

설명 가능한 인공지능을 활용한 단기 콜옵션 가격 예측 연구

A Study on Short-Term Call Option Price Prediction Using eXplainable Artificial Intelligence

이우식¹

Woosik Lee¹

요약

본 연구는 기계학습 기반 옵션 가격 예측 모형의 성능을 검증하고 설명가능한 인공지능(XAI) 기법을 활용하여 예측 과정의 투명성을 확보하는 것을 목적으로 한다. 미국 Apple사의 콜옵션 데이터를 활용하여 블랙숄즈 모형과 XGBoost 모형의 예측 성능을 비교 분석하였다. 두 모형 모두 기초자산 가격, 행사가격, 만기까지 일수, 시변 무위험이자율, 30일 역사적 변동성을 공통 입력 변수로 사용하였다. 실험 결과, XGBoost 모형이 블랙숄즈 모형보다 우수한 예측 성능을 보였다. MSE 기준으로 약 87.9%의 성능 개선을 달성하였으며, MAE와 RMSE에서도 각각 62.9%, 65.3%의 오차 감소를 실현하였다. 실제 가격과 예측 가격 비교를 통해 XGBoost 모형이 모든 가격 구간에서 일관된 예측 정확도를 보이는 것을 확인하였다. SHAP 분석을 통한 특성 중요도 평가에서는 기초자산 가격과 행사가격이 옵션 가격 예측에 가장 중요한 변수로 식별되었다. 본 연구는 기존 연구와 달리 XAI 기법을 활용하여 기계학습 모형의 예측 과정을 해석 가능하게 만들었다는 점에서 학술적 의의를 갖는다.

핵심어 : 비즈니스 애널리틱스, 금융공학, 금융수학, 금융 AI, 금융 파생 상품

Abstract

This study aims to validate the performance of machine learning-based option pricing prediction model and ensure transparency in the prediction by utilizing explainable artificial intelligence (XAI) technique. I conducted a comparative analysis of the predictive performance between the Black-Scholes and the XGBoost models using call option data from Apple Inc. Both models employed the same input variables including underlying asset price, strike price, days to expiration, time-varying risk-free rate, and 30-day historical volatility, with actual call option prices as the target output variable. The experimental results demonstrate that the XGBoost model significantly outperformed the Black-Scholes model in predictive accuracy. The XGBoost model achieved approximately 87.9% performance improvement based on MSE, with error reductions of 62.9% and 65.3% in MAE and RMSE, respectively. Through actual versus predicted call option price comparisons, I confirmed that the XGBoost model exhibited consistent predictive accuracy across all price ranges. Feature importance analysis using SHAP identified underlying asset price

¹ College of Business Administration, Gyeongsang National University, Jinju, Korea [Professor]
e-mail: woosiklee@gnu.ac.kr

Received(July 27, 2025), Review Result(1st: August 19, 2025), Accepted(October 13, 2025), Published(October 31, 2025)



© 2025 The Authors. Published by NCISS.
This is an open access article licensed under the Creative Commons Attribution-NonCommercial 4.0 International License.
To view a copy of this license, visit <http://creativecommons.org/licenses/by-nc/4.0/>.

and strike price as the most critical variables for option price prediction. This study distinguishes itself from existing research by employing XAI technique to provide transparency in machine learning-based option price prediction.

Keyword : Business Analytics, Financial Engineering, Financial Mathematics, Financial AI, Financial Derivatives

1. 서론

2024년 우리나라 증권거래 시장에서 금융 파생상품시장(Financial Derivative Markets)의 일평균 거래대금은 67조원으로 전년 대비 14.3% 증가하였다 [1]. 이 중 금융 옵션(Financial Options, 이하 옵션) 상품의 거래규모는 약 5,816 억원으로 전체 금융 파생상품 시장에서 차지하는 비중은 상대적으로 작으나, 그 활용도와 응용 가능성은 지속적으로 확대되고 있다.

이처럼 옵션시장의 발전과 더불어, 옵션이 적용되는 영역은 금융업계에만 국한되지 않으며, 항공업계의 약정옵션(Contractual Options)활용과 국내 상장지수펀드(ETF)시장의 월배당 커버드콜(Covered Call), 프로텍트 풋(Protective Put) 기반 상품 출시, 농촌 토지 사용권, 기업가치 그리고 특허자산평가 등 다양한 산업 분야로 확산되고 있다 [2]. 이러한 다양한 분야에서 옵션이 활용됨에 따라 정확한 옵션 가격 평가의 중요성이 더욱 부각되고 있다. 항공업계의 좌석 예약 취소 옵션 가격 책정, ETF의 커버드콜 전략 수익성 평가, 실물자산의 투자 기회 가치 산정 등이 핵심 과제로 대두되고 있다.

하지만 정확한 옵션 가격 평가는 매우 어려운 과제이다. 옵션의 가치는 기초자산 가격의 미래 변화에 의존할 뿐만 아니라, 변동성, 만료까지의 시간, 금리, 배당금과 같은 기본 요소들과 더불어 거래비용 [3], 유동성 문제, 미시구조 효과와 같은 시장 마찰 요소들이 고려되어야 한다 [4].

블랙숄츠(Black-Scholes) 모형은 일정한 변동성과 무배당과 같은 특정 가정 하에서 유럽형 옵션(European Options) 가격을 결정하는 프레임워크를 제공한다 [5]. 그러나 기초자산의 변동성, 무위험 이자율 등이 만기시점까지 동일하다고 가정하는 등 현실을 제대로 반영하지 못하는 한계를 보였다. 이로 인해 배당금, 기초 자산의 점프, 확률 변동성(Stochastic Volatility)과 같은 요소들을 고려한 더 복잡한 모형들이 개발되었다. 더불어 폐쇄형 해법(Closed-Form Solution)이 불가능할 때는 유한차분법(Finite Difference Method) [6], 몬테카를로 시뮬레이션(Monte Carlo Simulation) [7] 그리고 푸리에 변환(Fourier Transform) [8]과 같은 수치해석적 방법들이 이용되고 있다 [4].

최근에는 기존 블랙숄츠 모형의 한계를 극복하기 위해 다양한 기계학습 방법을 활용한 옵션 가격 결정 모형들이 개발되고 있으며, 이들은 기존 모형보다 더 정확한 성과를 보이고 있다. Park 외 2인의 연구 [9]는 KOSPI 200 지수옵션 가격 결정에서 블랙숄츠 모형과 서포트벡터머신(SVM) 모형을 비교한 결과, 기계학습 모형이 특히 높은 시장 변동성 조건에서 더 높은 가격 결정 정확도를 보였다. Madhu 외 2인의 연구 [10]는 옵션 가격 결정에서 SVR의 다양한 커널 함수를 비교 분석한

결과, RBF 커널이 비선형 데이터 패턴 포착을 통해 가장 우수한 예측 성능을 보였다. Ivaşcu의 연구 [11]는 다양한 기계학습 알고리즘(SVM, 의사결정트리, 신경망 등)을 옵션 가격 결정에 적용한 결과, 전통적인 블랙숄즈 모형보다 우수한 정확도를 보이며 복잡한 비선형 관계와 고차원 데이터를 효과적으로 처리함을 보였다.

그러나 대부분의 기존 연구는 블랙숄즈 모형과 기계학습 모형의 성능 비교에만 초점을 맞추고 있으며, 이러한 기계학습 모형들은 우수한 예측력을 보이지만 모형의 해석가능성 부족으로 인해 예측 결과에 대한 신뢰성과 실무 적용성에 제약이 있다는 구조적 한계를 지니고 있다. 설명가능한 인공지능(explainable AI, XAI)을 활용한 옵션 가격 예측에 관한 연구가 전무한 실정이며, 국외 연구에서도 거의 찾아보기 어려운 상황이다.

이에 본 논문에서는 XAI를 활용하여 기계학습 기반(XGBoost) 주식 옵션(Equity Options) 가격 예측 모형을 구축하고, 각 모형 입력 변수가 예측 결과에 미치는 기여도를 정량적으로 규명하고자 한다. 구체적으로, 미국 주식의 단기 콜옵션(Call Options) 가격을 예측하기 위해 블랙숄즈 모형과 XGBoost 모형을 비교 분석하고, SHAP 값을 통해 콜옵션 가격 예측에 영향을 미치는 핵심 요인을 규명함으로써 선행 연구와의 차별점을 확립하고자 하였다.

본 논문은 다음과 같이 4개 장으로 구성된다. 제1장에서는 본 연구의 배경과 필요성을 설명하며, 제2장에서는 블랙숄즈모형, XGBoost모형, 그리고 SHAP에 대한 이론적 배경을 고찰한다. 제3장에서는 연구 설계와 실증 분석 방법을 제시하고, 그 결과를 보고한다. 마지막으로 제4장에서는 주요 결과를 바탕으로 연구의 의의 및 시사점을 논의하며 결론을 제시한다.

2. 이론적 배경

2.1 Black-Scholes

블랙숄즈 모형은 만기에만 행사되는 유럽형 옵션의 가격 결정 모형으로, 기초자산(S)이 다음의 확률과정을 따른다고 가정한다.

$$dS = \mu S dt + \sigma S dz$$

μ 는 기초자산의 기대수익률, σ 는 기초자산의 변동성 그리고 z 는 위너과정(Wiener Process)이다. 추가 가정은 다음과 같다. 기초자산의 거래 단위에 제약이 없어 연속적 거래가 가능하며, 공매도가 허용된다. 무위험이자율은 옵션 만기까지 상수로 유지되고, 차익거래 기회는 배제된다. 거래비용이 없는 완전자본시장환경 하에서 투자자들은 위험중립적 선호를 갖는다고 가정한다. 이러한 가정하에서 블랙숄즈 모형은 다음과 같은 콜옵션과 풋옵션의 가격을 도출한다. c 는 콜옵션 가격, p 는 풋 옵션 가격, X 는 행사가격, r 은 무위험이자율, q 는 배당률, T 는 잔존만기, $N(\cdot)$ 는 표준정규분포

의 누적밀도함수이다 [12].

$$c = SN(d_1) - Xe^{-(r-q)T}N(d_2)$$

$$p = Xe^{-(r-q)T}N(-d_2) - SN(-d_1)$$

$$d_1 = \frac{\ln(S/X) + (r - q + \sigma^2/2)T}{\sigma\sqrt{T}}$$

$$d_2 = \frac{\ln(S/X) + (r - q - \sigma^2/2)T}{\sigma\sqrt{T}}$$

2.2 XGBoost

XGBoost(eXtreme Gradient Boosting) [13]는 앙상블 기반의 기계학습 알고리즘으로 회귀와 분류 과제에 모두 활용 가능하며, 여러 산업 영역에서 탁월한 성능을 보여주고 있다.

XGBoost는 손실 함수의 기울기 방향을 이용해 약한 예측기(의사결정나무)를 단계적으로 구축하고 결합하는 방식으로 동작한다. 모형의 예측함수는 다음과 같이 표현된다 [14].

$$\hat{Y}_i^T = \sum_{k=1}^T f_k(x_i) = \hat{y}_i^{T-1} + f_T(x_i)$$

where

\hat{Y}_i^T : 첫번째부터 T번째 트리까지의 예측값을 합한 최종 결과

$f_k(\cdot)$: k번째 회귀 트리

x_i : 입력 특성벡터

\hat{y}_i^{T-1} : 직전 단계에서의 누적 예측결과

$f_T(x_i)$: 새로 학습된 트리의 예측값

XGBoost는 예측 정확도와 모형 복잡도를 동시에 최적화하는 목표함수를 최소화한다 [15].

$$L(\phi) = \sum_i L(y_i, \hat{y}_i) + \sum_k \Omega(f_k)$$

where

$L(\phi)$: 전체 목표함수

$\sum_i L(y_i, \hat{y}_i)$: 실제값 y_i 와 예측값 \hat{y}_i 의 손실함수

$\Omega(f_k)$: k번째 트리 f_k 에 대한 복잡도 페널티

ϕ : 모형의 모든 매개변수

복잡도 페널티 $\Omega(f_T)$ 는 의사결정나무구조의 복잡성을 조절하여 과적합을 방지함으로써 모형의 일반화 성능을 향상시킨다 [15].

2.3 SHAP

SHapley Additive exPlanations (SHAP) [16]은 게임이론의 샤플리 개념에 근거한 설명가능 인공지능 방법론이다. SHAP는 모든 특성의 조합을 고려하여 모형의 예측결과 $\hat{f}(x)$ 에 대한 각 특성의 영향력을 수치적으로 산출한다.

$$\begin{aligned} & E[f_{S \cup i}(x_{S \cup i})] - E[f_S(x_S)] \\ &= E[f(x_1, x_2, \dots, x_i, \dots, x_{n-1}, x_n)] - E[f(x_1, x_2, \dots, X_i, \dots, x_{n-1}, x_n)] \end{aligned}$$

where

S : 특성들의 부분집합

i : 분석대상 특성의 색인

$f_S(x_S)$: 부분집합 S 의 특성들로만 예측했을 때의 모형 출력값

$f_{S \cup i}(x_{S \cup i})$: 부분집합 S 와 특성 i 를 결합하여 예측했을 때의 모형 출력값

$E[\cdot]$: 기대값

위 공식에서 S 는 전체 특성집합, x 는 각 특성의 실제 관측값 그리고 X 는 해당 특성이 가질 수 있는 모든 값을 의미한다. 개별 특성에 대한 영향력의 총합은 모형의 최종 예측결과 $\hat{f}(x)$ 로 다음 식과 같이 나타낼 수 있다 [15].

$$\hat{f}(x) = \phi_0 + \sum_{i=1}^n \phi_i$$

where

$\hat{f}(x)$: 모형의 예측결과

ϕ_0 : 베이스라인 값

ϕ_i : 특성 i 의 SHAP값

n : 총 특성의 수

위 식에서 예측결과 $\hat{f}(x)$ 는 각 특성의 영향력 ϕ_i 와 모든 영향력 계산의 기준이 되는 베이스라인 값 ϕ_0 의 합으로 구성된다. 이와 같은 접근법을 통해 SHAP은 복잡한 모형의 예측 과정을 개별 특성의 영향력으로 분해하여 모형 입력 변수가 예측 결과에 미치는 기여도를 정량적으로 규명한다

[15].

3. 실증분석

3.1 자료의 구성

본 연구에 사용된 데이터셋은 Kaggle에서 제공하는 미국 Apple사의 일별 옵션 가격 및 계약 정보를 포함하고 있다.

분석에 적합한 데이터 품질을 보장하기 위해 다음과 같은 전처리를 수행하였다. 먼저 콜옵션 거래량이 0인 관측치와 결측값을 제거하였다. 원본 데이터는 장단기 옵션이 혼재되어 있으나, 단기옵션(만기 1~90일)이 전체의 약 55.28%를 차지하므로 단기 콜옵션만을 분석 대상으로 선정하였다. 이에 따라 만기까지 일수 90일 이하의 콜옵션을 대상으로 하고, 시간가치가 존재하는 콜옵션의 가격 예측 성능을 비교하기 위해 만기까지 일수가 0인 콜옵션은 분석에서 제외하였다.

무위험이자율은 3개월물 미국 국채 수익률을 사용하였으며, 월별 데이터를 선형보간법을 통해 일별 수익률로 변환한 후 일별 옵션 데이터와 매칭하였다. 또한 블랙숄즈 모형의 일정 변동성 가정을 수정하여 30일 역사적 변동성을 계산하여 사용하였다. 이러한 전처리 과정을 통해 최종적으로 2016년 2월 17일부터 2020년 12월 31일까지 285,037개의 데이터를 모형 분석에 활용하였다.

3.2 모형의 추정 및 분석

본 연구에서는 단기 콜옵션 가격 예측 성능을 비교하기 위해 전통적인 블랙숄즈 모형과 기계학습 모형을 동일한 조건하에서 분석하였다. 블랙숄즈 모형은 옵션 가격 결정의 이론적 기준으로 활용하며, 기계학습 모형으로는 XGBoost을 활용하여 데이터 기반의 예측 성능을 검증한다.

모형 간 공정한 비교를 위해 기초자산 가격, 행사가격, 만기까지 일수, 30일 역사적 변동성 그리고 시변 무위험이자율을 공통 입력 변수로 사용하였다. 타겟 변수는 콜옵션의 실제 거래가격으로 설정하여 모형의 예측 성능을 평가하였다.

데이터 분할은 무작위 추출을 통해 훈련용 64%, 검증용 16%, 테스트용 20%의 비율로 수행하였다. 기계학습 모형의 성능 최적화를 위해 모든 입력 변수와 타겟 변수를 0에서 1사이의 범위로 정규화하였다.

모형의 예측 성능은 RMSE(Root Mean Square Error), MAE(Mean Absolute Error), MAPE(Mean Absolute Percentage Error)를 통해 정량적으로 평가하였다. [표 1]은 테스트 데이터에 대한 두 모형의 성능 비교 결과를 보여준다. XGBoost 모형이 블랙숄즈 모형보다 모든 평가지표에서 우수한 예측 정확도를 보였다. MSE 기준으로 블랙숄즈 모형이 136.34를 기록한 반면, XGboost 모형은 16.34


로 약 87.9%의 성능 개선을 보였다. MAE에서는 블랙숄즈 모형의 4.03 대비 XGBoost의 1.50을 기록하여 약 62.9%의 오차 감소를 보였으며, RMSE에서도 블랙숄즈 모형의 11.68에서 XGBoost의 4.05로 약 65.3%의 개선을 보였다. 본 결과는 콜옵션 가격 예측 분야에서 기계학습이 갖는 성능 우위를 실증적으로 확인해주며, 선행 연구들의 결과와도 일관성을 보인다.

[표 1] 예측 모형의 성능 평가

[Table 1] Performance of Predictive Models

Performance Metrics	Black-Scholes	XGboost
MSE	136.3398	16.4319
MAE	4.0292	1.4955
RMSE	11.6765	4.0536

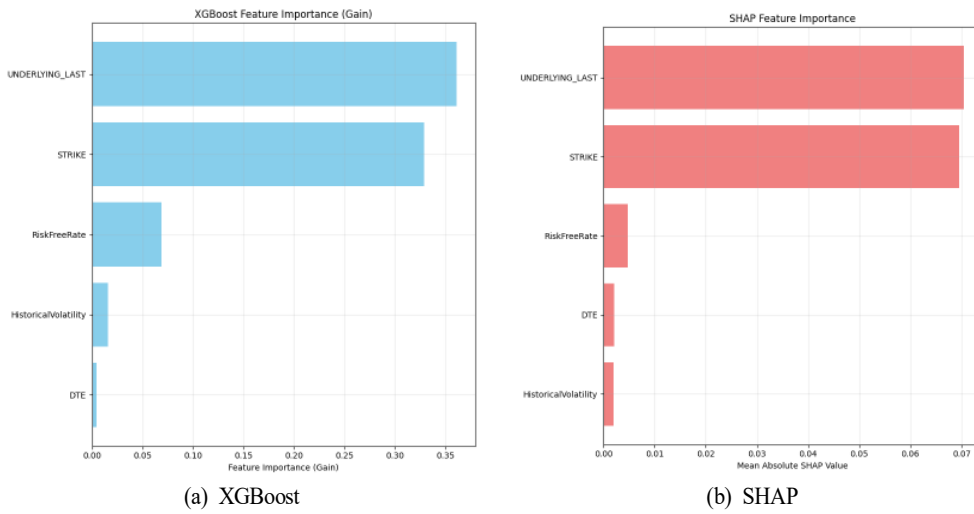
두 모형의 단기 콜옵션 가격 예측 성능을 시각적으로 비교한 [그림 1]에서도 성능 차이가 명확히 드러난다. 블랙숄즈 모형의 경우 데이터들이 완벽한 예측선을 중심으로 상대적으로 큰 분산을 보인 반면, XGBoost 모형의 경우 데이터들이 완벽한 예측선에 밀접하게 분포되어 있으며, 모든 구간에서 균등한 예측 성능을 보였다.



[그림 1] 실제 가격과 예측 가격 비교

[Fig. 1] Actual vs. Predicted Prices

XGBoost 모형에 대한 해석 가능성을 확보하기 위해 SHAP을 적용하여 콜옵션 가격 예측에 중요한 입력 변수를 분석하였다. [그림 2]에서 단기 콜옵션 가격 예측에 가장 큰 영향력을 미치는 주요 변수들을 보여준다. XGBoost 모형에서는 기초자산 가격(UNDERLYING_LAST)이 약 0.35로 가장 높은 중요도를 보였고, 행사가격(STRIKE)이 약 0.32로 근소한 차이로 두 번째 중요 변수로 식별되었다. SHAP 기반분석에서도 기초자산 가격이 약 0.07로 가장 높은 중요도를 나타냈고, 행사가격은 약 0.06으로 유사한 중요도를 보여 두 분석 방법 모두에서 일관된 결과를 보였다.



[그림 2] 특성 중요도
 [Fig. 2] Feature Importance

4. 결론

본 연구는 기계학습 기반 단기 콜옵션 가격 예측 모형의 성능을 실증적으로 검증하고, 설명가능한 인공지능(XAI)기법을 통해 모형의 해석가능성을 확보하고자 하였다. 미국 애플(Apple)사의 콜옵션 데이터를 활용하여 전통적인 블랙숄즈 모형과 XGBoost 모형의 성능 예측 성능을 비교 분석한 결과, 다음과 같은 주요 연구결과를 도출하였다.

첫째, XGBoost 모형이 블랙숄즈 모형 대비 우수한 예측 성능을 보였다. MSE 기준으로 약 87.9%의 성능 개선을 달성하였으며, MAE와 RMSE에서도 각각 62.9%, 65.3%의 오차 감소를 실현하였다. 이는 기계학습 모형이 옵션 가격의 복잡한 비선형 관계를 효과적으로 포착할 수 있음을 실증적으로 입증하는 결과이다. 또한 실제 가격과 예측가격 비교를 통해 XGBoost 모형이 모든 가격 구간에서 일관된 예측 정확도를 보이는 것을 확인하였다.

둘째, SHAP 분석을 통해 단기 콜옵션 가격 예측에 영향을 미치는 핵심 용인을 규명하였다. 기초자산 가격과 행사가격이 가장 중요한 예측 변수로 식별되었으며, 이는 XGBoost와 SHAP 분석 모두에서 일관된 결과를 보였다. 이러한 결과는 기존 연구에서 옵션 가격의 핵심 결정 요인으로 제시한 머니니스(Moneyness, UNDERLYING_LAST / STRIKE)와 일치하는 맥락을 보여준다 [4][9][11]. 본 연구에서는 머니니스를 직접 변수로 사용하지 않았으나, 기초자산 가격과 행사가격이 개별적으로 높은 중요도를 보인 것은 이들 간의 상대적 관계가 옵션 가격 결정에 핵심적 역할을 한다는 것

을 시사한다 [11].

본 연구의 학술적 의의는 다음과 같다. 기존 연구들이 주로 모형 간 성능 비교에만 집중한 반면, 본 연구는 XAI기법을 활용하여 기계학습 모형의 의사결정 과정에 대한 해석가능성을 확보했다는 점에서 학술적 기여도를 갖는다. 더불어 이는 금융 실무에서 요구되는 모형의 투명성과 신뢰성을 확보하는 데 중요한 기여를 한다.

본 연구의 한계점과 향후 연구방향은 다음과 같다. 첫째, 본 연구는 미국 한 개 기업의 콜옵션만을 대상으로 하였으므로 연구결과의 일반화 가능성에 제약이 있다. 향후 다양한 기업의 옵션 데이터와 풋옵션을 포함한 포괄적 분석이 필요하다. 둘째, 본 연구에서는 1에서 90일까지의 단기 만기만을 사용했다. 하지만 90일 이후의 중기와 장기 만기에 대한 분석을 통해 결과의 일반화 가능성 검증이 필요하다.

References

- [1] Korea Exchange, “2024 Derivatives Market Trends, Annual Report”, Korea Exchange, Seoul, Republic of Korea, Annual Rep., 2024. [Online]. Available: <http://data.krx.co.kr/contents/MDC/MGZN/publication/MDCMGZN001.cmd?menuId=MDCMGZN010>.
- [2] Y. Luo, Z. Wang, “A Review of the Option Pricing Model and Further Development”, 2nd International Conference on Financial Technology and Business Analysis, December 15-17, 2023, Beijing, China, pp. 1499-1506, doi: 10.54254/2754-1169/64/20231499.
- [3] M. H. Davis, V. G. Panas, T. Zariphopoulou, “European option pricing with transaction costs”, SIAM Journal on Control and Optimization, vol. 31, no. 2, March 1993, pp. 470-493, doi: 10.1137/0331022.
- [4] A. A. Pawar, D. Chaudhary, “Can GPT Price Options?”, 2024 IEEE International Conference on Future Machine Learning and Data Science (FMLDS), November 20-23, 2024, Sydney, Australia, pp. 364-370, doi: 10.1109/FMLDS63805.2024.00071.
- [5] F. Black, M. Scholes, “The pricing of options and corporate liabilities”, Journal of Political Economy, vol. 81, no. 3, May 1973, pp. 637-654, doi: 10.1086/260062.
- [6] L. Song, W. Wang, “Solution of the fractional black-scholes option pricing model by finite difference method”, Abstract and Applied Analysis, vol. 2013, June 2013, pp. 1-10, doi: 10.1155/2013/194286.
- [7] P. Boyle, M. Broadie, P. Glasserman, “Monte carlo methods for security pricing”, Journal of Economic Dynamics and Control, vol. 21, no. 8-9, August 1997, pp. 1267-1321, doi: 10.1016/S0165-1889(97)00028-6.
- [8] P. Carr, M. Stanley, D. Madan, “Option valuation using the fast fourier transform”, Journal of Computational Finance, vol. 2, no. 4, Summer 1999, pp. 61-73, doi: 10.21314/JCF.1999.043.
- [9] H. Park, N. Kim, J. Lee, “Parametric models and non-parametric machine learning models for predicting option prices: Empirical comparison using over KOSPI 200 index options”, Expert Systems with Applications, vol. 41, no. 11, August 2014, pp. 5227-5237, doi: 10.1016/j.eswa.2014.01.032.

- [10] B. Madhu, A. K. Paul, R. Roy, “Performance comparison of various kernels of support vector regression for predicting option price”, *International Journal of Discrete Mathematics*, vol. 4, no. 1, April 2019, pp. 21-31, doi: 10.11648/j.dmath.20190401.14.
- [11] C. F. Ivaşcu, “Option pricing using machine learning”, *Expert Systems with Applications*, vol. 163, January 2021, pp. 113799, doi: 10.1016/j.eswa.2020.113799.
- [12] S. Shin, H. Oh, J. H. Kim, “Estimation of KOSPI200 Index option volatility using Artificial Intelligence”, *Journal of the Korea Institute of Information and Communication Engineering*, vol. 26, no. 10, October 2022, pp. 1423-1431, doi: 10.6109/jkiice.2022.26.10.1423.
- [13] K. Ostrowski, K. Birman, “Extensible Web Services Architecture for Notification in Large-Scale Systems”, *The 2006 IEEE International Conference on Web Services (ICWS'06)*, July 9-13, 2006, Chicago, IL, USA, pp. 383-392, doi: 10.1109/ICWS.2006.63.
- [14] K. Tissaoui, T. Zaghdoudi, A. Hakimi, O. Ben-Salha, L. B. Amor, “Does Uncertainty Forecast Crude Oil Volatility before and during the COVID-19 Outbreak? Fresh Evidence Using Machine Learning Models”, *Energies*, vol. 15, no. 15, August 2022, pp. 1-20, doi: 10.3390/en15155744.
- [15] W. S. Lee, “A Study on KOSPI Volatility Prediction Using eXplainable Artificial Intelligence”, *Journal of the Korean Society of Industry Convergence*, vol. 28, no. 3, June 2025, pp. 747-754, doi: 10.21289/KSIC.2025.28.3.747.
- [16] S. M. Lundberg, S. I. Lee, “A Unified Approach to Interpreting Model Predictions”, *The 31st International Conference on Neural Information Processing Systems (NIPS'17)*, December 4-9, 2017, Long Beach, California, USA, pp. 4768-4777, doi: 10.5555/3295222.3295230.