

딥러닝을 이용한 비트코인 투자전략의 성과 분석

김선웅

국민대학교 비즈니스IT전문대학원 교수

Performance Analysis of Bitcoin Investment Strategy using Deep Learning

Sun Woong Kim

Professor, Graduate School of Business IT, Kookmin University

요약 최근 암호화폐거래소로 투자자들이 몰리면서 비트코인 가격이 급등락하고 있다. 본 연구의 목적은 딥러닝 모형을 이용하여 비트코인의 가격을 예측하고, 투자전략을 통해 비트코인의 수익성이 있는지를 분석하는 것이다. 비선형성과 장기기억 특성을 보이는 비트코인 가격 예측모형으로는 LSTM을 활용하며, 예측 가격을 입력변수로 하는 이동평균선 교차전략의 수익성을 분석하였다. 2013년부터 2021년까지의 LSTM 예측 가격을 이용한 비트코인 이동평균선 교차전략의 투자 성과는 단순 시장가격을 이용한 이동평균선 교차전략과 벤치마크전략 Buy & Hold 보다 각각 5.5%와 46% 이상의 수익률 개선 효과를 보여주었다. 최근 데이터까지 확장하여 분석한 본 연구의 결과는 기존의 연구들과 마찬가지로 암호화폐 시장의 비효율성(inefficiency)을 지지하고 있으며, 비트코인 투자자들에게는 딥러닝 모형을 이용한 투자전략의 실천 활용 가능성을 보여주었다. 향후 연구에서는 다양한 딥러닝 모형들의 성과 비교를 통해 최적의 예측모형을 개발하고 비트코인 투자전략의 수익성을 개선할 필요가 있다.

주제어 : 암호화폐거래소, 비트코인, 딥러닝, LSTM, 이동평균선 교차전략

Abstract Bitcoin prices have been soaring recently as investors flock to cryptocurrency exchanges. The purpose of this study is to predict the Bitcoin price using a deep learning model and analyze whether Bitcoin is profitable through investment strategy. LSTM is utilized as Bitcoin prediction model with nonlinearity and long-term memory and the profitability of MA cross-over strategy with predicted prices as input variables is analyzed. Investment performance of Bitcoin strategy using LSTM forecast prices from 2013 to 2021 showed return improvement of 5.5% and 46% more than market price MA cross-over strategy and benchmark Buy & Hold strategy, respectively. The results of this study, which expanded to recent data, supported the inefficiency of the cryptocurrency market, as did previous studies, and showed the feasibility of using the deep learning model for Bitcoin investors. In future research, it is necessary to develop optimal prediction models and improve the profitability of Bitcoin investment strategies through performance comparison of various deep learning models.

Key Words : Cryptocurrency Exchange, Bitcoin, Deep Learning, LSTM, Moving Average Cross-over Strategy

*Corresponding Author : Sun Woong Kim(swkim@kookmin.ac.kr)

Received February 23, 2021

Accepted April 20, 2021

Revised April 2, 2021

Published April 28, 2021

1. 서론

테슬라가 샀다. 최근 전기차업체 테슬라가 1조 7000억 원을 투자하여 대규모로 비트코인(Bitcoin)을 샀다는 발표가 나오자 비트코인 가격은 사상 최고 가격인 6,000 만원을 돌파하였다. 비트코인은 블록체인 기술에 기반하여 네트워크에서 안전한 거래를 위해 개발된 디지털화폐(digital currency)이다[1].

화폐 자산으로서의 성격에 대한 많은 논란에도 불구하고, 비트코인은 암호화폐거래소에서 주식과 비슷한 방법으로 활발하게 거래되고 있다[2]. 미국에서는 비트코인선물(Bitcoin futures)이 상장되어 거래되기 시작하였으며, 2020년 11월 온라인 결제기업 페이팔(PayPal)이 암호화폐 결제 서비스를 제공하기 시작하면서 비트코인은 디지털화폐 기능이 확대되는 추세에 있다.

비트코인은 전 세계적으로 다양한 암호화폐거래소에서 거래가 이루어지고 있으며 국내에서도 빗썸거래소(bithumb)를 비롯한 여러 거래소가 암호화폐 투자자들을 끌어들이고 있다. 비트코인을 비롯한 수백 종류의 암호화폐는 하루 거래금액이 6조원대를 돌파하면서 주식시장과 맞먹는 크기로 성장하고 있다. 가격이 급등하자 많은 투자자들이 암호화폐 거래에 뛰어들고 있으며, 가격의 급등락으로 오히려 큰 손해를 보고 있는 투자자들도 나타나면서 사회 문제화되기도 하였다.

암호화폐거래소의 구조는 증권거래소와 비슷하며, 비트코인을 비롯한 암호화폐 가격들은 주가보다 더 변동성이 크고 방향성이 강한 추세적 움직임을 보여주고 있다. 투자 전략적 관점에서 비트코인과 같은 암호화폐는 방향성과 변동성 측면에서 전통적인 주식이나 선물상품보다 더 매력적인 투자 대상이라고 할 수 있다.

주가 예측 방법으로는 기본적인 분석이나 기술적 분석이 활용되고 있다. 그러나 주가의 비선형성, 장기 추세, 순환 변동이나 무작위 교란 같은 불안정 요인들로 인해 전통적인 접근 방법들은 예측력이 현저히 떨어지는 한계점이 지적되고 있다. 이에 따라 통계적 접근 방법을 대체하는 다양한 인공지능기법들이 연구되고 있다[3]. 최근에는 유닛 사이의 연결이 순환적 구조를 가지고 있어 주가와 같은 시계열 자료 분석에 적합한 순환신경망(Recurrent Neural Network) 딥러닝 모델들이 연구되고 있다. 특히, 장기기억 처리가 가능한 LSTM(Long Short-Term Memory)은 주가나 비트코인 가격처럼 장기기억 특성을 보이는 시계열자료에서 우수한 예측 성능을 보여주고 있다[4-8].

암호화폐 시장이 확대됨에 따라 주가 예측모형을 활용한 암호화폐 가격 예측 연구들이 활발히 이루어지고 있다. 전통적 통계모형인 ARIMA, VAR, ECM 모형 등을 활용한 암호화폐 가격 예측 연구가 대표적이다[9-11]. 최근에는 불확실성이 큰 주가 예측에서 우수한 성과를 보이는 다양한 기계학습모형들이 활발히 연구되고 있다. 주요 모형에는 SVM, LightGBM, ANN, RNN, LSTM, SDAE 등이 포함되며[12-15], 감성분석을 이용한 암호화폐 가격 예측 연구도 진행되고 있다[16-18].

본 연구의 목적은 LSTM을 이용하여 비트코인의 가격을 예측하고, 예측된 가격을 이용하여 비트코인의 투자 전략을 제안하며, 실제 비트코인 가격 자료를 이용하여 실증 분석을 통해 제안된 투자전략의 수익성을 분석하는 것이다. 비트코인과 같은 암호화폐는 주식과는 달리 내재가치(intrinsic value)의 판단이 불가능하다. 그러나 대부분의 암호화폐 투자자들은 마치 주식 투자하듯 투기적 거래에 뛰어들고 있다. 내재가치를 판단할 수 없는 상황에서는 기본적 분석(fundamental analysis)보다는 본 연구에서 제안하는 모형과 같은 기술적 분석(technical analysis) 접근법이 유효하다.

본 연구는 기존의 연구와는 다음과 같은 차이점이 있다. 투자자산으로서 의미 있는 비트코인의 거래량이나 가격 움직임은 2017년 이후의 구간에서 나타난다[19]. 본 연구는 최근 데이터까지 확장하여 분석함으로써 2017년이나 2018년까지의 제한된 데이터에 기반한 기존 연구들의 한계점을 보완할 수 있을 것이다. 본 연구의 분석 대상 역시 국내 투자자들이 거래하고 있는 빗썸거래소의 비트코인 가격 데이터라는 점에서 미국 거래소의 비트코인 가격을 분석하고 있는 기존의 연구들과 차이점을 보인다. 여러 나라의 암호화폐거래소에서 동시에 거래되고 있는 비트코인의 거래소별 가격 차이를 이용한 차익거래(arbitrage)가 활발하기 때문에[19,20], 국내 비트코인 가격을 분석한 연구가 과연 해외 거래소의 가격을 분석한 연구와 차이가 나는지를 비교 분석하는 것은 의미가 있다고 판단된다. 또한 비트코인 가격 예측뿐만 아니라 예측된 가격을 투자에 활용하여 경제적 가치(economic value)를 얻을 수 있는지를 분석하였다는 점에서 본 연구의 차별성을 찾을 수 있다.

연구의 2장에서는 이론적 배경을 알아보고, 3장에서는 데이터와 실험 설계를 소개한다. 4장에서는 실험 결과를 분석하며, 마지막 장에서는 본 연구의 결론 및 향후 연구 방향을 제시한다.

2. 이론적 배경

2.1 암호화폐 시장

Satoshi Nakamoto는 2009년 최초의 암호화폐 비트코인을 개발하였다[1]. 비트코인은 디지털화폐로서 제안 되었으며 뒤를 이어 이더리움 등 다양한 형태의 암호화폐들이 등장하고 있다. 최근에는 영국이나 일본 정부처럼 비트코인을 공식 화폐로 인정하려는 분위기가 감지되고 있지만, 대부분의 투자자들은 비트코인을 투자의 수단으로 인식하고 비트코인 자체의 거래에 집중하고 있는 상황이다. 미국의 선물거래소는 비트코인선물을 상장시켜 비트코인을 투자 대상으로 더욱 확장하였다. 국내에서도 비트코인을 비롯한 많은 암호화폐가 여러 거래소를 통해 주식시장과 같이 활발하게 거래되고 있다. 국내 가상화폐거래소에서 거래되고 있는 암호화폐의 수도 200개가 넘고 있으며 비트코인의 시가총액도 900조 원을 넘어서며 삼성전자의 시가총액 500조 원보다도 크다.

디지털화폐 성격 논쟁으로부터 시작된 비트코인에 대한 연구는 최근 투자 대상 자산으로서의 가격 예측과 투자전략으로 발전하고 있다. 가격 예측모형으로는 전통적인 통계적 모형이나 기계학습 모형 등이 활용되고 있다.

거시경제 변수인 경제정책 불확실성 지수를 이용한 회귀모형을 이용한 연구에서 비트코인 가격은 불확실성 지수와 음의 상관관계가 있음이 밝혀졌다[21]. 2020년까지의 최근 자료를 포함한 회귀분석 연구에서는 비트코인 가격의 상승 추세와 하락 추세를 효과적으로 예측할 수 있음을 밝히고 주가의 random walk 가설을 기각하고 있다[22].

비트코인 가격의 비선형성과 불확실성 등으로 인해 통계적 방법보다는 기계학습과 같은 인공지능 모형들을 이용한 가격 예측 연구가 활발히 진행되고 있다. 분류모형인 SVM(Support Vector Machines)을 이용하여 비트코인 가격을 예측하고 5일 후의 가격 예측력이 우수함을 보여주었다[12]. 개별 암호화폐가 아닌 암호화폐 시장 전체의 가격 하락 추세를 예측할 목적으로 분류모형인 LightGBM 모형을 적용하여 2018년 자료에서 검증한 결과 SVM이나 RF(Random Forest)보다 우수한 추세 예측력을 보여주었다[15]. 비트코인 가격 예측에서 Logistic Regression이나 Linear Discriminant Analysis와 같은 통계모형의 예측력이 RF, XGBoost, SVM, LSTM과 같은 복잡한 기계학습모형보다 더 우수하다고 주장하였다[23]. 2018년까지의 비트코인 5분봉을 이용하여 다양한 ANN(Artificial Neural Network)

모형을 비교 분석한 결과 Bayesian regularization neural network의 RMSE가 가장 낮음을 보여주었다[24]. 통계모형과 RNN 모형의 가격 예측 성능을 비교한 결과 2016년까지의 비트코인 가격에서 통계모형인 ARIMA 모형의 예측 성과가 현저히 낮은 반면 LSTM 모형의 예측 성과가 우수함을 보여주었다[25]. 비트코인 대신 Dash, Litecoin, Monero를 이용한 암호화폐 가격 예측에서 ANN 모형이 SVM 보다 예측력이 우수함을 보여주었다[26].

감성분석을 이용한 가격 예측 연구도 활발하다. Bitcointalk 사이트에서 200만개 이상의 비트코인 관련 포스트 자료를 수집하고 여기에서 추출한 감성 변수와의 상관성을 분석한 결과, 비트코인 가격과의 상관성은 거의 나타나지 않지만 변동성이나 거래량과는 상관성이 높음을 밝혔다[18]. Google Trends 에서 키워드 'Bitcoin'을 투자자 관심 정보로 분석한 결과, 거래량은 다음 날 비트코인의 투자자 관심(attention)에 영향을 미치고 있지만 투자자 관심(attention)의 가격 예측력은 유의적이지 않음을 밝혔다[27]. Twitter의 감성분석을 통해 비트코인 가격 상승-하락과 긍정적-부정적 감성 사이에는 81.39%의 유의적인 상관성이 있음을 보여주었다[17].

가격 예측과 더불어 투자 전략으로 확장하여 분석한 연구는 적은 편이다. Momentum, filter rule, 이동평균선, RSI, 지지-저항선 등 5가지 기술적 지표를 결합하여 투자 전략을 실증분석한 결과 2018년까지의 비트코인 투자에서 개별 기술적 지표전략보다 지표들을 결합한 복합전략의 수익성이 우수함을 보여주었다[28]. ANN과 기술적 지표인 이동평균선, RSI를 이용하여 비트코인 가격의 상승과 하락을 예측하고, 상승으로 예측시 매수포지션, 하락으로 예측시 매도포지션 투자 전략을 분석한 결과, 2016년부터 2018년까지의 분봉 자료에서 비교모형인 Buy & Hold 전략보다 수익이 더 높음을 보여주었다[29].

비트코인의 차익거래 연구도 활발하다. 주식시장과 달리 암호화폐는 하나의 거래소가 아닌 국내외의 여러 암호화폐 거래소에서 거래가 가능하기 때문에 거래소에 따라 비트코인의 거래가격에 차이가 발생할 수 있다. VAR 모형을 이용하여 4개 거래소에서 거래되고 있는 비트코인의 거래소 간 가격 차이를 분석한 결과 유의적인 가격 차이를 발견하였으며, 특히 비트코인 가격이 상승 국면에서 가격 괴리율이 더 증가함을 보여주었다[20]. 전 세계 19개국 34개 암호화폐거래소에서 거래되는 Bitcoin, Ethereum, Ripple 등 4종류의 암호화폐에 대하여 거래소 간 가격 차이를 분석하고 차익거래 가능성을 분석한

결과 거래비용을 고려하여도 유의적인 차익거래 이익을 얻을 수 있음을 밝히고, 암호화폐거래소의 시장 분리(market segmentation) 문제를 지적하였다[19].

미국 암호화폐거래소에서 거래되고 있는 비트코인 가격 자료를 분석한 연구는 많은 편이지만 국내에서 거래되고 있는 비트코인 자료를 분석한 연구는 찾아보기가 어렵다. 본 연구는 국내의 빙썸거래소에서 거래되고 있는 비트코인 자료를 2021년까지 확장하여 분석하고 있다는 점에서 기존의 연구와의 차이점이 있다. 본 연구에서는 확장된 데이터에서도 기존의 연구들과 같은 결과를 얻을 수 있는지 분석하고자 한다.

2.2 LSTM

딥러닝은 인간의 뇌 신경세포 구조를 모방하여 구현한 인공신경망(artificial neural networks)에 기초하는 기계학습 방법의 한 종류이다. 여기에는 심층신경망(deep neural networks), 다층퍼셉트론(multilayer perceptron), 합성곱신경망(convolutional neural networks), 순환신경망(recurrent neural networks) 모형 등이 포함된다.

사람의 신경망 원리와 구조를 모방하여 만들어진 인공신경망 모형의 과최적화에 따른 문제들이 해결되면서 심층신경망은 입력층(input layer)과 출력층(output layer) 사이에 여러 개의 은닉층(hidden layer)을 포함하는 인공신경망 모형으로 발전하였다. 다층퍼셉트론은 심층신경망 모형의 하나로서 정방향 인공신경망 모형(feed-forward deep neural network)이다. 대만 주식 시장에서 다층퍼셉트론 회귀식을 이용하여 주가지수를 예측하고 예측 성과가 비교 모형들보다 우수함을 보여주었다[30]. 주가의 캔들차트와 기술적 지표를 입력변수로 하는 심층신경망 모형을 이용하여 인도 주식시장에서 주가의 상승과 하락의 분류 학습 결과 인공신경망 모형보다 분류 예측력이 8% 이상 높음을 보여주었다[31]. 심층신경망 모형을 응용한 알고리즘으로 합성곱신경망과 순환신경망 모형들이 등장하였다. 합성곱신경망은 다층의 feed-forward 인공신경망의 한 종류로서, 데이터의 특징을 추출하여 특징들의 패턴을 파악하는 구조로 이루어져 있으며, convolution과 pooling 층을 통해 학습이 진행된다. 주로 시각적 영상을 분석하는 데 사용되며 시계열 자료의 분석은 기술적 지표 등의 이미지 변환 과정을 통해 분석하게 된다. 15개의 기술적 지표 시계열 자료를 2차원 이미지로 변환한 후 미국 다우존스 주가지수 구성 30 종목의 추세 예측을 통해 투자 전략을 분석한

결과, 단순 Buy & Hold 전략보다 수익률이 높게 나타났다[32].

RNN은 데이터의 시간적 순서를 고려하지 않는 일반적인 신경망 모형과 달리 sequence 개념을 도입하여 내부적으로 입력변수를 기억할 수 있다. 이를 통해 과거 학습 결과를 현재 학습에 사용할 수 있어서 음성이나 주가와 같이 순차적으로 나타나는 시계열 자료의 처리에 적합한 딥러닝 모형이다. 그러나 데이터의 시차가 길어질수록 과거의 자료가 현재 시점에서 제대로 학습되지 못하는 기울기 소실(vanishing gradient) 문제가 발생한다[4]. 데이터의 시차가 길어지는 주가 분석의 경우 이러한 장기 의존성(long-term dependency) 문제는 주가 예측의 효율성을 떨어뜨릴 수 있다. LSTM은 이러한 장기기억 문제를 해결할 수 있도록 진화한 RNN 모형으로서 1997년 소개되면서 주가와 같은 시계열 자료의 분석에서 그 활용성이 확대되고 있다[33].

Fig. 1은 LSTM의 기본 구조이다.




Fig. 1. LSTM Architecture

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (1)$$

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (2)$$

$$C_t = f_t * C_{t-1} + i_t * \tanh(W_C \cdot [h_{t-1}, x_t], b_C) \quad (3)$$

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o) \quad (4)$$

$$h_t = o_t * \tanh(C_t) \quad (5)$$

Fig. 1에서 LSTM layer는 hidden state h_t 와 cell state C_t 로 이루어져 있다. 시간 t 에서의 hidden state 값은 출력값인 output state를 말한다. LSTM 모형의 가장 큰 특징은 기본 RNN 모형에 cell state를 추가하였다는 점이다. Cell state는 gate를 통해 기존의 정보를 어느 정도로 다음 단계로 전달할 것인가를 결정하는 역할을 한다. 이러한 과정을 통해 오래전 시점의 정보도 현재 정보에 반영되도록 함으로써 장기기억 문제를 해결할 수 있다. LSTM의 이러한 강점은 장기기억 속성을 보이는

주거나 암호화폐 등의 가격 예측에서 유용성이 크다고 할 수 있다.

LSTM의 핵심인 cell state는 Fig. 1의 수평으로 그려진 상단 선으로, 마치 컨베이어벨트처럼 순환신경망 전체 체인을 관통하며 계속 유지되고, 순환신경망에 input gate, output gate, forget gate를 추가하여, 어느 시점에서 데이터 정보를 버리거나 유지할 것인가를 선택적으로 cell state에 전달할 수 있다. LSTM의 첫 단계는 $t-1$ 시점의 cell state를 얼마나 유지할지를 sigmoid layer에 의해 식 1과 같이 결정하는 forget gate 단계이다. Input gate는 식 1에 의해 입력 정보를 얼마나 받아들일지 결정하고, output gate는 식 3에 의해 출력 데이터의 값을 결정한다. $t-1$ 시점의 cell state에 forget gate에서 출력된 값을 곱하여 식 4처럼 cell state 값의 일정 부분을 망각하고, 입력 정보와 $t-1$ 출력값을 처리한 결과에 input gate의 출력값을 곱하여 새로운 cell state를 정한다. 식 5를 통해 만들어진 새로운 cell state에 output gate의 출력값을 곱하여 cell state의 출력을 결정한다. 이러한 과정을 통해 RNN보다 sequence가 긴 시계열 데이터에서 더 우수한 학습을 수행할 수 있다 [34-36].

본 연구에서 분석한 비트코인의 가격 예측은 데이터의 sequence가 중요한 역할을 하는 시계열 데이터이기 때문에, 데이터의 순서와 관계없이 학습하는 심층신경망 모형이나 합성곱신경망 모형보다는 순환신경망 모형을 이용하여 분석하고자 한다. 특히, 비트코인을 포함한 암호화폐 가격에는 long memory 특성이 있음이 밝혀지고 있다[37,38]. 따라서 순환신경망 모형 중 long memory 특성을 잘 반영하는 LSTM 모형을 이용하여 비트코인의 가격을 예측하고 비트코인 투자 전략의 수익성을 분석하고자 한다.

3. 데이터와 실험 설계

3.1 데이터 소개

본 연구에서는 국내의 대표적인 암호화폐거래소 빗썸에서 거래되고 있는 비트코인의 일별 시가, 고가, 저가, 그리고 종가 데이터를 빗썸거래소의 API를 이용하여 구하였다. 데이터 분석 기간은 비트코인의 과거 자료 최대 확보 가능 기간인 2017년 5월 23일부터 2021년 1월 23일까지의 1,340일이다. 분석 기간의 비트코인 시작 가격은 3,206,000원, 마지막 거래가격은 35,479,000원으로

마감하여 짧은 시간 동안 10배 이상의 가격 폭등이 나타나고 있다.

다음 Fig. 2는 전체 분석 기간의 비트코인과 코스피 200 주가지수 움직임을 비교하여 보여주고 있다.



Fig. 2. Bitcoin and KOSPI 200 Index

3.2 실험 1단계 : LSTM을 이용한 비트코인 가격 예측

본 연구의 실험 1단계에서는 long memory 특성 [37,38]을 보이는 비트코인의 가격 예측을 위해 long memory 특성을 잘 반영하는 딥러닝 모형으로 LSTM을 선택하였다. 비트코인의 가격 정보를 활용하는 LSTM 모형을 이용하여 비트코인의 가격을 예측하고, 실험 2단계에서는 예측된 비트코인 가격을 이용한 이동평균선 교차 전략의 투자 성과를 비교 분석한다. 다음 Fig. 3은 본 연구의 실험 전체 진행 과정을 보여주고 있다.

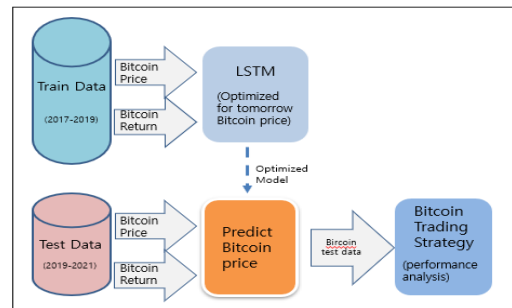


Fig. 3. Experimental Design

연구의 1단계에서 LSTM의 입력변수로는 비트코인의 일별 시가, 고가, 저가, 종가와 일별 수익률 자료를 이용한다. 5개의 입력변수를 이용하여 다음 날의 비트코인

종가를 예측하는 것을 목표로 한다. 2017년 5월 23일부터 2019년 12월 17일까지는 학습용 데이터, 2019년 12월 18일부터 2021년 1월 23일까지는 검증용 데이터로 구분하였으며, 학습용 데이터는 전체 데이터의 70%에 해당한다. 본 연구에서는 Python 3.9 환경에서 Tensorflow 2.4와 Keras를 사용하여 실험을 진행하였다.

937일의 학습 데이터 구간에서 최적화된 LSTM 모델을 403일의 검증 데이터 구간에 적용하여 비트코인의 다음 날 가격을 예측한다. LSTM의 비교 모형으로는 단순 RNN 모형을 분석한다. 딥러닝 최적화 알고리즘은 오차 감소 속도가 빠른 Adam optimizer를 이용하였고 활성화 함수는 hyperbolic tangent를 이용하였고, 지도학습은 100번의 반복 학습을 시행하였다. 지도학습을 추가적으로 확대하여도 예측 성과에 큰 차이는 없음을 확인하였다. 실험 결과의 성과평가 지표는 비트코인 가격의 예측값과 실제 값과의 평균 제곱근 오차를 계산하는 RMSE(Root Mean Square Error)이다. 학습과 검증을 위한 모형의 하이퍼 파라미터는 다음 Table 1과 같다.

Table 1. Hyperparameters

Hyperparameter	Values
Optimizer	Adam
Activation Function	tanh
Dropout Ratio	0.1
Epochs Number	100
Learning Rate	0.01
Sequence Length	5

3.3 실험 2단계 : 비트코인 투자전략과 성과평가 방법

본 연구의 실험 2단계에서는 실험 1단계에서 예측된 비트코인 가격을 이용한 비트코인의 투자 전략을 제안하고 실증분석을 통해 투자 전략의 투자 성과를 분석한다.

비트코인과 같은 암호화폐는 암호화폐거래소에서 주식과 같은 방법으로 거래되고 있다. 비트코인의 거래는 풍부한 유동성과 가격 변동성을 보이고 있다. 따라서 주식시장에서 활용되고 있는 다양한 투자 전략들은 비트코인의 투자 전략에도 적용 가능할 것으로 판단된다.

기술적 분석을 통한 주식투자에 활용되는 대표적인 투자 전략 중의 하나는 이동평균선 교차전략(moving average cross-over strategy)이다. 이 전략은 단기이동평균선이 장기 이동평균선을 상향 돌파하면 주가의 추세가 상승으로 전환됐다고 판단하여 매수포지션을 취하고, 반대로 단기 이동평균선이 장기 이동평균선을 하향

돌파하면 주가의 추세가 하락으로 전환되었다고 판단하여 매수포지션을 청산하는 전략이다. 이동평균선 교차전략은 주식시장의 가장 대표적인 추세 추종형(trend-following) 투자 전략으로서, 주식시장보다 더 강한 추세를 보이는 암호화폐 시장의 투자에서도 좋은 성과가 기대된다. 하루 6시간 30분 동안만 거래가 이루어지고 17시간 30분 동안 거래가 중단됨에 따라 발생하는 주가 갭(price gap)으로 인해 이동평균선의 왜곡 현상이 빈번히 발생하는 주식시장과 달리 암호화폐 시장은 365일, 24시간 연속적으로 거래가 이루어지기 때문에 주가 갭 문제로부터 자유로운 장점이 있다. 일반적으로 증권시장에서는 5일과 20일이 각각 단기와 장기로 활용되고 있다. 본 연구에서도 5일 이동평균선과 20일 이동평균선의 교차전략을 기본 전략으로 설정하였다. 다음 Fig. 4는 단기 이동평균선이 장기 이동평균선을 상향 돌파하면서 비트코인의 추세가 강한 상승 흐름을 이어가는 상승 추세 구간을 보여주고 있다.



Fig. 4. 5-20 Moving Average Cross-over

실험의 1단계에서 예측된 비트코인의 가격을 $predict_C$ 라고 하면 비트코인의 이동평균선 교차전략은 다음 식 (6)과 같다.

$$\begin{aligned}
 &input : short(5), long(20); & (6) \\
 &variables : short_ma(0), long_ma(0); \\
 &short_ma = average(predict_C, short); \\
 &long_ma = average(predict_C, long); \\
 &If short_ma cross over long_ma then buy(); \\
 &If short_ma cross below long_ma then sell();
 \end{aligned}$$

단기이동평균선이 장기 이동평균선을 상향 돌파하면 돌파 시점의 종가(C_{t1})로 매수포지션을 취한 후 보유하다가 단기이동평균선이 장기 이동평균선을 하향 돌파하면 하향 돌파 시점의 종가(C_{t2})로 매수포지션을 청산한다. i 번째 거래에 따른 투자 수익률(R_i)은 다음 식 (7)과 같이 계산한다.

$$R_i = \frac{C_{t2} - C_{t1}}{C_{t1}} \text{ for trade } i = 1, 2, \dots, n, \quad (7)$$

where C_{t1} is buy price, C_{t2} is sell price.

2019년 12월 18일부터 2020년 1월 23일까지의 전체 검증 기간에서 발생하는 누적수익률(CR)은 다음 식 (8)과 같이 계산한다.

$$CR = \prod_{i=1}^n (1 + R_i) - 1, \text{ Cumulative Return} \quad (8)$$

4. 실험 결과 분석

4.1 1단계 실험 결과

2017년 5월 23일부터 2019년 12월 17일까지의 학습 기간과 2019년 12월 18일부터 2021년 1월 23일까지의 검증 기간에서의 딥러닝 제안모형의 실험 결과는 다음 Table 2와 같다.

Table 2. Experiment Result

Period	RNN	LSTM
Training Period	0.0219	0.0200
Test Period	0.0227	0.0148

딥러닝의 실험 결과 비트코인의 가격 예측에서는 LSTM이 RNN보다 우수한 예측 성과를 보여주고 있다. 비트코인의 가격 예측에서 장기기억 문제가 영향을 미치고 있음을 알 수 있다. Fig. 5는 검증 기간에서 비트코인의 LSTM 예측 가격과 비트코인 실제 가격을 보여주고 있으며, 비교적 비슷한 가격 움직임이 나타나고 있다.



Fig. 5. Bitcoin Predicted Price for Test Period

4.2 2단계 실험 결과

실험의 1단계에서 예측된 비트코인의 종가를 이용한 이동평균선 교차전략은 실험의 검증 기간인 2019년 12월 18일부터 2021년 1월 23일까지 다음 Table 3과 같은 성과를 보여주었다.

Table 3. Trading Performance on Bitcoin(unit: %)

	LSTM	MA	B&H
Cumulative Return	467.9	443.6	318.9
Average Return	0.67	0.66	0.44
Standard Deviation	3.03	3.01	3.54
Sharpe Ratio	0.22	0.22	0.13
Maximum Draw Down	21.6	21.7	30.3
Time in the Market	68.7	68.0	100.0

MA : Moving average cross-over strategy using actual price.
 B&H : Buy & Hold Strategy.
 Average return and standard deviation is based on daily data.
 Sharpe Ratio is average return divided by standard deviation.

Table 3에서 LSTM은 딥러닝의 비트코인 예측 가격을 이용한 이동평균선 교차전략의 성과, MA는 예측 가격이 아닌 비트코인의 실제 가격을 이용한 이동평균선 교차전략의 성과, 그리고 B&H는 거래의 시작 시점에서 매수포지션을 취한 후 마지막 거래일까지 매수포지션을 유지하는 Buy & Hold 투자 전략의 성과이다.

본 실험의 검증 기간에서도 비트코인 가격은 8,470,000원에서 35,479,000원까지 3배 이상 폭등하면서 단순한 Buy & Hold 전략의 수익률도 318.9%를 나타내고 있다. 같은 기간 동안 LSTM을 이용한 이동평균선 교차전략의 누적수익률은 467.9%를 기록하여, 딥러닝에 기반

한 비트코인 가격 예측의 경제적 가치가 존재함을 보여 주고 있다.

수익뿐만 아니라 투자 위험을 동시에 고려하기 위하여 수익률을 위험지표인 표준편차로 나누어 계산하는 Sharpe Ratio 또한 LSTM 이동평균선 교차전략이 0.22로 나타나 단순한 B&H의 0.13보다 높게 나타나고 있다. Maximum Draw Down(MDD) 역시 LSTM이 21.6%로 가장 낮은 값을 나타내고 있다. MDD는 거래하는 동안 최고 수익 구간에서 최저 수익 구간까지의 수익 감소 폭으로 계산한다. 이 값이 크다면 투자자들이 거래하는 동안 스트레스가 커지기 때문에 실제 거래에서 실패할 확률이 커진다. Time in the Market은 전체 투자 기간에서 비트코인의 매수포지션을 보유하고 있는 시간 비율로서 투자 위험에 노출된 시간의 비율이다. Buy & Hold의 100%와 비교하여 이동평균선 교차전략의 매수포지션 보유 시간 비율은 70% 미만으로 나타나고 있어서 시장 위험에 노출되고 있는 시간을 줄일 수 있음을 알 수 있다. 한편, 5일의 단기이동평균선을 기준으로 장기 이동평균선을 최적화한 결과 19일이 가장 높은 수익률을 기록하였으며, 5일 이동평균선과 19일 이동평균선 교차전략의 누적수익률은 534.8%를 기록하였다.

Fig. 6는 데이터의 검증 기간에서 우수한 투자 성과를 보여준 LSTM 전략과 비교전략인 Buy & Hold 전략의 수익곡선(Equity Curve)을 보여주고 있다.

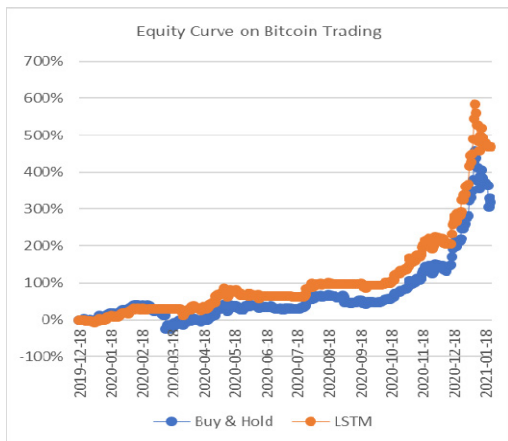


Fig. 6. Equity Curve on LSTM and Buy & Hold

5. 결론

본 연구에서는 가격이 급등락하면서 전 세계 투자자들

을 끌어들이고 있는 비트코인의 투자 전략의 성과를 분석하였다. 딥러닝 LSTM을 이용하여 비선형성과 불안정성을 보이는 비트코인 가격을 예측하였으며, 비트코인 예측 가격은 이동평균선 교차전략의 입력변수로 활용하였다.

LSTM 예측 가격을 이용한 이동평균선 교차전략은 본 연구의 검증 기간에서 누적수익률 467.9%를 보여, 비교 투자 전략인 Buy & Hold 전략의 318.9%보다 46% 이상의 수익률 개선 효과가 나타났다. 예측 가격이 아닌 실제 비트코인 가격을 이용하는 전통적인 통계적 이동평균선 교차전략의 수익률 443.6%보다도 5% 이상 수익률이 개선되었다. 한편, 수익률과 투자 위험도를 동시에 고려하는 성과 지표인 Sharpe Ratio 역시 LSTM 모형은 0.22로 나타나 단순 Buy & Hold 전략 0.13보다 우수한 결과를 보여주었다. LSTM 수익곡선의 최대 손실폭(MDD)은 21.6% 수준으로 Buy & Hold 전략의 30.3%보다 낮아 실제 투자에서 투자자 스트레스를 줄일 수 있음을 확인하였다.

본 연구는 국내 암호화폐거래소에서 거래되고 있는 비트코인의 투자 전략을 분석하였으며 분석 결과는 선진국 암호화폐거래소 자료를 이용한 기존의 연구 결과들과 일치하는 투자 분석 결과를 보여주어 비트코인과 같은 암호화폐의 포트폴리오 편입 투자자산으로서의 가능성을 보여주었다. 특히, 본 연구의 결과는 비트코인 시장의 평균 수익을 초과하는 투자 전략의 존재 가능성을 제시하여 암호화폐 시장의 효율성(market efficiency)을 부정하는 사례를 보여주었다는 점에서 학술적 의의가 있다. 대부분의 시장 참여자들이 비트코인 가격의 급등락에 이끌려 기준 없이 거래에 참여하고 있는 현실에서, 본 연구의 결과는 다양한 예측모형을 활용하여 정확한 가격 예측을 바탕으로 암호화폐 투자에 참여할 필요성을 보여주고 있다.

비트코인과 같은 암호화폐 시장은 도입 초창기이기 때문에 다양한 호재와 악재가 빈번히 발생하고 있으며, 이에 따라 비트코인 가격도 긍정적 뉴스와 부정적 뉴스에 따라 강한 상승과 하락을 반복하고 있다. 본 연구에서는 경쟁적 거래를 통해 형성되는 비트코인의 가격에 반영되어 나타나는 추세를 찾아 추세의 방향으로 거래를 하는 투자 전략의 성과를 분석하였기 때문에 강한 추세적 특징을 보이는 비트코인의 거래에서 높은 수익률을 보여주고 있다. 암호화폐 시장이 성숙한 시장으로 발전하면 역추세전략(anti-trend strategy)에 대한 연구도 필요할 것으로 판단된다.

본 연구에서는 비트코인 가격 예측모형으로 LSTM 모형 이외의 다양한 기계학습모형들을 분석하지 못한 한계점이 있다. 향후 연구에서는 CNN, DNN, MLP, SVM 등의 다양한 모형을 추가하여 개선된 예측 결과를 얻을 수 있는 기계학습 모형으로 확장하는 연구가 필요하다. 비트코인을 대상으로 분석한 본 연구를 바탕으로 향후 연구에서는 유동성이 풍부하면서 투자자의 많은 관심을 받고있는 Ethereum, Ripple, Dash 등의 암호화폐에 대한 투자 전략의 성과도 비교 분석할 필요가 있다.

REFERENCES

- [1] S. Nakamoto. (2008). *Bitcoin: A peer-to-peer electronic cash system*. <http://www.lopp.net/pdf/bitcoin.pdf>
- [2] H. J. Kim. (2018). Policy trends and issues on Crypto currency of Japanese government. *Journal of the Korea Institute of Information and Communication Engineering*, 22(10), 1398-1404. DOI : 10.6109/jkiice.2018.22.10.1398
- [3] M. Vijh, D. Chandola, V. A. Tikkiwal & A. Kumar. (2020). Stock closing price prediction using machine learning techniques. *Procedia Computer Science*, 167, 599-606. DOI : 10.1016/j.procs.2020.03.326
- [4] A. Yadav & C. K. Aditi Sharan. (2020). Optimizing LSTM for time series prediction in Indian stock market. *International Conference on Computational Intelligence and Data Science*, 167, 2091-2100. DOI : 10.1016/j.procs.2020.03.257
- [5] D. H. Shin, K. H. Choi & C. B. Kim. (2017). Deep learning model for prediction rate improvement of stock price using RNN and LSTM. *The Journal of Korean Institute of Information Technology*, 15(10), 9-16. DOI : 10.14801/jkiit.2017.15.10.9
- [6] J. U, P. Lu, C. Kim, U. Ryu & K. Pak. (2020). A new LSTM based reversal point prediction method using upward/downward reversal point feature sets. *Chaos, Solitons and Fractals*, 132, 1-15. DOI : 10.1016/j.chaos.2019.109559
- [7] W. Li & J. Liao. (2017). A comparative study on trend forecasting approach for stock price time series. *IEEE International Conference on Anti-counterfeiting, Security, and Identification*, 74-78. DOI : 10.1109/ICASID.2017.8285747
- [8] A. Moghar & M. Hamiche. (2020). Stock market prediction using LSTM recurrent neural network. *Procedia Computer Science*, 170, 1168-1173. DOI : 10.1016/j.procs.2020.03.049
- [9] N. A. Bakar & S. Rosbi. (2017). Autoregressive integrated moving average model for forecasting cryptocurrency exchange rate in high volatility environment: A new insight of bitcoin transaction. *International Journal of Advanced Engineering Research and Science*, 4(11), 130-137. DOI : 10.22161/ijaers.4.11.20
- [10] E. Demir, G. Gozgor, C. K. M. Lau & S. A. Vigne. (2018). Does economic policy uncertainty predict the Bitcoin returns? An empirical investigation. *Finance Research Letters*, 26, 145-149. DOI : 10.1016/j.frl.2018.01.005
- [11] X. Li & C. Wang. (2017). The technology and economic determinants of cryptocurrency exchange rates: The case of Bitcoin. *Decision Support Systems*, 95, 49-60. DOI : 10.1016/j.dss.2016.12.001
- [12] D. Aggarwal, S. Chandrasekaran, & B. Annamalai. (2020). A complete empirical ensemble mode decomposition ans support vector machine-based approach to predict Bitcoin prices. *Journal of Behavioral and Experimental Finance*, 27, 1-12. DOI : 10.1016/j.jbef.2020.100335
- [13] D. Mallqui & R. Fernandes. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning techniques. *Applied Soft Computing Journal*, 75, 596-606. DOI : 10.1016/j.asoc.2018.11.038
- [14] M. Liu, G. Li, J. Li, X. Zhu & Y. Yao. (2020). Forecasting the price of Bitcoin using deep learning. *Finance Research Letters*, In press. DOI : 10.1016/j.frl.2020.101755
- [15] S. Xiaolei, L. Mingxi & S. Zeqian. (2020). A novel cryptocurrency price trend forecasting model based on LightGBM. *Finance Research Letters*, 32, 1-6. DOI : 10.1016/j.frl.2018.12.032
- [16] M. Gang, B. Kim, M. Shin, U. Baek & M. Kim. (2020). LSTM-based prediction of Bitcoin price fluctuation using sentiment analysis. *Proceedings of Symposium of the Korean Institute of Communications and Information Sciences*, 561-562.
- [17] D. Pant, P. Neupane, A. Poudel, A. Pokhrel & B. Lama. (2018). Recurrent neural network based Bitcoin price prediction by Twitter sentiment analysis. *International Conference on Computing, Communication and Security*. DOI : 10.1109/CCCS.2018.85886824
- [18] Y. Ahn & D. Kim. (2020). Emotional trading in the cryptocurrency market. *Finance Research Letters*, in Press. DOI : 10.1016/j.frl.2020.101912
- [19] I. Makarov & A. Schoar. (2020). Trading and arbitrage in cryptocurrency markets. *Journal of Financial Economics*, 135, 293-319. DOI : 10.1016/j.jfineco.2019.07.001

- [20] K. Tsang & Z. Yang. (2020). Price dispersion in bitcoin exchanges. *Economics Letters*, 194, 1-5.
DOI : 10.1016/j.econlet.2020.109379
- [21] E. Demir, G. Gozgor, C. Lau & S. Vigne. (2018). Does economic policy uncertainty predict the Bitcoin returns? An empirical investigation. *Finance Research Letters*, 26, 145-149.
DOI : 10.1016/j.frl.2018.01.005
- [22] G. Cohen. (2020). Forecasting Bitcoin trends using algorithmic learning systems. *Entropy*, 22, 1-11.
DOI : 10.3390/e22080838
- [23] Z. Chen, C. Li & W. Sun. (2020). Bitcoin price prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 1-13.
DOI : 10.1016/j.cam.2019.112395
- [24] S. Lahmiri & S. Bekiros. (2020). Intelligent forecasting with machine learning trading systems in chaotic intraday Bitcoin market. *Chaos, Solitons and Fractals*, 133, 1-7.
DOI : 10.1016/j.chaos.2020.109641
- [25] S. McNally, J. Roche & S. Caton. (2018). Predicting the price of Bitcoin using machine learning. *26th Euromicro International Conference on Parallel, Distributed, and Network-based Processing*, 339-343.
DOI : 10.1109/PDP2018.00060
- [26] H. M. Kim & H. Kim. (2019). A study on predicting cryptocurrency distribution prices using machine learning techniques. *Journal of Distribution Science*, 10(11), 93-101.
DOI : 10.13106/ijidb.2019.vol10.no11.93
- [27] A. Urquhart. (2018). What causes the attention of Bitcoin?. *Economics Letters*, 166, 40-44.
DOI : 10.1016/j.econlet.2018.02.017
- [28] L. Liu. (2019). Are Bitcoin returns predictable? Evidence from technical indicators. *Physica A*, 533, 1-6.
DOI : 10.1016/j.physa.2019.121950
- [29] M. Nakano, A. Takahashi & S. Takahashi. (2018). Bitcoin technical trading with artificial neural network. *Physica A*, 510, 587-609.
DOI : 10.1016/j.physa.2018.07.017
- [30] T. L. Chen, C. H. Cheng & J. W. Liu. (2019). A causal time-series model based on multilayer perceptron regression for forecasting Taiwan stock index. *International Journal of Information Technology & Decision Making*, 18(6), 1967-1987.
DOI : 10.1142/S0219622019500421
- [31] N. Naik & B. Mohan. (2020). Intraday stock prediction based on deep neural network. *National Academy Science Letters*, 43, 241-246.
DOI : 10.1007/s40009-019-00859-1
- [32] O. Sezer & A. Ozbayoglu. (2018). Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach. *Applied Soft Computing*, 70, 525-538.
DOI : 10.1016/j.asoc.2018.04.024
- [33] S. Hochreiter & J. Schmidhuber. (1997). Long short-term memory. *Neural Computation*, 9(8), 1735-1780.
DOI : 10.1162/neco.1997.9.8.1735
- [34] J. Ilonen, J. Kamarainen & J. Lampinen. (2003). Differential evolution training algorithm for feed-forward neural networks. *Neural Processing Letters*, 17, 93-105.
- [35] H. J. Song, H. S. Choi, S. W. Kim & S. H. Oh. (2019). A study on financial time series data volatility prediction method using AI's LSTM method. *Journal of Knowledge Information Technology and Systems*, 14(6), 665-673.
DOI : 10.34163/jkits.2019.14.6.009
- [36] C. Olah. (2015). *Understanding LSTM networks*. <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [37] A. Bariviera. (2017). The inefficiency of Bitcoin revisited: A dynamic approach. *Economics Letters*, 161, 1-4.
DOI : 10.1016/j.econlet.2017.09.013
- [38] A. Phillip, J. Chan & S. Peiris. (2018). A new look at Cryptocurrencies. *Economics Letters*, 163, 6-9.
DOI : 10.1016/j.econlet.2017.11.020

김 선 웅(Sun Woong Kim)

[정회원]



- 1981년 2월 : 서울대학교 경영학과(경영학사)
- 1983년 2월 : KAIST 경영학과(공학 석사)
- 1988년 2월 : KAIST 경영학과(공학 박사)
- 2009년 3월 ~ 현재 : 국민대학교 비즈니스IT전문대학원 트레이딩시스템전공 교수
- 관심분야 : 트레이딩시스템, 자산운용, 투자위험관리
- E-Mail : swkim@kookmin.ac.kr