

Developing Cryptocurrency Trading Strategies with Time Series Forecasting Model

Hyun-Sun Kim* · Jae Joon Ahn**†

*Department of Investment Information Engineering, Yonsei University

**Division of Data Science, Yonsei University

시계열 예측 모델을 활용한 암호화폐 투자 전략 개발

김현선* · 안재준**†

*연세대학교 투자정보공학 협동과정

**연세대학교 데이터사이언스학부

This study endeavors to enrich investment prospects in cryptocurrency by establishing a rationale for investment decisions. The primary objective involves evaluating the predictability of four prominent cryptocurrencies - Bitcoin, Ethereum, Litecoin, and EOS - and scrutinizing the efficacy of trading strategies developed based on the prediction model. To identify the most effective prediction model for each cryptocurrency annually, we employed three methodologies - AutoRegressive Integrated Moving Average (ARIMA), Long Short-Term Memory (LSTM), and Prophet - representing traditional statistics and artificial intelligence. These methods were applied across diverse periods and time intervals. The result suggested that Prophet trained on the previous 28 days' price history at 15-minute intervals generally yielded the highest performance. The results were validated through a random selection of 100 days (20 target dates per year) spanning from January 1st, 2018, to December 31st, 2022. The trading strategies were formulated based on the optimal-performing prediction model, grounded in the simple principle of assigning greater weight to more predictable assets. When the forecasting model indicates an upward trend, it is recommended to acquire the cryptocurrency with the investment amount determined by its performance. Experimental results consistently demonstrated that the proposed trading strategy yields higher returns compared to an equal portfolio employing a buy-and-hold strategy. The cryptocurrency trading model introduced in this paper carries two significant implications. Firstly, it facilitates the evolution of cryptocurrencies from speculative assets to investment instruments. Secondly, it plays a crucial role in advancing deep learning-based investment strategies by providing sound evidence for portfolio allocation. This addresses the black box issue, a notable weakness in deep learning, offering increased transparency to the model.

Keywords : Cryptocurrency, Time series Analysis, Price forecasting, Trading Strategy

1. 서 론

2009년 1월 비트코인의 생성으로 시작된 암호화폐 시장

의 역사가 15년이 되었다. 비트코인의 창시자 사토시 나카모토가 비트코인을 공개하면서 발표한 논문 “Bitcoin: A Peer-to-Peer Electronic Cash System”는 그것의 개발 의도가 중앙의 통제 없이 p2p로도 빠르고 안전하게 거래할 수 있는 탈중앙 화폐 시스템을 구축하는 것에 있다고 밝히고 있다[10]. 하지만 비트코인과 수많은 알트코인은 화폐로서

Received 6 December 2023; Finally Revised 15 December 2023;
Accepted 15 December 2023

† Corresponding Author : ahn2615@yonsei.ac.kr

갖추어야 하는 조건을 갖추지 못하여 개발 의도대로의 쓰임이 매우 제한적이며 투자자산으로 보는 것이 타당하다는 의견이 지배적이다[2].

현실에서도 암호화폐는 투자자산의 한 종류로서 활발히 거래되고 있다. 암호화폐 시장의 규모는 현재 기준 글로벌 주식 시장 규모의 1%에 조금 못 미치는 정도이며, 최고점 기준으로는 2.5%에 달한 적도 있다. 당시의 시가총액은 \$3 trillion였으며, 1년만에 27% 수준인 \$0.8trillion로 축소되기도 하였다[6]. 이처럼 암호화폐 시장은 몇 차례의 급등과 급락을 반복하며 고수익을 좇는 투자자들을 꾸준히 유인하고 있다.

현재로서는 가격 변동성이 매우 큰 암호화폐를 매력적인 투자 대상 금융자산으로 볼 수 있다. 그런데 투자 결정을 위한 분석에 있어 암호화폐에는 몇가지의 중대한 문제가 존재한다. 첫째, 참고할 과거 이력이 충분히 쌓이지 않은 신생자산인 경우가 많고, 둘째, 연관 사업실적에 대한 재무제표 등의 보고서를 감사 받거나 공시하지 않으며, 셋째, 연관 사업모델 자체가 없는 경우도 많기 때문에 내재가치 평가에 한계가 있다. 따라서 기본적 분석 대신 기술적 분석을 통해 가치평가가 이루어지기도 하지만 상당 수의 경우에는 별다른 근거가 없는 ‘투기’의 대상이 되기도 한다.

본 연구는 암호화폐를 논리적 근거에 의한 투자자산으로 활용하자는 목적에서 시작한다. 비선형, 시계열 데이터인 암호화폐 가격을 하루 단위의 단기적 관점에서 예측하기 위해 다양한 학습 조건 하에서 전통적인 통계방법론과 인공지능 방법론을 적용해보고 예측 오차의 비교를 통해 연도별, 암호화폐 별로 어떤 모델의 예측력이 더 뛰어난지 평가해본다. 또한 확인된 가장 우수한 성과의 예측 모델을 활용해 예측오류가 낮은 암호화폐에 더 큰 투자비중을 부여하는 트레이딩 전략을 제안하고, 실증 분석을 통해 수익성을 확인한다.

본 연구는 다양한 시가총액 순위와 가격대의 암호화폐를 대상으로 분석을 시도하였다는 점, 학습 조건에 다양한 변조를 주어 예측 성능을 비교하고 각 대상에 가장 잘 들어맞는 예측 모델을 도출하였다는 점에서 기존 연구와 차별성이 있다. 또한 트레이딩 전략을 설계함에 있어, 전통적인 포트폴리오 전략을 따르지 않고 예측 모델이 잘 작동하는 자산일수록 투자 비중을 높이 두는 직관적인 논리를 반영하여 투자의 근거를 마련했다는 점에 의의가 있다.

2. 선행연구

암호화폐의 등장 초반에는 성격, 용도, 기술적 특징 등 펀더멘탈에 대한 연구가 주를 이루다가 5년여 이후부터는 암호화폐와 인과성을 보이는 요인들에 대한 연구가 본격적으

로 진행되었다. 뒤이어 암호화폐 가격 예측과 트레이딩 전략에 대한 연구가 다수 발표되고 있다[4]. 계량경제와 통계학의 이론을 결합하여 경제 변수의 움직임을 예측하는 방식[14]으로 접근하거나, 인공지능으로 인과 변수들 간 복잡한 관계를 분석하고 가격 흐름을 예측하는 방식이 사용되고 있다.

Zhang et al.[15]은 가상화폐 6종의 종가를 예측하기 위해 딥러닝 기법인 GRU(Gated Recurrent Unit)와 CNN(Convolution Neural Network)의 구조를 병합하는 모형을 제시했고, 가상화폐 6종 모두에서 랜덤 포레스트, SVM(Support Vector Machine), XGBoost, LSTM보다 우수한 성능을 확보하였다. Guo et al.[5]은 거래소 간 비트코인 이동 내역으로부터 가상화폐 가격 간의 관계를 포착하고, 이를 변수화해 CNN기반 모형 구축에 반영하여 예측성능을 향상시킨 바 있다. Jagannath et al.[7]은 비트코인 블록체인 네트워크의 정보(블록 크기, 해시 비율, 이동량 등)를 LSTM의 입력 변수로 활용해 예측성과를 향상시켰고, Kim[8]의 연구에서는 뉴스 제목에 대한 감성분석을 변수로 활용하여 LSTM 기반 예측 모형의 성능을 검증한 바 있다. Ortu et al.[12]도 기술적지표와 레딧(Reddit), 깃허브(Github)와 같은 온라인 투자 커뮤니티의 글들을 감성분석한 결과를 LSTM과 CNN 모형의 변수로 활용하여 비트코인과 이더리움 예측에 가장 높은 성과를 보였다고 주장하였다.

투자의 영역에서 진행된 연구로는 기존 투자자산과의 상관관계를 밝히거나 암호화폐의 포트폴리오 편입 성과와 전략에 대한 연구들이 있다. Dyhrberg[3]는 비트코인의 금융자산의 가능성 평가를 위해 금, 달러와 비트코인의 관계를 분석하여 위험 관리 용도로 사용될 가능성이 있고, 포트폴리오 구성 시 금과 달러 사이의 위치에 있는 금융자산 역할을 할 수 있을 것이라고 주장하였다. Marie et al.[9]은 통화, 주식, 채권, 금, 그리고 원유 등 다양한 금융자산들로 구성된 포트폴리오에 비트코인을 추가하는 것이 포트폴리오의 위험 조정 성과를 향상시킬 수 있는지 Mean-variance spanning test를 통해 분석한 바 있다.

본 연구에서는 예측력을 활용한 투자 전략 수립에 목적을 두고 통계학에서 사용되는 전통적인 시계열 데이터 분석 방법인 ARIMA와 딥러닝 기반의 LSTM, 가장 최근에 발표된 통계학 기반의 인공지능 소프트웨어인 Prophet을 적용하여 가장 높은 예측 성능을 보이는 모델을 찾고자 한다.

3. 연구방법

3.1 ARIMA(AutoRegressive Integrated Moving Average)

ARIMA는 계량경제학과 통계학에서 시계열 데이터의

분석에 가장 많이 쓰여온 방법 중 하나로 데이터의 시간적 변동에 따른 선형적 패턴을 예측하는 데에 강점이 있다. 자기회귀(AR), 누적 차분(I), 이동평균(MA)의 세 요소로 구성되는데, 자기회귀 요소는 이전 값들의 선형 조합으로 현재 값을 모델링한다. 누적 차분 요소는 비정상성을 가지는 데이터를 안정화하기 위해 차분하는 과정이며, 이동평균 요소는 백색잡음의 선형 관계로 현재 값을 모델링한다. ARIMA(p, d, q)로 표현되는 기본 구조에서 자기회귀 차수(p)는 이전 값의 개수를, 차분 차수(d)는 시계열 데이터가 정상성을 지니게 만들기 위해 필요한 차분 횟수를, 이동평균 차수(q)는 백색잡음의 평균을 계산하는 데 사용되는 이전 값의 개수를 나타낸다[1].

본 연구에서는 Bayesian Information Criterion(BIC)을 이용하여 도출한 최적 모델 ARIMA(1, 2, 0)을 적용하였다.

3.2 LSTM(Long Short-Term Memory)

LSTM은 순환 신경망(RNN, Recurrent Neural Network)의 한 유형으로, 주로 시계열 데이터 및 자연어 처리와 같은 순차적 데이터에 적용되는 딥러닝 모델이다. RNN의 문제로 지적되는 장기 의존성(long-term dependencies)을 해결하기 위해 고안되었으며 핵심 부분인 cell state는 컨베이어 벨트처럼 순환신경망 전체 체인을 관통하며 계속 유지되고, 순환신경망에 input gate, output gate, forget gate를 추가하여 어느 시점에서 데이터 정보를 얼마큼 버리거나 유지할 것인지를 선택적으로 전달할 수 있다. 이를 통해 긴 시퀀스에 대해 효과적인 학습 결과를 제공하여 전력 사용량, 물동량 분석, 주가 예측 등의 분야에서 빈번히 사용된다[11].

암호화폐의 가격 예측을 위해 본 연구에서는 <Table 1>의 설정으로 LSTM을 활용하였다.

<Table 1> Parameters for LSTM Model Training

Parameter	Value
Hidden size	16
Number of layers	2
Epoch	50
Batch size	1,024
Learning rate	0.01
Loss function	MSE
Optimizer	ADAM

3.3 Prophet

Prophet은 2017년 Facebook에서 발표한 통계학 기반의 시계열 예측 인공지능 소프트웨어이다. 통계적 지식이 없

이도 비즈니스 및 금융 분야에서 널리 활용할 것을 목표로 개발되어 매개변수의 조정이나 복잡한 전처리 과정 없이도 사용이 가능하다. 또한 사용자가 가지는 특수한 경험이나 사건을 모델에 반영할 수 있어 모델링이 직관적이고 빠르게 이루어진다. 추세(trend), 계절성(seasonality), 이벤트 효과(holiday)를 고려한 아래 (1)의 식으로 구성되어 있다[13].

$$y(t) = g(t) + s(t) + h(t) + \epsilon_t \tag{1}$$

g(t)는 주기적이지 않은 변동인 trend를, s(t)는 주간 또는 연간 계절성과 같은 주기적 변화를, h(t)는 불규칙적으로 발생하는 이벤트와 같은 요소를 반영한다. ϵ_t 는 정규분포를 따른다고 가정했을 때의 잔차이다.

본 연구에서는 비교적 단기간의 데이터를 학습하여 하루 단위의 예측 결과를 산출하므로 계절성이나 이벤트 효과에 대한 고려가 필요하지 않아 이들 요소에 대한 매개변수를 별도로 지정하지 않았다. <Table 2>는 실험 시 사용한 설정 값이다.

<Table 2> Parameters for Prophet model training

Parameter	Value
n_changepoints	25
changepoint_range	0.8 (80%)
changepoint_prior_scale	0.05
seasonality	Auto
holidays	Auto
interval_width	0.8

4. 실증 분석

4.1 연구 자료

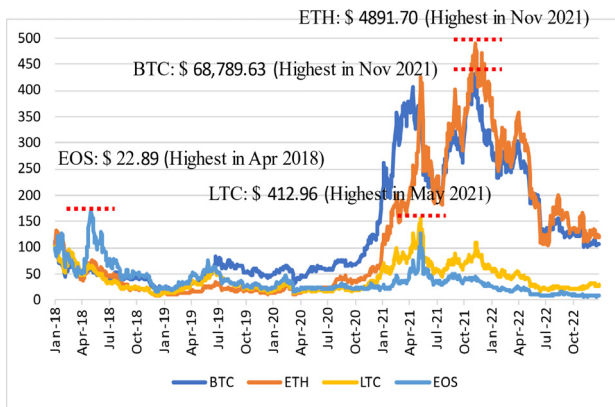
실험 대상 암호화폐의 선정에 있어 정상 운용자산임을 담보하기 위해 첫 ICO 이후 5년 이상이 경과되었을 것, 대중적 인지도와 거래 빈도, 이상 의심 거래 유무 등 암호화폐 시장 내에서 지속적으로 건전한 존재감이 있을 것의 두 가지 기준을 고려하였다. 의도적인 결함 또는 부정 운용으로 인해 분석, 예측의 의미가 존재하지 않는 상황을 피하기 위함이다. <Table 3>은 상장 년도와 시가총액 등 실험 대상 암호화폐의 기초적 특성이다.

비트코인(BTC)과 이더리움(ETH), 라이트코인(LTC), EOS(EOS)의 4가지 암호화폐를 선정하였고 글로벌 10위권 내의 암호화폐 거래소인 Bitfinex에서 2017.11.01부터 2022.12.31의 기간에 해당하는 1분 간격 현물 거래 가격

(USD) 정보를 수집하였다. <Figure 1>은 실험 대상 기간 4개 암호화폐의 가격 추이이며 상대적 변동성 파악을 위해 2017.11.01 가격을 100으로 두어 스케일링하였다.

<Table 3> Overview of 4 Cryptocurrencies

Symbol	First ICO	Rank by MC	Current Price	Market Cap (2023.12)
BTC	2009	#1	\$41,318.07	\$808,223,841,564
ETH	2014	#2	\$2,215.45	\$266,469,844,858
LTC	2011	#16	\$72.64	\$5,369,261,098
EOS	2017	#69	\$0.7065	\$784,482,774



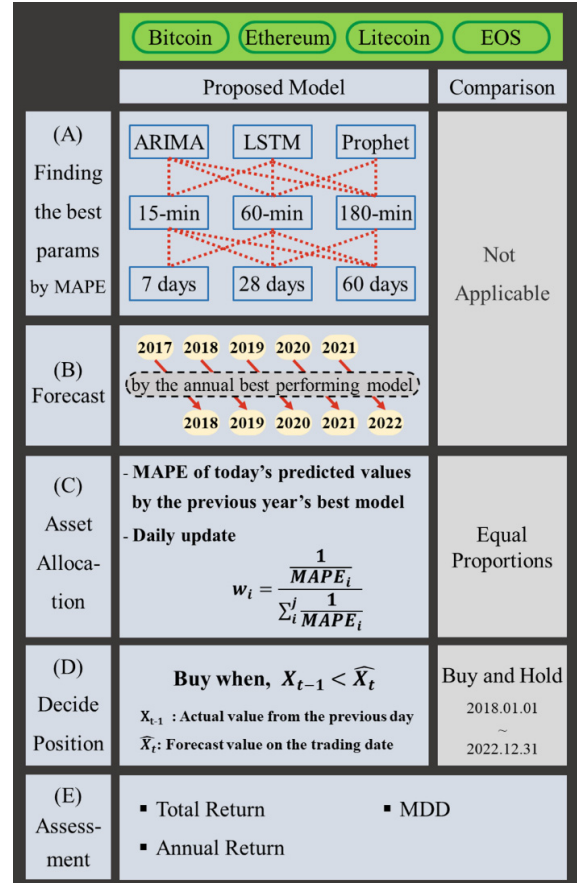
<Figure 1> Historical Prices of 4 Cryptocurrencies

4.2 연구 모형

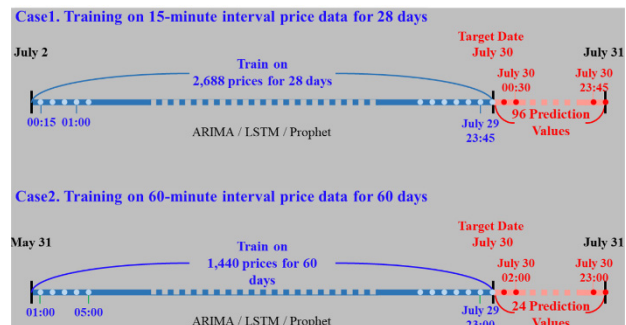
<Figure 2>는 본 연구의 실험 과정을 요약한 것이다. 트레이딩 기간은 2018년 1월 1일부터 2022년 12월 31일까지이며 2018년의 예측에 사용할 모델을 도출하기 위해 2017년 11월 1일부터 12월 31일까지의 데이터로 최적 모델을 확정하였다.

예측 단계에 있어, 본 연구는 다양한 학습 조건을 시도하여 최적 모델을 찾는 방식을 택하였다. 수집한 1분봉 데이터에 기초하여 각기 다른 방법론(ARIMA, LSTM, Prophet), 데이터 인터벌(15분봉, 60분봉, 180분봉), 학습 기간(7일, 28일, 180일)의 조합으로 학습하여 특정일(타겟 데이트)에 대한 예측을 실행하였다. Test data에 해당하는 타겟 데이트는 모델의 일반화를 위해 1년당 20일씩 무작위로 선정하였고 이 타겟데이트에 대한 예측 결과 산출을 위해 이전의 특정 기간동안 특정 간격의 가격 이력을 training data로 사용하였다. (LSTM, 60분봉, 28일)의 조합으로 7월 30일에 대한 예측을 하는 경우, 7월 2일01:00부터 7월 29일 24:00까지 28일 동안 60분 간격의 가격 데이터(training data)로 LSTM에 의해 학습한 후 7월 30일 01:00부터 24:00까지 60분 간격의 24개 예측치(test data)를

내놓는 방식이다. <Figure 3>는 모델 작동 방식을 도식화한 것이다.



<Figure 2> Outline of the Experiment



<Figure 3> How the Prediction Model Works

평가 기준은 이상치의 전체 결과에 대한 영향이 강조되지 않고 퍼센트로 표현되어 각기 다른 가격대의 암호화폐에 대한 예측 결과도 직관적 비교가 가능한 MAPE(Mean Absolute Percentage Error)로 설정하였다. 실제 값(X_t)과 예측 값(\hat{X}_t)의 차이를 실제 값으로 나눈 절댓값을 평균하여 백분율로 변환한 아래의 식 (2)를 따랐다.

$$MAPE = \frac{\sum_{i=1}^n \left[\frac{|X_i - \hat{X}_i|}{X_i} \right]}{n} \times 100\% \quad (2)$$

각 해의 20개 타겟 데이트의 MAPE를 평균하여 해당 년도의 최종 예측 성능으로 결론짓고 연도별, 암호화폐별 최적 예측 모델을 결정하였다.

트레이딩 단계에서는 예측 단계에서 결정된 연도별, 암호화폐별 최적 성능 모델을 활용하여 대상 기간의 매일에 대하여 예측을 실행한다. 단, 실제 상황에서 올해의 최적 성능 모델을 미리 알 수 없으므로 직전 해의 최적 성능 모델을 올해의 예측에 활용한다.

매일의 예측으로부터 얻고자 하는 값은 2가지이다. 하나는 거래일의 마지막 시점(24:00) 예측 값이고 다른 하나는 거래일 하루의 예측치에 대한 MAPE이다. 먼저 거래일의 마지막 시점 예측 값은 포지션의 결정에 사용한다. 본 연구에서는 매일 24:00에 1회의 거래를 허용하는데, 거래일 마지막 시점의 예측치가 전일의 동일 시점 실제 가격보다 크면 매수를 실행하고 반대의 경우에는 보유하고 있던 자산을 청산한다.

다음으로 거래일의 MAPE는 자산 배분을 결정하는 기준으로 삼는다. MAPE는 해당 자산의 미래 가격 예측에 얼마만큼의 오차가 있는 지를 뜻한다. 즉, 값이 작을수록 더 잘 예측하고 있다는 뜻이므로 더 잘 예측할 수 있는 암호화폐에 더 많이 투자하는 직관적인 논리에 따라 4개 암호화폐의 상대적 MAPE 크기로 자산 배분을 결정한다. 따라서, 일별 MAPE에 의해 일별 가중치가 달라지며 포트폴리오를 매일 리밸런싱한다. 자산 i 에 대한 투자 가중치(w_i)를 결정하는 식은 아래의 식 (3)과 같으며 <Figure 4>는 예측 모델에 의한 가중치 결정 과정을 도식화한 것이다.

$$w_i = \frac{1}{MAPE_i} / \sum_j \frac{1}{MAPE_j}, \sum w_i = 1 \quad (3)$$

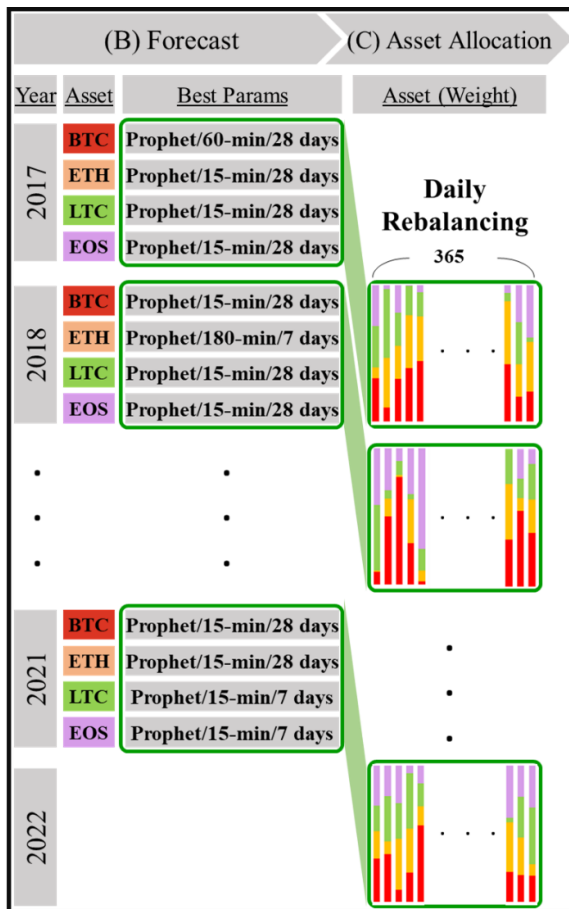
대상 기간의 마지막일인 2022년 12월 31일이 경과된 후 제시한 전략에 의한 트레이딩 결과와 매수 후 보유 전략에 따라 2018년 1월 1일에 균등비율로 매수 후 2022년 12월 31일 24:00에 청산한 투자안을 누적 수익률, 연간 수익률, 그리고 Maximum Draw Down(MDD)로 평가하여 수익률을 비교하였다. 균등 비율로 구성된 매수 후 보유 전략의 포트폴리오를 대조군으로 삼은 이유는 가중치와 매수 포지션 결정 측면에서 아무 조정도 하지 않은 상태라는 점에서 제안한 트레이딩 전략의 차별적 효과를 가장 극대화하여 보여준다고 판단하였기 때문이다.

4.3 결과 분석

<Table 4>는 비트코인에 대해 60일간의 15분봉 가격 데이터로 3가지 방법을 적용하여 트레이닝 후, 2018년을 타겟으로 테스트한 결과의 일부이다. 같은 방식으로 4개 암호화폐에 대하여 연도 별로 각기 다른 27개 학습 조건에서 실험 후 MAPE 크기를 비교하여 연도별, 암호화폐별 최적 예측 모델을 도출하였다(<Table 5>).

<Table 4> Assessment (MAPE) of Predictions on Bitcoin with Training Data at 15-minute Interval Prices for 60 Days

	ARIMA	LSTM	Prophet
2018-01-14	4.95%	21.67%	7.50%
2018-02-04	7.09%	5.59%	9.60%
⋮		⋮	
2018-08-18	16.63%	8.73%	6.17%
⋮		⋮	
2018-11-25	15.70%	14.83%	5.42%
2018-12-19	7.41%	9.95%	11.05%
	11.98%	6.08%	6.09%

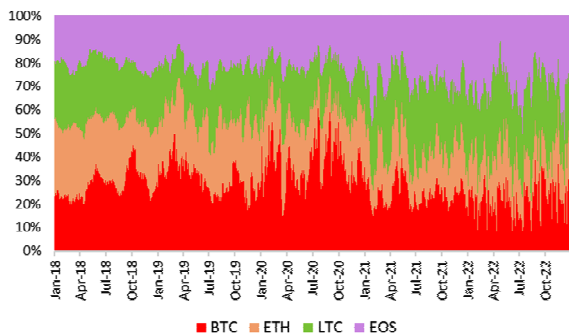


<Figure 4> Asset allocation by the MAPE

<Table 5> Best-performing Model within Each Year

	Year	Train Days	Time Interval	Method	MAPE
BTC	2017	28	60	Prophet	5.75%
BTC	2018	28	15	Prophet	3.02%
BTC	2019	7	60	Prophet	2.60%
BTC	2020	28	15	Prophet	2.50%
BTC	2021	28	15	LSTM	1.78%
ETH	2017	28	15	Prophet	5.63%
ETH	2018	7	180	Prophet	4.44%
ETH	2019	28	15	Prophet	3.54%
ETH	2020	28	15	Prophet	2.61%
ETH	2021	28	15	Prophet	3.48%
LTC	2017	28	15	Prophet	6.57%
LTC	2018	28	15	Prophet	4.37%
LTC	2019	28	15	Prophet	3.99%
LTC	2020	7	15	Prophet	3.35%
LTC	2021	7	15	Prophet	4.57%
EOS	2017	28	15	Prophet	9.86%
EOS	2018	28	15	Prophet	5.75%
EOS	2019	28	15	Prophet	3.98%
EOS	2020	7	15	Prophet	3.30%
EOS	2021	7	15	Prophet	3.56%

대체로 Prophet을 적용하여 15분 간격의 데이터로 28일 또는 7일간 학습시켰을 때 높은 예측 성능을 보였다. 이로 미루어 하루 단위의 단기적 예측에는 28일을 초과하는 긴 학습 기간이 효과적이지 않음을 알 수 있다. 모든 암호화폐에서 연도 경과에 따라 MAPE가 감소하는 경향을 보였으나 시장 상황과의 연관성을 찾기는 어려우며, 시가총액이 큰 비트코인과 이더리움의 MAPE가 나머지 두 암호화폐에 비해 낮음을 확인하였다.



<Figure 5> Daily Weight on Each Cryptocurrency

<Figure 5>는 모델의 예측 결과로 결정된 트레이딩 기간의 일별 가중치이며, <Table 6>는 트레이딩이 이루어지는 방식을 보여준다. 일별 예측 값에 의하여 포지션을 결정하고

매수 신호를 받은 암호화폐에 대하여 가중치만큼의 포트폴리오 내 비중을 두어 해당 일의 손익이 결정된다.

일 단위의 손익이 누적되어 최종 수익률이 산출되었다. <Figure 6>은 트레이딩이 시작된 2018년 1월 1일의 포트폴리오 가치를 1로 두었을 때 2022년 12월 31일까지의 트레이딩이 종료된 이후 계산된 포트폴리오 가치이다. <Table 7>은 두 투자안의 수익성 측정 결과이다. 제시한 전략의 경우 최종 가치는 2.86으로 매년 23.4%의 수익을 달성한 것과 동일한 결과였지만 균등비율로 투자하여 매수 후 보유 전략으로 운용한 포트폴리오는 손실을 기록하여 0.81의 가치를 보였다. 이는 매년 평균적으로 4.04%의 손실이 반복되었을 때와 동일한 결과이다.

<Table 6> Trading Simulation

Trade Date	Asset	X_{t-1}	\hat{X}_t	Position	Weight	Profit
2018-01-01	BTC	13,753	14,416.90	Buy	23%	-0.005
	ETH	736.50	780.57	Buy	34%	0.008
	LTC	225.15	228.00	Buy	24%	-0.001
	EOS	7.66	7.37	0	19%	0
2018-01-02	BTC	13,428	13,759.84	Buy	26%	0.025
	ETH	755.13	795.37	Buy	32%	0.043
	LTC	223.77	238.70	Buy	23%	0.028
	EOS	7.64	8.25	Buy	19%	0.017
2018-01-03	BTC	14,709	13,406.41	0	27%	0
	ETH	856.30	876.61	Buy	31%	0.03
	LTC	250.52	227.80	0	22%	0
	EOS	8.31	8.40	Buy	20%	0.026



<Figure 6> Cumulative Returns over Trading Period

<Table 7> Profitability Assessment

	Proposed	Buy and Hold
Total Return	2.860	0.814
Annual Return	0.234	-0.0404
MDD	-0.744	-0.867

두 투자안의 성과 차이는 시간 경과에 따라 커지다가 2021년 중반에 극대화되고 트레이딩 종료 시점까지 큰 폭을 유지한다. 2021년 말 최고점에 달하였고 2020년 말부터 2022년까지 급등과 급락을 반복하였던 암호화폐 시장 상황을 고려하면, 상승장일수록 시장 변화에 빠르게 대응하기 위하여 일 단위로 자산재분배를 실행하는 전략이 주요하였음을 알 수 있다. 또한 본 연구에서는 매수 후 보유 전략이 손실을 기록하며 종료되었는데 이는 <Figure 1>에서 보는 것처럼 라이트코인과 EOS의 가격이 트레이딩 시작 시점에 비하여 각각 69%와 89% 하락한 것에 기인한다. 4개 암호화폐에 대하여 동등한 비율로 투자되었기 때문에 하락폭보다 작은 폭으로 상승한 나머지 암호화폐가 전체 포트폴리오에 미친 양(+)의 기여가 잠식되었다. 같은 하락장에서도 본 연구에서 제시한 리밸런싱 전략은 오히려 약한 상승 추세를 보여, 자산배분의 중요성을 강조하고 있다.

변동성 지표인 MDD는 기간 중 전고점 대비 최대 낙폭을 뜻하여, 해당 투자안이 제일 크게 하락했을 때의 정도를 나타낸다. 따라서 MDD가 클수록 변동 폭이 큼을 의미한다. <Figure 7>은 두 투자안의 MDD를 도식화한 것이다. 2021년 이후의 투자에서는 능동적 리밸런싱을 하지 않고 매수 후 보유의 소극적 전략을 택할 때 오히려 변동성을 낮출 수 있는 구간도 존재하지만 전체 기간에 걸쳐 평가하였을 때 변동성 측면에서도 제시한 전략이 우수한 결과를 보인다.



<Figure 7> Maximum Draw Down Comparison

5. 결 론

본 연구에서는 다양한 학습 조건을 적용하여 가장 잘 작동하는 모델을 찾아내고, 해당 모델의 예측 성능에 비례하여 개별 자산의 투자 가중치를 결정하는 전략을 제시하였다. 하루 단위의 단기 예측에 있어 한 달 이상의 기간에 걸친 학습은 오히려 효과가 떨어지는 결과를 보였으며, 변동성이 큰 시장의 특성 상 15분 단위의 가격으로 학습하

였을 때 성과가 가장 좋았다. 또한 모델이 제시하는 상승 또는 하락 신호에 따라 예측력이 결정된 비율만큼 매수하는 규칙으로 거래하였을 때 최종 성과는 동등비율로 구성된 매수 후 보유 투자안에 비하여 월등히 높은 수익률을 보였다. 특히 상승장일수록 수동적 전략에 비하여 큰 폭의 수익 개선 결과를 보여 예측력의 제고와 전략의 고도화에 따라 수익률을 높일 수 있는 가능성이 증명되었다.

본 연구의 접근은 단일 모델의 초매개변수 최적화나 인과변수를 반영한 모델링으로 예측력을 제고하는 방식에 비하여 변동성이 높은 시장 상황에 유연하게 대처할 수 있다는 강점을 지닌다. 또한 딥러닝에 의한 포트폴리오 전략의 단점으로 지적되는 블랙박스 이슈를 해소하고 가중치 분배에 대한 근거를 제시하였다는 점에서 의의가 있다. 설명가능한 인공지능에 대한 사회적 요구가 증가하는 상황임을 감안하면 의미 있는 진전이다. 수익률과 변동성 사이의 트레이드오프 최적화에 초점을 맞춘 전통적 포트폴리오 전략과 달리 새로운 접근 방법을 제시하였다는 점도 본 연구의 성과라 할 수 있을 것이다.

다만, 사전에 설계된 여러 조합의 학습 조건을 적용하여 후보 군 안에서 최적의 모델을 찾은 점은 한계로 지적할 수 있다. 본 연구에서 사용한 각 방법론에 대해서도 매개변수 최적화를 거쳐 최종 예측 모델을 선정한다면 더 좋은 결과를 산출할 가능성이 존재한다. 또한 추후 연구에서는 예측 모델의 평가에 있어 MAPE 외 다른 지표를 고려해볼 수 있을 것이다. 이상치의 중요도를 높이 두어 MSE를 기준으로 두거나 다른 복합 지표를 사용하여 최적 모델을 도출하였을 때 본 연구와의 결과를 비교하는 것도 하나의 주제가 될 수 있다. 트레이딩 측면에서는 대조군을 설정함에 있어 균등 포트폴리오가 아닌, 시장 도미넌스가 반영된 투자안을 택한다면 현실의 투자 행태가 더 잘 반영되어 결과의 설득력이 높아질 것을 기대한다. 향후의 연구에서는 이상의 한계점을 보완하고 전략의 지속적 개선을 통해 더 나은 결과를 도출하고자 한다.

References

- [1] Box, G.E.P. and Pierce, D.A., Distribution of Residual in Autoregressive-Integrated Moving Average Time Series[J], *Journal of the American Statist Association*, 1970, Vol. 65, No. 332, pp. 1509-1526.
- [2] Corbet, S., Lucey, B., Urquhart, A., Yarovaya, L., Cryptocurrencies as a financial asset: A systematic analysis, *International Review of Financial Analysis*, 2019, Vol. 62, pp. 182-199.
- [3] Dyhrberg, A.H., Bitcoin, gold and the dollar - A GARCH volatility analysis, *Finance Research Letters*, 2016, Vol.

- 16, pp. 85-92.
- [4] Fang, F., Ventre, C., Basios, M., Kanthan, L., Martinez-Rego, D., Wu, F., and Li, L., Cryptocurrency trading: A comprehensive survey, *Financial Innovation*, 2022, Vol. 8, No. 1, pp. 1-59.
- [5] Guo, H., Zhang, D., Liu, S., Wang, L., Ding, Y., Bitcoin price forecasting: A perspective of underlying blockchain transactions, *Decision Support Systems*, 2021, Vol.151, 113650
- [6] <https://coinmarketcap.com/charts/>
- [7] Jagannath, N., Barbulescu, T., Sallam, K., Elgendi, I., Okon, A., McGrath, B., Jamalipour, A., and Munasinghe, K., A Self-Adaptive Deep Learning-Based Algorithm for Predictive Analysis of Bitcoin Price, *IEEE Access*, 2021, Vol. 9, pp. 34054 -34066
- [8] Kim, E., An Integrated Model for Predicting Changes in Cryptocurrency Return Based on News Sentiment Analysis and Deep Learning, *Knowledge Management Research*, 2021, Vol. 22, pp. 19-32.
- [9] Marie, B, Kim, O., and Ariane, S., Virtual Currency, Tangible Return: Portfolio Diversification with Bitcoin, *Journal of Asset Management*, 2015, Vol.16, pp.365-373.
- [10] Nakamoto, S., Bitcoin: A peer-to-peer electronic cash system, 2008. <http://www.lopp.net/pdf/bitcoin.pdf>
- [11] Olah, C., Understanding LSTM networks, 2015, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [12] Ortu, M., Uras, N., Conversano, C., Bartolucci, S., and Destefanis, G., On technical trading and social media indicators for cryptocurrency price classification through deep learning, *Expert Systems with Applications*, 2022, Vol. 198, p. 116804.
- [13] Sean, J., Taylor and Benjamin Letham., Forecasting at scale, *The American Statistician*, 2018, Vol. 72, No. 1, pp. 37-45.
- [14] Vogelpang, B., *Econometrics: theory and applications with eviews*, Pearson Education, 2005.
- [15] Zhang, Z., Dai, H.N., Zhou, J., Mondal, S.K., Garcia, M.M., and Wang, H., Forecasting cryptocurrency price using convolutional neural networks with weighted and attentive memory channels, *Expert Systems with Applications*, 2021, Vol. 183, p. 115378.

ORCIDHyun-Sun Kim | <https://orcid.org/0009-0002-5539-7140>Jae-Joon Ahn | <https://orcid.org/0000-0001-7974-8027>