ เหมาะสำหรับการทำงานกับข้อมูลที่มีขนาดที่ไม่สมดุลกันและมีความสำคัญที่แตกต่างกันของแต่ละกลุ่ม

บทที่ 4

ผลการดำเนินการวิจัย

ความสำคัญของงานวิจัยนี้ในการตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์ด้วยการสร้างแบบจำลองการเรียนรู้เชิงลึก โดยผลการทดลองของงานวิจัยจะแบ่งเป็นสองส่วนที่ประกอบไปด้วย ผลการประเมินประสิทธิภาพจากการเปรียบเทียบแบบจำลองทั้งสามอัลกอริทึม และผลการประเมินประสิทธิภาพจากการเปรียบเทียบจากการใช้เทคนิคการตัดคำที่แตกต่างกันของสองอัลกอริทึม

การเปรียบเทียบผลการประเมินประสิทธิภาพจากการเปรียบเทียบแบบจำลองทั้งสามอัลกอริทึมโดยใช้ตัวตัดคำที่เป็นค่าเริ่มต้นและอ้างอิงจากงานวิจัยก่อนหน้า ได้แก่ BiLSTM, Thai-BERT และ WangchanBERTa พบว่าแบบจำลองที่สามารถตรวจจับอาการภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์ได้มีความถูกต้องที่สุดด้วยเมตริกซ์ที่สำคัญสำหรับการวัดประสิทธิภาพของแบบจำลองด้วยค่า F1-score โดยเรียงจากมากไปน้อย คือ WangchanBERTa (BPE) ที่ 0.732 Thai-BERT (Newmm) ที่ 0.686 และ BiLSTM+ReLU (Attacut) ที่ 0.683 ตามตาราง 9

ตาราง 9 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลองด้วยการใช้ตัวตัดคำเริ่มต้น

แบบจำลอง (ตัวตัดคำเริ่มต้น)	F1-score	Recall	Precision	Accuracy
BiLSTM+ReLU (Attacut)	0.683	0.684	0.685	0.684
Thai-BERT (Newmm)	0.686	0.687	0.686	0.687
WangchanBERTa (BPE)	0.732	0.732	0.733	0.732

เมื่อพิจารณาผลประสิทธิภาพของแบบจำลองทั้งสามอัลกอริทึม ทางเราจึงนำแบบจำลอง WangchanBERTa และ Thai-BERT ทำการทดลองโดยใช้ตัวตัดคำที่แตกต่างกันต่อไป เนื่องจากอัลกอริทึม BiLSTM+ReLU เป็นแบบจำลองที่งานวิจัยก่อนหน้าได้ทำการทดลองก่อน ในงานวิจัยนี้ต้องการพัฒนาประสิทธิภาพจากงานวิจัยก่อนหน้า จึงนำอัลกอริทึมตระกูลของ BERT มาทดลองและเปรียบเทียบประสิทธิภาพกับแบบจำลองของงานวิจัยก่อนหน้า เนื่องด้วย


อัลกอริทึมที่นำมาทั้งสองอัลกอริทึม ใช้สถาปัตยกรรมเครือข่ายประสาทที่ซับซ้อนและมีขนาดใหญ่กว่า BiLSTM มาก อีกทั้งยังผ่านการฝึกฝนด้วยชุดข้อมูลภาษาไทยขนาดใหญ่

การเปรียบเทียบผลการประเมินประสิทธิภาพจากการเปรียบเทียบแบบจำลองทั้งสามอัลกอริทึมโดยใช้ตัวตัดคำที่แตกต่างกัน 1) Newmm 2) Attacut 3) BPE พบว่าแบบจำลองที่สามารถตรวจจับอาการภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์ได้มีความถูกต้องที่สุด ด้วยเมตริกซ์ที่สำคัญสำหรับการวัดประสิทธิภาพของแบบจำลองด้วยค่า F1-score คือ WangchanBERTa และเทคนิคการตัดคำที่ใช้คือ Newmm ที่ 0.742 รองลงมาคือ BPE ที่ 0.732 และ Attacut ที่ 0.722 และในส่วนของแบบจำลอง Thai-BERT ที่ใช้เทคนิคการตัดคำที่ได้ผลที่ดีที่สุดคือ Newmm Attacut และ BPE ตามลำดับ ดังตาราง 10 และเพื่อแสดงให้เห็นถึงประสิทธิภาพการทำนายของอัลกอริทึมในแต่ละคลาส จึงแสดงผล confusion matrix ระหว่าง WangchanBERTa และ Thai-BERT ที่ใช้เทคนิคการตัดคำ Newmm ดังภาพประกอบ 21 และแสดงผลกราฟ ROC Curve ของอัลกอริทึม WangchanBERTa และ Thai-BERT ที่ใช้เทคนิคการตัดคำแบบ Newmm ดังภาพประกอบ 22 และ 23 ตามลำดับ


ตาราง 10 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลองด้วยการใช้ตัวตัดคำที่แตกต่างกัน

แบบจำลอง (ตัวตัดคำต่าง ๆ)	F1-score	Recall	Precision	Accuracy
Thai-BERT (Newmm)	0.686	0.687	0.686	0.687
Thai-BERT (Attacut)	0.665	0.665	0.666	0.665
Thai-BERT (BPE)	0.663	0.665	0.665	0.665
WangchanBERTa (Newmm)	0.742	0.742	0.747	0.742
WangchanBERTa (Attacut)	0.722	0.723	0.727	0.723
WangchanBERTa (BPE)	0.732	0.732	0.733	0.732

The confusion matrix of WangchanBERTa algorithm




The confusion matrix of Thai-BERT algorithm

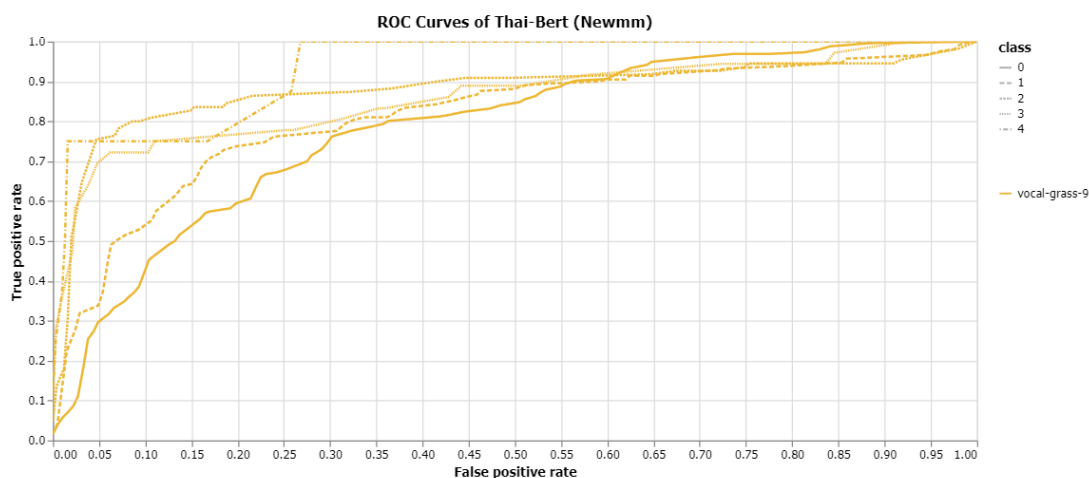


ภาพประกอบ 21 แสดง Confusion Matrix ระหว่างแบบจำลอง WangchanBERTa และ Thai-BERT โดยใช้เทคนิคการตัดคำ Newmm

ROC Curves of WangchanBERTa (Newmm)



ภาพประกอบ 22 แสดงกราฟ ROC Curve ของอัลกอริทึม WangchanBERTa โดยใช้เทคนิคการตัดคำ Newmm



ภาพประกอบ 23 แสดงกราฟ ROC Curve ของอัลกอริทึม Thai-BERT โดยใช้เทคนิคการตัดคำ Newmm

จากภาพประกอบ 21 Confusion Matrix พบว่าแบบจำลองทั้งสองอัลกอริทึมมีการทำนายผิดพลาดเยอะระหว่าง Anhedonic และ Other ทางเราจึงทำการเปรียบเทียบประสิทธิภาพของแบบจำลองทั้งสองอัลกอริทึมโดยแบ่งตามอาการของภาวะซึมเศร้า ดังตาราง 11 สำหรับแบบจำลอง WangchanBERTa และตาราง 12 สำหรับแบบจำลอง Thai-BERT

จากภาพประกอบ 22 และ 23 กราฟ ROC Curve แสดงถึงประสิทธิภาพของอัลกอริทึมที่สามารถตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยตามอาการของภาวะซึมเศร้า ยิ่งเส้นกราฟอยู่ชิดมุมบนซ้ายมากเท่าไร แสดงว่าอัลกอริทึมสามารถแยกแยะข้อมูลได้ถูกต้องแม่นยำมากขึ้น จากกราฟจะเห็นว่าเส้นของแต่ละคลาสโค้งขึ้นสูงอยู่เหนือเส้นทแยง แสดงว่าทั้งสองอัลกอริทึมมีความสามารถในการจำแนกอาการซึมเศร้าได้ดี โดยเฉพาะคลาส Guilty Feelings (3) และคลาส Sleep Problems (4) ที่มีพื้นที่ใต้กราฟมากที่สุด เมื่อพิจารณากราฟ ROC Curve แต่ละอัลกอริทึมพบว่า อัลกอริทึม WangchanBERTa (Newmm) มีประสิทธิภาพดีกว่าอัลกอริทึม Thai-BERT (Newmm)

ตาราง 11 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลอง WangchanBERTa โดยแบ่งตามอาการของภาวะซึมเศร้า

อาการของภาวะซึมเศร้า	F1-score	Recall	Precision	Accuracy
Anhedonic	0.739	0.773	0.707	0.774
Other	0.727	0.686	0.774	0.826
Suicidal Ideation	0.800	0.800	0.800	0.929
Guilty Feelings	0.684	0.722	0.650	0.961
Sleep Problems	0.667	0.500	1.000	0.994

ตาราง 12 ตารางแสดงประสิทธิภาพการจำแนกของแบบจำลอง Thai-BERT โดยแบ่งตามอาการของภาวะซึมเศร้า

อาการของภาวะซึมเศร้า	F1-score	Recall	Precision	Accuracy
Anhedonic	0.667	0.664	0.669	0.726
Other	0.707	0.724	0.691	0.797
Suicidal Ideation	0.766	0.746	0.789	0.919
Guilty Feelings	0.487	0.500	0.434	0.939
Sleep Problems	0.667	0.500	1.000	0.994

เมื่อเปรียบเทียบผลประสิทธิภาพของแบบจำลองเพื่อใช้ในการตรวจจับอาการของภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์สรุปได้ว่า แบบจำลองที่เหมาะสมที่สุดคือ WangchanBERTa โดยใช้เทคนิคการตัดคำ Newmm

บทที่ 5

สรุปผลการวิจัย อภิปรายผล และข้อเสนอแนะ

ในการทำวิจัย ผู้วิจัยได้วัดประสิทธิภาพของแบบจำลองแต่ละเทคนิคเพื่อนำมาเปรียบเทียบและสรุปผล โดยสามารถแบ่งหัวข้อในการสรุปผลได้ดังต่อไปนี้

5.1 สรุปผลการวิจัย

5.2 อภิปรายผลการวิจัย

5.3 ข้อเสนอแนะ

5.1 สรุปผลการวิจัย

ในงานวิจัยนี้ได้ศึกษาการจำแนกข้อความ (Text Classification) ด้วยการใช้อัลกอริทึมการเรียนรู้เชิงลึก (Deep Learning) เพื่อสร้างแบบจำลองในการจำแนกประเภทของอาการของภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์ที่เก็บรวบรวมข้อมูลมาจาก Twitter โดยข้อมูลที่นำมาใช้ในงานวิจัยเป็นข้อมูลจากงานวิจัยที่เกี่ยวข้อง ผลลัพธ์การทดลองพบว่า อัลกอริทึม WangchanBERTa ที่ใช้เทคนิคการตัดคำแบบ BPE ที่เป็น default ของอัลกอริทึมมีประสิทธิภาพในการตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยดีกว่าอัลกอริทึมอื่น มีค่า F-1 score, Recall และ Accuracy 73.2% Precision 73.3% และผลการทดลองที่ใช้เทคนิคการตัดคำ 3 แบบ พบว่าอัลกอริทึม WangchanBERTa ยังคงมีประสิทธิภาพดีกว่าอัลกอริทึมอื่น โดยใช้เทคนิคการตัดคำแบบ Newmm มีค่า F-1 score, Recall และ Accuracy 74.2% Precision 74.7% และสามารถนำแบบจำลองที่ได้จากงานวิจัยครั้งนี้ ไปใช้ในการตรวจจับภาวะซึมเศร้าจากข้อความของผู้ใช้สื่อสังคมออนไลน์ได้ ตลอดจนสามารถนำแบบจำลองไปพัฒนาเป็นโปรแกรมตอบโต้ข้อความอัตโนมัติ (Chatbot) เพื่อประยุกต์ใช้ในการรักษาผู้ป่วยโรคซึมเศร้าได้

ปัจจัยและข้อจำกัดที่ส่งผลกระทบต่อการศึกษาของงานวิจัยนี้ คือ ข้อมูลที่นำมาใช้ในงานวิจัย เนื่องจากเป็นชุดข้อมูลที่ใช้ในงานวิจัยที่เกี่ยวข้องที่มีการระบุข้อความแต่ละประเภทตามอาการของภาวะซึมเศร้าโดยนักจิตวิทยาการปรึกษา คณะจิตวิทยา จุฬาลงกรณ์มหาวิทยาลัย ทำให้มีความน่าเชื่อถือในชุดข้อมูล แต่ด้วยปริมาณข้อมูลมีจำนวนน้อย ประกอบกับข้อความที่ระบุอาการของภาวะซึมเศร้า บางอาการมีจำนวนน้อยกว่าอีกอาการเกือบ 20 เท่า จึงส่งผลกระทบต่อแบบจำลองการเรียนรู้เชิงลึกที่ต้องใช้ข้อมูลในปริมาณมากในการฝึกฝนการเรียนรู้ รวมถึงทรัพยากรและการตั้งค่าระบบต่าง ๆ ของเครื่อง ทำให้ประสิทธิภาพของแบบจำลองที่ได้ไม่ค่อยดี

5.2 อภิปรายผล

งานวิจัยนี้ได้ดำเนินการทดลองและประเมินประสิทธิภาพของแบบจำลองต่างๆ เปรียบเทียบกัน ผลการทดลองพบว่าอัลกอริทึม WangchanBERTa ให้ผลลัพธ์ที่ดีที่สุดเมื่อเทียบกับอัลกอริทึมอื่น ๆ ทั้งในกรณีที่ใช้เทคนิคการตัดคำแบบเริ่มต้นและเทคนิคการตัดคำที่แตกต่างกัน โดยเทคนิคการตัดคำแบบ Newmm ให้ประสิทธิภาพสูงสุด อย่างไรก็ตาม เมื่อเปรียบเทียบประสิทธิภาพของอัลกอริทึมในงานวิจัยนี้กับผลการทดลองในงานวิจัยก่อนหน้าพบว่า แม้ผู้วิจัยจะได้พยายามปรับค่าพารามิเตอร์ของอัลกอริทึม BiLSTM+ReLU เพื่อให้ได้ผลลัพธ์ที่สอดคล้องกับงานวิจัยก่อนหน้า แต่ก็ไม่สามารถทำซ้ำ (reproduce) ผลการทดลองเดิมได้ ดังนั้น ทางผู้วิจัยจึงตัดสินใจทำการฝึกฝนอัลกอริทึม BiLSTM+ReLU ขึ้นใหม่ตั้งแต่ต้น เพื่อใช้เป็นแบบจำลองพื้นฐาน (baseline) แล้วนำมาเปรียบเทียบกับอัลกอริทึม Thai-BERT และ WangchanBERTa ซึ่งพบว่า WangchanBERTa ให้ประสิทธิภาพที่ดีที่สุด เพื่อทำความเข้าใจสาเหตุที่ประสิทธิภาพของอัลกอริทึมยังไม่เทียบเท่ากับผลในงานวิจัยก่อนหน้า ทางผู้วิจัยจึงได้ดำเนินการวิเคราะห์ข้อผิดพลาดเชิงลึก (error analysis) เพิ่มเติม เพื่อให้เข้าใจปัญหาและข้อจำกัดของอัลกอริทึมและชุดข้อมูลมากขึ้น ดังนี้

5.2.1 ขนาดของชุดข้อมูล

ผลการทดลองชี้ให้เห็นว่าชุดข้อมูลที่ใช้ในงานวิจัยมีข้อจำกัดสองประการหลัก ๆ คือ ขนาดของชุดข้อมูลที่ค่อนข้างเล็ก และความไม่สมดุลของข้อมูล (imbalanced data) ในแต่ละประเภทอาการของภาวะซึมเศร้า

ประเด็นแรก ขนาดของชุดข้อมูลที่เล็กอาจส่งผลให้แบบจำลองไม่สามารถเรียนรู้รูปแบบและลักษณะเฉพาะของข้อมูลได้อย่างครอบคลุมและมีประสิทธิภาพเพียงพอ เนื่องจากข้อมูลที่ใช้ในการฝึกฝนโมเดลมีจำนวนจำกัด ทำให้โมเดลอาจไม่สามารถจับความสัมพันธ์ที่ซับซ้อนหรือรูปแบบที่หลากหลายของข้อมูลได้ดี ส่งผลให้เกิดข้อผิดพลาดในการทำนายหรือจำแนกประเภทของข้อมูลใหม่ ๆ

ประเด็นที่สอง ความไม่สมดุลของข้อมูลในแต่ละประเภทอาการของภาวะซึมเศร้า โดยพบว่าบางอาการที่มีจำนวนข้อมูลน้อยกว่าอาการอื่น ๆ ถึงเกือบ 20 เท่า ความไม่สมดุลนี้อาจทำให้แบบจำลองเรียนรู้และให้น้ำหนักกับอาการที่มีข้อมูลมากเป็นพิเศษ ในขณะที่อาการที่มีข้อมูลน้อยอาจไม่ได้รับการเรียนรู้เพียงพอ ส่งผลให้เกิดอคติ (bias) ในการทำนาย และอาจทำให้ประสิทธิภาพโดยรวมของแบบจำลองลดลง

5.2.2 ความสับสนของการระบุประเภทข้อมูลและคำศัพท์

การวิเคราะห์กลุ่มคำ (Word Cloud) ของชุดข้อมูลที่ใช้ในการฝึกฝนแบบจำลอง พบว่ามีการใช้คำทั่วไป (common word) ที่เกี่ยวข้องกับภาวะซึมเศร้าในทุกประเภทอาการ ซึ่งสอดคล้องกับผลการวิจัยของ “ภาษา การสื่อสาร และโรคซึมเศร้า: การสำรวจแนวทางพัฒนาการสื่อสารด้านโรคซึมเศร้าเพื่อคุณภาพชีวิตที่ยั่งยืนของเยาวชนไทย” (จันทิมา อังคพนิชกิจ, 2019)

ยกตัวอย่างเช่น ในอาการ Suicidal Ideation ซึ่งเกี่ยวข้องกับความคิดฆ่าตัวตาย กลับพบว่าคำที่เกี่ยวข้องโดยตรง เช่น "อยากตาย" หรือ "อยากฆ่าตัวตาย" มีขนาดเล็กในกลุ่มคำ ในขณะที่คำทั่วไปอย่าง "ตัวเอง" "เรา" หรือ "ความสุข" กลับมีขนาดใหญ่กว่า ซึ่งแสดงให้เห็นว่าคำที่ปรากฏบ่อยในข้อความไม่ได้สะท้อนถึงลักษณะเฉพาะของอาการนั้น ๆ อย่างชัดเจน

นอกจากนี้ ยังพบความผิดพลาดจากการระบุประเภทอาการโดยนักจิตวิทยาการปรึกษาเอง ยกตัวอย่างเช่น ข้อความ "ทรมาน" ถูกจัดอยู่ในสองประเภทอาการ คือ Other และ Anhedonic ซึ่งอาจสร้างความสับสนให้กับแบบจำลองในการเรียนรู้ลักษณะเฉพาะของแต่ละประเภท

ข้อผิดพลาดเหล่านี้ ทั้งในแง่ของการใช้คำทั่วไปที่พบในหลายประเภทอาการ และความไม่สอดคล้องในการระบุประเภทอาการโดยผู้เชี่ยวชาญ อาจส่งผลให้แบบจำลองเกิดความสับสนและมีประสิทธิภาพในการจำแนกประเภทอาการได้ไม่ดีเท่าที่ควร เนื่องจากข้อมูลที่ใช้ในการเรียนรู้มีความคลุมเครือและไม่ชัดเจนเพียงพอ

5.3 ข้อเสนอแนะ

จากการวิเคราะห์ผลการวิจัย และการวิเคราะห์ข้อผิดพลาดเชิงลึก (Error Analysis) พบว่างานวิจัยนี้มีประเด็นที่น่าสนใจและมีความสำคัญต่อความเข้าใจเกี่ยวกับการตรวจจับภาวะซึมเศร้าจากข้อความภาษาไทยบนสื่อสังคมออนไลน์ อย่างไรก็ตามยังมีบางประเด็นที่ควรพิจารณาเพิ่มเติมเพื่อพัฒนาคุณภาพและความสมบูรณ์ของงานวิจัย ดังนี้

5.3.1 ด้านของการปรับปรุงคุณภาพของข้อมูล

จากผลการวิจัยพบว่าปัจจัยสำคัญที่ส่งผลต่อประสิทธิภาพของแบบจำลองในการจำแนกอาการของภาวะซึมเศร้า คือ ขนาดของชุดข้อมูลที่ค่อนข้างเล็ก และความคล้ายคลึงของคำศัพท์ในข้อความ ซึ่งส่วนใหญ่เป็นคำทั่วไป (common word) ที่พบได้ในผู้ที่มีภาวะซึมเศร้า (จันทิมา อังคพนิชกิจ, 2019) ดังนั้น เพื่อพัฒนาประสิทธิภาพของแบบจำลอง ควรมีการเพิ่มขนาดของชุดข้อมูล และจัดการกับปัญหาความคล้ายคลึงของคำศัพท์ เช่น การใช้เทคนิคการเพิ่มข้อมูล

(data augmentation) ด้วยการสร้างข้อความสังเคราะห์ที่มีความหลากหลายมากขึ้น หรือการใช้เทคนิคการแปลงข้อความ (text transformation) เพื่อสร้างรูปแบบข้อความที่แตกต่างออกไป

5.3.2 ด้านของการปรับปรุงคุณภาพของแบบจำลอง

งานวิจัยนี้ได้ทำการเปรียบเทียบประสิทธิภาพของอัลกอริทึม BiLSTM, Thai-BERT และ WangchanBERTa เท่านั้น ซึ่งในงานวิจัยต่อไปอาจมีการทดลองใช้อัลกอริทึมอื่น ๆ เพิ่มเติมเพื่อค้นหาแบบจำลองที่เหมาะสมที่สุดกับลักษณะของชุดข้อมูลนี้ นอกจากนี้ อาจพิจารณาการปรับแต่งพารามิเตอร์ของแบบจำลอง (model tuning) หรือการใช้เทคนิคการเรียนรู้เชิงลึกขั้นสูง เช่น attention mechanism หรือ การเรียนรู้แบบถ่ายโอน (transfer learning) แบบอื่น ๆ เพื่อพัฒนาความสามารถของแบบจำลองในการจับใจความสำคัญและความแตกต่างระหว่างอาการต่าง ๆ

5.3.3 ด้านของการปรับปรุงปริมาณของข้อมูล

เนื่องจากงานวิจัยนี้ใช้ข้อมูลจากแหล่งข้อมูลเดียว และมีปริมาณค่อนข้างน้อย ซึ่งอาจไม่เพียงพอสำหรับการฝึกฝนแบบจำลองการเรียนรู้เชิงลึกให้มีประสิทธิภาพสูงสุด ดังนั้นในการพัฒนาต่อยอดงานวิจัย ควรมีการรวบรวมข้อมูลเพิ่มเติมจากแหล่งอื่น ๆ เช่น จากโซเชียลมีเดีย บทความ หรือเว็บไซต์ที่เกี่ยวข้องกับภาวะซึมเศร้า เพื่อเพิ่มความหลากหลายและปริมาณของข้อมูล ซึ่งจะช่วยให้แบบจำลองสามารถเรียนรู้รูปแบบของอาการต่าง ๆ ได้ครอบคลุมและแม่นยำมากขึ้น อย่างไรก็ตาม ในการเก็บข้อมูลเพิ่มเติมนั้น จำเป็นต้องคำนึงถึงจริยธรรมและความเป็นส่วนตัวของผู้ใช้งานด้วย

บรรณานุกรม

- Bidirectional LSTM. (2020). <https://paperswithcode.com/method/bilstm>
- Chawla, V., Bowyer, W., Hall, O., และ Kegelmeyer, W. P. (2011). SMOTE: Synthetic Minority Over-sampling Technique, arXiv:1106.1813.
- Chormai, P., Prasertsom, P., และ Rutherford, A. (2019). AttaCut: A Fast and Accurate Neural Thai Word Segmenter, arXiv:1911.07056.
- Devlin, J., Chang, M.-W., Lee, K., และ Toutanova, K. (2018). BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. *CoRR*, *abs/1810.04805*.
- Hämäläinen, M., Patpong, P., Alnajjar, K., Partanen, N., และ Rueter, J. (2021). Detecting Depression in Thai Blog Posts: a Dataset and a Baseline. *CoRR*, *abs/2111.04574*.
- Hochreiter, S., และ Schmidhuber, J. (1997). Long Short-term Memory. *Neural computation*, 9, 1735-1780.
- Husseini Orabi, A., Buddhitha, P., Husseini Orabi, M., และ Inkpen, D. (2018). *Deep Learning for Depression Detection of Twitter Users*.
- Komsan Kiatrungrit. (2016). Social Media Use and Suicide. Retrieved from <https://www.rama.mahidol.ac.th/ramachannel/en/article/%e0%b8%9b%e0%b8%b1%e0%b8%8d%e0%b8%ab%e0%b8%b2%e0%b8%81%e0%b8%b2%e0%b8%a3%e0%b9%83%e0%b8%8a%e0%b9%89%e0%b8%aa%e0%b8%b7%e0%b9%88%e0%b8%ad%e0%b8%aa%e0%b8%b1%e0%b8%87%e0%b8%84%e0%b8%a1%e0%b8%ad%e0%b8%ad/>
- Koto, F. (2014). *SMOTE-Out, SMOTE-Cosine, and Selected-SMOTE: An enhancement strategy to handle imbalance in data level*. Paper presented at the 2014 International Conference on Advanced Computer Science and Information System.
- Lam, G., Dongyan, H., และ Lin, W. (2019). *Context-aware Deep Learning for Multi-modal Depression Detection*. Paper presented at the ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP).
- Lewinsohn, P. M., Rohde, P., Seeley, J. R., Klein, D. N., และ Gotlib, I. H. (2000). Natural course of adolescent major depressive disorder in a community sample: predictors

- of recurrence in young adults. *Am J Psychiatry*, 157(10), 1584-1591.
- Lowphansirikul, L., Polpanumas, C., Jantrakulchai, N., และ Nutanong, S. (2021). WangchanBERTa: Pretraining transformer-based Thai Language Models. *CoRR*, *abs/2101.09635*.
- Oh Jihoon, Yun Kyongsik, Maoz Uri, Kim Tae-Suk, และ Jeong-Ho, C. (2019). Identifying depression in the National Health and Nutrition Examination Survey data using a deep learning algorithm. *Journal of Affective Disorders*, 257, 623-631.
- Ottavio, C. (2022). An Intuitive Explanation of LSTM.
<https://medium.com/@ottaviocalzone/an-intuitive-explanation-of-lstm-a035eb6ab42c>
- Pakawat Nakwijit. (2020). ทำความเข้าใจ BERT.
- Phattharayuttawat, S., Ngamthipwattana, T., และ Sukhatungkha, K. (1999). The norm profile for 'the thai mental health questionnaire'. *Age (year)*, 15(20), 212.
- Phatthiyaphaibun, W., Chaovavanich, K., Polpanumas, C., Suriyawongkul, A., Lowphansirikul, L., Chormai, P., . . . Udomcharoenchaikit, C. (2023). *PyThaiNLP: Thai Natural Language Processing in Python*, Singapore.
- Q. Cong, Z. Feng, F. Li, Y. Xiang, G. Rao, และ Tao, C. (2018). *X-A-BiLSTM: a Deep Learning Approach for Depression Detection in Imbalanced Data*. Paper presented at the 2018 IEEE International Conference on Bioinformatics and Biomedicine (BIBM).
- S. Mahasiriakalayot, T. Senivongse, และ Taephant, N. (2022). *Predicting Signs of Depression from Twitter Messages*. Paper presented at the 2022 19th International Joint Conference on Computer Science and Software Engineering (JCSSE).
- Sennrich, R., Haddow, B., และ Birch, A. (2015). Neural Machine Translation of Rare Words with Subword Units, arXiv:1508.07909.
- Spijker, J., de Graaf, R., Bijl, R. V., Beekman, A. T., Ormel, J., และ Nolen, W. A. (2002). Duration of major depressive episodes in the general population: results from The Netherlands Mental Health Survey and Incidence Study (NEMESIS). *Br J Psychiatry*, 181, 208-213.

- Tadesse, M. M., Lin, H., Xu, B., และ Yang, L. (2019). Detection of Depression-Related Posts in Reddit Social Media Forum. *IEEE Access*, 7, 44883-44893.
- William, D., และ Suhartono, D. (2021). Text-based Depression Detection on Social Media Posts: A Systematic Literature Review. *Procedia Computer Science*, 179, 582-589.
- Wongpatikaseree, K., Yomaboot, P., Katchapakirin, K., และ Kaewpitakkun, Y. (2020). Social Behavior Analysis and Thai Mental Health Questionnaire (TMHQ) Optimization for Depression Detection System. *IEICE Transactions on Information and Systems*, E103.D, 771-778.
- World Health Organization. (2021). Depressive disorder (depression).
<https://www.who.int/news-room/factsheets/detail/depression#:~:text=An%20estimated%203.8%25%20of%20the.among%20women%20than%20among%20men.>
- Yates, A., Cohan, A., และ Goharian, N. (2017). Depression and Self-Harm Risk Assessment in Online Forums, arXiv:1709.01848.
<https://ui.adsabs.harvard.edu/abs/2017arXiv170901848Y>
- Zogan, H., Wang, X., Jameel, S., และ Xu, G. (2020). Depression Detection with Multi-Modalities Using a Hybrid Deep Learning Model on Social Media. *CoRR*, abs/2007.02847.
- จันทิมา อังคพณิชกิจ. (2019). ภาษา การสื่อสาร และโรคซึมเศร้า: การสำรวจแนวทางพัฒนาการสื่อสารด้านโรคซึมเศร้าเพื่อคุณภาพชีวิตที่ยั่งยืนของเยาวชนไทย: มหาวิทยาลัยธรรมศาสตร์
- ดำรงเดช เติมนิรมย์, ฉัตรเกล้า เจริญผล, และ จริยา จิรานุกูล. (2016). การเปรียบเทียบประสิทธิภาพโครงสร้างเหมืองข้อมูลเพื่อจำแนกโรคซึมเศร้าจากพฤติกรรมการโพสต์ข้อความบนทวิตเตอร์. *วารสารวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยมหาสารคาม*, 39(3), 331-343.
- ธรรณิษฐ์ กองสุข, พิเชฐ อุดมรัตน์, สุวรรณมา อรุณพงศ์ไพศาล, มาโนช หล่อตระกูล, ณรงค์ มณีทอง, นันทวิช สิริธิรักษ์, . . . เคนบุปผา, เ. (2008). ความสัมพันธ์ระหว่างเหตุการณ์ความเครียดในชีวิตกับการเกิดโรคซึมเศร้าในผู้ป่วยที่มารับบริการของโรงพยาบาลมหาวิทยาลัย 5 แห่ง ปี 2549. *วารสารสมาคมจิตแพทย์แห่งประเทศไทย*, 53(1), 61-68.
- สำนักงานปลัดกระทรวงสาธารณสุข. (2021). รายงานการเข้าถึงบริการของผู้ป่วยโรคซึมเศร้า

ปีงบประมาณ 2564. https://thaidepression.com/www/report/main_report/
สำนักงานพัฒนาธุรกรรมทางอิเล็กทรอนิกส์ กระทรวงดิจิทัลเพื่อเศรษฐกิจและสังคม. (2021).
เอกสารการแถลงผลการสำรวจพฤติกรรมผู้ใช้อินเทอร์เน็ตในประเทศไทย ปี 2564.
สุวรรณภา อรุณพงศ์ไพศาล, และ สรยุทธ วาสิกนันทน์. (2015). ตำราโรคซึมเศร้า (1). ขอนแก่น: คลัง
น่านวิทยา.



ประวัติผู้เขียน

ชื่อ-สกุล

จตุรวิทย์ อัจหาญ

