

가역 인스턴스 정규화와 장단기 메모리를 결합한 암호화폐 가격 예측 모델

강경문, 조인휘*
한양대학교, *한양대학교

jw540836088@hanyang.ac.kr, *iwjoe@hanyang.ac.kr

Cryptocurrency Price Prediction Model Combining Reversible Instance Normalization and Long Short-Term Memory

Jiang Jing Wen, Joe In Whee*
Hanyang Univ., *Hanyang Univ.

요약

암호화폐 시장의 극심한 변동성과 복잡성은 정확한 가격 예측에 상당한 과제를 안겨준다. 기존의 시계열 예측 방법은 종종 암호화폐 데이터의 비선형성과 불확실성으로 인해 기대에 미치지 못한다. 이 논문은 Reversible Instance Normalization(RevIN)과 Long Short-Term Memory(LSTM) 네트워크를 통합하여 암호화폐 가격 예측에 대한 새로운 접근 방식을 제안한다. BTC, ETH, BNB, SOL, XRP 5 가지 암호화폐 데이터를 활용한 실험 결과, 제안된 방법은 다양한 평가 지표에서 다른 모델보다 훨씬 뛰어난 성능을 보여주어 암호화폐 시장의 급격한 변화와 복잡성을 처리하는 데 있어 효율성을 입증한다.

I. 서론

암호화폐 시장의 극심한 변동성과 복잡성은 투자자와 연구자 모두에게 상당한 도전과 기회를 제공한다. 비트코인과 이더리움과 같은 암호화폐의 가치가 계속 상승함에 따라, 가격 움직임을 정확하게 예측하는 것은 금융 기술 분야에서 중요한 문제가 되었다. 기존의 시계열 예측 방법은 암호화폐 시장의 비선형성과 높은 불확실성에 직면했을 때 종종 성과가 좋지 않아 연구자들은 보다 진보된 머신 러닝과 딥 러닝 기술로 전환하게 되었다. 최근 몇 년 동안 딥 러닝 모델, 특히 순환 신경망(RNN)과 장단기 메모리(LSTM) 및 게이트 순환 유닛(GRU)과 같은 변형은 시계열 예측 작업에서 뛰어난 성능을 보였다. 이러한 모델은 데이터의 장기적 종속성을 포착할 수 있으므로 금융 시계열 데이터 처리에 특히 적합하다[1]. 그러나 고빈도 거래 환경에서 이러한 모델은 여전히 과적합, 계산 효율성, 예측 안정성과 같은 과제에 직면한다. 이 연구에서는 RevIN(Reversible Instance Normalization)[2]와 LSTM 을 결합한 새로운 RevIN-LSTM 모델을 제안하여 암호화폐 가격 예측의 정확도와 안정성을 개선하는 것을 목표로 한다. 우리의 접근 방식은 장기적 종속성을 포착하는 LSTM 의 이점을 활용할 뿐만 아니라 RevIN 기술을 통해 매우 변동성이 큰 데이터를 처리하는 모델의 능력을 향상시킨다.

II. 본론

1. 제안 방법

예측 모델의 품질과 신뢰성을 보장하기 위해 우리는 먼저 CEEMDAN(Complete Ensemble Empirical Mode Decomposition with Adaptive Noise) 메서드[3]를 사용하여 종가 시퀀스를 여러 고유 모드 함수(IMF) 및 잔차(residual)로 분해한다. CEEMDAN 기술은 신호처리에서 비선형 및 비정상 시계열을 분석할 때 유용하게 사용되며, 복잡한 데이터를 여러 주파수 성분으로 나누어 모델이 다양한 패턴을 학습할 수 있도록 돕는다. 암호화폐 가격과 같은 비정상적인 시계열 데이터를 여러 IMF 와 잔차로 분해함으로써, 모델은 비선형적이고 복잡한 패턴을 더 명확하게 학습할 수 있다. 분해된 구성 요소들은 기존의 피쳐(시가, 고가, 저가, 종가, 거래량)에 추가되어 데이터의 다양성을 높였으며, 이는 모델이 더 복잡한 패턴을 학습하는 데 도움이 된다. 특히, 이 분해 기법은 암호화폐 시장의 급격한 변동성에 따른 다양한 주파수 성분을 구분하여 모델이 단기적 및 장기적 변화를 효과적으로 처리할 수 있다. 이러한 전처리 과정은 암호화폐 시장의 비선형성과 높은 변동성 문제를 해결하는 데 중요한 역할을 했습니다. 시계열 데이터는 종종 평균과 분산이 시간이 지남에 따라 변하는 비정상적인 특성을 보인다. 이로 인해 학습 데이터와 테스트 데이터의 분포가 달라지고, 이는 모델의 성능 저하로 이어질 수 있다. 이 문제를 해결하기 위해 우리는 RevIN(Reversible Instance Normalization) 기술을 도입다. RevIN 은 학습 시 입력 데이터를 정규화한 후, 예측 결과가 나올 때 비정규화하여 원래 분포로 복원하는 과정을 거친다. 이를 통해 학습 데이터와 테스트 데이터 간의 분포 차이로 인한 성능 저하를 최소화하고, 예측 결과의 신뢰성을 높일 수 있다. 마지막으로 LSTM 네트워크를 사용하여 암호화폐 데이터의 시간적 종속성을 포착한다. 게이팅

메커니즘과 내부 메모리 장치를 통해 LSTM 은 긴 시퀀스, 학습 패턴 및 데이터의 추세에 대한 정보를 유지할 수 있기 때문에 이 작업에 적합하다. LSTM 계층의 출력은 Dense 레이어를 거쳐 최종 예측을 내린다. 자세한 모델 구성은 그림 1 에 나와 있다.

2. 실험 결과

이 연구에서 사용된 데이터 세트는 2021 년 4 월부터 2024 년 4 월까지 5 개의 다양한 암호화폐(BTC, ETH, BNB, SOL, XRP)에 대한 일일 과거 데이터로 구성되어 있으며, 총 1120 개 거래일이며, 여기에는 시가, 고가, 저가, 종가, 거래량과 같은 특징이 포함되어 있다. 우리는 이를 3:1:1 의 비율로 훈련 세트, 검증 세트, 테스트 세트로 나누며, 2023 년 10 월 16 일 이전의 과거 데이터는 훈련 세트와 검증 세트로 나뉜다. 테스트 세트에는 2023 년 10 월 16 일부터 2024 년 4 월 24 일까지 총 192 개 거래일의 데이터가 포함되어 있으며, 훈련된 모델은 테스트 세트의 데이터를 입력으로 사용하여 증가를 예측한다. 이 논문에서 각 입력에는 32 개 연속 거래일이 포함된다. 즉, 이전 32 개 거래일의 데이터를 활용하여 다음 날의 증가를 예측한다. 표 1 에 설명된 실험 결과는 암호화폐 가격 예측에서 RevIN-LSTM 모델의 효율성을 명확하게 강조한다. 이 모델은 가장 낮은 RMSE 를 달성하여 실제 가격과의 편차가 최소화되었을 뿐만 아니라, 가장 낮은 MAE 를 기록하여 예측 정확도가 높다는 것을 나타낸다. 또한 모델의 MAPE 는 테스트된 모델 중에서 가장 낮으며 예측의 정확성을 나타낸다. 높은 R^2 값은 모델이 가격 변동의 변동을 효과적으로 포착하는 강력한 설명력을 가지고 있음을 나타낸다. 그림 2 는 실제 암호화폐 종가 시리츠와 대조하여 모델의 예측 곡선을 시각화하였다. 파란색 곡선은 실제 증가를 나타내고 빨간색 곡선은 RevIN-LSTM 을 나타낸다. 그림에서 RevIN-LSTM 은 최소한의 편차로 BTC, ETH, BNB 및 SOL 에 가장 잘 맞는다는 것을 알 수 있다. XRP 에서 시간 간격의 중간과 꼬리에 어느 정도 상위 편차가 나타난다. 그럼에도 불구하고 제안된 모델은 다른 모델과 비교했을 때 5 가지 암호화폐 세트 모두에 비교적 좋은 적합도를 생성한다.

Model	RMSE	MAE	MAPE	R^2
LSTM-GRU	291.8518	223.0449	1.7764	0.9777
CNN-LSTM	284.4073	216.0714	1.5623	0.9773
CNN-BiLSTM	300.8365	233.2869	1.7248	0.9774
TCN-LSTM	269.6830	216.8669	1.9243	0.9775
McVCsB [4]	211.7607	158.7392	1.1932	0.9781
StockMixer [5]	432.2726	346.5312	3.1884	0.8741
RevIN-LSTM	78.0312	50.2735	0.3553	0.9982

표 1. 모델 성능 비교

III. 결론

본 논문에서 제시된 RevIN-LSTM 모델은 RMSE, MAE, MAPE, R^2 를 포함한 여러 평가 지표에서 CNN-LSTM, CNN-BiLSTM, LSTM-GRU 와 같은 기존의 하이브리드 딥러닝 모델보다 상당히 우수한 성능을 보였다. 향후 작업에서는 시장 심리와 거시경제 지표와 같은 추가적인 외부 요인을 통합하여 예측 정확도를 더욱 높이는 방법을 모색할 것이다.




그림 1. 모델 프레임워크




그림 2. 예측 곡선

ACKNOWLEDGMENT

Put sponsor acknowledgments.

참 고 문 헌

- [1] Selvin, S., et al. "Stock price prediction using LSTM, RNN and CNN-sliding window model," International Conference on Advances in Computing, Communications and Informatics (ICACCI) '17, pp. 1643-1647, Sep. 2017.
- [2] Li, Z., et al. "Revisiting Long-term Time Series Forecasting: An Investigation on Linear Mapping," arXiv preprint arXiv:2305.10721, May 2023.
- [3] Torres, M. E., et al. "A complete ensemble empirical mode decomposition with adaptive noise," IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP) '11, pp. 4144-4147, May 2011.
- [4] Cui, C., et al. "McVCsB: A new hybrid deep learning network for stock index prediction," Expert Systems with Applications '232, 120902, December 2023.
- [5] Fan, J., et al. "StockMixer: A Simple Yet Strong MLP-Based Architecture for Stock Price Forecasting," AAAI '38, pp. 8389-8397, Mar. 2024.