

## 기계학습 알고리즘을 이용한 알트코인의 가격 예측 성과

김 선 웅  
국민대학교 비즈니스IT전문대학원 교수

# Prediction Performance of Altcoin Price using Machine Learning Algorithm

Sun Woong Kim

Professor, Graduate School of Business IT, Kookmin University, Seoul 02707, Korea

### [요 약]

비트코인의 등장 이후 많은 알트코인이 거래되면서 국내 암호화폐 시장도 세계적인 암호화폐 시장으로 발전하고 있다. 본 연구에서는 알트코인의 가격 예측을 목표로 기술적 지표와 기계학습 모델을 제안하였다. 알트코인에 대한 일별 가격 자료와 기술적 지표, 그리고 비트코인의 기술적 지표를 입력변수로 하는 기계학습 알고리즘의 예측 성과를 비교하고, 경제적 가치를 분석하였다. 실증분석 결과는 다음과 같다. 첫째, 15개의 특성 변수 중 일별 고가가 가장 높은 중요도 점수를 보여주었다. 둘째, 비트코인 가격이 알트코인 가격에 미치는 영향력은 상대적으로 미미하였다. 셋째, LSTM 모형의 예측 결과가 가장 높게 나타났다. 넷째, 예측 결과를 이용한 투자전략의 분석을 통해 제안된 예측모형이 투자자에게 경제적 가치를 제공할 수 있음을 보여주었다. 본 연구는 다양한 예측 알고리즘을 통해 김치 프리미엄이 존재하는 국내 알트코인에 대한 정확한 가격 예측을 시도하였고, 투자자들에게 투자의 방향성을 제공하였다는 점에서 학술적, 실무적 의의가 크다고 할 수 있다.

### [Abstract]

In the Korean cryptocurrency market, many altcoins are traded along with Bitcoin, developing into a global cryptocurrency market. In this study, technical indicators and machine learning models were proposed to predict the price of altcoins. The predictive performance of the machine learning algorithms was compared, and the economic value of the results was analyzed for the altcoins. The empirical results are as follows. First, the high price showed the highest feature importance F-score among the 15 feature variables. Second, Bitcoin's influence was relatively insignificant. Third, the prediction performance of the LSTM model was the highest. Fourth, through the analysis of investment strategies using prediction results, the proposed prediction model showed the economic value for investors. This study is of great academic and practical significance in that it attempted to accurately predict the price of domestic altcoins with kimchi premium through various prediction algorithms and provided investors with an investment direction.

**색인어** : 알트코인, 비트코인, 기술적 지표, 기계학습 알고리즘, 알렉산더 필터 룰

**Keyword** : Altcoins, Bitcoin, Technical indicator, Machine learning algorithm, Alexander filter rule

<http://dx.doi.org/10.9728/dcs.2023.24.1.141>



This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (<http://creativecommons.org/licenses/by-nc/3.0/>) which permits unrestricted non-commercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

**Received** 15 November 2022; **Revised** 12 December 2022

**Accepted** 14 December 2022

**\*Corresponding Author; Sun Woong Kim**

**Tel:** +82-2-910-5471

**E-mail:** [swkim@kookmin.ac.kr](mailto:swkim@kookmin.ac.kr)

## I. 서론

2009년 비트코인(Bitcoin) 도입되며 나타나기 시작한 암호화폐 시장(cryptocurrency market)은 수천 종류 이상의 암호화폐가 활발히 거래되는 시장으로 발전하였다. 알트코인(Altcoin)은 “alternative”와 “coin”의 합성어이며 비트코인 이외의 암호화폐를 말한다.

디지털 통화 및 온라인 결제 시스템을 표방하며 도입된 비트코인과 알트코인은 지난 몇 년 동안 가격이 급등락하면서 투기적 수요가 폭발적으로 증가하고 있다. 그러나 암호화폐의 높은 수익률에만 현혹되어 사전 지식이나 경험이 많지 않은 상태에서 투기에 가세하면서 큰 손해를 보는 투자자들도 나타나고 있다. 암호화폐 거래는 기본적으로 주식시장과 유사한 거래시스템을 채택하고 있어 가격 분석 방법도 주가 분석 방법과 유사한 측면이 있다. 주가 분석 방법에는 기업의 본질가치(fundamental value)를 분석하는 기본적 분석 방법과 가격 움직임 자체를 분석하는 기술적 분석(technical analysis) 방법 등이 전통적으로 활용되고 있다[1].

비트코인 도입 취지는 중앙 정부의 화폐에 대한 대체 통화로서 상대적으로 가격의 안정성이 담보되어야 하나 가격이 수백만 원에서 수천만 원 사이를 오가며 급등락함에 따라 과연 비트코인이 본질가치를 갖는가에 대한 의구심이 많아지고 있다. 논문[2]은 비트코인 가격이 투기적 거품(speculative bubble)을 형성하고 있으며, 본질가치는 0이라고 주장하고 있다. 논문[3]은 우리나라에서 거래되고 있는 비트코인 가격에 영향을 미치는 요인을 수급 요인, 경제적 요인, 그리고 심리적 요인 등으로 나누어서 분석한 결과 실물경제 변수에 영향을 받기보다는 포털 검색지수나 언론 기사 등 대중의 관심을 나타내는 심리적 요인에 더 강하게 영향을 받고 있다고 주장하였다.

본질가치가 없거나 논할 수 없는 상황에서 알트코인에 대한 투자의 접근방법은 기술적 분석 방법이 유용할 것이다[4]. 논문[5]은 현금 흐름이 발생하는 우량주식이나 채권과 달리 암호화폐나 신생 기업 또는 소규모 기업과 같은 자산은 본질 가치 산정이 어려운 자산으로 분류하고 기술적 지표를 이용하여 가격을 예측한 결과 비교모형보다 예측 성과가 높음을 보여주었다. 특히, 가격의 상승과 하락 폭이 큰 비트코인의 연구 결과들은 기술적 거래 규칙을 이용하여 높은 수익성을 산출할 수 있음을 밝히고 있다[6], [7].

본 연구의 목적은 국내 암호화폐 시장에서 알트코인의 가격 정보와 기술적 지표(technical indicators)를 이용하여 알트코인의 미래 가격을 예측하고, 예측 성과의 경제적 가치(economic value)를 실증 분석하고자 한다. 특히, 비트코인과 알트코인 간의 상호 작용이 존재한다는 연구에 기초하여 비트코인의 기술적 지표도 입력변수로 활용한다[8].

한국 암호화폐 시장은 김치 프리미엄(kimchi premium)이라는 가격 구조를 보임에 따라 다른 나라의 암호화폐와 일정 부분 독립적인 가격 요소를 포함하고 있어, 국내 알트코인의 가격을 분석하는 것은 의미가 크다고 판단된다. 본 연구의 결

과는 폭등과 폭락을 거듭하는 암호화폐 가격에 휘둘러 부화뇌동 매매에 빠진 투자자들에게 정확한 가격 예측과 안정적인 수익이 나타나는 실전적 투자전략에 대한 정보를 제공할 수 있을 것이다.

## II. 이론적 배경

### 2-1 알트코인과 비트코인

비트코인의 등장 이후 많은 암호화폐가 개발되어 암호화폐 거래소에서 거래되고 있다. 이에 따라 암호화폐 시장에서 비트코인이 차지하는 시가총액의 비중도 하락하고 있지만 2022년 9월 말 기준 41.11%를 차지하고 있어 암호화폐 시장에서 지배적인 역할을 하고 있다[9]. 논문[8]은 비트코인과 알트코인 시장이 상호 의존적이며, 이러한 관계는 장기보다는 단기에서 더 강하다는 것을 보여주었다. 논문[10]은 비트코인 가격이 리플과 라이트코인 가격에 영향을 미침을 밝히고 비트코인이 암호화폐 시장에서 중심 역할을 함을 보여주었다. 논문[11]은 비트코인의 가격이 하락하는 경우 알트코인의 가격에 더 강하게 영향을 미치는 비대칭적 관계를 밝혔고, 특히 그 영향력은 2017년의 암호화폐 가격 폭락 이후 더 자주 나타남을 보여주었다.

논문[12]은 암호화폐 시장의 가격 급변동 국면에서 비트코인과 대시, 이더리움과 라이트코인, 리플과 스텔라 사이에 강한 연관성이 있음을 보여주었다. 논문[13]은 COVID-19 팬데믹 국면에서 비트코인과 알트코인 가격을 분석한 결과 유의적인 집단행동(herding behavior) 특성이 있음을 밝혔다. 논문[14]은 LSTM, CNN, GRU(Gated Recurrent Unit) 딥러닝 모형을 이용하여 이더리움의 가격을 예측하고, LSTM 모형의 가격 예측력이 가장 우수함을 밝혔다.

논문[15]은 기술적 거래 규칙을 이용하여 알트코인의 투자 전략을 제안하고 리플, 이더리움, 비트코인캐시, 에이다, 라이트코인에 대한 실증 분석을 통해 추세 추종형 투자전략이 높은 수익성을 보임을 밝혔다. 논문[16]은 감성분석과 딥러닝 기반의 비트코인 수익률 변동 예측 통합모형을 이용하여 예측모형의 성과가 우수함을 보여주었다. 논문[17]은 비트코인의 수익률 예측에서 요인 증강 기법(factor augmentation)을 통해 비트코인 가격 예측의 정확성을 높였다. 논문[18]은 LSTM 모형 기반 암호화폐 가격 예측을 위한 입력변수들의 중요도를 분석한 결과, 암호화폐의 시가, 고가, 저가, 종가, 거래량 정보를 조합했을 때 가장 우수한 예측 성과가 나타남을 보였다. 논문[19]은 뉴스 기사를 이용하여 한국과 미국에서 거래되고 있는 비트코인의 가격을 예측한 결과 RNN(Recurrent Neural Network) 모형의 예측력이 우수함을 밝혔다.

### 2-2 기술적 지표

기술적 분석은 과거의 주가나 거래량을 이용하여 기술적 지표(technical indicators)를 산출하고 이를 이용하여 미래 가격 움직임을 예측하려는 통계적인 분석 방법이다. 기술적 지표는 본질가치가 없거나 주식보다 본질가치를 산출하기 어려운 암호화폐 등의 가격 예측에서 유용성이 크다고 할 수 있다[4], [5], [8].

기술적 지표를 이용한 암호화폐의 거래는 암호화폐의 과거 자료로부터 통계적 검증이 가능하며, 투자자의 감정을 배제하고 거래를 실행할 수 있는 장점이 있다. 기술적 지표는 추세 지표(trend-following indicators)와 역추세 지표(anti-trend indicators)로 나누어진다. 추세지표는 가격의 추세(trend)를 파악하여 추세의 방향으로 가격이 움직일 것으로 가정하며, 역추세 지표는 가격의 상승이나 하락이 충분히 진행된 시점에서 추세가 역전될 것으로 가정하는 지표이다. 대표적인 추세지표와 역추세 지표는 이동평균선과 스톡스틱 지표이다[15].

논문[5]은 본질가치를 측정하기 어려운 비트코인이나 소형 주식 또는 신생 주식 등의 가격 예측에서 이동평균선과 같은 기술적 지표를 이용하면 예측 성과가 개선됨을 보여주었다. 논문[20]은 2016년부터 2018년까지의 비트코인과 알트코인에 대한 이동평균선을 이용한 투자전략의 성과를 분석하고 시장의 평균 수익보다 더 높은 수익성이 나타남을 보여주었다. 논문[21]은 이동평균선과 돌파 지표를 이용하여 암호화폐의 수익성을 분석한 결과, 거래비용을 고려하는 경우 이더리움, 리플, 라이트코인의 수익성은 비교전략보다 수익성이 높음을 보여주었다.

주식시장보다 변동성이 큰 암호화폐 시장의 가격 예측에서는 추세지표의 예측 성과가 높게 나타나고 있다[6], [15]. 논문[22]은 기술적 지표를 이용하여 비트코인의 가격을 예측한 결과 일별 자료(daily data)에서는 예측력이 높게 나타나고 있으나 분별 자료(minute data)에서는 예측 성과가 높지 않음을 보여주었다.

### 2-3 기계학습 알고리즘

최근에 와서 주가나 암호화폐와 같은 비선형적이며 불규칙한 변동 특성을 보이는 자산 가격의 예측에서 기계학습 알고리즘의 활용이 확대되고 있다. 논문[23]의 조사에 의하면 암호화폐의 가격 예측에서는 LSTM(Long Short-Term Memory), ANN(Artificial Neural Network), SVM(Support Vector Machines), RF(Random Forest), Regression Models 등이 자주 활용되고 있음을 밝혔다. 논문[24]은 비트코인의 5분 봉 예측에서 RF, XGBoost(eXtreme Gradient Boosting), SVM, LSTM 모형의 성과가 전통적인 통계적 모형보다 우수함을 보여주었다. 논문[25]은 RF와 LR(Logistic Regression) 모형을 이용하여 비트코인의 가격을 예측한 결과 RF 알고리즘이 LR 모형보다 예측 정확도가 더 높음을 보여주었다. 논문[26]은 비트

코인의 1분 단위의 단기 가격 예측에서 LSTM 모형이 RF, GRU, LR, XGBoost, FNN(Feedforward Neural Networks) 모형보다 예측력이 우수함을 보여주었다. 논문[27]은 DCN(Deep Cross Networks) 기반 앙상블 기법을 융합한 하이브리드 기계학습 모형을 제안하고 비트코인 가격 예측의 성과가 우수함을 보여주었다.

## III. 자료와 예측모형 소개

### 3-1 자료 소개

본 연구에서는 2017년 9월 24일 기준 시가총액 상위 그룹에 있는 암호화폐 중 이더리움(Etherium), 비트코인캐시(Bitcoin Cash), 리플(Ripple), 님(Nem)과 비트코인을 분석하였다. 이더리움, 비트코인캐시, 리플, 님과 비트코인에 대한 심볼은 각각 ETH, BCH, XRP, XEM, BTC로 표시한다. 비트코인과 알트코인의 시가총액 자료는 암호화폐 가격 정보 제공업체인 코인마켓캡에서 구하였다(<https://coinmarketcap.com>). 알트코인과 비트코인 가격 자료는 국내 최대 암호화폐거래소인 업비트거래소([www.upbit.com](http://www.upbit.com))에서 수집하였다. 자료의 수집 기간은 2017년 9월 26일부터 2022년 9월 30일까지이며, 일별 시가(open price), 고가(high price), 저가(low price), 그리고 종가(close price) 자료를 수집하였다.

<표 1>은 암호화폐에 대한 시가총액과 분석 기간에서의 가격 정보를 보여주고 있다.

표 1. 암호화폐의 기본 정보

Table 1. Basic Informations on Cryptocurrencies

Symbol	Market cap.	First Price	Last Price	Price Change
ETH	26,780	325,000	1,910,500	488%
BCH	6,994	493,500	166,900	-66%
XRP	6,740	203	697	243%
XEM	1,945	256	59.3	-77%
BTC	61,082	4,322,000	28,033,000	549%

\* Market cap.: market capitalization value(million \$) as of 2017.09.26.

\* First Price : Price as of 2017.09.26.

\* Last Price : Price as of 2022.09.30.

\* Price Change : Price change rate from first price to last price

분석 기간에서 비트코인은 4,322,000원에서 28,033,000원으로 상승하면서 549%의 상승률을 보였지만 알트코인은 종류별로 가격의 변동이 큰 차이를 보였다. 이더리움과 리플은 각각 488%와 243%의 가격 상승을 기록하였고 비트코인캐시와 님은 각각 -66%와 -77%의 가격 폭락이 나타났다.

<그림 1>은 자료의 전체 분석 기간에서 암호화폐의 가격 변동추세를 보여주고 있다.

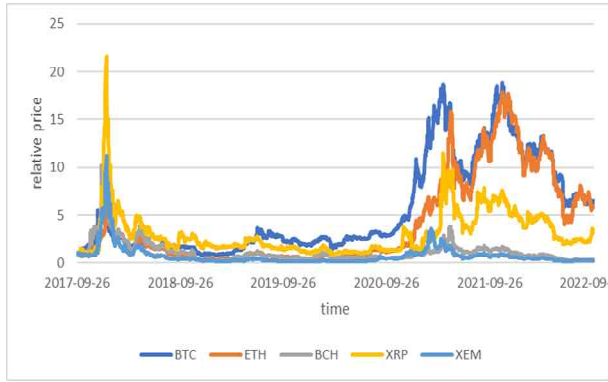


그림 1. 암호화폐 가격 추이(2017.9.26.=1원 기준)

Fig. 1. Price Trends(1 won as of 2017.09.26.)

자료의 분석 기간에서 비트코인과 알트코인들은 2018년, 2020년, 2021년 등에서 큰 폭의 가격 상승과 폭락 상황이 발생하고 있다.

본 연구에서는 알트코인의 일별 증가를 예측하기 위하여 해당 알트코인의 과거 시가, 고가, 저가 정보를 기본적인 입력 변수(input variables)로 한다. 추가적인 입력변수로는 해당 알트코인의 과거 가격을 이용하여 산출하는 기술적 지표이다.

기술적 지표 중 추세지표로는 MACD(Moving Average Convergence and Divergence), DMI(Directional Movement Index), MTM(Momentum), 역추세 지표로는 RSI(Relative Strength Index), STO(Stochastics), CCI(Commodity Channel Index) 지표를 선택하였다. 추세 지표는 가격이 움직이는 방향으로 더 움직일 것으로 예상하는 지표이며, 역추세 지표는 가격이 어느 한 방향으로 충분히 움직인 후 역전되는 성질을 이용하는 지표이다.

제안된 지표들은 실제 주식시장에서 가장 많이 활용하고 있는 기술적 지표들이며, 지표 계산을 위한 파라미터는 최적화 위험을 피하기 위해 주식시장에서 적용되는 기본값으로 산출하였다.

논문[10]은 비트코인 가격이 알트코인 가격에 유의적인 영향을 미치고 있음을 밝혔다. 알트코인의 가격을 예측하기 위해 본 연구에서도 비트코인의 기술적 지표를 입력변수로 활용한다.

이상을 종합하면, 알트코인의 가격 예측을 위한 본 연구의 목표변수(target variable)는 해당 알트코인의 일별 증가, 입력변수는 해당 알트코인의 일별 시가, 고가, 저가, 해당 알트코인의 일별 6개 기술적 지표, 비트코인의 일별 6개 기술적 지표를 포함하여 총 15개의 특성 변수(feature variables)이다.

기술적 지표의 초기치 계산에 필요한 기간을 고려하여 실제 가격 예측을 위한 입력변수의 시작 시점은 2018년 1월 1일로 정하였다. 따라서 실제 분석 기간은 2018년 1월 1일부터 2022년 9월 30일까지의 1,734일이다.

### 3-2 예측모형 소개

본 연구에서는 대표적 기계학습 알고리즘인 RF, XGBoost(XGB), SVR(Support Vector Regression),

LSTM 모형을 이용하여 알트코인의 가격을 예측한다. RF와 XGB는 앙상블 학습 알고리즘이며, SVR은 주가나 암호화폐의 가격과 같은 시계열 자료의 예측에서 유용성이 큰 것으로 밝혀지고 있다[28].

의사결정나무(decision tree) 기법은 입력값에 대한 예측값을 찾아가는 과정을 하나의 나무 구조로 나타낸 모형으로서 수립하기가 쉽고 직관적이지만 과 최적화될 확률이 높다. 이를 해결하기 위해 다수의 의사결정나무를 생성하고 각 의사결정나무 모형의 예측값을 종합하여 가장 많은 부류를 최종 예측값으로 결정하는 기법이 RF 알고리즘이다[29].

XGB는 의사결정나무의 부스팅(boosting) 기법을 개선한 알고리즘이다. 부스팅이란 많은 약한 분류기를 결합하여 강한 분류기를 만드는 장점을 보이는 앙상블 기법이지만 속도가 느리다는 단점이 있다. XGB는 느린 학습 속도를 개선한 알고리즘으로 약한 분류기를 개선해 나가는 과정에서 탐욕적 알고리즘(greedy algorithm)을 사용하여 분류 모형을 발견하고 분산처리를 통해 최적의 가중치를 계산한다[30]. 앙상블 학습모형은 중요 특성 변수를 추출할 수 있는 알고리즘이 내장되어 있다. XGB는 각 특성 변수가 의사결정수 갈라치기에서 몇 번씩 나타나는지를 구하는 F-score를 제공하고 있어서 XGB 알고리즘을 이용하면 수많은 특성 변수에서 상대적으로 중요도가 높은 특성 변수를 추출하고 중복되는 특성 변수는 제거할 수 있다[31]. 논문[31]은 XGBoost에 기반하여 특성 변수를 추출하고 LSTM 딥러닝 모형의 입력변수로 활용하여 EUR/USD 환율 자료를 이용하여 예측한 결과 성과가 크게 개선됨을 보여주었다.

SVR은 기존의 인공신경망과 유사한 학습 알고리즘이면서도 복잡하고 불규칙적으로 움직이는 주가와 같은 시계열 자료 예측과 같은 문제를 해결하는데 적합한 알고리즘이다 [28]. SVR 알고리즘은 구조적 위험의 최소화를 통해 일반화 특성을 잘 보여준다. 논문[28]은 SVR을 이용하여 코스피 200 주가지수 변동성 모형의 모수를 추정하고 실증 분석한 결과 주식시장 변동성을 유의적으로 예측하였다. 논문[32]은 SVR을 이용하여 인도증권거래소의 주가를 예측하고 포트폴리오를 구성한 결과 비교모형보다 10% 이상 더 높은 수익률을 달성하였다.

LSTM 알고리즘은 주가나 암호화폐와 같은 시계열 자료의 예측에서 그 유용성이 크다[33]. 특히, LSTM 알고리즘은 시계열 자료의 시차(lag)가 길어질 때 발생하는 기울기 소실 문제를 잘 해결할 수 있도록 개선된 RNN 모형의 하나로서, cell state를 추가하여 주가와 같은 과거 정보의 장기 의존성 문제(long memory)를 잘 해결하고 있다[33]. 이에 따라 최근에는 LSTM 모형을 이용한 주가, 전력사용량, 원유 가격과 같은 다양한 시계열 자료의 예측 연구가 활발히 진행되고 있다 [34]-[36].

### 3-3 실험 설계

본 연구의 분석 기간은 2018년 1월 1일부터 2022년 9월 30일까지의 1,734일이며, 이 중 2018년 1월 1일부터 2021년 4월 28일까지 1,214일은 학습용 데이터, 2021년 4월 29일부터 2022년 9월 30일까지의 520일은 검증용 데이터로 활용한다. 실험은 Python 3.8.5 환경에서 Tensorflow와 Keras를 사용하여 수행하였다. 본 연구의 실험은 크게 2단계로 구분하여 진행된다.

실험 1단계에서는 학습용 데이터에 대한 XGB 알고리즘의 학습을 통해 산출된 특성 변수 중요도(feature's importance)를 분석하여 중요도 높은 특성 변수를 선택하는 과정이다. 알트코인 가격 예측의 입력변수는 해당 알트코인의 시가, 고가, 저가와 해당 알트코인의 기술적 지표 MACD, MMT, DMI, RSI, STO, CC, 비트코인의 기술적 지표 MACD, MMT, DMI, RSI, STO, CCI 등 총 15개이다. 알트코인의 일별 증가 예측에서 특성 변수의 중요도를 XGB의 F-score 분석을 통해 중요 특성 변수를 선택한다.

실험 2단계에서는 1단계에서 선택된 특성 변수를 입력변수로 하는 기계학습 알고리즘을 이용하여 학습용 데이터에서 최적해를 찾고, 최적화된 알고리즘을 검증용 데이터에 적용하여 알트코인의 다음 날의 일별 증가를 예측한다. 예측값과 실제 값을 비교하여 알고리즘의 예측 성과를 비교할 것이다.

특성 변수들은 정규화를 거친 후 입력변수로 활용하였다. 정규화는 Python의 MinMaxScaler를 이용하였으며, 정규화 수식은 식 (1)과 같다.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)}, \tag{1}$$

where  $x'$  and  $x$  are normalized values and historical values of feature variables.

예측 성과의 비교를 위해 성과 비교의 대표적인 척도인 평균 제곱근 오차(Root Mean Square Error; RMSE)를 이용하였다. RMSE는 식 (2)와 같이 계산한다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (y_t - y'_t)^2}, \tag{2}$$

where  $y_t$  and  $y'_t$  are actual values and predicted values for close price on day  $t$ .

<그림 2>는 실험 진행 과정을 도표화하여 보여주고 있다.




그림 2. 실험 진행 과정  
Fig. 2. Experiment Process

## IV. 실험 결과 분석

### 4-1 특성 변수 중요도 분석

학습용 데이터 구간에서 알트코인 가격 예측을 위한 전체 15개 특성 변수를 해당 알트코인의 입력변수로 하는 XGB 알고리즘으로부터 feature importance를 산출하였으며, <그림 3>은 산출된 결과값을 도표로 보여주고 있다.

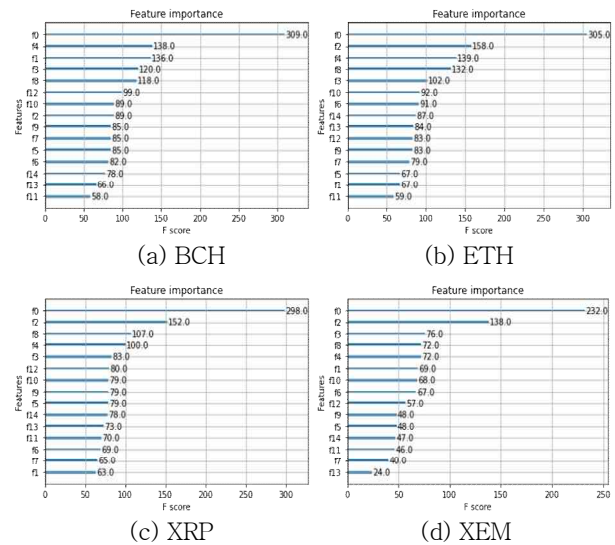


그림 3. 특성 변수 중요도 도표  
Fig. 3. Feature Variables Importance Chart

각 알트코인의 가격 예측에서 중요한 역할을 하는 특성 변수는 알트코인 별로 조금씩 차이를 보인다. 중요도 F-score는 최대 309에서 최소 24까지 분포하고 있다. 각 알트코인에서 100 이상의 F-score를 갖는 특성 변수를 선택하여 기계학습 알고리즘의 예측을 위한 입력변수로 활용한다. 알트코인 별로 중요도 순으로 선택된 특성 변수는 다음과 같다. BCH는 high, cci, open, macd, rsi, ETH는 high, low, cci, rsi, macd를 선택, XRP는 high, low, ris, cci XEM은 high, low를 선택한다.

특성 변수 중 high는 모든 알트코인의 가격 예측에서 가장 높은 F-score를 보여주고 있으며 다음으로는 low가 차지하고 있다. 기술적 지표에서는 cci, rsi, macd의 중요도가 높게 나타나고 있다. 특히, 본 연구에서 중요도가 높게 나타난 high 특성 변수의 역할은 최근 EUR/USD 환율 예측에서도 high price가 가장 높은 F-score를 보임을 밝힌 논문[31]의 연구 결과와도 일치하고 있다. 그러나 비트코인의 기술적 지표 특성 변수는 하나도 선택되지 않아 비트코인의 가격이 알트코인의 가격 결정에 중요하게 영향을 미친다는 기존 연구들과 차이를 보였다[37], [38].

4-2 기계학습 알고리즘을 이용한 가격 예측 결과 분석

특성 변수 중요도 분석을 통해 선택된 특성 변수를 입력변수로 하여 알트코인에 대한 학습용 데이터 구간에서 기계학습 알고리즘을 최적화하고 최적화 모형을 검증용 데이터 구간에 적용하여 예측 성과를 평가하였다. <표 2>부터 <표 5>까지는 알트코인별 예측 성과에 대한 평가지표 RMSE를 정리하였으며, <그림 4>에서 <그림 7>은 선택된 특성 변수를 입력변수로 하는 알고리즘 중 가장 우수한 예측 성과를 보이는 알고리즘에 의한 예측 가격과 실제 가격 움직임을 비교하여 표시하였다.

표 2. BCH 예측 성과

Table 2. Predictive Performance Metric RMSE on BCH

Features	XGB	LSTM	SVR	RF
All Features	0.0287 (0.0008)	0.0180 (0.0172)	0.0499 (0.0743)	0.0218 (0.0047)
Selected Features	0.0178 (0.0012)	<b>0.0144</b> (0.0168)	0.0372 (0.0588)	0.0153 (0.0060)
Exclude BTC	0.0283 (0.0009)	0.0150 (0.0191)	0.0487 (0.0738)	0.0209 (0.0047)

The values in parentheses indicate RMSE for the training data. Boldface represents the best performance.

BCH 가격 예측을 위해 선택된 특성 변수는 high, cci, open, macd, rsi이며, XGB, LSTM, SVR, RF 등 모든 알고리즘의 가격 예측에서 선택된 특성 변수를 입력변수로 하는 예측 성과가 가장 높게 나타났다. 알고리즘별 성과에서는 LSTM의 선택 특성 변수를 입력변수로 하는 예측 성과가 가장 우수한 결과를 보여주었다. 한편, BTC 특성 변수를 제외한 예측 성과가 BTC 특성 변수를 포함한 성과보다 더 높게 나타났다.




그림 4. LSTM 기반 BCH 예측 가격과 실제 가격  
Fig. 4. LSTM-based Predicted and Actual Price on BCH

표 3. ETH 예측 성과

Table 3. Predictive Performance Metric RMSE on ETH

Features	XGB	LSTM	SVR	RF
All Features	0.0217 (0.0007)	0.1117 (0.0150)	0.0512 (0.0754)	0.0369 (0.0050)
Selected Features	0.0219 (0.0011)	0.4463 (0.0135)	0.0499 (0.0789)	0.0400 (0.0048)
Exclude BTC	<b>0.0216</b> (0.0008)	0.4175 (0.0138)	0.0493 (0.0750)	0.0384 (0.0051)

The values in parentheses indicate RMSE for the training data. Boldface represents the best performance.

ETH 가격 예측을 위해 선택된 특성 변수는 high, low, cci, rsi, macd이며, 예측 알고리즘에 따라 결과가 차이를 보였다. 알고리즘별 성과에서는 XGB의 BTC 특성 변수를 제외한 예측 성과가 가장 우수한 결과를 보여주었다.




그림 5. XGB 기반 ETH 예측 가격과 실제 가격  
Fig. 5. XGB-based Predicted and Actual Price on ETH

표 4. XRP 예측 성과

Table 4. Predictive Performance Metric RMSE on XRP

Features	XGB	LSTM	SVR	RF
All Features	0.0386 (0.0007)	0.0223 (0.0160)	0.0722 (0.0532)	0.0692 (0.0055)
Selected Features	0.0286 (0.0012)	<b>0.0177</b> (0.0156)	0.0465 (0.0651)	0.0309 (0.0047)
Exclude BTC	0.0326 (0.0008)	0.0194 (0.0176)	0.0639 (0.0523)	0.0305 (0.0056)

The values in parentheses indicate RMSE for the training data. Boldface represents the best performance.

XRP 가격 예측을 위해 선택된 특성 변수는 high, low, rsi, cci이며, XGB, LSTM, SVR, RF 등 모든 알고리즘의 예측에서 선택된 특성 변수를 입력변수로 하는 예측 성과가 가장 높게 나타났다. 알고리즘별 성과에서는 LSTM의 선택 특성 변

수를 입력변수로 하는 예측 성과가 가장 우수한 결과를 보여주었다. 한편, BTC 특성 변수를 제외한 예측 성과가 BTC 특성 변수를 포함한 성과보다 더 높게 나타났다.

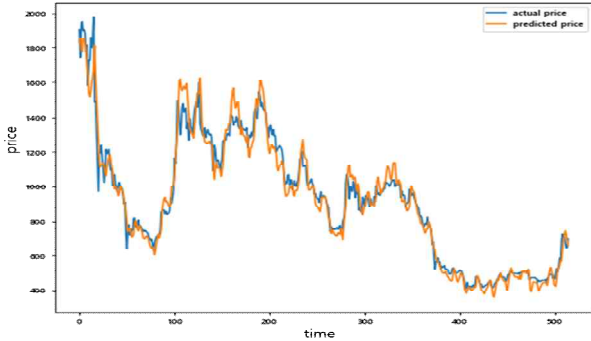


그림 6. LSTM 기반 XRP 예측 가격과 실제 가격  
Fig. 6. LSTM-based Predicted and Actual Price on XRP

표 5. XEM 예측 성과

Table 5. Predictive Performance Metric RMSE on XEM

Statistics	XGB	LSTM	SVR	RF
All Features	0.0362 (0.0007)	0.0081 (0.0118)	0.0977 (0.0541)	0.0251 (0.0047)
Selected	0.0295 (0.0014)	<b>0.0069</b> (0.0247)	0.0634 (0.0857)	0.0211 (0.0059)
Exclude BTC	0.0328 (0.0007)	0.0091 (0.0204)	0.0776 (0.0482)	0.0259 (0.0049)

The values in parentheses indicate RMSE for the training data. Boldface represents the best performance.

XEM 가격 예측을 위해 선택된 특성 변수는 high, low이며, XGB, LSTM, SVR, RF 등 모든 알고리즘의 예측에서 선택된 특성 변수를 입력변수로 하는 예측 성과가 가장 높게 나타났다. 알고리즘별 성과에서는 LSTM의 선택 특성 변수를 입력변수로 하는 예측 성과가 가장 우수한 결과를 보여주었다. 한편, BTC 특성 변수를 제외한 예측 성과가 BTC 특성 변수를 포함한 성과보다 더 높게 나타났다.




그림 7. LSTM 기반 XEM 예측 가격과 실제 가격  
Fig. 7. LSTM-based Predicted and Actual Price on XEM

BCH, XRP, XEM의 경우는 선택된 특성 변수만을 입력변수로 하는 LSTM 알고리즘의 예측 성과가 가장 좋은 결과를 보여주고 있다. 그러나 ETH의 경우는 나머지 3개의 알트코인과는 다르게 XGB 알고리즘의 성과가 더 높게 나타났다.

## V. 예측 가격을 활용한 투자전략의 성과 분석

### 5-1 투자전략의 제안

기계학습 알고리즘을 활용하여 알트코인에 대한 가격을 예측한 후 예측 가격을 이용하여 알트코인의 투자전략의 성과를 분석한다. 본 연구에서 활용할 투자전략은 알렉산더 필터 전략 AFR(Alexander Filter Rule)을 제안한다. AFR은 필터의 크기가 x% 라고 할 때, 가격이 저점에서 x% 이상 상승하면 매수하고, 매수포지션 진입 이후 고점에서 x% 이상 하락하면 하락 전환으로 인식하여 포지션을 매도하는 기계적인 거래전략(mechanical trading strategy)이다[39], [40].

<그림 3>은 AFR 전략의 매수와 매도의 진입 방법을 도식화하여 보여주고 있다.

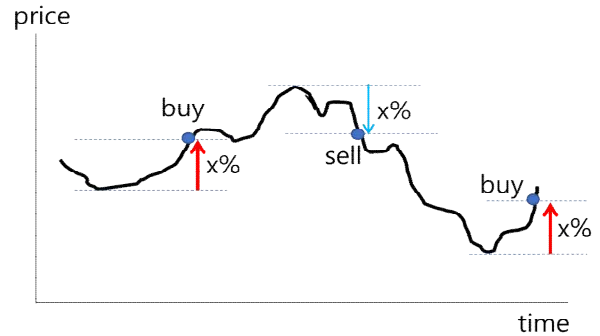


그림 8. 알렉산더 필터 룰(x% 필터)  
Fig. 8. Alexander Filter Rule(x% filter)

표 6. 알렉산더 필터 전략의 포지션 진입과 청산 규칙  
Table 6. Entry and Exit Rules on AFR Strategy

Strategy	Entry Rule	Exit Rule
AFR1	Buy if $PP > PP\_B \cdot (1+x/100)$	Exit if $PP < PP\_T \cdot (1-x/100)$
AFR2	Buy if $AP > AP\_B \cdot (1+x/100)$	Exit if $AP < AP\_T \cdot (1-x/100)$
AFR3	Buy if $PP > PP\_B \cdot (1+x/100)$	Sell if $PP < PP\_T \cdot (1-x/100)$
AFR4	Buy if $AP > AP\_B \cdot (1+x/100)$	Sell if $AP < AP\_T \cdot (1-x/100)$
B&H	Buy on First Day	Exit on Last Day

PP: Predicted Price, PP\_B: PP Bottom, PP\_T: PP Top  
AP: Actual Price, AP\_B: AP Bottom, AP\_T: AP Top  
BH: Buy and Hold Strategy

<표 6>은 본 연구에서 제안하는 AFR 전략을 보여주고 있다. AFR1과 AFR3는 예측 가격을 이용하여 매수와 매도 진입 조건을 계산하는 전략이고, AFR2와 AFR4는 실제 가격을 이용하여 매수와 매도 진입 조건을 계산하는 전략이다. AFR1과 AFR2는 매수포지션만 진입을 허용하는 매수전략(long only strategy)이며, AFR3와 AFR4는 매도포지션도 진입을 허용한 양방향 전략이다.

AFR1은 예측 가격이 저점에서 x% 상승하면 해당 알트코인을 매수하고, 예측 가격이 고점에서 x% 하락하면 매수포지션을 청산하는 매수전략(long only strategy)이다. AFR3은 알트코인의 예측 가격이 저점에서 x% 상승하면 매수하고 반대로 예측 가격이 고점에서 x% 하락하면 매수포지션을 청산함과 동시에 신규로 매도포지션을 진입하는 양방향 진입전략이다. AFR2는 실제 가격이 저점에서 x% 상승하면 해당 알트코인을 매수하고, 고점에서 x% 하락하면 매수포지션을 청산하는 매수전략이며, AFR4는 실제 가격이 저점에서 x% 상승하면 해당 알트코인을 매수하고 반대로 고점에서 x% 하락하면 매수포지션을 청산함과 동시에 신규로 매도포지션을 진입하는 양방향 진입전략이다. 제안된 모든 투자전략의 성과 평가를 위한 포지션 진입과 청산 가격은 실제 알트코인 가격을 기준으로 가정하였다. B&H는 거래 첫날 매수 후 마지막 날까지 보유하는 단순 매수 후 보유 전략으로, 제안된 투자전략에 대한 벤치마크 전략(benchmark strategy)이다.

5-2 투자전략의 성과 분석

예측모형에 의하여 산출된 예측 가격이 경제적 가치를 갖는지를 판단하기 위하여 2021년 4월 29일부터 2022년 9월 30일까지의 검증용 데이터 기간에서 제안된 투자전략의 성과를 분석한다.

<그림 9>는 필터 크기에 따른 알트코인별 AFR1과 AFR3 전략에 대한 수익의 크기를 비교하여 보여주고 있다.

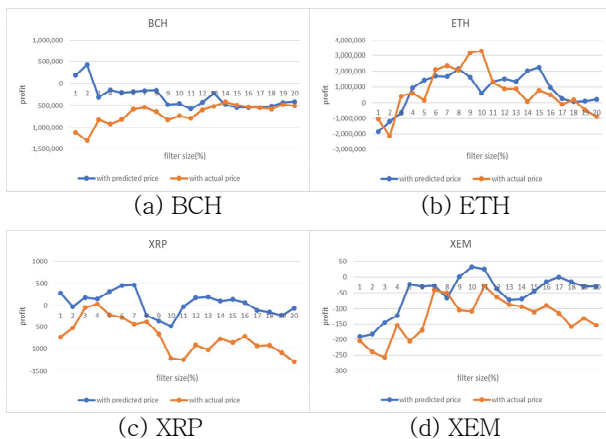


그림 9. 필터 크기에 따른 AFR1과 AFR2 전략의 수익 비교  
 Fig. 9. AFR1 and AFR2 Strategy Profit by Filter Size

<그림 9>는 long only 전략에서 with predicted price는 예측 가격 필터 기반 진입전략의 수익성, with actual price는 실제 가격 필터 기반 진입전략의 수익성을 표시한다. 투자 성과는 ETH를 제외하면 예측 가격 기반 진입전략의 성과가 실제 가격 기반 진입전략의 성과보다 높게 나타나고 있다. 필터 크기는 5~10%에서 비교적 안정적인 수익성을 보였다.

<표 7>은 5% 필터를 적용하는 경우 예측 가격 기반 진입 전략과 실제 가격 기반 진입전략의 수익성을 비교하여 보여 주고 있다.

표 7. 알렉산더 필터 전략(5% 필터)의 수익성 비교(단위: 원)  
 Table 7. AFR(5% filter) Strategy Performance(unit: won)

Strategy	BCH	ETH	XRP	XEM
AFR1	-200.750	1,428,500	325	-23
AFR2	-811,900	166,500	-203	-206
AFR3	1,283,100	4,531,500	1,768	360
AFR4	33,000	1,981,500	642	-81
B&H	-1,079,600	-1,302,500	-1,208	-364.7

매수전략인 AFR1과 AFR2의 성과를 비교하면 모든 알트코인에서 예측 가격에 기반한 포지션 진입전략 AFR1의 투자 성과가 높게 나타났다. 또한, 매수와 매도 포지션 진입이 모두 가능한 양방향 전략 AFR3와 AFR4의 성과를 비교하여도 예측 가격에 기반한 포지션 진입전략인 AFR3의 투자 성과가 높게 나타났다. Long only 전략인 AFR1과 AFR2보다 양방향 진입이 가능한 AFR3와 AFR4의 성과가 높다. 이러한 양방향 진입전략은 현물 알트코인에서는 실행 불가능한 전략이지만, perpetual swap과 같은 알트코인의 선물상품에서는 활용할 수 있다. 한편, 제안된 모든 투자전략의 성과는 벤치마크 전략인 B&H의 성과보다 높게 나타나, 기계학습 알고리즘을 이용한 알트코인의 예측 가격은 경제적 가치가 있음을 보여주었다.

VI. 결 론

비트코인의 등장으로 시작된 암호화폐 시장은 많은 종류의 알트코인이 나타나면서 거대한 시장으로 발전하고 있다. 본 연구는 비트코인과 비교하여 그동안 연구가 많이 이루어지지 않은 알트코인에 대한 가격 예측을 목표로 진행하였다. 특히, 불규칙적이고 비선형적으로 움직이는 알트코인의 가격 예측에 적합한 것으로 알려진 기계학습 알고리즘을 이용하여 예측의 정확도를 높이고, 예측 결과를 이용하면 경제적 가치를 창출할 수 있는지까지 분석하였다.

분석대상 알트코인은 이더리움, 비트코인캐시, 리플, 그리고 님 등이며 분석 기간은 2018년 1월 1일부터 2022년 9월



30일까지이다. 일별 자료를 이용하여 알트코인의 가격을 예측하기 위하여 일별 시가, 고가, 저가와 기술적 지표인 MACD, Momentum, DMI, RSI, Stochastics, CCI 정보를 입력변수로 하여 기계학습 알고리즘을 통해 종가를 예측하였다. 암호화폐 시장에서는 가장 비중이 큰 비트코인의 영향력이 큰 것으로 밝혀지고 있어 비트코인의 기술적 지표도 입력변수로 추가하였다. 기계학습 알고리즘에는 Random Forest, Support Vector Regression, XGBoost, LSTM이 포함된다.

실증 분석 결과는 다음과 같다. 첫째, XGBoost 알고리즘을 이용하여 15개 특성 변수의 상대적 중요도를 파악한 결과, 해당 알트코인의 하루 중의 고가의 중요도가 가장 높게 나타났다. 둘째, 비트코인이 알트코인의 가격에 미치는 영향력은 상대적으로 약하게 나타났다. 셋째, 기계학습 알고리즘의 알트코인 가격 예측 정확도는 이더리움을 제외하면 LSTM이 가장 높게 나타나 시계열 자료의 예측에서 LSTM 모형의 유용성이 밝혀졌다. 넷째, 예측 가격을 이용한 알렉산더 필터 전략의 성과가 높게 나타나 기계학습 알고리즘의 예측 결과는 높은 경제적 가치가 있음을 보여주었다.

본 연구는 다양한 기계학습 알고리즘을 통해 소위 김치 프리미엄이 있는 국내 알트코인의 가격 예측을 시도하고, 실제 투자자들에게 예측 결과가 경제적 가치가 있음을 보여주었다는 점에서 학술적, 실무적 의의가 크다고 할 수 있다. 그러나 암호화폐 가격은 여러 외부 요인에 따라 변동이 심한 특성으로 인해 정확한 가격 예측은 일정한 한계점을 가지고 있다. 또한 이더리움의 예측 결과가 비교적 시가총액 규모가 작은 비트코인캐시, 리플, 님 등의 예측 결과와 왜 다른지에 대한 추가적인 설명을 하지 못한 점은 본 연구의 한계점이다. 제안된 알렉산더 필터 전략의 투자 성과를 분석하면서 실제 투자에 수반되는 거래비용을 고려하지 못하였다는 점 역시 본 연구의 한계점이다. 향후 연구에서는 다양한 기계학습 알고리즘을 추가하고, 하이퍼파라미터(hyper-parameters)의 최적화 과정 등을 통해 가격 예측의 정확성을 개선할 필요가 있다.

## 참고문헌

- [1] J. L. Bettman, S. J. Sault, and E. L. Schultz, "Fundamental and technical analysis: substitutes or complements?" *Accounting and Finance*, Vol. 49, pp. 21-36, January 2009. <https://doi.org/10.1111/j.1467-629x.2008.00277.x>
- [2] E. T. Cheah and J. Fry, "Speculative bubbles in Bitcoin markets? An empirical investigation into the fundamental value of Bitcoin," *Economics Letters*, Vol. 130, pp. 32-36, May 2015. <https://doi.org/10.1016/j.econlet.2015.02.029>
- [3] K. K. Lee, S. Cho, G. Min, and C. W. Yang, "The determinant of Bitcoin prices in Korea," *Korean Journal of Financial Studies*, Vol. 48, No. 4, pp. 393-415, August 2019. <https://doi.org/10.26845/KJFS.2019.08.48.4.393>
- [4] R. Adcock and N. Gradojevic, "Non-fundamental, non-parametric Bitcoin forecasting," *Physica A*, Vol. 531, 121727, pp. 1-10, October 2019. <https://doi.org/10.1016/j.physa.2019.121727>
- [5] A. Detzel, H. Liu, J. Strauss, G. Zhou, and Y. Zhu, "Learning and predictability via technical analysis: Evidence from bitcoin and stocks with hard-to-value fundamentals," *Financial Management*, Vol. 50, No. 1, pp. 107-137, March 2021. <https://doi.org/10.1111/fima.12310>
- [6] S. W. Kim, "Profitability of trading system for cryptocurrency," *Journal of Digital Contents Society*, Vol. 22, No. 3, pp. 555-562, March 2021. <https://doi.org/10.9728/dcs.2021.22.3.555>
- [7] D. F. Gerritsen, E. Bouri, E. Ramezanifar, and D. Roubaud, "The profitability of technical trading rules in the Bitcoin market," *Finance Research Letters*, Vol. 34, 101263, pp. 1-10, May 2020. <https://doi.org/10.1016/j.frl.2019.08.011>
- [8] P. Ciaian, M. Rajcaniova, and A. Kancs, "Virtual relationships: Short- and long-run evidence from Bitcoin and altcoin markets," *Journal of International Financial Markets, Institutions & Money*, Vol. 52, pp. 173-195, January 2018. <https://doi.org/10.1016/j.intfin.2017.11.001>
- [9] <https://kr.tradingview.com/symbols/BTC.D/>
- [10] S. Corbet, A. Meegan, C. Larkin, B. Lucey, and L. Yarovaya, "Exploring the dynamic relationships between cryptocurrencies and other financial assets," *Economics Letters*, Vol. 165, pp. 28-34, April 2018. <https://doi.org/10.1016/j.econlet.2018.01.004>
- [11] E. Demir, S. Simonyan, C. Garcia-Gomez, and C. K. M. Lau, "The asymmetric effect of bitcoin on altcoins: evidence from the nonlinear autoregressive distributed lag model," *Finance Research Letters*, Vol. 40, 101754, pp. 1-6, May 2021. <https://doi.org/10.1016/j.frl.2020.101754>
- [12] E. C. Cagli, "Explosive behavior in the prices of Bitcoin and altcoins," *Finance Research Letters*, Vol. 29, pp. 398-403, June 2019. <https://doi.org/10.1016/j.frl.2018.09.007>
- [13] P. E. Mandaci and E. C. Cagli, "Herding intensity and volatility in cryptocurrency markets during the COVID-19," *Finance Research Letters*, Vol. 46, 102382, pp. 1-7, May 2022. <https://doi.org/10.1016/j.frl.2021.102382>
- [14] T. Zoumpikas, E. Houstis, and M. Vavalis, "ETH analysis and predictions utilizing deep learning," *Expert Systems with Applications*, Vol. 162, 113866, pp. 1-15, August 2020. <https://doi.org/10.1016/j.eswa.2020.113866>
- [15] S. W. Kim, "Performance on altcoin investment using technical trading rules," *Journal of the Korea*

- Academia-Industrial Cooperation Society*, Vol. 23, No. 6, pp. 198-207, June 2022.  
<https://doi.org/10.15762/KAIS.2022.23.6.198>
- [16] E. Kim, "An integrated model for predicting changes in cryptocurrency return based on news sentiment analysis and deep learning," *Knowledge Management Research*, Vol. 22, No. 2, pp. 19-32, June 2021.  
<https://doi.org/10.15813/kmr.2021.22.2.002>
- [17] Y. Yeom, Y. Han, J. Lee, S. Park, J. Lee, and C. Baek, "Factor augmentation for cryptocurrency return forecasting," *The Korean Journal of Applied Statistics*, Vol. 35, No. 2, pp. 189-201, April 2022.  
<https://doi.org/10.5351/KJAS.2022.35.2.189>
- [18] J. Park and Y. S. Seo, "Understanding the association between cryptocurrency price predictive performance and input features," *KIPS Transactions on Software and Data Engineering*, Vol. 11, No. 1, pp. 19-28, January 2022.  
<https://doi.org/10.3745/KTSDE.2022.11.1.19>
- [19] J. Won and T. Hong, "The prediction of cryptocurrency on using text mining and deep learning techniques: Comparison of Korean and USA market," *Knowledge Management Research*, Vol. 22, No. 2, pp. 1-17, June 2021. <https://doi.org/10.15813/kmr.2021.22.2.001>
- [20] K. Grobys, S. Ahmed, and N. Sapkota, "Technical trading rules in the cryptocurrency market," *Finance Research Letters*, Vol. 32, 101396, pp. 1-7, January 2020. <https://doi.org/10.1016/j.frl.2019.101396>
- [21] D. Svogun and W. Bazan-Palomino, "Technical analysis in cryptocurrency markets: Do transaction costs and bubble matter?," *Journal of International Financial Markets, Institutions & Money*, Vol. 79, 101601, pp. 1-13, June 2022. <https://doi.org/10.1016/j.intfin.2022.101601>
- [22] N. Gradojevic, D. Kukolj, R. Adcock, and V. Djakovic, "Forecasting Bitcoin with technical analysis: A not-so-random forest?," *International Journal of Forecasting*, Article in Press, September 2021. <https://doi.org/10.1016/j.ijforecast.2021.08.001>
- [23] A. M. Khedr, I. Arif, P. Raj, 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, January/March 2021. <https://doi.org/10.1002/isaf.1488>
- [24] Z. Chen, C. Li, and W. Sun, "Bitcoin price prediction using machine learning: An approach to sample dimension engineering," *Journal of Computational and Applied Mathematics*, Vol. 365, 112395, pp. 1-13, February 2020. <https://doi.org/10.1016/j.cam.2019.112395>
- [25] S. A. Basher and P. Sadorsky, "Forecasting Bitcoin price direction with random forests: How important are interest rates, inflation, and market volatility?," *Machine Learning with Applications*, Vol. 9, 100355, pp. 1-19, June 2022. <https://doi.org/10.1016/j.mlwa.2022.100355>
- [26] P. Jaquart, D. Dann, and C. Weinhardt, "Short-term bitcoin market prediction via machine learning," *The Journal of Finance and Data Science*, Vol. 7, pp. 45-66, November 2021. <https://doi.org/10.1016/j.jfds.2021.03.001>
- [27] P. K. Nagula and C. Alexakis, "A new hybrid machine learning model for predicting the bitcoin price," *Journal of Behavioral and Experimental Finance*, Vol. 36, 100741, pp. 1-13, August 2022. <https://doi.org/10.1016/j.jbef.2022.100741>
- [28] S. W. Kim and H. S. Choi, "Estimation of GARCH models and performance analysis of volatility trading system using Support Vector Regression," *Journal of Intelligence and Information Systems*, Vol. 23, No. 2, pp. 107-122, June 2017. <https://doi.org/10.13088/jiis.2017.23.2.107>
- [29] S. Kim and C-H., Jihn, "A convergent study on deriving an optimal idea for a movie scenario using the random forest," *The Korean Society of Science & Art*, Vol. 39, No. 5, pp. 37-47, December 2021. <https://doi.org/10.17548/ksaf.2021.12.30.37>
- [30] Y. Kim, H. S. Choi, and S. W. Kim, "A study on risk parity asset allocation model with XGBoost," *Journal of Intelligence and Information Systems*, Vol. 26, No. 1, pp. 135-149, March 2020. <https://doi.org/10.13088/jiis.2020.26.1.135>
- [31] P. H. Vuong, T. T. Dat, T. K. Mai, P. H. Uyen, and P. T. Bao, "Stock price forecasting based on XGBoost and LSTM," *Computer Systems Science & Engineering*, Vol. 40, No. 1, pp. 237-246, May 2021. <https://doi.org/10.32604/csse.2022.017685>
- [32] S. Mishra and S. Padhy, "An efficient portfolio construction model using stock price predicted by support vector regression," *North American Journal of Economics and Finance*, Vol. 50, 101027, pp. 1-14, July 2019. <https://doi.org/10.1016/j.najef.2019.101027>
- [33] S. W. Kim, "Prediction performance of LSTM-based economic policy uncertainty index on asset prices: Traditional asset vs digital asset," *Journal of Digital Contents Society*, Vol. 23, No. 6, pp. 1105-1113, June 2022. <https://doi.org/10.9728/dcs.2022.23.6.1105>
- [34] X. Teng, X. Zhang, and Z. Luo, "Multi-scale local cues and hierarchical attention-based LSTM for stock price trend prediction," *Neurocomputing*, Vol. 505, pp. 92-100,

September 2022.

<https://doi.org/10.1016/j.neucom.2022.07.016>

- [35] W. Li and D. M. Becker, “Day-ahead electricity price prediction applying hybrid models and feature selection algorithms under consideration of market coupling,” *Energy*, Vol. 237, 121543, pp. 1-16, December 2021. <https://doi.org/10.1016/j.energy.2021.121543>
- [36] G. A. Busari and D. H. Lim, “Crude oil price prediction: A comparison between AdaBoost-LSTM and AdaBoost-GRU for improving forecasting performance,” *Computers and Chemical Engineering*, Vol. 155, 107513, pp. 1-9, December 2021. <https://doi.org/10.1016/j.compchemeng.2021.107513>
- [37] J. Osterrieder, “Bitcoin and cryptocurrencies- Not for the faint-hearted,” *International Finance and Banking*, Vol. 4, No. 1, pp. 56-94, January 2017. <https://doi.org/10.5296/ifb.v4i1.10451>
- [38] S. Corbet, P. Katsiampa, and C. K. M. Lau, “Measuring quantile dependence and testing directional predictability between Bitcoin, altcoins and traditional financial assets,” *International Review of Financial Analysis*, Vol. 71, 101571, pp. 1-21, September 2020. <https://doi.org/10.1016/j.irfa.2020.101571>
- [39] E. F. Fama and M. E. Blume, “Filter rules and stock market trading,” *The Journal of Business*, Vol. 39, No. 1, pp. 226-241, January 1966.
- [40] S. W. Kim, “Forecasting COVID-19 pandemic stock prices using portal search intensity and deep learning,” *Journal of Digital Contents Society*, Vol. 23, No. 2, pp. 343-350, February 2022. <https://doi.org/10.9728/dcs.2022.23.2.343>



**김선웅(Sun Woong Kim)**

1983년 : 한국과학기술원 경영과학과 (공학석사)

1988년 : 한국과학기술원 경영과학과 (공학박사)

1988년~1998년: 보람투자신탁운용주식회사

1999년~2003년: 원업투자자문주식회사

2004년~2008년: 에프이테크주식회사

2009년~현 재: 국민대학교 비즈니스IT전문대학원 트레이딩시스템전공 주임교수

※ 관심분야 : 트레이딩시스템, 자산운용, 투자위험관리, AI증권연구