

딥러닝을 활용한 자산분배 시스템

(Portfolio System Using Deep Learning)

김 성 수¹⁾, 김 종 인^{2)*}, 정 기 철³⁾

(Kim SungSoo, Kim Jong-In, and Jung Keechul)

요 약 딥러닝 네트워크 기반의 알고리즘의 발전으로 인공지능은 전세계적으로 빠른 성장세를 보이고 있다. 그 중 금융은 인공지능이 가장 많이 활용될 분야로 예상되고 있으며 최근 많은 연구가 되고 있다. 기존의 딥러닝을 사용한 재무 전략은 단일 종목에 대한 주가 예측에만 치중되어 있어 변동성에 취약하다. 따라서 본 연구는 딥러닝을 이용하여 펀드 구성 종목을 산출하고 종목들을 분산 투자하여 ETF 상품을 구성하는 모델을 제안한다. 실험 결과로 제안하는 모델을 통해 코스피 100 지수를 대상으로 하는 성능을 분석하며 수익률 또는 안정성 측면에서 향상된 결과를 확인하였다.

핵심주제어 : 자산분배, 딥러닝, 오토인코더, ETF

Abstract As deep learning with the network-based algorithms evolve, artificial intelligence is rapidly growing around the world. Among them, finance is expected to be the field where artificial intelligence is most used, and many studies have been done recently. The existing financial strategy using deep-run is vulnerable to volatility because it focuses on stock price forecasts for a single stock. Therefore, this study proposes to construct ETF products constructed through portfolio methods by calculating the stocks constituting funds by using deep learning. We analyze the performance of the proposed model in the KOSPI 100 index. Experimental results showed that the proposed model showed improved results in terms of returns or volatility.

Key Words : Portfolio, Deep Learning, Autoencoder, ETF

* Corresponding Author : eyezzang@gmail.com

+ 본 연구는 과학기술정보통신부 및 정보통신기술진흥센터의 SW 중심대학사업의 연구결과로 수행되었음(2018-0-00209-001)

This research was supported by the MSIP(Ministry of Science, ICT & Future Planning), Korea, under the National Program for Excellence in SW(2018-0-00209-001) supervised by the IITP(Institute for Information & communications Technology Promotion)

Manuscript received December 14, 2018 / revised January 11, 2019 / accepted February 12, 2019

1) 숭실대학교 글로벌미디어학부, 제1저자

2) 숭실대학교 글로벌미디어학부, ☞Fait 대표, 교신저자

3) 숭실대학교 글로벌미디어학부, 공동저자

1. 서 론

딥러닝 네트워크 기반의 알고리즘이 발전됨에 따라 인공지능은 전 세계적으로 빠른 성장세를 보이고 있다. 글로벌 분석 기업 IDC(International Data Corporation)는 세계 인공지능 시스템의 규모를 2016년 약 9조원에서 2022년 약 141조원에 이를 것으로 추정하고 있다. 인공지능은 기존 IT 분야에 한정되어 사용되는 것뿐 아니라 생산, 마케팅, 유통 등 다양한 영역의 의사결정 부분에

활용되고 있다[1].

그 중 금융은 인공지능이 가장 많이 활용될 분야로 예상되고 있어 최근 많은 연구가 되고 있으며, 금융 분야의 업무 자동화, 금융 서비스, 신용평가, 트레이딩, 준법 감시 등 다양한 업무에 머신러닝 기반 인공지능이 활용되고 있다[2]. 로보어드바이저 시장은 2016 국내에 도입된 이후 2018년 1조원 시장에서 2025년에 30조원까지 성장할 것으로 예상되고 있다. 이를 증명하듯이 다수의 금융회사들은 자체 개발 혹은 인공지능 전문업체와의 협업으로 로보어드바이저 상품을 제작하고 있다[3]. 현재 많은 로보어드바이저는 CNN, AE, LSTM 등 딥러닝 신경망에 기반한 주가 예측, 위험 탐지, 종목 추천 시스템을 활용한 상품들을 고객들에게 제공하고 있다.

본 논문은 딥러닝을 활용한 금융 투자 시스템을 개발하는 것을 목적으로 한다. 금융 투자방법은 기본적 분석과 기술적 분석 2 부분으로 나눌 수 있다. 기본적 분석이란 주식 시장에서 증권의 가격이 증권의 내재가치와 일치하지 않을 수 있다는 전제하에 PBR, PER과 같은 증권의 내재가치를 분석하는 방법이다. 기술적 분석은 과거의 증권가격 및 거래량 추세와 변동성에 대한 정보를 이용하여 미래 증권가격의 변화를 예측하는 분석 기법이다. 관련된 연구들은 다음과 같다. 2012년 황련희 등은 방향성 거리함수를 사용하여 중국의 상업 은행 효율성을 분석하여 국유상업은행의 주식제 개편이 은행효율성 향상에 영향을 미치는 것을 확인하였다[4]. 2016년 반주일 등은 인터넷 포털사이트에서의 피검색빈도와 주식 수익률을 분석하는 연구를 하였으며 피검색빈도가 높은 기업일수록 차주의 주간 수익률이 높음을 확인하였다[5]. 2010년 김선웅, 안현철은 기술적 지표를 사용하여 주가를 예측하는 기존의 논문과 달리 비가격 지표들을 연동하여 주가 예측을 시도한 실험 결과, 높은 정확도와 더불어 비가격 지표들의 시장 예측에 대한 효용성을 확인하였다[6]. 2017년 이우식은 비지도 학습 방법 중 하나인 은닉 노드에 핵심 특성에 대한 압축된 표현을 저장하는 오토인코더를 통하여, 코스피 지수를 예측하는 연구를 하였으며, 실험 결과 79%의 예측 정밀도를 보였다[7]. 2004년 김유일 등은 SV

M과 신경망을 통하여 코스피 200 지수를 예측하는 연구를 진행하여, 코스피 200 데이터를 입력값으로 받고 일주일 후의 값을 예측하는 모델을 만들었으며 신경망, SVM 모두 예측률이 50%를 넘겼다[8]. 2002년 김현수 등은 인공 신경망을 이용하여 코스피 200 주가지수 선물의 가격 결정성을 실증 분석하는 연구를 하여, 입력 변수의 개수와 신경망의 성능 사이의 상관관계를 분석하였으며, 입력 변수가 7개인 경우 인공 신경망 모형이 일반 모형보다 좋은 성능을 보이는 것을 확인 하였다[9]. 2018년 주일택, 최승호 및 2017년 신동하 등은 RNN과 LSTM을 이용하여 단일 종목의 주가를 예측하는 모델을 만들었으며, 예측된 주가 그래프가 높은 수준으로 실제 주가와 유사함을 확인하였다[10,11]. 2017년 김성수, 홍광진은 LSTM 신경망을 이용하여 코스피 200 주가지수 선물의 가격 예측 연구를 하였다. 이 연구는 1ong position을 사용할 경우 약 0.54 포인트의 수익을 보이는 것을 확인하였다[12].

위의 연구들은 공통적으로 단일 종목에 대한 주가 방향성 예측을 하는 것에 초점을 맞추고 있다. 단일 종목에만 투자를 할 경우 국내, 국제 금융시장의 변동성이 큰 시기에 투자한 종목이 급락할 위험성이 크다는 문제점을 지닌다. 따라서 단일 종목의 변화를 예측하는 시스템은 큰 손실이 발생할 가능성을 내재하는 문제점을 지닌다. 그에 따라 딥러닝을 활용한 금융 시스템도 단일 종목이 아닌 분산 투자를 목적으로 하는 모델의 필요성이 증대되었다. 미래에셋 대우는 인공지능을 이용하여 펀드의 구성 종목을 선택하거나 구성 종목의 비율을 조정한 상품을 출시하였고, 1년 수익률 1.73%를 기록하였다. 이와 같은 인공지능을 활용한 분산투자 방법과 관련된 연구로 J.B.Heaton 등은 오토인코더를 사용하여 현재 판매되는 ETF 상품의 구성 종목들의 비율을 재조정하여 더 높은 수익률을 얻는 ETF 상품을 만드는 시스템에 대한 연구를 진행하였으며, 표본 추출된 각 구간에 있어서 대부분의 경우 타겟 ETF 상품보다 높은 수익률을 확인하였다[13]. 2018년 유재필, 신현준은 J.B Heathon의 아이디어를 국내 ETF 상품에 적용하는 실험을 하였으며, 딥러닝을 이용한 포트폴리오 방법이 국내 금융 시

장에도 효과가 있음을 확인하였다. 하지만 위의 연구는 시스템을 통해 최종적으로 만들어지는 새로운 펀드에 각 종목 변수가 몇%의 가중치로 구성되어 있는지 알기 어려워 투자자가 오토인코더로 만들어진 펀드를 실제로 구성하기 어렵다는 문제점을 지닌다[14].

본 논문에서는 인공 신경망을 활용한 ETF 상품을 만드는 포트폴리오 시스템을 제안한다. J.B Heathon의 방법론에 따라 오토 인코더를 통해 펀드를 구성할 변수를 선택하고, 선택된 변수들을 기존의 금융 포트폴리오 방법을 통해 구매 가능한 펀드를 구성하는 것을 목적으로 한다. 본 논문의 순서는 다음과 같다. 첫째 ETF 상품 개발 시스템의 구조에 대하여 설명하고 둘째 본 연구에 사용하는 데이터를 처리하는 부분에 관하여 설명한다. 셋째로 실험에 대한 결과를 분석하며 마지막으로 본 연구에 대한 결론을 적는다.

2. 딥러닝 자산배분 시스템

2.1 시스템 구성

본 논문은 가격지표 만으로 ETF의 종목을 선택 가능한 Heathon의 방법론을 활용하여 딥러닝 신경망을 통해 코스피 100지수의 종목들 중 일부 종목을 추출하고, 추출된 종목들을 금융공학의 포트폴리오 전략을 활용해 구현 가능한 ETF 상품을 만드는 시스템을 제안한다.

본 시스템의 주 데이터인 주가 데이터는 시계열 데이터를 활용하기 때문에 시계열 처리에 적합한 신경망 구조가 필요하다. 본 시스템은 주가 그래프의 장기적인 움직임을 판단하는 것을 목적으로 하기 때문에 장기 기억에서 기울기 손실 문제가 있는 LSTM 대신 오토인코더 신경망 구조를 사용한다. 오토인코더는 딥러닝의 대표적인 비지도 학습 알고리즘으로써 데이터를 간의 선형 및 비선형적인 관계를 표현하는데 적합하며, 데이터의 잡음 제거와 패턴 추론에 강점을 지니고 있다.

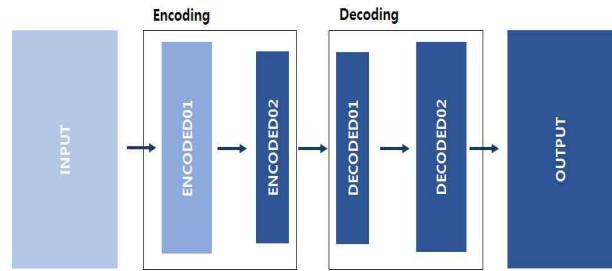


Fig. 1 Autoencoder Model Structure

오토인코더 신경망은 Fig. 1과 같이 신경망 층 두 개를 대칭되게 붙여 놓은 구조로 입력 층을 통해 들어온 데이터는 인코딩 층을 거쳐 특징 값을 구하고 디코딩 층에서는 특징 값을 복원하여 최종 출력 층에서 원본과 최대한 유사하도록 학습하는 신경망 구조이다. 따라서 과거의 주가 데이터의 움직임을 학습해 미래의 주가의 추세를 예측하는데 적합한 신경망 구조로 사용될 수 있다.

본 연구에서 제안하는 딥러닝 자산배분 시스템은 오토인코딩과 자산배분의 2가지 단계로 구성되어 있으며, 본 연구에서 사용하는 데이터는 2014년 1월 2일에 코스피 100 지수에 구성된 종목들의 일별 주가 데이터이다.




Fig. 2 Deep Learning Portfolio Process

본 연구에서 사용된 오토인코더 신경망은 합성곱 신경망을 기반으로 구성되어 있으며 각 층을 인코딩 2개 층과 디코딩 2개 층으로 구성되어 있다. 인코딩 첫 번째 층은 16개의 필터를 만들며 필터 사이즈는 7의 값을 갖도록 한다. 2번째 인코딩 층은 8개의 필터를 만들며 길이 값 13의 필터 사이즈를 갖는다. 디코딩 층은 인코딩 층과 대칭된 형태로 구축한다. 모든 신경망 층은 오버피팅을 방지하기 위해 12 정규화를 사용하였다. 본 논문은 위와 같이 설계된 모델을 800 epochs

동안 학습을 진행하였다. 오토인코더 신경망의 인코딩 층과 디코딩 층의 활성화 함수로는 ReLU를 사용하였으며 출력층의 활성화 함수는 선형 함수를 사용하였다. 손실함수로는 Mean Squared Error를 사용하였고, 옵티마이징 함수로는 Adam Optimizer 함수를 사용했다.

Fig. 3과 같은 두 번째 단계인 자산배분 구간에서는 학습구간의 데이터에서 2 norm difference 오차 값이 가장 작은 상위 15개 종목과 포트폴리오의 기본 속성인 다각화를 위해 오차가 가장 큰 상위 15, 35, 75개를 함께 섞은 포트폴리오를 생성한다[13,14]. 오토인코딩 구간에서 선택된 종목들을 동일비중 포트폴리오, 시가총액 가중 포트폴리오, 평균-분산 포트폴리오 총3가지 방법으로 하나의 ETF 상품으로 만드는 작업을 수행한다.

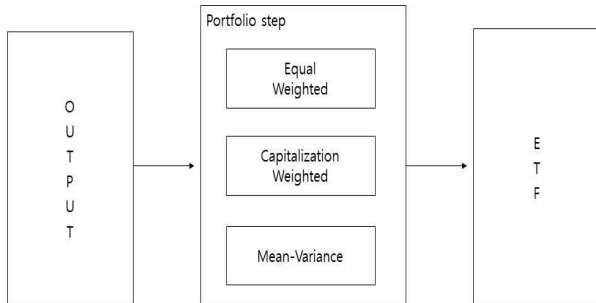


Fig. 3 Portfolio Selection Model

동일비중 포트폴리오(Equal-weighted)는 SNP500 지수를 만드는 방법으로 위험자산 N개에 대해 각 종목의 비중 W를 1/N로 동일하게 구성 [식(1)]하는 것이다.

$$W_x = \frac{1}{N} \text{ 식(1)}$$

시가총액 가중비중 포트폴리오(Capitalization-Weighted)는 KOSPI 지수를 만드는데 사용하는 방식으로 종목 x의 구매비중 W를 위험자산 x의 시가총액을 구성 종목들의 시가총액 총합에서 나눈 값[식-2]으로 사용하는 방식이다.

$$W_x = \frac{c_x}{\sum c_x} \text{ (} C_x \text{: 종목 } x \text{의 시가총액) 식(2)}$$

평균-분산 포트폴리오(Mean-Variance) 전략은 N 개의 위험자산에 대하여 각 종목들의 평균과 분산을 사용하여 최적의 포트폴리오를 찾는 방법을 의미한다. 본 논문에서는 샤프지수를 최대화하는 포트폴리오 전략[식-3]을 사용한다.

$$W_x = MAX\left(\frac{mean(R_x) - R_f}{\sqrt{VAR}}\right)$$

(r_x : 종목 x 수익률, r_f : 무위험수익률, var : 종목분산) 식(3)

3. 실험 방법 및 분석

본 논문에서 딥러닝을 이용한 포트폴리오 분석을 위해 국내 증권시장의 대표지수인 코스피 100의 구성 종목 중 일부를 추출하여 더 좋은 수익률을 보일 수 있는 ETF 상품을 개발하는 것을 목적으로 한다. 실험 결과는 딥러닝 기반의 포트폴리오 시스템을 통해 만든 ETF 상품과 국내 대표지수 중 하나인 코스피 100과의 비교분석을 통해 설명하려 한다. 실험에 사용된 코스피 100 지수는 국내 증시에 시가총액 기준 100위 안에 드는 종목들을 가지고 펀드를 만든 것이기 때문에 코스피 100 지수의 구성 종목의 변동이 잦다. 따라서 본 논문은 2014년 1월 2일 기준 코스피 100 지수의 구성 종목들만을 가지고 진행되었다.

연구의 실험 모델은 코스피 100 구성 종목들의 주가 데이터를 2014년 1월 2일부터 2018년 4월 17일 총 1054 거래일의 데이터를 사용하였다. 데이터는 첫 800 거래일을 기준으로 training data와 test data로 나누었으며 실험 모델의 신경망 과적합을 방지하기 위해 training data중 마지막 150일은 validation data로 사용하였다. 시계열 데이터인 주가 데이터를 사용하기 때문에 데이터를 섞지 않았다. 실험은 데이터들 중 training data를 분류하여 학습하고 validation data에 성능이 좋은 모델을 추출해 test data에 적용하는 방식을 사용하였다. Test data는 2017년 4월 1일부터 2018년 4월 17일까지이며 이 시점에 계산된 구매비율로 구성된 펀드의 성능을 다양한 지표로 분석하는 것을 목적으로 하였다.

3.1 결정변수 설정

본 논문에서 제안하는 시스템은 과거 800 거래일을 학습하여 미래의 추가 추세를 예측하고 예측된 결과를 토대로 종목을 추출하고 추출된 종목의 구성 비율을 조정하여 새로운 ETF 상품을 만드는 것을 목적으로 한다. 본 실험에서는 3가지의 평가 지표(수익률, 샤프지수, 최대값 대비 하락률)를 통해 성능 평가를 하였다. 수익률은 본 포트폴리오가 얼마만큼 수익을 더 보였는가에 대한 중요한 지표이다. 수익률은 복리의 성격을 지니기 때문에 기하 평균을 사용하여 측정하였다. 기하평균의 계산식은 식(4)와 같다.

$$Mean = \sqrt[n]{\prod_i price_{x,i}}$$

($price_{x,i}$: I 시점의 종목 x의 가격) 식(4)

샤프지수는 위험 자산에 투자함으로써 얻은 초과 수익의 정도를 나타내는 지표로 윌리엄 샤프(William F. Sharpe) 교수가 펀드 평가를 위해 개발한 지수이다. 샤프지수가 높을수록 수익률 변동 폭이 크지 않으면서 높은 수익을 올리는 펀드라고 보면 된다. 샤프 지수의 계산식은 다음과 같다.

$$SharpeRatio = \frac{ER_x - ER_f}{\sigma_x}$$

(σ_x : 자산의 표준편차, ER_x : 자산수익률, ER_f : 무위험수익률) 식(5)

마지막으로 최대값 대비 하락률은 투자 기간 중 포트폴리오의 고점에서 저점까지 최대 누적 손실을 의미하며 만들어진 펀드가 하락장에서 얼마나 가격 방어를 할 수 있는지를 나타내는 지표로 활용된다. 최대값 대비 하락률의 계산식은 다음과 같다.

$$MDD = MAX\left(\frac{Price_{x,i} - Peakprice_{x,i}}{Peakprice_{x,i}}\right)$$

($Price_{x,i}$: i 시점 x의 가격, $Peakprice_{x,i}$: i 시점 x의 최고가격) 식(6)

3.2 결과분석

본 논문에서 제안하는 오토인코더 모델을 통해 변수를 추출한 결과 추출된 종목은 Table 1과 같다. 선택된 종목들은 동일비중 포트폴리오, 시가총액 가중 포트폴리오, 평균-분산 포트폴리오 방식을 통해 ETF 상품으로 만들어진다.

본 시스템은 ETF 구성종목 개수를 각각 30, 50, 100개를 사용하여 실험을 진행하였으며 ETF 상품들의 성능 분석은 앞서 설명한 평균수익률, 샤프비율, 최대값 대비 하락률을 통하여 이뤄지며, 결과는 Table 1과 같다.

식(4)에서 도출된 평균 수익률 관점에서 성능 평가를 하였을 때, 평균-분산 포트폴리오 방식으로 형성된 펀드가 구성 대비 높은 수익률을 보임을 확인 하였다.

식(5)에 따라 샤프비율 관점에서 분석 할 때 동일비중 포트폴리오를 통해 만든 ETF가 구성 대비 높은 성능을 보이는 것으로 확인 하였다. 식(6)에 따라 최대값 대비 하락률을 기준으로 보았을 때 시가총액 가중 포트폴리오가 30, 50개 종목을 선택하는 모델에서 가장 높은 성능을 보임을 확인하였다. 본 실험의 결과 30개 종목을 mean-variance 방법론으로 만든 ETF가 좋은 성능을 보임을 확인하였다.

Table 1.1 Result of Experiment(30 stocks)

Funds	Average Return	Sharpe ratio	MDD
KOSPI100	11.48	21.07	-11.01
Equal-Weighted	8.82	26.89	-10.96
Capitalization-Weighted	9.78	22.27	-10.80
Mean-Variance	17.75	10.56	-14.30

Table 1.2 Result of Experiment(50 stocks)

Funds	Average Return	Sharpe ratio	MDD
KOSPI100	11.48	21.07	-11.01
Equal-Weighted	8.79	29.07	-10.06
Capitalization-Weighted	8.52	24.91	-9.83
Mean-Variance	17.77	9.97	-19.8

Table 1.3 Result of Experiment(100 stocks)

Funds	Average Return	Sharpe ratio	MDD
KOSPI100	11.48	21.07	-11.01
Equal-Weighted	7.33	26.89	-10.61
Capitalization-Weighted	10.92	22.27	-10.66
Mean-Variance	14.74	12.24	-20.52

본 논문에서 제시하는 모델을 실험한 결과 실험 기간의 모든 구간에서 평균-분산 포트폴리오를 통해 구성된 펀드가 가장 높은 수익률을 보였지만 반대로 가장 낮은 샤프비율을 보이며 가장 높은 최댓값 대비 하락률을 보이는 등 변동성이 큰 단점이 존재함을 확인하였다. 또한 동일비중 포트폴리오 및 시가총액 가중 포트폴리오를 통해 만들어진 펀드들은 코스피 100 지수보다 더 높은 샤프비율을 보이고 더 낮은 최댓값 대비 하락률을 보이는 등 변동성이 더 낮은 펀드를 만들 수 있음을 확인하였지만 코스피 100 지수에 비해 더 낮은 수익률을 보임을 확인하였다. 따라서 본 논문에서 제안하는 시스템을 사용하여 포트폴리오를 만들 경우 더 높은 수익률 혹은 더 적은 변동성을 지닌 펀드를 만들 수 있음을 확인하였다.

Table 2 ETF Components(30)

한온시스템	포스코 대우	한화생명	LG상사	한화케미칼	신한지주
미래에셋대우	두산인프라코어	기업은행	동국제강	대우건설	삼성중공업
하나금융지주	제일기획	삼성화재	CJ	SK.1	현대글로비스
엔씨소프트	LG화학	롯데케미칼	CJ제일제당	농심	아모레퍼시픽
고려아연	KCC	NAVER	LG생활건강	롯데칠성	롯데정밀화학




Fig. 4 Graphs of Funds Return

4. 결론


세계 인공지능 시스템의 규모는 2022년 약 141조원에 이를 것으로 추정될 정도로 인공지능은 전 세계적으로 빠른 성장세를 보이고 있다. 금융은 인공지능이 가장 많이 활용될 분야로 예상되고 있으며 대표적으로 로보어드바이저 시장은 2025년에 30조원까지 성장할 것으로 예상되고 있다. 본 논문에서는 오토인코더 신경망을 통해 판매되고 있는 ETF 상품의 구성 종목 변수들을 추출하여 더 나은 성능의 펀드를 만드는 시스템에 대하여 제안하였다. 실험 결과 평균-분산 포트폴리오를 통해 구성된 펀드가 가장 높은 수익률을 보임과 동시에 가장 낮은 샤프비율, 가장 큰 변동성을 보임을 확인하였다. 동일비중 포트폴리오 및 시가총액 가중 포트폴리오를 통해 만들어진 펀드들은 낮은 변동성, 더 낮은 수익률을 보임을 확인하여 따라서 제안하는 시스템을 사용하여 포트폴리오를 만들 경우 더 높은 수익률 혹은 더 적은 변동성을 지닌 펀드를 만들 수 있음을 확인하였다.

본 실험은 기간 변화에 따른 코스피 100 구성 종목 변화에 대응하지 않고 고정된 종목만을 사용한다. 그에 따라 펀드의 구성종목 변화에 대응하는 추가적인 시스템 연구가 필요하다. 본 연구에서 제안한 실험 모델은 펀드를 구성하는 고정종목에 대해 각 종목들의 자산구성을 재조정(Rebalancing)하는 시스템을 고려하지 않았다. 이에 따라 펀드 구성종목 변화 대응에 추가적인 연구를 통하여 펀드 구성 종목의 변경에 따른 운영자산 재조정(Rebalancing) 시스템 구축을 예정이다. 차후 특정 펀드의 구성종목이 아닌 유가증권시장에 상장된 전 종목에 본 모델을 적용하여 펀드를 구성하는 시스템 구축을 예상된다.

References

[1] Shim, H. and Kim, K., "A Business Model Using Artificial Intelligence (AI) of Korean Companies," KITA, TRADE FOCUS, Vol. 2,

- No. 97, 2018.
- [2] "Status of Machine Learning at Home and Abroad in the Field of Finance," FSI, 2017.
- [3] KEB Hana Bank, "2018 Korean Roboadviser Report," KEB Hana Bank HAI Robo Center, 2018.
- [4] Hwang, R., Kim, S., Lee, D., and Nam D., "A Directional Distance Function Approach on the Efficiency of Chinese Commercial Banks," *Journal of the Korea Industrial Information Systems Research*, Vol. 17, No. 2, pp. 81-94, 2017.
- [5] Ban, J., Kim, M., and Jeon, Y., "Search Frequency in Internet Portal Site and the Expected Stock Returns," *Journal of the Korea Industrial Information Systems Research*, Vol. 21, No. 5, pp. 73-83, 2016.
- [6] Kim, S. and Ahn, H., "Development of an Intelligent Trading System Using Support Vector Machines and Genetic Algorithms," *Journal of Intelligence and Information System*, Vol. 16, No. 1, pp. 71-92, 2010.
- [7] Lee, W., "A Deep Learning Analysis of the KOSPI's Directions," *Journal of the Korean Data and Information Science Society*, Vol. 28, No. 2, pp. 287-295, 2017.
- [8] Kim, Y., Shin, E., and Hong, T., "Comparison of Stock Price Index Prediction Performance Using Neural Networks and Support Vector Machine," *The Journal of Internet Electronic Commerce Research*, Vol. 4, No. 3, pp. 221-243, 2004.
- [9] Kim H., Kim K., and Jeong D., "A Study on the Price Determination of KOSPI 200 Futures using Artificial Neural Network Model," *Korea Insurance Research Institute, Insurance Financial Research*, Vol. 13, No. 3, pp. 155-176, 2003.
- [10] Joo, I., Choi, S., "Stock Prediction Model based on Bidirectional LSTM Recurrent Neural Network," *Journal of Korea Institute of Information, Electronics, and Communication Technology*, Vol. 11, No. 2, pp. 204-208, 2018.
- [11] Shin, D., Choi, K., and Kim, C., "Deep Learning Model for Prediction Rate Improvement of Stock Price Using RNN and LSTM," *Journal of Advanced Information Technology and Convergence*, Vol. 15, No. 10, pp. 9-16, 2017.
- [12] Kim, S., Hong, K., "Development and Performance Analysis of Predictive Model for KOSPI 200 Index using Recurrent Neural Networks," *Journal of the Korea Industrial Information Systems Research*, Vol. 22, No. 6, pp. 23-29, 2017.
- [13] Heaton, J. B., Polson, N. G., and Witte, J. H., "Deep Portfolio Theory," University of Chicago, 2016.
- [14] Ryu, J., Shin, H., "Portfolio Selection Strategy Using Deep Learning," *Journal of Information Technology and Architecture*, Vol. 15, No. 1, pp. 43-50, 2018.



김 성 수 (Kim SungSoo)

- 학생회원
- 숭실대학교 글로벌미디어학부 학사 과정
- 관심분야 : 인공지능, 금융공학, 패턴인식



김 중 인 (Kim Jong-In)

- 정회원
- 청운대학교 멀티미디어학과 학사
- 숭실대학교 미디어학과 석사
- (주) Fait 대표이사
- 관심분야 : 컴퓨터비전, HCI, 가상현실, 행동인식, 공간인식 인터페이스



정 기 철 (Jung Keechul)

- 정회원
- 경북대학교, 공학석사, 경북대학교, 컴퓨터공학 공학박사
- 경북대학교, 컴퓨터공학 박사 후 연구원
- PRIP Lab.,Michigan State University
- Michigan State University,USA
- 숭실대학교 IT대학 글로벌미디어학부 부교수
- 전공: 패턴인식, 인공지능
- Intelligent User Interface Group, (DFKI, 독일)
- Machine Understanding Division(Electro Technical Laboratory, 일본) 방문연구원
- SIAT(School of Interactive Art and Technology, SFU, 캐나다) 방문교수 역임.
- Michigan State University
- 관심분야 : 인공지능, 컴퓨터비전, HCI