

# Cryptocurrency Auto-trading Program Development Using Prophet Algorithm

Hyun-Sun Kim\* · Jae Joon Ahn\*\*†

\*Department of Investment Information Engineering, Yonsei University

\*\*Division of Data Science, Yonsei University

## Prophet 알고리즘을 활용한 가상화폐의 자동 매매 프로그램 개발

김현선\* · 안재준\*\*†

\*연세대학교 투자정보공학 협동과정

\*\*연세대학교 데이터사이언스학부

Recently, research on prediction algorithms using deep learning has been actively conducted. In addition, algorithmic trading (auto-trading) based on predictive power of artificial intelligence is also becoming one of the main investment methods in stock trading field, building its own history. Since the possibility of human error is blocked at source and traded mechanically according to the conditions, it is likely to be more profitable than humans in the long run. In particular, for the virtual currency market at least for now, unlike stocks, it is not possible to evaluate the intrinsic value of each cryptocurrencies. So it is far effective to approach them with technical analysis and cryptocurrency market might be the field that the performance of algorithmic trading can be maximized. Currently, the most commonly used artificial intelligence method for financial time series data analysis and forecasting is Long short-term memory(LSTM). However, even the LSTM also has deficiencies which constrain its widespread use. Therefore, many improvements are needed in the design of forecasting and investment algorithms in order to increase its utilization in actual investment situations. Meanwhile, Prophet, an artificial intelligence algorithm developed by Facebook (META) in 2017, is used to predict stock and cryptocurrency prices with high prediction accuracy. In particular, it is evaluated that Prophet predicts the price of virtual currencies better than that of stocks. In this study, we aim to show Prophet's virtual currency price prediction accuracy is higher than existing deep learning-based time series prediction method. In addition, we execute mock investment with Prophet predicted value. Evaluating the final value at the end of the investment, most of tested coins exceeded the initial investment recording a positive profit. In future research, we continue to test other coins to determine whether there is a significant difference in the predictive power by coin and therefore can establish investment strategies.

**Keywords :** Price Forecasting, Cryptocurrency, Long short-term Memory, Prophet

---

Received 22 March 2023; Finally Revised 29 March 2023;

Accepted 29 March 2023

† Corresponding Author : ahn2615@yonsei.ac.kr

### 1. 서론

가상화폐 시장은 기존 주식 시장과 마찬가지로 많은 개인 투자자들이 거래에 참여하고 있다. 하지만 가상화폐 시장 역시 주식과 마찬가지로 정보력과 전문성을 가지고 있는 전문 투자자와 기관 투자자를 상대로 개인이 수익을 내기는 쉽지 않다. 이에 개인 투자자로서 가지는 한계를 보완하여 수익을 실현하고자 하는 방법들이 연구되고 있다. 그 중 하나로 언급되는 것이 스캘핑(Scalping)이다. 이는 투자 대상물의 펀더멘탈에 승부를 거는 가치 투자와는 상반되는 개념으로, 단기적인 가격과 수급에 모든 초점을 맞추어 오직 거래 데이터의 기술적인 분석을 통해 짧은 순간에 매매하고 보유에 따른 리스크를 줄이는 방법이다. 적어도 현재로서는 주식과 달리 대부분 가상화폐의 내재가치 판단이 불가능한 상황임을 고려하면 기본적 분석(Fundamental analysis)보다는 기술적 분석(Technical analysis) 접근법이 유효하다고 봄이 타당하다[8]. 스캘핑 전략은 매매 시마다 부과되는 수수료 등의 비용을 상회하는 이익을 실현해야 한다는 단점이 있지만 초고속 통신망이 일반화된 현재의 환경에서는 장중 시세 변화를 빠르게 포착하고 대응할 수 있기 때문에 위험을 최소화하고 작은 이익을 차곡차곡 쌓아 나갈 수 있는 전략으로 평가받고 있다.

본 연구는 이러한 스캘핑 기법으로 가상화폐를 자동 매매하는 시스템을 구현하는 것을 최종 목표로 두고 있다. 또한 그것의 핵심 과정으로 가상화폐의 가격 예측 정확도를 높이는 방법을 제안하고 투자수익률을 통해 제안 방법의 성과를 평가하고자 한다. 본 연구에서는 기존에 금융시계열 분석 예측에 유용하다고 알려진 LSTM(Long short-term memory) 방법의 기술적 한계를 확인하고 이를 보완한 새로운 예측 알고리즘으로서 Prophet을 제안한다.

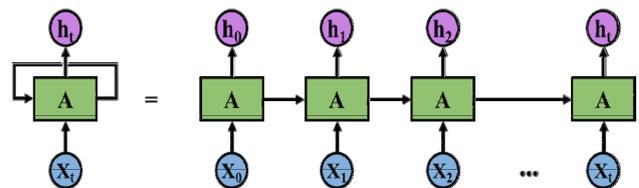
### 2. 이론적 배경

주식과 가상화폐의 가격은 전형적인 시계열 데이터이면서 비선형적인 모습을 보인다. 시계열 분석을 통한 예측은 관측된 과거의 자료들을 분석하여 이를 모형화하고, 이 추정된 모형을 사용하여 미래에 관측될 값들을 예측한다는 점에서 외생변수의 영향을 고려하지 않아 예측력이 떨어진다는 지적을 받는다. 하지만 스캘핑 전략의 관점에서라면 내생 변수들 사이의 관계를 정확히 파악하는 것만으로도 충분한 의미가 있으므로 딥러닝을 활용하여 인간의 인지 능력으로는 발견하지 못한 변수들 간의 상호작용을 보다 정확히 밝히는 것을 목표로 한다.

이와 관련해서는 이미 많은 선행연구들이 이루어져왔다. 독립변수의 제약이 적은 딥러닝의 특성을 활용하여 다양한 변수를 신경망 모형에 결합하고, 예측 성능을 향상시키는 개념이다. 시계열 분석을 위해 주로 사용되는 딥러닝 방법으로는 RNN과 RNN의 한 종류로 그것의 단점을 보완한 LSTM이 있는데 Kim and Won[7]의 연구에서는 계량경제 모형과 LSTM 모형을 결합하여 주가지수 변동성 예측 성능을 향상시킬 수 있음을 입증하였고, Livieris 등은 CNN-LSTM 모형을 결합하여 비트코인과 이더리움, 그리고 리플의 가격을 예측한 바 있다[11]. Mohammed와 Theyazn 역시 가상화폐의 가격 예측에 LSTM 방법을 적용하는 것이 효과적임을 주장하였으며[1], Lee[10]는 KOSPI200 지수의 변동성을 예측함에 있어 국내 언론사의 일별 기사 발행량을 LSTM 모형의 입력 값으로 추가하였을 때 GARCH 모형에 비해 예측 오차가 큰 폭으로 감소하는 결과를 보여주었다. 또한 Kim[9]은 기술적 지표들을 활용해 LSTM 모형으로 알트코인의 가격을 예측하고 이를 바탕으로 투자전략의 성과를 비교한 바 있다.

#### 2.1 RNN(Recurrent Neural Network)

순환 신경망은 인공신경망을 구성함에 있어서 특정 부분이 반복되는 구조를 가진다는 의미인데, 기존의 신경망이 단순히 각층의 뉴런이 연결되는 구조였다면, RNN은 아래 <Figure 1>과 같이 은닉층에 자신을 가리키는 구조를 가진다.



<Figure 1> RNN Block Diagram

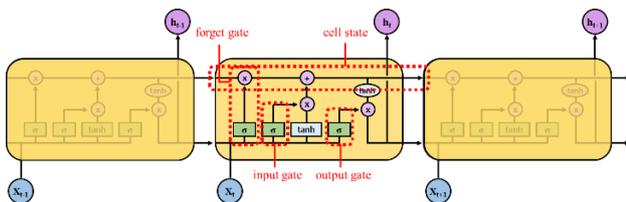
즉, 한 방향으로 이동하는 기본적인 신경망과 다르게 한 번 계산한 값을 다음 계산 입력 값에 다시 집어넣는 형태를 띠는 것이다. 시점  $t$ 의 은닉층 노드( $A_t$ )는 현재 시점인 시점  $t$ 의 입력 값( $X_t$ )과  $t-1$ 시점의 결과 값( $A_{t-1}$ )을 입력 값으로 받아 시점  $t$ 의 결과 값을 만들어내고 동시에 이 결과 값을  $t+1$ 의 은닉층에 전달한다[13]. 이때 한번 계산한 값이 다음 시점의 은닉층에 반영되는 비중을 Recurrent Weight라고 부른다. 이러한 구조 덕분에 이전 데이터와 나중 데이터 간의 영향도를 효과적으로 분석할 수 있어 시계열 분석에 적합한 모델이다.

그런데 이 구조는 시계열 분석과 관련하여 치명적인

문제점을 가진다. 바로 기울기 소실 문제(Gradient vanishing problem)의 발생이다. 학습을 계속함에 있어 시퀀스가 길어질수록 반복되어 곱해지는 Recurrent Weight가 작아져 결국 가중치 매개 변수가 업데이트되지 않게 된다. 이는 곧 장기 의존성을 학습하는 데에 어려움이 있다는 것을 뜻한다. 시퀀스가 길어지면 이전의 정보가 희석되어 장기적인 의존성(Long-term dependency)을 파악하기가 힘들어지는 것이다.

## 2.2 LSTM(Long Short-Term Memory)

전술한 장기 의존성 문제를 해결할 수 있도록 진화한 RNN 모형인 LSTM은 아래의 <Figure 2>와 같이 기본 RNN에 cell state가 추가되어 내부 구조가 비교적 더 복잡하다[3]. cell state는 컨베이어 벨트처럼 순환신경망 전체 체인을 관통하며 계속 유지되고, 순환신경망에 input gate, output gate 그리고 forget gate를 추가하여 어느 시점에서 데이터 정보를 얼마큼 버리거나 유지할 것인지를 선택적으로 전달할 수 있다. 이 과정을 통해 오래 전의 정보가 현재 시점의 정보에 반영되도록 하여 장기 의존성 문제를 해결하고자 한다. 이러한 구조적 특징은 주가와 마찬가지로 장기 기억 특성을 보이는 가상화폐의 가격 예측에 LSTM 방법을 활용하는 것이 적합할 수 있는 근거이다.



<Figure 2> LSTM Network Structure Diagram

동작 원리를 요약하면 다음과 같다.

- ① forget gate를 통해 이전 정보 기억 여부를 결정
- ② input gate를 통해 현재 정보가 얼마나 중요한지를 결정
- ③ 위의 결과로 memory cell 값을 생성
- ④ 현재 cell state 값을 얼마큼 전달할지 결정

forget gate는 이전 hidden state( $h_{t-1}$ )와 현재 input( $x_t$ )을 가지고 이들 중에서 어떠한 정보를 버릴 지를 정하는 게이트로 0부터 1 사이의 값을 가지며 1에 가까울수록 과거 정보를 많이 사용함을 뜻한다. input gate는 현 시점의 정보( $x_t$ )가 얼마나 중요한지 반영하여 어떤 것을 cell state에 저장할 것인지를 정한다. output gate는 forget gate

와 input gate에 의해 변경된 현재 cell state 값을 얼마나 빼서 다음 레이어로 전달할지 정하는 게이트이다. 즉, t-1 시점의 cell state에 forget gate에서 출력된 값을 곱하여 cell state 값의 일정 부분을 망각하고, 입력 정보와 t-1 출력 값을 처리한 결과에 input gate의 출력 값을 곱하여 새로운 cell state를 정한다. hidden state( $h_t$ )는 cell state를 한 번 더 가공하여 t시점에서 노출할 필요가 있는 정보만을 필터링해서 가지고 있다고 볼 수 있다[5, 12, 13, 15]. 이러한 과정을 통해 RNN보다 sequence가 긴 시계열 데이터에서 LSTM은 더 우수한 학습을 수행할 수 있다.

## 2.3 Prophet

Prophet은 시계열 데이터를 입력 값으로 받아들이며 미래를 예측하도록 훈련시키는, Facebook에서 2017년 공개한 시계열 예측 라이브러리이다[14]. 내부 알고리즘이 공개되지 않아 정확한 알고리즘을 알 수는 없으나 시계열의 시간 종속적인 특성을 고려하는 기존의 시계열 분석 방법론들과는 달리 곡선 적합(curve-fitting)으로 모형을 적합한다. 일반화된 가법 모델을 채택하고 있으며, 이는 요소의 분해와 새로운 요소의 추가가 쉽다는 장점을 가진다. 따라서 시계열 분석 방법론에 대한 지식이 많지 않더라도 비즈니스 도메인에 대한 경험과 이해를 알고리즘에 반영하기 용이하도록 설계되었다는 특징이 있다[4, 14]. Prophet의 기본 구조는 다음의 식처럼 3가지 핵심 요소인 추세(trend), 계절성(seasonality), 이벤트 효과(holiday)의 합으로 이루어진다.

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t$$

$g(t)$ 는 주기적이지 않은 변동인 trend를 반영하는 요소로 추세를 선형 또는 비선형으로 모형화 한다. 이 과정에서 고려되는 변화점은 모델에서 자동 선택되거나 사용자가 지정할 수 있다. 지난 해 9월로 공지되었던 이더리움의 머지 업그레이드와 같은 일정이 분석, 예측 기간에 포함되어 있다면 분석자가 변화점에 반영할 수 있다는 뜻이다.  $s(t)$ 는 주간 또는 연간 계절성과 같은 주기적 변화를 반영하는 요소이며 모델의 유연성 확보를 위해 푸리에 급수를 적용한다.  $h(t)$ 는 불규칙적으로 발생하는 이벤트와 같은 요소를 말하며,  $\varepsilon_t$ 는 정규분포를 따른다고 가정했을 때의 잔차이다.

Prophet은 기존의 딥러닝 기반 시계열 분석 방법론 대비 누락된 데이터 및 추세 변화에 강하고 예외적인 값을 잘 처리하는 것으로 알려져 있다. 이는 전술하였듯 Prophet이 곡선 적합 방식을 채택하고 있으며 비즈니스에 대한 이해를 바탕으로  $g(t)$ ,  $s(t)$ ,  $h(t)$ 의 각 요소들을 상황에 맞게 조정할 수 있기 때문이다. 선형모델과 비선

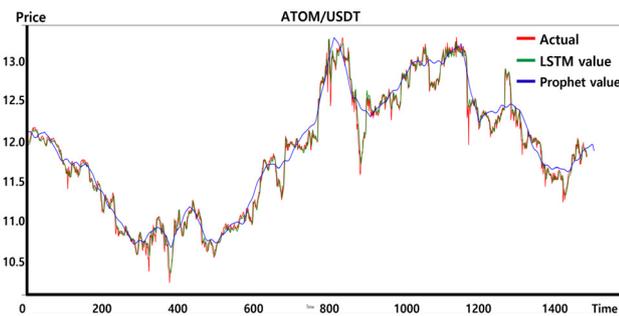
형 모델을 결합하여 시계열 데이터의 복잡한 패턴을 분석하고 이에 따라 예측의 정확도를 높일 수 있으며 일반적으로 기본 값만 사용해도 높은 성능을 보여 최근 가상화폐 및 주가와 같은 금융 데이터 예측에 많이 사용되고 있다. RNN의 단점으로 지적되는 병렬 처리가 가능하여 빠른 예측 속도를 확보할 수 있다는 것도 장점이다. 이에, 실시간 예측을 기반으로 하는 스캘핑 등의 초단타 매매 전략을 가능케 한다.

본 연구에서는 Python에서 Prophet을 이용하여 가상화폐의 가격을 예측하고 투자 관점에서 그 정확도를 분석한다.

### 3. 실험 및 결과 분석

#### 3.1 예측 정확도 비교 분석

아래의 <Figure 3>는 바이낸스의 USDT market에서 2023년 3월 1일부터 2023년 3월 16일까지의 ATOM 스팟 거래(15분봉 데이터) 1,500개에 대하여 각 예측 알고리즘 별 예측 가격과 실제 가격을 보여주고 있다. 약 15 일치의 데이터를 분석 대상으로 삼는 이유는 가상화폐 시장은 주식 시장과 달리 24시간 운영되어 연속적으로 가격의 변동이 발생한다는 점, 스캘핑 전략 구사의 관점에서 가격 변동을 파악하기 때문에 장기적 추세보다 단기 구간 내에서의 가격 변동이 매매 실행에 유관한 요소라는 점이다.



<Figure 3> Forecasting Value for ATOM with Prediction Models

LSTM의 예측 추이는 실제 가격 추이와 비슷한 변동 패턴을 보임을 확인할 수 있다. 그러나 주목할 것은 예측치 추이가 실제 값 추이에 한 기간씩 후행하고 있는 점이다. 이는 LSTM으로 예측한 미래의 시세가 오늘의 시세와 거의 동일하게 도출된다는 의미이며 그렇기 때문에 실제 매매를 목적으로 한 가상화폐의 가격 예측에 있어

LSTM 방법의 적용은 효과적이지 못하다고 할 수 있다. LSTM은 RNN이 가지고 있는 장기 의존성 문제를 해결할 수 있어 딥러닝 기반 시계열 예측 방법으로 널리 사용되고 있지만 Jin 등의 연구에서 이미 지적된 것처럼 예측치가 실제 값에 후행하는 모습을 보이는 경향이 있다는 점은 한계로 지적할 수 있다[6].

Prophet을 적용하여 예측한 ATOM의 가격 추이를 살펴보면 LSTM에 의한 예측 대비 실측치와의 오차가 존재하지만, 시차를 두고 예측 값이 실제 값에 후행하는 LSTM의 문제점을 Prophet을 적용함으로써 해결할 수 있음을 보여준다. <Table 1>은 예측력의 평가 시 주로 사용되는 MSE(Mean Squared Error), RMSE(Root Mean Square Error), MAE(Mean Absolute Error)와 MAPE(Mean Absolute Percentage Error) 값의 비교이다. 오차 값을 뜻하는 이 4가지의 측정 지표는 작을수록 예측 성능이 높다는 것이 일반적인 해석이지만 지표 자체의 한계와 LSTM의 후행성을 해결하지 않은 상태에서는 유의한 의미를 갖지 못한다고 볼 수 있다.

<Table 1> Comparison of Models for ATOM

	MSE	RMSE	MAE	MAPE(%)
LSTM	0.005	0.07	0.05	0.21
Prophet	0.12	0.34	0.26	0.02

#### 3.2 예측 값을 활용한 가상화폐의 자동매매 프로세스 설계

앞서 우리는 Prophet에 대하여 가상 화폐 가격 예측력 측면에서의 유용성을 확인할 수 있었다. 본 연구에서는 가상화폐의 시세 예측이 궁극적으로는 투자에 활용하여 수익을 실현하기 위함이라는 목적을 감안하여 단순히 일별 또는 시점 별 가격을 예측하기보다는 LSTM과 Prophet에 의한 각각의 예측 값에 근거해 자동으로 매매를 실행하고 이러한 거래가 반복되어 누적된 최종 실현 손익을 비교하여 시세 예측의 정확도를 파악하고자 한다. 실험의 설계는 다음과 같다.

- ① LSTM과 Prophet을 적용하여 가상화폐의 예측 값을 도출한다.
- ② 실제 값과의 편차를 실시간으로 받아낸다.  
편차={ (예측 값 - 실제 값) / 실제 값 } \* 100
- ③ 실시간 편차(uplimit 또는 downlimit)를 기준으로 -3%에서 3%의 구간에서 0.1 간격으로 값을 바꿔 가며 long 또는 short 포지션을 반복 실행한다.
- ④ 실험 종료 시점에서 각 거래로 발생한 순이익의 누적 값인 Final value를 확인하여 최초 투자금 USD100,000

대비 얼마의 손익이 발생하였는지 확인한다.

예측 값을 도출하는 단계에서는 3일, 4일, 5일, 7일, 15일, 30일, 60일치의 데이터를 대상으로 각각 실험해본 결과 전술한 2가지의 이유로 15일치의 거래 이력을 대상으로 예측하였을 때 적중률이 가장 높아 15일치의 데이터를 바탕으로 예측하였다. 2022년 1월 1일부터 1월 15일까지 글로벌 1위 가상화폐 거래소인 Binance의 USDT spot market에서 거래된 시가의 15분봉 1,500개를 사용하였으며 최초의 투자 시작금액은 USD100,000으로 설정하였다. 거래의 대상은 마찬가지로 Binance의 USDT spot market에서 스테이블코인을 제외하고 2022년 1월 시가총액 기준 상위 10개 가상화폐로 설정하였다. Intel(R) Core(TM) i7-10700F CPU @ 2.90GHz RAM 32G 사양, Python 3.8과 3.10 환경에서 Tensorflow 2.5와 Keras를 사용하여 실험을 진행하였다.

### 3.3 자동매매 실험 결과

<Table 2A>와 <Table 2B>는 2022년 1월 시가총액 기준 상위 10개의 가상화폐를 대상으로 각각 LSTM과 Prophet에 의한 예측 값을 생성하여 실행한 자동매매 성과를 요약한 결과이다. 주요 결과치로 정리한 값은 편차를 -3.0 ~ 3.0 사이에서 0.1 단위로 변경하며 900개의 조합으로 시뮬레이션 했을 때 승률이 85% 이상 나오는 투자 조합의 수, 해당 조합 별 최종 투자금액의 평균치, 조합 중 최대 투자수익과 최대 투자손실, 평균 수익과 평균 손실이다. 투자대상이 되는 가상화폐의 명칭은 거래소에서 사용되는 코드로 기재하였다[2].

<Table 2A> Summary of Experimental Results by LSTM

	No. of combinations win rate > 85%	Avg of final value	Max Profit	Max Loss	Avg Profit	Avg Loss
ADA	111	158,025	11,731	-4,519	4,587	-3,125
BNB	16	153,075	9,366	-3,415	3,203	-2,670
BTC	3	150,918	4,224	-1,080	1,434	-689
DOGE	10	187,607	9,313	-7,237	1,831	-1,602
DOT	278	170,743	16,320	-7,137	3,883	-983
ETH	60	156,580	12,575	-3,246	2,604	-1,165
MATIC	39	171,100	13,152	-6,552	4,503	-1,960
SHIB	270	167,484	19,312	-5,477	5,593	-1,139
SOL	176	180,610	16,317	-5,424	4,726	-1,980
XRP	81	153,535	7,433	-5,940	1,942	-1,827

<Table 2B> Summary of Experimental Results by Prophet

	No. of combinations win rate > 85%	Avg of final value	Max Profit	Max Loss	Avg Profit	Avg Loss
ADA	360	162,495	15,050	-7,560	4,584	-1,591
BNB	117	159,401	13,134	-2,520	3,460	-852
BTC	7	151,129	4,624	-2,517	1,250	-948
DOGE	108	161,749	10,859	-2,206	3,452	-727
DOT	372	187,983	46,473	-6,228	5,574	-906
ETH	278	166,491	17,594	-8,295	3,836	-2,813
MATIC	406	174,334	16,932	-7,065	4,728	-3,385
SHIB	111	177,345	20,319	-3,134	6,205	-1,533
SOL	256	234,533	40,094	-5,678	6,021	-1,856
XRP	87	158,837	9,459	-5,832	2,220	-2,368

LSTM과 Prophet 예측치에 의한 투자 성과를 비교함에 있어 기준이 될 수 있는 지표는 다양하지만 수익의 극대화 또는 위험의 최소화라는 원칙을 적용할 때 최종 투자금액의 평균치(Avg of final value)와 85% 이상 승률의 투자 조합 수(No. of combinations win rate > 85%)에 우선순위가 있다고 판단하였다. 이러한 관점에서 가장 먼저 눈에 띄는 차이는 85% 이상 승률을 보이는 투자 조합의 수(No. of combinations win rate > 85%)이다. 이익이 발생하는 거래이기 위해서는 우선적으로 가격 변동의 방향을 맞출 것이 전제되기 때문에 위의 6가지 결과 지표 중 예측의 정확도 반영 정도가 제일 높은 항목이다. 이후의 5가지 항목은 기본적으로 예측 값에 근거하지만 편차 조합 운용에 따라 수익의 크기가 달라질 수 있는 부분이다. LSTM 예측 값으로 매매를 실행한 결과를 보면 Prophet을 적용하였을 때보다 85% 이상 승률 조합의 수가 SHIB를 제외하고는 모두 현저히 적다. SHIB의 경우에도 Final value 평균 값, 이익 거래일 때 최대 이익치와 평균 이익치가 Prophet 적용 시보다 모두 작은데 이는 상대적으로 작은 수익을 발생시킨 여러 번의 거래가 이루어졌음을 뜻하여 투자 효율이 낮다고 평가될 수 있다. 수익의 평가 측면에서 LSTM이 더 좋은 결과를 보인 가상화폐로는 DOGE코인이 유일하였다. Prophet에 의한 Final value 평균 값이 \$161,749인 반면, LSTM의 예측치에 따랐을 때는 \$187,607로 약 16% 높았다. 또한 본 실험에서 대상으로 한 가상화폐들로 동일 비중의 포트폴리오를 구성하였을 때 LSTM 예측 성과의 기대값은 \$164,968였고 Prophet 예측 성과의 기대값은 \$173,430으로 산출되어 Prophet이 더 높은 성과를 보임이 확인되었다.

Prophet 예측 값에 의한 매매 성과를 보면, 승률이 85% 이상 나오는 투자 조합의 수는 MATIC이 406개로 가장 많았으며 DOT가 372개, ADA가 360개의 순이었다. 85% 이상 투자 승률 조합의 수가 많다는 것은 예측 값과 실제 값의 편차 크기를 좀 더 유연하게 운영할 수 있

음을 뜻한다. 가장 적은 개수를 보인 것은 7개 조합의 BTC로 다른 가상화폐 대비 상대적으로 안정되고 시가총액이 월등히 큰 특성 상 스캘핑 전략으로 만족할 만한 기대수익을 얻기가 쉽지 않음을 의미한다고 할 수 있다. BTC의 Final value 평균 값이 USD151,129, 이익 거래일 때 최대 이익치가 USD4,624, 손실 거래일 때 최대 손실치가 -USD2,517로 다른 가상화폐들의 동일 측정치 대비 현저히 작다는 점도 이와 같은 해석을 뒷받침한다. Final value 평균 값이 가장 큰 가상화폐는 SOL으로 해당 기간 가격 변동 폭이 컸기 때문으로 추정한다. 이익 거래일 때 평균 이익이 가장 큰 가상화폐는 SHIB였으며, 손실 거래일 때 평균 손실이 가장 큰 가상화폐는 MATIC, 가장 작은 가상화폐는 DOGE였다.

#### 4. 결 론

본 연구에서는 금융 시계열 데이터의 분석 및 예측 시 가장 널리 사용되는 딥러닝 알고리즘인 LSTM과 가장 최근에 공개된 Prophet의 특성을 파악하고 가상화폐 시세 예측 활용성에 대해 검토하였다. LSTM을 이용한 예측은 주식 시장에서는 좋은 성과를 보여주고 있기에 예측력 개선에 초점을 맞춘 연구가 현재에도 진행 중이다. 그러나 예측 값이 실제 값에 후행하는 LSTM의 문제점은 주식시장보다 상대적으로 변동성이 큰 가상화폐 시장에서는 그 유용성이 떨어질 수 있다. 변동성이 큰 만큼 잘못된 예측치를 근거로 매매 계약이 더 빈번히 자동 실행될 때 손실은 극대화될 수 있기 때문이다. 따라서 본 연구에서는 Prophet에 의한 예측치 활용의 효과성을 검증하고자 하는 차원에서 투자 시뮬레이션을 진행하였다. 투자 종료 시점에서 초기 투자금 대비 최종 가치를 확인하였을 때 85% 이상의 승률을 보이는 편차 조합들의 성과는 모두 150% 이상의 수익률로, 기술적 분석에 의한 예측 및 투자의 가능성이 확인되었다. 특히 대상으로 삼은 기간동안 상대적으로 큰 변동성을 보였던 가상화폐의 예상 투자 수익이 상위를 차지했고 최대 투자수익이나 평균 투자수익도 마찬가지로 순서였다. 다만, 분석 대상 기간 개별 가상화폐의 변동성 및 특성에 따라 수익을 창출할 수 있는 편차의 범위나 조합이 다르므로 투자 전략의 설계 시 유의하여야 하며 이를 반영한 추가적인 연구가 필요할 것으로 판단된다.

본 연구는 기존에 많은 분석 및 연구가 이루어졌던 LSTM 뿐 아니라 가장 최근의 시계열 분석 알고리즘인 Prophet을 활용하여 실제 가상화폐 거래 이력을 가지고 실험해보았다는 점에 의의가 있으며 향후 연구에서는 더 다양한 종류의 가상화폐를 대상으로 기간을 달리하여 실

험해보고 가상화폐의 특성과 모의 투자 결과 간 어떤 상관성이 있는지 정리하고자 한다. 또한 LSTM 모델의 수정처럼 Prophet에도 가상화폐의 가격 변동과 인과관계가 높은 요소들을  $g(t)$ ,  $s(t)$ ,  $h(t)$ 에 반영하여 예측력을 높일 수 있는 방안에 대한 모색도 필요할 것이다.

#### References

- [1] Ammer, M.A. and Aldhyani, T.H.H., Deep Learning Algorithm to Predict Cryptocurrency Fluctuation Prices: Increasing Investment Awareness, *ELECTRONICS*, 2022, Vol. 11, No. 15, p. 2349.
- [2] Binance, <https://www.binance.com/en/markets/spot-USDT>.
- [3] Hochreiter, S. and Schmidhuber, J., Long short-term memory, *Neural Computation*, 1997, Vol. 9, No. 8, pp. 1735-1780.
- [4] HYPERCONNECT, <https://hyperconnect.github.io/2020/03/09/prophet-package.html>
- [5] Ilonen, J., Kamarainen, J.K., and Lampinen, J., Differential evolution training algorithm for feed-forward neural networks, *Neural Processing Letters*, 2003, Vol. 17, pp. 93-105.
- [6] Jin, Y.H., Ji, S.H., and Han, K.H., Time Series Data Analysis and Prediction System Using PCA, *Journal of The Korea Convergence Society*, 2021, Vol. 12, No. 11, pp. 99-107.
- [7] Kim, H.Y. and Won, C.H., Forecasting the volatility of stock price index: A hybrid model integrating LSTM with multiple GARCH-type models, *Expert Systems with Applications*, 2018, Vol. 103, pp. 25-37.
- [8] Kim, S.W., Performance Analysis of Bitcoin Investment Strategy using Deep Learning, *Journal of the Korea Convergence Society*, 2021, Vol. 12, No. 4, pp. 249-258.
- [9] Kim, S.W., Prediction Performance of Altcoin Price using Machine Learning Algorithm, *Journal of Digital Contents Society*, 2023, Vol. 24, No. 1, pp. 141-151.
- [10] Lee, K.H., A news event driven approach for LSTM-based stock index volatility forecasting, [master's thesis], [Seoul, Korea]: Yonsei University, 2020.
- [11] Livieris, I.E., Pintelas, E., and Pintelas, P., A CNN-LSTM model for gold price time-series forecasting, *Neural Computing and Applications*, 2020, Vol. 32, pp. 17351-17360.
- [12] Naver blog, <https://blog.naver.com/jinp7/223005431267>.

- [13] Olah, C., Understanding LSTM networks, 2015, <https://colah.github.io/posts/2015-08-Understanding-LSTMs/>
- [14] Sean, J., Taylor and Benjamin Letham., Forecasting at scale, *The American Statistician*, 2018, Vol. 72, No. 1, pp. 37-45.
- [15] Song, H.J., Choi, H.S., Kim, S.W., and Oh., S.H., A study on financial time series data volatility prediction method using AI's LSTM method, *Journal of Knowledge Information Technology and Systems*, 2019, Vol. 14, No. 6, pp. 665-673.

## ORCID

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