

설명 가능한 인공지능과 CNN을 활용한 암호화폐 가격 등락 예측모형*

홍태호
부산대학교 경영대학
(hongth@pusan.ac.kr)

김은미
부산대학교 경영연구원
(keunmi100@pusan.ac.kr)

원종관
KCB 사업본부 상품개발부
(jg.won@koreacb.com)

김민수
부산대학교 경영대학
(mskim_growth@pusan.ac.kr)

블록체인 기술이 적용되어 있는 암호화폐는 높은 가격 변동성을 가지며 투자자 및 일반 대중으로부터 큰 관심을 받아왔다. 이러한 관심을 바탕으로 암호화폐를 비롯한 투자상품의 미래가치를 예측하기 위한 연구가 이루어지고 있으나 예측모형에 대한 설명력 및 해석 가능성이 낮아 실무에서 활용하기 어렵다는 비판을 받아왔다. 본 연구에서는 암호화폐 가격 예측모형의 성과를 향상시키기 위해 금융투자상품의 가치평가에 활용되는 기술적 지표들과 함께 투자자의 사회적 관심도를 반영할 수 있는 구글 키워드 검색량 데이터를 사용하고 설명 가능한 인공지능을 적용하여 모형에 대한 해석을 제공하고자 한다. 최근 금융 시계열 분야에서 예측성과의 우수성을 인정받고 있는 LSTM(Long Short Term Memory)과 CNN(Convolutional Neural Networks)을 활용하고, 'bitcoin'을 검색어로 하는 구글 검색량 데이터를 적용해 일주일 후의 가격 등락 예측모형을 구축하였다. LSTM과 CNN을 활용해 구축한 모형들이 높은 예측성능을 보였으며 구글 검색량을 반영한 모형에서 더 높은 예측성과를 확인할 수 있었다. 딥러닝 모형의 해석 가능성 및 설명력을 위해 XAI의 SHAP 기법을 적용한 결과, 구글 검색량과 함께 과매수, 과매도 정도를 파악할 수 있는 지표들이 모형의 의사결정에 가장 큰 영향들을 미치고 있음을 파악할 수 있었다. 본 연구는 암호화폐 가격 등락 예측에 있어 전통적으로 시계열 예측에 우수한 성과를 인정받고 있는 LSTM뿐만 아니라 이미지 분류에서 높은 예측성과를 보이는 딥러닝 기법인 CNN 또한 우수한 예측성능을 보일 수 있음을 확인하였으며, XAI를 통해 예측모형에 대한 해석을 제공하고, 대중의 심리를 반영하는 정보 중 하나인 구글 검색량을 활용해 예측성과를 향상시킬 수 있다는 것을 확인했다는 점에서 의의가 있다.

주제어 : 암호화폐, 설명 가능한 인공지능, 딥러닝, LSTM, CNN

논문접수일 : 2023년 3월 24일 논문수정일 : 2023년 5월 23일 게재확정일 : 2023년 5월 29일
원고유형 : Regular Track 교신저자 : 김은미

1. 서론

주가를 비롯한 금융투자상품과 관련된 주제는 전통적으로 많은 관심을 받아왔다. 최근 COVID-19로 인한 팬데믹 발생 이후 전 세계적으로 여러 금융투자상품의 가격이 크게 상승하였으며, 특히

암호화폐는 가격 변동성이 여타 금융투자상품들보다 높아 일반 대중 및 투자자들의 큰 관심을 받고 있다(Sarkodie et al., 2022). 이러한 관심을 바탕으로 국내외에서 암호화폐를 포함한 금융투자상품에 대한 연구들이 활발하게 이루어지고 있다(Chen et al., 2020). 그중 미래가치를 예측하는 분

* 2022년 대한민국 교육부와 한국연구재단의 지원을 받아 수행된 연구임(NRF-2022S1A5A2A01049880)

야로 기본적 분석(fundamental analysis)과 기술적 분석(technical analysis)으로 크게 분류된다. 기본적 분석은 내재적 가치를 분석하는 방법으로 재무요인, 경쟁요인 등의 정보를 활용하며, 기술적 분석은 시가, 종가, 고가, 저가, 거래량을 활용해 생성한 기술적 지표를 활용해 가격의 추세 및 등락 여부를 예측하는 방법이다. 기술적 분석을 위해 ARIMA(Auto Regressive Integrated Moving Average), VAR(Vector AutoRegressive)와 같은 경제학 기반의 시계열 방법론이 사용되었으며, 최근에는 인공지능 방법론을 활용한 연구가 활발하게 진행되고 있으며 예측성과에서도 그 성능을 인정받고 있다(Aras, 2021). 특히 LSTM(Long Short Term Memory)을 포함한 RNN(Recurrent Neural Networks) 기반의 기법들은 금융투자상품을 포함한 시계열 예측에 활용되어 왔고 여러 연구에서 통계적 방법론보다 우수한 예측성능을 가진다고 주장하고 있다(Ghosh et al., 2021; Moghar & Hamiche, 2020). 패턴이나 특징들을 효과적으로 파악하는 데 강점을 가진 CNN(Convolutional Neural Networks)도 수치형 데이터를 활용하기 위한 방법론이 다양하게 개발되면서 주가 및 암호화폐 등 금융 분야에도 활발하게 사용되고 있다(Hosaka, 2019). 또한 예측모형의 정확도를 향상시키기 위해 정성적 정보를 추가적인 입력변수로 활용하는 사례도 증가하고 있으며, 조유정 등(2021)은 인공지능 기반 기업들의 주가 예측모형을 구축하기 위해 ‘인공지능’, ‘딥러닝’, ‘머신러닝’과 같은 검색어에 대한 구글 검색량 조합을 입력변수로 활용해 LSTM 및 VAR 모형의 예측성능을 향상시켰다. Urquhart (2018)는 VAR 모형을 통해 비트코인과 구글 검색량 간의 상관관계를 파악했고, 기간에 따라 구글 검색량이 암호화폐 가격 변동성 및 거래량에 영향을 미칠 수 있음을 주장했다.

또한 Guo et al. (2021)은 비트코인 가격 예측에 구글 검색량을 활용하여 사회적 관심을 반영하였으며 예측모형의 성능을 향상시켰다. 이처럼 여러 연구에서 구글 검색량을 포함한 인터넷 검색량은 특정 주제에 대한 대중의 심리나 사회적 관심도를 대표할 수 있는 정성적 정보로 활용 가능함을 보여준다(Kristoufek, 2013).

그러나 머신러닝 및 딥러닝 기법을 활용한 모형은 예측성능의 우수성에도 불구하고 설명력 및 해석 가능성이 낮아 실무에서 활용하기 어렵다는 비판을 받아왔다. 일반적으로 금융권은 규제 산업에 포함되기 때문에, 예측력도 중요하지만 설명력 및 해석 가능성이 중요한 부분을 차지하고 있다. 이러한 이유로 딥러닝 등 예측력이 뛰어난 기법이 발전되고 있음에도 불구하고 설명력에 강점을 가지고 있는 통계적 기법을 활용하는 경우가 아직까지 다수 존재하는 실정이다(천예은 등, 2021). 최근에는 머신러닝 및 딥러닝 기법의 한계를 극복하고, 예측모형의 설명력을 향상시키기 위해 설명 가능한 인공지능(eXplainable Artificial Intelligence: XAI)과 관련된 기법들이 개발되고 다양한 분야에서 활용되고 있다(Coussement & Benoit, 2021). SHAP(SHapley Additive exPlanation)는 XAI의 대표적인 기법 중 하나로 예측 및 분류 기법의 종류에 상관없이 적용할 수 있다는 장점이 있어 활발하게 연구되고 있다(Antwarg et al., 2021). SHAP는 모형에서 사용한 변수들의 기여도 및 출력값에 기여하는 방향성을 추출할 수 있으며, 개별 관측치에서 어떤 변수가 결과값에 어느 정도 기여했는지 파악할 수 있다(Lundberg et al., 2018). 현재까지 신용평가, 이상 탐지 등 다양한 분야에서 활용되고 있지만 암호화폐 가격, 등락 예측 및 그 결과를 바탕으로 구현할 수 있는 투자 자문과 관련된 분야에서는 거의 활용되지

못하고 있는 실정이다.

본 연구에서는 비트코인 가격 등락 예측을 위해 기술적 지표와 더불어 구글 검색량 데이터를 활용한다. 여러 선행연구에서 우수한 성능을 주장하고 있는 딥러닝 기법인 LSTM과 CNN을 활용해 비트코인 가격 등락 예측 정확도를 높일 수 있는 최적의 예측모형을 탐색하고, XAI기법인 SHAP를 활용해 해당 예측모형의 설명력을 높여 단순히 상승, 하락과 같이 최종 예측 결과만을 제공하는 것이 아니라 해당 예측 결과를 산출한 근거를 함께 제시해 투명성과 해석 가능성을 향상시키고 이에 대한 적용예시를 제시한다.

2. 이론적 배경

2.1 암호화폐

암호화폐(Cryptocurrency)는 블록체인 기술을 기반으로 하여 거래를 안전하게 확인하고 보호하는 새로운 유형의 디지털 자산이며, 여기서 블록체인 기술은 원장(ledger)에 존재하는 거래 관련 데이터를 분산 컴퓨팅 기술을 이용해 탈중앙화된 방법으로 관리하는 기술이다(Li & Wang, 2017). 블록체인 기술로 만들어진 암호화폐들 중 Nakamoto (2008)에 의해 처음 제안된 비트코인(bitcoin)은 암호화폐가 시장에서 거래된 이래 지속적으로 가장 높은 시가 총액을 형성하고 있으며, 전체 시장을 주도하고 있다(이준식 등, 2018). 또한 세계 유수 기업에서 비트코인을 결제 수단으로 지정하고 있는 등 개인뿐만 아니라 기관에서도 큰 관심을 가지고 있다(Zhang et al., 2021). 비트코인과 더불어 이더리움(ethereum), 리플

(ripple), 바이낸스 코인(binanace coin) 등 다양한 암호화폐가 지속적으로 출시되고 있으며, 2023년 2월 기준 22,604개의 암호화폐가 유통되고 있다¹⁾. 비트코인을 포함한 암호화폐는 등장 이후 금융시스템이 선진화 되어 있지 않고 취약한 국가에서 대안적 화폐로서 기능할 것이라고 기대되었으나, 통화의 3대 기능 중 하나인 가치저장기능을 확실하게 가진다고 볼 수 없으며 가격의 급격한 변동으로 인해 가치척도 기능을 가지기 힘들다는 점에 기인하여(Jang & Kim, 2017), 비트코인을 주식이나 금과 같은 금융투자상품으로 분류하고 있다(장성일, 김정연, 2017; White et al., 2020; Shahzad et al., 2022; Nakano & Takahashi, 2020).

2.2 딥러닝 기반의 암호화폐 예측

비트코인을 비롯한 암호화폐는 주식과 유사한 특성을 가지고 있으며, 변동성이 높은 금융투자상품으로 분류할 수 있다(Su et al., 2020). 이에 따라 주가 예측에서 활용되고 있는 머신러닝 및 딥러닝 기법을 활용해 가격이나 등락을 예측하려는 연구들이 주를 이루고 있다. 시계열 예측에 강점을 보이는 RNN이나 LSTM은 예측성과의 우수성을 인정받고 있으며, 최근에는 이미지 분류에서 높은 분류 성능으로 자주 사용되는 CNN을 활용한 예측모형들이 우수한 예측성능을 보이고 있다. Guo et al. (2021)은 비트코인의 가격을 예측하는 데 있어 주요 영향을 미치는 원인을 파악하는 것이 어렵고, 장 마감에 없는 24시간 거래 환경으로 인해 높은 변동성을 가져 정확하게 예측하는 것이 어렵다는 것을 지적하였다. 이러한 문제점을 해결하기 위해 거래소 간 이동 및 거래소 내부 거래와 관련된 정보를 이용해 추출한

1) <https://coinmarketcap.com>

변수를 활용하여 웨이블릿 변환과 CNN 기반의 모형을 제시하였다. 제시한 모형은 인공신경망, LSTM, ARIMA 모형보다 우수한 예측성과를 보이며 변동성이 매우 큰 시계열 데이터를 예측할 때 우수성을 보인다고 하였다. Ortu et al. (2022)의 연구에서도 높은 가격 변동성과 암호화폐 시장의 자체적 특성으로 비선형성을 가진 시계열 예측에 우수성을 보여 왔던 딥러닝 기법을 활용하는 것이 예측성능 향상에 도움이 될 수 있다고 주장하며, 인공신경망, CNN, 그리고 LSTM 모형 등을 구축하였다. Alonso-Monsalve et al. (2020)은 암호화폐 기반의 고빈도 매매 시스템에 활용하기 위한 등락 예측모형을 구축하기 위해 CNN과 LSTM을 함께 활용하는 하이브리드 모형을 제시하였으며 CNN 기반의 모형이 등락 예측에서 우수한 성능을 보일 수 있음을 시사했다. 이처럼 입력 데이터의 적절한 이미지 변환을 기반으로 CNN을 활용한 연구가 활발하게 진행되고 있는 추세이며 예측성과도 우수한 것으로 나타났다.

예측성과 향상을 위해 인터넷 검색량, 뉴스 기사, SNS 등의 비정형 데이터도 예측모형에 활용되고 있다. Karalevicius et al. (2018)은 뉴스 기사, 블로그 게시글에 대한 감성분석을 사용하였으며 비트코인 가격과 뉴스 감성값 사이에 유의미한 관계가 존재함을 확인하였다. Abraham et al. (2018)은 비트코인과 이더리움의 가격 예측을 위해 구글 검색량 데이터와 트위터 게시글 데이터를 활용하였으며 실증분석을 통해 트위터 게시글로부터 추출한 감성점수보다는 구글 검색량과 일별 트위터 게시글 개수가 예측성과 향상에 통계적으로 유의미한 영향을 미친다고 하였다. Mittal et al. (2019)도 구글 검색량과 일별 트위터 게시글 개수, 트위터 게시글로부터 추출한 일별 감성점수를 선형 회귀분석, RNN, LSTM 등의 예측 기

법에 적용하였으며 구글 검색량과 일별 트위터 게시글 개수를 활용한 모형이 우수한 성능을 보임을 확인하였다. Guo et al. (2021)은 암호화폐 예측에서 대중들의 사회적 관심을 대변할 수 있는 데이터를 활용하는 것이 중요하다고 하였으며 구글 검색량을 사회적 관심을 나타내는 변수로 활용하였다. 이처럼 정성적 데이터들이 암호화폐 예측에서도 활발하게 활용되고 있으며 예측성과 향상에 대한 유의성을 인정받고 있다(Abraham et al., 2018; Mittal et al., 2019; Guo et al., 2021).

2.3 설명 가능한 인공지능

설명 가능한 인공지능(eXplainable Artificial Intelligence: XAI)은 분류 및 예측모형들이 예측값을 생성할 때 어떤 과정을 거치며, 어떤 변수들을 활용하는지 파악하기 위해 활용하는 기법이다 (Adadi & Berrada, 2018). XAI기법 중 SHAP(SHapley Additive exPlanations), LIME(Local Interpretable Model-Agnostic Explanation), 그리고 LRP(Layer-wise Relevance Propagation)는 다양한 머신러닝 및 딥러닝 등 인공지능 기법을 활용해 구축한 모형들의 설명력 및 해석 가능성을 향상시키기 위한 방법으로 활용되고 있으며 경영분야에서의 XAI 적용연구는 <표 1>과 같다.

이상탐지를 확인하기 위한 딥러닝 모형에서 LIME을 적용하여 어떤 단어가 자주 등장할 때 온라인 이상 행동으로 탐지하게 되는지(Zinovyeva et al., 2020), 어떤 단어들이 모형의 의사결정에 주요한 영향을 미치는지 파악하였다(Craja et al., 2020). SHAP는 예측모형을 위한 주요변수를 추출할 수 있으며 모형에 활용된 변수의 영향도 및 영향의 방향성을 파악할 수 있다. Antwarg et al. (2021)은 1999년 개최된 KDD Cup 대회에서 사용된 이상

〈표 1〉 경영분야에서의 XAI 적용연구

적용분야	XAI 기법	연구자	연구 내용
신용평가	SHAP	Wang et al. (2021)	온라인 P2P 대출 플랫폼에서 랜덤포레스트, 로지스틱 회귀분석 등의 기법을 활용해 P2P 대출에서 도산을 예측하는 모형들을 구축하고, SHAP를 활용해 주요 변수를 추출한 뒤 개별 관측치 별로 각 변수가 어떻게 적용되는지 파악함
	LRP	원종관 등 (2021)	개인 신용 데이터의 이미지 변환 및 합성곱 신경망을 적용하여 개인 파산 예측모형을 구축하였으며, LRP를 이용해 개인 파산 여부에 대한 설명력을 제공하였음
보험심사	SHAP	Azzone et al. (2022)	보험 인수심사를 위한 모형을 랜덤포레스트 기법으로 구축하였으며, SHAP를 활용한 변수 중요도와 랜덤포레스트 자체 변수 중요도를 비교해 XAI 기법을 비교하고, 이를 통해 보험 인수 심사와 관련된 주요 변수들을 추출함
이상/사기 탐지	LIME	Zinovyeva et al. (2020)	비정상적인 온라인 활동을 탐지하고 필터링하기 위해 딥러닝 기법으로 모형을 구축하고, 구축한 모형의 근본적인 구조를 해석하기 위해 LIME을 활용하였음. 이를 통해 모형의 해석 가능성을 제공할뿐만 아니라 모형 자체의 모순을 발견할 수 있음을 주장함
	LIME	Craja et al. (2020)	기업의 재무제표 사기탐지를 위해 텍스트 데이터 분석과 랜덤 포레스트, 인공신경망, XGBoost, SVM을 활용해 모형을 구축하고, 기업 재무제표에 등장하는 단어들 중 어떤 단어가 모형의 의사 결정에 주요한 영향을 미치는지 파악하기 위해 LIME을 적용
	LIME, SHAP	Antwarg et al. (2021)	약물 남용에 대한 이상 신호 탐지 모형을 구축하고, 신용카드 사기탐지 데이터, 이상탐지 데이터 등 여러 분야의 데이터에 적용하여 모형의 우수함을 주장하였으며, LIME와 SHAP를 적용하여 모형 구축에 활용된 변수의 영향도 및 영향의 방향성을 모형으로부터 추출함

탐지 데이터 셋과 신용카드 사기탐지 데이터를 활용해 구축한 예측모형의 판단이 옳지 않을 때 설명을 제공하기 위해 SHAP를 적용하여 개별 관측치별로 주요 변수들을 추출하였으며 Azzone et al. (2022)은 보험 만료 예측을 이자율, 인플레이션 등의 거시 경제적 변수와 인구통계학적 변수에 랜덤 포레스트를 적용하여 구축하고 각 분류별(연장, 만료)로 어떤 변수들이 주요 영향을 미치는지 파악하기 위해 SHAP를 활용하였으며 모형의 투명도를 향상시켰다. Wang et al. (2021)은 중국의 P2P 대출에서의 미래 채무 불이행 여부를 분류하는 모형을 구축하고 SHAP를 활용하

여 예측값에 영향을 크게 미치는 변수들을 추출한 뒤, 개별 관측치별로 예측 모형이 산출하는 결과값에 대한 해석을 추출된 변수를 중심으로 제공하였다. LRP는 숫자분류에서 어떤 픽셀이 특정 관측치를 특정 숫자로 분류하는 데 결정적 역할을 하는지 파악하기 위해 적용되었다(원종관 등, 2021).

XAI기법 중 SHAP는 게임 이론적 접근 방식을 활용해 기계 학습 모형의 출력값을 설명하는 방식으로 고전적인 샤프리 값을 사용한다(Giudici & Raffinetti, 2021). 대리 분석의 일종인 LIME과 다르게 일관성과 음의 영향력을 고려하는 특징을

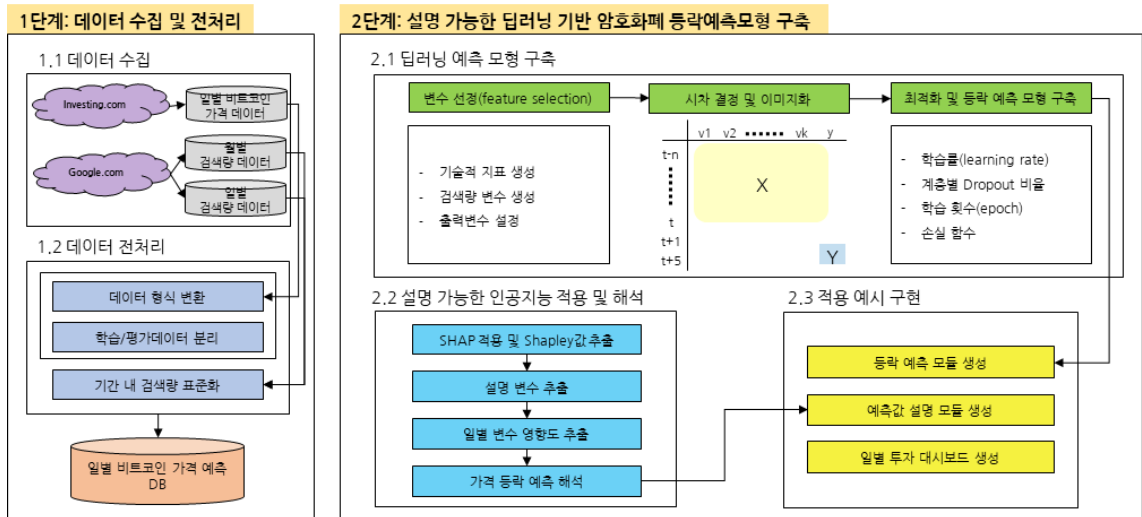
가지며 각 변수가 기초 예측값에서 얼마만큼의 영향을 어떤 방향으로 미치는지에 대해 개별 관측치 별로 파악하는 지역적 해석이 가능하고, 각 개별 관측치별 영향도를 종합하면 각 변수가 전체적으로 어떤 방향으로 기여하는지, 그리고 동시에 어떤 변수가 가장 큰 영향을 미치는지에 대한 전역적 해석이 가능해진다(Lundberg et al., 2018). 이러한 특성 및 장점을 바탕으로 SHAP는 제안된 이후로 의학, 경제 등 다양한 분야에 활용되고 있으며, 선행연구에서 가장 빈번히 활용되고 있는 기법 중 하나이다(Antwarg et al., 2021).

3. 연구 프레임워크

연구 프레임워크는 <그림 1>과 같다. 1단계는 데이터 수집 및 전처리 단계로 일별 비트코인 가격데이터와 구글 검색량 데이터를 수집한다. 비트코인 가격데이터는 글로벌 금융 포털 사이트

인 investing.com에서 수집하며, 구글 검색량 데이터는 trends.google.com을 활용한다. 데이터 형식을 모형구축에 적합하도록 변환한 뒤 모형의 학습을 진행할 학습데이터와 예측성능을 평가할 평가데이터로 분리한다. 구글 검색량은 전체 기간의 일별 상대적 검색량 산출 방법을 활용하여 모형 구축에 활용한다(Mittal et al., 2019).

2단계에서는 딥러닝 기반의 등락 예측 모형을 구축하고 설명 가능한 인공지능을 적용하여 모형에 대한 해석을 제공한다. 등락 예측 모형은 당일 종가 기준 일주일 뒤의 등락을 예측한다. 주식과 같은 금융 투자상품들은 일반적으로 일주일(5영업일) 이후를 예측해 중기 추세에 대한 정보를 제공하는 연구들이 다수 진행되고 있다(Yang et al., 2020). 비트코인의 경우 주식 등 금융투자상품 투자에 있어서의 위험을 헷징하는 수단으로 활용되기도 하는 등 금융투자상품과 밀접한 연관성을 가지고 있어(Pal & Mitra, 2019) 비트코인 예측에서도 중기적인 추세를 예측하는



<그림 1> 연구 프레임워크

것이 비즈니스적으로 더 큰 가치를 가진다고 판단하고 일주일 뒤 증가 등락 여부를 예측한다. CNN을 적용하기 위한 입력 데이터 생성은 기술적 지표와 구글 검색량 변수에 시차 개념을 적용하고 이미지 형태의 입력 데이터 구조로 설정한다(Alonso-Monsalve et al., 2020). CNN의 구조는 과적합 문제 방지에 우수성을 인정받았으며, 암호화폐 가격 등락 예측에서 우수한 예측성과를 보인 Lin et al. (2013)이 제안한 구조를 활용한다. 인공지능망, SVM, LSTM, CNN을 적용하여 모형을 구축하며 구글 검색량을 입력변수로 활용한 모형과 활용하지 않은 모형의 성과를 비교하여 구글 검색량이 가격 등락 예측에 유의미한 영향을 미치는지 파악한다.

XAI기법 적용 및 예측 결과 해석 부분에서는 게임 이론에 기반을 둔 SHAP를 활용해 이전 단계에서 구축한 딥러닝 예측모형이 산출해내는 일별 등락 예측값에 대한 해석을 실시한다. 변수별 샐플리 값들은 관측치 별로 다른 값들을 가질 수 있고, 모든 관측치의 샐플리 값들을 종합하면 전체 모형에서의 변수별 중요도 및 방향성을 파악할 수 있어 모형의 투명도 및 설명 가능성을 향상시킬 수 있다(이재준 등, 2021). 본 연구에서는 SHAP를 활용해 개별 관측치의 변수 중요도를 추출한 선행연구(Ayoub et al., 2021)와 같이 비트코인 가격 등락 예측 결과값에 어떤 변수가 어떤 값을 가지고 있으며, 어느 정도의 영향을 미치는지를 통해 해석하고자 한다(Antwarg et al., 2021). 마지막 적용단계에서는 이전 단계에서 구축한 딥러닝 예측모형이 산출한 일별 등락 예측 결과값과, XAI기법인 SHAP를 적용해 산출한 샐플리 값 기반의 해석 내용을 활용하여 투자자들에게 제공할 수 있는 서비스 예시를 생성한다.

4. 실증분석 및 분석결과


4.1 데이터

본 연구에서는 거래소별 비트코인의 달러(\$) 기준 일별 시가, 증가, 고가, 저가, 거래량에 대한 정보를 제공하는 Investing.com에서 2017년 1월 1일에서 2022년 1월 31일을 기간으로 하는 비트파이넥스 거래소의 가격 데이터를 수집하였다. 구글 검색량 데이터는 전체 기간의 월별 상대적 검색량을 먼저 추출하고, 전체 기간의 일별 상대적 검색량을 계산하기 위해 전체 기간에 걸쳐 있는 각 개별 월 내에서의 일별 상대적 검색량을 추출했다. 먼저 월별 데이터의 경우 trends.google.com에서 검색 국가는 ‘전 세계’, 분류는 ‘모든 카테고리’, 검색어는 ‘bitcoin’, 추출 기간은 2017년 1월 1일에서 2022년 1월 31로 설정하여 추출하였다. 0~100까지의 값으로 나타나며, 0에 가까울수록 추출 기간 내에서 검색량이 적은 것을 의미하고, 100에 가까울수록 검색량이 많다는 것을 의미한다. 각 개별 월내에서의 일별 상대적 검색량 추출을 위해 월별 데이터 추출과 검색조건을 동일하게 하고 추출 기간은 2017년 1월 1일에서 2017년 1월 31일까지와 같이 설정해 2017년 1월부터 2022년 1월까지의 각 개별 월 데이터를 수집하였다.

4.2 데이터 전처리

수집한 일별 비트코인 가격 데이터는 숫자(numeric) 형식이 아닌 객체(object) 형식으로 구성되어 있어, 추후 기술적 지표에서의 연산을 위해 숫자 형식으로 변환했다. 다음은 구축할 모형에 대한 학습과 성과 평가를 위해 학습용 데이터는 2017년 1월 1일부터 2021년 8월 26일까지로, 평가용 데이터는 2021년 8월 27일부터 2022년 1월

31일까지로 분류했다. 구글 검색량 데이터는 전체 분석 기간의 월별 상대적 검색량 데이터와 각 개별 월의 일별 상대적 검색량 데이터가 추출 가능하며, 본 연구에서는 전체 기간의 일별 상대적 검색량을 산출하기 위해 Mittal et al. (2019)의 연구에 사용된 방법론을 활용하였다. <그림 2>는 비트코인 가격 데이터와 변환된 구글 검색량 데이터로 구글 검색량 데이터는 가격 데이터와 유사한 추세를 보이고 있으며 검색량 변수가 비트코인 가격의 상승이나 하락에 주요한 영향을 미칠 수 있다는 것을 보여준다(이준식 등, 2018; 정기호, 하성호, 2020).



<그림 2> 비트코인 가격과 구글 검색량

4.3 변수선정

예측모형을 위해 비트코인 가격의 변동성, 추세, 모멘텀, 시장강도 등의 정보를 포함하고 있는 30개의 기술적 지표와 구글 검색량을 입력변수로 활용한다. 분석에 활용된 기술적 지표는 <표 2>와 같다(Kim & Enke, 2016). 각 기술적 지표 및 구글 검색량은 0과 1사이의 값으로 표준화하였다.

<표 2> 분석에 활용된 기술적 지표

변수명	기술적지표	변수명	기술적지표
V1	<i>Fast%K</i>	V16	<i>NCO</i>
V2	<i>Slow%K</i>	V17	<i>PO</i>
V3	<i>Band%b</i>	V18	<i>Psychology</i>
V4	<i>Band width</i>	V19	<i>ROC</i>
V5	<i>CCI</i>	V20	<i>RSI</i>
V6	<i>CO</i>	V21	<i>S-ROC</i>
V7	<i>Disparity</i>	V22	<i>Slow%d</i>
V8		V23	<i>SO</i>
V9	<i>DPO</i>	V24	<i>Sonar</i>
V10	<i>EOM</i>	V25	<i>Sonar signal</i>
V11	<i>MACD</i>	V26	<i>TRIX</i>
V12	<i>MAO</i>	V27	<i>VO</i>
V13	<i>MFI</i>	V28	<i>VROC</i>
V14	<i>MI</i>	V29	<i>Williams%R</i>
V15	<i>Momentum</i>	V30	<i>Z-score</i>

목표변수는 당일 증가 기준으로 일주일 뒤 증가가 더 높을 경우 1(상승), 낮을 경우 0(하락)으로 설정하며 목표변수의 분포는 <표 3>과 같다. 전체적으로 상승 일수가 하락 일수보다 높게 나타난다.

<표 3> 목표변수 분포


분류	상승	하락
전체	1,049 (56.73%)	800 (43.27%)
학습용	968 (67.97%)	731 (43.03%)
평가용	81 (54.00%)	69 (46.00%)

4.4 예측모형 구축

예측모형을 구축하기 위해 딥러닝 기법인 CNN과 LSTM, 그리고 머신러닝 기법인 인공신경망과 SVM을 활용하였다. 기술적 지표를 활용한 모형들은 CNN, LSTM, NN, SVM이라 하며, 기술적 지표와 구글 검색량 변수를 함께 활용한 모형은


CNN_G, LSTM_G, NN_G, SVM_G라 하였다. 학습 데이터와 평가 데이터는 8:2의 비율로 설정하였다.

CNN 모형은 Hosaka(2019)가 제안한 방법론을 바탕으로 합성곱 계층(convolution layer), 풀링 계층(pooling layer), 그리고 완전 연결층(fully connected layer)으로 이루어진 기본적인 CNN 구조를 적용하였다. <그림 3>과 같이 5개의 블록과 풀링층, 완전 연결층으로 구성되어 있으며, 5개의 블록은 각각 컨볼루션 계층과 과적합 방지를 위한 드롭아웃 계층, 그리고 데이터 정규화를 위한 배치 정규화 계층을 포함하고 있고, 활성화 함수로 기울기 소실 방지를 위한 ReLU 함수를 사용한다. 하이퍼 파라미터인 학습률, 각 드롭아웃 비율, 학습 횟수는 베이즈안 최적화 기법으로 검증 데이터의 예측성과를 최적화하도록 설정하였다.



<그림 3> CNN 모형 구조

LSTM 모형은 <그림 4>와 같이 구조를 설정하며, 하이퍼 파라미터인 학습률과 학습 횟수는 베이즈안 최적화를 활용해 설정하였다.



<그림 4> LSTM 구조

NN 모형에서 활성화 함수는 시그모이드 함수를 적용하였고, 은닉 계층의 수는 1, 학습률과 모멘텀은 각각 0.1로 설정하였으며 은닉 노드의 개수는 1부터 40 사이의 값으로, 학습 횟수는 100에서 2000사이로 설정하여 그리드 서치(grid search)를 통해 최적의 값을 사용하였다. 마지막으로 SVM 모형은 RBF커널 함수를 사용하고, C와, γ 은 각각 0.01, 100 사이의 값, 0.01에서 1사이의 값으로 설정하고 그리드 서치를 활용해 설정하였다.

4.5 예측성과

각 모형들의 예측성과는 <표 4>와 같다. 기술적 지표만을 변수로 활용한 모형에서는 LSTM 모형이, 기술적 지표 및 구글 검색량을 활용한 모형에서는 CNN_G 모형이 가장 높은 정확도를 기록했으며, 전체 모형 중에서는 CNN_G 모형이 61.33%의 정확도로 가장 높은 예측성과를 보였다. 또한 모형별 예측성과 차이가 통계적으로 유의미한지 파악하기 위해 맥니마(McNemar) 검정을 실시했다. <표 5>는 맥니마 검정 결과이며, CNN_G 모형은 LSTM_G 모형 등 다른 모형들과 1% 유의수준에서 통계적으로 유의미한 차이를 보여 예측성과의 차이가 신뢰할만한 수준이라 판단된다. 또한 동일한 기법 기준으로 구글 검색량을 사용한 모형들과 그렇지 않은 모형들을 비교해보면, 모든 모형에서 구글 검색량을 변수로 활용한 모형들의 분류 정확도 및 AUC 점수가 높았으며, 맥니마 검정 결과에서도 예측성과의 차이가 LSTM 기법의 경우 10% 수준에서, 인공신경망 기법의 경우 5% 수준에서, 나머지 모형들은 1% 수준에서 유의미한 차이를 보여 구글 검색량을 변수로 활용할 경우 예측성과 향상에 유의미한 영향을 미칠 수 있음을 시사했다.

〈표 4〉 모형별 예측성과 비교

입력변수	기술적 지표				기술적 지표 + 구글 검색량			
	NN	SVM	LSTM	CNN	NN_G	SVM_G	LSTM_G	CNN_G
학습용	64.05%	62.37%	61.22%	64.51%	64.17%	64.84%	62.21%	64.63%
평가용	56.00%	57.33%	59.33%	58.67%	58.00%	59.33%	60.00%	61.33%

〈표 5〉 맥니마(McNemar) 검정 결과

	SVM	LSTM	CNN	NN_G	SVM_G	LSTM_G	CNN_G
NN	2.45 (0.118)	5.600** (0.018)	19.593*** (0.000)	5.333** (0.021)	0.696 (0.404)	12.531*** (0.000)	31.373*** (0.000)
SVM		6.881*** (0.009)	12.755*** (0.000)	17.392*** (0.000)	9.600*** (0.002)	5.939** (0.015)	21.787*** (0.000)
LSTM			0.161 (0.689)	3.939** (0.047)	0.029 (0.864)	3.765* (0.052)	14.700*** (0.000)
CNN				8.82*** (0.003)	1.123 (0.289)	3.559* (0.059)	17.053*** (0.000)
NN_G					2.227 (0.136)	13.081*** (0.000)	43.891*** (0.000)
SVM_G						3.841* (0.050)	37.500*** (0.000)
LSTM_G							27.574*** (0.000)

*유의수준 10%, **유의수준 5%, *** 유의수준 1%에서 통계적으로 유의성을 가짐

5. XAI 적용 및 예측모형 해석


5.1 전역적 해석

가격 등락 예측모형에서 구글의 검색량을 활용한 CNN_G 모형이 가장 우수한 예측성적을 보였으며 CNN_G 모형에 SHAP를 적용하였다. SHAP는 전역적 해석 및 지역적 해석이 가능한데, 여기서 전역적 해석은 모형 자체에 대한 설명이고, 지역적 해석이란 개별 관측치에 대한 예측 결과값에 대한 설명이다. <그림 5>는 전역적 변수의 중요도이며 SHAP를 적용해 상위 10개의

변수를 도출하였다. Y축은 예측모형의 의사결정에 영향을 가장 많이 미치는 변수부터 내림차순으로 정렬되어 있는 변수 영향도이다. X축은 0보다 큰 값을 가지면 결과에 양의 영향을 미치며, 0보다 작은 값을 가지면 결과값에 음의 영향을 미친다고 해석할 수 있다. 또한 붉은색을 떨수록 변수의 값이 크다는 것을 의미하고, 푸른색을 떨수록 변수의 값이 작다는 것을 의미한다. 구글 검색량(`google_trend`)을 의미하는 V31과 기술적 지표 중 V29(`williams%R`), V6(`CO`, `chaikin's oscillator`)은 결과값과 음의 상관관계를 가지는

것으로 나타났고, V13(MFI, money flow index), V15(momentum), V22(slow_d), V23(SO, Stochastic Oscillator), V8(disparity_60, 60일 이격도)은 양의 상관관계를 가지는 것으로 나타났다. 가장 영향을 크게 미친 변수는 V31로 해당 변수의 값이 커질수록 출력 변수에는 음의 영향을 미치고 있으며, 예측 당시의 높은 대중의 관심은 일주일 후의 비트코인 가격에는 부정적인 영향을 미칠 수 있다고 해석할 수 있다. 이어 두 번째로 과매수, 과매도 정도를 파악할 수 있는 기술적 지표인 V29, V13, V15, V22, V23이 차례로 큰 영향을 미치는 것으로 나타났는데, V29는 모형 예측 결과값과 음의 상관관계를 가지며, V13, V15, V22, V23 지표들은 양의 관계를 가진다. V29는 0부터 100까지의 값을 가지며 일반적으로 0에 가까울수록 매수세가 강한 것이며 100에 가까울수록 매도세가 강하다고 간주할 수 있다(하현수, 하경모, 2019). 즉, V29의 값이 작아져 0에 가까워지면 매수세가 강해 일주일 후 가격이 상승할 가능성이 높다고 해석해 볼 수 있다. 또한 V13은 100에 가까울수록 매수세가 강하고, 0에 가까울수록 매도세가 강하다고 간주하며(Ghobadi, 2014), 해당 값이 커지면 매수세가 강해져 일주일 후 가격에도 긍정적인 영향을 미친다고 해석해 볼 수 있다. V15은 일반적으로 이전 가격보다 현재 가격이 얼마만큼 상승했는지를 파악하는 지표이며(Hon & Tonks, 2003), 값이 100 이상일 경우 상승추세에 있다고 볼 수 있고, 100 이하일 경우 하락추세에 있다고 볼 수 있다. SHAP값과 결합해서 해석하면, 본 연구에서 구축한 CNN_G 모형은 V15 변수의 값이 상승추세에 있다고 판단할 수 있을 경우 일주일 후 등락 예측값에 높은 가중치를 부여한다고 해석할 수 있다. 또한 V22, V23 변수는 100에 가까울수록 매수세가 강하며

0에 가까울수록 매도세가 강한 것을 의미하는 지표들인데(Ghobadi, 2014), 앞서 언급한 MFI와 같이 그 값이 클수록 CNN_G 모형이 예측값 산출에 양의 가중치를 부여한다고 해석할 수 있다. 이어 이동 평균선과 현재 가격이 얼마만큼의 차이를 나타내는지 파악하기 위한 V8 변수는 그 차이가 양의 방향으로 커질수록, 즉 비트코인 가격의 상승이 더 가팔라질수록 예측모형이 일주일 후 가격 예측에서 상승으로 분류할 가능성이 높아진다고 보고 있다. 거래량 정보를 함께 활용한 추세 지표로 볼 수 있는 CO의 경우 본 연구에서 구축한 예측모형이 그 값이 커질수록 추후 가격의 등락 여부에 하락으로 분류할 확률을 높이는 역할을 하고 있다고 해석해볼 수 있다. 한편 MAO, band_width 지표는 출력 변수에 미치는 영향의 방향성이 명확하지 않아 모형의 의사결정에 영향을 미치는 상위 10개의 변수에는 포함되었지만 양의 관계나 음의 관계를 가지지는 않는 것으로 볼 수 있는데, MAO는 양의 값에서 음의 값으로, 음의 값에서 양의 값으로 변할 때가 중요한 의미를 가질 수 있는 지표라는 점에서(Coutts et al., 2000), 밴드 폭은 변동성을 나타내고 상승 및 하락에 대한 정보를 정확하게 내포하지 않기 때문에 특정 관계가 나타나지 않는다고 해석해 볼 수 있다(양준열, 2021). 전역적 SHAP 분석을 통해, 구글 검색량과 함께 과매수, 과매도 정도를 파악할 수 있는 지표들이 모형의 의사결정에 가장 큰 영향들을 미치고 있음을 파악할 수 있고, 해당 지표들끼리 유사한 의미를 가질 경우 영향도의 방향성이 일치하는 것을 확인할 수 있었다.



<그림 5> SHAP에 의한 전역적 변수 중요도

5.2 지역적 해석

지역적 해석을 위해 개별 관측치 예측값에 대해 SHAP를 적용하였다. <그림 6>은 실제로 일주일 후에 상승했던 관측치를 상승한다고 분류(2021년 10월 7일 관측치)한 결과이고, <그림 7>은 일주일 후에 하락했던 관측치를 하락했다고 분류(2021년 12월 10일 관측치)한 결과이다. <그림 6>은 V29, V15, V13, V3, V12, V8 등의 변수는 등락 예측모형이 산출하는 예측값을 향상시키는 데 영향을 미쳤으며, V27, V18, V6, V31 등의 변수는 예측값을 하락시키는 데 영향을 미친 것을 파악할 수 있다. 이 중에서 V29, V15, V13, V6, V31, V8 변수는 SHAP를 통한 전역적 해석에서 중요한 변수로 분류됨과 동시에 출력 변수와 양, 음의 관계를 가졌던 변수들이고, 전역적 해석에서 주요변수로 추출되었던 변수들은 각 개별 관측치에서도 주요한 영향을 미치는 변수로 기능하고 있음을 파악할 수 있다. 그러나 V27과 같이 전역적 해석에서 주요변수에 포함되지 않은 변수들도 개별 관측치에서는 높은 영향을 미칠 수 있음을 확인할 수 있다.



<그림 6> 지역적 변수 중요도(상승)

<그림 7>은 암호화폐가 일주일 후 하락할 것이라고 분류했으며, V12, V16 등의 변수는 등락 예측모형의 산출 값을 향상시키는 데 영향을 미쳤으며, V22, V8, V31, V29, V13, V15, V26, V3 등과 같은 변수들은 예측모형 산출 값을 하락시키는 데 영향을 미쳤다. 특히 하락에 영향을 미친 변수들 중 V22, V8, V31, V29, V13, V15 변수는 전역적 해석에서도 관측되었던 변수들이고, 모형의 하락에 큰 영향을 미치고 있는 것을 확인할 수 있다.



<그림 7> 지역적 변수 중요도(하락)

이와 같이 SHAP를 활용할 경우 전역적인 해석뿐만 아니라 개별 관측치에 대한 지역적 해석도 가능하다. 개별 관측치에 대한 해석에서는 전역적 해석에서 추출한 주요변수들이 대부분 큰 영향을 미치고 있음을 확인할 수 있으며 이를 통해 블랙박스의 특징을 가지고 있는 딥러닝 모형의 해석 가능성 및 설명력을 향상시킬 수 있음을 보여준다.

5.3 적용예시

본 연구에서 제안한 딥러닝 기반 비트코인 가격 등락 예측모형인 CNN_G와 설명 가능한 인공지능 기법인 SHAP를 통해 일별 예측값에 대한 해석을 활용하여 생성할 수 있는 예시를 구현하

였다. 최근 머신러닝 및 딥러닝의 개념을 이용해 구축한 모형이 주식 및 암호화폐 투자성가에 우수한 성능을 보이는 것으로 나타나면서, 모형을 활용한 예측값 기반의 로보 어드바이저가 개발되고 있다. 그러나 알고리즘 추론 오류, 알고리즘 오작동 오류 등의 위험 또한 수반되고 있다(양영식, 맹수석, 2017). 로보 어드바이저를 사용하는 고객 측면에서는 로보 어드바이저의 신뢰성이 높을수록 수용성이 높아지며(Kim & Yang, 2021), 본 연구에서 제안한 CNN_G 모형과 SHAP 기반 해석을 함께 활용한다면 로보 어드바이저의 수용성을 향상시킬 수 있을 것으로 기대한다. <그림 8>은 본 연구에서 제시한 프레임워크를 활용해 생성할 수 있는 로보 어드바이저의 투자자문 기능을 구현한 예시이다.



<그림 8> 로보 어드바이저 예시

(위: 매수·보유 포지션 추천 예시, 아래: 매도·현금 관망 포지션 추천 예시)

6. 결론

본 연구에서는 딥러닝 기법인 CNN을 활용해 일주일 후의 비트코인 가격등락을 예측하는 모형을 구축하였다. 구글 검색량을 기술적 지표와 함께 예측모형의 입력변수로 활용해 예측모형의 성과를 향상시켰으며 딥러닝 기법이 가지고 있는 블랙박스적인 특성을 해결하기 위해 XAI기법인 SHAP를 적용하여 설명력과 해석 가능성을 확보하였다. 기술적 지표만을 입력변수로 활용한 모형에서는 LSTM 모형이, 구글 검색량 데이터와 기술적 지표를 함께 입력변수로 사용한 모형에서는 CNN_G 모형의 예측성도가 가장 우수하였으며 모든 모형에서 구글 검색량을 변수로 함께 활용한 모형의 예측성도가 향상된 것을 확인할 수 있었다. 구글 검색량을 변수로 활용한 모형들과 그렇지 않은 모형들의 예측성도의 차이가 최소 10% 수준에서 통계적 유의성을 보이며 대중들의 심리를 대변하는 구글 검색량 데이터는 암호화폐 등락 예측을 위한 주요변수가 될 수 있다는 점을 시사한다. 또한 예측성도가 가장 우수했던 CNN_G 모형에 설명 가능한 인공지능 기법인 SHAP를 적용하여 예측모형의 설명력 및 해석 가능성을 향상시키고 이를 활용하여 투자자문에 대한 로보 어드바이저 예를 구현해 보았다.

본 연구의 학술적 의의는 다음과 같다. 첫째, 산출한 결과값에 대한 설명을 제공하지 못하는 블랙박스적인 특징을 가지는 딥러닝 예측모형에 설명 가능한 인공지능을 적용해 설명력 및 해석 가능성을 향상시켰다. 기존의 딥러닝 기법을 활용한 주가 및 암호화폐 예측과 관련된 연구에서는 높은 예측성도를 보임에도 불구하고 예측값을 산출한 이유나 변수에 대한 분석이 부족하였고(이재웅, 한지형, 2021), 이러한 특징은 규제 산업에

포함되는 금융권에서는 딥러닝을 적용하기 힘들다는 비판을 받아왔다(천예은 등, 2021). 본 연구에서는 이를 해결하기 위해 딥러닝 모형이 산출하는 결과값에 어떤 변수가 어떤 방향으로 얼마만큼의 영향을 주는지 파악할 수 있는 XAI 기법인 SHAP를 활용해 전역적 해석 및 지역적 해석을 진행하였다. 이를 바탕으로 개별 예측에서 활용된 입력변수들이 어떤 방향으로 어느 정도의 영향을 미치는지 파악하였고, 다른 머신러닝 및 딥러닝 기법을 활용해 구축한 모형에도 적용할 수 있는 해석 방법을 제시하였다. 특히 국내외에서 이루어진 비트코인 및 암호화폐 가격 예측에서 설명력 향상을 위한 연구가 거의 이루어지지 않았다는 점에서 큰 의의가 있다.

둘째, 기술적 지표와 같은 정량적 데이터뿐만 아니라 대중 및 투자자의 사회적 관심도를 대변할 수 있는 정성적 데이터인 구글 검색량을 암호화폐 가격 등락 예측에 활용할 경우 예측성과를 향상시킬 수 있음을 실증분석을 통해 검증하였다. 본 연구에서 인공지능망, SVM, LSTM, CNN을 이용해 7일 뒤 등락 예측모형을 구글 검색량을 입력변수로 포함해 학습한 모형과 포함하지 않고 학습한 모형의 예측성과를 비교해본 결과 구글 검색량을 포함해 학습한 모형이 그렇지 않은 모형보다 우수한 예측성과를 보였다. 가장 우수한 예측성과를 보인 CNN_G 모형에 XAI 기법인 SHAP를 적용해본 결과 전역적 해석 부분에서 구글 검색량 변수가 가장 영향을 크게 미친 변수로 해석되며 해당 변수가 가격 등락 예측에서의 중요한 변수가 될 수 있음을 보였다.

셋째, 기존 선행연구에서 최근 활발하게 활용되고 있는 딥러닝 기법인 LSTM과 CNN을 활용해 등락 예측 모형을 구축하였다. 전통적으로 주가 및 암호화폐 가격 예측에 활용되고 있던 머신

러닝 기법들과 성과를 비교한 결과 LSTM 및 CNN을 기반으로 구축한 모형들의 예측성과가 우수함을 확인하였다. LSTM의 경우 기술적 지표와 같이 정량적 데이터를 활용해 구축한 예측에서 우수한 예측성능을 보였으며, CNN은 정성적 데이터를 함께 활용해 구축한 예측에서 가장 우수한 예측성능을 보였다. 특히 CNN은 데이터의 패턴 및 데이터 내의 상관관계 학습에서 다른 기법들보다 우수한 성능을 가지게끔 구조가 형성되어 있고(이모세, 안현철, 2018), 본 연구의 실증 분석에서도 정성적 정보인 구글 검색량이 가지고 있는 패턴이나 정보를 더 효과적으로 추출한 것으로 유추할 수 있다. 이를 통해 추후 시계열 예측과 관련된 분야에서도 적절한 데이터 종류 및 구조를 활용 할 경우 CNN 기반의 예측모형 정확도를 향상시킬 수 있음을 시사한다.

본 연구의 실무적 의의는 다음과 같다. 첫째, 서비스의 신뢰성이 중요한 가치를 가지는 금융권에서의 딥러닝 적용 가능성을 향상시킬 수 있다. 최근 유럽에서 시행되고 있는 GDPR(General Data Protection Regulation)은 알고리즘에 의한 자동화된 처리와 관련된 서비스에 일반 고객이 설명을 요구할 수 있으며, 이의를 제기할 수 있다는 내용을 포함하고 있다(천예은 등, 2021). XAI 기법을 활용해 딥러닝 모형의 결과값 도출에 대한 설명력을 제고할 수 있다면 높은 예측성과를 확보할 수 있을 뿐만 아니라 금융 산업에서의 규제에 부합할 수 있는 딥러닝 모형을 구축할 여지를 높일 수 있다.

둘째, 최근 암호화폐 투자와 관련해 투자자들의 매매 의사결정을 보조하는 로보 어드바이저의 수용성을 향상시킬 수 있다. 최근 로보 어드바이저의 설명 기능에 대한 수요가 높아지고 있으며(이근영, 2016), 로보 어드바이저에 대한 고객 수요를

높이기 위해서는 로보 어드바이저의 신뢰성이 요구된다(Kim & Yang, 2021). 본 연구에서 제안한 딥러닝과 설명 가능한 인공지능 기법을 활용해 예측력과 함께 설명력을 향상시킨다면 로보 어드바이저의 수용성을 높일 수 있다.

셋째, 비트코인의 일주일 뒤 가격 등락 예측의 정확도를 향상시켜 사회적 문제로 거론되고 있는 자산 시장에 대한 무분별한 투자를 예방하는데 기여할 수 있다. 특히 비트코인은 변동성이 매우 높은 금융투자상품으로 여겨지고 있고, 무리한 투기로 인해 많은 투자자들이 빚더미에 앉았던 사례가 다수 존재한다(이준식 등, 2018). 단기적인 추세와 관련된 정보를 제공할 수 있는 가격등락 예측모형은 관련된 사회 문제를 해결하는데 도움이 될 수 있다.

본 연구의 한계점 및 향후 연구 방향은 다음과 같다. 첫째, 본 연구는 선행연구를 바탕으로 기술적 지표와 구글의 검색량 데이터를 활용하여 모형을 구축했다. 하지만 최근 다양한 연구에서 뉴스 기사 및 트위터 등 텍스트 데이터를 함께 활용해 주가지수 및 금융투자상품의 가격 등락을 예측하려는 시도가 이어지고 있다. 따라서 추후 연구에서는 다양한 출처로부터 암호화폐 등락 예측에 도움이 되는 변수를 추가적으로 생성해 분석에 활용한다면 예측성과를 향상시킬 수 있을 뿐만 아니라, 설명력 면에서의 발전도 기대할 수 있다.

둘째, 본 연구에서 31개의 지표 데이터와 구글 검색량 데이터를 이미지 데이터로 변환했고, 7×33 형식의 이미지 데이터를 합성곱 신경망의 입력 값으로 사용했다. 이는 상대적으로 작은 크기의 데이터 형태이며, 이러한 경우 GoogLeNet이나 ResNet과 같이 다른 연구에서 우수한 성과가 증명된 모형들을 적용하기 어려워진다. 따라서 추후 연구에서는 데이터 변환 방법을 다양하게

적용하여 예측성과 차이를 비교, 분석해보는 것이 필요하다.

셋째, 본 연구에서는 여러 암호화폐 중 암호화폐 시장을 주도하고 있으며 시가 총액이 가장 큰 비트코인만을 분석 대상으로 선정해 실험을 진행하였는데, 이더리움 및 이더리움 네트워크 기반의 코인들과, 바이낸스 코인 등 암호화폐 및 가상자산 거래소에서 발행하는 코인 등 블록체인 네트워크의 특성과 수요층이 상이한 암호화폐가 다수 존재하기 때문에, 본 연구에서 제안한 모형 및 방법론을 해당 암호화폐들에 적용해보는 실증분석이 추가적으로 필요하다. 또한 일반적으로 블록체인 네트워크에 예술품이나 가상 세계에서의 개체의 소유권을 등록하는 NFT(Non-Fungible token)는 주로 암호화폐를 결제 수단으로 사용하는 등 암호화폐 시장과 큰 연관성을 가지고 있으며(Dowling, 2022), NFT와 함께 블록체인 네트워크를 활용하는 DeFi(Decentralized Finance)은 최근 시장 가치 및 거래량이 급격하게 상승하며 블록체인 시스템이 가지고 있는 가치의 대부분을 가지게 될 수 있는 가능성을 보여주고 있어(Schlatt et al., 2022), 해당 분야의 가격 예측과 관련된 측면에서도 본 연구에서 제안한 내용을 적용해보는 분석이 필요하다.

참고문헌(References)

[국내 문헌]

- 양영식, 맹수석. (2017). 로보어드바이저 거래와 금융소비자 보호 방안. *금융소비자연구*, 7(1), 39-71.
- 양준열. (2021). Attention based GRU 극점 예측 알고리즘을 통한 주가 방향성 예측 (Doctoral dissertation, 서울대학교 대학원).

- 원종관, 홍태호, 배경일. (2021). 신용 데이터의 이미지 변환을 활용한 합성곱 신경망과 설명 가능한 인공지능(XAI)을 이용한 개인신용 평가. *정보시스템연구*, 30(4), 203-226.
- 이근영. (2016). 국내외 로보어드바이저 (RoboAdvisor) 동향 및 현황 분석. *전자금융과 금융보안*, 6.
- 이모세, 안현철. (2018). 효과적인 입력변수 패턴 학습을 위한 시계열 그래프 기반 합성곱 신경망 모형: 주식시장 예측에의 응용. *지능정보연구*, 24(1), 167-181.
- 이재웅, 한지형. (2021). 설명 가능한 KOSPI 증감 예측 딥러닝 모델을 위한 Layer-wise Relevance Propagation (LRP) 기반 기술적 지표 및 거시 경제 지표 영향 분석. *정보과학회논문지*, 48(12), 1289-1297.
- 이재준, 이유린, 임도현, 안현철. (2021). XGBoost 와 SHAP 기법을 활용한 근로자 이직 예측에 관한 연구. *정보시스템연구*, 30(4), 21-42.
- 이준식, 김건우, 박도형. (2018). 비트코인 가격 변화에 관한 실증분석: 소비자, 산업, 그리고 거시변수를 중심으로. *지능정보연구*, 24(2), 195-220.
- 장성일, 김정연. (2017). 비트코인의 자산성격에 관한 연구. *한국전자거래학회지*, 22(4), 117-128.
- 정기호, 하성호. (2020). 인터넷 검색을 통한 암호화폐 수익률 및 변동성에 대한 인과검정: 적률인과 접근. *정보시스템연구*, 29(1), 289-301.
- 조유정, 손권상, 권오병. (2021). 인공지능의 사회적 수용도에 따른 키워드 검색량 기반 주가예측 모형 비교연구. *지능정보연구*, 27(1), 103-128.
- 천예은, 김세빈, 이자윤, 우지환. (2021). 설명 가능한 AI 기술을 활용한 신용평가 모형에 대한 연구. *한국데이터정보과학회지*, 32(2), 283-295.
- 하현수, 하경모. (2019). 인공 신경망과 웨이블릿 변환을 이용한 주가 지수 예측. *정보과학회 논문지*, 46(12), 1249-1261.

[국외 문헌]

- Abraham, J., Higdon, D., Nelson, J., & Ibarra, J. (2018). Cryptocurrency price prediction using tweet volumes and sentiment analysis. *SMU Data Science Review*, 1(3), 1.
- Adadi, A., & Berrada, M. (2018). Peeking inside the black-box: a survey on explainable artificial intelligence (XAI). *IEEE access*, 6, 52138-52160.
- Alonso-Monsalve, S., Suárez-Cetrulo, A. L., Cervantes, A., & Quintana, D. (2020). Convolution on neural networks for high-frequency trend prediction of cryptocurrency exchange rates using technical indicators. *Expert Systems with Applications*, 149, 113250.
- Antwarg, L., Miller, R. M., Shapira, B., & Rokach, L. (2021). Explaining anomalies detected by autoencoders using Shapley Additive Explanations. *Expert Systems with Applications*, 186, 115736.
- Aras, S. (2021). Stacking hybrid GARCH models for forecasting Bitcoin volatility. *Expert Systems with Applications*, 174, 114747.
- Ayoub, J., Yang, X. J., & Zhou, F. (2021). Combat COVID-19 infodemic using explainable natural language processing models. *Information Processing & Management*, 58(4), 102569.
- Azzone, M., Barucci, E., Moncayo, G. G., & Marazzina, D. (2022). A machine learning model for lapse prediction in life insurance contracts. *Expert Systems with Applications*, 191, 116261.
- Bach, S., Binder, A., Montavon, G., Klauschen, F., Müller, K. R., & Samek, W. (2015). On pixel-wise explanations for non-linear classifier decisions by layer-wise relevance propagation. *PLoS one*, 10(7), e0130140.
- Chen, Z., Li, C., & Sun, W. (2020). Bitcoin price

- prediction using machine learning: An approach to sample dimension engineering. *Journal of Computational and Applied Mathematics*, 365, 112395.
- Coussemont, K., & Benoit, D. F. (2021). Interpretable data science for decision making. *Decision Support Systems*, 150, 113664.
- Coutts, J. A., & Cheung, K. C. (2000). Trading rules and stock returns: some preliminary short run evidence from the Hang Seng 1985-1997. *Applied Financial Economics*, 10(6), 579-586.
- Craja, P., Kim, A., & Lessmann, S. (2020). Deep learning for detecting financial statement fraud. *Decision Support Systems*, 139, 113421.
- Dowling, M. (2022). Is non-fungible token pricing driven by cryptocurrencies?. *Finance Research Letters*, 44, 102097.
- Ghobadi, M. (2014). Profitability of technical analysis indicators to earn abnormal returns in international exchange markets. *Journal of Economics Finance and Accounting*, 1(4).
- Ghosh, P., Neufeld, A., & Sahoo, J. K. (2021). Forecasting directional movements of stock prices for intraday trading using LSTM and random forests. *Finance Research Letters*, 46, 102280.
- Giudici, P., & Raffinetti, E. (2021). Shapley-Lorenz eXplainable artificial intelligence. *Expert Systems with Applications*, 167, 114104.
- Guo, H., Zhang, D., Liu, S., Wang, L., & Ding, Y. (2021). Bitcoin price forecasting: A perspective of underlying blockchain transactions. *Decision Support Systems*, 151, 113650.
- Hon, M. T., & Tonks, I. (2003). Momentum in the UK stock market. *Journal of Multinational Financial Management*, 13(1), 43-70.
- Hosaka, T. (2019). Bankruptcy prediction using imaged financial ratios and convolutional neural networks. *Expert systems with applications*, 117, 287-299.
- Jang, S. I., & Kim, J. Y. (2017). A Study on The Asset Characterization of Bitcoin. *The Journal of Society for e-Business Studies*, 22(4), 117-128.
- Karalevicius, V., Degrande, N., & De Weerd, J. (2018). Using sentiment analysis to predict interday Bitcoin price movements. *The Journal of Risk Finance*, 19(1), 56-75.
- Kim, A. R., & Yang, H. K. (2021). A Study on the Perceived Value and the Intention to Use of the Robo-advisor: Moderating Effects of Innovativeness and Resistance to Innovation. *Financial Planning Review*, 14(2), 55-88.
- Kim, Y., & Enke, D. (2016). Developing a rule change trading system for the futures market using rough set analysis. *Expert Systems with Applications*, 59, 165-173.
- Kristoufek, L. (2013). BitCoin meets Google Trends and Wikipedia: Quantifying the relationship between phenomena of the Internet era. *Scientific reports*, 3(1), 1-7.
- Li, X., & Wang, C. A. (2017). The technology and economic determinants of cryptocurrency exchange rates: The case of Bitcoin. *Decision support systems*, 95, 49-60.
- Lin, M., Chen, Q., & Yan, S. (2013). Network in network. arXiv preprint arXiv:1312.4400.
- Lundberg, S. M., Erion, G. G., & Lee, S. I. (2018). Consistent individualized feature attribution for tree ensembles. arXiv preprint arXiv:1802.03888.
- Mittal, A., Dhiman, V., Singh, A., & Prakash, C. (2019, August). Short-term bitcoin price fluctuation prediction using social media and web search

- data. In 2019 Twelfth International Conference on Contemporary Computing (IC3) (pp. 1-6). IEEE.
- Moghar, A., & Hamiche, M. (2020). Stock market prediction using LSTM recurrent neural network. *Procedia Computer Science, 170*, 1168-1173.
- Nakamoto, S. (2008). Bitcoin: A peer-to-peer electronic cash system. *Decentralized business review, 21260*.
- Nakano, M., & Takahashi, A. (2020). A new investment method with AutoEncoder: Applications to crypto currencies. *Expert Systems with Applications, 162*, 113730.
- Ortu, M., Uras, N., Conversano, C., Bartolucci, S., & Destefanis, G. (2022). On technical trading and social media indicators for cryptocurrency price classification through deep learning. *Expert Systems with Applications, 198*, 116804.
- Pal, D., & Mitra, S. K. (2019). Hedging bitcoin with other financial assets. *Finance Research Letters, 30*, 30-36.
- Sarkodie, S. A., Ahmed, M. Y., & Owusu, P. A. (2022). COVID-19 pandemic improves market signals of cryptocurrencies - evidence from Bitcoin, Bitcoin Cash, Ethereum, and Litecoin. *Finance Research Letters, 44*, 102049.
- Schlatt, V., Guggenberger, T., Schmid, J., & Urbach, N. (2022). Attacking the trust machine: Developing an information systems research agenda for blockchain cybersecurity. *International Journal of Information Management, 102470*.
- Shahzad, S. J. H., Bouri, E., Rehman, M. U., & Roubaud, D. (2022). The hedge asset for BRICS stock markets: Bitcoin, gold or VIX. *The World Economy, 45(1)*, 292-316.
- Su, C. W., Qin, M., Tao, R., & Umar, M. (2020). Financial implications of fourth industrial revolution: Can bitcoin improve prospects of energy investment?. *Technological Forecasting and Social Change, 158*, 120178.
- Urquhart, A. (2018). What causes the attention of Bitcoin?. *Economics Letters, 166*, 40-44
- Wang, Z., Jiang, C., & Zhao, H. (2021). Know Where to Invest: Platform Risk Evaluation in Online Lending. *Information Systems Research, 33(3)*, 765-783.
- White, R., Marinakis, Y., Islam, N., & Walsh, S. (2020). Is Bitcoin a currency, a technology-based product, or something else?. *Technological Forecasting and Social Change, 151*, 119877.
- Yang, R., Yu, L., Zhao, Y., Yu, H., Xu, G., Wu, Y., & Liu, Z. (2020). Big data analytics for financial Market volatility forecast based on support vector machine. *International Journal of Information Management, 50*, 452-462.
- Zhang, Z., Dai, H. N., Zhou, J., Mondal, S. K., García, M. M., & Wang, H. (2021). Forecasting cryptocurrency price using convolutional neural networks with weighted and attentive memory channels. *Expert Systems with Applications, 183*, 115378.
- Zinovyeva, E., Härdle, W. K., & Lessmann, S. (2020). Antisocial online behavior detection using deep learning. *Decision Support Systems, 138*, 113362.

Abstract

The Prediction of Cryptocurrency Prices Using eXplainable Artificial Intelligence based on Deep Learning

Taeho Hong* · Jonggwan Won** · Eunmi Kim*** · Minsu Kim****

Bitcoin is a blockchain technology-based digital currency that has been recognized as a representative cryptocurrency and a financial investment asset. Due to its highly volatile nature, Bitcoin has gained a lot of attention from investors and the public. Based on this popularity, numerous studies have been conducted on price and trend prediction using machine learning and deep learning. This study employed LSTM (Long Short Term Memory) and CNN (Convolutional Neural Networks), which have shown potential for predictive performance in the finance domain, to enhance the classification accuracy in Bitcoin price trend prediction. XAI(eXplainable Artificial Intelligence) techniques were applied to the predictive model to enhance its explainability and interpretability by providing a comprehensive explanation of the model. In the empirical experiment, CNN was applied to technical indicators and Google trend data to build a Bitcoin price trend prediction model, and the CNN model using both technical indicators and Google trend data clearly outperformed the other models using neural networks, SVM, and LSTM. Then SHAP(SHapley Additive exPlanations) was applied to the predictive model to obtain explanations about the output values. Important prediction drivers in input variables were extracted through global interpretation, and the interpretation of the predictive model's decision process for each instance was suggested through local interpretation. The results show that our proposed research framework demonstrates both improved classification accuracy and explainability by using CNN, Google trend data, and SHAP.

Key Words : Cryptocurrency, XAI, Deep Learning, LSTM, CNN

Received : March 24, 2023 Revised : May 23, 2023 Accepted : May 29, 2023

Corresponding Author : Eunmi Kim

* College of Business Administration, Pusan National University

** Product Development Department, Korea Credit Bureau

*** Corresponding Author: Eunmi Kim

Institute of Management Research, Pusan National University
2, Busandaehak-ro 63 beon-gil, Geumjeong-gu, Busan 46241, Korea
Tel: +82-51-510-2531, E-mail: keunmi100@pusan.ac.kr

**** College of Business Administration, Pusan National University

저 자 소개



홍 태 호

현재 부산대학교 경영학과 교수로 재직 중이다. KAIST에서 경영정보시스템을 전공하여 공학석사와 공학박사를 취득하였다. 주요 관심분야는 비즈니스 애널리틱스, 딥러닝, 오피니언 마이닝, CRM 등이다. 주요 논문을 Expert Systems, Expert Systems with Applications, Information Processing & Management, Asia Pacific Journal of Information Systems, 지능정보연구, 정보시스템연구 등에 게재하였다.



원 종 관

부산대학교 경영학과에서 석사학위를 취득하였다. 현재 코리아 크레딧 뷰로(KCB) 상품 개발부에 근무 중이다. 주요 관심분야는 지능형 테크핀, 암호화폐 예측, 딥러닝, AI 등이다. 주요 논문을 지식경영연구, 정보시스템연구, 한국IT서비스학회지 등에 게재하였다.



김 은 미

부산대학교 경영학과에서 석사학위와 박사학위를 취득하였다. 현재 부산대학교 경영연구원 연구교수로 재직하고 있으며 주요 관심분야는 비즈니스 애널리틱스, 딥러닝, 소셜 미디어, CRM 등이다. 주요 논문을 Expert Systems with Applications, Asia Pacific Journal of Information Systems, 인터넷전자상거래연구, 정보시스템연구, 지능정보연구, 지식경영연구 등에 게재하였다.



김 민 수

부산대학교 경영학과에서 학사학위를 취득하였다. 현재 부산대학교 경영학과 경영정보 전공 석사과정에 재학 중이다. 주요 관심분야는 비즈니스 애널리틱스, 신용평가, 딥러닝 등이다.