

딥러닝과 단기매매전략을 결합한 암호화폐 투자 방법론 실증 연구*

이유민
부산대학교 경영학과
(selina-lee@naver.com)

이민혁
부산대학교 경영학과
(minhyuk.lee@pusan.ac.kr)

암호화폐시장이 지속해서 성장함에 따라 하나의 새로운 금융시장으로 발전하였다. 이러한 암호화폐시장에 관한 투자전략 연구의 필요성 또한 대두되고 있다. 본 연구에서는 단기매매전략과 딥러닝을 결합한 암호화폐 투자 방법론에 대해 실증 분석을 진행하였다. 투자 대상의 암호화폐를 이더리움으로 설정하고, 과거 데이터를 기반으로 최적의 파라미터를 찾아 이를 활용하여 실험 모델의 투자 성과를 분석하였다. 실험 모델은 변동성돌파전략, LSTM(Long Short Term Memory)모델, 이동평균 교차 전략, 그리고 단일 모델들을 결합한 결합 모델이다. 변동성돌파전략은 일 단위로 변동성이 크게 상승할 때 매수하고 당일 종가에 매도하는 단기매매전략이며, LSTM모델은 시계열 데이터에 적합한 딥러닝 모델인 LSTM을 활용하여 얻은 예측 증가를 이용한 매매방법이다. 이동평균 교차 전략은 단기 이동평균선이 교차할 때 매매를 결정하는 방법이다. 결합 모델은 변동성돌파전략의 매수 조건과 변동성돌파전략의 목표 매수가보다 LSTM의 예측 증가가 큰 경우 매수하는 조건이 동시에 만족하면 매수하는 규칙이다. 결합 모델은 변동성돌파전략과 LSTM모델의 파생 변수를 활용해 매수 조건에 AND와 OR를 사용하여 만든 매매 규칙이다. 실험 결과, 단일 모델보다 결합 모델에서 투자 성과가 우수함을 확인하였다. 특히, 데일리 트레이딩과 매수 후 보유의 누적수익률은 -50%이하인 것에 비해 결합 모델은 +11.35%의 높은 누적수익률을 달성하여 하락이 지속되던 투자 기간에도 기술적으로 방어하며 수익을 낼 수 있음을 확인하였다. 본 연구는 기존의 딥러닝 기반 암호화폐 가격 예측에서 나아가 변동성이 큰 암호화폐시장에서 딥러닝과 단기매매전략을 결합하여 투자 성과를 개선하였다는 점에서 학술적 의의가 있으며, 실제 투자 시 적용 가능성을 보여주었다는 점에서 실무적 의의가 있다.

주제어 : 블록체인, 암호화폐, 이더리움, 투자전략, 단기매매전략, 가격예측, 딥러닝, LSTM, 결합모델

논문접수일 : 2023년 2월 16일 논문수정일 : 2023년 3월 20일 게재확정일 : 2023년 3월 22일
원고유형 : Regular Track 교신저자 : 이민혁

1. 서론

암호화폐시장이 지속적으로 성장함에 따라 하나의 금융시장으로 발전하였다. 실제 암호화폐 투자 측면에 있어 유용한 전략을 개발하는 연구의 필요성이 대두되고 있으며, 주식시장과 암호화폐시장의 트레이딩 관련 연구가 점차 이루어

지고 있다. 최근 주식시장에서 활용되고 있는 기술적 거래 규칙을 통한 매매 방법과 머신러닝, 딥러닝, 또는 여러 AI 모델을 활용한 트레이딩 시스템 모델을 적용하는 시도를 하고 있다(양훈석 등, 2019). 하지만 실질적으로 투자와 관련하여 기술적 거래 규칙과 인공지능 모델을 결합하여 수익성을 분석한 연구는 미미한 수준이다. 이에

* This research was supported by Basic Science Research Program through the National Research Foundation of Korea (NRF) funded by the Ministry of Education (NRF-2021R111A3049656)

따라 본 연구에서는 딥러닝 모델 하나보다는 기존의 기술적 거래 규칙을 결합한 매매 시그널(signal)을 통해 투자한다면 딥러닝 학습 과정에서 오차를 기술적 매매 지표가 보완하여 투자 성과가 개선될 수 있을 것이라 판단하였다.

본 연구의 목적은 딥러닝과 단기매매전략을 결합한 모델로 암호화폐를 투자하는 경우 단일 모델보다 투자 성과가 개선되는지에 대해 실증적으로 분석하는 것이다. 기존 연구에서는 다양한 딥러닝 모델을 통해 암호화폐 가격 예측에만 머무른 연구가 많았고 암호화폐 중에서도 비트코인을 대상으로 한 연구가 대부분이었다(Ferdiansyah et al., 2019; Rizwan et al., 2019; Zhang, 2022). 또한 선행 연구들의 테스트 기간에는 전 고점을 돌파한 큰 상승을 포함하고 있어 높은 수익률을 기록했지만, 하락이 지속되는 경우 이를 방어하면서 유의미한 수익률이 나오는 투자 방법인지 알 수 없는 한계가 존재했다(Awoke et al., 2021).

따라서 본 연구에서는 암호화폐시장의 큰 변동성을 고려했을 때 직접 투자의 위험성을 보완하는 방법으로, 기존 주식시장에서 활용하고 있는 단기매매전략인 변동성돌파전략과 딥러닝의 LSTM을 결합한 모델의 암호화폐 이더리움의 투자 성과를 분석하고 우수한 투자 전략으로서 실효성이 있는지 확인하고자 한다.

2. 이론적 배경

2.1 암호화폐 관련 연구

암호화폐(Cryptocurrency)는 ‘암호화(crypto)’와 ‘통화(currency)’의 합성어로, 분산 원장에서 공개키

암호화를 통해 안전하게 데이터를 전송하고 해시 함수를 이용해 쉽게 소유권을 증명해낼 수 있는 블록체인(blockchain) 기술 기반의 가상자산을 말한다. 최근 암호화폐가 ‘화폐’가 아닌 ‘자산’으로 분류되면서 ‘암호화된 자산’, ‘디지털 자산’이라는 용어의 변경이 일어나고 있는데 본 연구에서는 기존 선행연구에서 주로 사용했던 ‘암호화폐’라는 단어를 사용한다. 최초의 암호화폐는 비트코인(Bitcoin, BTC)으로, 2008년 10월 31일 사토시 나카모토(Satoshi Nakamoto)의 ‘Bitcoin: A Peer-to-Peer Electronic Cash System’라는 논문을 통해 처음 발표되었다(Nakamoto, 2008). 비트코인은 신뢰할 수 있는 중앙기관 즉, 금융기관을 통하지 않고 당사자들끼리 지불(payment)을 수행할 수 있도록 하는 개인 대 개인의 전자 화폐 시스템이다. 비트코인을 제외한 나머지 암호화폐를 비트코인을 대체하는 코인이라고 하여 ‘알트코인(Alternative coin)’이라고 부른다. 2022년 11월 28일 기준, 코인마켓캡에 등록된 전 세계 알트코인 종류는 9,128개에 달한다¹⁾. 전 세계 알트코인 시가총액 1위인 이더리움(Ethereum, ETH)은 비탈릭 부테린(Vitalik Buterin)에 의해 발명되었다. 부테린은 닉 사보(Nick Szabo)와 마크 밀러(Mark Miller)가 1994년에 고안한 디지털 형식으로 표현된 약속의 집합인 ‘스마트 컨트랙트(Smart contract)’를 블록체인 영역에 적용시킴으로써 이전까지 화폐적 기능에 초점을 맞추었던 암호화폐의 사용성을 확장시켰다(Buterin, 2013; Wood, 2014). 여러 블록체인 응용프로그램을 개발할 수 있는 이더리움 기술 덕분에 현존하는 대부분의 탈중앙화 분산 어플리케이션은 이더리움 플랫폼 위에서 구동되고 있어 향후 사용성과 확장성 면에 있어 그 영향력이

1) 코인마켓캡, <https://coinmarketcap.com>

더욱 증가할 것으로 보인다.

암호화폐시장이 급속도로 성장하면서 최근 암호화폐와 그 시장에 관한 연구가 활발히 진행되고 있다. 지난 5년간의 국내 암호화폐 관련 연구를 정리해 보면 다음과 같다. 2018년에는 암호화폐에 대한 정의와 가상자산 규제 및 블록체인 기술 기반인 스마트 컨트랙트의 법적 쟁점에 대한 연구가 이루어졌다(고동원, 2018; 김제완, 2018; 민병길, 박원익, 2018; 양영식, 송인방, 2018). 암호화폐 정의 및 제도 관련 연구 외에도 소비자, 산업, 거시 변수를 중심으로 한 비트코인 가격 변화 요인에 대한 실증 분석 연구와 암호화폐시장의 변동성 파급효과에 관한 연구가 일찍이 시작되었다(이준식 등, 2018; 임재욱, 김동주, 2018). 2019년부터는 통계 기법과 다양한 머신러닝 모델을 활용한 비트코인 위주의 암호화폐 가격 예측 연구가 이루어지기 시작했다(윤성욱, 2019; 이기광 등, 2019). 2020년부터는 이전보다 고도화된 다양한 딥러닝 모델을 활용하여 암호화폐 가격을 예측하는 시도들이 있었고 이더리움, 리플 등 주요 알트코인 가격 예측 연구도 점차 진행되었다(최수빈 등, 2020; Alonso- Monsalve et al., 2020). 2021년 이후부터는 암호화폐 가격 예측에 대한 연구에서 나아가 이더리움을 중심으로 블록체인 기술 및 플랫폼 비즈니스에 대한 연구가 활발히 진행되고 있다(김효종 등, 2021; 남원홍, 길현영, 2021; 한정희, 2021). 이처럼 암호화폐시장과 관련된 연구는 제도적인 부분에서 딥러닝 모델을 활용한 암호화폐 가격 예측으로, 가격 예측에서 암호화폐 기반 기술인 블록체인 플랫폼 기술 및 비즈니스에 대한 연구로 확장되고 있다. 암호화폐는 특정 블록체인 네트워크에서 사용되는데, 현존하는 대부분의 탈중앙화 분산 어플리케이션(Decentralized Application, DApp)은

이더리움을 기반으로 하고 있어 사용성 증가에 따른 네트워크 효과로 향후 가치 상승이 기대되는 암호화폐라고 볼 수 있다.

이러한 배경으로 본 연구에서는 연구 대상인 암호화폐를 비트코인이 아닌 이더리움으로 설정하였다. 최근 이더리움은 ERC-20, ERC-721 등 다양한 블록체인 기반 응용 서비스의 기술적 근간이 되는 암호화폐로 미국 투자은행 골드만삭스는 향후 비트코인의 시가총액을 추월할 수 있을 것으로 전망하고 있다(Quiroz-Gutierrez, 2021). 또한, 기술적 거래규칙을 적용해 알트코인의 투자 성과를 분석한 연구에서 투자자가 한 종목에 투자할 경우 이더리움에 집중하는 것이 안정적인 수익구조를 보여준다는 연구결과가 있었다(김선용, 2022).

2.2 가격 예측 및 매매 관련 연구

최근 인공지능의 딥러닝과 머신러닝을 활용한 금융 시계열 데이터의 예측 연구가 활발하게 이루어지고 있다. 금융시장에서는 주가, 지수, 그리고 변동성을 예측하는 연구가 다수 진행되어왔다(류의림 등, 2022; An, 2022; Cho & Lee, 2022).

기존에 딥러닝 모델을 사용한 암호화폐 가격 예측 연구의 경우, 모델의 성능 평가를 통한 가격 예측력의 우수성을 입증한 연구가 있었다(Malsa et al., 2021). 기존 암호화폐 가격과 관련된 연구는 대부분 비트코인 중심으로 이루어져 왔는데, 최근 시가 총액이 높은 알트코인에 대한 가격 예측 연구도 시도되고 있다(Aditya Pai et al., 2022; Sung et al., 2022; Chen, 2020). 이더리움 가격 예측 관련 연구로는 2020년에는 머신러닝 기법 중 선형 회귀와 SVM(Support Vector Machine)을 활용한 이더리움 가격 예측 연구가 진행된 바 있다

(Poongodi et al., 2020). 본 연구와 유사하게 LSTM 모델과 변동성돌파전략을 활용하여 주가 예측 및 투자 성과를 분석한 연구(이은우, 이원부, 2022)에서는 변동성돌파전략 적용 시 매수가 일어난 날들을 학습시킴으로써 다음 날 주식 등락을 예측하여 매매 여부를 판단하는 모델을 제안하였으며, 단순한 LSTM 증가 예측 모델보다 제안 모델의 투자 수익률이 더 우수한 결과가 있었다. 본 연구는 앞의 연구와 달리 변동성돌파전략의 매매 신호를 예측 모델에 학습시키지 않고 독립적인 매매 규칙으로 활용하였다는 점에서 차이가 있다. 또한, 이은우 등(2022)의 연구에서는 제안 모델 개발 시, LSTM 예측 모델에 변동성돌파전략의 매매 신호 데이터를 입력 변수로 활용하였다. 제안 모델의 누적수익률은 17.2%였으며 LSTM 증가 예측 모델은 11.7%, 매수 후 보유 전략은 -12.7%의 결과를 보였다. 즉, 제안 모델의 누적수익률은 매수 후 보유 전략보다 약 30% 높은 수익률을 기록하였다.

본 연구에서는 LSTM 예측 모델로부터 얻은 증가와 변동성돌파전략의 매매 신호를 결합한 매수 조건을 통해 매매를 진행하였다. 실험 결과, 결합모델은 11.35%, LSTM모델은 -50.39%, 매수 후 보유 전략은 -62.95%의 누적수익률을 보였다. 즉, 결합모델의 누적수익률은 매수 후 보유 전략보다 74%를 뛰어넘는 누적수익률을 달성하였다는 점에서 앞의 연구보다 더 우수한 성과를 보임을 알 수 있다. 또한, LSTM 예측 모델을 통한 단순 매매 규칙은 유효하지 않을 수 있음을 발견하였다.

그 밖에도 비트코인 가격을 ARIMA와 RNN을 이용해 예측하고 각 국가의 뉴스 기사를 이용해 추세 변화점을 기준으로 분리하여 학습하는 seperated RNN모형을 제안하여 기존 RNN보다 예측 성능을

높였다는 연구가 있었다(원종관, 홍태호, 2021). 2개의 RNN모델을 결합한 앙상블 모델로 S&P 500 지수를 예측한 연구에서는 MSE, F1-Score, Precision, Recall, Accuracy를 통해 예측 성능을 평가하였는데 전통적인 방법보다 딥러닝 앙상블 모델을 통한 예측 결과가 투자 의사 결정에 더 도움을 줄 수 있다는 결과가 있었다(Li & Pan, 2022). 그러나, 기존 가격 예측 연구 모델의 우수한 성능을 나타내는 지표만으로는 실제 투자 시장에 적용하기 어려운 한계가 존재한다(Andi, 2021). 또한, 앞선 연구에서 사용한 모델의 경우 다음과 같은 한계가 존재한다. 기존 시계열 예측에 널리 사용되는 통계 모형인 ARIMA는 과거 데이터를 바탕으로 만들어진 모형으로 데이터 중심이 아닌 모델 중심으로 예측을 수행한다는 한계가 존재한다. SVM 모델의 경우 머신러닝 모델 중 하나로 예측보다는 학습을 통해 이진 분류를 하는 것을 목적으로 주로 사용된다. RNN 모델은 시계열 데이터에 적합한 딥러닝 모델이지만 데이터의 기간이 길어질수록 먼 과거의 입력 정보는 잊어버려 활용하지 못하는 장기 의존성 문제가 존재한다(Bengio et al., 1994). 따라서 본 연구에서는 데이터의 길이와 상관없이, 모델이 아닌 데이터 중심으로 복잡한 연산을 통하여 향후 증가를 예측하기 위해 LSTM 예측 모형을 사용하였다.

Banik 등(2022)은 인도 주식의 증가를 활용해 가격을 예측하는 연구를 진행하였는데 SVR, ARIMA, Moving Average, Linear Regression 모델보다 LSTM의 RMSE와 MAE가 가장 낮아 LSTM모델이 다른 비교 모델보다 오차가 작다는 것을 보여 주었다. Andi(2021)의 연구에서는 3가지 모델인 Linear regression, Lasso Algorithm, 제안 모델인 LSTM을 사용한 로지스틱 회귀 모델을 사용해 비트코인과 비트코인 캐시의 가격을 예측하였다.

그 결과 Accuracy, Precision, Recall, Sensitivity에서 모두 LSTM을 사용한 로지스틱 회귀 모델이 가장 성능이 좋았다. 그 밖에 김선웅(2021)은 LSTM 예측 모델을 통해 비트코인의 증가를 예측하고 이를 활용한 이동평균선 교차 전략의 수익성을 분석하는 연구를 진행하였다. 가격 예측 시 LSTM의 비교 모델로 RNN 모델을 사용하였으며 LSTM 모델이 RNN모델보다 우수한 예측 성과를 보였다. 비트코인 투자 성과는 이동평균선 교차 전략과 매수 후 보유보다 LSTM 예측 모델을 통한 매매가 각각 5%, 46% 이상의 수익률 개선 효과가 나타나 딥러닝에 기반한 비트코인 가격 예측의 경제적 가치가 존재함을 보여주었다. 또한, 예측 기간에 활용한 데이터는 대부분 큰 상승장을 포함하고 있었기 때문에 결과적으로 높은 수익률을 달성할 수 있다는 것을 확인하였다. 이처럼 다양한 가격 예측 연구에서 LSTM모델의 예측 성능에 대한 우수성이 입증되고 있음을 확인하였다(정현조 등, 2022). 즉, 선행 연구 분석을 통해 딥러닝 모델 중 LSTM이 가격 예측 연구에 활발히 사용되고 있고, 다른 모델보다도 LSTM 예측 모델의 우수한 성능을 확인하여 본 연구에서도 가격 예측 시 LSTM 모델을 사용하였다.

딥러닝 기술이 금융 서비스에 활발하게 사용됨에 따라 딥러닝을 활용한 트레이딩 시스템에 대한 연구도 진행되고 있다. 딥러닝 모델 하나 또는 여러 개를 결합하여 주식시장에서 정량적 투자 전략에 대해 분석하는 연구가 있었다(Liu et al., 2017). LSTM을 사용한 주가 예측과 단기 트레이딩에 대한 연구와 S&P 500 중 정보기술 섹터 주식들의 포트폴리오에 대한 일 별 수익률을 예측하여 알고리즘 트레이딩을 적용하는 시도가 있었다(Banik et al., 2022; Yan & Ouyang, 2018; Lim & Lundgren, 2019). 암호화폐시장이 빠르게

성장함에 따라 주식시장에서 사용한 딥러닝 기법들을 암호화폐시장에 적용해 보는 연구가 많이 진행되고 있다. LSTM과 Locally Weighted Regression을 사용하여 인텔(Intel)의 주가를 예측하여 수익률을 비교하는 연구(Chen et al., 2017)에서는 예측 모델을 통한 트레이딩 규칙은 어제의 증가보다 오늘의 예측 증가가 크면 매수하는 간단한 알고리즘 트레이딩 전략을 사용하였다.

3. 연구 설계 및 방법

3.1 연구 설계

본 연구는 변동성돌파전략과 LSTM을 활용하여 하락 추세였던 2022년 1월부터 5월까지 5개월간의 매매 결과를 통해 투자 성과를 분석하는 실증연구이다. <Figure 1>은 본 논문의 연구 절차를 도식화한 것이다.

본 연구는 4단계의 절차로 수행한다. 첫째, 기술적 투자 전문가인 래리 윌리엄스가 주식시장에서 활용할 목적으로 개발한 변동성돌파전략을 활용하여 암호화폐 투자에서도 좋은 성과를 보이는지 확인한다. 둘째, LSTM모델을 활용해 암호화폐 증가를 예측하고 간단한 트레이딩 규칙을 적용하여 투자 성과를 분석한다. 셋째, 변동성돌파전략과 LSTM모델로부터 얻은 변수를 활용하여 다양한 결합 모델을 만들어 투자 성과 개선에 유의미한 모델인지 탐색한다. 또한, 결합 모델의 결과에 대한 객관적인 타당성을 위해 단기 이동평균 교차 전략에 대한 실험도 진행하여 4가지 실험 모델 중 어떤 모델이 가장 우수한 성과를 보이는지 확인한다. 그 밖에도 연구에서 실험한 시스템 트레이딩과 벤치마크 투자 방식(테일리

트레이딩, 매수 후 보유, 적립식 매수)의 결과를 비교하였다.

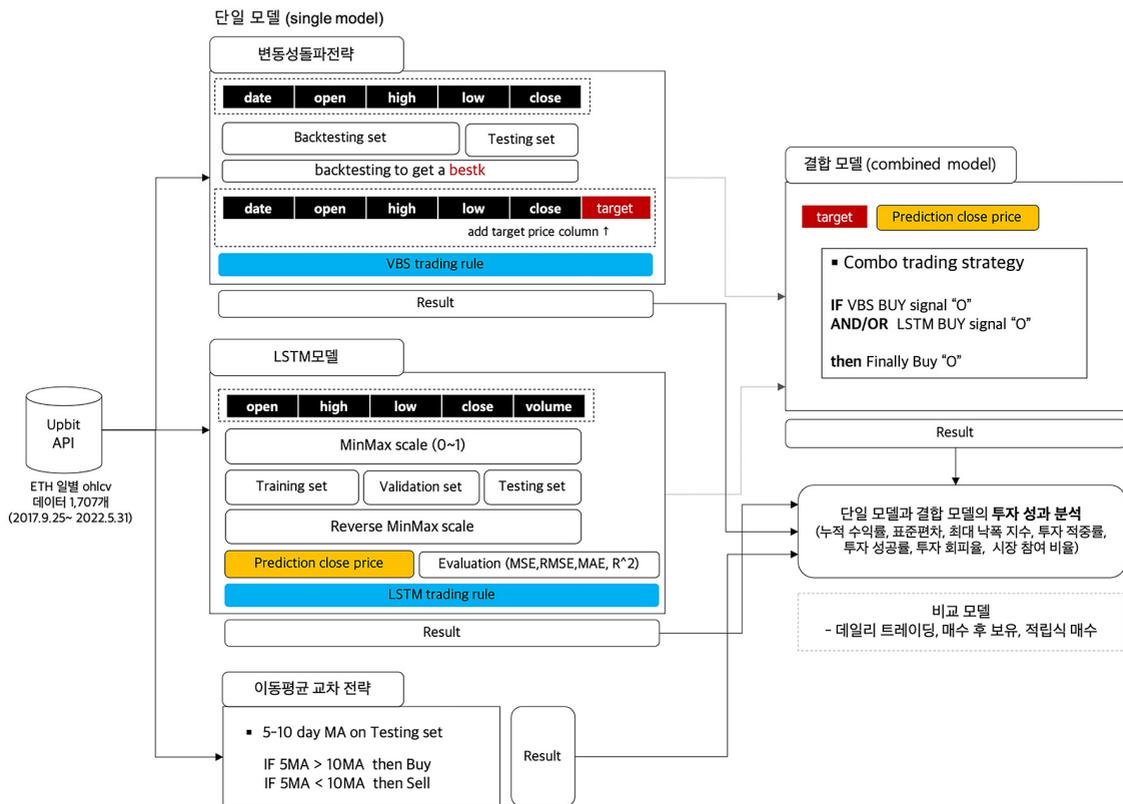
3.2 데이터 수집 및 처리

실험은 구글(Google)의 Colabory(‘Colab’)에서 진행하였다. 국내 암호화폐 거래소 업비트(Upbit)의 API를 통한 암호화폐 이더리움의 가격 데이터이다. 암호화폐 가격 예측 관련 선행연구에서는 일 단위 가격 예측이 가격의 흐름과 방향성을 분석하기 용이하다는 결과가 있었다(McNally et al., 2018; Spilak, 2018). 이에 따라 본 연구에서는 이더리움이 업비트에 처음 상장된 2017년

9월 25일부터 2022년 5월 31일까지의 이더리움 일별 가격 데이터를 수집하였다. 일별 가격 데이터는 거래 날짜(date), 시가(open), 고가(high), 저가(low), 종가(close), 거래량(volume) 6개로 구성되어 있으며, 활용한 가격 단위는 원화이다.

본 연구에서 최종적으로 비교하고자 하는 것은 5개월간의 투자 결과로, 투자 기간은 2022.1.1.~2022.5.31.까지 151일이다. 이에 따라 데이터의 가공은 변동성돌파전략과 LSTM모델에 각각 맞게 진행하였으며 데이터 가공 과정과 형태는 다음과 같다.

변동성돌파전략에서는 2단계에 걸쳐 데이터를 가공하였다. 첫 번째로, 1707개의 전체 데이터에서



〈Figure 1〉 Research Process

테스트 기간을 제외한 기간에서 1549일을 백테스팅 기간으로 설정하였다. 변동성돌파전략에서 6일(2021.12.25.~2021.12.30.)간의 데이터는 LSTM의 학습 기간과 151개의 출력값을 맞춰주기 위해 제외시켰다. 두 번째로, 백테스팅 과정을 거쳐 이더리움 가격 데이터에 가장 최적화 된 k(bestk) 값을 찾고 이 값을 투자 기간에서 활용하였다. 백테스팅은 과거 데이터를 기반으로 트레이딩 전략의 향후 실행 가능성을 테스트하는 것이다. 이더리움 투자 시 누적 수익률을 극대화하는 k 값을 찾기 위해 k 값을 0.1에서 0.9의 경우로 나누어 누적 수익률을 계산하였다. 마지막으로 변동성돌파전략은 1일 전의 가격 데이터를 통해 다음 날의 매수 목표가(target price)를 결정하므로 테스트 데이터 셋은 152(151+1)일로 설정하였다.

LSTM모델에서는 데이터의 학습을 위해 3단계의 전처리 과정을 거쳤다. 데이터 정제, 데이터 정규화, 그리고 데이터 분할 과정이다. 첫 번째로 암호화폐 가격 예측 모델의 학습에 필요한 입력 데이터(feature)는 시가(open), 고가(high), 저가(low), 종가(close), 거래량(volume) 5가지의 데이터이므로 날짜(date) 열은 제외하여 데이터 프레임을 재구성하였다. 두 번째로 데이터 정규화(Normalization) 과정인 Min-Max Scaling을 통해 모든 입력값들을 0과 1 사이의 값을 가지도록 변환하여 학습하였다. Min-Max Scale의 계산식은 다음과 같다. X는 모든 입력값(feature)을 의미하며 X_{min} 는 입력값들 중 최소값, X_{max} 는 입력값들 중 최대값을 나타낸다.

$$\frac{X - X_{min}}{X_{max} - X_{min}}$$

세 번째로 training set/validation set/testing set

설정을 위해 데이터 분할 과정을 거쳤다. 2022년 1월 1일부터 5월 31일(151일)이 투자 기간이고 과거 7일을 데이터를 학습에 사용하므로 158(151+7)일을 testing set으로 설정하였다. 나머지 1549일 데이터 셋은 sklearn.model_selection 패키지의 train_test_split 함수를 사용하여 training set과 validation set을 8:2의 비율로 분할하였다.

이동평균 교차 매매 전략은 별도의 백테스팅 및 학습 과정을 거치지 않았다. 이미 검증된 기술적 매매규칙이므로 이동평균선은 단기 이동평균선인 5일 이동평균선과 10일 이동평균선을 활용하였다. 이에 따라 테스트 기간을 기준으로 과거 5일, 10일에 대한 종가 데이터가 필요하므로 총 161(151+10)일치의 종가 데이터를 활용하여 실험을 진행하였다.

결합 모델도 마찬가지로 백테스팅 및 학습 과정 없이 투자 기간에 두 가지 단일 모델(변동성돌파전략, LSTM모델)에서 얻은 파생 변수를 활용하였다. 결합 모델의 매매 규칙 중 매수 조건으로 2일 전의 가격 데이터를 사용하는 규칙이 있어 투자 시작일 기준 2일 전의 가격 데이터가 필요하므로 결합 모델의 경우 153(151+2)일치의 종가 데이터를 사용하였다.

3.3 연구 방법

3.3.1 변동성돌파전략

변동성돌파전략은 변동성이 높을 때 매매를 하는 전략이다. 변동성돌파전략의 규칙은 다음과 같다. 첫째, 전날 일봉의 고가와 저가를 기준으로 range를 계산한다. range는 고가에서 저가를 차감한 값이다. 둘째, 당일 장중 가격이 당일 시가에 전날의 k(상수) × range를 더한 값보다 클 경우 매수한다. 이때 k 값은 기본적으로 0.5로 설

정하지만 0.1~0.9 사이의 k 값 중 백테스팅을 통해 최고 수익률을 달성하는 최적의 k 값을 찾아 설정할 수 있다. 본 연구에서는 1549일의 이더리움 일별 가격데이터를 백테스팅에 활용하여 최적의 k값을 <Figure 2>와 같이 발견하였다. k가 0.3일 때, 누적수익률이 4434.9%로 가장 높아 0.3을 최적의 k값으로 설정하였다.

backtesting set						백테스팅 투자기간:1549 일	
	date	open	high	low	close		
0	2017.9.25	324500	326500	320000	325000	k=0.1	crr=0.583
1	2017.9.26	325000	328500	320000	321500	k=0.2	crr=5.199
2	2017.9.27	321000	325000	320000	324500	k=0.3	crr=44.349
3	2017.9.28	342000	346500	327000	332500	k=0.4	crr=39.549
4	2017.9.29	331000	333500	312500	327500	k=0.5	crr=18.659
...
1544	2021.12.20	4899000	4947000	4700000	4866000	k=0.6	crr=28.804
1545	2021.12.21	4866000	4996000	4818000	4936000	k=0.7	crr=19.341
1546	2021.12.22	4937000	4990000	4850000	4893000	k=0.8	crr=19.137
1547	2021.12.23	4893000	5010000	4802000	4871000	k=0.9	crr=12.876
1548	2021.12.24	4971000	5025000	4913000	4937000		

<Figure 2> Backtesting result for best k

셋째, 매수했을 경우, 당일 종가를 기준으로 매도하여 일별 수익률을 계산한다. <Table 1>은 변동성 돌파전략에 대한 pseudo code이다. $range_{t-1}$ 은 전일 고가에서 전일 저가를 뺀 값으로 전일의 가격 변동폭을 나타낸다. $target_t$ 은 오늘의 목표 매수가로, 오늘의 시가에 전일의 가격 변동폭과 k값을 곱하고 더하여 구한다. 변동성 돌파전략의 매수 조건은 오늘의 특정 시점의 가격이 오늘의 목표가가 되면 매수하는 것이다. 즉, 매수 조건을 오늘의 고가가 오늘의 목표가보다 크면 특정 시점에 오늘의 목표가를 도달한 것으로 보고 매수한 것으로 판단한다. ror_t 은 return of rate의 약어로 오늘의 로그수익률을 나타낸다. 변동성 돌파전략은 오늘의 목표가에 매수하고 오늘의 종가에 매도하므로 오늘의 로그 수익률은 오늘의 종가를 오늘의 목표가로 나누고 로그를 씌운 값으로 계산할 수 있다. 이 때 매수 조건이 만족하지 않는 경우, 매수가 일어나지 않으므로 오늘의

수익률은 0이 된다.

<Table 2>는 백테스팅을 통해 최적의(best k) 값을 도출한 과정이다. k가 0.3일 때, 누적 수익률이 44.349(4434.9%)로 가장 높아 이를 최적의 k로 설정하였다.

<Table 1> Volatility Breakout Strategy

Trading rule and rate of return
$range_{t-1} = high_{t-1} - low_{t-1}$ $target_t = open_t + (range_{t-1} \times k)$
If $high_t > target_t$ then Buy for $target_t$ Sell for $close_t$
$ror_t = \ln\left(\frac{close_t}{target_t}\right)$

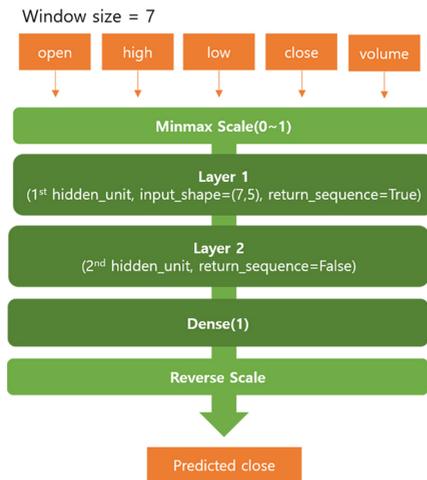
<Table 2> Backtesting results to find the best k

k	Cumulative Return
0.1	0.583
0.2	5.199
0.3	44.349
0.4	39.549
0.5	18.659
0.6	28.804
0.7	19.341
0.8	19.137
0.9	12.876

3.3.2 LSTM모델

본 연구에서 사용한 LSTM 구조는 <Figure 3>과 같다. 2개의 LSTM모델을 사용한 2-layer LSTM 모델을 사용하였다. Stacked LSTM은 LSTM이

더 복잡한 task를 해결할 수 있도록, 모델의 복잡도를 높이는 방법 중 하나이다. 신경망에서 모델의 성능을 향상시키기 위해 은닉층의 노드 개수를 과도하게 증가시키는 것보다 층(layer)을 깊게 쌓는 것이 더 효율적인 방법으로 알려져 있다.



<Figure 3> LSTM structure

학습/검증/테스트 과정을 거쳐 다음 날의 종가를 가장 잘 예측하는 LSTM모델을 얻기 위해 Learning rate, 1st Layer unit, 2nd Layer unit, Epoch, Batch size, Loss function 6가지의 하이퍼파라미터를 다르게 튜닝하여 <Table 3>과 같이 5개의 예측 후보 모델(candidate models)을 만들어 실험하였다.

<Table 3> Candidate Models

	Model1	Model2	Model3	Model4	Model5
Learning rate	0.002	0.001	0.002	0.001	0.002
1st Layer unit	64	64	64	64	64
2nd Layer unit	4	4	4	4	4
Epoch	200	200	200	200	200
Batch size	16	16	64	32	32
Loss function	MSE	MSE	MSE	MSE	MSE

<Table 4> Training/Validation loss

	Training loss	Validation loss
Model1	0.00021	0.00030
Model2	0.00019	0.00028
Model3	0.00023	0.000236
Model4	0.00022	0.000244
Model5	0.00021	0.00025

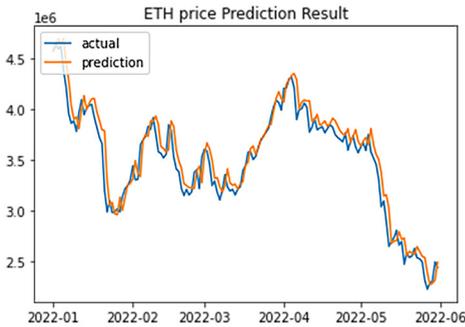
<Table 4>는 5가지 모델 별 훈련/검증 모델의 손실 값을 나타낸 표이다. 이 때 사용한 Loss function은 예측 값과 실제 값의 차이를 계산하는 함수로 모델의 하이퍼파라미터 설정 시 MSE로 설정하였으므로 결과의 loss도 MSE 값으로 나타내었다. 학습 결과인 Training loss를 통해 5가지 모델이 잘 학습된 것을 확인하였다. 모델의 학습 결과를 통해 예측 모델을 선정할 때는 학습 기간이 아닌, 테스트 기간을 잘 예측해야하므로 검증 결과가 더 좋은 모델을 최종 예측 모델로 선택하였다. 검증 결과, Model3의 Validation loss가 0.000236으로 가장 낮아 이를 최적의 예측 모델로 선택하였으며 본 연구에서 활용한 모델의 최적의 하이퍼파라미터는 <Table 5>와 같다.

<Table 5> Optimal Hyperparameter for Model3

	Model3
Learning rate	0.002
1st Layer unit	64
2nd Layer unit	4
Epoch	200
Batch size	64
Loss function	MSE

과거 7일간의 데이터를 바탕으로 다음 날의 종가를 예측하고자 하였으므로 Window size는 7로

설정하였고, 활성화 함수(activation function)는 평균이 0이고 -1과 1사이의 출력값을 가지는 하이퍼볼릭 탄젠트(hyperbolic tangent)를 이용하였다. 옵티마이저(optimizer)는 오차 감소 속도가 빠른 Adam을 사용하였다. 검증 결과, valid loss가 0.000236으로 이를 예측 모델로 사용하였다.



<Figure 4> LSTM Prediction result

<Figure 4>는 5개월간의 투자기간 중 실제 증가와 LSTM모델의 예측 증가 그래프이다. 모델의 예측 결과 RMSE는 145,765.275 MAE는 107,796.103이고 MAPE는 0.032, R^2 은 0.921로 잘 예측하는 것을 확인하였다. LSTM 예측 모델은 예측 증가 하나만을 출력하기 때문에 트레이딩을 위해서는 선행 연구를 토대로 단순 매매 규칙을 적용해주어 LSTM모델의 투자 성과를 분석하였다. <Table 6>은 LSTM 모델에 대한 pseudo code이다.

<Table 6> LSTM Trading Strategy

Trading rule and rate of return
$\text{If } pred_t > close_{t-1}$ $\text{then Buy for } open_t$ $\text{Sell } close_t$ $ror_t = \ln\left(\frac{close_t}{open_t}\right)$

$pred_t$ 은 오늘의 예측 증가이고 $close_{t-1}$ 은 어제의 증가를 나타낸다. LSTM모델의 단순 매수 규칙은 어제의 증가보다 오늘의 예측 증가가 크면 매수하는 것이다. 따라서 본 매수 조건이 만족하면 오늘의 시가에 매수하고 오늘의 증가에 매도하여 오늘의 로그 수익률을 구한다. 매수 조건을 만족하지 않는 경우, 오늘의 수익률은 0이 된다.

3.3.3 이동평균 교차 전략

본 논문은 결합 모델의 투자 전략에 대한 타당성을 판단하기 위해 기존에 기술적 매매 신호로 널리 사용되고 있는 단기 이동평균선을 활용하여 실험을 진행하였다. 암호화폐시장은 1일 24시간 동안 개장인 점과 이은우 등(2022)연구에서 단기매매를 위해 단기 이동평균 교차 전략을 사용한 것을 고려하여 5일 10일 이동평균 교차를 통한 매매규칙을 적용하였다. <Table 7>은 이동평균 교차 전략에 대한 pseudo code이다. $5MA_t$ 는 오늘의 5일 이동평균치, $10MA_t$ 는 오늘의 10일 이동평균치를 나타낸다. 즉, 오늘(t시점)을 기준으로 과거 5일간의 이동평균치, 오늘(t시점)을 기준으로 과거 10일간의 이동평균치이다. 본 연구에서 사용한 이동평균 교차 전략은 5일 이동평균치가 10일 이동평균치 보다 크면 상승 추세로 판단하여 오늘 증가에 매수하고, 특정 시점(k 시점)에 작아지면 하락 추세로 판단하여 오늘의 증가에 매도하는 것이다. 매수/매도 조건을 만족하지 않는 경우, 수익률이 0이거나 기존 수익률을 유지하게 된다.

〈Table 7〉 Moving Average Cross Strategy

Trading rule and rate of return
<p><i>If</i> $5MA_t > 10MA_t$ <i>then Buy</i> for $close_t$</p> <p><i>Elif</i> $5MA_{t+k} < 10MA_{t+k}$ <i>then Sell</i> for $close_{t+k}$</p> <p>$ror_{t+k} = \ln\left(\frac{Sell\ price_{t+k}}{Buy\ price_t}\right)$</p>

3.3.4 결합 모델

본 연구에서 제안하는 결합 모델은 변동성 돌파전략에서 얻은 목표 매수가와 LSTM모델로 예측하여 얻은 예측 종가를 활용하여 독창적인 투자 전략을 고안한 것이다. 결합 모델은 공격적(Aggressive) 투자와 보수적(Conservative) 투자 2가지 유형으로, 단일 모델에서 활용한 조건문을 결합하여 공격적 투자의 경우 OR를, 보수적 투자의 경우 AND를 활용한 것이다. 즉, 보수적 투자 방식은 변동성 돌파전략의 매수 신호와 LSTM 매수 신호가 동시에 만족할 때 매수하는 것이고, 공격적 투자 방식은 변동성 돌파전략의 매수 신호 또는 LSTM 매수 신호 둘 중 하나라도 만족하면 매수를 결정하는 것이다. 이 과정에서 결합 모델의 매수 결정 조건을 달리하여 10가지의 투자 전략을 구성하였고 테스트 기간에 적용 후 7가지의 투자 성과 지표를 통해 투자 성과를 분석하였다. 결합 모델의 매매 규칙은 <Table 8>과 같다.

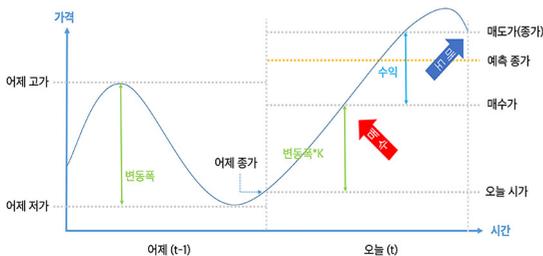
결합 모델 매매 규칙에서 ‘Combo’는 결합한 모델(combined model)의 줄인 말로 결합 모델을 의미하며, ‘MCombo’는 Median price를 사용한 결합 모델을 나타낸다. Median price는 당일 고가와 저가의 중간값으로 가격의 평균이나 중앙값의 개념으로 가격의 추세를 파악하는 보조 지표

이다. ‘1, 2, 3’은 트레이딩 규칙의 종류를, ‘A, C’는 공격적 투자 유형과 보수적 투자 유형을 표시한 것이다. 결합 모델의 매매 규칙은 수집한 일별 가격 데이터로부터 얻는 변수를 조합하여 구성하였다.

〈Table 8〉 Combined Model Strategies

Combo1-A	Combo1-C
<p><i>if</i> $high_t > target_t$ <i>OR</i> $pred_t > target_t$ <i>then Buy</i> for $target_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{target_t}\right)$</p>	<p><i>if</i> $high_t > target_t$ <i>AND</i> $pred_t > target_t$ <i>then Buy</i> for $target_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{target_t}\right)$</p>
Combo2-A	Combo2-C
<p><i>If</i> $high_t > target_t$ <i>OR</i> $pred_t > close_{t-1}$ <i>then Buy</i> for $target_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{target_t}\right)$</p>	<p><i>If</i> $high_t > target_t$ <i>AND</i> $pred_t > close_{t-1}$ <i>then Buy</i> for $target_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{target_t}\right)$</p>
Combo3-A	Combo3-C
<p><i>If</i> $high_{t-1} > target_{t-1}$ <i>OR</i> $pred_t > close_{t-1}$ <i>then Buy</i> for $open_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{open_t}\right)$</p>	<p><i>If</i> $high_{t-1} > target_{t-1}$ <i>AND</i> $pred_t > close_{t-1}$ <i>then Buy</i> for $open_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{open_t}\right)$</p>
MCombo1-A	MCombo1-C
<p><i>If</i> $high_t > target_t$ <i>OR</i> $pred_t > median_{t-1}$ <i>then Buy</i> for $target_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{target_t}\right)$</p>	<p><i>If</i> $high_t > target_t$ <i>AND</i> $pred_t > median_{t-1}$ <i>then Buy</i> for $target_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{target_t}\right)$</p>
MCombo3-A	MCombo3-C
<p><i>If</i> $high_{t-1} > target_{t-1}$ <i>OR</i> $pred_t > median_{t-1}$ <i>then Buy</i> for $open_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{open_t}\right)$</p>	<p><i>If</i> $high_{t-1} > target_{t-1}$ <i>AND</i> $pred_t > median_{t-1}$ <i>then Buy</i> for $open_t$</p> <p>$ror_t = \ln\left(\frac{close_t}{open_t}\right)$</p>

Combo1-A의 경우, 매수 조건에 OR가 있는 공격적 유형으로 두 가지 매수 조건 중 하나라도 만족하면 오늘의 목표가에 매수하는 전략이다. 첫 번째 매수 조건은 변동성돌파전략의 매수 조건이 만족하는 것이다. 오늘의 고가가 오늘의 목표가보다 크면 매수가 이루어진 것으로 보기 때문에 이를 하나의 매수 조건으로 두었다. 두 번째 매수 조건은 LSTM모델에서 얻은 오늘의 예측 증가가 오늘 목표가보다 크면 매수가 이루어지는 것이다. Combo1-C의 경우, 매수 조건에 AND가 있는 보수적 유형이므로 두 가지 매수 조건이 모두 성립할 때 매수가 이루어진다(조대표, 유대표, 2021). <Figure 5>는 결합 모델의 매매 예시 그래프이다.



<Figure 5> Combined Model's Trading Example

나머지 8가지의 결합 모델은 Combo1 매매 규칙을 토대로 매수 시점 및 조건을 변형한 것이다. Combo2는 Combo1의 두 번째 매수 조건의 오늘의 목표가를 어제의 증가로 바꾸어 준 것이고, Combo3은 Combo2의 매수 조건에서 첫 번째 조건에서 오늘의 변동성돌파전략을 어제의 변동성돌파전략으로 바꾼 것이다. MCombo1은 Combo1의 두 번째 매수 조건인 오늘의 목표가 대신 어제의 Median price 변수를 사용하였다. MCombo3은 MCombo1의 매수 조건에서 오늘의 변동성돌파전략 대신

어제의 변동성돌파전략을 사용한 것이다. MCombo 전략은 오늘의 예측 증가와 비교하는 대상이 어제의 증가가 아닌 어제의 Median price이다.

4. 연구 결과

실험 모델의 투자 성과 분석을 위해 여러 투자 성과 지표를 사용함으로써 투자 모델에 대한 성능을 다방면으로 평가 및 해석하였다. <Table 9>는 본 연구에서 사용한 누적 수익률을 포함한 투자 성과 지표이다. 수익률을 안정적으로 얻을 수 있는지를 나타내는 누적 수익률의 표준편차, 전체 투자 기간 중에서 매수 시 양의 수익의 빈도와 매수하지 않았을 때 음의 수익의 빈도를 더한 투자 적중률, 투자 적중률을 세분화한 것으로 매수했을 때 양의 수익을 얻은 경우를 나타내는 투자 성공률, 매수하지 않았을 경우 음의 수익을 나타내는 비율인 투자 회피율이 있다. 최대 누적 수익률 대비 최저 누적 수익률의 낙폭을 계산하는 최대 낙폭 지수는 투자자의 투자 스트레스를 나타내는 지표이고, 시장 참여 비율은 매수하는 과정에서 시장 위험에 노출된 정도를 나타낸다. 본 연구에서 제안하는 실험 모델이 실제 우수한 성과를 보였는지 입증하기 위해 매수 후 보유, 데일리 트레이딩, 적립식 투자 등과 같은 비교 모델을 설정하였다.

(Table 9) Investment Performance Indicators

누적 수익률	$\prod_{t=1}^n (1 + \ln(\frac{Sell\ price_t}{Buy\ price_t})) - 1$
표준편차	$\sqrt{\frac{(cr_1 - m)^2 + \dots + (cr_t - m)^2}{t}}$
투자 적중률	$\frac{Win\ time}{Period}$
투자 성공률	$\frac{Win\ time}{Buy\ time}$
투자 회피율	$\frac{Avoid\ time}{No\ Buy\ time}$
최대 낙폭 지수	$MIN(\frac{cr+1}{peak\ cr+1} - 1)$
시장 참여 비율	$\frac{Buy\ time}{Period}$

최근 4년간의 이더리움 가격 데이터를 활용하여 실험 모델 별 투자 전략을 적용한 결과, 단일 모델보다 결합 모델의 투자 성과가 우수함을 보였다. <Table 10>은 실험 모델에 대한 투자 결과이며 <Table 11>는 전체 결합 모델의 투자 결과이다. 결합 모델 Combo1-C의 누적 수익률은 11.35%로 투자 기간이 하락이 지속되는 기간이 있음에도 불구하고 양의 수익률을 보이는 것을 확인하였다. 이는 함께 실험한 단일 모델인 변동성돌파전략, LSTM모델, 이동평균교차 전략보다 높은 수치이다.

단일 모델의 누적 수익률은 변동성돌파전략이 -8.25%, LSTM모델이 -50.39%로 많은 선행연구에서 수익률 비교 모델로 사용하는 매수 후 보유가 -62.95% 이상인 것에 비하여 어느 정도 하락에 방어할 수 있음을 확인하였다. LSTM모델의 경우,

예측 증가 그래프가 실제 증가 그래프 위쪽에서 후행하였는데 이에 단순 매매 규칙을 적용한 결과 낮은 수익률을 보였다. 즉, 가격 데이터만을 활용한 LSTM 예측 모델을 통한 단순 매매 규칙은 유효하지 않을 수 있음을 나타내기도 했다.

그 밖에도 본 연구 결과의 객관적인 타당성을 입증하기 위해 사용한 비교 모델의 누적 수익률과 최대 낙폭 지수도 비교해 보았다. <Table 12>은 비교 모델에 대한 투자 결과이다. 첫 번째 비교 모델은 데일리 트레이딩으로 당일 시가에 매수해서 당일 종가에 매도하는 일일 매매 전략이다. 3일 적립, 5일 적립, 주(7일) 적립, 월(30일) 적립식 등의 적립식 투자는 투자 시작일 당일 종가에 매수해서 n일 간격으로 n일째 되는 날의 종가에 매수만 하고 투자 종료일 종가에 매도하는 방법이다 (n=3, 5, 7, 30). 매수 후 보유 전략은 투자 시작일 종가에 매수하여 투자 종료일 종가에 매도하는 전략이다. 결합 모델과 비교해 본 결과 수익률과 안정성 면에서 결합 모델의 전략이 매우 우수한 것을 확인하였다. <Figure 6>은 본 연구에서 사용한 전체 모델의 누적 수익률 그래프로, 결합 모델 Combo1-C의 수익률이 가장 높은 것을 확인할 수 있다. 즉, 딥러닝 예측 모델을 통한 예측 가격과 기존 단기 매매 전략인 변동성돌파전략을 결합한 매매 전략 중에서도 변동성돌파전략의 매수 조건을 만족하고, 오늘의 예측 증가가 오늘의 목표가보다 큰 경우 매수하여 당일 종가에 매도하는 투자 전략이 가장 우수했다. 본 연구의 결과를 통해 딥러닝 예측 모델을 토대로 한 여러 매매 조건을 실험하여 하락이 지속되는 기간에도 투자 성과를 상당히 개선하는 투자 전략이 있음을 확인하였다.

〈Table 10〉 Investment Results of Experimental Models

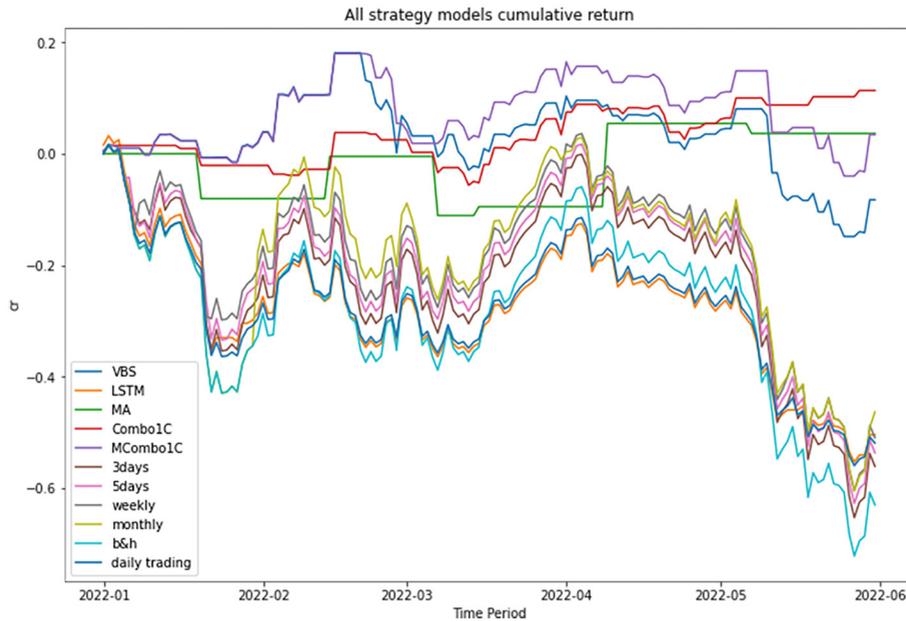
	변동성 돌파전략	LSTM모델	이동평균 교차 전략	Combo1-C	MCombo1-C
누적 수익률	-8.25%	-50.39%	3.64%	11.35%	3.43%
표준편차	0.0690	0.1182	0.0600	0.0472	0.0610
투자 적중률	69.54%	50.99%	50%	74.17%	72.85%
투자 성공률	49.45%	52.11%	50%	56%	52.63%
투자 회피율	100%	33.33%	50%	83.17%	93.33%
최대 낙폭 지수	-27.89%	-56.65%	-11.08%	-9.12%	-18.60%
시장 참여 비율	60.26%	94.04%	32.45%	33.11%	50.33%

〈Table 11〉 Investment Results of All Combined Models

	누적 수익률	표준편차	투자 적중률	투자 성공률	투자 회피율	최대 낙폭 지수	시장 참여 비율
Combo1-C	11.35%	0.047	74.17%	56%	83.17%	-9.12%	33.11%
MCombo1-C	3.43%	0.061	72.85%	52.63%	93.33%	-18.60%	50.33%
MCombo3-C	-4.82%	0.194	75.50%	56.98%	100%	-41.76%	56.95%
Combo2-C	-9.59%	0.070	68.87%	48.84%	95.38%	-28.47%	56.95%
Combo3-C	-12.97%	0.197	54.97%	57.14%	52.24%	-44.40%	55.63%
MCombo3-A	-46.03%	0.149	51.66%	52.67%	45%	-57.36%	86.75%
Combo3-A	-51.97%	0.121	52.98%	52.35%	100%	-57.48%	98.68%
Combo1-A	-74.99%	0.120	52.32%	38.46%	100%	-77.12%	77.48%
MCombo1-A	-91.71%	0.223	70.20%	68.09%	100%	-92.02%	93.38%
Combo2-A	-95.26%	0.228	32.45%	30.61%	100%	-95.66%	97.35%

〈Table 12〉 Investment Results of Comparative Models

	데일리 트레이딩	3일 적립	5일 적립	주 적립	월 적립	매수 후 보유
누적 수익률	-51.86%	-56.04%	-53.61%	-50.91%	-46.30%	-62.95%
최대 낙폭 지수	-56.64%	-65.81%	-63.33%	-61.77%	-61.58%	-72.57%
시장 참여 비율	100%	100%	100%	100%	100%	100%



〈Figure 6〉 Cumulative returns for the All Models

5. 결론

본 연구의 의의는 다음과 같다. 첫째, 기존 주식시장에서 활용하는 기술적 투자 방법을 암호화폐시장에 적용한 결과 유의미한 투자 성과를 보였으며 향후 더 다양한 기술적 투자 방법을 활용해 암호화폐 시스템 트레이딩에 적용해 볼 수 있는 가능성을 제공하였다.

둘째, 딥러닝 모델과 단기매매전략을 결합한 모델이 기존 단일 모델의 투자 성과를 개선하였다. 많은 선행 연구에서 기술적 매매 방법으로 사용하는 이동평균 교차 전략보다 7% 이상의 높은 수익률을 보여 유효한 전략임을 확인하였다.

셋째, 딥러닝 예측 모델과 기존 단기매매전략을 통해 얻은 파생 변수를 활용해 여러 매매 규칙을 구성하고 적용 가능성을 확인해 보는 시도

를 하였다. 가격 데이터 중에서 추세를 파악할 수 있는 여러 파생 변수를 적절히 조합하여 매매 규칙에 대한 유효성을 검증해 변동성 시장에서 단기 매매전략의 최적의 조합을 찾았다는 것에 의의가 있다.

마지막으로, 변동성이 큰 암호화폐시장에서 안정적으로 투자할 수 있는 기술적 방법이 있음을 확인하였다. 이에 따라, 이더리움 투자자 및 암호화폐 AI 트레이딩 개발사에게 실무적 적용 가능성을 보여주었다.

연구의 기여점은 다음과 같다. 첫째, 본 연구는 암호화폐 관련 연구 추이 및 글로벌 암호화폐 시장 2위이면서 탈중앙화 분산 어플리케이션 시장 점유율이 가장 높은 이더리움을 연구 대상으로 하였고, 암호화폐 가격 예측과 더불어 이를 활용한 투자 방법론을 실험하는 실증 연구로 발

전시켰다. 기존에는 다양한 딥러닝 모델을 통해 비트코인 위주의 암호화폐 가격 예측만을 시도한 연구가 많았다. 딥러닝 기반 가격 예측을 시도한 선행 연구 결과에서는 RMSE와 같은 모델의 성능 평가 지표가 개선된 것을 언급하였지만 그러한 지표만으로 실제 투자에 적용하는 것에는 어려움이 있었다. 본 연구에서는 이러한 한계를 극복하여 딥러닝과 단기매매전략을 활용하여 투자 시뮬레이션을 진행하여 투자 성과를 분석하였다.

둘째, 본 연구의 예측 및 투자 기간은 5개월간의 하락이 지속되던 장에 후행하는 LSTM 예측 모델의 한계를 발견하였다. 선행 연구의 예측 기간 대부분 최고점을 포함한 큰 상승장이 있어 단순 LSTM 예측 모델로도 높은 누적 수익률을 달성할 수 있었지만, 최저점을 포함한 단기 하락장에서도 유의미한지 성과를 내는 예측 모델인지 알 수 없는 한계가 존재했다. 본 연구를 통해 이전의 데이터를 후행하는 경향이 있는 단순 LSTM 예측 모델 기반 투자의 한계점을 확인할 수 있었다. 연구 결과, 가격 데이터만을 활용한 LSTM 예측 모델로 높은 누적 수익률을 달성할 수 있다는 것은 시장의 상황 별로 그 결과가 달랐다. 따라서 가격 예측 연구로 많이 활용되는 딥러닝 모델을 단순 매매 전략 방식을 적용하여 실제 투자에 활용하는 경우 유의해야 함을 밝혔다.

셋째, 딥러닝과 단기매매전략을 결합한 새로운 기술적 매매 방법을 통해 다양한 암호화폐 투자 방법을 모색하였다. 기존 트레이딩 관련 연구에서는 딥러닝 모델 또는 기술적 거래 규칙만을 활용한 연구가 진행되었고 이를 결합한 연구는 거의 존재하지 않았다. 본 연구와 유사하게 LSTM과 변동성돌과전략을 활용하여 주가 등락을 예측해 매매 방법을 제안하는 연구가 있었으

나, 실제 적용하기에는 방대한 학습 데이터를 활용하였다는 점과 5000번의 과도한 학습 횟수를 통해 특정 종목에 국한된 투자만 가능하다는 한계가 존재했다. 본 연구에서는 대부분의 암호화폐가 변동성이 크다는 특징을 가짐에 따라 암호화폐 투자 시 실제 적용할 수 있는 다양한 투자 규칙을 고안하고 실험함으로써 암호화폐를 대상으로 여러 기술적 투자 방법에 대한 실효성에 대해 분석하였다. 매매 규칙 또한 수집한 데이터에 근거하여 일별 가격 데이터로부터 추세 파악 매수 조건을 설정하였고, 큰 변동성에 최적화된 투자 방법을 찾고자 실증 분석을 시도하였다.

참고문헌(References)

[국내 문헌]

- 고동원. (2018). 암호화자산 거래와 제도화 방안. *상사판례연구*, 31(4), 291-318.
- 김선웅. (2021). 딥러닝을 이용한 비트코인 투자 전략의 성과 분석. *한국융합학회논문지*, 12(4), 249-258.
- 김선웅. (2022). 기술적 거래 규칙을 이용한 알트코인 투자의 성과. *한국산학기술학회 논문지*, 23(6), 198-207.
- 김제완. (2018). 블록체인 기술의 계약법 적용상의 쟁점-‘스마트계약 (Smart Contract)’을 중심으로. *법조*, 67(1), 150-200.
- 김효중, 한근희, 신승수. (2021). 이더리움 기반의 이더를 사용한 법원 경매 시스템에 관한 연구. *융합정보논문지*, 11(2), 31-40.
- 남원홍, 길현영. (2021). 이더리움 스마트 컨트랙트 검증을 위한 ATL 모델 채킹. *전기학회논문지*, 70(12), 2006-2014.

- 류의림, 이기용, 정연돈. (2022). 호가창과 뉴스 헤드라인을 이용한 딥러닝 기반 주가 변동 예측 기법. 한국전자거래학회지, 27(1), 63-79.
- 민병길, 박원익. (2018). 암호화폐의 현황과 현대 화폐이론 (MMT) 관점에서의 비판. 경기연구원 기본연구, 1-125.
- 양영식, 송인방. (2018). 블록체인 스마트계약의 상용화 대비를 위한 법적 과제. 법학연구, 18(2), 105-130.
- 양훈석, 김선웅, 최홍식. (2019). M&W 파동 패턴과 유전자 알고리즘을 이용한 주식 매매 시스템 개발. 지능정보연구, 25(1), 63-83.
- 원종관, 홍태호. (2021). 텍스트 마이닝과 딥러닝을 활용한 암호화폐 가격 예측: 한국과 미국시장 비교. 지식경영연구, 22(2), 1-17.
- 윤성욱. (2019). Analyzing Impact of Bitcoin Features to Bitcoin Price via Machine Learning Techniques. 정보과학회 컴퓨팅의 실제 논문지, 25(7), 329-334.
- 이기광, 조수지, 민경수, 양철원. (2019). 비트코인 가격의 결정요인: 한국시장에 대한 실증 분석. 한국증권학회지, 48(4), 393-415.
- 이은우, 이원부. (2022). 심층 신경망을 이용한 변동성 돌파전략 기반 주식 매매 방법에 관한 연구. 한국콘텐츠학회논문지, 22(3), 81-93
- 이준식, 김건우, 박도형. (2018). 비트코인 가격 변화에 관한 실증분석: 소비자, 산업, 그리고 거시변수를 중심으로. 지능정보연구, 24(2), 195-220.
- 임재욱, 김동주. (2018). 암호화폐 시장의 변동성 과급효과에 관한 연구. Journal of The Korean Data Analysis Society, 20(4), 1883-1895.
- 정현조, 이재환, 서지혜. (2022). LSTM 모델을 이용한 조각투자 상품의 가격 예측: 뮤직카우를 중심으로. 지능정보연구, 28(4), 81-94.
- 조대표, 유대표. (2021). 파이썬을 이용한 비트코인 자동매매 (실시간 자동매매 시스템 개발 입문, 개정판). 파이스타.
- 최수빈, 신동훈, 윤상혁, 김희웅. (2020). 암호화폐 가격 예측을 위한 딥러닝 앙상블 모델링 : Deep 4-LSTM Ensemble Model. 한국IT서비스학회지, 19(6), 131-144.
- 한정희. (2021). 블록체인 부동산 등기와 스마트 계약. 한국정보통신학회논문지, 25(2), 286-293.

[국외 문헌]

- Aditya Pai, B., Devareddy, L., Hegde, S., & Ramya, B. S. (2022). A time series cryptocurrency price prediction using lstm. In Emerging Research in Computing, Information, Communication and Applications: ERCICA 2020, Volume 2, 653-662.
- Alonso-Monsalve, S., Suárez-Cetrulo, A. L., Cervantes, A., & Quintana, D. (2020). Convolution on neural networks for high-frequency trend prediction of cryptocurrency exchange rates using technical indicators. Expert Systems with Applications, 149.
- An, C. H. (2022). Prediction Model Estimation and Dynamic Characteristics Analysis of Exchange Rate and KOSDAQ Index. International Journal of Intelligent Systems and Applications in Engineering, 10(1s), 171-177.
- Andi, H. K. (2021). An accurate bitcoin price prediction using logistic regression with LSTM machine learning model. Journal of Soft Computing Paradigm, 3(3), 205-217.
- Banik, S., Sharma, N., Mangla, M., Mohanty, S. N., & Shitharth, S. (2022). LSTM based decision support system for swing trading in stock market. Knowledge-Based Systems, 239.
- Bengio, Y., Simard, P., & Frasconi, P. (1994).

- Learning long-term dependencies with gradient descent is difficult. *IEEE transactions on neural networks*, 5(2), 157-166.
- Chen, G., Chen, Y., & Fushimi, T. (2017). Application of deep learning to algorithmic trading. *Tech. Rep*, Retrieved November 29, 2022, from <http://cs229.stanford.edu/proj2017/final-reports/5241098.pdf> (Downloaded 29 November, 2022)
- Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365.
- Cho, P., & Lee, M. (2022). Forecasting the Volatility of the Stock Index with Deep Learning Using Asymmetric Hurst Exponents. *Fractal and Fractional*, 6(7), 394.
- Li, Y., & Pan, Y. (2022). A novel ensemble deep learning model for stock prediction based on stock prices and news. *International Journal of Data Science and Analytics*, 1-11.
- Lim, D. B., & Lundgren, J. (2019). Algorithmic trading using LSTM-models for intraday stock predictions.
- Liu, S., Zhang, C., & Ma, J. (2017). CNN-LSTM neural network model for quantitative strategy analysis in stock markets. In *Neural Information Processing: 24th International Conference, ICONIP 2017, Guangzhou, China, November 14-18, 2017, Proceedings, Part II* 24. 198-206.
- Malsa, N., Vyas, V., & Gautam, J. (2021). RMSE calculation of LSTM models for predicting prices of different cryptocurrencies. *International Journal of System Assurance Engineering and Management*, 1-9.
- McNally, S., Roche, J., & Caton, S. (2018, March). Predicting the price of bitcoin using machine learning. In *2018 26th euromicro international conference on parallel, distributed and network-based processing (PDP)*. 339-343.
- Poongodi, M., Sharma, A., Vijayakumar, V., Bhardwaj, V., Sharma, A. P., Iqbal, R., & Kumar, R. (2020). Prediction of the price of Ethereum blockchain cryptocurrency in an industrial finance system. *Computers & Electrical Engineering*, 81.
- Quiroz-Gutierrez, M. (July 8, 2021). Goldman Sachs: Ethereum could overtake Bitcoin. *Fortune*. <https://fortune.com/2021/07/08/ethereum-bitcoin-goldman-sachs-ether-overtake-btc/>
- Spilak, B. (2018). Deep neural networks for cryptocurrencies price prediction (Master's thesis, Humboldt-Universität zu Berlin).
- Sung, S. H., Kim, J. M., Park, B. K., & Kim, S. (2022). A Study on Cryptocurrency Log-Return Price Prediction Using Multivariate Time-Series Model. *Axioms*, 11(9), 448.
- Yan, H., & Ouyang, H. (2018). Financial time series prediction based on deep learning. *Wireless Personal Communications*, 102, 683-700.

Abstract

An Empirical Study on the Cryptocurrency Investment Methodology Combining Deep Learning and Short-term Trading Strategies

Yumin Lee* · Minhyuk Lee**

As the cryptocurrency market continues to grow, it has developed into a new financial market. The need for investment strategy research on the cryptocurrency market is also emerging. This study aims to conduct an empirical analysis on an investment methodology of cryptocurrency that combines short-term trading strategy and deep learning. Daily price data of the Ethereum was collected through the API of Upbit, the Korean cryptocurrency exchange. The investment performance of the experimental model was analyzed by finding the optimal parameters based on past data. The experimental model is a volatility breakout strategy(VBS), a Long Short Term Memory(LSTM) model, moving average cross strategy and a combined model. VBS is a short-term trading strategy that buys when volatility rises significantly on a daily basis and sells at the closing price of the day. LSTM is suitable for time series data among deep learning models, and the predicted closing price obtained through the prediction model was applied to the simple trading rule. The moving average cross strategy determines whether to buy or sell when the moving average crosses. The combined model is a trading rule made by using derived variables of the VBS and LSTM model using AND/OR for the buy conditions. The result shows that combined model is better investment performance than the single model. This study has academic significance in that it goes beyond simple deep learning-based cryptocurrency price prediction and improves investment performance by combining deep learning and short-term trading strategies, and has practical significance in that it shows the applicability in actual investment.

Key Words : Blockchain, Cryptocurrency, Ethereum, Investment methodology, Short-term trading strategy, Price prediction, Deep learning, LSTM, Combined model

Received : February 16, 2023 Revised : March 20, 2023 Accepted : March 22, 2023

Corresponding Author : Minhyuk Lee

* Department of Business Administration, Pusan National University

** Corresponding Author: Minhyuk Lee

Department of Business Administration, Pusan National University

2, Busandaehak-ro 63beon-gil, Geumjeong-gu, Busan 46241, Republic of Korea

Tel: +82-51-510-3594, E-mail: minhyuk.lee@pusan.ac.kr

저 자 소개



이유민

현재 부산대학교 경영학과 디지털금융전공 석사과정에 재학 중이다. 덕성여자대학교 디지털미디어학과에서 학사학위를 취득하였다. 주요 관심 분야는 블록체인 기반 비즈니스이며, 그 외 디지털 자산, 암호화폐, 데이터 분석, 딥러닝, 투자 전략 등이다.



이민혁

KAIST에서 수리과학, 경영과학 학사를 서울대학교에서 산업공학 박사학위를 취득하였으며 현재 부산대학교 경영학과 디지털금융 전공 교수로 재직하고 있다. 주요 연구 분야는 인공지능, 빅데이터, 시계열 분석, 블록체인 기술을 활용한 금융시장 분석, 투자 전략, 금융 혁신 전략 등이다.