

บทความวิจัย

## การพยากรณ์คุณลักษณะที่มีความสำคัญต่อการยกเลิกบริการยูทูปพรีเมียมด้วยโครงข่ายประสาทเทียมและอัลกอริทึมการเรียนรู้แบบรวม

จักรินทร์ สันติรัตนภักดิ์\*

สาขาวิชาเทคโนโลยีธุรกิจดิจิทัล คณะบริหารธุรกิจ มหาวิทยาลัยวงษ์ชวลิตกุล

\* ผู้นิพนธ์ประสานงาน โทรศัพท์ 06 4791 5551 อีเมล: chakkarin\_san@vu.ac.th DOI: 10.14416/j.kmutnb.2026.08.002

รับเมื่อ 5 พฤศจิกายน 2568 แก้ไขเมื่อ 13 มีนาคม 2569 ตอบรับเมื่อ 30 มีนาคม 2569 เผยแพร่ออนไลน์ 19 สิงหาคม 2569

© 2026 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

### บทคัดย่อ

งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองที่มีประสิทธิภาพในการพยากรณ์แนวโน้มการยกเลิกบริการของผู้ใช้บริการยูทูปพรีเมียม และระบุปัจจัยสำคัญที่มีอิทธิพลต่อการตัดสินใจ เพื่อใช้เป็นแนวทางในการวางกลยุทธ์รักษาลูกค้าเชิงรุก โดยทำการศึกษาจากกลุ่มตัวอย่างจำนวน 10,983 รายการ ผ่านกระบวนการบูรณาการโครงข่ายประสาทเทียมร่วมกับอัลกอริทึมการเรียนรู้แบบรวม ได้แก่ XGBoost, LightGBM และ CatBoost พร้อมทั้งประยุกต์ใช้เทคนิค Optuna ในการปรับแต่งพารามิเตอร์ และใช้กรอบการคัดเลือกคุณลักษณะแบบหลายรอบ ร่วมกับ SHAP เพื่ออธิบายความสัมพันธ์ของข้อมูล ผลการวิจัยพบว่าแบบจำลอง LightGBM ที่มีการปรับสมดุลข้อมูลให้ประสิทธิภาพสูงสุด โดยมีค่า AUC เท่ากับ 0.93 ค่าความถูกต้อง เท่ากับ 0.85 และค่าการเรียกคืน เท่ากับ 0.90 แม้จะใช้ตัวแปรสำคัญเพียง 8 ตัวในการพยากรณ์ ซึ่งผลการวิเคราะห์ระบุว่าปัจจัยด้านพฤติกรรมมีความสำคัญมากกว่าด้านประชากรศาสตร์อย่างมีนัยสำคัญ โดยมีตัวแปรที่เป็นสัญญาณบอกในการรักษาลูกค้าสมาชิก ได้แก่ “จำนวนวิดีโอที่รับชม (ContentCount)” ซึ่งมีอิทธิพลสูงสุด รองลงมาคือ “ระยะเวลาการเป็นสมาชิก (Period)” “ชั่วโมงการรับชม (WatchTime)” และ “จำนวนช่องที่ติดตาม (Subscribed)” ในขณะที่ปัจจัยที่เป็นสัญญาณเตือนวิกฤตซึ่งเพิ่มความเสี่ยงในการยกเลิกคือ “ปัญหาการชำระเงิน (CamelCase)” และ “การติดต่อฝ่ายสนับสนุน (SupportTickets)” ส่วนปัจจัยเสริมที่ช่วยลดการยกเลิกได้คือ “รูปแบบสัญญา (Contract)” และ “การสนับสนุนด้านเทคนิค (TechSupport)” โดยองค์ความรู้ที่ได้จากการศึกษานี้ไม่เพียงแต่ยืนยันประสิทธิภาพของอัลกอริทึมการเรียนรู้แบบรวมในการจัดการข้อมูลพฤติกรรมที่ซับซ้อน แต่ยังนำไปสู่ข้อเสนอแนะเชิงกลยุทธ์ในการเฝ้าระวังกลุ่มผู้ใช้ที่ประสบปัญหาด้านธุรกรรม และกลุ่มที่มีปฏิสัมพันธ์ต่ำ เพื่อป้องกันการสูญเสียลูกค้า และสร้างความยั่งยืนให้แก่ธุรกิจในระยะยาว

**คำสำคัญ:** คุณลักษณะที่มีความสำคัญ โครงข่ายประสาทเทียม พยากรณ์การสูญเสียลูกค้า ยูทูปพรีเมียม อัลกอริทึมการเรียนรู้แบบรวม

การอ้างอิงบทความ: จักรินทร์ สันติรัตนภักดิ์, “การพยากรณ์คุณลักษณะที่มีความสำคัญต่อการยกเลิกบริการยูทูปพรีเมียมด้วยโครงข่ายประสาทเทียมและอัลกอริทึมการเรียนรู้แบบรวม,” วารสารวิชาการพระจอมเกล้าพระนครเหนือ, ปีที่ 36, ฉบับที่ 4, หน้า 1-19, ต.ค.-ธ.ค. 2569. เลขที่บทความ 264-088251, doi: 10.14416/j.kmutnb.2026.08.002.



Research Article

## Prediction of Feature Importance for YouTube Premium Cancellation Using Artificial Neural Network and Ensemble Learning Algorithms

Chakkarin Santirattanaphakdi\*

Department of Digital Business Technology, Faculty of Business Administration, Vongchavalitkul University, Nakhon Ratchasima, Thailand

\* Corresponding Author, Tel. 06 4791 5551, E-mail: chakkarin\_san@vu.ac.th DOI: 10.14416/j.kmutnb.2026.08.002

Received 5 November 2025; Revised 13 March 2026; Accepted 30 March 2026; Published online: 19 August 2026

© 2026 King Mongkut's University of Technology North Bangkok. All Rights Reserved.

### Abstract

This research aims to develop a high-performance predictive model for subscriber churn in the YouTube Premium service and to identify key determinants influencing user decisions, providing a basis for proactive customer retention strategies. Utilizing a dataset of 10,983 records, the study integrates Artificial Neural Networks (ANN) with ensemble learning algorithms, specifically XGBoost, LightGBM, and CatBoost. The methodology incorporates Optuna for hyperparameter optimization and an iterative feature selection framework combined with SHAP (SHapley Additive exPlanations) for model interpretability. The results demonstrate that the optimized LightGBM model, adjusted for class imbalance, achieves superior performance, with an Area Under the Curve (AUC) of 0.93, an accuracy of 0.85, and a recall of 0.90, while utilizing only eight critical variables. The analysis reveals that behavioral factors significantly outweigh demographic variables in predicting churn. Positive indicators for retention include "ContentCount" which exerts the highest influence, followed by "Period" "WatchTime" and "Subscribed" (number of channels followed). Conversely, "CamelCase" and "SupportTickets" are identified as critical negative indicators that significantly increase churn risk. Additionally, "Contract" type and "TechSupport" serve as supplementary factors in reducing cancellation rates. These findings not only validate the effectiveness of ensemble learning in handling complex behavioral data but also provide strategic insights for monitoring users with low engagement or transaction-related issues. Implementing these proactive measures can effectively mitigate customer loss and ensure long-term business sustainability.

**Keywords:** Feature Importance, Artificial Neural Network, Customer Churn Prediction, Youtube Premium, Ensemble Learning Algorithms

Please cite this article as: C. Santirattanaphakdi, "Prediction of feature importance for youtube premium cancellation using artificial neural network and ensemble learning algorithms," *The Journal of KMUTNB*, vol. 36, no. 4, pp. 1–19, Oct.–Dec. 2026 (in Thai), Art. no. 264-088251, doi: 10.14416/j.kmutnb.2026.08.002.

## 1. บทนำ

ในยุคดิจิทัลที่แพลตฟอร์มสตรีมมิ่งมีการแข่งขันสูง การรักษาสถานะสมาชิกถือเป็นปัจจัยสำคัญต่อความยั่งยืนของธุรกิจบริการสมัครสมาชิก โดยเฉพาะยูทูบ (YouTube) ที่เป็นแพลตฟอร์มหลักในการรับชมวิดีโอออนไลน์ของผู้ใช้งานทั่วโลก โดยในปี ค.ศ. 2026 มีผู้ใช้งานมากกว่า 2.70 พันล้านคนต่อเดือน [1] สำหรับประเทศไทย มีจำนวนการรับชมวิดีโอรวมประมาณ 207 พันล้านวิวต่อเดือน หรือเฉลี่ย 2,957 วิวต่อคน ซึ่งสะท้อนถึงการเข้าถึงโฆษณาที่ครอบคลุมประชากรราว 66.4% ของประเทศ และคิดเป็น 72.8% ของผู้ใช้อินเทอร์เน็ตทั้งหมด โดยจำนวนผู้ใช้ที่สามารถเข้าถึงผ่านโฆษณาเพิ่มขึ้นประมาณ 3.40 ล้านคน คิดเป็นร้อยละ 7.7 เมื่อเทียบกับช่วงต้นปี ค.ศ. 2024 [2] อย่างไรก็ตาม การแสดงโฆษณาระหว่างการรับชมอาจส่งผลต่อประสบการณ์ของผู้ใช้ ทำให้ผู้บริโภคมองว่าตัวเลือกหลีกเลี่ยงหรือจำกัดการรับชมโฆษณา ปัจจัยดังกล่าวนำไปสู่การเติบโตของบริการแบบมีค่าบริการรายเดือนอย่างยูทูบพรีเมียม (YouTube Premium) ซึ่งช่วยให้ผู้ใช้สามารถรับชมวิดีโอโดยไม่มีโฆษณาคั่น ฟังเพลงแบบออฟไลน์ และเล่นวิดีโอในพื้นหลัง ทั้งนี้ แม้จะตอบสนองความต้องการของผู้บริโภคในด้านความสะดวก และคุณภาพการรับชม แต่ยังคงพบว่าผู้ใช้งานบางส่วนยกเลิกการสมัครสมาชิก เนื่องจากระดับความพึงพอใจต่อประสบการณ์การใช้งาน การรับรู้ถึงคุณค่าของค่าบริการ ปัญหาทางเทคนิค รวมถึงทางเลือกจากแพลตฟอร์มสตรีมมิ่งอื่น ๆ [3]


หากธุรกิจปราศจากการทำความเข้าใจในโครงสร้างพฤติกรรมอาจมีความเสี่ยงที่จะเกิดข้อผิดพลาดจากการมองข้ามปัจจัยเชิงประสบการณ์ที่เป็นสัญญาณ

เตือนภาวะวิกฤต เช่น ปัญหาการชำระเงิน เช่นเดียวกับการจัดสรรทรัพยากรที่ไม่ตรงจุด จากการมุ่งเน้นตัวแปรที่มีอิทธิพลต่ำแทนที่จะเสริมสร้างความผูกพันผ่านตัวแปรหลัก เช่น ปริมาณการรับชม ซึ่งอาจปกปิดความเสี่ยงที่แท้จริง ส่งผลให้ธุรกิจสูญเสียโอกาสในการดำเนินการมาตรการป้องกันเชิงรุก และนำไปสู่ความล้มเหลวในการรักษาความยั่งยืนของฐานรายได้ในสภาวะตลาดที่มีการแข่งขันสูง

การพยากรณ์การยกเลิกบริการที่ผ่านมามีการใช้โครงข่ายประสาทเทียม (Artificial Neural Networks; ANN) [4] เพื่อพัฒนาแบบจำลอง โดย Amuda และ Adeyemo [5] ได้พัฒนาโมเดลด้วยโครงข่ายแบบหลายชั้น (Multi-Layer Perceptron; MLP) ต่อมา Dalmia และคณะ [6] ใช้เทคนิคการหาเพื่อนบ้านใกล้ที่สุด (K-Nearest Neighbors; K-NN) และ XGBoost ในการปรับปรุงประสิทธิภาพของการพยากรณ์ ส่วน He และคณะ [7] ผสมผสานเทคนิคการเพิ่มประสิทธิภาพแบบเกรเดียนต์ (Gradient Boosting) กับต้นไม้ตัดสินใจแบบสุ่มอย่างยิง (Extremely Randomized Trees) แต่ยังคงเกิดปัญหาการสูญหายของข้อมูลจากการสุ่มลดขนาดข้อมูล ขณะที่ Sam และคณะ [8] ใช้อัลกอริทึมป่าแบบสุ่ม (Random Forest) และซัพพอร์ตเวกเตอร์แมชชีน (Support Vector Machine; SVM) เพื่อเพิ่มความแม่นยำของแบบจำลอง ด้าน Pustokhina และคณะ [9] ใช้เทคนิคการสุ่มตัวอย่างเกินของกลุ่มน้อยแบบสังเคราะห์ (Synthetic Minority Over-sampling Technique; SMOTE) เพื่อจัดการกับข้อมูลที่ไม่มีสมดุลร่วมกับเครื่องจักรการเรียนรู้แบบเอนกประสงค์แบบถ่วงน้ำหนักที่ผ่านการหาค่าเหมาะสมที่สุด (Optimized Weighted Extreme Learning Machine; OWELM)

นอกจากนี้ Alboukaey และคณะ [10] ได้พัฒนาโมเดลการวิเคราะห์ความสดใหม่ ความถี่ และมูลค่า (Recency, Frequency and Monetary; RFM) ร่วมกับหน่วยความจำระยะสั้นแบบยาว (Long Short-Term Memory; LSTM) และโครงข่ายประสาทเทียมคอนโวลูชัน (Convolution Neural Network; CNN) ส่วน Britto และ Gobinath [11] ได้ผสมผสานหน่วยรีเวิร์สเกต (Gated Recurrent Unit; GRU) กับหน่วยความจำระยะสั้นแบบยาวสองทิศทาง (Bidirectional Long Short-Term Memory; Bi-LSTM) เพื่อเพิ่มความสามารถในการเรียนรู้ลำดับข้อมูล

อย่างไรก็ตามจากการทบทวนวรรณกรรมพบว่า ยังคงมีช่องว่างที่สำคัญคือ การสูญเสียข้อมูลสำคัญจากการสุ่มลดขนาดข้อมูลเพื่อแก้ปัญหาความไม่สมดุลของคลาส ซึ่งส่งผลกระทบต่อความแม่นยำในการระบุพฤติกรรมของผู้บริโภค เช่นเดียวกับค่า AUC ที่จำกัดเมื่อต้องเผชิญกับชุดข้อมูลซับซ้อนและมีปฏิสัมพันธ์ระหว่างตัวแปรสูง และการศึกษาที่ประยุกต์ใช้เทคนิคการอธิบายโมเดล เพื่อวิเคราะห์อิทธิพลของปัจจัยเฉพาะเจาะจงที่ส่งผลต่อการตัดสินใจของผู้ใช้ยังคงค่อนข้างจำกัด งานวิจัยนี้มีวัตถุประสงค์เพื่อพัฒนาแบบจำลองที่มีประสิทธิภาพในการพยากรณ์แนวโน้มการยกเลิกบริการของผู้ใช้บริการยูทูปพรีเมียม และระบุปัจจัยสำคัญที่มีอิทธิพลต่อการตัดสินใจเพื่อใช้เป็นแนวทางในการวางกลยุทธ์รักษาลูกค้าเชิงรุก โดยบูรณาการโครงข่ายประสาทเทียมร่วมกับอัลกอริทึมการเรียนรู้แบบรวม เพื่อเพิ่มประสิทธิภาพการพยากรณ์ให้มีความแม่นยำ ตลอดจนประยุกต์ใช้เทคนิค SHAP เพื่อให้ได้มาซึ่งองค์ความรู้ใหม่ที่สามารถนำไปใช้ในสถานการณ์จริงได้อย่างมีประสิทธิภาพ



รูปที่ 1 การพัฒนาตัวแบบพยากรณ์คุณลักษณะที่มีความสำคัญต่อการยกเลิกบริการยูทูปพรีเมียม

## 2. วิธีการทดลอง

การพัฒนาตัวแบบพยากรณ์คุณลักษณะที่มีความสำคัญต่อการยกเลิกบริการยูทูปพรีเมียม ประกอบด้วย การสร้างชุดข้อมูล การเตรียมข้อมูลก่อนการประมวลผล การพัฒนาแบบจำลอง และการประเมินประสิทธิภาพ ดังรูปที่ 1

### 2.1 การสร้างชุดข้อมูล

งานวิจัยนี้ได้ประยุกต์ใช้เทคนิคการสุ่มตัวอย่างแบบหลายขั้นตอน (Multi-stage Sampling) โดยเริ่มจากการใช้การสุ่มตัวอย่างแบบโควตา (Quota Sampling) เพื่อจัดสรรสัดส่วนผู้ตอบแบบสอบถามตามคุณลักษณะทางประชากรศาสตร์ที่สำคัญ ได้แก่ อายุ ระยะเวลาใช้งาน และรูปแบบการสมัครสมาชิก ควบคู่ไปกับการสุ่มตัวอย่างแบบสะดวก (Convenience Sampling) โดยใช้

แบบสอบถามออนไลน์ผ่านแบบฟอร์มที่เปิดเป็นสาธารณะ ผ่านการกระจายเครื่องมือวิจัยในช่องทางสื่อสังคมออนไลน์ที่หลากหลาย เพื่อลดการกระจุกตัวของข้อมูลในกลุ่มผู้ใช้งานแพลตฟอร์มใดแพลตฟอร์มหนึ่งเพียงอย่างเดียว ตั้งแต่เดือนมกราคม-กันยายน พ.ศ. 2568 รวมระยะเวลาทั้งสิ้น 9 เดือน

อย่างไรก็ตามเพื่อเป็นการยืนยันว่าจำนวนตัวอย่างที่มีขนาดใหญ่ในงานวิจัยนี้สามารถเป็นตัวแทนของประชากรในวงกว้างได้อย่างแท้จริง และปราศจากอคติของข้อมูล ผ่านกระบวนการตรวจสอบคุณภาพข้อมูลเพื่อให้นั่นใจในความถูกต้อง ผู้วิจัยได้กำหนดคำถามคัดกรองเพื่อระบุตัวตนของผู้ใช้งานยูทูปพรีเมียมที่แท้จริงก่อนเข้าสู่เนื้อหาหลักของแบบสอบถาม พร้อมทั้งดำเนินการตรวจสอบความซ้ำซ้อนของข้อมูลผ่านที่อยู่อีเมลเพื่อป้องกันอคติจากการตอบซ้ำ ซึ่งอาจส่งผลต่อความเป็นตัวแทนของประชากร ส่งผลให้การสร้างชุดข้อมูลในงานวิจัยนี้มีความน่าเชื่อถือ และสามารถนำไปอ้างอิงถึงกลุ่มประชากรเป้าหมายได้อย่างมีนัยสำคัญ โดยแบ่งหมวดหมู่ตัวแปรต้นตามลักษณะ และประเภทของข้อมูล ออกเป็น 4 หมวดหมู่ ประกอบด้วย 1) ประชากรศาสตร์ 2) พฤติกรรมการใช้งาน 3) สมาชิกและบริการ และ 4) บริการเสริม รายละเอียดดังตารางที่ 1

ตารางที่ 1 การแบ่งหมวดหมู่ตัวแปรต้น

| ตัวแปร        | ความหมาย  | ค่าที่เป็นไปได้           |
|---------------|-----------|---------------------------|
| ประชากรศาสตร์ |           |                           |
| Sex           | เพศ       | ชาย, หญิง                 |
| Age           | อายุ      | จำนวนเต็ม (ปี)            |
| Married       | สถานะสมรส | โสด, สมรส, หม้าย/หย่าร้าง |
| Child         | การมีบุตร | มีบุตร, ไม่มีบุตร         |

ตารางที่ 1 การแบ่งหมวดหมู่ตัวแปรต้น (ต่อ)

| ตัวแปร              | ความหมาย                  | ค่าที่เป็นไปได้                                                                                     |
|---------------------|---------------------------|-----------------------------------------------------------------------------------------------------|
| ประชากรศาสตร์ (ต่อ) |                           |                                                                                                     |
| Place               | สถานที่หลักในการใช้บริการ | บ้าน, ที่ทำงาน, ระหว่างเดินทาง, สถานที่สาธารณะ                                                      |
| Period              | ระยะเวลาการเป็นสมาชิก     | จำนวนเต็ม (เดือน)                                                                                   |
| พฤติกรรมการใช้งาน   |                           |                                                                                                     |
| WatchTime           | ชั่วโมงการรับชม           | จำนวนเต็ม (ชั่วโมงต่อวัน)                                                                           |
| ContentCount        | จำนวนวิดีโอที่รับชม       | จำนวนเต็ม (วิดีโอที่รับชมต่อวัน)                                                                    |
| TopContent          | ประเภทเนื้อหาที่รับชมบ่อย | เสียงเท่านั้น, ภาพและเสียง                                                                          |
| LoginFrequency      | ความถี่การเข้าใช้         | จำนวนเต็ม (ครั้งต่อวัน)                                                                             |
| TopViewContent      | ประเภทเนื้อหาหลักที่รับชม | เกม, เพลง, ข่าวสาร, กีฬา, พอดแคสต์, ภาพยนตร์/รายการทีวี, การศึกษา, แฟชั่น/ความงาม, สยองขวัญ, อื่น ๆ |
| Playlists           | เพลย์ลิสต์ที่สร้าง/ติดตาม | จำนวนเต็ม (เพลย์ลิสต์)                                                                              |
| Subscribed          | จำนวนช่องที่ติดตาม        | จำนวนเต็ม (ช่อง)                                                                                    |
| สมาชิกและบริการ     |                           |                                                                                                     |
| Contract            | รูปแบบสัญญา               | รายเดือน, รายปี                                                                                     |
| PaymentMethod       | วิธีการชำระเงิน           | บัตรเครดิต, AIS, Google Play, TrueMoney                                                             |
| TypeSubscription    | รูปแบบการสมัครสมาชิก      | แผนส่วนบุคคล, แผนครอบครัว, แผนนักเรียน/นักศึกษา                                                     |

## ตารางที่ 1 การแบ่งหมวดหมู่ตัวแปรต้น (ต่อ)

| ตัวแปร                          | ความหมาย              | ค่าที่เป็นไปได้                    |
|---------------------------------|-----------------------|------------------------------------|
| <b>สมาชิกและการบริการ (ต่อ)</b> |                       |                                    |
| ServiceChanges                  | ขอเปลี่ยนบริการ       | จำนวนเต็ม (ครั้ง)                  |
| AcquisitionSource               | แหล่งที่มาของลูกค้า   | การโฆษณา, การแนะนำ, การทดลองใช้ฟรี |
| CamelCase                       | ปัญหาการเข้ารหัส      | จำนวนเต็ม (ครั้ง)                  |
| SupportTickets                  | การติดต่อฝ่ายสนับสนุน | จำนวนเต็ม (ครั้ง)                  |
| <b>บริการเสริม</b>              |                       |                                    |
| InternetService                 | ประเภทเครือข่าย       | Wi-Fi, 4G/5G                       |
| TechSupport                     | การสนับสนุนด้านเทคนิค | ไม่เคย, เคย                        |
| StreamingTV                     | บริการสตรีมมิงทีวี    | ไม่มี, มี                          |
| DigitalTV                       | บริการดิจิทัลทีวี     | ไม่มี, มี                          |

จากตารางที่ 1 ตัวแปรตาม (Dependent Variable) คือ “ยกเลิกการใช้บริการ (Cancellation)” หากผู้ตอบแบบสอบถามยังคงใช้บริการอยู่พบว่ามีอยู่ในปัจจุบัน กำหนดค่าเป็น “ไม่ยกเลิก” ตรงกันข้าม หากปัจจุบันไม่ได้ใช้บริการแล้ว กำหนดค่าเป็น “ยกเลิก”

## 2.2 การเตรียมข้อมูลก่อนการประมวลผล

การเตรียมข้อมูลก่อนการประมวลผลเพื่อให้ข้อมูลอยู่ในรูปแบบที่เหมาะสมต่อการวิเคราะห์ มีรายละเอียดดังนี้

### 2.2.1 การตรวจสอบช่วงข้อมูล (Range Validation)

การเก็บข้อมูลด้วยแบบสอบถาม แม้จะช่วยลดปัญหาข้อมูลที่สูญหาย (Missing Value) และปัญหาข้อมูลผิดปกติ แต่การให้ผู้ใช้ระบุข้อมูลอาจเสี่ยงต่อค่าที่ผิดปกติ เนื่องจากจากความตั้งใจหรือไม่ตั้งใจก็ได้

ดังนั้นจึงต้องตรวจสอบค่าที่ไม่สอดคล้องกับความเป็นจริง ทั้งนี้ หากตรวจพบจะทำเครื่องหมายแยกออกมาเป็น “ผิดปกติ”

### 2.2.2 การแทนค่ารหัสหมวดหมู่ (Categorical Code Representation)

เนื่องจากข้อมูลที่อยู่ในรูปของจำนวนเต็มสามารถนำไปวิเคราะห์ และประมวลผลได้โดยตรง โดยไม่จำเป็นต้องมีการแปลงรหัสเพิ่มเติม เนื่องจากตัวเลขเหล่านี้มีความหมายเชิงปริมาณ และสามารถคำนวณทางสถิติได้ทันที ในทางกลับกันตัวแปรเชิงหมวดหมู่จำเป็นต้องทำการแปลงให้อยู่ในรูปตัวเลขเพื่อความสะดวกในการประมวลผลเชิงคำนวณ

### 2.2.3 การตรวจสอบความสอดคล้องเชิงตรรกะ (Logical Consistency)

สำหรับตัวแปรที่มีความสัมพันธ์กันโดยตรงเป็นขั้นตอนสำคัญในการประเมินคุณภาพข้อมูล เพื่อให้แน่ใจว่าค่าของตัวแปรที่บันทึกไว้นั้นไม่ขัดแย้งกันเอง โดยเฉพาะเมื่อมีความสัมพันธ์เชิงตรรกะหรือเชิงกฎเกณฑ์กำหนดอยู่แล้ว

### 2.2.4 การแบ่งชุดข้อมูล (Data Splitting)

การแยกชุดข้อมูลต้นฉบับออกเป็นส่วยย่อยเพื่อใช้ในการฝึกฝน และประเมินประสิทธิภาพ นอกจากนี้ยังช่วยลดความเสี่ยงต่อการเกิดภาวะโมเดลไม่สามารถจับความสัมพันธ์ของข้อมูลได้ (Underfitting) และสามารถพยากรณ์ผลลัพธ์กับข้อมูลที่ไม่เคยเห็นมาก่อนได้อย่างแม่นยำมากขึ้น

## 2.3 การพัฒนาแบบจำลอง

การพัฒนาแบบจำลองด้วยโครงข่ายประสาทเทียม [4] ในงานวิจัยนี้ใช้โครงสร้างแบบตามลำดับ (Sequential) ที่ประกอบด้วยชั้นซ่อน (Hidden Layers) จำนวน 2 ชั้น ขนาด 64 และ 32 นิวรอน ตามลำดับ โดยประยุกต์ใช้ฟังก์ชันกระตุ้นแบบ ReLU ในชั้นซ่อนเพื่อเพิ่มประสิทธิภาพ



การเรียนรู้ความสัมพันธ์ที่ซับซ้อน และใช้ฟังก์ชันซิกมอยด์ (Sigmoid) ในชั้นผลลัพธ์ (Output Layer) สำหรับการจำแนกประเภทแบบไบนารี (Binary Classification) ผ่านการประมวลผลข้อมูลนำเข้าที่ผ่านการปรับบรรทัดฐานด้วยวิธีการสเกลเลอร์มาตรฐาน (StandardScaler) ในส่วนของกระบวนการฝึกสอนโมเดลได้กำหนดพารามิเตอร์การเรียนรู้ด้วยตัวปรับโครงสร้างอัลกอริทึมสำหรับหาค่าที่เหมาะสมที่สุดแบบ Adam (Adam Optimizer) ควบคู่กับฟังก์ชันการสูญเสียด้วยค่าความคลาดเคลื่อนแบบไบนารีครอสเอนโทรปี (Binary Cross-Entropy) โดยใช้จำนวนรอบในการเรียนรู้เท่ากับ 100 รอบ (Epochs) และขนาดข้อมูลรายกลุ่ม (Batch Size) ที่ 32 ส่งผลให้โมเดลสามารถวิเคราะห์ปัจจัยเชิงพฤติกรรม และปัจจัยด้านประชากรศาสตร์ต่าง ๆ เพื่อระบุแนวโน้มการยกเลิกบริการของลูกค้าได้อย่างมีประสิทธิภาพ

นอกจากนี้การพัฒนาแบบจำลองยังร่วมกับอัลกอริทึมการเรียนรู้แบบรวม [12] กลุ่มบูตติง (Boosting) ที่ได้รับความนิยมในปัจจุบัน เพื่อเพิ่มประสิทธิภาพ และความแม่นยำผ่านกลไกการเรียนรู้แบบลำดับ (Iterative Learning) ที่เน้นการลดความคลาดเคลื่อน (Bias) จากความผิดพลาดของโมเดลก่อนหน้านี้อย่างมีระบบ ประกอบด้วย XGBoost และ LightGBM เป็นอัลกอริทึมเพิ่มประสิทธิภาพแบบไล่ระดับ (Gradient Boosting Algorithm) โดดเด่นด้านความเร็วในการประมวลผลบนชุดข้อมูลขนาดใหญ่ด้วยโครงสร้างต้นไม้ตัดสินใจที่มีประสิทธิภาพสูง ขณะที่ CatBoost ช่วยจัดการตัวแปรเชิงหมวดหมู่ได้อย่างแม่นยำโดยไม่ต้องผ่านกระบวนการแปลงข้อมูลที่ซับซ้อน ดังนั้นการบูรณาการโมเดลเหล่านี้จึงช่วยให้สามารถวิเคราะห์รูปแบบพฤติกรรมผู้ใช้ที่หลากหลาย และระบุปัจจัยสำคัญที่มีผลต่อการตัดสินใจของลูกค้าได้อย่างมีนัยสำคัญทางสถิติ

และตอบโจทย์การนำไปใช้จริงในเชิงธุรกิจ

การคัดเลือกตัวแปรที่มีผลกระทบสูงก่อนจะตัดตัวแปรที่มีผลกระทบต่ำออก และสรุปความสำคัญของตัวแปรแต่ละตัวด้วยค่าเฉลี่ยของค่าสัมบูรณ์ (Mean Absolute SHAP Value) [13] เป็นตัวแทนความสำคัญของคุณลักษณะเชิงบวกหรือเชิงลบต่อการพยากรณ์ผลลัพธ์ [14] โดยเริ่มจากเกณฑ์วิเคราะห์ความสำคัญของตัวแปรด้วย SHAP (SHAP Importance Value) ต่ำเพื่อเก็บตัวแปรที่มีความสำคัญปานกลางไว้ จากนั้นปรับเกณฑ์สูงขึ้นในรอบถัดไปเพื่อคัดเลือกเฉพาะตัวแปรที่มีผลต่อโมเดลสูงสุดทำให้ตัดตัวแปรที่ไม่มีความสำคัญเป็นไปอย่างมีหลักการ และไม่ขึ้นกับค่าความสำคัญแบบเดิมเพียงอย่างเดียวเมื่อได้ชุดตัวแปรสำคัญจะฝึกฝนโมเดลใหม่ และประเมินประสิทธิภาพอีกครั้ง จนกว่าจะได้โมเดลมีประสิทธิภาพสูงสุดบนชุดทดสอบการดำเนินการเช่นนี้ช่วยลดจำนวนตัวแปรที่ไม่สำคัญลดความซับซ้อนของโมเดล และป้องกันปัญหาการเรียนรู้เกิน (Overfitting) ในขณะเดียวกันยังคงรักษาความแม่นยำในการพยากรณ์

อย่างไรก็ดีแม้การคัดเลือกคุณลักษณะด้วยการเรียนรู้แบบลำดับร่วมกับค่า SHAP จะเป็นการต่อยอดจากแนวคิดเดิม แต่มีความแตกต่างอย่างมีนัยสำคัญเหนือกว่าการคัดเลือกแบบดั้งเดิมที่มักใช้วิธีการคัดเลือกแบบสถิติเชิงเดียวหรือการวัดความสำคัญเพียงครั้งเดียว เช่น การวัดความสัมพันธ์เชิงเส้นหรือสหสัมพันธ์ (Correlation) เปลี่ยนมาเป็นการประเมินส่วนร่วมที่แท้จริง (Marginal Contribution) ของแต่ละตัวแปรในทุกมิติของความสัมพันธ์ จึงช่วยขจัดปัญหาความทับซ้อนของข้อมูล (Multicollinearity) และปฏิสัมพันธ์ระหว่างตัวแปรที่ซับซ้อน (Non-linear Interactions) อย่างมีประสิทธิภาพ เนื่องจากโมเดลจะทำการประเมินค่าน้ำหนักใหม่ในทุกรอบที่คุณลักษณะที่ไม่เกี่ยวข้องจะถูกคัดออก ส่งผลให้ได้ชุดคุณลักษณะมีความสอดคล้อง

ทั้งในระดับภาพรวม (Global) และระดับรายบุคคล (Local) นำไปสู่การสร้างแบบจำลองที่มีความกระชับ (Parsimonious Model) แต่ยังคงไว้ซึ่งประสิทธิภาพในการพยากรณ์สูงสุดและสามารถอธิบายเหตุผลเบื้องหลังการตัดสินใจของปัญญาประดิษฐ์ได้อย่างแม่นยำตามหลักการของ XAI (Explainable AI)

## 2.4 การประเมินประสิทธิภาพ

งานวิจัยนี้ประเมินประสิทธิภาพด้วยชุดตัวชี้วัดที่ครอบคลุมทุกมิติ [15] ประกอบด้วย

### 2.4.1 ค่าความถูกต้อง (Accuracy)

สำหรับใช้วัดถูกต้องโดยรวมของโมเดล หรือสัดส่วนของตัวอย่างทั้งหมดที่โมเดลพยากรณ์ถูกต้อง ดังสมการที่ (1)

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

### 2.4.2 ค่าความแม่นยำ (Precision)

ใช้วัดการพยากรณ์คลาสบวก แสดงสัดส่วนของตัวอย่างที่โมเดลพยากรณ์เป็นบวกและถูกต้อง ดังสมการที่ (2)

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

### 2.4.3 ค่าการเรียกคืน (Recall)

สำหรับใช้วัดความสามารถในการตรวจจับตัวอย่างจริงเป็นบวก แสดงสัดส่วนของตัวอย่างบวกที่โมเดลสามารถพยากรณ์ถูกต้อง ดังสมการที่ (3)

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

### 2.4.4 ค่าประสิทธิภาพโดยรวม (F-measure)

เป็นค่ากลางสำหรับประเมินความสมดุลระหว่างค่าความแม่นยำและค่าการเรียกคืน ดังสมการที่ (4)

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

### 2.4.5 ค่า AUC (Area Under the ROC Curve)

สำหรับใช้วัดความสามารถของโมเดลในการแยกแยะคลาสบวก และคลาสลบ ดังสมการที่ (5) และ (6)

$$TPR = \frac{TP}{TP + FN} \quad (5)$$

$$FPR = \frac{FP}{FP + TN} \quad (6)$$

## 3. ผลการทดลองและอภิปรายผลการทดลอง

แบบจำลองพยากรณ์การยกเลิกบริการยูทูปพรีเมียมพัฒนาขึ้นด้วยการเขียนโปรแกรมภาษาไพทอนบน Google Colaboratory แบบมีค่าใช้จ่ายสำหรับการฝึกฝนโมเดลที่ต้องการเพิ่มทรัพยากรการประมวลผลมีรายละเอียดดังนี้

### 3.1 ผลการสร้างชุดข้อมูล

ผู้วิจัยได้ตรวจสอบความถูกต้องของแบบสอบถามพบว่าข้อมูลทั้งสิ้น 10,983 รายการที่ตรงตามข้อกำหนดในการวิจัย จากนั้นจึงนำเข้าสู่การวิเคราะห์ข้อมูลเบื้องต้น ดังตารางที่ 2 และ 3

ตารางที่ 2 ค่าน้อยที่สุด ค่ามากที่สุด ค่าเฉลี่ย และค่ามัธยฐานสำหรับข้อมูลจำนวนเต็ม

| ตัวแปร | Min | Max | Mean  | Median |
|--------|-----|-----|-------|--------|
| Age    | 18  | 70  | 43.61 | 43     |
| Period | 1   | 120 | 47.80 | 44     |



**ตารางที่ 2** ค่าน้อยที่สุด ค่ามากที่สุด ค่าเฉลี่ย และ  
ค่ามัธยฐานสำหรับข้อมูลจำนวนเต็ม (ต่อ)

| ตัวแปร         | Min | Max | Mean  | Median |
|----------------|-----|-----|-------|--------|
| WatchTime      | 0   | 12  | 5.26  | 5      |
| ContentCount   | 0   | 50  | 17.61 | 14     |
| LoginFrequency | 0   | 30  | 15.15 | 15     |
| Playlists      | 0   | 20  | 10.10 | 10     |
| Subscribed     | 0   | 100 | 37.34 | 33     |
| ServiceChanges | 0   | 5   | 2.51  | 3      |
| CamelCase      | 0   | 5   | 2.50  | 2      |
| SupportTickets | 0   | 10  | 4.99  | 5      |

**ตารางที่ 3** การแจกแจงคลาสสำหรับตัวแปรหมวดหมู่

| ตัวแปร     | การแจกแจงคลาส  |       |
|------------|----------------|-------|
| Sex        | ชาย            | 4,527 |
|            | หญิง           | 6,456 |
| Married    | โสด            | 6,023 |
|            | สมรส           | 2,998 |
|            | หม้าย/หย่าร้าง | 1,962 |
| Child      | ไม่มีบุตร      | 6,001 |
|            | มีบุตร         | 4,982 |
| Sex        | ชาย            | 4,527 |
|            | หญิง           | 6,456 |
| Married    | โสด            | 6,023 |
|            | สมรส           | 2,998 |
|            | หม้าย/หย่าร้าง | 1,962 |
| Child      | ไม่มีบุตร      | 6,001 |
|            | มีบุตร         | 4,982 |
| Place      | บ้าน           | 4,743 |
|            | ที่ทำงาน       | 2,706 |
|            | ระหว่างเดินทาง | 1,738 |
|            | สาธารณะ        | 1,796 |
| TopContent | เสียง          | 3,518 |
|            | ภาพและเสียง    | 7,465 |

**ตารางที่ 3** การแจกแจงคลาสสำหรับตัวแปรหมวดหมู่ (ต่อ)

| ตัวแปร            | การแจกแจงคลาส        |       |
|-------------------|----------------------|-------|
| TopViewContent    | เกม                  | 1,165 |
|                   | เพลง                 | 1,657 |
|                   | ข่าวสาร              | 1,925 |
|                   | กีฬา                 | 1,109 |
|                   | พอดแคสต์             | 688   |
|                   | ภาพยนตร์/รายการทีวี  | 746   |
|                   | แฟชั่น/ความงาม       | 522   |
|                   | การศึกษา             | 1,069 |
|                   | สยองขวัญ             | 1,063 |
|                   | อื่น ๆ               | 1,039 |
| Contract          | รายเดือน             | 6,627 |
|                   | รายปี                | 4,356 |
| PaymentMethod     | บัตรเครดิต           | 2,761 |
|                   | Google Play          | 2,919 |
|                   | AIS                  | 2,922 |
|                   | True Money           | 2,381 |
| TypeSubscription  | แผนส่วนบุคคล         | 6,682 |
|                   | แผนครอบครัว          | 1,678 |
|                   | แผนนักเรียน/นักศึกษา | 2,623 |
| AcquisitionSource | การโฆษณา             | 4,667 |
|                   | การแนะนำ             | 1,644 |
|                   | การทดลองใช้ฟรี       | 4,672 |
| InternetService   | Wi-Fi                | 7,598 |
|                   | 4G/5G                | 3,385 |
| TechSupport       | ไม่เคย               | 6,049 |
|                   | เคย                  | 4,934 |
| StreamingTV       | ไม่มี                | 8,550 |
|                   | มี                   | 2,433 |
| DigitalTV         | ไม่มี                | 3,560 |
|                   | มี                   | 7,423 |
| Cancellation      | ไม่ยกเลิก            | 7,526 |
|                   | ยกเลิก               | 3,457 |

### 3.2 ผลการเตรียมข้อมูลก่อนการประมวลผล

เนื่องจากข้อมูลดิบอาจไม่อยู่ในรูปแบบที่เหมาะสมต่อการนำไปใช้กับโมเดล จึงต้องผ่านขั้นตอนการประมวลผลข้อมูล ประกอบด้วย

3.2.1 ผลการตรวจสอบช่วงข้อมูล จากการกำหนดขอบเขตที่เป็นไปได้ตามความสมเหตุสมผล เช่น ตัวแปร Age ถูกกำหนดให้มีค่าอยู่ระหว่าง 10-99 ปี ขณะที่ตัวแปร WatchTime กำหนดให้อยู่ระหว่าง 0-24 ชั่วโมงต่อวัน นอกจากนี้ตัวแปรที่นับจำนวน เช่น ContentCount จะกำหนดช่วงให้อยู่ที่ 0-500 ครั้ง เพื่อสะท้อนขอบเขตการใช้งานจริง ส่วนตัวแปรเชิงปริมาณ เช่น LoginFrequency, Period, Playlists, Subscribed รวมถึงตัวแปร CamelCase, SupportTickets และ ServiceChanges จะต้องมีค่าเป็นจำนวนเต็มที่ไม่เป็นลบ ( $\geq 0$ ) เป็นต้น ทั้งนี้หากตรวจพบค่าที่นอกช่วงตัวเลขจะพิจารณาตัดข้อมูลรายการดังกล่าวออกไป

3.2.2 ผลการแทนค่ารหัสหมวดหมู่ให้อยู่ในรูปตัวเลขเพื่อความสะดวกในการประมวลผล โดยหมวดหมู่แบบ Binary เช่น Child, TechSupport, StreamingTV และ DigitalTV สามารถแทนค่าเป็น 0 และ 1 ได้โดยตรง เช่น มี/ไม่มี หรือ เคย/ไม่เคย เป็นต้น ส่วนหมวดหมู่แบบ Nominal เช่น ตัวแปร Sex, Place, TopContent, TopViewContent, PaymentMethod, TypeSubscription, AcquisitionSource และตัวแปร InternetService ควรเข้ารหัสแบบ One-hot Encoding เพื่อหลีกเลี่ยงการตีความลำดับที่ผิดพลาด ขณะที่หมวดหมู่แบบ Ordinal เช่น Married และ Contract แทนค่าเป็นลำดับตัวเลข เช่น 0=โสด, 1=สมรส 2=หม้าย/หย่าร้าง หรือ 0=รายเดือน 1=รายปี เพื่อสะท้อนถึงลำดับเชิงตรรกะของตัวแปร ดังนั้น Cancellation หากยังคง

ใช้บริการอยู่ในปัจจุบัน กำหนดค่าเป็น 0 (No) และหากเคยใช้บริการ แต่ปัจจุบันไม่ได้ใช้บริการแล้ว กำหนดค่าเป็น 1 (Yes)

3.2.3 ผลการตรวจสอบความสอดคล้องเชิงตรรกะสำหรับตัวแปรที่มีความสัมพันธ์กันโดยตรง เช่น หาก SupportTickets เท่ากับ 0 แต่กลับมี TechSupport หรือ หาก WatchTime เท่ากับ 0 แต่ ContentCount มากกว่า 0 เช่นเดียวกับ Cancellation หากเท่ากับ “No” แต่ Period เท่ากับ 0 จากที่กล่าวมาถือว่าข้อมูลมีตรรกะขัดแย้งกันต้องทำการตรวจสอบ และปรับแก้ให้ถูกต้อง

3.2.4 ผลการแบ่งชุดข้อมูลคือ การแยกชุดข้อมูลต้นฉบับออกเป็นส่วนย่อย งานวิจัยนี้กำหนดให้ร้อยละ 80 สำหรับชุดข้อมูลฝึกฝน (Training Set) สำหรับเรียนรู้รูปแบบและคุณลักษณะสำคัญของข้อมูล และร้อยละ 20 สำหรับชุดข้อมูลทดสอบ (Test Set) ในการประเมินประสิทธิภาพของโมเดล

### 3.3 ผลการพัฒนาแบบจำลอง

การพัฒนาแบบจำลองด้วยโครงข่ายประสาทเทียมและอัลกอริทึมการเรียนรู้แบบรวม ด้วยโมเดล XGBoost, LightGBM และ CatBoost นั้น เนื่องจากข้อมูลที่นำมาใช้ในการวิเคราะห์มีความไม่สมดุลของคลาส อาจก่อให้เกิดอคติในกระบวนการเรียนรู้ของเครื่อง จนนำมาสู่ความคลาดเคลื่อนในการพยากรณ์ จึงจำเป็นต้องมีการปรับค่าพารามิเตอร์ *scale\_pos\_weight* หรือการสุ่มตัวอย่าง (Sampling) ช่วยให้โมเดลให้ความสำคัญกับคลาสที่มีจำนวนน้อยมากขึ้น โดยกำหนด *scale\_pos\_weight* จากตัวแปร Cancellation ที่เป็น “No” เท่ากับ 7,526 รายการ และ “Yes” เท่ากับ 3,457 รายการ ดังสมการที่ (7)

$$\begin{aligned} scale\_pos\_weight &= \frac{n_{positive}}{n_{negative}} \quad (7) \\ &= \frac{7,526}{3,457} \\ &= 2.1770 \end{aligned}$$

จากสมการที่ (7) แสดงถึงข้อมูลชุดฝึกฝนที่ไม่ยกเลิกบริการ (non Cancellation) มากกว่ายกเลิกบริการ (Cancellation) ประมาณ 2.18 เท่า คิดเป็น 68.53% และ 31.47% ตามลำดับ ดังนั้นการตั้งค่า *scale\_pos\_weight* จะช่วยถ่วงน้ำหนักให้ความผิดพลาดในคลาสยกเลิกบริการให้มีความสำคัญมากขึ้นระหว่างฝึกฝนโมเดลด้วยการคัดเลือกตัวแปรแบบทีละขั้น (Stepwise Feature Elimination) แบบคัดเลือกย้อนกลับ (Backward Elimination) โดยเริ่มจากการใช้ตัวแปรทั้งหมด และค่อย ๆ ลบตัวแปรที่มีความสำคัญน้อยที่สุดทีละตัว จนกว่าจะได้ชุดตัวแปรคุณลักษณะที่ให้ผลลัพธ์ที่ดีที่สุดเมื่อวัดผลจากค่าประสิทธิภาพโดยรวม

อย่างไรก็ตามความสำคัญของตัวแปรไม่สามารถพิจารณาจากค่าประสิทธิภาพโดยรวมเพียงอย่างเดียว จึงนำเทคนิค SHAP (SHapley Additive exPlanations) มาใช้เป็นเครื่องมืออธิบายผลลัพธ์ของแต่ละตัวแปรต่อการพยากรณ์โดยตรง ส่งผลให้การคัดเลือกตัวแปรมีเหตุผลเชิงอธิบาย จึงไม่ใช่เพียงการตัดสินใจตามค่าตัวชี้วัดเพียงอย่างเดียว ดังตารางที่ 4 พบว่า XGBoost และ CatBoost ใช้ตัวแปร 11 ตัวที่เหมือนกันทุกตัว ในทางกลับกัน LightGBM ใช้ตัวแปรเพียง 8 ตัว โดยตัด *Age*, *Married* และ *LoginFrequency* ออก โดยตัวแปรหลักที่มีอิทธิพลต่อการยกเลิกบริการคือ *ContentCount*, *Subscribed* และ *Period* ซึ่งเป็นข้อมูลที่สะท้อนถึงความผูกพันและการมีส่วนร่วมของผู้ใช้ต่อแพลตฟอร์ม

ตารางที่ 4 ค่า SHAP importance ของชุดคุณลักษณะ

| ชุดคุณลักษณะ   | XGBoost | LightGBM | CatBoost |
|----------------|---------|----------|----------|
| Age            | 0.0624  | –        | 0.0613   |
| Married        | 0.1309  | –        | 0.1257   |
| Period         | 1.0526  | 1.0978   | 0.9603   |
| TechSupport    | 0.1776  | 0.1572   | 0.1729   |
| Contract       | 0.2695  | 0.3200   | 0.3137   |
| WatchTime      | 0.7935  | 0.8591   | 0.6565   |
| ContentCount   | 1.9073  | 2.2409   | 1.8442   |
| LoginFrequency | 0.0929  | –        | 0.0721   |
| Subscribed     | 1.3796  | 1.5865   | 1.2594   |
| CamelCase      | 0.4736  | 0.4707   | 0.5609   |
| SupportTickets | 0.3038  | 0.3095   | 0.3150   |

จากตารางที่ 4 เมื่อพิจารณาคุณลักษณะที่มีความสำคัญต่อการยกเลิกบริการยูทูปพรีเมียมจากแต่ละอัลกอริทึมพบว่า XGBoost ให้ความสำคัญสูงสุดกับตัวแปร *ContentCount*, *Subscribed* และ *Period* ซึ่งสะท้อนพฤติกรรมการใช้งาน และระยะเวลาการสมัครที่มีอิทธิพลต่อการตัดสินใจยกเลิกบริการ ในขณะที่ LightGBM ให้ความสำคัญสูงกับ *ContentCount*, *Subscribed* และ *WatchTime* แสดงให้เห็นว่าระดับการรับชมวิดีโอ และปริมาณเนื้อหาที่ผู้ใช้เข้าถึงมีบทบาทสำคัญต่อการคงอยู่ของลูกค้า ส่วน CatBoost เน้นตัวแปร *ContentCount*, *Subscribed* และ *Period* เช่นเดียวกับ XGBoost แต่ค่าความสำคัญของตัวแปร *CamelCase* และ *SupportTickets* มีน้ำหนักสูงขึ้นกว่าอัลกอริทึมอื่น แสดงให้เห็นว่าการจัดการด้านการชำระเงิน และบริการสนับสนุนมีผลต่อการตัดสินใจยกเลิกบริการเช่นกัน

### 3.4 ผลการประเมินประสิทธิภาพ

หลังจากได้ชุดตัวแปรคุณลักษณะที่ดีที่สุดแล้วนำมาทดสอบประสิทธิภาพของโมเดลด้วยค่าความถูกต้อง

ค่าความแม่นยำ ค่าการเรียกคืน ค่าประสิทธิภาพโดยรวม และค่า AUC บนชุดข้อมูลทดสอบ ดังตารางที่ 5

**ตารางที่ 5** ผลการประเมินประสิทธิภาพด้วยตัวชี้วัดบนชุดข้อมูลทดสอบ

| ตัวชี้วัด            | XGBoost | LightGBM | CatBoost |
|----------------------|---------|----------|----------|
| ค่าความถูกต้อง       | 0.8457  | 0.8434   | 0.8457   |
| ค่าความแม่นยำ        | 0.6929  | 0.6891   | 0.6929   |
| ค่าการเรียกคืน       | 0.9162  | 0.9125   | 0.9162   |
| ค่าประสิทธิภาพโดยรวม | 0.7890  | 0.7857   | 0.7890   |
| ค่า AUC              | 0.9295  | 0.9281   | 0.9295   |

จากตารางที่ 5 การเปรียบเทียบผลลัพธ์ของการผสมผสานโครงข่ายประสาทเทียมกับอัลกอริทึมการเรียนรู้แบบรวมทั้ง 3 โมเดลบนชุดข้อมูลทดสอบ ได้แก่ XGBoost, LightGBM และ CatBoost ด้วยตัวชี้วัดประสิทธิภาพที่ครอบคลุมทุกมิติ จากการประเมินพบว่าประสิทธิภาพในแต่ละตัวชี้วัดมีความใกล้เคียงกันมาก โดยค่าความถูกต้องทั้ง XGBoost และ CatBoost เท่ากันคือ 0.8457 ซึ่งสูงกว่า LightGBM เล็กน้อย สำหรับค่าการเรียกคืน ซึ่งบ่งบอกถึงความสามารถในการจับกลุ่มผู้ที่ยกเลิกบริการได้ถูกต้องพบว่า XGBoost และ CatBoost มีค่าสูงที่สุดเท่ากันที่ 0.9162 แสดงว่าสามารถตรวจจับได้ครอบคลุมมากที่สุด รองลงมาคือ LightGBM เท่ากับ 0.9125

เมื่อพิจารณาค่าประสิทธิภาพโดยรวมพบว่า XGBoost และ CatBoost มีค่าสูงที่สุดคือ 0.7890 รองลงมาคือ LightGBM เท่ากับ 0.7857 เช่นเดียวกับค่า AUC ที่เป็นตัวชี้วัดการแยกแยะระหว่างกลุ่มยกเลิกบริการและไม่ยกเลิกบริการนั้น XGBoost และ CatBoost มีค่า

AUC สูงที่สุดคือ 0.9295 แสดงถึงความสามารถในการจำแนกกลุ่มที่ชัดเจนที่สุด รองลงมาคือ LightGBM เท่ากับ 0.9281

อย่างไรก็ดีค่าความแม่นยำพบว่า XGBoost และ CatBoost มีค่าสูงที่สุดที่ 0.6929 ซึ่งสะท้อนถึงความสามารถในการพยากรณ์ผู้ที่ยกเลิกบริการได้แม่นยำมากที่สุด ขณะที่ LightGBM มีค่าความแม่นยำต่ำกว่าเล็กน้อยที่ 0.6891 แต่เป็นที่น่าสนใจว่าค่าความแม่นยำที่ค่อนข้างต่ำโดยเปรียบเทียบค่าการเรียกคืนที่สูงมาก สะท้อนให้เห็นว่าแบบจำลองนี้ถูกปรับตั้งมาในลักษณะเน้นการตรวจจับกลุ่มเสี่ยงให้ครอบคลุมมากที่สุด แต่อาจต้องแลกมาด้วยความคลาดเคลื่อนในลักษณะการพยากรณ์ผิดพลาดว่าลูกค้าจะยกเลิกบริการ (False Positive; FP) ในสัดส่วนที่ค่อนข้างสูง ซึ่งผลลัพธ์ในลักษณะนี้บ่งชี้ถึงกลยุทธ์แบบเผื่อระวังสูงสุด เพื่อไม่ให้พลาดการตรวจจับลูกค้าที่มีแนวโน้มจะยกเลิกบริการจริง อันจะส่งผลเสียหายในภาพรวมของธุรกิจ

เมื่อพิจารณาในรายละเอียดจะเห็นว่าค่าความแม่นยำที่จำกัดนี้ ส่งผลกระทบโดยตรงต่อต้นทุนการดำเนินงาน เนื่องจากองค์กรอาจต้องสูญเสียงบประมาณทางการตลาดหรือทรัพยากรบุคคลไปกับการมอบข้อเสนอพิเศษ หรือการติดต่อสื่อสารกับลูกค้ากลุ่มที่ไม่ได้มีเจตนาจะยกเลิกบริการจริงถึงประมาณร้อยละ 30 ของกลุ่มที่พยากรณ์ไว้ ดังนั้นงานวิจัยนี้จึงเสนอแนะว่าควรนำผลลัพธ์จากแบบจำลองไปใช้ควบคู่กับการจัดลำดับความสำคัญตามค่าความน่าจะเป็น (Probability Score) โดยเลือกใช้มาตรการรักษาลูกค้าที่มีต้นทุนต่ำหรือเน้นการสร้างความสัมพันธ์ (Soft Incentives) กับกลุ่มลูกค้าที่มีความเสี่ยงไม่ชัดเจนเพื่อลดความสิ้นเปลืองของทรัพยากร ในขณะที่ยังคงรักษาข้อดีของค่าเรียกคืนที่สูงมากในการป้องกันการสูญเสียลูกค้าในภาพรวมได้อย่างมีประสิทธิภาพ

เป็นที่น่าสังเกตว่าแม้ LightGBM จะใช้ชุดตัวแปรคุณลักษณะน้อยกว่า เมื่อเปรียบเทียบกับ XGBoost และ CatBoost แต่ประสิทธิภาพโดยรวมของโมเดลยังคงใกล้เคียงกัน งานวิจัยนี้จึงเลือกใช้ชุดตัวแปรคุณลักษณะจำนวน 8 ตัวแปรที่ได้จากการวิเคราะห์ด้วยโครงข่ายประสาทเทียม ร่วมกับอัลกอริทึม LightGBM ประกอบด้วย *Period*, *TechSupport*, *Contract*, *WatchTime*, *ContentCount*, *Subscribed*, *CamelCase* และ *SupportTickets* นำเข้ากระบวนการปรับแต่งพารามิเตอร์ด้วย Optuna เพื่อค้นหาค่าพารามิเตอร์ที่เหมาะสมที่สุดในจำแนกกลุ่มผู้ใช้ที่ยกเลิกบริการ และไม่ยกเลิกบริการ รายละเอียดดังตารางที่ 6

ตารางที่ 6 พารามิเตอร์ LightGBM จาก Optuna

| พารามิเตอร์      | ค่าจาก Optuna | คำอธิบาย                                |
|------------------|---------------|-----------------------------------------|
| boosting_type    | dart          | การใช้ DART boosting ช่วยลด Overfitting |
| num_leaves       | 41            | จำนวนใบไม้สูงสุดต่อ tree                |
| max_depth        | 3             | ความลึกสูงสุดของ tree                   |
| learning_rate    | 0.0777        | อัตราการเรียนรู้                        |
| n_estimators     | 446           | จำนวน tree ที่สร้าง                     |
| subsample        | 0.8514        | สัดส่วนข้อมูลสำหรับแต่ละ tree           |
| colsample_bytree | 0.6621        | สัดส่วนฟีเจอร์สำหรับแต่ละ tree          |
| reg_alpha        | 6.6429        | L1 regularization                       |
| reg_lambda       | 0.8735        | L2 regularization                       |
| scale_pos_weight | 1.6934        | การปรับน้ำหนัก Class imbalance          |

จากตารางที่ 6 พารามิเตอร์ดังกล่าวถูกเลือกโดยอัตโนมัติผ่านกลไกการค้นหาของ Optuna ซึ่งช่วยลดภาระในการปรับแต่งแบบแมนนวล (Manual) และได้ค่าที่เหมาะสมต่อโครงสร้างข้อมูลจริงมากขึ้น เมื่อทดสอบประสิทธิภาพของโมเดลภายใต้พารามิเตอร์ที่ได้จาก Optuna พบว่าค่าความถูกต้อง ค่าความแม่นยำ ค่าการเรียกคืน ค่าประสิทธิภาพโดยรวม และค่า AUC เท่ากับ 0.85 0.70 0.89 0.79 และ 0.93 ตามลำดับ ซึ่งสูงกว่าเดิมในหลายตัวชี้วัด โดยเฉพาะค่าความแม่นยำที่เพิ่มขึ้นอย่างเด่นชัด แสดงถึงโมเดลสามารถระบุผู้ที่มีแนวโน้มยกเลิกบริการได้แม่นยำมากยิ่งขึ้น ลดปัญหาการพยากรณ์ผิดเป็นบวกปลอมได้ดีกว่าเดิม แม้ค่าการเรียกคืนจะลดลงเล็กน้อย แต่ผลรวมเชิงสมดุลยังคงมีแนวโน้มที่ดี

เมื่อเปรียบเทียบกับงานวิจัยของ Amuda และ Adeyemo [5] ที่ใช้โครงข่ายประสาทเทียมแบบหลายชั้น ซึ่งมีค่าความถูกต้อง และค่าประสิทธิภาพโดยรวมสูงกว่า 0.97 จะเห็นได้ว่าแบบจำลองของงานวิจัยนี้มีความแม่นยำต่ำกว่า อย่างไรก็ตามการใช้ข้อมูลที่มีโครงสร้างชัดเจนและความสมดุลสูง อาจส่งผลให้ค่าความถูกต้องโดยรวมสูงกว่าการประยุกต์ใช้กับข้อมูลเชิงพฤติกรรมของผู้ใช้บริการจริง ในทางกลับกันงานวิจัยของ Dalmia และคณะ [6] ซึ่งใช้เทคนิคการหาเพื่อนบ้านใกล้ที่สุด และ XGBoost มีค่าความแม่นยำอยู่ที่ 0.87 และงานของ He และคณะ [7] ผสมผสานเทคนิคการเพิ่มประสิทธิภาพแบบเกรเดียนต์กับต้นไม้ตัดสินใจแบบสุ่มอย่างยิ่งที่มีค่า AUC เพียง 0.68 เปรียบเทียบกับผลลัพธ์ของงานวิจัยนี้ที่มีค่า AUC สูงกว่าอย่างชัดเจน แสดงให้เห็นถึงความสามารถในการจำแนกกลุ่มเป้าหมายได้ดีกว่าในเชิงพื้นที่ได้กราฟโค้ง


ROC ซึ่งเป็นตัวชี้วัดประสิทธิภาพโดยรวม สำหรับงานของ Sam และคณะ [8] ที่ใช้อัลกอริทึมป่าแบบสุ่มและซัพพอร์ตเวกเตอร์แมชชีนมีความแม่นยำสูงสุดที่ 0.85 ซึ่งผลการวิจัยครั้งนี้มีค่าความถูกต้องใกล้เคียงกันแต่ให้ค่า AUC ที่สูงกว่า ซึ่งบ่งชี้ถึงความเสี่ยงในการจำแนกกลุ่มข้อมูล ในส่วนของ Pustokhina และคณะ [9] ที่ประยุกต์ใช้เทคนิคการสุ่มตัวอย่างเกินของกลุ่มน้อยแบบสังเคราะห์ เพื่อแก้ปัญหาค่าข้อมูลไม่สมดุลร่วมกับเครื่องจักรการเรียนรู้แบบเอ็กซ์ตรีมแบบถ่วงน้ำหนักที่ผ่านการหาค่าเหมาะสมที่สุดพบว่าค่าความถูกต้อง และค่าประสิทธิภาพโดยรวมเท่ากับ 0.94 และ 0.92 ตามลำดับ ในทางกลับกันงานวิจัยนี้ยังสามารถคงค่าการเรียกคืนในระดับสูงได้ดีกว่าในกรณีที่มีข้อมูลมีความหลากหลาย และไม่สมดุล นอกจากนี้ Alboukaey และคณะ [10] ที่พัฒนาโมเดลการวิเคราะห์ความสดใหม่ ความถี่ และมูลค่า ร่วมกับหน่วยความจำระยะสั้นแบบยาว และโครงข่ายประสาทเทียมคอนโวลูชันพบว่าค่า AUC และค่าประสิทธิภาพโดยรวมเท่ากับ 0.90 และ 0.80 ตามลำดับ ซึ่งต่ำกว่าแบบจำลองในงานนี้มีค่า AUC สูงถึง 0.93 ส่วนงานของ Britto และ Gobinath [11] ที่ผสมผสานระหว่างหน่วยรีเวิร์สเกตกับหน่วยความจำระยะสั้นแบบยาวสองทิศทาง ที่ให้ค่าความแม่นยำ และค่าการเรียกคืนสูงถึง 0.84 และ 0.98 ตามลำดับ ซึ่งแม้จะมีประสิทธิภาพสูงกว่า แต่ต้องอาศัยโครงสร้างข้อมูลลำดับเวลาที่ซับซ้อนและการฝึกโมเดลด้วยข้อมูลขนาดใหญ่

เมื่อพิจารณาถึงงานวิจัยระดับสากลที่มุ่งประยุกต์ใช้อัลกอริทึมการเรียนรู้แบบรวมกลุ่มบูตตึง เมื่อเปรียบเทียบกับงานของ Singh และคณะ [16] พบว่าแม้โมเดล XGBoost ให้ค่าความถูกต้องสูงสุดที่ 0.84

และป่าแบบสุ่มจะมีความสมดุลที่เหมาะสมด้วยค่าความถูกต้องและค่าการเรียกคืนที่ 0.78 และ 0.69 ตามลำดับ แต่ยังมีประสิทธิภาพต่ำกว่า โดยเฉพาะด้านการตรวจจับกลุ่มเป้าหมาย ขณะที่งานของ Chang และคณะ [17] ได้ผลลัพธ์ค่าความถูกต้อง และค่า AUC เท่ากับ 0.87 และ 0.95 ซึ่งสูงกว่าในด้านความสามารถในการจำแนกโดยรวม แต่ไม่ได้เน้นค่าการเรียกคืนอย่างชัดเจน ส่วนงานของ Noviandy และคณะ [18] พบว่าโมเดล LightGBM ให้ค่าความถูกต้อง ค่าการเรียกคืน และค่าประสิทธิภาพโดยรวม เท่ากับ 0.81 0.91 และ 0.87 ซึ่งมีแนวโน้มสอดคล้องกันในการให้ความสำคัญกับค่าการเรียกคืน แม้ค่าความถูกต้องจะต่ำกว่า เช่นเดียวกับงานของ Poudel และคณะ [19] ที่มีค่าความถูกต้องและค่า ROC-score เท่ากับ 0.81 และ 0.86 ตามลำดับ และงานวิจัยของ Li และคณะ [20] ที่โมเดล CatBoost ให้ค่าความถูกต้องสูงสุดเพียง 0.81 ซึ่งโดยรวมยังต่ำกว่างานวิจัยนี้ แสดงให้เห็นถึงความโดดเด่นทั้งในด้านค่าการเรียกคืน และค่า AUC อีกทั้งสอดคล้องกับแนวโน้มการใช้อัลกอริทึมการเรียนรู้แบบรวมกลุ่มบูตตึงที่ให้ประสิทธิภาพสูงในการพยากรณ์การยกเลิกบริการ

เมื่อพิจารณาความสำคัญของตัวแปรคุณลักษณะแต่ละตัว ทั้งลำดับความสำคัญของตัวแปร และทิศทางอิทธิพลต่อการยกเลิกบริการในเชิงข้อมูลรายบุคคลจาก SHAP Importance ของอัลกอริทึม LightGBM ดังรูปที่ 2 โดยแกน X คือ ค่า SHAP ที่เป็นบวกผลักให้โมเดลพยากรณ์การยกเลิกมากขึ้น ส่วนค่าเป็นลบผลักให้พยากรณ์ไม่ยกเลิกมากขึ้น และสีของจุดสื่อถึงค่าพีเจอร์ ประกอบด้วยสีแดงเท่ากับค่าสูง ในทางตรงกันข้ามสีน้ำเงินเท่ากับค่าต่ำ





รูปที่ 2 ชุดตัวแปรคุณลักษณะจาก SHAP importance  
ต่อการยกเลิกบริการยูทูปพรีเมียม

จากรูปที่ 2 หากจุดแดงอยู่ด้านขวาหมายถึงค่าฟีเจอร์สูงทำให้ความเสี่ยงยกเลิกบริการเพิ่มขึ้น ตรงกันข้ามหากจุดแดงอยู่ด้านซ้ายหมายถึงค่าฟีเจอร์สูงจะช่วยลดความเสี่ยงการยกเลิกบริการ เมื่อพิจารณาทิศทางอิทธิพลของตัวแปรแต่ละตัว แบ่งออกได้เป็น 2 กลุ่ม คือ กลุ่มตัวแปรหลักที่มีอิทธิพลสูงต่อการพยากรณ์ ประกอบด้วย 4 ตัวแปร ได้แก่ 1) *ContentCount* คือ จำนวนวิดีโอที่รับชมที่มีค่าสูง และกระจุกตัวอยู่ทางซ้าย โดยมีค่า SHAP ติดลบ ส่วนจุดสีน้ำเงินมีค่าต่ำ และอยู่ทางขวามีค่า SHAP เป็นบวก แสดงถึงพฤติกรรมผู้ใช้ที่ยังบริโภคคอนเทนต์มากโอกาสยกเลิกลดลง ในทางกลับกันผู้ใช้ที่บริโภคคอนเทนต์น้อยจะมีความเสี่ยงยกเลิกบริการสูง 2) *Subscribed* คือ จำนวนช่องที่ติดตามมีค่าสูงเช่นกัน ส่งผลให้ค่า SHAP ติดลบ กล่าวคือ หากมีช่องที่ติดตามมากจะช่วยลดความเสี่ยงต่อยกเลิกบริการ ขณะที่สำหรับผู้ใช้ที่ไม่ค่อยมีช่องที่ติดตาม แปลว่ามีความสนใจต่ำกว่าจะดันค่า SHAP ให้เป็นบวกหรือเสี่ยงต่อยกเลิกบริการสูงขึ้นนั่นเอง 3) *Period* ที่เป็นระยะเวลาการเป็นสมาชิก แสดงถึงระยะเวลากับความสัมพันธ์ โดยค่าสูงให้ SHAP ติดลบ และค่าต่ำให้ SHAP เป็นบวก กล่าวคือ หากผู้ใช้ที่อยู่กับแพลตฟอร์มนานจะช่วยป้องกันกันการยกเลิกบริการได้สูงขึ้น แต่ผู้ใช้งานเพียงช่วงเวลาสั้น ๆ มีโอกาสยกเลิก

บริการสูงกว่า และ 4) *WatchTime* ซึ่งมีรูปแบบเหมือน *ContentCount* แต่มีอิทธิพลน้อยกว่า โดยชั่วโมงการรับชมสูงจะลดโอกาสยกเลิกบริการ ในทางกลับกันเวลารับชมต่ำผลักดันให้เกิดยกเลิกบริการ อีกกลุ่มคือ ตัวแปรประกอบที่มีอิทธิพลต่ำ แต่อาจมีความเกี่ยวข้องทางอ้อมต่อการพยากรณ์อีก 4 ตัวแปร ได้แก่ 1) *CamelCase* ซึ่งจะตรงกันข้ามกับกลุ่มพฤติกรรมเชิงบวก โดยด้านขวามีค่า SHAP เป็นบวกแทนด้วยจุดสีแดงจำนวนมาก แสดงถึงปัญหาการชำระเงินที่บ่อยครั้ง ส่งผลโดยตรงต่อโอกาสยกเลิกบริการ 2) *SupportTickets* มีแนวโน้มเดียวกับ *CamelCase* แต่ผลกระทบต่ำกว่า เนื่องจากจำนวนครั้งที่ติดต่อฝ่ายสนับสนุนยิ่งมาก ย่อมจะสัมพันธ์กับความเสี่ยงยกเลิกบริการสูงขึ้น ซึ่งสะท้อนถึงประสบการณ์ที่ติดขัดในการใช้งาน 3) *Contract* ที่มีค่าสูงย่อมส่งผลให้ค่า SHAP ติดลบ โดยรูปแบบสัญญาณเป็นรายปีช่วยลดการยกเลิกบริการ ในขณะที่สัญญาระยะสั้นหรือแบบรายเดือน มีความเสี่ยงต่อการยกเลิกบริการมากขึ้น และ 4) *TechSupport* ที่ถึงแม้ความสำคัญโดยรวมไม่สูงมากนัก แต่ทิศทางชัดเจนจากการได้รับการสนับสนุนด้านเทคนิคที่หลากหลายจะสามารถลดโอกาสยกเลิกบริการได้ดี

นอกจากนั้นการอธิบายความสัมพันธ์ของข้อมูลทั้งในระดับภาพรวม และระดับรายบุคคล ด้วยใช้ค่า SHAP เป็นเกณฑ์ในการคัดเลือกตัวแปรที่มีความสำคัญต่ำออกจากแบบจำลอง ซึ่งช่วยเพิ่มความกระชับของโมเดลและลดปัญหาความสัมพันธ์ทับซ้อนของตัวแปรแสดงให้เห็นอย่างชัดเจนว่าในบริบทของธุรกิจสตรีมมิง ปัจจัยด้านพฤติกรรมของผู้ใช้มีความสำคัญมากกว่าปัจจัยด้านประชากรศาสตร์ โดยจำนวนวิดีโอที่รับชมเป็นปัจจัยเชิงบวกที่มีอิทธิพลสูงสุดต่อการรักษาลูกค้า ขณะที่ปัญหาการชำระเงิน และจำนวนครั้งในการติดต่อฝ่ายสนับสนุน สะท้อนถึงสัญญาณความเสี่ยงในการยกเลิกบริการ เมื่อเปรียบเทียบกับงานวิจัยในบริบท



อุตสาหกรรมโทรคมนาคม ได้แก่ Chang และคณะ [17], Novianidy และคณะ [18] และ Poudel และคณะ [19] พบว่าผลลัพธ์มีปัจจัยสำคัญที่ค้นพบแตกต่างกันตามบริบทอุตสาหกรรม โดยงานวิจัยในภาคธุรกิจโทรคมนาคมชี้ให้เห็นสอดคล้องกันว่าประเภทสัญญา โดยเฉพาะสัญญาแบบรายเดือน ระยะเวลาการเป็นสมาชิก และค่าบริการรายเดือนเป็นตัวแปรหลักที่มีอิทธิพลต่อการสูญเสียลูกค้า ทั้งนี้ สะท้อนให้เห็นว่างานวิจัยนี้มีความโดดเด่นในการชี้ให้เห็นบทบาทของปัจจัยเชิงพฤติกรรมในบริบทสตรีมมิง ขณะที่งานวิจัยในอุตสาหกรรมโทรคมนาคมให้ความสำคัญกับปัจจัยเชิงโครงสร้างของบริการมากกว่า ซึ่งแสดงถึงความแตกต่างเชิงบริบทที่สำคัญในการตีความและนำผลลัพธ์ไปประยุกต์ใช้เชิงกลยุทธ์

ผลการวิเคราะห์ข้อมูลสามารถสร้างเป็นข้อเสนอแนะ ได้แก่ 1) การรักษาเอ็นเกจเมนต์จากระบบตัวผู้ใช้ที่มี *ContentCount* หรือ *WatchTime* ต่ำและ *Period* สั้น เพื่อนำเสนอแผนกระตุ้นการใช้งาน เช่น เพลย์ลิสต์ส่วนบุคคล การแจ้งเตือนคอนเทนต์ที่เกี่ยวข้อง สิทธิพิเศษเริ่มต้น เป็นต้น 2) การป้องกันการยกเลิกเชิงรุกโดยจับสัญญาณ *CamelCase* หรือ *SupportTickets* เพื่อขยายความช่วยเหลือหรือบริการไปยังกลุ่มเป้าหมายที่ยังไม่เคยได้รับบริการที่รวดเร็วยิ่งขึ้น เช่น เสนอช่องทางชำระเงินสำรองหรือคูปองชดเชย เป็นต้น 3) การบริหารสัญญาและข้อเสนอพิเศษสำหรับกลุ่ม *Contract* ระยะสั้น อาจเสนอแพ็คเกจการต่ออายุอัตโนมัติ รวมถึงเพิ่มทางเลือกสัญญาผูกมัดระยะสั้น เช่น ราย 3 เดือนหรือราย 6 เดือน เพื่อดึงค่า SHAP ไปทางลบ และ 4) การยกระดับการให้บริการที่เกี่ยวข้องเนื่องจาก *TechSupport* ที่แม้ความสำคัญโดยรวมจะต่ำสุดแต่มีทิศทางชัดเจน ดังนั้นแนวทางการให้บริการ

ด้านเทคนิคด้วยช่องทางที่เข้าถึงง่ายและรวดเร็ว ส่งผลโดยตรงต่อการลดความเสี่ยงยกเลิกบริการ

#### 4. สรุปผลการทดลอง

การพัฒนาแบบจำลองการพยากรณ์แนวโน้มการยกเลิกบริการยูทูปพรีเมียม โดยประยุกต์ใช้โครงข่ายประสาทเทียม ร่วมกับอัลกอริทึมการเรียนรู้แบบรวมพร้อมประยุกต์ใช้กรอบการคัดเลือกคุณลักษณะแบบหลายรอบ ร่วมกับเทคนิค SHAP เพื่ออธิบายความสัมพันธ์ของข้อมูล ผลการประเมินพบว่าผลลัพธ์จากแต่ละตัวชี้วัดใกล้เคียงกันมาก โดย LightGBM จะใช้ชุดตัวแปรคุณลักษณะน้อยกว่าเมื่อเปรียบเทียบกับ XGBoost และ CatBoost แต่ประสิทธิภาพโดยรวมของโมเดลยังคงใกล้เคียงกัน งานวิจัยนี้จึงเลือกใช้ชุดตัวแปรคุณลักษณะ 8 ตัวจากโมเดล LightGBM ผ่านเทคนิค Optuna ในการปรับแต่งพารามิเตอร์จะเห็นได้ว่าแบบจำลองที่น่าเสนอในงานวิจัยนี้ แม้จะมีค่าความถูกต้อง และค่าประสิทธิภาพโดยรวมต่ำกว่าบางงานวิจัยก่อนหน้านี้ แต่มีความโดดเด่นในค่าการเรียกคืน และค่า AUC ที่อยู่ในระดับสูง แสดงถึงศักยภาพของแบบจำลองในการตรวจจับกลุ่มผู้ใช้ที่มีแนวโน้มยกเลิกบริการได้อย่างมีประสิทธิภาพ ซึ่งมีความเหมาะสมต่อการนำไปใช้ในเชิงธุรกิจเพื่อการคาดการณ์และวางแผนกลยุทธ์การรักษาผู้ใช้บริการในอนาคต

ผลการตีความแบบจำลองสะท้อนให้เห็นความแตกต่างของปัจจัยสำคัญตามบริบทอุตสาหกรรมอย่างชัดเจน โดยในธุรกิจสตรีมมิงปัจจัยด้านพฤติกรรมของผู้ใช้มีบทบาทสำคัญมากกว่าปัจจัยด้านประชากรศาสตร์ โดยเฉพาะจำนวนวิดีโอที่รับชมซึ่งเป็นปัจจัยเชิงบวกที่ส่งเสริมการคงอยู่ของลูกค้า ขณะที่ปัญหาการชำระเงินและความถี่ในการติดต่อฝ่ายสนับสนุนเป็นสัญญาณ

เดือนของความเสียหายในการยกเลิกบริการ ในทางกลับกัน บริบทของอุตสาหกรรมโทรคมนาคมให้ความสำคัญกับ ปัจจัยเชิงโครงสร้างของบริการมากกว่า โดยเฉพาะ ประเภทสัญญา ระยะเวลาการเป็นสมาชิก และค่าบริการ รายเดือน ซึ่งล้วนเป็นตัวแปรหลักที่มีอิทธิพลต่อการ สูญเสียลูกค้า แสดงให้เห็นว่าการตีความโมเดลจำเป็นต้อง พิจารณาควบคู่กับบริบทของอุตสาหกรรมเพื่อให้สามารถ นำไปใช้ในเชิงกลยุทธ์ได้อย่างเหมาะสม

เห็นได้ว่ารูปแบบอิทธิพลของตัวแปรที่มีผลต่อการ ยกเลิกบริการไม่ได้มีลักษณะเป็นเส้นตรง แต่มีความ ซับซ้อนตามพฤติกรรมการใช้งานจริง ซึ่งตัวแปรอย่าง ระยะเวลาการใช้งาน และปริมาณเนื้อหาที่รับชม มีรูปแบบการส่งอิทธิพลที่ชัดเจนต่อการตัดสินใจอยู่ หรือยกเลิกบริการ องค์ความรู้นี้ช่วยให้ผู้ประกอบการ สามารถกำหนดค่าเกณฑ์วิกฤต (Threshold) เพื่อใช้เป็น สัญญาณเตือนล่วงหน้าได้อย่างแม่นยำ อันจะนำไปสู่ ประโยชน์เชิงปฏิบัติที่ธุรกิจสามารถใช้ตัวแปรบ่งชี้ วิกฤต เช่น ปัญหาด้านการชำระเงิน หรือจำนวนครั้งที่ ติดต่อฝ่ายสนับสนุน เพื่อพยากรณ์การยกเลิกบริการ ได้อย่างแม่นยำ ช่วยให้การวางกลยุทธ์รักษาลูกค้า มีประสิทธิภาพ และลดค่าใช้จ่ายในการหาลูกค้าใหม่ อย่างไรก็ตามงานวิจัยยังมีข้อจำกัดสำคัญจากการใช้ ข้อมูลที่รวบรวมผ่านแบบสอบถามออนไลน์ ซึ่งอาจเกิด ความคลาดเคลื่อนจากความจำหรืออคติส่วนบุคคล รวมถึงข้อจำกัดของข้อมูลที่เป็นเพียงภาพรวมขณะใด ขณะหนึ่ง ทำให้ขดมิติของพฤติกรรมที่เปลี่ยนแปลง ตามกาลเวลา ดังนั้นแนวทางการวิจัยในอนาคตจึงควร เปลี่ยนไปใช้ข้อมูลผู้ใช้ตามพฤติกรรมการใช้งานจริงจาก ระบบ (System Logs) เพื่อความแม่นยำสูงสุด และควร นำปัจจัยภายนอกเข้ามาร่วมวิเคราะห์ เช่น การปรับ อัตราค่าบริการ หรือความพึงพอใจต่อเนื้อหาเฉพาะกลุ่ม

เพื่อให้แบบจำลองมีความสมบูรณ์และครอบคลุม บริบททางธุรกิจที่ซับซ้อนได้ดียิ่งขึ้น

### เอกสารอ้างอิง

- [1] Global Media Insight. (2026, Jun.). Youtube statistics 2026 (demographics, users by country & more ). [Online]. Available: <https://www.globalmediainsight.com/blog/youtube-users-statistics/>
- [2] S. Kemp, “Digital 2025: Thailand,” *Data Reportal*, Mar. 2025.
- [3] J. Bhattacharya, “Youtube premium statistics 2025: Top user trends,” *SEO Sandwich*, 2025.
- [4] C. C. Aggarwal, *Neural Networks and Deep Learning: A Textbook*. Springer, 2018.
- [5] K. A. Amuda and A. B. Adeyemo, “Customers churn prediction in financial institution using artificial neural network,” *arXiv preprint arXiv:1912.11346*, 2019, doi : 10.48550/arXiv.1912.11346.
- [6] H. Dalmia, C. V. S. S. Nikil, and S. Kumar, “Churning of bank customers using supervised learning,” in *Innovations in Electronics and Communication Engineering*, 2020, pp. 681–691, doi: 10.1007/978-981-15-3172-9\_64.
- [7] Y. He, Y. Xiong, and Y. Tsai, “Machine learning based approaches to predict customer churn for an insurance company,” in *2020 Systems and Information*



- Engineering Design Symposium (SIEDS)*, 2020, pp. 1–6, doi: 10.1109/SIEDS49339.20.9106691.
- [8] D. Sam, K. C. Suresh, N. Kanya, C. Tamilselvi, and M. V. S. L. Tejasria, “An improved bank customer churn and loan prediction model using supervised machine learning approach,” *Turkish Journal of Physiotherapy and Rehabilitation*, vol. 32, no. 3, 2021.
- [9] I. V. Pustokhina, D. A. Pustokhin, P. T. Nguyen, M. Elhoseny, and K. Shankar, “Multi-objective rain optimization algorithm with WELM model for customer churn prediction in telecommunication sector,” *Complex & Intelligent Systems*, vol. 9, pp. 3473–3485, 2023, doi: 10.1007/s40747-021-00353-6.
- [10] N. Alboukaey, A. Joukhadar, and N. Ghneim, “Dynamic behavior based churn prediction in mobile telecom,” *Expert Systems with Applications*, vol. 162, 2020, Art. no. 113779, doi: 10.1016/j.eswa.2020.113779.
- [11] M. J. Britto and R. Gobinath, “Hybrid attention based GRU BiLSTM (GRBiLSTM) for banking customer churn prediction,” *Turkish Online Journal of Qualitative Inquiry (TOJQI)*, vol. 12, no. 3, pp. 2933–2937, 2021.
- [12] L. Rokach, “Ensemble learning: Pattern classification using ensemble methods, 2nd ed.,” *World Scientific Publishing*, 2019, doi: 10.1142/11325.
- [13] L. S. Shapley, “A value for n-person games,” in *The Shapley Value: Essays in Honor of Lloyd S. Shapley*, A. E. Roth, Ed. Cambridge University Press, 1988, pp. 31–40, doi: 10.1017/CBO9780511528446.003.
- [14] S. M. Lundberg and S.-I. Lee, “A unified approach to interpreting model predictions,” in *Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS 2017)*, Long Beach, CA, USA, 2017, pp. 4768–4777.
- [15] C. D. Manning, P. Raghavan, and H. Schütze, “*Introduction to Information Retrieval*,” Cambridge, UK: Cambridge University Press, 2008.
- [16] P. P. Singh, F. I. Anik, R. Senapati, A. Sinha, N. Sakib, and E. Hossain, “Investigating customer churn in banking: A machine learning approach and visualization app for data science and management,” *Data Science and Management*, vol. 7, no. 1, pp. 7–16, 2024, doi: 10.1016/j.dsm.2023.09.002.
- [17] V. Chang, K. Hall, Q. A. Xu, F. O. Amao, M. A. Ganatra, and V. Benson, “Prediction

- of customer churn behavior in the telecommunication industry using machine learning models,” *Algorithms*, vol. 17, no. 6, pp. 231, 2024, doi: 10.3390/a17060231.
- [18] T. R. Noviandy, G. M. Idroes, I. Hardi, M. Afjal, and S. Ray, “A model-agnostic interpretability approach to predicting customer churn in the telecommunications industry,” *Infolitika Journal of Data Science*, vol. 2, no. 1, pp. 34–44, 2024, doi: 10.60084/ijds.v2i1.199.
- [19] S. S. Poudel, S. Pokharel, and M. Timilsina, “Explaining customer churn prediction in telecom industry using tabular machine learning models,” *Machine Learning with Applications*, vol. 17, 2024, Art. no. 100567, doi: 10.1016/j.mlwa.2024.100567.
- [20] A. Li, T. Yang, X. Zhan, Y. Shi, and H. Li, “Utilizing data science and AI for customer churn prediction in marketing,” *Journal of Theory and Practice of Engineering Science*, vol. 4, no. 5, pp. 72–79, 2024, doi: 10.53469/jtpes.2024.0404.10.