

การสร้างและประเมินแบบจำลองการทำนายการมีส่วนร่วมของบัญชี TikTok
ด้านอาหารและเครื่องดื่มในประเทศไทย จากคุณลักษณะทางภาพในวิดีโอด้วยวิธีการเรียนรู้ของเครื่อง

ฟูจิ งามบรรจง

TNI

วิทยานิพนธ์นี้เป็นส่วนหนึ่งของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรมหาบัณฑิต

บัณฑิตศึกษา สาขาเทคโนโลยีสารสนเทศ

สถาบันเทคโนโลยีไทย-ญี่ปุ่น

ปีการศึกษา 2568

DEVELOPING AND EVALUATING PREDICTION MODELS FOR USER ENGAGEMENT
IN THAILAND'S FOOD & BEVERAGE TIKTOK ACCOUNTS FROM VISUAL FEATURES
USING MACHINE LEARNING

Fuji Ngambanjong

TNI

A Thesis Submitted in Partial Fulfillment of the Requirements
for the Degree of Master of Science Program in Information Technology
Graduate Studies

Thai-Nichi Institute of Technology

Academic Year 2025

หัวข้อวิทยานิพนธ์

การสร้างและประเมินแบบจำลองการทำนายการมีส่วนร่วม
ของบัญชี TikTok ด้านอาหารและเครื่องดื่มในประเทศไทย
จากคุณลักษณะทางภาพในวิดีโอด้วยวิธีการเรียนรู้ของเครื่อง
ฟูจิ งามบรรจง
เทคโนโลยีสารสนเทศ
ดร.สะพรั่งสิทธิ์ มฤตสาธ

โดย

สาขาวิชา

อาจารย์ที่ปรึกษาวิทยานิพนธ์

บัณฑิตศึกษา สถาบันเทคโนโลยีไทย-ญี่ปุ่น อนุมัติให้บัณฑิตวิทยานิพนธ์ฉบับนี้เป็นส่วนหนึ่ง
ของการศึกษาตามหลักสูตรปริญญาวิทยาศาสตรบัณฑิต

.....รองอธิการบดีฝ่ายวิชาการ

(รองศาสตราจารย์ ดร.วรกร ศรีเชวงทรัพย์)

วันที่.....เดือน.....พ.ศ.....

คณะกรรมการสอบวิทยานิพนธ์

.....ประธานกรรมการ

(รองศาสตราจารย์ ดร.ทิมพันธุ์ เจริญพงษ์)

.....กรรมการ

(ดร.ประมุข บุญเสียง)

.....กรรมการ

(ว่าที่ร้อยตรี ดร.พิชิตชัย คำอินทร์)

.....อาจารย์ที่ปรึกษาวิทยานิพนธ์

(ดร.สะพรั่งสิทธิ์ มฤตสาธ)

พู่จิ งามบรรจง : การสร้างและประเมินแบบจำลองการทำนายการมีส่วนร่วมของบัญชี TikTok ด้านอาหารและเครื่องดื่มในประเทศไทย จากคุณลักษณะทางภาพในวิดีโอด้วยวิธีการเรียนรู้ของเครื่อง. อาจารย์ที่ปรึกษา : ดร.สะพรั่งสิทธิ์ มฤตสาธร, 89 หน้า.

ปัจจุบัน TikTok เป็นแพลตฟอร์มสื่อสังคมออนไลน์ที่มีบทบาทสำคัญต่อการตลาดดิจิทัล โดยเฉพาะในอุตสาหกรรมอาหารและเครื่องดื่ม ซึ่งการมีส่วนร่วมของผู้ใช้งาน เช่น การกดถูกใจ การแสดงความคิดเห็น และการแชร์ ถือเป็นตัวชี้วัดสำคัญของประสิทธิภาพเนื้อหา อย่างไรก็ตาม การคาดการณ์ระดับการมีส่วนร่วมของวิดีโอยังคงเป็นปัญหาที่มีความซับซ้อน เนื่องจากได้รับอิทธิพลจากหลายปัจจัย

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาและเปรียบเทียบแบบจำลองการทำนายการมีส่วนร่วมของคลิปวิดีโอ TikTok ด้านอาหารและเครื่องดื่มในประเทศไทย โดยใช้คุณลักษณะทางภาพร่วมกับเทคนิคการเรียนรู้ของเครื่อง ข้อมูลที่ใช้ในการวิจัยประกอบด้วยคลิปวิดีโอจำนวน 1,000 คลิป จากบัญชี TikTok ด้านอาหารและเครื่องดื่มจำนวน 50 บัญชี ซึ่งมีผู้ติดตามระหว่าง 10,000-50,000 คน โดยวิเคราะห์คุณลักษณะทางภาพ เช่น ความสว่าง สี สัน โลโก้ และประเภทของอาหารภายในวิดีโอ

แบบจำลองที่ใช้ในการทดลอง ได้แก่ Random Forest, Support Vector Classifier (SVC), LightGBM, CatBoost และ Logistic Regression ในฐานะแบบจำลองพื้นฐาน โดยประเมินผลด้วยค่า Accuracy, Precision, Recall, F1-score และ ROC-AUC

ผลการทดลองพบว่า การทำนายการกดถูกใจให้ผลดีที่สุด รองลงมาคือการแชร์ และการแสดงความคิดเห็นทั้งค่า Accuracy และ ROC-AUC โดยค่าความถูกต้องสูงสุดเท่ากับ 0.7350, 0.7000 และ 0.5950 ตามลำดับ แบบจำลอง ผลการวิเคราะห์ความสำคัญของคุณลักษณะพบว่า ความสว่าง สี สัน สดใส และประเภทของอาหาร เป็นปัจจัยสำคัญที่ส่งผลต่อระดับการมีส่วนร่วมของผู้ใช้งาน

บัณฑิตศึกษา

สาขาวิชา เทคโนโลยีสารสนเทศ

ปีการศึกษา 2568

ลายมือชื่อนักศึกษา

ลายมือชื่ออาจารย์ที่ปรึกษา

FUJI NGAMBANJONG : DEVELOPING AND EVALUATING PREDICTION MODELS FOR USER ENGAGEMENT IN THAILAND'S FOOD & BEVERAGE TIKTOK ACCOUNTS FROM VISUAL FEATURES USING MACHINE LEARNING. ADVISOR : DR.SAPRANGSIT MRUETUSATORN, 89 PP.

TikTok plays significant roles for digital marketing, especially in the food and beverage industry. User engagement, including likes, comments, and shares, is considered a key indicator of content performance. However, predicting engagement levels on TikTok videos remains a complex task due to multiple influencing factors.

This research aims to develop and compare machine learning models for predicting engagement on food and beverage TikTok videos in Thailand using visual features extracted from videos. The dataset consisted of 1,000 video clips collected from 50 Thai food and beverage TikTok accounts. The visual features analyzed included brightness, colorfulness, logos, and food categories appearing in the videos.

The machine learning models used in this study were Random Forest, Support Vector Classifier (SVC), LightGBM, CatBoost, and Logistic Regression as the baseline model. Model performance was evaluated using Accuracy, Precision, Recall, F1-score, and ROC-AUC.

The results showed that predicting likes achieved the best performance, followed by shares and comments in terms of both Accuracy and ROC-AUC. The highest Accuracy scores were 0.7350, 0.7000, and 0.5950, respectively. Feature importance analysis indicated that brightness, colorfulness, and food categories were significant factors affecting user engagement levels.

Graduate Studies

Field of Study Information Technology

Academic Year 2025

Student's Signature.....

Advisor's Signature.....

กิตติกรรมประกาศ

วิทยานิพนธ์ฉบับนี้สำเร็จลุล่วงได้ด้วยดีจากความกรุณาและการสนับสนุนจากหลายฝ่าย ผู้วิจัยขอกราบขอบพระคุณ ดร.สพรั่งสิทธิ มฤตุสาธร์ อาจารย์ที่ปรึกษาวิทยานิพนธ์ ที่ได้กรุณาให้คำปรึกษา ข้อเสนอแนะ และแนวทางในการดำเนินงานวิจัยมาโดยตลอด รวมถึงให้คำแนะนำในการปรับปรุงแก้ไข ข้อบกพร่องต่างๆ ด้วยความเอาใจใส่และความเมตตาอย่างยิ่ง จนทำให้วิทยานิพนธ์ฉบับนี้สำเร็จสมบูรณ์

ผู้วิจัยขอขอบพระคุณคณะกรรมการสอบวิทยานิพนธ์ทุกท่าน ได้แก่ รองศาสตราจารย์ ดร.ทิมพันธุ์ เจริญพงษ์ ดร.ประมุข บุญเสียง ว่าที่ร้อยตรี ดร.พิชิตชัย คำอินทร์ ที่ได้กรุณาให้ข้อเสนอแนะ คำวิจารณ์ และแนวทางในการปรับปรุงงานวิจัยให้มีความสมบูรณ์และมีคุณค่าทางวิชาการมากยิ่งขึ้น

นอกจากนี้ ผู้วิจัยขอขอบคุณแหล่งข้อมูล งานวิจัย และเครื่องมือทางเทคโนโลยีต่างๆ ที่เกี่ยวข้องกับการศึกษาด้านการเรียนรู้ของเครื่อง การวิเคราะห์ข้อมูล และแพลตฟอร์ม TikTok ตลอดจนผู้พัฒนาไลบรารีและเครื่องมือโอเพนซอร์สที่ช่วยสนับสนุนการดำเนินงานวิจัยครั้งนี้

ท้ายที่สุดนี้ ผู้วิจัยขอขอบคุณคณาจารย์ทุกท่านใน สถาบันเทคโนโลยีไทย-ญี่ปุ่น ที่ได้ถ่ายทอดความรู้และประสบการณ์ทางด้านเทคโนโลยีสารสนเทศ ตลอดจนขอขอบคุณครอบครัว เพื่อนร่วมชั้นเรียน และบุคคลรอบข้างทุกท่าน ที่คอยให้กำลังใจ ความช่วยเหลือ และการสนับสนุนตลอดระยะเวลาการศึกษาและการจัดทำวิทยานิพนธ์ฉบับนี้

ผู้วิจัยหวังเป็นอย่างยิ่งว่า วิทยานิพนธ์ฉบับนี้จะเป็นประโยชน์ต่อผู้ที่สนใจด้านการวิเคราะห์ข้อมูล การเรียนรู้ของเครื่อง และการศึกษาพฤติกรรมผู้ใช้งานบนสื่อสังคมออนไลน์ รวมทั้งสามารถนำไปประยุกต์ใช้หรือพัฒนาต่อยอดในงานวิจัยและภาคธุรกิจที่เกี่ยวข้องในอนาคตได้ต่อไป

ฟูจิ งามบรรจง

สารบัญ

	หน้า
บทคัดย่อภาษาไทย.....	ง
บทคัดย่อภาษาอังกฤษ.....	จ
กิตติกรรมประกาศ.....	ฉ
สารบัญ.....	ช
สารบัญตาราง.....	ฌ
สารบัญรูป.....	ญ
บทที่	
1 บทนำ.....	1
1.1 ความเป็นมาและความสำคัญของปัญหา.....	1
1.2 วัตถุประสงค์ของการวิจัย.....	5
1.3 ขอบเขตของการวิจัย.....	5
1.4 ประโยชน์ที่คาดว่าจะได้รับ.....	6
1.5 นิยามศัพท์เฉพาะ.....	6
2 ทฤษฎี หลักการ และงานวิจัยที่เกี่ยวข้อง.....	7
2.1 องค์ความรู้และทฤษฎีพื้นฐานที่เกี่ยวข้อง.....	7
2.2 วิธีการและเทคนิคที่ใช้การเรียนรู้ของเครื่อง.....	17
2.3 เครื่องมือและโปรแกรมที่ใช้ในการวิจัย.....	25
2.4 งานวิจัยที่เกี่ยวข้อง.....	26
3 ระเบียบและวิธีดำเนินการวิจัย.....	33
3.1 เก็บข้อมูลและเตรียมข้อมูล.....	34
3.2 การดึงฟีเจอร์จากภาพในโพสต์.....	34
3.3 การทำความสะอาดล้างข้อมูลและประมวลผล.....	38
3.4 การเลือกและพัฒนาโมเดลการทำนาย.....	40
3.5 การฝึกฝน ตรวจสอบและทดสอบโมเดล.....	42

สารบัญ (ต่อ)

บทที่		หน้า
3	3.6 การประเมินผล	42
4	ผลการวิจัย.....	44
	4.1 การออกแบบการทดลอง	44
	4.2 ผลการทดลองจำแนกตามประเภทการมีส่วนร่วม	44
	4.3 ผลการทดลองด้วยค่า Accuracy และ ROC-AUC.....	49
	4.4 การวิเคราะห์ความสำคัญของคุณลักษณะทางภาพ	51
5	บทสรุป อภิปราย และข้อเสนอแนะ.....	53
	5.1 สรุปผลการวิจัย.....	53
	5.2 อภิปรายผล.....	54
	5.3 ข้อเสนอแนะ	57
	บรรณานุกรม	59
	ภาคผนวก	63
	ภาคผนวก ก. เอกสารประกอบการนำเสนอสอบป้องกันวิทยานิพนธ์.....	64
	ประวัติย่อผู้วิจัย.....	89

สารบัญตาราง

ตาราง	หน้า
2.1 ปัจจัยที่มีผลต่อการมีส่วนร่วมทางโซเชียลมีเดีย.....	27
2.2 เทคนิคการเรียนรู้ของเครื่องที่ใช้ในการทำนายจากงานวิจัย.....	28
2.3 การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่องแต่ละประเภท	29
2.4 การเปรียบเทียบจำนวนตัวอย่างในงานวิจัยที่เกี่ยวข้อง	32
3.1 คุณลักษณะพีเจอร์จากภาพในโพสต์และมาตรฐานการวัดข้อมูล.....	36
3.2 คุณลักษณะภาพและเครื่องมือสำหรับการตรวจจับคุณลักษณะ.....	38
3.3 การเปรียบเทียบเทคนิค หลักการทำงานและความเหมาะสมกับงานวิจัย	40
3.4 เทคนิคการเรียนรู้ของเครื่องที่ใช้ในการทดลอง	42
4.1 ผลการประเมินประสิทธิภาพของการกดไลก์ (Like) แบบ Confusion Matrix.....	44
4.2 ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการทำนายการกดไลก์ (Like).....	45
4.3 ผลการประเมินประสิทธิภาพของการแชร์ (Share) แบบ Confusion Matrix	46
4.4 ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการทำนายการแชร์ (Share).....	47
4.5 ผลการประเมินประสิทธิภาพของแสดงความคิดเห็น (Comment) แบบ Confusion Matrix.....	48
4.6 ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการแสดงความคิดเห็น (Comment)	49
4.7 การเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยค่า Accuracy และ ROC-AUC ในการทำนายการกดไลก์ การแชร์ และการแสดงความคิดเห็น	50
4.8 ลำดับความสำคัญของคุณลักษณะทางภาพ 5 อันดับแรก.....	51

สารบัญรูป

รูป	หน้า
1.1 ลำดับความสำคัญของนโยบายทางการตลาดของผู้บริหารสำหรับ 12 เดือนข้างหน้า.....	1
1.2 โซเชียลมีเดียแพลตฟอร์มที่ได้รับความนิยมในประเทศไทย.....	2
1.3 การเปลี่ยนแปลงในการใช้แพลตฟอร์มสำหรับธุรกิจจากปี 2022 ถึง 2023.....	2
1.4 อุตสาหกรรมตามลำดับการลงทุนโฆษณาสูงสุดในประเทศไทยช่วงมกราคมถึงตุลาคม ปี 2023	3
1.5 ตัวชี้วัดความสำเร็จของเนื้อหาของโฆษณา.....	4
2.1 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตามและการมีส่วนร่วม.....	8
2.2 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตาม และการกดถูกใจ	9
2.3 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตาม Follower และจำนวนความคิดเห็น	10
2.4 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตาม Follower และจำนวนการรีโพสต์	11
2.5 แนวคิดการเดินทางของผู้บริโภคของ McKinsey	16
3.1 ระบบที่นำเสนอ.....	33
3.2 รูปตัวอย่างของภาพตัวแทนวิดีโอ	35
3.3 รูปตัวอย่างที่ Apify ทำการ Scraping	39
3.4 รูปตัวอย่างของข้อมูลที่ต้องการ หลังจากทำความสะอาด	39
3.5 รูปตัวอย่างของข้อมูลที่เป็น Boolean ก่อนนำไปทำนาย.....	40

TNI

THAI - NICHI INSTITUTE OF TECHNOLOGY

บทที่ 1

บทนำ

1.1 ความเป็นมาและความสำคัญของปัญหา


แพลตฟอร์มและเทคโนโลยีดิจิทัลมีบทบาทสำคัญอย่างมากในโลกปัจจุบัน จากการสัมภาษณ์ประธานและเจ้าหน้าที่การตลาด 1,015 คนทั่วโลก ดังรูปที่ 1.1 ผลลัพธ์แสดงให้เห็นว่านโยบายที่พวกเขาให้ความสำคัญมากที่สุด เพื่อที่จะลดความเสี่ยงของบริษัทต่อความไม่แน่นอนทาง เศรษฐกิจในปัจจุบัน คือ การเร่งย้ายไปสู่แพลตฟอร์ม หรือเทคโนโลยีดิจิทัลรูปแบบใหม่ เพราะแพลตฟอร์มดิจิทัลที่ได้นั้นสามารถกระตุ้นให้ลูกค้ามีส่วนร่วมได้ลึกซึ้งมากขึ้น นอกจากนี้ยังสามารถเก็บข้อมูล ซึ่งนำมาใช้ในการพัฒนาตอบสนองความพึงพอใจของลูกค้า และความผูกพันบัญชีต่อแบรนด์ ได้ลึกซึ้งมากขึ้น เทคโนโลยีที่นักการตลาดให้ความสำคัญ ได้แก่ การใช้ปัญญาประดิษฐ์ (AI) และการวิเคราะห์ ข้อมูล (Data Analytics) เพื่อสร้างประสบการณ์ที่ดีแก่ลูกค้า ในขณะที่เดียวกันก็สามารถทำความเข้าใจลูกค้าได้มากขึ้น การประยุกต์ใช้แพลตฟอร์มโซเชียล (การค้าขายผ่าน โซเชียลมีเดีย) เป็นต้น [1]



Source: 2023 Deloitte Global Marketing Trends executive survey, conducted in June 2022.

รูปที่ 1.1 ลำดับความสำคัญของนโยบายทางการตลาดของผู้บริหารสำหรับ 12 เดือนข้างหน้า [1]

จากรูปที่ 1.2 แพลตฟอร์ม Facebook ยังคงเป็นที่ได้รับความนิยมสูงสุดในประเทศไทยและตามมาด้วย TikTok ซึ่งความนิยมนั้นวัดจากกลุ่มคนตัวอย่างคนช่วงอายุ 16 ถึง 64 ปีใน ประเทศไทย ที่ยังเล่นโซเชียลมีเดียอย่างต่อเนื่อง [2]




รูปที่ 1.2 โซเชียลมีเดียแพลตฟอร์มที่ได้รับความนิยมในประเทศไทย [2]



รูปที่ 1.3 การเปลี่ยนแปลงในการใช้แพลตฟอร์มสำหรับธุรกิจจากปี 2022 ถึง 2023 [3]


ถึงแม้ว่า Facebook จะยังเป็นแพลตฟอร์มที่คนใช้งานและชอบมากที่สุด แต่ในเชิงธุรกิจแล้ว ก็ถือว่าค่อนข้างท้าทาย เพราะปริมาณการมีส่วนร่วมของผู้ชม ในการกดถูกใจ หรือแสดงความคิดเห็นในปัจจุบันถือว่าต่ำมากอยู่ที่ 0.02-0.05% ในขณะที่ผู้เชี่ยวชาญได้กล่าวว่าในปี 2024 TikTok นั้น เป็นแพลตฟอร์มที่มีการเข้าถึงผู้ชม และทำให้เกิดการมีส่วนร่วมได้ค่อนข้างดี [2] ปัจจุบันอัตราการมีส่วนร่วมเฉลี่ยของผู้ใช้ TikTok ทั่วโลกในปัจจุบันในปี 2024 อยู่ที่ประมาณ 3.30% ซึ่งตัวเลขนี้ลดลงถึง 40% เมื่อเทียบกับปี 2023 หมายความว่าในปีที่ผ่านมาค่าเฉลี่ยของการมีส่วนร่วมเคยสูงกว่านี้อาจมีนัยสำคัญ การลดลงดังกล่าวส่งสัญญาณว่าแบรนด์และครีเอเตอร์ที่เคยได้รับการมีส่วนร่วมมหาศาลบน TikTok กำลังเผชิญความท้าทายมากขึ้นในช่วงต้นปี 2024 อย่างไรก็ดี แม้อัตราการมีส่วนร่วมโดยรวมจะลดลง แต่ TikTok ยังคงเป็นแพลตฟอร์มที่ขึ้นชื่อว่าการมีส่วนร่วมสูงเมื่อเทียบกับโซเชียลมีเดียประเภทอื่นๆ เนื่องจากลักษณะเนื้อหาวิดีโอสั้นที่กระตุ้นให้ผู้ชมมีปฏิสัมพันธ์กับครีเอเตอร์อย่างสม่ำเสมอ [4] นอกจากนี้ยังสามารถสังเกตได้จากรูปที่ 1.3 ที่แบรนด์ต่างๆ มีการลงทุนในตลาดบน TikTok มากขึ้น และมีอัตราการเติบโต สูงที่สุดในทางธุรกิจ [3]

จากรูปที่ 1.4 ในตลาดประเทศไทย อุตสาหกรรมที่มีการลงทุนโฆษณาเยอะที่สุดคือ ธุรกิจอาหารและเครื่องดื่ม [5] ดังนั้นงานวิจัยนี้ จะให้ความสำคัญกับการศึกษาบัญชีที่เกี่ยวข้องกับอาหาร หรือ เครื่องดื่มในแพลตฟอร์มของ TikTok



รูปที่ 1.4 อุตสาหกรรมตามลำดับการลงทุนโฆษณาสูงสุดในประเทศไทยช่วงมกราคมถึงตุลาคมปี 2023 [5]

ในขณะที่ปัจจัยที่นักการตลาดใช้ในการวัดความสำเร็จในการโฆษณาที่แสดงในรูปที่ 1.5 คือ การมีส่วนร่วมหรือการมีส่วนร่วมของคนดู [2] ทำให้ในงานวิจัยนี้ เราอ้างอิงความสำเร็จของ วิดีโอ สั้น ใน TikTok จากการมีส่วนร่วมด้วยเช่นกัน



รูปที่ 1.5 ตัวชี้วัดความสำเร็จของเนื้อหาโฆษณา [2]

TikTok นั้นเป็นแพลตฟอร์มที่มีชื่อเสียงสำหรับวิดีโอระยะสั้นซึ่งแต่ละคลิปจะประกอบด้วย เนื้อหา ภาพและเนื้อหาข้อความ โดยปกติเนื้อหาภาพจะดึงดูดความสนใจได้อย่างรวดเร็ว และสามารถ สร้าง การมีส่วนร่วมได้ดี โดยเฉพาะบนแพลตฟอร์มที่เน้นองค์ประกอบด้านภาพ ในขณะที่เนื้อหาข้อความ

อาจใช้เวลาในการทำความเข้าใจ แต่สามารถให้ข้อมูลเชิงลึก และดึงดูดผู้ใช้ที่กำลังมองหาข้อมูล ที่ละเอียด หรือการสนทนาเชิงลึกได้มากกว่า [6] เพราะฉะนั้น งานวิจัยนี้จะตั้งสมมติฐาน โดยการใช้เนื้อหาภาพจาก วิดีโอมาใช้ในการทำนายการมีส่วนร่วมของคลิป์วิดีโอ

การทำนายการมีส่วนร่วมของคลิป์วิดีโอใน TikTok เป็นประโยชน์ต่อนักการตลาด เพื่อคาดการณ์ หรือทำนายว่า คลิป์วิดีโอดังกล่าวจะได้รับความนิยมมากน้อยเพียงใดก่อนการลงทุน และสามารถช่วย ในการพัฒนาเนื้อหาให้ตรงกับความต้องการของกลุ่มเป้าหมายได้มากยิ่งขึ้น และอาจนำไปสู่การเพิ่ม ยอดขาย หรือสร้างแบรนด์ในที่สุด

1.2 วัตถุประสงค์ของการวิจัย

เพื่อพัฒนา ประเมินและเปรียบเทียบ แบบจำลองการทำนายการมีส่วนร่วมของผู้ใช้งานต่อ คลิป์วิดีโอบนแพลตฟอร์ม TikTok ด้านอาหารและเครื่องดื่มในประเทศไทย จากคุณลักษณะวิดีโอ โดยใช้ เทคนิคการเรียนรู้ของเครื่อง

1.3 ขอบเขตของการวิจัย

1.3.1 กลุ่มตัวอย่าง

คลิป์วิดีโอของบัญชีเกี่ยวกับอาหารและเครื่องดื่มในประเทศไทยที่เผยแพร่บน แพลตฟอร์ม TikTok จำนวน 1,000 คลิป์วิดีโอ โดยวิดีโอที่ใช้ในการประเมินมีลักษณะดังต่อไปนี้

- คลิป์วิดีโอที่มีเนื้อหาเกี่ยวข้องกับอาหารและเครื่องดื่มหรืออาหารหรือเครื่องดื่มในวิดีโอ
- คลิป์วิดีโอมีความยาวในช่วง 15-60 วินาที ซึ่งเป็นช่วงที่มีประสิทธิภาพมากที่สุด [7]
- คลิป์วิดีโอในช่วง 2 ปีซึ่งหมายถึง 6 กันยายน 2023 - 5 กันยายน 2025
- คลิป์จากบัญชี TikTok ที่มีผู้ติดตาม 10,000-50,000 คน ซึ่งเป็นช่วงที่มีเปอร์เซ็นต์

การมีส่วนร่วมสูงดังเห็นในภาพ 2.1 [4] เป็นบัญชีเกี่ยวกับอาหารและเครื่องดื่มในประเทศไทย

- คลิป์วิดีโอจำนวน 1,000 คลิป์จาก 50 บัญชี บัญชีละ 20 คลิป์
- คลิป์วิดีโอต้องโพสต์มาแล้วเกิน 90 วัน เพราะโอกาสที่ยอดวิวหรือการมีส่วนร่วม

เพิ่มขึ้นนั้นน้อยมาก [8]

1.3.2 ขอบเขตการวิเคราะห์

การวิเคราะห์ในงานวิจัยนี้มุ่งเน้นการศึกษาผลกระทบขององค์ประกอบทางภาพในวิดีโอ TikTok ต่อระดับการมีส่วนร่วมของผู้ใช้งาน โดยพิจารณาเฉพาะข้อมูลเชิงปริมาณ ได้แก่ จำนวนการกดไลค์ (Likes), จำนวนความคิดเห็น (Comments), จำนวนการแชร์หรือรีโพสต์ (Shares/Reposts) และจำนวนการ ดูวิดีโอ (Views) ทั้งนี้ การวิเคราะห์วิดีโอนั้นจะครอบคลุมเฉพาะปัจจัยทางภาพ (Visual Features) เช่น

สี ความคอนทราสต์ ใบหน้า อารมณ์ ข้อความและอื่นๆ โดยไม่รวมปัจจัยด้านเสียง คำบรรยายใต้ภาพ (Caption) หรือประเภทของคอนเทนต์ เพื่อให้ผลการศึกษาสะท้อนถึงอิทธิพลขององค์ประกอบภาพต่อการมีส่วนร่วมอย่างชัดเจน

1.3.3 เทคนิคการเรียนรู้ของเครื่องที่นำมาศึกษา วิเคราะห์ พัฒนาและประเมิน

- Random Forest
- Support Vector Classifier (SVC)
- LightGBM
- Catboost

1.4 ประโยชน์ที่คาดว่าจะได้รับ

ระบบประเมินการมีส่วนร่วมที่สามารถทำนายระดับการมีส่วนร่วมของผู้ใช้ต่อคลิปวิดีโอได้ อย่าง แม่นยำ ช่วยให้ผู้ประกอบการในอุตสาหกรรมร้านอาหารและเครื่องดื่มเข้าใจพฤติกรรม อีกทั้งเรา ใช้การประยุกต์วิธีการเรียนรู้ของเครื่องหลายเทคนิคของผู้ใช้บนแพลตฟอร์ม TikTok และสามารถ ปรับ กลยุทธ์การตลาดได้อย่างมีประสิทธิภาพมากขึ้น

1.5 นิยามศัพท์เฉพาะ

1.5.1 **การมีส่วนร่วม (Engagement)** หมายถึง การมีส่วนร่วมของผู้ใช้งานต่อคลิปวิดีโอ บนแพลตฟอร์ม TikTok คือ การกดไลก์ (Like) การแสดงความคิดเห็น (Comment) การแชร์ รีโพสต์ (Share/Repost) และจำนวนการเข้าชม (Views)

1.5.2 **องค์ประกอบทางภาพ (Visual Features)** หมายถึง องค์ประกอบเชิงภาพที่ปรากฏ ในวิดีโอ เช่น สีสันทัน ความสมมาตร ความคอนทราสต์ คุณภาพของภาพ ใบหน้า บุคคล และอื่นๆ ซึ่งมีผล ต่อการมีส่วนร่วมของผู้ใช้งาน

1.5.3 **แบบจำลองการทำนาย (Prediction Model)** หมายถึง แบบจำลองเชิงคณิตศาสตร์ หรือสถิติที่ถูกสร้างขึ้นโดยอาศัยเทคนิคการเรียนรู้ของเครื่อง เพื่อใช้ในการคาดการณ์หรือทำนายผลลัพธ์ ที่อาจเกิดขึ้นในอนาคต

1.5.4 **เทคนิคการเรียนรู้ของเครื่อง (Machine Learning Techniques)** หมายถึง กระบวนการหรืออัลกอริทึมที่ใช้ในการทำให้อุปกรณ์คอมพิวเตอร์สามารถเรียนรู้รูปแบบและความสัมพันธ์จาก ข้อมูล และนำมาปรับปรุงการทำงานหรือการวิเคราะห์ เพื่อให้ได้ผลลัพธ์ที่มีประสิทธิภาพและแม่นยำ ยิ่งขึ้น

บทที่ 2

ทฤษฎี หลักการ และงานวิจัยที่เกี่ยวข้อง

บทนี้จะกล่าวถึงทฤษฎี หลักการ และงานวิจัยที่เกี่ยวข้องกับการสร้างและประเมินแบบจำลอง การทำนายการมีส่วนร่วมบนแพลตฟอร์ม TikTok โดยเน้นไปที่คุณลักษณะวิดีโอ โดยเนื้อหาในบทนี้ จะแบ่งออกเป็นสาม หมวดหมู่ได้แก่ องค์ความรู้และทฤษฎีพื้นฐาน วิธีการและเทคนิคที่ใช้ และงานวิจัยที่เกี่ยวข้อง ซึ่งในแต่ละหมวดหมู่จะมีการเชื่อมโยงแนวคิด ความรู้ ทฤษฎีบทที่เกี่ยวข้อง และอ้างอิง งานวิจัยที่มีความใกล้เคียงกัน เพื่อนำมาประยุกต์ใช้กับการงานวิจัย

2.1 องค์ความรู้และทฤษฎีพื้นฐานที่เกี่ยวข้อง

ในหมวดนี้จะครอบคลุมทฤษฎีที่เกี่ยวข้องกับคุณลักษณะของแพลตฟอร์ม TikTok และคุณลักษณะของวิดีโอและปัจจัยต่างๆ ที่มีอิทธิพลต่อการมีส่วนร่วม ของผู้ใช้งานแพลตฟอร์มสื่อสังคมออนไลน์ โดยเน้นที่การสื่อสารผ่านองค์ประกอบทางภาพ

2.1.1 ทฤษฎีเกี่ยวกับคุณลักษณะของ TikTok

ทฤษฎีนี้มุ่งเน้นที่การศึกษาและทำความเข้าใจคุณลักษณะเฉพาะของแพลตฟอร์ม TikTok

ความยาวของวิดีโอ : วิดีโอบนแพลตฟอร์ม TikTok สามารถมีความยาวได้สูงสุดถึง 10 นาที

ฟิลเตอร์และเอฟเฟกต์ : ผู้ใช้สามารถเลือกใช้ฟิลเตอร์และเอฟเฟกต์ที่หลากหลายในการปรับแต่งรูปภาพและวิดีโอ ตั้งแต่แบบพื้นฐานไปจนถึงเอฟเฟกต์ฉากเขียว

คลังเพลง : มีเพลงให้เลือกใช้มากมายที่ไม่ติดลิขสิทธิ์ ทำให้ TikTok กลายเป็นช่องทางสำคัญ สำหรับการทำการตลาดอุตสาหกรรมเพลงในปัจจุบัน

การติดต่อ : ผู้ใช้สามารถบันทึกและแก้ไขวิดีโอได้ง่ายๆ ผ่านแอปพลิเคชันโดยตรง
การแสดงความคิดเห็นและการตอบกลับ : สามารถตอบกลับ และแลกเปลี่ยนความคิดเห็นระหว่างผู้สร้างวิดีโอและผู้ชม รวมถึงมี #Hashtag Challenges ที่เชิญชวนให้ผู้ใช้เข้าร่วมสนุก

ฟีเจอร์ E-commerce : TikTok มีฟีเจอร์เพื่อเป็นช่องในการซื้อขายออนไลน์ชื่อ TikTok Shopping เพื่อให้ผู้ใช้สามารถดูและสั่งซื้อสินค้าผ่านแอปได้โดยตรง ทั้งยังสามารถเชื่อม ต่อไปยังร้านค้าผ่านลิงก์ในโปรไฟล์ได้


การเพิ่มการมีส่วนร่วม : ผู้ใช้สามารถสร้างเนื้อหา และแบ่งปันได้อย่างสะดวก ทั้งผ่านการ ส่งข้อความโดยตรงและแพลตฟอร์มอื่นๆ

จุดเด่น : TikTok เป็นแพลตฟอร์มที่โดดเด่นในการเผยแพร่วิดีโอสั้น ซึ่งได้รับความนิยมอย่างสูง เป็นแหล่งรวมของ ครีเอเตอร์และอินฟลูเอนเซอร์รุ่นใหม่ เหมาะสมสำหรับครีเอเตอร์ที่ต้องการ สร้างตัวตนในแพลตฟอร์ม และเป็นช่องทางที่มีศักยภาพสูงในการสร้างการรับรู้ให้กับแบรนด์ เนื่องจากมีผู้ใช้จำนวนมากและสามารถเข้าถึงกลุ่มเป้าหมายได้อย่างกว้างขวาง [9]

ประเภทการมีส่วนร่วมใน TikTok :

1. จำนวนการกดถูกใจ : สะท้อนถึงความชอบของผู้ชมต่อวิดีโอ
2. จำนวนความคิดเห็น : แสดงการมีส่วนร่วมเชิงลึก
3. จำนวนการแชร์ รีโพสต์ : สะท้อนว่าผู้ชมเห็นว่าคลิปมีคุณค่าเพียงพอที่จะแบ่งปันต่อ
4. จำนวนการดูวิดีโอ : จำนวนครั้งที่โพสต์ถูกเปิดดู [4]


2.1.2 สหสัมพันธ์ระหว่าง จำนวนผู้ติดตามและการมีส่วนร่วมใน TikTok



รูปที่ 2.1 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตามและการมีส่วนร่วม [4]

ทางแหล่งข้อมูล [4] ได้ทำการวิเคราะห์ชุดข้อมูลที่ใช้ในการวิเคราะห์วิดีโอจำนวน 808,128 วิดีโอ มาจาก 3,127 โปรไฟล์ TikTok ที่มีการใช้งานอย่างต่อเนื่องบนแพลตฟอร์ม ระหว่างเดือน มกราคม 2023-สิงหาคม 2024 จากรูปที่ 2.1 แสดงให้เห็นว่า จำนวนผู้ติดตาม มีอิทธิพลต่ออัตราการมีส่วนร่วมบน TikTok กล่าวคือ บัญชีที่มีผู้ติดตามจำนวนมากมักจะมีอัตราการมีส่วนร่วมสูงขึ้นตามไปด้วย สำหรับบัญชีขนาดเล็ก ที่มีจำนวนผู้ติดตามต่ำกว่า 5,000 คน มีอัตราการมีส่วนร่วมเฉลี่ยอยู่ที่ประมาณ 3.95% ในขณะที่บัญชีขนาดใหญ่ ที่มีผู้ติดตามมากกว่า 100,000 คน มีอัตราการมีส่วนร่วมเฉลี่ยสูงกว่า อยู่ที่ประมาณ 5.35% แม้ว่าความแตกต่างในเปอร์เซ็นต์ดังกล่าวอาจดูไม่มากนัก (ประมาณ 1.2%) แต่ก็สะท้อนให้เห็นถึงแนวโน้มชัดเจนว่า เมื่อครีเอเตอร์หรือแบรนด์สร้างฐานผู้ติดตามที่กว้างขึ้น ความไว้วางใจและความคุ้นเคยที่ผู้ติดตามมีต่อนี้อาจเพิ่มขึ้น ส่งผลให้พวกเขามีแนวโน้มจะมีส่วนร่วมกับเนื้อหา นั้นมากขึ้นตามไปด้วย ในทางกลับกัน บัญชีขนาดเล็กที่ยังมีผู้ติดตามไม่มากกำลังอยู่ในช่วงเริ่มสร้างตัวตนและค้นหากลุ่มผู้ชมของตนเอง ทำให้อัตราการมีส่วนร่วมอาจยังไม่สูงเท่าบัญชีใหญ่ที่มีฐานแฟนคลับเหนียวแน่นกว่า ในขณะที่ บัญชี TikTok ที่มีจำนวนผู้ติดตามระหว่าง 10,000-50,000 คนก็ถูกจัดอยู่ในกลุ่มบัญชีที่มีอัตราการมีส่วนร่วมสูงที่สุด [4]


2.1.3 สหสัมพันธ์ระหว่าง จำนวนผู้ติดตาม Follower และการกดถูกใจ



รูปที่ 2.2 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตาม และการกดถูกใจ [4]

การกดไลก์มักถูกมองว่า เป็นรูปแบบการมีส่วนร่วมขั้นพื้นฐานและถูกพบมากที่สุด แต่สามารถสะท้อนความน่าสนใจของเนื้อหาได้เช่นกัน บัญชีขนาดเล็กที่มีผู้ติดตามน้อยกว่า 5,000 คน มีอัตราการกดไลก์ประมาณ 4.15% ในขณะที่บัญชีที่มีผู้ติดตามระหว่าง 10,000-50,000 คน มีอัตราการกดไลก์สูงสุดอยู่ที่ 5.25% ซึ่งอาจสามารถตีความได้ว่า บัญชีระดับนี้สามารถหาจุดสมดุลที่ดีระหว่างการเข้าถึงผู้ชมกว้าง และยังคงรักษาความใกล้ชิดกับผู้ชมได้อยู่ เพราะบัญชีที่มีขนาดผู้ติดตามมากกว่า 50,000 คน สัดส่วนการกดไลก์ต่อจำนวนผู้ชมจะลดลงเล็กน้อยมาอยู่ที่ประมาณ 4.9% สาเหตุหนึ่งอาจเป็นเพราะเมื่อฐานผู้ติดตามมีความหลากหลายมากขึ้น ความชื่นชอบในเนื้อหาอาจกระจายตัวออกไป ทำให้คอนเทนต์จากเพจเหล่านี้ไม่สามารถโฟกัสกับผู้ใช้งานได้เท่ากับบัญชีขนาดกลาง [4]


2.1.4 สหสัมพันธ์ระหว่าง จำนวนผู้ติดตามและจำนวนความคิดเห็น



รูปที่ 2.3 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตาม Follower และจำนวนความคิดเห็น [4]

การแสดงความคิดเห็น เป็นการแสดงการมีส่วนร่วมที่ลึกซึ้งมากกว่าการกดไลก์ เป็นการเกิดบทสนทนา ขึ้นที่แท้จริงระหว่างผู้สร้างคอนเทนต์และผู้ชม จากรูปที่ 2.3 สำหรับบัญชีเล็กที่คนติดตามน้อยกว่า 5,000 คนและบัญชีที่มีผู้ติดตามระหว่าง 10,000-50,000 คน มีอัตราการแสดงความคิดเห็นสูงที่สุดเมื่อเทียบกับกลุ่มอื่น อยู่ที่ 0.7% ของจำนวนผู้ชมทั้งหมด สำหรับแนวโน้มโดยรวมอัตราการคอมเมนต์ จะค่อยๆ ลดลง เมื่อจำนวนผู้ติดตามเพิ่มขึ้น และจะต่ำที่สุดเมื่อบัญชีมีผู้ติดตามเกิน 100,000 คน โดยเฉลี่ยอยู่ที่เพียง 0.3%

2.1.5 สถิติความสัมพันธ์ระหว่าง จำนวนผู้ติดตามและจำนวนการรีโพสต์



รูปที่ 2.4 ความสัมพันธ์ระหว่าง จำนวนผู้ติดตาม Follower และจำนวนการรีโพสต์ [4]

การแชร์นั้นอาจถือเป็นรูปแบบการมีส่วนร่วมที่ทรงพลังที่สุดรูปแบบหนึ่ง เพราะคอนเทนต์ของคุณไม่เพียงแต่ถูกชื่นชอบ แต่ยังมีคุณค่ามากเพียงพอที่จะถูกส่งต่อให้ผู้อื่น เมื่อจำนวนผู้ติดตามเพิ่มขึ้น อัตราการแชร์นั้นกลับจะค่อยๆ ลดลง อาจเป็นเพราะบัญชีใหญ่ มักเข้าถึงผู้ชมหลากหลายกลุ่มกว่า เนื้อหาที่ผลิตออกมาจึงอาจไม่ได้โดนใจผู้ชมทุกคนจนอยากแชร์ ยิ่งไปกว่านั้น เมื่อบัญชีใหญ่โพสต์เนื้อหาบ่อยครั้งขึ้น ความโดดเด่นของแต่ละโพสต์ก็อาจลดลง [4]

2.1.6 ความสัมพันธ์ระหว่าง การแสดงผลของ TikTok กับเวลา

บริษัท Trendpop เป็นบริษัทที่มีแพลตฟอร์มวิเคราะห์และให้ข้อมูลเชิงลึก (analytics & insights) โฟกัสไปที่ วิดีโอสั้นบนโซเชียลมีเดีย โดยเฉพาะ TikTok เป็นหลัก ซึ่งปัจจุบัน Trendpop ถูกควมรวมโดย Collab บริษัทด้านเทคโนโลยีสำหรับครีเอเตอร์ ซึ่งเป็น พาร์ทเนอร์อย่างเป็นทางการของ TikTok ในด้านงานสร้างสรรค์และการตลาด

Trendpop ได้ทำการวิจัยวิดีโอบางส่วนจากฐานข้อมูลกว่า 2 พันล้านวิดีโอ และติดตามผลลัพธ์การเติบโตของวิดีโอในช่วง 24 ชั่วโมงแรก, 48 ชั่วโมง, 7 วัน และยาวไปถึง 90 วัน หลังจากโพสต์ ซึ่งจากผลการศึกษาดังนี้

จำนวนยอดเปอร์เซ็นต์เฉลี่ยของคนดูเทียบกับความสัมพันธ์ทางเวลา :

- 32% ของยอดดูทั้งหมดภายใน 24 ชั่วโมงแรก
- 38% ของยอดดูทั้งหมดภายใน 48 ชั่วโมงแรก
- 55% ของยอดดูทั้งหมดภายใน 7 วัน
- 80% ของยอดดูทั้งหมดภายใน 30 วัน
- เกือบ 100% ของยอดดูทั้งหมดภายใน 90 วัน

จำนวนยอดเปอร์เซ็นต์เฉลี่ยของการมีส่วนร่วมของคนดูกับความสัมพันธ์ทางเวลา :

- 53% ของยอดไลค์ทั้งหมดจะเกิดขึ้นใน 24 ชั่วโมงแรก
- 81% ของยอดไลค์ทั้งหมดจะเกิดขึ้นใน 7 วัน
- 64% ของคอมเมนต์ทั้งหมดจะเกิดขึ้นใน 24 ชั่วโมงแรก
- 81% ของการแชร์ทั้งหมดจะเกิดขึ้นใน 24 ชั่วโมงแรก

ซึ่งได้ตั้งข้อสันนิษฐานว่า สาเหตุที่วิดีโอได้รับการมีส่วนร่วมในระดับสูงในช่วงแรกนั้น เป็นผลมาจากกลไกของอัลกอริทึม TikTok ซึ่งมีแนวโน้มที่จะแสดงวิดีโอให้กับผู้ติดตามของครีเอเตอร์ก่อน โดยกลุ่มนี้มีแนวโน้มในการมีส่วนร่วมสูงกว่าเมื่อเปรียบเทียบกับผู้ชมทั่วไป นอกจากนี้ ผู้ติดตามมีแนวโน้มที่จะแสดงความคิดเห็นในช่วงต้นของการเผยแพร่ เนื่องจากเป็นเวลาที่ครีเอเตอร์มีโอกาสตอบกลับความคิดเห็นมากที่สุด [8]

2.1.7 ทฤษฎีการสื่อสารทางภาพ

ทฤษฎีนี้เน้นถึงวิธีที่ผู้ใช้รับรู้และตอบสนองต่อเนื้อหาภาพและวิดีโอ ซึ่งจากการศึกษาพบว่า องค์ประกอบความสวยงามของภาพ หรือคุณภาพของสีในภาพ สามารถดึงดูดความสนใจ และกระตุ้นความสนใจของผู้บริโภค ในแพลตฟอร์ม TikTok ที่คอนเทนต์เกี่ยวกับอาหาร [10] โดยทั่วไปแล้ว เนื้อหาทางภาพมักดึงดูดความสนใจได้อย่างรวดเร็ว และสามารถสร้างการมีส่วนร่วม (Engagement) ได้มาก ทั้งในรูปของ “การกดถูกใจ การแชร์ และจำนวนการรับชม” [6]

ในทางกลับกัน เนื้อหาที่เป็นข้อความ (Textual Content) มักต้องใช้เวลาและความสนใจมากกว่าในการอ่าน แต่สามารถให้ข้อมูลเชิงลึกและสร้างการมีส่วนร่วมกับผู้ใช้ที่ต้องการรายละเอียดหรือการสนทนาเชิงลึก นอกจากนี้ ตามทฤษฎี Dual Coding Theory ได้ระบุว่า สิ่งเร้าทางภาพ (Visual Cues) มีอิทธิพลเหนือกว่าสิ่งเร้าทางคำพูด (Verbal Cues) [6]

ในขณะที่การใช้คุณลักษณะด้านเสียงและวิดีโอในคอนเทนต์อาหาร เป็นวิธีที่มีประสิทธิภาพในการ โน้มน้าวใจผู้ชม และ ดึงดูดให้พวกเขาดูวิดีโอจนจบ [10]

แม้ว่าทุกปัจจัยมีผลต่อการมีส่วนร่วมของแพลตฟอร์ม TikTok ทั้งหมด แต่เนื่องด้วยการที่เราโฟกัสไปที่วิดีโอคอนเทนต์เกี่ยวกับอาหาร เราจึงเลือกทำนายจากองค์ประกอบของภาพ เพราะเนื้อหาภาพนั้นสามารถทำให้เกิดกระตุ้นความอยากอาหารได้ดี

งานวิจัยกล่าวว่าผู้คนมัก ใช้สัญญาณทางภาพ เช่น สี รูปร่าง การจัดวาง หรือพื้นผิวของอาหาร เพื่อประเมินรสชาติ ความสดใหม่ และคุณภาพของอาหาร แม้ยังไม่ได้บริโภคจริง ถึงกับมีการกล่าวว่า “รสชาติอาหารแรกเกิดขึ้นผ่านสายตา” หมายความว่า การมองเห็นอาหารเพียงอย่างเดียวก็สามารถกระตุ้นให้เกิดความอยากกินได้ [11]

2.1.7.1 สี

สีนั้นถูกนำมาใช้เป็นตัวกลางในการถ่ายทอดสื่อสารกับผู้ใช้งาน ทั้งในการสื่อสารข้อมูล กระตุ้นอารมณ์ และความทรงจำ ผ่านกลไกทางประสาทสัมผัสและการรับรู้ทางปัญญากลไกทางประสาทสัมผัสช่วยแยกแยะวัตถุออกจากพื้นหลัง หรือวัตถุอย่างอื่น ในขณะที่กลไกทางปัญญาช่วยให้เชื่อมโยงภาพที่เห็นกับข้อความหรือสารสำคัญที่มุ่งหมายจะสื่อ

สีนั้นมีความเชื่อมโยงทางด้านจิตวิทยา สีแต่ละสีมีปฏิกิริยา ทางจิตวิทยา ที่แตกต่างกัน เช่น สีส้ม บ่งบอกถึง ความเป็นมิตร สีเทา สะท้อนถึง ความเป็นมืออาชีพ การเลือกสีที่เหมาะสมนั้นสามารถกำหนดทัศนคติ อารมณ์ ปฏิกริยาและความตั้งใจของผู้บริโภค ทำให้สินค้าแตกต่างกันได้ และความประทับใจ แรกของผู้บริโภคต่อผลิตภัณฑ์จะถูกสร้างขึ้นในช่วง 50 ส่วนในสิบของวินาทีแรก (ประมาณ 0.5 วินาที) และการประเมินนั้นขึ้นอยู่กับ สีประมาณ 62-90%

ในด้านการใช้สีบนเพจองค์กรในสื่อสังคม พบว่า สีที่สดใส มีประสิทธิภาพมากกว่าในการปรับปรุงทัศนคติของผู้บริโภคที่มีต่อแบรนด์ และในการเพิ่มความนิยมของโพสต์บนเพจ และสามารถดึงดูดความสนใจทางสายตาได้มากกว่า [6]

2.1.7.2 สมมาตรกับความคอนทราสต์

ในบริบทของโซเชียลมีเดีย ความสมมาตร หมายถึง ความคล้ายคลึงกันภายในภาพเดียวกัน ผู้ชมชอบวัตถุที่มีสมมาตรมากกว่าวัตถุที่ไม่มีสมมาตร ซึ่งส่งผลเชิงบวกต่อ ความพึงพอใจ

ความสนใจ หรือ ความชื่นชอบ ของผู้ใช้ความคอนทราสต์ทางสายตา หมายถึง ระดับความแตกต่างของความสว่าง ระหว่างส่วนที่สว่างและส่วนที่มีมืดในภาพ แต่ความคอนทราสต์สามารถนำไปประยุกต์ใช้กับหลาย องค์ประกอบในภาพ โดยทั่วไป ความคอนทราสต์ ช่วยให้สามารถแยกแยะวัตถุในเบื้องต้น ออกจากพื้นหลังได้ ความสามารถในการแยกแยะวัตถุจากพื้นหลังนี้ช่วย ลดความสับสนทางสายตา และทำให้ภาพมีความชัดเจนมากขึ้น นอกจากนี้ความคอนทราสต์สามารถเพิ่มขึ้นได้โดยการ ปรับความแตกต่างของสีหรือความสว่าง ระหว่างองค์ประกอบต่างๆ ในรูป [6]

2.1.7.3 ใบหน้า

ใบหน้าที่ของคน เป็นหนึ่งในเนื้อหาภาพที่พบมากที่สุดในการโพสต์ ใบหน้าคนถือ เป็นช่องทาง สำคัญของการสื่อสารแบบไม่ใช้คำพูด สมอของมนุษย์ สามารถจดจำใบหน้าที่ได้ ภายในไม่กี่ชั่วโมง หลังคลอด และเมื่ออายุได้ สองเดือน เด็กจะเริ่มแยกแยะลักษณะเฉพาะบนใบหน้า และสามารถ ประมวลผลอารมณ์จากสีหน้าได้ สมอส่วนขาของมนุษย์มีส่วนหนึ่งที่ มีหน้าที่เฉพาะ ในการจดจำ ใบหน้า ไม่เพียงช่วยแยกแยะความแตกต่างของ ใบหน้าแต่ละคน แต่ยังช่วยให้เรารับรู้ อารมณ์และการแสดงออกทางสีหน้าได้

งานวิจัยพบว่าใบหน้าที่มีเสน่ห์ดึงดูด มีประสิทธิภาพในการดึงดูดความสนใจจากผู้บริโภค และโพสต์ ที่มีใบหน้าที่คนมีแนวโน้มที่จะได้รับ การกดไลค์มากขึ้น 38% และการแสดงความคิดเห็นมากขึ้น 32% จำนวนใบหน้าที่ เพศ และอายุ ของคนในภาพ ไม่ส่งผลกระทบต่อความนิยมของโพสต์ ใบหน้าที่มีเสน่ห์ เด็กที่น่ารัก และสัตว์เลี้ยงน่ารัก มักนำไปสู่การคาดการณ์ ความนิยมสูง ในทางตรงกันข้ามภาพที่มี คุณภาพต่ำ พื้นหลังที่วุ่นวายเกินไป หรือ วัตถุที่ไม่ชัดเจน มักนำไปสู่การคาดการณ์ความนิยมต่ำ

ภาพในระยะหรือระดับที่ต่างกันนั้นจะทำให้เกิดความรู้สึกที่ต่างกัน ภาพถ่ายระยะใกล้ ช่วยลดระยะ ห่างทางอารมณ์และสร้าง ความรู้สึกใกล้ชิด ระหว่างผู้ชมและบุคคลในภาพ มุมกล้องระดับสายตา ช่วยให้เกิด ความสัมพันธ์แบบเสมอภาค ระหว่างผู้ชมและบุคคลในภาพ การสบตาโดยตรง กระตุ้นให้เกิด การมีส่วนร่วมทางอารมณ์ กับผู้ชม [6]

2.1.7.4 บุคคลมีชื่อเสียง

การใช้คนดังมักถูกนำมาใช้เพื่อมีอิทธิพลต่อความคิดเห็นของสาธารณชน การรับรองโดยคนดังมีความสำคัญจริง โพลที่ผู้ใช้รู้ว่ามาจากคนดังโดยตรงมีแนวโน้มที่จะได้รับการมีส่วนร่วมมากกว่าโพลที่มีเนื้อหาเหมือนกัน แต่ไม่ได้มาจากบัญชีของคนดัง เพราะตัวตนของคนดังนั้นช่วยสร้างความน่าเชื่อถือและเพิ่มการมีส่วนร่วมของผู้คนได้อย่างมีนัยสำคัญ [12]

2.1.7.5 อัตลักษณ์ของแบรนด์ในภาพ

โพสต์ที่มีองค์ประกอบของแบรนด์อาจมีความนิยมมากกว่า เนื่องจากโพสต์เหล่านี้มักจะเชื่อมโยงกับ อารมณ์ของผู้ใช้และความภักดีต่อแบรนด์ บางเพจบน โซเชียลมีเดีย มุ่งเน้นดึงดูดความสนใจ ของผู้ใช้ด้วยการแสดงอัตลักษณ์ของแบรนด์ผ่านโพสต์ โดยการเพิ่มองค์ประกอบที่สื่อถึงแบรนด์ ได้แก่ โลโก้ คำขวัญ หรือลักษณะเฉพาะตัวของแบรนด์ เป็นต้น [6]

2.1.7.6 ข้อความในภาพหรือวิดีโอ

ข้อความที่ใช้ในวิดีโอยังมีบทบาทสำคัญในการถ่ายทอดข้อมูลเกี่ยวกับผลิตภัณฑ์ เช่น ราคา คะแนนรีวิว ส่วนประกอบของอาหาร คุณภาพ หรือจุดเด่นต่างๆ ทำให้น่าเชื่อถือและเพิ่มความเข้าใจต่อผู้บริโภคสินค้าได้ดียิ่งขึ้น ผู้บริโภคจำนวนมากให้ความสำคัญกับความคมชัดและความสวยงามของภาพ รวมถึงการจัดวางข้อความให้อ่านง่ายและน่าสนใจ การใช้ข้อความกระตุ้นอารมณ์ เช่น คำพูดเชิญชวน “อร่อยจนต้องลอง” หรือ “ร้านลับที่ไม่ควรพลาด” นั้นมีผลในการกระตุ้นความรู้สึก ทำให้เกิดความสนใจและความตั้งใจซื้อสูงขึ้น ในช่องทาง TikTok เป็นแพลตฟอร์มที่เน้นวิดีโอสั้นและดึงดูดความสนใจภายในเวลาไม่กี่วินาที การใช้ข้อความและคำบรรยายอย่างมีประสิทธิภาพจึงช่วยให้เนื้อหาดึงดูดความสนใจผู้ชมตั้งแต่ช่วงต้น ลดอัตราการเลื่อนผ่าน และเพิ่มโอกาสในการดูวิดีโอจนจบ [10]

2.1.8 ทฤษฎีลักษณะบัญชีโซเชียลมีเดียเกี่ยวกับอาหาร

TikTok จึงเป็นแพลตฟอร์มที่มีความเหมาะสมสำหรับธุรกิจอาหาร เนื่องจากมีรูปแบบวิดีโอสั้นที่สามารถถ่ายทอดความน่าสนใจของอาหารได้อย่างรวดเร็วและเข้าถึงกลุ่มเป้าหมายจำนวนมากในเวลาอันสั้น อีกทั้งยังส่งเสริมให้เกิดความรู้สึกลอยล่อง และเพิ่มโอกาสในการเข้าชมร้านอาหาร [10] ภาพที่มีความคุ้นเคย โพสต์ที่มีภาพอาหารลักษณะทั่วไป หรือที่ผู้คนคุ้นเคย ส่งผลต่อการมีส่วนร่วมสูงกว่าภาพอาหารที่แปลกใหม่ เพราะเราสามารถประมวลผลผ่านทางด้านจิตใจได้มากกว่า และทำให้เกิดอารมณ์เชิงบวกได้ง่ายกว่า [13]


ประเภทของเนื้อหา คอนเทนต์อาหารบน TikTok เกี่ยวกับอาหารนั้นมีหลากหลาย ความอยากอาหาร เป็นอีกหนึ่งกระบวนการทางร่างกายที่เกิดขึ้น เมื่อถูกสิ่งกระตุ้นจากคอนเทนต์เกี่ยวข้องกับอาหาร อันได้แก่ การรีวิวอาหาร Mukbang หรือ ASMR ทำให้ผู้ผลิตคอนเทนต์ให้ความสำคัญกับการพัฒนาคุณภาพของภาพ เสียง และการไลฟ์สดริมเพราะ ช่วยเพิ่มความสนใจในสินค้าอาหารได้อย่างมีนัยสำคัญ นอกจากนี้การประเมินคุณค่าของอาหารหรือสินค้า จะได้รับอิทธิพลจากคำแนะนำจากอินฟลูเอนเซอร์ รีวิวจากเพื่อนผู้ใช้ และสิทธิประโยชน์ (เช่น ส่วนลด ราคา ความสะดวกสบาย) นักการตลาดควรให้ความสำคัญกับการจัดทำบรรจุภัณฑ์ที่ปลอดภัย และมีคำแนะนำการเก็บรักษาที่ชัดเจน เพื่อเสริมสร้าง

ความเชื่อมั่นของผู้บริโภค บรรจุภัณฑ์สามารถส่งผลโดยตรงต่อ การรับรู้คุณภาพของสินค้า การแสดง กระบวนการทำอาหาร และการแสดงส่วนผสมยังเป็นสิ่งที่กระตุ้นอารมณ์ ผู้ใช้ได้ดีด้วยเช่นกัน [14]

2.1.9 แนวคิดการเดินทางของผู้บริโภคในยุคดิจิทัล

แนวคิด Consumer Decision Journey (CDJ) ถูกนำเสนอขึ้นเพื่ออธิบายพฤติกรรมผู้บริโภคในยุคดิจิทัล ซึ่งแตกต่างจาก Marketing Funnel แบบดั้งเดิมที่มองกระบวนการตัดสินใจเป็นลำดับขั้นแบบเส้นตรง จากการรับรู้ไปสู่การซื้อเป็นกระบวนการแบบวนซ้ำ (Loop) ที่ผู้บริโภคสามารถกลับไปพิจารณาทางเลือกใหม่ ค้นหาข้อมูลเพิ่มเติม และได้รับอิทธิพลจากปฏิสัมพันธ์ออนไลน์หลายครั้ง ก่อนตัดสินใจซื้อ โมเดล CDJ แบ่งออกเป็น 5 ขั้นตอน ได้แก่

- ขั้นการรับรู้ (Awareness)
- ขั้นการพิจารณา (Consideration)
- ขั้นการตัดสินใจ (Decision)
- ขั้นหลังการซื้อ (Post-purchase)
- ขั้นความภักดีต่อแบรนด์ (Loyalty)



รูปที่ 2.5 แนวคิดการเดินทางของผู้บริโภคของ McKinsey [15]

Social media มีบทบาทสำคัญอย่างยิ่งในการสร้างการรับรู้แบรนด์ (Awareness) ในยุคดิจิทัล กรณีศึกษา Nike “You Can’t Stop Us” แสดงให้เห็นว่า วิดีโอเชิงอารมณ์ที่สื่อสารคุณค่าทางสังคม เช่น ความหลากหลาย ความอดทน และความเป็นหนึ่งเดียว สามารถสร้างการรับรู้ในวงกว้างผ่านแพลตฟอร์มออนไลน์ เช่น YouTube, Instagram และ Facebook ได้อย่างรวดเร็ว สำคัญคือ Awareness ในยุคดิจิทัลไม่ได้เกิดจากโฆษณาเชิงข้อมูลเพียงอย่างเดียว แต่เกิดจาก “คอนเทนต์ที่กระตุ้นอารมณ์และสอดคล้องกับบริบทสังคม”

ขั้น Consideration เป็นช่วงที่ผู้บริโภคเริ่มประเมินทางเลือก โดยได้รับอิทธิพลจากข้อมูลออนไลน์อย่างต่อเนื่อง ปัจจัยสำคัญในขั้นนี้ ได้แก่:

- User-Generated Content เช่น รีวิว รูปภาพ และวิดีโอจากผู้ใช้งานจริง ซึ่งสร้างความน่าเชื่อถือมากกว่าการโฆษณาโดยตรง
- ผู้บริโภคมีแนวโน้มเชื่อคำแนะนำจากผู้ใช้อื่น และใช้ข้อมูลดังกล่าวในการประเมินคุณค่าของสินค้า
- บุคคลที่มีผู้ติดตามจำนวนมากสามารถมีอิทธิพลต่อการพิจารณาของผู้บริโภค เนื่องจากเกิดความไว้วางใจและความสัมพันธ์เชิงสังคม
- Personalization การแสดงเนื้อหาหรือโฆษณาที่สอดคล้องกับพฤติกรรมการค้นหา ความสนใจ หรือประวัติการใช้งานของผู้ใช้ ทำให้การตัดสินใจเกิดขึ้นได้รวดเร็วขึ้น

การเดินทางของผู้บริโภค ไม่สิ้นสุดที่การซื้อ แต่ต่อเนื่องไปสู่ Post-Purchase และ Loyalty ในกรณีศึกษา Nike หลังจากผู้บริโภคซื้อสินค้าแล้ว การมีส่วนร่วมยังดำเนินต่อผ่านแอปพลิเคชัน เช่น การติดตามผลการออกกำลังกาย การรับคำแนะนำเฉพาะบุคคล และการสื่อสารต่อเนื่องกับแบรนด์ กลไกดังกล่าวช่วยสร้าง ความผูกพันระยะยาว ความไว้วางใจในแบรนด์ และความภักดี [15]

แอปพลิเคชัน TikTok สามารถตอบโจทย์แนวคิดการเดินทางของผู้บริโภคในยุคดิจิทัลได้อย่างชัดเจน เนื่องจากลักษณะของแพลตฟอร์มที่เน้นการเผยแพร่เนื้อหาในรูปแบบวิดีโอสั้นซึ่งมีศักยภาพในการกลายเป็นกระแส (Viral Video) และเข้าถึงผู้ใช้จำนวนมากในระยะเวลาอันรวดเร็ว ส่งผลต่อการสร้างการรับรู้ (Awareness) ต่อแบรนด์หรือผลิตภัณฑ์ โดยระดับการมีส่วนร่วมของผู้ชม เช่น การกดไลก์ การแสดงความคิดเห็น และการแชร์ สามารถใช้เป็นตัวสะท้อนความสนใจในขั้นดังกล่าวได้ นอกจากนี้ TikTok ยังเปิดโอกาสให้ผู้ผลิตเนื้อหา (Creator) หรือบุคคลทั่วไปสามารถสร้างเนื้อหาในลักษณะ User-Generated Content (UGC) ซึ่งมีบทบาทสำคัญต่อขั้นการพิจารณา (Consideration) เนื่องจากผู้บริโภคมีแนวโน้มให้ความเชื่อถือข้อมูลจากผู้ใช้งานจริงมากกว่าการสื่อสารเชิงโฆษณาโดยตรง อีกทั้งแพลตฟอร์มยังมีฟังก์ชันสนับสนุนการซื้อขายสินค้า รวมถึงเป็นช่องทางในการสื่อสารระหว่างผู้ขายและผู้บริโภค ซึ่งเอื้อต่อขั้นการตัดสินใจ (Decision) และการมีปฏิสัมพันธ์ต่อเนื่องหลังการซื้อ (Post-purchase) ดังนั้น โครงสร้างของ TikTok จึงสอดคล้องกับกระบวนการ Consumer Decision Journey ในยุคดิจิทัลอย่างเป็นระบบ

2.2 วิธีการและเทคนิคที่ใช้การเรียนรู้ของเครื่อง

2.2.1 การแบ่งประเภทการเรียนรู้ของเครื่องคอมพิวเตอร์

การเรียนรู้ของเครื่องแบ่งออกเป็น 3 ประเภทหลัก ตามลักษณะของข้อมูลที่ถูกใส่เข้ามาหรือข้อมูลสำหรับการฝึกดังนี้

การเรียนรู้แบบมีผู้สอน Supervised Learning เป็นการเรียนรู้จากข้อมูลที่มีป้ายกำกับหรือมีคำตอบที่ชัดเจน เพื่อใช้เป็นตัวอย่างให้ระบบได้เรียนรู้จากอดีต อัลกอริทึมจะใช้ข้อมูลที่มีผลลัพธ์ เฉลยเพื่อเปรียบเทียบกับข้อมูลใหม่ที่ป้อนเข้ามา และทำการทำนาย หรือจัดหมวดหมู่ข้อมูล ให้สอดคล้องกับลักษณะที่เรียนรู้มา

การเรียนรู้แบบไม่มีผู้สอน Unsupervised Learning เป็นการเรียนรู้จากข้อมูลที่ไม่มีป้ายกำกับ หรือคำตอบเฉลย โดยคอมพิวเตอร์จะต้องค้นหาโครงสร้างหรือรูปแบบของข้อมูลด้วยตนเอง มักใช้สำหรับ การจำแนกกลุ่มจากความคล้ายคลึงกันของข้อมูล และไม่มีกำหนดผลลัพธ์ล่วงหน้า

การเรียนรู้แบบเสริมแรง Reinforcement Learning เป็นการเรียนรู้ที่คล้ายกับการเรียนรู้ ของมนุษย์ โดยเครื่องจักรจะเรียนรู้ผ่านการปฏิสัมพันธ์กับสิ่งแวดล้อมที่เปลี่ยนแปลงตลอดเวลา ระบบ จะได้รับรางวัลหรือ บทลงโทษ ตามการกระทำของมัน ซึ่งจะช่วยให้ระบบปรับตัว และเรียนรู้ ว่าควรตอบสนองอย่างไรในสถานการณ์ต่างๆ [16]

การทำนายการมีส่วนร่วมของผู้ใช้บนแพลตฟอร์ม TikTok โดยการเรียนรู้ของเครื่อง ควรเป็น การเรียนรู้แบบมีผู้สอน เนื่องจากการทำนายการมีส่วนร่วมจะอิงจากข้อมูลในอดีต เช่น จำนวนการกดถูกใจ, จำนวนความคิดเห็น, จำนวนการแชร์ รีโพส্ট หรือ จำนวนการดูวิดีโอ ซึ่งถือเป็นผลลัพธ์ ที่ชัดเจนหรือมีการใส่ป้ายกำกับ ระบบต้องใช้ข้อมูลเหล่านี้เป็นตัวอย่างในการฝึกฝนโมเดล เพื่อคาดการณ์การมีส่วนร่วมของคลิปวิดีโอสั้นใน TikTok และการเรียนรู้แบบมีผู้สอนนั้นเหมาะกับการณ์ ที่เราต้องการทำนาย ผลลัพธ์ที่เฉพาะเจาะจง เช่น จำนวนการมีส่วนร่วมของวิดีโอใหม่ที่โพส

2.2.2 ประเภทของอัลกอริทึม

2.2.2.1 Random Forest

เทคนิคการจำแนกข้อมูลแบบไม่ตัดแต่งกิ่ง (Unpruned) คือจะไม่มี การตัดบางโหนดทิ้งเพื่อป้องกันต้นไม้เรียนรู้เยอะเกินไป (Overfitting) ซึ่งจะทำให้ต้นไม้ที่สร้างขึ้นมาจะโตเต็มที่ไปเรื่อยๆ จนแยกข้อมูลละเอียดที่สุดตามเกณฑ์ที่ตั้งไว้ และต้นไม้ถดถอย (Regression Trees) เพื่อทำนายค่าตัวเลข

เทคนิค Random Forest จะทำการจะค้นหาโหนด (Node) ที่อยู่ในกิ่งที่ดีที่สุดของต้นไม้โดยการสุ่มเลือกบางคุณลักษณะจากทุกคุณสมบัติที่มีอยู่ เพื่อสร้างโมเดลป่าหลายๆ ต้น หลังจากนั้นจึงทำการให้คะแนน (Vote) จนได้โมเดลสุดท้ายที่มีผลลัพธ์ที่ดีที่สุด โดยการใช้สูตรในการรวมกันดังนี้ [16]

$$E(x, M) = \frac{1}{S} \sum_{s=1}^S \beta_s M_s(x) \quad (2.1)$$

Random Forest จึงเป็นอัลกอริทึมที่เหมาะสมกับมีข้อมูลที่ซับซ้อนและตัวแปรหลากหลาย ในการทำนายค่าตัวเลขของการมีส่วนร่วมใน TikTok นอกจากนี้ยังสามารถจัดการกับข้อมูลที่ขาดหาย หรือข้อมูลที่มีความไม่สมดุลได้ดี

2.2.2.2 Support Vector Machines (SVM)

SVC เป็นอัลกอริทึมที่ใช้ในการจำแนกประเภทข้อมูล ซึ่งนิยามโดย Hyperplane และแบ่งข้อมูลออกจากกัน (Classification) นอกจากนี้ SVM ยังสามารถใช้สำหรับการถดถอย (Regression) โมเดลของ Support Vector ประกอบด้วย Kernel Function ซึ่งทำหน้าที่ เป็นฟังก์ชันแปลง (Translation Function) ในเมทริกซ์ ที่นำข้อมูลจาก Space เดิม (Input Space) ไปสู่ Space มิติสูง (Feature Space) มีการนิยามดังนี้:

$$K(u, v) = \phi(U) \quad (2.2)$$

ประเภทของ Kernel Function ที่ใช้บ่อย Linear Kernel, Polynomial Kernel, Radial Basis Function (RBF), Gaussian Kernel, Sigmoid Kernel แต่ในสำหรับงานวิจัยนี้ เราจะไม่เลือกพิจารณาและศึกษาทั้งหมด เพราะ ข้อมูลของงานวิจัยเรา มากกว่าสองมิติ Linear Kernel จึงไม่เหมาะสม ในขณะที่ Sigmoid Kernel และ Radial Basis Function (RBF) มีพื้นฐานจากการสร้าง Decision Boundary แบบไม่เชิงเส้น (Nonlinear) เหมือนกัน แต่ประสิทธิภาพของ RBF มากกว่า ฟังก์ชันที่เลือกศึกษาใน งานวิจัยมีดังนี้:

1. Polynomial Function

$$K(x_i, x_j) = (x_i^T + 1)^d \quad (2.3)$$

2. Radial Basis Function (RBF)

$$K(x_i, x_j) = e^{-\gamma \|x_i - x_j\|^2}, \gamma > 0 \quad (2.4)$$

3. Gaussian Function

$$K(x_i, x_j) = e^{-\frac{1}{2\sigma^2} \|x_i - x_j\|^2}, \gamma > 0 \quad (2.5)$$

พารามิเตอร์หรือตัวแปรด้านบน จะมีการปรับค่าให้เหมาะสมกับสถานการณ์ของการทำนายใน SVM สมการของโมเดลการทำนายใน SVM คือ:

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) \langle x_i, x_j \rangle + b \quad (2.6)$$

เวลาสร้างสมการทำนายของ SVM หรือ SVR (Support Vector Regression) ส่วนที่เป็น Inner Product ของข้อมูล คือ $\langle x_i, x_j \rangle$ แต่ในกรณีที่ข้อมูลซับซ้อน และไม่สามารถแยกด้วยเส้นตรง (Linear) เราจะแทนที่ Inner Product นี้ด้วย Kernel Function (Polynomial, RBF, Gaussian) [17]

$$f(x) = \sum_{i=1}^l (a_i - a_i^*) K \langle x_i, x_j \rangle + b \quad (2.7)$$

SVM เป็นอัลกอริทึมที่มีประสิทธิภาพสำหรับ การจำแนกประเภท และ การทำนายค่า โดยใช้ Kernel Function เพื่อแปลงข้อมูลเชิงซับซ้อนให้วิเคราะห์ได้ง่ายขึ้น

2.2.2.3 LightGBM

LightGBM เป็นอีกหนึ่งอัลกอริทึมในกลุ่มที่ถูกพัฒนามาจาก Gradient Boosting Decision Tree (GBDT) LightGBM นั้นเข้ามาช่วยแก้ปัญหาเกี่ยวกับการจัดการกับชุดข้อมูลที่มีมิติฟีเจอร์สูง และมีขนาดข้อมูลใหญ่ LightGBM เสนอเทคนิคใหม่ 2 แบบ ได้แก่ Gradient-based One-Side Sampling (GOSS) และ Exclusive Feature Bundling (EFB) ซึ่งช่วยลดเวลาและทรัพยากรในการฝึกโมเดลได้อย่างมาก

Gradient-based One-Side Sampling (GOSS) เป็นเทคนิควิธีการสุ่มตัวอย่างใหม่ที่มุ่งลดจำนวนข้อมูลตัวอย่าง โดยไม่กระทบต่อความแม่นยำของการประมาณค่า โดยหลักการเลือกข้อมูลตัวอย่างของ GOSS นั้น จะเลือกค่าที่มี Gradient สูงหรือมีค่าความผิดพลาดเยอะ มาฝึกฝนต่อเพราะทำให้ตัวโมเดลได้ค่าการเรียนรู้หรือ Information Gain มากขึ้น ในขณะที่ข้อมูลตัวอย่างที่มีค่า Gradient น้อยหรือการทำนายได้ดีแล้ว จะถูกละเว้นไว้ เพื่อลดจำนวนเวลาในการทำงาน ซึ่งมีสมการในการหา Variance Gain หรือ Information Gain ที่ใช้นำการตัดสินใจ Split Node เพื่อลดการทำงาน อย่างมีประสิทธิภาพดังนี้ [18]

$$-V_j = \left(\frac{(\sum_{x_i \in A_{lg}} + \frac{1-a}{b} \sum_{x_i \in B_{lg}})^2}{n_{lg}(d)} + \frac{\sum_{x_i \in A_{lg}} + \frac{1-a}{b} \sum_{x_i \in B_{lg}})^2}{n_{jr}(d)} \right) \quad (2.8)$$

ส่วน EFB เราจะรวม (Bundle) ใช้ลดจำนวนคุณลักษณะ (Features) โดยการรวมคุณลักษณะที่แทบไม่เกิดค่าพร้อมกัน (Exclusive Features) เข้าด้วยกันเป็น Feature เดียว เช่น ในกรณี One-Hot Encoding ที่มีหลายช่องแต่จะมีค่า Non-Zero แค่ช่องเดียวในแต่ละตัวอย่าง EFB จะรวมช่องเหล่านี้ไว้ใน Bundle เดียว ทำให้จำนวน Feature ที่ต้องคำนวณลดลงอย่างมาก ส่งผลให้การสร้าง Histogram เร็วขึ้น ใช้หน่วยความจำน้อยลง และยังคงความแม่นยำของโมเดลได้ใกล้เคียงเดิม [18]

แม้ว่า Light GBM จะมีประสิทธิภาพสูง แต่ก็ยังมีข้อจำกัดที่ควรพิจารณา เพราะการรวมฟีเจอร์หรือลดการเรียนรู้ในบางตัวแปร อาจทำให้โมเดลเกิด Overfitting หรือ Underfitting ได้ Light GBM เหมาะแก่การศึกษาในงานวิจัยนี้ เนื่องจาก Light GBM ช่วยลดจำนวนฟีเจอร์ให้อยู่ในระดับที่ประมวลผลได้อย่างมีประสิทธิภาพโดยไม่สูญเสียคุณภาพของข้อมูล เหมาะกับโจทย์ที่ต้องการความเร็วและแม่นยำในการทำนาย Engagement จากข้อมูลหลากหลายฟีเจอร์ของ TikTok

2.2.2.4 Catboost

Categorical Boosting เป็นหนึ่งในอัลกอริทึมของ Gradient Boosting ที่ถูกออกแบบมาเพื่อแก้ไขปัญหาสำคัญ 2 อย่างของอัลกอริทึมบูสต์แบบเดิมได้แก่

ปัญหาแรกคือ การเลื่อนค่าการทำนาย (Prediction Shift) โดยมีสาเหตุมาจากการรั่วไหลของข้อมูลเป้าหมาย (Target Leakage) กล่าวคือ โมเดลใช้ค่าผลลัพธ์จริงของตัวอย่างข้อมูลเดียวกัน ทั้งในขั้นตอนการสร้างฟีเจอร์และในการคำนวณค่าความชัน (Gradient) ส่งผลให้การแจกแจงข้อมูลที่โมเดลเรียนรู้จากชุดข้อมูลฝึกแตกต่างจากการแจกแจงข้อมูลในชุดทดสอบ ผลลัพธ์คือโมเดลมีความแม่นยำสูงในระหว่างการฝึก แต่ไม่สามารถทำงานได้อย่างมีประสิทธิภาพ เมื่อเจอข้อมูลใหม่

สูตรการเลื่อนค่าการทำนาย (Prediction Shift)

$$h^t = \operatorname{argmin}_{h \in H} \frac{1}{n} \sum_{k=1}^n (-g^t(x_k, y_k) - h(x_k))^2 \quad (2.9)$$

ซึ่งทาง CatBoost ได้เสนอแนวทางแก้ไขด้วย Ordered Boosting โดยใช้หลักการสุ่มลำดับตัวอย่าง (Permutation) และบังคับให้การคำนวณ Residual หรือ Gradient ของตัวอย่างที่อยู่ก่อนหน้าในลำดับนั้น ซึ่งต่างจากปกติที่ระบบให้เรียนรู้เลยว่า ชุดข้อมูลแบบนี้ คำตอบที่ถูกคืออะไร วิธีนี้ช่วยหลีกเลี่ยงการใช้คำตอบของตัวอย่างนั้นโดยตรง จึงสามารถลด Prediction Shift และทำให้โมเดลมีความเป็นกลางทางสถิติ (Unbiased)

ปัญหาที่สองคือ การจัดการตัวแปรเชิงหมวดหมู่ (Categorical Features) หรือ ข้อมูลที่อยู่ในรูปแบบหมวดหมู่ เช่น ประเทศ รหัสผู้ใช้ หรือประเภทสินค้า โดยปกติข้อมูลประเภทหมวดหมู่นี้ไม่สามารถนำมาเปรียบเทียบเชิงลำดับได้โดยตรง วิธีทั่วไปในการแปลงข้อมูลประเภทนี้คือการเข้ารหัสแบบวันฮอต (One-Hot Encoding) และการใช้ค่าสถิติจากผลลัพธ์ (Target Statistics) อย่างไรก็ตาม ทั้งสองวิธีมีข้อจำกัดสำคัญคือ การเข้ารหัสแบบวันฮอต (One-Hot Encoding) จะทำให้จำนวนฟีเจอร์เพิ่มขึ้นมากและต้องประมวลผลค่อนข้างเยอะ ในขณะที่การใช้ค่าสถิติจากผลลัพธ์ (Target Statistics) อาจทำให้เกิดการรั่วไหลของข้อมูลเป้าหมาย (Target Leakage) เนื่องจากโมเดลจะคำนวณผลลัพธ์จริงจากการใช้ตัวอย่างเดียวกัน [19]

CatBoost เสนอการใช้ค่าสถิติจากผลลัพธ์แบบเรียงลำดับ (Ordered Target Statistics) ซึ่งอาศัยแนวคิดการสุ่มลำดับ (Permutation) เช่นเดียวกับการบูสต์แบบเรียงลำดับ (Ordered Boosting) กล่าวคือ ค่าสถิติของแต่ละหมวดหมู่จะถูกคำนวณจากตัวอย่างข้อมูลที่ปรากฏก่อนหน้าในลำดับเท่านั้น วิธีการนี้ทำให้สามารถใช้ข้อมูลได้อย่างเต็มประสิทธิภาพ โดยไม่ละเมิดสมมติฐานทางสถิติ และช่วยลดปัญหาความคลาดเคลื่อนของเงื่อนไข (Conditional Shift) [19]

CatBoost นั้นมักถูกใช้ในงานด้านการให้คำแนะนำ (Recommendation System) และการทำนายพฤติกรรมผู้ใช้งาน เช่น การทำนายการกด (Click Prediction) ซึ่งมีความคล้ายคลึงกับงานวิจัย

2.2.3 เทคนิคการแบ่งข้อมูลในการสร้างแบบจำลองด้วยวิธีการไขว้ข้อมูล

k-Fold Cross-Validation เป็นวิธีการตรวจสอบและประเมินโมเดลที่มีการแบ่งชุดข้อมูลออกเป็น k ส่วน ซึ่งแต่ละส่วนจะไม่มีข้อมูลซ้ำกัน โดยข้อมูลที่ถูกแบ่งเป็นส่วนย่อย จะมีจำนวนข้อมูล เท่ากันในแต่ละชุดย่อย จากนั้นจะทำการ ฝึกและทดสอบโมเดลทั้งหมด k ครั้ง โดยในแต่ละรอบการทำงาน จะกำหนดให้ ชุดข้อมูลย่อยหนึ่งชุดทำหน้าที่เป็นชุดทดสอบ ส่วนชุดข้อมูลที่เหลือ จะถูกใช้เป็นชุดข้อมูลฝึก

ตัวอย่างการทำงานของ k-Fold Cross-Validation

รอบที่ 1: ใช้ D_1 เป็นชุดทดสอบ และ $D_2, \dots, D_k$ ใช้เป็นชุดฝึก

รอบที่ 2: ใช้ D_2 เป็นชุดทดสอบ และ $D_1, D_3, \dots, D_k$ ใช้เป็นชุดฝึก

ทำซ้ำในลักษณะนี้จนครบ k รอบ โดยแต่ละชุดย่อยจะทำหน้าที่เป็นชุดทดสอบเพียงครั้งเดียว การกระจายข้อมูลฝึกและทดสอบอย่างเท่าเทียมในแต่ละรอบช่วยลดความเสี่ยงที่โมเดลจะโน้มเอียง ชุดข้อมูลใดชุดหนึ่ง การทำงานในลักษณะนี้ช่วยให้มั่นใจได้ว่า ผลการประเมิน มีความเสถียรและแม่นยำ มากยิ่งขึ้น [16]

2.2.4 การประเมินประสิทธิภาพของแบบจำลอง

การประเมินประสิทธิภาพของโมเดลสามารถทำได้โดยการใช้ Confusion Matrix ซึ่งเป็นตารางสำหรับสรุปผลการทำนายของโมเดลการเรียนรู้ของเครื่อง เพื่อตรวจสอบความถูกต้อง โดยจำแนกการทำนายเป็น 4 ประเภท ดังนี้

		ค่าที่เกิดขึ้นจริง		
		Positive	Negative	
ทำการทำนาย	Positive	TP	FP	Positive
	Negative	FN	TN	Negative

คำอธิบายองค์ประกอบใน Confusion Matrix:

True : ทำนายถูกต้อง

False : ทำนายผิด

Positive : ผลลัพธ์ “ใช่”

Negative : ผลลัพธ์ “ไม่ใช่”

ผลลัพธ์จากการทำนายของโมเดล:

True Positive (TP) : ทำนายว่า “ใช่” และผลลัพธ์จริงก็เป็น “ใช่” (Hit)

True Negative (TN) : ทำนายว่า “ไม่ใช่” และผลลัพธ์จริงก็เป็น “ไม่ใช่” (Correct Rejection)

Type I Error)

False Positive (FP): ทำนายว่า “ใช่” แต่ผลลัพธ์จริงเป็น “ไม่ใช่” (False Alarm,

Error)

False Negative (FN): ทำนายว่า “ไม่ใช่” แต่ผลลัพธ์จริงเป็น “ใช่” (Miss, Type II

เงื่อนไขเพิ่มเติมที่ใช้ใน Confusion Matrix :

Condition Positive (P): จำนวนของข้อมูลจริงที่เป็น “ใช่” ทั้งหมด $P = TP + FN$

Condition Negative (N): จำนวนของข้อมูลจริงที่เป็น “ไม่ใช่” ทั้งหมด $N = FP + TN$

การประเมินโมเดลด้วยตัวชี้วัดด้านความถูกต้อง ในการประเมินโมเดล Machine Learning มักใช้ 4 ตัวชี้วัดหลักดังนี้

1. ค่าความถูกต้อง (Accuracy) หมายถึง สัดส่วนของการทำนายที่ถูกต้อง เมื่อเทียบกับจำนวนการ ทำนายทั้งหมด โดยคำนวณจากผลลัพธ์ของทุกคลาส ที่มีในโมเดลตาม สมการต่อไปนี้:

$$\text{Accuracy} = \frac{TP + TN}{TP + TN + FP + FN} \quad (2.10)$$

ค่าความถูกต้อง (Accuracy) เป็นตัวชี้วัดที่ใช้ในการตรวจสอบว่าโมเดลทำนายผลได้ตรงกับความเป็นจริงมากน้อยเพียงใด [16]

2. ค่าความแม่นยำ (Precision) หมายถึง สัดส่วนของการทำนายที่ถูกต้องเมื่อเทียบกับการทำนาย ที่ว่าเป็น “ใช่” ทั้งหมด เป็นตัวชี้วัดที่ใช้ในการประเมินความแม่นยำของการทำนายในแต่ละคลาส อย่าง แยกออกจากกัน ในสมการนี้หมายถึงคลาสการทำนายว่า “ใช่” [16]

$$\text{Precision} = \frac{TP}{TP + FP} \quad (2.11)$$

3. ค่าความระลึก (Recall) หมายถึง สัดส่วนของเหตุการณ์ที่โมเดลทำนายว่าเป็น “ใช่” เมื่อเทียบ กับจำนวนเหตุการณ์ “ใช่” ทั้งหมดที่เกิดขึ้นจริง เป็นตัวชี้วัดที่ใช้ประเมินความสามารถของโมเดลในการทำนายผลลัพธ์ “ใช่” ที่เป็นจริง ซึ่งสามารถคำนวณได้จากสมการ [16]

$$\text{Recall} = \frac{TP}{TP + FN} \quad (2.12)$$

4. ค่าความถ่วงดุล (F1 Score) หมายถึง ค่าที่ใช้วัดความสมดุลระหว่างค่าความแม่นยำ (Precision) และค่าความระลึก (Recall) โดยเป็นค่าเฉลี่ยเชิงฮาร์โมนิก (Harmonic Mean) ของทั้งสองค่า ทำให้สะท้อนประสิทธิภาพของโมเดลได้ครอบคลุมมากขึ้น โดยเฉพาะในกรณีที่ต้องการพิจารณาทั้งค่าความแม่นยำและความระลึกพร้อมกัน [16]

$$\text{F1 Score} = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}} \quad (2.13)$$

การใช้ Confusion Matrix ในการประเมินประสิทธิภาพนั้นมีข้อจำกัด เนื่องจากตัวชี้วัดเหล่านี้เป็นแบบ Threshold-Dependent ซึ่งค่าที่ได้จะขึ้นอยู่กับค่าขีดแบ่งที่กำหนดในการตัดสินใจผลลัพธ์ของแบบจำลอง ส่งผลให้การประเมินอาจเปลี่ยนแปลงได้ตามการกำหนด Threshold ที่แตกต่างกัน ดังนั้น งานวิจัยด้านการเรียนรู้ของเครื่องจึงนิยมใช้ Receiver Operating Characteristic (ROC) Curve และค่า Area Under the Curve (AUC) เป็นตัวชี้วัดเพิ่มเติม เพื่อให้สามารถประเมินประสิทธิภาพของแบบจำลองได้อย่างครอบคลุมในหลายระดับ threshold โดย ROC Curve เป็นกราฟที่แสดงความสัมพันธ์ระหว่างอัตราการตรวจจับค่าจริงและอัตราการแจ้งเตือนผิดพลาด ทำให้สามารถวิเคราะห์พฤติกรรมของแบบจำลองในภาพรวมได้ ขณะที่ค่า AUC ซึ่งเป็นพื้นที่ใต้กราฟ ROC ใช้สรุปความสามารถของแบบจำลองในการจำแนกข้อมูลให้อยู่ในรูปของค่าเดียว โดยค่าที่สูงแสดงถึงความสามารถในการแยกแยะคลาสที่ดีกว่า นอกจากนี้ ROC-AUC ยังเป็นตัวชี้วัดที่ไม่ขึ้นกับ Threshold และสามารถเปรียบเทียบประสิทธิภาพของแบบจำลองหลายรูปแบบได้อย่างมีประสิทธิภาพ อีกทั้งยังสามารถตีความได้ว่าเป็นความน่าจะเป็นที่แบบจำลองจะจัดอันดับตัวอย่างเชิงบวกสูงกว่าตัวอย่างเชิงลบ ซึ่งช่วยให้การประเมินผลมีความน่าเชื่อถือมากยิ่งขึ้นเมื่อเทียบกับการใช้ Accuracy เพียงอย่างเดียว ทั้งนี้ แม้ ROC-AUC มักถูกนำมาใช้ในการกรณีที่ข้อมูลมีความไม่สมดุลของคลาส แต่ก็สามารถประยุกต์ใช้เพื่อประเมินและเปรียบเทียบแบบจำลองในกรณีทั่วไปได้เช่นกัน [20]

2.3 เครื่องมือและโปรแกรมที่ใช้ในการวิจัย

ในการดำเนินงานวิจัยครั้งนี้ มีการเลือกใช้เครื่องมือและโปรแกรมคอมพิวเตอร์ที่สนับสนุนการดึงข้อมูลจากภาพในวิดีโอและการดึงข้อมูลจากโพสต์ในแพลตฟอร์ม TikTok จากนั้นนำมาประมวลผลด้วยวิธีการเรียนรู้ของเครื่อง (Machine Learning) เพื่อใช้ในการทำนายระดับการมีส่วนร่วมของผู้ใช้งานต่อวิดีโอ โดยเครื่องมือหลักที่ใช้ในการวิจัยประกอบด้วยดังนี้

2.3.1 Python และไลบรารีที่เกี่ยวข้อง

เป็นภาษาโปรแกรมหลักที่ใช้ในการการเขียนคำสั่งให้คอมพิวเตอร์ ช่วยให้งานได้รวดเร็วและมีไลบรารีหลากหลายสำหรับการวิเคราะห์ข้อมูลและการประมวลผล [21]

2.3.2 Apify TikTok Scraper

ใช้สำหรับดึงข้อมูลสาธารณะจากบัญชี TikTok เช่น จำนวนการกดถูกใจ ความคิดเห็น และข้อมูลอื่นๆ ของโพสต์วิดีโอใน TikTok โดยเครื่องมือนี้สามารถช่วยดึงข้อมูลได้จำนวนมากต่อหนึ่งครั้ง [22]

2.3.2 Microsoft Power Automate

เป็นเครื่องมืออัตโนมัติ (Automation Tool) ที่ใช้สำหรับสร้างกระบวนการทำงานแบบอัตโนมัติ (Workflow Automation) ในการจัดการข้อมูลและเชื่อมโยงผลลัพธ์จากการวิเคราะห์ เช่น การนำเข้าข้อมูลอัตโนมัติ ช่วยลดเวลาขั้นตอนการซ้ำแบบเดิม ในการทำงานของผู้วิจัย [23]

2.4 งานวิจัยที่เกี่ยวข้อง

2.4.1 งานวิจัยเชิงพฤติกรรมผู้ใช้กับการมีส่วนร่วมทางโซเชียลมีเดีย

งานวิจัยที่เกี่ยวข้องกับพฤติกรรมของผู้ใช้ในโซเชียลมีเดียได้ศึกษาเกี่ยวกับปัจจัยทางภาพต่างๆ ที่ส่งผลต่อ Engagement โดยดังนี้

E. Koutromanou et al. [6] มีวัตถุประสงค์เพื่อทดสอบและเปรียบเทียบโมเดลการเรียนรู้ของเครื่องหลายรูปแบบในการทำนายความนิยมของโพสต์โซเชียลมีเดียขององค์กร NGO โดยใช้ข้อมูลจาก Facebook และ Instagram ซึ่งในงานวิจัย มีการศึกษาว่าปัจจัยด้านภาพ มีบทบาทสำคัญต่อการมีส่วนร่วมของผู้ใช้อย่างไรต่อระดับการมีส่วนร่วมของผู้ใช้

F. A. M. Azman and N. Mustaffa [10] ได้ศึกษาผลกระทบของคอนเทนต์ที่ผู้ใช้สร้างขึ้น (User-Generated Content : UGC) ต่อความตั้งใจในการซื้ออาหารผ่านแพลตฟอร์ม TikTok โดยการใช้การสัมภาษณ์เชิงคุณภาพกับกลุ่มผู้ใช้งาน ผลการวิจัยพบว่า องค์ประกอบของคอนเทนต์ เช่น ภาพ วิดีโอ เสียง เพลงประกอบ และรีวิวอาหาร มีบทบาทสำคัญต่อการสร้างแรงจูงใจและความเชื่อมั่นของผู้บริโภค รวมถึงกระแสไวรัลใน TikTok ที่ช่วยกระตุ้นให้ผู้ซื้อตัดสินใจซื้อทั้งแบบออนไลน์และออฟไลน์

M. Philp et al. [13] ได้ใช้เทคนิค Computer Vision (Google Vision AI) ในการวิเคราะห์คุณลักษณะของภาพอาหารที่โพสต์บน Instagram เพื่อศึกษาว่าปัจจัยด้านภาพ เช่น ความเป็นอาหารแบบทั่วไปหรือความเป็นเอกลักษณ์ มีความสัมพันธ์กับระดับการมีส่วนร่วมของผู้ใช้บนโซเชียลมีเดีย

S. Z. Indillah et al. [14] ได้ศึกษาปัจจัยที่มีอิทธิพลต่อความตั้งใจซื้ออาหารบน TikTok Shop ของผู้บริโภคชาวอินโดนีเซีย โดยใช้แนวทางเชิงคุณภาพผ่านการสัมภาษณ์เชิงลึก ซึ่งมุ่งวิเคราะห์ปัจจัยด้านคอนเทนต์ ภาพและวิดีโอ รีวิวจากผู้ใช้ และความน่าเชื่อถือของอินฟลูเอนเซอร์ ว่ามีบทบาทต่อการสร้างการมีส่วนร่วมและการตัดสินใจของผู้บริโภคอย่างไร

D. Liu et al. [24] ได้นำเทคนิค Deep Learning มาประยุกต์ใช้ในการวิเคราะห์ภาพอาหาร โดยเฉพาะ Convolutional Neural Networks (CNNs) ซึ่งสามารถเรียนรู้คุณลักษณะของภาพแบบลำดับขั้น ตั้งแต่คุณลักษณะพื้นฐาน (Low-Level Features) เช่น สี พื้นผิว และรูปร่าง ไปจนถึงรูปแบบเชิงโครงสร้างของวัตถุ (Mid-Level Patterns) และคุณลักษณะเชิงความหมาย เช่น ประเภทอาหารหรือส่วนประกอบของอาหาร (High-Level Semantic Features) ส่งผลให้วิธีการที่ใช้ CNN มี

ความแม่นยำสูงกว่าวิธีการสกัดฟีเจอร์แบบดั้งเดิม เช่น Color Histogram หรือ Texture Descriptor อย่างมีนัยสำคัญ นอกจากนี้ งานวิจัยล่าสุดยังเริ่มใช้สถาปัตยกรรม Vision Transformer (ViT) ซึ่งใช้กลไก Self-Attention เพื่อเรียนรู้ความสัมพันธ์ของข้อมูลภาพในระดับกว้าง โดยมีรายงานผลการทดลองที่ให้ค่า Top-1 Accuracy ประมาณ 65.58% บนชุดข้อมูล ISIA Food-500 ซึ่งเป็นชุดข้อมูลภาพอาหารขนาดใหญ่ที่รวบรวมภาพอาหารหลายร้อยประเภทเพื่อใช้ฝึกและประเมินโมเดลจำแนกภาพอย่างไรก็ตาม งานวิจัยก่อนหน้านี้ยังพบข้อจำกัดด้านความหลากหลายของข้อมูลอาหารจากวัฒนธรรมต่างๆ ดังนั้นการวิเคราะห์คุณลักษณะทางภาพระดับพื้นฐาน เช่น สี ความสว่าง หรือความแตกต่างของภาพโดยผู้วิจัยจึงยังมีความสำคัญในการอธิบายองค์ประกอบภาพ เพื่อตัดสินผลของการประมวลผลของ ฟีเจอร์ของภาพในวิดีโอ

ตารางที่ 2.1 ปัจจัยที่มีผลต่อการมีส่วนร่วมทางโซเชียลมีเดีย

ลำดับ	ชื่อหัวข้อ	ปี	ปัจจัย
1	Examining Visual Impact: Predicting Popularity and Assessing Social Media Visual Strategies for NGOs	2023	1. สี 2. ความคอนทราสต์ 3. คุณภาพของภาพ 4. คน (ใบหน้าคน) 5. อัตลักษณ์แบรนด์
2	The Impact of User Generated Content on Food Purchase Intention Through TikTok Platform	2023	1. คุณภาพของภาพ 2. ข้อความ
3	Predicting Social Media Engagement with Computer Vision: An Examination of Food Marketing on Instagram	2022	1. คุณภาพของภาพ 2. จำนวนอาหาร/วัตถุในภาพ 3. ใบหน้าคน
4	Exploring Indonesian Consumer Insights and Factors Driving their Food Purchase Intention on TikTok Shop	2023	1. บรรจุภัณฑ์ 2. ส่วนผสม/วัตถุดิบ

2.4.2 งานวิจัยเชิงเทคนิคในการพัฒนาแบบจำลอง

งานวิจัยในด้านการพัฒนาแบบจำลองทางเทคนิคเกี่ยวกับการเรียนรู้ของเครื่องได้มุ่งเน้นการทดสอบและปรับปรุงประสิทธิภาพของโมเดลในการพยากรณ์ข้อมูล โดยงานวิจัยที่ศึกษาอยู่ดังนี้

นงลักษณ์ ตาดทอง ใช้เทคนิคการเรียนรู้ของเครื่อง เช่น Decision Tree, Naïve Bayes, K-Nearest Neighbors (KNN), Random Forest และ Ensemble Method เพื่อพัฒนาแบบจำลองที่สามารถทำนายแนวโน้ม การตัดสินใจซื้อที่อยู่อาศัยได้อย่างมีประสิทธิภาพ ซึ่งโมเดลที่ทำได้ดีที่สุด คือ โมเดล Ensemble ของ Decision Tree กับ KNN และ Random Forest [16]

งานวิจัยเกี่ยวกับการซื้อขายสกุลเงินดิจิทัล โดย ศิวชัย อศวกิจพานิช ได้นำโมเดล เช่น XGBoost, Support Vector Machine, Long-Short Term Memory, Equally Weighted Forecast Combinations, Adaptive Regression by Mixing and Aggregation of Forecasts Through Exponential Reweight และนำมาผสมผสานกับเทคนิค Ensemble Method 6 แบบเพื่อเพิ่มความแม่นยำในการพยากรณ์ และสร้างกลยุทธ์ การซื้อขายที่มีประสิทธิภาพสูงสุด [25]

งานวิจัยเกี่ยวกับการทำนายความนิยมของโพสต์ในโซเชียลมีเดีย โดย E. Koutromanou et al. [6] ได้ศึกษาและทดลองอัลกอริทึมการเรียนรู้ของเครื่อง Logistic Regression, Random Forest, AdaBoost Classifier, K-Nearest Neighbors และ Support Vector Classifier มาทดลองใช้ในการจำแนกโพสต์ว่า มีความนิยมสูงหรือต่ำ โดยอาศัย คุณลักษณะทางภาพที่สกัดจากภาพในโพสต์ของ NGO เด็ก (เช่น สี ความคมชัด ใบหน้า อารมณ์ โลโก้องค์กร) เพื่อทำนายจำนวนการมีส่วนร่วม (Likes, Comments, Shares) บน Facebook และ ซึ่งผลการทดลองพบว่า Support Vector Classifier (SVC) ให้ผลลัพธ์ที่ดีที่สุด โดยมี Accuracy 0.62 บน Facebook และ 0.81 บน Instagram

นอกจากนี้ยังมีการศึกษาอัลกอริทึมเพิ่มเติมในงานวิจัยต่างๆ เพื่อศึกษาและคัดเลือกโมเดลเพื่อนำมาใช้ในการทดลอง ได้แก่ S. Assavakijphanich [17] T. Chengsheng et al. [26]

ตารางที่ 2.2 เทคนิคการเรียนรู้ของเครื่องที่ใช้ในการทำนายจากงานวิจัย

ลำดับ	ชื่อหัวข้อ	ปี	เทคนิคการเรียนรู้
1	การพยากรณ์ผู้ที่มีแนวโน้มในการตัดสินใจซื้อที่อยู่อาศัย ในงานมหกรรมบ้านและ คอนโดโดยใช้เทคนิคการเรียนรู้ของเครื่อง	2020	1. Decision Tree 2. Naïve Bayes 3. K-Nearest Neighbors 4. Random Forest 5. Ensemble Method 6. Cross Validation

ตารางที่ 2.2 เทคนิคการเรียนรู้ของเครื่องที่ใช้ในการทำนายจากงานวิจัย (ต่อ)

ลำดับ	ชื่อหัวข้อ	ปี	เทคนิคการเรียนรู้
2	Cryptocurrency Trading with Ensemble Machine Learning Algorithm	2021	1. Long Short-Term Memory 2. Support Vector Machines 3. Extreme Gradient Boosting 4. Adaptive Regression by Mixing 5. Equally Weighted Forecast Combinations 6. Ensemble Method
3	Examining Visual Impact: Predicting Popularity and Assessing Social Media Visual Strategies for NGOs	2023	1. Logistic Regression 2. Random Forest 3. AdaBoost Classifier 4. K-Nearest Neighbors 5. Support Vector Classifier 6. Cross Validation
4	XGBoost : A Scalable Tree Boosting System	2016	1. Extreme Gradient Boosting
5	LightGBM : A Highly Efficient Gradient Boosting Decision Tree	2017	1. LightGBM
6	AdaBoost Typical Algorithm and its Application Research	2017	1. AdaBoost
7	CatBoost : Unbiased Boosting with Categorical Features	2019	1. CatBoost

ตารางที่ 2.3 การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่องแต่ละประเภท

ชื่อเทคนิค	การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่อง
Decision Tree	มักใช้กับงานที่มีความสัมพันธ์ของตัวแปรแบบตรงไปตรงมา และสามารถตีความผลลัพธ์ได้ง่าย เหมาะกับการวิเคราะห์ที่ต้องการความชัดเจนในกระบวนการตัดสินใจ

ตารางที่ 2.3 การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่องแต่ละประเภท (ต่อ)

ชื่อเทคนิค	การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่อง
Random Forest	เป็นการรวมผลลัพธ์จากหลาย Decision Tree เข้าด้วยกัน ทำให้สามารถประยุกต์ใช้กับงานที่มีความสัมพันธ์ของข้อมูลซับซ้อนมากขึ้น และช่วยลดความเอนเอียง (Bias) ของโมเดล
Naïve Bayes	อาศัยหลักความน่าจะเป็นในการจำแนกเงื่อนไข เหมาะกับงานที่มีตัวแปรอิสระต่อกัน และมีความสัมพันธ์ที่สามารถคาดการณ์ได้อย่างชัดเจน
K-Nearest Neighbors	อิงจากข้อมูลตัวอย่าง โดยพิจารณาความใกล้เคียงของข้อมูล เหมาะกับงานที่ข้อมูลมีการกระจายตัวคล้ายคลึงกัน และต้องการจำแนกกลุ่มตามความสัมพันธ์ของลักษณะร่วม
Long Short - Term Memory	เป็นสถาปัตยกรรมของโครงข่ายประสาทเทียม (Neural Network) ที่ออกแบบมาเพื่อจดจำข้อมูลระยะยาว โดยป้องกันปัญหาการลืมข้อมูลเก่า เหมาะกับงานที่มีข้อมูลต่อเนื่องตามลำดับเวลา
Support Vector Machines	เป็นอัลกอริทึมที่สร้างเส้นขอบเขต (Hyperplane) เพื่อแยกกลุ่มข้อมูลในพื้นที่หลายมิติได้อย่างมีประสิทธิภาพ เหมาะกับข้อมูลที่ไม่เป็นเส้นตรง (Non-Linear) และซับซ้อน
AR-MIX	เป็นเทคนิคที่รวมผลจากแบบจำลองการถดถอยหลายแบบ (Regression Models) และปรับ “น้ำหนัก” ของแต่ละโมเดลแบบอัตโนมัติ เหมาะกับงานพยากรณ์ที่ข้อมูลมีการเปลี่ยนแปลงตลอดเวลา
EWFC	เป็นวิธีการรวมผลการพยากรณ์จากหลายโมเดล โดยให้น้ำหนักเท่ากันทั้งหมด เหมาะกับกรณีที่ไม่มีข้อมูลเพียงพอจะระบุว่าโมเดลใดให้ผลดีที่สุด
Logistic Regression	เหมาะกับงานที่ความสัมพันธ์ไม่ซับซ้อนมาก และมีลักษณะเชิงเส้นระหว่างตัวแปรต้นกับผลลัพธ์ ใช้ได้ดีกับการจำแนกประเภท (Classification)
AdaBoost	เป็นอัลกอริทึมที่รวมโมเดล Weak Learners หลายตัวเข้าด้วยกันให้กลายเป็น Strong Learner โดยปรับน้ำหนักของข้อมูลในแต่ละรอบการเรียนรู้ ช่วยเพิ่มความแม่นยำและจัดการกับปัญหาที่ซับซ้อนได้ดี
XGBoost	ใช้กระบวนการเรียนรู้แบบ Gradient Boosting โดยเรียนรู้จากความผิดพลาดของรอบก่อนหน้า และมีการใช้ Regularization เพื่อลดปัญหา Overfitting เหมาะกับงานที่มีข้อมูลซับซ้อนปานกลางถึงขนาดใหญ่

ตารางที่ 2.3 การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่องแต่ละประเภท (ต่อ)

ชื่อเทคนิค	การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่อง
XGBoost	ใช้กระบวนการเรียนรู้แบบ Gradient Boosting โดยเรียนรู้จากความผิดพลาดของรอบก่อนหน้า และมีการใช้ Regularization เพื่อลดปัญหา Overfitting เหมาะกับงานที่มีข้อมูลซับซ้อนปานกลางถึงขนาดใหญ่
LightGBM	ใช้เทคนิคการลดจำนวนตัวอย่าง (GOSS) และการรวมพีเจอร์ที่ไม่ทับซ้อนกัน (EFB) ทำให้ประมวลผลได้รวดเร็ว เหมาะกับงานที่มีข้อมูลจำนวนมากและต้องการความเร็วในการฝึกโมเดล
CatBoost	ออกแบบมาเพื่อจัดการกับข้อมูลเชิงหมวดหมู่ (Categorical Data) และลดปัญหา Prediction Shift ที่เกิดจากการอ้างอิงข้อมูลตัวอย่างมากเกินไป เหมาะกับข้อมูลที่มี Noise หรือ Outlier

จากตารางที่ 2.5 ด้านล่าง จะเห็นได้ว่าการกำหนดข้อจำกัดเฉพาะในการทดลองส่งผลต่อจำนวนตัวอย่างที่สามารถเก็บได้ โดยจำนวนตัวอย่างจะแปรผันตามขอบเขตที่กำหนด ซึ่งช่วยให้ได้กลุ่มข้อมูลที่มีความสม่ำเสมอและสามารถเปรียบเทียบกันได้ง่าย อีกทั้งยังสะท้อนแนวโน้มของพฤติกรรมผู้ใช้งานได้อย่างชัดเจน

ตัวอย่างเช่น งานวิจัย Assessment of Accuracy, User Engagement, and Themes of Eating Disorder Content on TikTok ใช้ข้อมูลเพียง 200 วิดีโอ เพื่อศึกษาความสัมพันธ์ระหว่างความต้องการของเนื้อหาที่เกี่ยวกับโรคการกินผิดปกติ (Eating Disorder) กับระดับการมีส่วนร่วมของผู้ใช้บนแพลตฟอร์ม TikTok แม้งานดังกล่าวจะไม่ใช่งานที่มุ่งเน้นการพัฒนาโมเดลเชิงคาดการณ์โดยตรง แต่สามารถอ้างอิงเป็นกรณีศึกษาที่แสดงให้เห็นถึงการวิเคราะห์ผลกระทบของปัจจัยต่อการมีส่วนร่วมของผู้ใช้งานในแพลตฟอร์ม TikTok ได้อย่างเหมาะสม [27]

ในขณะที่ยานวิจัย Predicting User Engagement of Facebook Post Images in Leading Universities: A Machine Learning Approach เป็นการทำนายระดับการมีส่วนร่วม ของโพสต์ภาพบน Facebook ของมหาวิทยาลัยชั้นนำในสหรัฐอเมริกา อังกฤษ และออสเตรเลีย ประยุกต์ใช้ Google Cloud Vision API ร่วมกับอัลกอริธึม เพื่อจำแนกระดับ Engagement ได้อย่างมีประสิทธิภาพ ซึ่งใช้จำนวนข้อมูลภาพเพียง 1,008 ภาพ [28]

นอกจากนี้ งานวิจัย Examining Visual Impact: Predicting Popularity and Assessing Social Media Visual Strategies for NGOs ได้ใช้ข้อมูลภาพจำนวน 4,144 ภาพ จาก 12 องค์กร NGO บนแพลตฟอร์ม Facebook และ Instagram เพื่อจำแนกโพสต์ที่ได้รับความนิยม และสามารถทำนาย

Engagement ได้อย่างมีประสิทธิภาพ ด้วยการวิเคราะห์ทั้งคุณลักษณะภาพระดับสูง (เช่น ใบหน้า โลโก้ อารมณ์) และระดับต่ำ (เช่น สี ข้อความ ความคมชัด) [6]

ดังนั้น ในงานวิจัยนี้จึงเลือกขนาดกลุ่มตัวอย่างอยู่ที่ 1,000 วิดีโอ ซึ่งถือเป็นระดับที่สมดุลระหว่างความลึกของข้อมูลและความสามารถในการประมวลผล ทั้งยังสอดคล้องกับแนวทางของงานวิจัยก่อนหน้านี้ ที่แสดงให้เห็นว่าการใช้กลุ่มตัวอย่างที่มีความเฉพาะเจาะจงและเพียงพอจะช่วยให้การพัฒนาโมเดลทำนายผลมีความแม่นยำและน่าเชื่อถือ

ตารางที่ 2.4 การเปรียบเทียบจำนวนตัวอย่างในงานวิจัยที่เกี่ยวข้อง

ชื่องานวิจัย	แพลตฟอร์ม	จำนวนตัวอย่างการทดลอง
Predicting User Engagement of Facebook Post Images in Leading Universities' Pages	Facebook	1,008 รูปภาพ
Assessment of Accuracy, User Engagement, and Themes of Eating Disorder Content on TikTok	TikTok	200 วิดีโอ
Examining Visual Impact : Predicting Popularity and Assessing Social Media Visual Strategies for NGOs	Facebook & Instagram	4,144 รูปภาพ (2,587 จาก Facebook, 1,557 จาก Instagram)

งานวิจัยของเราแตกต่างจากงานวิจัยก่อนหน้านี้งานของเรามุ่งเน้นไปที่การทำนายระดับการมีส่วนร่วม (Engagement) ของผู้ใช้งานในแพลตฟอร์ม TikTok ซึ่งเป็นแพลตฟอร์มที่มีลักษณะเฉพาะต่างจาก Facebook และ Instagram ในงานวิจัยของ E. Koutromanou et al. [6] โดย TikTok เน้นเนื้อหาวิดีโอสั้นที่มีองค์ประกอบภาพเคลื่อนไหว นอกจากนี้ งานของเรายังโฟกัสไปที่บัญชีที่เกี่ยวข้องกับอาหารและเครื่องดื่มในบริบทของประเทศไทย ซึ่งมีวัฒนธรรมและพฤติกรรมผู้บริโภคเฉพาะตัว ส่งผลต่อรูปแบบการมีส่วนร่วม (Engagement) ที่แตกต่างกัน อีกการเลือกเทคนิคการเรียนรู้ของเครื่อง (Machine Learning) ที่นำมาประยุกต์ใช้ ศึกษาและทดลอง ยังมีโมเดลที่ต่างกัน


บทที่ 3

ระเบียบและวิธีดำเนินการวิจัย

การวิจัยนี้มีเป้าหมายเพื่อทำนายระดับการมีส่วนร่วมของผู้ใช้ต่อคลิปวิดีโอ ผ่านปัจจัยองค์ประกอบทางภาพบนแพลตฟอร์ม TikTok ในอุตสาหกรรมร้านอาหารและเครื่องดื่มและเพื่อให้บรรลุ วัตถุประสงค์ของงานวิจัย กระบวนการดำเนินงานถูกแบ่งออกเป็น 6 ขั้นตอน ดังนี้:

- ขั้นตอนที่ 1 เก็บข้อมูลและเตรียมข้อมูล (Dataset and Preparation)
- ขั้นตอนที่ 2 การดึงฟีเจอร์จากภาพในโพสต์ (Feature Extraction)
- ขั้นตอนที่ 3 การทำความสะอาดข้อมูลและประมวลผล (Data Cleaning and Processing)
- ขั้นตอนที่ 4 การเลือกพัฒนาโมเดลการทำนาย (Model Selection & Development)
- ขั้นตอนที่ 5 การฝึกฝน ตรวจสอบและทดสอบโมเดล (Training Validating and Testing Process)
- ขั้นตอนที่ 6 การประเมินผล (Evaluation)

ในแต่ละขั้นตอน การดำเนินงานเป็นไปตามลำดับเพื่อให้ได้แบบจำลองที่มีประสิทธิภาพในการทำนาย Engagement ตามเป้าหมายของงานวิจัยนี้



รูปที่ 3.1 ระบบที่นำเสนอ

3.1 เก็บข้อมูลและเตรียมข้อมูล

การเก็บข้อมูลสำหรับการวิจัยครั้งนี้ ได้มีการกำหนดเกณฑ์อย่างเป็นระบบเพื่อให้แน่ใจว่าข้อมูลที่นำมาใช้มีความสอดคล้องกับวัตถุประสงค์ของงานวิจัย โดยเน้นไปที่วิดีโอในแพลตฟอร์ม TikTok ที่มีเนื้อหาเกี่ยวกับอาหารและเครื่องดื่ม ที่มีลักษณะดังที่ได้ระบุไว้ในบทที่ 1 ขอบเขตของงานวิจัยดังนี้

กลุ่มตัวอย่าง : คลิปวิดีโอของบัญชีเกี่ยวกับอาหารและเครื่องดื่มในประเทศไทยที่เผยแพร่บนแพลตฟอร์ม TikTok จำนวน 1,000 คลิปวิดีโอ โดยวิดีโอที่ใช้ในการประเมินมีลักษณะดังต่อไปนี้

- คลิปวิดีโอที่มีเนื้อหาเกี่ยวข้องกับอาหารและมีรูปภาพหรือเครื่องดื่มในวิดีโอ
- คลิปวิดีโอมีความยาวในช่วง 15-60 วินาที
- คลิปวิดีโอในช่วง 2 ปีซึ่งหมายถึง 6 กันยายน 2023 - 5 กันยายน 2025
- คลิปจากบัญชี TikTok ที่มีผู้ติดตาม 10,000-50,000 คน
- คลิปวิดีโอจำนวน 1,000 คลิปจาก 50 บัญชี บัญชีละ 20 คลิป
- คลิปวิดีโอต้องโพสต์มาแล้วเกิน 90 วัน

การเก็บรวบรวมข้อมูลนั้นเริ่มจากการดึงโพสต์ที่เป็นสาธารณะของบัญชี TikTok อื่นๆ ที่เข้าเกณฑ์ตามขอบเขตที่กำหนดไว้ จากนั้นบันทึกรายการ URL ของคลิปที่เลือกไว้ โดยใช้เครื่องมือ Power Automate ร่วมกับ Google Form เพื่อรวบรวมลิงก์วิดีโอทั้งหมด หลังจากได้รายการลิงก์แล้ว จึงนำลิงก์เหล่านั้นมาดึงข้อมูล (Scraping) ผ่าน Unofficial TikTok API (Apify) เนื่องจาก TikTok API อย่างเป็นทางการไม่อนุญาตให้เข้าถึงข้อมูลโพสต์ของบัญชีอื่นโดยตรง

3.2 การดึงฟีเจอร์จากภาพในโพสต์

ในขั้นตอนที่สอง คือขั้นตอนการดึงปัจจัยองค์ประกอบทางภาพในวิดีโอ เพื่อนำเข้ามาทำนายในโมเดลในขั้นตอนถัดไป การเลือกคุณลักษณะที่ต้องการดึงออกมานั้นแบ่งเป็น คุณลักษณะระดับต่ำ (Low-Level Features) และคุณลักษณะระดับสูง (High-Level Features)

สำหรับ คุณลักษณะระดับต่ำ (Low-Level Features) ที่พื้นฐานของภาพที่คอมพิวเตอร์สามารถตรวจจับได้ตรงๆ โดยอาศัยค่าทางกายภาพ ประกอบด้วย สี, คอนทราสต์, ข้อความ


สำหรับ คุณลักษณะระดับสูง เป็นคุณลักษณะที่สัมพันธ์กับความหมายหรือการตีความของภาพ การค้นหามุ่งเน้นไปที่อาหาร ส่วนผสม บรรจุภัณฑ์ หรือใบหน้า โดยพิจารณาในรายละเอียดด้วย อย่างเช่นว่าในวิดีโอมี อาหารกี่เมนู (หนึ่งหรือหลายเมนู), ถ้ามีบุคคลปรากฏอยู่เพศชายหรือหญิงหรือมีการแสดง โลโก้ขององค์กรในภาพหรือไม่

สำหรับเครื่องมือที่ใช้ในการดึงคุณลักษณะเหล่านี้ ได้แก่ Google Colab เพื่อช่วยประมวลผลเพิ่มเติม ทั้งนี้ ในกรณีที่คุณลักษณะบางประการไม่สามารถตรวจจับได้ด้วยระบบอัตโนมัติ จะมีการตรวจสอบและตีความโดยผู้วิจัยเพื่อเสริมความครบถ้วนของข้อมูล

สำหรับวิดีโอ ซึ่งมีความต่อเนื่องเชิงเวลา การวิเคราะห์คุณลักษณะระดับต่ำสีและคอนทราสต์ อาจมีความซับซ้อนกว่าภาพนิ่ง งานวิจัยนี้จึงใช้วิธีสุ่มตัวแทนวิดีโอโดย ดึงเฟรมที่เกี่ยวข้องกับอาหาร เครื่องดื่ม หรือของหวานจำนวน 3 ภาพมาเป็นตัวแทนจากแต่ละวิดีโอ การเลือกเฟรมจากช่วงเวลาที่แตกต่างกัน ช่วงต้น กลางและท้าย เพื่อจับความหลากหลายของลักษณะภาพของวิดีโอ ในขณะที่ยังคงควบคุมต้นทุนด้านการคำนวณสำหรับการสกัดคุณลักษณะให้อยู่ในระดับที่เหมาะสม แล้วทำการคำนวณคุณลักษณะของแต่ละเฟรม (เช่น สีหลักและระดับคอนทราสต์) ก่อนจะเลือกค่ามัธยฐาน Median ตัวตรงกลางเป็นตัวแทนของคลิปวิดีโอ ซึ่งช่วยลดอิทธิพลของค่าผิดปกติ Extreme Values ที่อาจเกิดขึ้นในบางเฟรมได้ จากนั้นจึงนำค่าตัวแทนดังกล่าวเข้าสู่แบบจำลองการทำงาน



รูปที่ 3.2 รูปตัวอย่างของภาพตัวแทนวิดีโอ



รูปที่ 3.2 รูปตัวอย่างของภาพตัวแทนวิดีโอ (ต่อ)

ตารางที่ 3.1 คุณลักษณะพีเจอร์จากภาพในโพสต์และมาตรฐานการวัดข้อมูล

คุณลักษณะ	มาตรฐานการวัดข้อมูล
คุณลักษณะระดับต่ำ	
สีสดใส	ไม่ใช่ (0) ใช่ (1)
ความสว่าง	ไม่ใช่ (0) ใช่ (1)
คอนทราสต์	ไม่ใช่ (0) ใช่ (1)
ความชัดคม	ไม่ใช่ (0) ใช่ (1)
คุณลักษณะระดับสูง	
วัตถุดิบ	อาหารสำเร็จ (0) อาหารสำเร็จและกระบวนการทำอาหารหรือวัตถุดิบ (1)
อาหาร	ไม่มี (0) มีหนึ่งเมนู (1) มีมากกว่าหนึ่งเมนู (2)
ของหวาน	ไม่มี (0) มีหนึ่งเมนู (1) มีมากกว่าหนึ่งเมนู (2)
เครื่องดื่ม	ไม่มี (0) มีหนึ่งเมนู (1) มีมากกว่าหนึ่งเมนู (2)
ใบหน้าคน	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)
ผู้ใหญ่ ชาย (ใบหน้า)	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)
ผู้ใหญ่ หญิง (ใบหน้า)	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)
เด็ก (ใบหน้า)	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)

ตารางที่ 3.1 คุณลักษณะพีเจอร์จากภาพในโพสต์และมาตรฐานการวัดข้อมูล (ต่อ)

คุณลักษณะ	มาตรฐานการวัดข้อมูล
โลโก้	ไม่มี (0) มี (1)
บรรจุภัณฑ์	ไม่มี (0) มี (1)
ข้อความรีวิว/คะแนน	ไม่มี (0) มี (1)
ข้อความราคา/โปรโมชั่น	ไม่มี (0) มี (1)

หมายเหตุ :

- สีสดใส (Colorfulness): คำนวณจากค่า Saturation (S) ในระบบสี HSV โดยปรับสเกลให้อยู่ในช่วง 0–1 หากค่าเฉลี่ยของ $S \geq 0.5$ กำหนดให้เป็น 1 (ใช่) และหาก $S < 0.5$ กำหนดให้เป็น 0 (ไม่ใช่)
- ความสว่าง (Brightness): คำนวณจากค่า Value (V) ในระบบสี HSV โดยปรับสเกลให้อยู่ในช่วง 0–1 หากค่าเฉลี่ยของ $V \geq 0.6$ กำหนดให้เป็น 1 และหาก $V < 0.6$ กำหนดให้เป็น 0
- คอนทราสต์ (Contrast): คำนวณจากภาพระดับเทา (Grayscale) โดยหาความแตกต่างระหว่างค่า Percentile ที่ 95 และ Percentile ที่ 5 ของค่าความเข้มแสง หากค่าความแตกต่าง ≥ 180 กำหนดให้เป็น 1 และหาก < 180 กำหนดให้เป็น 0
- ความชัดคม (Sharpness): คำนวณจากค่า Variance of Laplacian ของภาพระดับเทา หากค่าความแปรปรวน $\geq 14,000$ กำหนดให้เป็น 1 และหาก $< 14,000$ กำหนดให้เป็น 0
- ใบหน้าคน: บุคคลที่แสดงการกระทำในวิดีโอ เช่น รับประทานอาหาร หรือกำลังปรุงอาหาร ไม่ใช่ ใบหน้าของคนในพื้นที่หลังที่ไม่สำคัญ
- โลโก้: สัญลักษณ์ เครื่องหมาย หรือภาพกราฟิกที่ใช้แทนตัวตนของแบรนด์หรือร้านค้า ซึ่งสามารถทำให้ผู้ชมจดจำและเชื่อมโยงกับองค์กร ผลิตภัณฑ์ หรือบริการนั้นได้โดยตรง
- บรรจุภัณฑ์: สิ่งที่ห่อหุ้มและนำเสนอสินค้าให้ผู้บริโภครับรู้ความตั้งใจของแบรนด์ มักอยู่ในรูปแบบนํ้ากลับบ้าน
- ข้อความรีวิว/คะแนน: ข้อความในวิดีโอที่สะท้อนการแสดงความคิดเห็น การให้ข้อมูลประกอบหรือการให้คะแนนต่อสินค้าอาหารหรือเครื่องดื่มโดยผู้สร้างเนื้อหาข้อความที่ปรากฏภายในวิดีโอซึ่งแสดงการประเมินความคิดเห็นเกี่ยวกับอาหารหรือเครื่องดื่ม

- ข้อความราคา/โปรโมชั่น: ข้อความที่ปรากฏภายในวิดีโอซึ่งแจ้งข้อมูลเกี่ยวกับราคา ส่วนลด โปรโมชั่น ระยะเวลาของกิจกรรม หรือสถานที่จัดกิจกรรมพิเศษ โดยมีวัตถุประสงค์เพื่อกระตุ้นความสนใจและการตัดสินใจของผู้ชม

ตารางที่ 3.2 คุณลักษณะภาพและเครื่องมือสำหรับการตรวจจับคุณลักษณะ

คุณลักษณะ	เครื่องมือสำหรับการตรวจจับคุณลักษณะ
คุณลักษณะระดับต่ำ	
สีสันสดใส	Google Colab (Pillow, NumPy, colorsys)
ความสว่าง	Google Colab (Pillow, NumPy, colorsys)
คอนทราสต์	Google Colab (Pillow, NumPy)
ความขัดคม	Google Colab (SciPy (ndimage), NumPy)
คุณลักษณะระดับสูง	
วัตถุติด	ตรวจสอบด้วยผู้วิจัย
อาหาร	ตรวจสอบด้วยผู้วิจัย
ของหวาน	ตรวจสอบด้วยผู้วิจัย
เครื่องดื่ม	ตรวจสอบด้วยผู้วิจัย
ใบหน้าคน	ตรวจสอบด้วยผู้วิจัย
ผู้ใหญ่ ชาย (ใบหน้า)	ตรวจสอบด้วยผู้วิจัย
ผู้ใหญ่ หญิง (ใบหน้า)	ตรวจสอบด้วยผู้วิจัย
เด็ก (ใบหน้า)	ตรวจสอบด้วยผู้วิจัย
โลโก้	ตรวจสอบด้วยผู้วิจัย
บรรจุภัณฑ์	ตรวจสอบด้วยผู้วิจัย
ข้อความรีวิว/คะแนน	ตรวจสอบด้วยผู้วิจัย
ข้อความราคา/โปรโมชั่น	ตรวจสอบด้วยผู้วิจัย

3.3 การทำความสะอาดล้างข้อมูลและประมวลผล

ในกระบวนการล้างข้อมูลและการประมวลผล ตัวแปรบางส่วนที่ไม่ถูกนำมาใช้ในการทำนาย จะถูกตัดออกไป จากรูปที่ 3.3 คือข้อมูลที่เราได้จากScraping ข้อมูลการมีส่วนร่วมผ่าน Apify ซึ่งสามารถสังเกตได้ว่ามีข้อมูลจำนวนมากทั้งหมด 258 แถว ซึ่งหลายแถวนั้นไม่สำคัญหรือไม่เกี่ยวข้องกับการทำนาย ดังนั้นจึงจำเป็นต้องดำเนินการทำความสะอาดข้อมูลให้อยู่ในรูปแบบที่เหมาะสมดังแสดงในรูปที่ 3.4

พร้อมกันนี้ ข้อมูลพารามิเตอร์อื่นๆ รวมถึงค่าประเภท Boolean ที่ได้จากการประมวลผลของการดึงฟีเจอร์ดังรูปที่ 3.5 ก่อนจะถูกนำไปใช้เป็นตัวแปรอิสระสำหรับการสร้างโมเดลในขั้นตอนถัดไปด้วย

N	Like	Share	Comment	Colorfulness	Brightness	Contrast	Sharpness	Ingredient	Food
1	0	0	0	0	1	1	1	0	0
2	0	1	0	0	1	0	1	1	0
3	0	1	0	0	1	0	1	1	0
4	0	1	0	0	1	0	1	1	0
5	0	1	0	0	1	0	0	0	0
6	0	0	0	0	1	0	1	1	0
7	0	1	1	0	1	0	0	0	0
8	0	0	0	0	1	0	0	1	0
9	0	0	0	0	1	0	1	1	0
10	0	0	0	0	1	0	1	0	0

รูปที่ 3.5 รูปแบบของข้อมูลที่เป็น Boolean ก่อนนำไปทำนาย

3.4 การเลือกและพัฒนาโมเดลการทำนาย

หลังจากขั้นตอนการเตรียมข้อมูล การล้างข้อมูล และการประมวลผลแล้ว ได้ทำการแปลงฟีเจอร์เชิงตรรกะ (Boolean Features) ที่ได้จากการวิเคราะห์ภาพ และข้อมูลอัตราการมีส่วนร่วม (Engagement Rate) เพื่อใช้เป็นตัวแปรนำเข้า (Input Features) สำหรับการฝึกโมเดล

จากการศึกษาอัลกอริทึมการเรียนรู้ของเครื่องในบทที่ 2 เราจึงได้วิเคราะห์ความเหมาะสมของอัลกอริทึมต่องานวิจัยของเราดังตารางที่ 3.2 และเลือกอัลกอริทึมสำหรับงานวิจัยตามตารางที่ 3.3

ตารางที่ 3.3 การเปรียบเทียบเทคนิค หลักการทำงานและความเหมาะสมกับงานวิจัย

ชื่อเทคนิค	ความเหมาะสมต่อการวิจัยนี้
Random Forest	ข้อดี : เนื่องจาก Random Forest ใช้ต้นไม้ตัดสินใจจำนวนมากในการทำนาย ทำให้สามารถจัดการกับข้อมูลที่ซับซ้อนและตัวแปรที่มีความหลากหลายได้อย่างมีประสิทธิภาพ อีกทั้งยังช่วยลดปัญหา Overfitting และรองรับข้อมูลที่ขาดหายหรือมีความไม่สมดุลได้ดี จึงมีความเหมาะสมสำหรับการทำนาย Engagement ที่เกี่ยวข้องกับหลายปัจจัยเชิงภาพและเชิงพฤติกรรม ข้อเสีย : การที่มีต้นไม้เยอะอีกหนึ่งนัยหนึ่งก็ทำให้บางทีเกิดความซับซ้อนมากเกินไป ซึ่งอาจมีโมเดลประเภทอื่นที่เหมาะสมกว่า ถ้าตัวอย่างในบางข้อมูลหรือตัวแปรที่มีน้อยเกินไป อาจจะทำให้โมเดลตีความ ข้อมูลได้ลำบาก

ตารางที่ 3.3 การเปรียบเทียบเทคนิค หลักการทำงานและความเหมาะสมกับงานวิจัย (ต่อ)

ชื่อเทคนิค	ความเหมาะสมต่อการวิจัยนี้
Support Vector Machines (SVM)	ข้อดี : SVM ใช้หลักการของเส้นแบ่งหลายมิติ (Hyperplane) เพื่อจำแนกและทำนายข้อมูลที่มีความซับซ้อน ซึ่งสอดคล้องกับบริบทของการมีส่วนร่วมบนแพลตฟอร์ม TikTok ที่มีตัวแปรหลายด้านและความสัมพันธ์ที่ซับซ้อน ข้อเสีย : SVM มีข้อจำกัดเมื่อใช้กับข้อมูลที่มีจำนวนมากหรือมีมิติสูง เนื่องจากต้องใช้เวลาและทรัพยากรในการประมวลผลสูง อย่างไรก็ตาม งานวิจัยนี้มีขนาดข้อมูลไม่มากนัก จึงยังเหมาะสมต่อการนำ SVM มาใช้ในการศึกษา
LightGBM	ข้อดี : Gradient-based One-Side Sampling (GOSS) และ Exclusive Feature Bundling (EFB) ช่วยในการลดจำนวนข้อมูลตัวอย่างและจำนวนฟีเจอร์ที่ต้องประมวลผล ทำให้โมเดลสามารถโฟกัสไปที่ตัวแปรที่มีความสำคัญต่อการทำนายผลลัพธ์ได้ดียิ่งขึ้น เหมาะสมกับการวิเคราะห์การมีส่วนร่วมบน TikTok ซึ่งมีหลายปัจจัยเชิงภาพและพฤติกรรมที่เกี่ยวข้องกัน ข้อเสีย : มีจุดเด่นในการลดจำนวนข้อมูลและฟีเจอร์เพื่อเพิ่มประสิทธิภาพการประมวลผล แต่ข้อได้เปรียบนี้อาจไม่ใช่ปัจจัยหลักของงานวิจัยนี้ นอกจากนี้หากการสุ่มเลือก ฟีเจอร์ ไม่มีประสิทธิภาพที่ดีพอ จะทำให้ผลลัพธ์ไม่มีประสิทธิภาพ
CatBoost	ข้อดี : เป็นอัลกอริทึมที่ถูกออกแบบมาเพื่อจัดการกับข้อมูลเชิงหมวดหมู่ได้อย่างมีประสิทธิภาพ พร้อมทั้งแก้ปัญหา Prediction Shift ที่มักเกิดจากการอ้างอิงข้อมูลตัวอย่างมากเกินไป ซึ่งทำให้ทำงานได้ดีแม้ในกรณีที่มี Noise หรือ Outlier อยู่ในข้อมูล อีกทั้งยังเหมาะกับชุดข้อมูลที่มีขนาดไม่ใหญ่มาก ซึ่งสอดคล้องกับขอบเขตของงานวิจัยนี้ ข้อเสีย : เนื่องจากกลุ่มข้อมูลในงานวิจัยนี้มีขนาดค่อนข้างเล็ก อาจทำให้การจัดการกับตัวแปรเชิงหมวดหมู่ไม่สามารถแสดงศักยภาพได้เต็มที่เท่ากับกรณีที่ใช้กับข้อมูลขนาดใหญ่

ตารางที่ 3.4 เทคนิคการเรียนรู้ของเครื่องที่ใช้ในการทดลอง

Support Vector Classifier (SVC)	Light GBM
Random Forest	CatBoost

3.5 การฝึกฝน ตรวจสอบและทดสอบโมเดล

การพัฒนาแบบจำลองในงานวิจัยนี้ดำเนินการภายใต้กระบวนการแบ่งข้อมูลอย่างเป็นระบบ เพื่อให้การประเมินผลมีความน่าเชื่อถือและสะท้อนความสามารถจริงของโมเดล โดยชุดข้อมูลทั้งหมดถูกแบ่งออกเป็น 3 ส่วน ได้แก่ ชุดฝึก (Training Set) ร้อยละ 70 ชุดตรวจสอบความถูกต้อง (Validation Set) ร้อยละ 10 และชุดทดสอบ (Test Set) ร้อยละ 20

ชุดฝึก (70%) ใช้สำหรับการเรียนรู้พารามิเตอร์ของโมเดลจากข้อมูลจริง โดยอัลกอริทึมจะปรับน้ำหนักหรือโครงสร้างภายในเพื่อให้สามารถจำแนกระดับการมีส่วนร่วมได้ดีที่สุดตามข้อมูลที่ได้รับ ชุดตรวจสอบความถูกต้อง (10%) ใช้สำหรับประเมินประสิทธิภาพระหว่างกระบวนการพัฒนาโมเดล และชุดทดสอบ (20%) ถูกกั้นไว้ตั้งแต่เริ่มต้นและไม่ได้ถูกใช้ในขั้นตอนการฝึกหรือการปรับแต่งโมเดลแต่อย่างใด โดยจะถูกนำมาใช้เพียงครั้งเดียวในขั้นตอนสุดท้าย เพื่อประเมินความสามารถของโมเดลกับข้อมูลที่ไม่เคยเห็นมาก่อน เพื่อให้ได้ผลลัพธ์ของแบบจำลองได้อย่างโปร่งใส

ผลลัพธ์ของการจำแนกจะประกอบด้วย 2 ระดับความนิยม (Popularity Classes) โดยใช้ค่า Median มัธยฐาน ค่ากลาง ของอัตราการมีส่วนร่วมเป็นเกณฑ์ ดังนี้:

1. ความนิยมต่ำ: ค่าต่ำกว่า มัธยฐาน
2. ความนิยมสูง: ค่าสูงกว่า มัธยฐาน

โดยทั่วไปแล้ว จะมีเพียงโพสต์ส่วนน้อยเท่านั้นที่ได้รับการมีส่วนร่วมสูงมาก ในกรณีเช่นนี้ ค่าเฉลี่ย Mean อาจได้รับอิทธิพลจากค่าผิดปกติ Outliers อย่างมีนัยสำคัญ ในขณะที่ค่ามัธยฐาน Median จะให้ค่ากลางที่มีความทนทานต่อค่าผิดปกติมากกว่า และเหมาะสมกว่าในการใช้แบ่งกลุ่มการมีส่วนร่วมระดับสูงและระดับต่ำ

หมายเหตุ : ชุดจำนวนข้อมูลเป็นเลขคู่ จึงไม่กำหนดว่า ค่ามัธยฐานนั้นเป็น ค่าความนิยมสูงหรือต่ำ

3.6 การประเมินผล

เพื่อให้สามารถประเมินประสิทธิภาพของแบบจำลอง งานวิจัยนี้ได้กำหนดวิธีการเปรียบเทียบกับค่าอ้างอิง (Baseline) ไว้ 2 แนวทาง

ประการแรก เนื่องจากข้อมูลถูกแปลงเป็นลักษณะทวิภาค (Binary Classification) โดยใช้ค่ามัธยฐาน (median) เป็นเกณฑ์ในการแบ่งคลาส ส่งผลให้จำนวนข้อมูลในแต่ละคลาสมีความสมดุล (Balanced Class Distribution) ดังนั้น ตัวจำแนกแบบสุ่ม (Random Classifier) จะมีค่าความแม่นยำคาดหวัง (Expected Accuracy) อยู่ที่ประมาณ 50% ซึ่งสามารถใช้เป็นค่าพื้นฐานในการเปรียบเทียบได้

ประการที่สอง คือการเลือกใช้แบบจำลอง Logistic Regression เป็น Baseline Model เนื่องจากเป็นแบบจำลองเชิงเส้นที่มีความเรียบง่ายและถูกใช้อย่างแพร่หลายในงานจำแนกประเภท ทำให้สามารถใช้เป็นจุดอ้างอิงในการเปรียบเทียบประสิทธิภาพกับแบบจำลองที่มีความซับซ้อนมากขึ้นได้อย่างเหมาะสม

Confusion Matrix จะถูกนำมาใช้เพื่อตรวจสอบความถูกต้อง เป็นเครื่องมือหลักในการวิเคราะห์ผลการจำแนกประเภท โดยมีวัตถุประสงค์เพื่อเปรียบเทียบผลลัพธ์ที่โมเดลทำนายกับค่าความเป็นจริงในชุดข้อมูลทดสอบ

การจำแนกในงานวิจัยนี้ถูกกำหนดเป็นแบบสองคลาส (Binary Classification) ได้แก่ ความนิยมต่ำ และ ความนิยมสูง โดยกำหนดให้

- ความนิยมสูง (High Popularity) หรือมี Engagement สูง แทนด้วยคลาส Positive
- ความนิยมต่ำ (Low Popularity) หรือมี Engagement ต่ำ แทนด้วยคลาส Negative

การเลือกใช้ตัวชี้วัดทั้งสี่ประการประกอบด้วยค่าความถูกต้อง (Accuracy), ค่าความแม่นยำ (Precision), ค่าความระลึก (Recall) และค่าความถ่วงดุล (F1 Score) ช่วยให้การประเมินแบบจำลองมีความครอบคลุมทั้งในมิติของความถูกต้องโดยรวม และความสามารถในการจัดการกับข้อมูลที่มีความไม่สมดุลระหว่างคลาส

ในการประเมินประสิทธิภาพของแบบจำลอง งานวิจัยนี้ใช้ตัวชี้วัดหลัก ได้แก่ Confusion Matrix และ ROC-AUC โดยค่า ROC-AUC ถูกนำมาใช้เพื่อประเมินความสามารถของแบบจำลองในการแยกแยะระหว่างคลาสในหลายระดับของค่าขีดแบ่ง (Threshold) ซึ่งช่วยให้สามารถเปรียบเทียบประสิทธิภาพของแบบจำลองได้อย่างครอบคลุม นอกจากนี้ยังมีการวิเคราะห์ความสำคัญของคุณลักษณะ (Feature Importance) จากบางแบบจำลองที่สามารถดึงข้อมูลออกมาได้ เพื่อใช้ในการตีความผลลัพธ์และระบุระดับการมีส่วนร่วมของคุณลักษณะเชิงภาพแต่ละตัวต่อผลลัพธ์ของการพยากรณ์

บทที่ 4

ผลการวิจัย

4.1 การออกแบบการทดลอง

งานวิจัยนี้มีเพื่อพัฒนา ประเมินและเปรียบเทียบ แบบจำลองการทำนายการมีส่วนร่วมของผู้ใช้งานต่อคลิปวิดีโอบนแพลตฟอร์ม TikTok ด้านอาหารและเครื่องดื่มในประเทศไทย จากคุณลักษณะวิดีโอ โดยใช้เทคนิคการเรียนรู้ของเครื่อง โดยพิจารณาการมีส่วนร่วมใน 3 รูปแบบ ได้แก่ การกดไลก์ (Like) การแชร์ (Share) และการแสดงความคิดเห็น (Comment)

การทดลองดำเนินการด้วยอัลกอริทึม 4 ประเภท ได้แก่ Support Vector Classifier (SVC), Random Forest, Light GBM และ Cat Boost โดยประเมินประสิทธิภาพด้วยตัวชี้วัด Accuracy, Precision, Recall และ F1-score

การทดลองในงานวิจัยนี้เป็นการจำแนกข้อมูลแบบสองคลาส โดยแบ่งระดับการมีส่วนร่วมออกเป็น คลาสที่ 0: ความนิยม (Low Engagement) และคลาสที่ 1: ความนิยมสูง (High Engagement) ตัวแบบได้รับการฝึกด้วยคุณลักษณะทางภาพ (Visual Features) ที่สกัดจากวิดีโอ ดังตารางที่ 3.1 การประเมินผลใช้ตัวชี้วัดดังต่อไปนี้: ค่าความถูกต้อง (Accuracy) ค่าความแม่นยำ (Precision) ค่าความระลึก (Recall) ค่าความถ่วงดุล (F1 Score)

งานวิจัยนี้แบ่งข้อมูลออกเป็นชุดฝึกสอนร้อยละ 70 ชุดตรวจสอบความถูกต้อง (Validation Set) ร้อยละ 10 และชุดทดสอบร้อยละ 20 โดยชุดทดสอบถูกกันออกตั้งแต่ต้นและไม่ถูกนำไปใช้ในขั้นตอนการปรับปรุงพารามิเตอร์

4.2 ผลการทดลองจำแนกตามประเภทการมีส่วนร่วม

4.2.1 ผลการทำนายการกดไลก์ (Like)

ตารางที่ 4.1 ผลการประเมินประสิทธิภาพของการกดไลก์ (Like) แบบ Confusion Matrix

ค่าจากการทำนายของแบบจำลอง		ค่าที่เกิดขึ้นจริง	
		สูง	ต่ำ
SVC	สูง	61	19
	ต่ำ	39	81
Light GBM	สูง	60	15
	ต่ำ	40	85

ตารางที่ 4.1 ผลการประเมินประสิทธิภาพของการกดไลค์ (Like) แบบ Confusion Matrix (ต่อ)

ค่าจากการทำนายของแบบจำลอง		ค่าที่เกิดขึ้นจริง	
		สูง	ต่ำ
Random Forest	สูง	65	24
	ต่ำ	35	76
CatBoost	สูง	62	15
	ต่ำ	38	85
Logistic Regression	สูง	65	21
	ต่ำ	35	79

จากตารางที่ 4.1 แสดงผลการจำแนกระดับความนิยมของวิดีโอ (ต่ำ/สูง) ด้วยแบบจำลอง SVC, LightGBM, Random Forest, CatBoost และ Logistic Regression (Baseline) ในรูปแบบ Confusion Matrix โดยแสดงจำนวนตัวอย่างที่ทำนายถูกต้องและทำนายคลาดเคลื่อนในแต่ละคลาส

จากผลการทดลองพบว่า แบบจำลองส่วนใหญ่สามารถจำแนกคลาส “ต่ำ” ได้ค่อนข้างแม่นยำ โดย LightGBM และ CatBoost ทำนายคลาดต่ำถูกต้อง 0.85 แต่ในสำหรับคลาส “สูง” พบว่า Random Forest และ Logistic Regression ทำนายถูกต้อง 0.65 ทำให้เห็นว่า ระบบจำแนกคลาส “ต่ำ” ได้ค่อนข้างแม่นยำกว่าคลาส “สูง”

ทั้งนี้ พบว่าทุกแบบจำลองมีแนวโน้มสับสนระหว่างคลาสต่ำและคลาสสูงในระดับใกล้เคียงกัน ซึ่งสะท้อนถึงความท้าทายในการจำแนกระดับความนิยมจากคุณลักษณะทางภาพเพียงอย่างเดียว และไม่มีแบบจำลองใดที่มีความเหนือกว่าอย่างชัดเจนในทุกมิติของการจำแนก

ตารางที่ 4.2 ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการทำนายการกดไลค์ (Like)

โมเดล	คลาส	Accuracy	Precision	Recall	F1-score
SVC	สูง	0.7100	0.7625	0.6100	0.6778
	ต่ำ	0.7100	0.6750	0.8100	0.7364
Light GBM	สูง	0.7250	0.8000	0.6000	0.6857
	ต่ำ	0.7250	0.6800	0.8500	0.7556
Random Forest	สูง	0.7050	0.7303	0.6500	0.6878
	ต่ำ	0.7050	0.6847	0.7600	0.7204

ตารางที่ 4.2 ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการทำนายการกดไลค์ (Like) (ต่อ)

โมเดล	คลาส	Accuracy	Precision	Recall	F1-score
CatBoost	สูง	0.7350	0.8052	0.6200	0.7006
	ต่ำ	0.7350	0.6911	0.8500	0.7623
Logistic Regression	สูง	0.7200	0.7558	0.6500	0.6989
	ต่ำ	0.7200	0.6930	0.7900	0.7383

จากตารางที่ 4.2 แสดงผลการเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในการทำนายการกดไลค์ (Like) โดยประเมินด้วยค่า Accuracy, Precision, Recall และ F1-Score บนชุดข้อมูลทดสอบ ผลการทดลองพบว่า ความแตกต่างของค่าประสิทธิภาพระหว่างแบบจำลอง ไม่ได้สูงมากนัก ค่า Accuracy ต่างกันสูงสุดเพียง 3% และไม่ได้มีประสิทธิภาพเหนือกว่าแบบจำลองอ้างอิงหรือ Logistic Regression (Baseline) ชัดเจนมากนัก โดยรวม CatBoost เป็นโมเดลที่ดีมีประสิทธิภาพโดยรวมสูงสุดเพราะมีค่าประสิทธิภาพสูงสุด Accuracy ที่อยู่ในช่วง 0.7100-0.7350 สะท้อนว่าแบบจำลองสามารถจำแนกระดับการกดถูกใจได้ในระดับปานกลาง

4.2.2 ผลการทำนายการแชร์ (Share)

ตารางที่ 4.3 ผลการประเมินประสิทธิภาพของการแชร์ (Share) แบบ Confusion Matrix

ค่าจากการทำนายของแบบจำลอง		ค่าที่เกิดขึ้นจริง	
		สูง	ต่ำ
SVC	สูง	59	22
	ต่ำ	41	78
Light GBM	สูง	59	23
	ต่ำ	41	77
Random Forest	สูง	61	24
	ต่ำ	39	76
CatBoost	สูง	66	28
	ต่ำ	34	72
Logistic Regression	สูง	68	28
	ต่ำ	32	72

จากตารางที่ 4.3 แสดงผลการจำแนกประสิทธิภาพของการแชร์ (Share) ของวิดีโอ (ต่ำ/สูง) ด้วยแบบจำลอง SVC, LightGBM, Random Forest, CatBoost และ Logistic Regression (Baseline) ในรูปแบบ Confusion Matrix โดยแสดงจำนวนตัวอย่างที่ทำนายถูกต้องและทำนายคลาดเคลื่อนในแต่ละคลาส

จากผลการทดลองพบว่า แบบจำลองส่วนใหญ่สามารถจำแนกคลาส “ต่ำ” ได้แม่นยำกว่าคลาส “สูง” โดย SVC ทำนายคลาสต่ำถูกต้อง 0.78 สำหรับคลาส “สูง” พบว่า Logistic Regression ทำนายถูกต้อง 0.68 จากตารางที่ 4.3 พบว่าทุกแบบจำลองมีแนวโน้มสับสนระหว่างคลาสต่ำและคลาสสูงในระดับใกล้เคียงกัน

ตารางที่ 4.4 ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการทำนายการแชร์ (Share)

โมเดล	คลาส	Accuracy	Precision	Recall	F1-score
SVC	สูง	0.6850	0.7284	0.5900	0.6519
	ต่ำ	0.6850	0.6555	0.7800	0.7123
Light GBM	สูง	0.6800	0.7195	0.5900	0.6483
	ต่ำ	0.6800	0.6525	0.7700	0.7064
Random Forest	สูง	0.6850	0.7176	0.6100	0.6594
	ต่ำ	0.6850	0.6609	0.7600	0.7069
CatBoost	สูง	0.6900	0.7021	0.6600	0.6804
	ต่ำ	0.6900	0.6792	0.7200	0.6990
Logistic Regression	สูง	0.7000	0.7083	0.6800	0.6939
	ต่ำ	0.7000	0.6923	0.7200	0.7059

จากตารางที่ 4.4 แสดงผลการเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในการทำนายการแชร์ (Share) โดยประเมินด้วยค่า Accuracy, Precision, Recall และ F1-score บนชุดข้อมูลทดสอบ ผลการทดลองพบว่า ความแตกต่างของค่าประสิทธิภาพระหว่างแบบจำลองไม่ได้สูงมากนัก โดยค่า Accuracy ของแต่ละแบบจำลองอยู่ในช่วง 0.6800–0.7000 ซึ่งมีความแตกต่างสูงสุดประมาณ 3% Logistic Regression เป็นโมเดลที่มีค่า Accuracy สูงสุดที่ 0.7000 และประสิทธิภาพโดยรวมสูงสุด เมื่อเทียบกับการทำนายการกดไลก์ (Like) การทำนายการแชร์ (Share) มี Accuracy สูงสุดต่ำกว่า 0.0350

4.2.3 ผลการทำนายการการแสดงความคิดเห็น (Comment)

ตารางที่ 4.5 ผลการประเมินประสิทธิภาพของแสดงความคิดเห็น (Comment) แบบ Confusion Matrix

ค่าจากการทำนายของแบบจำลอง		ค่าที่เกิดขึ้นจริง	
		สูง	ต่ำ
SVC	สูง	61	47
	ต่ำ	39	53
Light GBM	สูง	60	41
	ต่ำ	40	59
Random Forest	สูง	55	47
	ต่ำ	45	53
CatBoost	สูง	59	41
	ต่ำ	41	59
Logistic Regression	สูง	61	42
	ต่ำ	39	58

จากตารางที่ 4.5 แสดงผลการจำแนกระดับความนิยมของวิดีโอ (ต่ำ/สูง) สำหรับการทำนายการแสดงความคิดเห็น โดยนำเสนอในรูปแบบ Confusion Matrix ของแบบจำลอง SVC, LightGBM, Random Forest, CatBoost และ Logistic Regression (Baseline) เพื่อแสดงจำนวนตัวอย่างที่ทำนายถูกต้องและคลาดเคลื่อนในแต่ละคลาส

จากผลการทดลองพบว่า Light GBM และ CatBoost แบบจำลอง สามารถจำแนกคลาส “ต่ำ” ได้ถูกต้องมากที่สุดจำนวน 0.59 ในส่วนของคลาส “สูง” พบว่า SVC และ Logistic Regression ให้จำนวนการทำนายถูกต้องสูงสุดที่ 0.61 อย่างไรก็ตาม ความแตกต่างของจำนวนการทำนายถูกต้องในแต่ละแบบจำลองอยู่ในช่วงใกล้เคียงกัน

ตารางที่ 4.6 ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการแสดงความคิดเห็น (Comment)

โมเดล	คลาส	Accuracy	Precision	Recall	F1-score
SVC	สูง	0.5700	0.5648	0.6100	0.5865
	ต่ำ	0.5700	0.5761	0.5300	0.5521
Light GBM	สูง	0.5950	0.5941	0.6000	0.5970
	ต่ำ	0.5950	0.5960	0.5900	0.5930
Random Forest	สูง	0.5400	0.5392	0.5500	0.5445
	ต่ำ	0.5400	0.5408	0.5300	0.5353
CatBoost	สูง	0.5900	0.5900	0.5900	0.5900
	ต่ำ	0.5900	0.5900	0.5900	0.5900
Logistic Regression	สูง	0.5950	0.5922	0.6100	0.6010
	ต่ำ	0.5950	0.5979	0.5800	0.5888

จากตารางที่ 4.6 แสดงผลการเปรียบเทียบประสิทธิภาพของแบบจำลองการเรียนรู้ของเครื่องในการทำนายการแสดงความคิดเห็น (Comment) โดยประเมินด้วยค่า Accuracy, Precision, Recall และ F1-score บนชุดข้อมูลทดสอบ ผลการทดลองพบว่า ค่าประสิทธิภาพของแบบจำลองโดยรวมค่อนข้างต่ำเมื่อเทียบกับการทำนายการกดไลก์และการแชร์ โดยค่า Accuracy ของแต่ละแบบจำลองอยู่ในช่วง 0.5400–0.5950 ซึ่งมีความแตกต่างสูงสุดประมาณ 5.5% โดยรวม LightGBM และ Logistic Regression เป็นโมเดลที่มีประสิทธิภาพดีที่สุด จากผลลัพธ์ดังกล่าวสะท้อนว่า การทำนายการแสดงความคิดเห็นจากคุณลักษณะทางภาพเพียงอย่างเดียวมีความท้าทายมากกว่าการทำนายการกดไลก์และการแชร์ ทำให้ประสิทธิภาพของแบบจำลองอยู่ในระดับค่อนข้างต่ำเมื่อเปรียบเทียบกับตัวชี้วัดอื่นในงานวิจัยนี้

4.3 ผลการทดลองด้วยค่า Accuracy และ ROC-AUC

เพื่อให้เห็นภาพรวมของความสามารถในการจำแนกระดับการมีส่วนร่วมได้ชัดเจนยิ่งขึ้น นอกเหนือจากค่าความถูกต้อง (Accuracy) งานวิจัยนี้จึงได้นำค่าพื้นที่ใต้กราฟ ROC (ROC-AUC) มาใช้ในการประเมิน เนื่องจากเป็นตัวชี้วัดที่สะท้อนถึงความน่าจะเป็นที่แบบจำลองจะจัดอันดับตัวอย่างที่มีความนิยมสูง (Positive) ได้ถูกต้องกว่าตัวอย่างที่มีความนิยมต่ำ (Negative) ในทุกระดับของค่าขีดแบ่ง (Threshold)

ตารางที่ 4.7 การเปรียบเทียบประสิทธิภาพของแบบจำลองด้วยค่า Accuracy และ ROC-AUC ในการทำนายการกดไลก์ การแชร์ และการแสดงความคิดเห็น

Model	Like	Share	Comment
Logistic Regression	0.7200/0.7791	0.7000/0.7722	0.5950/0.6504
SVC	0.7100/0.7716	0.6850/0.7819	0.5700/0.6454
Random Forest	0.7050/0.7392	0.6850/0.7586	0.5400/0.5951
Light GBM	0.7250/0.7967	0.6500/0.6892	0.5950/0.6188
Cat Boost	0.7350/0.7825	0.6900/0.7844	0.5900/0.6436

หมายเหตุ : ค่าที่แสดงคือ Accuracy/ROC-AUC

ROC-AUC ในการจำแนกการกดไลก์ (Like): แบบจำลอง LightGBM แสดงศักยภาพในการแยกแยะคลาสได้ดีที่สุด โดยมีค่า ROC-AUC สูงถึง 0.7967 ซึ่งเข้าใกล้ระดับ 0.80 สะท้อนว่าคุณลักษณะทางภาพที่สกัดมานั้นมีความสัมพันธ์เชิงโครงสร้างที่ชัดเจนเพียงพอให้อัลกอริทึมกลุ่ม Gradient Boosting สามารถเรียนรู้และแบ่งแยกกลุ่มวิดีโอที่ได้รับความนิยมในแง่ของการกดไลก์ได้อย่างมีประสิทธิภาพ

ROC-AUC ในการจำแนกการแชร์ (Share): ในด้านการแชร์ แบบจำลอง CatBoost และ SVC ให้ค่า ROC-AUC ที่โดดเด่นใกล้เคียงกันคือ 0.7844 และ 0.7819 ตามลำดับ แสดงให้เห็นว่าทั้งสองอัลกอริทึมมีกลไกในการจัดการกับคุณลักษณะเชิงซับซ้อน (Non-linear) ได้ดี โดย SVC ใช้หลักการของเส้นแบ่งหลายมิติ (Hyperplane) ขณะที่ CatBoost ใช้การสุ่มลำดับเพื่อลดความเอนเอียง ทำให้มีความสามารถในการตรวจจับวิดีโอที่มีแนวโน้มจะถูกแชร์ได้แม่นยำกว่าการสุ่มเดาอย่างมีนัยสำคัญ

ROC-AUC ในการจำแนกการแสดงความคิดเห็น (Comment): เป็นที่น่าสังเกตว่าค่า ROC-AUC ในการทำนายความคิดเห็นของทุกแบบจำลองลดต่ำลงมาอยู่ในช่วง 0.59-0.65 โดยมี Logistic Regression เป็นแบบจำลองที่ให้ค่าสูงสุดที่ 0.6504 ประสิทธิภาพที่ลดลงนี้ชี้ให้เห็นว่าคุณลักษณะทางภาพเพียงมิติเดียวไม่เพียงพอต่อการแยกแยะคลาสความนิยมในแง่ของคอมเมนต์ได้ชัดเจนเท่ากับการไลก์หรือแชร์

การเปรียบเทียบในภาพรวมเมื่อพิจารณาค่า ROC-AUC ในทุกภารกิจ พบว่าอัลกอริทึมกลุ่ม Boosting (LightGBM และ CatBoost) มีความโดดเด่นในข้อมูลที่มีการมีส่วนร่วมสูง (Like และ Share) ขณะที่ Logistic Regression แม้จะเป็นแบบจำลองพื้นฐานแต่กลับมีความสามารถในการแยกแยะได้เสถียรที่สุดในภารกิจที่ซับซ้อนอย่าง Comment

4.4 การวิเคราะห์ความสำคัญของคุณลักษณะทางภาพ

ในส่วนนี้เป็นการวิเคราะห์เพื่อระบุว่าคุณลักษณะทางภาพ (Visual Features) ตัวใดมีอิทธิพลต่อการพยากรณ์การมีส่วนร่วมในแต่ละประเภทมากที่สุด โดยพิจารณาจากแบบจำลองที่ให้ประสิทธิภาพสูงสุดในแต่ละภารกิจ ได้แก่ แบบจำลอง CatBoost สำหรับการทำนายการกดไลค์ (Like), แบบจำลอง Logistic Regression สำหรับการทำนายการแชร์ (Share) และแบบจำลอง LightGBM สำหรับการทำนายการแสดงความคิดเห็น (Comment)

ตารางที่ 4.8 ลำดับความสำคัญของคุณลักษณะทางภาพ 5 อันดับแรก

Rank	Like	Share	Comment
1	Brightness (50.04%)	Dessert (15.62%)	Food (13.76%)
2	Colorfulness (26.33%)	Food (15.61%)	Contrast (10.07%)
3	Logo (11.96%)	Contrast (12.77%)	Brightness (8.60%)
4	Dessert (4.00%)	Promotion (6.52%)	Dessert (8.56%)
5	Face (2.43%)	Packaging (6.21%)	Beverage (8.02%)

จากผลการทดลองในตารางที่ 4.8 สามารถสรุปประเด็นสำคัญเกี่ยวกับอิทธิพลของคุณลักษณะทางภาพต่อการพยากรณ์การมีส่วนร่วมของผู้ใช้งานได้ดังนี้:

ความสำคัญของคุณลักษณะทางภาพต่อการกดไลค์ (Like): คุณลักษณะทางภาพระดับต่ำ (Low-Level Features) โดยเฉพาะความสว่าง (50.04%) และสีสดใส (26.33%) มีบทบาทสำคัญอย่างยิ่งต่อการพยากรณ์ ซึ่งสอดคล้องกับทฤษฎีการสื่อสารทางภาพที่ระบุว่าสีและความสว่างสามารถดึงดูดความสนใจทางสายตาของผู้ใช้ได้ในระยะเวลานับวินาที นอกจากนี้ การปรากฏของโลโก้ (11.96%) ยังเป็นคุณลักษณะระดับสูงที่มีอิทธิพลลำดับต้นๆ ซึ่งอาจสะท้อนถึงผลกระทบจากการรับรู้แบรนด์ (Brand Recognition) ต่อการตัดสินใจของผู้บริโภค

ความสำคัญของคุณลักษณะทางภาพต่อการแชร์ (Share): แม้คุณลักษณะระดับต่ำอย่างคอนทราสต์ยังคงมีความสำคัญ แต่ปัจจัยที่เกี่ยวข้องกับเนื้อหาโดยตรง (Content-Related Attributes) กลับมีบทบาทโดดเด่นขึ้นอย่างชัดเจน โดยเฉพาะประเภทของอาหารอย่างของหวาน (15.62%) และอาหารทั่วไป (15.61%) ซึ่งอาจสัมพันธ์กับความน่ารับประทานที่กระตุ้นให้ผู้ชมต้องการส่งต่อเนื้อหา นอกจากนี้ องค์ประกอบเชิงข้อมูล เช่น ข้อความราคา/โปรโมชั่น และบรรจุภัณฑ์ ยังติดอันดับปัจจัยสำคัญ ซึ่งชี้ให้เห็นว่าผู้ใช้งานมีแนวโน้มที่จะแชร์วิดีโอที่มีข้อมูลที่เป็นประโยชน์หรือมีความคุ้มค่าเชิงพาณิชย์

ความสำคัญของคุณลักษณะทางภาพต่อการแสดงความคิดเห็น (Comment): ผลลัพธ์แสดงให้เห็นว่าการทำนายการแสดงความคิดเห็นได้รับอิทธิพลจากปัจจัยที่หลากหลายและกระจายตัวมากขึ้น โดยมีคุณลักษณะด้านประเภทอาหาร (13.76%) เป็นปัจจัยอันดับหนึ่ง ตามด้วยคอนทราสต์และความสว่าง เป็นที่น่าสังเกตว่าคุณลักษณะด้านเครื่องดื่ม (8.02%) ปรากฏเป็นปัจจัยสำคัญเฉพาะในการกิจนี้ ซึ่งสะท้อนว่าประเภทของอาหารและเครื่องดื่มที่แตกต่างกันมีผลต่อระดับการกระตุ้นให้เกิดบทสนทนา หรือการแสดงความคิดเห็นที่แตกต่างกันไปตามความสนใจของผู้ใช้งาน

โดยสรุป คุณลักษณะทางภาพระดับต่ำ (Low-Level Features) และการปรากฏของโลโก้ มีบทบาทสำคัญอย่างยิ่งในการทำนายการกดไลก์ และแม้ว่าคุณลักษณะทางภาพจะยังคงมีความสำคัญต่อการทำนายการแชร์ และการแสดงความคิดเห็น แต่ปัจจัยที่เกี่ยวข้องกับเนื้อหา เช่น ประเภทของอาหาร และเครื่องดื่ม ก็มีส่วนช่วยในการทำนายอย่างมีนัยสำคัญเช่นกัน



TNI

บทที่ 5

บทสรุป อภิปราย และข้อเสนอแนะ

5.1 สรุปผลการวิจัย

วิทยานิพนธ์ฉบับนี้มีวัตถุประสงค์เพื่อพัฒนาและประเมินแบบจำลองสำหรับพยากรณ์ระดับการมีส่วนร่วม (Engagement) ของวิดีโอบนแพลตฟอร์ม TikTok โดยอาศัยคุณลักษณะเชิงปริมาณที่สกัดจากองค์ประกอบทางภาพเป็นตัวแปรอิสระ ปัญหาถูกกำหนดให้อยู่ในรูปแบบการจำแนกประเภทแบบสองคลาส ได้แก่ ระดับต่ำและระดับสูง ครอบคลุมตัวชี้วัด 3 ด้าน คือ จำนวนการกดไลก์ (Like) การแชร์ (Share) และการแสดงความคิดเห็น (Comment)

กลุ่มตัวอย่างประกอบด้วยวิดีโอจำนวน 1,000 คลิป จาก 50 บัญชี TikTok ประเภทอาหารและเครื่องดื่มในประเทศไทย ซึ่งมีจำนวนผู้ติดตามอยู่ระหว่าง 10,000-50,000 คน มีการสกัดคุณลักษณะทางภาพทั้งระดับต่ำ เช่น สีและความคอนทราสต์ และระดับสูง เช่น จำนวนเมนูอาหาร การปรากฏของใบหน้า เพศ โลโก้ และข้อความส่งเสริมการขาย จากนั้นคำนวณอัตราการมีส่วนร่วม (Engagement Rate) ของแต่ละตัวชี้วัด เพื่อใช้เป็นเกณฑ์ในการจัดกลุ่มระดับความนิยม

แบบจำลองที่นำมาทดลอง ได้แก่ Random Forest, Support Vector Classifier (SVC), LightGBM CatBoost และ Logistic Regression (Baseline) โดยใช้การแบ่งข้อมูลเป็นชุดฝึก ชุดตรวจสอบ และชุดทดสอบ และประเมินผลด้วยตัวชี้วัด ได้แก่ Accuracy, Precision, Recall, F1-score, ROC-AUC และ Feature Importance

ผลการทดลองพบว่า ความสามารถในการทำนายเรียงลำดับจากสูงไปต่ำคือการกดไลก์ (Like), การแชร์ (Share) และการแสดงความคิดเห็น (Comment) โดยพิจารณาจากค่าความถูกต้อง (Accuracy) สูงสุดของโมเดลในชุดทดสอบ ได้แก่ Like เท่ากับ 0.7350, Share เท่ากับ 0.7000 และ Comment เท่ากับ 0.5950 สะท้อนให้เห็นว่าคุณลักษณะทางภาพสามารถอธิบายความแปรปรวนของพฤติกรรมการกดถูกใจได้ดีกว่าการแสดงความคิดเห็น

ในด้านการเปรียบเทียบอัลกอริทึม พบว่ากลุ่ม Gradient Boosting มีความโดดเด่นในตัวชี้วัด Like โดย CatBoost ให้ค่า Accuracy สูงสุด (0.7350) สำหรับตัวชี้วัด Share พบว่าแบบจำลองพื้นฐานอย่าง Logistic Regression กลับให้ผลดีที่สุด (0.7000) ส่วน Comment ให้ผลดีที่สุทธ่วมกันระหว่าง LightGBM และ Logistic Regression (0.5950) ทั้งนี้ ความแตกต่างของ Accuracy ระหว่างโมเดลที่ทำผลงานได้ดีที่สุดและต่ำที่สุดคือ 3% สำหรับ Like, 2% สำหรับ Share และ 5.50% สำหรับ Comment ซึ่งแสดงถึงความไม่เสถียรในการทำนายการแสดงความคิดเห็น

เมื่อพิจารณาประสิทธิภาพผ่านค่าพื้นที่ใต้กราฟ (ROC-AUC) เพื่อประเมินความสามารถในการแยกแยะคลาส พบว่าแบบจำลองมีประสิทธิภาพสูงในด้าน Like (สูงสุด 0.7967 โดย LightGBM) และ Share (สูงสุด 0.7844 โดย CatBoost) ซึ่งเข้าใกล้ระดับ 0.80 ในขณะที่การแสดงความคิดเห็นมีค่า ROC-AUC ต่ำกว่าอย่างชัดเจน (สูงสุด 0.6504 โดย Logistic Regression) ยืนยันว่าคุณลักษณะทางภาพเพียงมิติเดียวไม่เพียงพอต่อการแยกแยะระดับความนิยมในแง่ของคอมเมนต์

สำหรับการวิเคราะห์ความสำคัญของคุณลักษณะ (Feature Importance) พบว่าปัจจัยทางภาพระดับต่ำ (Low-level features) เช่น ความสว่าง (50.04%) และสีสันสดใส (26.33%) มีอิทธิพลสูงสุดต่อการกดไลค์ ส่วนการแชร์จะให้ความสำคัญกับประเภทเนื้อหาอาหาร เช่น ของหวาน (15.62%) และอาหารทั่วไป (15.61%) รวมถึงข้อมูลโปรโมชัน ขณะที่การแสดงความคิดเห็นได้รับอิทธิพลจากประเภทอาหารและเครื่องดื่มเป็นหลัก

เมื่อพิจารณาจาก Confusion Matrix พบว่าแบบจำลองส่วนใหญ่จำแนกคลาส “ต่ำ” ได้แม่นยำกว่าคลาส “สูง” โดยในตัวชี้วัด Like แบบจำลอง LightGBM และ CatBoost จำแนกคลาสต่ำได้ถูกต้องสูงสุดถึง 0.85 สำหรับ Share แบบจำลอง SVC จำแนกคลาสต่ำได้ถูกต้องสูงสุดที่ 0.78 ขณะที่คลาสสูงของ Share แบบจำลอง Logistic Regression สามารถทำนายได้ถูกต้องสูงสุดที่ 0.68 ในส่วนของ Comment โมเดลมีความสามารถในการจำแนกทั้งสองคลาสในระดับที่ใกล้เคียงกันและค่อนข้างจำกัด (สูงสุดที่ 0.61)

โดยสรุป ผลการวิจัยชี้ให้เห็นว่า องค์ประกอบทางภาพมีศักยภาพในการใช้พยากรณ์การมีส่วนร่วมประเภท Like และ Share ได้ในระดับปานกลาง ขณะที่การพยากรณ์ Comment มีความซับซ้อนสูงกว่าและอาจได้รับอิทธิพลจากปัจจัยที่อยู่นอกเหนือจากองค์ประกอบทางภาพเพียงอย่างเดียว

5.2 อภิปรายผล

5.2.1 ความแตกต่างของระดับ Engagement ตามลักษณะพฤติกรรมผู้ใช้งาน

ผลการวิจัยแสดงให้เห็นว่าการทำนายการกดถูกใจให้ผลลัพธ์สูงสุด รองลงมาคือการแชร์ และต่ำที่สุดคือการแสดงความคิดเห็น สะท้อนถึงความแตกต่างในธรรมชาติของพฤติกรรมผู้ใช้งาน ซึ่งสอดคล้องกับกรอบทฤษฎีที่มอง engagement เป็น “กิจกรรมคนละระดับความพยายาม” โดย Like เป็นกิจกรรมต้นทุนต่ำ และ Comment เป็นกิจกรรมที่ต้องใช้การมีส่วนร่วมเชิงความหมายมากกว่าใช้ความพยายามสูงกว่า และมักเกี่ยวข้องกับปัจจัยด้านเนื้อหา บริบท อารมณ์ หรือความคิดเห็นส่วนบุคคล ซึ่งอาจไม่สามารถอธิบายได้ด้วยคุณลักษณะทางภาพเพียงอย่างเดียว

5.2.2 การอภิปรายด้านประสิทธิภาพของแบบจำลองและข้อจำกัดของตัวแปรนำเข้า

จากการทดลองพบว่าแบบจำลองที่มีสถาปัตยกรรมแตกต่างกันอย่างสิ้นเชิง ตั้งแต่แบบจำลองเชิงเส้นที่มีความซับซ้อนต่ำอย่าง Logistic Regression ไปจนถึงแบบจำลองกลุ่ม Boosting ที่มีสถาปัตยกรรมซับซ้อนสูง กลับให้ค่าประสิทธิภาพทั้งในด้าน Accuracy และ ROC-AUC ในระดับที่ใกล้เคียงกันอย่างมีนัยสำคัญ สถานะการอิมิตของประสิทธิภาพ นี้ชี้ให้เห็นว่า ภายใต้โครงสร้างข้อมูลชุดเดียวกัน การเลือกหรือเปลี่ยนประเภทของอัลกอริทึมไม่ได้เป็นปัจจัยหลัก ที่จะช่วยยกระดับความแม่นยำให้สูงขึ้นอย่างก้าวกระโดดได้ในงานวิจัยนี้ การผลักดันประสิทธิภาพการทำนายให้สูงขึ้นในอนาคต ไม่ได้ขึ้นอยู่กับ การแสวงหาอัลกอริทึมที่ซับซ้อนยิ่งขึ้น แต่ต้องอาศัยการออกแบบคุณลักษณะทางภาพให้มีประสิทธิภาพหรือให้มีความเป็น Multimodal มากขึ้น

5.2.3 ความไม่สมมาตรในการจำแนกคลาสต่ำและคลาสสูง

ผลการที่แบบจำลองสามารถจำแนกระดับการมีส่วนร่วมประเภท Like และ Share ในกลุ่มคลาสต่ำได้แม่นยำกว่าคลาสสูง อาจสะท้อนให้เห็นว่า องค์ประกอบทางภาพที่มีคุณภาพต่ำหรือขาดความโดดเด่น มักสัมพันธ์กับระดับการมีส่วนร่วมที่ต่ำอย่างสม่ำเสมอ กล่าวคือ เมื่อคุณลักษณะเชิงภาพไม่ดึงดูดหรือไม่สอดคล้องกับความคาดหวังของผู้ชม ความน่าจะเป็นในการเกิดปฏิสัมพันธ์ย่อมลดลงอย่างชัดเจน ในทางกลับกันการที่วิดีโอมีองค์ประกอบทางภาพที่ดีหรือมีคุณภาพสูง มิได้หมายความว่าส่งผลให้เกิดการมีส่วนร่วมในระดับสูงโดยอัตโนมัติ ทั้งนี้เนื่องจากพฤติกรรมการมีส่วนร่วมบนแพลตฟอร์ม TikTok อาจได้รับอิทธิพลจากปัจจัยอื่นร่วมด้วย เช่น ปัจจัยทางเสียง ความนิยมของบัญชี จังหวะเวลาในการเผยแพร่ กระแสสังคม หรือบริบทของเนื้อหา ซึ่งอยู่นอกเหนือขอบเขตขององค์ประกอบทางภาพเพียงอย่างเดียว ดังนั้น ผลการวิจัยนี้ชี้ให้เห็นว่าการมีส่วนร่วมบนแพลตฟอร์ม TikTok ไม่ได้ขึ้นอยู่กับองค์ประกอบทางภาพเพียงอย่างเดียว แต่มีความซับซ้อนและเกี่ยวข้องกับหลายมิติของการสื่อสารดิจิทัล

5.2.4 ความสำคัญของฟีเจอร์ในเชิงแบบจำลองและการตีความเชิงพรรณนา

คุณลักษณะทางภาพระดับต่ำและการปรากฏของโลโก้มีบทบาทสำคัญอย่างยิ่งในการทำนายการกดไลค์ โดยเฉพาะค่าความสว่างและสีที่สดใสซึ่งเป็นปัจจัยที่มีอิทธิพลสูงสุดสอดคล้องกับทฤษฎีการสื่อสารทางภาพที่ระบุว่าสิ่งเร้าทางภาพสามารถดึงดูดความสนใจและกระตุ้นการตอบสนองของผู้ใช้งานได้อย่างรวดเร็ว ในทางตรงกันข้าม แม้คุณลักษณะทางภาพจะยังคงมีความสำคัญต่อการทำนายการแชร์และการแสดงความคิดเห็น แต่ปัจจัยที่เกี่ยวข้องกับเนื้อหาโดยตรง เช่น ประเภทของอาหารและเครื่องดื่ม กลับมีส่วนช่วยในการทำนายอย่างมีนัยสำคัญมากกว่า ซึ่งสะท้อนให้เห็นว่าพฤติกรรมการมีส่วนร่วมที่ต้องใช้ความพยายามสูงกว่า เช่น การแชร์หรือการแสดงความคิดเห็น มักเกี่ยวข้องกับการประเมินคุณค่าของเนื้อหาและบริบทที่นอกเหนือไปจากองค์ประกอบความสวยงามเพียงอย่างเดียว นอกจากนี้

การที่โลโก้เป็นหนึ่งในปัจจัยหลักของการจดโลกซ์ให้เห็นว่าการรับรู้ถึงอัตลักษณ์ของแบรนด์มีผลต่อการตัดสินใจมีส่วนร่วมของผู้ใช้งาน

5.2.5 การตีความเชิงพรรณนาของการเปรียบเทียบข้อมูล

จากการวิเคราะห์เชิงสำรวจ ผู้วิจัยได้ทำการพิจารณาผลรวมของจำนวนการปรากฏของแต่ละคุณลักษณะทางภาพ และเปรียบเทียบระหว่างกลุ่มวิดีโอที่มีการมีส่วนร่วมต่ำและสูง เพื่อระบุรูปแบบความแตกต่างในระดับเบื้องต้น ผลการวิเคราะห์พบว่า คุณลักษณะบางประเภท เช่น สีสดใส (Colorfulness), ความสว่าง (Brightness) และคอนทราสต์ (Contrast) รวมถึงองค์ประกอบเชิงข้อมูล เช่น ข้อความรีวิว ราคา โปรโมชั่น และการปรากฏของโลโก้ มีแนวโน้มปรากฏในวิดีโอที่มีการมีส่วนร่วมสูงมากกว่า

ในกรณีของการปรากฏของโลโก้ พบข้อสังเกตเพิ่มเติมว่า ความเป็นที่รู้จักของแบรนด์อาจมีความเกี่ยวข้องกับระดับการมีส่วนร่วม โดยบัญชีที่เป็นแบรนด์ขนาดใหญ่ เช่น starbucksthailand มีการปรากฏของโลโก้ในวิดีโอที่มีความนิยมสูงในสัดส่วนที่สูง (18 จาก 19 วิดีโอ) และแนวโน้มลักษณะเดียวกันยังพบในบัญชี pizzahut1150_th และ burgerkingthai ซึ่งมีสัดส่วนวิดีโอที่มีโลโก้และได้รับความนิยมสูงอยู่ที่ประมาณ 94% และ 90% ตามลำดับ ในขณะที่บัญชีขนาดเล็ก เช่น bianca.bangkok, padthaijaetum และ ronin.pizza มีสัดส่วนดังกล่าวต่ำกว่ามาก ซึ่งอาจสะท้อนถึงบทบาทของ brand recognition ต่อพฤติกรรมการมีส่วนร่วมของผู้ใช้งาน

อย่างไรก็ตาม การวิเคราะห์ในลักษณะนี้เป็นเพียงการตีความเชิงพรรณนา (Descriptive Analysis) ซึ่งสะท้อนความแตกต่างของการกระจายตัวของฟีเจอร์ระหว่างกลุ่มข้อมูลเท่านั้น และไม่สามารถสรุปได้โดยตรงว่าเป็นปัจจัยเชิงสาเหตุที่ส่งผลต่อการเพิ่มขึ้นของการมีส่วนร่วม เนื่องจากไม่ได้พิจารณาความสัมพันธ์ร่วมระหว่างหลายตัวแปรพร้อมกัน

นอกจากนี้ แบบจำลองการเรียนรู้ของเครื่องจะประเมินความสำคัญของฟีเจอร์ภายใต้บริบทของตัวแปรทั้งหมด ซึ่งอาจทำให้ฟีเจอร์ที่มีความแตกต่างสูงในเชิงผลรวม มีบทบาทลดลงเมื่ออยู่ร่วมกับตัวแปรอื่น อีกทั้ง ความสัมพันธ์ที่สังเกตได้อาจได้รับอิทธิพลจากตัวแปรแฝง เช่น รูปแบบคอนเทนต์ ความนิยมของเสียงเพลง หรือบริบทของวิดีโอ ซึ่งไม่ได้ถูกนำมารวมในการวิเคราะห์นี้ ดังนั้น ผลการวิเคราะห์ดังกล่าวจึงควรถูกใช้เป็นแนวทางเบื้องต้นในการทำความเข้าใจลักษณะของข้อมูลและสนับสนุนการออกแบบฟีเจอร์ มากกว่าการใช้เป็นหลักฐานในการอธิบายความสำคัญของตัวแปรในเชิงแบบจำลองโดยตรง

5.3 ข้อเสนอแนะ

5.3.1 ข้อเสนอแนะการพิจารณาเพิ่มปัจจัยในการทำนาย

จากผลการวิจัยพบว่า องค์ประกอบทางภาพของวิดีโอมีความสัมพันธ์กับพฤติกรรมการกดถูกใจและการแชร์ในระดับปานกลาง ในขณะที่การทำนายความคิดเห็นนั้นประสิทธิภาพยังคงค่อนข้างต่ำอยู่ ดังนั้น หากต้องการให้โมเดลทำงานได้ประสิทธิภาพมากขึ้น อาจพิจารณาเพิ่มเติมและพัฒนาระบบดังนี้

- จำนวนภาพตัวแทนวิดีโอ ปัจจุบันใช้ตัวแทนอยู่ที่สามภาพ อาจไม่ครอบคลุมฉากสำคัญ หากเพิ่มจำนวน อาจช่วยลดความเอนเอียงของภาพตัวแทนของวิดีโอ
- เพิ่มฟีเจอร์ของภาพ ในการนำมาทำนายการมีส่วนร่วม
- การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกด้านภาพ เช่น Convolutional Neural Networks (CNNs) แทนการพึ่งพาคุณลักษณะที่สกัดด้วยวิธีเชิงสถิติแบบดั้งเดิม อาจจับฟีเจอร์ที่เรามองไม่เห็นได้
- การประยุกต์ใช้ข้อมูลแบบ Multimodal โดยผสมผสานคุณลักษณะจากหลายแหล่งข้อมูล เช่น ฟีเจอร์ภาพ เสียง และข้อความ Caption หรือ Hashtags เข้าด้วยกัน อาจช่วยเพิ่มประสิทธิภาพในการทำนายพฤติกรรมการมีส่วนร่วมที่มีความซับซ้อน โดยเฉพาะพฤติกรรมการแสดงความคิดเห็น ซึ่งมักได้รับอิทธิพลจากบริบทเชิงความหมายและอารมณ์ของเนื้อหามากกว่าปัจจัยภาพเพียงอย่างเดียว การผสมผสานข้อมูลหลายมิติอาจช่วยให้แบบจำลองสามารถเรียนรู้ปฏิสัมพันธ์ระหว่างองค์ประกอบเชิงภาพและเชิงภาษาได้ดียิ่งขึ้น
- ประยุกต์ใช้เทคนิค Natural Language Processing (NLP) เพื่อวิเคราะห์ข้อความ เช่น คำบรรยาย (caption) หรือข้อความที่ปรากฏในวิดีโอ (on-screen text) เพิ่มเติม
- เพื่อก้าวข้ามข้อจำกัดของคุณลักษณะที่ถูกกำหนดขึ้นด้วยมือ ควรพิจารณาศึกษาการดึงคุณลักษณะแบบอัตโนมัติโดยใช้แบบจำลองการเรียนรู้เชิงลึกที่ผ่านการฝึกฝนล่วงหน้า (Pretrained Deep Learning Models) เช่น โครงข่ายประสาทเทียมแบบคอนโวลูชัน (CNNs) หรือ Vision Transformers (ViT) ซึ่งมีความสามารถในการเรียนรู้ตัวแทนคุณลักษณะระดับสูง (High-Level Representations) จากข้อมูลภาพได้โดยตรง และช่วยลดความเอนเอียงที่อาจเกิดขึ้นจากการระบุข้อมูลโดยมนุษย์ (Annotation Bias)

5.3.2 ข้อเสนอแนะการพิจารณาเพิ่มขอบเขตในการทำนาย

งานวิจัยนี้กำหนดขอบเขตการศึกษาเฉพาะบัญชี TikTok ด้านอาหารและเครื่องดื่มในประเทศไทย ซึ่งเป็นหมวดหมู่เนื้อหาที่มีลักษณะเด่นด้านภาพอย่างชัดเจน ทั้งในมิติของสีสัน ความน่ารับประทาน และการจัดองค์ประกอบของวัตถุในเฟรม ส่งผลให้องค์ประกอบทางภาพมีบทบาทสำคัญต่อระดับการมีส่วนร่วมมากกว่าบริบทเนื้อหาบางประเภท

อย่างไรก็ตาม การจำกัดขอบเขตเฉพาะหมวดอาหารและเครื่องดื่ม อาจส่งผลต่อความสามารถในการทั่วไปของแบบจำลอง กล่าวคือ แบบจำลองที่พัฒนาขึ้นอาจมีประสิทธิภาพดีภายใต้บริบทที่ภาพมีความโดดเด่นสูง แต่เมื่อประยุกต์ใช้กับหมวดหมู่อื่น เช่น การศึกษา การเงิน เทคโนโลยี หรือเนื้อหาเชิงสาระ ความสำคัญขององค์ประกอบทางภาพอาจลดลง และปัจจัยด้านอื่นอาจมีอิทธิพลมากกว่า

ดังนั้น งานวิจัยในอนาคตควรพิจารณาขยายขอบเขตประเภทบัญชีให้มีความหลากหลายมากขึ้น เพื่อเปรียบเทียบความแตกต่างของอิทธิพลเชิงภาพในแต่ละหมวดหมู่เนื้อหา การศึกษาข้ามหมวดหมู่จะช่วยให้สามารถประเมินได้ว่า แบบจำลองที่พัฒนาขึ้นมีความเสถียรในบริบทที่แตกต่างกันหรือไม่ และปัจจัยใดมีบทบาทเด่นในแต่ละประเภทเนื้อหา

บรรณานุกรม

TNI

บรรณานุกรม

- [1] Deloitte Insights, “*Global Marketing Trends*,” [Online]. Available : <https://www2.deloitte.com/us/en/insights/topics/marketing-and-sales-operations/global-marketing-trends/2023.html>. [Accessed : October 24, 2024].
- [2] Content Shifu, “*Digital Marketing Trends*,” [Online]. Available : <https://contentshifu.com/blog/digital-marketing-trends>. [Accessed : October 24, 2024].
- [3] Hootsuite, “*Hootsuite Social Trends Report*,” [Online]. Available : <https://www.hootsuite.com/resources/social-media-toolkit>. [Accessed : October 24, 2024].
- [4] Socialinsider, “*TikTok Benchmarks Content Performance Analysis and Strategic Insights*,” [Online]. Available : <https://www.socialinsider.io/blog/tiktok-benchmarks> [Accessed : March 19, 2025].
- [5] Marketing Oops, “*Nielsen Media Spending and Gen New Gen Now Consumer Trends*,” [Online]. Available : <https://www.marketingoops.com/reports/nielsen-media-spending-2023-and-gen-new-gen-now-consumer-trends/>. [Accessed : October 24, 2024].
- [6] E. Koutromanou et al., “Examining visual impact : Predicting popularity and assessing social media visual strategies for NGOs,” *KKU Engineering Journal*, vol. 2, no. 4, pp. 588-616, December 2023.
- [7] Flixier, “*Ideal TikTok Video Length and Size in 2022*,” [Online]. Available : <https://flixier.com/blog/ideal-tiktok-video-length-and-size-in-2022>. [Accessed : October 24, 2024].
- [8] Trendpop, “*The New TikTok Video Lifecycle : A Closer Look at a Video’s Growth Rate Over Time*,” [Online]. Available : <https://www.trendpop.com/post/the-new-tiktok-video-lifecycle-a-closer-look-at-a-videos-growth-rate-over-time>. [Accessed : March 19, 2025].
- [9] สุเพ็ญนภา บุญเพิ่ม, “อิทธิพลการรับรู้ผ่านคลิปวิดีโอสั้นและภาพลักษณ์มหาวิทยาลัยที่ส่งผลต่อการตัดสินใจเข้าศึกษาต่อมหาวิทยาลัยเอกชนของนักเรียนมัธยมศึกษาตอนปลายในเขตกรุงเทพมหานคร,” สารนิพนธ์ บธ.ม. (บริหารธุรกิจญี่ปุ่น), สถาบันเทคโนโลยีไทย-ญี่ปุ่น, กรุงเทพฯ, 2565.

- [10] F. A. M. Azman and N. Mustaffa, "The impact of user generated content on food purchase intention through TikTok platform," *Journal of Contemporary Islamic Communication and Media*, vol. 3, no. 2, pp. 115-124, December 2023.
- [11] I. Vermeir and G. Roose, "Visual design cues impacting food choice : A review and future research agenda," *International Journal of Computer & Organization Trends*, vol. 9, no. 10, pp. 1,495, June 2025.
- [12] A. BenYishay et al., "When celebrities speak : A nationwide twitter experiment promoting vaccination in Indonesia," *Nature Human Behaviour*, vol. 5, no. 8, pp. 1,023-1,030, October 2021.
- [13] M. Philp et al., "Predicting social media engagement with computer vision : An examination of food marketing on Instagram," *Journal of Business Research*, vol. 149, no. 15, pp. 845-852, July 2022.
- [14] S. Z. Indillah et al., "Exploring indonesian consumer insights and factors driving their food purchase intention on TikTok shop," *Hatyai National and International Conference, ICIT 2023*, Songkla, Thailand, May 17, 2023, pp. 882-894.
- [15] S. Xu, "The consumer decision journey in the digital age : How brands influence consumer behavior online," *Proceedings of the 2004 Northeast Decision Science Institute Conference, NEDSI 2004 Proceedings*, New Jersey, USA, March 15-16, 2025, pp. 913-917.
- [16] นงลักษณ์ ตาดทอง, "การพยากรณ์ผู้ที่มีแนวโน้มในการตัดสินใจซื้อที่อยู่อาศัย ในงานมหกรรมบ้านและคอนโดโดยใช้เทคนิคการเรียนรู้ของเครื่อง," วิทยานิพนธ์ วท.ม. (เทคโนโลยีสารสนเทศ), สถาบันเทคโนโลยีไทย-ญี่ปุ่น, กรุงเทพฯ, 2563.
- [17] S. Assavakijphanich, "Cryptocurrency Trading with Ensemble Machine Learning Algorithm," B.Eng. Thesis (Automation Engineering), Chulalongkorn University, Bangkok, Thailand, 2021.
- [18] G. Ke et al., "LightGBM : A highly efficient gradient boosting decision tree," *39th Chinese Control Conference, NEDSI 2017*, California, USA, December 4-9, 2017, pp. 3,146-3,154.
- [19] L. Prokhorenkova et al., "CatBoost : Unbiased boosting with categorical features," *International Conference on Advanced Information Scientific Development, ICAISD 2018*, Montréal, Canada, December 3-8, 2018, pp. 6,638-6,648.

- [20] T. Fawcett, "An introduction to ROC analysis," *Pattern Recognition Letters*, vol. 27, no. 9, pp. 861-874, July 2006.
- [21] Python Software Foundation, "*Python 3.12 Documentation*," [Online]. Available : <https://docs.python.org/3/>. [Accessed : October 11, 2025].
- [22] Apify, "*TikTok Scraper*," [Online]. Available : <https://apify.com/>. [Accessed : October 24, 2024].
- [23] Microsoft, "*Power Automate Documentation*," [Online]. Available : <https://learn.microsoft.com/en-us/power-automate/>. [Accessed : October 11, 2025].
- [24] D. Liu et al., "Deep learning in food image recognition : A comprehensive review," *Applied Sciences*, vol. 254, no. 6, pp. 78-88, July 2025.
- [25] T. Chen and C. Guestrin, "XGBoost : A scalable tree boosting system," *Asian Control Conference, ASCC 2016*, San Francisco, USA, August 13-17, 2016, pp. 785-794.
- [26] T. Chengsheng et al., "AdaBoost typical algorithm and its application research," *International Conference on Advanced Algorithms and Control Engineering, ICAACE 2017*, Wuhan, China, October 27-29, 2017, pp. 223-225.
- [27] C. M. Lookingbill et al., "Assessment of accuracy, user engagement, and themes of eating disorder content on TikTok," *JAMA Network Open*, vol. 6, no. 4, pp. 237-246, April 2023.
- [28] E. Obucic et al., "Predicting user engagement of facebook post images in leading universities : A machine learning approach," *International Journal of Computer Science*, vol. 37, no. 4, pp. 883-891, August 2023.

ภาคผนวก

TNI

ภาคผนวก ก.

เอกสารประกอบการนำเสนอสอบป้องกันวิทยานิพนธ์

TNI

หัวข้อวิทยานิพนธ์

การสร้างและประเมินแบบจำลองการทำนาย

การมีส่วนร่วมของบัญชี TikTok

ด้านอาหารและเครื่องดื่มในประเทศไทย

จากคุณลักษณะทางภาพในวิดีโอด้วยวิธีการเรียนรู้ของเครื่อง

นาย พุฒิ งามบรรจง

ID: 2463110227



สถาบันเทคโนโลยีไทย-ญี่ปุ่น
Thai-Nichi Institute of Technology
泰日工业大学

หัวข้อการนำเสนอ

การแนะนำตัว	0	บทนำ	1
ทฤษฎี หลักการ และงานวิจัยที่เกี่ยวข้อง	2	ระเบียบและ วิธีดำเนินการวิจัย	3
ผลการวิจัย	4	บทสรุป อภิปราย และข้อเสนอแนะ	5

0

การแนะนำตัว

การศึกษา		
การศึกษา (ปริญญาตรี)	วิศวกรรมยานยนต์	
การศึกษา (ปริญญาโท)	การจัดการ	
การทำงาน		
นิลสัน	เจ้าหน้าที่บริหารงานบริการลูกค้า	
ลาซาด้า	นักวิเคราะห์อาวุโส	
เอสโซ่	ผู้จัดการเขต	
โทฟูจิ (ปัจจุบัน)	ผู้จัดการอาวุโสฝ่ายพัฒนาธุรกิจ	


บทที่ 1 : บทนำ

5

1


ความเป็นมาและความสำคัญของปัญหา

ลำดับความสำคัญของนโยบายทางการตลาดของผู้บริหาร [1]



1


โซเชียลมีเดียแพลตฟอร์มที่ได้รับความนิยมในประเทศไทย
จากกลุ่มคนตัวอย่างคนช่วงอายุ 16 ถึง 64 ปี [2]



7

1


การลงทุนในแต่ละแพลตฟอร์มสำหรับธุรกิจจากปี 2022 ถึง 2023 [3]



8

1

การลงทุนโฆษณาสูงสุดในประเทศไทยในแต่ละอุตสาหกรรมช่วงมกราคมถึงตุลาคมปี 2023 [5]



9

1

ปัจจัยที่นักการตลาดใช้ในการวัดความสำเร็จในการโฆษณา [2]



10

1

วัตถุประสงค์ของการวิจัย

เพื่อพัฒนา ประเมินและเปรียบเทียบ แบบจำลองการทำนายการมีส่วนร่วมของผู้ใช้งาน
ต่อคลิปวิดีโอบนแพลตฟอร์ม TikTok ด้านอาหารและเครื่องดื่มในประเทศไทย จาก
คุณลักษณะวิดีโอ โดยใช้เทคนิคการเรียนรู้ของเครื่อง

ประโยชน์ที่คาดว่าจะได้รับ

ระบบที่ทำนายการมีส่วนร่วมได้อย่างแม่นยำ
ช่วยผู้ประกอบการในอุตสาหกรรมร้านอาหารปรับกลยุทธ์การตลาดได้อย่างมีประสิทธิภาพ

11

1

ขอบเขตของการวิจัย

กลุ่มตัวอย่าง: คลิปวิดีโอของบัญชีอาหารและเครื่องดื่มในประเทศไทยที่เผยแพร่บนแพลตฟอร์ม
TikTok จำนวน 1,000 คลิปวิดีโอ (50 บัญชี บัญชีละ 20 คลิป) โดยมีลักษณะดังต่อไปนี้

- เนื้อหาเกี่ยวข้องกับอาหารและมีรูปอาหารหรือเครื่องดื่มในวิดีโอ
- ความยาวในช่วง 15-60 วินาที
- อยู่ในช่วง 2 ปีที่ผ่านมา
- คลิปวิดีโอต้องโพสต์มาแล้วเกิน 90 วัน
- คลิปจากบัญชี TikTok ที่มีผู้ติดตาม 10,000 – 50,000 คน



12

1

ขอบเขตของการวิจัย

ขอบเขตการวิเคราะห์:

การศึกษาผลกระทบขององค์ประกอบทางภาพในวิดีโอ

ต่อระดับการมีส่วนร่วมของผู้ใช้งาน ได้แก่

- จำนวนการกดถูกใจ (Likes),
- จำนวนความคิดเห็น (Comments),
- จำนวนการแชร์หรือรีโพสต์ (Shares/Reposts),
- จำนวนการดูวิดีโอ (Views)




13

บทที่ 2 : ทฤษฎี หลักการ และงานวิจัยที่เกี่ยวข้อง

14

2

สถิติความสัมพันธ์ระหว่าง จำนวนผู้ติดตามและการมีส่วนร่วมใน TikTok [4]




16

2

ทฤษฎีเกี่ยวกับคุณลักษณะของ TikTok


- ความยาวของวิดีโอ: ความยาวได้สูงสุด 10 นาที
- ฟิลเตอร์และเอฟเฟกต์: ปรับแต่งรูปภาพและวิดีโอ
- คลังเพลง: มีเพลงให้เลือกใช้มากมายที่ไม่ติดลิขสิทธิ์
- การติดต่อ: แก้ไขวิดีโอได้ง่ายๆ ผ่านแอปพลิเคชันโดยตรง
- การแสดงความคิดเห็นและการตอบกลับ: แลกเปลี่ยนความคิดเห็นระหว่างผู้สร้างวิดีโอและผู้ชม
- ฟีเจอร์ E-commerce: เป็นช่องในการซื้อขายออนไลน์ชื่อ TikTok Shopping



15

2


สถิติความสัมพันธ์ระหว่าง จำนวนผู้ติดตาม follower และการกดถูกใจ [4]



17

2


สถิติความสัมพันธ์ระหว่าง จำนวนผู้ติดตามและจำนวนความคิดเห็น [4]



18

2

สถิติความสัมพันธ์ระหว่าง จำนวนผู้ติดตามและจำนวนการรีโพสต์ [4]



19

2

ความสัมพันธ์ระหว่าง การแสดงผลของ TikTok กับเวลา

จำนวนยอดเปอร์เซ็นต์เฉลี่ยของคนดูเทียบกับความสัมพันธ์ทางเวลา :

- 32% ของยอดดูทั้งหมดภายใน 24 ชั่วโมงแรก
- 38% ของยอดดูทั้งหมดภายใน 48 ชั่วโมงแรก
- 55% ของยอดดูทั้งหมดภายใน 7 วัน
- 80% ของยอดดูทั้งหมดภายใน 30 วัน
- เกือบ 100% ของยอดดูทั้งหมดภายใน 90 วัน



20

2

ปัจจัยที่มีผลต่อการมีส่วนร่วมทางโซเชียลมีเดีย

งานวิจัย	คุณลักษณะทางภาพ			
	สี/คอนทราสต์	อัตลักษณ์แบรนด์	คุณภาพของภาพ	ข้อความ
Examining visual impact: Predicting popularity and assessing social media visual strategies for NGOs	●	●	●	
The Impact of User Generated Content on Food Purchase Intention Through TikTok Platform			●	●
Predicting social media engagement with computer vision: An examination of food marketing on Instagram			●	
Exploring Indonesian Consumer Insights and Factors Driving their Food Purchase Intention on TikTok Shop			●	

21

2


ปัจจัยที่มีผลต่อการมีส่วนร่วมทางโซเชียลมีเดีย

งานวิจัย	คุณลักษณะทางภาพ			
	คน (ใบหน้า)	คนดัง	อาหาร/วัตถุติด	บรรจุภัณฑ์
Examining visual impact: Predicting popularity and assessing social media visual strategies for NGOs	●			
When celebrities speak: A nationwide Twitter experiment promoting vaccination in Indonesia		●		
Predicting social media engagement with computer vision: An examination of food marketing on Instagram	●		●	
Exploring Indonesian Consumer Insights and Factors Driving their Food Purchase Intention on TikTok Shop		●	●	●

22

2

แนวคิดการเดินทางของผู้บริโภคในยุคดิจิทัล



23

2

เทคนิคการเรียนรู้ของเครื่องแต่ละประเภท

ชื่อเทคนิค	การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่อง
Decision Tree	มักใช้กับงานที่มีความสัมพันธ์ของตัวแปรแบบตรงไปตรงมา และสามารถตีความผลลัพธ์ได้ง่าย เหมาะกับการวิเคราะห์ที่ต้องการความชัดเจนในกระบวนการตัดสินใจ
Random Forest	เป็นการรวมผลลัพธ์จากหลาย Decision Tree เข้าด้วยกัน ทำให้สามารถประยุกต์ใช้กับงานที่มีความสัมพันธ์ของข้อมูลซับซ้อนมากขึ้น และช่วยลดความเอนเอียง (bias) ของโมเดล

24

2

เทคนิคการเรียนรู้ของเครื่องแต่ละประเภท

ชื่อเทคนิค	การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่อง
AdaBoost	เป็นอัลกอริทึมที่รวมโมเดล Weak Learners หลายตัวเข้าด้วยกันให้กลายเป็น Strong Learner โดยปรับน้ำหนักของข้อมูลในแต่ละรอบการเรียนรู้ ช่วยเพิ่มความแม่นยำและจัดการกับปัญหาที่ซับซ้อนได้ดี
XGBoost	ใช้กระบวนการเรียนรู้แบบ Gradient Boosting โดยเรียนรู้จากความผิดพลาดของรอบก่อนหน้า และมีการใช้ Regularization เพื่อลดปัญหา Overfitting เหมาะกับงานที่มีข้อมูลซับซ้อนปานกลางถึงขนาดใหญ่
LightGBM	ใช้เทคนิคการลดจำนวนตัวอย่าง (GOSS) และการรวมฟีเจอร์ที่ไม่ทับซ้อนกัน (EFB) ทำให้ประมวลผลได้รวดเร็ว เหมาะกับงานที่มีข้อมูลจำนวนมากและต้องการความเร็วในการฝึกโมเดล
CatBoost	ออกแบบมาเพื่อจัดการกับข้อมูลเชิงหมวดหมู่ (Categorical Data) และลดปัญหา Prediction Shift ที่เกิดจากการอ้างอิงข้อมูลตัวอย่างมากเกินไป เหมาะกับข้อมูลที่มี Noise หรือ Outlier

25

2

เทคนิคการเรียนรู้ของเครื่องแต่ละประเภท

ชื่อเทคนิค	การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่อง
Logistic Regression	เหมาะสำหรับปัญหาที่ความสัมพันธ์ไม่ซับซ้อนมาก และมีลักษณะเชิงเส้นระหว่างตัวแปรต้นกับผลลัพธ์ ใช้ได้ดีกับการจำแนกประเภท (Classification)
Naïve Bayes	อาศัยหลักความน่าจะเป็นในการจำแนกเงื่อนไข เหมาะกับงานที่มีตัวแปรอิสระต่อกัน และมีความสัมพันธ์ที่สามารถคาดการณ์ได้อย่างชัดเจน
K-Nearest Neighbors (KNN)	อิงจากข้อมูลตัวอย่าง โดยพิจารณาความใกล้เคียงของข้อมูล เหมาะกับงานที่ข้อมูลมีการกระจายตัวคล้ายคลึงกัน และต้องการจำแนกกลุ่มตามความสัมพันธ์ของลักษณะร่วม
Support Vector Machines (SVM)	เป็นอัลกอริทึมที่สร้างเส้นขอบเขต (Hyperplane) เพื่อแยกกลุ่มข้อมูลในพื้นที่หลายมิติได้อย่างมีประสิทธิภาพ เหมาะกับข้อมูลที่ไม่เป็นเส้นตรง (non-linear) และซับซ้อน

26

2

เทคนิคการเรียนรู้ของเครื่องแต่ละประเภท

ชื่อเทคนิค	การประยุกต์ใช้ของเทคนิคการเรียนรู้ของเครื่อง
Long Short -Term Memory	เป็นสถาปัตยกรรมของโครงข่ายประสาทเทียม (Neural Network) ที่ออกแบบมาเพื่อจดจำข้อมูลระยะยาว โดยป้องกันปัญหาการลืมข้อมูลเก่า เหมาะกับงานที่มีข้อมูลต่อเนื่องตามลำดับเวลา
AR-MIX	เป็นเทคนิคที่รวมผลจากแบบจำลองการถดถอยหลายแบบ (Regression Models) และปรับ “น้ำหนัก” ของแต่ละโมเดลแบบอัตโนมัติ เหมาะกับงานพยากรณ์ที่ข้อมูลมีการเปลี่ยนแปลงตลอดเวลา
EWFC	เป็นวิธีการรวมผลการพยากรณ์จากหลายโมเดล โดยให้น้ำหนักเท่ากันทั้งหมด เหมาะกับการที่ไม่มีข้อมูลเพียงพอจะระบุว่ามีโมเดลใดให้ผลดีที่สุด

27

2


เทคนิคการแบ่งข้อมูลในการสร้างแบบจำลองด้วยวิธีการไขว้ข้อมูล

k-Fold Cross-Validation

รอบที่ 1: ใช้ D_1 เป็นชุดทดสอบ และ D_2,...,D_k ใช้เป็นชุดฝึก

รอบที่ 2: ใช้ D_2 เป็นชุดทดสอบ และ D_1,D_3,...,D_k ใช้เป็นชุดฝึก

ทำซ้ำในลักษณะนี้จนครบ k รอบ โดยแต่ละชุดย่อยจะทำหน้าที่เป็นชุดทดสอบเพียงครั้งเดียว



28

2

จำนวนข้อมูลในงานวิจัย

ชื่องานวิจัย	แพลตฟอร์ม	จำนวนตัวอย่างการทดลอง
Predicting User Engagement of Facebook Post Images in Leading Universities' Pages	Facebook	1,008 รูปภาพ
Assessment of Accuracy, User Engagement, and Themes of Eating Disorder Content on TikTok	TikTok	200 วิดีโอ
Examining visual impact: predicting popularity and assessing social media visual strategies for NGOs	Facebook & Instagram	4,144 รูปภาพ (2,587 จาก Facebook, 1,557 จาก Instagram)

29

2

การประเมินประสิทธิภาพของแบบจำลอง

Confusion Matrix

	ค่าที่เกิดขึ้นจริง		
	Positive	Negative	
ค่าการทำนาย	TP	FP	Positive
	FN	TN	Negative

คำอธิบายองค์ประกอบใน Confusion Matrix:

True: ทำนายถูกต้อง

False: ทำนายผิด

Positive: ความนิยมสูง

Negative: ความนิยมต่ำ

30

2

การประเมินประสิทธิภาพของแบบจำลอง

ค่าความถูกต้อง (Accuracy)

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN}$$

ค่าความแม่นยำ (Precision)

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

ค่าความระลึก (Recall)

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

ค่าความถ่วงดุล (F1 Score)

$$F1 - Score = 2 \times \frac{Precision \times Recall}{Precision+Recall}$$

31

2

เครื่องมือและโปรแกรมที่ใช้ในการวิจัย

Python



Google Colab



APIFY TikTok Scraper



Microsoft Power Automate



32

บทที่ 3 :ระเบียบและวิธีดำเนินการวิจัย

33

3


ขั้นตอนกระบวนการทำวิจัย

- ขั้นตอนที่ 1: เก็บข้อมูลและเตรียมข้อมูล
- ขั้นตอนที่ 2: การดึงฟีเจอร์จากภาพในโพสต์
- ขั้นตอนที่ 3: การทำความสะอาดข้อมูลและประมวลผล
- ขั้นตอนที่ 4: การเลือกและพัฒนาโมเดลการทำนาย
- ขั้นตอนที่ 5: การฝึกฝน ตรวจสอบและทดสอบโมเดล
- ขั้นตอนที่ 6: การประเมินผล

34

3

ระบบที่นำเสนอ



35

3

ขั้นตอนที่ 1: เก็บข้อมูลและเตรียมข้อมูล

- คัดเลือกเลือกวิดีโอ ที่ตรงตามเกณฑ์ที่ตั้งไว้

ขอบเขตของการวิจัย

กลุ่มตัวอย่าง: คลิปวิดีโอของร้านอาหารและเครื่องดื่มในประเทศไทยที่เผยแพร่บนแพลตฟอร์ม TikTok จำนวน 1,000 คลิปวิดีโอ (50 บัญชี บัญชีละ 20 คลิป) โดยมีลักษณะดังต่อไปนี้

- เนื้อหาเกี่ยวข้องกับอาหารและเครื่องดื่มหรือเครื่องใช้ในครัว
- ความยาวในช่วง 15-60 วินาที
- อยู่ในช่วง 2 ปีที่ผ่านมา
- คลิปวิดีโอต้องโพสต์มาแล้วเกิน 90 วัน
- คลิปจากบัญชี TikTok ที่มีผู้ติดตาม 10,000 – 50,000 คน




36

3

ขั้นตอนที่ 1: เก็บข้อมูลและเตรียมข้อมูล

คัดเลือกเลือกวิดีโอ ที่ตรงตามเกณฑ์ที่ตั้งไว้



37

3

ขั้นตอนที่ 1: เก็บข้อมูลและเตรียมข้อมูล

คัดเลือกวิดีโอ ที่ตรงตามเกณฑ์ที่ตั้งไว้




38

3

ขั้นตอนที่ 1: เก็บข้อมูลและเตรียมข้อมูล

คัดเลือกวิดีโอ ที่ตรงตามเกณฑ์ที่ตั้งไว้



39

3

ขั้นตอนที่ 1: เก็บข้อมูลและเตรียมข้อมูล

บันทึกรายการ URL ของคลิปที่เลือกไว้ โดยใช้เครื่องมือ Power Automate ร่วมกับ Google Form เพื่อรวบรวมลิงก์วิดีโอทั้งหมด



40

3


ขั้นตอนที่ 2: การดึงฟีเจอร์จากภาพในโพสต์



44

3

ขั้นตอนที่ 2: การดึงฟีเจอร์จากภาพในโพสต์



45

3

ขั้นตอนที่ 2: การดึงฟีเจอร์จากภาพในโพสต์

คุณลักษณะระดับต่ำ	คำวัด	การดึงข้อมูล	เกณฑ์
สีสดใส	ไม่ใช่ (0) ใช่ (1)	ค่า Saturation (S) ในระบบสี HSV	0.5
ความสว่าง	ไม่ใช่ (0) ใช่ (1)	ค่า Value (V) ในระบบสี HSV	0.6
คอนทราสต์	ไม่ใช่ (0) ใช่ (1)	ค่าความเข้มแสง หลังจากการปรับ Grayscale ที่ P95 - P5	180
ความขัดคม	ไม่ใช่ (0) ใช่ (1)	ค่า Variance of Laplacian ของภาพระดับเทา	14,000

3

ขั้นตอนที่ 2: การดึงพีเจียร์จากภาพในโพสต์

วัตถุดิบ	อาหารสำเร็จ (0) อาหารสำเร็จและกระบวนการทำอาหารหรือวัตถุดิบ (1)
อาหาร	ไม่มี (0) มีหนึ่งเมนู (1) มีมากกว่าหนึ่งเมนู (2)
ของหวาน	ไม่มี (0) มีหนึ่งเมนู (1) มีมากกว่าหนึ่งเมนู (2)
เครื่องดื่ม	ไม่มี (0) มีหนึ่งเมนู (1) มีมากกว่าหนึ่งเมนู (2)
ใบหน้าคน	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)
ผู้ใหญ่ ชาย (ใบหน้า)	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)
ผู้ใหญ่ หญิง (ใบหน้า)	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)
เด็ก (ใบหน้า)	ไม่มี (0) มีหนึ่งคน (1) มีมากกว่าหนึ่งคน (2)
โลโก้	ไม่มี (0) มี (1)
บรรจุภัณฑ์	ไม่มี (0) มี (1)
ข้อความรีวิว/คะแนน	ไม่มี (0) มี (1)
ข้อความราคาโปรโมชั่น	ไม่มี (0) มี (1)

47

3

ขั้นตอนที่ 3: การทำความสะอาดข้อมูลและประมวลผล

ข้อมูลการมีส่วนร่วมผ่าน Apify ซึ่งสามารถสังเกตได้ว่ามีข้อมูลจำนวนมากทั้งหมด 258 แถว ซึ่งหลายแถวนั้นไม่สำคัญหรือไม่เกี่ยวข้องกับการทำนาย จึงจำเป็นต้องดำเนินการทำความสะอาดข้อมูลให้อยู่ในรูปแบบที่เหมาะสม

No.	Account	Like	Share	View	Comment	Like	Share	Comment
1	chocogems.th	4154	376	76400	22	5.44%	0.49%	0.03%
2	chocogems.th	1063	57	22500	11	4.72%	0.25%	0.05%
3	chocogems.th	86	5	2270	2	3.79%	0.22%	0.09%
4	chocogems.th	1199	63	26900	8	4.46%	0.23%	0.03%
5	chocogems.th	87	4	2129	2	4.09%	0.19%	0.09%
6	chocogems.th	185	36	4068	6	4.55%	0.88%	0.15%
7	chocogems.th	1688	97	35900	3	4.70%	0.27%	0.01%
8	chocogems.th	235	22	5280	6	4.45%	0.42%	0.11%
9	chocogems.th	168	56	4434	4	3.79%	1.00%	0.09%
10	chocogems.th	729	70	17300	9	4.21%	0.00%	0.05%

48

3

ขั้นตอนที่ 3: การทำความสะอาดข้อมูลและประมวลผล

จำเป็นต้องคำนวณอัตราการมีส่วนร่วม (Engagement Rate) ให้เป็นค่าร้อยละก่อนนำเข้าสู่กระบวนการทำนาย

$$\text{อัตราการมีส่วนร่วม (โลก)} = \frac{\text{การมีส่วนร่วม (โลก)}}{\text{จำนวนการรับชมวิดีโอ}} \times 100$$

$$\text{อัตราการมีส่วนร่วม (คอมเมนต์)} = \frac{\text{การมีส่วนร่วม (คอมเมนต์)}}{\text{จำนวนการรับชมวิดีโอ}} \times 100$$

$$\text{อัตราการมีส่วนร่วม (แชร์)} = \frac{\text{การมีส่วนร่วม (แชร์)}}{\text{จำนวนการรับชมวิดีโอ}} \times 100$$

49

3

ขั้นตอนที่ 3: การล้างข้อมูลและประมวลผล

ผลลัพธ์ของการจำแนกจะประกอบด้วย 2 ระดับความนิยม (Popularity Classes) โดยใช้ค่า Median มัธยฐาน ค่ากลาง ของอัตราส่วนมีส่วนร่วมเป็นเกณฑ์ ดังนี้:

1. ความนิยมต่ำ: ค่าต่ำกว่า มัธยฐาน
2. ความนิยมสูง: ค่าสูงกว่า มัธยฐาน



50

3

ขั้นตอนที่ 3: การทำความสะอาดข้อมูลและประมวลผล

นำค่าประเภท Boolean ที่ได้จากการประมวลผลของการดึงฟีเจอร์จากภาพกับข้อมูลการมีส่วนร่วม ผ่านที่ผ่านการทำความสะอาดแล้ว มาจัดในรูปแบบที่พร้อมสำหรับการเข้าสู่กระบวนการทำนาย

N	Like	Share	Comment	ColorTones	Brightness	Contrast	Sharpness	Ingredient	Food
1	0	0	0	0	1	1	1	0	0
2	0	1	0	0	1	0	1	1	0
3	0	1	0	0	1	0	1	1	0
4	0	1	0	0	1	0	1	1	0
5	0	1	0	0	1	0	0	0	0

N	Dessert	Beverage	Face	Men	Women	Children	Logo	Packaging	Review	Promotion
1	1	0	1	0	1	0	1	1	1	0
2	1	0	1	0	1	0	0	0	1	0
3	1	0	2	1	1	0	1	1	1	0
4	1	0	1	0	1	0	0	1	1	0
5	1	0	1	0	1	0	1	1	1	0

51

3

ขั้นตอนที่ 4: การเลือกและพัฒนาโมเดลการทำนาย

ชื่อเทคนิค	ความเหมาะสมต่อการวิจัยนี้
Random Forest	ข้อดี: เนื่องจาก Random Forest ใช้ต้นไม้ตัดสินใจจำนวนมากในการทำนาย ทำให้สามารถจัดการกับข้อมูลที่ซับซ้อนและตัวแปรที่มีความหลากหลายได้อย่างมีประสิทธิภาพ อีกทั้งยังช่วยลดปัญหา Overfitting และรองรับข้อมูลที่ขาดหายหรือมีความไม่สมดุลได้ดี จึงมีความเหมาะสมสำหรับการทำนาย Engagement ที่เกี่ยวข้องกับหลายปัจจัยเชิงภาพและเชิงพฤติกรรม ข้อเสีย: การที่มีต้นไม้เยอะเกินไปซึ่งทำให้เกิดความซับซ้อนมากเกินไป จึงอาจมีโมเดลประเภทอื่นที่เหมาะสมกว่า ตัวอย่างในบางข้อมูลหรือตัวแปรที่มีน้อยเกินไป อาจจะทำให้โมเดลมีความ ข้อมูลได้ลำบาก
Support Vector Machines (SVM)	ข้อดี: SVM ใช้หลักการของเส้นแบ่งหลายมิติ (Hyperplane) เพื่อจำแนกและทำนายข้อมูลที่มีความซับซ้อน ซึ่งสอดคล้องกับบริบทของการมีส่วนร่วมบนแพลตฟอร์ม TikTok ที่มีตัวแปรหลายด้านและความสัมพันธ์ที่ซับซ้อน ข้อเสีย: SVM มีข้อจำกัดเมื่อใช้กับข้อมูลที่มีจำนวนมากหรือมีมิติสูง เนื่องจากต้องใช้เวลาและทรัพยากรในการประมวลผลสูง อย่างไรก็ตาม งานวิจัยนี้มีขนาดข้อมูลไม่มากนัก จึงยังเหมาะสมควรนำ SVM มาใช้ในการศึกษา

52

3

ขั้นตอนที่ 4: การเลือกและพัฒนาโมเดลการทำนาย

LightGBM	ข้อดี: Gradient-based One-Side Sampling (GOSS) และ Exclusive Feature Bundling (EFB) ช่วยในการลดจำนวนข้อมูลตัวอย่างและจำนวนฟีเจอร์ที่ต้องประมวลผล ทำให้โมเดลสามารถใส่ได้กับข้อมูลที่แปรที่มีความสำคัญต่อการทำนายผลลัพธ์ได้ดียิ่งขึ้น เหมาะกับการวิเคราะห์การมีส่วนร่วมบน TikTok ซึ่งมีหลายปัจจัยเชิงภาพและพฤติกรรมที่เกี่ยวข้องกัน ข้อเสีย: มีจุดเด่นในการลดจำนวนข้อมูลและฟีเจอร์เพื่อเพิ่มประสิทธิภาพการประมวลผล แต่ข้อได้เปรียบนี้อาจไม่ใช่ปัจจัยหลักของงานวิจัยนี้ นอกจากนี้หากการสุ่มเลือก ฟีเจอร์ ไม่มีประสิทธิภาพที่ดีพอ จะทำให้ผลลัพธ์ไม่มีประสิทธิภาพ
CatBoost	ข้อดี: เป็นอัลกอริทึมที่ถูกออกแบบมาเพื่อจัดการกับข้อมูลเชิงหมวดหมู่ได้อย่างมีประสิทธิภาพ พร้อมทั้งแก้ปัญหา Prediction Shift ที่มักเกิดจากการอ้างอิงข้อมูลตัวอย่างมากเกินไป ซึ่งทำให้ทำงานได้ดีแม้ในกรณีที่มี Noise หรือ Outlier อยู่ในข้อมูล อีกทั้งยังเหมาะสมกับชุดข้อมูลที่มีขนาดใหญ่มาก ซึ่งสอดคล้องกับขอบเขตของงานวิจัยนี้ ข้อเสีย: เนื่องจากกลุ่มข้อมูลในงานวิจัยนี้มีขนาดค่อนข้างเล็ก อาจทำให้การจัดการกับตัวแปรเชิงหมวดหมู่ไม่สามารถแสดงศักยภาพได้เต็มที่เท่ากับการใช้กับข้อมูลขนาดใหญ่

53

3

ขั้นตอนที่ 5: การทดสอบโมเดล

ชุดข้อมูลทั้งหมดถูกแบ่งชุดฝึกจริง Train 70% และ ชุดตรวจสอบความถูกต้อง Validation 10% เพื่อใช้สำหรับการปรับแต่งโมเดล ขณะที่ชุดทดสอบ Test 20% จะถูกใช้เพียงครั้งเดียวในขั้นตอนสุดท้าย



54

3

ขั้นตอนที่ 6: การประเมินผล

ค่าความถูกต้อง (Accuracy): วัดสัดส่วนของการทำนายที่ถูกต้องทั้งหมดต่อจำนวนการทำนาย

ค่าความแม่นยำ (Precision): วัดความถูกต้องเฉพาะเมื่อโมเดลทำนายว่าเป็นคลาสใดคลาสหนึ่ง

ค่าความระลึก (Recall): วัดความสามารถของโมเดลในการระบุข้อมูลที่แท้จริงในแต่ละคลาส

ค่าความถ่วงดุล (F1 Score): เป็นค่าเฉลี่ยเชิงฮาร์โมนิกของ Precision และ Recall ซึ่งช่วยสร้างสมดุลระหว่างทั้งสอง

55

บทที่ 4 : ผลการวิจัย

56

4

ผลการประเมินประสิทธิภาพของ การกดไลก์ แบบ Confusion Matrix

ค่าจากการทำนายของแบบจำลอง		ค่าที่เกิดขึ้นจริง	
		สูง	ต่ำ
SVC	สูง	61	19
	ต่ำ	39	81
Light GBM	สูง	60	15
	ต่ำ	40	85
Random Forest	สูง	65	24
	ต่ำ	35	76
CatBoost	สูง	62	15
	ต่ำ	38	85
Logistic Regression	สูง	65	21
	ต่ำ	35	79

57

4

ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการทำนาย การกดไลก์

โมเดล	คลาส	Accuracy	Precision	Recall	F1-score
SVC	สูง	0.7100	0.7625	0.6100	0.6778
	ต่ำ	0.7100	0.6750	0.8100	0.7364
Light GBM	สูง	0.7250	0.8000	0.6000	0.6857
	ต่ำ	0.7250	0.6800	0.8500	0.7556
Random Forest	สูง	0.7050	0.7303	0.6500	0.6878
	ต่ำ	0.7050	0.6847	0.7600	0.7204
CatBoost	สูง	0.7350	0.8052	0.6200	0.7006
	ต่ำ	0.7350	0.6911	0.8500	0.7623
Logistic Regression	สูง	0.7200	0.7558	0.6500	0.6989
	ต่ำ	0.7200	0.6930	0.7900	0.7383

58

4

ผลการประเมินประสิทธิภาพของ การแชร์ แบบ Confusion Matrix

ค่าจากการทำนายของแบบจำลอง		ค่าที่เกิดขึ้นจริง	
		สูง	ต่ำ
SVC	สูง	59	22
	ต่ำ	41	78
Light GBM	สูง	59	23
	ต่ำ	41	77
Random Forest	สูง	61	24
	ต่ำ	39	76
CatBoost	สูง	66	28
	ต่ำ	34	72
Logistic Regression	สูง	68	28
	ต่ำ	32	72

59

4

ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการทำนาย การแชร์

โมเดล	คลาส	Accuracy	Precision	Recall	F1-score
SVC	สูง	0.6850	0.7284	0.5900	0.6519
	ต่ำ	0.6850	0.6555	0.7800	0.7123
Light GBM	สูง	0.6800	0.7195	0.5900	0.6483
	ต่ำ	0.6800	0.6525	0.7700	0.7064
Random Forest	สูง	0.6850	0.7176	0.6100	0.6594
	ต่ำ	0.6850	0.6609	0.7600	0.7069
CatBoost	สูง	0.6900	0.7021	0.6600	0.6804
	ต่ำ	0.6900	0.6792	0.7200	0.6990
Logistic Regression	สูง	0.7000	0.7083	0.6800	0.6939
	ต่ำ	0.7000	0.6923	0.7200	0.7059

60

4

ผลการประเมินประสิทธิภาพของ แสดงความคิดเห็น แบบ Confusion Matrix

ค่าจากการทำนายของแบบจำลอง		ค่าที่เกิดขึ้นจริง	
		สูง	ต่ำ
SVC	สูง	61	47
	ต่ำ	39	53
Light GBM	สูง	60	41
	ต่ำ	40	59
Random Forest	สูง	55	47
	ต่ำ	45	53
CatBoost	สูง	59	41
	ต่ำ	41	59
Logistic Regression	สูง	61	42
	ต่ำ	39	58

61

4

ผลการเปรียบเทียบประสิทธิภาพแบบจำลองสำหรับการแสดงความคิดเห็น

โมเดล	คลาส	Accuracy	Precision	Recall	F1-score
SVC	สูง	0.5700	0.5648	0.6100	0.5865
	ต่ำ	0.5700	0.5761	0.5300	0.5521
Light GBM	สูง	0.5950	0.5941	0.6000	0.5970
	ต่ำ	0.5950	0.5960	0.5900	0.5930
Random Forest	สูง	0.5400	0.5392	0.5500	0.5445
	ต่ำ	0.5400	0.5408	0.5300	0.5353
CatBoost	สูง	0.5900	0.5900	0.5900	0.5900
	ต่ำ	0.5900	0.5900	0.5900	0.5900
Logistic Regression	สูง	0.5950	0.5922	0.6100	0.6010
	ต่ำ	0.5950	0.5979	0.5800	0.5888

62

บทที่ 5 :บทสรุป อภิปราย และข้อเสนอแนะ

63

5

สรุปผลการวิจัย

- ความสามารถในการทำนายเรียงลำดับจากสูงไปต่ำคือ Like > Share > Comment
- ความแตกต่างของประสิทธิภาพโดยรวมระหว่างโมเดลไม่ได้มีนัยสำคัญสูงมาก
- แบบจำลองส่วนใหญ่สามารถจำแนกคลาส “ต่ำ” ได้แม่นยำกว่าคลาส “สูง” สำหรับตัวชี้วัด Like และ Share

64

5

สรุปผลการวิจัย

- องค์ประกอบทางภาพมีศักยภาพในการใช้พยากรณ์การมีส่วนร่วมประเภท Like และ Share ได้ในระดับปานกลาง
- ขณะที่การพยากรณ์ Comment มีความซับซ้อนสูงกว่า ยังทำได้ไม่ดีนัก



65

5

อภิปรายผล

ความแตกต่างของระดับ Engagement ตามลักษณะพฤติกรรมผู้ใช้งาน

- Comment เป็นกิจกรรมที่ต้องใช้การมีส่วนร่วมเชิงความหมายมากกว่า Like และ Share ใช้ความพยายามสูงกว่า
- Comment มักเกี่ยวข้องกับปัจจัยด้านเนื้อหา บริบท อารมณ์ หรือความคิดเห็นส่วนบุคคล ซึ่งอาจไม่สามารถอธิบายได้ด้วยคุณลักษณะทางภาพเพียงอย่างเดียว

66

5

อภิปรายผล

ประสิทธิภาพของกลุ่ม Boosting และลักษณะความสัมพันธ์เชิงไม่เชิงเส้น

- กลุ่ม Boosting ให้ประสิทธิภาพสูงกว่าเล็กน้อย อาจสะท้อนถึงความสามารถของอัลกอริทึมดังกล่าวในการจัดการความสัมพันธ์ไม่เชิงเส้นของตัวแปรภาพ
- ความแตกต่างของค่าประสิทธิภาพที่ไม่มากนัก จึงอาจยังไม่สะท้อนภาพที่แท้จริง ข้อมูลภาพเพียงชุดเดียวอาจยังไม่เพียงพอ

67

5

อภิปรายผล

ความไม่สมมาตรในการจำแนกคลาสต่ำและคลาสสูง

- ผลการที่แบบจำลองสามารถจำแนกระดับการมีส่วนร่วมประเภท Like และ Share ในกลุ่มคลาสต่ำได้แม่นยำกว่าคลาสสูง
- เมื่อคุณลักษณะเชิงภาพไม่ดึงดูด ความน่าจะเป็นในการเกิดปฏิสัมพันธ์ย่อมลดลง
- ในทางกลับกันการที่วิดีโอมีองค์ประกอบทางภาพที่ดี มีได้หมายความว่าส่งผลให้เกิดการมีส่วนร่วมในระดับสูงโดยอัตโนมัติ

68

5

ข้อเสนอแนะ

การพิจารณาเพิ่มปัจจัยในการทำนาย

- จำนวนภาพตัวแทนวิดีโอ
- เพิ่มพีเจอร์ของภาพ
- การประยุกต์ใช้เทคนิคการเรียนรู้เชิงลึกด้านภาพ
- การประยุกต์ใช้ข้อมูลแบบ Multimodal



70

5

อภิปรายผล

ความไม่สมมาตรในการจำแนกคลาสต่ำและคลาสสูง

- ผลการที่แบบจำลองสามารถจำแนกระดับการมีส่วนร่วมประเภท Like และ Share ในกลุ่มคลาสต่ำได้แม่นยำกว่าคลาสสูง
- เมื่อคุณลักษณะเชิงภาพไม่ดึงดูด ความน่าจะเป็นในการเกิดปฏิสัมพันธ์ย่อมลดลง
- ในทางกลับกันการที่วิดีโอมีองค์ประกอบทางภาพที่ดี มีได้หมายความว่าส่งผลให้เกิดการมีส่วนร่วมในระดับสูงโดยอัตโนมัติ

69

5

ข้อเสนอแนะ

การพิจารณาเพิ่มขอบเขตในการทำนาย

- ปัจจุบัน หมวดหมู๋ อาหารและเครื่องดื่ม องค์ประกอบทางภาพมีบทบาทสำคัญต่อระดับการมีส่วนร่วมมากกว่าบริบทเนื้อหาบางประเภท
- ประยุกต์ใช้กับหมวดหมู๋อื่น เช่น การศึกษา การเงิน เทคโนโลยี เพื่อเปรียบเทียบความแตกต่างของอิทธิพลเชิงภาพในแต่ละหมวดหมู๋เนื้อหา



71



**THANK YOU FOR
YOUR ATTENTION**

72

TNI

THAI - NICHI INSTITUTE OF TECHNOLOGY