Journal of the Korea Convergence Society
Vol. 9. No. 6, pp. 39-44, 2018

ISSN 2233-4890
https://doi.org/10.15207/JKCS.2018.9.6.039

심층 신경회로망 모델을 이용한 일별 주가 예측

황희수
한라대학교 전기전자공학과

Daily Stock Price Forecasting Using Deep Neural Network Model

Heesoo Hwang
Department of Electrical and Electronic Engineering, Halla University

요 약 심층 신경회로망은 적합한 수학적 모델에 대한 어떠한 가정 없이 데이터로부터 유용한 정보를 추출해서 예측에 필요한 입출력 관계를 정의할 수 있기 때문에 최근 시계열 예측 분야에서 주목 받고 있다. 본 논문에서는 주가의 일별 종가를 예측하기 위한 심층 신경회로망 모델을 제안한다. 제안된 심층 신경회로망은 예측 정밀도를 높이기 위해 단일 층의 오토인코더와 4층의 신경회로망이 결합된 구조를 갖는다. 오토인코더 층은 주가 예측에 필요한 최적의 입력 특징을 추출하고 4층의 신경회로망은 추출된 특징을 사용해 주가 예측에 필요한 동특성을 반영하여 주가를 출력한다. 제안된 심층 신경회로망의 학습은 층별로 단계적으로 이뤄지며 최종 단계에서 전체 심층 신경회로망에 대해 한 번 더 학습이 실행된다. 본 논문에 제안된 방법으로 KOrea composite Stock Price Index (KOSPI) 일별 종가를 예측하는 심층 신경회로망을 구현하고 기존 방법과 예측 정확도를 비교, 평가한다.

주제어 : 융합, 주가 예측, 주가 모델링, 심층 신경망, 심층 학습, 시계열 예측

Abstract The application of deep neural networks to finance has received a great deal of attention from researchers because no assumption about a suitable mathematical model has to be made prior to forecasting and they are capable of extracting useful information from large sets of data, which is required to describe nonlinear input-output relations of financial time series. The paper presents a new deep neural network model where single layered autoencoder and 4 layered neural network are serially coupled for stock price forecasting. The autoencoder extracts deep features, which are fed into multi-layer neural networks to predict the next day's stock closing prices. The proposed deep neural network is progressively learned layer by layer ahead of the final learning of the total network. The proposed model to predict daily close prices of KOrea composite Stock Price Index (KOSPI) is built, and its performance is demonstrated.

Key Words : Convergence, Stock Price Forecasting, Stock Price Modeling, Deep Neural Network, Deep Learning, Time Series Forecasting

1. 서론

주식시장에서 종합주가지수나 종목별 지수를 예측하는 것은 잡음과 변동성으로 인해 매우 어려운 일로 인식되고 있지만 그럼에도 주가 예측 모델을 만들기 위한 다양한 방법들이 시도되어 왔다[1-6,9]. 주가의 움직임을 정확하게 예측하기 위한 방법은 여전히 해결되지 않은 문제로 인공신경망[4], SVM (Support Vector Machine)[5,6]과 같은 기계학습 방법이 금융 시계열을 예측하는데 널리 사용되었고 예측의 정확도를 높여 왔다.

*Corresponding Author : Heesoo Hwang (hshwang@halla.ac.kr)
Received April 4, 2018 Revised April 26, 2018
Accepted June 20, 2018 Published June 28, 2018

최근에는 시계열에 딥러닝 기반의 심층 신경망을 적용하려는 연구가 활발히 이뤄지고 있다. 기존의 기계학습 방법에 비해 이 연구들은 연관성이 있는 특징 정보를 추출해서 복잡한 실세계 데이터를 효과적으로 반영하는 모델링을 통해 이전 보다 성능이 개선된 결과를 제시하고 있다[7,8]. 금융 시계열 데이터의 복잡성을 고려하면 금융 시계열 예측에 딥러닝을 도입하려는 시도는 더 다양화될 것이며 상대적으로 탐색 여지가 많은 분야로 인식되고 있다[9]. 금융 분야에 적용된 딥러닝 연구로 Deep Belief Network (DBN)을 사용한 환율 예측[10], 금융 시장 예측[11,12], Recurrent Neural Network (RNN)을 사용한 구글 주가 예측[13] 및 Convolutional Neural Network (CNN)으로 주가에 미치는 이벤트 예측[14]이 있다.

본 연구는 KOSPI 일별 종가의 예측 정확도를 개선하기 위한 새로운 심층 신경회로망 모델을 제안한다. 제안된 모델은 단일 층의 오토인코더(autoencoder)와 4층의 신경회로망이 결합된 구조를 갖는다. 오토인코더는 주가 예측에 필요한 최적의 특징을 추출하고 4층의 신경회로망은 이를 입력으로 사용해 주가 예측에 필요한 동특성을 반영해 주가를 출력한다. 제안된 방법의 타당성 분석을 위해 KOSPI의 일별 종가를 예측하기 위한 심층 신경회로망 모델을 구현하고 기존 연구결과와 예측 정확도를 비교, 평가 한다. 2장은 제안된 심층 신경회로망의 구조를, 3장은 심층 신경회로망의 학습을, 4장은 주가지수 예측 시뮬레이션 및 성능 평가를, 5장은 결론을 기술한다.

2. 심층 신경망 모델

2.1 심층 신경회로망 구조

1일 앞선 주가지수의 예측을 위해 본 논문에서 제안한 심층 신경회로망의 구조가 Fig. 1에 보인다. 이 심층 신경회로망은 단일 층의 오토인코더와 4층의 신경회로망이 결합된 구조를 가지며 데이터 흐름은 다음과 같은 단계로 진행된다.

[단계 1] 전처리로 신경회로망 학습에 사용할 입·출력 데이터를 [-1, 1] 범위로 정규화 한다.

[단계 2] 정규화 된 입력 데이터는 주가 예측에 필요한 특징(주요 성분)을 추출하는 단일 층의 오토인코더에 입력된다.

[단계3] 추출된 특징(오토인코더의 출력)은 은닉층(hidden layer)을 거쳐 중간 출력층(intermediate output layer)에서 주가지수의 고가, 저가 및 종가를 출력한다.

[단계4] 출력된 고가, 저가 및 종가는 은닉층을 거쳐 출력층에서 종가를 출력한다.

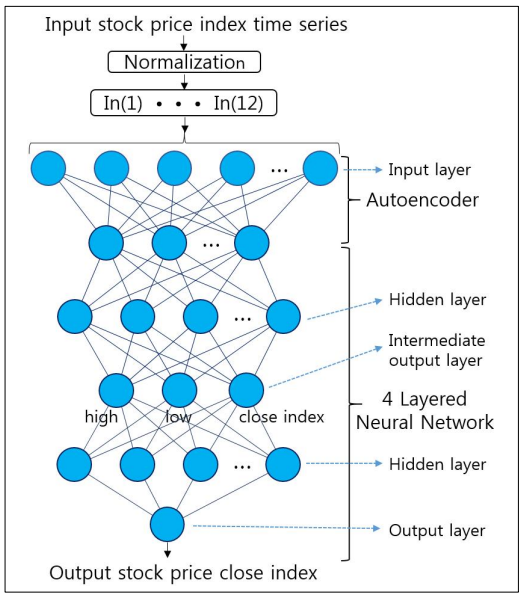

Fig. 1. Architecture of the proposed deep neural network

2.2 입력 변수

주식 시장은 매우 복잡하고 변동성이 크기 때문에 다양한 기계학습을 적용한 예측 모델이 개발되고 있는데, 이들 모델은 재무 지표, 경제 요인들이나 과거의 주가 움직임 데이터를 사용하였다. 주가는 경제 및 정치 등의 많은 요인에 의해 영향을 받는데, 이들 요인 모두를 예측 모델에 반영하는 것은 불가능하다. 주가 예측에 대한 많은 연구가 있지만 어떤 방법과 변수를 사용하는 것이 객관적으로 더 좋다는 연구 결과는 없다. 이는 연구마다 사용한 방법, 변수 및 데이터의 차이로 인해 객관적인 비교가 어렵기 때문일 것이다.

본 논문에서는 주가의 움직임 자체에만 주목한다. 즉, 과거 주가의 움직임과 유사한 상황이 되면 주가는 동일한 방식으로 움직인다고 가정한다. 이는 캔들스틱(candlestick) 차트는 시간과 분야에 독립적이어서 과거의 주가 변동 패턴이 그 때와 유사한 상황이 되면 현재나 미래에 반복될 수 있다는 연구[15,16]를 적용한 것이다.

캔들스틱은 단위 시간(일, 주 또는 월) 동안 주가의 시가, 종가, 최고가와 최저가에 기초해서 만들어진다. 캔들스틱 패턴은 단일, 이중 또는 삼중의 캔들스틱에 의해 형성된다. 연구결과에 의하면 의미 있는 캔들스틱 패턴의 패턴의 99.8%는 단일 및 이중 캔들스틱이기[15] 때문에 본 논문에서는 Table 1에 보인 예측 1일 전과 2일 전의 12개의 변수를 예측 모델의 입력으로 사용한다.

Table 1. Input variables of the proposed deep neural network model

KOSPI	Input variables	
	2 days ahead	1 day ahead
High price	In(1)	In(7)
Low price	In(2)	In(8)
Close price	In(3)	In(9)
5 day moving average	In(4)	In(10)
10 day moving average	In(5)	In(11)
20 day moving average	In(6)	In(12)

3. 심층 신경회로망 모델의 학습

심층 신경회로망 모델의 학습은 먼저 층별로 진행하고 층별로 학습된 전체 신경회로망을 한 번 더 학습한다. 이를 위해 다음과 같은 단계를 거친다.

[단계1] Fig. 2(a)에 보인 것과 같이 단층의 오토인코더를 학습시킨다. 사용한 입력변수는 Table 1과 같고 정규화된 입력(In) 데이터를 사용하며 출력(In') 데이터는 입력과 동일하다. 즉 오토인코더는 입력과 동일한 데이터를 출력하도록 비교사 방식으로 학습된다. 학습된 오토인코더는 입력 데이터를 복제할 수 있는 주요 특징(성분)만을 추출할 수 있다.

[단계2] 단계1의 오토인코더 출력을 입력으로 사용하고 1개의 은닉층을 가지며 KOSPI 고가, 저가 및 종가를 출력으로 하는 Fig. 2(b)와 같은 다층 신경회로망을 교사 방식으로 학습한다.

[단계3] 단계2에서 학습된 다층 신경회로망의 출력(KOSPI 고가, 저가 및 종가)을 입력으로 사용하고 1개의 은닉층을 가지며 KOSPI 종가를 출력으로 하는 Fig. 2(c)와 같은 다층 신경회로망을 교사 방식으로 학습한다.

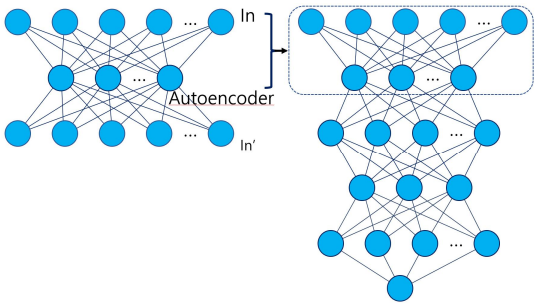

(a) Learning autoencoder

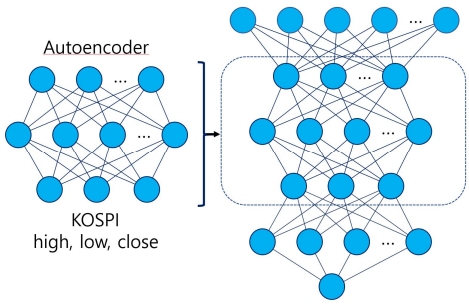

(b) Learning the 1st multilayer neural network

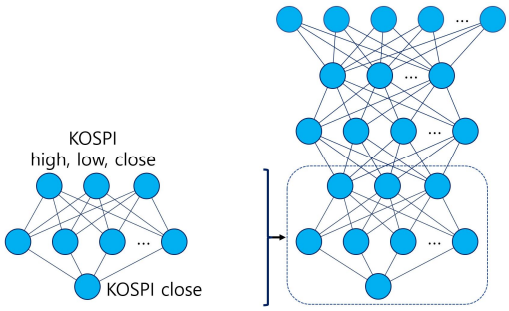

(c) Learning the 2nd multilayer neural network

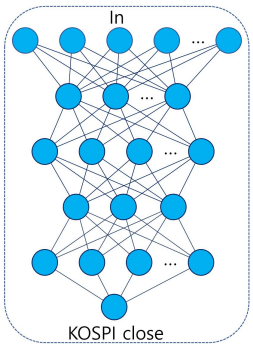

(d) Learning deep neural network

Fig. 2. Learning procedure of the proposed deep neural network

[단계4] 단계1에서 단계3까지 학습된 신경회로망으로 Fig. 2(d)의 심층 신경회로망을 구성하고 정규화된 입력(In)과 출력(KOSPI 종가) 데이터로 학습한다.

심층 신경회로망의 학습에는 scaled conjugate gradient descent 역전파 방식이[17] 사용되며 오토인코더의 학습을 위한 비용함수는 학습 오차이외에 벌칙함수로 L2 regularization 및 sparsity regularization 항이 추가된다[18]. 심층 신경회로망 뉴런의 전달함수는 logistic sigmoid 함수가 사용된다.

4. 주가지수 예측

심층 신경회로망 모델은 입력으로 Table 1에 보인 1일 및 2일 전의 주가지수 데이터를 사용하여 다음 날의 주가지수 종가를 예측한다. 주가지수 예측을 위한 심층 신경회로망 모델의 학습에는 2006년 12월부터 2008년 2월까지의 일별 KOSPI 데이터가 사용되며, 학습된 모델의 평가에는 2008년 3월부터 6월까지의 데이터가 사용된다. 심층 신경회로망 모델에서 오토인코더의 학습 횟수는 200이며 나머지 층별 다층신경회로망 및 통합 심층 신경회로망의 최대 학습 횟수는 100이다.

본 논문에서 제안한 심층 신경회로망으로 구현된 주가지수 예측 모델(DNN1과 DNN2)의 매개변수는 Table 2에 있다. 이 매개변수는 반복 학습을 통해 얻은 최적화된 값으로 오토인코더에 사용된 뉴런의 수는 두 경우 모두 4 이다. 단층 오토인코더의 주요 성분(입력 변수) 추출 성능을 검증하기 위해 12개 입력 데이터에 대해 주성분 분석을 수행한다.

Table 2. Deep neural network parameters for the KOSPI prediction model

Model	n_a	n_{h1}	n_{h2}
DNN1	4	31	26
DNN2	4	34	8

n_a: The number of neurons in autoencoder layer
n_{h1}: The number of neurons in the 1st hidden layer
n_{h2}: The number of neurons in the 2nd hidden layer
DNN: Deep Neural Network

Table 3. The variance percentage of each principal component(PA)

PA	P(%)	PA	P(%)
1	72.8230	7	0.7265
2	14.4718	8	0.6234
3	6.1337	9	0.5755
4	2.6476	10	0.1897
5	0.8715	11	0.0727
6	0.8316	12	0.0331

Table 3은 입력 데이터별 주성분의 상대적인 분산 비율(P)을 퍼센트로 표시한 것으로 주성분(PA) 4개가 전체의 96.08%를 담당한다. 주성분 수 4는 오토인코더 출력 노드 수와 동일하므로 오토인코더가 주요 입력 특징을 추출할 수 있음을 볼 수 있다. Table 4는 본 논문의 예측 모델(DNN1, DNN2)과 퍼지 모델 및 얕은 신경회로망 모델의 예측 오차인 Mean Absolute Percent Error (MAPE)를 비교한 것이다. DNN1과 DNN2 모델의 평균 정확도가 퍼지 모델 대비 학습에서 36.7%, 평가에서 36.2% 개선되었고 얕은 신경회로망 모델 대비 학습에서 25.0%, 평가에서 40.5% 개선되었다.

Table 4. KOSPI prediction errors

Model	MAPE	
	Learning	Test
Fuzzy Model[19]	1.0390	1.0630
Neural Network[19]	0.8770	1.1400
DNN1	0.6412	0.6896
DNN2	0.6748	0.6672

Fig. 3과 Fig. 4는 각각 학습 및 평가에 사용한 KOSPI 실 데이터와 예측 데이터를 비교한 그림으로 실선은 실 데이터이고 •은 예측된 데이터이다. 추세가 바뀌는 날에서 상대적으로 오차가 큼을 볼 수 있다.

Fig. 5와 Fig. 6은 각각 학습과 평가에서 예측된 KOSPI 종가(•으로 표시)와 KOSPI 실 데이터의 고가 및 저가(실선으로 표시)를 비교한 그림이다. 예측된 종가가 실 데이터의 고가와 저가 범위 내에 있음을 볼 수 있다.

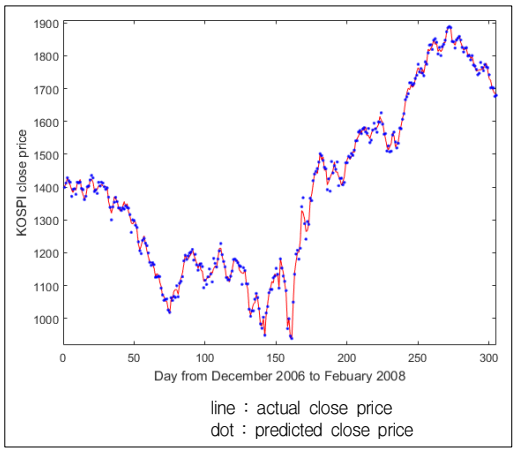

Fig. 3. Output comparison of KOSPI daily close prices in the learning

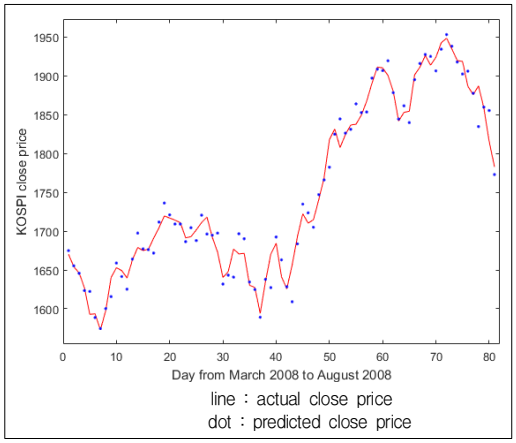

Fig. 4. Output comparison of KOSPI daily close prices in the test

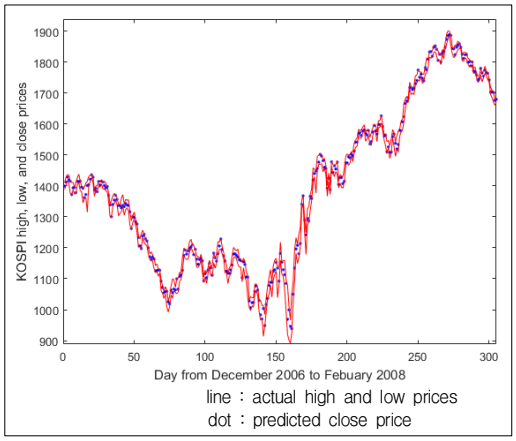

Fig. 5. Predicted daily close price in the learning

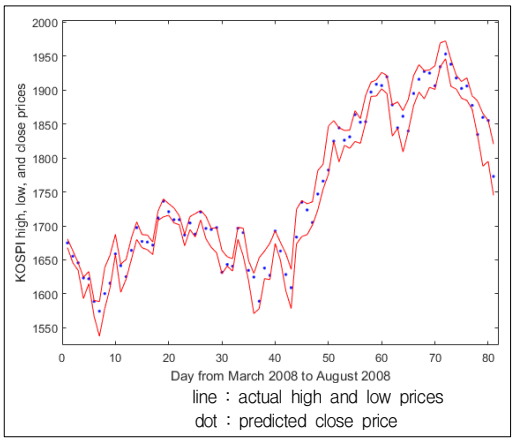

Fig. 6. Predicted daily close price in the test

5. 결론

본 논문에서는 주가지수 예측을 위한 심층 신경회로망 모델을 제안하였다. 예측 정확도를 높이기 위해 심층 신경회로망은 입력 변수를 추출할 수 있는 오토인코더와 주가지수의 변동성을 추종하는 4층의 신경회로망으로 구성되었다. 층별 선행 학습을 통해 심층 신경회로망의 학습 효율을 높이기 4층 신경회로망에 중간 출력층을 도입하였다. 시뮬레이션 결과 기존의 퍼지모델 및 얕은 신경회로망에 비해 예측 정확도가 최소 25% 이상 개선되어 제안된 방법의 우수함을 보였다. 향후 제안된 방법으로 예측된 지수를 토대로 KOSPI 주가지수 연계형 레버리지 및 인버스 펀드(Exchange Traded Funds)의 매매 전략에 대한 연구가 수행될 것이다.

REFERENCES

[1] S. H. Koh. (2016). A Converging Approach on Investment Strategies, Past Financial Information, and Investors' Behavioral Bias in the Korean Stock Market, *Journal of the Korea Convergence Society*, 7(6), 205-212.

[2] H. H. Kim, K. D. Sung, J. W. Jeon & G. T. Yeo. (2016). Analysis of the Relationship Between Freight Index and Shipping Company's Stock Price Index, *Journal of digital Convergence*, 14(6), 157-165.

[3] S. H. Choi & J. I. Choi. (2017). Analysis of Stock Price Increase and Volatility of Logistics Related Companies,

Journal of digital Convergence, 15(2), 135-144.

[4] Z. H. G. Wang, Q. Liu & J. A. Yang. (2014). Feature Fusion Based Forecasting Model for Financial Time Series, *Plos One*, 9(6), 172-200.

[5] C. J. Lu, T. S. Lee & C. C. Chiu. (2009). Financial Time Series Forecasting Using Independent Component Analysis and Support Vector Regression, *Decision Support Systems*, 42(2), 115-125.

[6] W. Huang, Y. Nakamori & S. Y. Wang. (2005). Forecasting Stock Market Movement Direction with Support Vector Machine, *Computers & Operations Research*, 32(10), 2513-2522.

[7] G. E. Hinton & R. R. Salakhutdinov. (2006). Reducing The Dimensionality of Data with Neural Networks, *Science*, 313(5786), 504-507.

[8] Y. Bengio, A. Courville & P. Vincent. (2013). Representation Learning: A Review and New Perspectives, *IEEE Trans. on Pattern Analysis & Machine Intelligence*, 35(8), 1798-1828.

[9] R. C. Cavalcante, R. C. Brasileiro, V. L. F. Souza, J. P. Nobrega & A. L. I. Oliveira. (2016). *Computational Intelligence and Financial Markets: A Survey and Future Directions," Expert Systems with Applications*, 55, 194-211.

[10] F. Shen, J. Chao & J. Zhao. (2015). Forecasting Exchange Rate Using Deep Belief Networks and Conjugate Gradient Method, *Neurocomputing*, 167, Issue C, 243-253.

[11] T. Kuremoto & et. al. (2014). Time Series Forecasting Using A Deep Belief Network with Restricted Boltzmann Machines, *Neurocomputing*, 137(15), 47-56.

[12] Y. Bengio, P. Lamblin P, D. Popovici D & H. Larochelle. (2007). Greedy Layer-wise Training of Deep Networks, *Advances in neural information processing systems*, 19, 153.

[13] L. D. Persio & O. Honcha. (2017). Recurrent Neural Networks Approach to The Financial Forecast of Google Assets, *Int. J. of Mathetics and Computers in Simulation*, 11, 7-13.

[14] X. Ding X, Y. Zhang, T. Liu & J. Duan. (2015). Deep Learning for Event-driven Stock Prediction, *Proc. of the 24th Int. Joint Conf. on Artificial Intelligence*, 2327-2333.

[15] K. H. Lee & G. S. Jo. (1999). Expert System for Predicting Stock Market Timing Using A Candlestick Chart, *Expert System With Applications*, 16, 357-364.

[16] L. C. H. Leon, A. Liu & W. S. Chen. (2006). Pattern Discovery of Fuzzy Time Series for Financial Prediction, *IEEE Trans. Knowledge and Data Engineering*, 18(5), 613-625.

[17] M. F. Moller. (1993). A Scaled Conjugate Gradient Algorithm for Fast Supervised Learning, *Neural Networks*, 6, 525 - 533.

[18] B. A. Olshausen & D. J. Field. (1997). Sparse Coding with An Overcomplete Basis Set: A Strategy Employed by V1, *Vision Research*, 37, 3311 - 3325.

[19] H. S. Hwang & J. S Oh. (2009). Time Series Stock Prices Prediction Based on Fuzzy Model, *Journal of The Korean Institute of Intelligent Systems*, 19(5), 689-694.

황 희 수(Heesoo Hwang) [정회원]

- 1988년 2월 : 연세대학교 본대학원 전기과 (공학석사)
- 1993년 2월 : 연세대학교 본대학원 전기과 (공학박사)
- 1993년 4월 ~ 2001년 2월 : 한국고속철도기술개발사업단 선임 및 수석연구원
- 2001년 3월 ~ 현재 : 한라대학교 전기전자과 교수
- 관심분야 : 기계학습, 데이터 기반 모델링, 진단 및 예측
- E-Mail : hshwang@halla.ac.kr