

# 거시경제변수가 지역 별 아파트 전세가격에 미치는 영향 및 예측모델 구축에 관한 연구

## A Study on the Effect of Macroeconomic Variables on Apartment Rental Housing Prices by Region and the Establishment of Prediction Model

김은미\*  
Kim, Eun-Mi

### Abstract

This study attempted to identify the effects of macroeconomic variables such as the All Industry Production Index, Consumer Price Index, CD Interest Rate, and KOSPI on apartment lease prices divided into nationwide, Seoul, metropolitan, and region, and to present a methodological prediction model of apartment lease prices by region using Long Short Term Memory (LSTM). According to VAR analysis results, the nationwide apartment lease price index and consumer price index in Lag1 and 2 had a significant effect on the nationwide apartment lease price, and likewise, the Seoul apartment lease price index, the consumer price index, and the CD interest rate in Lag1 and 2 affect the apartment lease price in Seoul. In addition, it was confirmed that the wide-area apartment jeonse price index and the consumer price index had a significant effect on Lag1, and the local apartment jeonse price index and the consumer price index had a significant effect on Lag1. As a result of the establishment of the LSTM prediction model, the predictive power was the highest with RMSE 0.008, MAE 0.006, and R-Squared values of 0.999 for the local apartment lease price prediction model. In the future, it is expected that more meaningful results can be obtained by applying an advanced model based on deep learning, including major policy variables

Keywords: LSTM, VAR, Apartment Jeonse Price, Consumer Price Index

## 1. 서 론

### 1.1. 연구의 배경

COVID-19이후 국내 금융과 부동산시장은 막대하  
게 풀린 유동성 자금으로 인한 어려움을 겪고 있다. 21

년 6월 이후 부동산시장은 점차 하락세를 보이다가 22  
년 5월 이후 하강국면으로 진입<sup>1)</sup>하였는데, 이는 과거  
의 외환위기나 금융위기 때처럼 경기 부진과 맞물려  
지속적인 주택가격의 하락이 초래될 수 있음을 보여  
준다. 실제로 아파트 매매가격과 전세가격은 전국 지  
역에서 약세를 보이고 있으며,<sup>2)</sup> 특히 전세가격에 비해

\* 주택도시보증공사 연구위원 Korea Housing Urban Guarantee Corporation(first author: kem531@khug.or.kr)

매매가격이 상대적으로 더 하락하여 전세가율이 높아 지는 지역을 볼 수 있다.<sup>3)</sup> 경제학적 입장에서 이러한 주택가격은 '수요와 공급에 의해 결정될 뿐만 아니라 투자자산으로서 다양한 거시변수에 의해 영향을 받는다'<sup>4)</sup>고 전제할 수 있다.

즉, 전세가격이란 전세수요와 공급의 확대 또는 축소에 따른 결과일 뿐만 아니라 금리 변동성, 시장 간 통화량 이동, 인플레이션 등 다양한 거시경제의 영향에 따른 복합적인 결과값이라고 할 수 있다.

이러한 주택가격과 거시경제변수의 관계에 대한 연구는 부동산, 주식 등 자산가격 급·등락 현상의 원인과 대응방안을 모색하기 위해 국내외적으로 지속적인 연구가 진행되어 왔으나, 주택전세가격에 대한 연구는 전 세계적으로 국내만 유일하게 주택 전세제도를 적용하고 있기 때문에 연구가 다소 부족한 실정이다.<sup>5)</sup>

이에 본 연구에서는 전세가격에 영향을 미치는 거시경제 요인을 파악하고, 그에 따른 전세가격의 예측 모델을 제시하고자 한다.

## 1.2. 연구의 목적과 범위

따라서 본 연구의 목적은 다음과 같다. 1) 선행연구를 기반으로 거시경제변수를 선정하고, 아파트 전세가격지수는 지역으로 구분하여 거시경제변수가 지역별 아파트 전세가격에 미치는 영향을 파악하고자 한다. 2) 시계열 데이터에 적합한 신경망 아키텍처인 LSTM(Long Short Term Memory)을 적용하여 지역별 아파트 전세가격의 방법론적 예측모형을 제시하고자 하였다.

이에 본 연구에서는 금융위기를 기준으로 2008년 1월부터 2022년 7월까지 월별 데이터를 구축하였다. 종속변수는 전국, 서울, 6개 광역, 지방 아파트 전세가격지수이고, 독립변수는 거시경제변수인 전산업 생산지수, 소비자물가지수, 금리, 주가지수이다. 종속변수별 총 4개의 데이터를 구축하였다.

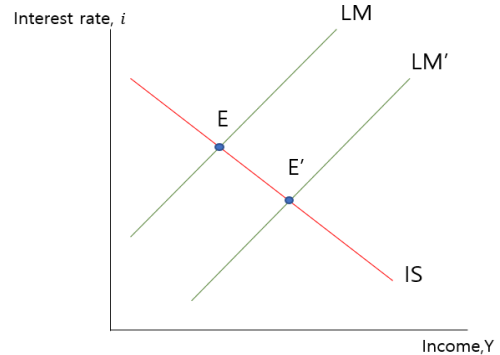


Figure 1. Increased money supply and macro-economic balance

본 연구는 총 6장으로 구성되어 있으며 1장은 연구의 배경과 목적, 범위로 구성하였다. 2장은 이론적 배경을 설명하고, 3장은 본 연구와 관련된 선행연구를 분석하였다. 4장은 변수와 OLS, LSTM모형을 설명하였으며, 5장은 각 모형에 따른 분석결과를 나타내고, 6장은 본 연구의 결론을 서술하였다.

## 2. 이론적 배경

주택가격의 변동에 영향을 미치는 거시경제와 관련된 선행연구들은 대부분 통화정책의 전달경로(Transmission Mechanism)에 관해 집중되어 있으나, 금리수준 및 가계의 순자산 가치를 변화시키는 전파경로 역시 통화정책의 전달경로와 동일하다고 볼 수 있다.<sup>6)</sup> 통화정책의 전달경로란 통화정책이 총생산과 국민소득에 영향을 주기 위해서 화폐공급 증가라는 화폐시장의 충격을 생산물 시장에 전달하는 수단을 말한다. 이에 본 연구는 IS-LM모형의 금리와 소득을 통한 통화정책의 전달경로인 <Figure 1>을 이용하여 설명하고자 한다.

통화정책의 전달경로에 따른 화폐공급의 증가를 통해 LM곡선은 이동하게 되어 새로운 균형점(E → E')이 형성된다. 그에 따라 실질금리가 하락하게 되며 투

자 수요의 증가로 인한 가계소득이 증가하게 된다. 이는 곧 주택시장의 주택수요 증가로 이어지며 수요증가에 따른 주택가격이 상승하게 되는 결과를 초래하게 된다.

이와 같이 경제 이론의 시각에서 경제변수의 변화는 어떤 균형점으로 향하는 힘이 존재한다고 가정하고 있으며, 이에 본 연구는 거시경제 변수에 따른 아파트 전세가격이 받는 영향을 확인하고 더 나아가 지역 별 아파트 전세가격의 예측모델을 구축하고자 한다.

### 3. 선행연구

본 장은 연구의 목적에 따라 거시경제변수가 주택의 전세가격에 미치는 영향에 관한 선행연구와 전세가격의 예측모델 구축에 관한 선행연구로 구성하고자 한다.

#### 3.1. 거시경제와 전세가격 간의 관계 분석

차경수·배정환(2019)은 일반적으로 주택가격이 거시경제학적 배경과 지역적인 공간에 따라 영향을 받아 변동하는 것으로 가정하였다. 이에 국내 주택가격의 변동특성을 분석하고 거시경제의 구조적 충격이 국내 주택가격의 변동에 미치는 효과를 분석하고자 하였다. 그 결과 전통적 금리경로와 신용경로에 의해 주택가격이 영향을 받는 것으로 나타났으며 그 원동력은 거시환경의 변화인 것으로 분석되었다.

금기조·김병량(2015)은 주가지수와 거시경제변수를 고려하여 금융변수를 선정하고, 각 변수들이 주택매매·전세 가격지수에 미치는 영향을 분석하였다. 해당 연구는 매매가격 데이터와 전세가격 데이터를 금융위기 전후로 구분한 후 벡터오차수정모형을 통해 각 변수들 간의 장기적 균형관계를 추정하였다. 분석 결과 주택전세가격지수에 영향을 미치는 요인을 보면, 금융위기 전에는 금리와 환율변수가 음의 영향을

미치고 있으며, HR, 전기의 전세가격지수, 금리는 양의 영향을 미치고 있음을 확인하였다. 또한 금융위기 후에는 CD(91)금리가 음의 영향을 미치고 있음을 확인하였다.

이근영·김남현(2016)은 거시·금융 변수를 통제변수로 투입하여 금리가 주택가격에 미치는 영향을 분석하였다. 이를 위해 금리와 주택가격을 기준으로 상승·하락기로 구분하였다. 분석결과, 전세가격 변화율이 매매가격 변화율보다 금리 상승기의 금리인상충격에 더 민감하게 반응함을 확인하였으며, CD 금리인상충격이 다른 단기 금리인상충격들에 비해 주택가격변화에 미치는 영향이 가장 크나 전반적인 효과는 금리 별로 크게 다르지 않음을 확인하였다.

문규현(2019)은 이자율과 소비자물가지수의 변화가 주택매매시장과 주택전세시장에 어떠한 영향을 미치는지 규명하고자 하였다. 시계열데이터 분석을 위한 VAR, VECM모형을 활용하였으며 CD금리와 KOFIX금리를 투입하였다. 모든 이자율이 하락하는 기간에 이자율의 변화가 전체주택시장의 가격변화에 더 많은 영향을 미치는 결과를 보였으며 이는 주택매매와 전세 수요자가 비교적 풍부한 유동자금을 적절히 활용하는 데 기인하는 것으로 보았다.

김종선(2021)은 주택담보대출시장의 금리변동성이 국내 주택매매·전세가격의 변동성에 미치는 영향을 분석하고자 하였다. 주택담보대출의 금리변동성과 주택전세가격의 변화간에는 유의미한 음의 관계로 나타났다. 이는 주택전세가격이 가계의 자산가격이 아닐지라도 주택 매매가격과 연계되어 움직이는 특성을 고려했을 때, 금리변동성이 주택전세가격 변화와 역동조화현상을 제시한다.

김현우·진경호·이교선(2012)은 주택 수요자 중심적인 입장에서 거시경제변수를 선정하고, 주택 전세가격에 미치는 영향을 실증 분석하였다. 분석 결과 주택의 전세가격에 영향을 미치는 경제변수인 가계대출금리가 상승할 경우, 주택을 매수하기 위해 대출을 할

용한 사람에게 대출상환에 대한 부담증가로 이어져 구입한 주택을 다시 팔고 전세로 주택을 마련하는 회귀현상이 나타날 수 있음을 제시하였다.

전해정·박현수(2012)는 대체재이론(‘주택의 매매가격이 전세가격에 영향을 미친다’)과 자산이론(‘주택의 전세가격이 매매가격에 영향을 미친다’)을 서로 비교하여 주택시장에 실질적으로 작용하고 있는 이론을 정의하고자 하였다. 특히 주요 거시경제변수인 이자율을 적용하고, 기간을 구분하여 실증분석하였다. 분석 결과 일방적인 방향으로의 흐름이 아닌 매매시장과 전세시장이 서로 상호작용하며 영향을 미치는 것으로 나타났다.

이희석(2007)은 계량경제모형인 VAR모형을 적용하여 주택매매지수와 주택전세지수에 영향을 미치는 요인과 관계를 분석하고자 하였다. 특히 거시경제변수를 고려하여 통화량, 환율, 경제활동 참가율 등을 이용하였다. 분석결과 경제활동참가율과 회사채 수익률, 건설수주는 주택매매지수에 영향을 미치는 것으로 나타났으며 그에 따라 주택매매시장에 따른 정책을 제시하고자 할 경우, 거시경제를 고려하여 상호 적용될 수 있는 방안을 마련해야 할 것이라고 주장하였다.

### 3.2. 주택가격의 예측모델 구축에 관한 연구

조보근·박경배·하성호(2020)는 지역 아파트 실거래가격지수를 활용하여 ARIMA, Random Forest, LSTM의 예측모델을 구축하고 각 예측모델의 성능 비교, 예측결과에 미치는 주요 변수와 아파트 실거래 가격지수와와의 관계를 파악하고자 하였다. 가장 높은 예측력을 나타낸 LSTM모델 예측 결과, 지역 별 아파트 매매현황과 통화량, 금리의 경우 전 지역에 걸쳐 주요 변수로 규명되어 부동산 예측모델에서 주요 변수로서의 활용 가능성을 확인하였다 또한 본 연구를 통해 전통적인 시계열 모형과 기계학습 기법 사이의 예측 성능을 비교 하였다는 점에서 학술적인 시사점을 제시

하였다.

이종민·이종아·정준호(2017)는 텍스트마이닝을 적용하여 뉴스데이터를 수집하고, 이를 통해 전세시장의 주택전세가격을 예측하는 모델을 구축하고자 하였다. 특히 텍스트마이닝 중 토픽모형을 적용하고 예측 모델은 ARIMA시계열 분석을 활용하여 연구의 방법론을 제시했다는 점에 의의가 있다. 분석결과 ‘전세’뉴스 토픽은 전세가격 변동률을 예측하는데 유의미한 결과가 있음을 확인하였으며 전세가격 예측의 근거를 마련하여 주거안정을 위한 정책을 제시할 수 있음을 주장하였다.

박노진(2017)은 독립성분분석을 활용하여 부동산 매매지수와 전세지수를 예측하고자 하였다. 전세가격과 매매가격을 두 개의 독립변수로 재구성하고 이를 통해 예측한 후 역변환을 시도하여 모델을 구축하였다. 그 결과 자기회귀이동평균모형과 예측력 검정을 시도하였으며 독립성분분석을 활용한 예측력이 더 높다는 것을 확인할 수 있었다.

본 연구의 차별성은 다음과 같다. 1) 연구의 공간적 범위를 전국, 서울, 광역, 지방으로 고려하여 분석하였고, 2) 전통적 계량모형인 OLS모형과 LSTM신경망 모형의 예측력을 비교하였다.

다음의 <Table 1>은 기존 선행연구의 모형과 변수를 정리하여 나타낸 것이다.

## 4. 자료 및 분석모형

### 4.1. 자료수집

본 연구의 분석을 위해 국내 금융위기를 기준으로 하여 2008년 1월부터 2022년 7월까지 총 175개의 월간 시계열 데이터를 구축하였다.

종속변수는 아파트 전세가격지수로 삼되, 전국, 서울, 광역, 지방으로 지역을 구분하여 설정하였다. 그중 광역은 인천, 대전, 울산, 대구, 부산, 광주의 아파트 전

Table 1. Summary of Models and Variables in Previous Studies

Author	Model	Variable
Keum Gi Jo. Kim Byung Ryang(2015)	VECM Impulse Response Analysis	KOSPI, CD(91), M2, Apartment selling price index Apartment Jeonse Price Index
Lee Keun Yeong Kim Nam hyun(2016)	VAR using Cholesky Decomposition	Apartment selling price index, exchange rate Apartment Jeonse Price Index, CPI, KOSPI
Moon Gyu Hyeon(2019)	VAR, VECM	Interest rate, CPI, Apartment selling price index Apartment Jeonse Price Index
Jo Bo-Geun, Park Kyung-Bae Ha Sung Ho(2020)	ARIMA, LSTM Random Forest	CPI, M2, CD(91), Apartment selling price index Apartment Jeonse Price Index
Kim Chong-Sun(2021)	Tgarch, Garch	Apartment selling price index Apartment Jeonse Price Index, Mortgage rates
Kim Hyun Woo, Chin Kyung Ho Lee Kyo Sun(2012)	OLS	Apartment selling price index, household loan interest rate Apartment Jeonse Price Index, the number of employed
Lee Hee Suk(2007)	VAR	Apartment selling price index, KOSPI, PPI M1, M2, Exchange rate
Cha Kyung Soo, Bae Jeong Hwan(2019)	SVAR	Housing Price, Interest rate, GDP, Investment, Consumption
Chun Hae Jung Park Heon Soo(2012)	VAR	Interest rate, Housing Price, Chonse Price
Pak Ro Jin(2017)	ARIMA, ICA	Apartment selling price index Apartment Jeonse Price Index
Lee Jong Min, Lee Jong Ah, Jeong Jun Ho(2017)	Topic Model. ARIMA	News data(words)

세가격지수를 나타내며, 지방은 서울, 수도권, 광역을 제외한 지역으로 정의된다.

독립변수는 거시경제를 고려하고 아파트 전세가격과 관련된 선행연구를 기반으로 하여 전산업 생산지수, 소비자물가지수, 금리, 주가지수로 선정하였다. 금리변수는 영업일을 기준으로 CD금리(91일)의 월 평균값을 투입하였으며 주가지수는 KOSPI(종가)를 적용하였다.

종속변수와 독립변수에 관한 내용 및 출처는 <Table 2>와 같다.

## 4.2. 분석모형

### 4.2.1. OLS

최소자승법(Ordinary Least Squared, OLS)은 종속변수가 두 개 이상의 독립변수에 의해 영향을 받을 때 회귀식의 잔차제곱합(Residual Sum of Squares, RSS)을 최소화하는 회귀계수를 추정·분석하는 방법을 말하며,<sup>7)</sup> 해당식은 Eq.(1)과 같다.

$$y = \beta_0 + \beta_1 y_{1i} + \beta_2 y_{2i} + \dots + e_i \quad (1)$$

Table 2. Variable description

Sortation	Variable	Content	Sources
Dependent variable (monthly, APT)	K_Index	National-Apartment Jeonse Price Index	KB Real Estate Data Hub  A Survey on Housing Prices
	S_Index	Seoul-Apartment Jeonse Price Index	
	M_Index	Metropolitan City-Apartment Jeonse Price Index	
	P_Index	Provincial-Rental Housing Price Index	
Independent variable	IAIP	Index of All Industry Production(2015=100)	Kosis
	CPI	Consumer Price Index(2020=100)	Kosis
	CD	Certificate of Deposit(91), %	Korea Bank
	KOSPI	Korea Composite Stock Price Index(1980=100)	Korea Bank

Eq.(1)의  $e_t$ 는 종속변수  $y$ 를 추정할 때 발생하는 오차를 말하며, 해당 값의 잔차제곱합이 최소가 되는 회귀계수인  $\beta$ 값을 추정하여 모형을 분석한다.

$\beta$ 는 독립변수가 1단위 증가 할 때 종속변수의 기대 변화량을 나타내는 회귀계수를 말한다. 특히  $\beta_0$ 는 모든 독립변수의 값이 0이 될 경우 종속변수의 기댓값인 절편계수이다.

본 연구는 시계열 데이터를 적용하기 때문에  $t$ 시점에서의 자료 간의 관계를 분석하는 OLS회귀식을 Eq.(2)와 같이 정의한다.

$$y = \beta_0 + \beta_1 y_t + \beta_2 y_{t+1} + \dots + e_t \quad (2)$$

Eq.(2)는 데이터가 Stationary하다는 조건을 충족해야 하기 때문에 통계적 가설 검정을 이용하여 정상성 여부를 확인한다.

#### 4.2.2. LSTM

순환신경망(Recurrent Neural Network, RNN)은 어떤 특정 부분이 반복되는 구조를 통해 순서를 학습하기에 효과적인 딥러닝 알고리즘으로서 시계열 등의

데이터를 다룰 때 주로 사용된다. RNN은 반복적인 순환경로를 통해 과거의 정보를 학습할 수 있는 점과 구조가 단순하여 쉽게 구현할 수 있다는 점에도 불구하고 시간 방향 오차역전파(Back Propagation Through Time, BPTT)에서 기울기 소실 혹은 기울기 폭발로 인해 과거의 학습 결과가 사라지는 장기 의존성(Long Term Dependency) 문제가 발생한다. 이러한 문제 해결을 위해 고안된 장·단기기억(Long Short Term Memory, LSTM)모델은 더 오랜 기간 정보를 저장하고, 데이터를 학습하는 동안 오류를 감소시키는 작업을 통하여 RNN의 장기 의존성 문제를 해결할 수 있다.

LSTM은 <Figure 2>과 같이 ① 망각게이트(Forget gate), ② 입력게이트(Input gate), ③ 출력게이트(Output gate)인 4개의 Layer(Sigmoid, Tanh)가 반복적으로 학습을 수행한다.

Eq.(3)의 망각게이트(Forget gate)는  $t-1$ 시점의 순환된 과거입력값인  $h_{t-1}$ 와 현재 입력값인  $x_t$ 를 고려하여 가중치를 주고, 이를 저장할 것인지 혹은 버릴 것 인지에 대한 여부를 판단한다.

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f) \quad (3)$$




Figure 2. Long Short Term Memory: LSTM  
Source: <https://www.turing.com>

Eq.(4), Eq.(5)의 입력게이트(Input gate)는 현재 정보의 저장여부를 결정하며 Sigmoid, Tanh 함수를 활성화함수로 적용한다.

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i) \quad (4)$$

$$\tilde{C}_t = \tanh(W_C \cdot [h_{t-1}, x_t] + b_C) \quad (5)$$

Eq.(6)은 과거의 정보를 업데이트 하는 과정을 나타내며 cell state과정으로도 불린다.

$$C_t = f_t \times C_{t-1} + i_t \times \tilde{C}_t \quad (6)$$

Eq.(7), Eq(8)은 어떤 값을 출력할지 결정하는 과정으로서 Tanh함수를 통해 최종 cell state을 산출한다.

$$o_t = \sigma(W_o [h_{t-1}, x_t] + b_o) \quad (7)$$

$$h_t = o_t \times \tanh(C_t) \quad (8)$$

### 4.3. 연구설계

본 연구는 거시경제변수가 지역별 아파트 전세가격에 미치는 영향을 분석하고, 거시경제 변수 중 금리와 아파트 전세가격 사이의 단변량 LSTM예측모델을 구

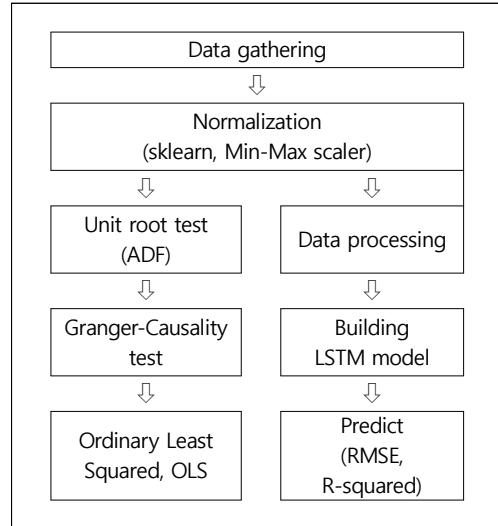


Figure 3. The research workflows

축하여 예측력을 검증하고자 한다.

이에 연구 설계 부분을 두 부분으로 구분할 수 있으며 그 내용은 <Figure 3>과 같다.

첫 번째, 선행연구를 기반으로 거시경제 변수를 선정하고 연구의 시간적 범위를 고려하여 2008년 1월부터 2022년 7월까지의 월별 시계열 데이터를 수집하였다.

두 번째, 각 데이터를 정규화(Normalization)한다. 이를 통해 데이터 값은 0과 1사이 범위로 변환되었으며 저자는 sklearn의 Min-Max Scaler를 적용하였다.

세 번째, 정규화된 시계열 데이터가 정상적인지 또는 단위근의 존재 확인 및 내생변수 간 인과관계를 파악하기 위해 Augmented-Dickey-Fuller Test, Granger Causality Test를 시행하였다. 이후 최소자승법(Ordinary Least Squared, OLS)에 적용하여 거시경제변수가 지역별 아파트 전세가격에 미치는 영향을 분석하고자 하였다.

네 번째로는 조절변수인 금리와 지역별 아파트 전세가격 간의 예측모델을 구축하고자 데이터 처리(Data processing)과정을 진행하였다. LSTM모델은 3




Figure 4. Data structure  
Source: <https://swlock.blogspot.com/>

차원 배열의 입력값을 사용하기 때문에 기존 데이터를 (Figure 4)와 같이 3차원(data-size, time-steps, input-dim) 가공하였다.

LSTM예측 모델을 구축(Building LSTM model)하는데 필요한 과정은 ① 아키텍처, ② 컴파일링, ③ 피팅으로 구성된다. 각 과정 내 가장 중요한 점은 하이퍼파라미터의 설정이다. 아키텍처 과정은 Layer 수와 Layer에 존재하는 뉴런의 수, 활성화함수를 설정하고, 컴파일링에서는 optimizer함수와 loss, metrics를 설정한다. 마지막으로 피팅과정은 모델의 학습부분으로서 epoch값을 설정한다.

예측력(Predict)검정을 위해 평균 제곱근 오차(Root Mean Squared Error, RMSE), 평균 절대값 오차(Mean Absolute Error, MAE)를 적용하였다.

## 5. 분석결과

### 5.1. 기초통계분석

종속변수인 아파트 전세가격지수 중 전국평균 74.51, 서울평균 68.53, 광역평균 75.91, 지역평균 83.55로 나타났다. 평균적으로 전국 대비 서울의 아파트 전세가격 지수가 가장 낮고, 지역의 아파트 전세가격 지수가 가장 높게 형성되어 있음을 확인할 수 있다.

Table 3. Basic Statistical Analysis

	n	mean	std	min	max
K_Index	175	74.51	14.38	49.60	100.90
S_Index	175	68.53	15.86	43.30	100.60
M_Index	175	75.91	14.10	50.60	100.50
P_Index	175	83.55	12.99	58.00	102.70
IAIP	175	99.99	9.14	77.40	118.00
CPI	175	94.11	6.53	79.50	108.70
CD	175	2.31	1.18	0.60	6.00
KOSPI	175	2071	416	1063	3296

독립변수인 전산업 생산지수의 평균값은 99.99, 최소값은 77.4, 최대값은 118로 나타났으며 소비자물가지수는 평균값 94.11, 최소값 79.5, 최대값 108.7로 나타났다. 또한 CD금리의 평균값은 2.31, 최소값은 1.18, 최대값은 6으로 나타났다. KOSPI지수는 평균값 2071, 최소값은 1063, 최대값은 3296으로 나타났다. (Table 3)는 연구에 투입된 변수의 기초통계분석을 보여준다.

### 5.2. 상관관계분석

본 장에서는 변수들 간 상관관계 분석을 시행하였다. 종속변수인 전국, 서울, 광역, 지역 아파트 전세가격지수에 따른 4개의 데이터에 따른 상관관계 분석은 (Table4~7)과 같다.

전국아파트 전세가격지수를 종속변수로 두고 상관관계 분석을 시행한 결과, 종속변수와 가장 높은 상관관계를 갖는 변수는 전산업생산지수(0.13)로 나타났다. 반면에 가장 낮은 상관관계를 갖는 변수는 소비자물가지수(0.06)로 나타났다.

서울아파트 전세가격지수를 종속변수로 두고 상관관계 분석을 시행한 결과, 종속변수와 가장 높은 상관관계를 갖는 변수는 전산업생산지수(0.13)로 나타났



Table 4. Correlation Analysis of K\_Index

	K_Index	IAIP	CPI	CD	KOSPI
K_Index	1.00				
IAIP	0.13	1.00			
CPI	0.06	0.05	1.00		
CD	0.10	0.11	0.04	1.00	
KOSPI	0.11	0.18	0.09	-0.13	1.00

Table 5. Correlation Analysis of S\_Index

	S_Index	IAIP	CPI	CD	KOSPI
S_Index	1.00				
IAIP	0.22	1.00			
CPI	0.13	0.04	1.00		
CD	0.09	0.11	0.05	1.00	
KOSPI	0.11	0.18	0.10	-0.14	1.00

다. 반면에 가장 낮은 상관관계를 갖는 변수는 CD금리 (0.09)인 것으로 나타났다.

광역시아파트 전세가격지수를 종속변수로 두고 상관관계 분석을 시행한 결과, 종속변수와 가장 높은 상관관계를 갖는 변수는 KOSPI주가지수(0.12)인 것으로 나타났다. 반면에 가장 낮은 상관관계를 갖는 변수는 CD금리(0.064)로 나타났다.

또한 다른 변수들에 반해 소비자물가지수는 종속변수와 음의 상관관계(-0.06)를 나타냈다.

지방아파트 전세가격지수를 종속변수로 두고 상관관계 분석을 시행한 결과, 종속변수와 가장 높은 상관관계를 갖는 변수는 CD금리(0.11)로 나타났다. 반면에 가장 낮은 상관관계를 갖는 변수는 전산업생산지수와 소비자 물가지수(0.06)로 나타났다.

독립변수 중 전산업생산지수와 KOSPI주가지수가 가장 높은 상관관계를 나타냈으며 소비자 생산지수와 CD금리가 가장 낮은 상관관계를 나타냈다.

Table 6. Correlation Analysis of M\_Index

	M_Index	IAIP	CPI	CD	KOSPI
M_Index	1.00				
IAIP	0.05	1.00			
CPI	-0.06	0.05	1.00		
CD	0.04	0.09	0.04	1.00	
KOSPI	0.12	0.18	0.08	-0.13	1.00

Table 7. Correlation Analysis of P\_Index

	P_Index	IAIP	CPI	CD	KOSPI
P_Index	1.00				
IAIP	0.01	1.00			
CPI	0.01	0.07	1.00		
CD	0.11	0.12	0.02	1.00	
KOSPI	0.06	0.17	0.07	-0.13	1.00

### 5.3. 단위근 검정

본 연구는 시계열 데이터의 정상성(Stationarity) 여부를 확인하기 위해 Dickey and Fuller(1979)의 ADF(Augmented Dickey and Fuller)와 PP(Phillips Perron)단위근 검정을 시행하였다.

Eq.(9)와 같이 단위근이 존재한다는 귀무가설을 세우고 P-value값에 따라 기각 또는 채택한다.

$$H_0 : \phi = 1 \tag{9}$$

ADF 분석결과 <Table 8>과 같이 종속변수인 전국, 서울, 광역, 지방의 아파트 전세가격지수와 독립변수인 전산업생산지수, 소비자물가지수, CD금리, KOSPI 지수 모두 0.05보다 큰 P-value값을 나타냈다. 즉, 단위근이 존재한다는 귀무가설을 기각할 수 없고 모두 불안정한 시계열로 분석되었다.

Table 8. ADF(Augmented Dickey and Fuller)

Sortation	variable	ADF	P-value
Dependent variable	K_Index	-0.196	0.938
	S_Index	0.770	0.991
	M_Index	-0.461	0.899
	P_Index	-0.574	0.712
Independent variable	IAIP	-0.843	0.806
	CPI	0.797	0.991
	CD	-1.083	0.379
	KOSPI	-1.897	0.334

Table 9. PP(Phillips Perron)

Sortation	variable	PP	P-value
Dependent variable	K_Index	-0.104	0.438
	S_Index	0.844	0.301
	M_Index	-0.455	0.719
	P_Index	-0.668	0.552
Independent variable	IAIP	-0.791	0.306
	CPI	0.783	0.221
	CD	-1.009	0.492
	KOSPI	-1.926	0.629

PP 분석결과 <Table 9>와 같이 종속변수인 전국, 서울, 광역, 지방의 아파트 전세가격지수와 독립변수인 전산업생산지수, 소비자물가지수, CD금리, KOSPI 지수 모두 0.05보다 큰 P-value값을 나타냈다. 즉, 단위근이 존재한다는 귀무가설을 기각할 수 없고 모두 불안정한 시계열로 분석되었다.

이에 각 내생변수에 대한 차분을 통해 귀무가설을 기각하고자 하였으며, 차수를 선정하기 위해 저자는 python의 statsmodels library에서 autolag 파라미터를 통해 AIC(Akaike Info Criterion)와 BIC(Bayes Information Criterion)를 확인하고자 하였다. 그 결과, <Figure 5>와 같이 종속변수를 포함한 4개의 데이터의 적정 차수는 2인 것으로 나타났다.

Table 10. A unit root test (Differencing)

Sortation	variable	ADF(diff)	PP(diff)
Dependent variable	K_Index	-3.592*	-2.492*
	S_Index	-3.884*	-3.522*
	M_Index	-3.491*	-3.723*
	P_Index	-2.661*	-2.419*
Independent variable	IAIP	-8.230*	-7.921*
	CPI	-1.154*	-1.932*
	CD	-3.649*	-3.244*
	KOSPI	-14.873*	-10.923*

<Table 10>은 2차 차분 시계열에 대한 ADF와 PP의 단위근 검정 결과를 나타내며 단위근이 존재하지 않음을 확인할 수 있다.

또한 변수의 다중공선성 여부를 확인하기 위해 VIF 값을 확인하였다. 그 결과, 변수 간 다중공선성은 존재하지 않는 것으로 나타났다.

또한 변수의 다중공선성 여부를 확인하기 위해 VIF 값을 확인하였다. 그 결과, 각 변수의 다중공선성 결과 값은 10 미만으로 나타나 다중공선성이 변수 간 존재하지 않는 것으로 나타났다.

독립변수 간의 상관성 검증 외에도 오차항의 독립성을 테스트하여 자기상관 여부를 판단하기 위해 저자는 Durbin-Watson Test를 시행하였다.

본 Durbin-Watson Test의 귀무가설은 ' $H_0$ : 오차항 사이에 자기상관관계가 없다.' 설정하였다.

각 Durbin-Watson Test의 결과값은 0~4범위 내에 있으며 P-value값을 통해 귀무가설을 채택할 수 있음을 확인하였다.

즉, 오차항 사이에 자기상관관계가 없음을 확인하였으며 그 결과는 <Table 11>과 같다.

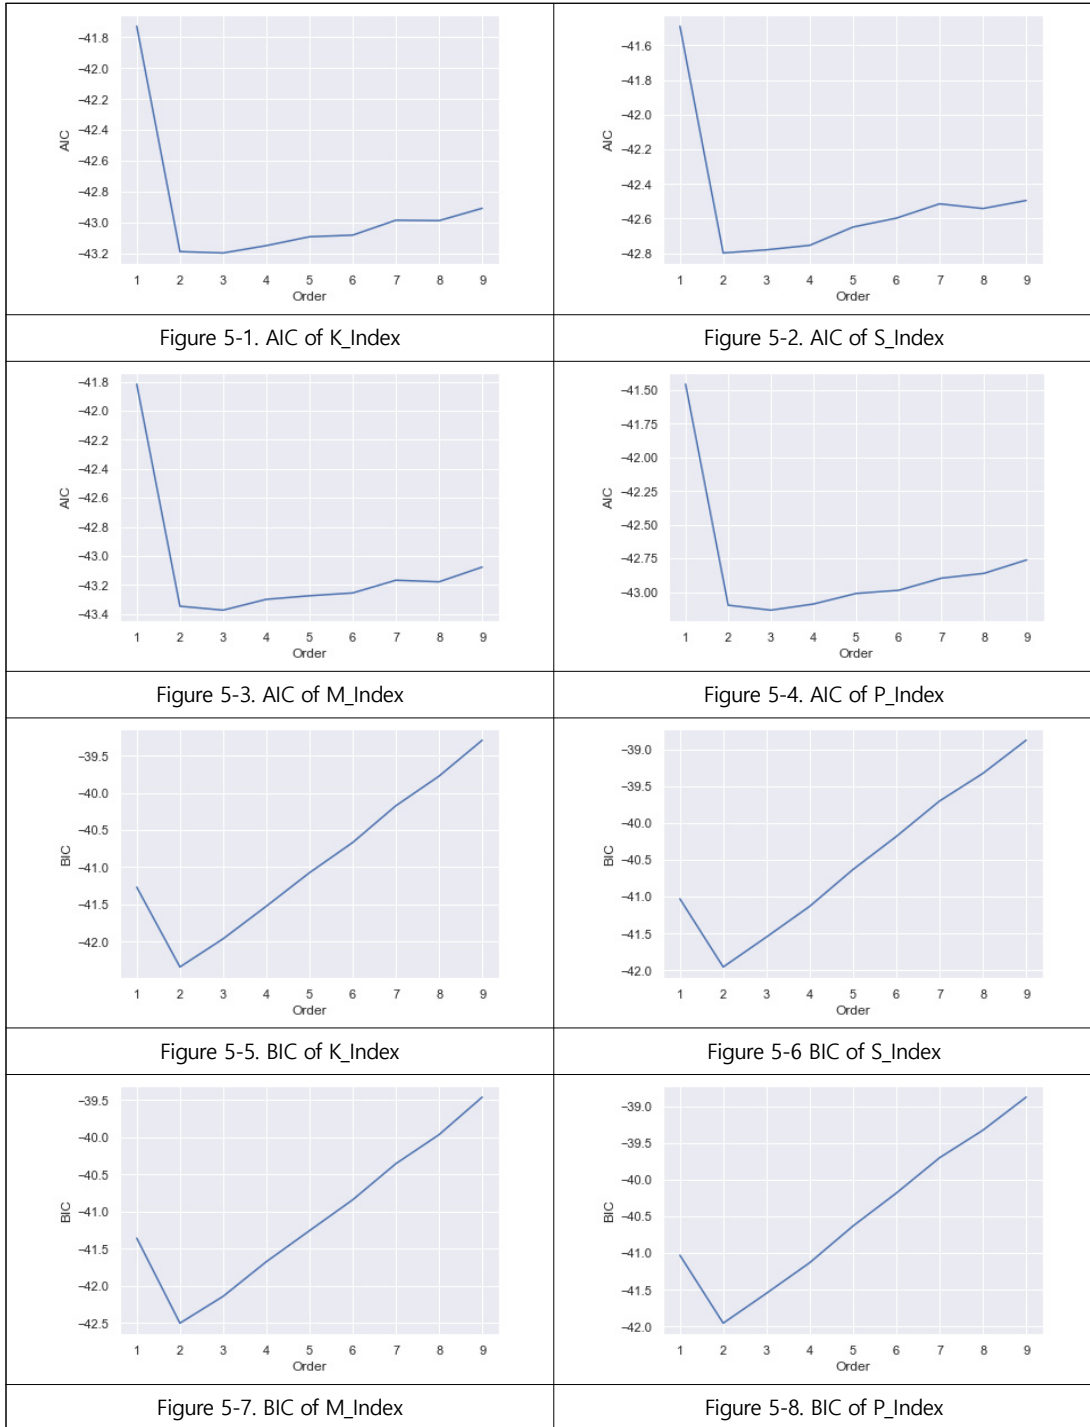


Figure 5. Result of AIC, BIC

Table 11. Durbin-Watson Test

Sortation	variable	DW	P-value
Dependent variable	K_Index	2.591	0.864
	S_Index	3.157	0.941
	M_Index	1.575	0.427
	P_Index	3.145	0.579
Independent variable	IAIP	1.272	0.962
	CPI	2.637	0.844
	CD	3.223	0.438
	KOSPI	2.135	0.677

#### 5.4. 인과관계 검정

각 내생변수들의 인과관계를 확인하기 위해 그랜저 인과관계 검정을 시행하였으며 그 결과는 <Table 12>과 같다.

인과관계 검정을 위해 먼저 그랜저 인과관계의 귀무가설을 설정한다. 귀무가설은 ‘x 변수가 y 변수에 대해 그랜저 인과(Granger-cause)하지 못한다.’이다.

귀무가설은 한 변수가 다른 변수를 예측하는데 도움이 되지 않는다는 해석을 둘 수 있으며 본 연구의 그랜저 인과관계 검정 귀무가설은 Eq.(10)과 같다.

$$H_0 : \lambda_1 = \lambda_2 = \dots = \lambda_q = 0 \quad (10)$$

인과관계 검정 결과, 광역 아파트 전세가격 지수 → CD금리, 지방 아파트 전세가격지수 → 전산업생산지수, CD금리 → 소비자물가지수는 귀무가설을 채택하였으며, 이는 광역 아파트 전세가격지수, 지방 아파트 전세가격지수, CD금리가 각각 CD금리, 전산업생산지수, 소비자물가지수의 원인변수가 아님을 뜻한다. 그 외 내생변수는 5% 유의 수준 내 유의미하며 그 기준은 p-value값과 같다.

Table 12. Granger Causality Analysis

	P-value	Lag	P-value
K_Index→IAIP	0.0104	IAIP→KOSPI	0.0291
K_Index→CPI	0.0182	CPI→K_Index	0.0001
K_Index→CD	0.0284	CPI→S_Index	0.0050
K_Index→KOSPI	0.0197	CPI→M_Index	0.0000
S_Index→IAIP	0.0061	CPI→P_Index	0.0001
S_Index→CPI	0.0127	CPI→IAIP	0.0001
S_Index→CD	0.0156	CPI→CD	0.0011
S_Index→KOSPI	0.0025	CPI→KOSPI	0.0125
M_Index→IAIP	0.0221	CD→K_Index	0.0001
M_Index→CPI	0.0103	CD→S_Index	0.0000
M_Index→CD	0.1000	CD→M_Index	0.0002
M_Index→KOSPI	0.0180	CD→P_Index	0.0055
P_Index→IAIP	0.1558	CD→IAIP	0.0006
P_Index→CPI	0.0052	CD→CPI	0.3433
P_Index→CD	0.0233	CD→KOSPI	0.0006
P_Index→KOSPI	0.0159	KOSPI→K_Index	0.0000
IAIP→K_Index	0.0002	KOSPI→S_Index	0.0000
IAIP→S_Index	0.0003	KOSPI→M_Index	0.0000
IAIP→M_Index	0.0000	KOSPI→P_Index	0.0000
IAIP→P_Index	0.0054	KOSPI→IAIP	0.0006
IAIP→CPI	0.0043	KOSPI→CPI	0.0001
IAIP→CD	0.0000	KOSPI→CD	0.0000

#### 5.5. 공적분 검정

본 연구는 시계열 데이터 간에 공적분이 존재하는지를 판단하기 위해 요한슨 검정을 시행하였다.

<Table 13>은 공적분에 대한 Johansen 검정결과를 나타낸다. 공적분 관계에 대한 귀무가설은 ‘ $H_0$ : 공적분 벡터가 존재하지 않는다.’이며, 검정을 위해 Trace 통계량과 Eigen통계량을 사용하였다.

각 모형의 검정통계량 값이 1% 유의수준의 임계값

Table 13. Values of teststatistic and critical values of test

K_Index				
	test	10pct	5pct	1pct
$r \leq 1$	11.46	22.76	25.32	30.45
$r \leq 0$	35.22	39.06	42.44	48.45
S_Index				
	test	10pct	5pct	1pct
$r \leq 1$	14.28	20.74	28.97	34.09
$r \leq 0$	34.16	38.77	44.58	49.97
M_Index				
	test	10pct	5pct	1pct
$r \leq 1$	10.48	15.57	21.57	22.24
$r \leq 0$	27.55	31.27	38.88	41.11
P_Index				
	test	10pct	5pct	1pct
$r \leq 1$	17.57	24.37	31.27	39.65
$r \leq 0$	34.57	41.57	42.87	47.37

보다 작으므로 귀무가설은 기각되지 않는다.

### 5.6. OLS 분석

앞서 AIC분석, BIC분석 결과에 따라 본 모형의 적정 시차는 2시차로 결정하고, 각 시차 별 OLS분석을 시행하였다. <Table 14-1>의 전국 아파트 전세가격지수의 함수를 보면 Lag1, 2에서 전국 아파트 전세가격지수와 소비자물가지수는 5% 유의수준 하에서 통계적으로 유의미한 영향을 주는 것으로 나타났다. 추정 함수에 대한 R-squared값은 0.7144으로 확인되었으며 추정회귀식은 Eq.(11)과 같다.

$$\begin{aligned}
 KIndex_t = & 0.004 + 1.754KIndex_{t-1} \quad (11) \\
 & - 0.764KIndex_{t-2} - 0.001IAIP_{t-1} \\
 & - 0.009IAIP_{t-2} + 0.072CPI_{t-1} \\
 & - 0.059CPI_{t-2} - 0.013CD_{t-1} \\
 & + 0.006CD_{t-2} + 0.002KOSPI_{t-1} \\
 & + 0.008KOSPI_{t-2}
 \end{aligned}$$

<Table 14-2> 서울 아파트 전세가격지수의 함수를 보면 Lag1,2에서 서울 아파트 전세가격지수와 소비자물가지수, CD금리는 5% 유의수준 하에서 통계적으로 유의미한 영향을 나타냈다.

추정 함수에 대한 R-squared값은 0.6981인 것으로 확인되었으며 추정회귀식은 Eq.(12)과 같다.

$$\begin{aligned}
 SIndex_t = & 0.004 + 1.729SIndex_{t-1} \quad (12) \\
 & - 0.738SIndex_{t-2} + 0.003IAIP_{t-1} \\
 & - 0.008IAIP_{t-2} + 0.069CPI_{t-1} \\
 & - 0.066CPI_{t-2} - 0.029CD_{t-1} \\
 & + 0.021CD_{t-2} + 0.002KOSPI_{t-1} \\
 & + 0.008KOSPI_{t-2}
 \end{aligned}$$

<Table 15-1>의 광역 아파트 전세가격지수의 함수를 보면 Lag1에서 광역 아파트 전세가격지수, 소비자물가지수가 5% 유의수준 하에서 통계적으로 유의미한 영향을 나타냈다. 광역 아파트 전세가격지수는 Lag2에서도 마찬가지로 5% 유의수준 하에서 통계적으로 유의미한 영향을 나타냈다.

추정 함수에 대한 R-squared값은 0.7249인 것으로 확인되었으며 추정회귀식은 Eq.(13)과 같다.

$$\begin{aligned}
 MIndex_t = & 0.002 + 1.769MIndex_{t-1} \quad (13) \\
 & - 0.779MIndex_{t-2} - 0.004IAIP_{t-1} \\
 & - 0.007IAIP_{t-2} + 0.047CPI_{t-1} \\
 & - 0.032CPI_{t-2} - 0.001CD_{t-1} \\
 & - 0.005CD_{t-2} + 0.004KOSPI_{t-1} \\
 & + 0.005KOSPI_{t-2}
 \end{aligned}$$

Table 14. OLS Analysis results(K\_Index, S\_Index)

14-1 OLS Analysis results(K_Index)						14-2 OLS Analysis results(S_Index)					
	K_Index	IAIP	CPI	CD	KOSPI		S_Index	IAIP	CPI	CD	KOSPI
K_Index (-1)	1.754*	-0.768*	-0.114	0.263	0.808	S_Index (-1)	1.729*	-0.348	-0.203	0.289	1.023*
	[41.041]	[-2.155]	[-0.923]	[0.752]	[1.416]		[36.918]	[-1.107]	[-1.881]	[0.940]	[2.046]
K_Index (-2)	-0.764*	0.755*	0.120	-0.272	-0.836	S_Index (-2)	-0.738*	0.355	0.212*	-0.311	-1.036*
	[-18.209]	[2.155]	[0.984]	[-0.792]	[-1.492]		[-15.914]	[1.138]	[1.978]	[-1.025]	[-2.093]
IAIP (-1)	-0.001	0.530*	0.005	0.209*	0.116	IAIP (-1)	0.003	0.544*	0.006	0.208*	0.098
	[-0.229]	[7.921]	[0.245]	[3.170]	[1.082]		[0.307]	[8.082]	[0.287]	[3.175]	[0.922]
IAIP (-2)	-0.009	0.239*	0.016	-0.138*	-0.056	IAIP (-2)	-0.008	0.247*	0.010	-0.128*	-0.045
	[-1.198]	[3.564]	[0.697]	[-2.098]	[-0.470]		[-0.855]	[3.639]	[0.453]	[-1.942]	[-0.423]
CPI (-1)	0.072*	0.446*	1.256*	0.134	-0.664*	CPI (-1)	0.069*	0.447*	1.251*	0.144	-0.662*
	[3.150]	[2.361]	[19.044]	[0.722]	[-2.197]		[2.440]	[2.348]	[19.109]	[0.781]	[-2.192]
CPI (-2)	-0.059*	-0.299	-0.293*	-0.249	0.613*	CPI (-2)	-0.066*	-0.328	-0.286*	-0.261	0.609*
	[-2.611]	[-1.579]	[-4.427]	[-1.340]	[2.015]		[-2.357]	[-1.727]	[-4.378]	[-1.413]	[2.016]
CD (-1)	-0.013	-0.007	-0.013	1.508*	-0.074	CD (-1)	-0.029*	-0.024	-0.008	1.502*	-0.078
	[-1.811]	[-0.119]	[-0.633]	[24.920]	[-0.755]		[-3.139]	[-0.407]	[-0.406]	[25.122]	[-0.806]
CD (-2)	0.006	-0.034	0.014	-0.546*	0.018	CD (-2)	0.021*	-0.011	0.008	-0.542*	0.032
	[0.919]	[-0.555]	[0.663]	[-1.340]	[0.187]		[2.268]	[-0.195]	[0.404]	[-9.193]	[0.325]
KOSPI (-1)	0.002	0.095*	0.035*	0.006	0.883*	KOSPI (-1)	0.002	0.087*	0.039*	0.002	0.879*
	[0.453]	[2.155]	[2.320]	[0.139]	[12.479]		[0.411]	[1.962]	[2.559]	[0.054]	[12.472]
KOSPI (-2)	0.008	0.011	-0.023	0.028	0.057	KOSPI (-2)	0.008	-0.002	-0.025	0.036	0.061
	[1.523]	[0.229]	[-1.419]	[0.531]	[0.754]		[1.153]	[-0.043]	[-1.590]	[0.808]	[0.821]
C	0.004*	0.026*	0.002	0.021*	0.055*	C	0.004*	0.026*	0.003	0.021*	0.052*
	[2.578]	[2.717]	[0.709]	[2.204]	[3.512]		[2.813]	[2.591]	[0.942]	[2.102]	[3.128]
No. of Equations		5				No. of Equations		5			
Log likelihood		3259.41				Log likelihood		3216.34			
AIC		-43.1886				AIC		-42.7988			
BIC		-42.3429				BIC		-41.9531			
R-Squared		0.7144				R-Squared		0.6981			

Table 15. OLS Analysis results(M\_Index, P\_Index)

15-1. OLS Analysis results(M_Index)						15-2. OLS Analysis results(P_Index)					
	M_Index	IAIP	CPI	CD	KOSPI		P_Index	IAIP	CPI	CD	KOSPI
M_Index (-1)	1.769*	-1.095*	-0.027	-0.136	0.620	P_Index (-1)	1.803*	-0.687*	0.195	0.459	0.399
	[42.959]	[-2.965]	[-0.210]	[-0.371]	[1.035]		[46.728]	[-2.225]	[1.817]	[1.515]	[0.801]
M_Index (-2)	-0.779*	1.063*	0.033	0.125	-0.653	P_Index (-2)	-0.810*	0.663*	-0.192	-0.445	-0.422
	[-19.343]	[2.939]	[0.262]	[0.348]	[-1.113]		[-21.379]	[2.186]	[-1.818]	[-1.494]	[0.863]
IAIP (-1)	-0.004	0.510*	0.007	0.197*	0.115	IAIP (-1)	-0.012	0.512*	0.017	0.224*	0.105
	[-0.557]	[7.615]	[0.336]	[2.967]	[1.061]		[-1.305]	[7.530]	[0.728]	[3.358]	[0.960]
IAIP (-2)	-0.007	0.240*	0.021	-0.151*	-0.064	IAIP (-2)	-0.008	0.224*	0.032	-0.124	-0.073
	[-1.074]	[3.645]	[0.861]	[-2.315]	[-0.606]		[-0.951]	[3.297]	[1.365]	[-1.870]	[-0.661]
CPI (-1)	0.047*	0.416*	1.256*	0.124	-0.651*	CPI (-1)	0.048*	0.489*	1.248*	0.104	-0.721*
	[2.264]	[2.224]	[18.969]	[0.667]	[-2.147]		[2.033]	[2.584]	[18.906]	[0.564]	[-2.364]
CPI (-2)	-0.032	-0.239	-0.298*	-0.223	0.614*	CPI (-2)	-0.027	-0.287	-0.304*	-0.272	0.691*
	[-1.511]	[-1.263]	[-4.448]	[-1.182]	[0.046]		[-1.153]	[-1.497]	[-4.551]	[-1.442]	[2.232]
CD (-1)	-0.001	-0.008	-0.018	1.525*	-0.054	CD (-1)	0.002	0.005	-0.031	1.492*	-0.049
	[-0.236]	[-0.144]	[-0.872]	[25.587]	[-0.559]		[0.366]	[0.080]	[-1.452]	[24.257]	[-0.489]
CD (-2)	-0.005	-0.036	0.019	-0.566*	-0.005	CD (-2)	-0.005	-0.038	0.031	-0.530*	0.009
	[-0.626]	[-0.611]	[0.947]	[-9.602]	[-0.062]		[-0.675]	[-0.609]	[1.474]	[-8.866]	[-0.100]
KOSPI (-1)	0.004	0.101*	0.033*	0.016	0.888*	KOSPI (-1)	0.006	0.091*	0.027	0.004	0.900*
	[0.857]	[2.318]	[2.166]	[0.382]	[12.509]		[1.118]	[2.089]	[1.805]	[0.106]	[12.802]
KOSPI (-2)	0.005	0.020	-0.023	0.033	0.057	KOSPI (-2)	0.002	0.012	-0.026	0.021	0.050
	[1.007]	[0.438]	[-1.468]	[0.726]	[0.768]		[0.496]	[0.262]	[-1.639]	[0.465]	[0.681]
C	0.002*	0.025*	0.002	0.023*	0.057*	C	0.008	0.020*	0.003	0.024*	0.058*
	[2.062]	[2.638]	[0.620]	[2.324]	[3.639]		[0.571]	[2.019]	[0.865]	[2.544]	[3.632]
No. of Equations			5			No. of Equations			5		
Log likelihood			3276.90			Log likelihood			3249.44		
AIC			-43.3469			AIC			-43.0983		
BIC			-42.5012			BIC			-41.9329		
R-Squared			0.7249			R-Squared			0.7051		

Table 16. Hyper-parameters of LSTM

Hyper parameter	input
Neuron	30
Hidden Layer	4
Optimizer	Adam
Metrics	Mean Absolute Error, MAE
Batch Size	203
Epoch	200
Active Function	Tanh
Loss Function	Mean Squared Error, MSE

〈Table 15-2〉의 지역 아파트 전세가격지수의 함수를 보면 Lag1에서 지역 아파트 전세가격지수, 소비자물가지수가 5% 유의수준 하에서 통계적으로 유의미한 영향을 나타냈다. 지역 아파트 전세가격지수는 Lag2에서도 마찬가지로 5% 유의수준 하에서 통계적으로 유의미한 영향을 나타냈다.

또한, 추정 함수에 대한 R-squared값은 0.7051으로 확인되었으며 추정회귀식은 Eq.(14)와 같다.

$$\begin{aligned}
 PIndex_t = & 0.008 + 1.803EIndex_{t-1} \quad (14) \\
 & - 0.81EIndex_{t-2} - 0.012IAIP_{t-1} \\
 & - 0.008IAIP_{t-2} + 0.048CPI_{t-1} \\
 & - 0.027CPI_{t-2} - 0.002CD_{t-1} \\
 & - 0.005CD_{t-2} + 0.006KOSPI_{t-1} \\
 & + 0.002KOSPI_{t-2}
 \end{aligned}$$

〈Table 14〉, 〈Table 15〉는 전국, 서울, 광역, 지방의 아파트 전세가격지수를 종속변수로 두고 전산업생산지수, 소비자물가지수, CD금리, KOSPI지수를 독립변수로 설정한 OLS분석 결과이다.

### 5.7. LSTM

본 연구는 전국, 서울, 광역, 지역 아파트 전세가격

Table 17. LSTM summary

Layer	Output Shape	Param
LSTM	(None, 20, 30)	4200
LSTM_1	(None, 20, 30)	7320
LSTM_2	(None, 30)	7320
Dense	(None, 1)	31
Total params	18,871	
Trainable params	18,871	
Non-Trainable params	0	

지수를 종속변수로 두고 거시경제 변수인 전산업생산지수, 소비자물가지수, CD금리, KOSPI주가지수를 독립변수로 선정하여 거시경제변수에 따른 지역별 아파트 전세가격을 예측하고자 하였다.

이에 저자는 keras클래스의 sequence, models, layers 서브패키지를 사용하여 LSTM예측모델을 구축하였다. 또한 Dense, Embedding, LSTM 클래스를 적용하여 인공신경망의 계층을 구현하고, LSTM레이어와 드롭아웃 정규화를 추가하여 3층의 Hidden Layer를 쌓아 아키텍처를 형성하고 모델의 학습환경에 대한 설정을 위한 컴파일링을 시도하였다. 컴파일링을 위한 모델의 optimizer는 adam함수, loss는 MSE, metrics는 MAE로 설정하였다. 마지막으로 구현된 LSTM모델을 데이터에 피팅함으로써 모델의 결과 및 예측값을 산출하였다.

본 연구에 적용된 LSTM예측 모델의 최적 하이퍼파라미터는 〈Table 16〉과 같다.

최적 하이퍼 파라미터를 적용하여 구축된 LSTM예측모델의 summary는 〈Table 17〉과 같다.

LSTM\_1층은 모든 time-step의 은닉 상태를 출력하기 때문에 (None, 20, 30)로 표시되었으며 내부 파라미터가 7,320개로 나타났다. LSTM\_2층의 출력 크



Table 18. Verification of Predictive power

Model	RMSE	MAE
K_Index	0.023	0.019
S_Index	0.021	0.017
M_Index	0.012	0.009
P_Index	0.008	0.006

기는 마지막 time-step의 은닉상태만 출력하기 때문에 (None, 30)으로 나타났으며, 마찬가지로 내부 파라미터는 7,320개이다.

Dense층의 Output Shape는 (None, 1), Param값은 31인 것으로 나타났다. 이는 최종 출력 계층의 node가 1개이고 LSTM과 출력 계층 사이에 적용되는 가중치 수는 31개를 말한다. 31개의 가중치 중 30개는 입력값에 대한 가중치이고, 1개는 평균값을 조절하는 가중치를 뜻한다.

Total params값은 18,871로 나타났으면 이는 Trainable params값과 동일하다.

LSTM모델의 예측 성능 검정을 위해 평균제곱근오차(Root Mean Squared Error, RMSE)와 평균절대값오차(Mean Absolute Error, MAE)를 이용하여 2008년 1월 부터 2022년 7월 까지의 예측결과인 예측 월별 데이터와 실제 월별데이터를 비교하였다. RMSE는 표준편차를 일반화시킨 척도로서 실제값과 예측 값의 차이가 얼마인지를 측정할 수 있다. Eq.(15)의  $X$ 는 실제 값,  $F$ 는 예측값,  $n$ 은 기간을 나타낸다.

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (X_t - F_t)^2} \quad (15)$$

MAE는 실제값인  $y_i$ 와 예측값인  $\hat{y}_i$ 의 차에 절대값을 취해 절대 오차를 계산하는 척도인 잔차 제곱합의 평균을 이용하여 계산하며 Eq.(16)과 같다.

Table 19. Result of R-Squared

Model	R-Squared
K_Index	0.993
S_Index	0.994
M_Index	0.998
P_Index	0.999

$$MAE = \frac{\sum_{i=1}^n |y_i - \hat{y}_i|}{n} \quad (16)$$

각 LSTM모델에 관한 예측 성능지표 결과는 <Table 18>와 같다. 예측 결과, 지방의 아파트 전세가격지수 LSTM모델의 RMSE값(0.008)과 MAE값(0.006)이 가장 낮게 나타나 지방 아파트 전세가격지수 예측력이 가장 높다.

R-Squared값은 분산 기반으로 종속변수에 대한 설명변수들의 설명력을 평가하며 1에 가까울수록 설명 정확도가 높음을 나타낸다. Eq.(17)의  $y_i$ 는 실제 값,  $\hat{y}_i$ 은 예측값,  $\bar{y}$ 는 평균값을 말한다.

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (17)$$

지역별 LSTM예측 모델의 R-Squared결과값은 <Table 19>과 같다.

전국 아파트 전세가격 LSTM모델의 R-Squared값은 0.993, 서울 아파트 전세가격 LSTM모델의 R-Squared값은 0.994, 광역 아파트 전세가격 LSTM모델의 R-Squared값은 0.998, 지역 아파트 전세가격 LSTM모델의 R-Squared값은 0.999인 것으로 나타났다. 4개의 예측모델은 모두 높은 설명력을 나타내고

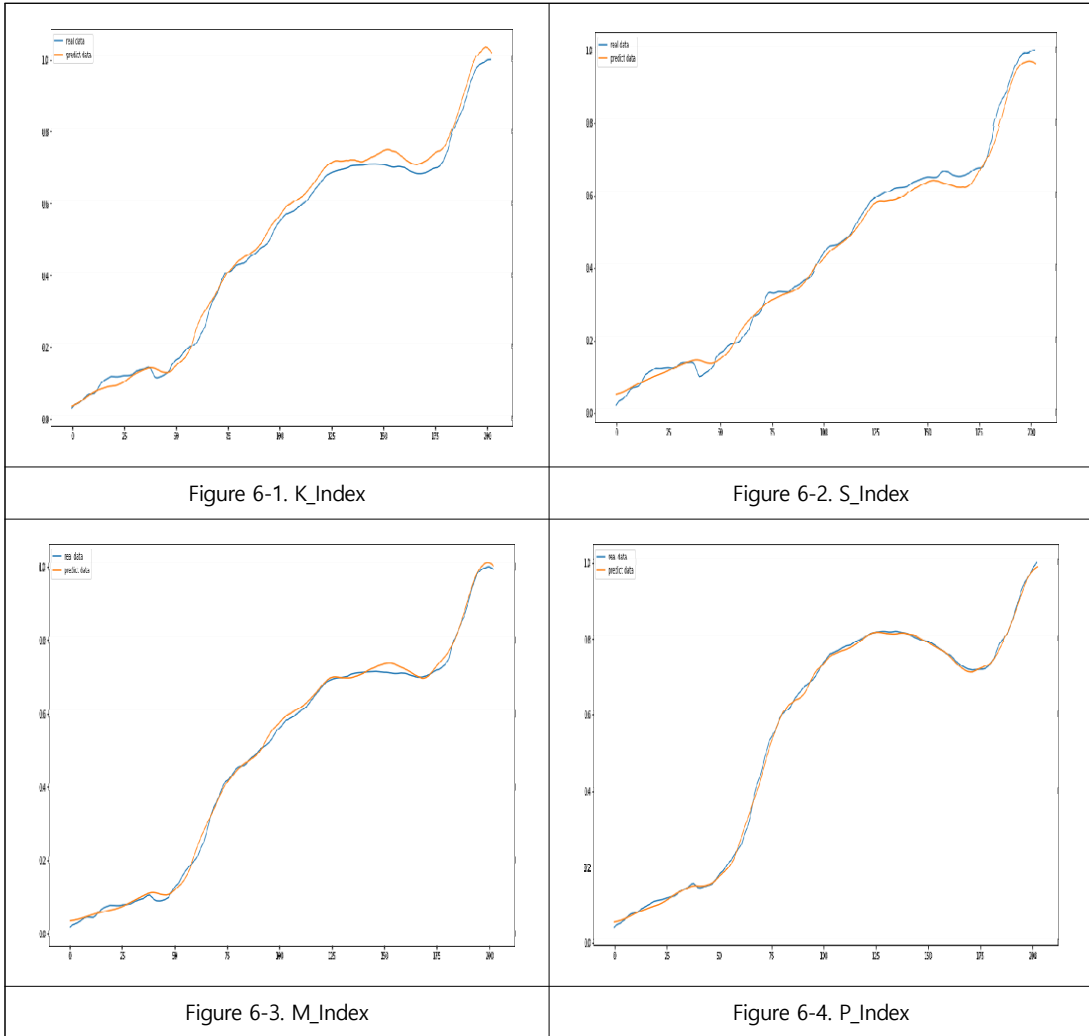


Figure 6. Comparison of read data and predict data

있으며 특히 지역 아파트 전세가격에 대한 각 독립변수들의 설명력이 가장 높은 것으로 나타났다.

〈Figure 6〉은 전국, 서울, 광역, 지역의 아파트 전세가격 지수의 LSTM예측모델 시각화를 나타낸다.

각 데이터를 모델에 학습시키고, 독립변수의 예측값과 종속변수의 실제값을 비교하여 나타냈다.

예측모델의 성능지표값이 의미하는 바와 같이 각 예측 결과는 매우 안정적으로 학습되었으며 모델 성

능이 높음을 확인할 수 있었다.

## 6. 결론

본 연구는 거시경제변수인 전산업생산지수, 소비자물가지수, CD금리, KOSPI지수가 전국, 서울, 광역, 지역으로 구분된 아파트 전세가격에 미치는 영향을 파악하고 LSTM(Long Short Term Memory)을 활용 지

역별 아파트 전세가격의 방법론적 예측모형을 제시하고자 하였다.

먼저, 거시경제변수가 지역 별 아파트 전세가격에 미치는 영향을 파악하기 위한 OLS분석결과에 따르면 Lag1, 2에서 전국 아파트 전세가격지수와 소비자물가지수는 전국 아파트 전세가격에 유의미한 영향을 주는 것으로 나타났고, 마찬가지로 Lag1,2에서 서울 아파트 전세가격지수와 소비자물가지수, CD금리는 서울 아파트 전세가격에 영향을 주는 것으로 나타났다.

또한, 광역 아파트 전세가격은 Lag1에서 광역 아파트 전세가격지수, 소비자물가지수가 유의미한 영향을 보였으며 지역 아파트 전세가격은 Lag1에서 지역 아파트 전세가격지수, 소비자물가지수가 유의미한 영향을 나타냄을 확인하였다.

두 번째, 거시경제변수에 따른 지역별 아파트 전세가격을 예측하고자 하였다. 시계열데이터에 적합한 신경망모형인 LSTM모형을 적용하였으며 예측모델의 예측 성능 검정을 위해 RMSE, MAE, R-Squared 값을 산출하였다.

본 연구에서는 keras클래스의 sequence, models, layers 서브패키지를 적용하여 LSTM인공신경망의 계층을 구현하고, LSTM레이어와 드롭아웃 정규화를 추가하여 3층의 Hidden Layer를 쌓아 아키텍처를 형성하였다. 또한 모델의 학습환경에 대한 설정을 위한 컴파일링을 시도하였으며 모델의 optimizer는 adam 함수, loss는 MSE, metrics는 MAE로 설정하였다. 마지막으로 구현된 LSTM모델을 데이터에 피팅함으로써 모델의 결과 및 예측값을 산출하였다.

예측력 검증 결과, 전국, 서울, 광역 지역의 아파트 전세가격 예측모델 중 지방 아파트 전세가격 LSTM 예측모델이 RMSE 0.008, MAE 0.006으로 가장 낮게 나타났고, R-Squared값은 0.999로 예측력이 가장 높았다. 또한 전국, 서울, 광역, 지역 아파트 전세가격의 VAR회귀식 R-Squared값(0.7051)과 비교했을 때에도 지역 아파트 전세가격 LSTM예측모델의 설명력이

더 높은 것으로 나타났다.

본 연구는 거시경제변수를 금융변수, 주가지수, 물가, 생산지수로 세분화하고, 전세가격을 지역별로 구분했다는 점에 차별성이 있다. 또한, 시계열 데이터를 활용한 통계적 분석방법과 딥러닝 분석모형을 적용하여 비교하고 특히 딥러닝을 활용한 주택가격 예측연구와는 다르게 저자는 아파트 전세가격을 시계열데이터로 구축하고 LSTM모형을 활용하여 예측모델을 구축했다는 점에서 차별성이 있다.

그러나 지역별 아파트 전세가격에 많은 영향을 미칠 수 있는 부동산 정책을 반영한 변수를 포함하지 못한 점은 연구의 한계라고 볼 수 있다.

향후 전세가격 관련 연구는 다양한 출처에서 부동산 시장예측에 활용 가능한 데이터나 전세 가격의 형성에 영향을 미치는 주요 정책변수들을 포함하여 딥러닝 기반의 발전된 모형을 적용한다면 더욱 의미 있는 결과를 얻을 수 있을 것으로 기대된다.

- 주1. 국토연구원(2022). 부동산시장 조사분석
- 주2. 한국부동산원 (2022.9.) 전국 아파트 매매가격 공시
- 주3. 뉴스핌 (22.10.05) '집값 떨어지는데 깡통전세 될라... 전세계약 앞둔 세입자들 '전전공공'
- 주4. 금기조, 김병량(2015) KOSPI지수와 금융변수가 주택 매매가격과 전세가격에 미치는 영향 분석.
- 주5. 김현우, 진경호, 이교선(2012) 주택전세가격과 거시경제변수간의 관계 연구.
- 주6. 김진유(2006) 신문기사가 부동산가격변동에 미치는 영향
- 주7. 김은미(2017) 기술금융이 은행의 성과에 미치는 영향 분석
- 주8. 차경수, 배정환(2019) 거시경제의 구조적 충격이 주택 시장에 미치는 영향.
- 주9. 민인식, 최필선(2016) STATA 시계열데이터 분석. ㈜지필미디어.

## 참고문헌

## References

국토연구원 부동산시장연구센터. 2022. 부동산시장 조사분석. 38.  
Korea Research Institute for Human Settlements.

2022. KRIHS. 38.
- 금기조, 김병량. 2015. KOSPI지수와 금융변수가 주택 매매가격과 전세가격에 미치는 영향 분석. *부동산학보*. 60: 182-195.
- Keum GJ, Kim BR. 2015. The Effects of Financial Market Variables and KOSPI on the Housing Price and the Rental Price. *Korea Real Estate Academy*. 60:182-195.
- 김종선. 2021. 주담대 금리변동성이 서울 주택가격 및 전세가격의 변동에 미치는 영향 분석. *무역보험연구*. 22(6):101-116.
- Kim JS. 2021. A Study on the Coupling Effect and Volatility Spillover Effect from Mortgage Loan Rate to Housing Sales Prices & Rental Prices in Seoul. *The Korean Academy for Trade Credit Insurance*. 22(6):119-144.
- 김진유. 2006. 신문기사가 부동산가격변동에 미치는 영향. *주택연구*. 14(2):39-63.
- Kim JY. 2006. Influence of Newspaper Articles on Real Estate Market. *Housing Studies*. 14(2): 39-63.
- 김현우, 진경호, 이교선. 2012. 주택 전세가격과 거시경제변수간의 관계 연구. *한국건설관리학회논문집*. 13(2):128-136.
- Kim HW, Chin KH, Lee KS. 2012. A Study on Relationship between House Rental Price and Macroeconomic Variables. *Korean Journal of Construction Engineering and Management*. 13(2):128-136.
- 문규현. 2019. 금리변화가 국내주택시장에 미치는 영향에 관한 연구. *금융공학연구*. 18(1):1-20.
- Moon GH. 2019. The Effects from Interest Rates to Korean House Markets. *The Korean Journal of Financial Engineering*. 18(1):1-20.
- 박노진. 2017. 부동산 매매지수와 전세지수 예측: 독립성분분석을 활용한 분석. *응용통계연구*. 30(2): 271-280.
- Park RJ. 2017. Forecasting Korean housing price index:application of the independent component analysis. *The Korean Journal of Applied Statistics*. 30(2):271-280.
- 이근영, 김남현. 2016. 금리와 주택가격. *경제학연구*. 64(4):45-82.
- Lee KY, Kim NH. 2016. Interest Rates and Housing Prices. *The Korean Economic Association*. 64(4): 45-82.
- 이종민, 이종아, 정준호. 2017. 뉴스 빅데이터를 이용한 전세 가격 예측. *부동산학보*. 69: 43-57.
- Lee JM, Lee JA, Jeong JH. 2017. The Jeonse Price Forecasting used by News Big Data. *Korea Real Estate Academy*. 69:43-57.
- 이희석. 2007. 거시경제변수가 주택매매 및 전세지수에 미치는 영향에 관한 연구. *경원대학교 대학원 박사학위논문*.
- Lee HS. 2007. A Study on the Influence of Macroeconomic Factors upon the Housing Transaction and the Jeonse Rental Index. Graduate school of Kyungwon University.
- 전해정, 박헌수. 2012. 거시경제 요인을 고려한 주택 매매·전세시장의 동학적 상관관계 분석. *서울도시연구*. 13(3):99-114.
- Chun HJ, Park HS. 2012. An Analysis on the Dynamic Correlation between Chonse Prices and Housing Prices Considering the Macroeconomic Variables. *The Seoul Institute*. 13(3): 99-114.
- 조보근, 박경배, 하성호. 2020. 기계학습 알고리즘을 활용한 지역 별 아파트 실거래가격지수 예측모델 비교. *정보시스템연구*. 29(3):119-144.
- Jo BG, Park KB, Ha SH. 2020. Comparative Analysis

for Real-Estate Price Index Prediction Models using Machine Learning Algorithms. <i>Journal of information systems</i> , 29(3):119-144.	2022년 10월 07일 원고접수(Received)
차경수, 배정환. 2019. 거시경제의 구조적 충격이 주택 시장에 미치는 영향. 국회예산정책처.	2022년 10월 17일 1차심사(1st Reviewed)
Cha KS, Bae JH. 2019. Effects of Structural Impacts on the Housing Market in Macroeconomy. National Assembly Budget Office.	2022년 10월 31일 2차심사(2st Reviewed)
	2022년 11월 22일 게재확정(Accepted)

### 초 록

본 연구는 거시경제변수인 전산업생산지수, 소비자물가지수, CD금리, KOSPI지수가 전국, 서울, 광역, 지역으로 구분된 아파트 전세가격에 미치는 영향을 파악하고 LSTM(Long Short Term Memory)을 활용하여 지역별 아파트 전세가격의 방법론적 예측모형을 제시하고자 하였다.

VAR분석결과에 따르면 Lag1, 2에서 전국 아파트 전세가격지수와 소비자물가지수는 전국 아파트 전세가격에 유의미한 영향을 주는 것으로 나타났고, 마찬가지로 Lag1,2에서 서울 아파트 전세가격지수와 소비자물가지수, CD금리는 서울 아파트 전세가격에 영향을 주는 것으로 나타났다. 또한, 광역 아파트 전세가격은 Lag1에서 광역 아파트 전세가격지수, 소비자물가지수가 유의미한 영향을 보였으며 지역 아파트 전세가격은 Lag1에서 지역 아파트 전세가격지수, 소비자물가지수가 유의미한 영향을 나타냄을 확인하였다.

LSTM예측모델 구축 결과, 지역 아파트 전세가격 예측모델의 RMSE 0.008, MAE 0.006, R-Squared값은 0.999로 예측력이 가장 높았다. 향후, 주요 정책변수들을 포함하여 딥러닝 기반의 발전된 모형을 적용한다면 더욱 의미 있는 결과를 얻을 수 있을 것으로 기대된다.

주요어 : 장단기 메모리 모형(LSTM), 벡터 자기회귀 모형(VAR), 아파트 전세가격, 소비자물가지수