

시장 상태 적응형 Hybrid GA-ESN 기반 주가 예측 알고리즘 트레이딩 시스템에 관한 실증연구: DIA, QQQ, SPY, KOSPI200 지수 중심으로

정동균¹, 김훈희^{2*}

¹국립부경대학교 소프트웨어융합혁신원 교수, ²국립부경대학교 컴퓨터인공지능공학부 교수

An Empirical Study on a Market Regime-Adaptive Hybrid GA-ESN based Algorithmic Trading System for Stock Price Prediction: Evidence from DIA, QQQ, SPY, and KOSPI200

Dong-Kun Jung¹, Hoon-Hee Kim^{2*}

¹Professor, Center Software Convergence & Innovation Pukyong National University

²Professor, Department of Computer and Artificial Intelligence Engineering, Pukyong National University

요약 전통적 기술적 분석 기법은 경험적으로 설정된 파라미터에 크게 의존하기 때문에, 비선형성과 비정상성을 갖는 금융 시계열의 예측 정확도와 거래 안정성을 향상하는데 한계가 있다. 이에 본 연구는 시장 상태 적응형 Hybrid GA-ESN(Genetic Algorithm-Echo State Network) 기반 주가 예측 알고리즘 트레이딩 시스템을 제안하여 예측 성과와 위험 관리 효율성을 동시에 개선하고자 한다. 유전 알고리즘(GA)으로 골든/데드 크로스(GC), 엔벨로프 이동평균(ENV), 상대강도지수(RSI)의 핵심 파라미터를 자동 최적화하고, 평활화(Smoothing)와 Triangle Target 기반 전환점 정보를 포함한 기술적 분석 신호를 ESN의 입력으로 사용하였다. 또한 금융 시장을 추세와 변동성에 따라 네 가지 시장 상태로 분류하고, 교차검증 기반 ESN 구조를 적용해 비정상적 시장 환경 변화에 대한 적응력을 강화하였다. DIA, QQQ, SPY, KOSPI200 지수 실증 분석 결과, 제안한 Hybrid GA-ESN 모델은 매수-보유 전략과 고정형 ESN 대비 수익률과 최대낙폭 측면에서 전반적으로 우수한 성과를 보였다.

주제어 : 금융 시계열 예측, 하이브리드 모델, 유전 알고리즘, 에코 스테이트 네트워크, 시장 상태 분류

Abstract Traditional technical analysis methods rely on empirically chosen parameters, which limits their effectiveness in improving prediction accuracy and trading stability for nonlinear and non-stationary financial time series. This study proposes a market regime-adaptive Hybrid GA-ESN (Genetic Algorithm-Echo State Network)-based algorithmic trading system for stock price prediction. A genetic algorithm is employed to automatically optimize key parameters of the Golden/Dead Cross (GC), Envelope Moving Average (ENV), and Relative Strength Index (RSI), mitigating parameter-sensitivity issues. Smoothed prices and a triangle target representation for turning points are then used as input features to the ESN. In addition, the market is classified into four regimes according to trend and volatility, and a cross-validation-based ESN is adopted to enhance adaptability to changing market conditions. Empirical results for the DIA, QQQ, SPY, and KOSPI200 indices demonstrate that the proposed Hybrid GA-ESN model outperforms the Buy-and-Hold strategy and static ESN models in terms of both return and maximum drawdown.

Key Words : Algorithmic Trading, Stock Price Prediction, Hybrid Model, Genetic Algorithm (GA), Echo State Network (ESN), Market Regime Classification

이 논문은 부경대학교 자율창의기술연구비(2024년)에 의하여 연구되었음.

*교신저자 : 김훈희(h2kim@pknu.ac.kr)

접수일 2026년 01월 08일 수정일 2026년 02월 11일 심사완료일 2026년 02월 20일

1. 서론

금융 시장은 비선형성(non-linearity)과 비정상성(non-stationarity)을 동시에 지니는 복잡한 메커니즘으로, 시계열 데이터의 통계적 특성이 시간에 따라 변화한다[3,8]. 이러한 특성으로 인해 전통적인 예측 모델이나 고정 규칙 기반 기법은 시장 구조 변화와 급격한 변동성을 충분히 반영하는데 한계를 가지며[8], 특히 잡음이 많은 금융 환경에서 주가 전환점(turning point)을 안정적으로 예측하는 것은 여전히 어려운 문제로 남아 있다[3,4].

기술적 분석은 이동평균 기반 규칙이나 모멘텀 지표를 활용하여 추세와 매매 시점을 판단하는 방법으로 널리 사용되어 왔다[5,18]. 그러나 시장 국면(Regime) 변화와 거래비용, 시장 효율성에 따라 성과가 일관되지 않다는 한계가 지적되어 왔다[6,19]. 또한 경험적으로 설정된 파라미터에 대한 민감도가 높아, 변동성이 큰 구간에서는 오 신호(False signal) 증가로 트레이딩 성과 불안정성이 발생할 수 있다[2,7].

최근 이러한 문제를 완화하기 위해 유전 알고리즘(Genetic Algorithm, GA)과 순환신경망(Recurrent Neural Network, RNN) 기반 모델을 결합한 하이브리드 접근이 주목받고 있다[2,14]. GA는 기술적 분석 지표(Technical Analysis Indicator, TI)와 모델 하이퍼파라미터를 데이터 기반으로 최적화함으로써 파라미터 민감성과 주관적 설정 문제를 보완할 수 있으며[2,12,13,14], Echo State Network(ESN)는 Reservoir Computing 기반 구조로 복잡한 비선형 시계열을 효율적으로 학습할 수 있어 금융 시계열 예측에 적합한 모델로 제시되고 있다[10,15].

한편, 동일한 예측 모델이라도 시장의 안정성, 변동성, 추세 구조에 따라 성과가 달라질 수 있어 시장 상태(레짐) 기반의 적응형 학습 필요성이 강조된다[1,16]. 이에 본 논문에서는 GA 기반 파라미터 최적화와 시장 상태 분류 기법을 결합한 Hybrid GA-ESN 기반 주가 예측 및 알고리즘 트레이딩 모델을 제안한다. 또한, 미국 ETF DIA, QQQ, SPY와 국내 KOSPI200 지수를 대상으로 다양한 시장 국면에서의 예측 성능과 위험 관리 효율성을 실증적으로 분석한다. 특히 본 연구는 전통적 기술적 분석 지표(GC, ENV, RSI)의 파라미터를 GA로 최적화하고, 전환점 기반 Triangle Target을 활용한 ESN 예측 모형을 결합한 하이브리드 구조를 제안하였다. 또한 추세와 변동성에 기반한 4가지 시장 상태 분류와 교차검증

ESN을 결합하여, 비정상 금융 시계열에서 시장 상태 적응형 트레이딩 프레임워크를 제시한다는 점에서 기존 연구와 차별성을 가진다.

2. 이론적 배경 및 관련 연구


2.1 금융 시계열 특성과 기술적 분석

금융 시계열 데이터는 비선형성과 비정상성을 동시에 지니며, 시간에 따라 평균과 분산, 상관 구조가 변화하는 특성을 보인다[3,8]. 이러한 특성으로 인해 단일 모형이나 고정된 규칙에 기반한 예측 기법은 시장 환경 변화에 효과적으로 대응하기 어렵다. 특히 추세 전환이나 급격한 변동 구간에서는 기존 모델의 예측 오차가 확대되는 경향을 보이고 있다[8,16].

기술적 분석은 가격과 거래량의 과거 패턴을 활용하여 향후 가격 움직임을 예측하는 대표적인 방법이다. 이동평균 교차(Golden/Dead Cross), 엔벨로프 이동평균(Envelope MA), 상대강도지수(RSI) 등이 기술적 분석 지표로 널리 사용되고 있다[5,18]. 일부 연구에서는 단순 기술적 매매 규칙이 통계적으로 유의한 성과를 보일 수 있음을 제시하였으나[5], 시장 효율성 및 거래비용을 고려할 경우 장기적으로 일관된 초과 수익을 달성하기 어렵다는 비판도 제기되어 왔다[6,9,19]. 이러한 한계는 기술적 분석 지표가 경험적 파라미터 설정에 의존하고, 시장 국면 변화에 민감하다는 점에서 기인한다.

2.2 전환점(Turning Point) 탐지


전환점 탐지(Turning Point, TP)는 추세 반전의 구조적 패턴을 포착하기 위한 핵심 절차이며, 가격 신호를 구조적으로 변환하여 전환점의 형태적 특징을 분리하고 강조하는 방법이다[3,4,14].



[Fig. 1] Smoothing

특히 [Fig. 1]과 같이 가격 변화 진폭(Δp)과 시간 간격(Δt)의 조건을 만족하는 평활화(Smoothing)로 의미

있는 국소 극값만 남기고, 이를 기반으로 [Fig. 2]와 같이 전환점의 접근 정도를 삼각파 표적(Triangle Target)으로 정량화한 뒤 예측 모델이 학습하도록 설정함으로써 전환점 예측 성능을 강화하였다[4]. 이러한 전처리 는 추세 변화 탐지에 핵심적 역할을 수행하는 정보를 제공한다.



[Fig. 2] Triangle Target

2.3 유전 알고리즘 기반 최적화와 금융 응용

유전 알고리즘(GA)은 자연 선택과 진화 과정을 모방한 확률적 탐색 기반 최적화 기법으로, 복잡하고 비선형적인 탐색 공간에서 전역 최적해를 효과적으로 탐색할 수 있는 장점을 가진다[17]. GA는 개체 모집단(Population)의 선택(Selection), 교차(Crossover), 돌연변이(Mutation) 연산을 반복 수행하며, 각 개체는 문제의 해 후보를 의미한다. 금융 분야에서는 기술적 분석 지표의 파라미터 최적화, 매매 규칙 설계, 포트폴리오 구성 등 다양한 문제에 적용되어 왔다[2,12]. 특히 경험적 설정에 의존하는 기술적 분석 지표의 파라미터 민감도 문제를 완화하고, 데이터 기반 의사결정을 가능하게 한다는 점에서 유용성이 보고되고 있다[2,7,14].

본 논문에서는 GA를 활용하여 기술적 분석 지표 및 예측 모델 파라미터를 최적화하기 위해 예측 정확도와 거래 안정성을 동시에 고려한 적합도 함수를 아래의 수식(1)과 같이 정의하였다.


$$F = \sum_{t=1}^T w_t \cdot |P_t - \hat{P}|^{-1} - \lambda \cdot MDD \quad (1)$$

여기서 P_t 는 실제 가격, \hat{P}_t 는 예측 가격, MDD 는 최대 낙폭(Maximum Drawdown), λ 는 위험 가중 계수이다.

적합도 함수(F)는 추세 전환점, 수익률의 예측 오차 항 ($|P_t - \hat{P}|$)과 MDD 를 결합하여, 단순 수익률 중심이 아닌 위험 관리 관점까지 반영하도록 설계되었다. 이를 통해 예측 정확도가 높더라도 과도한 손실을 유발하는 파라미터 조합은 낮은 적합도로 평가되며, 실질적인 트레이딩 환경에 적합한 해를 탐색할 수 있도록 하였다.

2.4 Echo State Network와 시장 상태 기반 학습

Echo State Network는 Reservoir Computing 기반의 순환신경망으로, 입력층과 출력층만을 학습하고 내부 reservoir 가중치는 고정함으로써 학습 효율성을 크게 향상시킨 [Fig. 3]과 같은 구조를 가진다[10,11].



[Fig. 3] Standard Structure of ESN

입력층의 K 개 입력 유닛은 외부 시계열 신호 $u(t)$ 를 중앙의 저장소(Reservoir)로 전달하며, N 개의 내부 유닛으로 구성된 저장소는 다수의 순환 연결을 갖는 비선형 동적 공간을 형성한다. 이러한 순환 구조로 인해 과거 정보가 에코(echo)와 같이 저장소 상태에 유지되어, 시계열 데이터의 시간적 의존성이 자연스럽게 반영된다. Reservoir의 상태 업데이트는 입력과 직전 상태에 기반한 비선형 갱신 방식으로 이루어지며, 그 동작은 다음과 같은 수식(2)으로 표현된다.

$$x(t) = (1 - \alpha)x(t-1) + \alpha f(W_{in}u(t) + W_{res}x(t-1)) \quad (2)$$

여기서 $x(t)$ 는 시점 t 의 Reservoir 상태, $u(t)$ 는 입력 신호를 의미하며, W_{in} 과 W_{res} 는 각각 입력 가중치와 내부 순환 가중치이다. 비선형 함수 $f(\cdot)$ 는 일반적으로 tanh 함수를 사용하며, α 는 leak rate로서 현재 입력과 과거 상태 간의 반영 비율을 조절한다. 이러한 구조를 통해 ESN은 복잡한 비선형 시계열 패턴을 효율적으로 확장-기억할 수 있는 동적 표현 공간을 형성한다[11].

ESN의 핵심 특징은 Reservoir 내부 가중치 W_{in} 과 W_{res} 를 학습하지 않고 무작위로 고정한 상태에서, 출력층 가중치 W_{out} 만을 학습한다는 점이다[11]. 이로 인해 전통적인 RNN에서 요구되는 복잡한 역전파(Backpropagation) 과정을 회피할 수 있으며, 선형회귀 기반의 간단한 학습만으로도 효율적인 시계열 학습이 가능하다. 따라서, 출력층의 L 개 출력 유닛은 저장소 상태를 선형 결합하여 최종 출력 신호를 생성하며, 출력 가중치 W_{out} 은 다음과 수식(3)과 같이 정규화된 최소 제

곱 해를 통해 계산된다.

$$W_{out} = (X^T X + \lambda I)^{-1} X^T Y \quad (3)$$

여기서 X 는 시간에 따라 누적된 Reservoir 상태 행렬, Y 는 목표 출력(target) 행렬을 의미하며, λ 는 과적합을 방지하기 위한 정규화 계수이다. 이러한 구조는 Reservoir가 입력 신호를 고차원 비선형 공간으로 확장하여 복잡한 시계열 패턴을 유지·기억하고, 출력층이 이를 단순한 선형 조합을 통해 판독(Readout)하는 방식으로 동작함을 의미한다. [Fig. 3]은 입력 신호가 비선형적으로 확장된 reservoir 공간을 거쳐 출력으로 매핑되는 ESN의 핵심 메커니즘을 직관적으로 보여준다.

금융 시장은 단일한 확률 과정이 아닌, 서로 다른 특성을 지닌 다수의 시장 상태(국면)로 구성된다는 관점이 제시되어 왔다[1,8]. 이러한 시장 상태는 안정성, 변동성, 추세 특성 등에 따라 구분될 수 있으며, 동일한 예측 모델이라도 시장 국면에 따라 성과 차이가 발생한다[1,16].

본 연구에서는 Regime-Switching 접근과 Volatility Clustering 기법[1,20]을 기반으로, 시장 상태를 추세(Trend)와 변동성(Volatility)의 조합으로 나누는 4가지 시장 상태로 정의하였다. 먼저, 추세 기반 분류는 일정 기간 동안의 가격 흐름이 상승 또는 하락 방향을 가지는지를 정량적으로 판단하기 위해 로그 가격에 대한 단순 선형회귀 모형을 적용한다. 시점 t 에서의 로그 가격은 다음 수식(4)과 같이 표현된다.

$$\log P_t = \beta_0 + \beta_1 t + \epsilon \quad (4)$$

여기서 β_1 은 가격 변화의 방향과 속도를 나타내는 추세 계수로, $\beta_1 > 0$ 이면 상승 추세, $\beta_1 < 0$ 이면 하락 추세로 분류한다. 또한 추세의 일관성은 아래의 수식(5)과 같이 결정계수 R^2 를 이용하여 평가하며, 이는 회귀모형이 로그 가격 변동을 얼마나 잘 설명하는지를 나타낸다.

$$R^2 = 1 - \frac{\sum_t (\log P_t - \widehat{\log P}_t)^2}{\sum_t (\log P_t - \log P)^2} \quad (5)$$

한편, 변동성 기반 분류는 시장의 불확실성과 위험 수준을 반영하기 위해 로그 수익률의 이동 표준편차를 사용한다. 로그 수익률 r_t 와 변동성 σ_t 는 다음 수식(6)과 같이 정의된다.

$$\sigma_t = std(r_t), \quad r_t = \ln\left(\frac{P_t}{P_{t-1}}\right) \quad (6)$$

이때 변동성은 최근 n 일 동안의 이동 표준편차로 계산되며, 값이 클수록 가격 변동 폭이 크고 시장 불확실성이 높은 상태를 의미한다.

본 연구에서는 변동성 기준값을 20일 이동 표준편차의 중앙값(median)으로 설정하여, 이를 초과하는 경우 '변동', 그렇지 않은 경우 '비변동' 상태로 분류하였다. 각 자산에 대해 전체 표본 기간 동안 계산된 20일 이동 표준편차 시계열을 산출한 후 그 분포의 중앙값을 기준값으로 정의한다. 기준값 이상이면 '변동' 상태, 미만이면 '비변동' 상태로 분류한다. 중앙값을 사용한 이유는 극단값(Outlier)에 덜 민감하면서도 샘플을 거의 절반씩 고·저 변동 상태로 나누어 각 시장 상태별로 충분한 관측치를 확보하고자 했기 때문이다.

이러한 추세 및 변동성 분류를 결합함으로써 [Fig. 4]와 같이 안정·비변동, 안정·변동, 추세·비변동, 추세·변동의 네 가지 상태로 구분되며, 각 시장 상태는 가격 움직임의 방향성과 변동성 수준에 따라 차별화된 특성을 나타낸다.

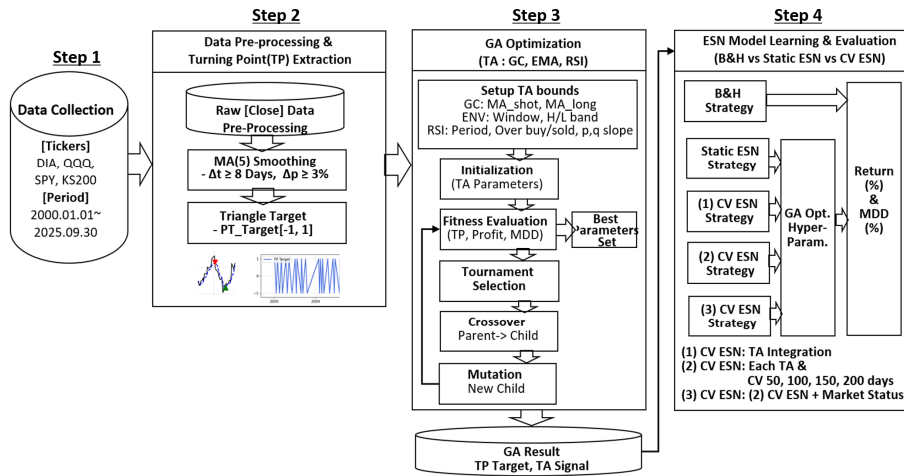


[Fig. 4] Four Market Regimes

3. 연구 방법

본 연구의 전반적인 프레임 워크 [Fig. 5]는 전체 처리 과정을 네 단계로 정리한 것이다.

Step 1에서는 DIA, QQQ, SPY, KOSPI200 지수의 장기 일별 종가 데이터를 수집하고, Step 2에서는 MA(5) 평활화(Smoothing)와 Δt , Δp 기준을 적용하여 전환점(TP)과 Triangle Target을 생성한다. Step 3에서는 GA를 이용해 기술적 지표(TI) GC, ENV, RSI 지표의 핵심 파라미터를 최적화하고, Step 4에서는 최적화된 TI



[Fig. 5] Research Framework

신호와 TP 타깃을 입력으로 ESN을 학습하여 B&H, ST ESN, CV ESN 전략의 수익률과 MDD를 비교한다.

Step 1: 데이터 수집 (Data Collection)

분석 대상 자산으로 미국 ETF DIA, QQQ, SPY와 국내 KOSPI200 지수를 선정하고, 2000년 1월부터 2025년 9월까지의 일별 종가 데이터를 수집하였다. 이 단계에서는 장기 시장 상태 변화를 반영할 수 있도록 충분한 기간의 시계열 데이터를 확보한다.

Step 2: 데이터 전처리 및 전환점 추출(Data Pre-processing & Turning Point Extraction)

수집된 원시 종가 데이터는 예측 안정성을 높이기 위해 전처리 과정을 거친다. 우선 5일 이동평균 MA(5) 기반 평활화를 적용하여 단기 잡음을 제거하며, 8일 간격 ($\Delta t \geq 8$ days)과 3% 이상의 가격 변화($\Delta p \geq 3\%$)를 기준으로 의미 있는 가격 전환점(Turning Point, TP)을 추출하였다. 이후 전환점 정보를 Triangle Target 구조 ($TP_Target \in \{-1, 1\}$)로 변환하여, 상승·하락 전환 신호를 명확히 구분할 수 있도록 지도 학습용 타깃 데이터를 생성하였다.

Step 3: GA 기반 기술적 분석 지표 최적화(GA Optimization)

전환점 예측 성능을 극대화하기 위해 GA을 활용하여

기술적 분석 지표(TI)의 파라미터를 자동 최적화하였다.

대상 지표는 GC, ENV, RSI이며, 각 지표별로 탐색 범위(예: 이동평균 기간, 밴드 폭, 과매수·과매도 기준)를 설정하였다. GA는 초기 파라미터 집단을 생성한 후, 전환점(TP) 정확도, 누적 수익률(Return), 최대 낙폭(MDD)을 포함한 적합도 평가를 수행한다. 이후 토너먼트 선택, 교차, 돌연변이 연산을 반복하여 전환점 예측과 거래 안정성을 동시에 만족하는 최적 파라미터 집합을 도출하였다.


Step 4: ESN 모델 학습 및 성과 평가(ESN Model Learning & Evaluation)

GA을 통해 최적화된 기술적 분석 신호는 ESN의 입력 변수(Features)로 사용되며, 가격 전환점을 기반으로 생성된 Triangle Target은 모델 학습을 위한 목표 변수(Target)로 활용된다. 본 연구에서는 성과 비교를 위해 다음 세 가지 전략으로 구성되었다.

- B&H 전략: 매수·보유 기준선 전략
- Static(ST) ESN: 고정 학습 구조를 갖는 ESN
- CV ESN: 다중 윈도우 교차검증 기반 ESN

ESN 모델의 일반화 성능을 검증하기 위해 전체 표본을 학습 구간과 테스트 구간으로 분할하였다. ST ESN의 학습과 테스트 기간은 각각 2000~2015년, 2016~2025년로 구분하였다. 그러나, CV ESN은 [Fig 6]과 같이 학습은 고정 길이 2,500영업일을 사용하고, 테스트 구간을

각각 50/100/150/200일을 폴드로 순차 슬라이딩하여 진행이 되었다.



[Fig. 6] Cross-Validation Fold Configuration

ESN 학습 성능에 직접적인 영향을 미치는 주요 하이퍼파라미터에 대해서도 탐색을 수행하였다. <Table 1>은 하이퍼파라미터의 설정값으로, 선행 연구의 권고 범위와 예비 실험 결과를 바탕으로 Reservoir size와 sparsity 각각 1,000, 0.1 값으로 고정하였다. 그리고 ESN의 안정성과 예측 성능에 중요한 영향을 미치는 구간을 중심으로 Spectral radius 0.5~1.2, Leaky rate 0.1~0.9, Ridge 정규화 계수 $10^{-6} \sim 10^{-1}$, 입력 스케일 0.1~1.0 범위에서 탐색되었다.

<Table 1> Hyperparameter Settings

Hyper Parameters	Description	Scope / Setup
Reservoir size	Number of reservoir neurons	1,000
Sparsity	Sparsity ratio of reservoir W	0.1
Spectral radius	Scaling of reservoir eigenvalues	0.5 ~ 1.2
Leak rate α	State update	0.1 ~ 0.9
Ridge α	Output-layer L2 regularization	($10^{-6} \sim 10^{-1}$)
Input scale	Input scale adjustment	0.1 ~ 1.0
Activation	Reservoir nonlinear activation function	tanh
Washout	Initial stabilization period	최대 50 steps

4. 연구 결과

4.1 자산·전략별 성과 비교

본 연구의 미국 주요 ETF DIA, QQQ, SPY와 국내 대표 지수 KOSPI200에 대한 예측 전략 및 기술적 분석 지표별 성과는 각각 아래의 <Table 2>, <Table 3>와 같다. <Table 2>는 DIA, QQQ, SPY, KOSPI200 지수를 대상으로 B&H, ST(고정) ESN, CV(교차검증) ESN의 누적 수익률과 최대 낙폭(MDD)을 비교한 결과를 나타낸다.

B&H 전략은 대부분의 자산에서 가장 높은 누적 수익률을 기록하였다. 예를 들어 QQQ와 SPY에서 각각

<Table 2> Comparison of Returns (%) & MDD (%) by Asset: B&H, ST ESN, and CV ESN

Tickers	Return /MDD	B&H	ST ESN	CV ESN (TI Integration)			
				CV50	CV100	CV150	CV200
DIA	Return	229.08	119.28	125.01	76.34	126.58	75.60
	MDD	36.70	25.88	24.30	31.95	23.32	31.95
QQQ	Return	487.11	129.54	142.38	197.24	108.23	234.27
	MDD	35.12	29.05	21.09	24.49	24.12	25.11
SPY	Return	288.39	60.24	98.04	129.69	96.73	97.43
	MDD	33.72	23.13	22.25	15.93	23.63	16.71
KS200	Return	102.54	18.39	58.03	37.84	9.17	32.22
	MDD	41.19	36.94	41.18	41.77	35.78	36.27

<Table 3> Comparison of Returns (%) & MDD (%) by TI for CV ESN (GC, ENV, RSI)

Tickers	Return/ MDD	CV ESN(TI Individual)											
		GC				ENV				RSI			
		CV50	CV100	CV150	CV200	CV50	CV100	CV150	CV200	CV50	CV100	CV150	CV200
DIA	Return	107.66	132.08	83.39	87.59	83.53	107.09	111.41	126.66	121.95	141.44	210.02	127.91
	MDD	30.25	35.69	25.25	35.69	34.34	20.98	30.47	20.89	24.36	21.70	20.84	23.37
QQQ	Return	295.39	405.35	447.09	287.72	191.01	183.35	154.98	134.96	388.05	217.76	243.40	113.91
	MDD	43.83	28.56	31.11	31.34	26.61	25.69	24.68	28.87	34.22	47.21	30.98	44.06
SPY	Return	143.42	146.72	97.06	62.22	182.92	187.19	167.56	207.29	137.89	184.84	128.89	101.13
	MDD	25.77	33.72	21.06	33.72	26.85	24.50	28.32	22.03	22.51	17.06	21.78	22.70
KS200	Return	54.32	33.73	65.22	20.84	18.06	57.67	44.01	-0.60	138.64	191.66	75.79	64.76
	MDD	35.32	43.41	34.08	32.51	34.06	31.08	24.99	40.74	32.30	30.76	36.07	36.98

487.11%, 288.39%의 수익률을 보였으나, 동시에 전반적으로 33~41% 수준의 높은 최대 낙폭(MDD)을 동반하여 변동성 및 위험 노출이 크게 나타났다. 이는 장기 상승 구간에서는 유리하지만, 시장 급변 구간에서는 위험 관리 측면에서 한계를 가지는 전략임을 보여준다.

ST ESN 전략은 B&H 대비 수익률은 낮으나, 전반적으로 MDD가 감소하여 일정 수준의 위험 완화 효과를 보였다. 그러나 단일 학습 구간에 기반한 구조로 인해 시장 환경 변화에 대한 적응력은 제한적이었으며, 일부 자산에서는 수익률 개선 효과가 제한적으로 나타났다.

CV ESN(TA 통합) 전략은 다중 윈도우 학습을 통해 시장 변화에 대한 적응력이 향상되었으며, 대부분의 자산에서 ST ESN 대비 낮은 MDD를 기록하였다. 특히 QQQ와 SPY에서는 특정 윈도우 CV100, CV200에서 수익률과 위험 관리가 동시에 개선되는 결과가 관측되었다. 다만 자산별로 최적의 윈도우 길이가 상이하게 나타나, 단일 윈도우보다는 다중 윈도우 기반 분석이 효과적인 것으로 나타났다.

B&H 전략은 높은 수익률을 제공하는 반면 위험 노출이 크고, ST ESN은 제한적인 안정성 개선을 보였으며, CV ESN은 수익률과 안정성 간의 균형 측면에서 가장 안정적인 성과를 나타냈다. 이는 교차검증 기반 학습 구조가 금융 시장의 비정상성과 구조적 변화를 보다 효과적으로 반영할 수 있음을 시사한다.

<Table 3>은 CV ESN을 기술적 분석 지표(TI) GC, ENV, RSI를 개별적으로 사용했을 때의 성과를 지수별로 비교한 결과를 나타낸다. 전반적으로 지표별 성과 차이가 뚜렷하게 나타났으며, 동일한 지표라도 지수와 CV 윈도우 길이에 따라 수익률과 최대 낙폭(MDD)의 균형이 다르게 형성되는 경향이 확인되었다.

DIA의 경우, GC 기반 CV100에서 수익률 132.08%를 기록하였으나 MDD는 35.69%로 비교적 크게 나타났

다. 반면 RSI 기반 CV150에서는 수익률 210.02%와 MDD 20.84%를 기록하여, 수익성과 안정성이 동시에 개선된 결과를 보였다. 이는 DIA 지수에서 RSI 지표가 전환점 탐지에 상대적으로 효과적임을 시사한다.

QQQ에서는 GC 지표의 성과가 두드러졌다. GC 기반 CV150은 수익률 447.09%를 기록하며 전체 결과 중 가장 높은 수익률을 보였고, MDD는 31.11%로 유지되었다. RSI 기반 전략에서도 CV50에서 388.06%의 높은 수익률을 보였으나, MDD가 34.22%로 상대적으로 크게 나타나 위험 관리 측면에서는 한계가 확인되었다. 반면, ENV 기반 CV150은 MDD가 24.68%로 낮아 안정성 측면에서 강점을 보였다.

SPY의 경우, ENV 지표 기반 CV200이 수익률 207.29%와 MDD 22.03%를 기록하여 가장 균형 잡힌 성과를 보였다. RSI 기반 CV100 또한 수익률 184.84%와 MDD 17.06%로 낮은 낙폭을 나타내어, 안정성 측면에서 유리한 결과를 보였다.

KOSPI200에서는 전반적으로 수익률이 낮게 나타났으나, RSI 기반 전략에서 상대적으로 개선된 성과가 관찰되었다. 특히 RSI 기반 CV100은 수익률 191.66%를 기록하였으며, MDD는 30.76%로 다른 지표 대비 안정적인 수준을 유지하였다. 반면 ENV 기반 CV200에서는 수익률이 -0.60%로 나타나, 지표 및 윈도우 선택의 중요성이 확인되었다.

요약하면, CV ESN의 성과는 기술적 분석 지표 선택과 교차검증 윈도우 길이에 크게 의존하는 것으로 나타났다. RSI 지표는 전반적으로 위험 관리 측면에서 안정적인 성과를 보였고, GC 지표는 높은 수익률을 제공하는 반면 변동성이 상대적으로 크게 나타나는 경향이 확인되었다. 이러한 결과는 단일 지표보다는 지표 특성과 시장 환경을 고려한 통합적 접근의 필요성을 시사한다.

<Table 4> Comparison of Returns (%) and MDD (%) by Market Regime and TI for CV ESN

Ticker	Market Regime	Return/MDD	CV50			CV100			CV150			CV200		
			GC	ENV	RSI	GC	ENV	RSI	GC	ENV	RSI	GC	ENV	RSI
DIA	Stable-non-volatile	Return	0.70	0.69	1.40	3.67	0.85	4.62	6.55	0.05	5.54	11.49	4.38	8.75
		MDD	2.45	3.12	2.49	5.71	5.15	4.56	4.11	4.80	5.02	5.33	5.21	5.50
	Stable-volatile	Return	1.63	3.13	-0.07	-0.82	2.76	-3.48	-1.06	2.37	3.57	-0.32	5.20	4.98
		MDD	4.50	4.20	6.50	12.85	11.90	11.61	12.49	9.01	9.71	17.77	12.79	16.57
	Trend-non-volatile	Return	1.57	2.83	2.84	5.00	5.67	6.18	6.08	9.67	8.31	6.90	9.04	5.11
		MDD	2.62	2.08	2.58	2.52	2.61	3.13	2.74	3.01	3.71	1.48	2.52	2.37
Trend-volatile	Return	1.57	-1.06	0.91	3.39	1.82	2.35	3.65	1.65	8.03	7.37	9.56	8.19	
	MDD	6.49	6.98	6.31	9.73	8.67	9.04	9.92	11.09	9.27	6.65	5.02	7.87	
QQQ	Stable-non-volatile	Return	0.27	-1.01	0.85	7.44	4.51	7.31	3.46	12.97	5.53	11.76	1.89	6.61
		MDD	5.24	6.10	4.95	7.96	7.28	8.35	4.03	3.57	4.87	7.84	11.38	9.09
	Stable-volatile	Return	-2.53	0.06	-1.97	2.77	3.06	-1.73	7.45	0.70	8.24	6.61	7.14	1.82
		MDD	10.90	9.12	11.01	15.51	10.93	17.43	13.59	14.55	13.03	15.22	16.68	20.46
	Trend-non-volatile	Return	7.48	5.75	7.88	8.27	6.81	10.60	20.85	11.93	16.99	16.78	8.57	18.47
		MDD	3.74	3.21	3.31	4.53	4.35	3.62	4.48	4.57	4.54	4.39	5.37	3.15
Trend-volatile	Return	2.49	1.76	2.91	9.14	2.11	4.03	9.02	4.12	-1.13	17.18	16.07	3.73	
	MDD	8.11	7.69	8.63	11.53	10.84	12.37	9.32	9.95	15.83	15.41	6.56	21.15	
SPY	Stable-non-volatile	Return	1.08	1.75	-0.15	3.24	3.96	3.47	1.66	8.78	0.31	6.54	9.64	9.15
		MDD	3.01	1.80	2.67	4.98	4.75	4.36	1.87	1.60	2.48	8.23	8.74	7.82
	Stable-volatile	Return	0.34	0.90	1.44	1.01	0.45	-1.55	-0.43	4.35	1.06	0.14	8.16	1.38
		MDD	5.80	7.05	6.04	13.15	10.80	13.50	14.08	8.51	11.87	18.35	12.61	14.36
	Trend-non-volatile	Return	3.52	4.39	3.27	4.90	6.83	6.02	7.74	9.56	6.75	6.91	12.92	6.20
		MDD	2.20	2.69	2.11	3.62	2.77	3.39	3.88	4.04	4.01	2.65	2.87	2.72
Trend-volatile	Return	0.08	-1.20	0.74	3.68	3.49	4.82	3.02	3.01	7.35	4.09	6.88	8.91	
	MDD	7.77	9.05	8.84	9.98	11.00	8.55	8.87	11.57	9.73	3.98	6.48	5.99	
KS200	Stable-non-volatile	Return	-0.38	0.28	0.30	1.32	2.33	3.64	3.24	4.41	1.00	3.88	1.68	3.54
		MDD	5.02	5.05	5.03	6.68	6.18	6.28	7.45	8.14	8.76	9.56	10.49	8.98
	Stable-volatile	Return	2.07	0.38	1.61	-2.14	1.47	1.11	-3.79	2.45	-0.42	-5.63	-0.30	5.80
		MDD	7.28	7.22	6.93	15.60	12.89	11.90	16.22	10.41	16.49	14.50	13.37	9.46
	Trend-non-volatile	Return	2.59	1.00	3.56	3.33	0.33	5.65	7.11	3.95	15.78	5.61	4.48	14.90
		MDD	3.56	5.03	3.31	4.70	5.72	5.57	7.12	8.49	4.53	1.44	2.39	3.02
Trend-volatile	Return	1.13	0.32	2.38	2.75	3.92	8.87	10.94	-2.43	10.16	4.51	-2.86	1.65	
	MDD	7.91	7.06	8.19	9.27	8.39	7.69	13.65	11.05	10.12	18.20	17.18	19.25	

4.2 시장 상태별 성과 및 통계적 유의성

지수 DIA, QQQ, SPY, KOSPI200을 대상으로, 4가지 시장 상태인 안정·비변동, 안정·변동, 추세·비변동, 추세·변동 유형별로 교차검증 CV50, CV100, CV150, CV200으로 기술적 분석 지표 GC, ENV, RSI에 대한 수익률(Return)과 최대낙폭(MDD)에 대한 결과는 <Table 4>과 같다.

먼저 DIA의 경우, 안정·비변동 및 안정·변동 시장에서는 전반적으로 수익률이 낮고 지표 간 성과 차이가 제한적으로 나타났다. 반면 추세·비변동 시장에서는 ENV 기

반 CV150과 CV200에서 각각 9.67%, 9.04%의 수익률과 3.01%, 2.52%의 낮은 MDD를 기록하며 가장 안정적인 성과를 보였다. 추세·변동 시장에서는 수익률이 유지되었으나 MDD가 증가하는 경향이 관측되었다.

QQQ에서는 시장 상태에 따른 성과 차이가 가장 뚜렷하게 나타났다. 안정 시장에서는 수익률이 낮거나 변동성이 크게 나타났으나, 추세·비변동 시장에서는 GC 기반 CV150이 20.85%의 수익률과 4.48%의 MDD를 기록하며 가장 우수한 성과를 보였다. 또한 RSI 기반 CV200은 18.47%의 수익률과 3.15%의 매우 낮은 MDD를 기록하

여 위험 관리 측면에서 강점을 보였다. 반면 추세·변동 시장에서는 GC가 가장 높은 수익률을 기록하였으나, MDD 역시 크게 증가하여 변동성 환경에서의 위험 노출이 확인되었다.

SPY의 경우, 안정 시장에서는 전반적으로 낮은 수익률과 비교적 높은 MDD가 관측되었다. 추세·비변동 시장에서는 ENV 기반 CV200이 12.92%의 수익률과 2.87%의 낮은 MDD를 기록하여 가장 균형 잡힌 성과를 보였다. 추세·변동 시장에서는 수익률이 유지되었으나, 안정적인 환경 대비 MDD가 증가하는 경향이 나타났다.

KOSPI200은 전반적으로 수익률 수준이 상대적으로 낮았으나, 추세·비변동 시장에서는 RSI 기반 CV150이 15.78%의 수익률과 4.53%의 MDD를 기록하며 가장 우수한 성과를 보였다. 반면 안정·변동 시장과 추세·변동 시장에서는 MDD가 크게 증가하여 변동성에 대한 취약성이 확인되었다.

본 연구 결과, 중·장기 CV(150~200) 구간에서는 GC는 수익률 극대화, ENV는 추세 유지 안정성, RSI는 위험 억제 측면에서 지표별 역할이 구분되어 다중 CV 기반 접근의 유효성이 확인되었다. 더 나아가 해외 지수와 달리 KOSPI200에서는 변동성 완화 성향의 지표가 상대적으로 유리하게 작동하여, 자산 특성에 따른 차별적 지표 학습 구조 적용의 필요성을 시사하고 있다.

4.3 GA 적합도 설계와 기술적 분석 지표 특성

전환점(TP), 수익률(Return), 최대 낙폭(MDD)에 대한 패널티를 동시에 GA 적합도 함수에 포함한 결과, 전통적으로 알려진 기술적 분석 지표의 특성과는 다른 양상이 관측되었다. 즉, 시장 상태 적합성 측면에서 GC는 추세 시장에, ENV는 추세와 변동성이 결합된 구간에, RSI는 저변동·회보 시장에 상대적으로 적합한 특성 가진다. 그러나 본 연구에서는 RSI 지표가 추세·변동 시장 구간에서도 유의미한 우위를 나타내는 비정형적인 패턴을 보였다. 이에 위험 관리 척도인 MDD 패널티를 GA 적합도 평가에서 제외하여 재분석한 결과, GC 지표가 가지는 추세 구간에서의 강점과 ENV 지표의 회보 유지 구간에 대한 반응성이 부분적으로 회복되는 양상이 확인되었다. 따라서, 기술적 분석 지표의 시장 적합성이 고정된 속성이 아니라 적합도 설계에 따라 재구성될 수 있는 동적 특성이 확인되었다. 이는 시장 상태(레짐) 분류와 적응형 학습 구조를 결합한 하이브리드 모델 설계 시 적합도 함수의 정의가 핵심 설계 변수임을 시사한다.

5. 결론

본 연구에서는 미국 주요 ETF(DIA, QQQ, SPY)와 국내 지수(KOSPI200)를 대상으로 B&H, 고정형 ESN(ST ESN), 교차검증 기반 ESN(CV ESN) 전략의 성과를 비교하고, 기술적 분석 지표(GC, ENV, RSI)와 시장 상태에 따른 특성을 분석하였다. 특히, GA를 이용한 기술적 분석 지표 파라미터 최적화와 ESN을 이용한 전환점 기반 시계열 예측을 단일 프레임워크 안에서 결합한 hybrid GA-ESN 구조이다. 이를 통해 규칙 기반 기술적 분석과 비선형 신경망 예측의 장점을 동시에 활용하도록 설계되었다.

분석 결과, B&H 전략은 높은 누적 수익률을 기록하였으나 최대 낙폭(MDD)이 크게 나타나 위험 관리 측면에서 한계가 확인되었으며, ST ESN은 MDD를 일부 완화하였으나 시장 변화에 대한 적응력은 제한적이었다. 반면 CV ESN은 다중 윈도우 학습을 통해 대부분의 자산에서 MDD를 효과적으로 감소시키며 수익률과 안정성 간의 균형 측면에서 우수한 성과를 보였다. 그리고 시장 상태(레짐)별 분석 결과, 모든 지수에서 추세·비변동 시장이 가장 높은 수익률과 가장 낮은 MDD를 동시에 달성한 핵심 국면으로 확인되었다. 특히 QQQ와 SPY에서는 중·장기 교차검증(CV150, CV200) 구간에서 성과 개선이 두드러졌으며, KOSPI200의 경우 RSI 기반 전략이 추세·비변동 시장에서 상대적으로 안정적인 성과를 보였다. 이는 자산 특성과 시장 상태에 따라 차별화된 지표와 학습 구조 적용의 필요성을 시사한다. 요약하면, CV 중·장기 구간에서 GC는 수익률 극대화, ENV는 추세 유지 안정성, RSI는 변동성 완화 측면에서 지표별 역할이 분화됨을 확인되었다.

또한 GA 적합도 함수에 전환점(TP), 수익률, MDD를 동시에 반영한 결과, 기술적 분석 지표의 전통적인 시장 적합성과는 다른 비정형적 패턴이 관측되었다. 이는 기술적 분석 지표의 성과가 고정된 속성이 아니라, 적합도 설계와 위험 관리 기준에 따라 동적으로 재구성될 수 있음을 의미한다. 또한 시장 상태 분류와 적응형 학습 구조를 결합한 하이브리드 모델 설계에서 적합도 함수 정의의 중요성을 시사한다.

연구의 학술적 기여는 첫째, GA 기반 기술적 분석 지표 최적화와 전환점 중심 ESN을 결합한 하이브리드 모델을 통해 기술적 분석의 파라미터 민감도와 비선형·비정상 시계열 예측 문제를 동시에 완화할 수 있는 예측 모델을 제시한 데 있다. 둘째, 시장 상태(레짐) 분류와 교차

검증 ESN을 통합하여, 자산·지표·윈도우 조합별로 수익률과 최대 낙폭이 어떻게 달라지는지 체계적으로 보여줌으로써, 시장 상태 적응형 알고리즘 트레이딩 설계에 대한 실증적 근거를 제공한다.

본 연구에서 제시한 수익률은 거래비용, 슬리피지, 세금 등을 반영하지 않은 이론적 성과이다. 이는 실제 트레이딩 환경에서 구현될 경우 체결 지연과 시장 충격 등으로 인해 성과가 감소할 수 있다는 한계가 있다. 향후 연구에서는 실제 거래 환경에서 발생 가능한 수수료, 슬리피지, 세금 등을 반영한 백테스트와 시뮬레이션을 수행하여, 제안 모형의 순수익률과 위험 조정 성과를 재평가할 필요가 있다. 더 나아가 다양한 자산군과 시장 미시구조 요인을 고려한 확장 연구를 통해 본 모델의 실무 적용 가능성을 보다 정교하게 검증하고자 한다.

REFERENCES

- [1] A.Ang and A.Timmermann, "Regime changes and financial markets," *Annual Review of Financial Economics*, Vol.4, No.1, pp.313-337, 2012.
- [2] N.Baba, T.Kawachi, T.Nomura and Y.Sakatani, "Utilization of neural networks and genetic algorithms for improving the traditional technical analysis in the financial market," in *Proceedings of the SICE 2004 Annual Conference*, Vol.2, pp.1409-1412, 2004.
- [3] D.Bao, "A generalized model for financial time series representation and prediction," *Applied Intelligence*, Vol.29, No.1, pp.1-11, 2008.
- [4] D.Bao and Z.Yang, "Intelligent stock trading system by turning point confirming and probabilistic reasoning," *Expert Systems with Applications*, Vol.34, No.1, pp.620-627, 2008.
- [5] W.Brock, J.Lakonishok and B.LeBaron, "Simple technical trading rules and the stochastic properties of stock returns," *The Journal of Finance*, Vol.47, No.5, pp.1731-1764, 1992.
- [6] D.P.Brown and R.H.Jennings, "On technical analysis," *The Review of Financial Studies*, Vol.2, No.4, pp.527-551, 1989.
- [7] W.C.Chiang, D.Enke, T.Wu and R.Wang, "An adaptive stock index trading decision support system," *Expert Systems with Applications*, Vol.59, pp.195-207, 2016.
- [8] J.D.Hamilton, "A new approach to the economic analysis of nonstationary time series and the business cycle," *Econometrica*, Vol.57, No.2, pp.357-384, 1989.
- [9] R.Hudson, M.Dempsey and K.Keasey, "A note on the weak form efficiency of capital markets: The application of simple technical trading rules to UK stock prices 1935-1994," *Journal of Banking & Finance*, Vol.20, No.6, pp.1121-1132, 1996.
- [10] H.Jaeger, "The echo state approach to analysing and training recurrent neural networks," *German National Research Center for Information Technology*, Technical Report, Vol.148, pp.1-47, 2001.
- [11] H.Jaeger and H.Haas, "Harnessing nonlinearity: Predicting chaotic systems and saving energy in wireless communication," *Science*, Vol.304, No.5667, pp.78-80, 2004.
- [12] S.H.Jeong, H.S.Lee, H.Nam and K.J.Oh, "Using a genetic algorithm to build a volume weighted average price model in a stock market," *Sustainability*, Vol.13, No.3, pp.1011, 2021.
- [13] T.H.Lee, H.B.Park and H.H.Kim, "Optimized technical analysis indicators and genetic algorithm-based trading strategies for the Korean financial market," In *Annual Conference of KIPS (Korea Information Processing Society)* pp.599-600, 2023.
- [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] M.Lukoševičius and H.Jaeger, "Reservoir computing approaches to recurrent neural network training," *Computer Science Review*, Vol.3, No.3, pp.127-149, 2009.
- [16] J.M.Maheu and T.H.McCurdy, "Identifying bull and bear markets in stock returns," *Journal of Business & Economic Statistics*, Vol.18, No.1, pp.100-112, 2000.
- [17] M.Mitchell, *An Introduction to Genetic Algorithms*, Cambridge, MA: MIT Press, 1998.
- [18] J.J.Murphy, *Technical Analysis of the Financial Markets: A Comprehensive Guide to Trading Methods and Applications*, New York, NY: Penguin, 1999.
- [19] C.H.Park and S.H.Irwin, "What do we know about the profitability of technical analysis?," *Journal of Economic Surveys*, Vol.21, No.4, pp.786-826, 2007.
- [20] Z.Wang, P.Chen, P.Liu and C.Wu, "Volatility forecasts by clustering: Applications for VaR estimation," *International Review of Economics & Finance*, Vol.94, pp.103355, 2024.

정 동 균(Dong-Kun Jung)

[정회원]



- 2019년 2월 : 국립부경대학교 경영대학원 (경영학석사)
- 2023년 2월 : 국립부경대학교 경영대학원 (경영학박사)
- 2025년 9월 ~ 현재 : 국립부경대학교 소프트웨어융합혁신원 계약 교수

<관심분야>

빅 데이터, 생성형 AI, 딥러닝, 데이터 분석 자동화

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