การประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อวิเคราะห์ประสิทธิภาพของการตลาดดิจิทัลในภาคธุรกิจ

The Application of Deep Learning Techniques to Analyze the Effectiveness of Digital Marketing in the Business Sector

รสสุคนธ์ สุวรรณกูฏ[1*] อัจฉราภรณ์ นาชัยทอง[2]

[1]คณะวิทยาการจัดการและเทคโนโลยีสารสนเทศ มหาวิทยาลัยนครพนม [2]คณะบริหารธุรกิจและการบัญชี มหาวิทยาลัยราชภัฏร้อยเอ็ด

Rossukon Suwannakoot[1*] Atcharapom Nachaithong[2]

[1]Faculty of Management Science and Information Technology, Nakhon Phanom University

[2]Faculty of Business Administration and Accountancy, Roi Et Rajabhat University

[*]Corresponding Author E-mail: rossukon.koy@npu.ac.th

(วันที่รับบทความ: 17 กุมภาพันธ์ 2568 วันที่แก้ไขบทความ 17 มิถุยายน 2568 วันที่ตอบรับบทความ: 14 กรกฎาคม 2568)

บทคัดย่อ

การศึกษาวิจัยในครั้งนี้มีวัตถุประสงค์ 1) เพื่อประยุกต์ใช้งานเทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ประสิทธิภาพของการตลาดดิจิทัล 2) เพื่อเปรียบเทียบประสิทธิภาพโมเดลการเรียนรู้เชิงลึกสำหรับการวิเคราะห์ข้อมูลจากแพลตฟอร์มดิจิทัล และ 3) เพื่อประเมินประสิทธิภาพของการตลาดดิจิทัลโดยใช้ตัวชี้วัดทางการตลาด โดยใช้ข้อมูลจากแพลตฟอร์มสื่อสังคมออนไลน์ การพาณิชย์อิเล็กทรอนิกส์ และระบบโฆษณาออนไลน์ จำนวน 57,000 เรคคอร์ด 29 แอททริบิวต์ โดยใช้ตัวชี้วัดในการวิเคราะห์ 2 กลุ่ม ได้แก่ 1) ตัวชี้วัดด้านการตลาดดิจิทัล (อัตราการมีส่วนร่วม, อัตราการคลิก และผลตอบแทนจากการลงทุน) และ 2) ตัวชี้วัดด้านประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก (Accuracy, Precision, Recall, F1-Score และ RMSE)

ผลการวิจัยพบว่า การใช้โมเดล BERT ในการวิเคราะห์ข้อความ ความคิดเห็น และอารมณ์ของลูกค้าจากโพสต์ มีค่าความถูกต้องสูงสุด ร้อยละ 92.50 และเพิ่มอัตราการมีส่วนร่วม ได้ถึงร้อยละ 25.00 แสดงให้เห็นว่าการวิเคราะห์ความคิดเห็นของลูกค้าเป็นปัจจัยสำคัญที่ช่วยปรับปรุงการตลาด โดยข้อความที่มีเนื้อหาบวกมีผลต่อยอดขายมากกว่าข้อความทั่วไป ผลการเปรียบเทียบโมเดล พบว่า โมเดล BERT มีความถูกต้องสูงสุด ร้อยละ 92.50 ส่วนการประเมินประสิทธิภาพของการตลาดดิจิทัล พบว่า ให้ผลลัพธ์ที่ดีที่สุดในทุกตัวชี้วัดได้ถึงร้อยละ 27.80 อัตราการคลิกร้อยละ 12.60 และผลตอบแทนจากการลงทุนร้อยละ 18.20 ตามลำดับ การวิจัยยังชี้ให้เห็นว่าการวิเคราะห์ความคิดเห็นของลูกค้า โดยเฉพาะความคิดเห็นบวก มีผลกระทบต่อยอดขายและแสดงถึงความสำคัญของการใช้เทคโนโลยีการเรียนรู้เชิงลึกในการเข้าใจพฤติกรรมและความต้องการของลูกค้า และผลการวิจัยนี้สามารถนำไปปรับปรุงกลยุทธ์การตลาดดิจิทัล เพื่อสร้างความสัมพันธ์และเพิ่มผลตอบแทนจากการลงทุนอย่างมีประสิทธิภาพ

คำสำคัญ: การเรียนรู้เชิงลึก, การวิเคราะห์ประสิทธิภาพ, การตลาดดิจิทัล

Abstract

This study aims 1) to apply deep learning techniques to analyzing the effectiveness of digital marketing, 2 to compare the performance of deep learning models for analyzing data from digital platforms and 3. to assess the performance of digital marketing using marketing metrics based on data from online businesses through social media platforms, e-commerce and online advertising systems. The dataset consists of 57,000 records with 29 attributes. The analysis is conducted using two sets of metrics: 1) digital marketing metrics (engagement rate, click-through rate and return on investment) and 2) deep learning model performance metrics (Accuracy, Precision, Recall, F1-Score, and RMSE).

The research results showed that using the BERT model to analyzing customer feedback, comments, and sentiments from posts achieved the highest accuracy rate of 92.50 and increased engagement by 25.00. This demonstrates that analyzing customer feedback is a key factor in improving marketing strategies. Positive content in posts had a greater impact on sales compared to general posts. The model comparison results showed that the BERT model provided the highest accuracy of 92.50. Regarding the evaluation of digital marketing effectiveness, the results were the best across all metrics, with an engagement rate increase of 27.80, a click-through rate increase of 12.60 and a return on investment increase of 18.20, respectively. The study also highlighted that analyzing customer feedback, especially positive feedback, significantly impacts sales and emphasizes the importance of using deep learning technology to understand customer behavior and needs. These research findings can be applied to improve digital marketing strategies, fostering relationships and enhancing return on investment effectively.

Keywords: Deep Learning, Performance Analytics, Digital Marketing

บทนำ

ในยุคที่เทคโนโลยีดิจิทัลเข้ามามีบทบาทสำคัญในภาคธุรกิจ การตลาดดิจิทัล (Digital Marketing) ได้กลายเป็นหนึ่งวิธีการที่องค์กรธุรกิจใช้เพื่อเข้าถึงลูกค้า สร้างการมีส่วนร่วม และเพิ่มยอดขาย (Alghizzawi et al., 2023) อย่างไรก็ตาม ความซับซ้อนของพฤติกรรมผู้บริโภคที่เปลี่ยนแปลงอย่างรวดเร็ว ประกอบกับปริมาณข้อมูลขนาดใหญ่ที่เกิดขึ้นจำนวนมากจากหลายแพลตฟอร์ม เช่น สื่อสังคมออนไลน์ เว็บไซต์การซื้อขายออนไลน์ และโฆษณาออนไลน์ ทำให้การประเมินประสิทธิภาพของการตลาดดิจิทัลเป็นสิ่งที่ท้าทาย (Yoganandham, 2024)

การเรียนรู้เชิงลึก (Deep Learning) เป็นหนึ่งในเทคนิคของปัญญาประดิษฐ์ที่มีความสามารถในการประมวลผลข้อมูลจำนวนมหาศาล และสามารถระบุรูปแบบที่ซับซ้อนได้อย่างแม่นยำ การเรียนรู้เชิงลึกถูกนำมาใช้ในหลายบริบททางธุรกิจ รวมถึงการวิเคราะห์ข้อมูลตลาด คาดการณ์พฤติกรรมผู้บริโภค และเพิ่มประสิทธิภาพการโฆษณาออนไลน์ (Chen, Pelger & Zhu, 2024) ในด้านการตลาดดิจิทัล การเรียนรู้เชิงลึกสามารถนำมาใช้เพื่อวิเคราะห์ความคิดเห็นของลูกค้า (Sentiment Analysis) ตรวจสอบแนวโน้มของตราสินค้า และทำนายอัตราการตอบสนองของการส่งเสริมการโฆษณาได้อย่างแม่นยำ อย่างไรก็ตาม จากการทบทวนวรรณกรรม พบว่า งานวิจัยส่วนใหญ่ที่ใช้การเรียนรู้เชิงลึกในบริบทของการตลาดดิจิทัล มักมุ่งเน้นเฉพาะการวิเคราะห์ข้อมูลข้อความหรือความคิดเห็นของลูกค้าเพียงด้านเดียว และยังขาดการเปรียบเทียบประสิทธิภาพของโมเดลต่าง ๆ ในหลายมิติ เช่น ข้อมูลลำดับเวลาและภาพโฆษณา นอกจากนี้ยังพบว่างานวิจัยจำนวนมากไม่ได้เชื่อมโยงผลการวิเคราะห์กับตัวชี้วัดทางการตลาดโดยตรง เช่น อัตราการมีส่วนร่วม (Engagement Rate) หรือผลตอบแทนจากการลงทุน (ROI) ส่งผลให้การประยุกต์ใช้ผลลัพธ์ในด้านการตลาดยังมีข้อจำกัด งานวิจัยนี้จึงมุ่งเติมเต็มช่องว่างดังกล่าว โดยพัฒนาและเปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้เชิงลึกที่แตกต่างกัน เพื่อนำไปสู่การประเมินผลที่ครอบคลุมและเป็นรูปธรรมยิ่งขึ้นในบริบทของภาคธุรกิจ (Wankhade, Rao & Kulkarni, 2022)

งานวิจัยนี้เลือกใช้โมเดล BERT, LSTM และ CNN เนื่องจากมีจุดเด่นที่เหมาะสมกับลักษณะข้อมูลที่หลากหลาย จากแพลตฟอร์มดิจิทัล โดยโมเดล BERT เหมาะสำหรับการวิเคราะห์ข้อความ และความรู้สึกของลูกค้า ด้วยความสามารถในการเข้าใจบริบทของภาษาได้ลึกซึ้ง โมเดล LSTM เหมาะสำหรับการวิเคราะห์ข้อมูลลำดับเวลา เช่น พฤติกรรมของผู้บริโภคหรือแนวโน้มการคลิกโฆษณา ในขณะที่ CNN เหมาะกับการประมวลผลภาพ เช่น การวิเคราะห์โฆษณาในรูปแบบกราฟิกหรือวิดีโอ โดยทั้งสามโมเดลสามารถประยุกต์ใช้กับข้อมูลที่ไม่มีโครงสร้าง (Unstructured Data) ซึ่งเป็นองค์ประกอบสำคัญของการตลาดดิจิทัลในยุคปัจจุบัน จากความสามารถดังกล่าว งานวิจัยนี้จึงมุ่งเน้นการประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อวิเคราะห์ประสิทธิภาพการตลาดดิจิทัลในภาคธุรกิจ โดยใช้ข้อมูลจากแพลตฟอร์มสื่อสังคมออนไลน์การพาณิชย์อิเล็กทรอนิกส์ และแหล่งข้อมูลออนไลน์อื่น ๆ เพื่อวิเคราะห์ว่าส่วนประกอบ

ใดของการตลาดดิจิทัลมีผลกระทบมากที่สุดต่อพฤติกรรมของลูกค้า งานวิจัยนี้ยังมุ่งเน้นการประยุกต์ใช้การเรียนรู้เชิงลึกที่สามารถช่วยให้ธุรกิจสามารถประเมินและปรับปรุงการตลาดดิจิทัลได้อย่างมีประสิทธิภาพ

การศึกษาในครั้งนี้จะช่วยให้ธุรกิจสามารถประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึก เพื่อเพิ่มประสิทธิภาพของการส่งเสริมการตลาด ลดต้นทุนในการทำโฆษณา และสร้างประสบการณ์ที่ดีขึ้นให้กับลูกค้า นอกจากนี้ ผลลัพธ์ของงานวิจัยยังสามารถนำไปใช้เป็นแนวทางสำหรับนักการตลาด นักวิเคราะห์ข้อมูล นักบริหารธุรกิจ และนักวิจัยที่สนใจศึกษาแนวทางการประยุกต์ใช้เทคโนโลยีทางด้านการเรียนรู้เชิงลึกมาเพิ่มยอดขายทางการตลาดดิจิทัลได้ในอนาคต

วัตถุประสงค์การวิจัย

1. เพื่อประยุกต์ใช้งานเทคนิคการเรียนรู้เชิงลึกในการวิเคราะห์ประสิทธิภาพของการตลาดดิจิทัล
2. เพื่อเปรียบเทียบประสิทธิภาพโมเดลการเรียนรู้เชิงลึกสำหรับการวิเคราะห์ข้อมูลจากแพลตฟอร์มดิจิทัล
3. เพื่อประเมินประสิทธิภาพของการตลาดดิจิทัลโดยใช้ตัวชี้วัดทางการตลาด

ทบทวนวรรณกรรม

การเรียนรู้เชิงลึก เป็นแขนงหนึ่งของการเรียนรู้ของเครื่อง (Machine Learning) ที่ใช้ โครงข่ายประสาทเทียมหลายชั้น (Artificial Neural Networks) ในการประมวลผลข้อมูลและเรียนรู้รูปแบบที่ซับซ้อนจากข้อมูลปริมาณมาก (Torres et al., 2021) การเรียนรู้เชิงลึกถูกนำไปใช้ในหลายอุตสาหกรรมเพื่อเพิ่มประสิทธิภาพ และความสามารถในการวิเคราะห์ข้อมูลขนาดใหญ่ ตัวอย่างการประยุกต์ใช้ในภาคธุรกิจ ได้แก่ การตลาดดิจิทัล เป็นการวิเคราะห์ความคิดเห็นของลูกค้า โดยใช้โมเดลการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) เช่น Bidirectional Encoder Representations from Transformers (BERT) ซึ่งเป็นโมเดลการเรียนรู้เชิงลึกสำหรับการประมวลผลภาษาธรรมชาติที่พัฒนาโดย Google และ Long Short-Term Memory (LSTM) เป็นประเภทหนึ่งของโครงข่ายประสาทเทียมแบบวนซ้ำ (Recurrent Neural Network: RNN) ที่ถูกออกแบบมาเพื่อแก้ปัญหาเรื่องการจดจำข้อมูลระยะยาวในข้อมูลลำดับ เช่น ข้อความ เสียง วิดีโอ และข้อมูลอนุกรมเวลา (Alaparthi & Mishra, 2020)

การวิเคราะห์ประสิทธิภาพ (Performance Analysis) เป็นกระบวนการตรวจสอบและประเมินผลของระบบหรือกิจกรรมหนึ่ง ๆ เพื่อพิจารณาว่ามีประสิทธิภาพตามเป้าหมายที่กำหนดไว้หรือไม่ (Liu et al., 2023) โดยทั่วไป การวิเคราะห์ประสิทธิภาพจะเกี่ยวข้องกับการวัดผลลัพธ์ (Outcomes) กระบวนการทำงาน (Processes) และทรัพยากรที่ใช้ (Resources) ในบริบทของธุรกิจและการตลาด การวิเคราะห์ประสิทธิภาพสามารถใช้เพื่อวัดความสำเร็จที่นำมาใช้ เช่น ประสิทธิภาพของการส่งเสริมการตลาดดิจิทัล การบริหารทรัพยากรองค์กร หรือผลการดำเนินงานขององค์กร (Adwan et al., 2023)

Rahardja (2022) กล่าวว่า การวิเคราะห์สื่อสังคมออนไลน์เป็นวิธีการอย่างหนึ่งของการตลาดในธุรกิจการตลาดออนไลน์เป็นแผนการตลาดอย่างหนึ่งที่ใช้เทคโนโลยีดิจิทัลและช่องทางออนไลน์ในการเข้าถึงลูกค้า เพื่อสร้างมูลค่าและกระตุ้นการมีส่วนร่วม สื่อสังคมออนไลน์มีบทบาทสำคัญในยุคดิจิทัล เนื่องจากพฤติกรรมผู้บริโภคเปลี่ยนแปลงไปสู่แพลตฟอร์มออนไลน์ เช่น สื่อสังคมออนไลน์ เว็บไซต์ และแพลตฟอร์มการพาณิชย์อิเล็กนิกส์ และเป็นการผสมผสานระหว่างปัญญาประดิษฐ์ (AI) ข้อมูลขนาดใหญ่ (Big Data) และระบบอัตโนมัติ (Automation) เพื่อให้การวิเคราะห์ด้านการตลาดมีความแม่นยำและตรงกับพฤติกรรมของลูกค้าในระดับบุคคล (Personalization) มากขึ้น

การเรียนรู้เชิงลึกมีศักยภาพในการวิเคราะห์ข้อมูลที่มีโครงสร้างซับซ้อนและไม่มีโครงสร้างจำนวนมากจากแพลตฟอร์มดิจิทัล ซึ่งมีความหลากหลายทั้งในด้านรูปแบบ (ข้อความ รูปภาพ ลำดับเหตุการณ์) และบริบท เช่น ความรู้สึกของลูกค้า แนวโน้มการซื้อ หรือการตอบสนองต่อโฆษณา ความสามารถของการเรียนรู้เชิงลึก ในการเรียนรู้รูปแบบแฝง (Latent Patterns) และความสัมพันธ์เชิงลึกในข้อมูล ช่วยให้สามารถคาดการณ์และตัดสินใจได้อย่างแม่นยำมากยิ่งขึ้น ส่งผลต่อการเพิ่มประสิทธิภาพของการตลาดในหลายด้าน ไม่ว่าจะเป็นการปรับเนื้อหาให้ตรงกลุ่มเป้าหมาย การเลือกช่วงเวลาการแสดงโฆษณา หรือการปรับงบประมาณตามประสิทธิผลของแคมเปญ ทั้งนี้ยังช่วยลดต้นทุนที่ไม่จำเป็น และเพิ่มโอกาสในการเข้าถึงลูกค้าอย่างมีประสิทธิภาพ (Ullal et al., 2021)

การประเมินประสิทธิภาพการตลาดดิจิทัลมักใช้ตัวชี้วัดหลัก (Key Performance Indicators: KPIs) ซึ่งเป็นตัวชี้วัดเชิงปริมาณที่ช่วยวัดความสำเร็จของแคมเปญการตลาดดิจิทัล ตัวชี้วัดหลักที่สำคัญในงานวิจัยนี้ ได้แก่ (Ghahremani & Nozari, 2021)

1. อัตราการมีส่วนร่วม (Engagement Rate: ER) เป็นตัวชี้วัดระดับการโต้ตอบของผู้ใช้กับเนื้อหาการตลาด เช่น การกดถูกใจ (Like) การแสดงความคิดเห็น (Comment) และการแชร์ (Share) เมื่อเทียบกับจำนวนครั้งที่เนื้อหานั้นปรากฏบนหน้าจอของผู้ใช้ สามารถแสดงในสมการที่ 1 (Bajeja, 2024)

$$ER = \left(\frac{Likes + Comments + Shares}{Total\ Impression}\right) \times 100 \quad (1)$$

2. อัตราการคลิก (Click-Through Rate: CTR) เป็นตัวชี้วัดที่ใช้วัดประสิทธิภาพของโฆษณาหรือเนื้อหาทางการตลาด โดยแสดงให้เห็นว่าในจำนวนครั้งที่โฆษณาถูกแสดงผล มีผู้ใช้ที่คลิกลิงก์หรือโฆษณาเป็นกี่เปอร์เซ็นต์ สามารถแสดงในสมการที่ 2 (Azad et al., 2024)

$$CTR = \left(\frac{\text{จำนวนคลิกทั้งหมด}}{\text{จำนวนการแสดงผลทั้งหมด}}\right) \times 100 \quad (2)$$

3. ผลตอบแทนจากการลงทุน (Return on Investment: ROI) เป็นตัวชี้วัดที่ใช้ประเมินผลกำไรของแคมเปญการตลาด โดยเปรียบเทียบรายได้ที่ได้รับจากแคมเปญกับค่าใช้จ่ายที่ลงทุนไป สามารถแสดงในสมการที่ 3 (Smith, 2024)

$$ROI = \left(\frac{\text{กำไรสุทธิ}}{\text{ต้นทุนการตลาดทั้งหมด}}\right) \times 100 \quad (3)$$

การใช้ตัวชี้วัดเหล่านี้ช่วยให้ธุรกิจสามารถปรับปรุงการตลาดดิจิทัลได้อย่างมีประสิทธิภาพมากขึ้น โดยการวิเคราะห์และปรับปรุงแคมเปญเพื่อเพิ่มการมีส่วนร่วมของผู้ใช้ อัตราการคลิก และผลตอบแทนจากการลงทุน

การประเมินประสิทธิภาพของโมเดลในกระบวนการการเรียนรู้ของเครื่อง เป็นกระบวนการสำคัญที่ช่วยให้เรารู้ว่าตัวแบบที่เราสร้างขึ้นมีความแม่นยำและทำงานได้ดีเพียงใด โดยทั่วไปการประเมินประสิทธิภาพของโมเดลมีหลายวิธี ขึ้นอยู่กับประเภทของปัญหาและข้อมูลที่ใช้ สามารถนำมาใช้คำนวณการประเมินประสิทธิภาพของการทำนายจากตัวแบบได้ในรูปแบบต่าง ๆ ดังนี้ (Mijwil & Aljanabi, 2023; Berliana & Riasetiawan, 2024)

1. ค่าความถูกต้อง (Accuracy) คือ สัดส่วนของการทำนายที่ถูกต้องจากการทำนายทั้งหมด คำนวณโดยการหารจำนวนกรณีที่ทำนายถูกต้องด้วยจำนวนกรณีทั้งหมดที่ทำการทำนาย โดยพิจารณาทุกคลาส สามารถแสดงในสมการที่ 4

$$Accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (4)$$

2. ค่าความแม่นยำ (Precision) คือ สัดส่วนของการทำนายที่เป็นบวกจริง ๆ เมื่อเปรียบเทียบกับการทำนายทั้งหมดที่เป็นบวก คำนวณจากจำนวนกรณีที่ทำนายเป็นบวกและถูกต้องเทียบกับจำนวนกรณีที่ทำนายเป็นบวกทั้งหมด สามารถแสดงในสมการ 5

$$\text{Precision} = \frac{\text{TP}}{\text{TP} + \text{FP}} \quad (5)$$

3. ค่าความระลึก (Recall) คือ สัดส่วนของกรณีที่เป็นบวกจริง ๆ ที่ถูกทำนายเป็นบวกจากทั้งหมดที่เป็นบวกจริง ๆ คำนวณจากจำนวนกรณีที่ทำนายเป็นบวกและถูกต้องเทียบกับจำนวนกรณีที่เป็นบวกจริงทั้งหมด สามารถแสดงในสมการที่ 6

$$Recall = \frac{TP}{TP + FN} \quad (6)$$

4. ค่าความถ่วงดุล (F1 – Score หรือ F-Measure) คือ ค่าเฉลี่ยถ่วงน้ำหนักระหว่าง Precision และ Recall ซึ่งให้ค่าที่สมดุลสำหรับทั้งสองค่าดังกล่าว การคำนวณคือการหาค่าเฉลี่ยแบบถ่วงน้ำหนักระหว่าง Precision และ Recall โดยคำนึงถึงทั้งความแม่นยำและการดึงกลับ สามารถแสดงในสมการที่ 7

$$F-measure = \frac{2 * Recall * Precision}{Recall + precision} \quad (7)$$

5. ค่าเฉลี่ยรากที่สองของผลต่างกำลังสอง (Root Mean Square Error: RMSE) วัดรากที่สองของค่าเฉลี่ยของผลต่างกำลังสองระหว่างค่าทำนายกับค่าจริง เป็นเมทริกซ์ที่ให้ความสำคัญกับความผิดพลาดขนาดใหญ่ สามารถแสดงในสมการที่ 8

$$RMSE = \sqrt{\frac{1}{n}\sum_{i=1}^{n}(y_i - \hat{y}_i)^2} \quad (8)$$

จากการทบทวนวรรณกรรมของการเรียนรู้เชิงลึก การวิเคราะห์ประสิทธิภาพการตลาดดิจิทัล ผู้วิจัยได้กำหนดเป็นกรอบแนวคิดการวิจัยดังนี้

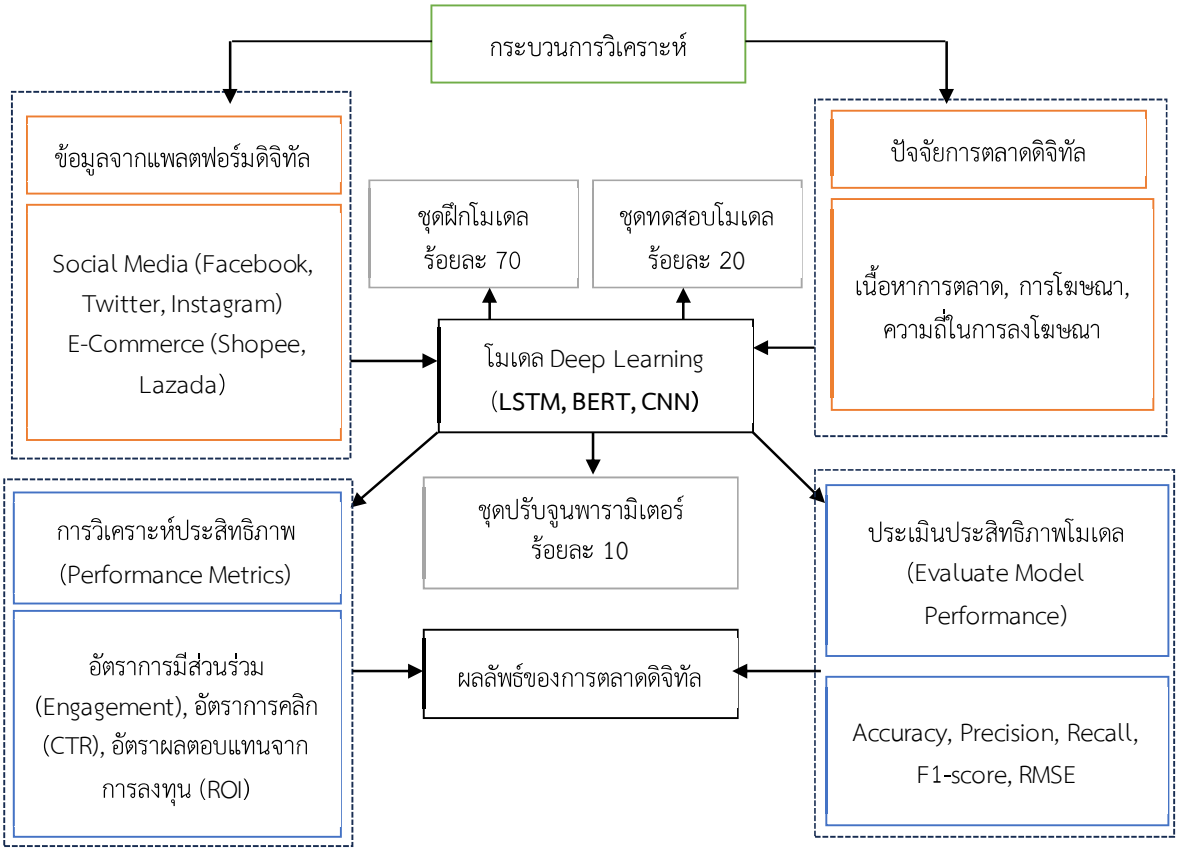

ภาพที่ 1 กรอบแนวคิดการวิจัย

วิธีดำเนินการวิจัย

งานวิจัยนี้มุ่งเน้นการประยุกต์ใช้การเรียนรู้เชิงลึก เพื่อวิเคราะห์ประสิทธิภาพการตลาดดิจิทัลในภาคธุรกิจ โดยใช้ข้อมูลจากแพลตฟอร์มดิจิทัล เช่น สื่อสังคมออนไลน์ การพาณิชย์อิเล็กทรอนิกส์ และแพลตฟอร์มโฆษณาออนไลน์ กระบวนการดำเนินการวิจัยสามารถแบ่งออกเป็น 6 ขั้นตอนหลัก ดังนี้

ขั้นตอนที่ 1 การกำหนดขอบเขตของการวิจัย เป็นขั้นตอนแรกของการดำเนินการวิจัยคือการกำหนดขอบเขตของการศึกษา โดยระบุกลุ่มเป้าหมาย ตัวแปรที่ใช้ และแพลตฟอร์มดิจิทัลที่เกี่ยวข้อง ในงานวิจัยนี้ กลุ่มเป้าหมาย คือธุรกิจที่ใช้การตลาดดิจิทัลผ่านแพลตฟอร์มสื่อสังคมออนไลน์ (Facebook, Instagram, Twitter) การพาณิชย์อิเล็กทรอนิกส์ เช่น Shopee, Lazada, Amazon และระบบโฆษณาออนไลน์ เช่น Google Ads งานวิจัยยังใช้ตัวแปรที่เกี่ยวข้อง ได้แก่ ตัวแปรอิสระ ซึ่งเป็นข้อมูลจากแพลตฟอร์มดิจิทัล เช่น จำนวนการกดไลก์ แชร์ คอมเมนต์ ค่าใช้จ่ายในการโฆษณา และประเภทของเนื้อหา ตัวแปรตาม ซึ่งเป็นตัวชี้วัดประสิทธิภาพการตลาด เช่น อัตราการมีส่วนร่วม อัตราการคลิก และ ผลตอบแทนจากการลงทุน (Return on Investment) (Hamdani et al., 2022)

ขั้นตอนที่ 2 การเก็บรวบรวมข้อมูล เมื่อกำหนดขอบเขตของการวิจัยแล้ว ขั้นตอนต่อไปคือการเก็บรวบรวมข้อมูลจากแพลตฟอร์มดิจิทัล ข้อมูลที่นำมาใช้ในการวิเคราะห์ แบ่งออกเป็น 2 ประเภท ได้แก่ ข้อมูลโครงสร้าง (Structured Data) เช่น สถิติจากแพลตฟอร์มสื่อสังคมออนไลน์ ข้อมูลโฆษณา และยอดขายจากการพาณิชย์อิเล็กทรอนิกส์ และข้อมูลที่ไม่มีโครงสร้าง (Unstructured Data) เช่น ข้อความรีวิว คอมเมนต์ของลูกค้า และโพสต์ที่เกี่ยวข้องกับแบรนด์ จำนวน 57,000 เรคคอร์ด 29 แอททริบิวต์ (Sivarajah et al., 2017)

ขั้นตอนที่ 3 การเตรียมข้อมูล (Data Preprocessing) หลังจากรวบรวมข้อมูลเรียบร้อยแล้ว ข้อมูลจะต้องผ่านการทำความสะอาดและแปลงให้อยู่ในรูปแบบที่เหมาะสม สำหรับข้อมูลที่เป็นข้อความแบบไม่มีโครงสร้าง จากหลากหลายแพลตฟอร์ม พบว่ามีทั้งภาษาไทย ภาษาอังกฤษ และภาษาท้องถิ่นในบางส่วน โดยงานวิจัยนี้เลือกใช้เฉพาะข้อมูลที่เป็นภาษาไทยและภาษาอังกฤษในการวิเคราะห์ และตัดข้อความที่มีภาษาอื่นหรือข้อความผสมภาษาหลายรูปแบบออกจากชุดข้อมูล ทั้งนี้เพื่อความสอดคล้องกับโมเดลการประมวลผลภาษา (NLP Model) ซึ่งมีขั้นตอนการเตรียมข้อความก่อนนำเข้าสู่โมเดลมีการดำเนินการดังนี้ (Roy et al., 2018)

1. การทำ Tokenization ด้วยวิธี Word Piece Tokenizer โดยใช้ Tokenizer ที่สอดคล้องกับโมเดล BERT-base-multilingual-uncased ซึ่งรองรับหลายภาษา

2. การตัดหรือเติม Padding เพื่อให้ความยาวของข้อความเท่ากัน โดยกำหนด Maximum Sequence Length ที่ 128 Token

3. การสร้าง Attention Mask เพื่อระบุว่า Token ใดในลำดับควรถูกประมวลผลหรือไม่

4. การ Encoding ข้อความให้เป็น Tensor เพื่อให้สามารถป้อนเข้าสู่โมเดล BERT ได้อย่างถูกต้อง กระบวนการดังกล่าวช่วยให้ข้อมูลข้อความมีความพร้อมและอยู่ในรูปแบบที่เหมาะสมกับการเรียนรู้ของโมเดล BERT อย่างมีประสิทธิภาพ

นอกจากนี้ข้อมูลตัวเลขที่ใช้ในการวิเคราะห์ เช่น ค่าโฆษณาและยอดขาย จะถูกทำให้เป็นมาตรฐานโดยใช้วิธีการปรับค่าข้อมูลให้อยู่ในช่วงที่เหมาะสม (Normalization) หรือการแปลงข้อมูล (Standardization) ข้อมูลที่ผ่านกระบวนการเตรียมแล้วจะถูกแบ่งออกเป็น 3 ส่วน ได้แก่ ชุดฝึกโมเดล (Training Set) ร้อยละ 70 ชุดปรับจูนพารามิเตอร์ของโมเดล (Validation Set) ร้อยละ 10 และชุดทดสอบโมเดล (Test Set) ร้อยละ 20 เนื่องจากเป็นแนวทางมาตรฐานที่ได้รับการยอมรับอย่างแพร่หลายในงานวิจัยด้านการเรียนรู้ด้วยเครื่อง และการเรียนรู้เชิงลึก (Heaton, 2018) สัดส่วนดังกล่าวช่วยให้โมเดลสามารถเรียนรู้จากข้อมูลจำนวนมากในสัดส่วนร้อยละ 70เพื่อให้เกิดการเรียนรู้รูปแบบได้อย่างมีประสิทธิภาพ ขณะเดียวกัน การใช้ข้อมูลร้อยละ 10 สำหรับการปรับจูนพารามิเตอร์ช่วยป้องกันการเกิดปัญหา Overfitting ส่วนข้อมูลอีกร้อยละ 20 ใช้สำหรับการทดสอบประสิทธิภาพของโมเดลกับข้อมูลที่โมเดลไม่เคยเห็นมาก่อน เพื่อประเมินความสามารถในการ Generalize ไปยังข้อมูลจริงอย่างมีประสิทธิภาพ

ขั้นตอนที่ 4 โมเดลการเรียนรู้เชิงลึก ขั้นตอนต่อไปคือการประยุกต์ใช้โมเดลการเรียนรู้เชิงลึกเพื่อนำมาวิเคราะห์ประสิทธิภาพของการตลาดดิจิทัล โมเดลที่ใช้ในงานวิจัยนี้ประกอบด้วย (Van Houdt et al., 2020) Long Short-Term Memory (LSTM) นำมาใช้สำหรับวิเคราะห์ข้อมูลที่มีลำดับเวลา เช่น พฤติกรรมของลูกค้า (Deepa, 2021) Bidirectional Encoder Representations from

Transformers (BERT) ใช้สำหรับวิเคราะห์ความคิดเห็นของลูกค้าและเนื้อหาโฆษณา และ Convolutional Neural Network (CNN) ใช้สำหรับวิเคราะห์ข้อมูลภาพและโฆษณาบนแพลตฟอร์มดิจิทัล (Li et al., 2021)

ขั้นตอนที่ 5 การวิเคราะห์และประเมินประสิทธิภาพของโมเดล เมื่อโมเดลผ่านการฝึกและปรับแต่งพารามิเตอร์แล้วจะ ต้องนำมาทดสอบและประเมินผลเพื่อวิเคราะห์ประสิทธิภาพการตลาดดิจิทัล ตัวชี้วัดที่ใช้ในการวิเคราะห์แบ่งออกเป็น 2 กลุ่ม ได้แก่ 1) ตัวชี้วัดด้านการตลาดดิจิทัล (อัตราการมีส่วนร่วม, อัตราการคลิก และผลตอบแทนจากการลงทุน) 2) ตัวชี้วัดด้านประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก (Accuracy, Precision, Recall, F1-Score และ RMSE) (Fitrianingsih & Zuraeni, 2024)

ขั้นตอนที่ 6 การสรุปผลและการนำไปประยุกต์ใช้ เป็นขั้นตอนสุดท้ายของงานวิจัยนี้ คือการสรุปผลการศึกษาและนำเสนอแนวทางการปรับปรุงการตลาดดิจิทัล จากผลการวิเคราะห์ที่ได้จากโมเดลจะช่วยให้ธุรกิจสามารถปรับปรุงการส่งเสริมการตลาดดิจิทัล และเพิ่มประสิทธิภาพของโฆษณาออนไลน์ได้ (Yim, 2020)

จากที่กล่าวมาทั้ง 6 ขั้นตอน งานวิจัยนี้จัดอยู่ในประเภทการวิจัยประยุกต์ (Applied Research) โดยใช้ระเบียบวิธีวิจัยเชิงปริมาณเป็นหลัก เนื่องจากมีการนำข้อมูลขนาดใหญ่จากแพลตฟอร์มดิจิทัลมาวิเคราะห์ด้วยเทคนิคการเรียนรู้เชิงลึก เพื่อหาความสัมพันธ์และประสิทธิภาพของการตลาดดิจิทัลในภาคธุรกิจ เน้นการใช้ข้อมูลตัวเลขสามารถวัดผลได้อย่างเป็นรูปธรรม โดยผลลัพธ์ที่ได้สามารถนำไปประยุกต์ใช้เพื่อพัฒนาแผนการตลาดและเพิ่มประสิทธิภาพของการวางแผนการโฆษณาออนไลน์ในทางปฏิบัติได้อย่างชัดเจน

ผลการวิจัย

งานวิจัยนี้มุ่งเน้นการประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อวิเคราะห์ประสิทธิภาพการตลาดดิจิทัล โดยใช้ข้อมูลจากแพลตฟอร์มสื่อสังคมออนไลน์ การพาณิชย์อิเล็กทรอนิกส์ และระบบโฆษณาออนไลน์ ผลการวิจัยสามารถสรุปได้ ดังนี้

1. การเรียนรู้เชิงลึกเป็นเครื่องมือสำคัญในการวิเคราะห์ข้อมูลทางการตลาดดิจิทัล โดยช่วยให้ธุรกิจสามารถเข้าใจพฤติกรรมของลูกค้าได้เชิงลึกมากขึ้น และส่งเสริมการตลาดที่มีประสิทธิภาพสูงขึ้น ดังตารางที่ 1

ตารางที่ 1 ผลการประยุกต์ใช้การเรียนรู้เชิงลึกในการวิเคราะห์ประสิทธิภาพการตลาดดิจิทัล

Analysis Aspect	Deep Learning Model	Accuracy	Engagement Improvement	CTR Improvement	ROI Improvement
Sentiment Analysis	BERT	92.50	25.00	12.30	17.90
Customer Behavior Prediction	LSTM	88.70	20.40	10.80	15.60
Ad Performance Analysis	CNN	86.30	18.70	9.50	14.20

จากตารางที่ 1 พบว่า การวิเคราะห์ข้อความความคิดเห็นของลูกค้าโดยใช้โมเดล BERT เพื่อวิเคราะห์ความคิดเห็นและอารมณ์ของลูกค้า (Sentiment Analysis) จากโพสต์ คอมเมนต์ และรีวิว มีค่าความถูกต้องสูงสุดที่ร้อยละ 92.50 และสามารถเพิ่มอัตราการมีส่วนร่วม ได้ถึงร้อยละ 25.00 แสดงให้เห็นว่าการวิเคราะห์ความคิดเห็นของลูกค้าเป็นปัจจัยสำคัญที่ช่วยปรับปรุงการตลาดที่เป็นข้อความที่เป็นเชิงบวกมีผลต่อยอดขาย มากกว่าข้อความทั่วไป อันดับ 2 โมเดล LSTM สามารถคาดการณ์พฤติกรรมของลูกค้าได้แม่นยำ โดยมีค่าความถูกต้องร้อยละ 88.70 และช่วยเพิ่มผลตอบแทนจากการลงทุนได้ร้อยละ 15.60 และ CNN มีความถูกต้องในการวิเคราะห์ภาพโฆษณาที่ร้อยละ 86.30 และช่วยเพิ่มอัตราการคลิกได้ร้อยละ 9.50 ซึ่งเป็นประโยชน์สำหรับการออกแบบโฆษณาที่มีประสิทธิภาพตามลำดับ

2. การเปรียบเทียบประสิทธิภาพโมเดลการเรียนรู้เชิงลึกสำหรับการวิเคราะห์ข้อมูลจากแพลตฟอร์มดิจิทัล ซึ่งงานวิจัยนี้ได้เปรียบเทียบ 3 โมเดล ได้แก่ 1) โมเดล BERT ใช้สำหรับวิเคราะห์ความคิดเห็นของลูกค้าและ Sentiment Analysis 2) โมเดล LSTM ใช้สำหรับวิเคราะห์ข้อมูลที่มีลำดับเวลา การตอบสนองต่อโฆษณา และ 3) โมเดล CNN ใช้สำหรับวิเคราะห์ภาพและองค์ประกอบของโฆษณา แสดงผลการวิจัยดังตารางที่ 2

ตารางที่ 2 ผลการเปรียบเทียบโมเดลการเรียนรู้เชิงลึกสำหรับการวิเคราะห์การตลาดดิจิทัล

Deep Learning Model	Accuracy	Precision	Recall	F1-Score	RMSE	การนำไปใช้
BERT	92.50	91.20	93.00	92.10	.15	วิเคราะห์ความคิดเห็นของลูกค้า
LSTM	88.70	87.90	89.20	88.50	.20	คาดการณ์แนวโน้มของพฤติกรรมผู้บริโภค
CNN	86.30	85.10	87.00	86.00	.25	วิเคราะห์ภาพโฆษณาและคอนเทนต์

จากตารางที่ 2 พบว่า โมเดล BERT มีความถูกต้องสูงสุดที่ร้อยละ 92.50 และสามารถวิเคราะห์ความคิดเห็นของลูกค้าได้ถูกต้องที่สุด โมเดล LSTM มีความถูกต้องที่ร้อยละ 88.70 มีความสามารถดีเยี่ยมในการพยากรณ์แนวโน้มของผู้บริโภค โดยสามารถวิเคราะห์ว่าช่วงไหนลูกค้าจะมีกำลังซื้อสูงสุด และโมเดล CNN มีความถูกต้องร้อยละ 86.30 เหมาะกับการวิเคราะห์องค์ประกอบภาพในโฆษณา ซึ่งช่วยให้สามารถออกแบบโฆษณาที่ดึงดูดความสนใจมากขึ้น ตามลำดับ

3. การประเมินประสิทธิภาพของการตลาดดิจิทัลโดยใช้ตัวชี้วัดทางการตลาด งานวิจัยได้ใช้ตัวชี้วัดหลักทางการตลาด (Key Performance Indicators: KPIs) ดังตารางที่ 3

ตารางที่ 3 ผลการวิเคราะห์การประเมินประสิทธิภาพการตลาดดิจิทัลโดยใช้ตัวชี้วัดทางการตลาด

Deep Learning Model	Engagement Rate	CTR	ROI
Deep Learning-Based Targeting	27.80	12.60	18.20
Traditional Targeting	15.30	8.40	10.70
A/B Testing	20.50	10.90	14.50

จากตารางที่ 3 พบว่า การกำหนดเป้าหมายตามการเรียนรู้เชิงลึก (Deep Learning-Based Targeting) ให้ผลลัพธ์ที่ดีที่สุดในทุกตัวชี้วัด โดยช่วยเพิ่มอัตราการมีส่วนร่วมร้อยละ 27.80 อัตราการคลิก ร้อยละ 12.60 และผลตอบแทนจากการลงทุน ร้อยละ 18.20 โดยที่ A/B Testing มีประสิทธิภาพดีกว่า การกำหนดกลุ่มเป้าหมายแบบดั้งเดิม (Traditional Targeting) โดยเพิ่มอัตราการคลิกเป็นร้อยละ 10.90 และผลตอบแทนจากการลงทุนร้อยละ 14.50 และการกำหนดกลุ่มเป้าหมายแบบดั้งเดิมมีประสิทธิภาพต่ำสุด โดยมีอัตราการมีส่วนร่วมร้อยละ 15.30 และผลตอบแทนจากการลงทุน ร้อยละ 10.70 ตามลำดับ

สรุปและอภิปรายผลการวิจัย

จากการศึกษาวิจัยเรื่องการประยุกต์ใช้การเรียนรู้เชิงลึกเพื่อวิเคราะห์ประสิทธิภาพการตลาดดิจิทัลในภาคธุรกิจ สามารถสรุปการอภิปรายผลได้ดังนี้

1. การวิเคราะห์ข้อความความคิดเห็นของลูกค้าโดยใช้โมเดล BERT ถูกนำมาใช้ในการวิเคราะห์ความคิดเห็นและอารมณ์ของลูกค้าจากโพสต์ คอมเมนต์ และรีวิว โดยให้ค่าความถูกต้องสูงสุดร้อยละ 92.50 และสามารถเพิ่มอัตราการมีส่วนร่วมของลูกค้าได้ถึงร้อยละ 25.00 ผลการศึกษาชี้ให้เห็นว่าการวิเคราะห์ความคิดเห็นของลูกค้าเป็นปัจจัยสำคัญในการปรับปรุงทางการตลาด โดยเฉพาะ

ข้อความเชิงบวกที่มีอิทธิพลต่อยอดขายมากกว่าข้อความทั่วไป ซึ่งสอดคล้องกับงานวิจัยของ Sayeed et al. (2023) ที่ประเมินประสิทธิภาพของ BERT ในการวิเคราะห์ความรู้สึกในหลากหลายบริบท เช่น การประมวลผลข้อความในภาษาต่าง ๆ ธุรกิจร้านอาหาร ภาคเกษตรกรรม ระบบให้คะแนนเรียงความอัตโนมัติ (AES) และแพลตฟอร์มสื่อสังคมออนไลน์ เช่น Twitter และ Google Play ผลการวิจัยยืนยันว่า BERT มีประสิทธิภาพเหนือกว่ามาตรฐานในงานด้านความเข้าใจภาษา เช่น การวิเคราะห์ความรู้สึก การจำแนกข้อความ การตอบคำถาม และการยอมรับทางภาษา อย่างไรก็ตาม งานวิจัยนี้ยังมีข้อจำกัดที่ควรพิจารณา ได้แก่ การที่โมเดล BERT ยังไม่สามารถตีความข้อความที่เป็นกลางหรือมีความกำกวมได้อย่างแม่นยำ เช่น ข้อความที่มีอารมณ์เชิงลบแฝงอยู่ในเชิงบวก รวมถึงการรับมือกับข้อมูลเท็จหรือการแสดงความคิดเห็นที่ไม่จริงใจ ซึ่งอาจส่งผลต่อความน่าเชื่อถือของการวิเคราะห์ในบริบทของตลาดที่มีการสื่อสารซับซ้อน ทั้งนี้ Rahman (2024) พบว่า BERT มีประสิทธิภาพเหนือกว่าโมเดลอื่น ๆ ทั้งในด้านความแม่นยำและความเร็วในการประมวลผล โดยสามารถบรรลุความแม่นยำสูงสุดถึงร้อยละ 95.00 จุดเด่นของ BERT คือความสามารถในการจัดการชุดข้อมูลขนาดใหญ่และซับซ้อน ซึ่งช่วยเพิ่มความแม่นยำของการวิเคราะห์ความรู้สึก ส่งผลให้คุณภาพการบริการและความภักดีของลูกค้าดีขึ้นอย่างมีนัยสำคัญ รวมถึงสามารถเพิ่มรายได้ขององค์กรได้มากถึงร้อยละ 15.00

2. งานวิจัยนี้มุ่งเน้นการพัฒนาและเปรียบเทียบประสิทธิภาพของโมเดลการเรียนรู้เชิงลึก 3 รูปแบบ ได้แก่ BERT, LSTM และ CNN ผลการศึกษาพบว่า โมเดล BERT มีความแม่นยำสูงสุดร้อยละ 92.50 และสามารถวิเคราะห์ความคิดเห็นของลูกค้าได้อย่างถูกต้องที่สุด โมเดล LSTM มีความแม่นยำร้อยละ 88.70 และมีประสิทธิภาพสูงในการพยากรณ์แนวโน้มของผู้บริโภค โดยสามารถระบุช่วงเวลาที่มีกำลังซื้อสูงสุด โมเดล CNN มีความแม่นยำร้อยละ 86.30 และเหมาะสำหรับการวิเคราะห์องค์ประกอบภาพในโฆษณา ซึ่งช่วยในการออกแบบสื่อโฆษณาที่สามารถดึงดูดความสนใจของลูกค้าได้อย่างมีประสิทธิภาพ การเปรียบเทียบนี้สอดคล้องกับงานวิจัยของ Bourahouat et al. (2024) และ Computer et al. (2023) ที่แสดงให้เห็นถึงประสิทธิภาพของการเลือกใช้โมเดลตามลักษณะของข้อมูลอย่างชัดเจน โดยเฉพาะกรณีที่ข้อมูลมีหลายรูปแบบ เช่น ข้อความและภาพ งานวิจัยนี้แสดงถึงผลกระทบเชิงบวกของการใช้โมเดลแบบ Hybrid ที่เลือกโมเดลให้เหมาะกับบริบทของข้อมูล ซึ่งช่วยให้องค์กรสามารถวิเคราะห์ข้อมูลได้ครบถ้วนและครอบคลุมยิ่งขึ้น

3. การประเมินประสิทธิภาพการตลาดดิจิทัลโดยใช้ตัวชี้วัดทางการตลาด พบว่า การกำหนดเป้าหมายตามการเรียนรู้เชิงลึก (Deep Learning-Based Targeting) ให้ผลลัพธ์ที่ดีที่สุดในทุกตัวชี้วัดสำคัญ โดยช่วยเพิ่มอัตราการมีส่วนร่วมเพิ่มขึ้นร้อยละ 27.80 อัตราการคลิกเพิ่มขึ้นร้อยละ 12.60 และผลตอบแทนจากการลงทุนเพิ่มขึ้นร้อยละ 18.20 ผลการศึกษานี้สอดคล้องกับงานวิจัยของ Ramagundam (2020) และ Beng & Ming (2020) ที่ชี้ให้เห็นว่าการประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องช่วยเพิ่มประสิทธิภาพในการจัดวางโฆษณาและการมีส่วนร่วมของผู้บริโภค โดยเฉพาะในเชิงปฏิบัติ ผลการวิจัยนี้สามารถนำไปใช้ในการวางแผนการตลาดที่มีความเฉพาะเจาะจง เช่น การแสดงโฆษณาเฉพาะบุคคลแบบเรียลไทม์ (Real-time Personalized Ads) การออกแบบข้อความและภาพโฆษณาที่ตอบสนองต่อความรู้สึกของกลุ่มเป้าหมาย รวมถึงการปรับงบประมาณสื่อโฆษณาโดยอิงจากประสิทธิภาพเชิงพฤติกรรมของลูกค้า ทั้งนี้แนวทางดังกล่าวสามารถนำไปประยุกต์ใช้ในแพลตฟอร์มต่าง ๆ เช่น Facebook Ads, Google Ads หรือแพลตฟอร์มการพาณิชย์อิเล็กทรอนิกส์ ได้อย่างมีประสิทธิภาพ

ข้อเสนอแนะ

ข้อเสนอแนะเพื่อนำผลการวิจัยไปใช้

1. จากผลการวิจัยพบว่าโมเดล BERT มีความแม่นยำสูงที่สุดในการวิเคราะห์ความคิดเห็นของลูกค้า โดยสามารถเพิ่มอัตราการมีส่วนร่วมของผู้ใช้งานได้ถึงร้อยละ 25 ดังนั้น ธุรกิจควรนำโมเดล BERT ไปประยุกต์ใช้ในการวิเคราะห์ข้อความจากสื่อสังคมออนไลน์อย่างเป็นระบบ เพื่อทำความเข้าใจความรู้สึกของลูกค้าและใช้ข้อมูลนี้ในการออกแบบเนื้อหาโฆษณาให้ตรงกับความคาดหวังและความต้องการของกลุ่มเป้าหมายอย่างมีประสิทธิภาพ

2. จากการเปรียบเทียบโมเดลทั้งสาม พบว่าแต่ละโมเดลเหมาะสมกับประเภทของข้อมูลที่แตกต่างกัน เช่น BERT เหมาะกับข้อความ, LSTM เหมาะกับข้อมูลลำดับเวลา และ CNN เหมาะกับภาพ ดังนั้น ควรพิจารณาการผสานการใช้งานโมเดล (Hybrid Model)

ให้เหมาะสมกับลักษณะข้อมูลที่ใช้งานจริงในธุรกิจ เพื่อเพิ่มความครอบคลุมและความแม่นยำของการวิเคราะห์ในทุกมิติของการตลาดดิจิทัล

3. จากการประเมินประสิทธิภาพการตลาดโดยใช้ Deep Learning-Based Targeting พบว่าให้ผลลัพธ์ที่ดีที่สุดในทุกตัวชี้วัด ทั้งในด้านอัตราการมีส่วนร่วม อัตราการคลิก และผลตอบแทนจากการลงทุน ดังนั้น ธุรกิจควรลงทุนในระบบการตลาดอัจฉริยะที่ใช้การเรียนรู้เชิงลึกในการกำหนดกลุ่มเป้าหมายแบบเรียลไทม์ รวมถึงปรับเนื้อหาและเวลาในการปล่อยโฆษณาให้เหมาะสมกับพฤติกรรมของลูกค้าในแต่ละช่วงเวลา

ข้อเสนอแนะในการวิจัยครั้งถัดไป

1. พัฒนา Explainable AI (XAI) เพื่อลดปัญหาการขาดความสามารถในการอธิบายการตัดสินใจ (Black Box Problem) ควรพัฒนา AI ที่สามารถอธิบายการตัดสินใจได้ เพื่อลดปัญหา “Black Box Problem” ซึ่งทำให้ไม่สามารถเข้าใจเหตุผลเบื้องหลังการตัดสินใจของโมเดลได้

2. เพิ่มแหล่งข้อมูลใหม่ เช่น เสียงและวิดีโอ เพื่อพัฒนาโมเดล Multi-Modal Learning ที่สามารถวิเคราะห์ข้อมูลจากหลายแหล่งพร้อมกัน ทำให้การประมวลผลและการตัดสินใจของ AI แม่นยำและครอบคลุมมากขึ้น

กิตติกรรมประกาศ

งานวิจัยนี้ได้รับการพิจารณาด้านจริยธรรมการวิจัยแบบยกเว้นจากคณะกรรมการจริยธรรมการวิจัยในมนุษย์ มหาวิทยาลัยราชภัฏร้อยเอ็ด เมื่อวันที่ 2 พฤษภาคม 2568

เอกสารอ้างอิง

Adwan, A. A., Kokash, H., Adwan, R. A., & Khattak, A. (2023). Data analytics in digital marketing for tracking the effectiveness of campaigns and inform strategy. *International Journal of Data and Network Science*, *7*(2), 563-574.

Alaparthi, S., & Mishra, M. (2020). Bidirectional encoder representations from transformers (BERT): A sentiment analysis odyssey. *Journal of Marketing Analytics*, *9*(2), 118-126.

Alghizzawi, M., Alhanatleh, H., Alhawamdeh, Z. M., Ahmed, E., & Al-Gasawneh, J. A. (2023). The Intersection of digital marketing and business performance. *Migration Letters*, *20*(8), 1202-1214.

Azad, H. K., Sharma, R., & Verma, R. (2024). Click-through rate analysis for understanding user behavior in information retrieval. *In 2024 15th International Conference on Computing Communication and Networking Technologies (ICCCNT)* (pp. 1-7). IEEE.

Bajeja, N. (2024). Digital marketing strategies to improve customer experience and engagement. *Journal of Informatics Education and Research*, *4*(1), 569-578.

Berliana, E. V., & Riasetiawan, M. (2024). Comparative analysis of naïve bayes classifier, support vector machine and decision tree in rainfall classification using confusion matrix. *International Journal of Advanced Computer Science & Applications*, *15*(7), 560-567.

Beng, T. W., & Ming, L. T. (2020). A Critical review on engagement rate and pattern on social media sites. *In International Conference on Digital Transformation and Applications* (pp. 1-4). ICDXA.

Bourahouat, G., Abourezq, M., & Daoudi, N. (2024). Improvement of Moroccan dialect sentiment analysis using Arabic BERT-based models. *Journal of Computer Science*, *20*(2), 157-167.

Chen, L., Pelger, M., & Zhu, J. (2024). Deep learning in asset pricing. *Management Science*, *70*(2), 714-750.

Computer, J. H., Honova, S. M., Computer, V. P., Setiawan, C. A., & Parmonangan, I. H. (2023). Sentiment Analysis of skincare product reviews in indonesian language using IndoBERT and LSTM. *In 2023 IEEE 9th Information Technology International Seminar (ITIS)* (pp. 1-6). IEEE.

Deepa, M. D. (2021). Bidirectional encoder representations from transformers (BERT) language model for sentiment analysis Task. *Turkish Journal of Computer and Mathematics Education (TURCOMAT)*, *12*(7), 1708-1721.

Fitrianingsih, F., & Zuraeni, B. (2024). Analisis ramalan cuaca di Sekupang, Kota Batam menggunakan algoritma decision tree dan confusion matrix. *EKOSPHERE: Jurnal Ekonomi Pembangunan dan Manajemen*, *1*(3), 15-26.

Ghahremani-Nahr, J., & Nozari, H. (2021). A survey for investigating key performance indicators in digital marketing. *International Journal of Innovation in Marketing Elements*, *1*(1), 1-6.

Hamdani, N. A., Muladi, R., & Maulani, G. A. F. (2022). Digital marketing impact on consumer decision-making process. *In 6th Global Conference on Business, Management, and Entrepreneurship (GCBME 2021)* (pp. 153-158). Bandung: Atlantis Press.

Heaton, J. (2018). Ian Goodfellow, Yoshua Bengio, and Aaron Courville: Deep learning. *Genetic Programming and Evolvable Machines*, *19*(1), 305-307.

Li, Z., Liu, F., Yang, W., Peng, S., & Zhou, J. (2021). A survey of convolutional neural networks: analysis, applications, and prospects. *IEEE Transactions on Neural Networks and Learning Systems*, *33*(12), 6999-7019.

Liu, B., Yu, L., Che, C., Lin, Q., Hu, H., & Zhao, X. (2023). Integration and performance analysis of artificial intelligence and computer vision based on deep learning algorithms**.***Applied and Computational Engineering*, *64*(1), 44-50**.**

Mijwil, M. M., & Aljanabi, M. (2023). A comparative analysis of machine learning algorithms for classification of diabetes utilizing confusion matrix analysis. *Baghdad Science Journal*, *20*(5). 1712-1728.

Rahardja, U. (2022). Social media analysis as a marketing strategy in online marketing business. *Startupreneur Business Digital (SABDA Journal)*, *1*(2), 176-182.

Rahman, B. (2024). Optimizing customer satisfaction through sentiment analysis: a BERT-based machine learning approach to extract insights. *IEEE Access*, 12, 151476-151489.

Ramagundam, S. (2020). Machine learning algorithmic approaches to maximizing user engagement through ad placements. *International Journal of Scientific Research in Computer Science Engineering and Information Technology*, *6*(3), 1163 – 1175.

Roy, S., Sharma, P., Nath, K., Bhattacharyya, D. K., & Kalita, J. K.. (2018). Pre-processing: a data preparation step. *Encyclopedia of Bioinformatics and Computational Biology*, 1, 463-471.

Sayeed, M. S., Mohan, V., & Muthu, K. S. (2023). BERT: A review of applications in sentiment analysis. *HighTech and Innovation Journal*, *4*(2), 453-462.

Sivarajah, U., Kamal, M. M., Irani, Z., & Weerakkody, V. (2017). Critical analysis of big data challenges and analytical methods. *Journal of Business Research*, 70, 263-286.

Smith, J. F. (2024). Using return on investment and resiliency return on investment for preparedness. *Public Administration Review*, *84*(2), 213-217.

Torres, J. F., Hadjout, D., Sebaa, A., Martínez-Álvarez, F., & Troncoso, A. (2021). Deep learning for time series forecasting: a survey. *Big Data*, *9*(1), 3-21.

Ullal, M. S., Hawaldar, I. T., Soni, R., & Nadeem, M. (2021). The role of machine learning in digital marketing. *Sage Open*, *11*(4), 1-12.

Van Houdt, G., Mosquera, C. & Nápoles, G. (2020). A review on the long short-term memory model. *Artificial Intelligence Review*, *53*(8), 5929-5955.

Wankhade, M., Rao, A. C. S. & Kulkarni, C. (2022). A survey on sentiment analysis methods, applications, and challenges. *Artificial Intelligence Review*, *55*(7), 5731-5780.

Yim, K. H. (2020). A study on digital marketing promotion strategy and implementation strategy implementation plan of global SMEs. *Journal of Digital Convergence*, *18*(11), 195-205.

Yoganandham, G. (2024). Evaluating the effectiveness of digital marketing strategies in higher education in India: impact on the sector and the construction of quality knowledge. *Degrés*, *9*(7), 12-26.