

# 머신러닝 방법론을 적용한 지방세수 예측 방안 연구\*

## A Study on Local Tax Revenue Forecasting using Machine Learning Methodology

문 소 영\*\*·이 서 희\*\*\*

Mun So Yeong·Lee Seo Hee

### ■ 목 차 ■

- I. 서론
- II. 지방세수 예측 방식과 선행연구
- III. 연구 설계 및 분석 결과
- IV. 결론

지방자치단체는 저출산·고령화로 인한 인구구조변동, COVID-19 발병, 전 세계적인 저성장 등 급변하는 환경변화에 직면하여 있다. 지방자치단체를 둘러싼 환경변화를 반영하면서도 안정적인 재정운영을 위해 세수 예측의 정확성이 주목받고 있다. 이에 본 연구는 1994년부터 2021년까지 지방세 징수액 자료를 수집하고, 다양한 알고리즘을 적용하여 2017년부터 2023년까지 총 지방세수를 예측하였다. 이를 실제 징수액 및 기존 추계방식과 비교하여 지방세수 예측에 머신러닝 방법론을 적용할 수 있는지, 적용할 수 있다면 가장 정확도가 높은 모델(알고리즘)이 무엇인지 살펴보았다. 정확성은 MAPE와 RMSE를 사용하여 평가하였다. 분석 결과, 신경망 기반 머신러닝 방법론의 예측정확도가 높음을 발견하였다. 이를 통해 지방세수 예측의 정확도와 신속성을 높이기 위해 머신러닝 방법론 적용의 유용성을 확인하였다. 그리고 데이터를 기반으로 다양한 머신러닝 방법론을 적용하여 지방세수 추계 오차를 줄이는 개선 방안을 모색했다는 점에서 연구의 의미를 찾을 수 있다.

□ 주제어: 머신러닝, 알고리즘, 지방재정, 세수 예측, 세수오차

\* 이 연구는 한국지방재정공제회가 주최하는 「제1회 LOMAC 학술연구논문 공모전」의 수상작(우수상)을 수정·보완하였음

\* 제1저자, 한국행정연구원 객원연구원

\*\* 교신저자, 한국지방행정연구원 부연구위원

논문 접수일: 2024. 5. 14. 심사기간: 2024. 5. 14. ~ 2024. 6. 18. 게재확정일: 2024. 6. 18.

Local governments are confronted with rapidly changing environmental dynamics, including demographic shifts due to low birth rates and an aging population, the emergence of COVID-19, and global economic stagnation. The accuracy of tax revenue forecasting is gaining attention for stable financial management while reflecting the environmental changes surrounding local governments. In this study, we collected data on local tax collections from 1994 to 2021 and applied various algorithms to predict total local tax revenue from 2017 to 2023. The results were compared with actual collections and existing estimation methods to determine if machine learning methodologies can be applied to local tax revenue forecasting, and if so, which models (algorithms) have the highest accuracy. Accuracy was evaluated using MAPE and RMSE. We found that neural network-based machine learning methodologies are more accurate. This confirms the usefulness of applying machine learning methodologies to improve the accuracy and speed of local tax revenue forecasting. The significance of this study is that it explored improvement measures to reduce the error of local tax revenue estimation by applying various machine learning methodologies based on data.

□ Keywords: Machine Learning, Algorithms, Revenue Forecasting, Local Finance, Tax Revenue Error

## I. 서론

1995년 자치단체장 선거를 기점으로 지방자치가 부활한 이후 역대 정부마다 지방분권을 추진하고 있다. 지방분권 강화의 흐름 속에서 지방자치단체는 지역 주민의 기대와 요구를 반영한 공공서비스를 공급하기 위해 노력하고 있다. 중앙정부와 달리 지방자치단체는 지방세 수입을 예측하여 예산을 편성하기 때문에 지역에 적합한 정책을 제공하기 위해서는 정확한 예측을 통한 일정 수준의 세수 규모 확보가 필수적이다(이석환, 2018; 정일환, 2021). 이는 정확한 지방세 세수 예측이 선행되어야 안정적인 예산 편성과 나아가 효율적이면서 건전한 재정 운영도 가능함을 의미한다.

세수 예측의 부정확성은 재원 조달의 안정성을 저해하고, 계획을 무의미하게 만들며, 집행률 점검 등의 중간 평가의 중요성을 하락시킨다. 예상보다 세수가 적으면 계획보다 사업규모를 축소할 수 밖에 없고, 당초 예상보다 낮은 수준에서 공공서비스를 제공하게 되어 주민 생활에 불편을 초래한다. 이에 반해 예상보다 세수가 많아도 새로운 사업을 추가 편성하거나 기존 사업의 예산을 증액하는 과정에서 시간에 쫓겨 부실한 심의가 이루어질 가능성이 존재한다. 수지균형을 재정 운영의 기본원칙(지방자치법 제137조)으로 삼는 우리나라에서 세수 예측의 부정확성은 건전한 재정 운영을 방해할 수 있다. 나아가 부정확한 세수 예측은 장기적인 재정 운영을 어렵게 만들고 근시안적인 정책 집행으로 인해 행정의 책임성마저 악화시킬 수 있다.

하지만 해를 거듭할수록 지방자치단체의 세수 예측의 정확도는 하락하여 2021년에는 약 27%의 오차율을 보일 정도이다. 지방자치단체는 저출산·고령화에 따른 인구구조변동, 전 세계적인 저성장 등 급변하는 환경변화에 직면하여 있다. 특히, COVID-19 전염병 확산이라는 유례없는 외부 충격으로 인해 경제활동 방식이 급변하면서 현행 추계산식(방법)으로는 예측력이 하락하는 한계점이 나타났다. 지방세수 추계 오차는 불가피하지만 최근 급격한 경기변동과 부동산 시장 부진으로 인해 세수 추계의 불안정성이 커지고 있으며, 이에 매년 달라지는 환경변화를 반영하면서도 정확한 지방세수 예측 방식을 검토할 필요가 있다.

최근에는 인공지능을 활용한 머신러닝 방법을 적용하여 예측을 실시하는 연구가 수행되고 있다. 부동산·환율·전력 거래량·광물 가격 예측에서 사용되고 있으며, 조세정책에서도 세수 오차를 줄이려는 시도 중 하나로 언급되고 있다(Makridakis et al., 2018; 정일환, 2021). 머신러닝 방법론은 다양한 분야의 예측에 활용되고 있지만 예측값이 기존 방식보다 월등하게 정확하지, 어떤 알고리즘이 가장 적합한지에 대해서는 적용 분야에 따라 다른 상황이다. 이에 본 연구는 지방세수 예측에서도 머신러닝 방법론을 적용하였을 때 예측의 정확도가 향상될

수 있는지 검토하는 것부터 연구를 시작한다. 머신러닝 방법론 적용 가능성 자체에 중점을 두고, 향후 정확성이 높은 모형을 개발하는데 일조할 수 있는 탐색적 연구를 수행하고자 한다.

연구는 지방세 세수 예측 과정에서 머신러닝 방법을 적용할 수 있는지에 관한 가능성을 살펴보고, 머신러닝을 활용하였을 때 예측의 정확도가 현행보다 높아질 수 있는지 점검하는 것을 목적으로 한다. 그리고 지방자치단체의 세수 예측과 재정정책 수립 과정에서 정책 결정자의 의사결정에 근거로 사용될 수 있는 기초자료를 제공하고자 한다. 정확한 세수 예측을 위한 최적의 머신러닝 알고리즘을 분석하기 전에 새로운 방법론을 적용하여 세입 예측이 내포하는 불확실성을 감소시킬 수 있는지를 탐색한다. 이에 특정 방법론보다 다양한 알고리즘을 적용하여 예측값의 범위를 확보하고, 이를 바탕으로 재정지출 수준 및 공공서비스 공급 수준을 계획하는데 기여하고자 한다.

이를 위해 2장에서는 기존 세수 예측 모형과 함께 다양한 머신러닝 방법의 장·단점을 살펴본다. 제3장에서는 현행 세수모형과 다양한 머신러닝 방법론의 예측값을 비교하고, 정확성을 기준으로 예측에 활용될 수 있는 적절한 모형을 파악한다. 마지막으로 지방세수 예측 과정에서 예측의 정확도를 높일 수 있는 개선 방안에 대해 시사점을 제공한다.

## II. 지방세수 예측<sup>1)</sup> 방식과 선행연구

### 1. 지방세수 예측 방식과 세수 오차

세수추계 또는 예측(Revenue forecasting)은 “과거 세수추이 및 경제변수 등을 기반으로 산식을 적용하여 다음 연도 세수 기댓값을 예측하는 연 단위 작업”(행정안전부, 2022)으로 지방자치단체별로 자체추계 및 행정안전부 세수추계 프로그램을 이용하거나 별도의 전문기관에 의뢰하여 예측을 실시한다(한재명, 2022).

지방세 세수예측은 기본적으로 진도비 방식을 사용하며, 추계변수에 해당 연도 예상징수액을 곱한 뒤 세입특수요인을 반영하여 예측한다. 구성 요소를 자세히 살펴보면, T년 예상징수액은 “당해연도 1~7월 징수액과 최근 6년 중 최대·최소를 제외한 4년 진도비로 계산한 8~12월 징수액의 합계”로 산출하고, 추계변수는 거래신장률, 가격상승률, 세액신장률 등 부

1) 세수추계는 해당 연도 일부를 바탕으로 총 규모를 미루어 추산하는 것이지만(이석환, 2018), 과거 자료를 바탕으로 미래값을 추정한다는 점에서 본 연구에서는 추계를 예측과 동일한 의미로 사용한다.

동산 및 경제동향 관련 변수로 최근 6~7년에 대한 회귀분석 결과 결정계수가 0.6 이하인 경우 최대·최소를 제외한 4년 평균치를 이용하여 예측하고, 0.6 이상이면 최대·최소를 제외하지 않고 예측한다. 마지막으로 세입특수요인은 자치단체 특성에 따라 지방세입에 영향을 주는 요인이다(행정안전부, 2022).

$$T+1\text{년 세수예상액} = T\text{년 예상징수액} \times \text{추계변수} \pm \text{세입특수요인}$$

지방세는 11개 세목으로 구성되어 있으며, 행정안전부는 세목별로 세원으로 적합한 추계변수를 선정하여 총 43개 추계방식을 사용한다. 대표적인 예로 취득세를 살펴보면 주택, 토지, 건축물, 차량 등 세원에 따라 거래 신장률, 가격 상승률을 적용하여 세수를 예측한다. 진도비를 활용하면 세목의 증감추이를 비교적 수월하게 예측할 수 있다는 장점이 있지만 중앙정부가 특정 정책을 크게 변화시킬 경우 세수 예측의 오차가 커진다는 단점이 있다(이석환, 2018).

〈표 1〉 지방세 추계 산식(취득세)

구분		추계 산식
취득세	주택	당해년도 예상징수액[주택] × (1+주택거래신장률) × (1+주택가격상승률) ± 세입특수요인
	토지	당해년도 예상징수액[토지] × (1+토지거래신장률) × (1+토지가격상승률) ± 세입특수요인
	건축물	당해년도 예상징수액[건축물] × (1+건축물거래신장률) × (1+신축건축물기준가격상승률) ± 세입특수요인
	차량	당해년도 예상징수액 × (1+차량거래신장률) × (1+차량가격상승률) ± 세입특수요인
	기타	당해년도 예상징수액 ± 세입특수요인 [대상 : 선박, 항공기, 기계장비, 기타]

출처: 행정안전부(2022)

세수추계의 핵심은 ‘지방세 세목별 추세’와 ‘국내·외 경기변동 요인’에 대한 정확한 예측이다(김재영 외, 2004). 현행 지방세 세수추계 기본 모형에 의하면 추계변수, 세입특수요인 등을 통해 어느 정도 거시경제 환경변화를 반영하도록 하고 있다. 하지만 부동산 시장 침체 또는 활성화, 공시지가 변동, 기타 국내·외 정세 변화 등 새로운 변수를 즉각적으로 반영하기에는 어려움이 있다.

〈표 2〉 지방세 세목별 추계변수(주요)

구분	추계변수
취득세	주택/토지 거래신장률·가격상승률, 건축물 거래신장률·신축건축물기준가액상승률 차량 거래신장률·가격상승률,
재산세	단독주택/공동주택/토지 가격상승률·과표적용률증감률 신축건축물기준가액상승률·감가상각률증감률
등록면허세	면허, 등록
지역자원시설세	특정자원, 특정시설 신축건축물기준가액상승률·과표적용률증감률·감가상각률증 감률
자동차세	소유, 자동차세 보전, 운수업체 보조
주민세	차량증감률(소유분), 자동차세보전분안분율, 운수업체보조금안분율증감율
지방소득세	개인분(개인균등·개인사업· 법인균등), 재산, 종업원세
지방소비세	세액신장률 또는 납세의무자증감률
지방교육세	종합소득, 양도소득, 특별징수, 법인세
레저세	GDP 증가율 또는 GRDP 증가율(양도소득) 취득세 부동산거래 신장률·가격상승률
담배소비세	추계연도 지방소비세 안분액
과년도수입(광역/기초)	취득세, 등록면허세, 레저세, 주민세, 재산세, 자동차세, 담배소비세
매출액 증감률	각 세목 추계액에 각 세율 적용하여 합산
세액신장률	매출액 증감률
체납증감률, 체납징수율	체납증감률, 체납징수율

출처: 한재명(2022)

지방자치단체는 재정활동을 통해 국가가 부여한 임무를 달성하거나 지역에 고유한 공공서비스를 제공하기 위해 필요한 자금을 조달하고 사용한다(이진수 외, 2020). 때문에 지방세수를 예측하는 것은 예산 배분 전 나중에 지불할 규모를 파악한다는 측면에서 계획적인 재정운영을 위해 필수적인 단계이자(이석환, 2018), 중장기 재정계획을 수립하는 기초자료로 활용된다는 점에서 재정의 안정성과 계획성을 확보하는 출발점이다.

지방세수 예측은 전년도 하반기에 이루어지기에 과거에 예상하지 못한 법적·제도적 환경변화가 발생할 불확실성을 내포하고 있기에 세수오차 발생 자체는 불가피하다. 하지만 2021년 이후 부동산 가격 폭등 및 전염병 발생 등 급격한 외부환경 변화로 인해 최근 10년간 평균한 자리수였던 세수 오차율이 증가하였고, 이로 인해 계획성 있는 재정 운영에 어려움이 예상된다.

## 2. 지방세수 예측 방식과 선행연구

지방세수 예측에 대한 선행연구는 세수 예측 기법에 대한 평가와 세수 예측 오차 발생 요인을 규명하는 연구 두 부분으로 나눌 수 있다. 첫째, 현행보다 예측의 정확성을 높이기 위해 계량경제학적 방법론을 사용한 예측 기법을 평가하고 개선 방안을 제시하는 연구이다. 기존 연구에서 제시한 세수예측기법은 축약형 시계열분석(고영선, 2000), Box-Jenkins시계열(ARIMA)분석(이은국, 1994, 김현아, 2002), 지수평활법(Frank, 1990; 이영희·조기현, 1998; 이현선·박태규, 2007; 이석환, 2018), Holt-Winter의 이모수법(조임곤, 2001; 조택희, 2005), 칼만필터를 사용한 시계열예측법(이석환·박근화, 2018), 테일오차분해(배상석, 2016) 등으로 다양한 기법을 소개하고 세수추계 개선방안을 제시하고 있다. 둘째, 세수 예측의 정확도가 하락하는 요인을 밝히는 연구이다. 연구에서 밝힌 주요 원인으로 경기변동, 지방세 제도(법)의 잦은 변화, 정부정책 변화, 정치적 요인(정치적 경기순환가설:PBC), 예산담당자의 전문성 부족, 경기불황에 대비하여 자치단체들이 여유자원(slack resource) 확보 방법으로 사용 등을 손꼽을 수 있으며, 세목별로 차이가 있지만 총 세수규모를 기준으로 과소예측하는 성향이 나타났다(배상석, 2013; 정일환, 2021).

이 연구에서는 급변하는 외부환경을 통제하기보다 지방세를 정확하게 예측하는데 적합한 방법론을 찾는 것에 집중하고자 한다. 주요 선행연구에서 제시한 분석 방법과 특징을 살펴보면 다음과 같다. 고영선(2000)은 1991년부터 1998년까지 축약형 시계열모형을 적용하여 세수를 예측하였고, 이를 통해 오차수정모형과 10년 탄성치 이동평균 방식의 예측력이 우수함을 확인하였다. 하지만 축약형 시계열 모형은 법·제도·경제변수의 변동을 반영하지 못하는 한계가 있었다(이태석, 2015).

이은국(1994)은 1957년부터 1991년까지 서울시의 일반회계 및 특별회계를 대상으로 세입과 세출의 예측형태, 예측 정확성, 예측오차, 예측편향을 분석하였는데, 일반적으로 알려진 세입 과소추정 및 세출 과대추정의 시각(보수적 관점: Burkhead, 1956; Caiden & Wildavsky, 1974; Larkey & Smith, 1989)과 다르게 세입·세출 과대추정이 나타남을 확인하였다. 이는 지방자치단체(해당 연구에서는 서울시)가 세출을 과대추정한 뒤, 명목적인 균형 예산을 달성하기 위해 세입도 과대추정하는 것을 의미하며, 양출제입(量出制入)의 재정원리가 바탕인 시대에 조세체계의 일관성이 결여될 수 있기에 균형예산의 법적 의무 조항을 강제해야 된다고 주장한다. 그리고 이러한 과대추정을 줄이고, 세입·세출 예측의 정확성을 높으려면 AIRIMA(1,1,0)모형이 적합하다는 결론을 내렸다. ARIMA모형은 복잡성이 낮아 범용성이 높다는 것이 가장 큰 특징이다. 내생변수 간 상호관계도 체계적으로 분석할 수 있다(이학연 외,

2021). 하지만 데이터 양이 적거나, 추세가 분명하게 드러나지 않고 불규칙적인 경우에는 예측력이 떨어지는 단점이 있다(이상훈 외, 2012).

이영희·조기현(1998)은 광역자치단체를 대상으로 취득세, 등록세, 주민세, 자동차세, 담배소비세 5개 지방세에 대해 월별, 분기별, 연간모형별로 적절한 분석기법을 연구하였다. 연간 모형은 OLS, SUR기법을 적용하고, 분기모형은 ARIMA, 월별모형은 지수평활법을 이용하였다. 분석 결과, 월별·분기별모형에서는 유의미한 결과가 나타나지 않아 세목별·지역별 데이터 구축, 담당 실무자에 대한 교육프로그램 개발 및 계량기법 개선을 위해 지속적인 연구가 필요함을 강조하였다. 해당 연구는 경기 전체, 금융 등 경제변수를 계량화하여 세수추계에 활용한 거시계량모형으로 예측의 현실성을 높이고자 노력하였다. 하지만 실무자들이 이해하기에는 쉽지 않은 부분이 많으며(이학연 외, 2021), 지방세 세목에 따라 거시경제지표를 구하기 어려운 경우가 많아 실제 세수 추계 적용에는 어려움이 있다(이상훈 외, 2012).

이석환(2018)은 예측의 정확성을 판단하기 위해 여러 모형을 비교하였다. 서울시 시세와 자동차세를 대상으로 이동평균, 지수평활, ARIMA모형, 회귀분석을 적용하였다. 1975년부터 2010년의 시계열자료를 사용하여 예측모형을 설정하고, 2011년부터 2015년까지의 예측값을 계산하여 해당 기간의 실제값과 차이로 정확도를 확인하였다. 분석 결과, 서울시 시세는 지수평활과 회귀모형이 가장 우수하였고, 자동차세는 단순 시계열분석이 예측 정확도가 가장 높게 나타났다. 지수평활법은 과거 시계열 관측값을 가중평균하여 시계열에 포함된 확률오차들을 평균화하는 방법이다(이석환 외, 2018). 지수평활법은 최근 관찰 자료에 가중치를 부여하여 예측을 실시하기 때문에 단기 예측력이 높다는 특징이 있다. 다른 모형에 비해 상대적으로 쉽게 모형을 구성하고 결과가 상당히 정확하지만 추세가 선형적인 경우에만 한정된다. 즉, 급격한 사회변화가 나타나거나 장기 예측에서는 추세의 불안정성이 나타날 우려가 있다(이학연 외, 2021).

이현선·박태규(2007)는 1987년부터 2003년까지 당시 전체 지방자치단체의 13개 지방세 세목을 바탕으로 2003년 예측치를 산출하여 행안부 지방세 예측결과와 비교하였고, 이를 통해 지수평활이 예측오차가 가장 작은 것을 확인하였다. 이에 지방교부세 산정을 위한 추세분석 방식을 지수평활로 대체할 수 있다고 주장하였다.

조임곤(2001)은 서울시 지방세 결산자료를 대상으로 Holt-윈터(Holt-winter)방법을 사용한 1999년 예측치와 실제 예산(안)을 비교하였는데, 당시에 사용하던 세입예측 방식보다 시간이동설계를 활용한 소프트웨어가 단순하면서 예측력이 높다는 점을 확인하였다. Holt-윈터 방법은 지수평활법에 속하지만 계절 변동 있는 선형추세를 가진 시계열에 적용할 수 있으며, 한 모수를 사용한 이중평활방법이 아닌 두 모수를 사용할 수 있는 것이 특징이다(이학연 외, 2021).

선행연구는 다양한 예측 방식을 제시하여 지방세수 예측의 정확도를 높이기 위해 노력하고 있지만 지방세수 예측에 머신러닝 알고리즘을 활용하여 예측력을 비교한 연구는 충분하지 않다. 최근 정일환(2021)은 이동평균법, 지수평활법, ARIMA모형, 머신러닝기법(GRNN, KNN)을 적용하여 세입예측 방식의 정확도를 분석하였다. 1970년부터 2019년까지 서울시 보통세입 결산자료와 2002년부터 2018년까지 광역시 산하 69개 자치구 보통세입 결산자료를 바탕으로 세입변화가 적은 2010년부터 2014년까지 기간 및 세입변화가 급격한 2015년부터 2019년까지 기간의 예측성을 비교하였다. 분석 결과, 머신러닝 방식이 다른 방식에 비해 예측력이 높은 경우는 서울시 2010-2014년과 광역시 자치구 2010-2014 및 2015-2019년이 었다. 이를 통해 기계학습을 활용한 세수 예측이 지방세에도 적용될 수 있음을 확인하였다.

아직까지 머신러닝 알고리즘을 적용한 세수 예측 연구가 매우 드물며, 기존 방식에 비해 정확도가 높은지에 대해서도 연구마다 결과가 다르다. Makridakis et al.(2018)은 머신러닝 알고리즘과 기존 예측모형 간 예측의 정확성 정도와 계산에 사용된 비용을 비교하였는데, 기존 모형이 머신러닝 알고리즘보다 높은 예측력을 보이고, 계산비용은 더 낮았다. 이에 반해 국내에서는 송석현(2021)이 국고잔액을 예측하는데 선형회귀, 랜덤 포레스트, 그래디언트 부스팅이라는 머신러닝 방법론을 적용하였고, 국고잔액 전체와 소득세는 선형회귀가 가장 예측력이 높았으며, 부가가치세는 랜덤 포레스트가 예측력이 높아 머신러닝 방법론의 유용성을 확인함과 동시에 세목별로 예측에 적합한 알고리즘이 다를 수 있음을 시사하였다.

이에 본 연구는 다양한 머신러닝 알고리즘을 적용하였을 때 지방세수 예측의 정확도가 현행보다 증가할 가능성에 대해 점검하고, 이를 통해 계획적인 지방재정 운영에 기여할 방안을 모색하고자 한다.

### 3. 머신러닝 방법론과 특성

구조화된 정책 문제에서 머신러닝 알고리즘을 적용하면 합리적 의사결정을 구현할 수 있다(김병조·은종환, 2020). 행정안전부의 세수추계 방법이나 선행연구에서 수행한 세수예측 방법들과 비교해서 머신러닝을 이용한 세수예측 방법은 복잡한 비선형 관계 학습이 가능하다는 장점이 있다. 기존 회귀분석이나 시계열자료에 기반한 예측 방법들은 주로 선형 가정에 기반하기 때문에 복잡한 비선형 관계를 포착하기 어렵다. 반면 머신러닝 알고리즘은 데이터의 복잡한 패턴과 구조를 인식하고 학습할 수 있어 기존 방법론이 놓치는 상호작용 및 비선형 관계를 탐지하고 반영하여 세수 예측의 정확도와 신뢰성을 향상시킬 수 있다.

또한 기존 방법론이 수동으로 변수의 선택과 변환을 수행해야 하는 반면 머신러닝 알고리

좁은 변수 간의 상호작용을 적절하게 고려하거나 변수를 변환하여 복잡한 관계를 반영하는 등 자동화된 변수 선택 및 생성 과정을 통해 모델링의 편향을 최소화하고 예측 성능을 향상시킬 수 있다. 이 외에도 과적합(overfitting)을 완화해서 일반화 성능을 높일 수 있으며, 하이퍼파라미터 튜닝을 통해 최적의 모델 구조를 찾을 수 있다.

다양한 머신러닝 알고리즘 중 지방세수 예측에 활용할 수 있는 가장 기본적인 방법은 선형 회귀이다. 회귀 기반 방법론인 선형 회귀는 지도학습의 한 종류로 학습 데이터(Training Data)를 기반으로 모델의 가중치를 조정해가며 최적의 모델을 찾는 기법이다. 기존 세수예측 방법과 유사하지만, 모델의 기본 형태를 가정할 필요가 없고, 비선형적인 상호작용과 곡선 형태의 변수를 모델에 반영할 수 있다. 또한, 선형 회귀의 과적합을 방지하고 일반화 성능을 향상시키기 위해 정규화 항을 추가한 릿지 회귀(Ridge Regression) 및 라쏘 회귀(Least Absolute Shrinkage and Selection Operator: Lasso Regression)도 회귀 기반 방법론에 포함된다. 라쏘 회귀는 L1 정규화를, 릿지 회귀는 L2 정규화를 사용한다.

회귀 기반 방법론 외에, 비선형 관계를 잘 반영하는 기법으로 결정 트리(Decision Tree) 방법론, 여러 개의 결정 트리를 앙상블하여 예측 정확도를 높이고 분산을 줄이는 랜덤 포레스트(Random Forest), 약한 결정 트리를 순차적으로 학습하여 오차를 줄여나가는 그래디언트 부스팅(Gradient Boosting) 및 XGBoost(Extreme Gradient Boosting) 등을 활용할 수 있다. 각 방법의 특징을 살펴보면 다음과 같다. 결정 트리는 예측 변수를 기반으로 “뿌리-중간-끝”의 트리구조를 생성하여 각 노드에서 조건을 확인한 후 분류 또는 회귀를 수행한다. 이 방식은 분류기준에 따라 시각화할 수 있으며, 설명이 쉽고(장유미·유한별, 2023), 데이터의 비선형 패턴을 포착하는 장점이 있다. 랜덤 포레스트는 앙상블 모델을 기반으로 여러 개의 결정 트리를 합하여 결과를 출력하는데, 분산을 줄이기 위해 여러 개의 트리를 평균화한다. 랜덤 포레스트는 전통적인 회귀분석에서의 기본적인 가정인 오차항 분포 가정, 동분산성 가정, 시계열적 상관성과 같은 조건에 제약을 받지 않으며, 무작위 샘플링을 반복하여 다수의 결정 트리로 구성된 숲(forest)을 형성하고, 여기서 확보한 예측범주 중 다수결투표 방식으로 최종 결정을 내린다(최필선·민인식, 2018). 이는 동일하게 분포된 독립적인 결정트리가 반복되면서 예측오차를 줄인다는 이점이 있다. 그래디언트 부스팅도 랜덤 포레스트와 비슷한 앙상블 모델을 기반으로 하며, 여러 개의 결정 트리를 연속적으로 학습하면서 이전 트리의 오차를 보정해 나가는 방식이다. 랜덤 포레스트와 달리 분류기가 순차적으로 생성되어 이전 분류기의 학습이 다음 분류기 학습에 영향을 미친다(장유미·유한별, 2023). 이에 각 트리는 이전 트리의 오차를 최소화하는 방향으로 학습되는 특징이 있다. 그래디언트 부스팅은 과적합에 강하지만 분류결과에 대한 해석이 불가능하다는 단점이 존재한다(장유미·유한별, 2023)

이 외에도 지방세 데이터가 시계열자료라는 특성을 고려하여 시계열 기반 방법론인 Long

Short-Term Memory(LSTM) 및 Gated Recurrent Unit(GRU) 등의 순환 신경망(RNN) 기법을 통해서도 지방세수 예측을 수행할 수 있다. 순환 신경망(RNN)은 과거 정보를 기억하여 순차적인 학습이 이루어지기에 시계열 예측에서 우수성을 보임에도 불구하고 시간 역전파(back propagation through time: BPTT) 과정에서 기울기가 폭발한다는 한계(vanishing gradient problem)가 있다. LSTM(Long Short-Term Memory)과 GRU(Gated Recurrent Units)는 RNN(Recurrent Neural Network)의 변형으로 장기 의존성 문제(Long term dependency)를 해결할 수 있으면서 시계열 데이터, 텍스트, 연속된 데이터 패턴을 학습하는 데 유용하다. 순환 신경망(RNN)은 시계열 데이터에서 먼 과거의 학습데이터일수록 현재에 미치는 영향이 적어지는 문제점이 있다. LSTM의 경우 "gate"라고 불리는 구조를 통해 정보를 저장하거나 잊어버리게 하는데, 이러한 구조 덕분에 LSTM은 장기 의존성을 학습할 수 있다. LSTM은 입력, 삭제, 출력, 게이트라는 네 개의 gate를 포함하며, 각 gate에서 units개의 뉴런을 갖는다. 이때 units값이 커질수록 더 복잡한 패턴을 학습할 수 있지만 훈련시간과 메모리 사용량이 크게 늘어나기도 한다. GRU는 LSTM의 변형으로, reset gate와 update gate라는 두 개의 게이트만을 가지고 있다. 때문에 LSTM보다 더 간소화된 구조를 가지고 있으며, 이로 인해 학습이 빠르다. 때문에 적은 데이터에서는 LSTM보다 GRU가 더 잘 작동할 수도 있다. 2022년에 미국의 지방정부 예산 수입을 예측하기 위해 머신러닝을 활용한 연구(Chung et al., 2022)에서는 인공 신경망의 일종인 일반화 회귀 신경망(GRNN), 회귀 기반 방법론인 K-최근접 이웃 알고리즘(KNN), 의사결정 트리 방법론인 분류 및 회귀 트리(CART) 등의 방법론을 활용했다.

본 연구에서는 다양한 머신러닝 알고리즘을 적용하여 지방세수 예측 모델의 예측력을 비교하고, 성능과 더불어 세수 담당자의 해석 가능성, 계산 비용 등의 요소를 고려하여 머신러닝 방법론의 적용이 지방세수 예측의 정확도를 높일 가능성이 있는지 살펴본다.

### Ⅲ. 연구 설계 및 분석 결과

#### 1. 학습 자료 및 분석방법

본 연구는 지방세수 예측을 실행하기 위해 '자료 수집-분석 모형 설계(학습)-분석'의 과정을 반복한다. 행정안전부의 예산자료를 수집하여 머신러닝 알고리즘별로 학습한 뒤, 각각의 예측치와 실제 징수 실적을 비교한다. 분석 모형 설계(학습)과정은 일반적인 머신러닝 방법 적용 순서를 따른다. 우선 자료를 학습데이터, 검증데이터, 테스트데이터로 구분한 뒤, 학습

데이터에 알고리즘을 적용하여 예측모형을 설정한다. 이후 검증데이터로 정확성을 극대화할 수 있는 모수 튜닝(parameter tuning)을 반복하여 최종 모형을 선택하고, 다시 테스트데이터를 활용하여 예측의 정확성을 평가한다(정일환, 2021). 본 연구에서도 학습데이터와 검증데이터로 나누어 모델을 확정하고 예측을 실시하였다.

시간순으로 살펴보면 2017년부터 2021년 지방세 규모를 예측하는데 있어 N년도까지 데이터로 N+2년을 예측하였다. 예를 들어, 2017년 지방세수를 예측하기 위해 2015년까지의 데이터만 사용하였고, 그 이후 데이터는 전무하다고 가정하였다. 이를 확장하면 2018년 지방세수 예측에는 2016년까지, 2019년 지방세수 예측에는 2017년까지 데이터만 사용하였고, 동일한 방식으로 2021년 지방세수 예측치는 2019년 자료까지만 사용하였다.

지방세수 예측을 위해 세 가지 성격 8가지 알고리즘을 적용한다. 첫째, 회귀기반 방법론으로 선형 회귀, 릿지 회귀, 라쏘 회귀이다. 둘째, 비선형기반으로 결정 트리, 랜덤 포레스트, 그라디언트 부스팅이다. 셋째, 순환신경망(RNN)기반 LSTM, GRU이다. 모델별 일반화 성능을 확인하기 위해 RNN 모델을 제외한 모든 모델은 기본 하이퍼파라미터를 사용하였다. 지방세는 시계열자료이기에 연도 간 상관관계가 존재하는 문제점이 있다. 이는 훈련데이터와 검증데이터가 상호독립적이면서 동일한 확률분포(independent and identically distributed: iid)를 가진다는 가정을 위배하게 된다. 때문에 다양한 알고리즘을 적용하여 지방세라는 시계열 데이터를 예측하는데 적합한 알고리즘이 무엇인지 살펴본다.

해당 방식을 적용하여 2017년부터 2021년까지 5개년 연도별 예측결과를 도출하고 이를 행정안전부의 기존 지방세수 추계방식에 따른 예측값(당초예산) 및 실제 5개년 연도별 징수실적과 비교하였다. 징수실적과 예측 데이터의 비교는 잔차 오차 판별 기준으로 사용되는 RMSE(Root Mean Squared Error, 평균 제곱근 오차)와 MAPE(Mean Absolute Percentage Error, 평균 절대 백분율 오차)를 활용하였다. RMSE는 예측값과 실제값 간 차이 제곱의 평균에 제곱근으로 측정하고, MAPE는 예측값과 실제값 사이의 절대적 백분율 차이의 평균으로 계산한다. 두 가지 모두 수치가 낮을수록 예측의 정확도가 높다고 해석하며, 계산식은 다음과 같다.

$$MAPE = \frac{1}{n} \sum_{t=1}^n \left| \frac{Z_t - \hat{Z}_t}{Z_t} \right| \times 100 \dots\dots\dots(1)$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{t=1}^n (Z_t - \hat{Z}_t)^2} \dots\dots\dots(2)$$

t = 시점,  $Z_t$  = t 시점의 관측치,  $\hat{Z}_t$  = t 시점 예측치

학습에 사용된 데이터는 1994년부터 2021년까지 지방세 징수실적(순계기준)이다. 예측하고자 하는 2017년에서 2021년에 대해 각 연도에서 2년 전까지 값만을 사용하여 학습을 실시하였다. 그리고 지방세수도 시도별, 시군구별, 시도에 세목별 구분을 결합한 경우, 시군구에 세목별 구분을 결합한 경우 네 가지로 구분하여 학습량이 달라질 때 예측의 결과도 달라지는지 살펴보았다.

시간의 경과에 따라 자치단체명이 변경되었거나 통·폐합된 지역도 모두 학습에 사용하며 최신 지역명을 기준으로 과거 데이터를 통합하였다. 이에 총 17개 광역자치단체(시도), 226개 기초자치단체(시군구)의 지방자치단체별 데이터를 학습에 사용하였다. 동일한 방법으로 1994년부터 2021년까지 세목명이 변경되었거나 통·폐합된 부분까지 모두 학습에 사용하였고, 중복을 제외하면 총 23개 세목이 학습에 사용되었다. 다만 연구기간 중 기존 재산세와 종합토지세가 재산세로 통합되는 등 지방세 세목의 주요 내용이 변경<sup>2)</sup>된 경우가 존재하기에 시도별, 시군구별로 구분한 예측치를 중심으로 연구결과를 분석하고, 세목별 학습의 경우 앞선 구분에 추가하여 학습량이 세분화될수록 예측의 정확도에 영향을 미치는지 살펴보는데 그친다.

〈표 3〉 학습에 사용된 지방세 세목 구분(1994~2021)

연도	세목	수(개)
1994년 ~ 2018년	취득세, 등록세, 면허세, 주민세, 재산세, 자동차세, 농업소득세, 도축세, 레저세, 담배소비세, 주행세, 종합토지세, 도시계획세, 공동시설세, 사업소세, 지역개발세, 지방교육세, 지난년도수입	18
2019년 이후	취득세, 재산세, 등록면허세, 지역자원시설세, 자동차세, 주민세, 지방소득세, 지방소비세, 담배소비세, 레저세, 지방교육세, 지난년도수입	12
중복 제외 합계		23

학습에 사용한 총 징수실적(규모)의 변화추이를 살펴보면 1998년과 2009년, 2013년, 2016년, 2018년을 제외하고 1994년부터 2021년까지 전년 대비 증가하는 추세이다.

2) 연구기간 중 세목 통·폐합에 의한 변경은 다음과 같다. 2005년에는 종합토지세와 재산세가 재산세로 통합되었고, 2010년에는 주민세(균등할, 소득할)과 사업소세(재산할, 종업원할)이 주민세(균등분, 재산분)과 지방소득세(종업원분, 소득분)로 개편되었고, 자동차세와 주행세가 자동차세로 통합, 재산세와 도시계획세가 재산세로 통합되었다. 2014년에는 지방소득세 종업원분이 주민세 종업원분으로 전환되었다.

〈표 4〉 지방세 징수 규모(1994~2021)

(단위: 천원)

연도	징수실적	연도	징수실적
1994	13,158,532,134	2008	45,622,842,577
1995	15,494,592,259	2009	45,167,789,510
1996	17,407,902,024	2010	49,159,804,982
1997	18,402,297,620	2011	52,300,144,494
1998	17,225,238,697	2012	53,938,064,336
1999	18,616,273,165	2013	53,778,880,641
2000	20,602,537,923	2014	61,725,013,244
2001	26,665,055,185	2015	70,977,794,136
2002	31,525,799,629	2016	75,531,651,466
2003	33,132,942,858	2017	80,409,136,820
2004	34,091,408,026	2018	84,318,258,059
2005	35,977,358,996	2019	90,460,408,494
2006	42,812,025,242	2020	102,048,782,443
2007	43,524,289,072	2021	112,798,429,503

## 2. 예측결과 비교

머신러닝 알고리즘을 통해 도출한 세수예측치와 기존 세수예측방식을 적용한 결과(당초예산)를 실제 값인 징수실적과 비교하고, 머신러닝 방법론을 활용한 세수예측의 정확도가 증가하였는지 분석한 결과이다.

### 1) 알고리즘별 예측결과(RNN 제외)

다양한 머신러닝 알고리즘을 통해 도출한 지방세수 예측치를 시도별, 시군구별, 시시도에 세목별 구분을 결합한 경우, 시군구에 세목별 구분을 결합한 경우 네 가지로 구분하여 제시하면 다음과 같다. 첫째, 2017년부터 2021년까지 기존 지방세추 예측방법을 적용한 예측값(당초예산)보다 낮은 규모의 세입액을 예측하였다. 이는 서울시만을 대상으로 머신러닝 방법론을 적용한 정일환(2021)의 연구 결과와 부분적으로 일치한다. 하지만 지방세수 예측에 있어 머신러닝 방식 적용의 유용성은 존재한다. 정일환(2021) 연구에서는 서울시 세입 자료를 바탕으로 세입변동이 적은 기간, 큰 기간으로 다양한 기간을 예측하였는데, 여러 기간 중 2010년부터 2014년까지 기간에서는 머신러닝 방법이 기존 방식보다 예측정확성이 높게 나타났다.

이를 통해 예측대상과 시기에 따라 정확성이 달라질 수 있음을 알 수 있다.

둘째, 시도별, 시군구별, 시도에 세목별 구분을 결합한 경우, 시군구에 세목별 구분을 결합한 경우 네 가지로 구분한 학습량 차이에 따른 예측의 정확도는 알고리즘에 따라 다르게 나타났다. 랜덤 포레스트(rf)의 경우에는 학습량이 증가하면 상대적으로 예측치가 증가하여 정확도가 높아졌다.

〈표 5〉 지방세 예측 결과(RNN 제외)

(단위: 십억원)

연도 / 구분		2017	2018	2019	2020	2021
징수실적		80,409	84,318	90,460	102,049	112,798
당초예산		71,189	77,914	81,827	90,950	92,605
linear	시도별	66,973	71,498	76,100	80,833	85,486
	시군구별	65,848	70,181	74,587	79,114	83,562
	시도+세목별	59,655	62,351	67,239	72,775	78,312
	시군구+세목별	57,460	60,263	65,028	69,453	74,419
ridge	시도별	67,154	71,536	76,052	80,728	85,343
	시군구별	65,784	70,120	74,532	79,060	83,511
	시도+세목별	59,673	62,358	67,241	72,775	78,310
	시군구+세목별	57,421	60,228	64,995	69,415	74,379
lasso	시도별	66,973	71,498	76,100	80,833	85,486
	시군구별	65,847	70,180	74,586	79,113	83,561
	시도+세목별	59,655	62,351	67,239	72,775	78,312
	시군구+세목별	57,459	60,262	65,026	69,451	74,417
tree	시도별	61,725	70,978	75,532	80,409	84,318
	시군구별	61,725	70,978	75,532	80,409	84,318
	시도+세목별	61,726	70,978	75,532	80,409	84,318
	시군구+세목별	61,722	70,992	75,536	80,409	84,318
rf	시도별	58,955	67,045	72,785	77,539	81,888
	시군구별	59,142	67,338	73,059	78,102	82,257
	시도+세목별	59,884	67,258	73,320	77,968	82,712
	시군구+세목별	59,263	67,532	73,108	78,247	82,193
gb	시도별	60,384	69,502	73,752	78,627	82,473
	시군구별	53,157	62,120	66,506	70,846	75,449
	시도+세목별	57,472	63,714	70,154	75,189	79,639
	시군구+세목별	52,183	58,487	65,639	70,205	74,121

2017년부터 2021년까지 실제 징수실적과 머신러닝 방식을 활용한 지방세수 예측치와 기존 세수예측 방식(당초예산)과의 차이를 살펴보면 다음과 같은 특징이 나타났다. 첫째, 모든 연도에서 기존 세수예측 방식(당초예산)이 가장 차이가 작았다. 둘째, 지방세수 오차의 크기는 모델에 따라 다르게 나타났으며, 동일한 모델이더라도 학습량의 세분화 정도에 따라서 예측 편차의 범위가 상당히 다르게 나타났다. 대표적으로 tree의 경우에는 학습량이 시도별, 시군구별, 세목별로 세분화되더라도 예측치 편차가 크지 않았다. 이에 반해 라쏘 회귀의 경우 학습량에 따라 예측의 편차가 크게 나타났다. 마지막으로 모든 연도에서 예측치와 실제 징수 실적 간 차이가 마이너스(-) 값을 보였다. 이는 과소예측을 의미하며, 머신러닝 방법론을 적용하더라도 대부분 지방자치단체에서 과소예측을 실행하는 현실과 유사한 결과가 나타남을 확인할 수 있다. 지방세수의 과소예측은 재정자립도가 낮은 기초자치단체일수록 전체 예산에서 자체재원이 차지하는 비중이 낮아서 세수예측을 소홀히 하거나 추가경정예산 편성에서 여유자금을 확보하고자 정확한 지방세수 예측의 유인이 감소할 수 있다고 본다(최병호·이근재, 2016).

〈표 6〉 지방세 예측 결과와 징수실적의 차이

(단위: 십억원)

연도 / 구분		2017	2018	2019	2020	2021
징수실적		80,409	84,318	90,460	102,049	112,798
당초예산		-9,220	-6,404	-8,634	-11,099	-20,194
linear	시도별	-13,436	-12,820	-14,360	-21,216	-27,313
	시군구별	-14,561	-14,138	-15,874	-22,935	-29,236
	시도+세목별	-20,754	-21,967	-23,221	-29,274	-34,487
	시군구+세목별	-22,949	-24,055	-25,433	-32,596	-38,379
ridge	시도별	-13,256	-12,782	-14,408	-21,321	-27,456
	시군구별	-14,625	-14,199	-15,929	-22,989	-29,288
	시도+세목별	-20,736	-21,960	-23,219	-29,274	-34,489
	시군구+세목별	-22,988	-24,091	-25,465	-32,634	-38,420
lasso	시도별	-13,436	-12,820	-14,360	-21,216	-27,313
	시군구별	-14,562	-14,138	-15,874	-22,936	-29,237
	시도+세목별	-20,754	-21,967	-23,221	-29,274	-34,487
	시군구+세목별	-22,950	-24,057	-25,434	-32,598	-38,382

연도 / 구분		2017	2018	2019	2020	2021
tree	시도별	-18,684	-13,340	-14,929	-21,640	-28,480
	시군구별	-18,684	-13,340	-14,929	-21,640	-28,480
	시도+세목별	-18,683	-13,341	-14,929	-21,640	-28,480
	시군구+세목별	-18,687	-13,326	-14,924	-21,639	-28,480
rf	시도별	-21,454	-17,273	-17,676	-24,510	-30,911
	시군구별	-21,267	-16,980	-17,401	-23,947	-30,541
	시도+세목별	-20,525	-17,060	-17,141	-24,080	-30,086
	시군구+세목별	-21,146	-16,786	-17,353	-23,801	-30,605
gb	시도별	-20,025	-14,817	-16,708	-23,422	-30,326
	시군구별	-27,252	-22,198	-23,954	-31,202	-37,349
	시도+세목별	-22,937	-20,605	-20,307	-26,860	-33,159
	시군구+세목별	-28,226	-25,831	-24,822	-31,843	-38,677

최종적으로 머신러닝 알고리즘을 활용한 지방세수 예측 결과에 대해 RMSE(Root Mean Squared Error, 평균 제곱근 오차)와 MAPE(Mean Absolute Percentage Error, 평균 절대 백분율 오차)를 적용하여 추계정확도를 살펴본 결과는 다음과 같다. 첫째, 수치가 낮을수록 추계정확도가 높다고 판단하는데 시도별, 시군구별, 시도에 세목별 구분을 결합한 경우, 시군구에 세목별 구분을 결합한 경우 네 가지 구분 모두에서 기존 세수예측 방식(당초예산)의 정확도가 가장 높았다.

둘째, 머신러닝 알고리즘만을 대상으로 예측의 정확성을 평가하면 시도별로 구분한 경우에는 MAPE와 RMSE 모두에서 선형 회귀와 라쏘 회귀가 예측 정확성이 가장 높게 나타났다(MAPE=0.2301, RMSE=18,693,351,565). 시군구별로 구분했을 경우 MAPE는 선형 회귀와 라쏘 회귀가 0.2550으로 예측의 정확도가 높게 측정되었고, RMSE는 결정 트리가 20,146,099,702로 정확도가 높게 나타났다. 시도에 세목별 구분을 결합한 경우에는 MAPE와 RMSE 모두 결정 트리가 예측 정확성이 가장 높게 나타났다(MAPE=0.2590, RMSE=20,145,928,664). 시군구와 세목별 구분을 결합한 경우에서도 MAPE와 RMSE 모두 결정 트리가 예측 정확성이 가장 높게 나타났다(MAPE=0.2590, RMSE=20,144,086,853).

〈표 7〉 지방세 예측 결과에 대한 성능평가

구분		MAPE	RMSE
당초예산		0.1315	12,095,726,764
linear	시도별	0.2301	18,693,351,565
	시군구별	0.2550	20,221,822,658
	시도+세목별	0.3776	26,452,911,404
	시군구+세목별	0.4349	29,283,490,399
ridge	시도별	0.2303	18,735,452,822
	시군구별	0.2560	20,275,507,283
	시도+세목별	0.3775	26,449,077,230
	시군구+세목별	0.4358	29,320,088,709
lasso	시도별	0.2301	18,693,351,592
	시군구별	0.2550	20,222,708,365
	시도+세목별	0.3776	26,452,974,502
	시군구+세목별	0.4350	29,285,220,626
tree	시도별	0.2590	20,146,099,702
	시군구별	0.2590	20,146,099,702
	시도+세목별	0.2590	20,145,928,664
	시군구+세목별	0.2590	20,144,086,853
rf	시도별	0.3116	22,922,828,068
	시군구별	0.3056	22,581,615,149
	시도+세목별	0.3006	22,321,291,230
	시군구+세목별	0.3039	22,508,845,321
gb	시도별	0.2874	21,761,981,135
	시군구별	0.4331	28,905,871,883
	시도+세목별	0.3571	25,234,908,522
	시군구+세목별	0.4672	30,298,483,068

## 2) RNN 모델 예측결과

RNN 모델의 경우 시도-시군구-세목별로 세분화된 지방세 데이터를 학습하고 예측한 값을 중심으로 분석한다. 시계열 데이터에 적합하면서 예측 정확도가 높은 모델을 찾기 위해 batch, unit, patience를 다양하게 조절하였다. 이를 MAPE 성능평가 결과에 따라 정렬하면 대체로 LSTM보다 GRU의 정확도가 높게 나타났다.

GRU 중에서도 “batch 32, unit 100, patience 10”이 가장 정확도가 높았으며, 이는 기존 세수예측 방식(당초예산)보다도 정확도가 높은 예측값이었다. 특정 batch, unit, patience에서

기존보다 정확도가 높았기에 향후 지방자치단체별 또는 세목별 예측에서 해당 모델을 중심으로 세부 조정을 실시하는 후속연구의 필요성이 존재한다.

〈표 8〉 RNN 모델의 예측결과

구분	MAPE	RMSE	비고
GRU	0.0643	5,842,315,430	batch: 32, unit: 100, patience: 10
당초예산	<b>0.1315</b>	<b>12,095,726,764</b>	-
GRU	0.1525	15,165,526,085	batch: 16, unit: 100, patience: 100
GRU	0.1787	14,950,026,009	batch: 16, unit: 100, patience: 50
GRU	0.1792	15,405,631,404	batch: 16, unit: 100, patience: 10
GRU	0.1794	14,876,567,641	batch: 1, unit: 100, patience: 50
GRU	0.1933	15,657,180,033	batch: 1, unit: 100, patience: 100
GRU	0.2023	16,952,705,641	batch: 8, unit: 100, patience: 50
GRU	0.2129	22,302,732,527	batch: 8, unit: 50, patience: 50
GRU	0.2140	16,219,080,824	batch: 8, unit: 100, patience: 10
GRU	0.2144	17,322,103,632	batch: 1, unit: 50, patience: 50
GRU	0.2326	18,649,574,211	batch: 32, unit: 50, patience: 50
GRU	0.2420	21,264,321,468	batch: 32, unit: 50, patience: 100
GRU	0.2715	19,957,405,285	batch: 1, unit: 50, patience: 100
LSTM	0.2781	34,535,576,593	batch: 16, unit: 100, patience: 100
GRU	0.3025	21,491,865,251	batch: 1, unit: 100, patience: 10
GRU	0.3043	20,826,364,141	batch: 1, unit: 50, patience: 10
GRU	0.3152	22,122,329,433	batch: 8, unit: 50, patience: 100
GRU	0.3353	23,884,501,140	batch: 8, unit: 100, patience: 100
GRU	0.3627	24,718,173,012	batch: 32, unit: 100, patience: 100
GRU	0.3728	28,301,848,941	batch: 32, unit: 100, patience: 50
GRU	0.3847	29,505,235,570	batch: 16, unit: 50, patience: 100
LSTM	0.3890	25,140,304,969	batch: 32, unit: 100, patience: 50
LSTM	0.3939	27,440,537,940	batch: 16, unit: 100, patience: 50
LSTM	0.4056	25,801,357,542	batch: 8, unit: 100, patience: 100
LSTM	0.4270	30,177,672,617	batch: 8, unit: 50, patience: 100
LSTM	0.4455	32,266,237,443	batch: 1, unit: 50, patience: 50
GRU	0.4853	28,955,895,536	batch: 8, unit: 50, patience: 10
LSTM	0.5167	34,220,221,762	batch: 32, unit: 100, patience: 100
LSTM	0.5760	33,539,532,236	batch: 32, unit: 50, patience: 100
LSTM	0.5849	34,364,574,308	batch: 1, unit: 100, patience: 100
LSTM	0.6577	36,306,414,929	batch: 16, unit: 50, patience: 100

구분	MAPE	RMSE	비고
GRU	0.6966	35,074,239,395	batch: 16, unit: 50, patience: 50
LSTM	0.7073	31,690,013,921	batch: 1, unit: 100, patience: 50
LSTM	0.7085	34,412,522,202	batch: 8, unit: 100, patience: 10
LSTM	0.9352	45,585,886,107	batch: 1, unit: 100, patience: 10
LSTM	1.0780	58,528,001,518	batch: 8, unit: 50, patience: 50
LSTM	1.1989	44,628,688,136	batch: 16, unit: 100, patience: 10
GRU	1.2547	49,752,919,235	batch: 32, unit: 50, patience: 10
LSTM	1.2982	47,611,157,743	batch: 8, unit: 100, patience: 50
LSTM	1.3543	58,877,853,294	batch: 16, unit: 50, patience: 50
LSTM	1.5040	47,669,613,344	batch: 32, unit: 50, patience: 50
LSTM	1.6374	54,551,039,719	batch: 32, unit: 100, patience: 10
GRU	1.7282	52,016,038,306	batch: 16, unit: 50, patience: 10
LSTM	2.1872	60,233,560,517	batch: 1, unit: 50, patience: 100
LSTM	3.6465	67,593,673,813	batch: 8, unit: 50, patience: 10
LSTM	10.1473	78,964,442,094	batch: 32, unit: 50, patience: 10
LSTM	10.3084	63,108,072,782	batch: 16, unit: 50, patience: 10
LSTM	44.1927	63,793,241,892	batch: 1, unit: 50, patience: 10

주: batch: 한번에 학습하는 데이터 사이즈, unit: 뉴런 수, patience: Early Stopping 단계 수

MAPE 성능평가를 기준으로 연도별 지방세 예측치 상위값을 연도별로 제시하면 다음과 같다.

〈표 9〉 MAPE 기준 지방세 예측치 상위값(RNN 모델)

(단위: 십억원)

구분	2017	2018	2019	2020	2021	비고
징수실적	80,409	84,318	90,460	102,049	112,798	
당초예산	71,189	77,914	81,827	90,950	92,605	
GRU	74,930	89,816	85,127	94,155	108,365	#1
	97,317	75,255	92,302	77,117	100,269	#2
	53,899	77,141	71,773	100,181	109,555	#3
LSTM	49,845	71,137	104,280	169,970	119,961	#2
	50,303	41,022	88,629	83,565	118,650	#4
	89,159	47,970	74,182	60,519	93,370	#3

주: #1: batch: 32, unit: 100, patience: 10  
 #2: batch: 16, unit: 100, patience: 100  
 #3: batch: 16, unit: 100, patience: 50  
 #4: batch: 32, unit: 100, patience: 50

MAPE 성능평가를 기준으로 지방세 예측치 상위값과 실제 징수실적과의 차이를 살펴보면 2018년을 제외하고 GRU가 기존 세수예측 방식(당초예산)보다 징수실적과의 차이, 즉 지방세수 오차가 더 적은 것으로 나타났다. 이는 시계열 데이터를 활용하여 예측을 실시할 경우 RNN모델 기반의 알고리즘 적용이 적절함을 의미한다.

〈표 10〉 지방세 예측 결과와 징수실적의 차이(RNN 모델)

구분	2017	2018	2019	2020	2021
징수실적	80,409	84,318	90,460	102,049	112,798
당초예산	-9,220	-6,404	-8,634	-11,099	-20,194
GRU	-5,479	5,498	-5,334	-7,894	-4,434
	16,908	-9,063	1,841	-24,932	-12,529
	-26,510	-7,177	-18,687	-1,868	-3,243
LSTM	-30,564	-13,182	13,820	67,921	7,163
	-30,106	-43,296	-1,831	-18,484	5,851
	8,750	-36,348	-16,279	-41,529	-19,428

## IV. 결론

정확한 지방세수 예측을 통해 안정적인 재정규모를 확보하면 장기적인 지출을 계획할 수 있고, 지역에 적합한 공공서비스를 능동적으로 제공하여 지방자치를 실현하는 수단이 될 수 있다. 이에 지방세수 예측의 정확도를 높이려면 경제환경 변화를 면밀하게 파악하거나 추계 모형을 정밀화해야 할 것이다. 현재 지방세수 예측 방식에서는 세입특수요인 등을 통해 경제환경 변화를 반영할 수 있도록 노력하고 있다. 하지만 인간의 인지적 한계라는 근본적인 문제와 함께 요인에 포함되지 않은 관찰되지 않는 변수의 영향으로 인해 예측값과 실제 징수액 간의 차이(오차)가 발생할 여지가 있다. 거기다가 자연재난 및 전염병과 같이 한시적이며 급작스럽게 등장하는 변화를 즉시 반영하기 어렵다는 문제점이 존재한다. 때문에 경제환경 변화를 반영할 수 있는 변수를 고민하면서도 다양한 변화를 반영할 수 있는 지방세수 예측 모형을 고민할 필요가 있다.

이에 본 연구는 머신러닝 방법론을 적용하여 지방세수 예측의 정확성을 높이고, 나아가 계획적인 재정운영의 기틀을 마련하고자 한다. 우리나라 지방자치단체의 1994년부터 2021년

까지 지방세 징수실적 자료를 바탕으로 다양한 머신러닝 방법론을 적용하여 2017년부터 2021년까지 지방세수 예측치를 추정하였다. 그리고 기존 세수예측 방식(당초예산)까지 포함하여 정확도를 점검하여 적절한 세수 예측 방법이 존재하는지 살펴보았다. 연구에 사용된 머신러닝 방법론은 선형 회귀, 릿지 회귀, 라쏘 회귀 등 회귀 기반 방법론과 결정 트리, 랜덤 포레스트, 그래디언트 부스팅 등을 적용하는 방식, 마지막으로 LSTM이나 GRU와 같은 순환 신경망(RNN) 기반의 시계열 특성을 고려한 방식을 모두 적용하였다. 본 연구는 세수 예측 정확도 향상이 재정건전성에 기여한다는 전제하에 시도별, 시군구별, 시도에 세목별 구분을 결합한 경우, 시군구에 세목별 구분을 결합한 경우 네 가지 방식으로 학습량에 따른 예측치 변화까지 분석하였다. 예측 정확도는 MAPE, RMSE를 사용하여 측정하였다.

주요 연구 결과를 요약하면 다음과 같다. 첫째, 대체로 기존 세수 예측 방식이 예측의 정확성 측면에서 우월한 반면 RNN 기반의 GRU는 예측의 정확도가 기존 방식보다도 높게 나타났다. 이는 시계열자료를 사용한 예측에서 머신러닝 방법론 적용이 가능함을 시사한다. 다양한 머신러닝 방법론 중 시간에 따른 학습자료와 예측자료 간 대응관계를 학습하는 GRU가 데이터의 상호 독립성을 가정하는 다른 모델에 비해 예측의 정확도가 높았다는 점에서 자료의 특성을 파악하고 이에 적합한 알고리즘을 채택할 필요성을 시사한다.

둘째, 머신러닝 방법론만을 대상으로 성능평가를 실시하면 학습량에 따라 정확도가 높은 알고리즘이 다르게 나타난다. 시도별로 구분한 총액자료를 학습했을 때는 선형 회귀와 라쏘 회귀의 예측 정확도가 높았다. 시군구별로 구분한 총액자료만을 대상으로 학습했을 때 MAPE 성능평가를 기준으로는 선형 회귀와 라쏘 회귀가 예측의 정확도가 높았고, RMSE 성능평가 기준은 결정 트리의 정확도가 높았다. 시도에 세목별 구분을 결합한 경우와 시군구와 세목별 구분을 결합한 경우에는 모두 결정 트리가 정확성이 가장 높았다. RNN 모델의 경우에는 GRU의 정확도가 가장 높았다. 이를 통해 기존 세수 예측 방식과 더불어 머신러닝 알고리즘을 추가 적용하면 지방세수의 최소값과 최대값을 예측할 수 있어 정책 담당자에게 변화폭에 따른 대응 전략을 마련할 기회를 제공할 수 있다. 다만 해당 연구가 지방자치단체별 총 지방세수를 예측했다는 점에서 향후 지방세를 세목별로 구분하여 예측을 시행하는 후속 연구를 통해 적절한 알고리즘을 검토해야 할 것이다.

본 연구는 최근 부상하고 있는 머신러닝 방법을 적용하여 지방세수 예측을 시도하였고, 다양한 알고리즘을 적용했다는 측면에서 연구의 의의를 갖는다. 분석 결과 특정 알고리즘만이 기존 방식보다 정확도가 높게 나타났지만 지방세수 예측과정에서 머신러닝 방법을 적용하면 세수오차를 줄일 가능성이 있음을 확인하였다. 기존 세수 추계 방식은 회귀분석을 기반으로 하고 있기에 인과관계 추정이 주 목적이며, 오차항 가정 등 다양한 제약이 존재한다(최필선·민인식, 2018). 하지만 머신러닝 알고리즘의 적용은 기존 인과관계에 의존하지 않고도 데이

터 기반 학습을 통해 정확성 높은 예측이 가능하다는 특징을 갖는다(정재현·이환웅, 2020). 본 연구는 머신러닝의 유용성을 확인함으로써 추계방식 개선의 방향성을 검토하였고, 이를 바탕으로 예측력 높은 모형이 구축되면 급격한 환경 변화에 선제적으로 대응하여 안정적인 재정 운영에 기여할 수 있다.

게다가 머신러닝 방법론은 정확도뿐만 아니라 예측에 소요되는 시간, 정보 투명성, 세수 담당자의 해석 가능성 등을 종합적으로 고려하면 기존 추계 방식을 기준으로 보조적인 수단으로 예측에 활용할 때 장점이 있다. 우선 데이터만 입수하면 빠른 시간 내에 예측치를 얻을 수 있다(송석현, 2021). 기존에는 데이터 취득과 입력, 결과 도출까지 담당자가 직접 수행하는 방식이라서 결과 예측에 상당한 시간이 소요되지만 머신러닝을 이용하면 신속하게 결과를 확인할 수 있다. 그리고 빅데이터를 활용하기에 정책 결과의 공신력을 높일 수 있다(송석현, 2021). 더불어 지방세수 예측 담당자의 노하우로 여겨지는 영역을 증거기반 정책의 영역으로 전환할 수 있다. 특히, 순환보직으로 인해 업무에 익숙해지면 새로운 업무로 변경되는 현실을 고려하면 세수 담당자의 경험이나 직관에만 의지하는 세수 예측은 불안정적이지만 머신러닝 알고리즘을 적용하면 최소한 세수 범위라도 확정할 수 있다.

다만 본 연구를 통해 같은 알고리즘(모델)을 사용하더라도 연도별 예측치의 성능이 달라질 수 있다는 점을 확인하였다. 따라서 한가지 방법론에 전적으로 의지하기보다 세목별 특성을 반영할 수 있는 알고리즘을 찾는 후속 연구가 이어져야 할 것이다. 지방세 11개 세목별로 징수 대상과 세수 규모에 영향을 미치는 변수가 달라서 동일한 머신러닝 방법론을 적용하더라도 예측의 정확도는 다르게 나타날 수 있다. 학습과정에서 세목별로 구분한 자료를 사용하여 세분화된 학습량에 따른 예측값 변화를 살펴보았으나, 총액을 기준으로 성능 비교를 실시했다는 한계가 존재한다. 본 연구가 지방세수 예측에서 머신러닝 알고리즘을 적용한 분석이 초기 단계임을 고려하여 적용 가능성 자체를 판단하고 다양한 알고리즘의 유용성을 살펴보는 데 집중하였지만 향후 개별 세목별로 추세를 예측하고, 각 세목을 예측하는데 적절한 알고리즘이 무엇인지에 관한 연구가 필요하다.

기존보다 지방세수 예측 오차가 적은 알고리즘이 GRU로만 나타났다는 점에서 급속한 기술 발전 속도에도 불구하고 머신러닝에 대한 지나친 낙관을 경계할 필요가 있다(Makridakis et al. 2018; 정일환, 2021). 학습을 위해 축적된 지방세수 데이터는 국세에 비해 적으며, 세목 통·폐합과 같은 제도 변화로 인해 연속성이 확보되지 못한 세목이 존재한다는 한계를 염두하고 기존 추계 방식과 더불어 예측의 범위를 가늠할 수 있는 보조적인 수단으로 활용해야 할 것이다.

## 【참고문헌】

- 고경희·이종욱. (2021). 텐서플로우 순환신경망 라이브러리를 이용한 음식물 쓰레기 배출량 예측. 「한국정보과학회 학술발표논문집」, 1783-1785.
- 고영선. (2000). 「세수추계모형의 예측력 비교」. KDI.
- 김병조·은종환. (2020). 행정-정책 의사결정에서 머신러닝(machine learning) 방법론 도입의 정책적 함의: 기계의 한계와 증거기반 의사결정(evidence-based decision-making). 「한국행정학보」, 54(1): 261-285.
- 김재영·전영준·김계원. (2004). 지방세 세수 추계 개선 방안 연구-경기도 취득세·등록세를 중심으로. 「현대사회와 행정」, 14: 1-27.
- 김현아. (2002). 「서울시 세입예측을 위한 모형 연구」. 기본연구과제. 서울연구원.
- 배상석. (2013). 우리나라 지방자치단체들의 세입추계오차에 관한 연구. 「한국정책학회보」, 22(1): 361-388.
- 배상석. (2016). 테일 오차분해기법을 사용한 지방정부 세입예측 오차에 관한 연구. 「한국자치행정학보」, 30(3): 95-121.
- 배인명. (2012). 지방자치단체의 재정건전성에 대한 연구. 「정책분석평가학회보」, 22(4): 261-284.
- 박지현. (2021). 「서울시 취득 세수의 예측오차 분석: 부동산 대책간의 영향을 중심으로-」. 수시과제 2021-04호. 한국지방세연구원.
- 송석현. (2021). 머신러닝을 활용한 국고잔액 예측 모형 개발. 「한국 SCM 학회지」, 21(2): 63-72.
- 이상훈·김진하·이지연. (2012). 「중기 지방세수 추계모형 개발을 위한 연구」. 한국지방세연구원.
- 이석환. (2018). 지방세 세수예측방법의 비교평가: 서울시를 중심으로. 「한국공공관리학보」, 32(2): 25-56.
- 이석환·박근화. (2016). 지방세 세수추계모형의 비교·평가: 서울시를 중심으로. 「한국공공관리학회 학술대회」, 77-102.
- 이영희·조기현. (1998). 「지방세수 예측을 위한 모형의 탐색: 광역정부를 중심으로」. 한국지방행정연구원 기본연구과제.
- 이은국. (1994). 서울시 세입. 세출의 예측행태와 예측의 정확도를 위한 Box-Jenkins 모형 분석. 「한국행정학보」, 28(1): 263-284.
- 이진수·김재훈·최승필·임현. (2020). 「재정건전성의 법적 개념과 기준」. 한국법제연구원.
- 이태석. (2015). 「구조변화를 고려한 세수추계 개선방안 모색」. 정책연구 2015-25. Korea Development Institute(KDI).
- 이학연·이현우·김진덕. (2021). 「자치분권시대 지방정부 세입운영의 효율화 방안: 세수예측방법을 중심으로」. 경기연구원 정책연구.

- 이현선·박태규. (2007). 지방세 추계모형 연구: 지수평활법을 중심으로. 「한국지방재정논집」, 12(2): 65-90.
- 임성일, 서정섭. (2004). 지방재정분석 및 평가지표 실용성 검증. 「한국지방재정논집」, 9(2): 1-21.
- 정일환. (2021). 머신러닝 접근의 재정관리: 세입추세 예측모형 연구. 「국정관리연구」, 16(4): 1-28.
- 정재현·이환웅. (2020). 「머신러닝을 활용한 조세·재정정책의 평가와 설계」. 한국조세재정연구원.
- 조임곤. (2001). 지방세 수입 예측기법의 탐색 및 활용. 「한국행정학보」, 35(4): 261-273.
- 조택희. (2005). 지방세 세수추정 모형에 관한 연구-충청북도의 경우를 중심으로. 「한국동서경제연구」, 17: 17-40.
- 최병호·이근재. (2016). 지방세수 추계 오차와 지방재정지출의 효율성. 「한국지방재정논집」, 21(3): 65-91.
- 최필선·민인식. (2018). 머신러닝 기법을 이용한 대졸자 취업예측 모형. 「직업능력개발연구」, 21(1): 31-54.
- 한재명. (2022). 「지방세 세수추계 개선방안」. 수사과제 2022-06호. 한국지방세연구원.
- 허명순. (2011). 지방재정 건전성 측정방법: 재정압박 지수개발을 중심으로: 재정압박 지수개발을 중심으로. 「한국지방재정논집」, 16(1): 177-210.
- 행정안전부. (2022). 「2022년 지방세 세수 추계 업무 매뉴얼」.
- Burkhead, J. (1956). *Governmental Budgeting*. New York: Hojn Wiley and Sons, Inc.
- Beth Walter Honadle, Beverly Cigler and James M. Costa. (2003). *Fiscal Health for Local Government*. Elsevier academic press.
- Caiden, N., & Wildavsky, A. B. (1980). *Planning and budgeting in poor countries*. New York: Hojn Wiley and Sons, Inc.
- Chung, I. H., Williams, D. W., & Do, M. R. (2022). For Better or Worse? Revenue Forecasting with Machine Learning Approaches. *Public Performance & Management Review*, 45(5): 1133-1154.
- Groves, Stanford M. & Maureen Godsey Valente. (1986). *Evaluating Financial Condition*. ICMA.
- Hendrick, R. (2004). Assessing and measuring the fiscal heath of local governments: Focus on Chicago suburban municipalities. *Urban Affairs Review*, 40(1): 78-114.
- Larkey, P. D., & Smith, R. A. (1989). Bias in the formulation of local government budget problems. *Policy Sciences*, 22(2): 123-166.
- Makridakis, S., Spiliotis, E., & Assimakopoulos, V. (2018). Statistical and Machine Learning forecasting methods: Concerns and ways forward. *PloS one*, 13(3): e0194889.

- Milner, C., & Berg, B. (2017). *Tax Analytics Artificial Intelligence and Machine Learning—Level 5*. PWC Advanced Tax Analytics & Innovation.
- Wasserbacher, H., & Spindler, M. (2022). Machine learning for financial forecasting, planning and analysis: recent developments and pitfalls. *Digital Finance*, 4(1): 63-88.

---

**문 소 영:** 서울대학교에서 행정학 박사학위를 취득하고(2023), 현재 한국행정연구소 객원연구원이다. 관심분야는 지방재정, 지방행정, 인구정책 등이며, 주요 연구로는 “지방자치단체 재정지출 영향요인 분석: 공간적 상호작용을 중심으로(2023)”, “지방재정조정제도의 재정형평화 기능 효율화 방안: 지니계수 분해 기법을 활용한 실증분석 결과를 중심으로(2023)” 등이 있다 (lopopolopopo@naver.com).

**이 서 희:** 서울대학교에서 행정학 박사학위를 취득하고(2020), 현재 한국지방행정연구원 지방재정경제실 부연구위원으로 재직 중이다. 주요 관심분야는 지방재정, 교부세, 지방세 등이며, 주요 연구로는 “재정분권이 공공부문 성과에 미치는 영향 분석(2023)”, “특별지방자치단체 재정지원에 대한 효과분석과 정책방향-부산·울산·경남 특별연합의 사례를 중심으로(2023)”, “지방세 감면과 지역경제와의 관계: 투자진흥지구 사례를 중심으로(2023)” 등이 있다(seotae10@krila.re.kr).