

# 클라우드 컴퓨팅과 기계학습 기법을 이용한 주식의 기술적 분석 지표 최적화 및 주가 추세 변동 예측

김훈희\*

국립부경대학교 컴퓨터·인공지능공학부 교수

## The Optimization of Technical Analysis Indicators and Stock Trend Prediction Using Machine Learning and Cloud Computing

Hoon-Hee Kim\*

Professor, Department of Computer Engineering and Artificial Intelligence, Pukyong National University

**요약** 국내 주식 시장에서 트렌드 예측을 위한 기계학습 모델의 활용 사례가 점점 증가하고 있다. 특히, 주가 데이터와 같은 복잡한 시계열 데이터를 분석하고 예측하기 위해서는 기계학습을 활용하는 것이 필수적이다. 본 연구에서는 클라우드 컴퓨팅 서비스를 활용한 금융 데이터 수집 및 금융 시계열 추세 예측을 위한 기계학습 시스템을 제안한다. 먼저, 데이터 수집을 위해 Amazon Web Services(AWS)의 서버리스 서비스를 활용하였으며, 기술적 분석 지표(Relative Strength Index(RSI), Simple Moving Average(SMA), 볼린저 밴드, Rate Of Change(ROC), Golden Cross and Dead Cross(GDC), Stochastic Oscillator(STOCH), Moving Average Convergence Divergence(MACD), Detrended Price Oscillator(DPO))의 임계치를 유전 알고리즘을 통해 최적화 하였다. 이후 최적화된 지표들을 Echo State Network(ESN), Recurrent Neural Network(RNN), 그리고 다양한 기계학습 분류 모델의 학습 데이터로 사용하여 각 종목의 추세를 예측하였다. 예측된 추세를 바탕으로 백테스트를 진행한 결과, 평균 수익률은 ESN이 334%, RNN이 175%, 그리고 분류 모델이 199%를 기록하였다. 따라서 본 연구는 국내 주식 투자에서도 기계학습이 높은 예측력을 보이며 다양한 활용 가능성을 지니고 있음을 시사 하였다.

**주제어** : 주가 추세 예측, 에코 스테이트 네트워크, 기계학습, 기술적 분석, 클라우드 컴퓨팅

**Abstract** The application of machine learning models for trend prediction in the domestic stock market is increasing. In particular, utilizing machine learning is essential for analyzing and predicting complex time-series data, such as stock price data. This study proposes a machine learning system for financial time-series trend prediction, utilizing cloud computing services. First, for data collection, the serverless service of Amazon Web Services was employed, and the thresholds of technical analysis indicators were optimized through a genetic algorithm. The optimized indicators were then used as training data for Echo State Network, Recurrent Neural Network (RNN), and various machine learning classification models to predict the trend of each stock. Based on the predicted trends, backtesting was conducted, and the results showed that the average returns were 334% for ESN, 175% for RNN, and 199% for classification models. Therefore, this study suggests that machine learning exhibits high predictive power in domestic stock investment and holds various potential applications.

**Key Words** : Stock Trend Prediction, Echo State Networks, Machine Learning, Technical Analysis, Cloud Computing

## 1. 서론

코로나 19 이후 주식 투자가 꾸준히 늘어나고 있다. 2019 년에 비해 2022 년 기준으로는 주식 투자자 수가 2 배 이상 증가하였으며 주식 시장 규모도 확대되었다. 주식 시장의 활성화로 금융 투자 분야에서 다양한 시도가 이뤄지고 있는데, 그 중에서도 인공지능을 활용하는 시도가 주목받고 있다. 로보 어드바이저와 같은 인공지능 시스템을 도입한 증권사의 사례도 존재한다. 이처럼 인공지능 기술은 금융 시장에서 큰 영향력을 미치고 있다.

선행 연구에서는 딥러닝을 비롯한 다양한 기계학습 모델을 사용하여 주식 데이터를 분석하는 시도가 있었다 [1-6]. 또한 주식 이외에도 암호화폐의 추세를 예측하는 연구도 발표되고 있다 [7-11]. 하지만 기계학습을 이용한 복잡한 시계열 데이터인 금융 데이터 추세 예측은 정확성이 낮아 실제 투자에 적용되기 어려움이 있다.

이러한 문제를 보완하기 위해 축적 컴퓨팅(Reservoir Computing) 방법인 Echo State Network (ESN)이 주목 받고 있다. 해외 연구에서는 S&P500 등에서 ESN 을 주식 데이터 분석에 활용한 사례가 다수 존재한다 [5, 12-15]. 그러나, 국내 주식 데이터를 ESN 으로 분석한 사례는 없었다. 따라서 본 연구에서는 ESN 및 기계학습을 국내 주가 데이터에 적용하여 예측력을 살펴보았다.

또한 기계학습 모델의 추세 예측 성능을 높이기 위해 기술적 분석 지표(Technical Analysis Indicator, TAI)를 유전자 알고리즘(Genetic Algorithms, GA)를 이용하여 최적화 하였다 [16-18]. 이렇게 최적화된 TAI를 기계학습 모델의 학습 데이터로 이용하였다.

본 연구를 위해서 국내 주식 시장의 데이터를 수집하고 분석 하는데는 클라우드 컴퓨팅 서비스인 Amazon Web Service (AWS)를 이용하였다. 데이터 수집은 서버리스 서비스를 이용하여 자동화 하였으며, 주식 데이터의 분석, 예측 모델 또한 클라우드 컴퓨팅 서비스를 이용하여 구현하였다.


따라서 수집된 주가 데이터를 이용하여 유전자 알고리즘을 이용하여 최적화된 기술적 지표를 추출하였으며, 이를 이용하여 다양한 기계학습 모델이 최고의 수익률을 낼 수 있도록 추세 학습을 진행하였다. 또한 각 모델의 특징과 문제를 분석하고 향후 주식 데이터 분석 예측을 강화하는데 필요한 점을 논의하고자 한다.

## 2. 연구 방법

### 2.1 데이터 수집 및 시스템 구조

본 연구는 AWS의 서버리스 서비스를 이용하여 데이터 수집 및 분석을 구현하였다. Amazon Event Bridge를 이용하여 매일 자정에 한국거래소(KRX)에서 국내 주식 데이터를 받아오는 AWS Lambda를 실행되도록 구성 하였고, 수집된 데이터는 전처리 및 분석을 위해 AWS S3에 저장 되도록 하였다 (Fig. 1).

데이터 전처리 및 분석은 고성능 컴퓨팅 인스턴스가 사용가능한 Amazon SagemMaker상에서 구현하였다. 특히 컴퓨팅 인스턴스를 병렬로 처리하여 한번에 10개씩의 주가 종목데이터가 전처리 되도록 하였다.



[Fig. 1] Auto Crawling Scheme

### 2.2 주가 데이터의 구성

본 연구에서는 국내 코스피, 코스닥 종목 중 삼성전자 및 2차 전지, 제약, 게임 분야에서 시가 총액을 기준으로 19종목의 주가 데이터를 수집하여 이용하였다. 종목의 선정 기준은 주가총액이 가장 높은 종목, 중위수 종목, 하위 종목을 하나씩 선정하여 가능한 다양한 종목의 데이터 이용하도록 준비하였다. 상장 폐지 종목을 피하기 위하여 최하위 종목은 선택하지 않았다. 각 주식의 상장 시점부터 2023년 5월까지의 증가, 시가, 고가, 저가, 거래량, 그리고 시가총액과 같이 기술적 분석 지표 계산에 필요한 데이터를 연구에 이용하였다.

### 2.3 기술적 분석 지표 최적화 방법

#### 2.3.1 기술적 분석 지표

기술적 분석이란 주가와 거래량 등의 데이터로 도출된 지표를 이용하여 특정 주식의 현재 상태를 판단한 후 투자 방향을 결정하는 의사결정 방법의 하나이다. 기술적 분석 지표는 주식 차트를 기반으로 계산되며 현재까지 주식 데이터의 추세, 과매수 및 과매도 상태, 거래량, 변동성 등을 평가하는 데에 사용된다. 하지만 기술적 분석

지표를 계산하기 위한 임계치는 투자자의 주관적 판단 또는 관습적인 수치를 주로 사용하고 있다. 예를 들어 주가의 매수 시그널인 골든 크로스를 관찰하기 위해서는 주가의 장기 이동 평균, 단기 이동 평균을 계산하여야 한다. 하지만 개별 종목마다의 최적의 장기, 단기 임계치는 모두 다르며, 이를 경험적으로 결정하기는 매우 어렵다.

따라서 본 연구에서는 최적화 기법 중 하나인 유전자 알고리즘을 적용하여 Relative Strength Index(RSI), Simple Moving Average(SMA), 볼린저 밴드, Rate Of Change(ROC), Golden Cross and Dead Cross(GDC), Stochastic Oscillator(STOCH), Moving Average Convergence Divergence(MACD), Detrended Price Oscillator(DPO) 총 8가지 기술적 분석 지표들의 임계치를 최적화 하였다 [14].

본 연구에선 각 기술적 분석 지표들을 이용해 투자 포지션 시그널(Buy, Sell, Hold)을 생성하였다. 이렇게 생성한 8개의 기술적 분석 지표에 대한 매매 신호를 기계 학습 모델의 데이터로 이용하였다.

### 2.3.2 유전 알고리즘을 이용한 TAI 최적화

유전 알고리즘은 생물학적 진화의 원리를 모방하여 풀고자 하는 문제에 대한 가능한 후보 해 조합들을 점차적으로 변형함으로써 최적의 해를 만들어 내는 전역 탐색 알고리즘이다.

유전 알고리즘의 동작 단계는 다음과 같다. 1) 무작위한 초기 염색체(최적의 해가 될 후보들) 집합 생성, 2) 초기 염색체 집합에 대한 적합도 계산, 3) 적합도 높은 염색체간 교차(Crossover) 및 변이(Mutation) 연산으로 자손 세대 생성, 4) 생성된 자손들의 적합도 계산, 5) 종료 조건을 만족할 때까지 위 과정을 반복한다.

본 연구에서는 이용되는 각각의 TAI의 임계치 파라미터들을 최적화 하였다. 예를 들어, MACD는 단기 지수이동평균(Exponential Moving Average, EMA)과 장기 EMA의 차이를 기준으로 하여 주식을 매수 또는 매도 할지 결정하는 기술적 분석 지표이다. MACD Signal은 k 일 간의 지수이동평균을 나타내며, MACD Oscillator는 MACD와 MACD Signal의 차이를 나타낸다. 따라서 MACD 지표에서 최적화가 필요한 임계치는 단기, 장기, k의 3개의 파라미터이다. 따라서 최적화된 파라미터를 통해 매매 신호를 구하였다.

최적화를 위해 적합도(fitness)는 초기 자본금 대비 수익률(profit)과 최대낙폭(Maximum Drawdown, MDD)을 이용하여 다음과 같이 정의 하였다.

$$fitness = 0.9 \times profit + 0.1 \times MDD$$

유전 알고리즘 종료 조건으로 최적화 파라미터가 더 이상 변동없이 수렴하거나 1000 세대 에폭(epoch) 제한을 설정하였다 [17, 18].

## 2.4 기계학습을 이용한 주가 추세 예측

기계학습 모델 학습을 위해 유전자 알고리즘을 이용하여 최적화된 기술적 지표로 생성된 매매 신호를 입력 특성(features)으로 이용하였고 학습 목표는 주가의 시가 총액 시계열의 추세를 기준으로 한 매매 신호로 하였다. 각 종목의 시작일로부터 70%를 학습 데이터로 이후의 30%는 테스트 데이터로 이용하였다. 종목별 최적 모델의 평가 기준은 수익률과 일치율을 합산한 값에 근거하였다. 이때 수익률에 더 큰 비중을 두기 위해 다음과 같이 모델의 평가 지표를 설정하였다.

$$(0.8 \cdot \text{수익률}) + (0.2 \cdot \text{일치율})$$

수익률은 테스트 데이터를 이용해 생성된 시그널신호를 바탕으로 모의 투자하여 계산된 값이다. 일치율은 테스트 데이터로 생성한 시그널과 해당기간 학습 목표 값의 일치/불일치 정도를 계산한 값이다. 또한 최적의 모델 하이퍼파라미터 조합을 구하기 위해 모델 별 그리드 서치(Grid Search)를 수행하였다.

### 2.4.1 Recurrent Neural Networks

Recurrent Neural Networks는 학습 동안 모든 가중치를 업데이트하고 이전 단계의 출력을 현재 단계의 입력으로 사용하기 때문에 순차적인 데이터와 시계열 데이터를 다루는 데 적합하다. 모델 학습 과정에서 신경망의 유닛 수, 배치 사이즈(batch size), 에폭(epoch)을 종목별로 그리드 서치로 최적화하였다.

### 2.4.2 Echo State Networks (ESN)

ESN은 순환 신경망의 한 종류로, 입력 층, 축적(reservoir) 층, 출력 층 세계의 계층으로 이루어져 있다. ESN은 축적 층의 유닛들만 재귀적으로 연결되어 있으며, 입력에서 축적 층, 축적에서 출력 층으로의 연결은 Feed-forward로 이루어져 있다. 학습시 가중치 업데이트는 축적 층에서 출력 층으로 연결된 연결에서만 이루어지며 나머지 연결을 미리 초기화되어 고정된다. 따라

서 단순한 선형 학습법을 이용하여 학습이 가능하지만 비선형 데이터를 학습할 수 있는 장점이 있다 [13, 14]. 본 연구에서는 축적 층의 유닛 수는 1000 으로 고정하였고, 하이퍼파라미터 Spectral radius, Sparsity, Noise 를 그리디 서치를 이용하여 종목별로 최적화하였다.

2.4.3 기본 분류 모델

추가 추세 예측을 위해 추가적으로 다음과 같은 다양한 기본 분류 모델을 활용하였다. Random Forest, Decision Tree, GBT, SVM, Naive Bayes을 이용하여 학습과 성능 평가를 수행하였다.

DT(Decision Tree)는 데이터를 나무 형태로 가지치기하여 도출된 의사 결정 규칙으로 패턴을 파악하고 예측하는 알고리즘이다. RF(Random Forest)는 다수의 의사결정 트리를 독립적으로 학습하고, 각 트리의 부분집합을 결합하여 예측하는 알고리즘이다. GBT(Gradient Boosting Tree)는 기존 트리의 예측 오차를 중심으로 다음 모델을 점진적으로 학습하여 성능을 향상시키는 알고리즘이다. SVM(Support Vector Machine)은 데이터를 고차원 공간으로 매핑하여 결정 경계를 정의하고, 클래스를 분류하는 알고리즘이다. Naive Bayes 는 간단하면서도 효과적인 분류 모델로, 베이즈 이론을 기반으로 예측을 수행하는 모델이다.

앞서 연구와 마찬가지로 각 모델의 하이퍼파라미터는 그리드 서치를 사용하여 종목별로 최적화하였다.

3. 연구결과


총 19 개 추가 종목을 대상으로 최적화된 ESN, RNN 과 분류 모델을 일반 수익률, 상대적 수익률, Buy and Hold 방식과의 비교, MDD 총 4 가지 성능 지표로 평가 하였다. 분류 모델은 각 모델을 최적화시킨 뒤, 종목별 최고 수익률을 내는 모델을 선택하였다. 그 결과 ESN 이 가장 높은 수익률을 내며 손실이 없는 모델임을 확인하였다.

3.1 일반 수익률

일반 수익률은 테스트 기간 내 종목별 투자 시그널을 바탕으로 주식 거래를 시도했을 때 도출되는 단순 수익률이다. 일반 수익률은 다음과 같이 도출하였다.


$$\text{일반수익률} = \frac{\text{최종자본금} - \text{초기자본금}}{\text{초기자본금}} \times 100 (\%)$$

ESN의 평균 수익률은 334%, 최소 수익률은 5%, 최대수익률은 16569%로 세 모델 중 가장 높았다 (Fig 2).




[Fig. 2] Profit ratios of Echo State Networks

RNN 은 평균수익률은 174%, 최소 수익률은 0%, 최대수익률은 964%로 손실이 없는 결과를 보였다 (Fig. 3).



[Fig. 3] Profit ratios of Recurrent Neural Networks

분류모델의 평균 수익률은 199%, 최소수익률은 16%, 최대 수익률은 1631%로 RNN 보다 높은 수익률을 보였으나 종목별로 적합한 모델이 상이했다. (Fig. 4).

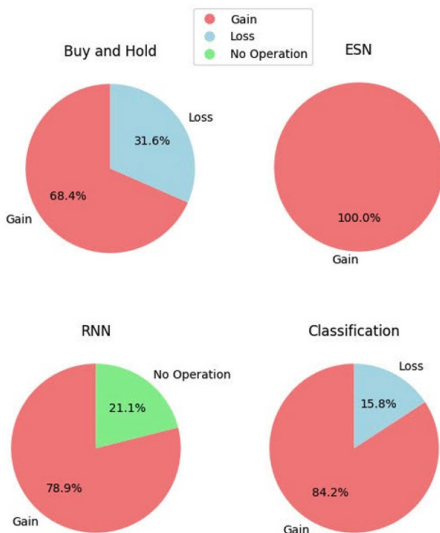


[Fig. 4] Profit ratios of Classification Models

### 3.2 Buy & Hold 수익률과의 비교

Buy & Hold 전략은 주식을 매수하여 이후 매수/매도를 하지 않고 그대로 주식을 보유하고 있다가 마지막 시점에서의 시가총액을 기준으로 매도하여 수익률을 계산하는 방식이다. 본 연구에서는 각 종목별 테스트 기간의 시작일, 종료일을 기준으로 Buy & Hold 일반 수익률을 도출하여 기계학습 모델 결과와 비교하였다 (Fig. 5).

테스트 기간 동안 KOSPI, KOSDAQ 지수는 약 32% 증가했다. Buy & Hold 전략의 수익률은 평균 235.35%이며 19 개 주식 중 13 개 주식에서 이익을 올리고 6 개 주식에서 손실이 발생했다. ESN 의 평균 수익률은 334.40%이며 19 개 종목 모두 이익을 올렸고 손실이 발생하지 않았다. RNN 의 평균 수익률은 174.95%이며 15 개 종목에서 이익을 올렸고 4 개 주식에서는 어떠한 거래 조치도 제안하지 않았다. 분류 모델의 평균 수익률은 199.20%이며 16 개 종목에서 이익을 올렸고 3 개 주식에서 손실이 발생하였다.



[Fig. 5] Gain & Loss Ratio

## 4. 논의

각 모델별로 최고 수익률, 최저 수익률을 내는 종목은 ESN 과 RNN 의 경우 동일하나 분류 모델은 앞선 두 모델과 다른 종목에서 최고, 최저 수익률을 보였다. 각 종목별로 높은 성능을 내는 모델이 다르므로 종목의 특성에 따라 적용할 모델을 구별하는 시도가 필요하다.

향후 현재 모델을 더 발전시킬 수 있는 방안으로 다음의 세 가지 방법을 제시할 수 있다. 주가는 국제적, 정치적, 재무적, 사회적 이슈 등 외부 요인의 영향을 받기에 거래 시 위 요인들을 즉각적으로 반영할 필요가 있다. 현재 모델은 거래 기준에 시가총액만을 반영했으나, 이후 자연어 처리를 활용하여 주식 추세 뉴스를 감정 분석하여 각 회사별 긍정 및 부정 감정 수치를 예측 값에 반영해 볼 수 있다 [19]. 또한 각 주식 종목에는 다양한 특성과 변동성이 존재하므로, 종목별로 적합한 모델을 고려해야 한다. 주식 종목들을 테마별로 분류해 모델의 가중치를 미세 조정하여 더욱 세부적으로 최적화해 볼 수 있다.

마지막으로 투자자에게는 손실률도 중요한 지표이다. 따라서 수익률 극대화에서 나아가 손실로 인한 투자자의 심리적 고통을 낮추기 위하여 예측 기간 동안의 MDD를 도출하여 이를 최소화하는 방향으로 모델을 학습하는 방식을 시도해볼 수 있다. 이를 통해 수익 최대화 뿐만 아니라 투자자의 심리적 안정을 함께 확보할 수 있다.

본 연구에서는 기술적 분석 지표와 유전 알고리즘, ESN 을 포함한 다양한 기계학습 모델을 활용하여 주식 종목별 추세를 예측하고 매매시 그 수익률을 비교 분석하였다. 특히, 다른 연구와 달리 비선형 시계열 분석에 특화된 축적 컴퓨팅 기법인 ESN을 이용하였다. 여러 성능 평가 지표를 통하여 다른 모델과 비교했을 때 ESN이 가장 높은 성능을 달성했으며 원금 손실이 없었다. 이는 국내 주식시장의 투자를 위한 기계학습 모델에 ESN이 활용될 수 있음을 시사한다. 또한 향후에는 다양한 모델들과 결합한 앙상블 모델을 구축하여 주식시장의 예측력을 높일 수 있을 것이라 기대한다.

## REFERENCES

- [1] J. Oh, "Development of a stock trading system based on a neural network using highly volatile stock price patterns," PeerJ Computer Science, Vol.8, pp.e915, 2022.
- [2] Y. Deng, Y. Liang, and S. M. Yiu, "Towards interpretable stock trend prediction through causal inference," Expert Systems with Applications, Vol.238, pp.121654, 2024.
- [3] Z. Mustafa and M. H. Sulaiman, "Stock price predictive analysis: An application of hybrid Barnacles Mating Optimizer with Artificial Neural Network," International Journal of Cognitive Computing in Engineering, Vol.4, pp.109-117, 2023.
- [4] Y. Song, "Enhancing stock market trend reversal

- prediction using feature-enriched neural networks," Heliyon, Vol.10, No.2, pp.e24136, 2024.
- [5] Z. Wang, H. Zhao, M. Zheng, S. Niu, X. Gao, and L. Li, "A novel time series prediction method based on pooling compressed sensing echo state network and its application in stock market," Neural Networks, Vol.164, pp.216-227, 2023.
- [6] H. J. Park, Y. Kim, and H. Y. Kim, "Stock market forecasting using a multi-task approach integrating long short-term memory and the random forest framework," Applied Soft Computing, Vol.114, pp.108106, 2022.
- [7] A. Golnari, M. H. Komeili, and Z. Azizi, "Probabilistic deep learning and transfer learning for robust cryptocurrency price prediction," Expert Systems with Applications, Vol.255, pp.124404, 2024.
- [8] N. N. AlMadany, O. Hujran, G. Al Naymat, and A. Maghyereh, "Forecasting cryptocurrency returns using classical statistical and deep learning techniques," International Journal of Information Management Data Insights, Vol.4, No.2, pp.100251, 2024.
- [9] A. Viéitez, M. Santos, and R. Naranjo, "Machine learning Ethereum cryptocurrency prediction and knowledge-based investment strategies," Knowledge-Based Systems, Vol.299, pp.112088, 2024.
- [10] A. Brini and J. Lenz, "Pricing cryptocurrency options with machine learning regression for handling market volatility," Economic Modelling, Vol.136, pp.106752, 2024.
- [11] Y. H. Liu and J. K. Huang, "Cryptocurrency trend forecast using technical analysis and trading with randomness-preserving," Computers and Electrical Engineering, Vol.118, pp.109368, 2024.
- [12] J. Liu et al., "Financial data forecasting using optimized echo state network," in Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics), Springer Verlag, Vol.11305, pp.138-149, 2018.
- [13] X. Lin, Z. Yang, and Y. Song, "Short-term stock price prediction based on echo state networks," Expert Syst Appl, Vol.36, No.3, pp.7313-7317, 2009.
- [14] X. Lin, Z. Yang, and Y. Song, "Intelligent stock trading system based on improved technical analysis and Echo State Network," Expert Systems with Applications, Vol.38, No.9, pp.11347-11354, 2011.
- [15] G. Trierweiler Ribeiro, A. Alves Portela Santos, V. Cocco Mariani, and L. dos Santos Coelho, "Novel hybrid model based on echo state neural network applied to the prediction of stock price return volatility," Expert Systems with Applications, Vol.184, pp.115490, 2021.
- [16] Y. Han, J. Kim, and D. Enke, "Selective genetic algorithm labeling: A new data labeling method for machine learning stock market trading systems," Engineering Applications of Artificial Intelligence, Vol.135, pp.108680, 2024.
- [17] F. Ecer, S. Ardabili, S. S. Band, and A. Mosavi, "Training multilayer perceptron with genetic algorithms and particle swarm optimization for modeling stock price index prediction," Entropy, Vol.22, No.11, pp.1239, 2020.
- [18] K. K. Yun, S. W. Yoon, and D. Won, "Interpretable stock price forecasting model using genetic algorithm-machine learning regressions and best feature subset selection," Expert Systems with Applications, Vol.213, pp.118803, 2023.
- [19] I. AbouHassan, N. K. Kasabov, V. Jagtap, and P. Kulkarni, "Spiking neural networks for predictive and explainable modelling of multimodal streaming data with a case study on financial time series and online news," Scientific Report, Vol.13, No.1, pp.18367, 2023.

## 김 훈 희(Hoon-Hee Kim)

[정회원]



- 2019년 8월 : 한국과학기술원 바이오및뇌공학과 (공학박사)
- 2020년 9월 2월 ~ 2021년 2월 : 주식회사 포엔 CTO
- 2021년 3월 ~ 2022년 8월 : 강남대학교 인공지능융합공학부 조교수
- 2022년 9월 ~ 현재 : 부경대학교 컴퓨터·인공지능공학부 조교수

〈관심분야〉

사물인터넷, 인공지능, 뇌공학, 클라우드 컴퓨팅