

## Consumer Response Prediction on an Online Gift Platform Using Generative AI-Based Image Features and Machine Learning

Eunji Kim\*, Hanjun Lee\*\*

\*Student, Department of Management Information Systems, Myongji University, Seoul, Korea

\*\*Associate Professor, Department of Management Information Systems, Myongji University, Seoul, Korea

### [Abstract]

This study develops machine learning models to predict review count and wish count on the KakaoTalk Gift platform and analyzes the contribution patterns of consumer response variables. Product data from the dessert and kitchen categories were collected, and features were constructed from price, discount rate, satisfaction score, product title-derived variables, and generative AI-based image variables. Only products with at least 10 reviews were used for the analysis. Random Forest, XGBoost, and LightGBM models were compared, and SHAP analysis was used to interpret the direction of feature contributions. The results show that the importance and contribution directions of variables differ by target signal and category, and that image-based variables provide supplementary predictive information for some categories and targets. This study presents a methodological framework for predicting and interpreting consumer responses in an online gifting context by integrating generative AI-based image variables with product data.

▶ **Key words:** Online gift platform, Consumer response prediction, SHAP analysis, Generative AI, Image-based features

### [요 약]

본 연구는 카카오톡 선물하기 플랫폼에서 리뷰 수와 위시 수를 예측하는 머신러닝 모델을 구축하고, 소비자 반응 변수의 기여 양상을 분석하였다. 디저트와 주방 카테고리 상품 데이터를 수집하여 가격, 할인율, 만족도, 상품명 파생 변수, 생성형 AI 기반 이미지 변수를 구성하였으며, 리뷰 수 10개 이상 상품만 분석에 활용하였다. Random Forest, XGBoost, LightGBM 모델을 비교하고 SHAP 분석으로 변수의 기여 방향을 해석하였다. 분석 결과, 변수의 중요도와 기여 방향은 타겟 지표와 카테고리에 따라 다르게 나타났으며, 이미지 기반 변수는 일부 카테고리와 타겟에서 보조적 예측 정보를 제공하였다. 본 연구는 생성형 AI 기반 이미지 변수와 상품 데이터를 통합하여 온라인 선물 환경의 소비자 반응을 예측·해석하는 방법론적 틀을 제시한다.

▶ **주제어:** 온라인 선물 플랫폼, 소비자 반응 예측, SHAP 분석, 생성형 AI, 이미지 기반 변수

- 
- First Author: Eunji Kim, Corresponding Author: Hanjun Lee
  - \*Eunji Kim (eunjiikim2@gmail.com), Department of Management Information Systems, Myongji University
  - \*\*Hanjun Lee (hjlee1609@gmail.com), Department of Management Information Systems, Myongji University
  - Received: 2026. 03. 03, Revised: 2026. 05. 01, Accepted: 2026. 05. 04.

## I. Introduction

온라인 커머스에서 '선물하기'는 상품 탐색, 결제, 전달이 하나의 흐름으로 결합된 대표적 비대면 소비 방식으로 자리 잡았다. 특히 모바일 기반 선물하기 서비스는 e-쿠폰을 넘어 실물 상품 배송까지 확장되면서 일상적인 선물 채널로 활용되고 있다.

국내 온라인 선물하기 시장 역시 빠르게 성장하고 있다. 2016년 8,000억 원대였던 시장 규모는 2020년 3조 원, 2022년 5조 원을 넘어섰으며[1], 카카오톡 선물하기를 비롯해 네이버, 쿠팡, CJ 올리브영 등 주요 플랫폼들이 관련 서비스를 확대하고 있다. 또한 통계청의 온라인 쇼핑 동향 조사 보도 자료[2]에 따르면 2025년 11월 기준 e-쿠폰 서비스의 온라인쇼핑 거래액은 전년 동월 대비 4% 증가하였다. 이는 온라인 선물하기 서비스가 특정 상황에 한정된 서비스가 아니라 일상적 소비 방식으로 확장되고 있음을 보여준다.

그러나 온라인 선물하기 환경에서는 소비자가 상품을 직접 확인하기 어렵기 때문에 플랫폼에서 제공되는 소비자 반응 지표가 중요한 정보 단서로 활용된다. 선행 연구[3]에 따르면 소비자는 상품평, 평점, 판매 순위와 같이 기업이 통제하기 어려운 단서를 활용하여 구매 과정의 불확실성을 줄이는 경향이 있다. 대표적인 반응 지표로는 리뷰 수, 리뷰 내용, 만족도, 별점 등이 있으며, 구매 이전 단계의 관심 신호로는 위시(wish)가 활용될 수 있다. 위시는 실제 구매 이전의 관심이나 선호를 반영하는 지표로, 온라인 선물하기 환경에서 잠재적 구매 의도를 이해하는 데 유용하다.

기존 온라인 선물하기 서비스 관련 연구는 주로 소비자의 심리적 특성, 사용자 경험, 플랫폼 확산의 산업적 영향에 초점을 두었다. 예를 들어 카카오톡 선물하기 이용 과정에서 20대 소비자가 느끼는 심리적 부담에 대한 연구[4], 취소 및 환불 기능에 대한 사용자 경험 연구[5], 모바일 교환권 확산이 오프라인 커피전문점 시장 구조에 미치는 영향을 분석한 연구[6]가 수행되었다. 한편 보다 넓은 온라인 서비스 및 전자상거래 맥락에서는 평점, 만족도, 판매 성과, 리뷰 유용성 등 다양한 소비자 반응 지표를 예측하는 연구가 축적되어 왔으며, 최근에는 텍스트뿐 아니라 이미지와 멀티모달 정보를 함께 활용하는 방향으로 확장되고 있다[7]-[13].

그럼에도 온라인 선물하기 플랫폼을 대상으로 실제 상품 및 행동 데이터를 활용하여 소비자 반응을 예측하고, 각 변수의 기여 양상을 해석한 연구는 아직 제한적이다.

특히 구매 이후 반응인 리뷰 수와 구매 이전 관심 신호인 위시 수를 함께 다루고, 생성형 AI 기반 이미지 변수를 통합하여 그 예측 기여 방향을 분석한 연구는 부족하다.

이에 본 연구는 카카오톡 선물하기 상품 상세페이지에서 관측 가능한 구조화된 상품 정보, 상품명 기반 텍스트 특성, 생성형 AI 기반 이미지 변수를 통합하여 다차원 데이터셋을 구축하였다. 또한 리뷰 수와 위시 수를 온라인 선물하기 환경의 대표적 소비자 반응 지표로 설정하고, 머신러닝 모델을 통해 이를 예측하며 SHAP 분석을 통해 주요 변수의 기여 방향을 해석한다. 본 연구는 인과관계 규명보다는 관측 데이터 기반 예측 및 연관성 해석에 초점을 둔다. 본 연구의 학문적 기여는 다음과 같다.

- 온라인 선물하기 플랫폼 맥락에서 구조화된 상품 정보, 상품명 기반 텍스트 특성, 생성형 AI 기반 이미지 변수를 통합한 분석 프레임워크를 제시한다.
- 리뷰 수와 위시 수를 각각 구매 이후 반응과 구매 이전 관심을 반영하는 소비자 반응 지표로 설정하고, 두 지표를 함께 예측한다.
- 트리 기반 머신러닝 모델과 SHAP 분석을 결합하여 예측 성능뿐 아니라 변수의 상대적 중요도와 기여 방향을 설명 가능하게 제시한다.
- 카테고리별로 이미지 기반 변수의 중요도와 기여 양상이 다를 수 있음을 확인함으로써, 온라인 선물 플랫폼에서 이미지 기반 단서의 역할을 세분화하여 이해할 수 있는 근거를 제공한다.

본 논문의 구성은 다음과 같다. II장에서는 온라인 선물하기 플랫폼 관련 연구와 소비자 반응 예측 연구를 검토한다. III장에서는 데이터 수집, 전처리 및 특징 추출, 모델 개발과 평가 방법을 설명한다. IV장에서는 변수 중요도 분석과 SHAP 분석을 포함한 실증 결과를 제시한다. V장에서는 연구 결과와 시사점 및 한계를 논의하고, VI장에서 결론을 제시한다.

## II. Related Works

### 1. Online Gifting Platforms

기존 온라인 선물하기 관련 선행 연구는 주로 사용자 경험과 심리적 인식, 그리고 모바일 교환권 확산이 산업 구조에 미친 영향에 초점을 두어 왔다. 사용자 경험 관련 연구[3]는 온라인 선물 이용 과정에서 소비자가 느끼는 심리적 부담과 서비스 개선 방향을 논의하였으며, 또 다른 연구[5]는 카카오톡 선물하기의 취소 및 환불 기능에 대한

사용자 인식을 분석하고 UX 및 서비스 디자인 측면의 개선 방향을 제시하였다. 또한 모바일 교환권 확산의 산업적 영향을 분석한 연구[6]는 카카오톡 선물하기를 중심으로 한 온라인 모바일 상품권 거래가 오프라인 커피전문점 시장 구조와 특정 브랜드로의 수요 집중에 영향을 줄 수 있음을 보였다.

이처럼 온라인 선물하기 플랫폼에 대한 기존 연구는 사용자 경험, 심리적 인식, 플랫폼 확산 효과를 중심으로 이루어져 왔다. 그러나 플랫폼 내부에서 관측되는 상품 정보와 이용자 반응 지표를 활용하여 소비자 반응을 정량적으로 예측하고, 변수의 기여 양상을 해석하려는 연구는 상대적으로 제한적이다.

## 2. Consumer Response Prediction

소비자 반응 예측 연구는 다양한 온라인 서비스 및 전자상거래 맥락에서 지속적으로 수행되어 왔다[7]-[13]. 초기 연구들은 주로 텍스트와 구조화된 정보를 활용하여 평점이나 참여 수준을 예측하였다. 예를 들어 네이버 영화 리뷰 데이터를 활용한 연구[7]는 제목, 전문가 평론, 네티즌 평균 점수 등을 바탕으로 영화 평점을 예측하였고, 온라인 강의 플랫폼을 분석한 연구[8]은 강의 제목, 가격, 강의 시간, 수강자 수, 강의 설명 및 기술 태그를 활용하여 평점과 수강자 수를 예측하였다.

최근에는 전자상거래 환경에서 고객만족도, 상품 판매, 신규 상품 성과, 리뷰 유용성 등 다양한 소비자 반응 지표로 예측 대상이 확장되고 있다. 온라인 주문 데이터를 활용한 연구[9]는 배송 시간, 주문 금액, 지역 등 거래 속성을 바탕으로 고객만족도를 예측하였고, 라이브커머스 및 전자상거래 연구들은 상품 텍스트, 이미지, 상호작용 정보, 시계열 요인 등을 결합한 멀티모달 예측 프레임워크를 제안하였다[10]-[13].

이처럼 소비자 반응 예측 연구는 텍스트와 구조화된 정보 중심 접근에서 이미지와 멀티모달 정보를 함께 활용하는 방향으로 확장되고 있다. 그러나 온라인 선물하기 플랫폼을 대상으로 구매 이후 반응인 리뷰 수와 구매 이전 관심 신호인 위시 수를 동시에 예측하고, 생성형 AI 기반 이미지 변수의 기여 방향까지 해석한 연구는 제한적이다. 따라서 본 연구는 온라인 선물 환경에서 구조화된 상품 정보, 상품명 기반 텍스트 특성, 생성형 AI 기반 이미지 변수를 통합하여 소비자 반응을 예측하고 해석한다는 점에서 기존 연구를 확장한다.

## III. Approach

### 1. Data Collection

본 연구는 ‘카카오톡 선물하기’ 플랫폼에서 2025년 11월부터 12월까지 수집한 상품 단위 데이터를 활용하였다. 분석 대상은 식품 카테고리의 ‘디저트’와 리빙 카테고리의 ‘주방·수입 주방’이며, 이후 ‘주방’으로 표기하였다. 두 카테고리는 가격대와 상품 특성이 상이하어 카테고리별 예측 양상을 비교하기에 적합하다고 판단하였다.

데이터는 각 카테고리에 노출된 전체 상품 목록을 대상으로 두 단계 크롤링을 통해 수집하였다. 1차 수집에서는 제품 ID, 상품 상세 페이지 URL, 상품명, 할인율, 가격, 만족도, 리뷰 수, 위시 수를 수집하였고, 2차 수집에서는 각 상품의 썸네일 이미지를 추가로 확보하였다. Fig. 1은 수집한 상품 상세 페이지 예시를 나타낸다. 최종적으로 디저트 3,000건, 주방 4,600건의 상품 데이터를 확보하였다.

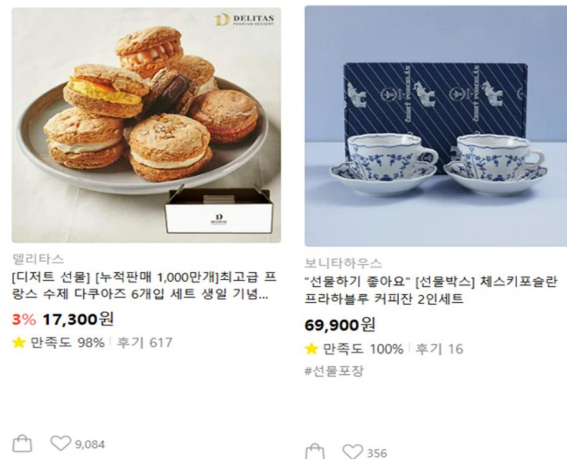


Fig. 1. Examples of Product Detail Page: Dessert Category (Left) and Kitchen Category (Right)

### 2. Data Preprocessing and Feature Extraction

수집된 원자료를 확인한 결과, 플랫폼에서는 리뷰 수가 10개 미만인 상품에 대해 만족도(평점) 정보가 제공되지 않았다. 이에 본 연구는 만족도 변수를 포함하기 위해 리뷰 수 10개 이상 상품으로 분석 대상을 한정하였다. 다만 이러한 기준은 표본 수를 축소하고, 상대적으로 리뷰가 축적된 상품 중심의 표본 구성을 초래할 수 있으므로 결과 해석과 일반화에는 주의가 필요하다.

변수 분포의 비대칭성과 극단값 영향을 완화하기 위해 가격, 리뷰 수, 위시 수에는 로그 변환을 적용하였다 (price\_log, review\_log\_cnt, wish\_log\_cnt). 또한 상품명 텍스트로부터 상품명 길이(names\_len), 따옴표 포함

여부(has\_quote), 대괄호 포함 여부(has\_bracket)를 파생 변수로 구성하였다. 이 변수들은 상품명에 포함된 정보량, 강조 표현, 프로모션성 표현을 반영하는 대리 지표로 활용하였다.

이미지 기반 변수는 색상 특성과 의미적 특성으로 구분하여 추출하였다. 먼저 선행연구[14]를 참고하여 OpenCV 기반 HSV 색공간으로 변환한 뒤 채널별 최빈값을 산출하였다. Hue(H)는 warm, cool, middle로 범주화하여 원-핫 인코딩하였고, Saturation(S)은 로그 변환(s\_log\_mode), Value(V)는 분위수 기반 low, mid, high 구간으로 나누어 순서형 변수로 변환하였다.

상품 이미지의 의미적 특성은 OpenAI API를 활용해 0-1 범위의 이미지 평가 점수로 산출하였다. 공통 변수로는 시각적 매력(aesthetic\_score), 기술적 품질(visual\_quality\_score), 선물 적합성(giftability\_score), 색상 다양성(color\_diversity\_score), 배경 청돈도(background\_cleanliness\_score), 브랜드 노출도(brand\_strength\_score), 제품 식별 가능성(product\_visibility\_score), 이미지 내 텍스트 비중(text\_density\_score)을 사용하였다. 주방 카테고리에는 소재의 고급스러움(material\_premium\_score), 기능 표현의 명확성(functional\_clarity\_score), 위생적 인상(hygienic\_feel\_score), 공간 효율성(space\_saving\_score), 고급 주방 분위기(premium\_kitchen\_feel\_score), 미니멀리즘 정도(design\_minimalism\_score)를 추가하였다. 주방 카테고리에 사용한 프롬프트는 Table 1에 제시하였으며, 디저트 카테고리에서는 주방 특화 변수를 제외한 동일 구조의 프롬프트를 사용하였다.

Table 1. Prompt for Image-Based Feature Extraction (Kitchen Category)

Prompt
Evaluate the given Kakao Gift 'Kitchen/Imported Kitchen' product image and convert the evaluation results into feature scores. Output JSON only. Do not include code blocks or explanatory text.
[Scoring Rules] - All scores must be real numbers between 0 and 1, rounded to two decimal places (e.g., 0.73). More fine-grained evaluation is preferred. - 0.90-1.00: Very high - 0.70-0.89: High - 0.40-0.69: Moderate - 0.00-0.39: Low

[Evaluation Criteria]  
 - aesthetic\_score: How visually appealing the image is (color harmony / design / styling)  
 - visual\_quality\_score: Image capture quality (resolution / focus / lighting / noise / distortion)  
 - giftability\_score: How much the product feels gift-appropriate (gift packaging / product set composition / premium feel)  
 - color\_diversity\_score: Variety and variation of major colors (monotone vs. diverse)  
 - background\_cleanliness\_score: How simple and non-distracting the background is  
 - brand\_strength\_score: Clarity and prominence of logo/brand name exposure  
 - product\_visibility\_score: How large and clear the product appears (easy to recognize at a glance)  
 - text\_density\_score: How much text/copy appears in the image (higher score = more text)

[Additional Evaluation Criteria for Living/Kitchen]  
 - material\_premium\_score: How premium the materials appear (e.g., stainless steel / glass / ceramic / solid wood)  
 - functional\_clarity\_score: How clearly the function/purpose is conveyed by the image (you can tell what it is immediately)  
 - hygienic\_feel\_score: How hygienic/clean the image feels (neat and tidy without stains or clutter)  
 - space\_saving\_score: How space-efficient it appears (slim/compact/easy to store)  
 - premium\_kitchen\_feel\_score: How much it feels like imported/premium kitchenware (professional, high-end kitchen vibe)  
 - design\_minimalism\_score: Degree of minimalistic design (simple, uncluttered, well-organized)

생성형 AI 기반 이미지 점수의 타당성을 보완적으로 점검하기 위해, 카테고리별 100개 표본 이미지에 대해 소규모 검증을 수행하였다. 두 명의 인간 평가자가 공통 항목을 평가하였고, 평가 척도를 0-1 범위로 변환한 뒤 OpenAI 기반 점수와 상관관계를 확인하였다. 그 결과 OpenAI 점수와 인간평가 평균 간 평균 Pearson 상관관계 수는 디저트 카테고리에서 약 0.52, 주방 카테고리에서 약 0.49로 나타났다. 또한 동일 프롬프트를 다른 생성형 AI 모델에 적용한 민감성 검토에서는 OpenAI와 Grok 간에 일부 항목의 중간 수준 정합성이 관찰되었으나, 모델별 점수 차이도 존재하였다. 따라서 본 연구의 이미지 기반 변수는 인간 인식의 객관적 측정치라기보다, 고정된 모델과 프롬프트를 통해 상품 이미지의 의미적 특성을 구조화한 조작적 대리변수로 해석하였다.

전처리 및 특징 추출 이후 최종 데이터셋은 디저트 827건(21개 변수), 주방 803건(27개 변수)으로 구성되었다. 주요 수치형 변수에 대한 기술통계는 Table 2와 Table 3에 카테고리별로 제시하였다.

Table 2. Descriptive Statistics (Dessert Category)

Feature	Mean	Std	Min	Max
aesthetic_score	0.821	0.063	0.45	0.92
visual_quality_score	0.878	0.038	0.7	0.95
giftability_score	0.75	0.14	0.1	0.98
color_diversity_score	0.593	0.136	0.15	0.95
background_cleanliness_score	0.892	0.088	0.4	0.98
brand_strength_score	0.683	0.21	0	0.95
product_visibility_score	0.849	0.061	0.6	0.95
text_density_score	0.418	0.177	0	0.85
sale_ratio	0.085	0.279	0	1
satisfaction	94.036	5.965	70	100
names_len	39.354	15.226	9	83.00
review_log_cnt	4.07	1.443	2.398	9.21
wish_log_cnt	6.774	1.355	2.708	11.29
price_log	9.872	0.492	8.683	11.44
s_log_mode	2.764	2.019	0	5.545

### 3. Model Development

본 연구는 소비자 반응 지표로서 리뷰 수와 wish 수를 각각 예측하는 회귀 문제로 설정하였다. 두 종류의 카테고리리와 두 종류의 타겟 변수를 조합하여 총 4개의 예측 과제(디저트-리뷰, 디저트-wish, 주방-리뷰, 주방-wish)를 구성하였다. 타겟 변수는 전처리 단계에서 로그 변환한 review\_log\_cnt와 wish\_log\_cnt를 사용하였다.

본 연구는 다양한 알고리즘의 포괄적 벤치마킹보다는, 온라인 선물하기 환경에서 관측되는 구조화된 상품 정보와 생성형 AI 기반 이미지 변수를 활용한 예측 및 해석 프레임워크를 제시하는 데 초점을 둔다. 이에 따라 데이터의 비선형 관계와 변수 간 상호작용을 반영할 수 있는 대표적인 트리 기반 앙상블 회귀 모델인 Random Forest, XGBoost, LightGBM을 비교 대상으로 설정하였다. 최종 데이터셋을 7:3 비율로 분할한 후, 훈련 데이터에서 하이퍼파라미터 튜닝을 수행하고 최적 설정으로 모델을 학습하였다. 하이퍼파라미터 탐색은 Randomized Search로 후보 영역 탐색 후 Grid Search로 세부 조정을 수행하였다. 세 모델 모두 동일한 절차로 주요 하이퍼파라미터를 튜닝하였으며, Table 4에는 SHAP 해석의 기준 모델인 LightGBM의 설정을 제시하였다.

Table 3. Descriptive Statistics (Kitchen Category)

Feature	Mean	Std	Min	Max
aesthetic_score	0.826	0.051	0.55	0.92
visual_quality_score	0.892	0.038	0.6	0.95
giftability_score	0.74	0.115	0.3	0.98
color_diversity_score	0.509	0.148	0.15	0.95
background_cleanliness_score	0.915	0.075	0.3	0.98
brand_strength_score	0.457	0.306	0	0.95
product_visibility_score	0.871	0.051	0.6	0.95
text_density_score	0.235	0.181	0	0.8
material_premium_score	0.686	0.163	0.1	0.95
functional_clarity_score	0.777	0.1	0.05	0.95
hygienic_feel_score	0.862	0.05	0.5	0.95
space_saving_score	0.597	0.106	0.05	0.94
premium_kitchen_feel_score	0.658	0.155	0.05	0.94
design_minimalism_score	0.802	0.08	0.4	0.95
sale_ratio	0.073	0.261	0	1
satisfaction	95.359	5.607	73	100
names_len	50.447	17.776	8	96
review_log_cnt	3.895	1.254	2.485	8.951
wish_log_cnt	7.657	1.185	2.944	11.002
price_log	10.165	0.565	7.314	12.038
s_log_mode	2.567	1.664	0	5.545

Table 4. Main Hyperparameter Settings for LightGBM Models

Hyperparameter	Dessert		Kitchen	
	Review	Wish	Review	Wish
n_estimators	1000	800	1200	1200
learning_rate	0.005	0.01	0.01	0.005
max_depth	3	3	5	4
subsample	0.9	0.9	0.6	0.9
num_leaves	15	7	15	7
min_child_samples	20	20	15	15
reg_alpha	0.5	0.5	0.1	0.5
reg_lambda	1	2	2	2

한편 본 연구에서 리뷰 수와 wish 수는 플랫폼에서 동일 시점에 함께 관측되는 대표적 소비자 반응 지표이므로, 각 예측 과제에서 목표 변수를 제외한 나머지 반응 지표를 입력 변수로 포함하였다. 이는 인과적 선후 관계를 식별하기 위한 설계라기보다, 실제 상품 상세페이지에서 동시에 관측 가능한 행동 신호를 통합하여 예측력을 평가하기 위한 방법론적 선택이다. 다만 두 지표 간 높은 연관성으로 인해 예측 성능 일부가 상호 상관관계에 의해 강화될 가능성이 있으므로, 본 연구에서는 추가적으로 상호 입력 변수를 제외한 비교 모델을 통해 그 영향을 점검하였다. 따라서 본 설계는 신규 상품의 사전 반응 예측보다는, 이미 플랫폼에 노출되어 관련 반응 지표가 함께 관측되는 상품군에 대한 동시점 예측 및 해석에 보다 적합한 것으로 이해할 필요가 있다.

#### 4. Model Evaluation

모델 성능 평가는 분할된 테스트 데이터에서 수행하였다. 성능 비교를 위해 결정계수( $R^2$ ), 평균제곱근오차 (RMSE), 평균절대오차(MAE)를 사용하였으며, 모든 지표는 로그 변환된 타겟(review\_log\_cnt, wish\_log\_cnt)을 기준으로 산출하였다. 또한 기준 성능을 확인하기 위해 훈련 데이터의 타겟 평균값으로 테스트 데이터를 예측하는 mean baseline을 추가하였다. 카테고리별 리뷰 수와 위시 수 예측 과제에 대한 7:3 hold-out 평가 결과는 Table 5와 Table 6에 제시하였다.

단일 hold-out 분할에 따른 우연성을 보완하기 위해 5-fold cross-validation을 추가 수행하였다. LightGBM 모델의 디저트 리뷰/위시 예측  $R^2$ 은 각각  $0.689 \pm 0.061$ 과  $0.587 \pm 0.036$ , 주방 리뷰/위시 예측  $R^2$ 은 각각  $0.660 \pm 0.080$ 과  $0.510 \pm 0.058$ 로 나타났다. 이에 본 연구는 교차검증에서도 일정 수준의 예측 성능을 유지한 LightGBM을 이후 변수 중요도 및 SHAP 해석의 기준 모델로 활용하였다.

Table 5. Model Performance Comparison: Dessert

Target	Model	$R^2$	RMSE	MAE
Review Count	Mean baseline	-0.01	1.39	1.09
	Random Forest	0.69	0.77	0.58
	XGBoost	0.73	0.72	0.56
	LightGBM	0.69	0.76	0.60
Wish Count	Mean baseline	-0.01	1.31	0.99
	Random Forest	0.62	0.80	0.58
	XGBoost	0.64	0.78	0.57
	LightGBM	0.56	0.87	0.64

Table 6. Model Performance Comparison: Kitchen

Target	Model	$R^2$	RMSE	MAE
Review Count	Mean baseline	0.00	1.37	1.05
	Random Forest	0.73	0.70	0.53
	XGBoost	0.76	0.67	0.50
	LightGBM	0.72	0.73	0.52
Wish Count	Mean baseline	0.00	1.16	0.92
	Random Forest	0.57	0.76	0.61
	XGBoost	0.58	0.75	0.60
	LightGBM	0.55	0.78	0.62

기여 방향은 이후 SHAP 분석에서 추가로 해석한다. 분석 결과는 타겟 변수에 따라 Fig. 2와 Fig. 3에 제시하였다.

먼저 리뷰 수 예측 모델(Fig. 2)에서는 두 카테고리 모두에서 위시 수(wish\_log\_cnt)가 가장 높은 중요도를 보였으며, 가격(price\_log), 만족도(satisfaction), 채도 최빈값(s\_log\_mode), 상품명 길이(names\_len)가 공통적으로 상위권에 포함되어 유사한 변수 구성 패턴을 나타냈다. 상위 10개 변수 기준으로 비교하면, 두 카테고리 모두에서 브랜드 노출도(brand\_strength\_score), 색상 다양성(color\_diversity\_score), 선물 적합성(giftability\_score), 텍스트 비중(text\_density\_score) 등이 주요 변수로 확인되었다. 한편 카테고리별로는 디저트 모델에서 배경 정돈도(background\_cleanliness\_score)가 상위 변수에 포함된 반면, 주방 모델에서는 디자인 미니멀리즘(design\_minimalism\_score)이 상위 10개에 포함되어 카테고리 특성이 일부 반영되는 양상을 보였다.

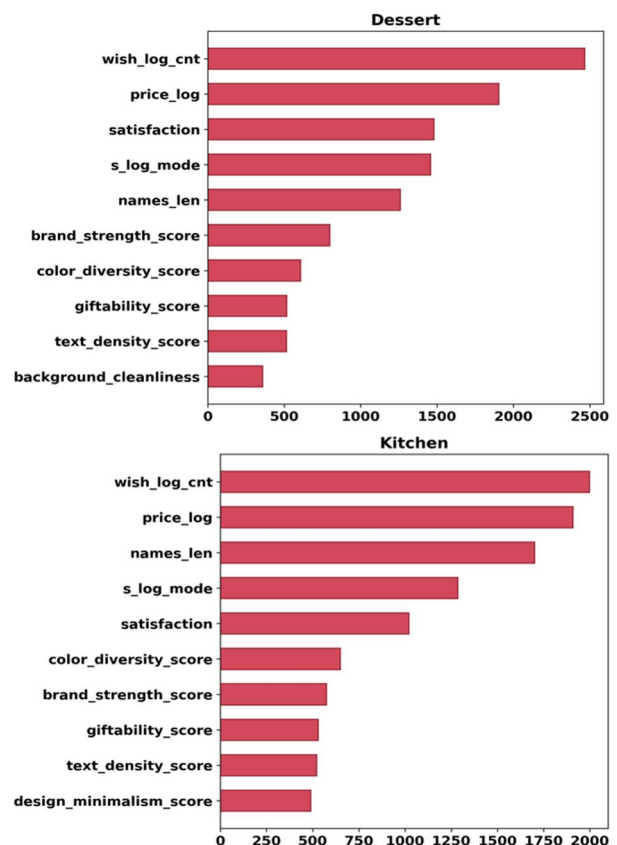


Fig. 2. Feature Importances for Review Count Prediction

### IV. Results

#### 1. Feature Importance Analysis

모델 예측에 각 변수가 얼마나 기여하는지 확인하기 위해 중요도 분석[15]을 수행하였다. 변수 중요도는 트리 분할 과정에서 변수가 사용되는 정도를 기반으로 산출되며, 변수의

다음으로 위시 수 예측 모델(Fig. 3)에서는 두 카테고리 모두에서 리뷰 수(review\_log\_cnt), 가격(price\_log), 상품명 길이(names\_len), 채도 최빈값(s\_log\_mode), 만족도(satisfaction)가 상위권에 공통적으로 포함되었다. 다만

중요도 순위에는 차이가 나타났는데, 주방 카테고리에서는 가격(price\_log)이 가장 높은 중요도를 보인 반면, 디저트 카테고리에서는 리뷰 수(review\_log\_cnt)의 중요도가 상대적으로 더 높게 나타났다. 또한 디저트 모델에서는 제품 인식 가능성(product\_visibility\_score)이 상위 변수에 포함된 반면, 주방 모델에서는 카테고리 특화 변수인 고급 주방 분위기(premium\_kitchen\_feel\_score) 및 소재 고급스러움(material\_premium\_score)이 상위 10개 변수에 포함되었다. 이는 위시 수 예측에서 주방 카테고리의 경우 ‘프리미엄/소재’ 관련 이미지 변수가 상대적으로 높은 예측 기여를 보일 수 있음을 시사한다.

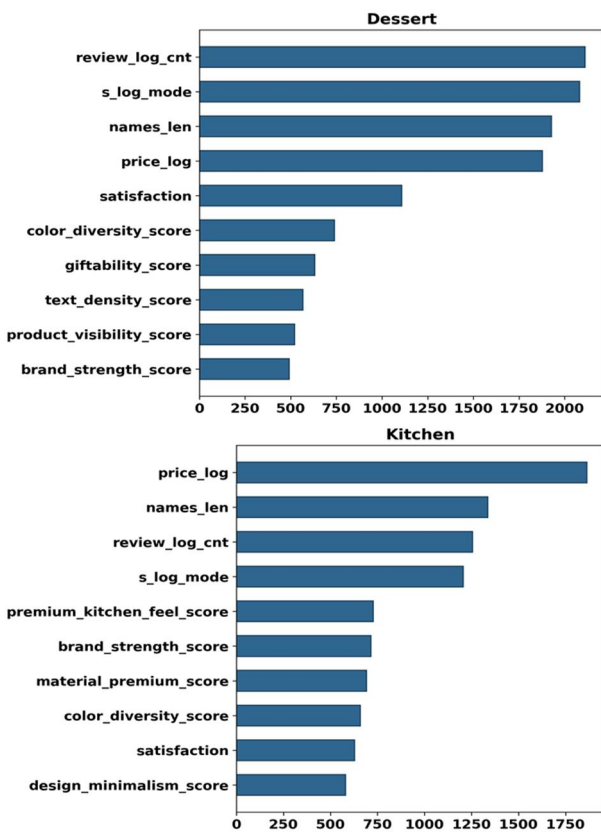


Fig. 3. Feature Importances for Wish Count Prediction

## 2. SHAP Analysis: Review-target Model

다음으로 카테고리별 리뷰 수 예측 모델에서 각 변수가 예측값에 기여하는 방향과 크기를 보다 구체적으로 확인하기 위해 SHAP 분석을 수행하였다. Fig. 4는 디저트 카테고리, Fig. 5는 주방 카테고리의 리뷰 수 예측 모델에 대한 SHAP summary plot을 제시한다. SHAP 값이 양(+)의 방향일수록 해당 변수가 리뷰 수 예측값을 증가시키는 방향으로 기여하며, 음(-)의 방향일수록 예측값 감소 방향으로 기여한다. 또한 점의 색상은 변수값의 크기(High/Low)를 의미한다.

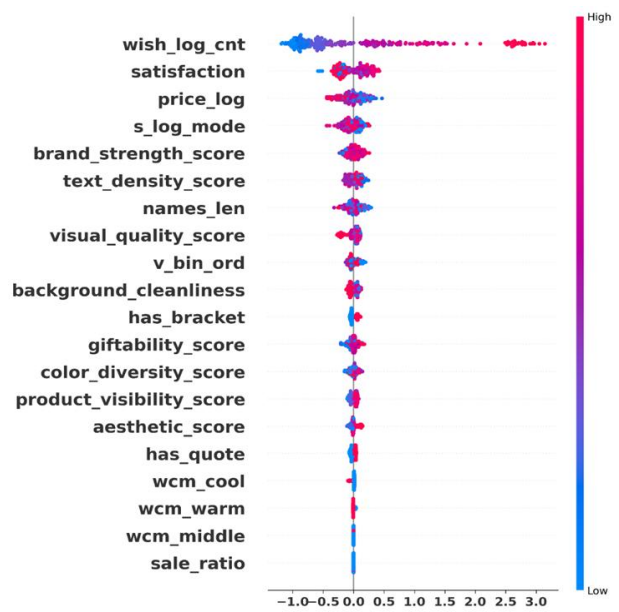


Fig. 4. SHAP Results for Review Count: Dessert

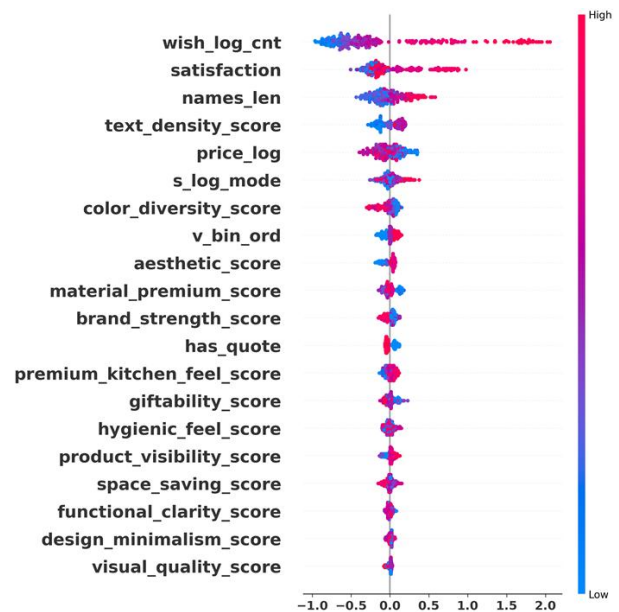


Fig. 5. SHAP Results for Review Count: Kitchen

두 카테고리에서 공통적으로 위시 수(wish\_log\_cnt)는 값이 클수록 양(+)의 SHAP 영역에 주로 분포하여 리뷰 수 예측값 증가에 기여하는 경향이 관찰되었다. 또한 가격(price\_log)은 값이 낮은 경우가 상대적으로 양(+)의 SHAP 영역에 더 많이 위치하여, 가격이 낮을수록 리뷰 수 예측값이 증가하는 방향으로 기여하는 패턴이 나타났다. 특히 디저트 카테고리(Fig. 4)에서는 price\_log가 상위 변수(3순위)로 나타나 가격 변수의 상대적 중요도가 두드러졌다. 반면 만족도(satisfaction)는 두 카테고리 모두에서 SHAP 값이 양-음 방향으로 혼재되어, 단순로운 기여 패턴이 뚜렷하게 나타나지 않았다. 이는 본 연구의 표본이 리뷰 수 10개 이상 상품으

로 제한되어 만족도 값이 높은 구간에 집중되고, 그 결과 만족도 변수의 분산과 변별력이 제한되었기 때문에 해석된다. 또한 만족도는 구매자의 평가 수준을 나타내는 질적 지표인 반면, 리뷰 수는 노출 기간, 판매 규모, 플랫폼 내 인기가 누적된 양적 반응 지표이므로 두 변수 간 관계가 단순한 단조 관계로 나타나기 어려운 것으로 볼 수 있다.

카테고리별로는 일부 변수에서 상이한 기여 양상이 확인되었다. 예를 들어 밝기(v\_bin\_ord) 및 색상 다양성(color\_diversity\_score)은 주방 카테고리(Fig. 5)에서 상대적으로 더 뚜렷한 분포 패턴을 보이며, v\_bin\_ord는 값이 클수록 예측값 증가 방향에 더 자주 위치하고, color\_diversity\_score는 값이 낮을수록 예측값 증가 방향에 분포하는 경향이 관찰되었다. 또한 상품명 길이(names\_len)와 따옴표 포함 여부(has\_quote) 등 텍스트 기반 변수는 두 카테고리에서 SHAP 분포가 상이하게 나타나, 동일 변수라도 카테고리에 따라 예측 기여 양상이 달라질 수 있음을 보여준다. 아울러 주방 카테고리에서는 premium\_kitchen\_feel\_score 등과 같은 도메인 특화 이미지 변수가 상대적으로 상위에 위치하여, 주방 상품의 리뷰 수 예측에서 이미지가 전달하는 ‘프리미엄/공간’ 관련 단서가 추가적으로 반영될 수 있음을 확인할 수 있었다.

### 3. SHAP Analysis: Wish-target Model

Fig. 6과 Fig. 7은 각각 디저트 카테고리와 주방 카테고리에서 위시 수를 타겟으로 한 LightGBM 모델의 SHAP summary plot 결과를 제시한다. SHAP 값이 양(+)의 방향일수록 해당 변수가 위시 수 예측값을 증가시키는 방향으로 기여하며, 음(-)의 방향일수록 예측값 감소 방향으로 기여한다. 또한 점의 색상은 변수값의 크기(High/Low)를 의미한다.

두 카테고리에서 공통적으로 리뷰 수(review\_log\_cnt)는 값이 클수록(High) 양(+)의 SHAP 영역에 주로 분포하여 위시 수 예측값 증가에 기여하는 경향이 관찰되었다. 이는 리뷰와 위시가 플랫폼 내에서 동시에 관측되는 대표적 반응 지표로서 높은 연관성이 반영된 결과로 해석할 수 있다. 또한 만족도(satisfaction)와 채도 최빈값(s\_log\_mode)은 두 카테고리 모두에서 상위 변수로 나타나, 상품의 평점 정보 및 이미지의 색상 특성이 위시 수 예측에 일정 수준 기여함을 보여준다.

카테고리별로는 상위 변수 구성과 기여 양상에서 차이가 확인되었다. 디저트 카테고리(Fig. 6)에서는 가격(price\_log)이 상위 변수(3순위)로 나타났으며, SHAP 분포가 양음 방향으로 혼재되어 가격의 기여 방향이 다른 변수들과의 조합에 따라 달라질 수 있음을 나타낸다. 반면 주방 카테고리(Fig. 7)에서는 상품명 길이(names\_len)가 상위 변수(3순위)로 나타났고, 값이 큰 경우가 상대적으로 음(-)의 SHAP 영역에

더 많이 분포하는 경향이 관찰되어 상품명 길수록 위시 수 예측값 감소 방향으로 기여할 가능성을 보여준다.

또한 두 카테고리 모두에서 배경 청정도(background\_cleanliness\_score), 따옴표 포함 여부(has\_quote), 대괄호 포함 여부(has\_bracket) 등의 변수가 상위권에 포함되어, 이미지/텍스트의 일부 특성이 위시 수 예측에 공통적으로 기여할 수 있음을 확인하였다. 특히 주방 카테고리에서는 premium\_kitchen\_feel\_score이나 material\_premium\_score 등의 변수가 상위에 포함되어, 주방 상품의 위시 수 예측에서는 ‘프리미엄/소재’ 관련 이미지 변수가 상대적으로 더 활용될 가능성을 보여준다.

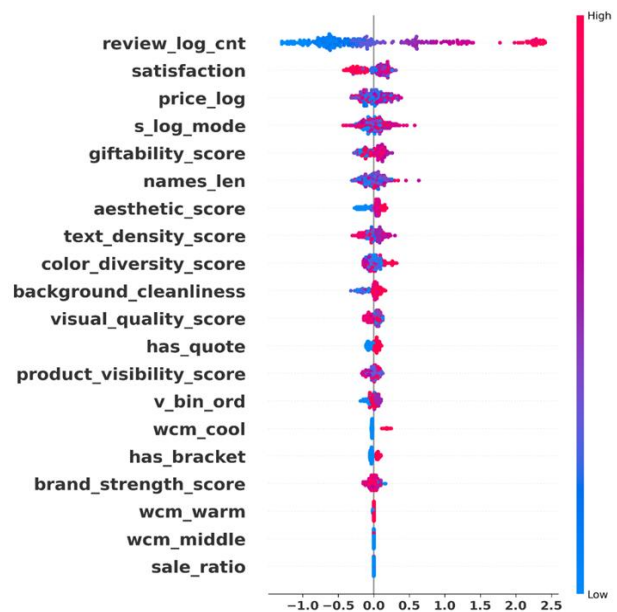


Fig. 6. SHAP Results for Wish Count: Dessert




Fig. 7. SHAP Results for Wish Count: Kitchen

#### 4. Additional Robustness Analyses

추가적으로 리뷰 수와 위시 수의 상호 입력 설계가 예측 성능에 미치는 영향을 확인하기 위해, 두 변수 간 상관관계 분석하고 각 타겟 모델에서 상대 반응 변수를 제외한 LightGBM 비교 모델을 구축하였다. 로그변환 변수 기준으로 상관분석을 수행한 결과, 디저트 카테고리에서 review\_log\_cnt와 wish\_log\_cnt의 Pearson 상관관계수는 0.7947, Spearman 상관관계수는 0.7477로 나타났으며, 주방 카테고리에서는 각각 0.6930, 0.6594로 나타났다. 모든 계수는  $p < .001$  수준에서 유의하여 두 반응 지표 간에 비교적 강한 정(+)의 연관성이 확인되었다.

Table 7과 같이 상호 반응 변수를 제외한 LightGBM 모델의 성능을 카테고리별과 타겟별로 재산출하였다. 리뷰 수 예측에서 위시 수를 제외한 모델의  $R^2$ 은 디저트 0.159, 주방 0.363으로 나타났으며, 위시 수 예측에서 리뷰 수를 제외한 모델의  $R^2$ 은 디저트 0.051, 주방 0.086으로 나타났다. 이는 리뷰 수와 위시 수가 예측 성능에 중요한 행동 신호로 작용함을 보여주며, 동시에 상호 반응 변수를 제외하더라도 가격, 텍스트, 이미지 기반 변수만으로 일부 설명력이 유지됨을 의미한다.

또한 이미지 기반 변수의 추가적 예측 효용을 확인하기 위해 이미지 변수 포함 모델과 제외 모델의 성능을 비교하였으며, LightGBM 기준 결과를 Table 8에 제시하였다. 디저트 카테고리에서는 이미지 변수 포함 시 성능이 소폭 향상되었으나, 주방 카테고리에서는 리뷰 수 예측의 성능 개선이 나타나지 않았고 위시 수 예측에서만  $R^2$ 이 0.490에서 0.550으로 증가하였다. 따라서 이미지 기반 변수는 모든 과제에서 일관된 성능 향상을 제공한다기보다, 일부 카테고리별과 타겟, 특히 위시 수 예측에서 제한적인 추가 정보를 제공하는 것으로 해석하는 것이 적절하다. 다만 이는 관측 데이터 기반의 예측적 연관성이며, 이미지 특성이 소비자 반응을 직접 유발한다는 인과적 해석으로 확장되지는 않는다.

Table 7. Performance of Comparison Models Excluding Cross-response Inputs

Category	Target (Excluded Input)	$R^2$	RMSE	MAE
Dessert	Review Count (Wish Count)	0.159	1.267	0.978
	Wish Count (Review Count)	0.051	1.264	0.974
Kitchen	Review Count (Wish Count)	0.363	1.090	0.849
	Wish Count (Review Count)	0.086	1.108	0.888

Table 8. Performance Comparison with and without Image-based Features (LightGBM)

Category	Target	Image Features	$R^2$	RMSE	MAE
Dessert	Review	Included	0.694	0.765	0.599
		Excluded	0.674	0.789	0.618
	Wish	Included	0.555	0.865	0.639
		Excluded	0.550	0.871	0.657
Kitchen	Review	Included	0.717	0.727	0.521
		Excluded	0.740	0.697	0.523
	Wish	Included	0.550	0.777	0.617
		Excluded	0.490	0.828	0.666

#### V. Discussion

본 연구는 카카오톡 선물하기 플랫폼의 상품 단위 데이터를 활용하여 리뷰 수와 위시 수를 예측하는 머신러닝 모델을 구축하고, 상품 기본 정보와 생성형 AI 기반 이미지 변수가 예측 과정에서 어떻게 활용되는지를 분석하였다. 분석 결과, 주요 변수의 상대적 중요도와 기여 방향은 카테고리별과 타겟 지표에 따라 다르게 나타났다.

리뷰 수와 위시 수는 플랫폼에서 동시에 관측되는 반응 지표로서 높은 연관성을 보였으며, 각각 구매 이후 반응과 구매 이전 관심을 반영하는 지표로 해석할 수 있다. 리뷰 수 예측에서는 낮은 가격이 예측값 증가 방향으로 기여하는 경향이 비교적 일관되게 나타났으나, 위시 수 예측에서는 가격, 만족도, 일부 이미지 변수의 기여 방향이 혼재되어 여러 단서의 조합이 반영될 가능성을 보였다. 또한 주방 카테고리에서는 일부 예측 과제에서 도메인 특화 이미지 변수가 상위 변수로 나타나, 카테고리별 변수 구성에 차이가 있음을 확인하였다.

이러한 결과는 상품 상세페이지 구성 및 상품 표현 전략 수립에 참고할 수 있는 정량적 단서를 제공한다. 예를 들어 디저트 상품은 썸네일에서 제품과 선물 구성이 즉시 식별되도록 배경을 단순화하고 제품을 크게 배치하는 방식을 고려할 수 있으며, 주방 상품은 소재감, 고급스러움, 실제 사용 장면이 드러나는 이미지를 강화하는 방식을 고려할 수 있다. 다만 이러한 전략은 관측 데이터 기반의 예측적 연관성에 근거한 것이므로, 실제 적용 시에는 A/B 테스트 등을 통해 효과를 검증할 필요가 있다.

한계로는 본 연구가 카카오톡 선물하기라는 단일 플랫폼의 두 개 카테고리를 대상으로 수행되었다는 점에서 일반화에 제약이 있고, 각 카테고리 내 노출 상품을 폭넓게 포함하였더라도 플랫폼 전체 상품군을 대표한다고 보기는 어렵다는 점이 있다. 또한 만족도 변수를 포함하기 위해

리뷰 수 10개 이상 상품으로 분석 대상을 제한함에 따라 표본 수가 축소되고, 상대적으로 반응이 축적된 상품 중심으로 표본이 구성되었을 가능성이 있다. 생성형 AI 기반 이미지 변수 역시 일부 개념 중첩이나 평가상의 모호성, 블랙박스적 특성을 내포할 수 있고 브랜드 인지도나 광고 노출과 같은 잠재적 교란 변수 및 크롤링 기반 수집 과정의 편향 가능성을 충분히 배제하기 어렵다. 아울러 리뷰 수와 위시 수를 상호 입력 변수로 활용한 구성은 예측 목적에는 부합하지만, 두 변수 간 강한 정(+)의 연관성으로 인해 예측 성능의 일부가 이러한 상관성에 의해 강화되었을 가능성이 있으며, 인과 방향을 직접 규명하는 데에는 한계가 있다. 또한 본 연구는 2025년 11~12월에 수집된 단일 시점 데이터를 기반으로 하므로, 상품 생애주기, 시즌성, 할인 행사 및 프로모션과 같은 동적 요인을 충분히 반영하지 못했을 가능성이 있다. 이에 따라 리뷰 수와 위시 수는 상품 자체의 특성뿐 아니라 노출 기간, 시즌성, 프로모션 효과가 함께 반영된 누적 반응 지표로 해석될 필요가 있다. 따라서 본 연구의 변수 중요도와 SHAP 결과는 고정된 인과 효과라기보다 해당 수집 시점에서 관측된 예측적 연관성으로 이해하는 것이 적절하다. 향후 연구에서는 시간 축 데이터, 다양한 카테고리, 복수 플랫폼을 포함한 시계열 또는 패널 데이터 기반 접근을 통해 일반화 가능성과 외적 타당성을 추가로 검토할 필요가 있다. 끝으로, 생성형 AI 기반 이미지 점수의 타당성을 보완적으로 확인하기 위해 소규모 인간평가 및 타 생성형 AI와의 비교를 수행하였으나, 동일 모델의 반복 호출 안정성 및 프롬프트 변화에 따른 민감도 분석은 충분히 수행하지 못했다는 한계가 있다.

## VI. Conclusions

본 연구는 온라인 선물 환경에서 소비자 반응 지표를 예측할 때 생성형 AI 기반 이미지 변수가 일부 카테고리 및 타겟에서 보조적인 예측 정보를 제공할 수 있음을 확인하였다. 특히 이미지 기반 변수의 중요도와 기여 양상은 타겟 지표와 카테고리에 따라 상이하게 나타났으며, 이는 온라인 선물 플랫폼에서 소비자 반응을 이해할 때 시각적 단서를 함께 고려할 필요가 있음을 시사한다. 또한 본 연구는 생성형 AI 기반 이미지 변수를 구조화된 상품 데이터와 통합하고, 예측과 해석을 함께 제시하는 방법론적 틀을 제안하였다는 점에서 의의를 가진다.

## REFERENCES

- [1] Bridge Economy, "“Capture the 5 trillion KRW market”... Fierce Competition in the Mobile Gifting Industry," Oct. 5, 2023. [Online]. <https://www.viva100.com/20231005010000924>
- [2] Statistics Korea (KOSTAT), "Online Shopping Trends Survey: November 2025," 2025. [Online]. <https://www.kostat.go.kr>
- [3] S. Kim, "Does Online Gift-giving Platform Improve the Consumer Gift-giving Process?: The Role of Platform Literacy, Platform-provided Information and Feedback," PhD Dissertation, Sejong University, Aug. 2023. <https://www.riss.kr/link?id=T16824686>
- [4] D. Choi and Y. Jung, "Study on User Experience of Kakao Talk Gift: Analysis of Consumption Behavior and Psychology of 20s," Proceedings of the 2024 Korean Society of Design Science Fall International Conference, pp. 36-37. Nov. 2024.
- [5] G. Won, H. Jung and H. Kwon, "Exploring User Preference on Cancellation/Refund Policy within Kakao TalkGift Service," Proceedings of the 2024 Korean Society of Design Science Spring International Conference, pp. 304-305. May. 2023.
- [6] M. Woo, "The Effect of Online Gift Certificate Transactions on Offline Market Structure: Focused on KakaoTalk Gift and Coffee Shop Markets," Master's Thesis, Yonsei University, Jun. 2023. <https://www.riss.kr/link?id=T16810699>
- [7] M. Kim and J. Lim, "Predicting Netizens' Movie Ratings Using Expert Movie Critique and Netizen Review Big Data," Proceedings of the 2022 Korean Institute of Industrial Engineers Fall Conference, Nov. 2022.
- [8] H. Kim, "Text-Based Feature Analysis for Predicting Online Course Ratings and Enrollment: A Multi-Platform Comparative Approach," Journal of Digital Contents Society, Vol. 26, No. 6, pp. 1623-1632, Jun. 2025. DOI: 10.9728/dcs.2025.26.6.1623.
- [9] M. Zaghoul, S. Barakat, and A. Rezk, "Predicting E-commerce Customer Satisfaction: Traditional Machine Learning vs. Deep Learning Approaches," Journal of Retailing and Consumer Services, Vol. 79, Art. no. 103865, Jul. 2024. DOI: 10.1016/j.jretconser.2024.103865.
- [10] W. Xu, Y. Cao, and R. Chen, "A Multimodal Analytics Framework for Product Sales Prediction with the Reputation of Anchors in Live Streaming E-commerce," Decision Support Systems, Vol. 177, Art. no. 114104, Feb. 2024. DOI: 10.1016/j.dss.2023.114104.
- [11] X. Li, J. Shen, D. Wang, W. Lu, and Y. Chen, "Multi-modal Transform-based Fusion Model for New Product Sales Forecasting," Engineering Applications of Artificial Intelligence, Vol. 133, Art. no. 108606, Jul. 2024. DOI: 10.1016/j.engappai.2024.108606.
- [12] S. Chaube, R. Kar, S. Gupta, and M. Kant, "Multimodal AI Framework for the Prediction of High-potential Product Listings in E-commerce: Navigating the Cold-start Challenge," Expert Systems with Applications, Vol. 282, Art. no. 127524, Jul. 2025.

DOI: 10.1016/j.eswa.2025.127524.

- [13] H. Wei, Y. Yang, and Y.-W. Chen, "Multimodal Review Helpfulness Prediction with a Multi-level Cognitive Reasoning Mechanism: A Theory-driven Graph Learning Model," *Decision Support Systems*, Vol. 191, Art. no. 114406, Apr. 2025. DOI: 10.1016/j.dss.2025.114406.
- [14] S. Lee, H. Oh, H. Lim, and E. Choung, "Prediction View per Subscriber Counts Model Based on Youtube Thumbnails Using Machine Learning Approach," *Proceedings of the 2024 Korea Contents Society Conference*, May. 2022.
- [15] Y. So, E. Woo, and H. Lee, "Machine Learning-based Learning-to-Rank Approach for Horse Race Prediction and Web Service Development," *Journal of The Korea Society of Computer and Information*, Vol. 30, No. 11, pp. 311-318, Nov. 2025. DOI: 10.9708/jksci.2025.30.11.311

## Authors



Eunji Kim is an undergraduate student in the Department of Management Information Systems at Myongji University, Korea, and is expected to graduate in February 2027. She is interested in software development and

data analysis and is preparing for a career in the IT industry.



Hanjun Lee received his B.S. and M.S. degrees in Computer Engineering from Seoul National University in 2001 and 2004, respectively, and his Ph.D. degree in Management Information Systems from Korea

University in 2016. He joined the Department of Management Information Systems at Myongji University, Seoul, Korea, as a faculty member in 2020. His research interests include data science, particularly text mining, machine learning, and online review analysis.