

A Deep Learning Based Predictive Modeling of Bitcoin Prices: Analysis with a Focus on Investor Rationality and Risk Management

Tae-Wook Kim*, Jung-woo Sohn**

*Student, Dept. of Industrial and Systems Engineering, KAIST, Daejeon, Korea

**Professor, Dept. of Software, Yonsei University, Wonju, Korea

[Abstract]

A number of studies have been conducted using diverse data sources to forecast cryptocurrency prices. However, unlike the rational behavior of human investors who manage risk through asset diversification between risky and safe assets, most deep learning models for cryptocurrency price prediction have overlooked features related to safe assets that may not appear directly connected to Bitcoin as risky assets. In response, this study demonstrates that a deep learning price-forecasting model designed by incorporating safe assets—specifically Korean bond indices—alongside Bitcoin significantly improves prediction performance. In our experiment, features derived from the Korean Bond Indexes were selected through the Granger Causality Test to assess their relevance for Bitcoin price prediction. To ensure reliability in forecasting, the dataset was preprocessed to achieve stationarity across all features. The results indicate that a model trained on both Bitcoin-related variables (representing risky assets) and Korean Bond features (representing safe assets) delivers enhanced predictive performance.

▶ **Key words:** Bitcoin, Price prediction, Stationarity, Granger-Causality test, KRX bond index

[요약]

지금까지 다양한 데이터 소스를 활용한 암호화폐 가격 예측 연구가 진행되어 왔다. 그러나 위험자산과 안전자산 간의 분산투자를 통해 리스크를 관리하는 인간 투자자의 합리적 행위와 달리, 대부분의 딥러닝 기반 암호화폐 가격 예측 모델은 비트코인과 같은 위험자산과 직접 연결되지 않아 보이는 안전자산 관련 특성을 간과해 왔다. 이에 본 연구는 안전자산, 특히 한국 채권지수를 비트코인과 함께 모델에 포함시킨 딥러닝 기반 가격 예측 모델이 예측 성능을 유의미하게 향상시킴을 보여준다. 실험에서는 한국 채권지수에서 도출된 특성을 Granger 인과성 검정을 통해 비트코인 가격 예측에의 적합성을 평가하여 선택하였다. 또한, 예측의 신뢰성을 확보하기 위해 모든 특성에 대해 정상성을 만족하도록 데이터셋을 전처리하였다. 연구 결과, 비트코인 관련 변수(위험자산)와 한국 채권 관련 특성(안전자산)을 동시에 학습한 모델이 더 나은 예측 성능을 보였다.

▶ **주제어:** 비트코인, 가격 예측, 시계열 정상성(Stationarity), Granger-Causality 검정, 채권 지수

- First Author: Tae-Wook Kim, Corresponding Author: Jung-woo Sohn
- *Tae-Wook Kim (twkim@kaist.ac.kr), Dept. of Industrial and Systems Engineering, KAIST
- **Jung-woo Sohn (jwsohn00@yonsei.ac.kr), Dept. of Software, Yonsei University
- Received: 2025. 08. 13, Revised: 2025. 09. 01, Accepted: 2025. 09. 15.
- This paper is an extended version of the study titled 'Design of a Deep Learning Model for Price Prediction Based on Investor Rationality', which was presented at the Korea Society of Computer and Information Summer Conference 2024.

I. Introduction

비트코인은 매우 높은 변동성을 지닌 위험 자산으로 간주되며, 이에 따라 투자자와 연구자들 모두에게 큰 관심을 받고 있다. 이들의 주요 관심사는 성공적인 수익을 거두기 위한 비트코인 가격 예측에 있으며, 이를 위해서는 가격 결정에 영향을 미치는 다양한 요인을 식별하는 것이 중요하다. 이러한 요인들은 고전 경제학에서 말하는 수요와 공급 균형(equilibrium)을 바탕으로 한 시장 가격 형성 원리에 기초한다.

전반적으로 비트코인 가격은 크게 암호화폐 시장과 전통적인 의미에서 시장 이 두 가지로부터 영향을 받는다고 볼 수 있다. 암호화폐 시장 내에서는 비트코인이 다른 코인들과 상호 영향을 주고받으며[1], 전통 금융, 현물 시장에서는 원유, 원자재, 주식, 채권과 같은 자산들과도 연관성이 있다[2]. 이처럼 다양한 요인들을 반영하여 비트코인 가격을 예측하는 것은 복잡한 문제이다. 여기서 딥러닝 기술의 강점은 이러한 다양한 요인들 중에서 핵심적인 요인을 효과적으로 추출하고 이를 통합하여 최적의 예측 결과를 도출해낼 수 있다는 점이다[3].

그러나 기존의 가격 예측 모델들에는 몇 가지 잠재적인 한계가 존재한다. 대부분의 딥러닝 기반 비트코인 예측 모델들은 투자자의 의사결정 구조를 충분히 반영하지 않는다. 예를 들어, 투자자 포트폴리오 다각화 (portfolio diversification, risk management) 사례에서 볼 수 있듯이 [15-17], 고전 경제학의 투자 이론에서는 투자자들의 투자결정을 '위험 자산'과 '안전 자산' 사이의 균형 배분으로 설명한다. 그럼에도 불구하고, 이러한 경제학적 관점에서의 합리적인(rationality) 투자 판단 원리¹⁾가 딥러닝 모델의 피쳐 선정 및 학습 데이터 구성 과정에서는 충분히 반영되지 않는 경우가 많다. 본 연구의 핵심 아이디어는, 가격 예측 모델의 학습이 단순히 데이터 기반이 아니라, 인간 투자자의 리스크 관리 원칙을 학습할 수 있도록 처음부터 설계될 필요가 있다는 것이다. 이를 위해서는 데이터의 사전 필터링, 전처리, 피쳐 선택이 그러한 관점을 바탕으로 이루어져야 한다.

또 하나 주목할 점은, 암호화폐 시장에서 비직관적인 특징으로, 미국 외 국가들, 특히 한국 시장의 거래량이 미국 시장보다 더 크다는 사실이다[4]. 따라서 본 연구에서는 데이터의 스케일이라는 관점에서 한국 시장 데이터를 활용하는 것이 비트코인 가격 예측 모델의 성능을 향상시킬 수

있다고 판단하였고, 이에 따라 한국의 비트코인 시장과 채권 시장 데이터를 활용하기로 하였다.

이와 같은 문제의식을 바탕으로, 본 연구는 한국 채권 지수라는 안전 자산을 딥러닝 기반 가격 예측 모델에 통합함으로써, 더 나은 예측 성능을 달성할 수 있음을 보이고자 한다. 본 연구의 주요 기여는 다음과 같다.

- 한국의 5개 채권 지수에 대한 시계열 데이터의 정상성(stationarity)을 확보한 후, Granger 인과성 검정을 통해 비트코인 가격 예측에 기여할 수 있는 피쳐만을 선별하여 데이터셋을 구성하였다.
- 비트코인 및 채권 관련 피쳐에 Min-Max 정규화를 적용하는 동시에, 로그 차분을 통해 정상성을 확보함으로써 모델이 미지의 데이터에 대해서도 견고한(robust) 예측이 가능하도록 하였다.
- 한국 채권 지수 관련 피쳐의 유용성을 검증하기 위해, LSTM 기반 모델 간 성능 비교를 수행하였으며, 추가적으로 SHAP (Shapley Additive Explanations) 분석을 통해 각 피쳐의 중요도를 정량적으로 평가하였다.

II. Related works

1. Relationship between Bitcoin and other assets

비트코인과 타 자산 간의 관계, 그리고 이를 활용한 포트폴리오 다각화 및 헤지 전략에 대한 주요 연구는 다음과 같다. Harb 외[5]등은 비트코인과 다른 암호화폐 간의 수익률 변동성 전이(spill-over)뿐만 아니라, 암호화폐와 미국 주식 및 채권 시장 간의 변동성 상호의존성에 대해 분석하였다. 이 연구는 암호화폐 시장이 미국 주식 시장과는 분리되어 있다고 추측되나, 채권 시장과는 일정한 연관성을 갖고 있음을 보여주었다.

또한, 천연가스와 비트코인 간의 변동성 전이를 분석한 연구에서는 천연가스로부터 비트코인으로의 전이 효과가 존재함을 확인하였다[6]. Akhtaruzzaman 외[7]등은 비트코인, 글로벌 산업 포트폴리오, 채권 지수를 기반으로 한 포트폴리오 다각화 연구를 수행하였으며, 비트코인과 산업 포트폴리오 및 채권 지수 간의 동적 조건부 상관계수가 낮다는 점을 보였다.

Guesmi 외[8]등은 비트코인, 금, 원유, 신흥국 주식 시장으로 구성된 투자 포트폴리오의 리스크가, 비트코인을

1) 투자자 합리성은 투자자가 손실 위험을 최소화할 때 나타나는 자산 배분 패턴으로, 리스크 관리는 위험 자산과 안전자산의 상호 관계 속에서 투자자가 가격 변동으로 인한 손실 위험을 분산하는 과정으로 구분할 수 있다.

제외한 후자의 세 가지 자산만으로 구성된 포트폴리오보다 유의미하게 낮다는 결과를 통해, 비트코인이 투자자의 헤지 및 리스크 관리에 기여할 수 있음을 시사하였다.

하지만 현재 비트코인 시장에서 한국 시장의 규모나 영향력이 매우 크다는 점을 고려할 때[4], 기존 연구들은 모두 미국 시장 중심으로만 수행되었다는 점에서 차이점이 존재한다. 이러한 기존 연구의 흐름은 비트코인에 영향을 미칠 수 있는 보다 광범위한 글로벌 금융 특성이나 한국 금융 시장의 특수성을 포착하는 데 제약이 있을 수 있다.

2. Bitcoin price prediction using deep learning

최근 딥러닝 기술의 발전에 따라, 비트코인 가격 예측을 위한 다양한 연구가 진행되어 왔다. Kim 외[9]등은 비트코인의 온체인 데이터(on-chain data)를 기반으로 LSTM(Long Short-Term Memory) 모델을 활용하여 가격을 예측하였다. 이들은 비트코인 가격 시계열을 6개의 구간으로 분할한 후, 각 구간에 대해 변화 지점을 탐지(change point detection)하고 정규화를 적용함으로써, 가격 변동 추세와 암묵적인 패턴을 효과적으로 포착할 수 있었으며 높은 성능의 예측 모델을 구현하였다.

Tanwar 외[10]등은 다양한 암호화폐 간의 관계에 주목하여, 비트코인의 가격 변화를 기반으로 Litecoin 및 Zcash의 가격을 예측하고자 하였다. 이들은 GRU(Gated Recurrent Unit) 및 LSTM 기반 모델을 활용하여 상호연동되는 가격 패턴을 반영하였다. 한편, Parekh 외[11]등은 비트코인 및 기타 암호화폐 간의 가격 관계 분석과 더불어, 최근의 트위터 감성(sentiment) 데이터를 함께 활용하여 가격을 예측하였다. 이들은 GRU 및 LSTM 기반의 딥러닝 모델을 통해 기존 전통적 방법보다 향상된 성능의 예측 결과를 보여주었다.

그러나 다수의 딥러닝 기반 비트코인 예측 연구들은 시계열 데이터의 정상성(stationarity) 확보에 대한 고려 없이 Min-Max 정규화만을 적용하는 경향이 있다. 시계열 데이터의 평균과 분산이 시간에 따라 일정하지 않다면, 예측 정확도에 악영향을 미칠 수 있으며[12], 학습된 모델은 새로운 데이터에 대해 낮은 일반화 성능을 보일 가능성이 높다. 또한, 감성 데이터나 타 암호화폐 가격 데이터 등 다양한 입력 데이터의 예측 기여도를 검증하지 않은 채 단순히 모델 성능만을 기준으로 데이터의 효과를 주장하는 경우도 많다. 이는 Granger 인과성 검정과 같은 통계적 가설 검정을 병행하지 않을 경우, 모델 해석 및 신뢰성 측면에서 한계가 존재할 수 있음을 의미한다.

III. Dataset Construction

1. Data collection

본 연구는 한국 채권 정보가 비트코인 가격 예측에 효과적인지를 검증하기 위해, 한국의 5개 채권 지수 데이터를 KRX 정보 데이터 시스템으로부터 수집하였으며, 원화 기준의 비트코인 일일 종가 데이터는 암호화폐 거래소 업비트(Upbit)에서 수집하였다. 전체 데이터 수집 기간은 2021년 1월 19일부터 2024년 1월 23일까지이다.

수집된 다섯 개의 한국 채권 지수에 대한 요약 정보는 Table 1에 정리되어 있으며, 각 지수에서 추출 가능한 세부 피쳐는 Table 2에 제시하였다. 모든 피쳐는 일 단위의 시계열 데이터로 구성되어 있으며, 비트코인 종가 데이터는 매일 거래가 이루어지므로 결측이 없지만, 채권 데이터는 공휴일과 주말에는 거래가 없기 때문에 해당 일자의 데이터는 존재하지 않는다.

Table 1. Descriptions for the five Korean Bond Indices

Notation	Index	Description
PRIME	Korea Government Bond Prime Rate Index	Indicator combining Korean government bonds and the prime rate, reflecting basic interest rate trends in the domestic financial market
KTB	Korea Treasury Bond Index	Index tracking the price movements of South Korean government bonds (treasury bonds), providing an overview of the government bond market
KTB 10Y	Korea Treasury Bond Index	Index specifically targeting 10-year maturity South Korean government bonds, offering insights into the 10-year government bond market
KRX	Korea Exchange Bond Index	Comprehensive index tracking various bond types in the South Korean bond market, providing an overview for investors

Table 2. Korean Bond Index features

Features	Descriptions	PRIME	KTB	KTB 10Y	KRX	KRX AA-
Total Return Index Closing Price	The closing price of an index that reflects the total return on an investment, accounting for both price changes and reinvested income such as dividends or interest	0	0	0	0	0
Net Price Index Closing Price	The closing price of an index that reflects only the price movements of an investment, excluding any reinvested income like dividends or interest	0	0	0	0	0
Duration	A measure of the sensitivity of the price of a bond or other fixed income investment to changes in interest rates. It represents the weighted average time it takes for the bond's cash flows to repay its initial price	0	0	0	0	0
Convexity	A measure of the curvature in the relationship between bond prices and yields. It provides additional information about the price-yield curve beyond what is explained by duration	0	0	0	0	0
Yield to Maturity	The total return anticipated on a bond if it is held until it matures, considering its current market price, par value, coupon interest rate, and the number of years to maturity	0	0	0	0	0
Market Price Index Closing Price	The closing price of an index that reflects the overall market price movements of a group of securities	X	0	0	0	0
Call Reinvestment Index Closing Price	The closing price of an index that considers the impact of call options and reinvestment returns on the total return of an investment.	X	X	X	0	0
Zero Reinvestment Index Closing Price	The closing price of an index that reflects the performance of an investment without considering any reinvestment of income	X	X	X	0	0

Table 3. p-value of the Granger-Causality Test from Each Feature to Bitcoin Close
(The final 29 significant features are marked with bold typeface)

Features	PRIME	KTB	KTB 10Y	KRX	KRX AA-
Total Return Index Closing Price	0.0746	0.0132	0.0177	0.0065	0.0071
Net Price Index Closing Price	0.039	0.0122	0.0173	0.021	0.0077
Duration	0.4681	0.0311	0.0408	0.0231	0.0376
Convexity	0.4305	0.0275	0.0485	0.0271	0.0296
Yield to Maturity	0.0965	0.0024	0.0143	0.0062	0.0056
Market Price Index Closing Price	X	0.0111	0.0035	0.0076	0.0073
Call Reinvestment Index Closing Price	X	X	X	0.0065	0.0071
Zero Reinvestment Index Closing Price	X	X	X	0.007	0.0073

2. Feature selection with Granger causality test

모델 예측 성능을 향상시키기 위해서는 효과적인 입력 피처를 제공하는 것이 필수적이다. 하지만 가능한 모든 피처 조합을 비교하여 최적 조합을 계산하는 것은 비효율적이며, 예측에 기여하지 않거나 오히려 성능을 저하시킬 수 있는 피처까지 포함되면 모델 성능이 악화될 수 있다.

이에 본 연구는 신뢰할 수 있는 통계적 기준을 바탕으로 피처를 선별하고자 하였으며, 구체적으로는 Granger 인과성 검정[13]을 활용하여 각 피처가 비트코인 종가 예측에 유의미한지를 평가하였다. 해당 검정을 수행하기 위해서는 모든 시계열 데이터가 정상성을 만족해야 하며, 이를 검증하기 위해 Augmented Dickey-Fuller (ADF) 검정을 적용하였다. 정상성이 만족되지 않는 경우에는 1차 로그 차분을 적용하여 정상 시계열로 변환하였다.

이러한 과정을 거쳐, 비트코인 종가와 각 피처에 대한 ADF 테스트의 p-value가 모두 0.05 미만임을 확인하였고, Granger 인과성 검정을 통해 29개의 유의미한 피처를 최종적으로 선별하였다 (Table 3 참조).

3. Dataset construction

$X_T^{feature}$ 는 시점 $T - K + 1$ 부터 T 까지의 임의의 피처 값을 포함한 벡터이며, 수식 (1)과 같이 정의된다. T 와 $T + 1$ 은 실제 날짜상으로 하루를 의미하지 않으며, 데이터가 존재하는 가장 가까운 두 날짜를 의미한다.

데이터셋은 다음 두 가지로 구성하였다: P_K 는 비트코인 종가만을 포함한 샘플, P_K^{Bond} 는 비트코인 종가와 채권 관련 피처를 함께 포함한 샘플이다. X_T^{Bit} 는 $T - K + 1$ 부터 T 까지의 비트코인 종가 시계열이며, y_{T+1} 은 다음 시점의 비트코인 종가를 의미한다. B_T 는 동일한 시점 범위에서 선별된 29개 채권 피처들의 벡터로 구성된다.

시퀀스 길이 자연수 K 는 2부터 14까지 변화시키며 실험을 수행하였으며, 최적의 K 값을 찾기 위해 총 13개의 P_K 와 P_K^{Bond} 데이터셋을 각각 구축하였다.

$$X_T^{feature} = [x_{T-K+1}^{feature}, x_{T-K+2}^{feature}, \dots, x_T^{feature}] \quad (1)$$

$$[X_T^{Bit}, y_{T+1}] \in P_K \quad (2)$$

$$[X_T^{Bit}, B_T, y_{T+1}] \in P_K^{Bond} \quad (3)$$

$$B_T = [X_T^{Bond_1}, X_T^{Bond_2}, \dots, X_T^{Bond_{29}}] \quad (4)$$

4. Preprocessing

딥러닝 모델의 성능은 입력 데이터의 전처리 방식에 따라 큰 영향을 받을 수 있다. 일반적으로 Min-Max 정규화가 많이 사용되지만, 이 방법은 두 가지 단점을 가진다. 첫째, 미지의 값이 학습 데이터 범위를 초과하는 경우 예측 값이 1을 넘거나 0 이하가 되어 해석이 어려울 수 있다. 둘째, 값의 범위가 크고 변동성이 큰 경우 상대적으로 작은 값들이 모델에 의해 무시될 수 있다.

예를 들어, Fig. 1은 비트코인 가격에 단순히 Min-Max Scaling을 적용한 결과이며, 이러한 데이터로 학습한 모델은 0~1 범위 내에서만 예측하려는 경향이 강해질 수 있다. 이에 따라 본 연구는 모든 피처에 대해 1차 로그 차분을 먼저 적용하여 시계열의 정상성을 확보한 후, 그 결과에 대해 Min-Max 정규화를 수행하였다. 이 방법은 Fig. 2에 제시된 바와 같이 미지의 데이터에 대해서도 더 강건한 (robust) 예측이 가능하도록 한다.




Fig. 1. Min-Max scaling result




Fig. 2. Log Differencing and Min-Max Scaling result

IV. Experiment

1. Model architecture

3장에서 구성한 두 종류의 데이터셋, 즉 비트코인 정보만을 포함한 P_K 와 비트코인 및 채권 관련 정보를 모두 포함한 P_K^{Bond} 를 활용하여 딥러닝 모델을 학습시켰다. 그 목적은 채권 관련 정보의 포함 여부가 비트코인 종가 예측에

미치는 영향을 비교 및 평가하는 것이다.

사용된 모델은 시계열 데이터 학습에 효과적인 LSTM (Long Short-Term Memory) 레이어와 Dense 레이어를 조합하여 구성하였다. 모델의 구조는 Fig. 3에 제시되어 있다. 입력 형태는 각 데이터셋의 비트코인 종가 및 채권 관련 피쳐 수에 따라 달라지며, 모델은 비트코인 가격과 29개의 채권 관련 시계열 피쳐 간의 시간적 관계를 학습함으로써, 위험 자산과 안전 자산 간의 상호작용 및 미시경제 제하의 리스크 관리 이론을 반영하도록 설계되었다.

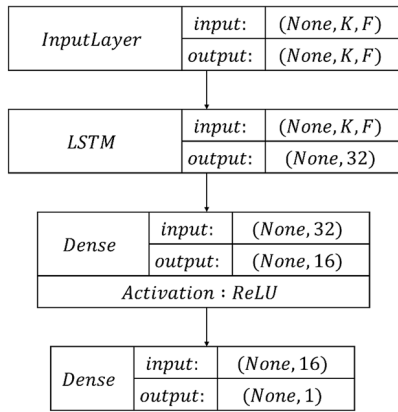


Fig. 3. Model Architecture

Table 4. Performance comparison of the two types of dataset ($K = 5$)

Dataset	MSE	MAE
P_K	0.0046	0.0452
P_K^{Bond}	0.0041	0.0447

2. Training details

모델 구성 및 학습은 Keras 프레임워크를 활용하여 구현하였으며, 손실 함수로는 평균제곱오차(Mean Squared Error, MSE)를, 최적화 알고리즘으로는 학습률 10^{-4} 를 설정한 Adam Optimizer를 사용하였다. 모델 성능 평가 지표로는 평균절대오차(Mean Absolute Error, MAE)를 활용하였다. 배치 크기는 32로 설정하였다.

전체 데이터셋은 훈련(Train), 검증(Validation), 테스트(Test) 셋으로 8:1:1의 비율로 분할했으며, 학습은 훈련 셋을 이용해 진행했다. 각 에포크(epoch) 종료 시마다 검증 셋에서의 성능을 평가했고, 가장 높은 성능을 보인 모델 상태를 기준으로 테스트 셋에 대한 최종 성능을 측정하였다. 이러한 전체 학습 및 테스트 과정을 10회 반복 수행하여, 각 데이터셋 구성에 따른 평균 성능을 비교하였다.

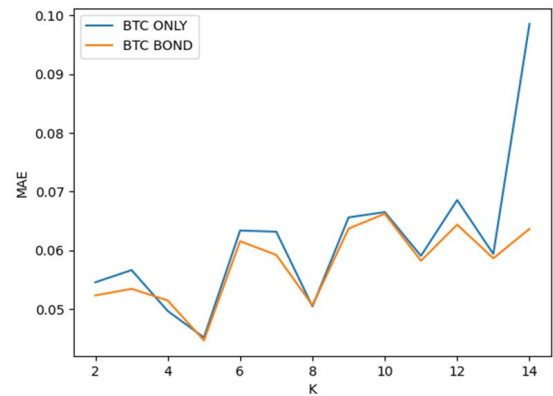


Fig. 4. MAE for each P_K^{Bond} dataset by K

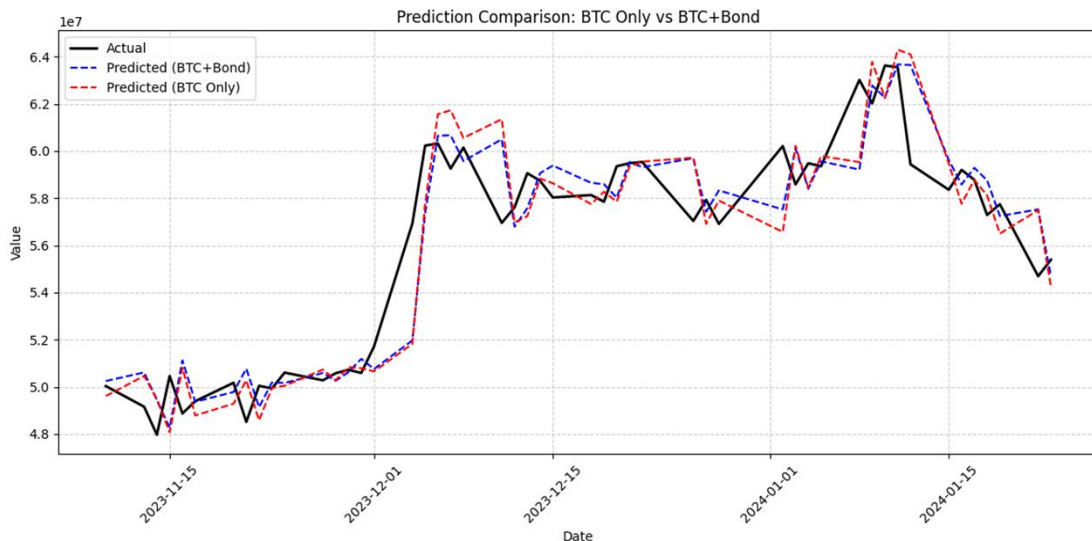


Fig. 5. Price prediction comparison: BTC only dataset vs. BTC with bond ($K = 5$)




Fig. 6. The impact of each feature in P_K^{Bond} measured with SHAP ($K = 5$)

V. Results

비트코인 증가 정보만을 사용한 P_K 와, 채권 관련 정보를 함께 포함한 P_K^{Bond} 데이터셋에 대해 다양한 K 값(시계열 길이)에 따라 학습한 결과는 Fig. 4에 나타나 있다. 해당 결과에서는 채권 지수 피처를 함께 사용하는 경우, 비트코인 단독 정보만 사용하는 경우보다 전반적으로 MAE 값이 낮게 나타나는 것을 확인할 수 있다. Fig. 5에서는 성능 비교 결과 가장 우수했던 $K = 5$ 를 기준으로 부분 시계열에 대한 예측값을 채권 지수 피처가 포함된 경우와 아닌 경우를 구분해서 보여 주고 있으며 Table 4와 Fig. 4의 결과와 마찬가지로 채권 지수 피처를 포함한 경우의 예측 성능이 일관성 있게 우수함을 관찰할 수 있다.

또한 Table 4에서는 두 데이터셋 각각에 대해 최적의 K 값을 적용한 경우의 MAE 및 MSE지표를 제시하고 있다. 채권 피처가 포함된 P_K^{Bond} 데이터셋의 MAE는 0.0426으로, 비트코인 정보만으로 구성된 데이터셋을 학습하였을 때 P_K 의 MAE 0.0449보다 더 낮은 오차를 기록하였다. 이는 채권 관련 피처들이 비트코인 가격 예측에 긍정적으로 기여함을 시사한다. 추가로, Table 5와 6에서는 사용된 데이터셋의 갯수를 학습/검증/테스트 구분에 따라 구체적으로 기술하고 각각의 경우의 에러값을 보여 주고 있으며, 전체적으로 채권 피처가 포함된 Table 6 경우의 에러값이 낮음을 관찰할 수 있다.

다만, 낮은 MAE (혹은 MSE) 값이 모든 채권 관련 피처가 비트코인 가격 예측에 효과적이라는 것을 의미하지는

않는다. 따라서 각각의 채권 관련 피처가 미치는 영향력을 정량적으로 평가하기 위해 SHAP (Shapley Additive Explanations) 값[14]을 계산하였다. Fig. 6는 SHAP 값을 활용하여 $K = 5$ 일 때 테스트 데이터셋(P_K^{Bond})에 대한 각 피처의 영향력을 보여주고 있다. 여기서, KTB Duration부터 KTB 10-Y TRI까지의 피처들이 BTC 증가보다 더 큰 영향을 미치는 것으로 나타났다. 이는 일반적인 직관과는 달리 모델의 성능에 직접적으로 작용할 것 같은 BTC 증가보다 한국 채권 지수 관련 피처들의 다수가 모델 성능에 더 큰 영향력을 발휘했다고 볼 수 있다. 즉, 한국 채권 지수 관련 피처들은 비트코인 가격 예측에서 오차를 줄이는 방향으로 실제 유의미한 영향을 미치며, 예측에 효과적으로 활용될 수 있음을 유추할 수 있다.

VI. Conclusions

본 연구는 투자자 합리성 관점에서 안전 자산을 고려한 딥러닝 기반 비트코인 가격 예측의 가능성을 탐색하였다. 특히, 비트코인 시장에 큰 영향을 미치고 있는 한국 시장을 기반으로, 한국 채권 지수 피처가 예측에 기여할 수 있는지를 분석하였다.

Granger 인과성 검정을 활용해 비트코인 가격 예측에 유의미한 채권 피처들을 선별하고, 이를 포함한 시계열 데이터를 기반으로 LSTM 모델을 학습시켰다. 그 결과, 단순히 비트코인 정보만을 사용한 모델보다 채권 피처를 함께

Table 5. (Bond data included) Number of train/validation/test samples and error statistics w.r.t K

k	n (train)	n (val.)	n (test)	MSE (avg)	MSE (min)	MSE (max)	MAE (avg)	MAE (min)	MAE (max)
2	592	74	75	0.006461253	0.006248458	0.006633764	0.052322976	0.05060719	0.053669587
3	592	74	74	0.007365555	0.00711842	0.007922524	0.053444312	0.051727571	0.057826061
4	591	74	74	0.005146523	0.004774745	0.005493627	0.051460761	0.050014276	0.053441226
5	590	74	74	0.004092212	0.003942816	0.004278176	0.044659881	0.043297	0.046718895
6	589	74	74	0.008702141	0.008571404	0.008965684	0.06155002	0.060886703	0.062280189
7	588	74	74	0.007551687	0.007244939	0.007977272	0.059223919	0.056960493	0.061421465
8	588	73	74	0.004747203	0.004477891	0.004961342	0.050651746	0.049301066	0.052809067
9	587	73	74	0.009033752	0.008737721	0.009200701	0.063711445	0.062100861	0.064984128
10	586	73	74	0.011108737	0.010938115	0.011434212	0.066226555	0.065482058	0.067100368
11	585	73	74	0.006388349	0.006147021	0.006662891	0.058216618	0.056987513	0.060307708
12	584	73	74	0.010262706	0.01013453	0.010427214	0.064373422	0.062265821	0.066649757
13	584	73	73	0.007391087	0.007210445	0.007709302	0.058647877	0.056795944	0.061402243
14	583	73	73	0.008589065	0.008351395	0.008948321	0.063646957	0.061966538	0.066540912

Table 6. (BTC only) Number of train/validation/test samples and error statistics w.r.t K

k	n (train)	n (val.)	n (test)	MSE (avg)	MSE (min)	MSE (max)	MAE (avg)	MAE (min)	MAE (max)
2	592	74	75	0.00655404	0.006414659	0.00666718	0.054562374	0.05273699	0.055867951
3	592	74	74	0.007715189	0.007581103	0.00787156	0.056638713	0.055497762	0.057320833
4	591	74	74	0.004718539	0.004664091	0.004789173	0.049668097	0.049211189	0.050207425
5	590	74	74	0.004640125	0.00448266	0.004742957	0.045165311	0.044335604	0.045881733
6	589	74	74	0.008532229	0.008444768	0.00865557	0.063374019	0.062922709	0.063689597
7	588	74	74	0.007986547	0.007938604	0.008079587	0.063176385	0.062860891	0.063838474
8	588	73	74	0.004671711	0.004648606	0.004727713	0.050456503	0.050015274	0.050736852
9	587	73	74	0.009191282	0.009021017	0.009458474	0.065612404	0.064329788	0.066873625
10	586	73	74	0.011067043	0.010964736	0.011153743	0.066515619	0.065969639	0.067518115
11	585	73	74	0.006789116	0.006637572	0.006914565	0.05905702	0.058211483	0.059857156
12	584	73	74	0.011357054	0.011235391	0.011481843	0.068569615	0.067858301	0.069701299
13	584	73	73	0.007514339	0.007418525	0.007647006	0.059380519	0.058852274	0.059934825
14	583	73	73	0.024692006	0.008988833	0.165061459	0.098559494	0.064912871	0.395585895

활용한 모델이 더 나은 예측 성능을 나타냈다. 이는 비트코인 가격과 직접적인 관련은 낮아 보이지만 합리적 투자자 선택 이론에 기반했을 때 관련이 높은 채권 지표들이 오히려 고성능 모델 구축에 핵심적인 역할을 했음을 보여준다. 이러한 결과는 직관에 반하며 기존의 연구에서 다루지 않았던 새로운 발견으로 시장과 관련된 예측 모델 설계 시 피쳐 선택에 있어 표면적인 상관성보다 경제 이론이나 시장 구조에 기반한 인과적 메커니즘의 고려가 모델 성능 향상에 중요한 통찰을 제공할 수 있음을 시사한다.

REFERENCES

- [1] S. Qureshi, M. Aftab, E. Bouri, and T. Saeed, "Dynamic interdependence of cryptocurrency markets: An analysis across time and frequency," *Physica A: Statistical Mechanics and its Applications*, Vol. 559, pp. 125077, 2020. DOI: <https://doi.org/10.1016/j.physa.2020.125077>
- [2] P. Wang, X. Liu, and S. Wu, "Dynamic Linkage between Bitcoin and Traditional Financial Assets: A Comparative Analysis of Different Time Frequencies," *Entropy*, Vol. 24, No. 11, Article No. 1565, pp. 1-23, 2022. DOI: 10.3390/e24111565
- [3] A. M. Khedr, I. Arif, P. R. P. V, M. El-Bannany, S. M. Alhashmi, and M. Sreedharan, "Cryptocurrency price prediction using traditional statistical and machine-learning techniques: A survey," *Intelligent Systems in Accounting, Finance and Management*, Vol. 28, No. 1, pp. 3-34, 2021. DOI: <https://doi.org/10.1002/isaf.1488>
- [4] S. Shukla, "Korean Won Topped Dollar as Preferred Currency for Crypto Trades in First Quarter," *Bloomberg*, <https://www.bloomberg.com/news/articles/2024-04-16/korean-won-topped-dollar-as-preferred-currency-for-crypto-trades-last-quarter>, 2024.
- [5] E. Harb, C. Bassil, T. Kassamany, and R. Baz, "Volatility

- Interdependence Between Cryptocurrencies, Equity, and Bond Markets," *Computational Economics*, Vol. 63, No. 3, pp. 951–981, Mar. 2024. DOI: 10.1007/s10614-022-10318-7
- [6] A. Omura, A. W. K. Cheung, and J. J. Su, "Does natural gas volatility affect Bitcoin volatility? Evidence from the HAR-RV model," *Applied Economics*, Vol. 56, No. 4, pp. 414–425, 2024. DOI: 10.1080/00036846.2023.2168608
- [7] M. Akhtaruzzaman, A. Sensoy, and S. Corbet, "The influence of Bitcoin on portfolio diversification and design," *Finance Research Letters*, Vol. 37, pp. 101344, 2020. DOI: <https://doi.org/10.1016/j.frl.2019.101344>
- [8] K. Guesmi, S. Saadi, I. Abid, and Z. Ftiti, "Portfolio diversification with virtual currency: Evidence from bitcoin," *International Review of Financial Analysis*, Vol. 63, pp. 431–437, 2019. DOI: <https://doi.org/10.1016/j.irfa.2018.03.004>
- [9] G. Kim, D. H. Shin, J. G. Choi, and S. Lim, "A Deep Learning-Based Cryptocurrency Price Prediction Model That Uses On-Chain Data," *IEEE Access*, Vol. 10, pp. 56232–56248, 2022. DOI: 10.1109/ACCESS.2022.3177888
- [10] S. Tanwar et al., "Deep Learning-Based Cryptocurrency Price Prediction Scheme With Inter-Dependent Relations," *IEEE Access*, Vol. 9, pp. 138633–138646, 2021. DOI: 10.1109/ACCESS.2021.3117848
- [11] R. Parekh et al., "DL-GuesS: Deep Learning and Sentiment Analysis-Based Cryptocurrency Price Prediction," *IEEE Access*, Vol. 10, pp. 35398–35409, 2022. DOI: 10.1109/ACCESS.2022.3163305
- [12] A. Dixit and S. Jain, "Effect of stationarity on traditional machine learning models: Time series analysis," 2021 Thirteenth International Conference on Contemporary Computing (IC3-2021), pp. 117–122, Aug. 2021. DOI: 10.1145/3474124.3474167
- [13] C. W. J. Granger, "Investigating Causal Relations by Econometric Models and Cross-spectral Methods," *Econometrica*, Vol. 37, No. 3, pp. 424–438, Aug. 1969. DOI: 10.2307/1912791
- [14] S. M. Lundberg and S.-I. Lee, "A Unified Approach to Interpreting Model Predictions," in *Advances in Neural Information Processing Systems* 30, Curran Associates, Inc., pp. 4765–4774, 2017.
- [15] H. R. Varian, *Intermediate Microeconomics: A Modern Approach*. 8th ed., W. W. Norton & Company, 2014.
- [16] E. J. Elton, M. J. Gruber, S. J. Brown, & W. N. Goetzmann, *Modern Portfolio Theory and Investment Analysis* (9th ed.). John Wiley & Sons. 2014.
- [17] H. Markowitz (1952), "Portfolio Selection," *The Journal of Finance*, Vol. 7, No. 1, pp. 77–91 (March 1952)

Authors



Tae-Wook Kim received the B.S. degree from the Division of Software, Yonsei University, South Korea, in 2025. He is currently pursuing the M.S. degree with the Department of Industrial and Systems

Engineering, KAIST. His research interests include statistical learning, data privacy.



Jung-woo Sohn received B.S. and Ph.D. degrees in Aerospace Engineering and Information Sciences and Technology from Seoul National University, Korea in 1998 and The Pennsylvania State University, USA in

2013, respectively. Dr. Sohn joined the faculty of the Division of Software at Yonsei University in 2021. He is currently an Assistant Professor in the Division of Software, Yonsei University. He is interested in market system design, trading agent design, and agent-based simulations.