

## 인공신경망을 이용한 주택가격지수 예측

이지영, 유재필\*  
키스채권평가

### Prediction of Housing Price Index Using Artificial Neural Network

Lee Jiyoung, Jae Pil Ryu\*  
KIS Pricing

**요 약** 부동산의 시장 참여자들에게 부동산 가격에 대한 방향성을 예측하는 것은 의사결정에 있어서 매우 중요하다. 이를 위해 주로 회귀분석, ARIMA, VAR 등의 방법론을 사용하는데 이는 불특정 변수에 의해서 변동하는 자산의 가치를 예측하는데 한계점을 갖는다. 때문에 본 연구에서는 이를 보완하기 위해서 인공신경망 기법을 이용해 부동산 시장에서 유동성이 풍부한 서울 아파트 가격 추이를 예측하고자 한다. 인공신경망 학습을 위해서 총 12개의 거시 및 미시적 변수를 나눠 학습 모형을 설계하는데 거시적 요인은  $CASE_1$ , 미시적 요인은  $CASE_2$  그리고 두 요인을 조합해서 요인을 구성한  $CASE_3$  으로 나눠서 실험한다. 그 결과  $CASE_1$  과  $CASE_2$  는 약 2년 동안 87.5%의 예측을 보이고  $CASE_3$ 은 95.8%의 예측성과를 보인다. 본 연구는 아파트 가격에 영향을 주는 다양한 요인들을 거시적 및 미시적으로 구분하여 정의하고 미래의 아파트 가격의 방향성을 예측하는데 인공신경망 기법을 제안하고 그 실효성을 분석했다. 따라서 최근 발전하고 있는 학습 기법이 부동산 분야에 다양한 관점으로 적용되어 시장 참여자들의 효율적인 의사결정을 할 수 있기를 기대한다.

**Abstract** Real estate market participants need to have a sense of predicting real estate prices in decision-making. Commonly used methodologies, such as regression analysis, ARIMA, and VAR, have limitations in predicting the value of an asset, which fluctuates due to unknown variables. Therefore, to mitigate the limitations, an artificial neural was is used to predict the price trend of apartments in Seoul, the hottest real estate market in South Korea. For artificial neural network learning, the learning model is designed with 12 variables, which are divided into macro and micro factors. The study was conducted in three ways: (Ed note: What is the difference between case 1 and 2? Is case 1 micro factors?)CASE1 with macro factors, CASE2 with macro factors, and CASE3 with the combination of both factors. As a result, CASE1 and CASE2 show 87.5% predictive accuracy during the two-year experiment, and CASE3 shows 95.8%. This study defines various factors affecting apartment prices in macro and microscopic terms. The study also proposes an artificial network technique in predicting the price trend of apartments and analyzes its effectiveness. Therefore, it is expected that the recently developed learning technique can be applied to the real estate industry, enabling more efficient decision-making by market participants.

**Keywords** : Artificial Neural Network, Machine Learning, Deep Learning, Housing Price, Seoul Apartments

---

\*Corresponding Author : Jae Pil Ryu(KIS Pricing)

email: jaepilryu@kispricing.com

Received February 9, 2021

Accepted April 2, 2021

Revised April 1, 2021

Published April 30, 2021

## 1. 연구배경

한국은 가계 자산에서 부동산 자산이 차지하는 비중이 약 70%로 매우 높다[1]. 그만큼 국민 경제에 있어서 부동산 자산가치가 미치는 영향은 크고, 정부 및 국민에게 부동산과 관련된 정책 및 사회적 이슈는 매우 중요한 사안이라고 할 수 있다. 예컨대 정부는 부동산 가격이 가파른 상승을 보이면 이를 조정하기 위해 다양한 정책을 수립한다. 따라서 부동산 정책을 수립하는 입안자, 건설회사, 부동산 투자자 그리고 잠재적 소유자 등에게 부동산 가격에 대한 선행적 예측은 무엇보다 중요하다. 특히 부동산 중에서도 주택에 대한 사회적 관심이 가장 크며 이와 관련된 경기 변동을 알 수 있는 지표로 주택가격지수가 있다. 주택가격지수란 전국 주택의 매매 가격을 바탕으로 산출하는 지표로 국내 주택 시장의 현황을 분석하고 이해하는데 유효한 지수이다. 특히 우리나라의 경우에는 주택 중에서도 아파트에 대한 거래 비중이 매우 높다[2]. 때문에 주택가격지수 외에도 관련 기관에서는 지역별 아파트가격지수 또는 규모별 아파트가격지수 등 섹터(sector)화한 아파트 가격지수들도 함께 공시하고 있다. 앞서 기술했듯이 주택과 관련된 주요 지표들은 다양한 관점의 시장 참여자들에게 의사결정 측면에서 매우 중요한 자료인 만큼 이를 예측하는 연구가 활발하게 진행되고 있다.

한국의 주택시장의 특이점을 고려하여 국내 선행연구 위주로 살펴보면 주택가격지수를 예측하기 위해 주로 회귀분석, ARIMA(autoregressive integrated moving average) 그리고 VAR(vector autoregressive model) 등을 이용한다. 임성식은 외부충격요인을 분석하고 ARIMA 모형을 이용해서 주택가격지수를 예측했다[3]. 이창훈은 장단기 아파트가격지수의 예측 분포를 산출하고자 베이지안 기법의 단점을 보완하기 위해 확장 변수 모형을 제안하였고 그 결과 기존의 베이지안 기법에 비해 예측력이 우수한 것을 알 수 있었다. 그리고 단기 예측력에서는 자기회귀모형의 예측력이 가장 우수했다[4]. 이정우는 k-최근접이웃(k-nearest neighbours)을 적용한 공간가중행렬 방법으로 단위면적당 아파트 매매가격을 예측한 결과 공산오차모형에 비해서 공간시차모형의 예측력이 높았고 지역별로 아파트 가격 변동에 미치는 변수가 불특정하다는 것을 입증했다[5]. 이현재는 이미지 자료 예측에 사용되는 CNN(convolutional neural networks) 기법을 서울 아파트 가격 예측을 위해 적용하고 주요 기반 시설을 가격결정요인에 반영하였다[6]. 전해정은

VAR 모형을 통해 2009년 1월부터 2019년 5월까지 지역별로 거시경제변수가 주택가격 예측에 미치는 영향을 분석하였고 특히 전세 가격과 주택담보대출 비율의 상승은 주택 매매 가격을 상승시키는 요인이라는 것을 입증했다[7]. 앞서 기술한 다양한 회귀모형은 시계열 자료를 예측하는데 주로 사용되는 방법이지만 독립성 및 등분산성 등의 가정과 다중공선성의 한계 그리고 불특정 변수에 대한 잡음(noise) 등의 단점이 있다[8]. 더불어 이태영은 주택 가격 예측을 위한 LSTM(long short term memory models)을 이용해서 예측의 성능을 입증하였는데 학습을 위한 데이터 기간의 범위가 제한적이라 학습의 한계점을 내포하고 있다[9]. 이처럼 다양한 선행연구를 참고하여 본 연구에서는 인공신경망(artificial neural network; 이하 ANN) 기법을 이용해 주택가격지수를 예측하고자 한다. 본 논문의 구성은 다음과 같다. 2장에서는 인공신경망 학습 모형에 대한 이론적 배경 및 구조를 설명하고, 3장에서는 학습을 위한 입력 변수에 대해서 그리고 4장에서는 실험 계획 및 실험 결과에 대해서 기술한다. 끝으로 5장에서는 결론을 제시한다.

## 2. 인공신경망 학습 모형

본 장에서는 인공신경망 학습의 이론적 배경과 구조에 대해서 설명한다.

### 2.1 이론적 배경

의사결정에 대한 문제를 그물 형식으로 구축한 망을 통해서 인간의 뇌와 유사한 동작을 할 수 있게 만든 것이 인공신경망의 시작이었다. 초기에는 데이터 학습에 대한 예측 성능이 좋지 않았지만 비지도학습(unsupervised learning)을 이용한 은닉 층(hidden layer)에서의 데이터 전처리 방법이 발전하면서 많은 주목을 받게 되었다[10]. 1987년 Lapedes와 Farber에 의해서 인공신경망 학습 모형을 이용하여 과거 주가 자료를 바탕으로 미래의 주가를 예측하는 연구가 발표되면서 지금까지 기계학습(machine learning)을 이용해 다양한 상품 가치 시계열을 예측하는 연구가 활발하게 진행되고 있다[11]. 인공신경망 학습 모형은 사람의 뇌에 대한 정보성 자료에 대한 처리 과정을 수학적 모델로 구현하고 상호적으로 연결을 하여 망(networks)을 구축한 것이다[12].

## 2.2 구조적 설명

인공신경망 학습 모형은 최적의 함수 근사자(function approximator)이며 복잡하고 방대한 자료도 입력 층(input layer)과 출력 층(output layer)의 관계를 분석하고 학습 과정에서 새로운 샘플(sample)도 찾아낼 수 있다[13]. 일반적으로 비모수 회귀분석인 경우에는 선형 방정식의 매개변수를 산출하는 방식이지만 인공신경망 모형은 이를 적용하지 않는 회귀분석(non parametric regression)이다. 인공신경망 모형은 병행적으로 상호작용하는 입력 층, 은닉 층 그리고 출력 층을 구성하는 노드(node)로 설계가 되고 각 산출 요소는 가중치의 합(weighted sum)으로 계산한다[14]. Fig. 1은 본 연구에서 구축하고자 하는 인공신경망 모형의 구조를 나타낸 그림인데  $n$ 개의 입력 값인  $x_i$ 는 가중된  $w_i$ 를 반영하여 신경망을 구축하고  $w_i$ 가 반영된  $x_i$ 의 편차인  $b$ 를 합해 Eq. (1)과 같이  $A$ 를 구한다.

$$A = \sum x_i w_i + b \quad (1)$$

Where,  $x$  denotes Input Value,  $b$  denotes deviation reflected by  $w$

그리고 활성화 함수(activation function)인  $f$ 를 통해서 출력 값을 계산하는데 이는 Eq. (2)와 같이 계산한다.

$$f(A) = f(x_i w_i + b) \quad (2)$$

Where,  $f$  denotes activation functions

Eq. (2)에서  $w_i$ 와  $x_i$ 는 실수 값이고 입력 변수가 많으면 산출 과정을 단순화하기 위해서 편차 값인  $b$ 를 가상 입력 값인  $x_0 = +1$ 로 가정하고  $w_0$ 로 개정할 수 있다. Fig. 1에서 은닉 층은 각 입력변수에 대응하는 마디들로 구성하고 은닉 층은 다수의 은닉 마디로 설계한다. 각 은닉마디는 입력 층에서 변수들의 선형결합(linear combination)을 비선형함수(nonlinear function)로 처리하고 출력 층 및 다른 은닉 층으로 전달한다. 더불어 출력 층은 목표변수(target)에 대응해서 마디를 구성하는데 목표변수에 따라서 다수의 출력마디가 구성될 수 있다. 본 연구에서는 총 6개의 입력 층과 하나의 은닉 층에서 5개의 은닉마디를 갖는 인공신경망 모형을 모델링(modeling)하고 이에 대한 예측력을 분석하고자 한다.




Fig. 1. Structure of the ANN

## 3. 학습 입력 변수

본 연구는 인공신경망 모형을 이용해 주택 매매 가격의 방향성을 예측하기 위해 Table 1을 참고하여 부동산 가격에 영향을 주는 거시적 및 미시적 요인으로 각 6개씩 구성한다.

### 3.1 거시적 요인

거시적 요인으로는 통화량, 물가, 이자율, 실업률 그리고 주가지수를 선정한다. 통화량은 주택매매가격에 인과관계가 있고 시장 금리는 주택 매매를 위한 자금 확보 능력 및 주택 정책에 영향을 주는 주요 요인이다[15]. 주식 시장과 부동산 시장은 대표적인 투자 시장인데 유동성의 흐름이 각 시장에 시차를 두고 인과관계를 보인다. 또한 소비자 물가인 경우에는 실물 자산의 가치를 나타내는 대표적인 요인으로 물가 지수의 변동은 주택 가격의 모멘텀(momentum)에 영향을 준다. 실업률은 소비 주체와 직접적인 영향이 있는 요인으로 산업 경기 전반에 영향을 주는 요인이다. 더불어 주택 시장의 투자자로서 자금을 지급할 수 있는 여력 및 대출 상환의 우려는 주택 매매 가격에 영향을 준다.

### 3.2 미시적 요인

미시적 요인으로는 부동산 수요를 결정하는 거래량, 가구 수 그리고 대출 이자율 변수와 부동산 공급을 결정하는 지가, 준공량 그리고 미분양 정보를 선정한다.

거래량은 부동산 시장의 유동성을 나타내는 대표적인 요인인데, 거래량이 상승할 경우 재고 주택이 줄어들며 주택 가격을 상승하는 관계를 가진다. 주택은 가구 단위로 결정되며 가구 구조의 변화는 주택의 공급 변화에 영

Table 1. Housing Price Determinants

Factors		Case
General	Social	Population, Number of households, Public facilities, Real estate
	Economic	Level of income, Savings, Consumption and investment, Balance of international payments
	Administrative	Land system, Planning and regulation of land use activities
Area	General	Oriented social, Economic, Administrative factors
	Natural	Natural qualities(indicators, topography, geographical features, soil, weather conditions, natural environment, risk of disaster, etc.)
Individual	Land	Degree of access to public facilities and commercial facilities, The degree of access to hazardous facilities and hate facilities
	Building	Quality and quantity of construction, Condition of appropriation with buildings and land and local environment

향을 미친다. 서울의 인구수는 하락하고 있지만 가구의 분파는 세분화되고 주택의 수 또한 가구의 수에 집중되게 된다[16]. 주택의 가격은 대출을 통한 레버리지를 발생시키는 실패자산이므로 대출 이자율은 주택 가격에 영향을 줄 수 있다. 비탄력적인 성격을 갖는 주택 공급량은 인허가, 착공 그리고 준공에 도달하기까지 주택 공급의 과정을 지표로 확인할 수 있다. 또한 주택 시장에 공급되는 준공 자료는 부동산 공급의 예측 변수로 적용가능하다. 더불어 주택의 미분양 정보는 초과 공급을 확인할 수 있는 지표로 수요와 공급의 원리로 결정되는 가격의 구조에서 주택의 초과 공급에 따른 주택 가격의 영향을 확인할 수 있다[17].

Table 2. Correlation between housing prices and factors

Unemployment (=BF <sub>1</sub> )	Interest rate (=BF <sub>2</sub> )	Inflation (=BF <sub>3</sub> )
0.03	-0.08	0.05
Money supply (=BF <sub>4</sub> )	Price index (=BF <sub>5</sub> )	KOSPI (=BF <sub>6</sub> )
-0.01	0.06	-0.10
households (=SF <sub>7</sub> )	Completion (=SF <sub>8</sub> )	Land price (=SF <sub>9</sub> )
-0.86	0.09	0.67
Loan interest (=SF <sub>4</sub> )	Unsold home (=SF <sub>5</sub> )	Volume (=SF <sub>6</sub> )
-0.68	-0.92	0.16

Fig. 2와 Fig. 3은 2013년부터 2020년까지 각각 거시적 및 미시적 요인의 변수와 주택 가격 추이를 100pt 기준으로 변환해서 나타낸 그림이며, Fig. 3에서 거래량 요인은 변동성이 크기 때문에 시각적 이해를 높이기 위해서 보조 y축(우)으로 표현한다.

Table 2는 주택 가격과 총 12개의 요인 별 상관계수

를 나타내고 있는데 세대수와 대출 이자율 그리고 미분양 수는 주택 가격과 음의 상관관계를 그리고 지가는 양의 상관관계를 보인 반면, 기타 요인들은 유의미한 상관관계를 보이지 않는다. 또한 주가지수는 주택 가격을 선행하는 모습을 보이고, 2019년 초 주택 가격이 크게 하락할 당시에 가장 많은 주택 매매 거래량을 보이고 있다.

본 연구에서는 요인 별 표현의 편리성을 위해 실업률(=BF<sub>1</sub>), 이자율(=BF<sub>2</sub>), 인플레이션(=BF<sub>3</sub>), 통화량(=BF<sub>4</sub>), 물가(=BF<sub>5</sub>), KOSPI(=BF<sub>6</sub>), 가구수(=SF<sub>7</sub>), 준공량(=SF<sub>8</sub>), 지가(=SF<sub>9</sub>), 대출이자율(=SF<sub>4</sub>), 미분양가구수(=SF<sub>5</sub>) 그리고 거래량(=SF<sub>6</sub>)으로 맵핑(mapping)한다.

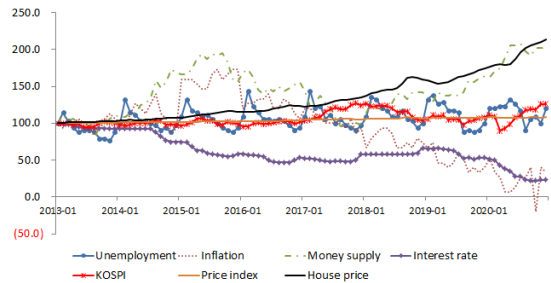


Fig. 2. Macroeconomic factors and housing price trends

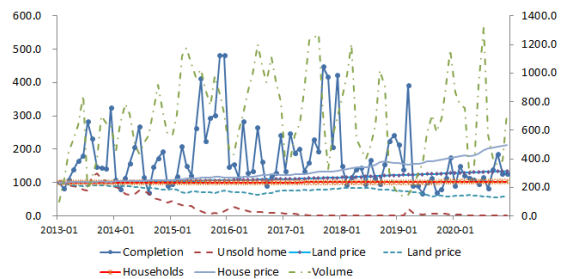


Fig. 3. Micro-factors and trends in housing prices

### 4. 실험계획 및 분석

본 장에서는 인공지능망 모형을 이용한 주택 가격의 방향성 예측을 위한 실험 계획 및 결과 분석에 대해서 기술한다.

#### 4.1 실험계획

본 연구에서는 실험 자료 중 목표 값을 서울 아파트 가격 지수로 선정한다. 서울 아파트의 경우에는 거래 유동성이 풍부하고 정책적으로도 매우 민감한 대상이기 때문에 시장 참여자들에게 서울 아파트 가격의 방향성을 분석하는 것이 매우 중요하다. 따라서 본 연구에서는 실험 자료로 서울 아파트의 가격 지수를 선정하고 이에 영향을 주는 거시적 및 미시적 변수를 정의한다.

Table 3. Experimental plan

Experimental Factors	Details
Subjects to experiment	Seoul Apartment Price Index
Input Variables	Macroeconomic(CASE) : $BF_1, BF_2, BF_3, BF_4, BF_5, BF_6$ Micro-factors(CASE) : $SF_1, SF_2, SF_3, SF_4, SF_5, SF_6$
Experimental period	Learning Period : 2007.01~2018.12 Prediction period : 2019.01~2020.12
Experiment cycle	Monthly
Learning Objectives	Up and Down
Learning Methods	Artificial Neural Network Model

더불어 실험을 위한 입력 변수는 인공지능망 학습을 위해 정규화 과정을 통해 데이터 가공을 진행한다. 실험 자료의 수집 기간은 2007년 1월부터 2020년 12월까지 인데 인공지능망 학습을 위한 학습 기간은 2007년 1월부터 2018년 12월까지 그리고 예측 기간은 2019년 1월부터 2020년 12월까지로 하며, 해당 예측 기간에 한 달 후 상승과 하락에 대한 방향성을 실제 자료와 비교 및 분석한다. 또한 거래 빈도와 유동성 등을 고려해서 모든 실험 자료의 주기는 월 별로 입수한다. Table 3은 본 연구의 실험계획을 정리한 표이다.

#### 4.2 결과분석

본 연구에서는 서울 아파트 가격에 영향을 주는 각 6

개의 거시적 및 미시적 요인에 대해 2007년 1월부터 2018년 12월까지의 월 별 시계열 자료들과 서울 아파트 가격 지수 시계열 자료를 바탕으로 학습 모형을 구성한다. 구성된 모형에 2019년 1월부터 2020년 12월까지의 입력 변수를 투입하고 한 달 후의 상승 및 하락에 대한 방향성을 예측하고자 한다. 또한 서울 아파트 가격 지수에 대한 예측성도를 높이기 위해서 경우의 수를 고려한 거시적 및 미시적 요인을 조합한 요인 변수를 추출한다. 본 절에서 거시적 요인을 통한 실험은 CASE<sub>1</sub>, 미시적 요인을 통한 실험은 CASE<sub>2</sub> 그리고 거시적 및 미시적 요인을 조합한 요인을 통한 실험은 CASE<sub>3</sub>으로 표현한다.

본 실험에서는 1년에 12번의 예측력을 분석할 수 있으며, Table 4는 분기별로 예측성도를 나타낸 표이다. 분기별로 나눠서 분석한 결과 대체적으로 예측력이 우수한 것을 확인할 수 있다.

Table 4. Experimental results

Year	Quarter	Factor Groups	Prediction rate	Number of passes
2019	1Q	CASE <sub>1</sub>	66.67	2/3
		CASE <sub>2</sub>	100.00	3/3
		CASE <sub>3</sub>	100.00	3/3
	2Q	CASE <sub>1</sub>	66.67	2/3
		CASE <sub>2</sub>	33.33	1/3
		CASE <sub>3</sub>	100.00	3/3
	3Q	CASE <sub>1</sub>	100.00	3/3
		CASE <sub>2</sub>	100.00	3/3
		CASE <sub>3</sub>	100.00	3/3
	4Q	CASE <sub>1</sub>	100.00	3/3
		CASE <sub>2</sub>	100.00	3/3
		CASE <sub>3</sub>	100.00	3/3
2020	1Q	CASE <sub>1</sub>	66.67	2/3
		CASE <sub>2</sub>	100.00	3/3
		CASE <sub>3</sub>	66.67	2/3
	2Q	CASE <sub>1</sub>	100.00	3/3
		CASE <sub>2</sub>	100.00	3/3
		CASE <sub>3</sub>	100.00	3/3
	3Q	CASE <sub>1</sub>	100.00	3/3
		CASE <sub>2</sub>	100.00	3/3
		CASE <sub>3</sub>	100.00	3/3
	4Q	CASE <sub>1</sub>	100.00	3/3
		CASE <sub>2</sub>	100.00	3/3
		CASE <sub>3</sub>	100.00	3/3
Total		CASE <sub>1</sub>	87.5	21/24
		CASE <sub>2</sub>	87.5	21/24
		CASE <sub>3</sub>	95.8	23/24

특히 시행 착오법(trial and error method)을 모델링하여 새로운 요인 세트(set)를 추출한 CASE<sub>3</sub>의 요인은 BF<sub>2</sub>, BF<sub>3</sub>, BF<sub>4</sub>, BF<sub>5</sub>, BF<sub>6</sub>, SF<sub>4</sub> 이다. 대부분 거시적인 요인에서 선정되었고 이는 CASE<sub>1</sub>과 CASE<sub>2</sub> 보다 예측력이

다소 우수하다.  $CASE_3$ 의 경우에는 2020년 1분기를 제외하고 모든 분기에서 향후 한 달 후의 아파트 가격 방향성 예측에 성공했다.  $CASE_2$ 의 2019년 2분기를 제외하고는 대부분 2/3 또는 3/3 확률로 예측 성공을 보인다. 총 기간 동안  $CASE_1$ 과  $CASE_2$ 는 87.5%의 예측력을 보이고  $CASE_3$ 은 95.8%의 예측력을 보이는데 특히  $CASE_3$ 의 경우에는 총 24번의 실험에서 무려 1번을 제외하고 한 달 후의 주택 가격에 대해 모두 예측에 성공했다.

Fig. 4는 각  $CASE$  별로 예측 기간 동안의 출력 값을 나타내고 있는 그림인데 0.5보다 크면 상승으로 보고 0.5보다 작으면 하락으로 본다. 때문에 한 달 후 실제 아파트 가격이 상승했을 경우 출력 값이 1에 가까울수록 더욱 성능이 좋은 출력 값이며 하락했을 경우에는 0에 가까울수록 우수한 출력 값이라고 할 수 있다.  $CASE_1$ 과  $CASE_2$ 의 예측 확률은 87.5%로 동일하지만 출력 값은  $CASE_2$ 가 0.5에 대부분 근접하면서  $CASE_1$ 이 더 좋은 출력 값을 보이고 있다. 반면  $CASE_3$ 은 대부분 예측 확률도 95.8%로 가장 높으면서 출력 값에 대한 성능도  $CASE_1$ 과  $CASE_2$  보다 좋은 결과를 보여준다.




Fig. 4. Output value for monthly for 2 years

### 5. 결론

최근 딥러닝, 인공지능 그리고 빅데이터 등 4차 산업과 관련된 분야에 대한 관심이 높아지면서 학계와 산업에서 다양한 연구는 물론 현업에 효과적으로 적용되는

사례가 증가하고 있다. 특히 기계학습 기법을 이용해 시계열 자료를 예측하는 것은 기존의 회귀분석, VAR 등과 같은 방식의 한계점을 보완하고 있다. 따라서 본 연구에서는 인공신경망 모형을 이용해 주택 경기의 방향성을 예측하고 주택 가격에 영향을 주는 변수 요인을 선정했다. 즉 입력 층에 학습되는 정보로서 거시적 요인과 미시적 요인을 구분하여 학습 모형을 설계하고 최근 2년 동안 예측력을 분석한 결과, 약 87%의 예측력을 보이면서 그 우수성을 입증했다. 또한 좀 더 우수한 변수 요인을 추출하기 위해서 거시적 및 미시적 요인을 조합한 변수를 선정한 결과, 동일 기간 약 90% 이상의 예측력을 보였다.

결과적으로 주택 경기는 거시적인 시장의 경기 흐름과 함께 주택 시장의 수요 및 공급의 통합 변수를 적용해야 주택 가격의 방향성에 대한 예측성고를 높일 수 있다는 것을 입증했다. 따라서 주택 시장의 조정을 위해서는 주택 시장 내부만을 조정하는 것이 아닌 거시적 요인과 주택 시장 내부적 요인의 조화가 중요하다는 것을 의미한다.

### References

- [1] D. W. Kim, "Do Households Own Too Much of Housing Asset? An Analysis of Investment Return of Housing Asset", *Journal of Korean Economic Analysis*, Vol.23, No.3, pp.171-236, Nov. 2017. DOI: <http://dx.doi.org/10.22823/jkea.23.3.201712.171>
- [2] M. H. Jang and H. S. Kim, "A Research on Fluctuations of Housing Prices Using Text Mining", *Journal of Korean Economic Analysis*, Vol.30, No.2, pp.35-42, Apr. 2019. DOI: <https://doi.org/10.6107/JKHA.2019.30.2.035>
- [3] S. S. Lim, "A study on the forecasting models using housing price index", *The Korean Data and Information Science Society*, Vol.25, No.1, pp.65-76, Jan. 2014. DOI: <http://dx.doi.org/10.7465/jkdi.2014.25.1.65>
- [4] C. H. Lee, "A Bayesian Variable Selection Method for Seoul Apartment Price Index Prediction", *The Korean Economic Association*, Vol.68, No.1, pp.153-190, Mar. 2020. DOI: <http://dx.doi.org/10.22841/kjes.2020.68.1.005>
- [5] W. J. Lee, C. Y. Park, "Prediction of apartment prices per unit in Daegu-Gyeongbuk areas by spatial regression models", *The Korean Data and Information Science Society*, Vol.26, No.3, pp.561-568, May. 2015. DOI: <https://doi.org/10.7465/jkdi.2015.26.3.561>
- [6] H. J. Lee, "Prediction and factors of Seoul apartment price using convolutional neural networks", *The*

*Korean Journal of applied Statistics*, Vol.33, No.5, pp.603-614, Oct. 2020.

DOI: <https://doi.org/10.5351/KJAS.2020.33.5.603>

- [7] H. J. Chun, "Effects of Macroeconomic Variables on Regional Housing Prices Using Bayesian Panel VAR Model", *Asia Culture Academy of Incorporated Association*, Vol.10, No.6, pp.1349-1362, Dec. 2019. DOI: <https://doi.org/10.22143/HSS21.10.6.100>
- [8] T. H. Kim, H. H. Kuk, "A Study on Apartment Price Models Using Regression Model and Neural Network Model Taehun Kim and Hankuk Hong", *The Korea Spatial Planning Review*, Vol.43, pp.183-200, Dec. 2004.
- [9] T. H. Lee and M. J. Jun, "Prediction of Seoul House Price Index Using Deep Learning Algorithms with Multivariate Time Series Data", *SH Urban Research & Insight*, Vol.8, No.2, pp.39-57, Aug. 2018. DOI: <https://doi.org/10.26700/shuri.2018.08.8.2.39>
- [10] S. M. Warren and P. Walter, "A logical calculus of the ideas immanent in nervous activity", *Bulletin of mathematical biophysics*, Vol.5, pp.115-133, Dec. 1943. DOI: <https://doi.org/10.1007/BF02478259>
- [11] P. R. Burrell and B. O. Folarin, "The impact of neural networks in finance", *Neural Computing & Applications*, Vol.6, pp.193-200, Dec. 1997. DOI: <https://doi.org/10.1007/BF01501506>
- [12] J. P. Ryu, H. J. Shin, "Portfolio Selection Strategy Using Deep Learning", *Korea Institute of Enterprise Architecture*, Vol.15, No.1, pp.43-50, Mar. 2018. DOI: <http://doi.org/10.22865/jita.2018.15.1.43>
- [13] S. Peterson and A. B. Flanagan, "Neural network hedonic pricing models in mass real estate appraisal", *Journal of Real Estate Research*, Vol.31, No.2, pp.147-164, Oct. 2009. DOI: [http://doi.org/10.1007/978-1-4615-0909-7\\_9](http://doi.org/10.1007/978-1-4615-0909-7_9)
- [14] J. P. Ryu, H. J. Shin, "A Methodology for Hedging Equity Linked Warrant Using Artificial Neural Network", *The Korea Academia-Industrial cooperation Society*, Vol.13, No.13, pp.1091-1098, Mar. 2012. DOI: <https://doi.org/10.5762/KAIS.2012.13.3.1091>
- [15] H. I. Jang, B. W. Lim and H. K. Kim, "Changes in the comovement of house price and Jeonse price in the Korean housing market considering the macroeconomic factors", *Housing Studies*, Vol.27, No.4, pp.89-124, Nov. 2019. DOI: <http://dx.doi.org/10.24957/hsr.2019.27.4.89>
- [16] J. H. Sung, "An analysis of factors influencing the formation of apartment sale price in Changwon City : focused on the influence of unsold apartments", *Residential Environment Institute Of Korea*, Vol.17, No.1, pp.1-12, Mar. 2019. DOI: <http://dx.doi.org/10.22313/reik.2019.17.1.1>
- [17] K. M. Kim, "A Study on Dynamic Correlations between the Seoul Apartment Market and Factors of Macroeconomic Variable", *KOREA REAL ESTATE ACADEMY REVIEW*, Vol.73, No.1, pp.115-129, May.

이 지 영(Lee Jiyoung)

[정회원]



- 2017년 2월 : 한성대학교 일반대학원 경제부동산학과(부동산학박사)
- 2006년 4월 ~ 현재 : KIS채권평가 평가본부 주석파생실

<관심분야>

부동산, 기계학습, 딥러닝

유 재 필(Jae Pil Ryu)

[정회원]



- 2017년 2월 : 상명대학교 일반대학원 공과대학 경영공학과(공학박사)
- 2013년 10월 ~ 2016년 10월 : KIS채권평가 금융공학연구소
- 2016년 11월 ~ 현재 : KIS채권평가 평가본부 주석파생실

<관심분야>

금융공학, 기계학습, 딥러닝