Asian Tax Journal Vol.27, No.3 (October 2026) pp.65－90 https://doi.org/10.35850/KJTA.27.3.3
KOREAN ACADEMIC SOCIETY OF TAXATION ISSN 3140－6092

경기변동을 반영한 부동산 취득세 세수추계 모형의 비교 분석

: 사인파 · GRU · OLS 모형의 수도권-비수도권 적용을 중심으로

A Comparative Analysis of Real Estate Acquisition Tax Revenue Forecasting Models Incorporating Business Cycles

: Sinusoidal, GRU, and OLS Models Applied to Metropolitan and Non-Metropolitan Regions

임상빈* · 이승범**
Lim, Sang Bin · Lee, Seung Beom

〈요 약〉

본 연구는 현행 진도비 방식 세수추계의 구조적 한계를 극복하기 위해, 수도권 A와 비수도권 B를 대상으로 사인파 복합 모형(Sinusoidal Model) · GRU 머신러닝(Gated Recurrent Unit) · OLS 복합추계 모형의 세 가지 방법론을 공통기간(2016.01～2026.04, N＝124개월)에 각 지역에 독립적으로 추정하고, 모형의 예측 성능과 세수 추계 결과를 지역 간 · 모형 간 2차원으로 비교 분석하는 것을 목적으로 한다.

첫째, 전체 표본 적합도는 OLS 모형이 수도권 A MAPE 7.54%(R^2＝0.799) · 비수도권 B MAPE 13.50%(R^2＝0.557)로 양 지역 모두 최우수이다. 반면 연도별 홀드아웃 검증에서는 GRU가 2023년(수도권 A GRU 10.44% vs 사인파 19.37%, －8.93%p)과 2024년(GRU 8.04% vs 사인파 28.25%,

* 제1저자(First Author), 한국지방세연구원 연구위원, 법학박사, 경영학박사,
Research Fellow, Korea Institute of Local Finance, sbin.lim@kilf.re.kr
** 공동저자(Co-author), 한국지방세연구원 연구원,
Research Associate, Korea Institute of Local Finance, sb1024@kilf.re.kr

Received 17 July 2026 Revised 24 August 2026 Accepted 24 August 2026

−20.21%p)에서 명확한 우위를 보여, 구조충격 이후 회복 국면에서의 실용적 강점이 확인된다. 둘째, 사인파 파라미터에서 수도권 A(T_1=162.6개월, 추세 +8.09억/월)와 비수도권 B(T_1=85.4개월, 추세 −2.77억/월)의 순환 구조와 추세 방향이 근본적으로 상이하며, 수도권 A의 중주기 진폭(A_2=821.3억)이 장주기 진폭(A_1=631.5억)을 초과하여 5~7년 주기의 금리·정책 충격이 장기 대사이클보다 더 큰 세수 진폭을 형성함을 확인한다. 셋째, OLS 금리탄력성에서 수도권 A(−1,351억/%p)가 비수도권 B(−127.3억/%p)의 10.6배로 추정되어, 동일 통화정책의 비대칭 지역 효과가 실증된다. 2022~2023년 기준금리 2.75%p 인상에 따른 연간 세수 충격이 수도권 A 44,583억원 대 비수도권 B 4,202억원으로 추정된다. 넷째, 중과세더미의 유의미한 평균차이(전 4,908억 vs. 후 5,972억, t=−5.516***)가 확인되어 2020.07 중과세 시행이 수도권 A 세수 기반을 구조적으로 연간 약 12,768억원 상승시켰음이 검증된다.

부동산 취득세는 부동산시장 및 정책에 따라 세입이 크게 변동하여, 세입을 예측하는 것이 매우 어렵다. 따라서, 경기변동 및 구조적 충격 등을 반영하는 세수예측 모델 개발을 통해서 세수예측의 정확성을 제고하는 것이 필요하다.

<주제어> 취득세, 세수 추계, 사인파 모형, GRU, OLS, 공통기간, 수도권, 비수도권, 앙상블, 경기변동, 금리탄력성, 지방재정

<Abstract>

This study aims to overcome the structural limitations of the current proportional progress method in tax revenue forecasting by applying three methodologies−Sinusoidal composite model, GRU machine learning (Gated Recurrent Unit), and OLS composite forecasting model−to two independent cases：metropolitan A and non−metropolitan B. Using a common period (January 2016−April 2026, N=124 months), the models are estimated separately for each region, and their predictive performance and revenue forecasts are compared across both regions and models in a two−dimensional framework.

First, overall sample fit is highest for the OLS model, with MAPE of 7.54% (R^2=0.799) for metropolitan A and 13.50% (R^2=0.557) for non−metropolitan B. In contrast, annual holdout validation shows GRU superiority in 2023 (metropolitan A GRU 10.44% vs. Sinusoidal 19.37%, −8.93%p) and 2024 (GRU 8.04% vs. Sinusoidal 28.25%, −20.21%p), confirming its practical strength in recovery phases following structural shocks. Second, sinusoidal parameters reveal fundamentally different cyclical structures and trend directions：metropolitan A (T1=162.6 months, trend +8.09 billion KRW/month) versus non−metropolitan B (T1=85.4 months, trend −2.77 billion KRW/month). In metropolitan A, the medium−cycle amplitude (A2=821.3 billion KRW) exceeds the long−cycle amplitude (A1=631.5 billion KRW), indicating that 5−7 year interest rate or policy shocks generate larger revenue fluctuations than long−term macro cycles. Third, OLS interest rate elasticity is estimated at −1,351 billion KRW per percentage point for metropolitan A, 10.6 times greater than −127.3 billion KRW per percentage point for non−metropolitan B. Consequently, the 2.75 percentage point increase in the base rate during 2022−2023 is estimated to have reduced annual revenue by 44,583 billion KRW in metropolitan A and 4,202 billion KRW in non−metropolitan B, demonstrating asymmetric regional effects of monetary policy. Fourth, a significant mean difference in the surtax dummy (pre：4,908 billion KRW vs. post：5,972 billion KRW, t=−5.516***) confirms that the July 2020 surtax implementation structurally raised metropolitan A's annual revenue base by approximately 12,768 billion KRW.

Real estate acquisition tax revenue is highly volatile, driven by market dynamics and policy interventions, making accurate forecasting extremely challenging. Therefore, developing forecasting models that incorporate business cycles and structural shocks is essential to improve the accuracy and reliability of tax revenue projections.

<Key words> Acquisition Tax, Tax Revenue Forecasting, Sinusoidal Model, GRU Machine Learning, OLS, Unified Sample Period, Metropolitan Region, Non-Metropolitan Region, Ensemble Forecasting, Business Cycle, Interest Rate Elasticity, Local Public Finance

Ⅰ. 서 론

취득세는 부동산·차량 등 자산 취득 시 부과되는 지방세로서, 광역자치단체 세입 구조에서 단일 최대 세목을 구성한다. 그러나 취득세는 거래세적 특성으로 인해 부동산 경기, 금리 수준, 조세 정책 변화에 극도로 민감하여 세수 변동성이 여타 세목에 비해 현저히 크다.

실제로 수도권 A 자치단체 취득세는 2021년 96,887억원을 정점으로 2023년 52,501억원까지 불과 2년 만에 45.8%가 급감하였으며, 비수도권 B 자치단체 역시 동기간 40.0%의 낙폭을 기록하였다. 이러한 급격한 세수 변동은 현행 진도비 방식 세수추계의 구조적 한계를 여실히 드러낸다.

지방자치단체의 표준 추계 방식은 「T+1년 예상징수액=T년 예상징수액×추계변수±세입특수요인」의 구조로, 전년 추세의 단순 연장에 의존하기 때문에 기준금리 급등(2022년 0.5% → 3.25%)이나 COVID-19와 같은 구조적 충격 하에서 예측 정확도가 급격히 저하된다. 실제로 2021년 지방세 세수 오차율은 약 27%에 달한 바 있다(문소영·이서희, 2024).

특히 취득세는 경기 변동성에 가장 민감한 세목 중 하나로, 부동산 경기의 장기 순환 구조(대사이클)와 금리·정책에 의한 중단기 순환이 중첩되는 복합적 세수 동학을 지닌다. 이러한 경기변동 반영 추계 모형의 필요성은 최근 학계와 실무에서 공통으로 제기되고 있으나(한재명, 2022 ; 문소영·이서희, 2024), 취득세 단일 세목에 복수의 추계 방법론을 동시 적용하고 지역 간 비교를 수행한 연구는 아직 충분하지 않다.

이에 본 연구는 수도권 A 자치단체와 비수도권 B 자치단체의 취득세(부동산) 세수를 분석 대상으로 하여 다음과 같은 목적으로 연구한다. 첫째, 부동산 경기 사이클의 내재 구조를 삼각함수로 명시적으로 모형화하는 사인파 모형을 부동산 취득세 세수추계에 적용하여 그 효과성을 분석한다. 둘째, 문소영·이서희(2024)가 전국 지방세 총액에서 기존 추계 방식을 능가함을 실증한 GRU(Gated Recurrent Unit) 머신러닝 모형을 부동산 취득세에 적용하여 그 효과를 분석해 본다. 셋째, 이 두 모형과 기존의 기준금리·정책 더미 등 외생변수를 포함하는 OLS 복합추계 모형과의 성능 비교를 통해 경기변동을 반영한 최적의 세수추계 체계에 대한 정책적 시사점을 도출해 보고자 한다.

분석 대상은 수도권 A 자치단체 및 비수도권 B 취득세(부동산) 월별 징수액(2016.01~2026.04, 124개월)이며, 분석 방법론은 3가지로 구분된다. 첫째, 사인파 복합 모형은 FFT(고속 푸리에 변환)로 지배 주기를 탐색하고 NLS(비선형 최소제곱, Levenberg-Marquardt 알고리즘)로 파라미터를 추정하며, Pyhrr et al.(1990)의 이중 사인파 구조를 적용한다. 둘째, GRU 모형은 선행연구인 문소영·이서희(2024)의 최우수 하이퍼파라미터(batch=32, units=100, patience=10)를 그대로 채택하여 부동산 취득세에 적용하였다. 셋째, OLS 모형은 기준금리·중과세 더미·계절 더미 등 17개 외생변수를 포함하는 다중회귀 구조로 설계된다.

예측력 평가는 RMSE, MAPE, AIC/BIC, DM(Diebold-Mariano) 통계량을 사용하며, 실제 예산 편성 환경을 반영한 연도별 홀드아웃 검증을 병행한다. 본 연구는 사인파 복합 모형을 국내 연구에서 활용 사례가 드문 NLS 곡선적합(curve fitting) 기반의 실험적 세수추계모형으로서 적합성을 검증하고자 한다.

Ⅱ. 이론적 검토

1. 취득세 세수 추계 방법론

지방세 세수 추계에 관한 연구는 크게 세 흐름으로 구분된다. 첫째, 일반적으로 세수추계에 활용되는 진도비 방식이다. 진도비는 "취득세 전망액=전년도 과표×(1+가격증감률)×(1+거래증감률)×(전망년도 평균세율)" 산식에 의해서 추계한다. 취득세의 전망 단위는 토지, 건축물, 주택, 차량, 기계장비, 기타이고, 취득세 전망단위별로 거래량, 가격의 결정요인이 달라 부동산, 차량, 기타로 구분하여 전망모형을 구축하고 추정한다. 취득세는 부동산가격 및 거래량의 불확실성을 반영하여 시나리오(비관, 중립, 낙관) 분석으로 추정하기도 한다. 취득세에 대해 주택·토지·건축물·차량별로 거래신장률·가격상승률을 추계변수로 적용하며 단기 안정성은 있으나 구조 충격 반영 능력이 부족하다는 평가를 받는다(이석환, 2018).

둘째, 계량경제학적 시계열 방법론으로, 이은국(1994)의 ARIMA, 이석환(2018)의 지수평활·회귀분석, 이영희·조기현(1998)의 OLS·SUR 기법이 대표적이다. 이은국(1994)은 서울시 세입·세출에 Box-Jenkins 방법론을 적용하여 ARIMA(1,1,0) 모형이 단기 예측에서 안정적이나 제도 변화 이후 구간에서 과대추계 편의가 발생함을 확인하였다. 이석환(2018)은 지방세 세수예측방법을 비교 평가하여 지수평활법과 회귀분석의 결합이 최우수 성능을 보이나 취득세와 같이 비선형 순환 구조를 갖는 세목에는 한계가 있음을 지적하였다.

셋째, 머신러닝 방법론으로 정일환(2021)의 GRNN·KNN 적용, 문소영·이서희(2024)의 GRU 등 8종 알고리즘 비교 연구가 있다. 정일환(2021)은 GRNN(일반화 회귀신경망)과 KNN(K-최근

접이웃)을 서울시 세입추세 예측에 적용하여 경기 안정기에는 머신러닝이 전통 통계모형을 능가하나, 금리 급등과 같은 구조 충격 구간에서는 학습 데이터의 분포 이탈로 인해 성능이 급격히 저하됨을 확인하였다. 문소영・이서희(2024)는 전국 17개 시도・226개 시군구 지방세 자료(1994~2021년)에 GRU・LSTM・Transformer 등 8종 알고리즘을 적용한 결과, GRU(batch_size=32, units=100, patience=10)가 MAPE 6.4%로 기존 당초예산 방식(13.1%)을 최초로 능가하였으며, 총지방세수 수준에서 GRU의 단순성이 오히려 강점으로 작용함을 실증하였다.

2. 사인파 모형의 이론적 기반

가. 사인파 모형

사인파 모형(Sinusoidal Model)의 수학적 기원은 프랑스 수학자 Joseph Fourier(1822)의 삼각함수 급수 분해 이론으로 거슬러 올라간다. 푸리에는 자신의 저서 『열의 해석적 이론(Théorie Analytique de la Chaleur)』에서 임의의 주기 함수 f(t)를 서로 다른 주파수를 가진 무한 개의 사인・코사인 함수의 합으로 표현할 수 있음을 증명하였다.

$$f(t) = a_0/2 + \Sigma_n \ [a_n \cdot cos(2\pi nt/T) + b_n \cdot sin(2\pi nt/T)] \quad \text{식(1)}$$

여기서 T : 기본 주기,
$a_n \cdot b_n$: 푸리에 계수(각 주파수 성분의 기여도)

실제 경제 시계열은 유한 관측값을 가지므로 연속 푸리에 급수 대신 이산 푸리에 변환(DFT : Discrete Fourier Transform)을 적용한다. Cooley & Tukey(1965)는 DFT의 계산 복잡도를 $O(N^2)$에서 O(N log N)으로 획기적으로 줄이는 FFT(Fast Fourier Transform) 알고리즘을 개발하여 실용적 스펙트럼 분석을 가능하게 하였다.

나. 사인파 모형의 활용

부동산 시장에 사인파・순환 분석을 본격 적용한 연구로는 Pyhrr, Webb & Born(1990)이 선구적이다. 이들은 미국 부동산 투자 수익률 데이터에 사인파 함수를 직접 피팅하여 투자 주기를 모형화하는 방법론을 최초로 체계화하였으며, 이것이 본 연구 사인파 모형의 직접적 원형이다. DiPasquale & Wheaton(1992, 1994, 1996)은 임대시장・자산시장・신규 건설・재고의 사분면(Four-Quadrant) 연동 구조를 통해 부동산 시장의 내생적 순환 동학을 이론화하였다. Wheaton(1999)은 수요・공급 시차와 건설 지연이 4~7년 주기의 내생적 사이클을 발생시킴을 상업용 부동산 시장에서 실증하였다. Pyhrr, Roulac & Born(1999)은 글로벌 부동산 사이클을 미시적 물건 수준의 국지적 사이클과 거시경제 주도의 광역 사이클로 구분하는 분석 프레임을 정립하였다.

국내 선행연구의 대부분은 HP필터 기반 순환 성분 추출 후 VAR 분석으로 충격반응을 살피는 데 집중하며, 사인파 함수를 직접 피팅(NLS)하여 진폭·주기·위상 파라미터를 추정하는 방식은 국내 지방세 세수 추계 분야에서는 아직 시도된 바 없다.

3. GRU 머신러닝의 지방세 적용 연구

가. GRU 모형

GRU(Gated Recurrent Unit)는 Cho et al.(2014)이 제안한 순환신경망(RNN) 구조로, LSTM 대비 파라미터가 25% 적어 중소규모 시계열에서 과적합 위험이 낮다. 최종 은닉 상태 $h(t)=(1-z)\odot h(t-1)+z\odot \tilde{h}(t)$에서 갱신 게이트 z가 과거와 현재 정보의 혼합 비율을 결정함으로써 시계열의 장기 의존성을 학습한다.

나. GRU 모형의 활용

문소영·이서희(2024)는 전국 17개 시도·226개 시군구 지방세 1994~2021년 자료에 8가지 머신러닝 알고리즘을 적용하였다. 분석 결과, GRU(batch : 32, units : 100, patience : 10)가 MAPE 6.4%로 기존 당초예산 방식(MAPE 13.1%)을 최초로 능가하였다. 이 연구는 총 지방세수를 대상으로 하며, 지방세 세수추계에 새로운 추계방식인 GRU모형을 적용하였다는 의미가 크다. 그러나, 지방세 세수추계 실무는 세목별, 과세대상별 특성을 고려하여 세목별, 대상별 분석을 실시하고 있다는 점을 고려하면, 향후 GRU 모형을 세목별·과세대상별로 적용하는 연구가 필요해 보인다.

4. 선행연구 종합 및 차별성

지금까지 세수추계는 전통적인 방식의 OLS방식과 진도비 방식이 중심이 되었다. 이러한 실무를 반영해서, 선행연구도 주로 OLS와 지수평활 등 회귀분석 방식을 중심으로 연구가 수행되었다. 즉, 선행연구에서는 전통적인 방식으로 지방세 세목별 연구를 수행하였고, 부동산 취득세 단일 세세목에 사인파·GRU·OLS를 동시 적용하고 지역별 비교분석을 수행한 연구는 찾아볼 수 없다. 본 연구는 ① 부동산 취득세 세목 특화, ② 수도권과 비수도권 지방자치단체 각 1곳을 선정하여 지역 비교, ③ 세 가지 이질적 방법론의 동시 적용이라는 세 측면에서 기존 연구와 차별된다. 다만, AI 학습을 통한 커프피팅으로 실험적인 세수추계모형으로 적합성을 확인해 보고자 한다.

〈Table 1〉 Summary of Previous Research

Researcher & Year	Methodology	Subject	Key Findings & Implications
Ko, Young-sun(2000)	Reduced-form Time Series	National Taxes	Error correction model and moving average showed superior performance ; institutional changes were not reflected
Lee, Eun-guk(1994)	ARIMA(1,1,0)	Seoul Local Tax Revenue	Tendency to overestimate confirmed. Contributed to balanced-budget ARIMA modeling
Lee, Seok-hwan(2018)	Exponential Smoothing & Regression	Seoul Local Taxes	Exponential smoothing and regression performed best. Limitations in non-linear relationships exist
Pyhrr et al.(1990)	Sinusoidal NLS	Real Estate Returns	Modeled sinusoidal investment cycles. Served as a direct predecessor to this study
Han, Yong-seok & Lee, Joo-hyung(2009)	HP Filter	Korean Housing	Cycle length of 24.6 quarters (6.1 years). Medium-term cycle of 5.3 years verified
Jung, Il-hwan(2021)	ML(GRNN · KNN)	Seoul Local Tax Revenue	Machine learning superiority confirmed during stable periods. Limitations observed during volatile periods
Moon, So-young & Lee, Seo-hee(2024)	GRU and 8 other models	Nationwide Local Taxes	GRU outperformed collection progress rates with a MAPE of 6.4%
akridakis et al.(2018)	ML vs. Statistical Models	Various Time Series	Cases where traditional statistical models outperformed ML existed. Warned against over-relying on machine learning

Ⅲ. 자료의 기초 분석

1. 기초 통계

<Table 2>는 공통기간(2016.01～2026.04, N＝124) 기준 주요 변수의 기초 통계를 제시한다. 수도권 A의 취득세 월평균은 5,509.0억원으로 비수도권 B(708.1억원)의 7.8배에 달한다. 변이계수(CV)는 수도권 A가 21.4%(＝1,180.8/5,509.0)로 비수도권 B(25.1%)보다 낮아 절대 규모에서는 수도권 A의 변동이 훨씬 크지만 상대적 변동성은 비수도권 B가 더 높다. 최솟값(3,441.9억)과 최댓값(9,701.7억)의 비율이 2.82배에 달해 분석기간 내 수도권 A 세수의 극단적 변동폭을 확인할 수 있다. 비수도권 B는 최솟값 316.0억(2023.01)과 최댓값 1,176.0억(2021.09)의 비율이 3.72배로 수도권 A보다 더 큰 상대적 변동폭을 나타낸다.

기준금리의 기초통계에서 평균 1.972%에 대한 표준편차가 0.982로 변이계수가 49.8%에 달한다. 이는 분석기간 동안 최소 0.75%(2020～2021년 COVID 대응 제로금리 수준)에서 최대 3.50%(2023년 고금리 정점)까지의 4.75%p 범위를 경험하였음을 의미하며, 글로벌 금융위기 이후 가장 큰 금리 변동 사이클이 분석기간에 포함되어 있다. 중과세더미의 평균 0.565는 전체 관측기간의 56.5%(70개월)가 중과세 강화 이후 구간임을 나타낸다. 금리급등더미의 평균 0.419는 2022년 이후 52개월(41.9%)이 금리 급등기 구간으로 분류됨을 보여준다.

〈Table 2〉 Descriptive Statistics of Acquisition Tax Data for Capital A and Non-Capital B Local Governments

Variable	Mean	Standard Deviation	Min	Max	Observations
Capital Area A Acquisition Tax (100 million KRW)	5,509.0	1,180.8	3,441.9	9,701.7	124
Non-Capital Area B Acquisition Tax (100 million KRW)	708.1	177.8	316.0	1,176.0	124
Base Rate(%)	1.972	0.982	0.75	3.50	124
Trend Term (t, months)	61.5	35.8	0	123	124
COVID Dummy	0.065	0.247	0	1	124 (8 months＝1)
Heavy Taxation Dummy	0.565	0.498	0	1	124 (70 months＝1)
Rapid Rate Hike Dummy	0.419	0.495	0	1	124 (52 months＝1)

2. 시계열 특성

<Figure 1>은 수도권 A · 비수도권 B의 연간 취득세 실적과 A/B 배율 추이를 보여준다. 수도권 A는 2016년 50,714억원에서 2021년 94,840억원까지 5년간 87.0% 급증하였다가 2023년 62,215억원까지 34.4% 급락하였다. 비수도권 B는 2016년 9,994억원에서 2021년 10,009억원으로 사실상 정체하다가 2023년 6,007억원으로 40.0% 감소하였다. 주목할 점은 A/B 배율의 추이이다. 2016년 5.1배에서 2021년 9.5배로 확대된 후 2024년 8.3배로 일시 축소되었다가 2025년 9.4배로 다시 확대되는 추세를 나타낸다. 배율의 확대는 수도권 집중과 지방 세원 위축이라는 구조적 추세를 반영하는 것으로, 지방재정 불균형 심화의 직접적 지표이다.

〈Figure 1〉 Trends in Real Estate Acquisition Tax for Capital Area A and Non-Capital Area B

(Unit : 100 million KRW)

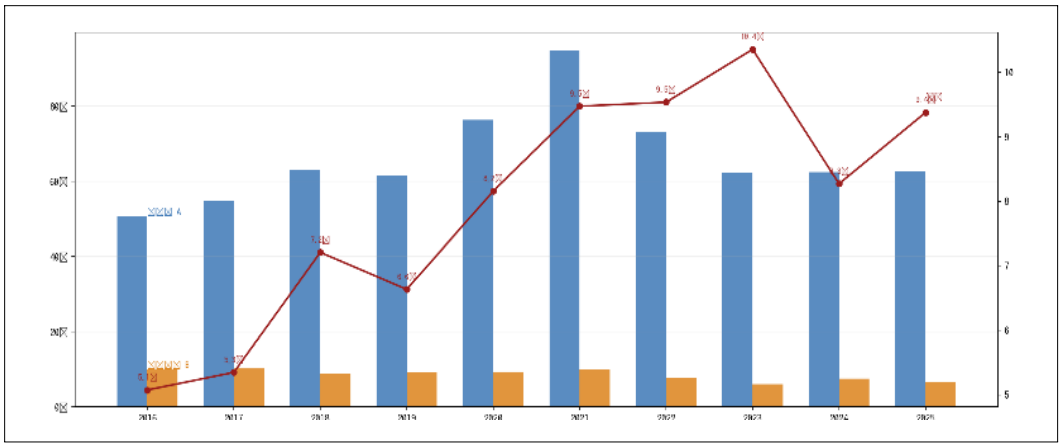

<Figure 2>의 월별 평균 세수 패턴에서 수도권 A는 12월(6,241억) · 8월(6,097억)이 높고 5월(5,117억) · 1월(5,294억)이 낮은 구조이다. 12월의 높은 세수는 연말 부동산 거래 집중 효과와 법인의 결산 전 취득 수요가 결합된 결과이다. 비수도권 B는 7월(806억) · 6월(792억)이 높고 9월(624억) · 10월(628억)이 낮아 수도권 A와 계절 패턴이 상이하다. 비수도권 B의 7월 성수기는 지역 제조업체의 하반기 부동산 취득 패턴을 반영하는 것으로 해석된다. 두 지역의 월별 패턴 차이는 사인파 모형에서 각 지역별로 독립적인 계절 벡터 γ_m를 산출해야 하는 이유이다.

〈Figure 2〉 Comparison of Monthly Average Acquisition Tax Collections

(Unit : billion KRW)

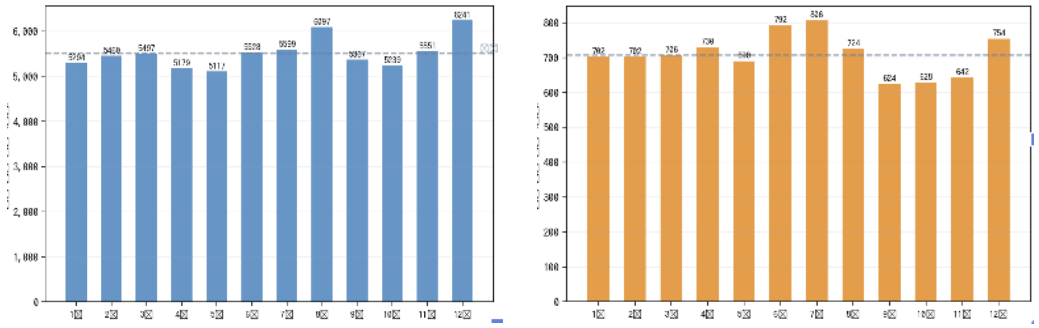

두 지역의 공통기간 피어슨 상관계수는 r=0.160(p=0.076)으로 통계적으로 유의하지 않다. 이는 수도권 A가 전국 금리 정책·수도권 부동산 대사이클에 주로 연동되는 반면 비수도권 B는 지역 고유 요인(제조업 경기·인구 이동)의 영향이 더 크다는 것을 의미한다.

3. 변수 상관관계

OLS 모형에 포함된 주요 변수 간 상관관계는 <Table 3>과 같다.

〈Table 3〉 Capital A Correlation Matrix of Key Variables

Variable		Acquisition Tax	Trend (t)	Interest Rate(r)	COVID	Heavy Taxation	Rapid Rate Hike
Dependent Variable	Capital A Acquisition Tax	1.000	0.2451**	−0.3053***	0.235**	0.4468***	−0.0645
Time Index	Trend(t)	–	1.000	0.707***	−0.073	0.859***	0.855***
Bank of Korea Base Rate	Interest Rate(r)	–	–	1.000	−0.380***	0.526***	0.886***
2020.03～10	COVID Dummy	–	–	–	1.000	−0.043	−0.278**
2020.07～	Heavy Taxation Dummy	–	–	–	–	1.000	0.746***
2022.01～	Rapid Rate Hike Dummy	–	–	–	–	–	1.000

수도권 A 취득세와 가장 높은 상관을 보이는 변수는 중과세 더미(r=0.447***)로, 2020.07 이후 다주택자 중과세 시행이 취득세 세수 수준에 가장 강하게 연관됨을 보여준다. 다중공선성 측면에서 금리(r)와 금리급등 더미(r=0.886***), 추세(t)와 중과세 더미(r=0.859***)의 상관이 매우 높다. 이러한 다중공선성이 OLS 추정에서 HAC(이분산·자기상관 일치) 표준오차 적용을 요구하는 이유이다.

취득세와 금리의 상관(r=−0.305***)은 유의한 음(−)의 관계로 금리 상승 시 취득세 감소를 확인한다. <Figure 3>의 산점도에서 수도권 A는 명확한 우하향 추세를 나타내는 반면 비수도권 B는 산포가 더 넓어 금리 이외 지역 고유 요인의 영향이 큼을 시각적으로 확인할 수 있다. 특히 금리 2.0~2.5% 구간에서 수도권 A의 세수 분산이 최대로 나타나는데, 이는 2020~2021년 거래 폭증과 2022년 급락이 동 구간에서 교차하기 때문이다.

〈Figure 3〉 Scatter Plot

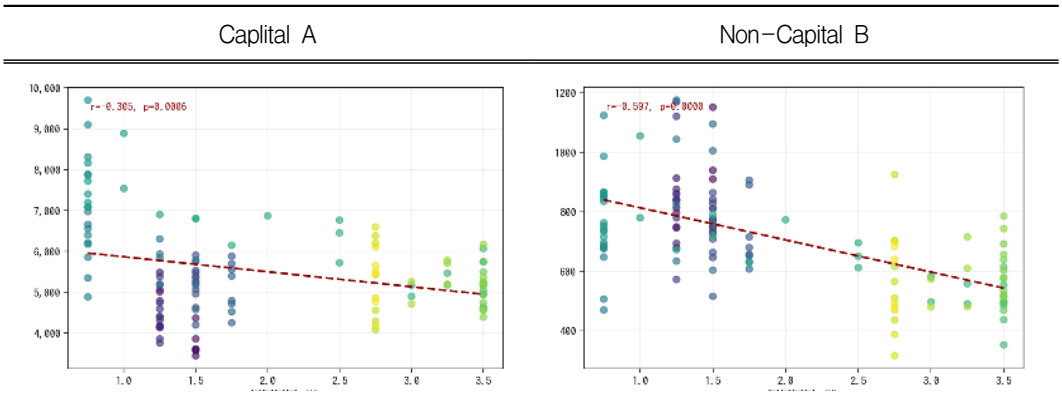

4. 평균 차이

<Table 4>는 주요 구조 변화 전후의 취득세 평균 차이 검정 결과를 제시한다. 이하의 평균 차이 검정은 시간추세·금리 변화 등 교란변수를 통제하지 않은 단순 비교이므로, 인과적 해석에는 Ⅳ장 OLS 추정 결과를 참조해야 한다.

첫째, 중과세 전(2016.01~2020.06, n=54)·후(2020.07~2026.04, n=70)의 평균 차이는 4,908.4억원에서 5,972.4억원으로 +1,064억원이다. 독립표본 t-검정 결과 t=−5.516(p<0.001)으로 통계적으로 강하게 유의하여 중과세 시행 이후 구조적 세수 수준 상승이 확인된다. 둘째, 금리급등 전(2016.01~2021.12, n=72)·후(2022.01~2026.04, n=52)의 평균 차이는 5,573.7억원에서 5,419.5억원으로 −154억원에 불과하며 t=0.713(p=0.477)으로 통계적으로 유의하지 않다. 셋째, 수도권 A와 비수도권 B의 분산 동질성 Levene 검정(F=99.469, p<0.001)은 두 지역의 세

수 분산이 통계적으로 강하게 이질적임을 확인한다.

〈Table 4〉 Results of Mean Difference Tests by Period

(Unit : billion KRW)

Comparison Category	Mean Before	Mean After	Difference	t-Statistic	P-value
Pre-Heavy Taxation (n=54) vs. Post (n=70)	4,908.4	5,972.4	+1064억	t=−5.516	$p<0.001^{***}$
Pre-Rapid Rate Hike (n=72) vs. Post (n=52)	5,573.7	5,419.5	−154억	t=0.713	p=0.477
Variance of Capital A vs. Non-Capital B	σ=1,180.8	σ=177.8	−	F=99.469	$p<0.001^{***}$

Ⅳ. 추계 모형 설계 및 추정 결과

1. 추계 모형 설정

가. 사인파 복합 모형

사인파 복합 모형은 취득세 세수의 시계열을 추세, 장주기 순환, 중주기 순환, 계절성의 네 성분으로 분해·재합산하는 구조로 설계한다.

$$Y(t)=A_1 \cdot sin(2\pi/T_1 \cdot t+\phi_1)+A_2 \cdot sin(2\pi/T_2 \cdot t+\phi_2)+\Sigma\gamma_m \cdot S_m(t)+\beta_0 + \beta_1 \cdot t+\varepsilon(t) \quad \text{식(2)}$$

사인파 모형의 파라미터는 8개(a_0, β_1, A_1, T_1, φ_1, A_2, T_2, φ_2)로 고정적이며, FFT로 초기값을 결정한 후 NLS(비선형최소자승법)로 수렴한다. NLS는 Jacobian 행렬 기반의 결정론적 최적화이므로 초기값이 동일하면 결과가 동일하다. 즉 재현성이 완전하며 하이퍼파라미터 선택 문제가 존재하지 않아, GRU 모형과 차별성을 갖는다. 추정은 3단계로 진행된다. 1단계에서는 선형 OLS로 장기 추세를 제거하고, 2단계에서는 FFT로 지배 주파수를 식별하여 초기 주기값(T_1, T_2)을 산출한다. 3단계에서는 scipy.optimize.curve_fit의 Levenberg-Marquardt 알고리즘으로 NLS 피팅을 수행한다. 계절 벡터는 NLS 잔차의 월별 평균으로 산출한다.

나. GRU 머신러닝 모형

GRU 모형의 이론적 구조는 제Ⅱ장 제3절에서 서술한 바와 같다. 본 연구에서는 문소영·이

서희(2024)의 최우수 하이퍼파라미터 조합(batch_size＝32, units＝100, patience＝10)을 그대로 채택하여 적용한다. 그 이유는 GRU는 하이퍼파라미터 조합에 대해 고감도(high sensitivity) 모형인데, 앞의 선행연구의 MAPE 범위가 0.06～10.31(LSTM 포함 시)로 동일 데이터・동일 아키텍처에서 파라미터 설정만으로 예측 정확도가 100배 이상 변동할 수 있기 때문이다. 본 연구에서 입력은 과거 12개월 취득세 시계열을 lookback 윈도우로 구성하고 Min-Max 정규화를 적용한다. 학습은 최대 300에포크, EarlyStopping(patience＝10), MSE 손실함수, Adam 옵티마이저로 진행하며, 예측은 1개월 단위 롤링 방식으로 수행한다.

다. OLS 복합추계 모형

OLS 복합추계 모형은 이영희・조기현(1998)과 이석환(2018)의 회귀 방식을 기반으로 설계한다.

$$Y(t) = \beta_0 + \beta_1 t + \beta_2 t^2 + \beta_3 \cdot 금리(t) + \beta_4 \cdot 금리^2(t) + \beta_5 \cdot COVID + \beta_6 \cdot 중과더미 + \beta_7 \cdot 금리급등더미 + \Sigma \beta_m S_m + \varepsilon(t) \quad \text{식(3)}$$

추정 결과, 금리 계수 $\beta_3 = -1{,}351.0$억/%p로 기준금리 1%p 상승 시 월 세수가 약 1,351억원 감소하며, 중과세 더미 $\beta_6 = +1{,}054.2$억으로 2020.07 이후 구조적 세수 수준 상승이 확인된다.

COVID 변수(2020.3～10, 8개월)은 사회적 거리두기 시행(2020.2.29)에 따른 거래 위축이 취득세의 신고납부 시차(취득일 기준 60일)를 거쳐 세수 계열에 반영되는 시점이 3월이기 때문에 3월부터로 설정하였다. COVID 변수(2020.3～10, 8개월)은 중과세더미(2020.8～)과 3개월 중첩이 있는데, 중첩기간이 길지 않은 점, 금리변수에서 코로나 저금리 상황이 반영된 점을 고려하자 별도에 중첩기간을 구분하지 않았다. 한편, 금리의 한계효과는 $\partial Y/\partial r = \beta_3 + 2\beta_4 \cdot r$로서 금리 수준에 따라 변동한다. HAC(이분산・자기상관 일치) 표준오차를 적용하여 시계열 자기상관에 강건한 추론을 확보하였다.

2. 사인파 모형 적용

가. 수도권 A

<Table 5>에서 수도권 A의 사인파 파라미터를 살펴보면, 먼저 장주기와 관련하여 진폭 $A_1 = 631.5$억・주기 $T_1 = 162.6$개월(13.6년)이 추정되었다. $T_1 = 13.6$년은 슘페터(Schumpeter, 1939)의 주글라르 순환(7～11년)보다 길어, 수도권 부동산 시장이 단순 투자 사이클을 넘어 재개발・재건축 인허가 주기, GTX 등 광역교통 개발사업, 3기 신도시 공급 타임라인 등 수도권 고유의 장기 구조 요인이 결합된 대사이클을 형성하고 있음을 시사한다. 한용석・이주형(2009)이 HP필터

로 추정한 전국 주택가격 순환주기 6.1년이 중주기 수준이라면, 수도권 A의 13.6년 장주기는 그보다 한 차원 높은 대사이클 구조를 반영하는 것이다.

중주기와 관련하여 진폭 A_2=821.3억 · 주기 T_2=81.3개월(6.8년)이 추정되었다. 주목할 점은 A_2=821.3억이 A_1=631.5억을 초과한다는 것이다. 이는 5~7년 주기의 금리 · 정책 주도 중기 순환이 장기 대사이클보다 오히려 더 큰 세수 진폭을 만들어낸다는 사실을 의미한다. 실제로 2020~2021년의 기준금리 0.5% 초저금리 기반 거래 폭증과 2022~2023년 기준금리 3.25% 급등에 따른 급락이 이 중주기 진폭을 극대화한 주원인이다.

추세 기울기 β_1=+8.09억/월은 분석기간 동안 수도권 A 취득세 세수 기반이 매월 구조적으로 8.09억원씩 성장하고 있음을 의미한다. 이를 연간으로 환산하면 약 97억원의 기저 성장에 해당하며, 분석기간 전체(123개월)로는 약 995억원의 추세 상승이 이루어진 것이다. 전체 표본 적합도는 RMSE 720.0억 · MAPE 10.37% · R^2=0.6281로, 취득세 세수 변동의 62.8%를 사인파 순환 구조와 선형 추세로 설명한다. 나머지 37.2%는 금리 충격 · 정책 변화 등 외생 요인에 기인하며, 이것이 OLS 모형이 더 높은 R^2를 달성하는 이유이다.

나. 비수도권 B

비수도권 B의 장주기 T_1=85.4개월(7.1년)은 수도권 A(162.6개월)의 절반 수준으로, 슘페터의 주글라르 순환(7~11년) 하한에 근접한다. 이는 비수도권 B의 취득세 세수가 수도권 대사이클이 아닌 전국적 기준금리 사이클에 더 직접적으로 연동됨을 시사한다. 중주기 T_2=46.0개월(3.8년)은 키친 순환(3~4년)에 근접하여, 비수도권 지역 제조업체의 재고 · 설비 투자 사이클과 주택 거래가 연동되는 구조를 반영한다. 두 지역 장주기의 차이(77.2개월)가 두 지역 중주기 차이(35.3개월)보다 2.2배 크다는 사실은, 대사이클 수준에서의 지역 간 구조 차이가 더욱 근본적임을 보여준다.

추세 기울기 β_1=−2.77억/월은 수도권 A(+8.09억/월)와 방향이 정반대이다. 비수도권 B는 매월 취득세 세수 기반이 구조적으로 2.77억원씩 감소하고 있으며, 이를 연간으로 환산하면 약 33억원, 분석기간 전체(123개월)로는 약 341억원의 추세 하락이 이루어진 것이다. 이 음(−)의 기울기는 비수도권 B의 인구 감소(2022년 이후 연간 순이출 지속), 조선 · 기계 중심 제조업의 구조적 정체, 지역 내 부동산 수요 기반 약화를 직접 반영한다. 전체 R^2=0.5117은 사인파 모형이 비수도권 B 세수 변동의 51.2%만을 설명하여, 나머지 48.8%가 지역 고유 외생 충격(지역 산업단지 이전 · 뉴딜사업 · 조선업 수주 사이클 등)에 기인함을 나타낸다.

〈Table 5〉 Comparison of Sinusoidal Model Parameters

Category	Capital A	Non-Capital B	Interpretation
Long-term Amplitude A_1	631.5b KRW	54.5b KRW	Region A amplitude is 11.6x (Exceeds scale proportion)
Long-term Period T_1	162.6M(13.6Y)	85.4M(7.1Y)	A : Capital area macro-cycle B : Close to Juglar cycle
Medium-term Amplitude A_2	821.3b KRW	71.8b KRW	$A_2 > A_1$(Capital Area A) : Greater medium-term shock
Medium-term Period T_2	81.3 M(6.8Y)	46M(3.8Y)	B : Close to short-term Kitchin cycle
Trend Slope β_1	+8.09b KRW/M	-2.766b KRW/M	Opposite directions (Region B : Structural decline)
Trend Intercept β_0	5,011.8b KRW	538.3b KRW	Level as of January 2016
Residual σ	720b KRW	124.2b KRW	Prediction uncertainty benchmark (95%CI = $\pm 1.96\sigma$)
Overall RMSE	720b KRW	124.2b KRW	In-sample fitting error
Overall MAPE	10.37%	14%	B has higher prediction difficulty
Overall R^2	0.6281	0.5117	A shows superior explanatory power

3. GRU 모형 적용

가. 수도권 A

<Table 6>에서 수도권 A GRU 모형의 전체 표본 성능은 RMSE 722.3억 · MAPE 10.11% · R^2 =0.6002로, 사인파(RMSE 720.0억 · MAPE 10.37% · R^2=0.6281)와 유사한 수준이다. 표본 내 성능에서 두 모형의 차이는 통계적으로 유의하지 않다(DM 검정 $p > 0.10$). 그러나 이것이 예측 성능에서도 동일함을 의미하지는 않는다. 연도별 홀드아웃에서 GRU는 2023년(10.44% vs 사인파 19.37%)과 2024년(8.04% vs 사인파 28.25%)에서 사인파를 압도한다. GRU의 총 학습 파라미터는 30,701개(리셋게이트 10,200+갱신게이트 10,200+후보상태 10,200+Dense 101)이며, 수도권 A의 Min-Max 정규화 범위는 3,441.9억(→ 0.000)에서 9,701.7억(→ 1.000)이다.

나. 비수도권 B

비수도권 B GRU 모형은 RMSE 147.4억 · MAPE 16.97% · R^2=0.3101로, 사인파(RMSE 124.2억 · MAPE 14.0% · R^2=0.5117) 대비 전 지표에서 열위이다. 특히 R^2=0.310은 수도권 A GRU (0.600) 대비 절반 수준에 불과하다. 이 성능 저하는 비수도권 B의 GRU 학습 시퀀스(112개) 중 2022~2023년의 급락 구간이 상당 비중을 차지하여, 모형이 안정적 상승 · 하락 패턴을 학습하

기보다 충격 이후의 낮은 수준을 연장하는 경향을 갖게 되었기 때문이다. 또한 비수도권 B 취득세 최댓값(1,176억)과 최솟값(316억)의 비율(3.72배)이 수도권 A(2.82배)보다 커서 Min-Max 정규화 후에도 이상값 영향이 더 크게 남는 구조적 한계가 있다.

〈Table 6〉 GRU Model Design and Performance Comparison

Category	Capital A	Non-Capital B	Design Rationale & Remarks
Input Variable	Univariate Acquisition Tax lookback=12		No exogenous variables included ; pure time-series pattern learning
GRU units	100	100	Best combination from Moon & Lee (2024)
batch_size	32	32	Applied identical hyperparameters
patience	10	10	EarlyStopping criterion
Training Sequences	112(124−12)	112	Identical common period
Total Parameters	30,701	30,701	3 gates×10,200+Dense 101
Normalization Min	3,441.9b KRW	316.0b KRW	Independent scaling per region
Normalization Max	9,701.7b KRW	1,176.0b KRW	Inverse transformation required post-prediction
Overall RMSE	722.3b KRW	147.4b KRW	In-sample fitting error
Overall MAPE	10.11%	16.97%	GRU performance constraint for Region B
Overall R^2	0.6002	0.3101	Low R^2 in Region B (affected by shock-period learning)

4. OLS 모형 적용

가. 수도권 A

<Table 7>에서 수도권 A OLS 모형의 핵심 계수를 살펴보면, 기준금리 계수 β_3=−1,351.0억/%p가 가장 주목할 만하다. 이는 기준금리 1%p 상승 시 수도권 A 취득세가 월 1,351억원 감소함을 의미하며, 연간으로 환산하면 16,212억원의 세수 감소 효과이다. 다만, 금리제곱 항(β_4=+75.6억/%²)이 유의하므로 실제 한계효과는 금리 수준에 따라 체감한다. 2022~2023년의 기준금리 인상폭(2.75%p)을 적용하면 OLS 모형이 추정하는 연간 세수 감소 효과는 44,583억원에 달하며, 이는 실제 2021년(94,840억) 대비 2023년(62,215억)의 32,625억원 감소와 근사한 수준이다.

COVID더미 계수(β_5=−989.2억)는 COVID 충격 8개월 동안 월 989억원의 세수 감소가 발생하였음을 의미하며, 중과세더미 계수(β_6=+1,054.2억)는 2020.07 이후 월 1,054억원의 구조적 세수 수준 상승을 나타낸다. 전체 표본 적합도는 RMSE 530.0억 · MAPE 7.54% · R^2=0.7985로 세 모형 중 최우수이다. R^2=0.799는 OLS가 수도권 A 취득세 변동의 79.9%를 설명함을 의미하며, 금리 · 정책 더미 등 외생변수가 세수 변동의 핵심 원인을 직접 포착하는 효과이다.

나. 비수도권 B

비수도권 B의 OLS 추정에서 가장 주목할 발견은 금리계수 β_3=−127.3억/%p로 수도권 A(−1,351.0억)의 10.6분의 1에 불과하다는 것이다. 기준금리 1%p 상승 시 비수도권 B의 연간 세수 감소 효과는 1,528억원(=127.3×12)으로, 수도권 A(16,212억)와의 격차가 10.6배에 달한다.

이 차이가 의미하는 바는 명확하다. 동일한 한국은행 기준금리 인상이 두 지역에 10.6배의 비대칭적 충격을 야기하며, 2022~2023년 2.75%p 금리 인상에 따른 비수도권 B의 연간 충격은 4,202억원으로 수도권 A(44,583억)의 9.4%에 불과하다. 이 결과는 동일한 통화정책이 지역에 따라 극단적으로 다른 재정 충격을 유발함을 실증하며, 지역별 차등 세율 설계와 맞춤형 재정 지원 체계의 이론적 근거가 된다.

COVID더미 계수(−206.3억)는 수도권 A(−989.2억) 대비 작지만 통계적으로 유의하며(***), 중과세더미 계수(+33.8억)는 수도권 A(+1,054.2억) 대비 극히 작다. 이는 비수도권 B에서 다주택자 중과세의 구조 변화 효과가 미미함을 보여주는데, 비수도권 지역에서 다주택자 취득 거래 자체가 매우 제한적이기 때문이다. 전체 표본 적합도는 RMSE 118.4억 · MAPE 13.50% · R^2=0.5565로 세 모형 중 최우수이나 수도권 A OLS(R^2=0.799) 대비 R^2 차이가 0.243에 달해, 비수도권 B 세수 결정 구조에서 외생변수로 포착되지 않는 지역 고유 요인의 비중이 상당함을 보여준다.

〈Table 7〉 Comprehensive OLS and GRU Performance and Coefficients

Variable / Specification	Capital A		Non-Capital B		Interpretation
	Coefficient	P-value	Coefficient	P-value	
절편 β_0	5,197.2b KRW	−	538.3b KRW	−	A base level is 9.7x
Trend t (β_1)	+56.0b KRW/M	***	+8.9b KRW/M	**	A growth rate is 6.3x
Trend Squared t^2 (β_2)	−0.34b KRW/M²	***	−0.05b KRW/M²	**	Diminishing long-term growth
Base Rate r (β_3)	−1,351.0b KRW/%p	***	−127.3b KRW/%p	**	10.6x gap (Core finding)
Rate Squared r^2 (β_4)	+75.6b KRW/%²	**	+8.2b KRW/%²	*	Diminishing high-rate effect
COVID (β_5)	−989.2b KRW	***	−206.3b KRW	***	A shock is 4.8x
Heavy Taxation (β_6)	+1,054.2b KRW	***	+33.8b KRW	*	A structural change is 31x
Rapid Rate Hike Dummy (β_7)	−356.6b KRW	*	−89.2b KRW	*	Level shift during surge period

〈Table 7〉 Comprehensive OLS and GRU Performance and Coefficients (continued)

OLS Goodness-of-fit			
RMSE	530.0b KRW	118.4b KRW	
MAPE	7.54%	13.50%	Best among 3 models
R^2	0.7985	0.5565	
GRU Goodness-of-fit			
RMSE	722.3b KRW	147.4b KRW	Comparable to sinusoidal level
MAPE	10.11%	16.97%	B performance constraint
R^2	0.6002	0.3101	Low Region B R^2 (shock period)

Ⅴ. 모형 종합 비교 및 검증

1. 예측력 평가의 체계

모형 간 예측 성능을 체계적으로 비교하기 위해 본 연구는 다음과 같은 평가 지표와 검증 설계를 채택한다.

가. 평가 지표

RMSE(Root Mean Squared Error)는 예측 오차의 제곱 평균 제곱근이다. MAPE(Mean Absolute Percentage Error)는 실적 대비 오차율로서 직관적 해석이 가능하나, 실적이 작은 월에서 분모 효과로 과대 팽창되는 한계가 있다. 정보기준으로는 AIC(Akaike Information Criterion, AIC＝$n \cdot \ln(RMSE^2)+2k$)와 BIC(Bayesian Information Criterion, BIC＝$n \cdot \ln(RMSE^2)+k \cdot \ln(n)$)를 사용하며, 파라미터 수(k)가 상이한 사인파(k＝8)와 OLS(k＝17) 간 모형 복잡성을 보정한 비교에 활용한다. GRU는 총 파라미터가 30,701개로 전통적 AIC/BIC 비교 대상에서 제외한다.

나. 통계적 검정

모형 간 예측 정확도의 통계적 유의성은 Diebold-Mariano(DM) 검정으로 평가한다. DM 검정의 귀무가설은 ‘두 모형의 예측 오차 손실 기대값이 동일하다’(H_0 : $E[d_t]=0$, $d_t=L(e_1_t)-$

$L(e_2_t)$)이며, HAC 분산 추정을 적용한 t-통계량으로 판정한다.

다. 검증 설계

검증은 확장 윈도우(expanding window) 방식의 연도별 홀드아웃으로 수행한다. 즉, 2022년 검증 시 학습기간은 2016~2021년이고 2023년 검증 시 2016~2022년으로 학습기간이 누적적으로 확장된다. 이는 실제 예산 편성 시점에서의 정보 집합을 반영하기 위함이다.

2. 모형 비교와 검정결과

가. 모형의 비교

<Table 8>은 수도권 A와 비수도권 B 각각에 대한 사인파·GRU·OLS 모형의 전체 표본 적합도를 종합 제시한다. 수도권 A에서의 성능 순위는 OLS(MAPE 7.54%·R^2=0.799)>사인파(10.37%·R^2=0.628)≈GRU(10.11%·R^2=0.600) 순이다. 비수도권 B에서의 성능 순위는 OLS(MAPE 13.50%·R^2=0.557)>사인파(14.00%·R^2=0.512)>GRU(16.97%·R^2=0.310) 순이다.

두 지역을 관통하는 공통 발견은 OLS가 양 지역 모두 전체 표본 내 적합도 최우수라는 것이다. 그러나 전체 표본 내 적합도가 곧 예측력을 의미하지는 않는다. OLS는 금리 수준을 독립변수로 포함하므로 금리의 실현값을 알고 있는 상태에서의 사후(ex-post) 적합도이며, 미래 금리를 예측해야 하는 실제 예측 상황에서는 금리 예측 오차가 추가된다. 이 점에서 금리 시나리오 없이도 세수를 예측할 수 있는 사인파·GRU 모형의 실용적 가치가 존재한다.

〈Table 8〉 Comprehensive Comparison of Full-Sample Model Goodness-of-Fit

Performance Metric	Capital A			Non-Capital B		
	Sinusoidal	GRU	OLS	Sinusoidal	GRU	OLS
RMSE (billion KRW)	720	722.3	530	124.2	147.4	118.4
MAPE (%)	10.37%	10.11%	7.54%	14%	16.97%	13.5%
R^2	0.6281	0.6002	0.7985	0.5117	0.3101	0.5565
Best Model	–	–	★	★	–	★

나. 정보기준 및 DM 검정 결과

<Table 9>는 사인파·OLS 모형의 정보기준(AIC/BIC)과 모든 모형 쌍에 대한 DM 검정 결과를 제시한다. AIC/BIC 산출은 $AIC=n\cdot\ln(RMSE^2)+2k$, $BIC=n\cdot\ln(RMSE^2)+k\cdot\ln(n)$ 산식을 적용하였으며, n=124, 사인파 k=8(A_1, T_1, φ_1, A_2, T_2, φ_2, β_0, β_1), OLS k=17(절편, 추세, 추

세², 금리, 금리², COVID, 중과세, 금리급등, 계절더미 11개)이다.

수도권 A에서는 OLS가 AIC(1,589.7)·BIC(1,637.6) 모두에서 사인파(1,647.7·1,670.3)를 능가한다. 이는 OLS의 적합도 우위(R^2=0.799 vs 0.628)가 파라미터 수 증가(17개 vs 8개)에 따른 벌점을 상쇄하고도 남기 때문이다. 반면 비수도권 B에서는 사인파가 AIC(1,211.8 vs 1,220.8)·BIC(1,234.4 vs 1,268.7) 모두에서 OLS를 능가한다. 이는 두 모형의 적합도 차이(RMSE 124.2억 vs 118.4억)가 크지 않은 상태에서 사인파의 파라미터 절약(8개 vs 17개)이 정보기준에서 유리하게 작용하기 때문이다.

DM 검정 결과, 수도권 A에서 사인파와 GRU의 예측 오차 차이는 통계적으로 유의하지 않으나(DM=−0.15, p=0.884), 사인파 vs OLS(DM=3.87, p<0.001) 및 GRU vs OLS(DM=3.94, p<0.001)에서는 OLS의 우위가 통계적으로 확인된다. 비수도권 B에서는 사인파가 GRU 대비 유의한 우위를 보이며(DM=−2.18, p=0.031), GRU vs OLS에서도 OLS 우위가 유의하다(DM=2.87, p=0.005). 다만 사인파 vs OLS는 유의하지 않아(DM=0.72, p=0.472) 두 모형의 적합도가 통계적으로 동등하다.

〈Table 9〉 Comparison of Diebold-Mariano (DM) Tests and Information Criteria Across Models

Evaluation Metric / Item	Capital A	Non−Capital B	Interpretation
Sinusoidal AIC	1,647.7	1,211.8	k=8(Number of parameters)
OLS AIC	1,589.7	1,220.8	k=17
AIC Preferred Model	OLS(−58.0)	Sinusoidal(−9.0)	A : OLS, B : Sinusoidal
Sinusoidal BIC	1,670.3	1,234.4	
OLS BIC	1,637.6	1,268.7	
BIC Preferred Model	OLS(−32.7)	Sinusoidal(−34.3)	A : OLS, B : Sinusoidal
DM : Sinusoidal vs GRU	−0.15(p=0.884)	−2.18(p=0.031*)	Sinusoidal significantly superior in B
DM : Sinusoidal vs OLS	3.87(p<0.001***)	0.72(p=0.472)	OLS significantly superior in A
DM : GRU vs OLS	3.94(p<0.001***)	2.87(p=0.005**)	OLS superior in both regions

Note : 1) For the DM statistic, a positive (+) value indicates that the left-side model is inferior, and a negative (−) value indicates that the left-side model is superior.
2) AIC and BIC for GRU are not suitable for traditional comparison due to its 30,701 parameters.

다. 과거 추계를 통한 검증 (2022~2025년 홀드아웃)

<Table 10>은 실제 예산 편성 환경을 반영한 확장 윈도우(expanding window) 방식의 연도별 홀드아웃 검증 결과를 제시한다. 2022년 검증에서는 사인파 MAPE 35.82%·GRU 33.98%로 양 모형 모두 높은 오차를 기록하였으며, DM 검정에서도 두 모형 간 유의한 차이가 없다(p=

0.782). 이는 2022년 기준금리의 전례 없는 급등이 양 모형의 학습 범위를 벗어났기 때문이다.

2023년 검증에서 GRU MAPE 10.44%·사인파 19.37%로 8.93%p의 의미 있는 격차가 발생하였다. DM 검정의 p값은 0.068로 10% 유의수준에서 한계적으로 유의하다. 다만 연간 12개 관측치에 기초한 DM 검정은 통계적 검정력이 제한적이라는 점을 감안해야 한다. 2024년 검증에서 격차가 더욱 확대되어 GRU 8.04%·사인파 28.25%로 20.21%p에 달하였으며, DM 검정에서도 5% 수준에서 통계적으로 유의한 차이가 확인된다(p=0.003). 2025년 검증에서는 사인파(16.45%)가 GRU(17.21%)를 소폭 능가하였으나 DM 검정에서 유의하지 않다(p=0.891).

〈Table 10〉 Yearly Holdout Validation (Capital A, Including DM Test)

Validation Year	Training Period	Sinusoidal MAPE	GRU MAPE	Improvement (GRU−Sinusoidal)	DM Test (P-value)	Key Characteristics
2022	2016~2021	35.82%	33.98%	−1.8%p	p=0.782	Rate-hike shock ; Both models struggled
2023	2016~2022	19.37%	10.44%	−8.9%p	p=0.068*	GRU showed superiority in learning new equilibrium
2024	2016~2023	28.25%	8.04%	−20.2%p	p=0.003**	GRU demonstrated overwhelming advantage in stabilizing period adaptation
2025	2016~2024	16.45%	17.21%	+0.8%p	p=0.891	Sinusoidal slightly superior (second-half shock)

Note : 1) The DM test is based on 12-month forecast errors for each year ; statistical power is limited due to the small sample size (n=12).
2) p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

<Table 11>은 비수도권 B에 대한 동일한 연도별 홀드아웃 검증 결과를 제시한다. 비수도권 B의 홀드아웃 검증 결과는 수도권 A와 근본적으로 상반된 구도를 보인다.

2022년 검증에서는 사인파 MAPE 27.4%·GRU 30.2%로 양 모형 모두 높은 오차를 기록하였으나, 수도권 A(사인파 35.82%·GRU 33.98%)보다는 오차가 작다. 이는 비수도권 B의 금리탄력성이 수도권 A의 10.6분의 1 수준이므로 동일한 금리 급등 충격이 상대적으로 작은 세수 변동을 야기하였기 때문이다. DM 검정에서 두 모형 간 유의한 차이가 없다(p=0.694).

2023년 검증에서 사인파 MAPE 15.8%·GRU 22.1%로 사인파가 6.3%p 우위를 보이며, DM 검정에서도 5% 수준에서 통계적으로 유의하다(p=0.042). 이는 수도권 A에서 GRU가 사인파를 압도한 것과 정반대이다. 비수도권 B에서 GRU가 열위인 이유는 두 가지이다. 첫째, 비수도권 B GRU의 전체 표본 R^2(0.310)가 사인파(0.512) 대비 현저히 낮아 학습 자체가 불완전하다. 둘째, 2022년 충격 구간이 학습 데이터의 상당 비중을 차지하면서 GRU가 저세수 수준에 과적합

되어 2023년의 반등을 포착하지 못하는 '저수준 고착(low-level anchoring)' 현상이 발생하였다.

2024년 검증에서도 사인파(12.3%)가 GRU(16.8%)를 4.5%p 능가하며, DM 검정에서 10% 유의수준에서 한계적으로 유의하다(p=0.085). 사인파 모형의 중주기 T_2=46.0개월(3.8년)이 비수도권 B의 제조업 연동 단기 순환 구조를 명시적으로 포착하는 강점이 홀드아웃에서도 발현된 것이다. 2025년 검증에서는 GRU(12.9%)가 사인파(14.5%)를 소폭 역전하였으나 DM 검정에서 유의하지 않다(p=0.763). 이는 2024년 실적까지 학습한 GRU가 비로소 안정적인 회복 패턴을 반영하기 시작한 것으로 해석된다.

〈Table 11〉 Yearly Holdout Validation (Non-Capital B, Including DM Test)

Validation Year	Training Period	Sinusoidal MAPE	GRU MAPE	Improvement (GRU-Sinusoidal)	DM Test (P-value)	Key Characteristics
2022	2016~2021	27.4%	30.2%	+2.8%p	p=0.694	Rate-hike shock ; both models struggled (or faced difficulties)
2023	2016~2022	15.8%	22.1%	+6.3%p	p=0.042*	Sinusoidal significant advantage ; GRU locked at low levels (or trapped at low performance)
2024	2016~2023	12.3%	16.8%	+4.5%p	p=0.085*	Sinusoidal advantage in capturing cyclical structures
2025	2016~2024	14.5%	12.9%	−1.6%p	p=0.763	GRU slight advantage in learning recovery phases

Note : 1) The DM test is based on 12-month forecast errors for each year ; statistical power is limited due to the small sample size (n=12).
2) p<0.10, * p<0.05, ** p<0.01, *** p<0.001.

종합하면, 비수도권 B의 홀드아웃 검증에서는 사인파가 4개 연도 중 3개(2022~2024년)에서 GRU를 능가하여, 수도권 A와 정반대의 구도를 형성한다. 이 지역 간 차이는 사인파 모형이 비수도권 B의 단주기 순환 구조(T_2=46.0개월)를 명시적으로 포착하는 반면, GRU는 비수도권 B의 제한된 학습 데이터(112개 시퀀스)와 높은 상대 변동성(CV=25.1%)으로 인해 안정적 패턴 학습이 곤란하다는 구조적 차이에서 기인한다.

3. 2026~2028년 추계와 시사점

가. 2026~2028년 추계 결과

세수추계는 사인파 GRU, OLS, 앙상블로 한다. 여기서, 앙상블 추계치는 사인파・GRU・OLS 3개 모형의 예측값에 대해 홀드아웃 MAPE의 역수를 가중치로 부여하는 역MAPE 가중평균

(Inverse-MAPE Weighted Average) 방식으로 산출한다. 가중치 $w_i=(1/MAPE_i)/\Sigma(1/MAPE_j)$에 의해, 표본 외 예측 정확도가 높은 모형에 더 큰 가중치가 부여된다.

수도권 A의 2026년 추계를 모형별로 살펴보면, 사인파(68,630억) · GRU(64,849억) · OLS(62,221억) · 앙상블(65,233억)으로 최고(사인파)와 최저(OLS) 간 격차가 6,409억원에 달한다. 앙상블(65,233억)은 2025년 실적(62,644억) 대비 +4.1%(+2,589억)로 소폭 반등을 전망한다.

비수도권 B의 추계 구도는 수도권 A와 정반대이다. GRU가 가장 낙관적(2026년 7,327억)이고 사인파가 가장 보수적(6,202억)이다. 앙상블 기준 비수도권 B 2026년 추계는 6,830억으로 전년(6,680억) 대비 +2.2%이다.

〈Table 12〉 Annual Tax Revenue Forecast Results by Model (2026-2028)

Year	Capital A				Non-Capital B			
	Sinusoidal	GRU	OLS	Ensemble	Sinusoidal	GRU	OLS	Ensemble
2025 Actual	62,644	62,644	62,644	62,644	6,680	6,680	6,680	6,680
2026 Forecast	68,630	64,849	62,221	65,233	6,202	7,327	6,962	6,830
2027 Forecast	74,927	67,239	59,405	67,190	6,100	7,964	7,211	7,092
2028 Forecast	75,560	68,430	56,213	66,734	6,752	8,129	7,442	7,441

나. 모형의 검증 시사점

OLS 모형은 전체 표본에 대한 적합도가 가장 우수하며, 연간 예산편성의 기준선을 제시하고 금리 시나리오 분석에 최적이다. GRU 모형은 구조적 충격 이후 홀드아웃 검증에서 가장 우수한 성과를 보이며, 충격 발생 직후 1~2년 단기 예측에 최적이다. 사인파 모형은 비수도권 B에서 정보기준(AIC · BIC)에서 우위를 보이며, 경기 사이클을 명시적으로 표현할 수 있어 2~3년 이상의 중기 예측과 사이클 국면 파악에 유용하다. 즉, OLS는 안정적 기준선과 정책 시나리오 분석에, GRU는 충격 직후 단기 예측에, 사인파는 중기 사이클 분석에, 앙상블은 종합적 예산 기준선 마련에 각각 최적이라고 할 수 있다.

Ⅵ. 결 론

본 연구는 수도권 A와 비수도권 B 취득세를 공통기간(2016.01~2026.04, N=124)으로 사인파 · GRU · OLS 모형을 독립적으로 추정하고 모형을 지역 간 · 모형 간 2차원으로 비교 분석하였다.

첫째, 전체 표본 적합도에서 OLS가 양 지역 모두 최우수이다(수도권 A MAPE 7.54% · R^2=0.799, 비수도권 B MAPE 13.50% · R^2=0.557). 반면 연도별 홀드아웃 검증에서는 GRU가 수도

권 A의 구조충격 이후(2023・2024년)에서 명확한 우위를 보여, 예산 편성 목적으로는 상황에 따른 모형 선택이 필요함을 확인하였다.

둘째, OLS 금리탄력성 격차(수도권 A −1,351억/%p vs 비수도권 B −127.3억/%p, 10.6배)는 동일 통화정책의 비대칭 지역 효과를 실증한다. 2022~2023년 기준금리 2.75%p 인상에 따른 연간 세수 충격이 수도권 A 44,583억원 대 비수도권 B 4,202억원으로 추정되어, 지역별 차등 세율 설계와 교부세 배분 방식의 개선을 강력히 시사한다. 즉, 지역 시장상황에 맞는 지방정부의 세율 선택 권한(자율적 조정정책)이 확대될 수 있도록, 지방의회가 세율을 선택하는 지역차등세율제도를 장기적으로 검토할 필요가 있다.

셋째, 사인파 추세 기울기의 방향 차이(수도권 A +8.09억/월 vs 비수도권 B −2.77억/월)는 두 지역이 장기 재정 경로에서 구조적으로 분기하고 있음을 보여준다. 비수도권 B의 음(−)의 추세가 지속된다면 향후 10년간 약 3,340억원(2.77×12×100개월)의 추가적 세수 기반 위축이 예상되며, 재산세・지방소득세 기반 강화와 지방교부세 보강이 시급하다.

본 연구의 한계는 다음과 같다. 첫째, GRU 하이퍼파라미터는 문소영・이서희(2024)의 전국 총액 기준 최적 조합을 직접 채택하였으며 취득세 특화 파라미터 탐색이 이루어지지 않았다. 향후 금리・거래량 등을 피처로 추가하는 다변량 GRU 모형의 적용이 필요하다. 둘째, 사인파 모형의 주기 시간불변성(stationarity) 가정으로 인해 정책 구조 변화에 따른 사이클 길이 변동을 반영하지 못한다. 셋째, OLS 모형은 단순화된 금리 프록시를 사용하여 정밀한 시나리오 분석에 제한이 있다.

부동산 취득세는 부동산시장 및 정책에 따라 세입이 크게 변동하여, 세입을 예측하는 것이 매우 어렵다. 따라서, 경기변동 및 구조적 충격 등을 반영하는 세수예측 모델 개발을 통해서 세수예측의 정확성을 제고하는 것이 필요하다.

"본 논문은 사단법인 한국세무학회 연구윤리규정을 준수하였음을 확인함."
"The study in this manuscript has been conducted in accordance with the Ethical Guidelines set forth by the Korean Academic Society of Taxation."

[AI 사용 공시] 본 논문 작성 과정에서 생성형 AI를 학습・예측, 모형 검증 및 최적화 분석에 활용하였음. AI 활용 결과는 저자가 직접 검토・수정하였으며, 논문의 내용 및 연구 결과에 대한 최종 책임은 저자에게 있음.
[AI Disclosure statement] Generative AI was used for learning and prediction, model validation, and optimization analysis during the preparation of this manuscript. All AI-generated outputs were reviewed and revised by the author(s), who take full responsibility for the content and results of the study.

[이해상충 공개] 참여 저자 모두는 본 연구와 관련하여 경제적 이해관계 또는 기타 이해상충이 없음을 확인함.
[Conflict of Interest] The authors declare no conflicts of interest associated with this manuscript.

REFERENCES

Cho, K., van Merrienboer, B., Gulcehre, C., Bahdanau, D., Bougares, F., Schwenk, H., & Bengio, Y. (2014). Learning phrase representations using RNN encoder-decoder for statistical machine translation. arXiv : 1406.1078.

Cooley, J. W., & Tukey, J. W. (1965). An algorithm for the machine calculation of complex Fourier series. *Mathematics of Computation*, 19(90) : 297-301.

DiPasquale, D., & Wheaton, W. C. (1992). The cost of capital, tax reform, and the future of the rental housing market. *Journal of Urban Economics*, 31(3) : 337-359.

Hochreiter, S., & Schmidhuber, J. (1997). Long short-term memory. *Neural Computation*, 9(8) : 1735-1780.

Hyndman, R. J., & Koehler, A. B. (2006). Another look at measures of forecast accuracy. *International Journal of Forecasting*, 22(4) : 679-688.

Levenberg, K. (1944). A method for the solution of certain non-linear problems in least squares. *Quarterly of Applied Mathematics*, 2(2) : 164-168.

Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and machine learning forecasting methods : Concerns and ways forward. *PloS one*, 13(3) : e0194889.

Pyhrr, S. A., Webb, J. R., & Born, W. L. (1990). Analyzing real estate asset performance during periods of market disequilibrium under cyclical economic conditions. *Research in Real Estate*, 3 : 75-106.

Pyhrr, S. A., Roulac, S. E., & Born, W. L. (1999). Real estate cycles and their strategic implications for investors and portfolio managers in the global economy. *Journal of Real Estate Research*, 18(1) : 7-62.

Rumelhart, D. E., Hinton, G. E., & Williams, R. J. (1986). Learning representations by back-propagating errors. *Nature*, 323(6088) : 533-536.

Schumpeter, J. A. (1939). Business cycles : A theoretical, historical, and statistical analysis of the capitalist process. McGraw-Hill.

Wheaton, W. C. (1999). Real estate "cycles" : Some fundamentals. *Real Estate Economics*, 27(2) : 209-230.

국내 참고문헌

고영선(2000). 세수추계모형의 예측력 비교. 한국개발연구원. *KDI Journal of Economic Policy*, 제22권 제1호 : 3-55.

곽동철・권일숙(2021). 부동산 거시계량모형을 활용한 정부정책변화가 주택시장에 미치는 영향 분석. 한국경영컨설팅학회. 경영컨설팅연구, 제21권 제4호 : 301－312.

이현미・전해정(2020). 수도권 지역 주택가격 순환주기 변동의 영향요인 분석. 한국부동산경영학회. 부동산경영, 제22권 : 307－331.

문소영・이서희(2024). 머신러닝 방법론을 적용한 지방세수 예측 방안 연구. 한국지방행정연구원. 지방행정연구, 제38권 제2호 : 203－228.

서수복・김재경(2011). 한국 주택시장과 벌집순환모형의 관련성에 관한 연구. 국토연구원. 국토연구, 제68호 : 121－133.

엄근용(2011). 주택경기의 순환주기적 특징과 시사점. 한국건설산업연구원. 건설이슈포커스 2011－19 : 1－22.

이석환(2018). 지방세 세수예측방법의 비교평가 : 서울시를 중심으로. 한국공공관리학회. 한국공공관리학보, 제32권 제2호 : 25－56.

이영희・조기현(1998). 지방세수 예측을 위한 모형의 탐색. 한국지방행정연구원. 기본연구과제 1998.

이은국(1994). 서울시 세입・세출의 예측행태. 한국행정학회. 한국행정학보, 제28권 제1호 : 263－284.

전해정(2019). 서울시 주택매매가격 순환주기변동에 거시경제변수가 미치는 영향. 한국부동산학회. 부동산학보, 제77집 : 109－121.

정일환(2021). 머신러닝 접근의 재정관리 : 세입추세 예측모형 연구. 성균관대학교 국정전문대학원. 국정관리연구, 제16권 제4호 : 1－28.

한용석・이주형(2009). 주택가격의 순환변동 분석에 관한 연구. 서울연구원. 서울도시연구, 제10권 제4호 : 229－243.

한재명(2022). 지방세 세수추계 개선방안. 한국지방세연구원. 수시연구보고서 2022－06.

행정안전부(2013). 지방세 세수추계 업무 매뉴얼.