

합성곱 신경망을 이용한 주가방향 예측: 상관관계 속성선택 방법을 중심으로

Stock Price Direction Prediction Using Convolutional Neural Network: Emphasis on Correlation Feature Selection

어 균 선 (Kyun Sun Eo)

성균관대학교 경영대학 박사과정

이 건 창 (Kun Chang Lee)

성균관대학교 글로벌 경영학과/삼성융합의과학원(SAIHST) 융합의과학과 교수, 교신저자

요 약

딥러닝(Deep learning) 기법은 패턴분석, 이미지분류 등 다양한 분야에서 높은 성과를 나타내고 있다. 특히, 주식시장 분석문제는 머신러닝 연구분야에서도 어려운 분야이므로 딥러닝이 많이 활용되는 영역이다. 본 연구에서는 패턴분석과 분류능력이 높은 딥러닝의 일종인 합성곱신경망(Convolutional Neural Network) 모델을 활용하여 주가방향 예측방법을 제안한다. 추가적으로 합성곱신경망 모델을 효율적으로 학습시키기 위한 속성선택(Feature Selection, FS)방법이 적용된다. 합성곱신경망 모델의 성과는 머신러닝 단일 분류기와 앙상블 분류기를 벤치마킹하여 객관적으로 검증된다. 본 연구에서 벤치마킹한 분류기는 로지스틱 회귀분석(Logistic Regression), 의사결정나무(Decision Tree), 인공신경망(Neural Network), 서포트 벡터머신(Support Vector Machine), 아다부스트(Adaboost), 배깅(Bagging), 랜덤포레스트(Random Forest)이다. 실증분석 결과, 속성선택을 적용한 합성곱신경망이 다른 벤치마킹 분류기보다 분류 성능이 상대적으로 높게 나타났다. 이러한 결과는 합성곱신경망 모델과 속성선택방법을 적용한 예측방법이 기업의 재무자료에 내포된 가치를 보다 정교하게 분석할 수 있는 가능성이 있음을 실증적으로 확인할 수 있었다.

키워드 : 합성곱신경망, 주가방향 예측, 머신러닝, 딥러닝, 속성선택, 앙상블

I. 서 론

매일 백만 달러이상의 금액이 거래되고 있는 전 세계 주식시장을 예측하는 것은 금융시장에서의 중요한 화두이다(Hoseinzade and Haratizadeh,

2019). 정확한 주가예측은 투자자에게 금전적 이익을 가져다 줄 수 있고, 반대로 위기를 피할 수 있도록 돕는다. 기존 문헌에서는 주식 시장을 분석할 때 두 가지 방법이 사용된다. 첫째는 주가 예측방법이고, 둘째는 주가방향 예측방법이다. 주가 예측방법과 주가방향 예측방법은 다음과 같은 차이가 있다. 주가 예측방법은 주가 그 자체를 예측하는 것이고, 주가방향 예측방법은 주가의 상승,

† 이 논문은 2019년 대한민국 교육부와 한국연구재단의 지원을 받아 수행된 연구임(NRF-2019S1A5A2A01046529).

유지, 하락을 예측하는 것이다.

최근 활발하게 연구되고 있는 딥러닝 기법은 주가방향 예측에 유용하게 사용된다. 딥러닝 기법은 인공신경망 알고리즘을 바탕으로 발전되었다. 딥러닝은 많은 양의 데이터를 학습시킬수록 효율적인 학습이 가능하다는 장점으로 인해 의료분야, 경제분야, 재무분야 등과 같이 다양한 분야에 적용되고 있다(Affonso *et al.*, 2017; Chang, 2017; Kraus and Feuerriegel, 2017; LeCun *et al.*, 1998; Yuan *et al.*, 2018).

기존의 딥러닝을 이용한 주가방향 예측연구는 소셜 미디어 사용자의 감성분석을 통한 주가방향 예측에 딥러닝 기법을 사용한 연구(Wang *et al.*, 2018), 인도의 증권거래소와 뉴욕증권거래소에서 거래되는 종가를 RNN(Recurrent Neural Network), LSTM(Long Short-Term Memory), 합성곱신경망으로 예측하는 연구(Hiransha *et al.*, 2018), 재무상태표를 이미지화하여 파산기업과 지속가능한 기업을 합성곱신경망으로 분류하는 연구가 있다(Hosaka, 2019).

반면, 주가방향 예측에서 또 다른 중요한 주제는 자동 속성 선택이다. 초기속성 구성단계에서는 전문가에 의해 속성이 구성된다. 그러나 충분한 지식과 경험을 가진 금융전문가에 의해 선택된 변수에도 불구하고 머신러닝을 위한 최선의 변수 구성은 아닐 수 있다. 그러므로 주식시장 예측을 위한 속성선택 방법은 시장예측에 유익해 보이는 여러 속성들 속에서 유용한 속성을 선택하는데 사용된다. 이에 따라 선택된 속성은 최종적으로 머신러닝 분류기를 이용한 예측에 사용된다(Lee, 2009). 본 연구에서 사용된 속성선택 방법은 상관관계 속성선택 방법(Correlation Based Feature Selection)이다.

주가방향 예측 연구에서는 딥러닝 기법이 활발하게 연구되고 있지만 특히, 속성선택을 적용한 합성곱신경망에 대한 연구는 미흡하다. 의료, 공학 분야와 달리 경영, 경제 분야에서는 합성곱신경망에 대한 연구가 부족하다. 따라서 경영, 경제 분야의 특성에 적합한 합성곱신경망을 이용한 연

구가 필요하다.

본 연구에서는 주가방향 예측을 위하여 속성선택을 적용한 합성곱신경망(Convolutional Neural Network) 모델이 사용된다. 본 연구에서 제안하는 모델의 성과를 객관적으로 검증하기 위해 기존 머신러닝 분류기를 벤치마킹한다. 벤치마킹한 분류기는 로지스틱 회귀분석, 의사결정나무, 인공신경망, 서포트 벡터머신, 아다부스트, 배깅, 랜덤포레스트이다. 따라서 본 논문의 연구질문(Research Question, RQ)는 다음과 같다.

RQ: 속성선택을 적용한 후의 속성을 사용하여 주가방향 예측 시, 합성곱신경망은 벤치마킹 분류기보다 높은 성능을 나타내는가?

본 연구의 구성은 다음과 같다. 제II장에서는 주가방향 예측에 대한 머신러닝 연구와 합성곱신경망이 적용된 연구, 그리고 합성곱신경망을 이용한 주가방향 예측연구에 대해 설명한다. 제III장에서는 본 연구에서 사용한 합성곱신경망 모델의 구조에 대해 설명하고 연구방법을 설명한다. 제IV장에서는 실증분석 결과 및 토의를 다루고, 마지막으로 제V장에서는 결론과 본 연구의 한계점과 향후 연구에 대해 제시한다.

II. 관련 연구

2.1 주가방향에 관한 선행연구

머신러닝 방법은 주가방향 예측에 유용하다는 것이 입증되었다(Hoseinzade and Haratizadeh, 2019). 특히, 인공신경망과 서포트 벡터머신을 이용한 방법론이 주가방향 예측을 위해 공통적으로 사용된다. 머신러닝을 활용한 주가방향 예측연구에는 다양한 방법론이 존재 한다. 인공신경망과 서포트 벡터머신을 통한 주가지수 예측(Kim, 2003), LDA (Linear Discriminant Analysis), QDA(Quadratic Discriminant Analysis)을 이용한 주가지수 방향예측(Ou

and Wang, 2009), 나이브 베이즈(Naive Bayes) K-최근접이웃과 같은 머신러닝 분류기를 사용한 주가지수 방향예측연구 등이 있다(Huang *et al.*, 2005). 주가방향 예측에 관한 선행연구는 다음 표 1에 제시하였다.

Patel *et al.*(2015)는 기술적 분석 데이터를 바탕으로 주가방향을 예측하였다. 인공신경망, 서포트 벡터머신, 랜덤포레스트(Random Forest), 그리고 나이브 베이즈(Naive Bayes) 등과 같은 머신러닝 분류기의 성능을 비교하였다. Ballings *et al.*(2015)

는 기업의 재무지표를 이용해 여러 머신러닝 분류기들로 분석하였다. 분석에 사용된 분류기는 로지스틱 회귀분석, 인공신경망, 서포트벡터머신, K-최근접이웃(K-Nearest Neighbor), 랜덤포레스트, 아다부스트, 커널팩토리(Kernel Factory)이다.

Joo and Choi(2018)는 양방향 LSTM 순환신경망을 이용하여 주가 예측하는 모델을 제안했다. 제안된 순환신경망은 주가와 거래량을 바탕으로 학습되어 실제 주가와 예측된 주가 간의 평균제곱근오차를 통하여 모델의 성능을 평가하는데 사용된다.

〈표 1〉 주가방향 예측에 관한 연구

Authors	Year	Stock	FS	Classifiers	Results
Kim	2003	stock price index		SVM, NN	SVM better than NN
Huang <i>et al.</i>	2005	stock market movement		SVM, LDA, QDA, NN	SVM with highest performance
Ou and Wang	2009	stock market index movement		NBN, LR, DT, SVM, LS-SVM	SVM, LS-SVM with highest performance
Patel <i>et al.</i>	2015	stock price direction		NN, SVM, RF	RF with highest performance
Ballings <i>et al.</i>	2015	stock price direction		LR, NN, SVM, KNN, RF, AB, KF	RF with highest performance
Qiu <i>et al.</i>	2016	stock index		ANN, GA-ANN, SA-ANN	GA-ANN and SA-ANN better than ANN
Zhong and Enke	2017	stock market index	PCA	ANN	PCA-ANN with highest performance
Chong <i>et al.</i>	2017	stock return	PCA, AE, RBM	ANN, DNN, DNN-AR(Autoregressive)	DNN better than DNN-AR
Eo and Lee	2017	stock price direction	CFS	DT, LR, NN, SVM, RF, AB, BA, ST	RF with highest performance
Joo and Choi	2018	stock price		Bidirectional LSTM-RNN, Un-Bidirectional LSTM-RNN	Bidirectional LSTM-RNN is better than Unidirectional LSTM-RNN
Hu <i>et al.</i>	2018	stock price		ISCA-BPNN, BPNN, GWO-BPNN, PSO-BPNN, WOA-BPNN, SCA-BPNN	ISCA-BPNN is best performance
This study		stock price direction	Correlation Based Feature Selection	LR, DT, NN, SVM, AB, BA, RF, CNN	CNN with highest performance

분석결과로는 양방향 LSTM이 단방향 LSTM 표를 사용한 모델보다 더 높은 정확성을 보였다. Chong *et al.*(2017)은 PCA(Principal Component Analysis), AE(Auto Encoder), RBM(The Restricted Boltzmann Machine) 등과 같은 비지도 속성 재표현 방법으로 속성을 추출하였다. 추출한 속성은 DNN(Deep Neural Network) 모델에 학습시켜 주가 방향을 예측하는데 사용된다. Hu *et al.*(2018)은 구글 트렌드, S&P500과 다우존스산업평균지수(Dow Jones Industrial Average, DJIA)를 예측하는 사인 코사인 알고리즘(Improved Sine Cosine Algorithm, ISCA)을 제안했다. 사인 코사인 알고리즘과 역전파신경망(Back Propagation Neural Network, BPNN)를 결합한 모델은 높은 예측 성공률을 보여주었다.

Qiu *et al.*(2016)는 일본 닛케이 225 지수의 반등을 예측하기 위해 인공신경망을 적용했다. 인공신경망 모델은 전통적인 신경망학습 방법인 BP(Back Propagation)학습 알고리즘을 이용하여 닛케이 225 지수의 수익을 예측하는데 사용된다. 추가적으로 GA(Genetic Algorithm)와 SA(Simulated Annealing)이 적용된 인공신경망 모델은 예측 정확도를 높일 수 있었고, BP 알고리즘의 문제를 해결시킬 수 있었다.

Zhong and Enke(2017)은 S&P 500지수 ETF(SPY) 수익률의 일일 변동방향을 예측하는 머신러닝 분석프로세스를 제안하였다. 분석에 사용된 60개의 금융 및 경제 변수는 머신러닝 알고리즘의 학습에 사용되었다. 제안된 프로세스에는 데이터 구조를 단순화하고 재정렬하기 위한 차원축소기법이 적용되었다. 분석 프로세스에 적용된 3가지 차원축소 기법은 PCA, FRPCA(Fuzzy Robust Princial Component Analysis), KPCA(Kernel-Based Princial Component Analysis) 등이 있다. 차원 축소 기법이 적용된 생성된 12개의 데이터 셋은 인공신경망에 학습되어 수익의 일일방 향 예측에 사용된다.

차원 축소 방법을 적용한 인공신경망 모델과 적용하지 않은 경우의 신경망 모델의 성능을 비교한 결과는 PCA를 적용한 인공신경망이 다른 조합보다 약간 높은 분류 정확도를 보였다(Zhong and

Enke, 2017).

본 연구는 Eo and Lee(2017) 연구를 확장한 것이다. 즉, 2008년부터 2015년도 까지 근속된 KOSPI 상장 유통업 총 37개 회사를 대상으로 하였으며, 자료갯수는 1,184개이고 변수 개수는 109개이다. 자료대상은 분기별 재무자료와 주식종가로 구성하였다. 변수에 관한 상세한 내용은 <표 4>와 같다. Eo and Lee(2017) 연구에서는 주가의 상승율만 고려하였으나, 본 연구는 주가의 하락율까지 고려한 점에서 본 연구는 기존연구와 차별화된다. 이를 보다 자세히 설명하면, Eo and Lee(2017)에서는 타겟변수를 2클래스(25% 이상, 25% 미만), 3클래스(35% 이상, 15% 이상, 15% 미만), 4클래스(35% 이상, 25% 이상, 15% 이상, 미만), 5클래스(35% 이상, 25% 이상, 15% 이상, 5% 이상, 5% 미만)와 같이 구성하였다. 반면, 본 연구는 타겟변수를 2클래스(15% 이상, 15% 미만), 3클래스(15% 이상, -15% 이상, -15% 미만), 마지막으로 5클래스(30% 이상, 15% 이상, -15% 이상, -30% 이상, -30% 미만)로 구성하므로써 주가방향의 상승과 하락을 동시에 고려한 점에서 선행연구와 차별화된다.

2.2 합성곱신경망(Convolutional Neural Network) 관련 연구

2.2.1 합성곱신경망을 이용한 연구

합성곱신경망은 패턴분석 및 이미지 분류에 탁월한 성능을 나타낸다. 특히, 의학분야에서는 CT와 MRI 등 이미지가 합성곱신경망에 활발하게 적용되고 있다. 다음 <표 2>는 합성곱신경망을 이용한 연구이다.

Ting *et al.*(2019)은 유방암 분류를 위한 CNNI-BCC(Convolutional Neural Network Improvement for Breast Cancer Classification)을 제안하였다. 유방암 진단 전문가들은 CNNI-BCC을 유방암 병변 분류를 위해 사용했다. CNNI-BCC는 입력된 유방암 의료 영상을 분석하여 악성, 양성, 건강한 환자 분류에 사용된다.

〈표 2〉 합성곱신경망에 관한 연구

Authors	Year	Data	Classification	Convolution Neural Network Method
Ting <i>et al.</i>	2019	Breast Cancer	malignant, benign, and healthy patients	CNNI(Convolution Neural Network Improved)
Sellami and Hwang	2019	ECG	nonectopic, supraventricular ectopic beat, Ventricular ectopic beat, Fusion beat, Unknown beat	CNN-5layers, CNN-7layers, CNN-9layers, CNN-11layers
Pour and Seker	2020	Skin Lesion	globules, streaks	CNN-7layers, CNN-7layers+transform domain, CNN-15layers, CNN-15layers+transform domain.
Soomro <i>et al.</i>	2019	Retinal Blood Bessels	retinal blood vessels segmentation	PCA-CNN
Dang <i>et al.</i>	2019	Face Image	face image manipulation detection	CNN for MANFA(Manipulated Face), HF-MANFA(Hybrid-MANFA that uses Adaptive Boosting and XGBoost)
Yang <i>et al.</i>	2019	Human Activities in Videos	human action recognition	Asymmetric 3D-CNN
Moghaddam <i>et al.</i>	2020	Fault Diagnosis	18 Fault types	CNN

Sellami and Hwang(2019)는 합성곱신경망에 기반한 발전된 신경망을 제시하여 심장박동 분류방법을 제시하였다. 심전도 데이터는 정상 심박수보다 비정상 심박수가 훨씬 적게 나타나기 때문에 데이터의 불균형으로 인하여 정확한 분류가 어렵다. 제안된 심장박동 모델은 일괄 손실함수를 적용하여 데이터 클래스 간의 불균형을 극복하였고 예측성능이 향상되었다. 합성곱신경망에 대한 연구는 분류뿐만 아니라 물체 탐지에서도 엄청난 성공을 거두었다. 합성곱신경망은 피부암 병변 분할을 위한 자동진단 시스템에 적용되어 피부암의 조기 발견에 크게 기여하였으며, 결과적으로 성공적인 치료까지 이끌었다. 병변 세분화는 피부암 분석 단계의 초기에 해당한다. 피부암 분석용 데이터는 수량이 적을 뿐만 아니라 빛, 색, 크기, 표시와 같은 다양한 이미지가 포함된다. 이 때문에 연구자들은 병변 세분화를 위하여 광범위한 확대 및 전처리 기법을 사용하거나 병변과 무관한 이미지가 미리 훈련된 모델을 이용해 미세하게 튜닝 했다.

Pour and Seker(2020)는 피부 병변 및 피부 진찰 분류를 위하여 합성곱신경망 모델을 사용하였다. 제안된 모델은 적은 데이터 셋에도 불구하고 인공물을 제거하지 않고 이미지를 향상시키기 위한 과도한 데이터 증가나 전처리가 적용되지 않았다. 그 대신에 신경망 모델은 다른 도메인의 이미지를 재표현하는 방법으로 학습되었다.

합성곱신경망은 망막혈관을 분류하는데 사용되었다. 망막의 혈관을 분류하기 위해 사용된 합성곱 신경망은 눈병을 진찰하는데 중요한 역할을 한다(Soomro *et al.*, 2019).

망막 이미지의 품질을 개선하기 위해 제안된 모델은 훈련에 최적화하기 위해 클래스 밸런싱 손실 함수가 사용되었다. 제안된 합성곱신경망 모델은 4개의 데이터베이스(DRIVE, STARE, CHASE-DB1 및 HRF)를 이용하여 성능이 평가되었다.

합성곱신경망은 이미지 분류를 사용하는 자동진단 시스템에 높은 기여를 하였다.합성곱신경망이 적용된 의료용 자동진단 시스템은 의료전문가

에게 도움을 주어 이미지를 활용한 조기진단에서 엄청난 성공을 거두었다.

합성곱신경망은 얼굴이미지 조작탐지, 인간 활동분석, 고장진단과 같은 의료분야 뿐만 아니라 공학 분야에서 널리 사용되었다(Dang *et al.*, 2019; Moghaddam *et al.*, 2020; Yang *et al.*, 2019).

2.2.2 합성곱신경망을 이용한 주가방향예측에 관련된 연구

본 연구의 목적은 합성곱신경망을 이용하여 주가방향을 예측하는 것이다. 합성곱신경망을 이용한 주가방향 예측 연구는 다음 <표 3>과 같다.

Persio and Honchar(2016)은 S&P 500지수의 증가 기록 데이터를 분석하기 위해 합성곱신경망, LSTM, MLP 등과 같은 신경망 기법을 적용했다. 분석 결과로는 합성곱신경망이 LSTM 및 MLP보다 높은 성능을 나타냈다. Sezer and Ozbayoglu(2018)은 시계열 재무자료를 2D이미지로 변환하여 합성곱신경망 모델을 학습시키고, 학습된 모델을 바탕

으로 매수, 매도, 홀드 등과 같은 의사결정 지점을 예측하는 연구를 수행하였다. Lee and Ahn(2018)은 합성곱신경망을 이용해 주가지수의 그래프를 시각화하는 방법을 이용하여 주가의 패턴을 연구하였다.

Hoseinzade and Haratizadeh(2019)는 주가를 예측하기 위한 속성을 추출하기 위해 다양한 주식시장으로부터 데이터를 추출하였다. 다양한 출처로부터 추출된 데이터들은 합성곱신경망이 적용된 분석프레임워크를 통해 분석된다. 프레임워크는 다양한 초기 속성의 집합에 기초하여 S&P 500, NAS-DAQ, DJI, NYSE, RUSSELL 지수의 다음날 가격이동 방향을 예측하기 위해 사용된다. 합성곱신경망 기반의 분석 프레임워크는 벤치마킹 베이스 알고리즘에 비해 예측 성능이 크게 나타났다. Hiransha *et al.*(2018)는 과거 가격에 기반한 기업의 주가 4가지 주가예측용 딥러닝 학습 모델 사용하였다. 사용된 딥러닝 모델은 MLP, RNN, LSTM, 합성곱신경망이다. 데이터는 인도의 NSE(National

<표 3> 합성곱신경망을 이용한 주가방향 예측에 관한 연구

Authors	Year	Stock	FS	Classifiers	Deep learning method	Results
Persio and Honchar	2016	stock price		MLP	CNN, RNN	CNN with highest performance
Lee and Ahn	2017	stock price direction		LR, ANN, SVM	CNN	CNN with highest performance
Gunduz <i>et al.</i>	2017	stock price direction	Chi-Square, Random, Clustered by Correlation	LR	CNN	CNN-Corr is best performance
Hiransha <i>et al.</i>	2018	stock price		NN	RNN, LSTM, CNN	CNN is best performance
Sezer and Ozbayoglu	2018	stock price return			CNN, LSTM, MLP	CNN with highest performance
Hosaka	2019	bankruptcy		DT, LDA, SVM, NN, AB	CNN	CNN is best performance
Hoseinzade and Haratizadeh	2019	stock price direction	PCA	ANN, CNN	CNN	CNN with highest performance
This study		stock price direction	Correlation based feature selection	LR, DT, NN, SVM, AB, BA, RF	CNN	CNN with highest performance

Stock Exchange)와 뉴욕 증권거래소(NYSE)의 주간 종가가 사용되었다.

딥러닝 네트워크는 NSE의 단일 회사 주가로 학습되었고 NSE와 NYSE의 5개 회사 주가를 예측하기 위해 사용되었다. 합성곱신경망은 다른 딥러닝 모델보다 높은 성능을 나타냈다. 딥러닝 네트워크들은 NSE 데이터로 훈련되었음에도 불구하고 NYSE를 예측할 수 있었다. 이는 두 주식시장이 어느 정도 공통된 내적 역학관계를 갖고 있는 것으로 볼 수 있다. 딥러닝 네트워크의 결과는 ARIMA 모델과 비교하여 기존의 선형 모델인 ARIMA보다 성능이 우수하게 나타났다(Hiransha *et al.*, 2018).

Hosaka(2019)는 합성곱신경망을 파산 또는 지속 가능한 기업으로 분류하는 2종 분류 문제에 적용하였다. 데이터는 일본 증시에서 파산으로 상장 폐지된 102개 기업의 재무제표와 4개 회계기간에 걸쳐 현재 상장된 2,062개 기업의 재무제표가 분석에 사용된다. 재무제표에서 도출된 재무비율 데이터는 회색조 이미지로 표현된다. 이 과정에서 생성된 이미지는 합성곱신경망의 학습 및 테스트용으로 활용되었다. 합성곱신경망을 통한 파산 예측방법은 의사결정나무, LDA, 서포터벡터머신, MLP, AdaBoost 또는 Altman의 Z 00-score를 사용하는 방법과 비교하여 더 높은 성능을 나타냈다.

Gunduz *et al.*(2017)은 병렬식 합성곱필터를 가진 합성곱신경망을 제안하였다. 제안된 합성곱 신경망 모델은 Chi-Square 속성선택방법을 적용한

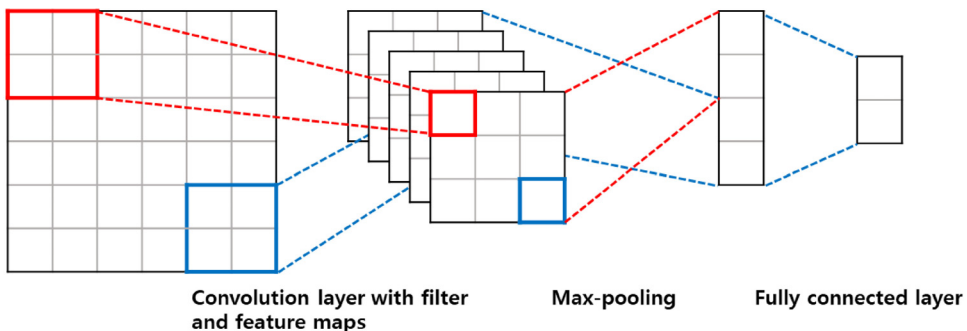
모델과 적용하지 않은 모델의 성과를 비교하였다. 추가적으로 랜덤으로 선택한 속성을 사용한 합성곱신경망 모델과 상관관계에 따라 클러스터링한 합성곱신경망 모델을 비교하였다. 합성곱 모델의 성능을 비교한 결과로는 상관관계에 따라 클러스터링한 모델이 보다 높은 성능을 나타냈다.

선행연구를 바탕으로 주가방향 예측연구를 살펴본 결과, 주가방향 예측을 위하여 머신러닝 단일 및 앙상블분류기, 딥 러닝 기법이 사용되었다. 분석 대상으로는 특히 주가지수, 주가방향, 주가 수익률 등을 예측하는 연구가 주를 이루었다. 특히 주가방향에는 매일매일 등락을 예측을 위한 기업의 기술지표를 주로 활용한다. 그러나 본 연구에서는 분기 별 재무비율 자료를 분석하는 모델을 제안한다. 이는 금융관련 전문지식이 없더라도 제안되는 모델을 이용하면 중-장기용 투자전략을 수립할 수 있고, 포트폴리오 개발에도 유용하다.

III. 연구설계 및 실증분석


3.1 합성곱신경망 모델(Convolutional Neural Network)

합성곱신경망(Convolutional Neural Network)은 물체를 인식하는 생물의 시각처리과정을 모방해 만든 딥러닝 알고리즘의 일종이다(Hiransha *et al.*, 2018). 합성곱신경망의 구조는 다음 <그림 1>과 같다.




<그림 1> 합성곱신경망의 구조

합성곱신경망은 입력층과 출력층을 포함하여 합성곱층(Convolution Layer), 풀링층(Pooling Layer) 그리고 완전연결층(Fully Connected Layer)으로 구성되어 있다(Lecun and Bengio, 1995). 입력층을 통해 데이터가 입력되면 합성곱층을 통해 데이터의 특징이 추출된다. 특징맵은 필터의 개수에 따라 그 수가 정해진다. <그림 2>에 있는 예시와 같이 2×2크기의 합성곱 필터는 4×4크기의 입력층에 대해 좌에서 우로 위에서 아래로 이동한다. 합성곱필터를 거치는 과정은 입력값의 압축이다. 맥스풀링 필터를 거치는 과정은 <그림 3>과 같다. 2×2필터가 2칸씩 거치면서 해당 영역에서 최대값을 선택한다. 이 결과는 맥스풀링 필터의 출력값이 된다. 합성곱 필터와 맥스풀링을 지나는 과정은 데이터의 특징을 부각시켜 주고 더욱 분별력을 높여준다.



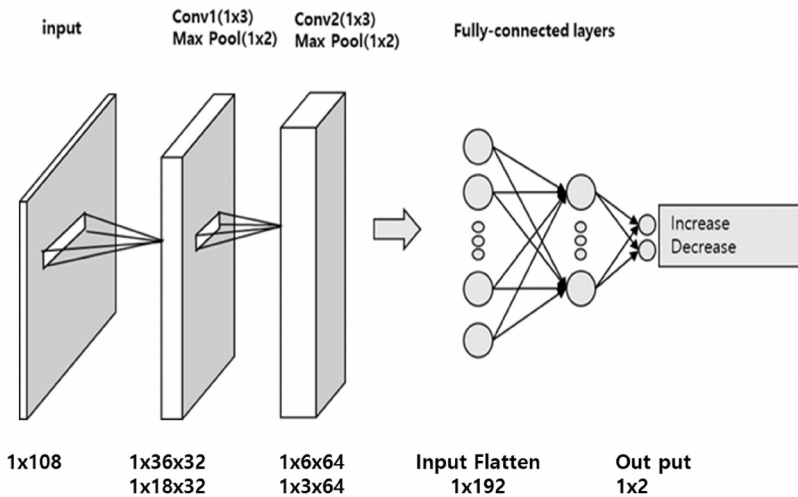
<그림 2> 2×2 합성곱 필터



<그림 3> 맥스풀링 필터

완전연결층은 신경망의 은닉층(Hidden Layer)에 해당된다. 은닉층에서는 많은 뉴런을 사용하면 섬세한 모델을 만들 수는 있지만, 학습용 데이터에 오버피팅(Overfitting)된다는 단점이 있다. 따라서 이를 예방하기 위해 드롭아웃(Dropout) 기법을 사용한다. 드롭아웃은 임의의 뉴런을 일정비율 제거하면서 학습시키는 방법이다. 드롭아웃은 오버피팅 시 뉴런들이 하나의 뉴런으로 움직이는 상호작용 현상을 예방할 수 있다. 본 연구에서는 드롭아웃 확률을 0.7로 설정하여 학습시켰다.

본 연구에서 사용한 합성곱신경망 모델은 다음 <그림 4>와 같은 구조적 특성을 갖는다. 본 연구에서는 재무비율 데이터가 독립변수이다. 이에 맞게 합성곱층과 풀링층을 변환시킬 필요가 있다. 따라서 다음과 같은 구조로 이루어져 있다.



<그림 4> 본 연구에서 제안하는 CNN 모델구조

첫째, 합성곱층은 1×3의 필터를 스트라이드 (stride) 1로, 맥스풀링 필터 사이즈는 1×2와 스트라이드 1로 시행했다. 둘째, Fully-connected 층은 완전연결층 즉, 인공신경망을 나타낸다. 완전연결 층에서는 모든 노드들이 연결되어있기 때문에 합성곱 층을 통과한 데이터를 통해 학습할 수 있다. 완전연결층에서의 학습은 최적화 방법인 Adam을 사용하고(Kingma and Ba, 2014), 활성화 함수로는 ReLU 함수를 사용하였다.

각 단계에 해당되는 데이터 사이즈는 다음과 같다. 처음 입력데이터에는 1×108으로 첫 번째 합성곱층을 거친 후에는 1×36×32으로 변환되고, 맥스풀링을 지난 다음에는 1×18×32으로 변환된다. 두 번째 합성곱층을 거친 후에는 1×6×64으로 변환되며 둘째 맥스풀링 거친 후에는 1×3×64로 변환된다. 마지막으로, 데이터는 펼쳐져 1×192 형태로 완전 연결층에 입력된다.

3.2 데이터

본 연구에서 사용된 데이터는 기업의 재무비율 데이터와 주가이다. 전체 데이터는 NICE 평가 정보(주)에서 운영하는 KIS-value에서 수집되었다. 2008~2015년도 기간 동안 근속된 KOSPI의 상장 유통업 기업이 대상이다. 유통업 기업은 총 37개 기업이며, 해당 기업의 분기별 재무비율 데이터를 수집하였다. 데이터의 레코드 수는 1,005개이며 10겹 폴더 검정을 통하여 약 904개는 학습 데이터에 사용되고 약 100개는 테스트데이터에 사용된다. 본 연구에서 사용한 데이터의 특성은 다음과 같다. 첫째, 독립변수는 재무비율데이터로 총 개수는 108개이며, 변수에 대한 내용은 <표 4>와 같다. 둘째, 주가방향을 예측하기 위하여 해당 기간 동안 기업의 월별 주식 증가를 수집했다. 수집된 월별 증가는 분기별 평균으로 가공하여 주가의 전년대비 성장률을 계산하였다. 종속변수 설정에 대한 자세한 내용은 제3.3절 연구방법에서 설명한다.

<표 4> 독립변수 내용

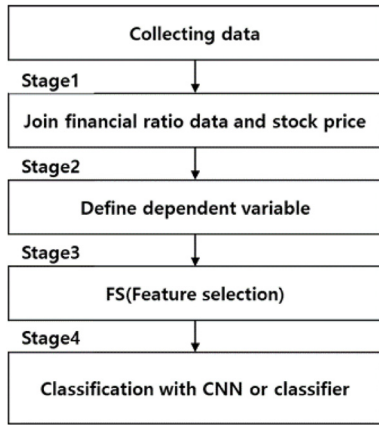
Independent Variable	No.
Total assets growth	1
Tangible assets growth	2
Current assets growth	3
Inventories growth	4
Shareholders equity growth	5
Net sales growth	6
Operating income growth	7
Income before income tax expense growth	8
Net income growth	9
No. of employee growth	10
Operating income to total assets	11
Income before income tax expense to total assets	12
Net income to total assets	13
Income before income tax expense	14
Net income before financial expenses to avg. total assets	15
Operating income to operating capital	16
Income before income tax expense to equity	17
Net income to shareholders equity	18
Income before income tax expense to capital stock	19
Net income to capital stock	20
Income before income tax expense to net sale	21
Net income to net sales	22
Gross profits to net sales	23
Operating income to net sales	24
Total expenses to total revenue	25
COGS to net sales	26
Depreciation ratio	27
Depreciation/total cost	28
Personnel expenses/total cost	29
Taxes / Income before income taxes	30
Taxes / total cost	31
Financial expenses / total liabilities	32
Financial expenses / total borrowings	33
Financial expenses / total expenses	34
Financial expenses / net sales	35
Times interest earned-operating act. basis	36

Independent Variable	No.
Times interest earned-operating income basis	37
Times interest earned-ordinary income basis	38
Times interest earned-income before income taxes basis	39
Dividend ratio	40
Dividend to net income	41
Coverage ratio	42
Debt coverage ratio	43
Loan efficiency ratio	44
EBIT/net sales	45
EBITDA/net sales	46
EBITDA/financial expenses	47
Equity to total assets	48
Current ratio	49
Quick ratio	50
Cash ratio	51
Non current assets ratio	52
Non current assets to equity & LT liabilities	53
Total liabilities to shareholders equity	54
Current liabilities to shareholders equity	55
Non-Current liabilities to shareholders equity	56
Total borrowings to total assets	57
Total borrowings to shareholders equity	58
Total borrowings/net sales	59
A/R to trade account payable	60
A/R to merchandise & finished goods	61
Trade account payable to inventories	62
Inventories to NWC	63
Non-Current liabilities to NWC	64
NWC to total assets	65
Reserves ratio	66
Reserves to total disposal amount of R/E	67
R/E to total assets	68
R/E to paid-in capital	69
Total CF to total liabilities	70
Total CF to total borrowings	71
Total C/F to total assets	72
Total C/F to net sales	73
Net CF to total borrowings	74
Total assets turnover	75

Independent Variable	No.
Equity turnover	76
Paid-in capital turnover	77
NWC turnover	78
Operating capital turnover	79
Non-Current assets turnover	80
Tangible assets turnover	81
Inventories turnover 1	82
Merchandise & finished goods turnover	83
Raw materials turnover	84
WIP turnover	85
A/R turnover	86
Trade account payable turnover	87
Inventories turnover 2	88
Net operating capital turnover	89
Value-added per employee	90
Net sales per employee	91
Income before income tax expense per employee	92
Net income per employee	93
Personnel expenses per employee	94
Avg. tangible assets, net of CIP per employee	95
Machinery & equipment per employee	96
Total assets per employee	97
Efficiency of investment-avg. total assets	98
Efficiency of investment-avg. tangible assets, net of CIP	99
Efficiency of investment-avg. machinery	100
Value added to net sales	101
Labor cost to value added	102
Income before income taxes to value added	103
Personnel expenses to value added	104
Financial expenses to value added	105
Rent to value added	106
Taxes & dues to value added	107
Depreciation to value added	108

3.3 연구방법

본 연구의 실증방법 순서는 <그림 5>와 같이 총 4단계로 구성된다.



〈그림 5〉 본 연구의 절차

Stage 1: 재무비율 데이터와 주가자료의 결합
 첫 단계에서는 재무비율 데이터와 주가자료가 결합된다. 재무비율 데이터는 분기별로 공시 되어 있고, 주가는 월별로 되어 있기 때문에 두 데이터 간의 시간단위가 다르다. 동일한 시간단위를 갖도록 주식 증가를 분기별 데이터로 재가공하여 재무비율과 주가자료를 결합하였다.

Stage 2: 종속변수 정의
 주가의 방향은 주가의 등락을 의미한다. 이를 분석하기 위하여 전년도 대비 해당 년도의 주가 상승률을 산출하였다. 본 연구에서는 단순 상승하강이 아니라 보다 정교한 예측을 위하여 상승률

별로 등락 임계점을 지정하였다. 종속 변수에 대한 산출 수식은 다음과 같다. P_{t+1} 은 해당 년도의 가격, P_t 는 전년도의 가격을 의미한다. 본 연구에서 사용된 독립변수는 t시점에 해당되고 종속변수인 주가방향은 t+1시점에 해당된다.

$$IR_{t+1} = \frac{(P_{t+1} - P_t)}{P_t}$$

변수에 대한 설명은 <표 5>와 같다. 정리하면 t2는 2클래스(15% 이상, 15% 미만), t3은 3클래스(15% 이상, -15% 이상, -15% 미만), 마지막으로 t5는 5클래스(30% 이상, 15% 이상, -15% 이상, -30% 이상, -30% 미만)이다. 이에 따라, 종속변수에 대한 클래스의 개수는 다음과 같다. t2에서는 1 = 536, 0 = 469이고, t3에서는 2 = 392, 1 = 342, 0 = 271이다, 마지막으로 t5에서는 4 = 292, 3 = 100, 2 = 342, 1 = 128, 0 = 143이다.

Stage 3: 속성 선택 적용

재무비율 데이터는 100개가 넘는 독립변수 즉, 속성으로 이루어져 있다. 이 단계는 종속변수에 높은 영향을 미치는 독립변수를 선택한다. 머신러닝 관점에서 속성선택은 고려하여야 할 속성의 수를 줄이고, 학습모형의 성능을 향상시키는데 유효하다. 본 연구에서는 필터 속성선택 방법 중 하나

〈표 5〉 변수에 대한 설명

t	Dependent Variable	Number of class	Independent Variable after FS
t2	15%	1 = 536 0 = 469	2, 5, 7, 16, 17, 19, 20, 39, 42, 46, 59, 66, 68, 69, 76, 105
t3	15%, 0, -15%	2 = 392 1 = 342 0 = 271	1, 6, 11, 16, 17, 18, 19, 20, 26, 32, 39, 52, 59, 68, 69, 70, 76, 77
t5	30%, 15%, 0, -15%, -30%	4 = 292 3 = 100 2 = 342 1 = 128 0 = 143	1, 11, 12, 15, 17, 20, 32, 59, 66, 68, 76

인 상관관계 속성선택 방법을 사용하여 속성을 선택하였다. 상관관계 속성 평가방법은 독립변수가 종속변수의 클래스와 상관관계가 높지만, 독립변수들 간에는 상관관계가 낮아야 한다. 다양한 부분 셋 간의 상관관계를 구하고 우선순위에 따라 적당한 속성을 선택한다. 상관관계 속성 평가방법에 대한 수식은 다음과 같다.

$$M_s = \frac{\overline{kr_{cf}}}{\sqrt{k+k(k-1)r_{ff}}}$$

여기서 M_s 는 변수의 부분 셋 S 에 포함되는 변수들 k 의 휴리스틱 값을 나타낸다. $\overline{r_{cf}}$ 는 변수와 클래스 간의 상관관계이고($f \in S$), $\overline{r_{ff}}$ 는 변수들 간의 내부 상관관계수의 평균이다. 따라서, 분자는 변수 집합으로 클래스를 얼마나 잘 예측할 수 있는지를 나타내고, 분모는 변수들 간에 얼마나 중복성이 있는지를 나타낸다. 속성선택을 통해 선택된 변수 개수는 각각 종속변수의 특성에 따라 다르며 t_2 는 16개(0.087), t_3 은 18개(0.086), t_5 는 11개(0.08)이다. 괄호안의 수치는 각 선택된 변수의 휴리스틱 값이다. 선택된 속성의 내역은 <표 5>와 같다.

Stage 4: 합성곱신경망을 통한 분류 및 벤치마킹 분류기 비교

다음 단계에서는 본 연구의 실증을 위한 단계이다. 속성선택을 적용한 후의 속성을 사용한 합성곱신경망의 성능을 검증한다. 객관적인 성과의 검증을 위해 다음과 같은 머신러닝 분류기를 벤치마킹 했다. 단일분류기는 로지스틱 회귀분석, 의사결정나무, 인공신경망, 서포트 벡터머신이고, 앙상블 분류기는 아다부스트, 배깅, 랜덤포레스트이다.

3.4 매트릭 평가(Metric Evaluation)

주가방향 예측 모델의 성능을 평가하기 위하여 정확도(Accuracy), 정밀도(Precision), 재현율(Recall),

그리고 F1점수(F1-Measure)를 산출하였다. 본 연구의 분류 평가는 <표 6>의 혼동 행렬을 사용한다. 정확도는 전체 분류한 건수에서 주가가 상승한 기업인지 하락한 기업인지 맞춘 비율이다. 정밀도는 주가가 상승한 기업이라고 분류한 경우 실제로 상승한 비율이다. 재현율은 실제 상승한 기업 중 상승할 것이라고 분류한 비율이다. F1점수는 정밀도와 재현율의 조화평균이다. TP(True Positive)는 주가 상승 기업을 분류기가 상승으로 분류한 건수이고, FP(False Positive)는 주가하락 기업을 상승으로 분류한 건수이다. TN(True Negative)는 주가하락 기업에 대해 분류기가 하락으로 분류한 건수이다. FN(False Negative)은 주가상승 기업을 하락으로 분류기가 하락으로 분류한 건수이다. 정확도, 정밀도, 재현율, F1점수의 수식은 다음과 같다. 본 연구는 교차검증(Cross Validation)을 사용했다(Arlot and Celisse, 2010). 10겹 교차검증(10 Fold-Cross Validation)은 전체 데이터를 10폴더로 분할 한 다음, 9개 폴더는 학습용으로 남은 1개 폴더는 테스트용으로 사용하여 평가하는 방법이다.

<표 6> 혼동행렬

		Predicted Class	
		Positive	Negative
Actual Class	Positive	TP	FN
	Negative	FP	TN

Accuracy = (TP+TN)/(TP+TN+FP+FN)

Precision = TP/(TP+FP)

Recall = TP/(TP+FN)

F1-Score = 2 * (Precision * Recall)/(Precision+Recall)

IV. 연구결과 및 토의

4.1 연구결과

본 연구에서는 주가방향 예측을 위해 상관관계 속성선택을 적용한 합성곱신경망을 제안했다. 본 연구에서 제시하는 RQ를 검증하기 위한 결과는 다음과 같다. <표 7>은 속성선택 전의 속성을 사

용한 분석결과이고, <표 8>은 속성선택을 사용한 속성을 적용한 분석결과이다. LR은 로지스틱 회귀분석, DT는 의사결정나무, NN은 인공신경망, SVM은 서포트 벡터머신, AB는 아다부스트, BA는 배깅, RF는 랜덤포레스트이다.

속성선택 전의 속성을 사용하여 얻은 결과는 다음과 같다. RF는 정확도, 정밀도, 재현율, F1 모든 성능지표에서 가장 높게 나타났다. t2, t3, t5 모든 경우에서 RF가 가장 높았다.

속성선택을 적용한 속성을 사용한 경우의 결과는 다음과 같다. 정확도, 정밀도, 재현율, F1점수의 결과는 모든 성능 지표에서 다음 분류기가 높게 나타났다. t2에서는 RF가 0.71로 가장 높게 측정되었고, t3, t5에서는 합성곱신경망이 0.73, 0.55로 가장 높게 나타났다.

본 연구의 결과를 요약하면 다음과 같다. 속성선택을 적용하기 전의 속성을 사용한 경우에는 합

성곱신경망의 성능이 다른 분류기보다 높게 나타나지 않았다. 그러나 속성선택을 적용한 속성을 사용한 경우에는 t3, t5에서 합성곱신경망이 다른 분류기보다 성능이 높게 나타났다.

합성곱신경망과 RF의 성능을 비교하기 위하여 두 결과를 통계적으로 검증할 수 있는 t검정 (* $p < 0.05$ 에서 유의함) 분석을 수행하였다. t검정에 대한 결과는 다음과 같다.

t2는 0.163으로 유의함을 보이지 않았고, t3은 0.000*으로 유의하게 나타났다. 마지막으로, t5는 0.001*로 유의하게 나타났다. t검정의 결과를 바탕으로 해석한 본 연구의 결과는 다음과 같다.

속성선택 후의 속성을 사용한 경우에는 t2에서 합성곱신경망과 랜덤포레스트는 비슷한 성능을 보였고, t3과 t5에서는 합성곱신경망이 랜덤포레스트보다 통계적으로 유의하게 높게 나타났음을 확인할 수 있었다.

<표 7> 속성선택 전 결과

Accuracy								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.58	0.65	0.53	0.52	0.63	0.64	0.71	0.56
t3	0.48	0.50	0.35	0.39	0.50	0.49	0.58	0.40
t5	0.36	0.39	0.25	0.34	0.35	0.40	0.45	0.35
Precision								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.58	0.65	0.53	0.28	0.63	0.64	0.71	0.61
t3	0.47	0.50	0.35	0.15	0.50	0.48	0.57	0.16
t5	0.32	0.39	0.26	0.12	0.33	0.36	0.43	0.22
Recall								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.58	0.65	0.53	0.53	0.63	0.64	0.71	0.56
t3	0.48	0.50	0.35	0.39	0.49	0.49	0.58	0.40
t5	0.36	0.39	0.25	0.34	0.35	0.40	0.45	0.35
F1								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.58	0.65	0.53	0.36	0.63	0.63	0.71	0.44
t3	0.46	0.50	0.35	0.22	0.49	0.48	0.57	0.23
t5	0.32	0.39	0.25	0.17	0.33	0.35	0.44	0.22

〈표 8〉 속성선택 후 결과

Accuracy								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.59	0.65	0.58	0.54	0.67	0.67	0.71	0.70
t3	0.45	0.51	0.42	0.59	0.48	0.55	0.57	0.73*
t5	0.35	0.37	0.35	0.35	0.32	0.42	0.43	0.55*
Precision								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.59	0.65	0.58	0.29	0.68	0.67	0.71	0.71
t3	0.44	0.51	0.42	0.32	0.47	0.55	0.58	0.73*
t5	0.25	0.37	0.32	0.33	0.29	0.40	0.43	0.54*
Recall								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.59	0.65	0.58	0.54	0.67	0.67	0.71	0.70
t3	0.45	0.51	0.42	0.39	0.48	0.55	0.57	0.73*
t5	0.38	0.37	0.35	0.35	0.32	0.42	0.43	0.55*
F1								
	LR	DT	NN	SVM	AB	BA	RF	CNN
t2	0.58	0.65	0.58	0.38	0.67	0.67	0.71	0.70
t3	0.42	0.51	0.42	0.22	0.47	0.54	0.57	0.73*
t5	0.29	0.37	0.33	0.22	0.29	0.39	0.43	0.54*

4.2 토의

본 연구의 학술적 의의는 다음과 같다.

첫째, 합성곱신경망은 속성선택을 적용한 속성을 사용함으로써 t3, t5에서 다른 머신러닝 분류기보다 높은 성능을 나타냈다. t3과 t5의 결과는 클래스 수가 t2보다 많기 때문에 예측이 더욱 어렵다. 본 연구에서는 상관관계 속성선택을 적용하여 변수 간의 노이즈를 줄여 합성곱신경망 모델의 학습 효율을 높이게 될 경우, 합성곱신경망은 우수한 결과 값을 보여준다. 이는 불필요한 속성을 제거하고 유효한 속성을 선별함으로써 합성곱신경망의 멀티클래스 분류 성능을 더욱 향상시킬 수 있음을 의미한다.

둘째, 상관관계 속성선택 방법을 적용하여 종속변수에 영향을 미치는 속성변수를 효과적으로 선별하였다. 즉, 전체 108개 속성변수 중 t2는 16개,

t3이 18개, t5는 11개를 선별하였다. 이와 같이 대폭 갯수가 줄어든 속성변수를 이용함으로써 연산량을 크게 줄일 수 있었다.

본 연구의 실무적 의의는 다음과 같다.

첫째, 기존 재무 분야에서 주가방향 예측방법으로 주로 사용되던 기법은 기술적 분석이었다. 기술적 분석이란 주가의 시계열 데이터로서의 패턴을 분석하여 주가방향을 예측하는 방법이다. 그러나 이 같은 기술적 분석은 오랫동안의 경험을 요구하고 또한 패턴자체에 따른 오류가 많아 실무적으로 많은 비판을 받고 있다. 반면 본 연구에서는 유의미한 속성을 선택하여 합성곱신경망이라고 하는 딥러닝 기법을 적용함으로써 누구든지 이용 가능한 주가방향 예측 방법을 제시하였다.

둘째 머신러닝 알고리즘을 이용한 주가방향 예측은 학습만 제대로 시키기만 하면 특별한 노하우

가 없어도 누구든지 해당 알고리즘을 이용하여 주가방향을 정확하게 예측할 수 있다. 본 연구에서는 합성곱신경망 알고리즘을 이용해 기존 머신러닝에 의한 방법보다 더 높은 결과 값을 보여주고 있다. 따라서, 주가방향 예측에서 합성곱신경망은 예측 도구로서의 가능성이 매우 높다는 것을 확인할 수 있었다.

V. 결 론

본 연구에서는 합성곱신경망 기법을 이용하여 주가방향 예측 방법을 제안하고 결과를 실증적으로 분석하였다. 신경망 학습 전 단계에는 효율적인 학습을 위하여 상관관계 속성선택 방법을 적용하여 속성을 선택하였다. 합성곱신경망의 성능은 벤치마킹 된 기존 머신러닝 분류기의 결과와 비교되었다. 벤치마킹한 분류기는 다음과 같다. 로지스틱 회귀분석, 의사결정나무, 인공신경망, 서포트 벡터 머신, 아다부스트, 배깅, 랜덤포레스트이다.

속성선택을 적용하기 이전의 결과는 기존의 머신러닝 방법을 통한 성능이 합성곱신경망 기법의 성능보다 높게 나타났다. 그러나 상관관계 속성선택을 거쳐 선별된 속성을 사용한 경우에는 합성곱신경망 기법의 결과가 유의한 정도로 높은 결과 값을 보였다. 특히 t_3 , t_5 의 결과에서 매우 유의한 수준으로 높게 나타났다. 이후 t 검정을 통해 결과의 통계적 유의성이 있음을 확인할 수 있었다.

마지막으로 본 연구의 한계점은 다음과 같다. 본 연구에서는 유통업 기업만을 대상으로 분석하였다. 따라서 KOSPI의 다양한 업종을 대상으로 추가적인 연구가 필요하다. 둘째, 본 연구에서는 합성곱신경망과 기존 머신러닝 분류기의 성능을 비교하였다. 향후 연구에서는 DNN, RNN, LSTM과 같은 동일한 딥러닝 기법과 비교가 필요하다. 셋째, 본 연구에서는 독립변수로 108개의 재무 비율자료를 이용했다. 기업차원에서는 기업의 재무 비율 자료와 기술적 지수를 접목한 분석방법이 필

요하고, 환율, 물가지수 등 추가로 다양한 외부지수를 접목해 연구한다면 주가방향 연구가 더욱 발전할 것으로 예상된다.

참 고 문 헌

- [1] Affonso, C., A. L. D. Rossi, F. H. A. Vieira, and A. C. P. de Leon Ferreira, "Deep learning for biological image classification", *Expert Systems with Applications*, Vol.85, 2017, pp. 114-122.
- [2] Arlot, S. and A. Celisse, "A survey of cross-validation procedures for model selection", *Statistics Surveys*, Vol.4, 2010, pp. 40-79.
- [3] Ballings, M., D. Van den Poel, N. Hespels, and R. Gryp, "Evaluating multiple classifiers for stock price direction prediction", *Expert Systems with Applications*, Vol.42, No.20, 2015, pp. 7046-7056.
- [4] Chang, F., "Deep learning for biological image classification", *Neural Networks & Machine Learning*, Vol.1, No.1, 2017, pp. 2-2.
- [5] Chong, E., C. Han, and F. C. Park, "Deep learning networks for stock market analysis and prediction: Methodology, data representations, and case studies", *Expert Systems with Applications*, Vol.83, 2017, pp. 187-205.
- [6] Dang, L. M., S. I. Hassan, S. Im, and H. Moon, "Face image manipulation detection based on a convolutional neural network", *Expert Systems with Applications*, Vol.129, 2019, pp. 156-168.
- [7] Di Persio, L. and O. Honchar, "Artificial neural networks architectures for stock price prediction: Comparisons and applications", *International Journal of Circuits, Systems and Signal Processing*, Vol.10, 2016, pp. 403-413.
- [8] Eo, K. S. and K. C. Lee, "Predicting stock price direction by using data mining methods", *Journal of the Korea Society of Computer and Information*,

- Vol.22, No.11, 2017, pp. 111-116.
- [9] Gunduz, H., Y. Yaslan, and Z. Cataltepe, "Intraday prediction of Borsa Istanbul using convolutional neural networks and feature correlations", *Knowledge-Based Systems*, Vol.137, 2017, pp. 138-148.
- [10] Hiransha, M., E. A. Gopalakrishnan, V. K. Menon, and K. P. Soman, "NSE stock market prediction using deep-learning models", *Procedia Computer Science*, Vol.132, 2018, pp. 1351-1362.
- [11] Hosaka, T., "Bankruptcy prediction using imaged financial ratios and convolutional neural networks", *Expert Systems with Applications*, Vol.117, 2019, pp. 287-299.
- [12] Hoseinzade, E. and S. Haratizadeh "CNNpred: CNN-based stock market prediction using a diverse set of variables", *Expert Systems with Applications*, Vol.129, 2019, pp. 273-285.
- [13] Hu, H., L. Tang, S. Zhang, and H. Wang, "Predicting the direction of stock markets using optimized neural networks with Google Trends", *Neurocomputing*, Vol.285, 2018, pp. 188-195.
- [14] Huang, W., Y. Nakamori, and S. Y. Wang, "Forecasting stock market movement direction with support vector machine", *Computers & Operations Research*, Vol.32, No.10, 2005, pp. 2513-2522.
- [15] Joo, I. T. and S. H. Choi, "Stock prediction model based on bidirectional LSTM recurrent neural network", *Korea Information Electron Communication Technology*, Vol.11, No.2, 2018, pp. 204-208.
- [16] Kim, K., "Financial time series forecasting using support vector machines", *Neurocomputing*, Vol.55, 2003, No.1-2, pp. 307-319.
- [17] Kingma, D. P. and J. Ba, "Adam: A method for stochastic optimization", *The 3rd International Conference on Learning Representations*, 2014, arXiv preprint arXiv:1412.6980.
- [18] Kraus, M. and S. Feuerriegel, "Decision support from financial disclosures with deep neural networks and transfer learning", *Decision Support Systems*, Vol.104, 2017, pp. 38-48.
- [19] LeCun, Y. and Y. Bengio, "Convolutional networks for images, speech, and time series", In M. Arbib, editor, *The Handbook of Brain Theory and Neural Networks*, MIT Press, Cambridge, Massachusetts, 1995, pp. 255-258.
- [20] LeCun, Y., L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition", *Proceedings of the IEEE*, Vol.86, No.11, 1998, pp. 2278-2324.
- [21] Lee, M. C., "Using support vector machine with a hybrid feature selection method to the stock trend prediction", *Expert Systems with Applications*, Vol.36, No.8, 2009, pp. 10896-10904.
- [22] Lee, M. S. and H. C. Ahn, "A time series graph based convolutional neural network model for effective input variable pattern learning: Application to the prediction of stock market", *Journal of Intelligence and Information Systems*, Vol.24, No.1, 2018, pp. 167-181.
- [23] Moghaddam, M., Q. Chen, and A. V. Deshmukh, "A neuro-inspired computational model for adaptive fault diagnosis", *Expert Systems with Applications*, Vol.140, 2020, p. 112879.
- [24] Ou, P. and H. Wang, "Prediction of stock market index movement by ten data mining techniques", *Modern Applied Science*, Vol.3, No.12, 2009, pp. 28-42.
- [25] Patel, J., S. Shah, P. Thakkar, and K. Kotecha, "Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques", *Expert Systems with Applications*, Vol.42, No.1, 2015, pp. 259-268.
- [26] Pour, M. P. and H. Seker, "Transform domain

- representation-driven convolutional neural networks for skin lesion segmentation”, *Expert Systems with Applications*, Vol.144, p. 113129, 2020.
- [27] Qiu, M., Y. Song, and F. Akagi, “Application of artificial neural network for the prediction of stock market returns: The case of the Japanese stock market”, *Chaos, Solitons & Fractals*, Vol.85, 2016, pp. 1-7.
- [28] Sellami, A. and H. Hwang, “A robust deep convolutional neural network with batch-weighted loss for heartbeat classification”, *Expert Systems with Applications*, Vol.122, 2019, pp. 75-84,
- [29] Sezer, O. B. and A. M. Ozbayoglu, “Algorithmic financial trading with deep convolutional neural networks: Time series to image conversion approach”, *Applied Soft Computing*, Vol. 70, 2018, pp. 525-538.
- [30] Soomro, T. A., A. J. Afifi, J. Gao, O. Hellwich, L. Zheng, and M. Paul, “Strided fully convolutional neural network for boosting the sensitivity of retinal blood vessels segmentation”, *Expert Systems with Applications*, Vol. 134, 2019, pp. 36-52.
- [31] Ting, F. F., Y. J. Tan, and K. S. Sim, “Convolutional neural network improvement for breast cancer classification”, *Expert Systems with Applications*, Vol.120, 2019, pp. 103-115.
- [32] Wang, Q., W. Xu, and H. Zheng, “Combining the wisdom of crowds and technical analysis for financial market prediction using deep random subspace ensembles”, *Neurocomputing*, Vol.299, 2018, pp. 51-61.
- [33] Yang, H., C. Yuan, B. Du, Y. Li, J. Xing, W. Hu, and S. J. Maybank, “Asymmetric 3d convolutional neural networks for action recognition”, *Pattern Recognition*, Vol.85, 2019, pp. 1-12.
- [34] Yuan, X., L. Xie, and M. Abouelenien, “A regularized ensemble framework of deep learning for cancer detection from multi-class, imbalanced training data”, *Pattern Recognition*, Vol.77, 2018, pp. 160-172.
- [35] Zhong, X. and D. Enke, “Forecasting daily stock market return using dimensionality reduction”, *Expert Systems with Applications*, Vol.67, 2017, pp. 126-139.

Stock Price Direction Prediction Using Convolutional Neural Network: Emphasis on Correlation Feature Selection

Kyun Sun Eo* · Kun Chang Lee**

Abstract

Recently, deep learning has shown high performance in various applications such as pattern analysis and image classification. Especially known as a difficult task in the field of machine learning research, stock market forecasting is an area where the effectiveness of deep learning techniques is being verified by many researchers. This study proposed a deep learning Convolutional Neural Network (CNN) model to predict the direction of stock prices. We then used the feature selection method to improve the performance of the model. We compared the performance of machine learning classifiers against CNN. The classifiers used in this study are as follows: Logistic Regression, Decision Tree, Neural Network, Support Vector Machine, Adaboost, Bagging, and Random Forest. The results of this study confirmed that the CNN showed higher performance compared with other classifiers in the case of feature selection. The results show that the CNN model effectively predicted the stock price direction by analyzing the embedded values of the financial data

Keywords: *Convolutional Neural Network, Stock Price Direction Prediction, Machine Learning, Deep Learning, Feature Selection, Ensemble*

* Ph.D Student, SKK Business School, Sungkyunkwan University

** Corresponding Author, Professor, Global Business Administration/Department of Health Sciences & Technology / SAIHST(Samsung Advanced Institute for Health Sciences & Technology), Sungkyunkwan University

◎ 저 자 소 개 ◎



어 균 선 (eokyunsun@gmail.com)

강릉원주대학교 산업정보경영공학과(공학사)를 졸업하고, 성균관대학교 경영대학에서 경영정보전공으로 석사학위를 취득하였다. 현재 성균관대학교 경영학과 박사과정에 재학 중이며, 주요 관심분야는 딥러닝, 앙상블 학습, 감성분석 등이다.



이 건 창 (kunchanglee@gmail.com)

한국과학기술원 경영과학과에서 석사 및 박사학위를 취득하였고, 현재 성균관대학교 경영대학 글로벌 경영학과/삼성융합의과학원(SAIHST) 융합의과학과 교수로 재직하고 있다. Decision Support Systems, Computers in Human Behavior, Journal of MIS, IEEE Transactions on Engineering Management, Frontiers in Psychology 등 다수의 국외 저널에 논문을 게재하였으며, 주요 연구분야는 인공지능, 빅 데이터분석, 헬스인포매틱스, 감성분석 등이다.

논문접수일 : 2020년 04월 18일

게재확정일 : 2020년 06월 10일

1차 수정일 : 2020년 06월 07일