

금리 변동을 반영한 LSTM 기반 주가 예측 모델 연구

(Stock Price Prediction Model Based on LSTM Reflecting Interest Rate Fluctuations)

김은솔*, 전재기**

(Eunsol Kim, Jaegi Jeon)

요약

최근 인플레이션의 영향으로 중앙은행이 금리 인상 기조를 유지하고 있으며, 이러한 경제 상황을 반영한 금융 시장 예측의 중요성이 커지고 있다. 그러나 국내에서는 최근 금리 변동을 고려한 주가 예측 연구가 부족한 실정이다. 본 연구에서는 주가 예측 모델에 금리를 변수로 추가하여 예측 정확도를 향상시키고자 하였다. 이를 위해 LSTM 알고리즘을 활용하였으며, 역사적으로 주가 변동이 컸던 시기의 데이터를 훈련하여 코스피 지수를 예측하였다. 또한, 시장 상황 및 섹터별 분석을 통해 금리의 영향을 다각도로 분석하였다. 다양한 평가지표를 사용하여 주가 예측과 등락 예측을 동시에 수행한 결과, 금리를 포함한 모델이 기존 모델에 비해 RMSE 기준 48.31% 오차가 감소하였으며, 예측 성능 차이는 통계적으로 유의한 것으로 확인되었다. 본 연구는 금리가 주가 예측에 중요한 변수임을 보여주며, 금리 변동을 포함한 모델이 예측 성능을 향상시킬 수 있음을 확인하였다.

■ 중심어: 금리; 주가예측; LSTM; 섹터별분석

Abstract

Due to the recent impact of inflation, central banks have maintained a policy of raising interest rates, highlighting the growing importance of financial market forecasting that reflects these economic conditions. However, there has been a lack of recent studies in Korea that consider interest rate in stock price prediction. In this study, we aimed to improve prediction accuracy by incorporating interest rates as a variable into stock price prediction models. For this purpose, we utilized the LSTM algorithm and trained the model on historical data from periods of high stock market volatility to predict the KOSPI index. Additionally, we conducted a multi-faceted analysis of the impact of interest rates through market conditions and sector-specific analyses. By employing various evaluation metrics, we performed both stock price prediction and directional movement prediction simultaneously. As a result, the model that incorporated interest rates demonstrated a 48.31% reduction in RMSE, compared to the baseline model, with the performance difference being statistically significant. This study confirms that interest rates are a critical variable in stock price prediction and that models reflecting interest rate fluctuations can enhance predictive performance.

■ keywords: Interest rate; Stock price prediction; LSTM; Sector analysis

1. 서론

주식 시장은 본질적으로 복잡하며 예측이 어렵지만, 최근 인공지능과 빅데이터 기술의 발전으

로 주식 시장 예측에 관한 연구가 활발히 이뤄지고 있다[1-3]. 특히, Long Short-Term Memory (LSTM) 모델은 과거 데이터의 패턴을 학습하는 특성이 있어 시간에 따른 주가 변동을 예측하는데 자주 활용되고 있다[4-6].

* 준회원, 전남대학교 데이터사이언스대학원 석사과정

** 정회원, 전남대학교 데이터사이언스대학원 조교수

이 논문은 2014년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(RS-2023-00242528). 이 논문은 전남대학교 학술연구비(과제번호: 2023-0525) 지원에 의하여 연구되었음.

접수일자: 2024년 10월 21일

수정일자: 2024년 11월 20일

게재확정일: 2024년 12월 04일

교신저자: 전재기 e-mail: jaegijeon@jnu.ac.kr

2022년 이후 미국 연방준비제도의 지속적인 금리 변동 정책이 주식 시장에 큰 영향을 미치면서, 글로벌 시장에서 금리가 중요한 경제 변수로 다시 주목받고 있다. 이에 따라 금리 데이터를 포함한 예측 연구의 필요성이 더욱 강조되고 있다[7, 8]. 하지만 국내 선행 연구들은 주로 주식 시장의 동향 예측에 중점을 두었거나[9-11], 주가를 예측하는 경우에도 거래량 변동만을 포함하여[12] 금리변동을 고려한 주가 예측 연구는 부족한 상황이다. 이에 본 연구는 선행 연구에서[12] 제시한 모델을 기반으로 금리를 추가하여 비교 분석하였으며, 자세한 내용은 본 논문의 4장에서 논의할 예정이다.

본 연구에서 제안하는 모델은 LSTM 알고리즘이며 총 17년간의 분석 기간에는 2008년 금융위기, 2020년 코로나 팬데믹 등 주가 변동이 극심했던 시기를 포함하여, 다양한 경제 상황을 고려해 예측 성능을 높이고자 하였다. 예측 기간은 2020년부터 2023년까지로 설정하였으며, 제안 모델이 기존 모델보다 더 높은 예측 성능을 보이는 것을 확인하였다. 또한, 기간별 및 섹터별로 나누어 세부 실험을 수행하였다. 먼저 기간별 실험에서는 예측 기간을 1년 단위로 세분화하여 연도별 금리 변동에 따른 예측 성능을 분석하였다. 섹터별 실험에서는 금리가 각 섹터에 미치는 영향이 다르다는 점을 고려해 일곱 가지 섹터로 분류한 후 분석을 수행하였고, 금리 변동에 큰 영향을 받는 섹터를 확인하였다. 모든 실험은 결과의 일관성을 확보하기 위해 5회 반복 수행되었으며, 평균 결과를 도출하여 분석에 반영하였다.

모델의 예측 성능 평가를 위해 다양한 평가 지표를 활용하여 주가의 수치 예측과 등락 예측을 동시에 수행하였으며, Diebold-Mariano (DM) 검정을 통해 기존 모델과 제안 모델 간 예측력 차이가 유의함을 확인하였다.

연구 결과, 제안 모델은 기존 모델에 비해 RMSE 기준으로 48.31% 예측 오차가 감소하였으며, 금리 변동이 시작되었던 2021년에는 회귀

분석의 예측 성능 차이가 37.11%로 두드러졌다.

본 연구의 목적은 금리 데이터를 모델에 통합하여 주가 예측 성능을 향상시키는 데 있다. 기존 국내 연구들은 여러 거시 지표를 사용했으나, 주로 금리보다 다른 지표의 영향에 집중하거나 코로나 이후의 금리 상승 시기를 반영하지 않았다. 본 연구는 장기간에 걸친 금리 변동을 반영하여, 금리가 주가에 미치는 영향을 심층적으로 분석하였다는 점에서 기존 연구와 차별성을 갖는다. 또한, 코로나 이후의 금리 변동 시기를 반영해 2020년 이후 주식 시장을 분석했다는 점에서 의의가 있다.

서론에 이어 2장에서는 LSTM 알고리즘과 모델 평가 지표에 대한 이론적 배경을 다루며, 3장에서는 제안 방법을 서술한다. 4장에서는 실험 분석을, 5장에서는 실험 결과를 다룬다. 마지막으로 6장에서는 연구의 결과를 요약하고 연구가 갖는 의의와 한계점을 제시한다.

II. 연구 배경

1. 피어슨 상관계수

피어슨 상관계수는 두 변수 간의 선형적 관계를 측정하는 지표로[13], 이를 통해 금리(x)와 주가(y) 사이의 상관관계를 분석할 수 있다. 상관계수 ρ 는 -1 에서 $+1$ 사이의 값을 갖는다.

$$\rho = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2} \sqrt{\sum_{i=1}^n (y_i - \bar{y})^2}} \quad (1)$$

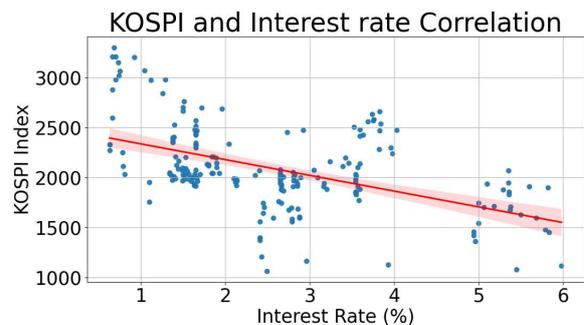


그림 1. 주가와 금리의 상관관계

실험 데이터를 월별 데이터로 분석 결과, 그림 1과 피어슨 상관관계수(ρ)의 값은 -0.5024 로 유의한 음의 상관관계를 보였다. 그러나 피어슨 상관계수와 같은 전통적 기법은 두 변수 간의 선형적 관계만을 분석하는 한계가 있다. 따라서 본 연구에서는 비선형적 상관성을 분석하기 위해 LSTM 모델을 제안한다.

2. Long Short-Term Memory (LSTM)

LSTM은 RNN의 기울기 소실 문제를 해결한 알고리즘이다[14]. LSTM은 장기 의존성을 더 효과적으로 학습하는 특성이 있어, 장기간의 비선형적인 시계열 데이터인 주가를 예측하는 데 효과적이다[15].

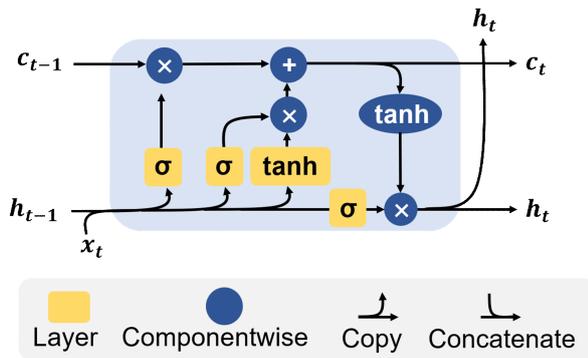


그림 2. LSTM 알고리즘

LSTM은 셀 상태를 갱신하기 위해 입력 게이트, 망각 게이트, 출력 게이트를 사용해 정보를 선택적으로 기억하고 업데이트한다. 입력 게이트는 새로운 정보를 얼마나 추가할지, 출력 게이트는 새로운 은닉 상태를 계산하는 역할을 한다. 이러한 과정을 통해 LSTM 네트워크는 시계열 데이터의 장기 의존성을 학습하며, 시점 간의 전이를 통해 장기적인 패턴을 학습할 수 있는 능력을 갖추게 된다.

3. 평가 지표

본 연구에서는 주가 예측을 위해 수치 예측과 등락 예측의 두 가지 접근법을 적용하였다. 이 절

에서는 각 예측 방법의 성능 평가를 위한 평가 지표와 DM 검정에 대해 설명한다.

가. 회귀 모델 평가

주가의 수치를 예측하는 회귀 모델은 오차율을 통해 평가되며, RMSE (Root Mean Squared Error), MAE (Mean Absolute Error), MAPE (Mean Absolute Percentage Error) 지표를 사용하였다[16-19].

$$RMSE = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_i - y_i)^2}{n}} \quad (2)$$

$$MAE = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i| \quad (3)$$

$$MAPE = \frac{1}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (4)$$

나. 분류 모델 평가

표 1. 혼동 행렬

예측	실제	
	상승	하락
상승	TP	FP
하락	FN	TN

주가의 등락을 예측하는 분류 모델은 혼동 행렬(Confusion Matrix)을 사용해 평가하였으며, 실제 주가 변동과 예측 결과를 비교하였다.

혼동 행렬에서는 TP (True Positive)는 실제 상승을 정확히 예측한 경우, FP (False Positive)는 실제 하락을 상승으로 예측한 경우, FN (False Negative)는 실제 상승을 하락으로 예측한 경우, TN (True Negative)는 하락을 정확히 예측한 경우를 나타낸다. 이러한 값들을 통해 정확도(Accuracy), 재현율(Recall), 정밀도(Precision), F1 Score를 아래와 같이 도출하여 모델의 성능을 종합적으로 평가하였다[20, 21].

$$Accuracy = \frac{TN + TP}{TN + FP + FN + TP} \quad (5)$$

$$Recall = \frac{TP}{TP+FN} \quad (6)$$

$$Precision = \frac{TP}{TP+FP} \quad (7)$$

$$F1\ Score = \frac{2 \times Precision \times Recall}{Precision + Recall} \quad (8)$$

$$\hat{\sigma}^2 = \frac{1}{T} \sum_{t=1}^T (d_t - \bar{d})^2 \quad (15)$$

$$DM = \frac{\bar{d}}{\hat{\sigma} / \sqrt{T}} \quad (16)$$

다. Diebold-Mariano 검정 (DM 검정)

DM 검정은 두 개의 시계열 예측 모델의 성능을 비교하는 통계적 방법으로[22], 다양한 금융 시계열 예측에서 두 모델이 상이한 성능을 가지는지 확인하기 위해 사용된다[22-25]. DM 검정은 예측 오차의 차이를 바탕으로 두 모델 간의 성능 차이가 유의미한지 평가한다. 변수 y_t 에 대한 두 가지 시계열 예측 $\hat{y}_{1,t}$ 와 $\hat{y}_{2,t}$ 가 주어졌을 때 각 예측에 대한 오차는 식 (9), (10)과 같다. 각 시점에서 오차 제곱의 차이 d_t 를 계산하여 두 모델의 성능 차이를 비교한다.

$$e_{1,t} = y_t - \hat{y}_{1,t} \quad (9)$$

$$e_{2,t} = y_t - \hat{y}_{2,t} \quad (10)$$

$$d_t = e_{1,t}^2 - e_{2,t}^2 \quad (11)$$

DM 검정의 귀무가설 H_0 는 두 모델의 예측력이 동일하다는 것으로, 예측 오차 차이의 기댓값 $E[d_t]$ 가 0이라는 것을 의미한다. 대립가설 H_1 은 두 모델의 예측력이 다르다고 가정한다.

$$H_0 : E[d_t] = 0 \quad (12)$$

$$H_1 : E[d_t] \neq 0 \quad (13)$$

DM 검정 통계량, DM 은 d_t 의 표본평균(\bar{d})과 표본 분산($\hat{\sigma}^2$)을 바탕으로 계산되며, 귀무가설 아래에서 근사적으로 표준 정규 분포를 따른다.

$$\bar{d} = \frac{1}{T} \sum_{t=1}^T d_t \quad (14)$$

III. 제안 방법

3. LSTM 기반 주가 예측 모델

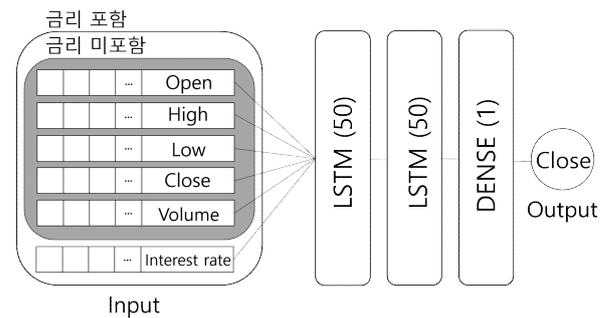


그림 3. 모델 구조

본 연구에서는 거래량 변동을 포함한 선행 연구의 모델을 기존 모델로 설정하였다. 선행 연구에서는[12] 거래량의 유무에 따라 분석을 수행하였으며, 거래량을 포함한 모델이 더 높은 예측력을 가진다는 점이 확인된 바 있다. 이를 기반으로 본 연구에서는 기존 모델의 입력 변수(시가, 고가, 저가, 종가, 거래량)에 금리를 추가하여, 금리 변동이 주가 예측에 미치는 영향을 분석하였다.

따라서 금리 포함 여부, 예측 목적(주가 예측 모델과 등락 예측 모델), 데이터 설정(전체 실험과 부분 실험) 등의 조건을 설정하여 각각 5회씩 실험을 수행하였다.

예측 목적에 따른 분석에서, 주가 예측 모델의 경우 선행 연구와 동일하게 익일 증가를 연속적인 값으로 예측하며, 손실 함수로 RMSE를 사용하였다. 등락 예측 모델은 익일 증가가 전일 대비 상승 또는 하락하는지 이진 분류하는 방식으로 구성되었으며, 손실 함수로 이진 교차 엔트로피(Binary Cross-Entropy)를 사용하고, 활성화 함수로는 Sigmoid를 적용하였다.

본 연구는 미국 시장 데이터를 사용한 선행 연구와 데이터가 다르기 때문에, 한국 시장 데이터의 특성을 반영하여 모델 구성을 일부 변경하고 성능을 최적화하였다. 따라서 제안하는 신경망 모델은 입력층, 2개의 LSTM 층, 출력층으로 구성되어 있다. 입력층은 LSTM 층에 전달될 데이터를 준비하며, 입력 데이터의 시계열 구조를 반영하도록 데이터를 정리한다. 두 개의 LSTM 층은 모두 50개의 유닛과 ReLU 활성화 함수를 적용하였다. 마지막 출력 단계에서 하나의 노드를 갖는 밀집(dense)층을 통해 예측을 수행한다.

모델 최적화 단계에서는 적응형 학습률을 적용하여 경사 하강법의 수렴 속도를 효율적으로 개선하는 Adam optimizer를 사용하였다.

각각의 실험은 5회씩 반복 수행하여 결과의 일관성과 신뢰성을 확보하였다. 이를 통해 실험 조건별로 모델의 성능 차이를 정확하게 평가할 수 있도록 하였다.

IV. 실험 분석

1. 데이터

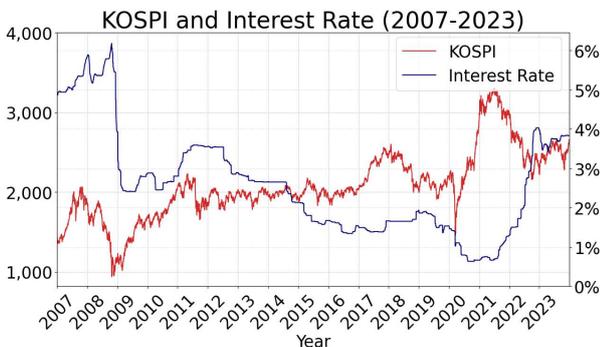


그림 4. 주가와 금리의 동향

본 연구에서 금리 변수는 단기 금리인 양도성 예금증서(CD금리)로, 주가는 코스피 지수로 설정하였다. 선행 연구는 데이터 수집 기간을 2000년부터 2018년으로 설정하고 나스닥 데이터를 사용하였으나, 본 연구는 한국 주식 시장의 특성과 금리 변동이 심했던 시기를 보다 효과적으로 분석하기 위해 테스트 기간을 2007년부터 2023

년까지로 수정하고, 주가 데이터를 코스피 지수로 설정하였다. 그림 4는 17년 동안의 해당 기간 코스피 지수 데이터와 금리 데이터를 나타낸다. 이 기간에는 2008년 금융 위기, 2020년 코로나 팬데믹, 유럽 재정위기, 미-중 무역전쟁, 러시아-우크라이나 전쟁 등이 포함된다. 다양한 시장 상황을 반영하도록 데이터 수집 구간을 설정하여 예측의 정확도를 높이고자 하였다.

표 2. 섹터별 데이터

섹터	ETF 종목명
1	정보기술 TIGER 200 IT
2	금융 KODEX 은행
3	헬스케어 TIGER 헬스케어
4	소비재 KODEX 필수소비재
5	산업재 TIGER 200 산업재
6	반도체 KODEX 반도체
7	자동차 KODEX 자동차

또한 주가가 섹터별로 상이한 반응을 보이는 점을 고려하여, 각 섹터의 독립적인 특성이 금리에 어떤 영향을 받는지 분석하였다. 표 2에서 제시한 바와 같이, 일곱 가지 섹터를 대상으로 시가총액 규모가 가장 큰 대표 상장지수펀드(ETF)를 선정하여 실험을 진행하였다. 글로벌 표준 분류 체계인 GICS (Global Industry Classification Standard)를 기반으로, 11개의 주요 섹터 중 시가총액 기준 상위 5개 섹터(정보기술, 금융, 헬스케어, 소비재, 산업재)를 선정하였다. 여기에 국내 주식 시장의 특성을 반영하기 위해 시가총액에서 가장 큰 비중을 차지하는 반도체와 두 번째로 큰 비중을 차지하는 자동차를 독립된 섹터로 추가하였다. 섹터별 분석에 사용된 데이터는 전체 실험과 동일한 기간으로 설정하였다. 상장일이 2007년 이후인 경우, 해당 상장일부서의 데이터를 사용하였으며 섹터별 비교를 위해 테스트 기간은 표 3과 동일하게 설정하였다.

표 3. 데이터 기간

데이터	훈련		검증		테스트	
	기간	개수	기간	개수	기간	개수
전체 실험	2007 - 2018	2963	2019	265	2020 - 2023	1004
부분 실험 1	2011 - 2018	1966	2019	265	2020	267
부분 실험 2	2012 - 2019	1965	2020	267	2021	267
부분 실험 3	2013 - 2020	1965	2021	267	2022	263
부분 실험 4	2014 - 2021	1966	2022	263	2023	264

표 3에서와 같이, 테스트 기간은 2020년부터 2023년까지 총 4년으로, 이 기간 동안 상승장, 횡보장, 하락장 등 여러 시장 상황이 나타나 다양한 환경에서 테스트를 수행할 수 있었다. 전체 실험으로 전반적인 예측 성능을 평가하였으며, 부분 실험에서는 연도별 시장 상황에 따른 분석을 통해 다양한 시장 상황에서 모델의 예측 성능 변화를 평가하였다.

2. 변수 설정 및 전처리

변수 설정 및 전처리 단계에서는 모델의 입력 변수와 데이터 전처리 과정을 다루었다. 실험에 사용된 입력 변수는 시가, 고가, 저가, 종가, 거래량, 금리이며, 익일 종가를 목표 변수로 설정하였다. 시계열 데이터의 특성을 고려하여 sliding window의 크기를 20으로 설정하여 20일간의 데이터를 사용해 익일 종가를 예측한다. 신경망에서는 입력 데이터의 스케일 차이가 크면 모델의 학습이 비효율적이거나 수렴 속도가 느려질 수 있으므로, 식 (17)의 Min-Max Normalization을 각 입력 변수에 적용하였다.

$$\text{Min-max Normalization} : z = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (17)$$

3. 제안 모델 성능 최적화

모델의 성능을 최적화하고, 과적합을 방지하면서 일반화 성능을 최대화하기 위해 본 연구의 실험에서 일부 하이퍼파라미터를 고정하고, 나머지 하이퍼파라미터를 Grid Search를 통해 최적화하

였다. 고정된 하이퍼파라미터로는 은닉층 수, 드롭아웃 비율, 에포크가 있으며, Grid Search를 통해 최적화된 하이퍼파라미터는 배치 크기, 초기 학습률, 유닛 수이다.

본 연구에서는 데이터셋의 크기와 문제의 복잡도를 고려하여 은닉층을 두 개로 설정하였으며, 이는 모델 성능에 충분하고 과적합을 방지할 수

표 4. 모델 하이퍼파라미터

하이퍼파라미터	Search space
은닉층 수	2
에포크	100
dropout 비율	0
배치 크기	16, 32, 64, 128
초기 학습률	0.0001, 0.0003, 0.0005, 0.0007, 0.001
유닛 수	50, 100, 150, 200

있는 것으로 확인되었다. 드롭아웃은 네트워크의 일부 노드를 무작위로 비활성화하여 과적합을 방지하기 위한 기법으로, 여러 실험 결과 여러 실험 결과 드롭아웃 비율의 설정이 성능에 미치는 차이가 미미하여 드롭아웃 비율을 0으로 설정하였다. 에포크의 경우 100으로 고정하고, 검증 데이터의 손실이 10번 연속된 에포크 동안 개선되지 않으면 학습을 종료하는 Early Stopping 기법을 적용하였다.

배치 크기, 초기 학습률, 유닛 수는 Grid Search를 사용하여 표 4의 탐색 범위 내에서 최적의 성능을 보이는 값을 선택하였다. 검증 데이터의 손실이 일정 에포크 동안 개선되지 않으면 학습률을 0.5배로 줄여 조정하였다. 이때 최소 학습률을 0.00001로 설정하여 학습률이 지나치게 낮아지는 것을 방지하였다.

표 5. 회귀 모델 실험 결과

금리		RMSE		MAE		MAPE		DM statistic*
		미포함	포함	미포함	포함	미포함	포함	
전체 실험	평균	120.473	62.263	83.085	47.216	3.002	1.748	6.516**
	개선율	48.31%		43.17%		41.75%		
부분 실험 1	평균	45.232	40.973	34.309	30.492	1.576	1.438	2.347**
	개선율	9.41%		11.12%		8.76%		
부분 실험 2	평균	70.38	44.26	56.65	35.805	1.08	1.215	7.926**
	개선율	37.11%		36.79%		32.76%		
부분 실험 3	평균	34.505	30.393	27.231	24.063	1.111	0.986	3.247**
	개선율	11.91%		11.63%		11.28%		
부분 실험 4	평균	27.484	23.774	22.388	18.51	0.918	0.732	2.999**
	개선율	13.49%		17.32%		20.26%		

**는 p-value 가 0.01 미만임

표 6. 분류 모델 실험 결과

금리		F1 score		Accuracy		Precision		Recall	
		미포함	포함	미포함	포함	미포함	포함	미포함	포함
전체실험	평균	0.544	0.560	0.52	0.529	0.557	0.562	0.533	0.554
	개선율	2.86%		1.73%		1.04%		4.01%	
부분실험1	평균	0.578	0.583	0.489	0.491	0.584	0.588	0.571	0.581
	개선율	0.89%		0.28%		0.58%		1.74%	
부분실험2	평균	0.542	0.569	0.533	0.542	0.547	0.552	0.535	0.589
	개선율	5.01%		1.72%		0.84%		10%	
부분실험3	평균	0.484	0.511	0.514	0.527	0.495	0.508	0.477	0.520
	개선율	5.48%		2.56%		2.5%		9.05%	
부분실험4	평균	0.549	0.574	0.512	0.570	0.512	0.616	0.498	0.649
	개선율	8.58%		11.31%		20.31%		30.38%	

V. 실험 결과

본 연구에서는 금리를 포함하지 않은 기존 모델과 금리를 포함한 제안 모델의 성능을 5회 반복 실험하여 분석하였다. 표 5는 다섯 번의 회귀 모델 실험에서 얻은 평가지표의 평균값과 개선율, 그리고 DM 검정 통계량을 나타내며, 표 6은 다섯 번의 분류 모델 실험의 평균 평가지표와 개선율을 나타낸다. 그림 5는 회귀 모델 실험의 RMSE 결과와 등락 예측 실험의 F1 score 결과를 요약한 그래프이며 다섯 번 실험의 평균값은 다이아몬드 기호(◆)로 표시하였다. 표 5를 통해 알 수 있듯이, 금리를 포함한 모델이 금리를 포함하지 않은 모델보다 회귀 모델과 분류 모델의 모

든 평가지표에서 더 나은 성능을 보였다. 또한 수치 실험 예측에 대한 DM 검정 결과, 모두 유의수준 0.01에서 금리를 포함한 모델과 포함하지 않은 모델 간에 유의한 차이가 있음을 확인하였다.

구체적으로, 전체 실험과 부분 실험에서 금리를 포함한 제안 모델이 성능 향상을 보였다. 전체 실험에서 RMSE가 평균적으로 48.31% 감소했고, 부분 실험에서는 9.41%에서 37.11%의 감소를 보였다. 특히 부분 실험 2의 테스트 기간(2021년)에서는 제안 모델이 현저한 성능 향상을 보였는데, 이는 갑작스러운 금리 상승 이후 금리 변동이 주가에 미치는 영향이 컸던 시기였기 때문으로 해석된다. 반면, 부분 실험 1의 테스트 기간(2020년)에서는 금리 변동이 거의 없었기 때문에 기존 모델과 성능 차이가 비교적 작게 나타난 것으로

* 다섯 번의 실험 중 p-value가 가장 큰 검정 통계량의 값.

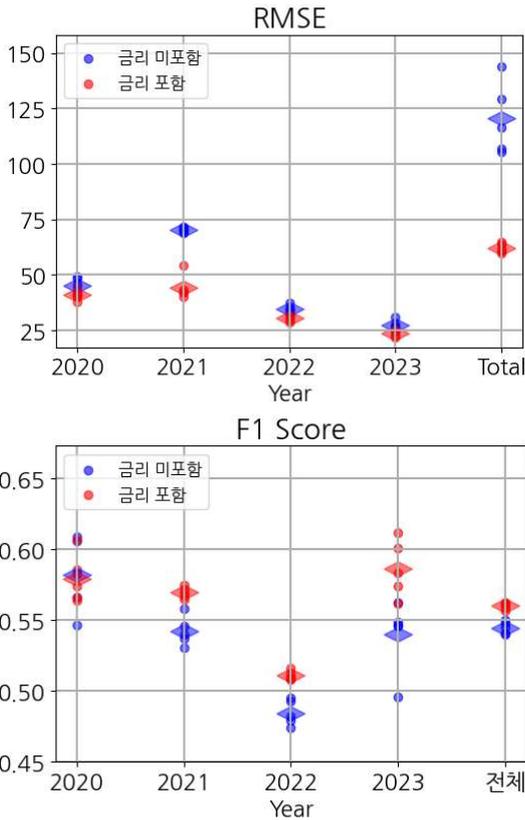


그림 5. 실험 결과

보인다. 부분 실험 3과 부분 실험 4의 테스트 기간(2022-2023년)에는 금리 인상이 점진적으로 이루어져 높은 수준이 되었지만, 모델 간 성능 차이는 부분 실험 2만큼 크지 않았다. 이는 금리 인상이 예상된 상황에서 시장이 이를 이미 반영했기 때문으로 해석된다. 결과적으로, 시장과 금리의 변동에 따라 예측 결과가 다르게 나타났으며, 특히 부분 실험 2에서와 같이 금리 변동 폭이 큰 시기에 금리를 포함한 모델의 예측 성능이 더 높아짐을 확인하였다.

또한, 표 6의 주가의 등락을 예측하는 분류 모델의 결과를 통해 등락 예측과 수치 예측의 결과가 연도별로 완벽하게 일치하지 않음을 확인하였다. 이에 따라 실제 값을 예측하는 RMSE가 더 중요한 지표로 간주되며, 등락 예측은 보조적인 역할을 수행할 수 있다. 특히, 부분 실험 4에서 금리를 포함한 모델이 8.58%의 개선율을 보였으나, RMSE가 여전히 핵심 지표로서, 등락 예측은 부차적인 분석 도구로 사용될 수 있다.

표 7. 섹터별 실험 결과

섹터	금리	RMSE*	
		미포함	포함
정보기술	평균	2686.84	1826.38
	개선율	32.02%	
금융	평균	711.114	629.388
	개선율	11.49%	
헬스케어	평균	1451.5	1194.45
	개선율	17.7%	
소비재	평균	674.24	608.319
	개선율	9.77%	
산업재	평균	445.12	420.314
	개선율	5.57%	
반도체	평균	3123.66	1317.78
	개선율	57.81%	
자동차	평균	455.073	355.768
	개선율	21.82%	

표 7의 섹터별 분석 결과에 따르면, 금리를 포함한 모델의 예측력이 전반적으로 개선되었으며, 특히 정보기술 및 반도체 섹터에서 두드러진 성능 향상이 나타났다. 정보기술 섹터(TIGER 200 IT)의 경우 32.02%의 예측력 개선을 보였고, 반도체 섹터(KODEX 반도체)는 57.81%의 개선을 기록하였다. 이는 두 섹터가 경기 민감주로 분류되기 때문으로 해석된다.

정보기술 섹터와 반도체 섹터 ETF의 구성 종목에는 SK하이닉스와 삼성전자와 같은 주요 기업들이 포함되어 있으며, 각각 20% 이상의 비중을 차지하고 있다. 이들 기업은 자본 집약적인 특성으로 인해 금리 변동에 민감하며, 금리 상승 시 자본 조달 비용이 증가하여 신기술 개발과 생산 투자에 부담이 가중될 수 있다. 특히 경기 민감도가 높은 반도체 및 전자 제품 수요는 경기 사이클에 크게 영향을 받기 때문에, 금리 변동이 매출과 성장성에 더욱 직접적인 영향을 미친다. 이러한 이유로 금리를 포함한 모델이 해당 산업의 금리 변동을 더 효과적으로 반영하여 예측 성능을 향상시킨 것으로 보인다.

금리 변동에 직접적인 영향을 받는 금융 섹터는 11.49%의 개선율을 보였다. 금리 상승 시 대

* 모든 섹터별 실험에서 p-value는 0.01 미만이었다.

출 이자 수익이 증가하는 긍정적인 영향과 대출 수요 감소, 자산 가치 하락과 같은 부정적인 영향이 동시에 작용했기 때문으로 보이며, 이러한 상반된 요인들로 인해 금리 변동의 효과가 일부 상쇄되어, 금융 섹터의 예측력 개선 폭은 상대적으로 낮았다고 해석된다.

VI. 결 론

본 연구에서는 LSTM 기반의 주가 예측 모델에 금리를 변수로 추가하여 예측 성능을 향상시켰다. 금리를 포함한 제안 모델의 성능은 연도별 부분 실험에서 RMSE 기준 최소 9.41%에서 최대 37.11%까지 개선되었으며, 전체 실험에서는 48.31%의 성능 향상을 확인할 수 있었다. 특히 2021년에는 코로나 이후 갑작스러운 금리 상승이 발생했으며, 이러한 변동을 모델이 효과적으로 반영하여 예측 정확도가 37.11% 향상되었다. 섹터별 분석에서도 RMSE가 5.57%에서 57.81%까지 개선되었으며, 정보기술(32.02%)과 반도체(57.81%) 섹터에서 가장 큰 개선 효과를 보였다. 이는 금리가 주가 예측에서 오차를 줄이고 예측 성능을 향상시키는 핵심적인 역할을 한다는 점을 시사한다.

다만, 본 연구에서는 금리의 영향을 분석하기 위해 다른 변수들을 의도적으로 배제하였다. 이 때문에 주가가 급격히 상승하여 과거에 비해 높은 수준을 형성한 경우, 모델 학습에 어려움이 발생했다. 급격한 주가 변동을 효과적으로 반영하기 위해, 향후 연구에서는 이동평균(MA)이나 장단기 이동평균선(MACD)과 같은 기술적 지표를 추가 변수로 포함하는 방안을 고려할 필요가 있다[26].

REFERENCES

- [1] Bhandari, H.N., Rimal, B., Pokhrel, N.R., Rimal, R., Dahal, K.R. and Khatri, R.K., "Predicting stock market index using LSTM," *Machine Learning with Applications*, vol. 9, p. 100320, 2022.
- [2] Xu, Y. and Keselj, V., "Stock prediction using deep learning and sentiment analysis", *In 2019 IEEE international conference on big data (big data)*, IEEE, pp. 5573-5580, Dec. 2019.
- [3] Sunny, M.A.I., Maswood, M.M.S. and Alharbi, A.G., "Deep learning-based stock price prediction using LSTM and bi-directional LSTM model", *In 2020 2nd novel intelligent and leading emerging sciences conference (NILES)*, IEEE, pp. 87-92, Oct. 2020.
- [4] Nelson, D.M., Pereira, A.C. and De Oliveira, R.A., "Stock market's price movement prediction with LSTM neural networks", *In 2017 International joint conference on neural networks (IJCNN)*, IEEE, pp. 1419-1426, May 2017.
- [5] Liu, S., Liao, G. and Ding, Y., "Stock transaction prediction modeling and analysis based on LSTM", *In 2018 13th IEEE Conference on Industrial Electronics and Applications (ICIEA)*, IEEE, pp. 2787-2790, May 2018.
- [6] Selvin, S., Vinayakumar, R., Gopalakrishnan, E.A., Menon, V.K. and Soman, K.P., "Stock price prediction using LSTM, RNN and CNN-sliding window model", *In 2017 international conference on advances in computing, communications and informatics (icacci)*, IEEE, pp. 1643-1647, Sep. 2017.
- [7] Rapach, D.E., Strauss, J.K. and Zhou, G., "International stock return predictability: What is the role of the United States?," *The Journal of Finance*, vol. 68, no. 4, pp. 1633-1662, 2013.
- [8] Haque, M. S., Amin, M. S., Miah, J., Cao, D. M., Ahmed, A. H., "Boosting Stock Price Prediction with Anticipated Macro Policy Changes", *Journal of Mathematics and Statistics Studies*, vol. 4, no. 3, pp. 29 - 34, 2023.
- [9] 황희수, "코스피 방향 예측을 위한 하이브리드 머신러닝 모델," *한국융합학회논문지*, 제12권, 제6호, 9-16쪽, 2021년
- [10] 황주훈, 김창복, "기술분석과 환경요소를 이용한 주가 예측을 향상을 위한 딥러닝 병렬 모델," *한국정보기술학회논문지*, 제21권, 11호, 53-61쪽, 2023년 11월
- [11] 한태동, "LSTM을 이용한 주가 예측: 기술 지표, 거시 경제 지표, 시장 심리의 조합을 중심으로," *융합지식학회논문지*, 제9권, 4호, 189-198쪽, 2021년 11월
- [12] 정종진, 김지연, "LSTM을 이용한 주가 예측 모델의 학습방법에 따른 성능 분석," *디지털융복합연구*, 제18권, 11호, 259-266쪽, 2020년
- [13] Cohen, I., Huang, Y., Chen, J., Benesty, J., Benesty, J., Chen, J., Huang, Y. and Cohen, I., "Pearson correlation coefficient," *Noise reduction*

- in speech processing*, pp. 1-4, 2004
- [14] Graves, A. and Graves, A., "Long short-term memory", *Supervised sequence labelling with recurrent neural networks*, pp. 37-45, 2012.
- [15] Fischer, T. and Krauss, C., "Deep learning with long short-term memory networks for financial market predictions", *European journal of operational research*, vol. 270, no. 2, pp.654-669, 2018.
- [16] Bukhari, A.H., Raja, M.A.Z., Sulaiman, M., Islam, S., Shoab, M. and Kumam, P., "Fractional neuro-sequential ARFIMA-LSTM for financial market forecasting," *Ieee Access*, vol. 8, pp. 71326-71338, 2020.
- [17] Song, D., Baek, A.M.C. and Kim, N., "Forecasting stock market indices using padding-based fourier transform denoising and time series deep learning models", *IEEE Access*, vol. 9, pp.83786-83796. 2021.
- [18] Song, D., Busogi, M., Baek, A.M. and Kim, N., "Forecasting stock market index based on pattern-driven long short-term memory," *Economic Computation & Economic Cybernetics Studies & Research*, vol. 54, no. 3, 2020.
- [19] Vuong, P.H., Dat, T.T., Mai, T.K. and Uyen, P.H., "Stock-price forecasting based on XGBoost and LSTM," *Computer Systems Science & Engineering*, vol. 40, no.1, 2022.
- [20] Basak, S., Kar, S., Saha, S., Khaidem, L. and Dey, S.R., : "Predicting the direction of stock market prices using tree-based classifiers", *The North American Journal of Economics and Finance*, vol. 47, pp. 552-567, 2019.
- [21] Peng, Y., Albuquerque, P.H.M., Kimura, H. and Saavedra, C.A.P.B., "Feature selection and deep neural networks for stock price direction forecasting using technical analysis indicators," *Machine Learning with Applications*, vol. 5, p. 100060, 2021.
- [22] Diebold, F.X. and Mariano, R.S., "Comparing predictive accuracy", *Journal of Business & economic statistics*, vol. 20, no. 1, pp. 134-144, 2002.
- [23] Giacomini, R. and White, H., "Tests of conditional predictive ability", *Econometrica*, vol. 74, no. 6, pp. 1545-1578, 2006.
- [24] Harvey, D., Leybourne, S. and Newbold, P., "Testing the equality of prediction mean squared errors", *International Journal of forecasting*, vol. 13, no. 2, pp. 281-291, 1997.
- [25] Kim, H.G. and Kim, J.H., "Forecasting the elasticity of variance with LSTM recurrent neural networks", *International Journal of*

Computer Mathematics, vol. 100, no. 1, pp. 209-218, 2023.

- [26] Kara, Y., Boyacioglu, M.A. and Baykan, Ö.K., "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*, vol. 38, no. 5, pp. 5311-5319, 2011.

저자 소개



김은솔(준회원)

2020년 조선대학교 경제학과 학사 졸업.
2023년~현재 전남대학교 데이터사이언스대학원 석사 과정.

<주관심분야: 딥러닝, 금융데이터분석>



전재기(정회원)

2010년 연세대학교 수학과 학사 졸업.
2019년 연세대학교 수학과 박사 졸업.
2019년~2020년 연세대학교 수학과 응용 해석및계산센터 박사후연구원.
2020년~2022년 서울대학교 수리과학부 미래인재양성교육연구단 박사후연구원

2022년~현재 전남대학교 데이터사이언스대학원 조교수

<주관심분야: 파생상품 가격결정, 금융시계열 모델링, 알고리즘 트레이딩, 강화학습기반 포트폴리오 최적화>