

การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้าบนแพลตฟอร์มโซเชียลมีเดียในบริบทของธุรกิจออนไลน์

The Application of Deep Learning Techniques in Analyzing Customer Opinions on Social Media Platforms in a Business Context Online

อัคราภรณ์ นาชัยทอง^{1,*} และศิรินทิพย์ อ้วนศรีเมือง²

Atcharaporn Nachaithong^{1,*} and Sirinthip Ouansrimeang²

Received : December 27, 2024 Revised : March 19, 2025 Accepted : March 26, 2025

บทคัดย่อ

โซเชียลมีเดียเป็นช่องทางหลักที่ลูกค้าใช้แสดงความคิดเห็นเกี่ยวกับผลิตภัณฑ์และบริการ ซึ่งข้อมูลเหล่านี้สามารถนำมาใช้วิเคราะห์เพื่อพัฒนากลยุทธ์ทางธุรกิจได้ อย่างไรก็ตาม การจำแนกความคิดเห็นของลูกค้าจากข้อความที่มีโครงสร้างหลากหลายและภาษาที่ไม่เป็นทางการเป็นความท้าทายสำคัญที่ต้องอาศัยเทคนิคการเรียนรู้เชิงลึกเพื่อเพิ่มความแม่นยำในการวิเคราะห์ การวิจัยนี้มีวัตถุประสงค์ 1) เพื่อวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดียและสามารถระบุและจำแนกความรู้สึกเชิงบวก เชิงลบ และเป็นกลาง 2) เพื่อประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดีย การวิจัยนี้เป็นการวิจัยเชิงประยุกต์ที่ใช้เทคนิคการเรียนรู้เชิงลึกเพื่อวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดีย เช่น ทวิตเตอร์และเฟซบุ๊ก โดยเริ่มต้นจากการรวบรวมข้อมูลความคิดเห็นจากลูกค้าในทั้งสองแพลตฟอร์มดังกล่าว จากนั้นทำการทำความสะอาดข้อมูล (Data Cleaning) และเตรียมข้อมูลเพื่อให้พร้อมสำหรับการวิเคราะห์ ต่อไปจะใช้โมเดลการเรียนรู้เชิงลึกในการจำแนกความคิดเห็นออกเป็นสามประเภทหลัก ได้แก่ ความรู้สึกเชิงบวก ความรู้สึกเชิงลบ และความรู้สึกเป็นกลาง การประเมินผลการทำงานของโมเดลจะใช้ตัวชี้วัดสำคัญคือ ความถูกต้อง ความแม่นยำ ความระลึก และความถ่วงดุล เพื่อประเมินประสิทธิภาพของโมเดลในการจำแนกความคิดเห็นของลูกค้า ผลการวิจัยพบว่า 1) โมเดล BERT มีความถูกต้องสูงสุดในการจำแนกความคิดเห็น โดยความถูกต้องในการจำแนกความรู้สึกเชิงบวกสูงถึง 93.0% และเชิงลบ 92.8% โมเดล LSTM มีความถูกต้อง 89.2% แต่ยังไม่เทียบเท่าโมเดล BERT ในการจำแนกความรู้สึกเชิงบวก ส่วนโมเดล CNN มีความถูกต้อง 86.9% และมีประสิทธิภาพต่ำกว่าทั้งโมเดล BERT และโมเดล LSTM ในการจับความหมายที่ซับซ้อน 2) ผลการประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกพบว่า BERT มีความถูกต้องสูงสุดที่ 92.5%, LSTM มีความถูกต้อง 88.7%, และ CNN มีความถูกต้อง 86.3% ตามลำดับ

คำสำคัญ: การวิเคราะห์ความรู้สึก การเรียนรู้เชิงลึก การประมวลผลภาษาธรรมชาติ การวิเคราะห์โซเชียลมีเดีย

^{*}ผู้ช่วยศาสตราจารย์ คณะบริหารธุรกิจและการบัญชี มหาวิทยาลัยราชภัฏร้อยเอ็ด

¹ Assistant Professor, Faculty of Business Administration and Accountancy Roi Et Rajabhat University

² กองคลังและพัสดุ มหาวิทยาลัยมหาสารคาม

² Division of Finance & Facilities, Mahasarakham University

* Corresponding author : atcharaporn_ju@reru.ac.th

Abstract

Social media has become a primary channel for customers to express their opinions on products and services, providing valuable insights for business strategy development. However, classifying customer opinions from diverse text structures and informal language presents a significant challenge, requiring deep learning techniques to enhance the accuracy of sentiment analysis. This research aims to 1) Analyze customer feedback from social media platforms and identify and classify sentiments as positive, negative and neutral. And 2) Evaluate the performance of deep learning models in analyzing customer feedback from social media platforms. This research is applied research that utilizes deep learning techniques to analyze customer feedback from social media platforms such as Twitter and Facebook. The process begins by collecting customer feedback from both platforms. The data is then cleaned and prepared for analysis. Next, deep learning models are used to classify the feedback into three main categories positive sentiment, negative sentiment and neutral sentiment. The model's performance will be evaluated using four key metrics accuracy, precision, recall and F1-score to assess the effectiveness of the model in classifying customer feedback. The results of the study showed that. 1.) The BERT model achieved the highest accuracy in classifying sentiments with an accuracy of 93.0% for positive sentiment and 92.8% for negative sentiment. The LSTM model had an accuracy of 89.2% but it did not perform as well as BERT in classifying positive sentiment. The CNN model had an accuracy of 86.9% and its performance was lower than both BERT and LSTM in capturing complex meanings. And 2) The performance evaluation of the deep learning models revealed that BERT achieved the highest accuracy at 92.5% followed by LSTM with an accuracy of 88.7% and CNN with an accuracy of 86.3% respectively.

Keywords : Sentiment Analysis, Deep Learning, Natural Language Processing (NLP), Social Media Analytics

1. บทนำ

ในยุคดิจิทัล โซเชียลมีเดียกลายเป็นช่องทางหลักที่ผู้คนใช้ในการสื่อสารและแบ่งปันความคิดเห็น รวมถึงข้อมูลที่เกิดจากการแสดงออกในรูปแบบต่าง ๆ เช่น ข้อความ ภาพ หรือวิดีโอ ซึ่งสะท้อนความรู้สึกและความคิดเห็นของผู้ใช้ ข้อมูลเหล่านี้จึงกลายเป็นแหล่งสำคัญที่สามารถนำไปใช้ในการวิเคราะห์เพื่อพัฒนากลยุทธ์ทางการตลาดได้อย่างมีประสิทธิภาพ (Hernández-Romero et al., 2023) การวิเคราะห์ความคิดเห็นหรือความรู้สึกจากข้อความบนโซเชียลมีเดียเป็นส่วนหนึ่งของกระบวนการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) ซึ่งมุ่งเน้นการจำแนกข้อความตามอารมณ์ เช่น ความรู้สึกเชิงบวก เชิงลบ หรือเป็นกลาง การวิเคราะห์ดังกล่าวช่วยให้เข้าใจความคิดเห็นของลูกค้า และสามารถนำข้อมูลเชิงลึกไปใช้ในการพัฒนาสินค้า การออกแบบแคมเปญการตลาด การปรับปรุงบริการลูกค้า และการสร้างความภักดีต่อแบรนด์ (Zhang et al., 2020)

หนึ่งในความท้าทายของการวิเคราะห์ความรู้สึกจากโซเชียลมีเดียคือความหลากหลายของรูปแบบภาษาที่ผู้ใช้เลือกใช้ ซึ่งรวมถึงคำแสลง ภาษาไม่เป็นทางการ การใช้สัญลักษณ์หรืออิโมจิที่อาจมีความหมายแฝงทำให้การวิเคราะห์อารมณ์มีความซับซ้อนสูง นอกจากนี้ การใช้จำนวนทวิตหรือการสื่อสารในบริบทเฉพาะอาจทำให้เกิดความเข้าใจผิดได้ เช่น การใช้ “อิโมจิหน้ายิ้ม” อาจไม่ได้หมายถึงความสุขเสมอไป อาจแฝงความหมายเชิงลบ การตีความในกรณีเหล่านี้จึงต้องอาศัยการเข้าใจบริบทอย่างละเอียด หากโมเดลไม่สามารถจับบริบทได้อย่างถูกต้อง อาจส่งผลให้การวิเคราะห์เกิดความคลาดเคลื่อน

เทคนิคการเรียนรู้เชิงลึกถือเป็นเทคโนโลยีที่สำคัญในการวิเคราะห์ข้อมูลที่มีความซับซ้อน โดยมีความสามารถในการสกัดคุณลักษณะที่ซ่อนอยู่จากข้อมูลได้อย่างมีประสิทธิภาพ โมเดลที่ได้รับความนิยมในการวิเคราะห์ข้อมูลได้แก่ โครงข่ายประสาทเทียมแบบลำดับ (Recurrent Neural Network: RNN) โครงข่ายประสาทเทียมแบบคอนโวลูชัน (Convolutional Neural

Network: CNN) และโมเดลทรานส์ฟอร์มเมอร์ (Transformer Models) ซึ่งเทคนิคเหล่านี้สามารถเรียนรู้จากบริบทที่ซับซ้อนของข้อความได้อย่างมีประสิทธิภาพ ทำให้สามารถระบุความรู้สึกและความหมายที่แฝงอยู่ได้อย่างแม่นยำ (Brown et al., 2020) การวิเคราะห์ข้อความจากโซเชียลมีเดียจึงเป็นเครื่องมือที่มีประสิทธิภาพในการปรับปรุงกลยุทธ์ทางการตลาด ช่วยให้ธุรกิจสามารถตอบสนองต่อความต้องการของลูกค้าได้อย่างรวดเร็วและตรงจุด นอกจากนี้ การนำเทคนิคการเรียนรู้เชิงลึกมาประยุกต์ใช้ในการวิเคราะห์ข้อมูลยังเพิ่มความแม่นยำและประสิทธิภาพในการดำเนินการ (Messaoudi et al., 2022; Win Myint et al., 2024)

การวิเคราะห์ข้อมูลจากโซเชียลมีเดียยังคงเผชิญกับความท้าทายหลายประการ คือ (1) ความหลากหลายของภาษาบนโซเชียลมีเดีย เช่น คำแสลง ภาษาไม่เป็นทางการ และอิโมจิ ที่อาจส่งผลกระทบต่อความแม่นยำของการวิเคราะห์ (2) การจำแนกความคิดเห็นของลูกค้าท่ามกลางข้อมูลที่มีบริบทซับซ้อนและไม่เป็นโครงสร้าง (3) การเลือกและปรับแต่งโมเดลการเรียนรู้เชิงลึกให้เหมาะสมเพื่อเพิ่มประสิทธิภาพในการวิเคราะห์ความคิดเห็นของลูกค้า ดังนั้น วัตถุประสงค์หลักของการวิจัยนี้ คือ วิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดีย ที่สามารถระบุ จำแนกความรู้สึกเชิงบวก เชิงลบ และเป็นกลาง อีกทั้งประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดียผลลัพธ์ ผลจากการวิจัยนี้จะถูกนำไปใช้ในการปรับปรุงกลยุทธ์การตลาด ช่วยให้ธุรกิจสามารถเข้าใจความคิดเห็นของลูกค้า และนำข้อมูลเชิงลึกไปใช้วางแผนการออกแบบแคมเปญการตลาด และการบริการลูกค้าได้อย่างมีประสิทธิภาพ

2. วัตถุประสงค์ของการวิจัย

2.1 เพื่อวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดียและสามารถระบุและจำแนกความรู้สึกเชิงบวก เชิงลบ และเป็นกลาง

2.2 เพื่อประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดีย

3. เอกสารงานวิจัยที่เกี่ยวข้อง

3.1 แนวคิดการวิเคราะห์ความรู้สึก (Sentiment Analysis)

การวิเคราะห์ความรู้สึก (Sentiment Analysis) เป็นกระบวนการที่ใช้ในการจำแนกอารมณ์และความคิดเห็นจากข้อความ ซึ่งเป็นเครื่องมือที่สำคัญสำหรับธุรกิจในการทำความเข้าใจความคิดเห็นของลูกค้าต่อผลิตภัณฑ์หรือบริการ เช่น การวิเคราะห์รีวิวและการสำรวจความพึงพอใจของลูกค้า การวิเคราะห์ความรู้สึกได้รับความนิยมเพิ่มขึ้นในช่วงหลายปีที่ผ่านมา โดยเฉพาะในด้านการตลาดและการตัดสินใจทางธุรกิจ (BaŞarslan & Kayaalp, 2021) นอกจากนี้ งานวิจัยที่ผ่านมาแสดงให้เห็นว่า การวิเคราะห์ข้อความจากโซเชียลมีเดียสามารถสกัดข้อมูลเชิงลึกเกี่ยวกับความคิดเห็นเฉพาะเจาะจงของผลิตภัณฑ์หรือบริการได้อย่างมีประสิทธิภาพ ด้วยเหตุนี้ องค์การธุรกิจจึงให้ความสำคัญกับการนำการวิเคราะห์ความรู้สึก (Sentiment Analysis) มาใช้ในการวิเคราะห์ความคิดเห็นของลูกค้า เพื่อช่วยปรับปรุงผลิตภัณฑ์และพัฒนาการให้บริการให้ตรงกับความต้องการมากขึ้น

3.2 แนวคิดการพัฒนาโมเดล (Model Development)


การพัฒนาโมเดล (Model Development) คือกระบวนการสร้างและปรับปรุงโครงสร้างหรือระบบเพื่อให้สามารถตอบสนองต่อวัตถุประสงค์ที่กำหนด โดยโมเดลอาจเป็นแบบจำลองในรูปแบบคณิตศาสตร์ กราฟิก อัลกอริทึม หรือแนวทางเชิงโครงสร้างที่ใช้ในงานวิจัย การวิเคราะห์ข้อมูล หรือการพัฒนากระบวนการธุรกิจ การพัฒนาโมเดลจึงเป็นการค้นหาความจริงของปรากฏการณ์โดยการระบุส่วนประกอบหรือฟังก์ชันต่าง ๆ และตรวจสอบความสัมพันธ์ระหว่างกัน รวมถึงการประเมินว่ามีความสอดคล้องกับสภาพความเป็นจริงหรือไม่ และสามารถใช้ในการอธิบาย ทำนาย หรือพยากรณ์ได้มากน้อยเพียงใด (Chaiwichit, 2017)

3.3 แนวคิดการเรียนรู้เชิงลึก (Deep Learning)

การเรียนรู้เชิงลึก (Deep Learning) เป็นเทคโนโลยีที่มีบทบาทสำคัญในการพัฒนาประสิทธิภาพของการวิเคราะห์ความรู้สึก โดยสามารถเรียนรู้จากข้อมูลที่ซับซ้อนได้อย่างมีประสิทธิภาพ และได้รับความนิยมในงานวิเคราะห์ข้อความ โมเดลที่ใช้บ่อย ได้แก่ โครงข่ายประสาทเทียมแบบลำดับ (RNN) และโครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNN) ซึ่งมีความสามารถในการจำและประมวลผลข้อมูลลำดับได้อย่างแม่นยำ ขณะเดียวกัน CNN จะช่วยในการตรวจจับรูปแบบจากข้อความและสกัดคุณลักษณะสำคัญ การผสมผสานระหว่างโมเดลเหล่านี้ เช่น การใช้โมเดล Long Short-Term Memory (LSTM) ซึ่งพัฒนาต่อยอดจาก RNN ช่วยเพิ่มความแม่นยำในการประมวลผลภาษาธรรมชาติ (Liu, 2020) นอกจากนี้ โมเดล BERT ได้รับการพัฒนาขึ้นเพื่อเพิ่มความสามารถในการทำความเข้าใจบริบทของข้อความในสองทิศทางพร้อมกัน ซึ่งช่วยให้การวิเคราะห์ความรู้สึกมีความแม่นยำมากขึ้น โมเดลประเภท Transformer นี้สามารถเรียนรู้ความหมายของคำตามบริบทที่ซับซ้อนและรองรับการประมวลผลข้อความขนาดใหญ่ได้อย่างมีประสิทธิภาพ ทำให้การเรียนรู้เชิงลึกเป็นเครื่องมือสำคัญในการวิเคราะห์ข้อความบนโซเชียลมีเดีย และการพัฒนากลยุทธ์ทางธุรกิจที่ขับเคลื่อนด้วยข้อมูล

3.4 แนวคิดการประมวลผลภาษาธรรมชาติ (NLP)

การประมวลผลภาษาธรรมชาติ (NLP) เป็นเทคโนโลยีที่ใช้ในการวิเคราะห์ข้อความจากมนุษย์เพื่อทำความเข้าใจความรู้สึก โดยงานวิจัยหลายชิ้นได้มุ่งเน้นการพัฒนาโมเดลที่สามารถเข้าใจบริบทของข้อความที่ซับซ้อนได้ ซึ่งช่วยสร้างเวกเตอร์ที่แทนคำและใช้โมเดลการเรียนรู้เชิงลึกในการวิเคราะห์บริบทได้อย่างมีประสิทธิภาพ การประมวลผลภาษาธรรมชาติ (NLP) ถูกนำไปใช้ในหลากหลายกรณี เช่น การวิเคราะห์รีวิวสินค้า การตรวจสอบความคิดเห็นในโซเชียลมีเดีย และการติดตามความคิดเห็นบนเว็บไซต์ นอกจากนี้ยังสามารถแยกแยะข้อความที่มีความซับซ้อนหรือมีบริบทหลากหลาย เช่น การใช้คำแสดง ภาษาไม่เป็นทางการ หรือการสื่อสารผ่านสัญลักษณ์และอิโมจิ ซึ่งช่วยให้การวิเคราะห์ความรู้สึกมีความแม่นยำยิ่งขึ้น (Chakraborty et al., 2020) ด้วยความก้าวหน้าของโมเดลภาษาขนาดใหญ่ (Large Language Models: LLMs) เช่น BERT ทำให้การประมวลผลภาษาธรรมชาติมีความแม่นยำและสามารถเข้าใจบริบทที่ซับซ้อนของข้อความได้ดียิ่งขึ้น การนำเทคนิคการฝังคำ (Word Embeddings) มาช่วยแปลงคำเป็นเวกเตอร์ที่มีความหมาย ทำให้โมเดลสามารถจับความสัมพันธ์ระหว่างคำได้อย่างมีประสิทธิภาพ ส่งผลให้ NLP กลายเป็นเทคโนโลยีสำคัญที่ช่วยให้ธุรกิจสามารถนำข้อมูลจากข้อความที่ไม่มีโครงสร้างมาใช้ในการตัดสินใจเชิงกลยุทธ์ได้อย่างมีประสิทธิภาพ



รูปภาพประกอบ 1 กรอบแนวคิดการวิจัย (Conceptual Framework)

จากการทบทวนวรรณกรรม และงานวิจัยที่เกี่ยวข้องสามารถแสดงดังกรอบแนวคิดการวิจัยดังภาพประกอบ 1

4. วิธีการดำเนินการวิจัย

งานวิจัยนี้เป็นการศึกษาเชิงประยุกต์ที่ใช้เทคนิคการเรียนรู้เชิงลึก โดยจะอธิบายขั้นตอนการดำเนินการวิจัยอย่างละเอียดในแต่ละขั้นตอน เพื่อให้เข้าใจถึงกระบวนการวิจัยทั้งหมด ซึ่งประกอบด้วย 4 ขั้นตอน ดังนี้

4.1 ขั้นตอนที่ 1 การเก็บรวบรวมข้อมูล

ขั้นตอนแรกของการวิจัยคือ การเก็บรวบรวมข้อมูลจากโซเชียลมีเดีย ซึ่งเป็นแหล่งสำคัญที่สะท้อนความคิดเห็นของลูกค้านต่อผลิตภัณฑ์หรือบริการ งานวิจัยนี้มุ่งเน้นการวิเคราะห์ข้อความที่แสดงอารมณ์และความคิดเห็นของลูกค้า (Chakraborty et al., 2020) โดยเลือกใช้ Twitter และ Facebook เนื่องจากเป็นแพลตฟอร์มที่ได้รับความนิยมสูง ข้อมูลจาก Twitter ถูกดึงผ่าน API โดยคัดเลือกรีวิวที่เกี่ยวข้องกับแฮชแท็กของผลิตภัณฑ์หรือบริการ เช่น รีวิวสินค้าและบริการ (Brooklyn et al., 2024) ส่วนข้อมูลจาก Facebook มาจากโพสต์และความคิดเห็นของเพจแบรนด์หรือกลุ่มสาธารณะ โดยใช้ Facebook Graph API (Kim & Hovy, 2020) ข้อมูลทั้งหมดถูกจัดเก็บในไฟล์ .CSV เพื่อความสะดวกในการประมวลผล โดยดำเนินการเก็บข้อมูลเป็นระยะเวลา 3 เดือน (มกราคม - มีนาคม 2567) รวม 70,598 แถว และ 9 แอททริบิวต์ เพื่อให้ครอบคลุมและหลากหลายสำหรับการวิเคราะห์ความคิดเห็นของลูกค้า

4.2 ขั้นตอนที่ 2 การเตรียมและประมวลผลข้อมูล

การเตรียมข้อมูลและการประมวลผลข้อมูลเป็นขั้นตอนสำคัญในการทำให้ข้อมูลพร้อมใช้งานสำหรับการป้อนเข้าโมเดล ข้อมูลจากโซเชียลมีเดียมักมีความซับซ้อน ดังนั้น การเตรียมข้อมูลที่มีคุณภาพจึงมีบทบาทในการเพิ่มประสิทธิภาพของโมเดล โดยมีขั้นตอนดังนี้

1. การทำความสะอาดข้อมูล (Data Cleaning) ขั้นตอนแรกในการเตรียมข้อมูลคือการลบส่วนประกอบที่ไม่เกี่ยวข้อง เช่น ลิงก์ URL แฮชแท็ก (@username) อีโมจิ และข้อมูลซ้ำซ้อน ข้อมูลที่ไม่เกี่ยวข้องจะทำให้โมเดลเกิดความสับสน จึงจำเป็นต้องลบออกเพื่อลดความซับซ้อนของข้อมูล (Liu, 2020)

2. การแปลงข้อความเป็นตัวพิมพ์เล็ก (Lowercasing) ข้อความในโซเชียลมีเดียมักมีการใช้ตัวพิมพ์ใหญ่และเล็กผสมกัน การแปลงข้อความเป็นตัวพิมพ์เล็กช่วยให้การประมวลผลมีความสม่ำเสมอ และป้องกันการเกิดความสับสนในคำที่เขียนต่างกันแต่มีความหมายเหมือนกัน (Jurafsky & Martin, 2021)

3. การแยกคำและการลบคำที่ไม่สำคัญ (Tokenization and Stop word Removal) ขั้นตอนแรกในการวิเคราะห์ข้อความคือการแยกคำหรือโทเคน (Tokenization) ซึ่งช่วยให้สามารถจัดการกับข้อความได้ง่ายขึ้น จากนั้นจะทำการลบคำที่ไม่มีความหมายสำคัญทางด้านอารมณ์ (Stop words) เช่น คำเชื่อม “และ” “หรือ” “แต่” ที่ไม่ส่งผลต่อการวิเคราะห์ความรู้สึก (Jurafsky & Martin, 2021)

4. การแปลงคำเป็นเวกเตอร์ (Word Embeddings) ข้อความจะถูกแปลงจากคำเป็นตัวเลขหรือเวกเตอร์ที่โมเดลสามารถประมวลผลได้ โดยใช้เทคนิคต่าง ๆ เช่น Word2Vec, GloVe หรือ Fast Text (Wang et al., 2020) การแปลงข้อความเป็นเวกเตอร์ช่วยให้โมเดลสามารถเข้าใจและตีความความหมายของคำในบริบทต่าง ๆ ได้อย่างแม่นยำ

4.3 ขั้นตอนที่ 3 การออกแบบและพัฒนาโมเดลการเรียนรู้เชิงลึก

การออกแบบและพัฒนาโมเดลการเรียนรู้เชิงลึกเป็นหัวใจสำคัญของงานวิจัยนี้ โดยการเรียนรู้เชิงลึกมีบทบาทในการวิเคราะห์ข้อมูลที่ซับซ้อนและมีปริมาณมาก โมเดลที่ใช้ในงานวิจัยนี้ประกอบด้วยกระบวนการประมวลผลภาษาธรรมชาติ (Bidirectional Encoder Representations from Transformers: BERT) ซึ่งมีความสามารถในการเรียนรู้บริบทของคำในข้อความ ทำให้สามารถเข้าใจความหมายที่แฝงอยู่ได้อย่างแม่นยำ โดยเฉพาะกับข้อความที่มี ภาษาที่ไม่เป็นทางการ คำแสลง และความหมายแฝง ซึ่งโมเดลอื่น เช่น LSTM และ CNN อาจไม่สามารถตีความได้ดีเท่า BERT ในการจำแนกความคิดเห็นเมื่อเทียบกับโมเดลอื่นในงานวิจัยนี้ จึงเป็นทางเลือกที่เหมาะสมที่สุดสำหรับการวิเคราะห์ความคิดเห็นของลูกค้าในบริบทที่ซับซ้อน การพัฒนาโมเดล BERT สำหรับการวิเคราะห์ความรู้สึกเริ่มต้นจากการใช้ชุดข้อมูลที่ได้รับการเตรียมไว้เข้าสู่กระบวนการฝึกสอน (Training) โดยใช้วิธีการ

เรียนรู้แบบมีการกำกับ (Supervised Learning) ซึ่งมีข้อมูลที่ได้รับการติดป้ายกำกับความรู้สึก (Sentiment Label) เช่น ความรู้สึกเชิงบวก เชิงลบ และเป็นกลาง (Liu, 2020) โมเดลจะทำการเรียนรู้และปรับปรุงการทำนายผลเพื่อสามารถระบุความรู้สึกของข้อความได้อย่างแม่นยำ ผู้วิจัยให้ทำการสร้างโค้ด Python ที่ใช้สำหรับการสร้าง Data Frame ผู้วิจัยได้ดำเนินการสร้างโค้ด Python ที่ใช้สำหรับการสร้าง Data Frame ในไลบรารี Pandas โดยมีข้อมูลที่เกี่ยวข้องกับการวิจัย โดยทำการกำหนดค่า คือ

0 คือ เชิงบวก (Positive) สามารถระบุความคิดเห็นที่แสดงถึงความพึงพอใจต่อสินค้าหรือการบริการ

1 เชิงลบ (Negative) สามารถระบุความคิดเห็นที่แสดงถึงความไม่พึงพอใจต่อสินค้าหรือการบริการ

2 เป็นกลาง (Neutral) สามารถระบุความคิดเห็นที่ไม่แสดงความรู้สึกต่อสินค้าหรือการบริการ

4.4 ขั้นตอนที่ 4 การประเมินประสิทธิภาพโมเดล

หลังจากพัฒนาโมเดลในขั้นตอนที่ 3 เสร็จเรียบร้อยแล้ว และขั้นตอนที่ 4 คือ การประเมินประสิทธิภาพโมเดล (Model Evaluation) ผู้วิจัยได้ใช้วิธีการประเมินประสิทธิภาพตามวิธีเมทริกซ์สับสน (Confusion Matrix) โดยทั่วไป เมทริกซ์สับสนจะประกอบด้วยองค์ประกอบดังนี้

True Positive (TP) จำนวนของตัวอย่างที่เป็นบวกจริงและถูกทำนายว่าเป็นบวก

True Negative (TN) จำนวนของตัวอย่างที่เป็นลบจริงและถูกทำนายว่าเป็นลบ

False Positive (FP) จำนวนของตัวอย่างที่เป็นลบจริงแต่ถูกทำนายว่าเป็นบวก

False Negative (FN) จำนวนของตัวอย่างที่เป็นบวกจริงแต่ถูกทำนายว่าเป็นลบ

และขั้นตอนนี้จะใช้วิธีการเรียนรู้ของเครื่อง ได้แก่ (Brown et al., 2020; Goodfellow et al., 2020)

ค่าความถูกต้อง (Accuracy) คือ เป็นตัวชี้วัดหลักที่ใช้ในการวัดว่าจำนวนข้อมูลที่โมเดลสามารถทำนายได้ถูกต้องคิดเป็นกี่เปอร์เซ็นต์ของข้อมูลทั้งหมดที่ใช้ในการทดสอบ ความแม่นยำช่วยบอกถึงภาพรวมของความสามารถในการทำนายของโมเดล ดังสมการที่ 1

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

ค่าความแม่นยำ (Precision) คือ วัดความแม่นยำในการทำนายค่าความรู้สึกเชิงบวกหรือเชิงลบ โดยคำนวณจากอัตราส่วนระหว่างจำนวนการทำนายที่ถูกต้องกับจำนวนการทำนายทั้งหมดในแต่ละประเภทความรู้สึก ดังสมการที่ 2

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

ค่าความระลึก (Recall) คือ วัดว่าจำนวนการทำนายผลที่ถูกต้องนั้นครอบคลุมจำนวนข้อมูลที่มีป้ายกำกับถูกต้องในชุดข้อมูลทดสอบมากน้อยเพียงใด ช่วยให้เห็นภาพการทำงานของโมเดลในกรณีที่ข้อมูลมีความหลากหลาย ดังสมการที่ 3

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

ค่าความถ่วงดุล (F – measure) คือ เป็นค่าที่นำ Precision และ Recall มาคำนวณรวมกันเพื่อให้เห็นภาพการทำงานของโมเดลในกรณีที่ข้อมูลมีการกระจายตัวของความรู้สึกที่ไม่เท่ากัน มีประโยชน์มากในกรณีที่ข้อมูลมีความไม่สมดุลกันระหว่างป้ายกำกับ ดังสมการที่ 4

$$F - measure = \frac{2*Recall*Precision}{Recall+Precision} \quad (4)$$

การประเมินผลโมเดลจะใช้ ชุดข้อมูลทดสอบ (Test Data) ซึ่งไม่เคยถูกใช้ในการฝึกโมเดลมาก่อน เพื่อให้แน่ใจว่าผลลัพธ์ที่ได้จากการทำนายมีความแม่นยำ นอกจากนี้ยังมีการใช้เทคนิคการตรวจสอบค่าความถูกต้องแบบไขว้ (Cross-Validation) ซึ่งเป็นการแบ่งข้อมูลออกเป็นหลายกลุ่มแล้วฝึกและทดสอบโมเดลกับกลุ่มข้อมูลที่แตกต่างกัน เพื่อเพิ่มความน่าเชื่อถือของผลลัพธ์และป้องกันการเกิดการเรียนรู้อย่างมากเกินไป (Overfitting) ของข้อมูล

5. ผลการวิจัย

การวิเคราะห์ความคิดเห็นของลูกค้าจากโซเชียลมีเดียเพื่อนำมาปรับปรุงกลยุทธ์ทางการตลาดโดยใช้เทคนิคการเรียนรู้เชิงลึกมีวัตถุประสงค์เพื่อจำแนกความรู้สึกของลูกค้าในแพลตฟอร์มโซเชียลมีเดียเป็นสามประเภท ได้แก่ ความรู้สึกเชิงบวก เชิงลบ และเป็นกลาง พร้อมทั้งประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นดังกล่าว ผลการวิจัยสามารถรายงานได้ตามวัตถุประสงค์ดังนี้

5.1 ผลการวิจัยตามวัตถุประสงค์ข้อที่ 1 การวิเคราะห์ความคิดเห็นของลูกค้าจากโซเชียลมีเดียและการจำแนกความรู้สึกเชิงบวก เชิงลบ และเป็นกลาง การวิจัยนี้มุ่งเน้นที่การวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดีย เช่น ทวิตเตอร์และเฟซบุ๊ก เพื่อนำมาจำแนกความรู้สึก ซึ่งประกอบด้วยโมเดล BERT, โมเดล LSTM และ โมเดล CNN ผลการวิเคราะห์แสดงดังตาราง 1

ตาราง 1 ผลการวิเคราะห์ความคิดเห็นของลูกค้าจากโซเชียลมีเดียและการจำแนกความรู้สึก

โมเดล	เชิงบวก Positive	เชิงบวก Positive	เชิงบวก Positive	เชิงลบ Negative	เชิงลบ Negative	เชิงลบ Negative	ความรู้สึก
BERT	93.0%	91.5%	92.2%	92.8%	91.3%	92.0%	ความพึงพอใจและการยินดีในผลิตภัณฑ์หรือบริการ
LSTM	89.2%	87.0%	88.1%	88.5%	87.3%	87.9%	ความไม่พึงพอใจหรือปัญหาที่ลูกค้าเผชิญอยู่ในผลิตภัณฑ์หรือบริการ
CNN	86.9%	85.4%	86.1%	86.0%	84.7%	85.3%	สินค้าในร้านนี้มีหลากหลาย, การบริการปกติ

จากตาราง 1 ผลการวิเคราะห์ความคิดเห็นของลูกค้าจากโซเชียลมีเดียและการจำแนกความรู้สึก พบว่า โมเดล BERT มีความถูกต้องสูงสุดในทุกประเภทของความรู้สึก โดยสามารถระบุความคิดเห็นที่แสดงออกถึงความพึงพอใจต่อผลิตภัณฑ์หรือบริการได้อย่างแม่นยำ โดยมีความถูกต้องในการจำแนกความคิดเห็นเชิงบวกสูงถึง 93.0% และสามารถระบุความคิดเห็นที่แสดงถึงความไม่พึงพอใจหรือปัญหาของลูกค้าได้ เช่น ความผิดหวังในสินค้าและบริการ โดยมีความถูกต้องสูงถึง 92.8% โมเดล LSTM มีประสิทธิภาพในการจำแนกความรู้สึกได้ดี ซึ่งมีความถูกต้อง 89.2% แต่ยังไม่เทียบเท่ากับ โมเดล BERT โดยเฉพาะในกรณีของความรู้สึกเชิงบวก และโมเดล CNN ทำงานได้ดีในการจำแนกความรู้สึก มีความถูกต้อง 86.9% แต่จะมีประสิทธิภาพน้อยกว่าโมเดล BERT และ โมเดล LSTM โดยเฉพาะในเรื่องของความสามารถในการจับความหมายที่ซับซ้อน แต่ยังมีข้อจำกัดในการนำ

การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้าบนแพลตฟอร์มโซเชียลมีเดีย 4 / อัจฉราภรณ์ นาชัยทอง และ ศรินทิพย์ อ้วนศรีเมือง

ข้อมูลมาใช้ในการวิเคราะห์เพียงสองแพลตฟอร์ม คือ Twitter และ Facebook ซึ่งอาจไม่ครอบคลุมความคิดเห็นของลูกค้าจากแพลตฟอร์มอื่น ๆ เช่น Instagram, Tik Tok หรือ YouTube ที่มีลักษณะเนื้อหาต่างกัน


5.2 ผลการวิจัยตามวัตถุประสงค์ข้อที่ 2 ผลการประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้าจากแพลตฟอร์มโซเชียลมีเดีย

ตาราง 2 ผลการประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้า

โมเดล (Model)	ค่าความถูกต้อง (Accuracy)	ค่าความแม่นยำ (Precision)	ค่าความระลึก (Recall)	ค่าความถ่วงดุล (F – measure)
BERT	92.5%	93.0%	91.5%	92.2%
LSTM	88.7%	89.2%	87.0%	88.1%
CNN	86.3%	86.9%	85.4%	86.1%

จากตาราง 2 ผลการประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้า แสดงให้เห็นว่า โมเดลการประมวลผลภาษาธรรมชาติ (BERT) มีประสิทธิภาพสูงสุด โดยมีค่าความถูกต้องสูงสุดที่ 92.5% ในขณะที่โมเดลโครงข่ายประสาทเทียมแบบวนกลับ (LSTM) มีความถูกต้องอยู่ที่ 88.7% และโมเดลโครงข่ายประสาทแบบคอนโวลูชัน (CNN) มีความถูกต้องอยู่ที่ 86.3% ในการจำแนกความรู้สึกเชิงบวก เชิงลบ และเป็นกลางอย่างแม่นยำ โดยโมเดล BERT สามารถประยุกต์ใช้ในการพัฒนาระบบวิเคราะห์ความคิดเห็นอัตโนมัติ สำหรับธุรกิจ เช่น การวิเคราะห์แนวโน้มตลาด ช่วยให้บริษัทสามารถติดตามความคิดเห็นของลูกค้าเกี่ยวกับสินค้าและบริการแบบเรียลไทม์ได้

Performance Evaluation of Deep Learning Models in Sentiment Analysis



รูปภาพประกอบ 2

ผลการประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้า

จากรูปภาพประกอบ 2 จะพบผลลัพธ์ โมเดล BERT มีประสิทธิภาพสูงสุดในทุกตัวชี้วัด โดยได้ค่าความถูกต้อง สูงสุดที่ 92.5% และมีค่าความถ่วงดุลสูงถึง 92.2% แสดงให้เห็นถึงความสามารถในการจัดประเภทความคิดเห็นของลูกค้าได้อย่างแม่นยำที่สุดเมื่อเปรียบเทียบกับโมเดลอื่น ๆ

ผลการวิจัยที่สำคัญชี้ให้เห็นว่า การวิจัยนี้แสดงให้เห็นว่าโมเดลการประมวลผลภาษาธรรมชาติ (BERT) มีประสิทธิภาพสูงสุดในการวิเคราะห์ข้อความ เมื่อเทียบกับโครงข่ายประสาทเทียมแบบวนกลับ (LSTM) และโครงข่ายประสาทแบบคอนโวลูชัน (CNN) โดยโมเดล BERT มีค่าความแม่นยำสูงถึง 92.5% ซึ่งสูงกว่า โมเดล LSTM ที่ 88.7% และโมเดล CNN ที่ 86.3% ความโดดเด่นของโมเดล BERT มาจากโครงสร้างการเรียนรู้บริบทแบบสองทิศทาง (Bidirectional) ที่ช่วยให้โมเดลสามารถจับความหมายและบริบทเชิงลึกของข้อความได้ดียิ่งขึ้น ซึ่งเหมาะสมกับการวิเคราะห์ข้อมูลที่ซับซ้อน เช่น ข้อความในโซเชียลมีเดียที่มีการใช้คำแสดง ภาษาที่ไม่เป็นทางการ และการใช้สัญลักษณ์ภาพ (เช่น อีโมจิ) ที่ยากต่อการประมวลผลด้วยวิธีการแบบดั้งเดิม แม้ว่าโมเดล LSTM และโมเดล CNN จะมีข้อดีในการจัดการข้อมูลลำดับและตรวจจับรูปแบบในข้อความ แต่ทั้งสองโมเดลยังมีข้อจำกัดในการจับความหมายเชิงบริบทที่ซับซ้อน ทำให้โมเดล BERT เป็นตัวเลือกที่เหนือกว่าในงานที่ต้องการการวิเคราะห์ข้อมูลเชิงลึกและซับซ้อน

6. อภิปรายผลการวิจัย

การอภิปรายผลในส่วนนี้จะครอบคลุมถึงการตีความผลการวิจัยที่ได้จากวิเคราะห์ความคิดเห็นของลูกค้าจากโซเชียลมีเดียและการจำแนกความรู้สึก และผลการประเมินประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกในการวิเคราะห์ความคิดเห็นของลูกค้าโดยเน้นการตีความผลลัพธ์เชิงลึก ดังนี้

โมเดลการประมวลผลภาษาธรรมชาติ (BERT) มีประสิทธิภาพสูงสุดในการวิเคราะห์ความรู้สึกจากข้อความ โดยเฉพาะการจำแนกข้อความเชิงบวกและเชิงลบได้อย่างสมดุลด้วยค่าความแม่นยำและค่าความระลึกที่โดดเด่น รวมถึงค่าความถ่วงดุลและค่าความถ่วงดุลซึ่งแสดงถึงความสามารถในการจัดการกับข้อมูลที่ซับซ้อนและมีบริบทหลากหลาย การค้นพบนี้สอดคล้องกับงานวิจัยของ Venugopalan & Gupta (2022) ที่ระบุว่า โมเดล BERT สามารถแยกแยะความรู้สึกจากข้อความที่มีอคติ (Bias) ได้อย่างมีประสิทธิภาพ การใช้ตัวกรองความหมาย (Semantic Filtering) ยังช่วยเสริมความแม่นยำและความน่าเชื่อถือของโมเดล การศึกษาในครั้งนี้แสดงให้เห็นว่าโมเดล BERT เหมาะสมที่สุดสำหรับการวิเคราะห์ข้อมูลเชิงความรู้สึกในบริบทที่ซับซ้อน เช่น โซเชียลมีเดีย และสามารถนำไปใช้ในธุรกิจและการตลาดได้อย่างมีประสิทธิภาพ ในขณะเดียวกัน โมเดล LSTM มีความสามารถเด่นในการจัดการข้อมูลลำดับต่อเนื่อง โดยมีค่าความถ่วงดุลที่ 88.1% ซึ่งแสดงถึงความแม่นยำสูงในการวิเคราะห์ความรู้สึก อย่างไรก็ตาม โมเดล LSTM ยังคงมีข้อจำกัดเมื่อเทียบกับโมเดล BERT โดยเฉพาะในด้านการเข้าใจบริบทที่ซับซ้อนหรือความหมายเชิงลึก สอดคล้องกับงานวิจัยของ Zhang et al., (2020) สนับสนุนข้อค้นพบนี้ โดยระบุว่าโมเดล LSTM เหมาะสมกับงานที่เกี่ยวข้องกับข้อมูลลำดับ แต่ไม่สามารถแข่งขันกับโมเดล BERT ในการวิเคราะห์ข้อความที่มีบริบทที่เปลี่ยนแปลงหรือซับซ้อนได้ เมื่อเปรียบเทียบกับโมเดล CNN พบว่า สามารถตรวจจับข้อความที่มีรูปแบบซ้ำได้ดี แต่ยังมีข้อจำกัดในด้านค่าความระลึกและความสามารถในการเข้าใจความหมายเชิงลึก โดยเฉพาะในบริบทที่ซับซ้อนหรือเปลี่ยนแปลง อีกทั้ง Sun et al. (2020) สนับสนุนผลการวิจัยดังกล่าว โดยชี้ว่าโมเดล CNN เหมาะสำหรับการวิเคราะห์ข้อมูลที่มีโครงสร้างข้อความพื้นฐาน แต่ไม่สามารถจัดการกับข้อมูลที่ซับซ้อนหรือการวิเคราะห์ข้อความที่มีลำดับเหตุการณ์ได้ดี ผลการวิจัยนี้แสดงให้เห็นว่าแม้โมเดล CNN จะมีศักยภาพในการวิเคราะห์บางประเภท แต่ยังคงพัฒนาเพิ่มเติมเพื่อเพิ่มประสิทธิภาพในการเข้าใจความหมายและบริบทที่ซับซ้อนในข้อความ

ทั้งนี้จากผลการประเมินประสิทธิภาพของโมเดลพบว่าโมเดล BERT มีประสิทธิภาพสูงสุดในการวิเคราะห์ข้อความจากโซเชียลมีเดีย โดยมีค่าความถูกต้อง 92.5% และค่าความถ่วงดุลสูงสุดเมื่อเทียบกับโมเดล LSTM และ โมเดล CNN ซึ่งแสดงให้เห็นว่าโมเดล BERT สามารถจับความหมายและบริบทของข้อความที่ซับซ้อนและไม่เป็นทางการได้ดี โดยเฉพาะในข้อมูลจาก

โซเชียลมีเดีย งานวิจัยนี้สอดคล้องกับการศึกษาโดย Xinjie et al. (2022) ที่ระบุว่าโมเดล BERT ช่วยเพิ่มความแม่นยำในการวิเคราะห์ความคิดเห็นของลูกค้า การใช้โมเดล BERT ทำให้สามารถเข้าใจพฤติกรรมและความคิดเห็นของลูกค้าได้อย่างลึกซึ้ง ความสามารถเด่นของโมเดล BERT คือการเรียนรู้บริบทของข้อความ ซึ่งเกิดจากโครงสร้างสถาปัตยกรรมทรานส์ฟอร์เมอร์และการฝึกอบรมล่วงหน้า ทำให้โมเดลเข้าใจข้อความที่มีการเปลี่ยนแปลงบริบทบ่อยครั้ง เช่น การใช้คำแสลง หรือข้อความที่ไม่มีรูปแบบแน่นอนในโซเชียลมีเดีย โดยงานวิจัยของ Sun et al. (2020) สนับสนุนว่าโมเดล BERT เหมาะสมกับการวิเคราะห์ข้อมูลที่ไม่เป็นทางการหรือข้อมูลที่ไม่สม่ำเสมอ ผลการทดลองยังยืนยันตรงกับผลการวิจัยของ Narejo et al. (2024) ที่พบว่าโมเดล BERT มีความถูกต้องสูงถึง 97.00% ในการวิเคราะห์บริบทวิจารณ์ผลิตภัณฑ์ และสามารถทำการทดสอบแบบ 5 เท่าให้ความถูกต้องถึง 99.21% ผลการศึกษานี้ชี้ให้เห็นว่าโมเดล BERT มีศักยภาพสูงในการใช้วิเคราะห์ข้อมูลเชิงความรู้สึกจากโซเชียลมีเดีย เช่น การวิเคราะห์ความคิดเห็นของลูกค้า การติดตามแนวโน้มตลาด และการพัฒนากลยุทธ์ทางธุรกิจ การที่โมเดล BERT สามารถจับข้อมูลเชิงบริบทได้ดีทำให้มีผลกระทบสำคัญในโลกธุรกิจ โดยเฉพาะในยุคที่ข้อมูลโซเชียลมีเดียมีบทบาทในการขับเคลื่อนการตัดสินใจ ทั้งนี้ปัจจุบันงานวิจัยด้านการวิเคราะห์ความรู้กำลังพัฒนาไปสู่การวิเคราะห์ที่แม่นยำและครอบคลุมมากขึ้น ด้วยการใช้โมเดลภาษาขนาดใหญ่ (LLMs) เช่น BERT ที่สามารถเข้าใจบริบทของข้อความได้ดีขึ้น แนวโน้มสำคัญ ได้แก่ การวิเคราะห์ข้อมูลหลายรูปแบบ (Multimodal Sentiment Analysis) ที่รวมข้อความ ภาพ และเสียงเพื่อให้ได้ข้อมูลเชิงลึกที่สมบูรณ์ขึ้น

จากที่กล่าวมาถึงแม้ว่าผลการทดลองจะแสดงให้เห็นว่า โมเดล BERT มีประสิทธิภาพสูงสุดในการวิเคราะห์ความคิดเห็นของลูกค้า แต่ยังมีข้อจำกัดหลายประการที่อาจส่งผลกระทบต่อความแม่นยำของโมเดลและทำให้เกิด Bias โดยเฉพาะจากอคติในข้อมูลที่ฝึก โมเดลอาจเรียนรู้จากความคิดเห็นที่ไม่สมดุล เนื่องจากผู้ใช้โซเชียลมีเดียมักโพสต์ความคิดเห็นเชิงบวกหรือเชิงลบอย่างรุนแรงมากกว่าความคิดเห็นที่เป็นกลาง นอกจากนี้ ข้อมูลที่ใช้ในการทดลองมาจาก Twitter และ Facebook เท่านั้น ซึ่งอาจไม่สะท้อนความคิดเห็นของผู้ใช้จากแพลตฟอร์มอื่น เช่น Instagram หรือ TikTok ที่มีโครงสร้างข้อความและวิธีการสื่อสารที่แตกต่างกัน อีกทั้ง ภาษาที่ใช้บนโซเชียลมีเดียมักเป็นภาษาที่ไม่เป็นทางการ มีคำแสลง อีโมจิ และการสะกดผิด ซึ่งอาจทำให้โมเดลเข้าใจความหมายผิดพลาดได้ง่าย แม้ว่าโมเดล NLP จะสามารถเรียนรู้บริบทได้ดี แต่ก็ยังมีข้อจำกัดในการตีความอารมณ์จากข้อความที่ซับซ้อน นอกจากนี้ งานวิจัยนี้มุ่งเน้นการจำแนกความคิดเห็นเป็น เชิงบวก เชิงลบ และเป็นกลาง เท่านั้น โดยไม่ได้วิเคราะห์ระดับความรุนแรงของอารมณ์ เช่น ความโกรธ ความพึงพอใจอย่างมาก หรือความผิดหวัง ซึ่งอาจส่งผลกระทบต่อการใช้งานจริงในภาคธุรกิจ อีกปัจจัยสำคัญที่อาจส่งผลกระทบต่อความแม่นยำของโมเดลคือ การเปลี่ยนแปลงของภาษา (Concept Drift) บนโซเชียลมีเดียที่มีการพัฒนาอย่างต่อเนื่อง หากโมเดลไม่ได้รับการอัปเดตข้อมูลใหม่เป็นระยะ อาจทำให้ความแม่นยำลดลงเมื่อเวลาผ่านไป ดังนั้น ควรมีการปรับปรุงโมเดลให้รองรับข้อมูลที่หลากหลายมากขึ้น ใช้ Multimodal Sentiment Analysis เพื่อรวมข้อมูลจากข้อความ ภาพ และเสียง รวมถึงพัฒนาโมเดลที่สามารถปรับตัวให้เข้ากับแนวโน้มของภาษาที่เปลี่ยนแปลงอยู่ตลอดเวลาเพื่อลดอคติและเพิ่มความแม่นยำในการวิเคราะห์ความคิดเห็นของลูกค้า

7. ข้อเสนอแนะในการทำวิจัยในอนาคต

7.1 ใช้โมเดลการประมวลผลภาษาธรรมชาติ (BERT) ในการวิเคราะห์ความรู้สึกของข้อมูลที่ซับซ้อน เนื่องจากมีประสิทธิภาพสูงที่สุดในด้านความแม่นยำและการตรวจจับข้อมูลที่ซับซ้อน แนะนำให้ใช้การประมวลผลภาษาธรรมชาติ (BERT) เป็นโมเดลหลักสำหรับวิเคราะห์ความรู้สึกของลูกค้าจากโซเชียลมีเดียในรูปแบบอื่น อาทิเช่น ยูทูบ ดิกด็อก อินสตาแกรม เป็นต้น

7.2 การวิเคราะห์ข้อความที่มีลำดับและความต่อเนื่องการนำโมเดลโครงข่ายประสาทเทียมแบบวนกลับ (LSTM) เหมาะกับการวิเคราะห์ข้อความที่มีลำดับชัดเจน เช่น บทสนทนาหรือข้อความที่เปลี่ยนแปลงตามลำดับเวลา ควรนำโมเดลนี้มาใช้ในกรณีนี้เพื่อเพิ่มประสิทธิภาพจับความสัมพันธ์ในลำดับของข้อความ และลดข้อผิดพลาดจากข้อมูลในอดีต

7.3 สำหรับข้อความที่มีโครงสร้างเฉพาะควรนำโมเดลโครงข่ายประสาทแบบคอนโวลูชัน (CNN) มาใช้ในการวิเคราะห์เอกลักษณ์ในข้อความ และตรวจจับคำที่ผิดปกติ หรือการสกัดคุณลักษณะของข้อความให้มีความชัดเจนขึ้น

7.4 การวิจัยในอนาคตสามารถมุ่งเน้นไปที่การพัฒนาโมเดล Sentiment Analysis แบบมัลติโมดอล (Multimodal Sentiment Analysis) ซึ่งรวมการวิเคราะห์ข้อมูลจากข้อความ ภาพ เสียง และวิดีโอ เพื่อเพิ่มความแม่นยำในการประเมินความคิดเห็นของลูกค้าในแพลตฟอร์มโซเชียลมีเดีย การศึกษานี้จะช่วยให้สามารถจับอารมณ์และบริบทของความคิดเห็นได้ลึกซึ้งยิ่งขึ้น โดยเฉพาะในกรณีที่ข้อความเพียงอย่างเดียวไม่สามารถสื่อสารอารมณ์ได้ครบถ้วน เช่น การใช้ภาพและอิมโฌในการแสดงความคิดเห็น

8. ประโยชน์ของงานวิจัย

8.1 ผลการวิจัยช่วยให้ธุรกิจสามารถเข้าใจความคิดเห็นและความรู้สึกของลูกค้าที่แสดงออกผ่านโซเชียลมีเดีย ซึ่งช่วยให้สามารถปรับปรุงกลยุทธ์ทางการตลาดและการสื่อสารได้อย่างตรงประเด็น และมีประสิทธิภาพมากขึ้น

8.2 การวิเคราะห์ความรู้สึกจากความคิดเห็นของลูกค้า ธุรกิจสามารถรับรู้ความคิดเห็นที่ซ่อนอยู่และใช้ข้อมูลเชิงลึกในการตัดสินใจเกี่ยวกับผลิตภัณฑ์ บริการ และการพัฒนากลยุทธ์ทางธุรกิจ

8.3 การวิจัยนี้ยังช่วยยืนยันประสิทธิภาพของโมเดลการประมวลผลภาษาธรรมชาติ (BERT) ในการวิเคราะห์ข้อความจากโซเชียลมีเดีย ซึ่งสามารถนำไปใช้พัฒนาเทคโนโลยีในอนาคตที่เกี่ยวข้องกับการวิเคราะห์ข้อมูลเชิงความรู้สึก

เอกสารอ้างอิง

- Başarslan, M. S., & Kayaalp, F. (2021). Sentiment analysis on social media reviews datasets with deep learning approach. *Sakarya University Journal of Computer and Information Sciences*, 4(1), 35–49.
- Brooklyn, P., Olukemi, A., & Bell, C. (2024). Social media sentiment analysis for brand reputation management. *Available at SSRN 4906218*, 1-14
- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., ... Amodei, D. (2020). Language models are few-shot learners. *In Advances in Neural Information Processing Systems*, 33, 1877-1901.
- Chaiwichit C. (2017). Creating and developing model. *Silpakorn Education Research Journal*, 9(1), 1-11. Retrieved January 18, 2025, from <https://so05.tci-thaijo.org/index.php/suedureasearchjournal/issue/view/8124> [in Thai].
- Chakraborty, K., Bhattacharyya, K., & Bag, R., (2020). A survey of sentiment analysis from social media data. *IEEE Transactions on Computational Social Systems*, 7(2), pp. 450-464,
- Goodfellow, I., Bengio, Y., & Courville, A. (2020). *Deep learning an MIT press book*. MIT Press.
- Hernández-Romero, I. M., Barajas-Villarruel, L. R., Flores-Tlacuahuac, A., Fuentes-Cortes, L. F., & Rico-Ramirez, V. (2023). Strategic planning for sustainable electric system operations: Integrating renewables and energy storage. *Computers & Chemical Engineering*, 177, 108312.
- Jurafsky, D., & Martin, J. H. (2021). *Speech and language processing*. (3rd ed.), Pearson.

- Kim, S. M., & Hovy, E. (2020). Determining the sentiment of opinions. *Proceedings of the 20th International Conference on Computational Linguistics (COLING)*, 1367–1373.
- Liu, B. (2020). *Sentiment analysis: mining opinions, sentiments and emotions* (2nd ed.). Cambridge University Press.
- Messaoudi, C., Guessoum, Z., & Ben Romdhane, L. (2022). Opinion mining in online social media: a survey. *In Social Network Analysis and Mining*, 12(1), Springer.
- Narejo, K. R., Zan, H., Dharmani, K. P., Zhou, L., Alahmadi, T. J., Sehito, N., Ghadi, Y. Y., & Assam, M. (2024). EEBERT: An emoji-enhanced BERT fine-tuning on amazon product reviews for Text sentiment classification. *IEEE Access*, 12, 131954- 131967.
- Sun, C., Qiu, X., Xu, Y., & Huang, X. (2020). How to fine-tune BERT for text classification. *Journal of Computer Science Springer*, 194-206.
- Venugopalan, M., & Gupta, D. (2022). An enhanced guided LDA model augmented with BERT based semantic strength for aspect term extraction in sentiment analysis. *Knowledge-based systems*, 246, 108668.
- Wang, C., Nulty, P., & Lillis, D. (2020). A comparative study on word embeddings in deep learning for text classification. *In Proceedings of the 4th international conference on natural language processing and information retrieval*, 37-46.
- Win Myint, P. Y., Lo, S. L., & Zhang, Y. (2024). Unveiling the dynamics of crisis events: sentiment and emotion analysis via multi-task learning with attention mechanism and subject-based intent prediction. *Information Processing and Management*, 61(4), 103695.
- Xinjie, L., Gang, X., Gaopeng, G., Zhen, L., Junzheng, S., & Jing, Y. (2022). ET-BERT: A contextualized datagram representation with pre-training transformers for encrypted traffic classification. *WWW 2022 - Proceedings of the ACM Web Conference 2022*, 633–642.
- Zhang, L., Wang, S., & Liu, B. (2020). Deep learning for sentiment analysis: a survey. *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 10(3), 1328.