

딥러닝을 이용한 Intraday 주가 예측 및 매매전략

홍윤식^o, 주창희^{**}

^o고려대학교 인공지능융합학과,

^{*}미래에셋자산운용,

^{**}고려대학교 컴퓨터학과

e-mail: shane0112@korea.ac.kr^o, changhee@korea.ac.kr^{**}

The Prediction and Trading Strategy for Intraday Stock Price Movements: A Deep Learning Approach

Yoonsik Hong^o, Changhee Joo^{**}

^oDept. of Applied Artificial Intelligence, Korea University,

^{*}Mirae Asset Global Investments,

^{**}Dept. of Computer Science and Engineering, Korea University

● 요약 ●

본 연구는 국내 주식의 intraday 가격변화를 딥러닝 모형들로 예측하고 그 예측모형을 이용한 매매전략 딥러닝 모형을 제안한다. 주식의 intraday 가격변화에 따라서, 고빈도 매매, 주문집행문제 (order execution problem), 자동화 매매 등과 같은 intraday 주식 트레이딩의 수익률이 달라지기 때문에, 주식의 intraday 가격변화 예측은 주식 투자에 있어서 중요하다. 해외 시장에 대해서는 인공지능 등을 이용한 intraday 가격변화 예측 연구가 활발히 이루어졌지만, 국내의 경우 관련한 연구가 드물어 그 효용성이 명확히 드러나지 않았다. 그에 따라서, KOSPI 50의 구성 종목에 대하여 정준의(canonical) 딥러닝 모형들을 적용하여 예측 성능을 비교한다. 또한, 그 예측모형들을 활용하여 간소화된 주문집행문제에서의 매매전략 딥러닝 모형을 제안한다. 그리고, 제안한 매매전략 딥러닝 모형을 KOSPI 50의 구성 종목에 대하여 실험하여, 제안한 방법론이 유효함을 밝힌다. 제시된 모형을 실제 주식 매매에 직접 적용하여 수익성을 개선할 수 있고, 사람이 직접 거래할지라도 효과적인 보조 지표가 될 수 있기에 본 논문은 실용적 의미를 지닌다.

키워드: 주가 예측 (stock prediction), 딥러닝 (deep learning), 매매전략 (execution strategy)

I. Introduction

주식 투자자들은 거래 빈도에 따라서 [1], 하루에도 많은 거래를 하는 고빈도 (high frequency) 매매 투자자와 중빈도 이하의 투자자로 분류될 수 있는 데, 두 종류 투자자 모두 intraday 주가 변화가 중요하다. Intraday 주가 변화는 주식 A의 가격이 09시 30분의 9000원에서 09시 40분에는 9500원이 되는 것처럼 하루 동안의 주가 변화를 의미한다. 먼저, 고빈도 매매 투자자의 수익률은 intraday 주가 변화에 직결되기에 intraday 주가 예측이 매우 중요하고, 그 예측에 맞춘 매매전략이 필요하다. 또한, 연구 [2]에 따르면 중빈도 이하 펀드 수익률도 매매 주문집행에 상당한 영향을 받아, 주식 투자에 있어서 intraday 주가 변화 예측 및 매매전략은 중요하다.

이러한 중요성과 필요성에도, 관련한 인공지능(AI) 연구가 국내에서 매우 드물어, 국내 intraday 매매와 관련한 AI 기술 적용에 제한이 있었다. 이러한 제한을 해소하기 위하여, 먼저 본 연구는 국내 주식

시장의 intraday 가격변화 예측을 위한 정준(canonical) 딥러닝 예측 모형(prediction model; 이하 PM)들을 검토한다. 그리고, 학습된 PM들을 이용하여 간소화된 주문집행문제 (order execution problem; 이하 OEP)를 위한 매매전략 딥러닝 모형 (trading model; 이하 TM)을 제안하고 실험하여 그 유효성을 밝힌다.

만들어진 딥러닝 PM과 TM을 실제로 현장에 적용할 경우, 수익성 개선을 기대할 수 있을 뿐만 아니라 사람의 주식 매매에 매우 효과적인 보조 지표로 사용이 될 수 있어 본 논문은 실용적인 의미를 지닌다.

II. Preliminaries

해외에서는 미국[3], 영국[4], FI-2010[4, 5] 등에 대한 intraday PM 연구들이 있었으나, 그 예측들을 딥러닝 기반 TM으로 연결하지는

못하였다. 국내에서도 기계학습 기반의 연구들[6, 7]이 있었으나, intraday 주가 움직임에 대한 PM은 매우 드물었다. 본 연구에서는 두 가지 한계점에 대해 다룬다.

PM 외에, 본 논문은 간소화된 OEP에 대한 TM을 제시하는데, OEP는 주어진 시간 동안 특정 주식을 특정 수량만큼 매수(매도)하려 할 때, 체결 과정의 손실(수익)을 최소화(최대화)하는 체결 전략을 찾는 문제이다 [8]. 주어진 시간 동안 균등한 수량을 연속적으로 주문하는 TWAP 전략을 [8]이 제시하였지만, 비현실적 가정들로 한계가 있었다 [9]. 근래에 강화학습 기반 접근들[9, 10]이 제시되었지만, 기존에 만들어진 PM을 활용하는 구조는 아니었다. 본 논문은 기존에 만들어진 PM이 사용될 수 있도록 TM을 설계하여, 기존 자원 또한 이용될 수 있게 하였다. 한편, 시장의 거래량기중평균가격(VWAP) 대비 평균체결가로 정의되는 price advantage (PA)가 OEP 전략 평가에 사용된다[9]. $VWAP_{[t_a, t_b]}$ 은 $t_a \sim t_b$ 기간의 거래대금을 거래량으로 나눈 값이다.

III. The Proposed Scheme

1. 문제 정의

주식거래시간에 속하는 시점 t_i 는 $\Delta t_i = t_i - t_{i-1}$ 이 상수 1분이 되도록, I_{all} 은 모든 i 의 집합으로, 정의한다. 본 연구는 Fig. 1과 같이 t_{i^*} 시점에 주식 $s \in S = \{s' : \text{연구대상주식}\}$ 을 L 주 만큼 $t_{i^*+T_1}$ 시점까지 매도하기로 결정했을 때, 어떻게 매도할지를 다룬다. 이때, $[t_{i^*}, t_{i^*+T_1}]$ 은 데이터 수신 및 모형 inference 시간으로, $[t_{i^*}, t_{i^*+T_1}]$ 는 매도주문을 체결시키는 기간으로 정의한다. 모형은 t_{i^*} 이전의 $[t_{i^*-T_0}, t_{i^*})$ 기간의 변수 p 개에 대한 데이터 $X_{s, i^*} \in \mathbb{R}^{T_0 \times p}$ 를 이용한다. X_{s, i^*} 의 각 행은 $[t_{i^*-T_0}, t_{i^*})$ 의 부분 구간인 $[t_i, t_{i+1})$ 의 데이터인 $\mathbf{x}_{s, t_i} \in \mathbb{R}^p$ 이다. 실험에서는 $T_0 = 10$, $T_1 = 9$ 이 사용되었다.

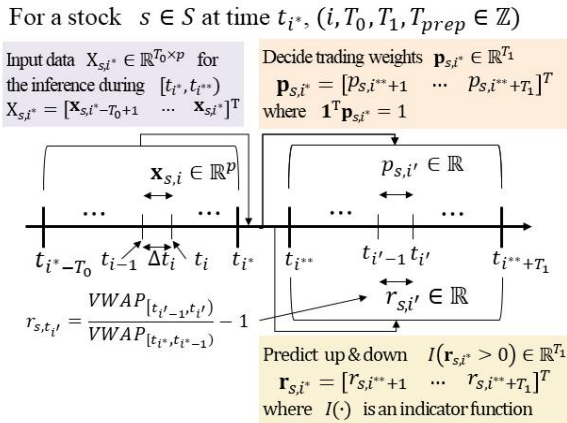


Fig. 1. The Timeline of the Problem

$r_{s, i'}$ 을 매도 결정 직전의 $VWAP_{[t_{i^*}, t_{i^*+T_1}]}$ 대비 예측구간 $VWAP_{[t_{i'-1}, t_{i'}]}$ 의 변화율이라 할 때, $r_{s, i'}$ 가 양수일지에 대한 확률 $P(r_{s, i'} > 0)$ 을 PM이 예측한다. 한편, 본래 OEP를 간소화하여 각 $[t_{i'-1}, t_{i'}]$ 에 체결시킬 비중 $p_{s, i'} \in [0, 1]$ 을 TM이 결정하고, 결정된 비중은 해당 기간의 VWAP으로 체결된다 가정한다. 문제를, 단일한 매매전략이 아닌 intraday PM과 TM 2가지로 나눈 이유는, 기존에 TM보다는 일반적인 예측에 대한 연구가 더 많이 이뤄졌기에 기존 연구를 활용하여 매매전략을 구성할 수 있도록 하기 위함이다. 또한, 단일한 매매전략 문제 접근으로 강화학습을 적용할 경우, 고차원 공간, 부분관측, 등의 문제점들로 학습 자체가 어려울 수 있기 때문이다 [11].

2. Model Architectures

PM과 TM은 개별 주식별로 개별 모형을 만드는 것이 아닌, 모든 주식에 통용되는 모형이다. 하지만, 통용되는 PM일지라도, 여러 구조를 가지는 PM을 실험한다. 그 모형들의 인덱스를 m 이라 하자.

Fig. 2는 여러 PM들의 일반적인 구조를 보여준다. 크게 backbone ϕ_m 와 head ψ_m 부분으로 나누어진다. ϕ_m 은 임의의 배치 $B = \{(s, i^*) : s \in S, i^* \in I_{all}\}$ 의 X_B 입력을 받아 2차원 배열을 출력한다. 모형에 따라서 2차원이 아닌 차원의 출력을 낼 수 있으므로 ϕ_m 은 마지막에 flattening을 수행하여 2차원 배열을 출력한다. 각 PM의 ϕ_m 구조는 차이가 있지만, ψ_m 는 모두 동일하게 1 - fully connected layer (FC) 구조로, 최종적으로 sigmoid 활성화 함수를 통과시켜 상승확률 $Z_{B, m} = P(r_{s, i'} > 0)$ 을 출력한다. 실험에서는 여러 층의 FC, LSTM, GRU, self-scaled-dot-product attention (이하 Attention) [12]을 이용한 총 4개 ϕ_m 를 이용하였다.

TM은, 먼저 입력 X_B 를 이미 학습된 여러 ϕ_m 을 사용하여 $Y_{B, m}$ 으로 변환한다. $Y_{B, m}$ 을 단일 층 FC인 ξ_m 에 통과시켜, 모두 p'' 열인 $W_{B, m}$ 을 출력한다. 그 후, concat 연산과 여러 FC층들로 구성된 χ 에 $W_{B, m}$ 를 통과시켜 $Z_{B, m}$ 을 출력한다. χ 의 마지막 활성화 함수는 softmax로 T_1 개 시점들의 매도 비중 출력한다. 한편, TM 학습 시, ϕ_m 의 파라미터는 고정(frozen)되어 학습되지 않고, ξ_m 와 χ 만 학습된다.




Fig. 2. The General Architecture of PM

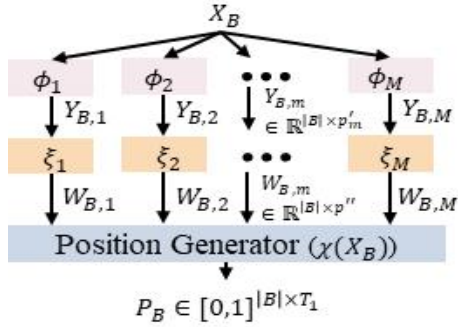


Fig. 3. The Execution Model

3. Learning Scheme

먼저 PM들이 학습된 후, 만들어진 PM들로 TM을 구성하여 학습시킨다. TM과 PM 모두 동일 train 데이터로 학습된다. PM은 binary cross entropy loss를 최소화하도록 학습시켰다. TM은 지도학습방식이 아니라, 위험을 줄이면서 수익을 극대화되도록 학습되어야 하므로 다음과 같이 목적함수를 정의하였다.

앞선 $r_{s,i}$ 의 배치를 R_B 라 할 때, $q_B = [q_i]_{i \in B} = (P_B \circ R_B) \mathbf{1} \in \mathbb{R}^{|B|}$ 라 하면 ($\mathbf{1}$ 은 one 벡터, \circ 은 Hadamard 곱), q_i 는 TM 출력값의 $[t_{i^*-1}, t_{i^*})$ 가격 대비 수익률을 의미한다. 해당 수익률이 음수인 인덱스를 뽑은 $B' = \{i : i \in B \text{ and } q_i < 0\}$ 라 할 때, TM은 (1)로 학습된다. π_B 는 수익률 극대화를, π_B^- 는 손실 리스크 축소를 위한 항이다. γ 는 두 항을 저울질하는 하이퍼파라미터로, $\gamma = 1$ 로 실험하였다.

$$\text{maximize } \pi_B + \gamma \pi_B^- \quad (1)$$

$$\text{where } \pi_B = \frac{1}{|B|} \sum_{i \in B} q_i ; \pi_B^- = \frac{1}{|B'|} \sum_{i \in B'} q_i \quad (2)$$

한편, 학습 방식에 따른 성능 차이를 방지하기 위하여, 다음 학습 방식을 모든 모형에 적용하였다. Adam optimizer를 사용한다. Validation 매트릭을 학습의 매 epoch 확인하여, 직전 epoch보다 개선이 없다면 0.9를 learning rate에 곱하여 감소시킨다. 7 epochs 연속하여 개선이 없다면 학습을 중단하고, 가장 좋은 validation 매트릭을 보여준 파라미터를 최종 사용한다. Validation 매트릭으로 PM은 accuracy를, TM은 목적함수를 사용하였다.

IV. Experimental Results

1. Data

한국거래소로부터 KOSPI50 구성 종목(2021. 12. 30. 기준)에 대한, 2022년 1~4월의 단일가 매매를 제외한 정규장의 매 1분 주가 및 관련 변수들 데이터를 구하였다. 해당 데이터는 전처리 및 엔지니어링 되어 수익률, 거래 규모, 가격변화, 스프레드, 매매 불균형 등에 관련한 $p = 44$ 개 변수가 사용되었다.




Fig. 4. The Train/Validation/Test Scheme

2. 실험 환경

Fig. 4.은 TM과 PM의 학습과 평가 방식을 보여준다. 모형은 매주 일요일에 학습된다. 학습된 모형이 다가오는 1주일 동안 사용(test)되는 것을 가정하였다. 따라서, test 구간들은 매주 월요일에 시작하여 일요일에 끝난다. Test 전 5거래일은 validation으로, 그리고 그 전 가장 최근 30거래일은 train 데이터로 사용된다. 각 거래일 데이터는, 매도결정시점 기준 09:19~15:09의 50개 주식에 대해, 총 약 1.7만 샘플로 구성된다. 이러한 방식을 매주 반복한다.

3. 실험 결과

PM은 multi-layer FC, Attention, LSTM, GRU를 ϕ_m 에 사용한 4가지 모형과 light gradient boosting model (LGBM) 기계학습 모형이 대조군으로 실험되었다. 그 결과 Table 1.처럼 딥러닝 기반 모형들이 LGBM 보다 모두 좋은 성능을 보여주었고, 그중 LSTM이 가장 좋은 성능을 보여주었다.

TWAP전략으로, 4가지 PM의 출력값이 scaling 된 매도 비중으로, 제안된 TM으로, 매도하는 경우의 실험 결과를 Table 2가 보여준다. 그 결과 제안된 TM이, 단순 PM들에 비하여 PA 평균에서는 3배 이상, PA 표준편차 대비 평균에서는 2배 가량 우수한 것을 확인할 수 있었다. 본 결과로부터 예측뿐만 아니라 주문 전략이 수익률에 많은 영향을 끼쳐 본 논문이 제시한 TM이 중요함을 보여준다. 한편, 단순 PM 기반 매매도 TWAP 전략보다는 좋은 성능을 보여주었다. Losing은 손실 발생 비율을 의미하는데, TM이 가장 낮아 위험도 또한 낮은 것을 볼 수 있다.

Table 1. The Evaluation of PMs

Models	Accuracy	F1	Precision	Recall
LSTM	75.71%	75.59%	75.30%	75.89%
GRU	75.61%	75.57%	75.02%	76.13%
Attention	75.22%	74.92%	75.17%	74.67%
MLP	74.69%	74.42%	74.55%	74.29%
LGBM	72.92%	72.29%	73.06%	71.53%

Table 2. The PA (bps) of TMs

Models	Mean PA (bp)	Mean/Std	Losing (%)
TM	3.1716	0.2488	36.95
LSTM	0.9727	0.1462	39.52
GRU	0.9543	0.1441	39.62
Attention	0.8415	0.1298	40.32
MLP	0.8170	0.1278	40.51
TWAP	0.4020	0.0671	43.56

V. Conclusions

지금까지, KOSPI 50 종목에 대한 intraday 주가 예측 및 매매전략 딥러닝 모형을 제시하고 실험하여 그 유효성을 밝히었다. 해외와 달리, 국내 주식시장은 intraday 주가에 관한 AI 연구가 많이 이루어지지 않아 한계점이 있었는데, 정준의 딥러닝 모형실험을 통하여 국내시장에서도 인공지능 방법론이 유효함을 보였다. 또한, 단순히 예측만이 아닌, 예측모형을 실제 매매로 연결시키는 OEP 매매전략모형 제시를 통해서 수익을 개선할 수 있음을 보였다.

REFERENCES

- [1] S. Jeong, and K. Lee, "Return on Investment and Trading Frequency of the Individual Investors of the Korean Stock Market," *Journal of Industrial Economics and Business*, Vol. 20, No. 6, pp. 2399-2415, December 2007.
- [2] R. Edelen et al., "Shedding light on "invisible" costs: Trading costs and mutual fund performance," *Financial Analysts Journal*, Vol. 69, No. 1, pp. 33-44, December 2018. DOI: 10.2469/faj.v69.n1.6
- [3] G. Taroon et al., "Employing Deep Learning In Intraday Stock Trading," 2020 Fifth International Conference on Research in Computational Intelligence and Communication Networks (ICRCICN), pp. 209-214, Bangalore, India, November 2020. DOI: 10.1109/ICRCICN50933.2020.9296174
- [4] Z. Zhang et al., "Deeplob: Deep convolutional neural networks for limit order books," *IEEE Transactions on Signal Processing*, Vol. 67, No. 11, pp. 3001-3012, March 2019. DOI: 10.1109/TSP.2019.2907260
- [5] J. Wallbridge, "Transformers for limit order books," <https://arxiv.org/abs/2003.00130>
- [6] Y. Kim et al., "Increasing Accuracy of Stock Price Pattern Prediction through Data Augmentation for Deep Learning," *The Korean Journal of BigData*, Vol. 4, No. 2, pp. 1-12, December 2019.
- [7] E. Ryoo et al., "Deep Learning-based Stock Price Prediction Using Limit Order Books and News Headlines," *The Journal of Society for e-Business Studies*, Vol. 27, No. 1, pp. 63-79, February 2022.
- [8] D. Bertsimas, and A. W. Lo, "Optimal control of execution costs," *Journal of Financial Markets*, Vol. 1, No. 1, pp. 1-50, April 1998. DOI: 10.1016/S1386-4181(97)00012-8
- [9] Y. Fang et al., "Universal Trading for Order Execution with Oracle Policy Distillation," *Proceedings of the AAAI Conference on Artificial Intelligence*, pp. 107-115, Palo Alto, California, USA, May 2021.
- [10] Y. Hong, and C. Joo, "Order Execution in KOSPI 50: A Reinforcement Learning Approach with Continuous Demonstrations," *KSII Transactions on Internet and Information Systems*, Under Review.
- [11] Z. Zhu, K. Lin, and J. Zhou, "Transfer learning in deep reinforcement learning: A survey," <https://arxiv.org/abs/2009.07888>
- [12] A. Vaswani et al., "Attention is all you need," 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, California, USA, December 2017. DOI: 10.48550/arXiv.1706.03762