Print ISSN: 2233-4165 / Online ISSN 2233-5382
doi:http://dx.doi.org/10.13106/ijidb.2019.vol10.no11.93

A Study on Predicting Cryptocurrency Distribution Prices Using Machine Learning Techniques
머신러닝 기법을 활용한 암호화폐 유통 가격 예측 연구

Han-Min KIM (김한민)[1], Hoik KIM (김호익)[2]

Received: September 30, 2019 Revised: October 21, 2019 Accepted: November 05, 2019

Abstract

Purpose: Blockchain technology suggests ways to solve the problems in the existing industry. Among them, Cryptocurrency system, which is an element of Blockchain technology, is a very important factor for operating Blockchain. While Blockchain cryptocurrency has attracted attention, studies on cryptocurrency prices have been mainly conducted, however previous studies mainly conducted on Bitcoin prices. On the other hand, in the context of the creation and trading of various cryptocurrencies based on the Blockchain system, little research has been done on cryptocurrencies other than Bitcoin. Hence, this study attempts to find variables related to the prices of Dash, Litecoin, and Monero cryptocurrencies using machine learning techniques. We also attempt to find differences in the variables related to the prices for each cryptocurrencies and to examine machine learning techniques that can provide better performance. **Research design, data, and methodology**: This study performed Dash, Litecoin, and Monero price prediction analysis of cryptocurrency using Blockchain information and machine learning techniques. We employed number of transactions in Blockchain, amount of generated cryptocurrency, transaction fees, number of activity accounts in Blockchain, Block creation difficulty, block size, umber of created blocks as independent variables. This study tried to ensure the reliability of the analysis results through 10-fold cross validation. Blockchain information was hierarchically added for price prediction, and the analysis result was measured as RMSE and MAPE. **Results**: The analysis shows that the prices of Dash, Litecoin and Monero cryptocurrency are related to Blockchain information. Also, we found that different Blockchain information improves the analysis results for each cryptocurrency. In addition, this study found that the neural network machine learning technique provides better analysis results than support-vector machine in predicting cryptocurrency prices. **Conclusion**: This study concludes that the information of Blockchain should be considered for the prediction of the price of Dash, Litecoin, and Monero cryptocurrency. It also suggests that Blockchain information related to the price of cryptocurrency differs depending on the type of cryptocurrency. We suggest that future research on various types of cryptocurrencies is needed. The findings of this study can provide a theoretical basis for future cryptocurrency research in distribution management.

Keywords : Blockchain, Cryptocurrency, Blockchain information, Machine Learning, Price Prediction, Distribution management

JEL Classification Code : A3, F37, F17

1. 서론

블록체인에 대한 관심이 높아지면서 자연스럽게 블록체인 시스템의 일부인 암호화폐에 대한 관심도 증가하고 있다(Jang & Lee, 2018). 블록체인 시스템은 안정적이고 효율

1 First Author, Doctoral Student, Business School, Sungkyunkwan University, Korea. Email: hanmin8809@gmail.com
2 Second Author, Master & Doctoral Student, Business School, Sungkyunkwan University, Korea. Email: hoik.r.kim@gmail.com

ⓒ Copyright: Korean Distribution Science Association (KODISA)
This is an Open Access article distributed under the terms of the Creative Commons Attribution Non-Commercial License (http://creativecommons.org/licenses/by-nc/4.0/) which permits unrestricted noncommercial use, distribution, and reproduction in any medium, provided the original work is properly cited.

적으로 운영되기 위해서 블록체인 네트워크에 참여하는 참여자가 다수 존재하여야 한다(Antonopoulos, 2014). 블록체인의 암호화폐는 사용자들의 자발적 참여를 유도함으로써 블록체인 시스템의 신뢰성 향상에 기여한다. 또한 블록체인 암호화폐는 금융거래, 실제 상품 거래, 상품의 유통, 다른 암호화폐들 간 유통 거래 등에도 활용되고 있다. 블록체인 기술은 유통 참여자들 간에 신뢰할 수 있는 공유된 원장을 활용할 수 있도록 하기 때문에 유통 관리의 측면에서 큰 이점을 제공한다(Wu, 2017). 상품의 유통 정보가 블록체인으로 관리 될 경우 유통에 참여하는 참여자들은 신뢰할 수 있는 전자 문서를 공유하기 때문에 보다 적은 비용으로 신속하고 효율적인 유통 관리가 가능하다. 또한, 블록체인의 투명성과 조작이 거의 불가능한 특성은 블록체인으로 관리되는 상품을 이용하는 소비자에게 큰 신뢰를 제공 할 수 있다. 실제로 월마트와 징동은 유통 관리에 블록체인 기술을 적용함으로써 상품의 유통 판매에 신뢰성을 확보하고 있다(Kshetri, 2019). 블록체인의 암호화폐는 유통 관리에 참여하는 사용자들에게 유통 수수료의 역할을 제공하거나 암호화폐를 기반으로 실제 상품을 거래할 수 있는 잠재력을 지니고 있다. 실제 비트코인의 경우 비트코인을 활용하여 기부를 하거나 실제 상품 및 서비스를 구매하기도 하며 거래에 필요한 수수료를 비트코인으로 지불하기도 한다(Jang & Lee, 2018; Mallqui & Fernandes, 2019). 또한, 실제 마켓에서는 암호화폐들 상호 간에 유통 거래가 진행되고 있는 상황이다.

블록체인과 암호화폐가 다양한 분야에서 영향을 미치면서 학술분야에서는 블록체인 시스템의 암호화폐에 대한 연구를 주로 수행하였다. 블록체인의 암호화폐 관련 연구들은 경제요인 지표나 블록체인 정보가 블록체인 암호화폐에 관련되어 있다는 사실을 발견하였다(Jang & Lee, 2018; Mallqui & Fernandes, 2019). 그 중 블록체인 정보는 블록체인 암호화폐 가격과 긴말하게 관련되어 있는 것으로 나타났다. 암호화폐 관련 연구들은 대부분 비트코인에 대해 연구를 수행하였다. 블록체인 암호화폐의 종류는 비트코인 이외에 다양한 암호화폐들이 존재한다. 기존의 연구들이 비트코인의 가격에만 집중해왔기 때문에 다른 암호화폐들에 대한 연구는 거의 수행되지 않았다. 블록체인의 시스템에서 암호화폐의 양은 블록체인 마다 차이가 존재하지만 일정량의 암호화폐를 유지하고 있다. 비트코인의 경우 발행량에 제한이 존재하기 때문에 일정양의 비트코인이 발행되고 나면 추가적인 비트코인은 발행되지 않는다. 반면에 이외에 수많은 암호화폐들은 다양한 분야에서 혜택을 제공할 수 있는 가능성을 가지고 있다. 하지만 아직까지 다른 암호화폐에 대한 연구는 거의 진행되지 않고 있다. 다시 말해서, 여전히 블록체인 암호화폐 연구는 해소되지 않은 학문적 갈증이 남아있는 상태이다. 특히, 유통 분야에서는 블록체인의 암호화폐에서 얻을 수 있는 혜택과 학문적 실무적 의미가 크기 때문에(Wu, 2017; Kshetri, 2019) 블록체인의 암호화폐에 대해 관심을 가질 필요가 있다. 따라서 본 연구는 암호화폐에 대한 가격을 예측하고 관련될 수 있는 변수들을 발견하고자 한다. 그 중 선행연구에서 암호화폐 가격과 가장 크게 관련되는 블록체인 정보들을 적극적으로 활용하고자 한다. 본 연구는 다음과 같은 연구 질문에 응답하고자 한다. 첫 번째, 블록체인 정보는 암호화폐 가격 예측과 관련될 수 있는가? 두 번째, 블록체인 정보와 암호화폐가 관련된다면 각각의 암호화폐마다 어느 블록체인 정보가 암호화폐 가격과 밀접하게 관련되는가? 위의 연구 질문을 해소하고자 본 연구는 머신러닝 기법을 활용하여 총 3 개의 암호화폐 대시, 라이트 코인, 모네로의 가격을 대상으로 분석을 실시하고자 한다. 본 연구의 연구결과는 대시, 라이트 코인, 모네로 암호화폐들의 가격 예측에 관련되는 블록체인 변수들을 발견하고 부족했던 이론적 공백을 채워 나아가는데 기여할 것이다. 실무적으로는 암호화폐를 활용하고자 하는 블록체인 관련 기업에게 가격 예측에 대한 관련 정보를 제공할 것이다.

2. 이론적 배경

2.1. 블록체인(Blockchain)

블록체인은 신뢰할 수 있는 원장을 네트워크 참여자에게 공유할 수 있는 기술로 정의될 수 있다(Antonopoulos, 2014; Dang, 2019). 블록체인을 구성하는 요인은 블록과 체인이 존재한다. 블록체인에서 블록은 거래 정보, 블록이 생성된 시간, 블록 고유의 해시 값, 블록의 번호 등의 정보를 포함한다. 블록을 생성하기 위해서는 블록을 생성할 수 있는 넌스(Nonce) 값을 대입 계산으로 발견해야 한다. 블록 생성에 부합하는 넌스 값을 반복 대입 계산으로 찾아내면 블록을 완성할 수 있는 자격을 부여 받는다. 새로운 블록이 생성된 것이다. 이 생성된 새로운 블록은 블록에 있는 정보들을 활용해 블록 고유의 해시 값을 생성한다. 블록의 해시 값은 블록의 고유한 값으로 다른 블록들과 중복되지

않는다. 채굴자는 새로운 블록을 생성하고 블록체인 네트워크에 생성된 블록을 전파한다. 블록체인 네트워크 참여자들은 새로운 블록을 검증하고 유효한 블록일 경우 네트워크의 다른 참여자 노드로 전파한다. 이렇게 해서 새로운 블록이 블록체인 네트워크에 정식 블록으로 인정받으면 채굴자는 새로운 블록에 대한 보상을 받는다. 이 과정을 작업증명 (PoW, Proof-of-Work)라고 일컫는다(Jang & Lee, 2018).

블록체인에서 체인의 구조는 다음과 같이 형성된다. 이전 블록의 해시 값은 새로운 블록을 생성하기 위해서 반드시 필요하다. 이전 블록의 해시 값을 포함하여 생성된 새로운 블록의 해시 값은 다음 블록의 해시 값 형성에 관여한다. 블록에 부여된 고유의 해시 값이 블록체인의 사슬 구조를 이루는 것이다. 해시 값은 투입 정보에 미세한 변화가 생기면 예측할 수 없는 결과 값이 도출된다. 또한, 투입 정보를 알고 있으면 결과 값은 수월하게 계산가능 하지만 반대로 결과 값만 가지고 투입 정보를 계산하는 것은 불가능하다. 이러한 비대칭 연산의 관계는 해시 함수의 핵심이라고 할 수 있다(Antonopoulos, 2014; Antonopoulos & Wood, 2018). 따라서 블록체인의 정보를 조작하고자 하는 공격자가 입력 정보 일부를 변경하게 되면 블록체인에 등록된 모든 블록이 영향을 받게 되고 이러한 블록들의 모든 정보를 수정하는 것은 현재로써 거의 불가능에 가깝다고 할 수 있다. 또한, 블록체인 내에서 새로운 블록들이 지속적으로 생성되고 있기 때문에 블록체인의 정보를 조작하는 것은 매우 어렵다고 할 수 있다. 블록체인의 이러한 특징은 참여자들 간에 정보를 공유하는 문제에 대한 해답을 제시한다.

2.2. 블록체인 관련 연구

블록체인 관련 연구들은 대부분 암호화폐 가격 예측 연구를 수행하였다. 일부 연구에서 블록체인을 산업에 적용하는 방안에 대해 개념적으로 제시한 연구(Kuo, Kim & Ohno-Machado, 2017)가 존재하지만 대부분의 연구 흐름은 블록체인의 암호화폐에 집중되어 있다. 암호화폐에 대한 연구들은 주로 비트코인의 가격과 변동성을 연구하였다. 선행 연구는 비트코인 가격에 비트코인 커뮤니티의 새로운 게시글, 커뮤니티 가입자, 비트코인의 거래량이 관련된다는 사실을 발견하였다(Ciaian, Rajcaniova & Kancs, 2016).

일부 연구에서는 암호화폐가 블록체인 내에서 발행되고 소모되는 사실을 감안하여 블록체인의 정보를 암호화폐 연구에 도입하였다. 선행 연구는 비트코인의 가격과 변동성이 거시경제요인, 블록체인 정보와 관련된다는 사실을 발견하였으며, 인공신경망, 서포트 벡터 머신, 선형 회귀 분석을 분석 기법으로 활용하여 인공신경망이 비트코인 가격과 변동성을 가장 우수하게 예측하는 것을 발견하였다(Jang & Lee, 2018). 일부 연구에서는 인공신경망과 서포트 벡터 머신을 적극 활용하였으며 서포트 벡터 머신이 인공신경망보다 비트코인 가격을 정확히 예측하는 것으로 보고하였다(Mallqui & Fernandes, 2019). 선행연구들은 암호화폐와 연관될 수 있는 요인들 중 블록체인 정보가 암호화폐 가격과 긴밀하게 관련되어있으며 매우 중요하다고 보고하고 있다.

선행 연구들을 요약하자면 비트코인에 대한 연구에 집중 되어있어 다른 암호화폐에 대한 연구는 거의 이루어지지 않았다는 사실을 파악할 수 있었다. 또한, 암호화폐와 관련되는 변수들을 발견하고자 하는 다양한 관점의 연구가 수행되었으며, 그 중에서도 블록체인 정보가 암호화폐와 크게 연관되어 있었다는 사실을 발견할 수 있었다. 현재 암호화폐 시장에서는 비트코인 이외에도 많은 암호화폐가 유통되고 거래되고 있다. 다양한 분야에서 블록체인을 활용하고자 하는 시도가 이루어지면서 다른 다양한 암호화폐에 대한 추가 연구가 필요한 상황이다. 본 연구는 기존에 연구되어 왔던 비트코인과 이더리움을 제외한 암호화폐를 대상으로 관련되는 블록체인 변수들을 발견하는 연구를 수행하고자 한다. 이를 위해서 선행연구에서 뛰어난 예측 분석방법으로 검증되었던 머신러닝 기법을 도입하고자 한다. 선행 연구에서는 머신러닝기법을 활용하여 거시경제 지표나 블록체인의 암호화폐 가격을 예측 분석하였으며, 머신러닝 기법이 기존의 분석방법보다 우수한 분석 결과를 제공한다는 사실을 발견하였다(Wang, 2011; Jang & Lee, 2018). 본 연구는 선행연구에서 크게 대표적으로 사용되었던 인공신경망과 서포트 벡터 머신 기법을 활용하고자 한다.

2.3. 인공신경망(Artificial Neural Network: ANN)

여러 머신러닝 기법 중 인간의 뇌신경 구조를 기반으로 만든 머신러닝 기법인 인공 신경망은 순서대로 입력 층, 은닉 층, 출력 층이 존재하는 구조를 가지고 있다(Farajnejad & Lau, 2017). 인공신경망은 여러 은닉 층을 가질 수 있기 때문에 다층 퍼센트론 형태로 구성되어 있다(Murphy, 2012). 입력층에 투입된 값은 은닉 층을 거쳐 계

산된 값으로 출력 층에 산출된다. 인공신경망은 출력층의 값이 목표 값과 크게 다를 경우 에러가 큰 값을 다시 입력층으로 전파시킨다. 그 후 가중치를 재설정하여 다시 계산을 수행하게 된다. 이러한 역전파 과정을 통해 인공신경망은 목표 값과의 오차를 수정해 나간다. 인공신경망은 단순히 특정 문제를 분류하는 것을 넘어서 경제 지표, 기업의 파산 여부, 자연어 처리, 암호화폐 가격 예측 등 많은 분야에서 활용된다(Murphy, 2012). 또한, 기업의 파산 여부와 신용점수를 예측하는 문제에서도 인공신경망은 의사결정에 도움이 될 수 있는 신뢰성 높은 결과를 제공하였다(Tsai & Wu, 2008). 비트코인 가격예측 연구에서 인공신경망 분석 기법은 블록체인 정보 변수를 기반으로 서포트 벡터 머신이나 선형 회귀 모델 분석 보다 높은 예측 결과를 제공하는 것으로 나타났다(Jang & Lee, 2018).

2.4. 서포트 벡터 머신(Support Vector Machine: SVM)

분류 문제뿐만 아니라 예측 문제에서도 적용 가능한 서포트 벡터 머신은 초평면(Hyperplane)의 원리를 활용하여 분류 및 예측 문제를 해결한다(Park, Chaffar, Kim & Ko, 2017). 초평면은 데이터들 간에 거리가 극대화되는 결정면(Margin)에 배치하게 된다(Cortes & Vapnik, 1995). 이 극대화된 결정면을 경계로 서포트 벡터 머신은 분류 문제를 해결한다. 하지만 비선형 문제에서는 서포트 벡터 머신의 초평면만으로 문제를 해결하기에 한계가 존재한다. 서포트 벡터머신은 비선형문제를 해결하기 위해 커널(Kernels)이라는 원리를 사용하는데 커널이란 데이터의 차원을 높여 초평면을 적용하는 방법이다. 높아진 차원에서는 초평면을 적용하면 비선형 문제도 분석 할 수 있게 된다. 서포트 벡터 머신은 선행연구에서 환율, 주식, 암호화폐 가격 예측에 적용되어 우수한 분석 결과를 제시하는 것으로 나타났다. 선행 연구는 서포트 벡터 머신이 미래 환율 옵션이나 현물 변동성을 예측하는데 뛰어난 예측 분석 결과를 제공하는 것을 발견하였다(Wang, 2011). 일부 연구에서는 주가 지수 변동성 예측에 서포트 벡터 머신이 예측의 정확도를 향상시킨다는 사실을 발견하였다(Huang, Nakamori & Wang, 2005). 또한, 블록체인 관련 연구에서는 서포트 벡터 머신을 활용하여 비트코인의 가격 및 변동성을 보다 정확하게 예측 하였다(Mallqui & Fernandes, 2019).

본 연구는 선행연구에서 우수한 분석 결과를 제공하였던 인공신경망과 서포트 벡터 머신을 주요 머신러닝 분석 기법으로 채택하고자 한다.

3. 연구 설계

3.1. 데이터 수집 및 요약

본 연구의 종속 변수는 연구 목적인 암호화폐 가격 예측을 위해 암호화폐 가격으로 설정하였다. 대시, 라이트 코인, 모네 암호화폐의 가격이며 데이터는 https://coinmetrics.io사이트에서 제공하는 블록체인 데이터를 활용하였다. 예측 분석을 위해 선행연구를 참고하여 종속변수인 암호화폐 가격에 로그(Log) 함수를 적용하였다(Jang & Lee, 2018). 독립변수는 암호화폐의 블록체인 정보이며, 모든 데이터의 단위는 하루이다. 데이터의 기간은 대시 암호화폐의 경우 2014년 2월 14일부터 2018년 12월 25일까지이며, 라이트 코인 암호화폐는 2013년 4월 28일부터 2018년 12월 25일까지이다. 모네로의 경우 2014년 5월 21일부터 2018년 12월 25일까지의 데이터를 활용하였다.

암호화폐의 가격은 블록체인 정보와 이론적으로 밀접하게 관련되어 있다(Jang & Lee, 2018). 블록체인 내 거래 수, 블록체인 내 활동 계정 수, 블록 크기, 생성된 블록 수 정보는 해당 블록체인에 대한 이용자들의 활동을 반영하며 정보의 변화에 따라 암호화폐의 가격은 관련되어질 수 있다. 암호화폐는 블록체인 시스템에서 발행되기 때문에 생성된 암호화폐 양과 블록 생성 난이도의 정보 또한 암호화폐 공급의 측면에서 크게 관련될 수 있다. 거래 수수료의 경우 블록체인 시스템을 이용하기 위해 지불해야 하는 암호화폐 비용을 의미하기 때문에 암호화폐의 소비 측면에서 가격과 연관될 가능성이 높다고 할 수 있다. 따라서 본 연구에서 독립변수로 활용된 블록체인 정보는 총 7개이며 블록체인 내 거래 수, 생성된 암호화폐 양, 거래 수수료, 블록체인 내 활동 계정 수, 블록 생성 난이도, 블록 크기, 생성된 블록 수로 구성하였다.

3.2. 분석 절차

본 연구는 선행 연구에서 수행되었던 비트코인과 이더리움을 제외한 대시, 라이트 코인, 모네로 암호화폐를 대상

으로 가격 예측 연구를 수행하고자 한다. 본 연구는 총 3개의 암호화폐 가격과 블록체인 정보와의 관계를 발견하는 탐색적 연구를 수행하게 될 것이다. 분석을 위해 래피드 마이너 분석 프로그램 9.3.001 버전을 활용할 계획이며, 머신러닝 기법으로 인공신경망과 서포트 벡터 머신 기법을 적용할 예정이다. 본 연구의 데이터들은 시계열 자료이기 때문에 예측 분석을 위해 종속변수는 현재시점(t)로 설정하였으며, 독립변수는 종속변수의 하루 전 시점으로(t-1) 데이터를 수정하였다. 분석 결과를 평가하기 위해 평균 제곱근 오차(Root Mean Square Error: RMSE)와 절대 평균율 백분 편차(Mean Absolute Percentage Error: MAPE)를 활용하고자 한다(Jang & Lee, 2018). 분석 결과의 신뢰성을 확보하기 위해 10겹 교차 검증을 수행할 것이다. 또한, 암호화폐들의 가격을 예측하기 위해서 각각의 암호화폐마다 블록체인의 정보를 위계적으로 추가하여 분석을 수행하고자 한다. 독립변수의 투입 순서는 블록체인 내 거래 수, 생성된 암호화폐 양, 거래 수수료, 블록체인 내 활동 계정 수, 블록 생성 난이도, 블록 크기, 생성된 블록 수 순서로 적용될 예정이다. 첫 번째 분석에서는 대시 암호화폐를 대상으로 분석을 진행하고 라이트코인, 모네로 암호화폐 순으로 분석이 수행될 예정이다. 아래 Figure 1에 연구모델을 제시하였다.

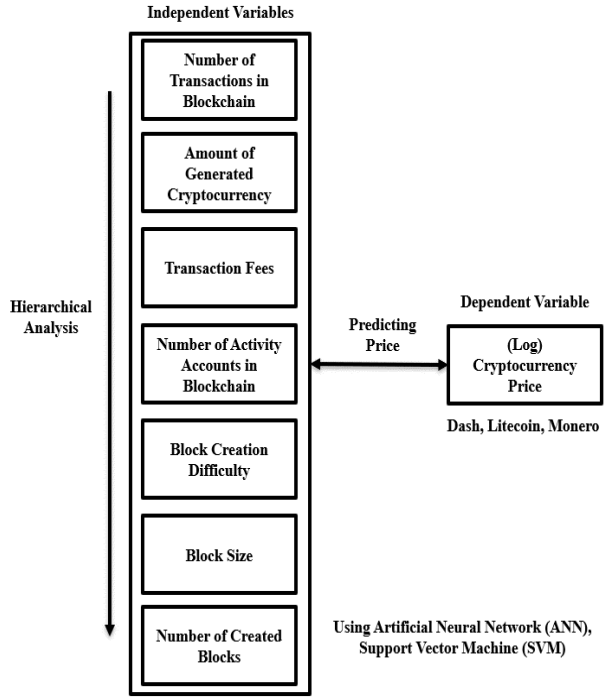

Figure 1: Research Model

4. 분석 결과

본 연구는 대시, 라이트 코인, 모네로 암호화폐 가격예측에 대한 분석 결과들을 아래 Table 1, 2, 3에 구체적으로 기술하였다. 먼저 아래 Table 들을 살펴보면, 투입되는 변수들, 분석한 머신러닝 기법, 결과 평가 기준, 예측 분석 결과 값을 볼 수 있다. 변수들을 위계적으로 추가되었으며 Table에 괄호 표시는 투입된 변수들의 총 개수를 의미한다.

대시 암호화폐 가격을 예측 분석한 Table 1을 살펴보면 인공신경망(ANN)은 서포트 벡터 머신(SVM) 보다 좋은 분석 결과를 제공하는 것을 볼 수 있다. 따라서 본 연구는 인공신경망 머신러닝 기법을 기반으로 결과를 설명하고자 한다. 먼저, 블록체인 내 거래 수 변수만을 투입하였을 때 RMSE는 0.900, MAPE는 1.851로 나타났으며, 생성된 암호화폐 양 변수를 추가하였을 때 RMSE는 0.486, MAPE는 0.624로 결과가 개선되었다. 거래 수수료 변수가 추가 도입 되자 분석 결과는 RMSE가 0.444, MAPE가 0.589로 향상 되었으며, 블록체인 내 활동 계정 수 변수를 도입하자 RMSE가 0.321, MAPE는 0.379로 분석 결과가 개선되는 것을 발견할 수 있었다. 하지만 블록 생성 난이도(RMSE = 0.333, MAPE = 0.423), 블록 크기(RMSE = 0.350, MAPE = 0.423), 생성된 블록 수(RMSE = 0.336, MAPE = 0.384) 변수들은 분석결과 향상에 기여하지 않았다.

결과적으로, 투입된 변수들에 따른 분석 결과를 보면 인공신경망 분석기법을 기준으로 블록체인 내 거래 수, 생성된 암호화폐 양, 거래 수수료, 블록체인 내 활동 계정 수 변수들을 투입했을 때 가장 개선된 분석결과를 얻을 수 있다는 것을 발견할 수 있었다(RMSE = 0.321, MAPE = 0.379). 이러한 결과는 블록체인 내의 모든 정보들이 암호화폐 가격과 관련되어 있지 않다는 사실을 반영한다. 또한, 신속한 예측 분석과 정확한 가격 예측을 위해서는 관련 변수가 신중히 선택되어야 한다는 것을 의미한다. 그 중 대시 암호화폐는 총 4개의 블록체인 내 거래 수, 생성된 암호화폐 양, 거래 수수료, 블록체인 내 활동 계정 수 변수가 가격 예측에 필요하다고 할 수 있다.

Table 1: The Analysis Results of Dash Cryptocurrency Price

Variable (Total input)	ANN		SVM	
	RMSE	MAPE	RMSE	MAPE
Number of transactions in Blockchain (1)	0.900	1.851	11.709	1.505
Amount of generated cryptocurrency (2)	0.486	0.624	10.924	0.991
Transaction fees (3)	0.444	0.589	10.850	1.209
Number of activity accounts in Blockchain (4)	**0.321**	**0.379**	1.320	0.465
Block creation difficulty (5)	0.333	0.423	1.237	0.475
Block size (6)	0.350	0.423	1.297	0.462
Number of created blocks (7)	0.336	0.384	1.302	0.463

아래 Table 2는 라이트 코인 암호화폐의 가격을 예측 분석한 결과를 기술하였다. Table 2를 살펴보면 인공신경망(ANN)은 서포트 벡터 머신(SVM) 보다 뛰어난 예측 분석결과를 보이고 있다. 인공신경망 분석 결과를 중심으로, 블록체인 내 거래 수 변수만을 고려하였을 때 RMSE는 0.214, MAPE는 0.316으로 나타났으며, 생성된 암호화폐 양 변수를 추가 도입하였을 때 RMSE는 0.214, MAPE는 0.294로 MAPE 값이 소폭 개선되었다. 반면에 거래 수수료 변수를 추가하였을 때 RMSE는 0.217, MAPE는 0.323으로 분석 예측력이 감소하였다. 블록체인 내 활동 계정 수 변수는 추가 되었을 때 RMSE는 0.205로 분석결과를 향상시키는 것으로 나타났으나 MAPE 기준으로 측정하였을 때는 0.310으로 크게 개선되지 않았다. 블록 생성 난이도 변수가 적용될 경우 RMSE는 0.209, MAPE 0.304로 분석결과가 향상되었으며, 블록 크기 또한 RMSE가 0.187, MAPE는 0.285로 예측 분석 결과를 향상 시켰다. 반면에 생성된 블록 수 변수는 분석 결과를 개선하지 못했다(RMSE = 0.195, MAPE = 0.299).

요약하자면, 블록체인 내 거래 수, 생성된 암호화폐 양, 블록체인 내 활동 계정 수, 블록 생성 난이도, 블록 크기가 적용되었을 때 라이트 코인 암호화폐 가격을 가장 잘 예측하는 것으로 나타났다(RMSE = 0.187, MAPE = 0.285). 이러한 결과는 암호화폐 별로 관련되는 블록체인 정보가 다르게 나타날 수 있다는 것으로 볼 수 있다. 대시 암호화폐와 다르게 라이트코인 암호화폐는 블록체인 내 거래 수, 생성된 암호화폐 양, 블록체인 내 활동 계정 수, 블록 생성 난이도, 블록 크기 변수가 가격 예측에 관련된다고 할 수 있다. 따라서 각각의 암호화폐 마다 관련되는 블록체인 정보를 식별하는 것이 필요하다고 할 수 있다.

Table 2: The Analysis Results of Litecoin Cryptocurrency Price

Variable (Total input)	ANN		SVM	
	RMSE	MAPE	RMSE	MAPE
Number of transactions in Blockchain (1)	0.214	0.316	0.657	0.386
Amount of generated cryptocurrency (2)	0.214	0.294	0.650	0.375
Transaction fees (3)	0.217	0.323	0.642	0.372
Number of activity accounts in Blockchain (4)	0.205	0.310	0.496	0.372
Block creation difficulty (5)	0.209	0.304	0.375	0.354
Block size (6)	**0.187**	**0.285**	0.373	0.350
Number of created blocks (7)	0.195	0.299	0.366	0.341

마지막으로, 모네로 암호화폐 가격을 예측 분석한 결과를 아래Table 3에 정리하였다. 분석 결과를 살펴보면 인공신경망(ANN)은 서포트 벡터 머신(SVM)보다 우월한 분석 결과를 제공하고 있었다. 인공신경망 분석 기법을 기준으로 블록체인 내 거래 수 변수만을 도입하였을 때 RMSE는 0.350, MAPE는 1.060으로 나타났으며, 생성된 암호화폐 양 변수를 추가하였을 때 RMSE는 0.195, MAPE는 0.833으로 분석 결과가 향상되었다. 거래 수수료 변수를 적용하였을 때 또한 RMSE가 0.185, MAPE는 0.746으로 분석 결과가 향상되었으며, 블록체인 내 활동 계정 수 변수가 추가 되었을 경우에도 RMSE가 0.173, MAPE는 0.703으로 결과가 개선되었다. 블록 생성 난이도 변수는 적용되었을 때 RMSE가 0.143로 향상되었지만 MAPE 기준으로는 0.715로 개선되지 않았다. 블록 크기 변수는 추가 되었을 때 RMSE가 0.136, MAPE가 0.702로 분석 결과를 향상에 기여하였으며, 생성된 블록 수 변수 또한 적용되었을 때 RMSE가

0.133, MAPE는 0.598로 예측 분석 결과를 개선시키는 것으로 나타났다.

결과적으로, 모네로 암호화폐의 경우 블록체인 내 거래수, 생성된 암호화폐 양, 거래 수수료, 블록체인 내 활동 계정 수, 블록 생성 난이도, 블록 크기, 생성된 블록 수 변수들이 모두 적용되었을 때 가장 좋은 분석결과를 제공하고 있었다(RMSE = 0.133, MAPE = 0.598). 또한, 변수들이 위계적으로 추가됨에 따라 분석 결과가 향상되는 것을 발견할 수 있었다. 따라서 모네로 암호화폐 가격분석에는 본 연구에서 활용된 모든 블록체인 정보 변수들을 고려할 필요가 있다.

Table 3: The Analysis Results of Monero Cryptocurrency Price

Variable (Total input)	ANN		SVM	
	RMSE	MAPE	RMSE	MAPE
Number of transactions in Blockchain (1)	0.350	1.060	0.471	1.305
Amount of generated cryptocurrency (2)	0.195	0.833	0.350	1.714
Transaction fees (3)	0.185	0.746	0.353	1.664
Number of activity accounts in Blockchain (4)	0.173	0.703	0.359	1.755
Block creation difficulty (5)	0.143	0.715	0.325	1.779
Block size (6)	0.136	0.702	0.323	1.851
Number of created blocks (7)	**0.133**	**0.598**	0.252	1.996

5. 시사점

본 연구의 분석 결과는 대시, 라이트 코인, 모네로 암호화폐들이 블록체인 정보와 관련되어 있다는 사실을 제공함과 동시에 각각의 암호화폐 가격에 관련되는 블록체인 정보 변수들이 다르게 나타난다는 분석 결과를 제시한다. 또한, 인공신경망과 서포트 벡터 머신 머신러닝 기법 중 대시, 라이트 코인, 모네로 암호화폐 유통 가격을 가장 우수하게 예측하는 머신러닝 기법은 모두 인공신경망 분석 기법이라는 사실을 제공한다. 본 연구는 분석결과를 기반으로 선행연구와의 비교를 통해 시사점을 논의하고 한계점과 향후 연구방안에 대해 제언하고자 한다.

5.1. 이론적 시사점

본 연구의 발견은 다음과 같은 이론적 시사점을 제공한다. 첫 번째, 본 연구는 대시, 라이트 코인, 모네로의 암호화폐들이 각각의 블록체인 정보와 관련이 되어있다는 사실을 발견하였다. 기존 비트코인 관련 연구에서는 암호화폐 가격과 관련된 변수들 중 블록체인의 정보가 가장 밀접하게 관련되어 있었다는 사실을 제공하였다. 하지만 비트코인 이외에도 다른 암호화폐의 가격과 블록체인 정보에 대한 연구는 거의 수행되지 않았다. 기존 암호화폐 관련 연구가 주로 비트코인에 대한 가격예측을 수행하였기 때문이다. 따라서 본 연구는 대시, 라이트 코인, 모네로 암호화폐 가격에 대한 예측 분석을 수행하였다. 분석 결과, 블록체인의 정보는 암호화폐 가격과 관련이 있는 것으로 나타났다. 본 연구의 발견은 암호화폐 관련 연구를 수행할 때 블록체인의 정보를 적극 활용할 필요성을 제안한다.

두 번째, 본 연구는 각각의 암호화폐마다 가격과 관련되는 블록체인 정보들이 차이가 존재한다는 사실을 발견하였다. 기존의 연구에서는 비트코인에 관련되는 블록체인의 정보들이 정확하게 무엇인지 제공하는 연구가 거의 수행되지 않았다. 따라서 본 연구는 암호화폐 가격과 블록체인의 정보를 개별적이고 위계적으로 적용하여 예측 분석을 수행하였다. 그 결과, 본 연구의 발견은 대시, 라이트 코인, 모네로 암호화폐의 가격에 관련되는 블록체인의 정보가 다르다는 사실을 제공한다. 이러한 사실을 향후 많은 암호화폐들에 대한 검증이 필요하다는 것으로도 볼 수 있다.

세 번째, 본 연구는 대시, 라이트 코인, 모네로 암호화폐 가격을 예측할 때 서포트 벡터 머신 보다 인공신경망 머신러닝 기법이 더욱 우수한 분석 결과를 제공한다는 사실을 발견하였다. 기존 연구에서는 서포트 벡터 머신도 비트코인 가격을 예측할 때 우수한 분석 결과를 제공하는 것으로 나타났다. 하지만 기존의 연구들이 비트코인에 대한 분석을 주로 수행하였기 때문에 대시, 라이트 코인, 모네로 암호화폐에 대한 분석에 있어 인공신경망과 서포트 벡터 머신 중 어떤 분석 알고리즘이 보다 우수한 성능을 제공하는지 식별할 수 없었다. 본 연구는 대시, 라이트 코인, 모네로 암호화폐 가격예측에 인공신경망이 서포트 벡터 머신보다 좋은 결과를 제공한다는 사실을 발견하였다는 의의를 가진다.

5.2. 실무적 시사점

본 연구의 결과는 다음과 같은 실무적 시사점을 제공한다. 첫 번째, 본 연구는 대시, 라이트 코인, 모네로 암호화폐를 활용하고자 하는 실무자에게 블록체인의 정보를 적극적으로 활용할 필요성을 제안한다. 블록체인 정보가 대시, 라이트 코인, 모네로 암호화폐 가격과 관련되어 있다는 본 연구의 발견은 실무자들에게 보다 정확한 암호화폐 유통 거래를 도울 것이다. 또한, 각각의 암호화폐마다 관련되는 블록체인 정보가 다르게 나타나기 때문에 암호화폐를 활용하고자 할 때 블록체인 정보가 담당하는 역할에 대해 주목하게 만들 것이다. 예를 들어서, 유통 분야에서 블록체인을 적용하고 유통관리에 필요한 비용을 암호화폐로 대체하고자 할 때 본 연구의 발견을 참고하여 블록체인 정보를 신중하게 고려하게 될 것이다.

두 번째, 본 연구는 대시, 라이트 코인, 모네로 암호화폐를 분석하는 실무자에게 인공신경망을 적극 활용할 것을 제안한다. 본 연구는 인공신경망이 서포트 벡터 머신 보다 암호화폐 가격 예측에 보다 적합하다는 사실을 제공한다. 따라서 암호화폐 분석 관련 실무자는 인공신경망을 활용하여 보다 정확한 분석 결과를 확보할 수 있을 것이다.

5.3. 한계점 및 향후 연구 방향

본 연구의 한계점과 연구 방향은 다음과 같다. 첫 번째, 본 연구는 암호화폐 가격예측에 블록체인 정보만을 활용하였다. 기존의 암호화폐 연구에서 블록체인 정보는 암호화폐 가격에 크게 관련되어 있는 변수였다. 본 연구는 이러한 사실을 기반으로 블록체인 정보를 활용하였지만 거시경제 요인이나 소셜 미디어의 데이터도 가격 예측에 중요한 관련이 되어 있을 수 있다. 향후 연구에서는 거시 경제요인, 암호화폐에 대한 유저들의 의견, 검색어 트렌드 등 다양한 변수들을 적절하게 고려하여야 할 것이다.

두 번째, 본 연구는 많은 암호화폐들 중 대시, 라이트 코인, 모네로 암호화폐 만을 대상으로 가격 예측 분석을 진행하였다. 암호화폐는 각각의 목적에 따라 다양하게 존재한다. 하지만 본 연구는 암호화폐들 중 3개만을 고려하였다. 향후 연구에서는 다양한 암호화폐들에 대한 추가 분석이 필요할 것으로 보인다.

블록체인은 유통분야에서 보다 많은 혜택을 제공할 수 있는 잠재력을 지니고 있으며, 현재 실무에서 적극적으로 활용되고 있는 기술이다. 따라서 블록체인을 구동하는 핵심 요인 중 하나인 암호화폐는 유통분야에서 지속적으로 관심을 가지고 연구해 나아갈 가치가 있다. 본 연구는 단순히 투자와 판매를 넘어서 블록체인의 암호화폐가 효율적인 유통관리에 기여할 수 있다고 판단하여 연구를 진행하였다. 본 연구는 향후 유통 분야에서 블록체인을 연구하고 암호화폐에 대한 관심을 두기 시작할 때 본 연구의 발견이 향후 연구에 필요한 이론적 기반을 제공하고 지식의 확장에 기여할 수 있기를 희망한다.

Reference

Antonopoulos, A. M. (2014). *Mastering Bitcoin: Unlocking digital cryptocurrencies.* O'Reilly Media, Inc.

Antonopoulos, A. M., & Wood, G. (2018). *Mastering ethereum: Building smart contracts and dapps.* O'Reilly Media, Inc.

Ciaian, P., Rajcaniova, M., & Kancs, D. A. (2016). The economics of Bitcoin price formation. *Applied Economics*, *48*(19), 1799-1815.

Cortes, C., & Vapnik, V. (1995). Support-vector networks. *Machine Learning*, *20*(3), 273-297.

Dang, T. T. (2019). Current situation of cryptocurrency in Vietnam. *The Journal of Business, Economics, and Environmental Studies*, *9*(4), 29-34.

Farajnejad, E., & Lau, W. Y. (2017). A fuzzy based early warning system to predict banking distress on selected Asia-Pacific countries. *The Journal of Asian Finance, Economics and Business*, *4*(1), 39-49.

Huang, W., Nakamori, Y., & Wang, S. Y. (2005). Forecasting stock market movement direction with support vector machine. *Computers & Operations Research*, *32*(10), 2513-2522.

Jang, H., & Lee, J. (2018). An empirical study on modeling and prediction of Bitcoin prices with bayesian neural networks based on Blockchain information. *IEEE Access*, *6*(1), 5427-5437.

Kara, Y., Boyacioglu, M. A., & Baykan, Ö. K. (2011). Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. *Expert Systems with Applications*, *38*(5), 5311-5319.

Kshetri, N. (2019). Blockchain and the economics of food safety. *IT Professional*, *21*(3), 63-66.

Kuo, T. T., Kim, H. E., & Ohno-Machado, L. (2017). Blockchain distributed ledger technologies for biomedical and health care applications. *Journal of the American Medical Informatics Association*, *24*(6), 1211-1220.

Mallqui, D. C., & Fernandes, R. A. (2019). Predicting the direction, maximum, minimum and closing prices of daily Bitcoin exchange rate using machine learning

techniques. *Applied Soft Computing, 75*(1), 596-606.

Murphy, K. P. (2012). *Machine learning: A probabilistic perspective*. Cambridge, MA, USA: MIT Press.

Park, Y. E., Chaffar, S., Kim, M. S., & Ko, H. Y. (2017). Predicting Arab consumers' preferences on the Korean contents distribution. *Journal of Distribution Science, 15(*4), 33-40.

Tsai, C. F., & Wu, J. W. (2008). Using neural network ensembles for bankruptcy prediction and credit scoring. *Expert Systems with Applications, 34*(4), 2639-2649.

Wang, P. (2011). Pricing currency options with support vector regression and stochastic volatility model with jumps. *Expert Systems with Applications, 38*(1), 1-7.

Wu, H., Li, Z., King, B., Ben Miled, Z., Wassick, J., & Tazelaar, J. (2017). A distributed ledger for supply chain physical distribution visibility. *Information, 8*(4), 1-18.