

건강검진 예약부도 후 방문 패턴 예측: 설명가능한 인공지능 기반 기여요인 분석

Predicting Post-No-Show Visit Patterns in Health Screenings: An XAI-Based Analysis of Contributing Factors

권동기(주저자) · 김성수(교신저자)

Dongki Kwon(First Author) · Sungsu Kim(Corresponding Author)

경북대학교 경영학부, 한국건강관리협회 School of Business Administration, Kyungpook National University & Korea Association of Health Promotion (777ssanai@gmail.com)

경북대학교 경영학부 & 경북대학교 에너지환경경제연구소 School of Business Administration, Kyungpook National University & Research Institute for Energy, Environment and Economy (RIEE), Kyungpook National University(sung Sukim@knu.ac.kr)

의료기관의 예약부도는 의료 서비스 자원의 낭비와 운영 효율성 저하를 초래하는 문제이며, 특히, 예약부도 이후 고객의 방문 여부를 예측하는 것은 실무적으로 중요하다. 본 연구는 한국건강관리협회의 2020~2022년 데이터를 활용하여 예약부도 이후 고객의 방문과 미방문 가능성을 예측하고, 설명 가능한 인공지능(Explainable AI, XAI) 기법을 이용해 주요 기여 요인을 분석하였다. Random Forest, Decision Trees, LightGBM을 포함한 머신러닝 및 앙상블 모형들을 비교하였으며, 방문 예측에는 LightGBM 모형, 미방문 예측에는 Random Forest 모형이 가장 우수한 성능을 보였다. SHAP 기법을 적용한 결과, 과거 재예약 여부와 신규 고객 여부 변수가 공통적으로 중요한 요인으로 나타났다. 또한, LIME 기법을 통해 변수별 영향력의 방향성과 중요도를 시각적으로 해석할 수 있도록 하였다. 본 연구는 의료기관의 예약 시스템 개선에 기여하며, 예약부도 이후 고객 행동을 예측함으로써 의료 자원의 효율적 운영과 맞춤형 고객 관리 전략 수립에 통찰을 제공한다.

주제어: 예약부도, 건강검진, 머신러닝, 운영효율성, 설명가능한 AI

Patient appointment no-shows constitute a significant challenge in healthcare institutions, leading to a substantial waste of medical service resources and a deterioration of operational efficiency. Consequently, accurately predicting patient visit propensity following initial appointment absenteeism holds considerable practical significance for effective healthcare management. This study leverages longitudinal data from the Korea Association of Health Promotion, spanning 2020 - 2022, to predict the likelihood of patient visitation versus non-visitation subsequent to appointment defaults. Crucially, the research employs eXplainable Artificial Intelligence (XAI) methodologies to elucidate key contributory factors. A comparative analysis was conducted across multiple machine learning and ensemble modeling approaches, specifically Random Forest, Decision Trees, and LightGBM algorithms. The empirical findings demonstrate that LightGBM exhibited superior predictive performance for visit prediction, whereas Random Forest achieved optimal efficacy for non-visitation forecasting. Application of the SHapley Additive exPlanations (SHAP) methodology revealed that historical rescheduling behavior and new patient status emerged as pivotal determinants across both predictive models. Furthermore, Local Interpretable Model-agnostic Explanations (LIME) techniques were employed to provide a visual interpretation of variable-specific influence directionality

최초투고일: 2025. 07. 01

수정일: (1차: 2025. 08. 16)

재제확정일: 2025. 09. 02

Copyright 2025 THE KOREAN ACADEMIC SOCIETY OF BUSINESS ADMINISTRATION

This is an open access article distributed under the terms of the Creative Commons Attribution License 4.0, which permits unrestricted, distribution, and reproduction in any medium, provided the original work is properly cited.

and feature importance magnitudes. This investigation contributes significantly to the advancement of healthcare appointment management systems and provides actionable insights for efficient medical resource allocation and personalized patient engagement strategies through predictive modeling of post-default patient behavioral patterns.

Keyword: No Show, Health Screening (Health Examination), Machine Learning, Operational Efficiency, eXplainable Artificial Intelligence (XAI)

1. 서론

검진 예약 제도는 의료 서비스의 질을 향상하고 고객에게 편리함을 제공하기 위해 여러 의료 기관에서 도입하고 있는 중요한 시스템이다(Kammrath et al., 2025). 하지만 예약부도 고객은 여전히 많으며 이로 인해 다른 고객의 검진 기회를 박탈하고, 의료진의 대기시간이 늘어나는 문제가 발생하고 있다(조규철&정다운, 2023). 이는 의료 서비스의 질관리와 의료 인력의 유지에 어려움을 초래한다. 이러한 문제를 해결하기 위해 의료기관에서는 예약부도 문제를 보다 체계적으로 관리할 필요성이 커졌으며, 많은 의료기관에서 예약부도에 영향을 미치는 요인을 파악하여 경영 안정성을 확보하고, 예약부도 고객의 방문율을 높이기 위해 노력하고 있다.

특히, 예약부도에 따른 경제적 손실이 심각한데, 고객 1명당 예약부도 평균 비용은 196달러(Kheirkhah et al., 2016), 예약부도에 의한 예상 연간 손실은 약 1,500억 달러 정도이고(Srinivas and Ravindran, 2018), 반복 가능성(Berg et al., 2013) 때문에 대부분의 의료기관이 부정적으로 인식되고 있으며 실제로 전체 예약의 평균 14% ~ 50%가 예약부도로 이어지고 있다(Daggy et al., 2010).

예약부도 이후 고객의 방문 가능성을 높이려면, 고객의 행동 패턴을 파악하고 이를 예측해 의료기관의

경영 안정성을 도모해야 한다. 의료 기관의 안정적인 운영을 위해서는 예약부도를 효율적으로 관리하는 것이 필수적이며, 이를 통해 의료 서비스의 질을 향상하고 고객 방문을 증가하려 한다. 이러한 문제 해결을 위해, 머신러닝, 앙상블 모형을 활용하여 예약부도 후 방문에 높은 영향을 주는 요인을 밝혀 내고, 설명 가능한 AI(eXplainable Artificial Intelligence, XAI) 연구로 예약부도자들의 방문과 미방문 현상을 깊이 이해하고자 한다.

의료 분야는 AI시스템의 의사결정이 신뢰 가능하고 검증될 수 있어야 함을 요구한다(Doshi-Velez and Kim, 2017; Holzinger et al., 2019; Samek, 2017). 기존의 블랙박스 모형의 잘못된 상관관계에 의존하여 문제를 해결하는 Clever Hans현상은, 상관관계가 존재하지 않을 경우 유용성을 제공하지 못할 가능성이 높아진다(Lapuschkin et al., 2019). 이를 충족시키기 위해서는 XAI가 필수적이며, 블랙박스 모형의 한계를 극복하고, 예측 모형의 투명성과 설명 가능성을 높이는 데 중요한 역할을 한다(Adadi and Berrada, 2018).

Hu et al.(2020)은 의료 기관의 예약 관리 시스템에서 발생하는 예약부도 문제를 다루며, 주요 결정 요인으로 의식적 요인과 무의식적 요인을 제시한다. 이러한 요인들이 검진 예약 시스템에 적용될 경우, 예약부도 행동을 관리하고 의료기관 예약 시스템, 고객 중심의 지속 가능한 의료서비스 제공이 중요하다

다고 강조한다. 또한, 의식적 요인과 무의식적 요인을 파악하여 예약부도를 반복하는 경험이 있는 고객을 구분하고 체계적으로 관리해야 한다는 전략적 접근이 필요하다고 주장한다.

본 연구는 예약부도 후 방문과 미방문을 예측하는데 핵심적인 요인을 규명하고, XAI를 활용해 이를 정밀하게 해석하는 것을 목표로 한다. 이를 위해 XAI 기술을 활용하여 예측 모형의 투명성과 설명 가능성을 향상하고, 검진 예약부도자들의 방문 문제를 보다 효과적으로 해결할 수 있는 새로운 통찰력을 제공하는 것을 목표로 한다.

본 논문의 구성은 다음과 같은 순서로 전개된다. 2절에서는 선행연구를 통해 예약부도의 요인과 예측 모형에 대해 다룬다. 3절 데이터 및 방법론에서는 종속변수와 독립변수에 대한 설명, 데이터 수집과 처리, 예측 모형 성능 평가에 대해 다룬다. 4절 결과분석에서는 예측성능을 비교하고 예측 영향 요인을 분석하기 위해 각 종속 변수별 SHAP(SHapley Additive exPlanations)와 LIME(Local Interpretable Model-agnostic Explanations) 해석의 결과를 제시한다. 5절 결론은 본 연구의 주요 내용을 정리하고, 시사점 및 한계점을 서술한다.

II. 문헌연구

예약 후 서비스를 이용하기 위해 예약 시간과 장소에 나타나지 않고, 사전 통보나 취소를 하지 않는 행위를 일반적으로 예약부도라고 정의한다. 권성탁 외(2015)은 의료기관을 방문하기로 예약한 후 예약일에 방문하지 않는 사례를 예약부도로 간주하였으며, Ahmadi et al.(2019)은 고객이 예약 날짜에 방문

하지 않고 취소도 하지 않은 경우를 예약부도로 정의했다. 본 연구는 예약을 한 고객이 예약일에 의료기관을 내원하지 않는 고객의 경우를 예약부도로 정의한다(임지현 외 2017).

머신러닝은 최근 다양한 산업과 학문 분야에서 폭넓게 활용되며, 복잡한 의사결정 문제를 해결하는 핵심 도구로 자리매김하고 있다. 나아가 머신러닝은 의료 분야를 넘어 출판산업의 수요 예측(이승필 외 2025), 공공부문의 자원 조달 시점 예측(임세환 외 2024), 기업가치 평가를 통한 투자 의사결정(Kang and Park, 2024) 등 다양한 영역에서도 실무적 의사결정을 지원하는 데 활용되고 있다. 이러한 흐름은 의료 영역에도 확산되어, 의료기관의 예약부도 연구에서도 머신러닝을 적용한 사례가 꾸준히 증가하고 있다(Dashtban and Li, 2022). 이는 단순히 예약부도율을 설명하는 기존 연구와 달리, 고객이 방문하는 현상에 대한 새로운 관점을 제시한다.

Hu et al.(2020)은 의료기관 예약 시스템에서 고객의 예약부도 행동을 다단계 관점에서 분석하며, 이러한 행동이 단순한 개인적 요인이 아닌 각 단계에서 발생하는 다양한 요인의 복합적 결과임을 강조했다. 연구에 따르면, 예약 채널의 편리성, 대기 시간, 예상 기술적 품질 같이 의식적인 결정 요인과 예약부도의 습관적 행동과 같은 무의식적인 요인이 주요 결정 변수로 작용한다. 또한, 이들 요인 간의 상호작용이 고객의 행동에 미치는 영향을 분석하여 예약부도 가능성을 체계적으로 예측하고 관리 전략을 수립할 필요성을 제시하였다. 이러한 접근은 각 단계별 문제점을 식별하고 개선함으로써 의료기관 예약 시스템의 효율성을 높이는 데 기여할 수 있음을 의미한다.

의식적인 결정 요인 중 예약 채널의 편리성은 개인이 의료 서비스를 받기 위해 부담해야 하는 금전적 부담 이외의 부분과 관련이 있다(Berry et al., 2002).

이는 개인의 행동 통제 수준을 긍정적으로 향상하고, 예약부도를 줄일 수 있다. 또한 예약 채널의 편리성은 실용성 또는 고객이 의료기관의 예약 시스템을 통해 예약을 신속하게 진행할 수 있는 반응 속도를 의미한다(Yang et al., 2015).

Fan et al.(2023)은 인터넷 기반 예약 시스템에서는 고객의 예약 시간, 날짜, 의료기관 의사의 전문성, 의사에 대한 온라인 평판, 고객과 의료기관 사이의 거리, 이전 외래 방문 경험 등이 예약부도에 중요한 영향을 미친다고 제시한다. 특히, 리드타임이 길어질수록 고객이 예약을 지키지 못할 가능성이 커진다고 주장했다. 이는 고객이 긴 리드타임 동안 예약을 잊어버릴 가능성이 증가하기 때문이다. 아울러, 오전 예약보다 오후 예약에서 부도율이 높은 경향이 관찰되었는데, 이는 고객의 일정 관리 및 대기 시간에 대한 부담과 관련될 수 있다. 이전 의료기관 방문 경험은 기존 방문 경험이 있는 고객이 신규 고객에 비해 예약부도율이 낮은 경향과 관련되어 생각해 볼 수 있다. 이는 고객의 경험적 지식과 인지적 기대가 예약부도 행동을 완화하는데 기여할 수 있음을 의미한다.

대기시간은 고객이 의료 서비스를 받기 위해 내원한 시점부터 서비스가 시작될 때까지의 경과 시간을 의미한다(Casado and Ruz, 2002). 기다림은 부정적인 감정을 유발하고, 그에 대한 행동적 반응으로 예약부도가 나타날 수 있다(Djelassi et al., 2018). Zhou et al.(2025)은 대기 시간 허용치는 예약 스케줄링에서 중요한 요소로 작용하며, 대기 시간을 줄이는 것은 고객 만족도를 높이고 예약부도를 감소시키는 데 기여한다고 분석하였다. 고객들은 대기 시간의 공정성에 민감하며, 긴 대기 시간은 고객 만족도 감소의 주요 원인 중 하나로 제시되었다. 특히, 대기 시간이 고객들의 기대치를 초과할 경우 부정적인 감정이 증폭되어 예약부도가 증가할 가능성이 높아진

다. 연구 결과는 예약부도와 대기 시간의 상관관계를 강조하며, 예약 순서와 스케줄링 전략이 대기 시간 및 부도율에 미치는 영향을 체계적으로 평가하였다. Kagedan et al.(2021)의 연구는 하루 중 늦은 시간대로 예약이 배정될수록 대기 시간이 증가하는 경향이 있으며, 이는 고객 만족도와 공정성 측면에서 부정적인 결과를 초래할 수 있음을 나타낸다. 이러한 결과는 의료기관이 예약 시스템의 효율성을 개선하고, 대기 시간 관리를 통해 고객 경험을 최적화할 필요가 있음을 강조한다.

예상 서비스 품질은 고객이 실제로 받았다고 인식한 의료 서비스의 결과로 정의된다(Wulandari et al., 2024). 특히 의료 서비스와 같은 고 신뢰(high-credence) 산업에서는 고객의 서비스 제공 과정에서 신뢰성 요소를 더 중요하게 고려하는 경향이 있다(Kang, 2006).

Andrade et al.(2013)은 고객의 서비스 품질 인식은 행동 반응에 중요한 요인으로 작용하며, 이를 개선하면 의료 서비스의 질과 고객 만족도를 높일 수 있다고 강조했다. 또한, 이러한 환경적 요인은 고객과 의료기관의 관계 형성 및 고객 만족도 향상에도 기여한다.

무의식적 결정 요인에는 예약부도 습관을 학습한 후 예약된 약속에 대해서 자동화되는 행동이다(Limayem et al., 2007). 무단결석 습관 수준이 높을수록 향후 예약된 예약부도 행동이 발생할 가능성이 높아진다. Hu et al.(2020)은 고객의 예약부도 행동을 심층적으로 분석하며, 행동 경제학 및 심리학 관점에서 자동화된 의사결정 및 습관적이고 반복적인 예약부도 경험은 고객에게 예약에 대한 부주의한 태도를 학습시킬 수 있음을 주장했다.

검진 예약부도와 같은 행동을 예측하기 위해 Explainable AI를 활용하면 AI 모형의 예측 결과를 투명하게 이

해할 수 있으며, 예약부도의 원인과 패턴을 명확하게 파악할 수 있다. 이는 의료 기관이나 서비스 제공자가 효과적인 대응 전략을 수립하는 데 큰 도움이 된다. XAI는 두 가지 측면에서 중요하다. 첫째, XAI는 인공지능의 예측을 평가하고 검증하는 데 도움을 준다. 이는 잘못된 예측으로 인한 부정적인 결과를 최소화하고, 모델을 지속적으로 개선하기 위해 중요하다. 예약부도에 대한 해당 예측 모형의 결과를 정당화하고, 모형의 오류를 신속하게 식별하고 수정하는 데 도움이 된다. 둘째, XAI를 통해 예약부도 후 방문을 유도하는 주요 요인을 식별함으로써 보다 효과적인 접근이 가능하다. 이는 각 요인의 중요도를 명확히 이해하고, 이를 기반으로 맞춤형 전략을 수립하여 고객들이 방문할 수 있도록 하는 데 기여한다. 예약부도 후 방문과 미방문의 특정 요인들을 파악함으로써, 의료 기관은 이러한 요인들을 강화하거나 조정하여 고객 방문율을 높일 수 있다. 이와 같은 접근 방식은 예약부도 문제를 보다 효과적으로 해결하고, 의료 서비스의 질을 향상하는 데 중요한 역할을 한다.

Yiye et al.(2024)의 연구는 의료 서비스에서 XAI를 활용해 고객의 예약부도(No-show) 행동의 주요 예측 요인을 분석하였다. 연구는 SHAP와 LIME과 같은 XAI 도구를 사용해 No-show 예측 모형의 해석 가능성을 높였다. 특히, 예약부도 행동의 주요 요인으로 이전 예약부도 횟수(Number Missed), 예약 대기 시간(Awaiting Time), SMS 알림 수신 여부(SMS Received), 그리고 고객의 나이를 변수로 지정했다. SHAP 분석 결과, 과거 예약부도 이력이 높은 SHAP 값을 나타내며, 이는 고객이 예약을 지키지 않을 가능성을 크게 높이는 요인으로 작용함을 의미한다. 또한, SMS 알림을 받은 고객은 부도율이 낮아지는 경향을 보였는데, 이는 효과적인 의사소통 전략이 고객 행동에 핵심적인 요인으로 작용할

가능성을 나타낸다. LIME 분석에서는 개별 고객의 행동을 설명할 수 있는 구체적인 요인들이 드러났으며, 이러한 분석은 모형의 예측 결과를 이해하고 신뢰성을 확보하는 데 도움을 준다. 결과적으로, XAI 기술을 활용한 분석은 예약부도 행동을 관리하고, 의료 자원의 낭비를 줄이는 데 중요한 통찰을 제공한다.

기존 연구는 대부분이 예약부도 발생의 원인이나 관련 요인에 초점을 맞추고 있으며, 예약부도 후 방문 여부에 관한 연구는 상대적으로 부족하다. Elkhider et al.(2022)은 과거 방문 경험이 많을수록 재방문 가능성이 높다고 주장하였으며, Drewek et al.(2017)은 예약 시점과 진료일 간의 시간 간격이 길수록 방문율이 감소하는 결과를 제시하였다. 이는 고객의 이전 예약 이력, 리드타임, 예약 요일 및 시간대 등은 단순한 예약부도 예측을 넘어 예약부도 이후의 실제 방문 행동 예측에도 의미 있는 변수로 작용할 수 있음을 시사한다.

본 연구는 예약부도 이후 고객의 방문 및 미방문 행동을 예측하기 위해 기존 연구와 유사한 변수 구성을 바탕으로 LightGBM, Random Forest 등 다양한 머신러닝과 앙상블 모형을 적용하여 높은 예측 성과를 도출하였다. 특히, SHAP와 LIME과 같은 설명 가능한 인공지능(XAI) 기법을 활용하여 변수의 방향성과 기여도를 시각적으로 제시하고, 모형 해석의 투명성과 실무 적용 가능성을 동시에 확보하였다. 이러한 접근은 기존의 통계 기반 연구와 차별화되며, 예약부도 이후 고객의 행동에 대한 정량적 해석과 예측이라는 측면에서 학술적 기여점을 가진다.

III. 데이터 및 방법론

3.1 데이터 확보 및 변수 선정

본 연구는 2020년 ~ 2022년 사이에 예약부도 1,010,908건, 한국건강관리협회(Korea Association of Health Promotion [KAHP])의 전국 16개 지부를 대상으로 예측 모형을 개발한다. 결측 데이터를 제외한 후 분석에 활용하였으며, 연구 진행 전 한국건강관리협회(IRB No. 130750-202306-HR-009)의 승인을 받았다.

독립변수는 인구사회학적인 특성, 문화적인 특성, 예약에 대한 행동 패턴, 신규 고객 영역으로 나누었으며 기존 연구에서 다룬 변수를 포함하고 있다. 선행연구에서는 예약부도의 원인을 의식적 요인과 무의식적 요인으로 구분한다. 의식적 요인으로는 예약 채널의 편리성, 대기 시간, 예상 기술적 품질이 있으며, 무의식적 요인으로는 예약부도의 습관적 행동이 포함된다(Hu et al., 2020).

〈Table 2〉에서 보면 인구사회학적 변수 중 연령 항목은, 연령이 증가할수록 정기적인 건강검진의 필요성을 더 잘 인지하게 되어 의료 서비스 이용 행태에 영향을 미칠 수 있다는 선행 연구(Shenson et al., 2012)를 참고하여, 본 연구에서는 고객을 20대부터 90대까지 연령대별로 구분하여 분석에 반영하였다. 여성이 남성보다 의료 서비스에 대한 이용률이 높고 관련 비용도 더 높다(Bertakis et al., 2000). 성별은 남, 여로 구분하였다(Guzek et al., 2015). 방문 일정, 공휴일, 그리고 명절과 같은 요인들이 고려되었다. 검진일정이 명절 전, 후와 공휴일 전, 후 여부는 의료 서비스 제공에 제약 발생 및 의료 인력의 부재 등에 따른 의료 서비스 제공 한계와 휴일에

따른 예약부도의 증가 가능성이 있어, 이는 예상 기술 품질에 영향을 줄 수 있다. Ratmanský et al. (2017)의 연구에 따르면, 주요 휴일 기간 동안의 예약부도율이 32%로 비교 대상 기간의 24.1% 보다 높은 수치였다. 공휴일이 고객의 내원 여부에 영향을 미칠 수 있음을 보여준다. 예약 채널의 편리성 측면에서 예약 방식은 웹사이트, 전화, 대면 예약으로 구분되며, 각 예약 방식의 편리성을 고려하여 고객이 특정 예약 채널을 선택하는 데 미치는 영향을 분석하고자 하였다(Simanjuntak and Sakti, 2023). 예약일은 예약 고객이 의료기관의 예약 시스템(전화, 인터넷, 대면 등)을 통해 건강검진 일자를 확정할 날짜를 의미하며, 이는 변경이나 취소 이전에 고객과 의료기관 간에 합의된 최초의 검진이 확정된 날짜를 기준으로 한다. 대기시간 관점에서 리드타임 변수는 예약일과 검진일 간의 시간 차를 기반으로 하여 예약부도 이후 실제 검진 여부에 영향을 미치는 요인으로 정의하였다. 일반적으로 리드타임이 길어질수록 방문 가능성이 낮아지는 경향이 있는데, Elkhider et al. (2022)은 리드타임이 7일 이하인 경우 예약부도율은 8%, 7~14일은 11%, 60일 이상일 경우 19%로 증가하였으며, 리드타임이 길수록 예약부도 가능성이 유의하게 상승하는 경향을 보였다. Drewek et al. (2017)은 리드타임이 30일 이상일 경우 예약부도율이 23%에서 47%로 증가하는 것으로 나타났다. 본 연구에서 리드타임은 1주, 2주, 3주, 4주에서 2개월, 3개월 이상으로 구분되었으며, 방문과 미방문에 영향을 미치는 요인을 파악하기 위해 7일 단위로 계산하였다. 예상 기술 품질은 검진 방문의 월, 요일, 시간과 같은 변수를 포함할 수 있다. 특정 시기와 시간대에 검진 수요가 집중되면 서비스 품질에 영향을 미칠 가능성이 있다. 검진일 변수는 계절적 특성과 건강검진 수요의 시기적 편차를 반영하기 위해 1월부

터 12월까지 월별로 구분하였다(Huang and Hanauer, 2014). 방문 요일 변수는 평일과 주말에 따라 고객의 방문 가능성에 차이가 있을 수 있어 요일별로 구분하였다(AlMuhaideb et al., 2019). 방문 시간 변수는 오전과 오후로 구분하여 시간대별 예약 이행 패턴을 분석하고자 하였다(Dashtban and Li, 2022). 재예약 여부 변수는 해당 고객이 해당 연도에 예약 부도 후, 동일 의료기관에 다시 예약을 진행한 이력이 있는지를 보여주는 이진 변수이다. 예약을 했던 연도 내에 재예약한 경험 여부를 기준으로 정의되며, 이는 고객의 재이용 의향이나 병원에 대한 관계 지속 가능성을 간접적으로 파악하는 데 활용할 수 있다. 예약 횟수는 고객의 건강검진 이용 빈도를 반영하는 변수로, 예약 횟수가 많을수록 예약부도 가능성이 낮다는 기존 연구 결과에 기반하여 포함하였다(Dashtban and Li, 2022). 예약부도 횟수는 반복적인 부도 경험이 향후 예약 이행에 부정적인 영향을 미친다는 점을 고려하여 변수로 설정하였으며, 데이터 분포와 예측 안정성을 바탕으로 2회부터 8회까지의 구간으로 구성하였다(Joseph et al., 2022). 특히, 예약부도 습관 변수는 부도 횟수를 예약 횟수로 나눈 값에 정규화된 검진일과 예약일 간의 간격을 곱하여 생성되었다. 이를 통해 개별 고객의 예약 습관과 부도 성향을 상대적인 수치로 표현할 수 있다. 부도 횟수가 많고 리드타임이 길수록 해당 값이 커지며, 이를 통해 고객의 예약 성실도를 보다 명확하게 평가할 수 있다. 또한, 예약일과 검진일 간의 간격을 정규화하

여 변수에 반영함으로써 예약과 실제 방문 간의 시간적 요소를 고려하여 고객의 예약 이행 가능성을 정밀하게 분석하고자 하였다. 더불어, 고객의 과거 예약부도 경험과 고객의 부도 빈도는 추후 예약 이행 여부에 작용할 가능성이 있다는 가정하에, 방문과 미방문 행동을 예측할 수 있는지 검증하고자 하였다.

〈Table 1〉에서 종속변수는 2022년 한 해 동안의 고객 방문 여부를 기준으로 예약부도 발생일 이후 2년 이내에 동일 기관을 방문한 경우를 방문(Visit=1), 방문하지 않은 경우를 미방문(No Visit=1)으로 정의하여 이진형(Binary) 종속변수를 생성하였다. 이는 국가건강검진이 2년 주기로 시행되기 때문으로 장기적인 방문까지 감안하여 설정했으며, 예약부도 후 방문과 미방문의 두 가지 패턴을 분석하였다. 이를 통해 방문과 미방문 예측 모형의 신뢰성을 높이고 예약 시스템 개선과 고객 관리 전략 개발을 개발하고자 한다.

3.2 분석방법

예약부도 후 고객이 방문할 가능성을 예측하는 것은 의료기관 입장에서 매우 중요한 과제다(Suk et al., 2021). 이러한 예측은 진료 공백을 줄이고, 과잉 예약(overbooking), 대기 고객 리스트 활용, 리마인더 발송 등 다양한 운영 전략 수립을 가능하게 하여 의료기관의 운영 효율성과 수익성을 제고하는 데 기여한다. 특히, 예약부도로 인한 의료 자원의 비효

〈Table 1〉 종속변수 설명

종속변수	빈도	비율(%)
방문(Visit = 1)	147,524	48.6
미방문(No Visit = 1)	156,218	51.4

〈Table 2〉 독립변수 설명과 데이터 특성

변수명	설명	n=707,166	변수명	설명	n=707,166
Age group	20대	73,675(10.4%)	Lead time(days)	1 ~ 7일	213,512(30.2%)
	30대	75,351(10.7%)		8 ~ 14일	153,692(21.7%)
	40대	115,233(16.3%)		15 ~ 21일	90,824(12.8%)
	50대	155,470(22%)		22 ~ 29일	64,185(9.1%)
	60대	174,479(24.7%)		30 ~ 59일	114,468(16.2%)
	70대	92,098(13%)		60 ~ 89일	32,732(4.6%)
	80대	20,588(2.9%)		90일 이상	334(0.0%)
	90대 이상	272(0.0%)			
Gender	남	402,281(56.9%)	Number of past reservations	2번	167,705(23.7%)
	여	304,885(43.1%)		3번	73,992(10.5%)
Public holidays	공휴일 전후1일 (±1일)	11,647(1.6%)		4번	31,903(4.5%)
Traditional holidays	명절 전후 1일(±1일)	14,785(2.1%)		5번	14,913(2.1%)
Reservation channel	홈페이지	60,410(8.5%)		6번	7,400(1%)
	전화	556,351(78.7%)		7번	4,118(0.6%)
	방문	90,405(12.8%)		8번	2,345(0.3%)
Scheduled appointment month	1월	41,941(5.9%)		9번	1,439(0.2%)
	2월	68,194(9.6%)		10번 이상	2,108(0.3%)
	3월	57,378(8.1%)	Number of past no shows	2번	579,501(81.9%)
	4월	56,397(8.0%)		3번	89,455(12.6%)
	5월	54,874(7.8%)		4번	24,343(3.4%)
	6월	64,439(9.1%)		5번	8,170(1.2%)
	7월	62,169(8.8%)		6번	3,226(0.5%)
	8월	55,099(7.8%)		7번	1,446(0.2%)
	9월	54,218(7.7%)		8번 이상	691(0.1%)
	10월	64,280(9.1%)	[Number of past no shows / Number of past reservations] × Lead time (regularization)	0.010 이하	334(0%)
	11월	61,078(8.6%)		0.011 ~ 0.020	152,514(21.6%)
	12월	67,099(9.5%)		0.021 ~ 0.030	89,219(12.6%)
Scheduled appointment day	일	23,880(3.4%)		0.031 ~ 0.040	67,728(9.6%)
	월	124,749(17.6%)		0.041 ~ 0.050	44,792(6.3%)
	화	112,553(15.9%)		0.051 ~ 0.060	28,574(4%)
	수	103,966(14.7%)		0.061 ~ 0.070	20,163(2.9%)
	목	107,270(15.2%)		0.071 ~ 0.080	21,318(3%)
	금	107,998(15.3%)	Past Rebooking	0.081 이상	52,039(7.4%)
	토	126,750(17.9%)		이력 있음(1)	471,421(66.7%)
Scheduled appointment time	오전	606,154(85.7%)	New client	이력 없음(0)	235,745(33.3%)
	오후	101,012(14.3%)		신규고객(1)	20,165(2.9%)
				기존고객(0)	687,001(97.1%)

올적 낭비를 방지하고, 고객의 접근성을 높이는 데에도 효과적이다(Deina et al., 2024). 더 나아가, AI 및 머신러닝 기반의 예측 모델은 단순한 방문 예측을 넘어서 자원 배분의 최적화, 고객 유지 관리, 서비스 품질 향상 등 의료기관의 중요 의사결정에 활용이 가능하여 폭넓은 경영 전략 수립의 기반이 된다(Amalina et al., 2025; Liu et al., 2022).

본 연구에서는 전국 16개 지역 한국건강관리협회 지부에서 수집한 20세 이상 고객의 약 101만 건의 예약부도 데이터를 분석하였다. 예측 모형 개발을 위해 Python(버전 3.12.3)과 Anaconda(버전 23.7.4) 패키지를 활용하여 머신러닝 및 앙상블 모형을 적용하였다. Random Forest, LightGBM, XGBoost와 같은 머신러닝 및 앙상블 기법을 사용하였으며, 독립 변수의 통계적 유의성을 검증하기 위해 독립 표본 t-검정을 수행하였다. t-검정에서 특정 변수의 p값이 0.05 미만일 경우, 해당 변수는 방문 여부에 따라 평균 차이가 통계적으로 유의미하게 나타나는 변수임을 의미한다. 따라서 두 집단 간에 차이가 없는($p > 0.05$) 변수는 분석에서 제외하였다. 이후, 다중로지스틱 회귀분석을 통해 예약부도 이후 고객 행동을 예측하는 데 통계적으로 유의미한 독립변수를 도출하였다. 특히, 유의확률(p-value)이 높은 변수를 하나씩 제거하는 후진 소거법(Backward Elimination)을 적용하였으며, 모든 비유의 변수들이 제거될 때까지 이 과정을 반복하였다. 그 결과, 예약부도와 관련하여 통계적으로 유의하고 예측력이 높은 14개의 독립변수가 최종적으로 선정되었다. 본 연구에서는 2020년 ~ 2021년 데이터 707,167건을 학습 데이터로 하였으며 2022년 데이터 303,741건을 테스트 데이터로 나누어 모형의 일반화 가능성과 예측 성능을 평가하였으며, Random Sampling 기법을 활용하여 모형의 신뢰성을 강화하였다(Mamandipoor et

al., 2022). 훈련 데이터에 과도하게 적합되는 과적합(overfitting) 문제를 방지하고자 5겹 교차검증(K-Fold Cross Validation)을 수행하였다(Varma and Simon, 2006).

3.3 예측모형

머신러닝 알고리즘을 활용하여 예측 모형을 구축하였다. 머신러닝은 인공지능(AI)의 한 분야로, 데이터로부터 패턴을 학습하여 자동으로 의사결정을 수행하고 예측 성능을 개선하는 기술이다. 예측 모델링에는 분류(classification)와 회귀(regression) 기법이 있으며, 회귀는 연속형 숫자 값을 예측하는 데 사용되고, 분류는 다수의 클래스 중에서 하나를 예측할 때 사용된다. 본 연구는 의료기관 예약부도 이후의 방문과 미방문 고객 행동을 예측하는 분류기법으로 분석을 수행하였다(Sarker, 2021).

본 연구에서는 확률 기반 모형, 선형 모형, 트리 기반 모형, 그리고 앙상블 모형을 비교 및 분석하였다. 확률 기반 모형 중 Multiple Logistic Regression은 이진 분류 문제 해결에 적합한 선형 모형으로, 입력 특징의 선형 조합으로 계산된 로짓(logit)을 시그모이드(sigmoid) 함수에 적용해 확률로 변환하고 이를 기반으로 분류를 수행한다(Yang et al., 2014).

트리 기반 모형인 Decision Trees는 트리 구조를 통해 데이터를 분할하며 각 노드에서 조건 분기를 통해 최종 리프 노드에서 예측값을 산출한다(Bagriacik and Otero, 2024). Random Forest는 다수의 결정 트리를 결합하여 예측 성능을 향상하며, 개별 트리의 예측 결과를 투표 또는 평균 방식으로 통합한다(Breiman, 2001). 이러한 트리 기반 모형은 변수 간의 비선형 관계를 포착하는 데 강점을 가지며, 본 연구와 같이 복잡한 예약 행동 패턴을 예측하는 데 효

과적이다.

앙상블 학습(Ensemble learning)은 복수의 예측 모델을 결합하여 단일 모델보다 더 강력한 예측 성능을 구현하는 기법으로, 특히 데이터가 불균형하거나 노이즈가 존재하는 경우에 유리하다. 본 연구에서는 성능과 효율성 측면에서 우수하다고 평가받는 부스팅 기반 앙상블 모형인 XGBoost와 LightGBM을 활용하였다. XGBoost는 Gradient Boosting 알고리즘을 기반으로 하며, 정규화 기법과 병렬 학습을 통해 빠르게 학습하고 과적합을 방지한다(Mitchell et al., 2018). LightGBM은 리프 중심 트리 분할(leaf-wise growth)을 사용하여 학습 속도를 개선하고 대용량 데이터 처리에 최적화된 구조를 제공한다(Hajihosseini et al., 2023). 예약부도 후 방문 및 미방문 예측은 독립변수를 포함한 알고리즘 모

형을 학습시키는 방식으로 수행되었으며, 해당 종속 변수들은 이분법적 분류 구조를 기반으로 구성되었다. 각 모형별 패키지 및 하이퍼 파라미터의 값은 <Table 3>과 같이 설정되었다.

3.4 예측 모형 성능 평가

이진 분류 문제의 성능은 혼동 행렬(confusion matrix)을 통해 정량적으로 평가할 수 있으며, 예측 모형의 성능은 정확도(Accuracy), 정밀도(Precision), 재현율(Recall), F1 점수(F1 Score), ROC AUC (Receiver Operating Characteristic Area Under the Curve), PR AUC(Precision-Recall Area Under the Curve), MCC (Matthews Correlation Coefficient)와 같은 지표를 사용하여 분석되었다.

<Table 3> 모델 패키지 및 하이퍼파라미터 설정

Model	Package	Hyperparameters
Decision Trees	sklearn	criterion=gini max_depth=10
Random Forest	sklearn	n_estimators= 50 min_samples_split=5 max_depth=15 min_samples_leaf=4
Multiple Logistic Regression	sklearn	penalty=l2 solver=liblinear C=1.0 max_iter=1000
LightGBM	lightgbm	objective=binary metric=binary_logloss reg_lambda=5.0 max_depth=4
XGBoost	xgboost	objective=binary:logistic eval_metric=logloss reg_lambda=5.0 max_depth=6

정확도는 실제 분류 카테고리를 정확히 예측한 비율을 의미하며, 식 (1)에서, TP는 실제 양성 클래스(Positive)를 양성으로 예측한 경우이며, TN은 실제 음성 클래스(Negative)를 음성으로 예측한 경우를 뜻한다. 반대로, FP는 실제로는 음성이지만 양성으로 잘못 예측한 경우이고, FN은 양성인데 음성으로 예측한 경우를 말한다.

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

모형이 예측한 값 중 정확히 예측된 값의 비율은 정밀도로 정의된다. 식 (2)에서 양성으로 예측한 사례들 중에서 실제로도 양성인 경우의 비율을 나타내며, 잘못된 양성 예측(False Positive)을 얼마나 효과적으로 억제했는지를 평가하는 데 유용하다.

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

재현율은 실제 값 중 모형이 올바르게 예측한 비율을 나타내며, 식 (3)에서 양성 클래스(Positive) 중에서 모형이 이를 정확하게 양성으로 식별한 비율을 의미한다. 재현율 값이 높다는 것은 실제로 존재하는 양성 케이스들을 모형이 잘 감지하고 있다는 것을 뜻한다.

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

F1 Score는 정밀도와 재현율 간의 균형을 수치로 나타낸 지표로, 이 둘의 조화 평균으로 계산된다. 식 (4)에서 두 지표 간의 균형을 고려하여, 한쪽 값이 지나치게 높거나 낮을 때 발생할 수 있는 왜곡을 줄

여준다. F1 Score 값이 1에 가까울수록 정밀도와 재현율이 모두 높은 상태를 의미하며, 0에 가까울수록 두 성능 지표 중 하나 이상이 매우 낮다는 것을 나타낸다. 따라서 F1 Score는 전체적인 분류 성능을 한 눈에 파악할 수 있는 중요한 지표로 자주 사용된다.

$$F1\ score = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (4)$$

클래스 불균형을 고려한 이진 분류 성능 평가 지표로 매튜 상관관계수(MCC)를 활용하였다. MCC는 예측값과 실제 값 간의 상관관계를 기반으로 하며, 정답과 오답(TP, TN, FP, FN)의 비율을 종합적으로 고려하는 지표이다. 식 (5)에서 클래스 간 불균형이 클 때에도 신뢰성 있는 평가가 가능하다는 점에서 정확도(Accuracy)나 F1 점수보다 우수한 특성을 가진다. MCC의 값은 -1에서 +1 사이에 분포하며, 1에 가까울수록 예측력이 높고, 0은 무작위 예측 수준, -1은 완전히 반대되는 예측 결과를 의미한다. 따라서 MCC는 단순히 양성과 음성 비율에 치우치지 않고 모델 전반의 균형 잡힌 성능을 정량적으로 평가하는 데 유용하다(Chicco and Jurman, 2020).

$$MCC = \frac{TP \times TN - FP \times FN}{\sqrt{(TP + FP)(TP + FN)(TN + FP)(TN + FN)}} \quad (5)$$

분류 모델의 성능 측정을 위해 ROC AUC 지표를 활용하였다. AUC는 수신자 조작 특성 곡선 하의 면적을 나타내며, 모델이 임의로 선택된 양성 사례와 음성 사례를 얼마나 잘 구분하는지를 수치적으로 표현한다.

PR AUC는 양성 클래스에 대한 예측의 신뢰도와 포착률에 중점을 둔다. 특히 데이터 내에서 양성 샘플

플이 극히 적은 경우, PR AUC는 ROC AUC보다 더 실질적인 성능 평가 지표로 간주된다. PR AUC는 이러한 곡선 아래 면적을 수치화한 값으로, 1에 가까울수록 모델이 양성 클래스에 대해 높은 정밀도와 재현율을 동시에 달성하고 있음을 의미한다.

3.5 모형 해석을 위한 XAI 기법 활용

예약부도 이후 방문 및 미방문 요인을 분석하기 위해, XAI 기법을 사용하였다. 복잡한 기계학습 모델의 예측 결과를 해석 가능하게 만들기 위해 특성(feature)이 예측 결과에 미치는 영향을 정량적으로 분석할 수 있는 SHAP 값을 산출하여 예측 결과에 대한 영향력을 정량적으로 평가하였다. SHAP는 게임 이론의 개념을 기반으로 개발된 기계 학습 모형의 예측 결과 해석 기법으로, 각 특성이 모형 예측에 기여하는 정도를 정량적으로 평가함으로써 예측 결과에 대한 직관적이고 체계적인 통찰을 제공한다(Lundberg and Lee, 2017).

Shapley 값은 협력 게임에서 각 플레이어의 공헌도를 공정하게 평가하기 위한 방법으로, 기계 학습에서는 각 데이터 특성이 예측 결과에 미치는 영향력을 평가하는 데 사용된다. 각 특성의 Shapley 값은 모형의 예측에 대한 그 특성의 한계 기여도를 나타내며, 모든 특성의 Shapley 값의 합은 모형의 예측과 일치한다. 또한 모형의 전반적인 해석 가능성을 향상하는 데 유용하다. 특성 중요도를 시각화하여 가장 큰 영향을 미치는 변수를 파악할 수 있으며, 특성 간의 상호작용도 평가할 수 있다(Nohara et al., 2022).

LIME(Local Interpretable Model-agnostic Explanations)은 복잡한 기계학습 모형의 예측을 이해하고 해석하기 위해 개발된 기법이다. 이 방법은 모형의 예측에 대한 설명을 제공함으로써 긍정적 요

인과 부정적 요인을 식별할 수 있도록 도와준다. 개별 데이터 포인트 주변에서 데이터를 샘플링하고, 이 샘플들을 사용하여 간단한 모형을 학습한다. 복잡한 원래 모형의 로컬 동작을 근사화하며, 모형의 예측에 기여하는 각 특성의 영향력을 가중치로 나타낸다. LIME은 모형의 예측이 어떠한 특성에 의해 주로 영향을 받는지 명확하게 이해할 수 있으며, 이는 모형의 투명성과 신뢰성을 증진시키는 데 기여한다(Huang et al., 2023).

IV. 결과 분석

4.1 예측성능 비교

본 연구는 총 5개의 기계학습 모델에 대해 예측성능을 비교 분석하였다. <Table 4>는 각 모델별로 정밀도(Precision), 재현율(Recall), F1 Score, 정확도(Accuracy), ROC AUC, PR AUC, 매튜 상관관계수(MCC) 등의 평가 지표를 통해 성능을 종합적으로 비교한 결과를 나타낸다. 이때 Class 항목의 Visit과 No Visit은 각각 예약부도 후 의료기관 방문 및 미방문 사례를 지칭한다. 일반적으로 이진 분류 모형의 평가에서는 정확도가 많이 활용되지만, 데이터의 클래스 불균형이 존재하는 경우 단일 정확도만으로는 모형의 성능을 적절히 판단하기 어렵다. 따라서 본 연구에서는 F1 Score, ROC AUC, PR AUC, MCC와 같이 불균형 문제에 더 민감하게 반응하는 지표들을 함께 고려하여 모형을 전반적으로 평가하였다. 특히, 매튜 상관관계수는 참값과 예측값 간의 상관관계를 종합적으로 반영하기 때문에 클래스 간 불균형 상황에서도 균형 잡힌 평가 기준으로 적합하다.

〈Table 4〉 모델 간 성능 분석(Precision, Recall, F1 Score, Accuracy, ROC AUC, PR AUC, MCC)

MODEL	Label	Precision	Recall	F1 Score	Accuracy	ROC AUC	PR AUC	MCC
LightGBM	Visit	0.8249	0.8498	0.8371	0.8394	0.8921	0.8836	0.6791
	No Visit	0.8540	0.8296	0.8416				
Random Forest	Visit	0.8288	0.8432	0.8359	0.8392	0.8914	0.8830	0.6785
	No Visit	0.8494	0.8355	0.8424				
Decision Trees	Visit	0.8214	0.8500	0.8355	0.8374	0.8887	0.8753	0.6752
	No Visit	0.8538	0.8254	0.8393				
XGBoost	Visit	0.8189	0.8532	0.8357	0.8371	0.8919	0.8847	0.6748
	No Visit	0.8556	0.8219	0.8384				
Multiple logistic regression	Visit	0.8030	0.8613	0.8311	0.8300	0.8859	0.8746	0.6620
	No Visit	0.8594	0.8004	0.8288				

〈Table 4〉의 모형별 예측 성능 비교 결과에 따르면, 방문 예측 종속변수의 경우 F1 Score(0.8371), ROC AUC(0.8921), MCC(0.6791) 지표에서 LightGBM이 가장 우수한 성능을 보였다. 미방문 예측 종속변수에 대해서는 F1 Score(0.8416), MCC(0.6791) 지표에서 Random Forest가 주요 지표에서 뛰어난 결과를 나타냈다. 일반적으로 머신러닝 분야에서는 F1 Score가 0.8 이상일 경우, 정밀도와 재현율 간 균형이 잘 이루어진 우수한 예측 성능으로 간주된다(Asimopoulos et al., 2024). F1 score 기준에서는 LightGBM(0.8371), Random Forest(0.8359), XGBoost(0.8357) 순으로 우수한 성능을 보였다. ROC AUC는 이진 분류에서 모델이 긍정 클래스와 부정 클래스를 얼마나 효과적으로 구분하는지를 나타내는 평가 지표다. ROC AUC 기준으로는 LightGBM(0.8921), XGBoost(0.8919), Random Forest(0.8914) 순으로 우수한 성능을 보였다. MCC는 불균형 데이터에서도 신뢰도 높은 성능 평가가 가능한 지표다(Chicco and Jurman, 2023). 일반적으로 0.6 이상일 경우 신뢰도를 갖는 것으로 간주된다. 이에 따라 MCC 값이 0.6791인 LightGBM은

데이터 불균형 상황에서도 견고한 예측 성능을 보이는 모형으로 해석될 수 있다. 그다음으로 Random Forest는 MCC 0.6785로 우수한 성능을 보였으며, Decision Trees가 0.6752로 안정적인 분류 능력을 확인할 수 있다.

4.2 예측 영향 요인 분석

건강검진 예약부도 이후 고객의 방문 여부를 예측하는 데 영향을 미치는 요인을 분석하는 것이다. 이러한 분석을 통해 의료기관은 고객의 행동 특성을 보다 명확히 이해하고, 이를 기반으로 예약 관리 및 자원 배분에 효과적인 전략을 수립할 수 있다. 본 연구에서는 방문 예측에 영향을 미치는 주요 요인을 파악하기 위해 SHAP의 특성 중요도 기법과 LIME 기법을 활용하였다.

4.2.1 방문(Visit) 종속변수


LightGBM 모형은 Gradient Boosting Decision Tree 계열의 알고리즘으로, 특히 범주형 변수 처리에

강점을 가지며, 데이터 전처리를 최소화하면서도 높은 예측 성능과 과적합 방지 능력을 보인다. 이러한 특성으로 의료 예약 데이터처럼 범주형 변수가 많은 구조적 데이터 셋에 효과적으로 적용될 수 있다(Yan et al., 2021).


〈Figure 1〉에서 개별 요인들의 특징들이 특정 모형 예측에 어떻게 기여하는지 보여주고 가장 기여도가 높은 요인들 순서대로 표시한다. 과거 재예약 여부(0.31973)가 가장 중요한 변수로 나타났다. 해당 변수는 예측값에 가장 큰 영향을 미치며, 재예약 이력이 있는 고객일수록 방문할 가능성이 크다는 점을 확인할 수 있다. 이는 과거 재예약 경험이 향후 행동에 중요한 영향을 미친다는 것을 의미한다. 다음으로 신규 고객 여부(0.02243)가 두 번째로 중요한 변수로 나타났다. 이는 해당 변수가 방문 여부 예측에 있어 민감하게 작용하며, 해당 의료기관의 이용 경험 유무가 예측 정확도에 영향을 미치는 주요 요인임을 나타

낸다. 세 번째로 중요한 변수는 과거 예약부도 횟수(0.01373)였다. 이는 고객의 이전 미방문 이력이 향후 방문 여부 예측에 영향을 미치는 요인임을 의미한다. 네 번째로 중요한 변수는 과거 예약 횟수(0.01242)였다. 고객의 의료기관 예약 경험이 방문 여부를 예측하는 데 있어 유의미한 정보로 작용함을 의미하며, 반복적인 예약 이력이 있는 고객일수록 예측 결과에 일정한 영향을 미친다는 점을 나타낸다. 이외에 예약 채널(0.00714), 나이(0.00594), 예약월(0.00409) 순으로 예측에 중요한 요소로 작용한다.

〈Figure 2〉에서 검진 방문에 긍정적인 기여는 오른쪽에 표시되고 부정적인 기여를 하는 요인은 왼쪽에 표시된다. 긴 막대는 해당 기여에서 중요도가 더 높다는 것을 의미한다. 방문 가능성을 높이는 주요 요인으로 예약 채널(0.0500), 과거 예약 횟수(0.0250), 나이(0.0155), 예약월(0.0146) 등이 확인되었다. 이들 변수는 값이 높을수록 방문 예측값을



〈Figure 1〉 특성 중요도 그래프(LightGBM Model)



〈Figure 2〉 LIME 해석 결과(LightGBM Model)

증가시키는 방향으로 작용하였으며, 특히 예약 채널과 과거 예약 경험은 고객의 의료기관 이용에 있어 긍정적인 행동 패턴으로 해석할 수 있다.

신규 고객(0.0967), 예약 시간(0.0195), 전통 휴일 전후 여부(0.0149) 등은 방문 가능성을 낮추는 부정적인 요인으로 작용하였다. 이들 변수는 예측값을 감소시키는 방향으로 기여하며, 특히 신규 고객 변수는 방문 경험이 부족하여 미방문 가능성을 높이는 요인으로 작용하는 것으로 해석된다.

4.2.2 미방문(No Visit) 종속변수

의료 기관의 예약부도 고객에 대한 방문 여부 예측 문제는 다양한 변수 간 상호작용과 비선형성이 존재하는 복잡한 데이터 구조를 가지기 때문에, 변수 간 관계를 자동으로 포착하고 비선형 결정 경계를 학습

할 수 있는 Random Forest의 특성이 잘 부합된다. 또한 예측값에 상대적으로 강하며, 다수의 결정 트리를 활용한 앙상블 학습 기반 모형으로, 과적합을 줄이고 높은 예측 정확도를 확보할 수 있다(Tang and Ishwaran, 2017).

〈Figure 3〉에서 재예약 여부(0.32470)가 가장 중요한 변수로 나타났으며, 이는 해당 변수가 고객의 미방문 가능성을 예측하는 데 있어 가장 강력한 신호로 작용한다는 점을 의미한다. 재예약 이력이 없는 고객일수록 실제 미방문할 가능성이 크다는 점에서, 과거 재예약 이행 여부가 추후 행동 예측에 중요한 영향을 미친다는 것을 시사한다.

두 번째로 중요한 변수는 신규 고객 여부(0.00990)로 나타났으며, 이는 신규 고객의 경우 방문 확률이 낮아질 가능성이 있음을 시사한다. 신규 고객은 의료

기관 시스템에 익숙하지 않거나, 예약 이후 방문까지 이어질 동기가 부족할 수 있어, 변수 중요도에 반영된 것으로 해석된다.


그 외에도 나이(0.00103), 과거 예약부도 횟수(0.00100), 리드타임(0.00054), 예약월(0.00048) 등도 상대적으로 낮은 수준이지만 예측에 일정 수준의 기여를 하고 있는 변수로 나타났다. 특히 과거 예약부도 횟수는 고객의 이전 행태를 기반으로 한 반복적 행동 예측을 가능하게 하며, 일정한 패턴을 보이는 고객군을 식별하는 데 유용한 정보로 해석할 수 있다.

반면, 예약 요일, 공휴일 등은 중요도 값이 거의 0에 수렴하며, 본 예측 모형에서는 상대적으로 기여도가 낮은 변수로 평가된다. 이는 해당 변수들이 고객의 방문 여부 결정에 미치는 영향이 제한적임을 의미한다.

이러한 분석 결과는 의료기관 예약부도 예방을 위


한 선제적 전략 수립에 활용될 수 있다. 특히, 재예약 이력이 없거나 신규 고객인 경우에는 예약 확정 시점에 알림 메시지를 강화하거나 일정 재확인 절차를 추가하는 등의 맞춤형 대응 방안을 설계함으로써 부도율을 낮추는 데 기여할 수 있다(Atta et al., 2024). 또한, 인센티브 제공 또는 페널티 제도(Ma et al., 2019)를 통해 방문 유도를 강화하는 전략 역시 효과적인 방안으로 고려될 수 있다.

〈Figure 4〉에서 긍정적인 기여는 왼쪽에 표시되고 부정적인 기여를 하는 요인은 오른쪽에 표시된다. 모형은 예약부도 이후 미방문할 확률이 0.70, 방문할 확률이 0.30으로 예측했으며, 미방문 가능성을 증가시키는 요인으로 신규 고객(0.5829), 재예약 여부(0.2423), 예약 채널(0.0695), 리드 타임(0.0244) 변수로 나타났다. 방문 가능성을 높이는 요인으로 나이(0.0598), 과거 예약 횟수(0.0457),



〈Figure 3〉 특성 중요도 그래프 (Random Forest Model)

Prediction probabilities



〈Figure 4〉 LIME 해석 결과(Random Forest Model)

예약월(0.0437), 정기휴일(0.0120) 변수로 나타났다.

신규 고객, 재예약 여부, 예약 채널 변수는 미방문 확률을 증가시키는 주요 요인으로 나타났다. 의료기관의 예약 이행을 개선을 위한 우선적 관리 대상으로 분류될 수 있다. 반면, 나이, 과거 예약 횟수, 예약월은 예측 결과에서 미방문 가능성을 낮추므로, 고객의 행동 안정성 또는 신뢰 기반의 반복 이용 가능성을 나타내며, 해당 고객군은 안정적인 예약 이행을 기대할 수 있는 집단으로 고려할 수 있다(Ferro et al., 2020). 〈Figure 2〉와 〈Figure 4〉의 Visit 예측 확률 0.55와 0.70 사이의 차이는 각각 특정 사례에 대한 모델의 개별 예측 확률이기 때문에 전체 데이터에서 산출한 방문율(48.6%)과 직접 비교할 수 없다. 로컬 예측값은 사례별 변수 조합과 모델 구조에 따라 변동되므로 모집단 수준의 기술 통계 비율과 1:1로 대응되지 않는다.

V. 결론

의료기관에서는 고객 예약부도는 의료 서비스 자원 낭비로 이어질 수 있으므로, 이를 최소화하기 위해 선제적 대처와 지속적인 노력이 요구된다. 예약부도는 여러 가지 원인에 의해 발생하며, 이는 의료기관 운영 비용 증가와 예약 시스템 과부하를 초래할 뿐만 아니라, 의료 혜택이 필요한 고객들이 적시에 검진이나 치료를 받을 기회를 잃게 되는 결과를 초래한다. 이로 인해 의료기관과 고객 모두에게 손실과 잠재적인 피해가 발생할 수 있다(Bech, 2005). 예약에 실패한 고객이 다시 예약을 시도할 경우, 해당 예약이 성공적으로 이행될지 여부에 대한 불확실성은 의료기관에 운영적 부담을 가중시킬 수 있다(Hu et al., 2020).

종속변수별 예측모형의 성능 비교 결과를 요약하면, 예약부도 후 방문 예측에서는 F1 Score, MCC 값의 LightGBM 모형이 0.8371, 0.6791로 가장 우수했으며, 예약부도 후 미방문 예측에서는 F1 Score, MCC 값의 Random Forest가 0.8424, 0.6785로 우수한 성능을 보였다.

모델의 예측 내용을 이해하기 위해 SHAP 기법의 상대적 변수 중요도를 해석한 〈Figure 1〉을 보면 방문 종속변수에서는 재예약 여부 변수 중요도가 가장 높았으며, 다음으로 신규자 변수가 높았다. 〈Figure 3〉을 보면 미방문 종속변수에서도 과거 예약부도 횟수 변수 중요도가 가장 높았으며, 다음으로 신규자 변수가 높았다.

5.1 학술적 기여점

본 연구는 기존의 예약부도에 초점을 맞춘 연구들과 차별화되어, 예약부도 이후 고객의 행동 패턴을 보다 정밀하게 이해하기 위해 예약부도 후 방문과 미방문이라는 두 가지 종속 변수를 중심으로 분석을 시도하였다. 이와 같은 접근을 통해 단순히 예약을 하지 않은 현상 자체에 머무르지 않고, 예약부도 이후 고객이 실제로 의료기관을 방문했는지, 혹은 끝내 방문하지 않았는지를 기준으로 고객 행동을 보다 구체적으로 규명하고자 하였다.

분석 결과, 두 가지 종속 변수에 대해 예측 모형을 구성하고 변수 중요도를 도출한 결과, 재예약 여부 변수가 가장 핵심적인 영향 요인으로 부각되었다. 이는 과거 예약부도 이후 고객이 다시 예약을 시도한 여부가, 향후 실제 방문으로 이어질 가능성에 결정적인 영향을 미친다는 사실을 입증한다. 특히, 예약부도 후 방문과 미방문 예측 모두에서 명절보다는 일반적인 휴일 변수가 더 높은 중요도를 보였으며, 이는 사

회문화적 요인 중에서도 일반 휴일이 고객의 행동에 보다 실질적인 영향을 미친다는 점을 나타낸다.

또한, 방문 행동과 관련하여 과거 예약 횟수가 중요한 변수로 평가되었으며, 이는 고객이 과거에 여러 차례 예약을 했던 경험이 있을수록 실제 방문으로 이어질 가능성이 높다는 것을 의미한다. 반면, 미방문 행동을 예측하는 데 있어서는 과거 예약부도 횟수가 더 중요한 변수로 작용하여, 반복적으로 예약부도를 낸 고객일수록 향후 방문 가능성이 낮다는 경향성을 보여주었다. 또한 예약 채널은 방문 예측에서 보다 큰 중요도를 보였으며, 고객이 어떤 채널을 통해 예약 및 재예약을 진행했는지가 방문 여부에 유의미한 영향을 미치는 것으로 나타났다. 반면 미방문 예측에서는 리드타임과 나이 변수가 더 큰 영향을 주었으며, 이는 예약 시점부터 실제 예약일까지의 기간(리드타임)과 고객의 연령대가 의료기관 방문 여부에 중요한 역할을 한다는 것을 확인할 수 있다.

이러한 결과는 SHAP 및 LIME 기반의 시각화를 통해 더욱 직관적으로 해석할 수 있었으며, 이는 의료기관이 예약 정책을 수립함에 있어 어떤 요인들을 우선적으로 고려해야 하는지를 명확하게 파악할 수 있도록 도와준다. 이는 향후 AI 기반의 설명 가능한 의사결정지원시스템(Explainable Decision Support System, EDSS)을 의료 행정 시스템에 통합하는데 있어 실질적인 기반이 될 수 있다(Kostopoulos et al., 2024).

더불어, LightGBM 모형을 통해 고객 방문에 긍정적인 영향을 미치는 요인으로 과거 예약 횟수, 예약부도 횟수, 고객의 나이, 성별, 예약월, 예약요일 등이 확인되었다. 이는 전반적인 고객의 특성과 예약 습관이 의료기관 방문과 직결된다는 점을 의미한다. 반면, 미방문 행동은 Random Forest 모형을 통해 신규 고객 여부, 재예약 여부, 예약 채널, 리드

타임, 예약 요일, 전통적인 휴일 등의 변수 값이 높을수록 미방문 가능성이 증가하는 경향을 보였다. 즉, 예약부도를 낸 이후에도 재예약을 하지 않고 리드타임이 긴 경우, 또는 예약 날짜가 특정한 요일이나 전통적인 휴일과 겹치는 경우 실제 방문 가능성이 낮아진다는 의미다.

마지막으로 사회문화적 변수의 중요성도 본 연구를 통해 다시금 확인되었다. 전통적인 휴일과 일반적인 휴일을 독립 변수로 포함시킨 분석에서, 일반 휴일 전후의 변수들이 전통적인 명절 변수보다 모든 종속 변수에서 더 높은 중요도를 나타내었다. 이는 실질적인 방문 행동에 영향을 미치는 요인으로서 사회적 맥락을 정밀하게 반영하는 것이 중요함을 시사한다.

5.2 실무적 기여점

예약부도 후 방문 및 미방문 여부의 종속변수별로 LightGBM 모형과 Random Forest 모형을 적용하여 예약부도 후 방문을 유도하는 전략을 제시하고 개인 맞춤형 관리 시스템 구축 가능성을 탐색하였다. 각각의 종속변수에서 공통적으로 중요한 과거 재예약 여부 변수는 고객의 예약부도 후 방문과 미방문 전략에서 중요시되어야 한다. 특히, 방문 고객은 LightGBM 모형을 활용하여 재예약 여부, 과거 예약 횟수에 따라 재예약을 유도하여 방문시키는 전략을 제시한다. 미방문 고객을 위한 Random Forest 모형을 통해 재예약 여부와 신규 고객이 주요 변수로 작용하는 것으로 나타나, 이들을 타깃으로 한 맞춤형 유입 전략이 필요하다. 또한 본 연구는 학습용과 테스트 데이터를 시계열에 따라 구분하여, 모형의 일반화 가능성과 시간적 예측 타당성을 확보했다는 점에서 기존 무작위 분할 기반 연구와 차별성을 가진다. 이러한 분석 결과는 의료기관이 예약부도 이후의 고객 행동을

사전에 예측하여, 부도 가능성이 높은 고객군을 대상으로 이중 확인, 검진 전일 예약확인 전화, 검진 당일 알림 톡과 위치 공유 링크의 실시간 메시지 발송을 통해 예약부도를 줄일 수 있을 것이다. 방문 가능성이 높은 고객군을 대상으로는 모바일 간편 예약 링크 제공, 검진 필요성에 대한 맞춤형 메시지 전달, 자동 예약 제안 등의 전략을 우선 적용함으로써 실제 방문으로 이어질 가능성을 더욱 높일 수 있을 것이다. 이는 검진 참여율 제고와 의료기관 자원 활용 효율성 향상에 기여할 수 있으며, 예약 이행 예측 시스템 구축 및 운영 효율성 향상에 실질적으로 도움이 될 수 있을 것으로 기대된다.

5.3 한계점 및 향후 연구방향

이 연구의 한계는 다음과 같이 정리된다. 첫째, 과거 의료기관에서 제공된 서비스에 대한 만족도나 의료기관 방문 대기 시간과 같은 고객 경험과 관련된 변수를 고려하지 못했다. 둘째, 고객의 진료 이력, 질병명, 건강 상태와 같은 개인 의료 정보는 분석에 반영할 수 없었다. 셋째, 연구는 한국건강관리협회의 검진 방문 데이터를 기반으로만 진행되었기 때문에, 다른 의료기관에서 제공되는 다양한 의료 서비스에 결과를 일반화하는 데 한계가 있다. 특히, 연구 대상 기관의 특성과 환경적 요인을 충분히 고려하지 못했기 때문에 동일한 결과를 다른 기관에 일반화하기 어려운 한계가 존재한다. 따라서 후속 연구에서는 다양한 기관의 데이터를 활용하여 모형을 보완하고, 각 기관별 특성이 반영된 맞춤형 예측 모형을 개발하는 것이 필요하다. 따라서, 이러한 과정을 거치면 연구 결과의 적용 범위를 넓히고, 보다 신뢰성 있는 예측 모형을 마련할 수 있을 것으로 기대된다.

향후 연구에서는 검진을 위해 사용하는 교통수단,

거주지와 검진 시설 간의 거리, 과거 검진 대기 시간, 과거 검진 비용 등 고객 행동에 영향을 미칠 수 있는 변수를 추가로 고려할 필요가 있다. 이러한 노력들을 통해, 예약부도 후 고객 행동을 보다 정확히 예측하고, 예약부도 고객을 효과적으로 관리하기 위한 전략을 마련할 수 있을 것으로 예상된다.

참고문헌

- 권성탁, 이예슬, 한은아, 김태현 (2015). "일개 대학병원 외래환자의 예약부도(No - Show) 관련요인," **대한보건연구(구 대한보건협회학술지)**, 제41권 2호, pp.29-46.
- (Kwon, Lee, Y., Han, E., and Kim, T. (2015). "Factors Associated with No-show in an Academic Medical Center," *Korean Public Health Res*, 41(2), pp.29-46.)
- 이승필, 박은일, 류두진 (2025). "설명가능한 기계학습을 이용한 베스트셀러 예측과 영향요인 분석," **경영학연구**, 제54권 1호, pp.81-108.
- (Lee S., Park E., and Ryu D. (2025). "Predicting Bestsellers and Key Drivers using Explainable Machine Learning," *Korean Management Review*, 54(1), pp.81-108.)
- 임세환, 민순홍, 최경환 (2024). "기계학습 방법을 활용한 가격 예측 모형 개발: 공군 항공유 구매 사례를 기반으로," **경영학연구**, 제53권 4호, pp.997-1025.
- (Lim S., Min S., Choi K. (2024). "Developing a Machine Learning-Based Model for Price Forecasting: A Case Study on ROKAF Jet Fuel Procurement," *Korean Management Review*, 53(4), pp.997-1025.)
- 임지현, 이상규, 김태현, 김지만 (2017). "병원 예약부도 (No-show) 감소를 위한 예약관리 방안," **한국병**
- 원경영학회지**, 제22권 호), pp.50-60.
- (Lim, J., Lee, S., Kim, T., and Kim, J. (2017). "Reducing Appointment No-Shows in Hospitals," *Korea Journal of Hospital Management*, 22(4), pp.50-60.)
- 조규철, 정다운 (2023). "노쇼 고객 관리 식당 예약 시스템," **한국컴퓨터정보학회 학술발표논문집**, 제31권 1호, pp.243-246.
- (Cho, K., and Jung, D. (2023). "No-show Prevention Restaurant Reservation System," *The Korea Soc. of Comput. and Inf.*, 31(1), pp.243-246.)
- Adadi, A., and Berrada, M. (2018). "Peeking Inside the Black-Box: A Survey on Explainable Artificial Intelligence (XAI)," *IEEE Access*, 6, pp.52138-52160.
- Ahmadi, E., Garcia-Arce, A., Masel, D., Reich, E., Puckey, J., and Maff, R. (2019). "A metaheuristic-based stacking model for predicting the risk of patient no-show and late cancellation for neurology appointments," *IJSE Transactions on Healthcare Systems Engineering*, 9(3), pp.272-291.
- AlMuhaideb, S., Alsawilem, O., Alsubaie, N., Ferwana, I., and Alnajem, A. (2019). "Prediction of hospital no-show appointments through artificial intelligence algorithms," *Annu. of Saudi Medicine*, 39(6), pp.373-381.
- Amalina, N. N., Ofori-Amanfo, K. B., and An, H. (2025). A Multi-Head Attention Soft Random Forest for Interpretable Patient No-Show Prediction.
- Andrade, C. C., Lima, M. L., Pereira, C. R., Fornara, F., and Bonaiuto, M. (2013). "Inpatients' and outpatients' satisfaction: The mediating role of perceived quality of physical and social environment," *Health & Place*, 21, pp.122-132.

- Asimopoulos, D., Siniosoglou, I., Argyriou, V., Karamitsou, T., Fountoukidis, E., Goudos, S. K., Moscholios, I. D., Psannis, K. E., and Sarigiannidis, P. (2024). "Benchmarking advanced text anonymisation methods: A comparative study on novel and traditional approaches," 2024 13th International Conference on Modern Circuits and Systems Technologies (MOCASST),
- Atta, S., Brown, R. B., Wasser, L. M., Mayer, N., Cassidy, J., Liu, P. J., and Williams, A. M. (2024). "Effect of a Patient Portal Reminder Message After No-Show on Appointment Reattendance in Ophthalmology: A Randomized Clinical Trial," *American Journal of Ophthalmology*, 263, pp.93-98.
- Bagriacik, M., and Otero, F. E. B. (2024). "Multiple fairness criteria in decision tree learning," *Applied Soft Computing*, 167, pp.112313.
- Bech, M. (2005). "The economics of non-attendance and the expected effect of charging a fine on non-attendees," *Health Policy (Amsterdam)*, 74(2), pp.181-191.
- Berg, B. P., Murr, M., Chermak, D., Woodall, J., Pignone, M., Sandler, R. S., and Denton, B. T. (2013). "Estimating the Cost of No-Shows and Evaluating the Effects of Mitigation Strategies," *Medical Decision Making*, 33(8), pp.976-985.
- Berry, L. L., Seiders, K., and Grewal, D. (2002). "Understanding Service Convenience," *Journal of Marketing*, 66(3), pp.1-17.
- Bertakis, K. D., Azari, R., Helms, L. J., Callahan, E. J., and Robbins, J. A. (2000). "Gender differences in the utilization of health care services," *The Journal of Family Practice*, 49(2), pp.147-152.
- Breiman, L. (2001). "Random forests," *Machine Learning*, 45(1), pp.5-32.
- Casado, A. B., and Ruz, F. J. (2002). "The consumer's reaction to delays in service," *International Journal of Service Industry Management*, 13(2), pp.118-140.
- Chicco, D., and Jurman, G. (2020). "The advantages of the Matthews correlation coefficient (MCC) over F1 score and accuracy in binary classification evaluation," *BMC Genomics*, 21(1), pp.6-6.
- Chicco, D., and Jurman, G. (2023). "The Matthews correlation coefficient (MCC) should replace the ROC AUC as the standard metric for assessing binary classification," *BioData Mining*, 16(1), pp.4-23.
- Daggy, J., Lawley, M., Willis, D., Thayer, D., Suelzer, C., DeLaurentis, P.-C., Turkcan, A., Chakraborty, S., and Sands, L. (2010). "Using no-show modeling to improve clinic performance," *Health Informatics Journal*, 16(4), 246-259.
- Dashtban, M., and Li, W. (2022). "Predicting non-attendance in hospital outpatient appointments using deep learning approach," *Health Syst*, 11(3), pp.189-210.
- Deina, C., Fogliatto, F. S., da Silveira, G. J. C., and Anzanello, M. J. (2024). "Decision analysis framework for predicting no-shows to appointments using machine learning algorithms," *BMC Health Services Research*, 24(1), pp. 37-17.
- Djelassi, S., Diallo, M. F., and Zielke, S. (2018). "How self-service technology experience evaluation affects waiting time and customer satisfaction? A moderated mediation model," *Decision Support Systems*, 111, pp.38-47.

- Doshi-Velez, F., and Kim, B. (2017). "Towards a rigorous science of interpretable machine learning," *arXiv preprint arXiv:1702.08608*.
- Drewek, R., Mirea, L., and Adelson, P. D. (2017). "Lead Time to Appointment and No-Show Rates for New and Follow-up Patients in an Ambulatory Clinic," *The Health Care Manager*, 36(1), pp.4-9.
- Elkhider, H., Sharma, R., Sheng, S., Thostenson, J., Kapoor, N., Veerapaneni, P., Siddamreddy, S., Ibrahim, F., Yadala, S., Onteddu, S., and Nalleballe, K. (2022). "Predictors of No-Show in Neurology Clinics," *Healthcare (Basel)*, 10(4), p.599.
- Fan, G., Deng, Z., and Liu, L. C. (2023). "Understanding the antecedents of patients' missed appointments: The perspective of attribution theory," *Data Science and Management*, 6(4), pp.247-255.
- Ferro, D. B., Brailsford, S., Bravo, C., and Smith, H. (2020). "Improving healthcare access management by predicting patient no-show behaviour," *Decision Support Systems*, 138, p.113398.
- Guzek, L., Fadel, W., and Golomb, M. (2015). "A Pilot Study of Reasons and Risk Factors for "No-Shows" in a Pediatric Neurology Clinic," *J. of Child Neurology*, 30(10), pp.1295-1299.
- Hajihosseini, M., Maghsoudi, A., and Ghezelbash, R. (2023). "A Novel Scheme for Mapping of MVT-Type Pb - Zn Prospectivity: LightGBM, a Highly Efficient Gradient Boosting Decision Tree Machine Learning Algorithm," *Natural Resources Research (New York, N.Y.)*, 32(6), pp.2417-2438.
- Holzinger, A., Langs, G., Denk, H., Zatloukal, K., and Müller, H. (2019). "Causability and explainability of artificial intelligence in medicine," *Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery*, 9(4), e1312.
- Hu, M., Xu, X., Li, X., and Che, T. (2020). "Managing patients' no-show behaviour to improve the sustainability of hospital appointment systems: Exploring the conscious and unconscious determinants of no-show behaviour," *Journal of Cleaner Production*, 269, p.122318.
- Huang, and Hanauer (2014). "Patient No-Show Predictive Model Development using Multiple Data Sources for an Effective Overbooking Approach," *Applied Clinical Informatics*, 5(3), pp.836-860.
- Huang, Q., Yamada, M., Tian, Y., Singh, D., and Chang, Y. (2023). "GraphLIME: Local Interpretable Model Explanations for Graph Neural Networks," *IEEE Transactions on Knowledge and Data Engineering*, 35(7), pp.6968-6972.
- Joseph, J., Senith, S., Kirubaraj, A., and Ramson, S. (2022). "Machine Learning for Prediction of Clinical Appointment No-Shows," *International Journal of Mathematical, Engineering and Management Sciences*, 7(4), pp.558-574.
- Kagedan, D. J., Edge, S. B., and Takabe, K. (2021). "Behind the clock: elucidating factors contributing to longer clinic appointment duration and patient wait time," *BMC Health Services Research*, 21(1), pp.87-89.
- Kammrath, P., Boehringer, D., Jordan, J., Lichtenberg, C., Lambeck, M., Ketterer, M. C., Reinhard, T., and Reich, M. (2025). "Efficient patient care in the digital age: impact of online appointment scheduling in a medical practice and a university hospital on the "no-show"-

- rate," *Frontiers in Digital Health*, 7, p.1567397.
- Kang, G.-D. (2006). "The hierarchical structure of service quality: integration of technical and functional quality," *Managing Service Quality*, 16(1), pp.37-50.
- Kang, K.-G., and Park, C.-Y. (2024). "A Study on the Development of Future Corporate Value Forecasting Classifier Reflecting ESG Information," *Korean Management Review*, 53 (2), pp.345-383.
- Kheirkhah, P., Feng, Q., Travis, L. M., Tavakoli-Tabasi, S., and Sharafkhaneh, A. (2016). "Prevalence, predictors and economic consequences of no-shows," *BMC Health Services Research*, 16(1), pp.13-13.
- Kostopoulos, G., Davrazos, G., and Kotsiantis, S. (2024). "Explainable Artificial Intelligence-Based Decision Support Systems: A Recent Review," *Electronics (Basel)*, 13(14), p.2842.
- Lapuschkin, S., Wäldchen, S., Binder, A., Montavon, G., Samek, W., and Müller, K.-R. (2019). "Unmasking Clever Hans predictors and assessing what machines really learn," *Nature Communications*, 10(1), pp.1096-1096.
- Limayem, M., Hirt, S. G., and Cheung, C. M. K. (2007). "How Habit Limits the Predictive Power of Intention: The Case of Information Systems Continuance," *MIS Quarterly*, 31 (4), pp.705-737.
- Liu, D., Shin, W.-Y., Sprecher, E., Conroy, K., Santiago, O., Wachtel, G., and Santillana, M. (2022). "Machine learning approaches to predicting no-shows in pediatric medical appointment," *NPJ Digital Medicine*, 5(1), pp.50-11.
- Lundberg, S. M., and Lee, S.-I. (2017). "A unified approach to interpreting model predictions," *Advances in Neural Information Processing Systems*, 30.
- Ma, H., Meir, R., Parkes, D. C., and Wu-Yan, E. (2019). "Penalty bidding mechanisms for allocating resources and overcoming present bias," *arXiv preprint arXiv:1906.09713*.
- Mamandipoor, B., Bruno, R. R., Wernly, B., Wolff, G., Fjølner, J., Artigas, A., Pinto, B. B., Schefold, J. C., Kelm, M., Beil, M., Sigal, S., Leaver, S., Dylan, W. D. L., Guidet, B., Flaatten, H., Szczeklik, W., Jung, C., and Osmani, V. (2022). "COVID-19 machine learning model predicts outcomes in older patients from various European countries, between pandemic waves, and in a cohort of Asian, African, and American patients COVID-19 machine learning model predicts outcomes in older patients from various European countries, between pandemic waves, and in a cohort of Asian, African, and American patients," *PLOS Digital Health*, 1(11).
- Mitchell, R., Adinets, A., Rao, T., and Frank, E. (2018). "Xgboost: Scalable gpu accelerated learning," *arXiv preprint arXiv:1806.11248*.
- Nohara, Y., Matsumoto, K., Soejima, H., and Nakashima, N. (2022). "Explanation of machine learning models using shapley additive explanation and application for real data in hospital," *Computer Methods and Programs in Biomedicine*, 214, pp.106584-106584.
- Ratmansky, M., Hai, N., Schlossberg, T., Mimouni-Bloch, A., and Schweiger, A. (2017). "Does pain take holidays? Non-attendance rates at a hospital-based pain clinic are elevated during the Jewish high-holidays," *Israel Journal of Health Policy Research*, 6(1), pp.11-11.

- Samek, W. (2017). "Explainable artificial intelligence: Understanding, visualizing and interpreting deep learning models," *arXiv preprint arXiv:1708.08296*.
- Sarker, I. H. (2021). "Machine learning: Algorithms, real-world applications and research directions," *SN Computer Science*, 2(3), pp.160.
- Shenson, D., Anderson, L., Slonim, A., and Benson, W. (2012). "Vaccinations and preventive screening services for older adults: opportunities and challenges in the USA," *Perspectives in Public Health*, 132(4), pp.165-170.
- Simanjuntak, J. A., and Sakti, S. (2023). "Hotel booking channels: Customer perspectives," *Journal of Industrial Engineering and Education*, 1(1), pp.12-29.
- Srinivas, S., and Ravindran, A. (2018). "Optimizing outpatient appointment system using machine learning algorithms and scheduling rules: A prescriptive analytics framework," *Expert Systems with Applications*, 102, pp.245-261.
- Suk, M. Y., Kim, B., Lee, S. G., You, C. H., and Hyun Kim, T. (2021). "Evaluation of Patient No-Shows in a Tertiary Hospital: Focusing on Modes of Appointment-Making and Type of Appointment," *International Journal of Environmental Research and Public Health*, 18(6), pp.3288-3215.
- Tang, F., and Ishwaran, H. (2017). "Random forest missing data algorithms," *Statistical Analysis and Data Mining*, 10(6), 363-377.
- Varma, S., and Simon, R. (2006). "Bias in error estimation when using cross-validation for model selection," *BMC Bioinformatics*, 7(1), pp.91-91.
- Vimbi, V., Shaffi, N., and Mahmud, M. (2024). "Interpreting artificial intelligence models: a systematic review on the application of LIME and SHAP in Alzheimer's disease detection," *Brain Informatics*, 11(1), p.10.
- Wulandari, R., Doddy, I. P., and Indaryani, L. (2024). "Measuring the impact of healthcare service quality of hospitals on customer satisfaction," *Corporate and Business Strategy Review*, 5(1, special Issue), pp.336-345.
- Yan, J., Xu, Y., Cheng, Q., Jiang, S., Wang, Q., Xiao, Y., Ma, C., Yan, J., and Wang, X. (2021). "LightGBM: accelerated genomically designed crop breeding through ensemble learning," *Genome Biology*, 22(1), pp.271-271.
- Yang, H., Guo, X., and Wu, T. (2015). "Exploring the influence of the online physician service delivery process on patient satisfaction," *Decision Support Systems*, 78, pp.113-121.
- Yang, Y., Zhang, H., Chai, Z., Chen, J., and Zhang, S. (2014). "Multiple Logistic Regression Analysis of Risk Factors Associated with Denture Plaque and Staining in Chinese Removable Denture Wearers over 40 Years Old in Xi'an - a Cross-Sectional Study," *PloS One*, 9(2), e87749-e87749.
- Yiye, V., Ugbomeh, O., Ezenkwu, C. P., Ibeke, E., Sharma, V., and Alkhayyat, A. (2024). Investigating Key Contributors to Hospital Appointment No-Shows Using Explainable AI. 2024 International Conference on Electrical Electronics and Computing Technologies (ICEECT).
- Zhou, S., Pang, S., Zhao, Y., and Shi, Y. (2025). "Sequencing and scheduling appointments with weighted completion time minimization and waiting time tolerance," *Computers & Operations Research*, 176, p.106948.

- 저자 권동기는 경북대학교 경영대학원에서 MBA를 받고, 경북대학교 경영학부 서비스·생산·물류 전공 박사과정에 재학하고 있다. 현재 한국건강관리협회에 재직 중이며, 주요 연구 분야는 머신러닝, 딥러닝, 설명가능한 인공지능(XAI), 자료포락분석(DEA) 등이다.
- 저자 김성수는 경북대학교 경영학부 서비스·생산·물류 전공 교수 및 경북대학교 에너지환경경제연구소장으로 재직 중이다. 미국 펜실베이니아주립대학교에서 산업공학과 경영과학 전공으로 박사를 취득하였다. 박사 취득 이후에는 Loyola University Maryland 경영대학에서 조교수, Bank of America 본사 Global Portfolio Strategies 부서 Vice President로 근무하였다. 주요 연구분야는 AI Transformation(AX), Operations Management and Supply Chain Management, Finance 등이다.