

펀드 위험등급 예측을 위한 머신러닝 기반 2단계 예측 모델 개발

김아람*, 박민호^o

Machine Learning-Based Two-Stage Prediction Model for Fund Risk Rating Prediction

A-Ram Kim*, Min-Ho Park^o

요약

금융 산업의 발전과 더불어 금융 투자 관련 범죄가 증가하자 금융당국은 2021년 금융소비자보호법을 시행해 판매사의 펀드 설명의무를 강화했다. 설명의무 대상인 위험등급은 투자 상품의 위험을 직관적으로 파악할 수 있는 중요한 지표이지만 관리가 소홀히 이루어져 왔다. 금소법 시행 이후 판매업계에서는 자체적으로 펀드 위험등급을 검증하고 관리하는 시스템을 구축하고 있다. 본 논문은 해당 시스템의 일환으로 머신러닝을 활용한 펀드 위험등급 2단계 예측 모델을 제안한다. 1단계에서는 금융 시계열 변동성 추정 모형인 GARCH 모형과 머신러닝 모델인 LSTM, 두 모형을 결합한 GARCH(1,1)-LSTM 모형을 사용하여 결산일 시점의 1개월 변동성을 예측한다. 2단계에서는 1단계에서 추정한 변동성과 기타 중요 위험지표를 4가지 커널별 SVM 분류 알고리즘에 입력해 펀드 위험등급을 예측한다. 연구 결과 GARCH(1,1)-LSTM 결합 모형이 가장 높은 변동성 예측 성과를 보였으며 RBF 커널을 이용한 다변량 SVM이 높은 위험등급 예측 정확도를 보였다.

Key Words : Fund, Risk Rating, Volatility, GARCH-LSTM, Machine Learning, SVM

ABSTRACT

This study proposes a two-stage prediction model for fund risk ratings using machine learning. In step 1, the GARCH model, the LSTM model and the GARCH-LSTM model, which combines the two models, are used to predict 1-month volatility. In step 2, the volatility and other important risk indicators are entered into the four kernel-specific SVM classification algorithms to predict the fund's risk rating. As a result, the GARCH-LSTM combination model showed the highest volatility prediction performance, and the multivariate SVM using the RBF kernel showed the highest risk rating prediction accuracy.

I. 서론

금융시장의 투자 기회 확대로 금융사고 위험이 증가하고 있다. 대표적인 사례로는 2019년 해외금리 연계

파생 결합 펀드 사태, 옵티머스 사모펀드 환매 중단 사태, 2020년 라임 사모펀드 환매 중단 사태 등이 있다. 이러한 사고는 금융회사가 정보 비대칭성을 악용해 불완전 판매를 한 것이 공통적이다. 이를 해결하기 위해

* 이 논문은 정부(과학기술정보통신부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임 (NRF-2023R1A2C1005461)

• First Author : Soongsil University, Department of IT Convergence, charmercy@naver.com, 정희원

o Corresponding Author : Soongsil University, School of Electronic Engineering, mhp@ssu.ac.kr, 종신희원

논문번호 : 202306-121-C-RN, Received June 9, 2023; Revised August 17, 2023; Accepted August 31, 2023

금융소비자보호법이 2020년 3월 제정되었고 2021년 3월 본격적으로 시행되었다.

금융사고 사례들과 같이 금융소비자들의 상품 이해도는 낮아지고 있으며 판매회사가 부당한 방식으로 과잉 소비를 유도할 가능성은 커지고 있다. 따라서 금융소비자 보호를 위해 금융회사들은 영업행위 시 ‘설명 의무’를 준수하여 위험등급과 수수료 등 상품 관련 중요 사항을 설명해야 한다. 위험등급은 상품의 변동성을 등급화한 지표로 원금 손실 위험 정도를 직관적으로 파악할 수 있다. 금융소비자보호법 시행 이후 금융당국은 펀드 위험등급 관리 감독을 강화하고, 이에 따라 판매업계에서는 선제적으로 관리하고자 하는 움직임이 커지고 있다. 그러나 현재의 펀드 위험등급 관리 방식은 등급 산정과 사후관리 측면에서 다음과 같은 한계점을 가지고 있다.

위험등급은 판매사 입장에서 사후적인 데이터에 기반하므로 변동 상황을 실시간으로 반영하기 어렵다. 판매 구조상 펀드는 크게 판매사와 운용사로 구성되며, 운용사에서 펀드를 설정한 후 판매사가 판매를 담당한다. 따라서 운용사가 공시하는 변경 내용을 판매사에서 즉시 반영하는 것은 어렵다. 펀드 정보가 변경된 경우 공시 시점은 증권 신고의 효력이 발생하는 당일 공시로 지정되어 있다. 당일 안에만 공시하면 되기 때문에 그림 1과 같이 상품 판매 후 정정 공시가 발생할 수 있다. 즉 판매 시점과 공시 시점 간의 시간적 차이가 생길 수 있다. 이에 따라 펀드 정보 변경 가능성을 예측하는 필요성이 부각되고 판매업계에서는 관리를 위한 움직임이 증가하고 있다.

2023년 1월에 발표된 금융감독원의 가이드라인에 의하면, 향후 판매사는 시장위험과 신용위험, 환율 위험 등 다양한 위험을 종합적으로 고려해 위험등급을 산정하고, 상품을 판매할 때 고객이 쉽게 이해할 수 있도록 위험등급의 의미를 설명해야 한다. 현재는 운용사가 공시한 정보를 기반으로 투자자에게 상품을 설명했다면, 앞으로는 판매사 자체적으로 펀드의 위험등급을 예측하고, 운용사가 산출한 펀드의 위험등급이 적절한지 능동적으로 검토할 수 있다. 따라서 본 연구에서는 펀드의 주간 수익률을 활용하여 변동성을 추정하고, 추정된 변

동성을 통해 향후 결산일 시점의 펀드 위험등급을 예측하고자 한다. 이를 통해 판매사는 더 정확한 위험등급을 제시하고 투자자는 상품의 위험성을 더 명확하게 이해할 수 있게 될 것이다.

본 논문은 다음과 같이 구성되어 있다. II장은 이론적 배경을 다루며 주식 시장과 펀드 시장 각각의 변동성 예측에 관한 선행연구를 조사하고 펀드의 위험등급에 대해 살펴보았다. III장은 분석 모형으로 1단계 연구에 사용된 GARCH(1,1)모형과 LSTM 모형, 두 모형을 결합한 GARCH(1,1)-LSTM 결합 모형에 관해 설명했다. 또한 2단계 연구에 사용된 SVM에 대해서도 살펴보았다. IV장은 연구 모형 관련 설명으로 2단계로 나뉜 연구 진행 방식과 검증 방법에 관해 서술했다. V장은 연구 결과로 1단계 변동성 예측 단계에서 사용된 모형들의 정확도를 비교하고, 펀드 유형별 정확도를 살펴보았다. 또한 2단계 위험등급 예측 단계에서는 커널을 4가지 경우로 다르게 설정하여 위험등급의 예측 정확도를 확인했다. 마지막으로 VI장은 모형 결과 내용을 요약하고 본 연구의 한계점 및 의의를 제시했다.

II. 이론적 배경

펀드(Fund)는 투자자의 자금을 운용사가 주식, 채권, 부동산 등에 투자하여 운용하고 수익을 분배하는 간접 투자 상품이다. 예금자 보호가 되지 않으며 위험도는 예적금보다 높지만, 적은 자금으로도 다양한 분산투자가 가능하고 상대적으로 높은 수익을 기대할 수 있는 대체크 수단이다. 투자 전에는 금융 지식과 이해력이 필요하며, 수익률과 위험을 동시에 고려해야 한다. 펀드의 위험을 측정하는 대표적인 지표는 표준편차 등이 있으며 투자자는 이러한 지표들을 활용하여 펀드의 성격과 자신의 투자성향을 파악할 수 있다.

2.1 펀드 위험등급의 개요

펀드의 위험등급은 금융소비자들이 펀드에 가입할 때 참고해야 하는 중요한 변동성 지표다. 금융소비자보호법 제19조에 따르면 금융상품 판매업자는 투자성 상품을 권유할 때 위험등급을 설명해야 한다. 또한 그림 2와 같이 기업공시 서식 작성 기준에 따라 집합투자기구의 투자위험 등급을 6단계 이상으로 구분하고 상단부에 해당 등급을 기재하고 등급에 따라 표시 칸의 색상을 다르게 표시해야 한다.

금융당국은 금융상품 판매업자가 설명해야 할 사항 중 투자성 상품의 위험등급 산정을 위한 가이드라인을 제시하고 있다. 현재 적용 중인 가이드라인은 2016년

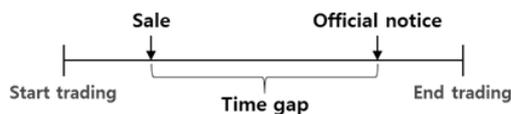


그림 1. 판매시점과 공시시점의 시간 격차
Fig. 1. Time gap between sale and official notice

투자 위험 등급					
1등급 (매우 높은 위험)					
1	2	3	4	5	6
매우 높은 위험	높은 위험	중간 위험	낮은 위험	매우 낮은 위험	가장 낮은 위험

OO자산운용(주)는 실제 수익률 변동성(또는 투자대상 자산의 종류 및 위험도 등)을 감안하여 O등급으로 분류하였습니다. 펀드의 위험 등급은 운용실적, 시장 상황 등에 따라 변경될 수 있다는 점을 유의하여 투자판단을 하시기 바랍니다.

그림 2. 투자설명서 작성 기준 서식
Fig. 2. Risk rating form in the investment manual

표 1. 펀드 위험등급 구간표
Table 1. Fund Risk Rating Range Table

등급	1(고위험)	2	3	4	5	6(저위험)
표준 편차	25% 초과	25%이하	15%이하	10%이하	5%이하	0.5%이하

5단계에서 6단계로 세분되었으며, 설정 후 3년이 지난 펀드에 대해서는 수익률 변동성을 기준으로 위험등급을 산정하고 있다. 수익률 변동성은 매년 결산 시점에 측정되며, 결산일 기준 이전 3년(156주) 동안 펀드의 주간 수익률의 연 환산 표준편차와 표 1의 등급 기준표의 표준편차 상한치를 비교하여 위험등급을 결정한다.

2.2 선행 연구

주식 시장에서의 변동성 예측은 주식 자체에 투자하는 경우뿐만 아니라 주가연계증권(ELS)과 같이 특정 주식이나 지수를 기초 자산으로 하는 구조화 파생상품, 한국거래소의 VKOSPI와 미국 S&P 500 지수옵션 기반 변동성 지수인 VIX 지수와 같이 지수옵션 시장의 내재 변동성을 이용한 미래 기대 변동성 등 다양한 분야에서 중요한 역할을 한다. 이처럼 주식의 변동성은 파생상품의 가치 평가와 헤지에 필요한 핵심 요소이므로 변동성 예측에 관한 많은 연구가 진행되고 있다.

주식 방향성 예측과 비교했을 때 변동성 예측은 변동성 특유의 군집 현상으로 인해 상대적으로 예측 확률이 높은 편이다²⁾. 계량경제학에서 금융 시계열 자료의 변동성 군집 현상을 설명하기 위해 Engle은 변동성을 과거의 오차들의 선형함수로 나타낸 ARCH 모형을 제안했다¹³⁾. Bollerslev는 ARCH 모형을 일반화한 GARCH 모형을 제안했고 이외에도 변동성을 예측하기 위한 금융 시계열 모형들이 발전되고 있다¹⁰⁾. 최근에는 인공지능영향을 활용한 연구도 이루어지고 있다.

주식 변동성 예측에 대한 연구는 활발히 이루어지고 있다. 그러나 펀드는 여러 자산에 분산하여 포트폴리오를 구성하기 때문에, 주식 투자나 지수 연계 투자보다 안정적인 상품이라고 간주되어서 변동성 예측에 관한 연구는 상대적으로 적게 이루어지고 있다. 1980년대 활성화된 주식시장과 달리 국내 펀드 시장은 2000년대

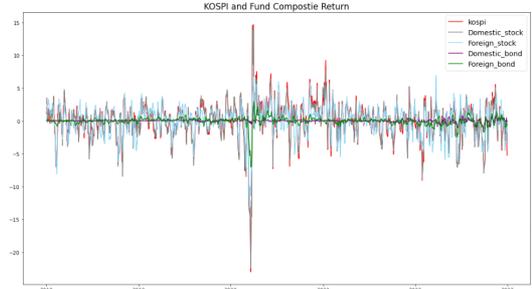


그림 3. KOSPI와 유형별 펀드 주간수익률 시계열
Fig. 3. A Time Series Comparison of KOSPI and Fund's Weekly Yield by Composite Type

중반 활성화되었기 때문에 국내에서는 펀드에 대한 연구가 미진한 상태이다. 그러나 최근 알파 수익률을 추구하기 위해 파생상품에 일부 투자하는 등 공격적인 투자 전략으로 운용하는 펀드가 증가함에 따라 펀드 변동성 예측의 필요성이 확대되고 있다.

현재까지는 펀드 변동성 예측에 관한 연구가 거의 이루어지지 않았기 때문에 본 연구에서는 주식 변동성 예측에 관한 선행 연구를 참고하여 펀드 변동성 예측 모형을 개발하고자 한다. 그림 3은 KOSPI와 유형별 펀드들의 주간 수익률을 시계열화한 자료이다. 분석 결과 그림과 같이 주가의 변동성이 한 번 커지면 그 증가 추세가 한동안 지속될 가능성이 높은 변동성 군집 현상이 펀드의 변동성에도 유사하게 나타나는 것을 확인했다.

III. 분석 모형

3.1 GARCH

금융상품의 변동성은 금융시계열인 수익률 분산의 움직임의 의미한다. 금융시계열의 변동성은 시간에 따라서 변하는 변동성 군집현상의 특징이 있다. 이는 큰 폭으로 변동하는 기간이 일정 기간 유지되는 현상이며 분산에 자기상관(Autocorrelation)이 존재하는 것을 의미한다. 고전적 회귀모형에서 오차항은 서로 상관관계가 없는 독립적인 백색잡음이라고 가정하고 있지만 실제 주식이나 지수 등 대부분의 금융시계열에서 오차항은 하나의 잔차항의 크기가 이웃하는 다른 잔차항의 크기와 서로 일정한 관련이 있는 자기상관 현상을 보인다. 즉 실제 금융 시계열은 변동성 자체도 시간에 흐름에 따라 바뀌는 조건부 이분산성과 변동성 군집현상을 고려해야 한다.

조건부 이분산성 연구에서 널리 사용되는 모형은 Bollerslev가 제안한 일반 자기회귀 조건부 이분산성 (GARCH: Generalized AutoRegressive Conditional

Heteroskedasticity) 모형이다¹⁰⁾. Engle이 제안한 자기회기 조건부 이분산성 (ARCH: AutoRegressive Conditional Heteroskedasticity) 모형에서 파생된 모형으로 ARCH 모형의 조건부 분산방정식에서 추정해야 할 모수가 많다는 단점을 보완했다. GARCH(1,1) 모형은 추정해야 할 모수가 작기 때문에 가장 보편적으로 이용되고 있다. GARCH(1,1) 모형은 다음과 같은 방정식을 가진다.

$$\sigma^2 = \omega + \alpha x_{t-1}^2 + \beta \sigma_{t-1}^2 + \epsilon_t \quad (1)$$

금융시계열의 변동성이 과거의 변동성에 의존하여 결정되도록 모형화 한 식이다. x 가 수익률이고 σ 가 변동성이고 ϵ_t 는 백색잡음일 때, 추정해야 할 모수는 ω, α, β 이다. 즉 ω, α, β 를 안다면 과거 변동값으로 현재의 변동성을 계산할 수 있고 미래 변동성도 예측할 수 있다. 본문에서는 펀드의 주간 수익률을 단일 변량 변수로 GARCH(1,1) 모형에 넣어 t+1 시점의 변동성을 예측했다.

3.2 LSTM

LSTM(Long Short-Term Memory)은 기존의 순환 신경망(RNN)이 출력과 먼 위치에 있는 정보를 기억할 수 없다는 단점을 보완한 모형이다. 메모리 셀 여러 개가 연결된 구조로 이루어져 있으며, 역전파 기법을 통해 학습을 진행하면서 과거에 학습한 정보를 새로운 학습 결과에 반영할 수 있기 때문에 시계열 예측에 활용된다.

LSTM은 4개의 게이트로 구성되어 있으며 상호 작용 레이어가 서로 정보를 주고받는다. Forget Gate는 과거의 정보를 얼마나 잊을지 결정하는 게이트로 Sigmoid Layer에 의해 결정이 된다. Input Gate는 현재 정보를 기억하기 위한 게이트로 현 시점의 정보를 현재의 Cell 에 얼마나 더할지 결정한다. 앞에서 계산한 Forget Gate, Input Gate를 바탕으로 과거 Cell을 새로운 Cell로 Update한다. 마지막으로 Output Gate에서 계산된 현재의 Cell을 현 시점의 은닉층 값으로 얼마나 출력할 것인지 결정한다.

3.3 GARCH-LSTM

금융시계열 모형은 계량기법을 사용하여 정확한 분석이 가능하지만 시장 환경의 변화에 따라 많은 시장 변수들의 잡음을 직접 반영하기 어렵다. 한편, 인공지능망 모형인 LSTM은 금융시계열 모형보다 높은 예측 성능을 보이지만 자료에 내재된 금융적 특성에 대한 해석이 어렵다. 이러한 이유로 LSTM과 금융시계열 모형을

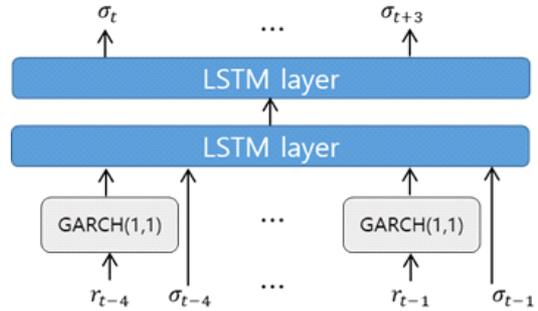


그림 4. GARCH-LSTM 구조
Fig. 4. Structure of GARCH-LSTM

결합한 다양한 연구가 진행되고 있다. Roh는 단일 금융시계열 모형과 인공지능망 모형을 결합한 모형을 제안하여 통계적 모형의 설명력과 인공지능망 모형의 비모수적 예측 방법의 장점을 동시에 구현했다⁵⁾. 또한 Hajizadeh와 Turksen은 GARCH 계열 모형과 인공지능망 모형을 결합한 모형이 예측 오차를 줄일 수 있음을 확인했다⁶⁾. 그림 4는 본 연구의 표준편차 예측을 위한 GARCH-LSTM 구조이다. r 은 금융시계열 GARCH 모형에서 추정된 모수로 예측한 변동성이며 σ 은 표준편차이다. 두 입력변수를 이론적 함수 형태가 없는 비모수적 모형인 LSTM의 입력변수로 활용했다.

3.4 SVM

SVM (Support Vector Machine)알고리즘은 기계 학습 분야 중 하나로 Vapnik에 의해 제안된 분류 학습모형이다. 주로 분류와 회귀 분석을 위해 사용하며 주어진 데이터들이 두 개의 클래스에 각각 속해 있을 때 새롭게 입력한 데이터가 두 클래스 중 어느 곳에 속하는지 결정하는 분류 모델이다. SVM은 여러 분야에서 널리 활용되고 있으며, 경험적 위험 최소화와 원칙이 아닌 구조적 위험 최소화를 기반으로 하고 있기 때문에 일반화의 오류를 감소시키는 점에서 기존의 방법들보다 우수한 성능을 가진다고 알려져 있다⁷⁾. 분류 성능의 향상을 위해서는 어떤 분류된 데이터에 대해서 가장 먼 거리인 초평면을 찾아야 한다. SVM 알고리즘은 데이터가 매핑된 공간에서 가장 큰 폭을 가진 경계를 찾는 알고리즘이다. 데이터를 분류하는 초평면은 여러 가지 경우가 나올 수 있는데 서포트 벡터(Support Vector)는 구분하는 초평면의 위치를 식별하는 훈련 관측값을 의미하며 그림 5의 실선 위의 점들에 해당한다.

본 연구는 멀티 클래스 분류에 해당하므로 선형 SVM으로 분류하기 어렵다. 이 경우 저차원의 데이터를 고차원의 데이터 값으로 이동시켜 데이터를 분류해

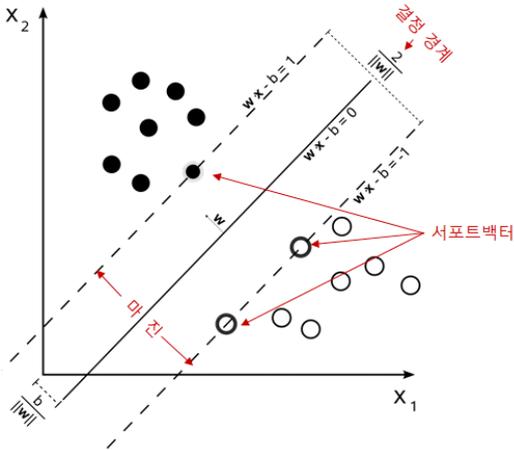


그림 5. SVM 도식화
Fig. 5. Visualization of SVM

야 하는데 특성 추가에 따른 연산량이 증가하거나 어떤 특성을 추가해야 할지 모르는 문제점이 발생할 수 있다. 따라서 비선형 SVM인 커널(Kernel) 함수를 추가한 SVM을 사용했다. 커널 함수에는 선형 커널(linear kernel), 시그모이드 커널(sigmoid kernel), 다항식 커널(polynominal kernel), 가우시안 방사 기저 함수 커널(Gaussian RBF kernel) 등이 있다. 이 중 어떤 커널을 사용할 것인지에 대해서는 합리적인 규칙이 정해져 있지 않으며 커널 함수별 성능도 큰 차이가 없기 때문에, 커널 함수의 결정은 데이터의 형태, 훈련 데이터의 총량, 속성 간의 관계를 고려한 다양한 시도와 평가를 기반으로 결정된다⁶⁾. 본 연구에서는 멀티클래스 SVM을 지원하는 파이썬 Scikit-learn의 SVM 중 분류 SVM인 SVC 모듈을 활용해 위험등급을 분류했다.

IV. 연구 설계

4.1 연구 모형

본 연구는 2단계로 구성되어 있다. 그림 6은 위험등급 예측의 흐름을 도식화 한 것으로, 1단계에서는 세 가지 예측 모델을 사용하여 1개월 동안의 변동성(표준편차)을 예측한다. 2단계에서는 1단계에서 예측한 변동성 지표와 기타 펀드 위험 지표를 SVM 분류 모델에 입력해 위험 등급을 예측한다.

4.1.1 변동성 예측

1단계 변동성 예측 과정에서는 세 가지 예측 모델을 사용해 각각의 성능을 비교했다. 금융 시계열 변동성 모형인 GARCH(1,1) 모형과 장기 메모리 학습이 가능

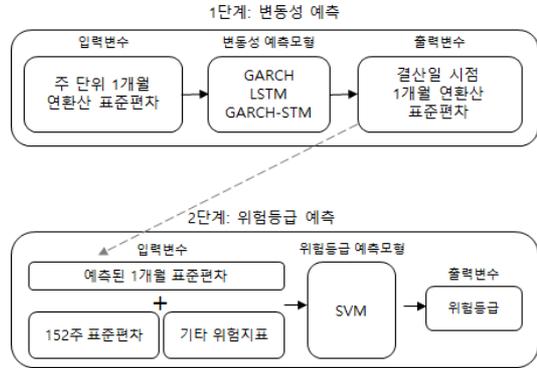


그림 6. 연구 모형 구조
Fig. 6. Visualization of Model Structure

한 LSTM 모형, 두 모형을 결합한 GARCH(1,1)-LSTM 모형으로 변동성을 예측했다. 모델링은 Python의 Arch(5.5 ver) 패키지와 Keras(2.12 ver) 라이브러리를 활용했다. GARCH(1,1) 모형과 LSTM 모형의 입력 변수는 주 단위 1개월 연환산 표준편차이다. 그림 4와 같이 GARCH(1,1)-LSTM 결합모형에서는 입력 변수로 주 단위 1개월 연 환산 표준편차 시계열인 σ 와 GARCH(1,1) 모형에서 도출한 시계열 데이터 r 를 사용했다. $t-4$ 시점부터 $t-1$ 시점까지를 입력값으로 받아 LSTM 계층을 통과하여 t 부터 $t+3$ 시점까지의 표준편차를 예측했다. 결산일 4주 전에 1달 표준편차를 예측하기 때문에 타임스텝은 4로 설정했다.

4.1.2 위험등급 예측

2단계 위험등급 예측 과정에서는 Support Vector Machine(SVM) 알고리즘을 사용했다. 이를 위해 Python의 Scikit-learn(사이킷런) 라이브러리에서 제공하는 Support Vector Classification(SVC) 분류 모델을 활용했다. 입력 변수로는 Pearson 상관계수를 이용해 표준편차와의 상관관계를 확인하고, 상관관계가 있는 펀드 위험지표를 선택했다. Pearson 상관계수는 두 변수간의 선형 상관 관계를 수치화한 값으로 -1에서 1 사이의 범위를 가지며, 상관관계가 없을수록 0에 가까운 값을 가진다. 일반적으로 0.1 이하의 값은 거의 상관관계가 없다고 해석된다. 그림 7은 Pearson 상관계수에 절대값을 취해 시각화한 결과이며, 표준편차와 Beta의 상관계수는 0.042로 거의 상관관계가 없음을 확인했다. 최종적으로 변동성 예측 모형을 통해 예측된 1개월 표준편차와 결산일 3년 전 시점으로부터의 152주 주간 수익률의 연환산 표준편차를 가중평균한 표준편차, Pearson 상관계수를 통해 상관성이 없는 Beta는 제외하고 상관성을 확인한 샤프지수(Sharp Ratio), 트레킹에

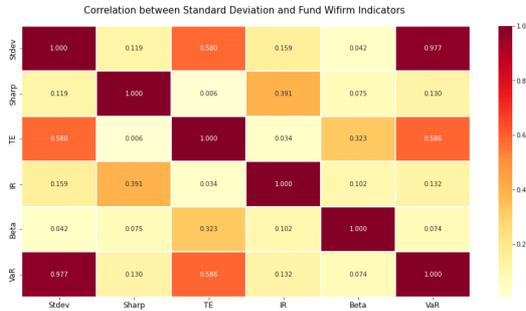


그림 7. 표준편차와 기타 위험지표의 Pearson 상관계수
Fig. 7. Pearson correlation coefficient of standard deviation and other risk indicators

러(Tracking Error), 정보비율(IR), 최대예상손실 97.5% VaR(Value at Risk) 총 5개를 입력 변수로 활용했다. 목표 변수는 1등급에서 6등급 사이의 범위를 갖는 펀드 위험등급이다. SVM 선형 모델에 비선형 특성을 추가해 분류 능력을 향상시킬 수 있는 커널을 사용했다. RBF, Sigmoid, Linear, Polynomial 총 4가지 형태 커널을 이용했으며, 하이퍼 파라미터인 gamma와 c는 사이킷런의 GridSearchCV 모듈을 이용해 튜닝했다.

4.2 연구 자료

본 연구는 2022년 12월 31일 기준 운용중인 펀드를 대상으로 했으며, 유형별 특성을 확인하고자 KFR 유형 분류 내 중유형 기준으로 국내주식형, 국내채권형, 국내 혼합형, 국내ETF, MMF 해외주식형, 해외채권형, 해외 혼합형, 해외ETF를 분석 대상으로 선정했다. 연구 데이터 수집 기간은 펀드 위험등급이 5단계에서 6단계로 변경된 2016년 6월 24일부터 2022년 12월 31일까지로 설정했다. 대상 펀드는 2022년 12월 31일 기준으로 3년 이상 운용중인 펀드이며, 총 2,585개의 펀드가 분석에 활용되었다.

1단계 변동성 예측 모형에서는 펀드의 주간 수익률과 결산 데이터를 활용해 각 펀드의 1개월 표준편차 시계열을 도출했다. 변동성 예측에는 일반적으로 로그 수익률이 사용되지만, 금융당국의 가이드라인을 따라 단순 수익률을 사용했다. 데이터는 펀드평가사인 한국펀드평가의 자료를 활용했다. 2단계 위험등급 예측 모형에서는 각종 위험지표와 97.5% VaR 등의 지표를 활용했다. 한국펀드평가의 자료를 활용했으며 위험등급은 각 펀드의 투자설명서에 공시된 위험등급을 사용했다.

4.3 검증 방법 및 성능평가지표

본 연구에서는 K-fold 교차검증(K-fold cross validation)을 사용해 검증 방법을 적용했다. 1단계 변

동성 예측 모형의 성능 평가를 위해 평균 제곱 오차 (Mean Squared Error: MSE)와 평균 제곱근 오차 (Root Mean Squared Error: RMSE)를 사용했다. 이 지표들은 모델의 예측 값과 실제 값 사이의 오차를 측정하는 데 사용된다. 2단계 위험 등급 예측 모형인 SVM의 분류 성과를 평가하기 위해 정확도(Accuracy)를 사용했다. 정확도는 모델이 정확하게 분류한 샘플의 비율을 나타내며, 분류 모형의 성능을 평가하는 데 널리 사용되는 지표다.

4.3.1 검증 방법

교차 검증(cross-validation)은 모델을 학습시킬 때 데이터를 훈련용과 검증용으로 나누고, 데이터를 교차하여 성능을 평가하는 방법이다. 교차 검증을 사용하는 이유는 일반화된 성능을 추정하기 위해서이다. 그림 7의 상단과 같이 한 번의 분할로만 평가를 진행하면 특정한 훈련용 데이터와 검증용 데이터에 대해서만 모델을 평가하게 되어 일반화된 성능을 제대로 파악하기 어렵다. 하지만 교차 검증을 사용하면 전체 데이터를 다양한 조합으로 나누어 모델을 여러 번 학습하고 성능을 평가하므로 보다 일반화된 성능을 추정할 수 있다. 이러한 방식은 데이터셋의 크기가 작거나, 모델의 성능을 정확히 평가하고자 할 때 유용하다.

K-fold 교차검증은 그림 8의 하단과 같이 전체 데이터를 K개의 폴드(fold)로 나누고, 폴드 1개를 Test data로 할당하고 나머지 K-1개의 폴드를 train data로 분할하는 과정을 K번 반복한다. 이렇게 하면 K번의 학습과 평가가 이루어지며, K개의 성능 결과의 평균을 학습 모델의 성능으로 사용한다. 반복에서 다른 폴드 조합이 사용되므로 모델은 다양한 데이터 조합에 대해 학습되고 평가되어 일반화된 성능을 추정할 수 있다. K-fold 교차검증은 데이터 부족으로 인한 과적합(overfitting)이나 과소적합(underfitting)을 방지할 수 있다. 또한 전

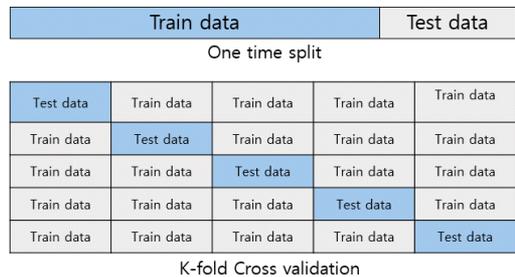


그림 8. 1회 분할과 K-fold 교차검증 도식화
Fig. 8. Comparison of one time split and K-fold cross validation

체 데이터를 훈련용과 검증용으로 나누어 활용하기 때문에 모델이 다양한 데이터에 적응하도록 도와주며, 특정한 데이터에 지나치게 의존하지 않게 된다. 이는 모델의 일반화 성능을 향상시키는 데 도움이 된다. K는 하이퍼파라미터로 본 연구에서는 K를 4로 지정해 4-fold 교차 검증을 사용했다.

4.3.2 성능 평가 지표

MSE는 회귀 분석에서 사용되는 성능지표로서, 실제 종속 변수와 예측한 종속 변수 간의 차이를 나타낸다. MSE는 예측 값과 실제 값의 차이의 제곱하여 평균한 값으로 정의한다. 본 연구에서는 이러한 지표들은 활용하여 1단계 변동성 예측 모형에서의 LSTM 모델의 성능 평가를 진행했다.

$$MSE = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{f}(x_i))^2 \quad (2)$$

$\hat{f}(x_i)$ 는 i 번째 입력 값에 대한 예측 값이다. 예측 값이 실제 값과 유사할수록 MSE는 작아진다. 즉 MSE가 작은 모델일수록 오차가 작기 때문에 예측 값이 실제 값을 잘 반영한다고 설명할 수 있다. MSE는 제곱을 하기 때문에 특이치에 민감하다. RMSE는 MSE에 루트를 쓰은 값으로 오류 값 차이에 대해 패널티를 부여하면서 오류 지표를 실제 값과 유사하게 다시 변환한다. 이로 인해 RMSE는 오류 값 해석이 보다 용이하다.

$$Accuracy = \frac{\text{옳게 분류된 데이터의 수}}{\text{전체 데이터의 수}} \quad (3)$$

SVM의 성능 평가지표로는 정확도, 오차행렬, 정밀도, 재현율, F1 스코어 등이 있다. 본 연구에서는 2단계 위험 등급 예측 모형인 SVM의 분류 성과 평가 지표로서 정확도(Accuracy)를 사용했다. 정확도는 전체 데이터 중에서 올바르게 분류된 데이터의 비율을 나타내며, 일반적인 분류 문제에서 보편적으로 사용되고 있다.

V. 연구 결과

5.1 펀드 변동성 예측 결과

5.1.1 검증 방법

표 2는 변동성 예측 모델의 성능을 평가하기 위해 MSE와 RMSE를 비교한 결과이다. 변동성 예측 결과에

표 2. 변동성 예측 모델 성능 비교
Table 2. Comparison of Volatility Prediction Model Performance

	GARCH	LSTM	GARCH-LSTM
MSE	592.0512	43.4936	34.7581
RMSE	24.3321	6.4343	5.7504

서 LSTM 단일 모델의 MSE와 RMSE가 GARCH(1,1) 모델보다 낮았으며, GARCH(1,1)-LSTM 결합모델의 MSE와 RMSE가 LSTM 단일 모델보다 더 낮았다. 이를 통해 GARCH(1,1)모델, LSTM 단일 모델, GARCH(1,1)-LSTM 결합 모델 순서대로 더 우수한 예측력을 보였음을 확인 할 수 있었다.

그림 9와 그림 10을 통해 상황별로 예측 모델을 비교한 결과 변동성이 높은 상황에서 GARCH(1,1)-LSTM 결합 모델의 성능이 우수함을 확인할 수 있었다. 그림 9에서 상황별로 모델의 성과를 시각화 했다. 우선 평가 대상 펀드들의 1개월 연환산 표준편차 평균을 상회하는 펀드들의 RMSE를 비교했을 때, GARCH(1,1)-LSTM 결합 모델의 RMSE가 낮은 것을 확인할 수 있었다. 반면 평균을 하회하는 펀드들의 평균 RMSE를 비교했을 때에는 LSTM 단일모델의 RMSE가 낮음을 확인할 수 있었다. 마지막으로 금융시장 변동성이 높았던 코로나 발생 시점의 RMSE를 비교한 결과, GARCH(1,1)-LSTM 결합모델의 RMSE가 낮았다. 이를 통해 변동성이 높은 상황에서는 GARCH(1,1)-LSTM 결합 모델이 더 우수한 성과를 보임을 확인했다.

그림 10은 변동성 상위 20위 펀드들의 모델별 예측 값을 비교한 결과이다. 변동성 상위 20위 펀드들의 대부분은 2020년 3월~4월 결산을 가지고 있으며, 해당 시기는 코로나 팬데믹 발생으로 금융시장 변동성이 큰

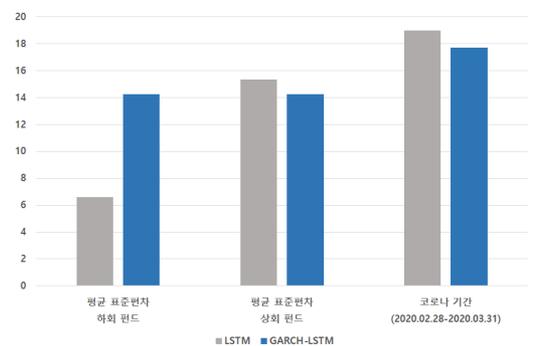


그림 9. 상황별 예측 모형 성과 비교
Fig. 9. Predictive Model Performance by Event

펀드	관심일	1개월 위험상승 표준편차(A)	예측값(B) (GARCH-LSTM)	예측값(C) (LSTM)	오차 X [A-B]	오차 Y [A-C]	오차X-오차Y
RR522661309	2022-03-08	191.0197	19.9312	19.6211	171.0885	171.3986	-0.3101
RR5210662866	2022-03-12	115.1235	20.6585	18.7003	94.4651	96.4233	-1.9582
RR5210671693	2020-04-02	106.2785	71.2323	47.4942	35.4902	59.2342	-23.7381
RR5234676157	2020-04-12	105.9835	26.0697	38.6953	79.8933	67.9582	12.6261
RR520674322	2020-04-09	104.1360	79.8418	82.4642	24.5382	21.7159	2.8224
RR5230687674	2020-04-17	80.3832	68.2920	48.2051	12.3315	12.2974	0.0371
RR5104809755	2020-03-31	78.3638	95.7631	54.6205	21.6007	23.7433	-2.1426
RR5212701604	2020-03-31	77.4232	53.4094	52.8717	23.7229	24.8096	-1.1377
RR5233933682	2020-04-06	75.7260	62.5826	64.6842	13.1414	11.0418	2.1016
RR5206814785	2020-03-31	75.4621	36.2391	53.7104	19.2030	21.7517	-2.5487
RR5206672664	2020-04-04	74.9966	54.0624	53.0721	20.9372	21.9275	-0.9903
RR5209814767	2020-03-31	74.9930	50.8545	42.9758	24.1391	32.0178	-7.8787
RR5102A16898	2020-03-31	74.4546	57.7235	59.8980	16.7311	21.5566	-4.8256
RR5210671719	2020-04-02	72.5830	26.7481	20.1756	45.8349	52.4075	-6.5726
RR5102753802	2020-04-11	71.8897	63.7886	38.3307	8.9976	13.5553	-4.9578
RR52072015	2020-04-04	71.8417	34.027	33.6142	17.7391	18.2273	-0.4885
RR5206A92867	2020-04-08	71.6732	61.1822	62.3165	10.4930	9.3587	1.1343
RR5209814775	2020-03-31	71.2946	49.5596	43.3726	21.7330	27.9221	-6.1870
RR5101A19704	2020-04-10	70.9969	58.9994	42.1382	12.2975	28.8387	-16.5611
RR5361AG7611	2020-04-01	70.9254	59.8280	56.0157	11.0974	14.9097	-3.8122

그림 10. 변동성 상위 20위 펀드별 예측 모형 성과 비교
Fig. 10. Comparison of Forecast Model Performance by Fund Top 20 Volatility

시점이었다. 오차 X는 GARCH(1,1)-LSTM 결합 모델의 예측 오차이고, 오차 Y는 LSTM 단일 모델의 예측 오차를 나타낸다. 오차 X-오차 Y는 GARCH(1,1)-LSTM 결합 모델과 LSTM 단일 모델간의 예측치의 오차를 비교한 값으로, 실제 표준편차에 대비한 예측치 오차를 나타낸다. 이 값이 작을수록 GARCH(1,1)-LSTM 결합 모델의 예측 오차가 작으며, 값이 0보다 작으면 GARCH(1,1)-LSTM 결합 모델의 예측치가 더 정확함을 의미한다. 그림 10을 통해 GARCH(1,1)-LSTM 결합 모델이 LSTM 단일 모델보다 변동성 예측에서 대체로 더 우수한 성능을 보임을 확인할 수 있다. 그림 9와 그림10에서 나타난 결과로 볼 때, GARCH(1,1)-LSTM 결합 모델이 더 우수한 성능을 보이는 이유는 비모수적 모형인 LSTM과 GARCH(1,1)과 같은 통계적 모형을 결합하는 방법이 변동성 예측에 있어서 향상된 성능을 보여준다는 것으로 생각할 수 있다. 이러한 이유는 3장에서 서술한 바와 같이 시장에서 관찰되는 데이터를 토대로 패턴학습을 하는 비모수적 모형인 LSTM 단일 모델에 금융시계열 자료에 존재하는 특성을 반영한 변동성 모형을 결합하는 것이 변동성에 대한 예측 성능을 향상시킬 수 있기 때문이다. 다만 이 모델은 결합 형태의 복잡성으로 모델의 이해와 관리가 어려울 수 있고, 계산 비용이 높아 빠른 응답 시간이 필요한 상황에서는 시간이 소모될 수 있다.

표 3은 표 2에서 가장 높은 예측 정확도를 보인 GARCH(1,1)-LSTM 결합 모형에 펀드 유형별로 표준편차를 입력 변수로 활용하여 분석한 결과이다. 표준편차 칼럼은 각 유형의 변동성을 나타내며, 변동성이 높은 주식 유형들의 RMSE가 크게 나타났다. 반면 변동성이 낮은 MMF형은 가장 낮은 RMSE를 나타냈다. 이는 표준편차와 성과지표 간에 양의 상관관계가 존재하며, 변

표 3. 유형별 GARCH(1,1)-LSTM 예측 성능 비교
Table 3. Comparison of GARCH(1,1)-LSTM prediction performance by type

유형	표준편차	MSE	RMSE
해외주식형	17.8554	179.5264	13.3987
국내주식형	21.2587	114.9894	10.7233
국내ETF	11.0535	64.5713	8.0356
해외혼합형	9.5532	58.6622	7.6591
해외ETF	13.0627	51.4638	7.1738
국내혼합형	7.4936	26.5984	5.1573
해외채권형	6.1727	15.6496	3.9560
국내채권형	1.1609	2.1218	1.4566
MMF	0.0117	0.0478	0.2187

동성이 큰 유형일수록 모델의 예측 성능이 상대적으로 저하되는 경향을 보여준다. 펀드는 그 유형에 따라 변동성 수준이 다르게 나타날 수 있다. 주식형 펀드는 주식 시장의 변동성에 직접 노출되어 있기 때문에 변동성이 크지만, 채권형 펀드는 안정적인 수익을 추구하기 때문에 변동성이 상대적으로 낮다. 주식 시장은 투자자들의 과대광고, 심리, 정치적 사건, 회사 정책과 같은 여러 경제적 요인들로 인해 큰 변동성을 보이는데, 순환 신경망(Recurrent neural network, RNN)을 특징 추출기로 사용하는 확률 기반 모델들은 장기 시퀀스를 예측할 때 큰 변동성을 갖는 구간을 예측하는데 어려움을 겪을 수 있다[12]. 이는 LSTM을 특징 추출기로 사용할 때, 신경망이 cell state에 저장된 모든 장기 시점들에 대한 정보를 출력 차원에 전부 담아낼 수 없기 때문이다[15]. 이러한 이유로 변동성이 높은 유형에서 GRACH-LSTM 결합 모델의 성능이 저하될 수 있는 현상이 나타날 수 있다.

5.2 펀드 위험등급 예측 결과

1단계 변동성 예측 모형을 통해 예측된 표준편차와 Pearson 상관계수를 통해 상관성을 확인한 샤프지수, 트레이닝에러, 정보비율, 97.5% VaR 총 5개의 변수를 입력으로 사용하여 1등급에서 6등급 사이의 펀드 위험등급을 예측했다. 이를 위해 사이킷런의 그리드서치(GridSearchCV)를 활용하여 SVM 모델의 하이퍼파라미터인 gamma와 C를 튜닝했으며, 각각의 커널별 모델을 평가했다. 결과적으로 RBF 커널을 사용한 다변량 SVM 모델이 79.28%의 가장 높은 분류율을 보였다. RBF 커널은 많은 특성을 생성하지 않고도 고차원 분류 문제를 다룰 수 있는 커널이며, gamma와 c 두 변수를 활용해 입력 공간을 무한대의 특정 공간으로 변환시킬

표 4. SVM 커널별 Accuracy
Table 4. Accuracy by SVM kernel

Kernel	RBF	Sigmoid	Linear	Poly
Accuracy	79.28%	61.47%	66.13%	66.15%

수 있어 다양한 분류에 강점을 가진다. 이러한 이유로 RBF 커널이 가장 우수한 성능을 보인 것으로 해석된다.

VI. 결 론

펀드 위험등급은 펀드의 위험도를 직관적으로 나타내는 중요한 지표이다. 따라서 판매사는 투자자의 성향에 맞는 위험등급의 펀드를 권유하고, 판매 이후에도 주기적으로 위험등급을 검증해야 한다. 이를 위해 본 연구에서는 실시간으로 펀드의 위험등급을 예측하고 검증할 수 있는 머신러닝 기반의 2단계 모델을 제안했다.

1단계 변동성 예측모형에서는 입력변수에 따라 모형의 성능이 달라졌다. 전체 펀드를 대상으로 한 경우 GARCH(1,1)-LSTM 결합 모형이 가장 우수한 예측력을 보였다. 저변동성 펀드인 경우에는 LSTM 모형이 예측력이 더 좋았으며, 고변동성 펀드인 경우 GARCH(1,1)-LSTM 결합모형이 우수한 성능을 보였다. 또한, 펀드 유형 내에서는 변동성이 높은 유형일수록 GARCH(1,1)-LSTM 결합모형의 예측력이 다소 저하되는 것을 확인했다. 2단계 펀드 위험등급 예측 모델에서는 SVM 모델 중 RBF 커널을 사용한 모델이 79.28%로 가장 높은 예측력을 보였다.

본 연구는 변동성 예측 단계에서는 수익률 이외의 외생변수는 고려하지 않았으며, 위험등급 예측 단계에서는 상관관계를 고려해 표준편차 이외의 기타 위험지표를 입력변수로 활용했다. 더 나은 예측 결과를 얻기 위해서는 변동성 예측 단계에서도 예측에 도움이 될 수 있는 추가적인 변수를 고려하는 것이 필요하다. 이를 통해 보다 신뢰도 높은 위험등급 산출이 가능할 것으로 기대한다.

References

[1] K. J. Kim, "Analysis of the predicted volatility of imported meat price based on GARCH and LSTM," Ph.D. dissertation, Graduate School, Konkuk University, 2020.
[2] Y. S. Ra, H. S. Choi, and S. W. Kim, "VKOSPI forecasting and option trading

application using SVM," *J. Intell. Inf. Syst.*, 2016.

(<https://doi.org/10.13088/jiis.2016.22.4.177>)

[3] S. B. Lee, "Volatility prediction of financial time series data using hybrid GARCH-LSTM algorithm," Ph.D. dissertation, Graduate School, Hankuk University of Foreign Studies, 2022.
[4] Y. S. Choi and H. J. Lee, "Comparison of volatility prediction for KOSPI200 index depending on volatility measurement methods," *Korean Statistical Soc.*, 2010.
[5] T. H. Roh, "Forecasting the volatility of stock price index," *Expert Syst. with Appl.*, vol. 33, no. 4, pp. 916-922, 2007.
(<https://doi.org/10.1016/j.eswa.2006.08.001>)
[6] H. S. Jang, "Assessment to prediction of occurrence of fecal coliform using machine learning," Ph.D. dissertation, Graduate School, Kunsan National University, 2018.
[7] Y. H. Kim and H. J. Kim, and B. J. Kim, "Prediction of replacement period of shield TBM disc cutter using SVM," *J. Korean Tunnelling and Underground Space Assoc.*, vol. 21, no. 5, pp. 641-656, 2019.
(<https://doi.org/10.9711/KTAJ.2019.21.5.641>)
[8] H. H. Yoo, et al., "Predictive analysis of fire risk factors in Gyeonggi-do using machine learning," *J. Korean Soc. Surveying, Geodesy, Photogrammetry and Cartography*, vol. 39, no. 6, pp. 351-361, 2021.
(<https://doi.org/10.7848/ksgpc.2021.39.6.351>)
[9] Financial Supervisory Service Press Release, "Guidelines for Determining Risk Ratings of Investment Products," 2023.
[10] T. Bollerslev, "Generalized autoregressive conditional heteroscedasticity," *J. Econometrics*, vol. 31, pp. 307-327, 1986.
([https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1))
[11] C. J. C. Burges, "A tutorial on support vector machines for pattern recognition," *Data Mining and Knowledge Discovery*, vol. 2, no. 2, pp. 121-167, 1998, <https://www.di.ens.fr/~mallat/papiers/svmtutorial.pdf>
[12] C. Brooks, "Predicting stock index volatility:

Can market volume help,” *J. Corecasting*, vol. 17, no. 1, pp. 59-80, 1998.

([https://doi.org/10.1002/\(SICI\)1099-131X\(199801\)17:1<59::AID-FOR676>3.0.CO;2-H](https://doi.org/10.1002/(SICI)1099-131X(199801)17:1<59::AID-FOR676>3.0.CO;2-H))

- [13] R. F. Engle, “Autoregressive conditional heteroscedasticity with estimator of the variance of United Kingdom inflation,” *Econometrica*, vol. 50, no. 4, pp. 987-1008, 1982.

(<https://doi.org/10.2307/1912773>)

- [14] F. Gonzalez Maranda and N. Burgess, “Modeling market volatilities: The neural network perspective,” *The Eur. J. Finance*, vol. 3, no. 2, pp. 137-157, 1997.

(<https://doi.org/10.1080/135184797337499>)

- [15] D. Ormoneit and R. Neuneier, “Experiments in predicting the German stock index DAX with density estimating neural networks,” in *Proc. IEEE/IAFE 1996 Conf. Computational Intell. Financial Eng.*, pp. 66-71, 1996.

(<https://doi.org/10.1109/cifer.1996.501825>)

- [16] E. Hajizadeh, A. Seifi, M. F. Zarandi, & I. B. Turksen, “A hybrid modeling approach for forecasting the volatility of S&P500 index return,” *Expert Syst. Appl.*, vol. 39, no. 1, pp. 431-436, 2012.

(<https://doi.org/10.1016/j.eswa.2011.07.033>)

김 아 람 (A-Ram Kim)



2015년 8월 : 동국대학교 식품
자원경제학과 경제학사 취득

2023년 8월 : 숭실대학교 IT융
합학과 공학석사 취득

<관심분야> 금융공학, 투자공
학, 머신러닝

박 민 호 (Min-Ho Park)



2000년 2월 : 고려대학교 전자
공학과 학사 졸업

2002년 2월 : 고려대학교 전자
공학과 석사 졸업

2010년 2월 : 서울대학교 전기
컴퓨터공학과 박사 졸업

2013년 3월~현재 : 숭실대학교

전자정보공학부 교수

<관심분야> 전자공학, 컴퓨터공학, 통신공학