

# 개인화 마케팅을 위한 머신러닝 기반 고객 행동 예측 모델 연구

김예진<sup>1</sup>, 김태림<sup>2</sup>, 김건민<sup>3</sup>, 김경백<sup>3</sup>

전남대학교 소프트웨어공학과<sup>1</sup>, 전남대학교 인공지능학부<sup>2</sup>, 전남대학교 인공지능융합학과<sup>3</sup>  
ye031010@jnu.ac.kr, ktr0706@jnu.ac.kr, geonminkim@jnu.ac.kr, kyungbaekkim@jnu.ac.kr

## A Study on Machine Learning-Based Customer Behavior Prediction Model for Personalized Marketing

Yejin Kim<sup>1</sup>, Taerim Kim<sup>2</sup>, Geonmin Kim<sup>3</sup>, Kyungbaek Kim<sup>3</sup>

<sup>1</sup>Dept. of Software Engineering, Chonnam National Univ.,

<sup>2</sup>Dept. of Artificial Intelligence, Chonnam National Univ.,

<sup>3</sup>Dept. of AI Convergence, Chonnam National Univ.

### 요약

개인화 마케팅 서비스의 중요도가 증가하는 상황에서 기존 A/B 테스트는 고객 행동 특성을 유연하게 대응하지 못한다는 문제를 지닌다. 이에 본 연구는 Google Analytics 4 (GA4)를 통해 수집한 고객 행동 데이터를 기반으로 동적 머신러닝 최적화 모델을 구축하고 성능을 검증한다. 이성적/감성적 메시지에 대한 클릭 및 전환 데이터를 수집 후, 증강하여 모델 학습용 데이터셋을 구성하였다. 정적 모델(Logistic Regression(LR))과 동적 모델을 비교한 결과, 정적 모델 대비 동적 모델이 4.7% 높은 정확도를 보여 실시간 맞춤형 메시지 전략의 효과를 입증하였다. 본 연구는 실제 행동 데이터에 기반한 동적 최적화 모델의 실무 적용 가능성을 실증적으로 제시한다.

### I. 서론

디지털 마케팅 환경은 점차 복잡해지는 추세이며, 이에 따라 개별 소비자의 맥락적 특성과 심리적 요인에 기반한 맞춤형 메시지 전달의 중요성이 증대되고 있다. 그러나, 현재 산업계에서 흔히 쓰이는 정적 A/B 테스트는 모든 사용자를 고정 집단으로 나눠 동일한 메시지만 노출하는 방식에 머무르고 있다. 이러한 방식은 고객 행동이 시간에 따라 동적으로 변화한다는 사실을 반영하지 못하며, 개인의 행동 특성 및 맥락적 변화를 포착하는 데 구조적 한계를 지닌다[1]. 실제 행동과 응답 간 불일치 문제는 행동 예측의 정확도를 저해하며, 이는 결과적으로 마케팅 전략의 정밀성과 효과성을 떨어뜨린다. 이에 본 연구는 GA4를 통해 수집된 사용자 행동 로그를 기반으로 머신러닝 기반 동적 최적화 모델을 제안한다. 본 연구의 목적은 단순한 클릭 예측을 넘어, 심리적 특성과 행동 양상 간 상관관계를 규명하고, 데이터 기반의 정밀한 행동 예측을 가능하게 하는 것이다.

### II. 이론적 배경 및 관련 연구

#### 2.1 정적 테스트의 한계

A/B 테스트는 트래픽을 임의의 두 집단으로 분할하여 주요 지표를 비교하는 정적 방식으로 설계된다. 그러나 이 방식은 시간적, 상황적 맥락을 고려하지 않아 유입 경로, 체류 시간 등의 동적 변수를 충분히 반영하지 못한다[2]. 이러한 한계는 마케팅 효율성을 저해하며, 행동 기반 인과 추론을 실현해야 한다는 요구와 상충된다. 이에 실제 행동 데이터 기반의 정밀한 예측 및 최적화가 기존 정적 실험을 대체하는 접근으로 부상하고 있다.

#### 2.2 머신러닝 기반 동적 최적화 연구

최근 정적 A/B 테스트의 한계를 극복하기 위해 머신러닝 기반의 동적

최적화 모델 연구가 진행되고 있다. 이에 본 연구는 통제된 실험 환경에서 수집된 고객 데이터를 기반으로 동적 모델을 구축했다. 특히, 타겟 변수(클릭유형) 발생률이 낮은 클래스 불균형 문제를 해결하고, 이를 시계열적으로 분석했다. 본 연구의 타겟 변수는 사용자가 해당 페이지 유형에서 평균 이상의 몰입적인 행동을 했는지 여부를 나타낸다.

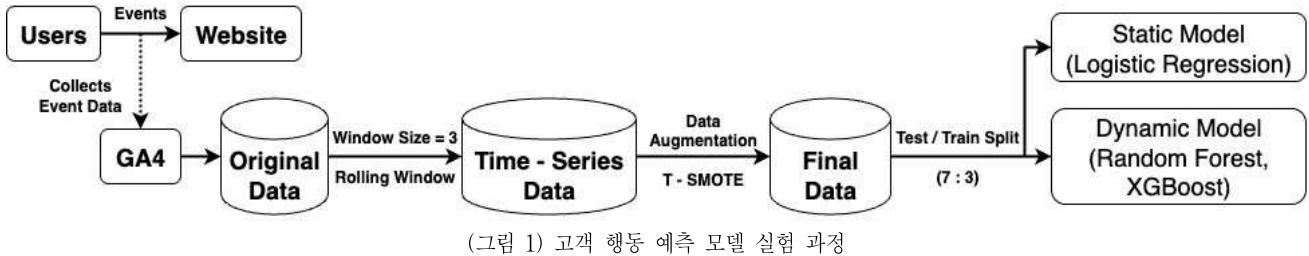
### III. 연구 방법

#### 3.1 GA4 기반 사용자 행동 데이터 수집 및 증강

본 연구는 통제된 A/B 테스트 환경을 구축하고 GA4를 활용하여 수집된 사용자별 웹사이트 이벤트 로그를 원시 데이터로 활용하였다. 사용자의 초기 선호도 확보를 위한 중립 게시물, 핵심 변수인 이성적 메시지와 감성적 메시지를 각각 노출하는 실험 페이지를 제작 후 데이터 수집 도구인 GA4를 통해 사용자의 유입 경로, 체류 시간, 스크롤 여부 등 이벤트 단위 행동 데이터를 수집하였다. 수집된 데이터를 통해 감성적 사용자의 더 오랜 체류 시간, 높은 스크롤 횟수 양상을 확인하였다. 한편, 수집된 원본 집계 데이터를, 동적 모델 학습에 적합한 형태로 증강하였다. 수치형 피처는 수집된 원본 데이터 평균 대비 10%의 표준편차의 범위에서 셈플링 및 합성하여 이를 통해 오차 범위 내에서의 데이터 다양성을 확보하였다. 특히, 이분적인 심리적 지표(감성, 이성)를 수치형 데이터로 변환하기 위해, 단위 행동 데이터의 비율에 맞추어 감정 점수로 변환하였다.

#### 3.2 시계열 데이터 구성

사용자의 과거 행동 패턴을 반영한 연속적인 분석을 위하여, 사용자 이벤트 발생 시간을 기준으로 데이터를 정렬한 후 Rolling Window 기법을



적용하여 시계열 데이터를 구성하였다. Window 크기를 2, 3, 4, 5로 설정한 실험 결과, 4와 5는 과적합 경향을 보이고 3으로 설정했을 때 예측 성능이 가장 높게 나타나, 각 이벤트 발생 시점 직전 3개 이벤트에 대한 체류 시간, 스크롤 시간, 스크롤 횟수 등의 평균값을 시계열 피쳐로 활용하였다. 이를 통하여 사용자의 행동 경향성을 분석한다. 또한, 수집 데이터의 클래스 불균형 문제를 해결하기 위해 데이터 증강을 수행한다. 시간적 종속성을 고려치 않는 일반 SMOTE 대신, 시간적 패턴을 보존하는 T-SMOTE (Synthetic Minority Over-sampling Technique) 기법을 적용하였다[3]. T-SMOTE는 소수 클래스에 속하는 인접한 시계열 샘플을 시간적 순서를 고려하여 보간함으로써 현실적인 가상 데이터를 만든다.

#### IV. 실험설계

본 연구는 고객 행동 데이터의 예측 성능을 정적 모델과 동적 모델 간에 비교하는 것을 목적으로 하였다. 정적 모델로는 행동 분석 분야에서 가장 널리 활용되는 LR 모델을 선택하였으며, 동적 모델로는 RandomForest(RF)와 XGBoost를 선정하였다. 특히 XGBoost는 고객 행동 패턴 분석 및 예측을 활용한 연구에 효과적임이 증명되어, 시계열 특징을 통합한 개인화된 행동 예측의 핵심 분류 모델로 선택하였다[4]. T-SMOTE로 증강된 데이터셋은 모델의 일반화 성능을 정확하게 평가하고 데이터 유출을 방지하기 위해 시간순 분할을 적용하여 초기 70%를 훈련 데이터로, 이후 30%를 테스트 데이터로 사용하였다. 성능 평가 지표에는 Accuracy, Precision, Recall, F1-score를 사용하였다.

#### V. 실험 결과

실험 결과, 시계열 특징을 포함한 증강된 데이터셋에서 XGBoost 모델이 가장 우수한 예측 성능을 보였다.

모델	Accuracy	Precision	Recall	F1-score
Logistic Regression	0.9290	0.8913	0.9762	0.9318
Random Forest	0.9704	0.9540	0.9881	0.97076
XGBoost	<b>0.9763</b>	0.9651	0.9881	<b>0.9765</b>

(표 1) 정적 및 동적 모델 실험 비교 결과

XGBoost 모델은 정적 기준 모델(LR) 대비 정확도에서 약 4.7% 높은 성능을 기록하며, 시계열 기반 행동 특징을 반영하는 동적 모델의 우수성을 명확히 입증하였다. 특히 동적 모델의 F1-score는 0.9765를 달성하여 예측정확도 향상을 확인하였다. 이는 동적 모델이 Rolling Window 크기 3으로 최적화된 시계열 기반 특징이 복잡한 고객의 행동 경향성을 더욱 정밀하게 포착했음을 의미한다. 이를 통해 실시간 맞춤형 마케팅에서 동적 모델 활용의 타당성을 입증하였다. 반면, LR은 정적 모델로서, 정확도는

92.9%에 이르렀으나, 행동 데이터의 시계열적 특성을 반영하지 못해 상대적으로 낮은 F1-score를 기록하였다.

#### VI. 결론 및 향후 연구

본 연구는 GA4 행동 데이터를 기반으로 정적 A/B 테스트의 구조적 한계를 극복할 수 있는 머신러닝 기반 동적 최적화 모델을 제안하고 그 효과를 실증하였다. 제안 모델은 사용자의 심리적 요인과 행동 패턴을 동시에 반영하여, 개인화 마케팅 전략의 가능성을 제시했다. 직접 수집한 데이터를 활용하여 고객의 심리적 특성과 행동적 패턴 간 상관관계를 규명하고, 증강한 데이터를 활용하여 고객의 행동 전환을 예측하는 모델을 학습하였다. 실험 결과, 동적 모델은 정적 모델 대비 약 4.7% 높은 정확도와 0.9765의 F1-score를 달성하여, 뛰어난 예측 성능과 확장성을 객관적으로 입증하였다. 향후 연구에서는 이러한 성과를 바탕으로 모델의 경량화 및 효율화 방안을 개발하고 이를 실시간 데이터 스트리밍 환경에 적용할 예정이다. 이러한 확장은 실제 산업 현장의 대규모 데이터 환경에서도 즉각적으로 반응하는 실시간 마케팅 자동화 체계를 구현하는 데 기여할 것이다.

#### ACKNOWLEDGMENT

본 연구는 2025년도 과학기술정보통신부 및 정보통신기획평가원의 소프트웨어중심대학사업의 연구결과로 수행되었습니다.(2021-0-01409)(34%). 본 연구성과는 2025년도 정부(교육부)의 재원으로 한국연구재단의 지원을 받아 수행된 기초연구사업임(RS-2025-25398164)(33%). 본 연구는 과학기술정보통신부 및 정보통신기획평가원의 인공지능융합혁신인재양성사업 연구 결과로 수행되었음(IITP-2025-RS-2023-00256629)(33%).

#### 참고 문헌

- [1] de Corte, K., Cairns, J., & Grieve, R. (2021). Stated versus revealed preferences: An approach to reduce bias. *Health Economics*, 30(5), 1095 - 1123.
- [2] Quin, F., Weyns, D., Galster, M., & Silva, C. C. (2024). A/B testing: A systematic literature review. *Journal of Systems and Software*, 211, 112011.
- [3] Zhao, P., Luo, C., Qiao, B., Wang, L., Rajmohan, S., Lin, Q., & Zhang, D. (2022). T-SMOTE: Temporal-oriented synthetic minority oversampling technique for imbalanced time series classification. In *Proceedings of the Thirty-First International Joint Conference on Artificial Intelligence (IJCAI-22)* (pp. 2406 - 2412).
- [4] Lou, J. (2024). Comparative analysis of logistic regression, random forest, and XGBoost for click-through rate prediction in digital advertising. In *Proceedings of the International Conference on Machine Intelligence and Emerging Technologies (MIED 2024)* (pp. 462 - 470).