

## การจำแนกความรู้สึกเกี่ยวกับผลิตภัณฑ์เงินฝากจากข้อความบนสื่อสังคมออนไลน์ โดยใช้เทคนิคการเรียนรู้ของเครื่อง

พลอยพัชชา ชยานนท์มาศสกุล\*

คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์

วิหัย นาดี้

คณะพาณิชยศาสตร์และการบัญชี มหาวิทยาลัยธรรมศาสตร์

\*Correspondence: ploypatcha-cha66@tbs.tu.ac.th

doi: 10.14456/jisb.2025.9

วันที่รับบทความ: 28 ต.ค. 2568

วันแก้ไขบทความ: 7 ธ.ค. 2568

วันที่รับบทความ: 19 ธ.ค. 2568

### บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาโมเดลสำหรับจำแนกอารมณ์จากความคิดเห็นของผู้ใช้งานที่เกี่ยวข้องกับผลิตภัณฑ์เงินฝาก โดยรวบรวมข้อมูลจากแพลตฟอร์มเฟซบุ๊ก (Facebook) ของธนาคารพาณิชย์และสถาบันการเงินเฉพาะกิจในประเทศไทย รวมทั้งสิ้น 7,245 ความคิดเห็น ข้อความต้นฉบับซึ่งเป็นภาษาไทยได้ถูกแปลเป็นภาษาอังกฤษเพื่อนำไปใช้ในการฝึกโมเดล BERT-base-uncased สำหรับการจำแนกอารมณ์แบบหลายป้ายกำกับ (Multi-Label Classification) ใน 10 ประเภท ได้แก่ ความสุข ความโกรธ ความเศร้า ความกลัว ความไว้วางใจ ความรังเกียจ ความประหลาดใจ ความคาดหวัง อารมณ์เชิงบวก และอารมณ์เชิงลบ ผลการประเมินโมเดลที่ผ่านการฝึกจำนวน 5 รอบ (Epochs) พบว่าโมเดลสามารถจำแนกอารมณ์ได้อย่างแม่นยำ โดยมีค่า Precision เท่ากับ 0.9194, Recall เท่ากับ 0.8526, F1-score เท่ากับ 0.8847, ROC AUC เท่ากับ 0.9614 และ Accuracy เท่ากับ 0.6796 ผลการวิจัยชี้ให้เห็นว่าเทคนิคการเรียนรู้เชิงลึกสามารถนำมาประยุกต์ใช้เพื่อวิเคราะห์ความคิดเห็นของลูกค้าในเชิงอารมณ์ได้อย่างมีประสิทธิภาพ และมีศักยภาพในการนำไปใช้งานจริง เช่น ระบบวิเคราะห์ความรู้สึกลูกค้า ระบบแจ้งเตือนอัตโนมัติเมื่อเกิดความคิดเห็นด้านลบ หรือการออกแบบแคมเปญทางการตลาดที่ตอบสนองต่ออารมณ์ของผู้ใช้บริการได้ดียิ่งขึ้น

**คำสำคัญ:** การจำแนกอารมณ์; ความคิดเห็น; สื่อสังคมออนไลน์; การจำแนกแบบหลายป้ายกำกับ; โมเดลเบิร์ต; ผลิตภัณฑ์เงินฝาก

### Citation

Chayanonmasakul, C. and Nadee, W. (2025). Classifying Sentiments About Deposit Product from Social Media Texts Using Machine Learning Techniques [การจำแนกความรู้สึกเกี่ยวกับผลิตภัณฑ์เงินฝากจากข้อความบนสื่อสังคมออนไลน์ โดยใช้เทคนิคการเรียนรู้ของเครื่อง]. *Journal of Information Systems in Business*, 11(2). 32-53.

## **Classifying Sentiments About Deposit Product from Social Media Texts Using Machine Learning Techniques**

**Ploypatcha Chayanonmasakul\***

Thammasat Business School, Thammasat University

**Winai Nadee**

Thammasat Business School, Thammasat University

\*Correspondence: ploypatcha-cha66@tbs.tu.ac.th

doi: 10.14456/jisb.2025.9

### **Abstract**

This research aims to develop a model for classifying emotions expressed in user comments related to deposit products. A total of 7,245 comments were collected from the official Facebook pages of commercial banks and Specialized Financial Institutions (SFIs) in Thailand. The comments, originally written in Thai, were translated into English and used to fine-tune the BERT-base-uncased model for multi-label emotion classification across ten categories: Joy, Anger, Sadness, Fear, Trust, Disgust, Surprise, Anticipation, Positive, and Negative. After training the model for five epochs, the results demonstrated strong performance, with a Precision of 0.9194, Recall of 0.8526, F1-score of 0.8847, ROC AUC of 0.9614, and Accuracy of 0.6796. These findings suggest that deep learning techniques can be effectively applied to emotional analysis of customer feedback. The model can be integrated into real-world applications such as sentiment dashboards, automated alert systems for negative feedback, or marketing campaigns that respond appropriately to users' emotional tones.

**Keywords:** Emotion Classification; Comments; Social Media; Multi-label Classification; BERT Model; Deposit Products

## 1. บทนำ

ผลิตภัณฑ์เงินฝากเป็นผลิตภัณฑ์ที่มีความสำคัญในการเป็นแหล่งเงินทุนสำคัญในการสนับสนุนกิจกรรมทางเศรษฐกิจ ช่วยสร้างรายได้ให้กับธนาคารผ่านดอกเบี้ย เช่น การปล่อยสินเชื่อ การลงทุน และการบริหารสภาพคล่องทางการเงินของธนาคาร รวมถึงเป็นเครื่องมือที่สำคัญในการสร้างความสัมพันธ์ระยะยาวระหว่างธนาคารและลูกค้า ผลิตภัณฑ์ด้านเงินฝากยังเป็นที่นิยมสำหรับคนไทยอย่างมาก ผลสำรวจการเข้าถึงบริการทางการเงินภาคครัวเรือนปี 2565 (ธนาคารแห่งประเทศไทย, 2566) แสดงให้เห็นว่ามีสัดส่วนการเข้าถึงบริการด้านเงินฝาก เท่ากับ ร้อยละ 89.6 รองจากบริการด้านการชำระเงินที่มีสัดส่วน เท่ากับ ร้อยละ 89.7 การเติบโตของยอดเงินฝากในระบบเศรษฐกิจเพิ่มขึ้นอย่างชัดเจน ถึงแม้เศรษฐกิจจะได้รับผลกระทบจากสถานการณ์โรคติดเชื้อไวรัสโคโรนา 2019 (COVID-19) แต่ยอดเงินฝากยังคงเติบโตอย่างต่อเนื่อง ตามรายงานติดตามภาวะเงินฝากและการออม ณ เดือน มี.ค. 2567 (ศูนย์วิจัยธนาคารออมสิน, 2567) ซึ่งตั้งแต่เดือน ก.ย. 2566 - มี.ค. 2567 ปริมาณเงินรับฝากรวมเริ่มกลับมามีทิศทางปรับเพิ่มขึ้น ส่วนหนึ่งเป็นผลจากอัตราดอกเบี้ยเงินฝากที่เพิ่มขึ้นตามการปรับขึ้นอัตราดอกเบี้ยนโยบายของไทย และทรงตัวอยู่ในระดับสูง รวมถึงความเชื่อมั่นของประชาชนที่เริ่มกลับมาจากเศรษฐกิจไทยที่ฟื้นตัวอย่างต่อเนื่อง ด้านความก้าวหน้าของเทคโนโลยีสื่อสังคมออนไลน์ (Social Media) เข้ามามีบทบาทสำคัญในการหาข้อมูลข่าวสารต่าง ๆ รวมถึงข้อมูลเกี่ยวกับผลิตภัณฑ์และบริการทางการเงิน หรือแนวโน้มทางเศรษฐกิจสามารถแพร่กระจายได้อย่างรวดเร็ว ผู้ฝากเงินหรือผู้บริโภคสามารถเข้าถึงข้อมูลและแสดงความคิดเห็นเกี่ยวกับผลิตภัณฑ์ทางการเงินได้สะดวก ซึ่งทำให้ธนาคารสามารถรับรู้ความต้องการของลูกค้าและทำการปรับปรุงผลิตภัณฑ์ให้เหมาะสมกับความต้องการของตลาดได้อย่างรวดเร็ว โดยเฉพาะในส่วนของผลิตภัณฑ์เงินฝาก เช่น บัญชีออมทรัพย์ บัญชีเงินฝากประจำ ที่เป็นฐานสำคัญในการระดมทุนของธนาคาร เหตุผลการใช้สื่อสังคมออนไลน์ของคนไทย (ปรีดี นกุลสมปรารถนา, 2567) แสดงให้เห็นถึงสาเหตุของการใช้สื่อสังคมออนไลน์ของคนไทย ในอันดับที่ 2 ใช้เพื่ออ่านข้อมูลข่าวสาร ร้อยละ 39.2 อันดับที่ 4 ใช้เพื่อส่งดูว่ามีใครกำลังพูดถึงเรื่องอะไรบ้าง ร้อยละ 35.9 และอันดับที่ 5 ใช้เพื่อค้นหาแรงบันดาลใจในการทำอะไรมาก ๆ รวมถึงซื้อสินค้า ร้อยละ 32.3 นอกจากนี้ แพลตฟอร์มสื่อสังคมออนไลน์ที่ได้รับความนิยมของคนไทย (ปรีดี นกุลสมปรารถนา, 2567) เป็นอันดับ 1 คือ เฟซบุ๊ก (Facebook) ทำให้เห็นว่าเฟซบุ๊กเป็นแพลตฟอร์ม (Platform) ที่มีความเหมาะสมสำหรับการนำมาใช้เป็นกลุ่มตัวอย่างในงานวิจัย เนื่องจากมีการแลกเปลี่ยนความคิดเห็นและข้อมูลอย่างแพร่หลาย ผู้วิจัยจึงเลือกใช้ข้อมูลความคิดเห็นจากแพลตฟอร์มเฟซบุ๊กเพื่อเป็นฐานข้อมูลในการวิเคราะห์ด้วยเทคนิคการเรียนรู้ของเครื่อง โดยกลุ่มเป้าหมายที่ศึกษาคือความคิดเห็น (Comment) ที่ปรากฏในโพสต์ (Post) ที่เกี่ยวข้องกับผลิตภัณฑ์เงินฝากของธนาคาร จากเพจ (Page) เฟซบุ๊กอย่างเป็นทางการของธนาคารพาณิชย์ในประเทศไทย ได้แก่ ธนาคารกรุงเทพ ธนาคารไทยพาณิชย์ ธนาคารกรุงศรีอยุธยา ธนาคารกรุงไทย ธนาคารกสิกรไทย และธนาคารไทยชนชาติ รวมถึงสถาบันการเงินเฉพาะกิจ ได้แก่ ธนาคารออมสิน ความก้าวหน้าในการเรียนรู้ของเครื่องจักรและการเรียนรู้เชิงลึกช่วยเพิ่มความสามารถในการประมวลผลและวิเคราะห์ชุดข้อมูลขนาดใหญ่ได้อย่างมาก เทคโนโลยีเหล่านี้เหมาะเป็นอย่างยิ่งสำหรับการจัดการข้อมูลที่ซับซ้อนและละเอียดอ่อนที่พบในสื่อสังคมออนไลน์ เนื่องจากสามารถระบบรูปแบบและทำนายข้อมูลโดยอาศัยข้อความและพฤติกรรมได้ (Cao et al., 2024) ช่วยให้การวิเคราะห์เชิงพยากรณ์มีประสิทธิภาพมากขึ้น ทำให้สถาบันการเงินสามารถตัดสินใจได้อย่างมีข้อมูลและแม่นยำ ด้วยการประเมินข้อมูลที่ไหลเข้ามาแบบเวลาจริงและการวิเคราะห์แนวโน้มในอดีต ช่วยให้เกิดความแม่นยำและความรวดเร็วในการวางแผนและตัดสินใจ (Raman & Tiwari, 2024) การนำการเรียนรู้ของเครื่องมาใช้กับผลิตภัณฑ์และกิจกรรมทางการเงินได้กลายเป็นเรื่องธรรมดา (Dhatterwal et al., 2023) ซึ่งโมเดลเทคนิคการเรียนรู้ของเครื่อง (Machine Learning Model) มีหลากหลายประเภท ซึ่งในงานวิจัยนี้สนใจที่จะศึกษาเทคนิคการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Learning) และเนื่องจากการเป็นการศึกษาที่เกี่ยวข้องกับข้อความบนสื่อสังคมออนไลน์มาใช้วิเคราะห์ความรู้สึก (Sentiment Analysis) เกี่ยวกับผลิตภัณฑ์เงินฝาก โดยใช้ชุดข้อมูลข้อความความคิดเห็นเกี่ยวกับผลิตภัณฑ์เงินฝากจากสื่อสังคมออนไลน์ที่มีการกำหนดป้ายกำกับ (Labels) ในการจำแนกอารมณ์ออกเป็น 10 ประเภท ได้แก่

ความสุข (Joy), ความโกรธ (Anger), ความเศร้า (Sadness), ความกลัว (Fear), ความไว้วางใจ (Trust), ความรังเกียจ (Disgust), ความประหลาดใจ (Surprise), ความคาดหวัง (Anticipation), เชิงบวก (Positive) และ เชิงลบ (Negative) งานวิจัยนี้ใช้ NRC Emotion Lexicon (Mohammad & Turney, 2013) ในการสร้างป้ายกำกับสำหรับข้อความ โดยอาศัยฐานข้อมูลคำศัพท์ที่เชื่อมโยงคำกับอารมณ์ต่าง ๆ ตามทฤษฎี Plutchik ซึ่งได้รับการยอมรับอย่างแพร่หลายในงานวิจัยด้านจิตวิทยาและงานประมวลผลภาษาธรรมชาติ (NLP) โดยครอบคลุมอารมณ์สำคัญทั้งด้านบวก ด้านลบ และอารมณ์คาดหวังล่วงหน้า (anticipatory emotions) ซึ่งมีความเกี่ยวข้องโดยตรงกับพฤติกรรมผู้บริโภคในบริบทการเงิน เช่น ความสุขและความไว้วางใจที่สื่อถึงความพึงพอใจต่อผลิตภัณฑ์ ความคาดหวังที่สะท้อนความต้องการหรือความสนใจในบริการใหม่ ๆ ตลอดจนความกลัวหรือความกังวลที่อาจเกี่ยวข้องกับความเสี่ยงในการตัดสินใจทางการเงิน นอกจากนี้ การเลือกใช้กรอบอารมณ์แบบหลายป้ายกำกับ (Multi-label) สอดคล้องกับองค์ความรู้ด้านจิตวิทยาที่ว่าอารมณ์มนุษย์สามารถเกิดร่วมกันได้มากกว่าหนึ่งมิติ และช่วยให้โมเดลสามารถจับ “ความละเอียดอ่อนทางอารมณ์” ได้ดียิ่งขึ้นในบริบทธุรกิจธนาคารที่ต้องการความแม่นยำด้าน Emotional Intelligence และยิ่งช่วยให้โมเดลสามารถเรียนรู้จากข้อมูลที่มีความเชื่อมโยงกับอารมณ์ในบริบทที่หลากหลาย เพิ่มความแม่นยำในการจำแนกประเภทข้อความ สำหรับการวิเคราะห์ความรู้สึก (Sentiment Analysis) ที่เกี่ยวข้องกันผลิตภัณฑ์เงินฝาก

นอกจากนี้การวิเคราะห์ความรู้สึกและการจดจำอารมณ์ครอบคลุมการประเมินและทำความเข้าใจอารมณ์ของบุคคลหรือกลุ่มคนผ่านช่องทางต่าง ๆ เช่น ข้อความ เสียง สีหน้าท่าทาง และภาษากาย ด้วยศักยภาพที่สามารถนำไปประยุกต์ใช้ในอุตสาหกรรมหลากหลาย ไม่ว่าจะเป็นการดูแลสุขภาพ การศึกษา หรือการติดตามความคิดเห็นบนสื่อสังคมออนไลน์ สาขาที่จึงได้รับความสนใจเพิ่มขึ้นอย่างรวดเร็วในช่วงที่ผ่านมา (Arano et al., 2021) BERT ได้รับความสนใจอย่างมาก แม้ว่าโมเดลเหล่านี้สามารถประมวลผลข้อความประเภทต่าง ๆ ได้หลากหลาย (Khan et al., 2024) แต่ BERT นั้นเป็นโมเดลที่รองรับเฉพาะภาษาอังกฤษ ซึ่งโมเดล BERT ถือเป็นหนึ่งในโมเดลที่ได้รับความนิยมสูงสำหรับการประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) เนื่องจากสามารถจัดการข้อความประเภทต่าง ๆ ได้อย่างมีประสิทธิภาพ (Khan et al., 2024) แม้ว่าโมเดล BERT ดั้งเดิม เช่น Bert-base-uncased จะรองรับเฉพาะภาษาอังกฤษ แต่ในการวิจัยนี้ได้มีการใช้วิธีการแปลข้อความภาษาไทยเป็นภาษาอังกฤษก่อน จากนั้นจึงนำข้อความที่แปลแล้วเข้าสู่กระบวนการวิเคราะห์ด้วย BERT เพื่อให้สามารถประยุกต์ใช้โมเดลนี้กับข้อมูลภาษาไทยได้อย่างเหมาะสม

การศึกษานี้ได้ประยุกต์ใช้โมเดล BERT ที่เป็นเทคนิคการเรียนรู้ของเครื่อง ซึ่งมีความสามารถในการเข้าใจบริบทของภาษาอย่างลึกซึ้ง เพื่อจำแนกอารมณ์ของลูกค้ายออกเป็น 10 ประเภทที่หลากหลาย โดยข้อความต้นฉบับที่เป็นภาษาไทยจะถูกแปลเป็นภาษาอังกฤษก่อนเข้าสู่กระบวนการวิเคราะห์ เพื่อเพิ่มความแม่นยำในการตรวจจับความรู้สึกและทัศนคติของลูกค้า ทั้งในเชิงบวก เชิงลบ และอารมณ์เชิงซ้อนอื่น ๆ ที่สะท้อนความพึงพอใจ ความคาดหวัง หรือความไม่พอใจต่อผลิตภัณฑ์เงินฝากของธนาคาร โดยมีวัตถุประสงค์ของการวิจัยด้วยการนำโมเดลเทคนิคการเรียนรู้ของเครื่อง BERT มาปรับแต่ง (Fine-Tune) ให้เข้ากับข้อมูล เพื่อจำแนกความรู้สึกจากข้อความบนสื่อสังคมออนไลน์เกี่ยวกับผลิตภัณฑ์เงินฝาก และเพื่อประเมินประสิทธิภาพการทำงานของโมเดลในการจำแนกความรู้สึกจากข้อความบนสื่อสังคมออนไลน์เกี่ยวกับผลิตภัณฑ์เงินฝาก โดยใช้เทคนิคการเรียนรู้ของเครื่อง นอกจากนี้การศึกษานี้เป็นการศึกษาโดยเก็บข้อมูลจากความคิดเห็น (Comment) ของโพสต์ที่ผู้ใช้งานบนสื่อสังคมออนไลน์ที่เป็นภาษาไทย จากเพจเฟซบุ๊กอย่างเป็นทางการของธนาคารพาณิชย์ในประเทศไทย ได้แก่ ธนาคารกรุงเทพ ธนาคารไทยพาณิชย์ ธนาคารกรุงศรีอยุธยา ธนาคารกรุงไทย ธนาคารกสิกรไทย และธนาคารไทยธนชาติ รวมถึงสถาบันการเงินเฉพาะกิจ ได้แก่ ธนาคารออมสิน โดยเก็บรวบรวมข้อมูลของโพสต์เกี่ยวกับเงินฝากในเพจของธนาคารทั้งหมดที่มีการโพสต์ตั้งแต่ มกราคม 2567 – กุมภาพันธ์ 2568 แบบไม่ระบุตัวตน นำข้อความจากสื่อสังคมออนไลน์มาวิเคราะห์และนำมาประมวลผลภาษาธรรมชาติ (NLP) เพื่อให้สามารถใช้ในแบบจำลองการเรียนรู้ของเครื่องได้

## 2. ทฤษฎีและงานวิจัยในอดีตที่เกี่ยวข้อง

### 2.1 แนวคิดเกี่ยวกับการเรียนรู้ของเครื่อง

#### 2.1.1 การเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Learning)

การเรียนรู้ของเครื่องแบบมีผู้สอน เป็นกระบวนการที่ระบบเรียนรู้จากข้อมูลที่ถูกป้ายกำกับไว้แล้ว หมายความว่า ข้อมูลที่ใช้ในการฝึกสอนประกอบไปด้วยข้อมูลนำเข้า (Input) และผลลัพธ์ (Output) ที่ถูกต้อง ระบบจะถูกฝึกให้จดจำรูปแบบความสัมพันธ์ระหว่างข้อมูลนำเข้าและผลลัพธ์ และนำมาใช้ในการทำนายผลลัพธ์ของข้อมูลใหม่ ๆ ได้ ตัวอย่างเช่น การทำนายราคาอสังหาริมทรัพย์จากข้อมูลขนาดพื้นที่และที่ตั้งเพื่อให้ได้ราคาที่คาดการณ์ไว้ (Alloghani et al., 2020) ซึ่งการเรียนรู้ของเครื่องแบบมีผู้สอน แบ่งออกได้เป็น 2 ประเภท ได้แก่ 1) การจำแนกประเภท (Classification) เป็นการจัดกลุ่มข้อมูลลงในประเภทต่าง ๆ เช่น การจำแนกอีเมล (e-mail) ว่าเป็นสแปม (Spam) หรือไม่เป็นสแปม 2) การถดถอย (Regression) เป็นการคาดการณ์ค่าตัวเลขต่อเนื่อง เช่น การทำนายยอดขายหรือราคาหุ้น

#### 2.1.2 การเรียนรู้ของเครื่องแบบไม่มีผู้สอน (Unsupervised Learning)

การเรียนรู้ของเครื่องแบบไม่มีผู้สอน ข้อมูลที่ใช้ในการฝึกจะไม่มีป้ายกำกับผลลัพธ์ไว้ ระบบจะพยายามค้นหารูปแบบหรือความสัมพันธ์ภายในข้อมูลด้วยตัวเอง ตัวอย่างเช่น การแบ่งกลุ่มลูกค้าโดยพิจารณาจากพฤติกรรมหรือการซื้อสินค้าหรือการวิเคราะห์แนวโน้มของข้อมูล (Wu et al., 2021) ซึ่งการเรียนรู้แบบไม่มีผู้สอน แบ่งออกได้เป็น 2 ประเภท ได้แก่ 1) การจัดกลุ่ม (Clustering) เป็นการจัดกลุ่มข้อมูลที่มีลักษณะคล้ายกันให้อยู่ในกลุ่มเดียวกัน เช่น การแบ่งกลุ่มลูกค้าตามลักษณะการซื้อ 2) การหาความสัมพันธ์ (Association) เป็นการหาความสัมพันธ์ระหว่างชุดข้อมูล เช่น การแนะนำสินค้าที่มักถูกซื้อพร้อมกัน

#### 2.1.3 การเรียนรู้ของเครื่องโดยการเสริมแรง (Reinforcement Learning)


การเรียนรู้ของเครื่องโดยการเสริมแรง เป็นกระบวนการที่ระบบเรียนรู้โดยการทดลองและความผิดพลาด โดยจะมีตัวแทน (Agent) ทำการกระทำ (Actions) กับสภาพแวดล้อม (Environment) เพื่อให้ได้ผลตอบแทน (Reward) กลับมา ตัวแทนจะเรียนรู้จากผลตอบแทนที่ได้และปรับปรุงการกระทำของตนเองเพื่อให้ได้ผลตอบแทนสูงสุด (Sarker, 2021) ตัวอย่างเช่น การสอนคอมพิวเตอร์ให้เล่นเกมหรือการควบคุมหุ่นยนต์ให้เดิน ในการฝึกสอนการเรียนรู้โดยการเสริมแรง ระบบจะเรียนรู้วิธีการตัดสินใจที่ดีที่สุดโดยพิจารณาผลตอบแทนจากการกระทำต่าง ๆ ที่เกิดขึ้น และจะพัฒนากลยุทธ์ในการแก้ไขปัญหาเพื่อให้ได้ผลลัพธ์ที่ต้องการในระยะยาวซึ่งในงานวิจัยนี้ได้ประยุกต์ใช้เทคนิคการเรียนรู้ของเครื่องแบบมีผู้สอน (Supervised Learning) สำหรับการจำแนกประเภท โดยเลือกใช้โมเดล BERT (Bidirectional Encoder Representations from Transformers) ซึ่งเป็นโมเดลภาษาเชิงลึกที่ผ่านการฝึกฝนล่วงหน้าด้วยชุดข้อมูลภาษาอังกฤษขนาดใหญ่ และได้รับการยอมรับอย่างกว้างขวางในงานด้านการประมวลผลภาษาธรรมชาติ เนื่องจากสามารถทำความเข้าใจบริบทของคำในประโยคได้อย่างแม่นยำทั้งจากด้านหน้าและด้านหลัง ซึ่งช่วยให้โมเดลสามารถประมวลผลข้อมูลภาษาได้ในเชิงลึกกว่าระบบเดิมที่มีทิศทางเดียว

อย่างไรก็ตาม เนื่องจาก BERT-base รองรับเฉพาะภาษาอังกฤษ ข้อความภาษาไทยจากสื่อสังคมออนไลน์จึงจำเป็นต้องได้รับการแปลเป็นภาษาอังกฤษก่อน เพื่อให้สามารถนำโมเดลได้อย่างถูกต้อง โดยงานวิจัยนี้ใช้โมเดลแปลภาษาจาก Hugging Face เพื่อรักษาโครงสร้างและบริบทของข้อความต้นฉบับให้ได้มากที่สุด จากนั้นจึงนำข้อความที่แปลแล้วไปผ่านกระบวนการปรับแต่งโมเดล (Fine-tuning) ด้วยชุดข้อมูลความคิดเห็นที่มีการระบุอารมณ์ไว้ล่วงหน้า เพื่อให้ BERT สามารถเรียนรู้ลักษณะเฉพาะของข้อความที่เกี่ยวข้องกับผลิตภัณฑ์เงินฝากของธนาคาร และสามารถจำแนกอารมณ์ออกเป็น 10 ประเภท ได้แก่ ความสุข, ความโกรธ, ความเศร้า, ความกลัว, ความไว้วางใจ, ความรังเกียจ, ความประหลาดใจ, ความคาดหวัง, เชิงบวก และเชิงลบ ได้อย่างแม่นยำ ซึ่งจัดอยู่ในกลุ่มปัญหาแบบหลายป้ายกำกับ (Multi-class Classification) ที่ข้อความหนึ่งสามารถแสดงอารมณ์ได้มากกว่าหนึ่งประเภท

แนวทางดังกล่าวได้รับการสนับสนุนจากงานของ Wei & Dihong (2024) ที่ชี้ให้เห็นว่าการนำโมเดลภาษาขนาดใหญ่ (Large Language Models: LLMs) ไปฝึกเพิ่มเติมด้วยข้อมูลเฉพาะทางสามารถเพิ่มประสิทธิภาพของการวิเคราะห์ความรู้สึกในบริบทการเงินได้อย่างชัดเจน อีกทั้งงานของ Gutiérrez-Fandiño et al. (2021) ยังยืนยันว่าการฝังเวกเตอร์ข้อความโดยคำนึงถึงบริบท (Contextual Embedding) โดยเฉพาะในสาขาที่มีลักษณะเฉพาะ เช่น ข้อความทางการเงินจะช่วยให้การจำแนกประเภทของข้อความมีความแม่นยำและเสถียรมากขึ้นเมื่อนำไปประยุกต์ใช้กับข้อมูลจริงการประยุกต์ใช้โมเดล BERT ที่ผ่านการปรับแต่งโมเดล (Fine-Tune) กับข้อมูลความคิดเห็นเกี่ยวกับผลิตภัณฑ์เงินฝากในงานวิจัยนี้ จึงมีเป้าหมายเพื่อทำความเข้าใจความรู้สึก ทศนคติ และความคาดหวังของลูกค้าในระดับที่ลึกยิ่งขึ้น ซึ่งข้อมูลเชิงลึกเหล่านี้สามารถนำไปใช้สนับสนุนการออกแบบผลิตภัณฑ์ บริการ และกลยุทธ์ทางการตลาดที่ตรงับอารมณ์และความต้องการของลูกค้าได้อย่างมีประสิทธิภาพ

## 2.2 การจำแนกความรู้สึกและอารมณ์

การวิเคราะห์ความรู้สึก (Sentiment Analysis) ขั้นตอนของการวิเคราะห์ความรู้สึกประกอบด้วยการดึงคุณลักษณะจากข้อมูลข้อความ สร้างโมเดลตัวจำแนกและประเมินประสิทธิภาพ วิธีการที่เป็นมาตรฐานนี้ถูกนำไปใช้กับงานการจำแนกความรู้สึกหลากหลาย เช่น การจำแนกรีวิว (Review) ภาพยนตร์ การรีวิวสินค้าออนไลน์ (Online) และข้อความทวิต (Tweet) บนสื่อสังคมออนไลน์ (Baz et al., 2022) นอกจากนี้ยังเป็นกระบวนการที่ช่วยในการระบุและวิเคราะห์อารมณ์หรือความคิดเห็นที่แฝงอยู่ในข้อความ โดยมีเป้าหมายหลักคือการวิเคราะห์โพลาริตี (Polarity) ของข้อความ เช่น เชิงบวก, เชิงลบ หรือเป็นกลาง (Neutral) (Wei & Dihong, 2024) รวมถึงการจัดประเภทแบบหลายป้ายกำกับ (Multi - Classification) เพื่อเจาะลึกถึงระดับหรือประเภทของอารมณ์ที่ซับซ้อนมากขึ้น เช่น งานวิจัยของ Plisiecki et al. (2024) ที่จัดประเภทอารมณ์มาใช้ในการประเมินและทำข้อมูลประกอบข้อความที่เกี่ยวข้องกับการเมืองในสื่อสังคมออนไลน์ของประเทศโปแลนด์ เพื่อตีความเนื้อหาและอารมณ์ที่แฝงอยู่ในข้อความอย่างมีประสิทธิภาพ โดยแบ่งออกเป็น 6 ประเภทหลัก ได้แก่ ความสุข (Happiness), ความเศร้า (Sadness), ความโกรธ (Anger), ความกลัว (Fear), ความรังเกียจ (Disgust) และ ความภาคภูมิใจ (Pride) ทฤษฎีอารมณ์เชิงวิวัฒนาการของ Plutchik (Plutchik's Psycho-evolutionary Theory of Emotion) เป็นหนึ่งในทฤษฎีที่ได้รับการอ้างอิงอย่างแพร่หลายในงานศึกษาด้านอารมณ์ โดยนักจิตวิทยาชาวอเมริกัน Robert Plutchik ได้เสนอว่าอารมณ์เป็นกลไกที่วิวัฒนาการขึ้นเพื่อช่วยให้สิ่งมีชีวิตสามารถตอบสนองต่อสถานการณ์ต่าง ๆ ได้อย่างเหมาะสมและเอาตัวรอดได้ในสภาพแวดล้อมที่เปลี่ยนแปลง ซึ่งงานวิจัยของ Saravia et al. (2018) ได้ระบุว่าในงานวิจัยด้านอารมณ์มักนิยมใช้วงล้ออารมณ์ของ Plutchik (Plutchik's Wheel of Emotion) เป็นพื้นฐานในการกำหนดประเภทของอารมณ์ ดังภาพที่ 1 ทฤษฎีวงล้ออารมณ์ของ Plutchik



ภาพที่ 1 ทฤษฎีวงล้ออารมณ์ของ Plutchik จาก The Emotion Wheel: What It Is and How to Use It.  
แหล่งที่มา: Karimova (2017)

ตามทฤษฎีวงล้ออารมณ์ของ Plutchik (1980) อารมณ์ของมนุษย์สามารถจำแนกออกเป็น 8 ประเภทหลัก ได้แก่ ความสุข, ความไว้วางใจ, ความกลัว, ความประหลาดใจ, ความเศร้า, ความรังเกียจ, ความโกรธ และความคาดหวัง ซึ่งเป็นอารมณ์พื้นฐานที่พบได้บ่อยในการตอบสนองของมนุษย์ทั้งในเชิงชีววิทยาและพฤติกรรมทางสังคม แนวคิดนี้ได้รับการนำมาใช้ในงานวิเคราะห์ข้อความ เนื่องจากสามารถสะท้อนความรู้สึกที่ปรากฏในถ้อยคำของผู้ใช้งานได้อย่างมีโครงสร้างและครอบคลุม

ในงานวิจัยนี้ ผู้วิจัยได้เลือกใช้อารมณ์จำนวน 10 ประเภท ได้แก่ ความสุข, ความไว้วางใจ, ความกลัว, ความประหลาดใจ, ความเศร้า, ความรังเกียจ, ความโกรธ ความคาดหวัง เชิงบวก และเชิงลบ โดยอิงจากทฤษฎีวงล้ออารมณ์ของ Plutchik ซึ่งเสนอว่าอารมณ์พื้นฐานของมนุษย์ประกอบด้วย 8 ประเภทแรก และพบได้บ่อยในบริบทของความคิดเห็นที่ปรากฏบนสื่อสังคมออนไลน์ โดยเฉพาะความคิดเห็นที่เกี่ยวข้องกับผลิตภัณฑ์ทางการเงิน เช่น ความพึงพอใจ ความคาดหวัง ความไม่พอใจ หรือความรู้สึกเชื่อมั่นต่อแบรนด์

สำหรับอารมณ์เชิงบวกและเชิงลบ แม้จะไม่ได้อยู่ในกลุ่มอารมณ์หลักของ Plutchik แต่มีความสำคัญอย่างยิ่งในเชิงบริบท เนื่องจากสามารถสะท้อน “ทิศทางของความรู้สึกโดยรวม” หรือโพลาริตีของข้อความได้อย่างชัดเจน โดยอิงจากแนวคิด Polarity of Words ตาม NRC Word-Emotion Association Lexicon (Mohammad & Turney, 2013) ซึ่งเหมาะสมกับลักษณะของความคิดเห็นที่พบในโลกความเป็นจริง และช่วยให้สามารถวิเคราะห์อารมณ์ของผู้ใช้งานในบริบทของผลิตภัณฑ์เงินฝากได้อย่างครอบคลุมมากยิ่งขึ้น โดยในบริบทของข้อความบนสื่อสังคมออนไลน์ที่เกี่ยวข้องกับเงินฝากมีความสำคัญอย่างยิ่งในยุคดิจิทัลที่ผู้คนมักแสดงความคิดเห็นเกี่ยวกับผลิตภัณฑ์และบริการผ่านแพลตฟอร์มออนไลน์ เช่น เฟซบุ๊ก, อินสตาแกรม (Instagram) และ เรดดิท (Reddit) ซึ่งมีความสำคัญเนื่องจากสามารถส่งผลกระทบและสะท้อนแนวโน้มในตลาดการเงินได้ (Chan & Chong, 2016) ข้อมูลที่มาจากแหล่งเหล่านี้ช่วยให้สถาบันการเงินสามารถเข้าใจทัศนคติและความคาดหวังของลูกค้าได้อย่างลึกซึ้ง ทั้งในแง่ของความพึงพอใจและความไม่พอใจต่อผลิตภัณฑ์เงินฝาก เช่น อัตราดอกเบี้ย การให้บริการ หรือโปรโมชั่นพิเศษ การวิเคราะห์ข้อความจาก

สื่อสังคมออนไลน์ช่วยเปิดเผยข้อมูลที่เป็นประโยชน์ต่อการวางกลยุทธ์ทางการตลาด การปรับปรุงบริการ และการสร้างความพึงพอใจแก่ลูกค้า

ในด้านเงินฝากการวิเคราะห์ความรู้สึกมีบทบาทสำคัญในการช่วยให้ธนาคารหรือสถาบันการเงินสามารถระบุความคิดเห็นที่สะท้อนถึงประสบการณ์จริงของลูกค้า เช่น หากมีผู้ใช้บริการโพสต์ข้อความว่า “ดอกเบี้ยเงินฝากต่ำกว่าธนาคารอื่นมาก” หรือ “การเปิดบัญชีออนไลน์ยุ่งยากและซับซ้อน” ข้อความเหล่านี้สามารถชี้ให้เห็นถึงจุดอ่อนของบริการที่อาจต้องได้รับการปรับปรุง (Wei & Dihong, 2024) ในทางกลับกันข้อความที่มีลักษณะเชิงบวก เช่น “ธนาคารนี้มีขั้นตอนการเปิดบัญชีที่ง่ายและสะดวก” หรือ “โปรโมชั่นเงินฝากสุดคุ้มที่ให้ดอกเบี้ยสูง” แสดงถึงความพึงพอใจของลูกค้า ซึ่งข้อมูลเหล่านี้สามารถนำไปใช้ในการสื่อสารและขยายผลความสำเร็จของบริการได้อย่างมีประสิทธิภาพ (Gutiérrez-Fandiño et al., 2021) การวิเคราะห์ข้อความเหล่านี้อาศัยเทคโนโลยีขั้นสูง เช่น การประมวลผลภาษาธรรมชาติ (Natural Language Processing: NLP) และการเรียนรู้ของเครื่อง (Machine Learning) โดยอาจใช้โมเดลพื้นฐาน เช่น Naïve Bayes หรือ Logistic Regression ไปจนถึงโมเดลที่ซับซ้อนกว่า เช่น Transformer-Based Models อย่าง BERT และ RoBERTa ที่ช่วยจับบริบทของข้อความและแยกแยะอารมณ์ในข้อความได้อย่างแม่นยำ (Liu et al., 2019) นอกจากนี้ยังสามารถใช้ Lexicon-Based Analysis ที่พึ่งพาฐานข้อมูลคำศัพท์ที่มีการเชื่อมโยงกับอารมณ์ความคิดเห็น เช่น SentiWordNet หรือ Financial Sentiment Lexicon ซึ่งเหมาะสำหรับการวิเคราะห์ข้อความที่มีความเกี่ยวข้องกับการเงินโดยเฉพาะ (Araque et al., 2019) Sentiment Analysis ไม่เพียงช่วยในเรื่องการวิเคราะห์ความคิดเห็นในปัจจุบัน แต่ยังสามารถติดตามแนวโน้มของความคิดเห็นในระยะยาวได้ด้วย เช่น การเปลี่ยนแปลงความรู้สึกของลูกค้าเกี่ยวกับเงินฝากก่อนและหลังการออกโปรโมชั่น หรือการเปรียบเทียบความคิดเห็นระหว่างธนาคารคู่แข่ง ข้อมูลเชิงลึกเหล่านี้ช่วยให้ธนาคารสามารถปรับปรุงผลิตภัณฑ์และบริการให้ตรงกับความต้องการของลูกค้าได้ดียิ่งขึ้น รวมถึงใช้เป็นข้อมูลอ้างอิงในการพัฒนากลยุทธ์การตลาดที่เน้นการตอบสนองความคาดหวังของลูกค้าในเชิงลึก (Wei & Dihong, 2024) ในภาพรวม Sentiment Analysis จึงเป็นเครื่องมือสำคัญสำหรับสถาบันการเงินในการทำความเข้าใจลูกค้าอย่างแม่นยำ ช่วยเพิ่มประสิทธิภาพในการให้บริการ ปรับปรุงคุณภาพของผลิตภัณฑ์ และสร้างความสัมพันธ์ระยะยาวกับลูกค้า ซึ่งเป็นปัจจัยสำคัญในการแข่งขันในยุคที่ความคิดเห็นบนสื่อสังคมออนไลน์มีบทบาทสำคัญต่อการตัดสินใจของผู้บริโภค

### 2.3 ผลลัพธ์เงินฝาก

ผลลัพธ์เงินฝากเป็นผลลัพธ์สำคัญของธนาคาร เนื่องจากช่วยเพิ่มสภาพคล่องทางการเงินและสนับสนุนการดำเนินธุรกิจของธนาคาร (Mohamed Zaki et al., 2024) โดยผลลัพธ์เงินฝากสามารถมีหลายประเภท ยกตัวอย่างเช่น 1) บัญชีออมทรัพย์ (Savings Account) ฝากถอนยืดหยุ่น เหมาะสำหรับการใช้งานในชีวิตประจำวัน 2) บัญชีฝากประจำ (Fixed Deposit) ดอกเบี้ยสูงกว่าออมทรัพย์ แต่ต้องฝากตามระยะเวลาที่กำหนด 3) บัญชีกระแสรายวัน (Current Account) สำหรับธุรกรรมเชิงธุรกิจ ไม่เน้นดอกเบี้ย 4) บัญชีเงินฝากดิจิทัล (Digital Account) ทำธุรกรรมผ่านแอปพลิเคชัน สะดวก รวดเร็ว 5) บัญชีเฉพาะกลุ่ม (Specialized Account) เช่น บัญชีสำหรับผู้สูงอายุ พร้อมสิทธิประโยชน์เฉพาะ ซึ่งข้อมูลประเภทเงินฝากสามารถนำมาใช้เป็นส่วนหนึ่งในการจัดหมวดหมู่และวิเคราะห์ความคิดเห็นได้อย่างมีประสิทธิภาพมากขึ้น ตัวอย่างเช่น หากข้อความกล่าวถึง “บัญชีออมทรัพย์” หรือ “ดอกเบี้ยเงินฝาก” โมเดลการวิเคราะห์ความรู้สึกสามารถจำแนกได้ว่าข้อความดังกล่าวสะท้อนถึงความพึงพอใจหรือความไม่พึงพอใจของลูกค้าได้อย่างแม่นยำยิ่งขึ้น

### 2.4 งานวิจัยที่เกี่ยวข้องผลลัพธ์เงินฝากจากข้อความบนสื่อสังคมออนไลน์ โดยใช้เทคนิคการเรียนรู้ของเครื่อง

Abdulrashid et al. (2024) ได้ศึกษาผลกระทบของลักษณะโพสต์บนสื่อสังคมออนไลน์ โดยเฉพาะวิธีตัวอย่าง ภาพยนตร์บนยูทูปที่มีต่อความสำเร็จหรือความล้มเหลวของภาพยนตร์ก่อนการเข้าฉาย เพื่อช่วยให้ผู้ผลิตภาพยนตร์และนักลงทุนสามารถตัดสินใจได้อย่างมีข้อมูล โดยใช้เครื่องมือ Machine Learning คือ Random Forest (RF) และ SHAP (SHapley Additive exPlanation) เพื่อระบุปัจจัยที่มีอิทธิพลต่อความสำเร็จหรือความล้มเหลวของภาพยนตร์

โดยใช้ Bayesian Optimization ในการปรับแต่งค่าพารามิเตอร์เพื่อเพิ่มประสิทธิภาพการทำนายให้ดียิ่งขึ้น และใช้ SHAP ในการอธิบายความสำคัญของแต่ละปัจจัย ผลการศึกษาพบว่าวิธีวัดตัวอย่างภาพยนตร์ับมียูทูปมีความสัมพันธ์กับรายได้ของภาพยนตร์ โดยเฉพาะปัจจัย เช่น จำนวนการเข้าชม สัดส่วนวีวเชิงบวกต่อเชิงลบ และระดับความตั้งใจในการซื้อบัตรชมภาพยนตร์ ซึ่งปัจจัยเหล่านี้สามารถทำนายความล้มเหลวหรือความสำเร็จของภาพยนตร์ได้อย่างมีประสิทธิภาพ

Meng et al. (2024) ได้ศึกษาเกี่ยวกับการคาดการณ์ความเสี่ยงฆ่าตัวตายของผู้ใช้บนสื่อสังคมออนไลน์ มีวัตถุประสงค์ในการคาดการณ์ความเสี่ยงในการฆ่าตัวตายของผู้ใช้เว่ยป้อ (Weibo) โดยเน้นการรวมข้อมูลจากข้อความโพสต์และลักษณะความสัมพันธ์ทางสังคมออนไลน์ เพื่อพัฒนาวิธีการที่สามารถระบุตัวผู้ใช้งานที่มีความเสี่ยงได้อย่างแม่นยำมากขึ้น โดยใช้เทคนิค Word2Vec เพื่อแปลงข้อความเป็นเวกเตอร์ และใช้ PageRank Algorithm ในการประเมินอิทธิพลของผู้ใช้งานในเครือข่ายสังคม และคาดการณ์ด้วยโมเดล TCNN-SN (Text Convolutional Neural Network based on Social Network relationships) เปรียบเทียบโมเดล โมเดลการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก (Deep Learning) อื่น ๆ เช่น Support Vector Machines (SVM), Naive Bayes (NB), TextCNN ซึ่งผลลัพธ์แสดงให้เห็นว่าโมเดล TCNN-SN สามารถเพิ่มความแม่นยำในการทำนายได้ดีกว่าโมเดลที่ใช้ข้อความอย่างเดียว โดยได้ Accuracy ร้อยละ 88.57, F1-score ร้อยละ 88.75, และ AUC ร้อยละ 94.25 ซึ่งสูงกว่าโมเดล TextCNN มาตรฐานถึง ร้อยละ 12.18, ร้อยละ 10.84, และ ร้อยละ 10.85 ตามลำดับ

Bae et al. (2021) ศึกษาและตรวจจับลักษณะทางภาษาและหัวข้อเนื้อหาที่เกี่ยวข้องกับผู้ที่มีความเสี่ยงจะเป็นโรคจิตเภทโดยใช้ข้อความจากเรดดิต และพัฒนาระบบการเรียนรู้ของเครื่องที่สามารถจำแนกและวิเคราะห์ความแตกต่างระหว่างกลุ่มที่เป็นโรคจิตเภทและกลุ่มควบคุมได้ ประยุกต์ใช้โมเดลการเรียนรู้แบบมีผู้สอน ได้แก่ Random Forest, Support Vector Machine, Logistic Regression และ Naive Bayes เพื่อจำแนกโพสต์ของผู้ที่มีความเสี่ยงเป็นโรคจิตเภทจากกลุ่มควบคุม โดยโมเดลที่มีประสิทธิภาพสูงสุดคือ Random Forest ที่ให้ความแม่นยำสูงสุดในการจำแนกโพสต์ (ร้อยละ 96) H. Han et al. (2024) ศึกษาวิจัยนี้เพื่อประเมินประสิทธิภาพของอัลกอริทึม การเรียนรู้ของเครื่อง (ML) ในการตรวจจับพฤติกรรมกรรมการกลั่นทางไซเบอร์ (Cyber-Trolling) ที่เพิ่มขึ้นจากการเก็บข้อมูลในสื่อสังคมออนไลน์ โดยเปรียบเทียบโมเดล Random Forest, Light Gradient Boosting Machine (LightGBM), Logistic Regression, Support Vector Machine (SVM) และ Naive Bayes ด้วยตัวชี้วัดผลลัพธ์ (Matrix) คือ Accuracy, Precision, Recall และ F1 Score ซึ่งผลลัพธ์ที่ได้คือโมเดล Random Forest ทำงานได้ดีที่สุดและมีความแม่นยำสูงสุด

Abdullah et al. (2024) ได้ศึกษาการวิเคราะห์ข้อมูลจากสื่อสังคมออนไลน์เพื่อระบุแนวโน้มในพาณิชย์อิเล็กทรอนิกส์ด้านแฟชั่น ซึ่งช่วยให้ผู้ค้าปลีกสามารถคาดการณ์แนวโน้ม ปรับปรุงการจัดการโลจิสติกส์ (Logistic) และตอบสนองความต้องการของผู้บริโภค ข้อมูลถูกเก็บรวบรวมผ่านกระบวนการดึงข้อมูลอัตโนมัติจากเว็บไซต์ (Web Scraping) โดยแหล่งข้อมูลประกอบด้วยสื่อสังคมออนไลน์และเว็บไซต์พาณิชย์อิเล็กทรอนิกส์ และวิเคราะห์ความรู้สึกเชิงบวกและเชิงลบของโพสต์และรีวิว โดยใช้ Vader Polarity Score ผลลัพธ์แสดงให้เห็นค่าที่ได้รับความนิยมและผลิตภัณฑ์ที่เป็นที่นิยมในขณะนั้น ทำให้ผู้ค้าปลีกสามารถปรับกลยุทธ์การตลาดและโลจิสติกส์ให้สอดคล้องกับแนวโน้มได้

นอกจากนี้หลายงานวิจัยได้ใช้ข้อมูลจากแพลตฟอร์มสื่อสังคมออนไลน์ เช่น เอ็กซ์, เรดดิต และเฟซบุ๊ก เพื่อวิเคราะห์ความรู้สึกของผู้ใช้งานในหัวข้อต่าง ๆ เช่น การแสดงออกถึงภาวะซึมเศร้า (Bae et al., 2021) หรือการตรวจจับข่าวปลอม (Meng et al., 2024) สิ่งนี้สอดคล้องกับการวิเคราะห์ความคิดเห็นของลูกค้านำมาเกี่ยวกับผลิตภัณฑ์เงินฝาก โดยการรวบรวมความคิดเห็นเหล่านี้จากเฟซบุ๊กหรือแพลตฟอร์มอื่น ช่วยให้ธนาคารสามารถเข้าถึงมุมมองของลูกค้านได้อย่างแท้จริง การจัดประเภทความรู้สึก (Sentiment Classification) งานวิจัยส่วนใหญ่เน้นการจัดประเภทข้อความ เช่น แบ่งเป็นเชิงบวก, เชิงลบ หรือเป็นกลาง ซึ่งงานวิจัยนี้จะรวมถึงการวิเคราะห์แบบ Multiclassification ที่ครอบคลุมอารมณ์ 10 ประเภท ได้แก่ ความสุข, ความโกรธ, ความเศร้า, ความกลัว, ความไว้วางใจ, ความรังเกียจ,

ความประหลาดใจ, ความคาดหวัง, เชิงบวก และเชิงลบ ซึ่งช่วยให้การจำแนกความรู้สึกเชิงลึกสามารถนำไปประยุกต์ใช้ได้ดีขึ้นในบริบทของผลิตภัณฑ์เงินฝาก โดยระบุประเภทความรู้สึกจากความคิดเห็นลูกค้า เช่น ความพึงพอใจต่ออัตราดอกเบี้ย หรือความไม่พอใจต่อบริการ การใช้โมเดลการเรียนรู้ของเครื่อง งานวิจัยเช่น Negru et al. (2025) แสดงให้เห็นการใช้โมเดลการเรียนรู้ของเครื่องและการเรียนรู้เชิงลึก เช่น BERT, RoBERTa, และ XLM-R ในการจับบริบทของข้อความและเพิ่มความแม่นยำของการวิเคราะห์ตัวชี้วัดการประเมินผล งานวิจัยส่วนใหญ่ประเมินผลโมเดลด้วยตัวชี้วัดหลัก ได้แก่ Accuracy, Precision, Recall, F1-score, และ ROC AUC เพื่อวัดความแม่นยำและประสิทธิภาพในการจำแนกข้อมูล นอกจากนี้ ยังมี Training Loss และ Validation Loss สำหรับติดตามพฤติกรรมของการเรียนรู้ของโมเดลระหว่างการฝึกฝน

### 3.1 กรอบแนวคิดการวิจัย

ผู้วิจัยได้อ้างอิงกรอบแนวคิดจาก ทฤษฎีวงล้ออารมณ์ของ Plutchik (Plutchik's Wheel of Emotions, 1980) ซึ่งเสนอว่าอารมณ์พื้นฐานของมนุษย์ประกอบด้วย 8 ประเภท ได้แก่ ความสุข, ความโกรธ, ความเศร้า, ความกลัว, ความไว้วางใจ, ความรังเกียจ, ความประหลาดใจ และความคาดหวัง อารมณ์เหล่านี้ถูกออกแบบมาเพื่อสะท้อนพฤติกรรมและการแสดงออกของมนุษย์อย่างครอบคลุม และได้รับการนำมาใช้อย่างแพร่หลายในงานวิจัยด้านการวิเคราะห์ความรู้สึก (Sentiment Analysis) บนข้อความ

## 4. วิธีการวิจัย


ผู้วิจัยใช้กลุ่มตัวอย่างเป็นข้อความที่เกี่ยวข้องกับผลิตภัณฑ์เงินฝาก ซึ่งดึงข้อมูลจากแพลตฟอร์มเฟซบุ๊ก เนื่องจากเป็นสื่อสังคมออนไลน์ที่ได้รับความนิยมมากที่สุดในประเทศไทย จากเพจของธนาคารพาณิชย์ในประเทศไทย คือ ธนาคารกรุงเทพ ธนาคารไทยพาณิชย์ ธนาคารกรุงศรีอยุธยา ธนาคารกรุงไทย ธนาคารกสิกรไทย และธนาคารไทยพาณิชย์ และสถาบันการเงินเฉพาะกิจ คือ ธนาคารออมสิน ซึ่งเก็บรวบรวมข้อมูลของโพสต์ในเพจของธนาคารที่มีการโพสต์ตั้งแต่ มกราคม 2567 – กุมภาพันธ์ 2568 โดยใช้ Exportcomments.com ที่เป็นเว็บไซต์สำเร็จรูปสำหรับดึงข้อมูลความคิดเห็นจากสื่อสังคมออนไลน์ ที่ความครบถ้วนและครอบคลุมสำหรับการนำมาวิเคราะห์

การพัฒนาและประเมินผลโมเดลมี 3 ขั้นตอนหลัก ดังนี้ 1. ข้อมูลทั้งหมดถูกแบ่งออกเป็น 3 ชุด ได้แก่ ชุดข้อมูลฝึก (Training Data) ร้อยละ 70, ชุดข้อมูลตรวจสอบความถูกต้อง (Validation Data) ร้อยละ 15 และชุดข้อมูลทดสอบ (Testing Data) ร้อยละ 15 การแบ่งในลักษณะนี้มีเป้าหมายเพื่อให้แน่ใจว่าโมเดลสามารถเรียนรู้จากข้อมูลส่วนใหญ่ พร้อมทั้งมีชุดข้อมูลสำหรับปรับพารามิเตอร์ (Parameter) ระหว่างการฝึก และชุดข้อมูลแยกต่างหากสำหรับประเมินผลหรืออย่างเป็นธรรมชาติ โดยชุดข้อมูลฝึกถูกนำมาใช้ในกระบวนการปรับแต่งโมเดลภาษาที่ผ่านการฝึกฝนล่วงหน้าเพื่อให้สามารถเรียนรู้ลักษณะเฉพาะของข้อความที่เกี่ยวข้องกับงานวิจัย เช่น การแสดงอารมณ์ในความคิดเห็นเกี่ยวกับผลิตภัณฑ์เงินฝาก ชุดข้อมูลตรวจสอบความถูกต้อง ใช้สำหรับตรวจสอบความแม่นยำระหว่างการฝึกและป้องกันปัญหาโอเวอร์ฟิตติ้ง (Overfitting) ในขณะที่ชุดข้อมูลทดสอบจะใช้เป็นข้อมูลแยกต่างหากในการประเมินประสิทธิภาพของโมเดลหลังจากการฝึกเสร็จสิ้น 2. การฝึกและทดสอบโมเดล เพื่อประมวลผลและจำแนกอารมณ์จากข้อความ ผู้วิจัยเลือกใช้ โมเดลภาษาที่ผ่านการฝึกมาแล้วล่วงหน้า (Pre-trained Language Model) จากแพลตฟอร์ม Hugging Face ซึ่งเป็นแหล่งรวมโมเดลด้านการประมวลผลภาษาธรรมชาติที่ได้รับการยอมรับอย่างแพร่หลาย โมเดลที่ใช้ในงานวิจัยนี้คือ BERT-base-uncased ซึ่งรองรับเฉพาะภาษาอังกฤษ และได้รับการฝึกฝนด้วยข้อมูลขนาดใหญ่จากแหล่งต่าง ๆ จึงมีความสามารถในการเข้าใจบริบทของภาษาได้อย่างลึกซึ้ง ผู้วิจัยนำโมเดลดังกล่าวมาใช้งานผ่านไลบรารี Transformers ของ Hugging Face โดยโหลดเข้าสู่กูเกิลโคลด์แพลตฟอร์มและปรับแต่งโมเดลเพิ่มเติมด้วยชุดข้อมูลที่ติดป้ายกำกับอารมณ์แล้ว เพื่อให้โมเดลสามารถเรียนรู้อารมณ์จากข้อความเฉพาะทางที่เกี่ยวข้องกับผลิตภัณฑ์เงินฝากของธนาคาร การใช้งานผ่าน Hugging Face มีข้อได้เปรียบคือสามารถเข้าถึงโมเดลระดับมาตรฐานได้อย่างรวดเร็ว และสามารถนำมาประยุกต์ใช้กับข้อมูลใหม่ได้อย่างยืดหยุ่นโดยไม่ต้องฝึกโมเดลจากศูนย์ ซึ่งช่วยลดเวลาและทรัพยากร


ในการพัฒนาโมเดลลงได้อย่างมากโดยโมเดลจะทำการวิเคราะห์ข้อความและแบ่งผลลัพธ์ออกเป็นอารมณ์ 10 ประเภท ได้แก่ ความสุข, ความโกรธ, ความเศร้า, ความกลัว, ความไว้วางใจ, ความรังเกียจ, ความประหลาดใจ, ความคาดหวัง, เชิงบวก และเชิงลบ และนำไปทดสอบกับชุดข้อมูลทดสอบเพื่อประเมินความแม่นยำและความสามารถในการจำแนกข้อความ 3. การประเมินผลโมเดล ในการวิจัยนี้ ได้ประเมินประสิทธิภาพของโมเดลโดยใช้ตัวชี้วัด 7 ประเภท ที่สะท้อนทั้งความสามารถในการเรียนรู้ของโมเดล และความแม่นยำในการจำแนกอารมณ์จากข้อความ ได้แก่ Training Loss, Validation Loss, Accuracy, Precision, Recall, F1-score และ ROC AUC

ผลการวิเคราะห์จะถูกนำเสนอในรูปแบบของกราฟเพื่อแสดงถึงความสัมพันธ์ของข้อมูล ผลคะแนนความแม่นยำของโมเดล และประสิทธิภาพของโมเดลในการจำแนกความรู้สึกของผู้ใช้งานที่มีต่อผลิตภัณฑ์เงินฝาก โดยสถิติและข้อมูลที่ได้นี้จะใช้เพื่อประเมินความสามารถของโมเดลเบื้องต้น และเป็นพื้นฐานสำหรับการนำโมเดลไปประยุกต์ใช้ในงานวิเคราะห์ข้อมูลจริง

การศึกษาครั้งนี้เป็นการรวบรวมข้อความที่เกี่ยวข้องกับผลิตภัณฑ์เงินฝาก ซึ่งดึงข้อมูลจากแพลตฟอร์มเฟซบุ๊กจากเพจของธนาคารพาณิชย์ในประเทศไทย คือ ธนาคารกรุงเทพ ธนาคารไทยพาณิชย์ ธนาคารกรุงศรีอยุธยา ธนาคารกรุงไทย ธนาคารกสิกรไทย และธนาคารไทยชนชาติ และสถาบันการเงินเฉพาะกิจ คือ ธนาคารออมสิน จำนวน 7 เพจ โดยใช้เว็บไซต์สำเร็จรูปสำหรับดึงข้อมูลExportcomments.com โดยรวบรวมได้ทั้งหมด 356 โปสต์ 7,245 ความคิดเห็นโดยแบ่งสัดส่วน ดังภาพที่ 2 ภาพแสดงสัดส่วนข้อมูลจำนวนโปสต์ของธนาคาร และภาพที่ 3 สัดส่วนข้อมูลจำนวนความคิดเห็นของธนาคาร



ภาพที่ 2 แสดงสัดส่วนข้อมูลจำนวนโปสต์ของธนาคาร




ภาพที่ 3 แสดงสัดส่วนข้อมูลจำนวนความคิดเห็นของธนาคาร


## 5. ผลการวิจัย และอภิปรายผล

### 5.1 การวิเคราะห์ข้อมูลด้วยความถี่ของอารมณ์ (Frequency of Emotions)

จากภาพที่ 4 ความถี่ของอารมณ์ (Frequency of Emotions) แสดงความถี่ของอารมณ์ที่โมเดลสามารถจำแนกได้จากชุดข้อมูลทดสอบ ซึ่งเป็นความคิดเห็นเกี่ยวกับผลิตภัณฑ์เงินฝากของธนาคารที่ได้จากสื่อสังคมออนไลน์ โดยข้อมูลดังกล่าวได้รับการติดป้ายกำกับอารมณ์ล่วงหน้า และถูกนำมาทำนายซ้ำอีกครั้งด้วยโมเดล BERT ที่ผ่านการฝึกฝนเสร็จสิ้นแล้ว เพื่อวิเคราะห์ลักษณะการกระจายของอารมณ์ที่โมเดลสามารถตรวจจับได้ ผลการวิเคราะห์พบว่า อารมณ์ที่ปรากฏบ่อยที่สุด ได้แก่ Positive และ Trust ซึ่งสะท้อนถึงความรู้สึกในเชิงบวก เช่น ความพึงพอใจ ความมั่นใจ และความไว้วางใจที่ผู้ใช้มีต่อผลิตภัณฑ์หรือบริการทางการเงิน ตามมาด้วยอารมณ์ Joy, Surprise และ Anticipation ในระดับที่ค่อนข้างสูง ในทางกลับกัน อารมณ์ด้านลบ เช่น Negative, Anger, และ Sadness ปรากฏในระดับปานกลาง ส่วนอารมณ์ที่มีความถี่ต่ำที่สุด คือ Fear และ Disgust ซึ่งอาจสะท้อนถึงความไม่สมดุลของข้อมูลในบางกลุ่มอารมณ์ ส่งผลต่อแนวโน้มการทำนายของโมเดลด้วย ทั้งนี้ เนื่องจากการจำแนกแบบหลายป้ายกำกับที่ข้อความหนึ่งสามารถสะท้อนอารมณ์ได้มากกว่าหนึ่งประเภท ความถี่ของอารมณ์ทั้งหมดจึงอาจสูงกว่าจำนวนข้อความในชุดข้อมูลทดสอบ โดยสอดคล้องกับภาพที่ 5 สัดส่วนจำนวนป้ายกำกับจากชุดข้อมูลกลุ่มตัวอย่างที่มีค่า Positive และ Trust มากที่สุด




ภาพที่ 4 ความถี่ของอารมณ์ (Frequency of Emotions)



ภาพที่ 5 สัดส่วนจำนวนป้ายกำกับจากชุดข้อมูลกลุ่มตัวอย่าง

## 5.2 เมทริกซ์การเกิดร่วมของอารมณ์ (Emotion Co-Occurrence Matrix)

เมทริกซ์การเกิดร่วมของอารมณ์ (Emotion Co-occurrence Matrix) แสดงความถี่ของการปรากฏร่วมกันของอารมณ์ทั้ง 10 ประเภทภายในข้อความเดียวกัน โดยค่าตัวเลขในแต่ละช่องของเมทริกซ์แสดงจำนวนครั้งที่อารมณ์สองประเภทปรากฏร่วมกัน ในข้อความเดียว เช่น แถว Trust คอลัมน์ Anticipation มีค่าร่วมอยู่ที่ 1,106 ครั้ง สะท้อนให้เห็นว่า ผู้ใช้ที่แสดงความไว้วางใจต่อผลิตภัณฑ์หรือบริการทางการเงินมักมีความคาดหวังร่วมอยู่ด้วย ในทำนองเดียวกัน มีการพบความถี่ของการเกิดร่วมกันระหว่างอารมณ์เชิงบวกอื่น ๆ ที่ค่อนข้างสูง เช่น Trust กับ Joy (1,872 ครั้ง), Positive กับ Joy (2,196 ครั้ง), และ Positive กับ Trust (2,246 ครั้ง) ซึ่งสะท้อนถึงแนวโน้มของอารมณ์ในเชิงสร้างสรรค์ เช่น ความมั่นใจ ความพึงพอใจ และความรู้สึกดี ต่ออนาคต ที่มักปรากฏพร้อมกันเมื่อผู้ใช้มีประสบการณ์เชิงบวกกับผลิตภัณฑ์ ขณะเดียวกัน อารมณ์เชิงลบบางคู่ เช่น Anger กับ Disgust (316 ครั้ง) และ Sadness กับ Negative (686 ครั้ง) ก็ปรากฏร่วมกันในระดับหนึ่ง โดยอาจสะท้อนถึงบริบทที่เกี่ยวข้องกับความไม่พอใจ ความผิดหวัง หรือประสบการณ์ที่ไม่เป็นไปตามความคาดหวัง นอกจากนี้ ค่าที่อยู่บนแนวทแยงของเมทริกซ์ เช่น Trust (2,749), Anticipation (1,521), และ Positive (3,512) แสดงถึงจำนวนข้อความที่แสดงอารมณ์เหล่านั้นโดยเฉพาะ โดยไม่จำเป็นต้องเกิดร่วมกับอารมณ์อื่น ค่าดังกล่าวชี้ให้เห็นว่าอารมณ์เชิงบวกเหล่านี้มักปรากฏอย่างเด่นชัดในชุดข้อมูลโดยรวม และเป็นองค์ประกอบสำคัญของความรู้สึก ของผู้ใช้งานที่มีต่อผลิตภัณฑ์ทางการเงิน โดยสรุป เมทริกซ์นี้ให้ข้อมูลเชิงลึกเกี่ยวกับลักษณะของการรับรู้และความรู้สึก ของผู้ใช้งานที่ไม่ใช่แบบอารมณ์เดียว แต่เป็นการผสมผสานของอารมณ์หลายแบบในข้อความเดียวกัน ซึ่งสามารถนำไปใช้ประโยชน์ในการออกแบบระบบแนะนำ การจัดกลุ่มความคิดเห็น หรือการวางกลยุทธ์สื่อสารที่สอดคล้องกับบริบททางอารมณ์ของกลุ่มเป้าหมายได้อย่างมีประสิทธิภาพ ดังแสดงภาพที่ 6



ภาพที่ 6 เมทริกซ์การเกิดร่วมของอารมณ์ (Emotion Co-Occurrence Matrix)

## 5.3 การประเมินผลโมเดล

ประเมินประสิทธิภาพของโมเดลโดยใช้ตัวชี้วัด 7 ประเภท ที่สะท้อนทั้งความสามารถในการเรียนรู้ของโมเดล และความแม่นยำในการจำแนกอารมณ์ จากข้อความ ได้แก่ Training Loss, Validation Loss, Accuracy, Precision, Recall, F1-score และ ROC AUC โดยผลการประเมินโมเดล จากตารางที่ 1 แสดงผลการประเมินโมเดล ฝึกโมเดล BERT สำหรับงานจำแนกอารมณ์แบบหลายป้ายกำกับ พบว่า ค่า Training Loss และ Validation Loss มีแนวโน้ม

ลดลงอย่างต่อเนื่อง จาก Epoch ที่ 1 ถึง 5 โดยค่า Validation Loss ลดลงจาก 0.3201 เหลือ 0.2094 ซึ่งสะท้อนว่าโมเดลสามารถเรียนรู้จากข้อมูลได้อย่างมีประสิทธิภาพ และไม่ปรากฏสัญญาณของปัญหาโอเวอร์ฟิตติ้งในระหว่างการฝึก ในส่วนของ ค่า Precision และ Recall พบว่าอยู่ในระดับที่ดีอย่างต่อเนื่อง โดยค่า Precision เพิ่มขึ้นจาก 0.844 ใน Epoch ที่ 1 เป็น 0.919 ใน Epoch ที่ 5 ขณะที่ค่า Recall เพิ่มขึ้นจาก 0.753 เป็น 0.853 ซึ่งทั้งสองค่ามีแนวโน้มสูงขึ้น และอยู่ในช่วงที่ถือว่า “ดี” ( $\geq 0.80$ ) ตั้งแต่ Epoch ที่ 3 เป็นต้นไป แสดงให้เห็นว่าโมเดลสามารถระบุอารมณ์ได้อย่างแม่นยำและครอบคลุมมากยิ่งขึ้นเมื่อผ่านการฝึกในแต่ละรอบ นอกจากนี้ ค่า F1-score ซึ่งเป็นค่ากลางระหว่าง Precision และ Recall ก็เพิ่มขึ้นอย่างต่อเนื่องจาก 0.796 ใน Epoch ที่ 1 เป็น 0.885 ใน Epoch ที่ 5 โดยเฉพาะใน Epoch ที่ 4 และ 5 ซึ่งมีค่า F1-score สูงกว่า 0.88 ถือว่าอยู่ในระดับ “ดีมาก” สะท้อนว่าโมเดลสามารถรักษาสมดุลระหว่างความแม่นยำและความครอบคลุมได้อย่างมีประสิทธิภาพ แม้ว่า ค่า Accuracy จะอยู่ในช่วง 0.44–0.68 ซึ่งอาจดูต่ำเมื่อเทียบกับงานจำแนกประเภททั่วไป แต่ในบริบทของการจำแนกแบบหลายป้ายกำกับที่โมเดลต้องทำนายอารมณ์หลายประเภทจากข้อความเดียว การได้ค่า Accuracy ต่ำจึงเป็นเรื่องปกติ และไม่ใช่อุปสรรคหลักในการประเมินประสิทธิภาพของโมเดลประเภทนี้ ท้ายที่สุด ค่า ROC AUC มีแนวโน้มเพิ่มขึ้นอย่างชัดเจนจาก 0.9249 ใน Epoch ที่ 1 เป็น 0.9614 ใน Epoch ที่ 5 โดยอยู่ในระดับที่ถือว่า “ดีมาก” ( $\geq 0.90$ ) ตั้งแต่ Epoch แรก แสดงให้เห็นว่าโมเดลสามารถแยกแยะระหว่างอารมณ์แต่ละประเภทได้อย่างแม่นยำและมีเสถียรภาพสูงตลอดกระบวนการฝึก


ตารางที่ 1 ผลการประเมินโมเดล ฝึกโมเดล BERT สำหรับงานจำแนกอารมณ์แบบหลายป้ายกำกับ

Epoch	Training Loss	Validation Loss	Precision	Recall	F1	Accuracy	Roc Auc
1	0.352900	0.320052	0.844349	0.753419	0.796296	0.442441	0.924863
2	0.273100	0.250019	0.878193	0.822650	0.849515	0.553398	0.950580
3	0.228700	0.228057	0.908372	0.834615	0.869933	0.636616	0.955852
4	0.208800	0.214973	0.908967	0.853419	0.880317	0.656033	0.960353
5	0.197800	0.209433	0.919355	0.852564	0.884701	0.679612	0.961445

### 5.3.1 Training Loss และ Validation Loss

ผลการฝึกโมเดลแสดงผ่านกราฟเปรียบเทียบค่าความสูญเสียระหว่างชุดข้อมูลฝึก (Training Loss) และชุดข้อมูลตรวจสอบ (Validation Loss) ดังภาพที่ 7 โดยกราฟแสดงค่าความสูญเสียของโมเดลในแต่ละ Epoch ช่วงระหว่างการฝึกจำนวน 5 รอบ (Epochs) จากกราฟจะเห็นได้ว่าโมเดลมีพฤติกรรมการเรียนรู้ที่มีเสถียรภาพ โดย ค่า Training Loss ลดลงอย่างต่อเนื่อง จาก 0.353 ใน Epoch ที่ 1 เหลือ 0.198 ใน Epoch ที่ 5 ซึ่งแสดงว่าโมเดลสามารถเรียนรู้รูปแบบจากข้อมูลฝึกได้อย่างมีประสิทธิภาพ ในขณะที่ค่า Validation Loss ก็ลดลงต่อเนื่อง จาก 0.320 ใน Epoch ที่ 1 เหลือเพียง 0.209 ใน Epoch ที่ 5 แม้หลังจาก Epoch ที่ 3 เป็นต้นไปอัตราการลดของ Validation Loss จะเริ่มชะลอลงเล็กน้อย แต่ยังไม่มีความเสี่ยงของการเพิ่มขึ้น ซึ่งบ่งชี้ว่าโมเดลสามารถ generalize ได้ดี กับข้อมูลที่ไม่เคยเห็นมาก่อน และไม่มีสัญญาณของปัญหาโอเวอร์ฟิตติ้ง นอกจากนี้ การที่ Training Loss ยังคงลดลงต่อเนื่องในขณะที่ Validation Loss มีแนวโน้มคงที่ในช่วงท้าย อาจสะท้อนว่าโมเดลเริ่มเข้าสู่ช่วงการเรียนรู้รายละเอียดเฉพาะของข้อมูลฝึกมากขึ้น แต่ไม่ได้ส่งผลลบต่อความสามารถในการประมวลผลข้อมูลใหม่ ดังนั้น การฝึกจำนวน 5 Epoch จึงถือว่า


เหมาะสมและเพียงพอ สำหรับได้โมเดลที่มีความสามารถในการเรียนรู้จากข้อมูลต้นแบบ และยังสามารถนำไปประยุกต์ใช้กับชุดข้อมูลใหม่ได้อย่างมีประสิทธิภาพ



ภาพที่ 7 กราฟแสดงค่า Training Loss และ Validation Loss ของโมเดลในแต่ละ Epoch

### 5.3.2 Confusion Matrix

ผลการจำแนกอารมณ์แยกแยะประเภทโดยละเอียดผ่านค่าชี้วัดรายอารมณ์ (Per-Emotion Metrics) ดังภาพที่ 8 ค่า Precision, Recall, F1-score และ Accuracy แยกรายอารมณ์ของโมเดล รวมถึงการใช้ Confusion Matrix ของแต่ละอารมณ์เพื่อประเมินความแม่นยำ ความครอบคลุม และความคลาดเคลื่อนของโมเดลในแต่ละอารมณ์ซึ่งช่วยชี้ให้เห็นทั้งจุดแข็งและข้อจำกัดของโมเดลในมิติที่ลึกซึ้งขึ้น



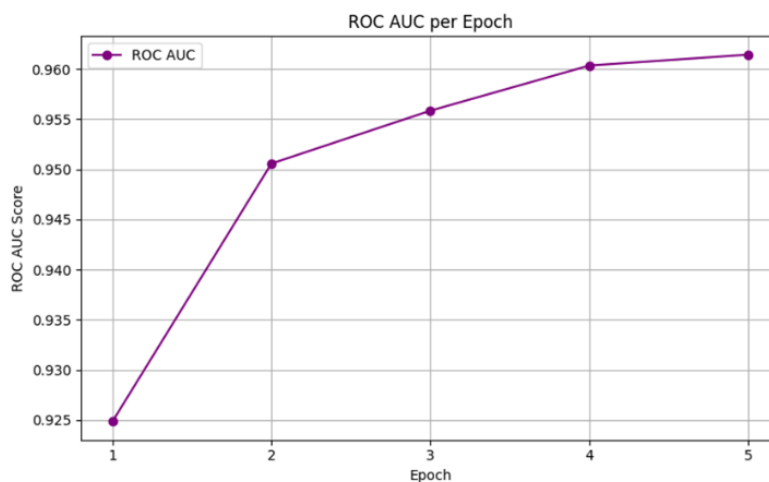
ภาพที่ 8 ค่า Precision, Recall, F1-score และ Accuracy แยกรายอารมณ์ของโมเดล

### 5.3.3 ROC AUC (Receiver Operating Characteristic - Area Under Curve)

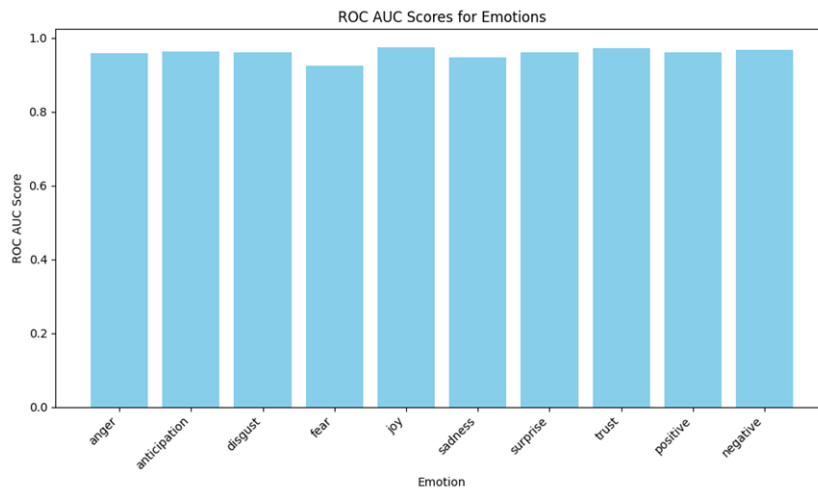
ค่า ROC AUC ของโมเดลในแต่ละ Epoch ตลอดกระบวนการฝึกจำนวน 5 รอบ โดย ROC AUC เป็นตัวชี้วัดที่ใช้ประเมินความสามารถของโมเดลในการแยกแยะระหว่างอารมณ์เชิงบวกและเชิงลบ ยิ่งค่าเข้าใกล้ 1.0 มากเท่าไร ยิ่งสะท้อนว่าโมเดลมีประสิทธิภาพ ในการจำแนกได้แม่นยำยิ่งขึ้นจากภาพที่ 9 ค่า ROC AUC ของโมเดลในแต่ละ

Epoch จะเห็นว่า ค่า ROC AUC มีแนวโน้มเพิ่มขึ้นอย่างต่อเนื่องตลอดช่วงการฝึก เริ่มจากประมาณ 0.925 ใน Epoch ที่ 1 และเพิ่มขึ้นเป็น 0.950 ใน Epoch ที่ 2 ก่อนจะขยับขึ้น เป็น 0.956, 0.960 และสูงสุดที่ 0.961 ใน Epoch ที่ 5 แนวโน้มดังกล่าวสะท้อนว่าโมเดลสามารถพัฒนาความสามารถในการจำแนกได้อย่างมีประสิทธิภาพอย่างรวดเร็วในช่วงต้น และยังสามารถ รักษาความเสถียรของผลลัพธ์ได้ดีในช่วงท้าย ที่สำคัญคือไม่มีสัญญาณของการลดลงหรือความผันผวนของค่า ROC AUC ในช่วงกลางของการฝึก ซึ่งแสดงว่าโมเดลไม่มีปัญหาโอเวอร์ฟิตติงที่อาจส่งผลกระทบต่อความแม่นยำของการประเมินบนชุดข้อมูลตรวจสอบ และสามารถแยกแยะอารมณ์ต่าง ๆ ได้อย่างมีประสิทธิภาพตลอดกระบวนการฝึก และภาพที่ 10 แสดงค่า ROC AUC แยกรายอารมณ์ ซึ่งใช้ในการประเมินความสามารถของโมเดลในการแยกแยะระหว่างข้อความที่มีและไม่มีอารมณ์เฉพาะได้ อย่างแม่นยำ โดยค่า ROC AUC ที่เข้าใกล้ 1.0 สะท้อนว่าโมเดลสามารถแยกคลาสบวกและลบได้อย่างมีประสิทธิภาพ ในขณะที่ค่าที่ใกล้ 0.5 จะบ่งชี้ว่าโมเดลมีประสิทธิภาพไม่ต่างจากการสุ่มทาย จากผลลัพธ์ในภาพ พบว่า โมเดลมีประสิทธิภาพที่ดีเยี่ยมในการจำแนกอารมณ์เกือบทุกประเภท โดยแต่ละอารมณ์มีค่า ROC AUC อยู่ในช่วงประมาณ 0.92–0.98 ซึ่งถือว่าอยู่ในระดับ “ดีมาก” ตามเกณฑ์มาตรฐานการประเมินโมเดล โดยเฉพาะอารมณ์ Joy, Trust, และ Surprise ที่มีค่า ROC AUC ใกล้เคียง 0.98 แสดงว่าโมเดลสามารถจำแนกอารมณ์เหล่านี้ได้อย่างแม่นยำและมีเสถียรภาพสูง นอกจากนี้ อารมณ์อย่าง Anticipation, Positive, Negative, และ Sadness

ก็มีค่า ROC AUC อยู่ในช่วงประมาณ 0.95–0.97 ซึ่งแสดงถึงความสามารถของโมเดลในการจัดการกับอารมณ์ที่มีบริบทหลากหลายได้อย่างน่าเชื่อถือ โดยไม่มีแนวโน้มของความสับสนระหว่างอารมณ์มากนัก อารมณ์ที่มีค่า ROC AUC อยู่ในระดับต่ำที่สุดในกลุ่ม (แม้จะยังถือว่าสูง) ได้แก่ Fear และ Anger ซึ่งอยู่ในช่วงประมาณ 0.92–0.93 แต่ยังคงสะท้อนประสิทธิภาพที่ดีในการแยกแยะอารมณ์เหล่านี้จากข้อความโดยรวม โดยไม่ปรากฏอารมณ์ใดที่มีค่า ROC AUC ต่ำกว่าเกณฑ์ที่ยอมรับได้ โดยสรุป โมเดลสามารถจำแนกอารมณ์แต่ละประเภทได้อย่างแม่นยำในภาพรวม โดยไม่มีอารมณ์ใดที่มีประสิทธิภาพต่ำหรือมีปัญหาการทำนายอย่างมีนัยสำคัญ ทั้งนี้ผลลัพธ์อาจสะท้อนถึงคุณภาพของชุดข้อมูลฝึกที่มีความสมดุลและครอบคลุม หรือการปรับแต่งโมเดลที่เหมาะสมต่อบริบทของการจำแนกอารมณ์ในข้อความภาษาไทย



ภาพที่ 9 ค่า ROC AUC ของโมเดลในแต่ละ epoch



ภาพที่ 10 ค่า ROC AUC แยกรายอารมณ์

## 6. สรุปผลการวิจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาโมเดลประมวลผลภาษาธรรมชาติ (Natural Language Processing) สำหรับจำแนกอารมณ์จากข้อความความคิดเห็นของผู้ใช้งานเกี่ยวกับผลิตภัณฑ์เงินฝากของธนาคาร โดยใช้แนวทางการปรับแต่งโมเดลภาษาแบบฝึกล่วงหน้า (Pre-trained Language Model) คือ BERT-base-uncased ซึ่งมีความสามารถในการเข้าใจบริบทของภาษาอังกฤษอย่างลึกซึ้ง โดยข้อความต้นฉบับที่เป็นภาษาไทยจะถูกแปลเป็นภาษาอังกฤษ และติดป้ายกำกับอารมณ์ทั้งสิ้น 10 ประเภท ภายใต้กรอบของปัญหาการจำแนกแบบหลายป้ายกำกับ (Multi-Label Classification) ซึ่งข้อความหนึ่งสามารถแสดงอารมณ์ได้มากกว่าหนึ่งประเภทพร้อมกัน จากการฝึกโมเดลเป็นเวลา 5 รอบ (Epochs) โดยใช้ Learning Rate เท่ากับ  $2e-5$  และ Batch Size เท่ากับ 8 พบว่าโมเดลมีประสิทธิภาพเพิ่มขึ้นอย่างต่อเนื่องในทุกตัวชี้วัดหลัก โดยเฉพาะใน Epoch ที่ 5 ซึ่งให้ผลลัพธ์ที่ดีที่สุด โดยมีค่า Precision เท่ากับ 0.9194, Recall เท่ากับ 0.8526, F1-score เท่ากับ 0.8847, ROC AUC เท่ากับ 0.9614 และ Accuracy เท่ากับ 0.6796 ค่าประสิทธิภาพเหล่านี้สะท้อนว่าโมเดลสามารถเรียนรู้และแยกแยะอารมณ์ได้อย่างแม่นยำ โดยเฉพาะ ROC AUC ซึ่งมีค่าสูงเกิน 0.96 แสดงถึงศักยภาพของโมเดลในการจำแนกระหว่างอารมณ์บวกและลบได้อย่างมีประสิทธิภาพ นอกจากนี้ การลดลงของค่า Training Loss จาก 0.3529 เหลือ 0.1978 และ Validation Loss จาก 0.3200 เหลือ 0.2094 ตลอดกระบวนการฝึก ยังบ่งชี้ว่าโมเดลสามารถเรียนรู้ได้อย่างมีประสิทธิภาพโดยไม่เกิดปัญหาโอเวอร์ฟิตติ้ง การวิเคราะห์ผลลัพธ์แยกรายอารมณ์จากกราฟประสิทธิภาพรายอารมณ์และ Confusion Matrix พบว่าโมเดลสามารถจำแนกอารมณ์ที่พบบ่อยได้อย่างแม่นยำ เช่น ความสุข, ความไม่ไว้วางใจ, และอารมณ์เชิงบวก ซึ่งมีค่า Precision และ Recall อยู่ในระดับสูง ในขณะที่อารมณ์ที่มีปริมาณข้อมูลน้อย เช่น ความกลัว และความรังเกียจ ยังคงมีข้อจำกัด โดยเฉพาะ Fear ที่มีค่า Recall ต่ำอย่างเห็นได้ชัดและเป็นอารมณ์ที่โมเดลมักพลาดการทำนาย ทั้งนี้ เมื่อพิจารณาค่า ROC AUC แยกรายอารมณ์จากภาพรวม จะพบว่าทุกคลาสมีค่าอยู่ในระดับ "ดีมาก" ( $\geq 0.92$ ) สะท้อนว่าโมเดลสามารถแยกแยะข้อความที่มีหรือไม่มีอารมณ์ได้อย่างแม่นยำ แม้ในกรณีของอารมณ์ที่มีลักษณะซับซ้อนหรือมีการปรากฏร่วมกับอารมณ์อื่นก็ตาม จากผลลัพธ์ทั้งหมด ผู้วิจัยสามารถสังเคราะห์นัยสำคัญเชิงประยุกต์ (Implications) ที่เป็นประโยชน์ต่อภาคธุรกิจธนาคารได้ว่า โมเดลที่พัฒนาขึ้นมีศักยภาพในการติดตามและประเมินแนวโน้มอารมณ์ของลูกค้าต่อผลิตภัณฑ์ทางการเงินที่มีลักษณะเนื้อหาค่อนข้างเฉพาะเจาะจง เช่น ผลิตภัณฑ์เงินฝาก ซึ่งโดยทั่วไปมักประกอบด้วยภาษาที่เป็นกลางและมีการแสดงอารมณ์เชิงลบในระดับต่ำ ความสามารถของโมเดลในการจำแนกอารมณ์เชิงบวกและอารมณ์เป็นกลางได้อย่างแม่นยำ จึงเอื้อต่อการนำไปประยุกต์ใช้เพื่อประเมินความสนใจของลูกค้า การวิเคราะห์ทิศทางรับรู้ของตลาด (market perception) หรือการผสานผลลัพธ์เข้ากับข้อมูลภายในของสถาบัน

การเงิน เพื่อใช้คาดการณ์แนวโน้มความสำเร็จและการตอบรับของผลิตภัณฑ์ได้ นอกจากนี้ แม้อะไรก็ตามจะมีข้อจำกัดบางประการในการจำแนกอารมณ์เชิงลบเนื่องจากปริมาณข้อมูลที่จำกัด แต่ผลลัพธ์ที่ได้ยังสามารถสนับสนุนการตัดสินใจเชิงบริหารในด้านต่าง ๆ เช่น การกำหนดกลยุทธ์การสื่อสาร การออกแบบเนื้อหา การวางตำแหน่งผลิตภัณฑ์ ตลอดจนการพัฒนากลยุทธ์การบริหารความสัมพันธ์ลูกค้า (CRM) ได้ในระดับที่มีนัยสำคัญต่อการดำเนินงาน อย่างไรก็ตามในการดำเนินงานวิจัยครั้งนี้ ผู้วิจัยตระหนักว่าการใช้ข้อมูลคอมเมนต์จากโพสต์ที่เกี่ยวข้องกับผลิตภัณฑ์เงินฝากเพียงประเภทเดียว อาจจำกัดความหลากหลายของอารมณ์ โดยเฉพาะอารมณ์เชิงลบรุนแรง เช่น ความโกรธหรือความรังเกียจ ซึ่งแทบไม่ปรากฏในชุดข้อมูล ส่งผลให้ขอบเขตของข้อเสนอเชิงบริหารที่สามารถสรุปได้ยังมีจำกัดเมื่อพิจารณาในมิติที่กว้างขึ้นของลูกค้าธนาคาร ดังนั้น หากในอนาคตสามารถขยายขอบเขตแหล่งข้อมูลไปสู่อินเทอร์เน็ตที่มีอารมณ์หลากหลายกว่า เช่น การวิเคราะห์ข้อมูลจากชาวออนไลน์ กระทั่งสาธารณะ หรือโพสต์ที่มีได้เกี่ยวข้องกับผลิตภัณฑ์โดยตรง ก็จะช่วยเพิ่มความครอบคลุมของข้อมูล และเอื้อต่อการวิเคราะห์ข้อเสนอเชิงบริหาร (Managerial Implications) ที่มีมิติและคุณค่าต่อเชิงปฏิบัติมากยิ่งขึ้น โดยสรุป โมเดลที่พัฒนาขึ้นสามารถจำแนกอารมณ์จากข้อความความคิดเห็นภาษาอังกฤษ (ที่แปลจากภาษาไทย) ได้อย่างมีประสิทธิภาพ โดยเฉพาะในบริบทของผลิตภัณฑ์ทางการเงิน ซึ่งมีลักษณะภาษาและการแสดงออกทางอารมณ์ที่ค่อนข้างชัดเจน ความสามารถของโมเดลนี้สามารถต่อยอดไปสู่การวิเคราะห์ความรู้สึกของลูกค้า การติดตามความพึงพอใจ และการพัฒนาระบบคัดกรองความคิดเห็นเชิงลบในเชิงธุรกิจและการให้บริการได้อย่างมีประสิทธิภาพในอนาคต

ข้อจำกัดของงานวิจัย 1) ทรัพยากรประมวลผล การฝึกโมเดลที่มีขนาดใหญ่ เช่น BERT-base จำเป็นต้องใช้ทรัพยากรในการประมวลผลสูง โดยเฉพาะหน่วยประมวลผลกราฟิก ที่สามารถเร่งความเร็วในการฝึกโมเดลได้อย่างมีนัยสำคัญ อย่างไรก็ตาม ในการวิจัยนี้ ผู้วิจัยใช้แพลตฟอร์มกูเกิลโคลแลป ซึ่งแม้จะรองรับการใช้งานหน่วยประมวลผลกราฟิกแต่มีข้อจำกัดด้านระยะเวลา (สูงสุดประมาณ 12 ชั่วโมงต่อเซสชัน (session)) และอาจไม่สามารถจัดสรรหน่วยประมวลผลกราฟิกได้ในช่วงที่มีผู้ใช้งานจำนวนมากพร้อมกัน ทำให้กระบวนการฝึกโมเดลในบางช่วงต้องหยุดชะงักหรือเริ่มต้นใหม่ ซึ่งส่งผลต่อความต่อเนื่องในการทดลอง และอาจกระทบต่อประสิทธิภาพของการฝึกในระดับหนึ่ง 2) การแปลภาษา เนื่องจากโมเดลที่เลือกใช้รองรับเฉพาะภาษาอังกฤษ ข้อความต้นฉบับภาษาไทยจึงต้องผ่านกระบวนการแปลเป็นภาษาอังกฤษก่อนนำเข้าสู่ระบบ โมเดลแปลที่ใช้ มีความแม่นยำในระดับที่ยอมรับได้ แต่ยังคงมีความคลาดเคลื่อนในกรณีที่มีคำเฉพาะ กลุ่มคำไม่เป็นทางการ หรือบริบทเฉพาะถิ่น เช่น คำแสลง การเล่นคำ หรือคำที่ใช้ในความหมายเชิงอารมณ์แฝง ซึ่งอาจส่งผลให้โมเดลไม่สามารถจับอารมณ์ที่แท้จริงของข้อความได้อย่างถูกต้อง และทำให้การจำแนกอารมณ์ผิดพลาดได้ง่าย โดยเฉพาะอารมณ์ที่ละเอียดอ่อน เช่น ความกลัวหรือความคาดหวัง 3) ความไม่สมดุลของข้อมูล ในการฝึกโมเดลครั้งนี้ พบว่าข้อมูลบางอารมณ์มีจำนวนน้อยกว่ามากเมื่อเทียบกับอารมณ์อื่น เช่น ความกลัว, ความประหลาดใจ และความรังเกียจ มีจำนวนข้อความที่แสดงอารมณ์เหล่านี้้น้อยมาก ทำให้โมเดลไม่มีโอกาสเรียนรู้ลักษณะของอารมณ์เหล่านี้ ได้เพียงพอ ส่งผลให้เมื่อโมเดลนำไปทำนาย มักจะหลีกเลี่ยงการทำนายอารมณ์เหล่านี้ หรือให้ผลลัพธ์ที่ไม่แม่นยำ (เช่น มีค่า Recall ต่ำ หรือไม่มีการทำนายถูกเลย) แม้ว่าโมเดลจะถูกออกแบบให้รองรับการจำแนกหลายอารมณ์พร้อมกันแล้วก็ตาม ปัญหานี้เรียกว่า “ความไม่สมดุลของข้อมูล” ซึ่งเป็นเรื่องปกติในการทำงานกับข้อมูลจริง แต่ก็ส่งผลต่อประสิทธิภาพของโมเดลอย่างชัดเจน โดยเฉพาะในอารมณ์ที่พบน้อย จึงอาจต้องหาวิธีเพิ่มตัวอย่างในคลาสเหล่านี้ หรือใช้เทคนิคอื่น ๆ เพื่อให้โมเดลเรียนรู้ได้ดีขึ้นในอนาคต 4) ความคลุมเครือของอารมณ์ ข้อความที่ได้จากผู้ใช้บนช่องทางออนไลน์ มักไม่ได้แสดงอารมณ์อย่างชัดเจนหรือตรงไปตรงมา เช่น ความไม่พอใจที่ซ่อนอยู่ภายใต้คำถามเชิงสุภาพ หรือความคาดหวังที่แฝงมากับความวิตกกังวล ซึ่งส่งผลให้ข้อความเดียวสามารถ มีได้มากกว่าหนึ่งอารมณ์ หรือมีการซ้อนทับของอารมณ์ที่มีลักษณะใกล้เคียงกัน เช่น ความคาดหวัง กับ ความไว้วางใจ หรือ ความเศร้า กับ อารมณ์เชิงลบ ความกำกวมและความละเอียดอ่อนในลักษณะเช่นนี้ก่อให้เกิดความท้าทายทั้งในกระบวนการติดป้ายกำกับอารมณ์ (labeling) และในการฝึกโมเดล เนื่องจากแม้แต่ผู้ประเมินในระดับมนุษย์เองก็อาจตีความอารมณ์ในข้อความเดียวกันได้แตกต่างกัน ดังนั้น ความไม่ชัดเจน

ของลักษณะอารมณ์จึงเป็นหนึ่งในปัจจัยที่ส่งผลต่อความไม่เสถียรของโมเดลในการจำแนกอารมณ์บางประเภท โดยเฉพาะในกลุ่มที่มีบริบทซับซ้อนหรือมีอารมณ์หลายระดับผสมกันอยู่ในข้อความเดียว นอกจากนี้ โจทย์ของงานวิจัยในครั้งนี้มุ่งวิเคราะห์อารมณ์จากคอมเมนต์ในโพสต์เกี่ยวกับผลิตภัณฑ์เงินฝากของธนาคาร ซึ่งโดยธรรมชาติแล้วมักไม่ก่อให้เกิดอารมณ์เชิงลบ เช่น ความกลัว ความรังเกียจ เป็นต้น ทำให้ข้อมูลในบางอารมณ์แทบไม่ปรากฏเลย และสะท้อนให้เห็นว่าผลลัพธ์ที่พบไม่ได้สะท้อนความสามารถของโมเดลเพียงอย่างเดียว แต่ยังจำกัดด้วยคอนเทนต์ที่นำมาวิเคราะห์อีกด้วย และหากสามารถเข้าถึงข้อมูลที่หลากหลายขึ้น เช่น การใช้ Social Listening จากข่าวหรือโพสต์ที่ไม่ได้เกี่ยวข้องกับผลิตภัณฑ์เงินฝากโดยตรง แต่เป็นข้อร้องเรียนหรือปัญหาที่เกิดขึ้นจากการใช้บริการธนาคาร อาจจะช่วยให้อาจจะช่วยให้ได้ข้อมูลอารมณ์ที่หลากหลายและสามารถนำไปใช้วิเคราะห์ความรู้สึกของลูกค้าได้มากกว่า

ข้อเสนอแนะสำหรับงานวิจัยในอนาคต 1) เพิ่มขนาดและคุณภาพของข้อมูล หนึ่งในปัจจัยหลักที่ส่งผลต่อประสิทธิภาพของโมเดลคือจำนวนตัวอย่างและความสมดุลของข้อมูลในแต่ละประเภทของอารมณ์ โดยเฉพาะกลุ่มที่มีความถี่ต่ำในชุดฝึก เช่น ความกลัว ความรังเกียจ และความประหลาด ซึ่งส่งผลให้โมเดลเรียนรู้ได้ไม่ทั่วถึง และมักหลีกเลี่ยงการทำนายอารมณ์เหล่านี้โดยไม่ตั้งใจ เนื่องจากข้อมูลไม่เพียงพอที่จะสร้างแบบแผนที่ชัดเจน เพื่อแก้ไขปัญหา ควรเพิ่มปริมาณข้อมูลจากแหล่งที่หลากหลาย เช่น โพสต์บนแพลตฟอร์มสื่อสังคมออนไลน์หรือคำตอบจากแบบสอบถามปลายเปิด เพื่อสะท้อนมุมมองและการใช้งานภาษาที่แตกต่างกันในบริบทจริง อีกทั้งสามารถนำเทคนิคการเพิ่มข้อมูล (Data Augmentation) มาช่วยขยายชุดข้อมูลได้อย่างมีประสิทธิภาพ ไม่ว่าจะเป็นการแปลกลับไปกลับมา (Back-Translation), การใช้คำเทียบเคียง (Paraphrasing), หรือการปรับโครงสร้างประโยคใหม่ วิธีการเหล่านี้จะช่วยให้อาจจะช่วยให้โมเดลมีโอกาสเรียนรู้อารมณ์ที่พบบ่อยน้อยมากขึ้น และลดผลกระทบจากความไม่สมดุลในชุดข้อมูลได้อย่างเป็นรูปธรรม 2) ใช้โมเดลที่รองรับภาษาไทยโดยตรง การแปลข้อความจากภาษาไทยเป็นภาษาอังกฤษก่อนนำเข้าโมเดลอาจทำให้สูญเสียบริบทเฉพาะของภาษาไทย เช่น คำแสลง การเล่นคำ หรือการเว้นวรรคที่มีนัยทางอารมณ์ ดังนั้นผู้วิจัยเสนอให้ใช้โมเดลภาษาที่รองรับภาษาไทยโดยตรง เช่น WangchanBERTa หรือ XLM-Roberta ซึ่งเป็นโมเดลขนาดใหญ่ที่ได้รับการฝึกฝนด้วยข้อมูลภาษาไทยโดยเฉพาะ (หรือหลายภาษาในกรณีของ XLM-R) ซึ่งจะช่วยให้โมเดลเข้าใจบริบทเชิงอารมณ์ที่ลึกซึ้งของข้อความภาษาไทยได้ดีขึ้น ลดความผิดพลาดจากการตีความคำแปล และอาจเพิ่มความแม่นยำของระบบในภาพรวมได้อย่างมีนัยสำคัญ 3) ทดลองใช้เทคนิคการปรับแต่งโมเดลขั้นสูง แม้การใช้ BERT แบบพื้นฐานสามารถให้ผลลัพธ์ในระดับที่น่าพอใจ แต่การปรับแต่งเพิ่มเติมด้วยเทคนิคขั้นสูง เช่น การกำหนด Class Weighting เพื่อเพิ่มน้ำหนักให้กับอารมณ์ที่มีจำนวนน้อย หรือการใช้ Focal Loss แทน Binary Cross-Entropy เพื่อโฟกัสที่ตัวอย่างที่โมเดลทำผิดได้บ่อย จะช่วยให้โมเดลเรียนรู้ได้ดีขึ้นในกลุ่มอารมณ์ที่ยากต่อการจำแนก อย่างไรก็ตาม ผู้วิจัยเลือกเริ่มต้นด้วย BERT และ Binary Cross-Entropy ซึ่งเป็นแนวทางมาตรฐานที่เหมาะสมกับงานจำแนกแบบหลายป้ายกำกับ เพื่อสร้างพื้นฐานเบื้องต้นที่สามารถใช้ประเมินประสิทธิภาพของโมเดลบนข้อมูลที่แปลจากภาษาไทยได้อย่างเป็นระบบ อีกทั้งยังช่วยควบคุมปัจจัยแทรก เช่น ความไม่สมดุลของข้อมูล และความเสี่ยงจากการปรับแต่งโมเดลมากเกินไปในช่วงต้น ผลลัพธ์จากพื้นฐานนี้จึงสามารถใช้เป็นจุดอ้างอิงที่ชัดเจนเมื่อนำเทคนิคขั้นสูงมาทดลองเพิ่มเติมในลำดับถัดไป นอกจากนี้ยังสามารถใช้โมเดลเรียนรู้หลายงานพร้อมกัน (Multi-Task Learning) เช่น การจำแนกอารมณ์ร่วมกับการจัดกลุ่มความพึงพอใจ เพื่อช่วยให้โมเดลเข้าใจโครงสร้างของข้อมูลได้กว้างขึ้นและเรียนรู้เชิงลึกได้ดียิ่งขึ้น และ 4) เชื่อมต่อกับระบบจริง หากนำโมเดลไปใช้งานจริงในระบบของธนาคาร เช่น ระบบบริหารความสัมพันธ์ลูกค้า (Customer Relationship Management: CRM) หรือฝ่ายบริการลูกค้า (Customer Service) ควรออกแบบระบบให้สามารถแสดงผลอารมณ์ที่ตรวจพบได้ในรูปแบบที่เข้าใจง่าย เช่น แดชบอร์ด (Dashboard) แบบสรุปอารมณ์ แผนภูมิแสดงแนวโน้มอารมณ์ หรือข้อความสรุปเชิงวิเคราะห์ในแต่ละช่วงเวลา เพื่อให้ฝ่ายบริการหรือผู้บริหารสามารถใช้ข้อมูลดังกล่าวตัดสินใจได้อย่างมีประสิทธิภาพ การประยุกต์โมเดลในลักษณะนี้จะช่วยให้ธนาคารสามารถติดตามความรู้สึกของลูกค้าแบบเรียลไทม์ เสริมสร้างภาพลักษณ์ที่ตอบสนองต่ออารมณ์ลูกค้า ได้อย่างตรงจุด สามารถออกแบบข้อเสนอได้ตามตรงพฤติกรรมของลูกค้า และปรับปรุงกระบวนการให้บริการลูกค้า ส่งผลให้

สามารถสร้างความพึงพอใจและความผูกพันในระยะยาว นอกจากนี้ ยังสามารถนำไปต่อยอดในการนำข้อมูลไปใช้สนับสนุนในการช่วยตัดสินใจในด้านการบริหารของธนาคารในภาพรวมอีกด้วย

## บรรณานุกรม

- ธนาคารแห่งประเทศไทย. (2566). รายงานผลสำรวจการเข้าถึงบริการทางการเงินภาคครัวเรือน ปี 2565. สืบค้น 20 พฤศจิกายน 2567. จาก <https://www.bot.or.th/th/research-and-publications/reports/financial-access-survey-of-thai-household.html>
- ปรีดี นุกุลสมปรารถนา. (4 มีนาคม 2567). รวมสถิติและ Insight สำคัญ ๆ ของคนไทยกับการใช้ Digital และ Social Media 2024. สืบค้น 20 พฤศจิกายน 2567. จาก <https://www.popticles.com/insight/thailand-digital-and-social-media-stats-2024/>
- ศูนย์วิจัยธนาคารออมสิน. (3 เมษายน 2567). รายงานติดตามภาวะเงินฝากและการออม ณ เดือน มีนาคม 2567. สืบค้น 20 พฤศจิกายน 2567. จาก <https://www.gsb.or.th/gsbresearch/published-works/13360/>
- Abdullah, A. S., Mishra, U., Bala Adithyan, G., & Sriram, B. (2024, February 22–23). *Opinion analysis and text pattern detection from social media data using integrated machine learning approach*. In *Proceedings of the 2024 Second International Conference on Emerging Trends in Information Technology and Engineering (ICETITE)* (pp. 1–6). IEEE. from <https://doi.org/10.1109/ic-ETITE58242.2024.10493286>
- Abdulrashid, I., Ahmad, I. S., Musa, A., & Khalafalla, M. (2024). Impact of social media posts' characteristics on movie performance prior to release: An explainable machine learning approach. *Electronic Commerce Research*. from <https://doi.org/10.1007/s10660-024-09852-3>
- Alloghani, M., Al-Jumeily, D., Mustafina, J., Hussain, A., & Aljaaf, A. J. (2020). A systematic review on supervised and unsupervised machine learning algorithms for data science. In M. W. Berry, A. Mohamed, & B. W. Yap (Eds.), *Supervised and unsupervised learning for data science* (pp. 3–21). Springer International Publishing. from [https://doi.org/10.1007/978-3-030-22475-2\\_1](https://doi.org/10.1007/978-3-030-22475-2_1)
- Arano, K., Orsenigo, C., Soto Gomez, M., & Vercellis, C. (2021). Multimodal sentiment and emotion recognition in hyperbolic space. *Expert Systems with Applications*, 184, 115507. from <https://doi.org/10.1016/j.eswa.2021.115507>
- Araque, O., Zhu, G., & Iglesias, C. A. (2019). A semantic similarity-based perspective of affect lexicons for sentiment analysis. *Knowledge-Based Systems*, 165, 346–359. from <https://doi.org/10.1016/j.knosys.2018.12.005>
- Bae, Y. J., Shim, M., & Lee, W. H. (2021). Schizophrenia detection using machine learning approach from social media content. *Sensors*, 21(17), 5924. from <https://doi.org/10.3390/s21175924>
- Baz, M., Sami, A., Prottasha, N., Kowsher, M., Murad, S., Bairagi, A., & Masud, M. (2022). Transfer learning for sentiment analysis using BERT based supervised fine-tuning. *Sensors*, 22(11), 4157. from <https://doi.org/10.3390/s22114157>
- Cao, Y., Dai, J., Wang, Z., Zhang, Y., Shen, X., Liu, Y., & Tian, Y. (2024). *Systematic review: Text processing algorithms in machine learning and deep learning for mental health detection on social media*. arXiv. from <https://doi.org/10.48550/arXiv.2410.16204>

- Chan, S., & Chong, M. (2016). Sentiment analysis in financial texts. *Decision Support Systems*, 94, 53–64. from <https://doi.org/10.1016/j.dss.2016.10.006>
- Dhatterwal, J. S., Kaswan, K. S., Grima, S., & Sood, K. (2023). Machine learning and deep learning for financial data analysis. In *Intelligent multimedia technologies for financial risk management: Trends, tools and applications* (pp. 115–135). Institution of Engineering and Technology. from [https://doi.org/10.1049/PBPC060E\\_ch6](https://doi.org/10.1049/PBPC060E_ch6)
- Gutiérrez-Fandiño, A., Alonso, M., Kolm, P., & Armengol-Estapé, J. (2021). *FinEAS: Financial embedding analysis of sentiment*. arXiv. from <https://doi.org/10.48550/arXiv.2111.00526>
- Han, H., Asif, M., Awwad, E., Sarhan, N., Ghadi, Y., & Xu, B. (2024). Innovative deep learning techniques for monitoring aggressive behavior in social media posts. *Journal of Cloud Computing*, 13(1), Article 19. from <https://doi.org/10.1186/s13677-023-00577-6>
- Karimova, H. (2017, December 24). *The emotion wheel: What it is and how to use it*. PositivePsychology.com. Retrieved 20 November 2024, from <https://positivepsychology.com/emotion-wheel/>
- Khan, L., Qazi, A., Chang, H.-T., Alhajlah, M., & Mahmood, A. (2024). Empowering Urdu sentiment analysis: An attention-based stacked CNN-Bi-LSTM DNN with multilingual BERT. *Complex & Intelligent Systems*, 11. from <https://doi.org/10.1007/s40747-024-01631-9>
- Liu, Y., Ott, M., Goyal, N., Du, J., Joshi, M., Chen, D., Levy, O., Lewis, M., Zettlemoyer, L., & Stoyanov, V. (2019). RoBERTa: A robustly optimized BERT pretraining approach. arXiv. from <https://doi.org/10.48550/arXiv.1907.11692>
- Meng, X., Wang, C., Yang, J., Li, M., Zhang, Y., & Wang, L. (2024). Predicting users' latent suicidal risk in social media: An ensemble model based on social network relationships. *Computers, Materials & Continua*, 79(3), 4259–4281. from <https://doi.org/10.32604/cmc.2024.050325>
- Mohammad, S. M., & Turney, P. D. (2013). *Crowdsourcing a word–emotion association lexicon*. *Computational Intelligence*, 29(3), 436–465. from <https://doi.org/10.1111/j.1467-8640.2012.00460.x>
- Mohamed Zaki, A., Khodadadi, N., Lim, W. H., & El-kenawy, E.-S. (2024). Predictive analytics and machine learning in direct marketing for anticipating bank term deposit subscriptions. *American Journal of Business and Operations Research*, 11, 79–88. from <https://doi.org/10.54216/AJBOR.110110>
- Negru, V.-A., Suci, V., Lăpușan, A.-M., Lemnaru, C., Dîșoreanu, M., & Potolea, R. (2025). Assessing language models' task and language transfer capabilities for sentiment analysis in dialog data. *Computer Speech & Language*, 89, 101704. from <https://doi.org/10.1016/j.csl.2024.101704>
- Plisiecki, H., Koc, P., Flakus, M., & Pokropek, A. (2024). Predicting emotion intensity in Polish political texts: Comparing supervised models and large language models in a resource-poor language. arXiv. from <https://doi.org/10.48550/arXiv.2407.12141>
- Plutchik, R. (1980). *Emotion: A psychoevolutionary synthesis*. Harper & Row.
- Raman, R., & Tiwari, P. (2024). Finance's AI revolution: Transforming banking and investments for tomorrow. In *Proceedings of the 4th International Conference on Emerging Systems and Intelligent Computing (ESIC 2024)*.

- Saravia, E., Liu, H.-C. T., Huang, Y.-H., Wu, J., & Chen, Y.-S. (2018). CARER: Contextualized affect representations for emotion recognition. In E. Riloff, D. Chiang, J. Hockenmaier, & J. Tsujii (Eds.), *Proceedings of the 2018 Conference on Empirical Methods in Natural Language Processing* (pp. 3687–3697). Association for Computational Linguistics. from <https://doi.org/10.18653/v1/D18-1404>
- Sarker, I. H. (2021). Machine learning: Algorithms, real-world applications and research directions. *SN Computer Science*, 2(3), Article 160. from <https://doi.org/10.1007/s42979-021-00592-x>
- Wei, L., & Dihong, G. (2024). Pre-trained large language models for financial sentiment analysis. *arXiv*. from <https://doi.org/10.48550/arXiv.2401.05215>
- Wu, X., Liu, X., & Zhou, Y. (2021). Review of unsupervised learning techniques. In Y. Bi, S. Kapoor, & R. Bhatia (Eds.), *Proceedings of 2021 Chinese Intelligent Systems Conference* (pp. 576–590). Springer. from [https://doi.org/10.1007/978-981-16-6324-6\\_59](https://doi.org/10.1007/978-981-16-6324-6_59)