

자기조직화지도를 통한 아파트 가격의 패턴 분석

이지영, 유재필*
키스채권평가 차장

Pattern Analysis of Apartment Price Using Self-Organization Map

Jiyoung Lee, Jae Pil Ryu*
Deputy Department Head, KIS Pricing

요약 최근 인공지능, 딥러닝, 빅데이터 등 4차 산업의 핵심 분야에 대한 관심이 커지면서 기존의 의사결정 문제를 전통적인 방법론의 한계점을 최소화하는 과학적 접근 방식이 대두되고 있다. 특히 이런 과학적인 기법들은 주로 금융 상품의 방향성을 예측하는데 사용되는데 본 연구에서는 사회적으로 관심이 높은 아파트 가격의 요인을 자기조직화지도를 통해 분석하고자 한다. 이를 위해 아파트 가격의 실질 가격을 추출하고 아파트 가격에 영향을 주는 총 16개의 입력 변수를 선정한다. 실험 기간은 1986년 1월부터 2021년 6월까지이며 아파트 가격의 상승 및 횡보 구간을 나눠 각 구간 별 변수들의 특징을 살펴본 결과, 상승 구간과 횡보 구간의 입력 변수의 통계적 성향이 뚜렷하게 구분되는 것을 알 수 있었다. 더불어 U1~U3 구간이 N1~N3 구간에 비해서 변수들의 표준편차가 상대적으로 크게 나왔다. 본 연구는 중장기적으로 상승과 하락이라는 큰 주기를 갖고 있는 부동산에 대해서 현재 시점의 현황을 정량적으로 분석한 것에 의미가 있으며 향후 이미지 학습을 통해 미래 방향성을 예측하는 연구에 도움이 되기를 기대한다.

주제어 : 자기조직화지도, 클러스터링, 데이터마이닝, 아파트 가격, 부동산

Abstract With increasing interest in key areas of the 4th industrial revolution such as artificial intelligence, deep learning and big data, scientific approaches have developed in order to overcome the limitations of traditional decision-making methodologies. These scientific techniques are mainly used to predict the direction of financial products. In this study, the factors of apartment prices, which are of high social interest, were analyzed through SOM. For this analysis, we extracted the real prices of the apartments and selected a total of 16 input variables that would affect these prices. The data period was set from 1986 to 2021. As a result of examining the characteristics of the variables during the rising and faltering periods of the apartment prices, it was found that the statistical tendencies of the input variables of the rising and the faltering periods were clearly distinguishable. I hope this study will help us analyze the status of the real estate market and study future predictions through image learning.

Key Words : Self-Organization Map, Clustering, Data Mining, Apartment prices, Property

*Corresponding Author : Jae Pil Ryu(jaepilryu@kispricing.com)

Received July 29, 2021

Accepted November 20, 2021

Revised August 18, 2021

Published November 28, 2021

1. 연구배경

부동산 가격은 비 유동성 자산이지만 한정적 유형 자산으로 다양한 시장 참여자들이 존재하는 분야이다. 특히 부동산 투자자 및 정책을 담당하는 정부 기관 그리고 거주를 위한 소유자 등은 서로 다른 이해관계를 갖고 시장에 참여한다. 이런 시장 참여자들에게 공통적으로 존재하는 의사결정 문제는 부동산 가격의 현황 파악 및 방향성을 예측하는 것이라 할 수 있는데 이는 쉽게 해결할 수 없는 난제이기 때문에 객관적이고 합리적인 판단 기준이 무엇보다 중요하다. 더군다나 주거는 인간의 기본적 욕구를 해결하기 위한 기초적인 요소 중 하나기 때문에 주거환경 보장에 관한 정부의 정책은 무엇보다 중요하다[1].

최근 4차 산업이 발전하면서 딥러닝(deep learning)과 인공지능(artificial intelligence)의 기술을 적용해서 자산 가치의 방향성을 예측하는 사례가 늘어나고 있다. 즉 정량적이고 과학적인 방법론을 통해서 보다 더 정확하고 객관적으로 의사결정 문제를 해결할 수 있다. 이는 전통적으로 예측을 위해 사용되는 회귀분석, VAR(vector autoregressive model) 등과는 접근 방식이 다른데 이러한 전통적 방식은 다중공선성(multicollinearity) 및 불특정 변수에 대한 잡음(noise)으로 인해 예측 성능에 한계점을 내포하고 있다[2]. 최근 연구 분야에서도 기계학습(machine learning)과 빅데이터(big data) 등을 활용해 다양한 시계열에 대한 예측 기법을 활발하게 진행하고 있다. 주로 투자 자산에 대한 예측 연구는 데이터의 양과 수집에 용이한 금융 자산의 시계열을 예측하는 연구가 활발하게 진행되고 있는데 허준영은 기업의 재무 자료를 SVM(support vector machine)을 통해 주가를 예측하고 회사의 내재 가치와 재무 자료의 인과관계를 분석하였다[3]. 유재필은 검색 키워드의 빅데이터를 기계학습 모형에 적용해 ETF(exchange traded fund)의 가격 방향성을 예측하였는데 이는 시장 수익률에 비해 우수한 성과를 보이는 것을 알 수 있었다[4]. 홍성혁은 주가 예측을 위해 LSTM(Long Short Term Memory) 모형의 단방향 예측 오류를 최소화하는 BLSTM 모형을 제안하고 거시적 변수와 개별 기업의 미시적 변수를 분석하였다[5]. 황희수는 하이브리드 머신러닝(machine learning)을 이용해 코스피 지수의 방향성을 예측하였는데 상승과 하락 각각 60% 이상의 예측력을 보이고 있으며 개별 모델에 비해서 모두 약 5~10% 이상의 개선을 보였다[6].

부동산 관련 시계열 예측과 관련된 논문을 살펴보면 배성완은 기계학습의 모형들을 주택 가격 추정 문제에 적용하여 비교 분석하였는데 다중회귀분석에 비해서 SVM, RF(random forest), GBRT(gradient boosting regression tree) 그리고 DNN(deep neural networks) 모형의 예측 성능이 우수하였고 그 중에서 GBRT가 가장 예측력이 높았다[7]. 김선아는 GARCH(generalized autoregressive conditional heteroskedasticity) 모형과 딥러닝을 이용해 주택 경매시장의 가격을 예측한 결과 딥러닝의 경우 MSE와 RMSE가 각각 약 38.0과 6.1로 나타났고 GARCH 모형의 경우 각각 약 42.8과 6.5로 딥러닝의 예측력이 더 우수한 것을 알 수 있었다[8]. 이지영은 주택 가격에 영향을 주는 총 12개의 시장 변수를 인공신경망(artificial neural network)의 입력 변수(input data)로 설정하여 모형을 설계하고 예측 실험을 하였다. 그 결과 거시적 변수의 경우와 미시적 변수 모두 약 90% 정도의 예측력을 보였다[9].

그 밖에 해외 논문을 보면 Cao et al.은 선형 방정식과 인공신경망을 이용해서 중국의 주가 시계열 예측에 대해 연구하였고 기업의 시가총액 및 장부가액 대비 시가총액 비율을 투입변수로 정의하였다. 그 결과 다변량의 인공신경망 모형이 단변량 인공신경망 모형에 비해서 예측 성능이 우수했다[10]. Jirong et al.은 부동산 가격의 예측을 위해 기계학습 모형중 하나인 SVM에 유전자 알고리즘(genetic algorithm)을 적용하여 G-SVM을 제안한 결과 기존의 SVM에 비해서 월등하게 예측성고가 우수했다[11]. 이처럼 과학적인 기법들을 자산 시계열의 미래 방향성 예측에 적용되어지고 있는데 비 유동적인 부동산 가격에 대한 정량적 분석에 관한 연구는 관심도에 비해 저조한 편이다. 따라서 본 연구에서는 클러스터링(clustering) 기법을 이용해 한국의 아파트 가격 지수를 경기 순환 개념 하에 주기 별 구분을 하고 각 구간 별로 요인들이 갖는 통계적 성향을 정량적으로 분석하고자 한다. 더불어 통계적 특징을 쉽게 파악하기 위해 변수들의 데이터를 방차형 차트로 표현함으로써 이에 대한 설명력을 높이는 방안을 제안한다.

본 논문의 구성은 다음과 같다. 2장에서는 본 연구의 연구모형에 대해 기술하고 3장에서는 클러스터링을 위한 입력 변수에 대해서 설명한다. 또한 4장에서는 실험 계획 및 결과 분석을 그리고 끝으로 5장에서는 결론을 제시한다.

2. 연구모형

본 장에서는 실험 대상인 한국의 아파트 가격 지수를 선정하는 과정을 설명하고 실험 모형인 클러스터링 기법에 대해서 기술한다.

2.1 실질 부동산 가격 지수

통계청 및 금융권 기업에서는 최근 거래되는 아파트 거래 자료를 바탕으로 지수화한 값을 공시하고 있다. 하지만 해당 값은 상대적이지 않고 절대적인 거래 가격을 제시하는 지표이기 때문에 객관적인 실험 데이터로 활용하는 것은 한계가 있으며 해당 자료만으로는 오판을 초래할 수 있다. 예컨대 부동산 가격의 경우에는 다른 유형 자산에 비해 물가 상승률 대비 저조한 상승 또는 하락을 나타내고 있을 수 있는데 부동산의 경우에는 명목금액이 상대적으로 크기 때문에 객관적인 실질 가치를 이해하는데 난해한 부분이 있다. 따라서 본 연구에서는 통계청에서 공시되는 아파트 가격 지수에서 소비자 물가 수준 만큼에 대한 부분을 제거하고 새로운 실질 부동산 가격 지수를 생성한다.

Fig. 1은 1986년 1월부터 2021년 6월까지 월별 소비자 물가와 실질 아파트 가격 지수를 나타낸 그림인데 이해도를 높이기 위해 초기 값을 100으로 환산해 보여 준다. 본 그림을 보면 1986년 1월을 기준으로 물가 상승률 대비 아파트 가격 지수는 약 30% 덜 오른 것을 알 수 있는데 이는 전국 아파트에 대한 대표 값을 의미하기 때문에 물가 상승보다는 다소 덜 오른 것으로 사료된다.




Fig. 1. Real Apartment Price Index

실질 아파트 가격 지수는 식(1)과 같이 월별 물가 지수의 움직이는 수익률을 아파트 가격 지수의 월별 수익률에 차감하여 산출한다. 식(1)의 $d(CP)$ 는 물가 지수의 월별 수익률, $d(AP)$ 는 아파트 가격 지수의 월별 수익률

그리고 AP_{t-1} 는 전월 아파트 가격 지수를 의미한다.

$$(d(CP) - d(AP)) * AP_{t-1} + AP_{t-1} \quad (1)$$

아파트의 실질 가격을 산출하는 방식은 다양하지만 본 연구는 클러스터링을 적용해 아파트 가격의 트렌드(trend)를 분석하는 것이 주된 목적이기 때문에 일반적인 단순 수익률 차감 방식을 이용한다[12].

2.2 자기조직화지도

자기조직화지도(Self Organizing Map; 이하 SOM)는 자율 학습을 사용한 신경망의 하나로 경쟁 학습 모형을 기반으로 한 비지도 학습(unsupervised learning)에 속한다[13]. SOM은 입력 층(input layer), 경쟁 층(competition layer), 그리고 출력 층(output layer)이 있는데 입력 층은 표본 자료에서 산출된 다차원 데이터로써 n 개의 p 차원으로 설계된다. 또한 가중치 벡터(weight vector)가 초기화 과정을 통해서 특정 값으로 정의되며 주로 선형 초기화 방식을 이용한다[14]. 가중치 벡터의 초기화 방법은 선형 초기화(linear initialization)와 무작위 초기화(random initialization)가 있다. SOM은 특정한 결과 값이 없이 입력 데이터가 주어지는 자율 학습에서는 비슷한 입력 값들이 들어오는 경우에 그것들을 유사한 그룹으로 설정하기 위해 스스로 연결 강도를 조절할 수 있다. 즉 입력 값의 통계적 특성을 통해 비슷한 데이터들을 같은 그룹으로 묶는 것을 의미한다. Fig. 2는 앞서 설명한 SOM의 구조적 알고리즘을 보여주고 있다.




Fig. 2. Structure of self-organization map

Kohonen은 뉴런(neuron)의 강도를 조정하기 이전의 신경망과는 다르게 정해진 승자 뉴런만이 유일한 출력 신호를 보낼 수 있는 승자 독점(winner talks all)의 방식을 제안하고 있다[15]. 또한 이웃(neighborhood) 개념

을 이용해 승자 뉴런과 상호적 관계에 있는 뉴런의 강도를 가공하도록 설계해 입력 층의 패턴을 보다 더 반영하도록 하고 있다. 자기조직화지도는 많은 장점이 있는데 대표적으로 하나의 전방 패스(feedforward flow)를 적용하기 때문에 학습 과정에서 속도가 상당히 빠르다. 더 나아가 연속적 학습 기능이 가능해서 입력 값의 통계적 분포가 변화하면 학습 분포 또한 그것에 맞게 변화한다.

본 연구에서는 SOM 알고리즘을 VBA(visual basic for application)으로 구현해서 다음 장에서 설명하는 입력 데이터를 통해 실험을 진행한다.

3. 입력변수 선정

본 연구에서는 아파트 가격 지수에 영향을 주는 총 16개의 입력 변수를 선정하고 이를 SOM 알고리즘을 통해 클러스터링 분석을 하고자 한다. 변수 선정은 클러스터링 분석을 위해 데이터의 확보 및 공시 주기 등을 고려하고 선행연구를 통해서 대량의 요인을 추출하고 정규화 및 시행착오법(trial and error method)적인 클러스터링 과정을 통해서 최종 16개의 입력 변수를 선정한다[16]. 즉 아파트와 관련된 약 50개의 키워드(keyword)를 바탕으로 특정 시점의 사전 학습을 통해서 성능이 좋은 16개의 변수를 갖고 실험을 진행한다.

Table 1은 총 16개의 입력 변수와 실질 아파트 가격 지수와의 상관계수를 나타낸 표이다. 상관계수는 1986년 1월부터 2021년 6월까지의 자료로 산출하였는데 대체적으로 1 또는 -1에 매우 가까운 변수는 없으며, 주로 양의 상관관계를 갖고 있는 변수들이 많다. 특히 전세 수요량과 실질 아파트 가격 지수의 상관계수가 0.86으로 가장 높은 반면에 미분양 수는 -0.69로 가장 낮은 상관관계를 보인다. 또한 표 안에 1~16의 숫자는 결과분석 부분에서 시각적 이해를 돕기 위한 넘버링(numbering)을 표기한 것이며 넘버링 순서는 실험 결과에 미치는 영향이 없다.

이렇게 수집된 자료들은 내포하는 의미와 성향이 다르기 때문에 원천 자료의 경우에는 단위 등이 다를 수 있다. 따라서 본 실험에서는 두 차례에 걸쳐서 정제작업(data scaling)을 실시하는데 가장 정규화의 기본이 되는 Z-score Normalization과 Min-max Normalization을 이용해서 표준화를 수행한다.

Table 1. Clustering Input Data

Input Data	
Raw Material Index (1 : 0.61)	Rent Demand (9 : 0.86)
Construction Index (2 : 0.33)	Stock Price Index (10 : 0.14)
Sales and Demand (3 : 0.59)	Completion Volume (11 : -0.03)
Consumer Prices (4 : 0.74)	Households Volume (12 : 0.29)
The Price of Oil (5 : -0.17)	Unemployment Rate (13 : 0.21)
Inflation Rate (6 : 0.04)	Housing Transactions (14 : -0.38)
Land Index (7 : -0.08)	Amount of Currency (15 : 0.41)
Loan Rate (8 : -0.26)	Unsold Housing Volume (16 : -0.69)

4. 실험계획 및 결과분석

본 장에서는 앞에서 설명한 총 16개의 입력 변수를 바탕으로 SOM 알고리즘에 적용하여 실질 아파트 가격 지수와 함께 비교 분석하고자 한다.

4.1 실험계획

본 연구에서는 아파트 가격에 영향을 주는 총 16개 항목에 대해서 월별로 데이터를 수집하고 수집한 데이터를 SOM 알고리즘을 통해서 클러스터링을 한다.




Fig. 3. Momentum Cycle of Apartment Price Index

Table 2. Experimental plan

Factors	Details
Subjects to experiment	Real Apartment Price Index
Input Variables	Total 16 Input Data (See Table 1)
Clustering Method	SOM algorithm
Experimental period	1986.01~2021.06
Data Cycle	Monthly

실험 대상인 실질 아파트 가격 지수인 Fig. 3은 1998년 IMF 경제 위기를 제외하고 실질 아파트 가격 지수를 중장기적인 관점에서 상승기와 횡보 또는 소폭 하락기로 나뉘는데 이는 실험 결과에서 나오는 각 구간(U1, N1, U3, N3)별 변수 특징을 분석하기 위함이다. 본 구간은 한 방향으로 움직이려는 모멘텀이 끝나는 구간까지를 구역으로 설정하는데 주식과 같은 단기 매매의 성향이 아니기 때문에 가시적인 관점에서 구간을 나눈다. 실험 데이터들은 실질 아파트 가격 지수를 포함해서 총 17개로 1098년 1월부터 월별로 데이터를 수집한다. Table 2는 본 논문의 실험계획을 정리한 표이다.

4.2 결과분석

본 절에서는 16개의 입력 변수를 SOM 알고리즘을 통해서 모멘텀(momentum) 구간 별로 패턴을 정량적으로 분석한다. U1~U3은 상승 구간이며 N1~N3은 횡보 및 소폭 하락의 구간이다. 부동산 자산의 특성상 금융 상품과 다르게 단기적 매매는 적합하지 않기 때문에 중장기적인 관점에서 패턴을 찾고 이를 분석하고자 한다. Table 3은 실험 환경에 대해 기본적으로 표현해주는 표인데 각 주기별 날짜와 해당 주기의 실질 아파트 가격의 상승률 그리고 해당 기간 동안의 총 개월 수를 나타내고 있다. 표를 보면 U1~U3은 약 30% 이상의 수익률을 보이고 나머지 횡보 및 소폭 하락 구간인 L1~L3은 보합 수준을 기록한 것으로 나타난다.

Table 3. Experimental Status

Start date (yy-mm)	End Date (yy-mm)	Rate of Rise	Total Months	Cycles
1986-01	1990-01	53%	49	U1
1990-01	1997-10	12%	94	L1
1999-10	2002-04	38%	30	U2
2002-04	2010-01	-4%	94	L2
2010-01	2017-10	38%	94	U3
2017-10	2020-10	4%	37	L3

Table 4. Clustering Basic Results

Cycles	Number of success months	Success rate	Standard deviation
U1	40	82%	1.58
L1	75	79%	0.93
U2	22	72%	1.24
L2	80	85%	0.82
U3	76	81%	0.93
L3	31	86%	1.34

Table 4는 클러스터링의 결과 값을 각 주기별로 나타내고 있는데 해당 주기의 총 16개의 변수들의 각각의 평균에서 오차범위 90% 안에 속하는 값들인 경우에 성공 횟수로 카운팅(counting)을 했다. 여기서 평균은 Fig. 4와 같이 각 주기별 3개의 대표 그룹을 추출하여 기준을 선정한다. 그 결과 모든 주기에서 약 80% 이내의 성공률을 보이고 있으며 이는 클러스터링을 통해 아파트 가격에 영향을 주는 주요 변수가 적절하게 선정되었다는 것을 의미한다.

더불어 본 연구에서는 부동산 가격에 영향을 주는 총 16개의 입력 변수를 주기에 맞게 6개의 그룹으로 클러스터링을 정량적으로 분석하기 위해 Fig. 4와 같이 방사형 차트로 결과를 시각화한다.

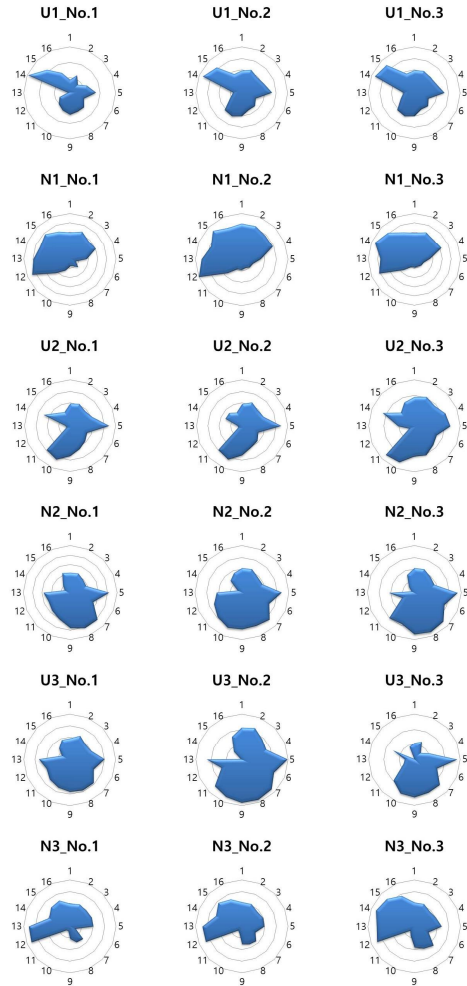


Fig. 4. Patterns of Input Data by Cycle

이를 위해 각 그룹에 속한 해당 시점(월)을 3개로 나눠 각각 변수의 평균을 산출하고 이를 방사형 차트로 그리면 동일 주기에 대해 3개의 방사형 차트로 결과를 확인할 수 있다. 예컨대 U1 주기에는 Fig. 4의 가장 맨 위 3개의 그림에 해당하는데 이는 U1 구간에서는 14~15번의 입력 변수인 주택거래량과 통화량의 값이 다른 변수들에 비해 상대적으로 값이 크다.

본 실험을 통해 상승과 하락 주기에 맞게 입력 변수들의 패턴들이 뚜렷하게 차별화되고 해당 주기별로 3개의 세부 그룹으로 나눠 방사형 차트를 그려도 동일한 주기별로 3개의 방사형 모양이 비슷한 결과를 보인다는 것을 알 수 있었다.

이는 약 3~5년의 중장기적인 주기에서 16개의 변수들의 수준(level)이 유사한 형태를 보인다는 것을 의미한다. 특히 상승 구간보다는 횡보 구간에서 방사형 모양이 둔감한 모양을 보이고 있으며, 실제 U1~U3 구간의 변수들 간의 표준편차는 약 1.25이며 N1~N3 구간의 변수들 간의 표준편차는 약 1.03으로 상승 구간이 좀 더 높게 나왔다.

5. 결론

본 연구는 SOM 알고리즘을 이용해서 아파트 가격에 영향을 주는 16개의 요인의 패턴을 분석하고 6개의 그룹으로 클러스터링을 하였다. 또한 클러스터링의 결과를 분석하기 위해서 아파트 가격 지수를 총 6개의 주기로 나눠 클러스터링 결과와 비교 하였다. 이를 쉽게 분석하기 위해서 해당 그룹에 속한 변수들을 세 그룹으로 나눠 평균을 구하고 방사형 차트로 구현했다.

그 결과 각 주기 별로 입력 변수들 간의 성격이 잘 반영되는 결과를 보이고 해당 주기 별로 뚜렷한 성향을 보이고 있다. 특히 대량의 변수를 이해하는데 쉽지 않은 부분들 방사형 차트로 구현함으로써 이해도를 높인 점에서 의미가 있으며 이는 향후 이미지 학습 기법을 통해 관련 연구를 진행하는데 도움이 될 것으로 기대한다. 더불어 각 주기 별로 클러스터링 결과가 좋다는 것은 총 16개의 입력 변수가 아파트 가격 요인에 적절하다는 것을 과학적이고 정량적으로 확인한 것에서 향후 아파트 가격 결정 요인에 관한 연구에 있어서 본 논문이 효과적인 참고 문헌이 되기를 바란다.

REFERENCES

- [1] J. Y. Kim, S. J. Lee. (2021). A Study on the Subjective Health Perception of Residents of Public Rental Housing and General Apartment Housing. *The Korean Association for Policy Studies*, 30(1), 261-288.
DOI : 10.33900/KAPS.2021.30.1.10
- [2] Y. S. Moh, S. T. Han, K. P. Yeon & H. C. Kang. (2015). A Study on Variable Importance Measures in Multiple Regression Analysis. *Journal of The Korean Data Analysis Society*, 17(6), 2981-2990.
UCI : G704-000930.2015.17.6.020
- [3] J. Y. Heo. (2015). SVM based Stock Price Forecasting Using Financial Statements. *KIISE Transactions on Computing Practices*, 21(3), 167-172.
UCI : G704-A00398.2015.21.3.001
- [4] J. P. Ryu, C. H. Han & H. J. Shin. (2016). Sector Investment strategies Using Big Data Trends. *Journal of the Korea Academia-Industrial*, 13(1), 111-121.
UCI : I410-ECN-0102-2017-560-000095063
- [5] S. H. Hong. (2020). Research on Stock price prediction system based on BLSTM. *Journal of the Korea Convergence Society*, 11(10), 19-24.
DOI : 10.15207/JKCS.2020.11.10.019
- [6] H. S. Hwang. (2021). Hybrid Machine Learning Model for Predicting the Direction of KOSPI Securities. *Journal of the Korea Convergence Society*, 12(6), 9-16.
DOI : 10.15207/JKCS.2021.12.6.009
- [7] S. W. Bae & J. S. Yu. (2018). Estimation of the Apartment Housing Price Using the Machine Learning Methods: The Case of Gangnam-gu, Seoul. *Korea Real Estate Analysts Association*, 24(1), 69-85.
DOI : 10.19172/KREAA.24.1.5
- [8] S. A. KIM & H. J. Jung. (2020). Prediction on the Housing Auction Market Using Deep Learning. *Journal of the Korea Real Estate Management Review*, 21(21), 7-26.
DOI : 10.37642/JKREMR.2020.21.1
- [9] J. Y. Lee & J. P. Ryu. (2021). Prediction of Housing Price Index Using Artificial Neural Network. *Journal of the Korea Academia-Industrial cooperation Society*, 22(4), 228-234.
DOI : 10.5762/KAIS.2021.22.4.228
- [10] Q. Cao, K. B. Leggio & M. J. Schniederjans. (2005). A comparison between Fama and French's model

and artificial neural networks in predicting the Chinese stock market. *Computers & Operations Research*, 32(10), 2499-2512.
DOI : 10.0.3.248/j.cor.2004.03.015

- [11] J. Gu, M. Zhu & L. Jiang. (2013). Housing price forecasting based on genetic algorithm and support vector machine. *Expert Systems with Applications*, 38(4), 3383-3386.
DOI : 10.1016/j.eswa.2010.08.123
- [12] J. G. Kim. (2011). An Empirical Analysis on the Relationship between Stock Price, Interest Rate, Price Index and Housing Price using VAR Model. *The Journal of Asian Finance, Economics and Business*, 11(10), 63-72.
DOI : 10.15722/jds.11.10.201310.63
- [13] J. P. Ryu, H. J. Shin, M. H. Kim & J. G. Back. (2017). Pattern Analysis of Stock Prices Using Machine Learning and Data Visualization. *Journal of Information Technology and Architecture*, 14(2), 189-198.
- [14] J. H. Jang & J. S. Oh. (2019). Study on Load Analysis of Propulsion System using SOM. *International Journal of Ocean System Engineering*, 33(5), 447-453.
DOI : 10.26748/KSOE.2019.012
- [15] T. Kohonen. (1990). The self-organizing map. *Proceedings of the IEEE*, 78(9), 1464-1480.
DOI : 10.1109/5.58325
- [16] G. S. Houg. (2020). A Study of the Effect of Transactions Involving Out-of-Town Buyers on Apartment Prices. *Korea Real Estate Review*, 30(4), 33-44.
DOI : 10.35136/krer.30.4.3

이 지 영(Jiyoung Lee)

[정회원]



- 2017년 2월 : 한성대학교 일반대학원 경제부동산학과(부동산학박사)
- 2006년 4월 ~ 현재 : KIS채권평가 평가본부 주식파생실
- 관심분야 : 부동산학, 기계학습, 딥러닝
- E-Mail : jiyong.lee@kispricing.com

유 재 필(Jae Pil Ryu)

[정회원]



- 2017년 2월 : 상명대학교 일반대학원 공과대학 경영공학과(공학박사)
- 2013년 10월 ~ 2016년 10월 : KIS 채권평가 금융공학연구소
- 2016년 11월 ~ 현재 : KIS채권평가 평가본부 주식파생실
- 관심분야 : 빅데이터, 데이터마이닝
- E-Mail : jaepilryu@kispricing.com