

# 암호화폐 가격 예측을 위한 딥러닝 앙상블 모델링 : Deep 4-LSTM Ensemble Model

최수빈\* · 신동훈\*\* · 윤상혁\*\*\* · 김희웅\*\*\*\*

## Development of Deep Learning Ensemble Modeling for Cryptocurrency Price Prediction : Deep 4-LSTM Ensemble Model

Soo-bin Choi\* · Dong-hoon Shin\*\* · Sang-Hyeak Yoon\*\*\* · Hee-Woong Kim\*\*\*\*

### ■ Abstract ■

As the blockchain technology attracts attention, interest in cryptocurrency that is received as a reward is also increasing. Currently, investments and transactions are continuing with the expectation and increasing value of cryptocurrency. Accordingly, prediction for cryptocurrency price has been attempted through artificial intelligence technology and social sentiment analysis. The purpose of this paper is to develop a deep learning ensemble model for predicting the price fluctuations and one-day lag price of cryptocurrency based on the design science research method. This paper intends to perform predictive modeling on Ethereum among cryptocurrencies to make predictions more efficiently and accurately than existing models. Therefore, it collects data for five years related to Ethereum price and performs pre-processing through customized functions. In the model development stage, four LSTM models, which are efficient for time series data processing, are utilized to build an ensemble model with the optimal combination of hyperparameters found in the experimental process. Then, based on the performance evaluation scale, the superiority of the model is evaluated through comparison with other deep learning models. The results of this paper have a practical contribution that can be used as a model that shows high performance and predictive rate for cryptocurrency price prediction and price fluctuations. Besides, it shows academic contribution in that it improves the quality of research by following scientific design research procedures that solve scientific problems and create and evaluate new and innovative products in the field of information systems

Keyword : Deep Learning, Ensemble Modeling, Cryptocurrency, Design Science, Price Prediction

Submitted : September 2, 2020

1<sup>st</sup> Revision : October 21, 2020

Accepted : November 30, 2020

\* 연세대학교 정보대학원 석사

\*\* 연세대학교 정보대학원 석사과정

\*\*\* 연세대학교 정보대학원 박사/스마트미디어랩 매니저, 교신저자

\*\*\*\* 연세대학교 정보대학원 교수

## 1. 서론

블록체인(Blockchain) 기술은 빅데이터, 인공지능(AI), 사물인터넷(IoT)과 함께 4차 산업 혁명을 이끌어갈 핵심 기술 중 하나이다(서무경, 정이상, 2018). 블록체인 기술은 급속도로 성장하고 있으며, 이와 동시에 암호화폐에 관한 관심도 높아지고 있다. 블록체인은 탈중앙화 이념을 기반으로 불특정 다수의 네트워크 참여자들과 공유한 정보들에 대한 암호화 방식을 통해 트랜잭션을 보호하는 기술이다(김준상, 2019). 블록체인 기술은 누구나 참여할 수 있고 정보가 공개되는 퍼블릭(Public) 블록체인과, 중앙 관리자가 존재하는 프라이빗(Private) 블록체인으로 구분된다. 암호화폐는 퍼블릭 블록체인의 이벤트 참여를 통해 받는 보상 개념으로 블록체인 기술 발전과 함께 암호화폐의 거래량도 증가하고 있다(윤성욱, 조현중, 2019).

주요 암호화폐들의 거래량이 증가하면서, 암호화폐의 가격 변화에 대한 연구자들의 관심도 높아지고 있다. 최근, 텍스트 마이닝 및 딥러닝 기법들을 활용한 암호화폐 가격을 예측하려는 연구들이 진행되고 있다. 암호화폐 가격 예측 관련 기존 연구들은 크게 텍스트 마이닝 기반 예측과 머신러닝/딥러닝 기반 예측으로 나뉜다. 텍스트 마이닝 기반 예측의 경우 웹이나 소셜미디어에서 암호화폐 관련 뉴스 등의 감성을 분석해 가격을 예측한 연구들이 상당수 있다(Georgoula et al., 2015; Karalevicius et al., 2018; Matta et al., 2015; Stenqvist and Lönnö, 2017). 그러나 해당 연구에서 활용된 자연어 처리(NLP) 기술은 암호화폐 시장에서만 쓰이는 전문적 용어의 의미와 맥락을 정확하게 반영하지 못했다는 한계가 있다. 머신러닝/딥러닝 기법을 활용한 연구들은 단일 모델 간의 성능 비교를 통해 연구가 진행되어 왔다(Sin and Wang, 2017; Yang et al., 2019). 연구 결과들의 정확도는 40~70% 사이여서, 성능 개선이 필요하다(Struga and Qirici, 2018). 또한, 장기적인 시간 단위의 예측 연구여서, 유동성이 큰 암호화폐 시장에 적용하기에는 한계점이 있다.

본 연구는 디자인 사이언스 연구 절차에 기반하여, 암호화폐 가격의 등락 분류(상승과 하락)와 단기(24시간) 종가 예측을 위한 딥러닝 앙상블 모델: Deep 4-LSTM Ensemble Model(D4LE)을 구축하고자 한다. 앙상블 학습을 통해 단일 모델의 낮은 정확도 및 과적합(overfitting)에 대한 한계점을 보완하며 더욱 정확한 예측이 가능한 모델을 구축하고자 한다. 또한, 연구 결과를 기반으로 단일 딥러닝 모델의 한계점 개선, 딥러닝 앙상블 모델의 새로운 구조 설계 및 최적의 조합 구성, 그리고 암호화폐 투자자들과 연구자들의 예측 참고 지표로서 기대효과를 제공하고자 한다.

## 2. 개념적 배경

### 2.1 암호화폐

암호화폐(Cryptocurrency)는 블록체인 기술 기반의 ‘암호화(crypto)’와, 통화(currency)의 지급 및 저축 그리고 교환수단을 의미하는 ‘화폐’를 합친 디지털 화폐를 의미한다(고동원, 2018). 암호화폐는 데이터를 분산 처리하는 분산 원장(Distributed Ledger) 기술을 통해 모든 사용자가 접근할 수 있고 거래명세를 보유할 수 있다. 중앙에서 화폐에 대한 모든 권리를 제어하고 신용이 있는 특정한 사람만 접근 가능한 기존 금융 시스템과는 다르게 자유롭다고 할 수 있다(송문호, 2019).

주요 암호화폐로는 비트코인, 이더리움, 리플이 있으며 본 연구에서는 이더리움(Ethereum, ETH)에 대한 가격 예측 모델을 구축한다. 2015년 비탈리크 부테린(Vitalik Buterin)이 개발한 이더리움은 Ethereum Foundation에서 지원하고 있는 오픈소스 프로젝트로서 비트코인에 이어 두 번째로 개발되었다. 결제 기능만 있는 비트코인과는 다르게, 이더리움은 스마트계약(smart contract) 기술을 기반으로 결제를 비롯한 다양한 분야에서 활용되도록 고안되어 ‘2세대 암호화폐’라고 불리고 있다(Wood, 2014). 암호화, 분산화, 안정화 등이 탁월해 상거래를

비슷한 투표, 크라우드펀딩, 계약과 협약, 지식 재산 등의 다양한 분야에서 활용되고 있다(서해, 2018). 이리움의 활용도에 대한 기대감이 높아짐에 따라 애플 컴퓨터 공동창업자 스티브 워즈니악(Steve Wozniak)은 “이더리움은 애플만큼의 영향력을 가질 것”이라고 언급하며 이더리움의 전망에 기대감을 보였다(blockinpress, 2018). 또한 Liu and Tsyvinsk (2018)에 따르면 암호화폐는 통화, 상품, 거시경제적 요인, 주식 시장에 노출되지 않고 경제적 가치 평가가 확립되지 않았기 때문에, 암호화폐 시장만의 요소들로 수익 예측이 가능하며, 타시장이 암호화폐 가격에 거의 영향을 주지 않는 것으로 밝혀졌다. 즉, 암호화폐 데이터는 가격 예측에 있어서 암호화폐 자체의 시계열적 성격이 주요하게 영향을 미친다(Raju and Tarif, 2020). 이에, 암호화폐 가격 예측 관련 대부분의 선행 연구에서 시계열 정보 기반으로 진행되어 왔다(Greaves and Au, 2015; Madan et al., 2015; Spilak, 2018). 그리하여 본 연구에서 또한 시계열 속성을 지닌 데이터에 대한 분석에 효과적인 LSTM을 기반으로 한 앙상블 모델을 구축하고자 하였다.

## 2.2 암호화폐 가격 예측 관련 선행 연구

암호화폐 가격 예측과 관련된 선행 연구는 사용 데이터에 따라 3가지 범위로 분류할 수 있다. 1) 텍스트 마이닝을 활용한 연구, 2) 머신러닝/딥러닝을 활용한 연구, 3) 텍스트 마이닝과 머신러닝/딥러닝 모두 활용한 연구로 분류할 수 있다.

첫 번째로 텍스트 마이닝을 활용한 선행 연구에서는, 주로 소셜미디어 및 기사 자료로부터 텍스트 데이터를 추출하여 감성 분석을 통한 암호화폐 가격 예측이 진행되었다. 이러한 연구들은 전반적으로 텍스트 데이터 자체보다는 게시글의 양이나 수치적 경향성을 나타내는 정보가 더 유용하다는 방법론적 한계가 있다(Abraham et al., 2018; Bollen et al., 2011; Matta et al., 2015). 또한, 텍스트 해석의 신뢰도가 낮고, 사람마다 텍스트에 반응하는 정도가

달라 일반화가 어렵다는 문제가 있다(Karalevicius et al., 2018).

두 번째로 머신러닝 분석을 활용한 선행 연구에서는, 개별적인 머신러닝 또는 딥러닝 모델 비교를 통한 암호화폐 예측이 진행되었다(Greaves and Au, 2015; McNally et al., 2018; Struga and Qirici, 2018). 특히, 금융 시장의 시계열적 속성과 비선형적 변동성을 예측하기 위해 딥러닝 모델이 사용되는 연구가 활발하게 진행되고 있다. 딥러닝 모델은 이해하기 어려운 복잡성에서 비선형적 패턴과 흐름을 도출해 정확한 예측이 가능하다는 장점이 있다(Khare et al., 2017). Greaves and Au(2015)는 Support Vector Machine와 Neural Network 등 머신러닝 알고리즘을 활용해 암호화폐 가격의 상승과 하락의 경향성에 대한 예측하였다. 또, McNally et al. (2018)와 Struga and Qirici(2018)는 딥러닝 알고리즘인 LSTM을 활용하여 암호화폐 가격에 대한 예측을 시도하였다. 기존 연구들은 장기적인 시간 단위의 가격 예측이 시도되었으며, 등락 분류 예측 정확도는 40~70% 수준으로 낮은 편이다.

마지막으로 텍스트마이닝과 머신러닝/딥러닝 분석 모두 활용한 연구들이 있다(Georgoula et al., 2015; Pant et al., 2018; Yang et al., 2019). 이 연구들은 텍스트마이닝 분석을 일차적으로 수행 후, 그 결과를 활용하여 머신러닝 분석을 하였다. 해당 연구들은 분석기법 간의 앙상블을 시도한 것이 아닌 분석 결과 간의 개별적인 비교분석만을 했다는 한계점을 가지고 있다. 또한, 암호화폐 가격 예측이 텍스트 마이닝 분석보다 머신러닝/딥러닝 분석에 의해 대체로 결정된다는 한계가 있다(Jain et al., 2018).

선행 연구들을 요약하자면 텍스트 마이닝을 활용한 암호화폐 예측 연구는 자연어 처리의 한계점을 보였으며, 머신러닝 분석을 활용한 연구들은 주로 장기적인 시간 단위의 예측 연구가 이루어졌다(Struga and Qirici, 2018b). 최근에는 시간 단위 예측을 시도한 연구도 진행되었으나, 가격 변동성이 큰 암호화폐 특성 때문에 60% 이하의 정확도라는

한계점이 있다(Pintelas et al., 2020). 이에 암호화폐 가격 예측 연구의 경향은 가격의 흐름과 방향성을 분석할 수 있는 일 단위 가격 예측들이 주로 진행되고 있다(McNally et al., 2018; Spilak, 2018). 마지막으로 대부분의 선행 연구들은 각 알고리즘을 개별적으로 활용하였다는 한계를 가진다. 최근 연구에서는 단일 모델 예측의 낮은 성능 한계를 극복하고자 앙상블 모델을 대안으로 제시되고 있다(Livieris et al., 2020). 앙상블 모델은 약한 예측 모델을 결합하여 강력한 하나의 모델로 개발하는 방법이다. 앙상블 학습은 Bagging, Boosting 그리고 Stacking 등의 다양한 방법이 존재하며 금융 시장 예측에 적용한 연구도 있다. 특히, Xie et al.(2018)는 주가 예측에 있어 단일 모델보다 앙상블 모델의 성능이 더 높은 성능을 보인다는 것을 증명하였다.

그리하여 본 연구는 딥러닝 기법들을 조합한 앙상블 모델을 구축해서 보다 정확한 일 단위 암호화폐 가격(종가)을 예측하고자 한다. 나아가 구축된 모델의 객관적인 타당성 검증을 위해 선행 연구에서 진행된 딥러닝 모델 결과와 비교하고자 한다.

### 3. 연구방법론

#### 3.1 데이터 수집

본 연구는 코인마켓캡(coinmarketcap.com)의 암호화폐 가격 데이터를 활용하였다. 코인마켓캡은 5,000개 이상의 암호화폐 관련된 다양한 시세 데이터, 거래소 별 거래량 등을 제공해 주는 암호화폐 포

털사이트이다. 전 세계 암호화폐 관련 포털사이트 중 가장 오래되었으며, 암호화폐 투자자들이 많이 사용하고 있는 서비스 중 하나이다.

코인마켓캡은 데이터는 5분마다 갱신되며, 암호화폐 가격은 거래량별로 가중치가 부여된 암호화폐 거래소들의 가격을 평균하여 제공된다. 본 연구에서는 코인마켓캡 API를 통해 2015년도 8월부터 2020년도 1월까지의 약 5년간의 이더리움(ETH) 가격 데이터를 수집하였다. 수집된 데이터는 총 1,624일간의 이더리움 가격 데이터이다. 가격 데이터는 거래 날짜(Date), 시가(Open), 고가(High), 저가(Low), 종가(Close), 거래량(Volume)으로 6개로 구성되어 있다(가격 기준은 달러임). 데이터는 24시간마다 저장되어, 본 연구에서 진행하고자 하는 단기 가격 예측(24시간 후) 가격 예측에 가장 적합하다고 판단하였다.

<표 1>은 수집된 데이터의 기술 통계량이다. 종가의 평균은 203.56달러이며, 최솟값은 0.43달러이며, 최댓값은 1396.42달러이다. 표준편차는 242.26달러로 유동성이 심하다는 것을 알 수 있다. 거래량은 하루 평균 약 23억 건 정도로, 거래량 역시 많은 시장임을 의미한다.

#### 3.2 연구 절차

본 연구는 정보시스템(Information Systems)과 컴퓨터 과학(Computer Science)을 융합하여 연구를 수행하는 디자인 사이언스 연구 방법론(Design Science Research Methodology)을 기반으로 한다 (Hevner et al., 2004).

<표 1> 이더리움(ETH) 데이터 기술 통계량

	시가(Open)	고가(High)	저가(Low)	종가(Close)	거래량(Volume)
Mean	203.51	210.93	195.10	203.56	2.35E+09
SD	242.26	252.88	229.60	242.09	3.14E+09
MIN	0.43	0.48	0.42	0.43	1.02E+05
25%	11.33	11.67	11.01	11.34	1.56E+07
50%	146.40	150.26	142.77	146.61	1.17E+09
75%	287.24	295.53	277.69	287.43	3.05E+09

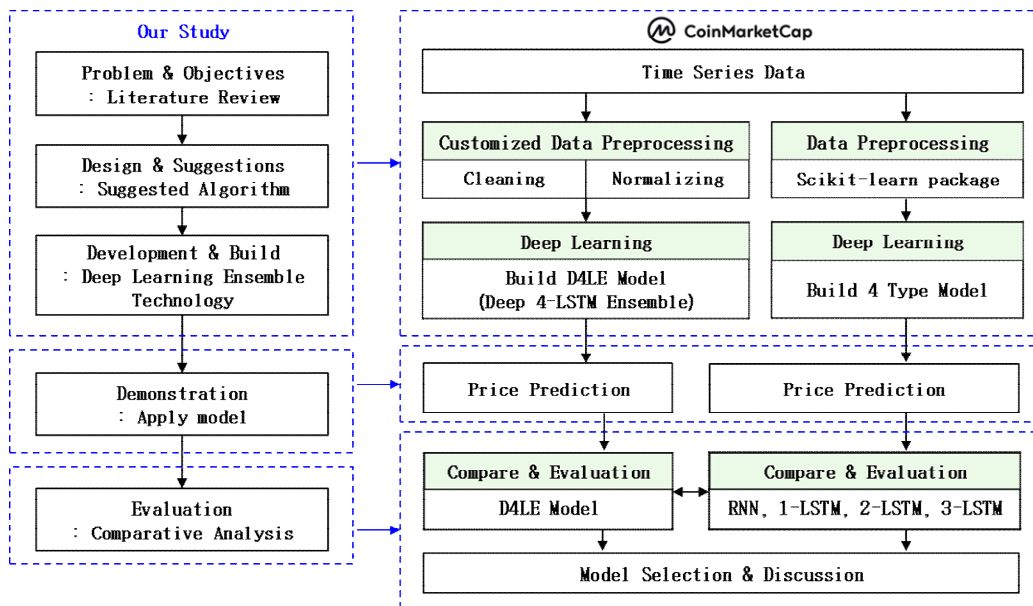
본 연구는 디자인 사이언스 프로세스를 기반으로 도출한 5단계의 절차로 진행한다. 첫 번째 절차로, 기존 문헌 연구에서 활용되었던 기법들을 바탕으로 현상에 대한 문제점과 연구 목적을 찾는다. 두 번째 절차로 기존 연구들이 가지고 있는 모델의 한계점을 해결하고 성능 개선을 보여줄 수 있는 새로운 알고리즘을 디자인하고 제시한다. 세 번째 절차로 인공지능을 기반으로 한 딥러닝 앙상블 모델을 개발하는 과정을 거친다. 네 번째 절차로 앞서 구축된 모델을 데이터에 적용하여 예측 결과를 확인한다. 마지막으로 다른 4종류의 딥러닝 모델들의 비교분석을 통해 본 연구에서 제안하는 모델을 평가하고 타당성을 보여준다. [그림 1]은 본 연구가 제시한 디자인 사이언스 연구 절차를 정리한 것이다.

### 3.3 데이터 처리

본 연구는 데이터의 전처리를 Python을 활용하여 다음과 같이 진행하였다. 전처리는 총 4단계로, 1) Raw 데이터를 데이터 프레임(Data frame)으로 변경, 2) 데이터 정제, 3)데이터 정규화, 그리고

4)데이터 분할이다.

첫 번째로 일별(daily)로 구성된 데이터 절차 길이(Sequence length)를 30으로 지정하여 30일 단위의 데이터 프레임 매트릭스(Matrix)로 재구성하였다. 두 번째로 데이터 정제 과정에서는 결측 값을 처리하기 위해 데이터 중 null 값이나 0으로 표시된 데이터를 평균값(mean)으로 대체하였다. 단, 2015년도 데이터의 경우 이더리움이 출시된 시기로서 효과적인 모델 학습을 위해 0으로 표시된 데이터 값은 제외하였다. 세 번째로 데이터 정규화 과정을 통해 모든 입력 값들을 0과 1 사이의 값으로 변환하였다. 마지막으로 데이터 분할 과정을 거쳤다. 수집된 이더리움 전체 데이터를 총 7:3 비율로 나누어 7부분의 데이터(학습 데이터)는 모델 학습에 활용하며 3부분의 데이터(테스트 데이터)는 테스트를 위해 활용하였다. 단 데이터가 시계열로 구성되어 있어서 순서를 고려해, 테스트 데이터는 최근의 데이터로 선정하였다. 그리고 하이퍼 파라미터(Hyper-parameter)들은 최적화를 위해 분할된 7부분의 학습 데이터를 8:2로 학습과 검증 부분으로 나누었다.



[그림 1] 연구절차

## 4. 모델링 결과 및 성능 평가

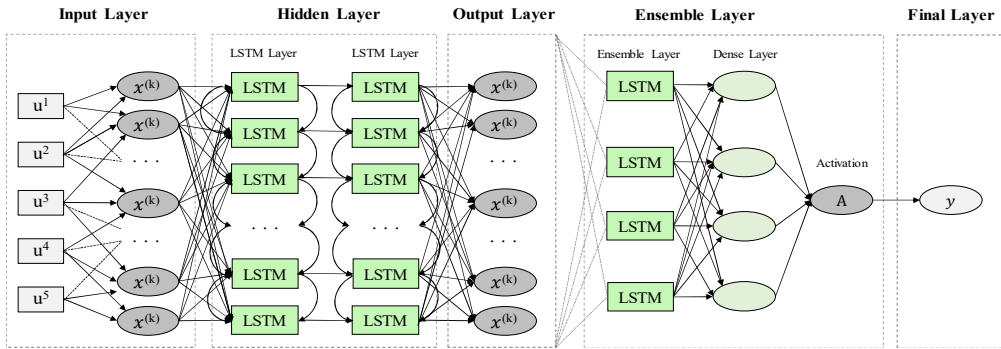
### 4.1 분석 결과

#### 4.1.1 딥러닝 앙상블 모델 개발

앙상블(Ensemble) 학습이란 여러 개의 개별적인 모델을 생성하고 예측 결과들을 결합함으로써 더욱 더 정확한 예측을 도출하려는 방법이다(West et al., 2005). 신경망 모형에 앙상블 학습이 적용된 것은 Hansen and Salamon(1990)에 의해 처음 제안되었으며, 단일 모델들의 결과를 조합하여 예측 성능을 대폭 향상시켰다. 본 연구의 암호화폐 가격 예측을 위한 딥러닝 앙상블 모델은 4개의 LSTM

(Long Short Term Memory)모형을 조합하여 구성했으며, 이를 「Deep 4-LSTM Ensemble(D4LE) model」이라고 한다.

LSTM은 순환신경망(Recurrent Neural Network, RNN) 방식 중 하나이다. 순환 신경망은 기억하는 상태 정보(Hidden state)를 활용한 순환(Recurrent) 구조로 순서(Sequence)가 있는 데이터를 모델링한다(Connor et al., 1994). 새로운 입력이 들어오면 네트워크 내부 기억을 수정하는 과정이 반복되고 네트워크 내부에는 순서 전체가 요약된 정보가 남는다. 사슬(Chain)과 같이 반복되는 네트워크를 가지고 있으므로 연속된 이벤트 분석에 적합한 구조를 가진다.



**Input: Pre-processed Data**

**Output: Final Predicted Data**

```

For t ⇒ 1 to T
  do Learn LSTM1 with input data
End
For t ⇒ 1 to T
  do Learn LSTM2 with input data
End
For t ⇒ 1 to T
  do Learn LSTM3 with input data
End
For t ⇒ 1 to T
  do learn LSTM4 with input data
End
...continue
    
```

```

For t ⇒ 1 to each Model
  do predicted data1 = LSTM1 result
  do predicted data2 = LSTM2 result
  do predicted data3 = LSTM3 result
  do predicted data4 = LSTM4 result
End
For t ⇒ 1 (ascending order)
  do learn weight*predicted data1
  do learn weight*predicted data2
  do learn weight*predicted data3
  do learn weight*predicted data4
End
For t ⇒ 1 (ascending order)
  do final = ((w*p1)+(w*p2)+
              (w*p3)+(w*p4))/4
End
    
```

[그림 2] Deep 4-LSTM Ensemble Model 알고리즘과 구조

LSTM은 Hochreiter and Schmidhuber(1997)가 제안한 딥러닝 알고리즘으로, RNN의 장기 의존성 문제(Long Term Dependency)를 해결하기 위해 개발되었다. 장기 의존성 문제는 절차가 많이 흐를수록 입력 데이터와 과거 데이터의 위치 차이가 커져 연결고리를 유지하기 힘들어지는 상태를 의미한다(Hochreiter and Schmidhuber, 1997). LSTM은 망각 게이트(Forget gate), 입력 게이트(Input gate), 출력 게이트(Output gate), 입력 조절 게이트(Input modulation gate)간 상호작용으로 상태 선(Cell state)을 보호하고 관리한다. 4개의 게이트를 통해 기울기 소실 문제(Vanishing gradient)를 방지할 수 있다(Sak et al., 2014). LSTM은 시계열 데이터의 장기 정보를 저장할 수 있기 때문에 주식 시장을 포함한 금융 관련 예측에서 높은 성능을 보인다(Heaton et al., 2017). 금융 시장에 대한 예측을 위해 딥러닝을 적용한 선행연구가 진행 중이며, 복잡한 패턴 학습을 통해 전통적 예측 모델 대비 우수한 성능을 보였다(Jia, 2016; Raju and Tarif, 2020).

앙상블 모델로 조합된 D4Le 모델 내부구조는 [그림 2]와 같다. 내부구조는 크게 입력층(Input Layer), 은닉층(Hidden Layer), 출력층(Output Layer), 앙

상블층(Ensemble Layer), 결과층(Final Layer) 5개 층으로 구성된다. LSTM 모델에 데이터가 입력층을 통해 들어가면, 내부의 2개의 은닉 층(Hidden layer)을 통해 학습하게 된다. 그리고 예측한 결과값이 출력층을 통해 나오게 된다. 4개의 LSTM 모델에서 출력된 예측 결과값을 가지고 앙상블층을 구성하게 된다. 앙상블층에서는 각 모델(LSTM 1~4)의 결과값에 가중치(Weight)를 곱해서 더한 후, 평균을 계산해 최종적인 예측 결과값을 출력한다.

#### 4.1.2 모델 학습 및 테스트

본 연구에서는 D4Le 모델 구성 후, 성능 최적화를 위해 LSTM 모델의 하이퍼 파라미터 최적화 과정을 진행했다(<표 2> 참조). 1차 과정은 뉴런(Neuron) 개수와 학습 횟수(Epoch)를 탐색했다. LSTM 모델 내부의 2개 층은 n개의 뉴런 수로 구성된다. 본 연구에서는 뉴런 수를 16, 32, 64, 128, 200으로 바꿔가면서 실험하였다. 또, 학습 횟수는 10, 30, 50, 100으로 바꿔가면서 실험하였다. 학습 횟수가 너무 적으면 모델 학습이 잘 되지 않고, 횟수가 너무 많으면 과적합 문제가 발생한다. 결론적으로 뉴런 수는 32개, 학습 횟수는 50일 경우 검증 데이터 예측 결과가 가장 좋게 나왔다.

<표 2> 모델별 최적화된 하이퍼 파라미터와 성능 비교 평가

Hyper-parameter	single RNN	single LSTM	2-LSTM	3-LSTM	D4Le
Hidden Layer	1	2	2	2	2
Neurons	256	128	64	64	32
Dropout Ratio	0.25	0.25	0.25	0.25	0.25
Gate Activation	tanh	tanh	tanh	tanh	tanh
Recurrent Activation	-	sigmoid	sigmoid	sigmoid	sigmoid
Batch Size	2	2	2	2	2
Epochs	150	100	50	50	50
Window Size	7	7	7	7	7
Sequence Length	30	30	30	30	30
Output Dimension	30	30	30	30	30
Optimizer	adam	adam	adam	adam	adam
Loss Function	mse	mse	mse	mse	mse
Accuracy	62.25%	78.77%	86.21%	85.57%	87.36%
RMSE	18.74%	8.56%	6.89%	7.05%	6.20%

2차 과정으로 최적의 윈도우 크기(Window size)와 활성화 함수(Activation function)에 대한 최적화 과정을 거쳤다. 2차 과정은 1차에서 선정된 뉴런 수와 학습 횟수를 32와 50으로 고정한 상태에서 진행했다. 윈도우 크기(Window size)는 모델이 학습을 하는 과정에서 사용하게 되는 이전 데이터 세트의 크기를 지칭하며 10, 7, 5, 3 순서로 줄여가면서 분석을 진행했다. 활성화 함수(Activation function)는 LSTM 내부의 2개의 은닉층에서 입력값을 출력값으로 변환하는 함수를 의미한다. 순환 함수(Recurrent activation)는 일반적으로 사용되는 시그모이드(Sigmoid) 함수를 그대로 사용했으며, 게이트 함수(Gate activation)는 4가지 함수인 tanh, relu, linear, softmax를 비교 분석하였다. 2차 분석의 결과로 윈도우 크기는 7, 게이트 함수는 tanh 함수의 조합으로 구성하였을 때 검증 데이터 예측 결과가 가장 좋게 나왔다. 1, 2차 최적화 과정을 거쳐 추가적인 하이퍼 파라미터 선정 작업을 진행했다. 드롭아웃 비율(Dropout ratio)은 과적합 방지를 위해 뉴런 사이에 연결된 모든 선 중 일부를 랜덤하게 끊는 비율을 의미하며, 본 연구에서는 0.25로 지정하였다. 배치 크기(Batch size)는 전체 데이터를 나눠서 학습한 후 다음 네트워크에 넘겨주는 양을 의미한다. 크기가 클수록 컴퓨터 메모리를 많이 사용하게 되어 본 연구에서는 2로 지정하였다. 절차 길이(Sequence length)와 출력 차원(Output dimension)은 30일 단위로 구성했다. 그리고 옵티마이저(Optimizer)는 Adam을 사용하였고 손실함수(Loss function)는 MSE(Mean Squared Error)를 사용했다.

## 4.2 모델 성능 평가

디자인 사이언스 연구절차의 마지막 단계로 본 연구에서 개발한 딥러닝 앙상블 모델 Deep 4-LSTM Ensemble(D4LE)과 다른 모델과의 성능을 비교 평가한다. 비교 평가에 활용되는 딥러닝 모델은 총 4개로, 선행 연구(McNally et al., 2018; Spilak,

2018)에서 활용됐던 simple RNN, simple LSTM과 2개의 LSTM으로 구성된 앙상블 모델(2-LSTM), 3개의 LSTM으로 구성된 앙상블 모델(3-LSTM)이다. 모델 간의 성능 비교 평가를 위해 일차적으로 각 모델별 최적의 하이퍼 파라미터 조합으로 구성하였을 때의 성능을 비교하고, 이차적으로 D4LE 모델과 같은 하이퍼 파라미터로 구성하였을 때의 성능을 비교한다. 성능 평가 척도로는 혼동 행렬(Confusion matrix)을 활용한 정확도(Accuracy)와 RMSE(Root Mean Squared Error)를 사용했다. 혼동 행렬(Confusion matrix)은 분류 모델에서 사용되는 성능 평가 척도로서 본 연구에서는 암호화폐 가격 등락에 대한 분류 성능 수치를 산출하기 위해 활용했다. True(1)는 실제 값이 예측 값과 일치하는 경우, False(0)는 실제 값과 예측 값이 일치하지 않는 경우를 의미하며 이를 기준으로 정확도(Accuracy)를 산출하였다. 정확도는 전체 분류 중에서 올바르게 예측한 비율로 전체 경우의 수에서 True로 행동한 비율을 의미하며 1에 가까울수록 좋다고 판단한다(Foody, 2002). RMSE(Root Mean Squared Error)는 평균 제곱근 오차를 의미하며 수치 예측 모델에 대한 정확도를 표현할 때 주요 성능 지표로 사용된다(Willmott and Matsuura, 2005). 예측된 값과 실제 값의 차이 제곱을 모두 더하여 제곱근을 취한 값을 나타내며 해당 수치가 낮을수록 정확도가 높다고 판단한다.

1차 비교 평가를 위해, 4개 비교 모델별 최적의 하이퍼 파라미터를 찾기 위한 탐색 과정을 거쳤다. Single RNN과 Single LSTM 모델은 단일 모델로서 성능 향상을 위해 뉴런과 epoch 수를 RNN은 256과 150, LSTM은 128과 100까지 늘렸다. 2-LSTM과 3-LSTM 모델은 2개의 LSTM과 3개의 LSTM으로 구성된 앙상블 모델로서 성능 향상을 위해 뉴런 64, epoch 수는 50으로 정하였다. 최종적으로 선정된 모델별 하이퍼 파라미터와 RMSE 비교 평가 결과는 <표 2>와 같다. D4LE모델의 가격 등락 분류 기준의 정확도는 87.36%, one day lag의 기준 RMSE 결과값은 6.20%로 우수한 성능을 보여주고 있음을 확인할 수 있다.



〈표 3〉 동일한 조건의 모델 성능 비교 평가

Parameter	single RNN	single LSTM	2-LSTM	3-LSTM	D4LE
Hidden Layer	1	2	2	2	2
Neurons	32	32	32	32	32
Dropout Ratio	0.25	0.25	0.25	0.25	0.25
Gate Activation	tanh	tanh	tanh	tanh	tanh
Recurrent Activation	-	sigmoid	sigmoid	sigmoid	sigmoid
Batch Size	2	2	2	2	2
Epochs	50	50	50	50	50
Window Size	7	7	7	7	7
Sequence Length	30	30	30	30	30
Output Dimension	30	30	30	30	30
Optimizer	adam	adam	adam	adam	adam
Loss Function	mse	mse	mse	mse	mse
Accuracy	51.16%	70.67%	80.71%	84.41%	87.36%
RMSE	20.75%	11.31%	9.69%	7.12%	6.20%

다음으로 비교 모델들을 모두 같은 하이퍼 파라미터를 구성했을 경우 모델별 성능 차이를 확인하였다. 1차 비교 평가에서 개별 모델들의 성능을 높이기 위해 차이를 두었던 뉴런 수와 학습 횟수도 모두 동일하게 고정하였다. 그 결과 1차 비교 평가 때와 마찬가지로 D4LE 모델이 우수한 성능을 보여준다. 반면에 모델 간 비교를 위한 나머지 4개의 딥러닝 모델들은 1차 비교보다 성능이 떨어졌다(<표 3> 참조).

## 5. 토의 및 시사점

### 5.1 결과 토의

블록체인 기술에 대한 높은 관심에 힘입어, 암호화폐 시장은 활발하게 투자되고 있다. 이에 비해 암호화폐 가격 예측에 관한 연구는 부족한 상황이다. 이에 본 연구는 디자인 사이언스 연구 방법의 절차를 기반으로(Peffers et al., 2007), 암호화폐 가격의 등락 분류와 24시간 단위의 증가 예측을 위한 앙상블 모델을 개발했다.

암호화폐 가격 예측 관련 선행 연구들은 텍스트 마이닝과 머신러닝/딥러닝 기술을 선택적으로 활용

하여 가격 예측을 시도하였으나, 명확한 한계점이 존재했다. 텍스트 마이닝을 활용한 연구들은 암호화폐 관련 기사 등을 대상으로 감성 분석을 시도했다. 그러나 감성 분석 결과보다는 게시글의 양이나 수치적 경향성을 나타내는 데이터가 가격 예측에 더 큰 영향을 미쳐 방법론적인 한계를 보였다(Abraham et al., 2018; Bollen et al., 2011; Jain et al., 2018; Matta et al., 2015). 그리고 머신러닝 및 딥러닝 기술을 활용한 연구들은 단일 머신러닝 모델을 활용했으며, 예측 정확도는 40%~70% 수준으로 개선이 필요했다(Greaves and Au, 2015; Heo et al., 2018).

본 연구는 이러한 연구의 필요성을 바탕으로 Deep 4-LSTM Ensemble(D4LE) 모델을 개발했다. D4LE 모델은 시계열 예측에 적합한 LSTM 모델 4개를 조합한 앙상블 모델로, 최적의 하이퍼 파라미터를 찾기 위한 과정을 거쳤다. 개발된 모델의 우수성을 평가하기 위해 선행 연구에서 활용된 모델과 LSTM 조합 개수를 바꾼 앙상블 모델들과의 비교 분석을 수행했다. 총 5개 모델 간의 성능 평가 결과, D4LE 모델이 가장 우수한 결과를 보여줬다. D4LE 모델의 암호화폐 가격 등락 분류에 대한 정확도는 87.36%, 증가 가격 예측에 대한 RMSE 값은 6.20%을 보여줬다.

추가적으로 본 연구에서는 D4LE 모델의 타당성을 검토하기 위해 암호화폐 전문가 3명(전업투자자 2명, 거래소 임원 1명)과 인터뷰하였다. 인터뷰는 1명당 약 30분 내외로 일자 단위 예측을 하는 D4LE 모델을 설명하고 실무적 의의 등을 묻는 방식으로 진행하였다. 인터뷰 결과를 정리하면 다음과 같다. 머신러닝이나 퀀트를 활용한 암호화폐 가격 예측은 암호화폐 거래 초창기부터 진행되어 왔다. 그 중에서 일부 모델들은 시간단위의 가격 예측을 높은 수준으로 정확하게 맞췄다. 그러나 암호 화폐 가격을 시간단위로 정밀하게 예측하더라도 거래물량 자체가 없으면 매수할 수 없다는 문제가 있다. 또한 대부분의 시간대의 가격 예측을 정확히 하더라도, 일부 시간대 가격예측이 정확하지 않으면 큰 손해가 날 수 있기 때문에 사용에 어려움이 있다고 한다. 이에 최근 전업 투자자와 거래소에서는 머신러닝 예측을 일자 단위 또는 7일 단위로 하고(Foxley, 2020), 이 결과를 시장 흐름을 파악하고 구매 결정에 보완제로 활용한다고 한다. 즉, 실무에서도 가격 예측에 D4LE와 비슷한 LSTM 기반한 모델들이 주로 사용되고 있음을 확인했다. 본 연구는 인터뷰 결과를 통해 D4LE 모델의 외적타당도를 일부 검증하였다.

## 5.2 한계점 및 향후 연구 방안

본 연구는 다음과 같은 한계점이 있으며, 이를 보완한 향후 연구 방향은 다음과 같다. 첫째, 본 연구에서 구축한 딥러닝 앙상블 모델(Deep 4-LSTM Ensemble : D4LE Model)은 다양한 딥러닝 기법 중에서 LSTM만을 기반으로 개발했다. 하지만 최근 딥러닝 기술들이 발전하면서 Gated recurrent unit(GRU), Convolutional Neural Network(CNN) 등을 활용한 가격 예측 시도가 있다. 향후 연구에서는 발전된 딥러닝 기법들을 조합의 예측모델링 시도를 기대한다.

둘째, 본 연구는 1일 단위의 단기 예측만 했다 한계가 있다. 선행 연구는 장기 단위 위주로 가

격을 예측하여, 변동성이 심한 암호화폐 가격 예측에는 효율성이 떨어지는 한계점을 보였다. 이에 본 연구에서는 24시간 간격의 가격 예측을 시도하여 기존 연구의 한계점을 보완할 수 있었다. 하지만 향후 연구에서 더 짧은 시간 단위의 정밀한 예측을 할 수 있다면, 가격 예측 연구 발전에 크게 이바지할 수 있다.

셋째, 본 연구에서는 다양한 암호화폐 중 2세대 암호화폐인 이더리움(ETH) 가격 데이터 하나만으로 예측모델을 개발하였다. 그러나 암호화폐 시장은 최근 3세대, 4세대 암호화폐가 나오고 있는 점을 고려하면, 하나 이상의 암호화폐를 대상으로 한 분석도 의미가 있을 것이다. 이를 통해 각 암호화폐의 개별적 특성을 비교 분석하여 새로운 시사점을 도출할 수 있을 것이다. 또한, 가격 데이터만 활용하여 외부 환경적인 요소에 대해 고려하지 못하였다. 그러므로 가격의 급격한 변화에 영향을 주는 환경 요인(신문 기사, 주가, 날씨 등)에 대한 추가적인 변수를 적용하면 더 좋은 성능이 나올 것으로 기대된다.

## 5.3 연구의 학술적/실무적 시사점

본 연구가 가지는 연구의 의의는 다음과 같다. 첫째, 암호화폐 관련 서비스를 제공하는 기업들에 보다 더 정교한 예측 및 위험 관리 등의 지표를 제시할 수 있다는 점에서 의의를 지닌다. 현재 페이스북, 카카오, 라인과 같은 대규모 사용자를 확보한 서비스가 암호화폐 발행과 활용을 준비하고 있다고 발표했으며, 인공지능 기술을 활용하여 암호화폐의 과거 가격 데이터의 움직임 분석한 뒤 가격을 예측해주는 서비스들 또한 출시되고 있다(Foxley 2020). 높은 성능의 딥러닝 앙상블 모델을 구축한 본 연구를 통해 예상치 못한 시장 하락과 거래 수익 창출에 대한 기존 연구 대비 차별화된 예측 모델을 기업들에 제시할 수 있다.

둘째, 디자인 사이언스 연구 방법을 활용하여 예측 모델을 개발 했다는 점에서 기존 선행 연구

들과 차별점을 갖는다. 본 연구는 디자인 사이언스 절차에 따라 문제 해결을 위한 프로세스와 프레임 워크, 성능 비교와 같은 절차를 따랐다는 데 연구 의의가 있다(Peffers et al., 2007; Wimmer and Yoon, 2017). 이를 통해 구축한 딥러닝 앙상블 모델 결과는 기존 암호화폐 예측 모델링의 한계를 개선할 수 있었다. 나아가 암호화폐 전문가 3명과 인터뷰하여 본 연구의 D4LE 모델의 외적 타당성을 일부 증명했다. 따라서 본 연구의 결과를 통한 암호화폐에 단기적인 투자를 시도할 때 유용한 참고 지표로 실무에서 바로 활용할 수 있다고 기대된다. 마지막으로, 많은 연구자가 암호화폐 가격 예측을 위한 새로운 알고리즘 개발을 시도하고 있으며 다양한 종류의 머신러닝 모델 조합으로 연구가 이루어져 왔다. 하지만 본 연구에서는 현존하는 알고리즘인 LSTM을 기반으로 최적의 하이퍼 파라미터를 구성하여 성능을 개선한 딥러닝 앙상블 모델을 개발했다. 앙상블 모델은 단일 모델의 낮은 성능과 과적합(overfitting)에 대한 한계점을 보완할 수 있다(Livieris et al., 2020). 이 결과 본 연구의 예측 정확도가 단일 머신러닝 모델 기반으로 암호화폐 가격 예측을 시도한 기존 연구(Greaves and Au, 2015; Heo et al., 2018) 결과보다 우수하다는 점에서 연구 의의가 있다.

## 참고문헌

- 고동원, “암호자산 거래와 제도화 방안”, *상사관례 연구*, 제31권, 제4호, 2018, 291-318.
- 김준상, “블록체인 기반 암호화폐의 조사”, *한국컴퓨터정보학회논문지*, 제24권, 제2호, 2019, 67-74.
- 서무경, 정이상, “4차 산업혁명시대의 블록체인 활용화에 관한 연구”, *예술인문사회융합멀티미디어논문지*, 제8권, 제9호, 2018, 287-296.
- 서 해, “[가상화폐 NEWS] 가상화폐 알고 거래 하자”, *스타트업레이더 코리아*, 2018, <http://www.startupradar.co.kr/news/articleView.html?idxno=422>.
- 송문호, “암호화폐의 법적 성격과 탈중앙화”, *동북아 법연구*, 제13권, 제2호, 2019, 273-293.
- 윤성욱, 조현중, “금융 분야에서의 블록체인 기술의 미래”, *전기학회논문지*, 제68권, 제12호, 2019, 1601-1606.
- Blockinpress, 애플 컴퓨터 공동창립자, “이더리움은 애플만큼의 영향력을 가질 것”, *블록인프레스*, <https://blockinpress.com/archives/5659>, 2018.
- Foxley W., “노믹스, 머신러닝으로 암호화폐 가격 예측 모델 개발”. *코인데스크코리아*, <http://www.coindesk.com/news/articleView.html?idxno=70776>, 2020.
- Abraham, J., D. Higdon, J. Nelson, and J. Ibarra, “Cryptocurrency price prediction using tweet volumes and sentiment analysis”, *SMU Data Science Review*, Vol.1, No.3, 2018.
- Bollen, J., H. Mao, and X. Zeng, “Twitter mood predicts the stock market”, *Journal of Computational Science*, Vol.2, No.1, 2011, 1-8.
- Connor, J.T., R.D. Martin, and L.E. Atlas, “Recurrent neural networks and robust time series prediction”, *IEEE Transactions on Neural Networks*, Vol.5, No.2, 1994, 240-254.
- Foody, G.M., “Status of land cover classification accuracy assessment”, *Remote Sensing of Environment*, Vol.80, No.1, 2002, 185-201.
- Georgoula, I., D. Pournarakis, C. Bilanakos, D.N. Sotiropoulos, and G.M. Giaglis, “Using Time-Series and Sentiment Analysis to Detect the Determinants of Bitcoin Prices”, *SSRN Electronic Journal*, 2015, <https://doi.org/10.2139/ssrn.2607167>.
- Greaves, A. and B. Au, “Using the bitcoin transaction graph to predict the price of bitcoin”, 2015.

- Hansen, L.K. and P. Salamon, "Neural network ensembles", *IEEE Transactions on Pattern Analysis and Machine Intelligence*, Vol.12, No.10, 1990, 993-1001.
- Heaton, J.B., N.G. Polson, and J.H. Witte, "Deep learning for finance : Deep portfolios", *Applied Stochastic Models in Business and Industry*, Vol.33, No.1, 2017, 3-12.
- Heo, J.-S., D.-H. Kwon, J.-B. Kim, Y.-H. Han, and C.-H. An, "Prediction of Cryptocurrency Price Trend Using Gradient Boosting", *KIPS Trans. Softw. and Data Eng.*, Vol.7, No.10, 2018, 387-396.
- Hevner, A.R., S.T. March, J. Park, and S. Ram, "Design science in information systems research", *MIS Quarterly*, Vol.28, No.1, 2004, 75-105.
- Hochreiter, S. and J. Schmidhuber, "Long short-term memory", *Neural Computation*, Vol.9, No.8, 1997, 1735-1780.
- Jain, A., S. Tripathi, H.D. Dwivedi, and P. Saxena, "Forecasting Price of Cryptocurrencies Using Tweets Sentiment Analysis", *2018 Eleventh International Conference on Contemporary Computing (IC3)*, Noida, India, 2018, 1-7.
- Jia, H., "Investigation into the effectiveness of long short term memory networks for stock price prediction". ArXiv Preprint, 2016, ArXiv: 1603.07893.
- Karalevicius, V., N. Degrande, and J. De Weerd, "Using sentiment analysis to predict inter-day Bitcoin price movements", *The Journal of Risk Finance*, Vol.19, No.1, 2018, 56-75.
- Khare, K., O. Darekar, P. Gupta, and V. Z. Attar, "Short term stock price prediction using deep learning", *2017 2<sup>nd</sup> IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology*, Bangalore, India, 2017, 482-486.
- Liu, Y. and A. Tsyvinski, "Risks and returns of cryptocurrency", *NBER Working Papers from National Bureau of Economic Research, Inc.*, 2018.
- Livieris, I.E., E. Pintelas, S. Stavroyiannis, and P. Pintelas, "Ensemble Deep Learning Models for Forecasting Cryptocurrency Time-Series", *Algorithms*, Vol.13, No.5, 2020, 121.
- Madan, I., S. Saluja, and A. Zhao, "Automated Bitcoin Trading via Machine Learning", *Algorithms*, Vol.20, 2015, 1-5.
- Matta, M., I. Lunesu, and M. Marchesi, "Bitcoin Spread Prediction Using Social and Web Search Media", *UMAP Workshops*, 2015, 1-10.
- McNally, S., J. Roche, and S. Caton, "Predicting the Price of Bitcoin Using Machine Learning", *2018 26<sup>th</sup> Euromicro International Conference on Parallel, Distributed and Network-Based Processing (PDP)*, Cambridge, UK, 2018, 339-343.
- Pant, D.R., P. Neupane, A. Poudel, A.K. Pokhrel, and B.K. Lama, "Recurrent Neural Network Based Bitcoin Price Prediction by Twitter Sentiment Analysis", *2018 IEEE 3<sup>rd</sup> International Conference on Computing, Communication and Security (ICCCS)*, Kathmandu, Nepal, 2018, 128-132.
- Peffer, K., T. Tuunanen, M.A. Rothenberger, and S. Chatterjee, "A Design Science Research Methodology for Information Systems Research", *Journal of Management Information Systems*, Vol.24, No.3, 2007, 45-77.
- Pintelas, E., I.E. Livieris, S. Stavroyiannis, T. Kotsilieris, and P. Pintelas, "Investigating the Problem of Cryptocurrency Price Prediction : A Deep Learning Approach", *IFIP*

- International Conference on Artificial Intelligence Applications and Innovations*, Neos Marmaras, Greece, 2020, 99–110.
- Raju, S.M. and A.M. Tarif, “Real-Time Prediction of BITCOIN Price using Machine Learning Techniques and Public Sentiment Analysis”, ArXiv Preprint, 2020, ArXiv:2006.14473.
- Sak, H., A. Senior, and F. Beaufays, “Long Short-Term Memory Based Recurrent Neural Network Architectures for Large Vocabulary Speech Recognition”, ArXiv:1402.1128 [Cs, Stat] 2014, <http://arxiv.org/abs/1402.1128>.
- Sin, E. and L. Wang, “Bitcoin price prediction using ensembles of neural networks”, *2017 13<sup>th</sup> International Conference on Natural Computation Fuzzy Systems and Knowledge Discovery(ICNC-FSKD)*, Guilin, China, 2017, 666–671.
- Spilak, B., “Deep neural networks for cryptocurrencies price prediction”, *Humboldt-Universität zu Berlin*, 2018.
- Stenqvist, E. and J. Lönnö, “Predicting Bitcoin price fluctuation with Twitter sentiment analysis”, 2017.
- Struga, K. and O. Qirici, “Bitcoin Price Prediction with Neural Networks”, *RTA-CSIT*, 2018, 41–49.
- West, D., S. Dellana, and J. Qian, “Neural network ensemble strategies for financial decision applications”, *Computers and Operations Research*, Vol.32, No.10, 2005, 2543–2559.
- Wimmer, H. and V.Y. Yoon, “Counterfeit product detection : Bridging the gap between design science and behavioral science in information systems research”, *Decision Support Systems*, Vol.104, 2017, 1–12.
- Wood, G., “Ethereum : A secure decentralised generalised transaction ledger”, *Ethereum Project Yellow Paper*, Vol.151, 2014, 1–32.
- Xie, Q., G. Cheng, X. Xu, and Z. Zhao, “Research based on stock predicting model of neural networks ensemble learning”, *International Conference on Electronic Information Technology and Computer Engineering(EITCE 2018)*, Shanghai, China, 2018.
- Yang, L., X.-Y. Liu, X. Li, and Y. Li, “Price Prediction of Cryptocurrency : An Empirical Study”, *International Conference on Smart Blockchain*, Birmingham, UK, 2019, 130–139.

## ◆ About the Authors ◆



**최 수 빈 (soobin924@naver.com)**

연세대학교 정보대학원 비즈니스 빅데이터 분석 석사 학위를 취득하였다. 주요 연구분야는 Big Data Analytics, Business Intelligence, Deep Learning, Machine Learning, Text/Data Mining 등이다.



**신 동 훈 (dh\_shin@yonsei.ac.kr)**

연세대학교 정보대학원 비즈니스 빅데이터 분석 트랙 석사과정이다. 현재 디지털서비스연구실에서 데이터분석 관련 연구들을 진행 중이다. 주요 연구 분야는 빅데이터분석, 머신러닝, 딥러닝 등이다.



**윤 상 혁 (scottyoon@kakao.com)**

연세대학교 정보대학원 정보시스템 박사이다. 현재 스마트미디어랩(SMR)에서 데이터 분석 업무를 맡고 있다. 주요 연구분야는 머신러닝, 디지털 마케팅, 비즈니스애널리틱스 등이다. 관련 연구들은 Electronic Commerce Research, IVEY Publishing 등에 논문이 게재되었다.



**김 희 웅 (kimhw@yonsei.ac.kr)**

National University of Singapore 정보시스템학과에서 근무한 후, 현재 연세대학교 정보대학원 교수로 재직 중이다. 주요 연구분야는 디지털 비즈니스, 정보시스템 관리 및 활용 등이다. 관련 연구들은 MIS Quarterly, Information Systems Research, Journal of Management Information Systems 등에 50여 편의 논문이 게재되었다. JAIS, IEEE TEM의 편집위원으로 활동했고, KrAIS 회장을 역임했다.