

# 단기 출산율 전망을 위한 AI 기법 활용 연구

A Study on the Application of AI Techniques for Short-Term  
Fertility Rate Forecasting

국립한밭대학교 산학협력단

2025. 12. 24.



# 제 출 문

국회예산정책처장 귀하

본 보고서를 “단기 출산율 전망을 위한 AI 기법 활용 연구” 연구 과제의 최종보고서로 제출합니다.

2025년 12월 24일

연구기관 : 국립한밭대학교 산학협력단  
연구책임자 : 오진호 한밭대학교 수리과학과  
공동연구원 : 계봉오 국민대학교 사회학과

연구조원 : 오혜성 한밭대학교 영어영문학과



# 목 차

단기 출산율 전망을 위한 AI 기법 활용 연구 .....	1
I. 서론 .....	1
II. 인공지능 활용 인구 연구 동향 .....	4
2.1. 인구추계 인공지능 활용 선행 연구 .....	4
2.2. 인공지능 학습데이터와 데이터 전처리 .....	6
2.3. 인공지능 기법과 시계열 예측 기본 원리 .....	15
III. 출산율 영향변수 선정 .....	31
3.1. 1993~2024년 연령별출산율 추이 .....	31
3.2. 선행연구 검토 .....	33
3.3. 저출생 통계지표 .....	34
3.4. 출산율 영향 주요 변수 대상 선정 .....	38
IV. 인공지능 활용 출산율 예측 .....	44
4.1. 인공지능 활용 연령별출산율 예측 .....	44
4.2. 사회, 경제 공변량 따른 출산율 변동 예측 .....	59
4.2. 사회, 경제 공변량 중요도 .....	71
V. 결론 및 제언 .....	76
〈참고문헌〉 .....	79
〈부록〉 .....	83

## 표 목차

〈표 2-1〉 인공지능 학습용 데이터 전처리 기법 비교 .....	14
〈표 2-2〉 LSTM과 Transformer 비교 .....	22
〈표 2-3〉 RNN, LSTM, TimeGPT 비교 .....	26
〈표 2-4〉 통계 모형과 인공지능 예측 차이 .....	28
〈표 3-1〉 저출생 통계지표 체계 .....	37
〈표 3-2〉 연령별 유배우율 (15-49세) .....	38
〈표 3-3〉 연령대별 유배우 여성의 기대자녀 수 .....	39
〈표 4-1〉 데이터 전처리 후, LSTM 2021~2024년 예측 출산율과 적합력 .....	46
〈표 4-2〉 데이터 전처리 후, Transformer 2021~2024년 예측 출산율과 적합력 ...	50
〈표 4-3〉 데이터 전처리 후, TimeGPT 2021~2024년 예측 출산율과 적합력 .....	54
〈표 4-4〉 LSTM, Transformer, TimeGPT 비교 .....	58
〈표 4-5〉 사회, 경제분야 공변량 자료원과 시계열 .....	60
〈표 4-6〉 (공변량 반영 여부) 인공지능 모델별 연령별출산율 10년 예측 비교 ...	70
〈표 4-7〉 LSTM 기반 사회, 경제분야 공변량 중요도 순위 .....	72
〈표 4-8〉 Transformer 기반 사회, 경제분야 공변량 중요도 순위 .....	73
〈표 4-9〉 TimeGPT 기반 사회, 경제분야 공변량 중요도 순위 .....	74

## 그림 목차

[그림 2-1] 과소적합, 일반화, 과적합 비교 .....	7
[그림 2-2] 10-폴더 교차검증 .....	9
[그림 2-3] RNN .....	15
[그림 2-4] LSTM 구조 .....	18
[그림 2-5] TimeGPT .....	24
[그림 2-6] TimeGPT와 다른 기법과의 RMAE 비교 .....	25
[그림 2-7] 인공지능 예측 방법 .....	29
[그림 2-8] 인공지능 연령별출산율 재귀적 예측 방법 (lag=15) .....	30
[그림 3-1] 합계출산율 추이 .....	31
[그림 3-2] 연령별 출산율 추이 .....	32
[그림 3-3] 저출생 통계지표체계 이론적 프레임워크 .....	35
[그림 3-4] 청년층 고용률 .....	39
[그림 3-5] 청년층의 수도권 거주자 비율 .....	40
[그림 3-6] 긍정적 결혼의향자 비율 .....	41
[그림 3-7] GDP 대비 가족공공 지출 비율 .....	42
[그림 4-1] (LSTM 적용) 연령별출산율 2021~2024년 예측 .....	47
[그림 4-2] LSTM 기반 연령별출산율, 합계출산율 10년간 예측 (lag 5) .....	49
[그림 4-3] LSTM 기반 연령별출산율, 합계출산율 10년간 예측 (lag 10) .....	49
[그림 4-4] (Transformer 적용) 연령별출산율 2021~2024년 예측 .....	51
[그림 4-5] Transformer 기반 연령별출산율, 합계출산율 10년간 예측 (lag 7) ..	52
[그림 4-6] Transformer 기반 연령별출산율, 합계출산율 10년간 예측 (lag 15) ..	52
[그림 4-7] (TimeGPT 적용) 연령별출산율 2021~2024년 예측 .....	55
[그림 4-8] TimeGPT 기반 연령별출산율, 합계출산율 10년간 예측 (lag 6) .....	56
[그림 4-9] TimeGPT 기반 연령별출산율, 합계출산율 10년간 예측 (lag 15) .....	57

[그림 4-10] 수도권 거주비율 원본자료와 Cubic spline 보간 및 회귀분석 .....	61
[그림 4-11] 수도권 거주비율 5세 간격 연령 보간 .....	62
[그림 4-12] 연령별출산율과 공변량의 인공지능 학습용 자료 .....	62
[그림 4-13] 공변량 반영 여부에 따른 LSTM 기반 Test 자료 예측 .....	64
[그림 4-14] 공변량 반영 여부에 따른 LSTM 기반 연령별출산율 10년 예측 .....	65
[그림 4-15] 공변량 반영 여부에 따른 Transformer 기반 Test 자료 예측 .....	66
[그림 4-16] 공변량 반영 여부에 따른 Transformer 기반 연령별출산율 10년 예측 ..	67
[그림 4-17] 공변량 반영 여부에 따른 TimeGPT 기반 Test 자료 예측 .....	69
[그림 4-18] 공변량 반영 여부에 따른 TimeGPT 기반 연령별출산율 10년 예측 ..	69

# 단기 출산율 전망을 위한 시 기법 활용 연구

오진호<sup>1)</sup>, 계봉오<sup>2)</sup>

## I. 서론

### 1. 들어가며

우리나라의 합계출산율(Total Fertility rate, TFR)은 2015년 이후 지속적인 하락세를 보이며 2023년에는 0.72명으로 세계 최저 수준을 기록하였다. 국가데이터처 KOSIS (2024)에 따르면 2024년에는 0.75명으로 소폭 반등할 것으로 예상되지만, 인구학적 구조와 미완결 출산코호트(cohort fertility)를 고려할 때 이러한 반등은 일시적 현상일 가능성이 높다. 선행연구(Yoo와 Sobota, 2018; 유삼현, 2022; 신윤정, 2022)에서도 출산 연령 지연에 따른 회복 탄력성이 낮으며, 구조적 저출산 국면이 지속될 것임을 지적하고 있다.

저출산의 장기화는 단순히 인구 규모 감소에 그치지 않고, 경제활동인구 축소, 지역 소멸, 부양비 급등 등 사회 전반의 지속가능성에 심대한 영향을 미친다. 이러한 상황에서 출산율 변동의 단기적 변화를 정확히 예측하는 것은 향후 인구정책 수립과 사회·경제 제도의 설계에 있어 핵심적 과제가 되고 있다. 특히 최근의 통계청 저출생지표 (2023, 2024)는 출산율이 다양한 사회·경제적 변수—혼인율, 고용 안정성, 주거비용, 교육비 부담 등—의 복합적 영향을 받는다고 명시하고 있어, 단일 요인 중심의 전통적 통계모형으로는 이러한 상호작용을 충분히 설명하기 어렵다.

사회·경제 변수들은 비선형적(Nonlinear) 관계와 다중 공선성(Multicollinearity)을 내포하며, 개별 요인의 변화가 출산행태에 미치는 영향은 시기별·집단별로 상이하다. 예를 들어, 경기침체에 실업률 상승은 결혼과 출산을 동시에 지연시키는 경향을 보이며, 주택가격 급등은 가계의 출산여력을 약화시킨다. 또한 여성의 경제활동 참여 확대와 교육 수준 향상은 출산시점의 지연을 유발하는 동시에 장기적 출산 의향을 변화시키는 복합효과를 갖는다. 이러한 요인 간의 복잡한 상호작용 구조를 반영하기 위해서

1) 국립한밭대학교 수리과학과, 노마드칼리지 기초과학부 부교수 | jhoh75@hanbat.ac.kr

2) 국민대 사회학과 교수 | bkye@kookmin.ac.kr

는 선형 회귀나 패널 분석을 넘어서는 새로운 접근이 필요하다.

최근 인공지능(Artificial Intelligence, AI) 기술의 발전은 이러한 복잡한 사회경제적 시스템의 비선형 구조를 모형화 할 수 있는 유력한 대안으로 부상하고 있다. 특히 머신러닝(Machine Learning)과 딥러닝(Deep Learning) 기법은 데이터 내 잠재적 패턴과 비선형 관계를 자동으로 학습하여 예측 정확도를 크게 향상시키는 장점을 지닌다. 이에 따라 인구학, 사회학, 경제학 등 다양한 분야에서 AI를 활용한 인구예측 및 출산율 분석 연구가 급격히 확산되고 있다.

본 연구의 목적은 사회·경제학적 요인이 10년 정도의 단기 출산율 변동에 미치는 비선형적 영향 구조를 분석하고, 이를 예측하기 위한 AI 기반 모델을 구축하는 데 있다. 구체적으로 다음 세 가지 목표를 설정하였다.

첫째, 최근 발표한 통계청 저출생 지표(2023)를 바탕으로 단기 출산율 증감 여부에 영향을 미치는 주요 사회·경제 변수들을 선별한다.

둘째, 선별된 변수 간의 비선형 관계를 반영할 수 있는 머신러닝 및 딥러닝 기반 예측 모형(LSTM, Transformer, TimeGPT 등)을 구축하고, 통계청 장래 출산율과 비교한다.

셋째, AI 예측결과를 기반으로 단기 출산율 상승 혹은 하락 국면의 주요 결정요인을 식별하고, 정책적 시사점을 도출한다.

이를 통해 본 연구는 단기적 출산율 변동의 조기 탐지와 사회·경제적 요인의 영향경로를 보다 명확히 규명함으로써, 향후 저출산 대응정책의 실증적 근거를 제공하고자 한다.

지난 10년간 인공지능을 활용한 인구예측 연구는 전통적인 코호트요인법(cohort-component method)의 한계를 보완하는 방향으로 발전해 왔다. 국내에서는 머신러닝 기반 격자(grid) 인구예측 모델을 개발하여 소지역 단위 인구변화를 정밀하게 예측하고 국토정책에 활용한 사례가 보고되었으며, 국외에서는 앙상블 트리모델(LightGBM, Random Forest)과 딥러닝(LSTM, Transformer) 구조를 결합하여 예측 오차 누적을 줄이는 시도가 활발히 이루어지고 있다.

이들 연구의 공통점은 AI 모델이 비선형적 패턴을 효과적으로 학습함으로써 단기 예측 정확도를 개선했다는 점에 있다. 특히 시계열 데이터의 장기 의존성을 고려하는 순환신경망(RNN) 기반 LSTM 모델은 출산율, 혼인율, 사망률 등 인구지표의 시간적 구조를 잘 포착하는 것으로 평가된다.

한편, 사회·경제적 요인이 출산율에 미치는 영향에 관한 연구 역시 활발히 진행되어 왔다. 국내 연구에서는 혼인율, 고용률, 여성 경제활동, 교육비 및 주거비 부담 등을 중심으로 지역 패널분석과 구조방정식모형(SEM)을 활용해 출산결정 요인을 실증적으로 규명하였다. 국외 연구에서는 주택가격, 실업률, 경기변동, 복지정책 변화 등이 출산행태 변화와 밀접히 관련된다는 사실이 다수의 연구를 통해 확인되었다. 또한 최근에는 구글 트렌드(Google Trends), SNS 빅데이터 등 디지털 지표를 이용하여 경기불안 시기의 출산율 변동을 조기에 예측하려는 연구도 등장하고 있다.

정리하면, 최근 인구예측 연구의 핵심 흐름은 전통적 인구학적 모형과 AI 기법의 결합, 사회·경제적 변수의 다차원적 영향 분석, 단기 변동에 대한 조기 탐지체계 구축으로 요약된다. 이러한 연구 방향은 향후 정책수립에 있어 예측 기반의 증거기반 의사결정을 가능하게 하는 중요한 기초가 된다.

본 연구의 분석 범위는 다음 세 가지 단계로 구성된다.

첫째, 다양한 인구 관련 데이터(출산율, 혼인율, 고용률, 주택가격지수 등) 또는 통계청(2023, 2024)의 저출생 지표에서 주요변수를 통합·정제하여 AI 학습 데이터셋을 구축한다. 둘째, 단기(10년) 시계열 예측에 적합한 비선형 모델(LSTM, Transformer, TimeGPT 등)을 적용하여 출산율의 단기적 증감 여부를 예측한다. 셋째, 사회·경제적 요인별 중요도를 산출(XGBoost, RandomForest)하고, 단기 출산율 변동의 주요 원인을 규명한다.

본 연구는 단기 예측에 초점을 맞추되, 향후 중·장기 출산율 전망 연구로의 확장을 염두에 두고 있다. 특히 AI 기법의 출산율 예측성과 이런 출산율에 영향을 미치는 사회, 경제적 요인의 중요도를 결합하여, 정책 현장에서 활용 가능한 실증적 근거를 제시하는 것이 본 연구의 궁극적 목표이다.

또한 본 연구는 전통적 통계모형이 가지는 한계를 보완하고, 사회·경제적 요인 간의 복합적 상호작용을 반영함으로써 단기 출산율 예측의 정확도와 현실적 설명력을 동시에 향상시키는 데 기여한다. 더불어 AI 기반 분석 결과를 통해 출산율 변동의 주요 요인을 정량적으로 파악함으로써, 중앙정부와 지방자치단체의 청년층 주거지원, 고용안정 정책, 보육비 지원과 같은 정책 설계에 실질적인 방향성을 제시할 수 있다.

나아가 본 연구는 향후 인공지능 기반 출산정책 의사결정 지원체계 구축의 시범사례로 활용될 수 있으며, 인구학과 데이터과학의 융합 연구 발전에도 기여할 것으로 기대된다.

## II. 인공지능 활용 인구 연구 동향

### 2.1. 인구추계 인공지능 활용 선행 연구

최근 들어 청년층 고용률, 실업률, 가구소득, 교육수준, 혼인율, 주거 여건, 양육비용 부담, 경제 안정성 등 다양한 사회·경제적 요인들이 출산율, 사망률, 국제이동률 등 인구변동의 주요 요인에 직·간접적으로 영향을 미친다는 사실이 점차 명확히 인식되고 있다. 이들 요인은 개별적으로 작용하기보다 상호의존적 관계망(interdependent network) 속에서 인구 변화를 유발하며, 그 상호작용이 복잡하고 비선형적이기 때문에 단순한 선형 분석만으로는 그 작동 메커니즘을 충분히 설명하기 어렵다.

기존의 전통적 통계모형은 변수 간의 복잡한 상호작용과 비선형적 구조를 충분히 반영하지 못한다는 한계가 지속적으로 지적되어 왔다. 특히 회귀계수에 기반을 둔 통계적 접근은 변수 간 인과관계를 명시적으로 표현할 수 있는 장점이 있으나, 사회·경제적 요인의 다층적 상호작용과 시계열적 종속성을 설명하는 데에는 제약이 크다. 이에 따라 최근 연구에서는 인공지능(AI) 기반의 학습 알고리즘을 활용하여 인구변동 요인을 보다 정밀하게 분석·예측하려는 시도가 활발히 이루어지고 있다. 이러한 접근은 단순히 예측 정확도를 높이는 데 그치지 않고, 인구변동에 영향을 미치는 사회·경제적 변수들의 내재적 관계를 탐색하고, 이를 바탕으로 정책적 함의(policy implications)를 도출하는 새로운 가능성을 제시한다.

최근 5년간의 국내외 연구를 살펴보면, 인공지능 기법을 인구예측에 접목하려는 다양한 시도가 확인된다(김유현·김동현, 2023; 변상영 외, 2023; 이상희 외, 2023; Chen 외, 2020<sup>a,b</sup>; Grossman 외, 2022; Wilson 외 (2023); Huwei 외 (2025)). 이들 연구는 기존의 코호트요인법(Cohort-Component Method)을 기본 틀로 하되, 머신러닝(Machine Learning)과 딥러닝(Deep Learning) 기법을 결합하여 합계출산율, 출생아 수, 소지역 단위 인구 등 다양한 인구지표를 예측하고 있다. 특히 LSTM(Long Short-Term Memory), Transformer, TimeGPT 등의 시계열 기반 AI 모델을 적용함으로써, 기존 통계모형 대비 예측 오차를 줄이고, 변수 간 비선형적 상호작용을 포착할 수 있음을 실증적으로 보여주었다.

저출산의 구조적 원인을 규명하기 위한 연구도 활발하게 진행되고 있다(조성호·문승

현, 2021; 박성훈, 2023, 2024; W. Li, 2024; Wilde 외, 2024). 이들 연구는 혼인율, 고용률과 실업률), 주거비용, 가구소득 등 다양한 사회·경제 지표가 출산율 변화에 미치는 영향을 실증적으로 분석하였다. 국내 연구에서는 주로 패널분석(panel analysis)이나 구조방정식모형(SEM: Structural Equation Modeling)을 이용해 지역별·개인 수준의 영향 요인을 규명하였다. 반면 해외 연구들은 주택가격, 경기침체, 고용 불안정, 경제위기 등이 출산행태 변화와 어떤 방식으로 연관되는지를 분석하며, 사회경제적 불확실성이 출산 결정에 미치는 구조적 경로를 탐색하고 있다.

최근에는 인공지능의 블랙박스(Black-box) 한계를 극복하기 위한 해석 가능한 인공지능(XAI) 접근이 주목받고 있다(Rawal 외(2021, 2024)). 이 접근은 단순히 예측값을 산출하는 데 그치지 않고, 모델이 내린 예측의 근거와 변수의 기여도(contribution)를 정량적으로 분석한다. 대표적으로 SHAP(Shapley Additive Explanations, Lundberg과 Lee, 2017) 값, Attention 가중치, LIME(Local Interpretable Model-agnostic Explanations, Ribeiro 외 (2016a,b)) 등의 기법을 활용하여, AI 예측 결과에 영향을 미친 변수들의 중요도(importance)와 방향성(effect direction)을 도출한다. 이를 통해 인공지능의 '결과 중심적 예측(result-driven forecasting)'을 '원인 기반 정책 해석(cause-informed interpretation)'으로 확장할 수 있으며, 이는 향후 인구정책의 데이터 기반 의사결정(data-driven decision making)을 강화하는 데 기여할 것으로 평가된다.

이상의 연구 동향을 종합하면, 인공지능을 접목한 인구예측 연구의 발전 방향은 크게 두 가지로 요약된다. 첫째, 학문적 연구 차원에서 머신러닝·딥러닝 알고리즘을 활용하여 사회·경제 변수와 인구지표 간의 복잡한 비선형 관계를 규명하려는 시도가 확산되고 있다. 이를 통해 전통적인 인구모형의 예측 정확도와 해석력을 동시에 개선하고 있으며, 특히 혼인율, 청년층 고용률, 주거비용, 가구소득, 교육수준, 양육비용 부담 등 다양한 변수들을 통합적으로 고려함으로써, 거시경제적 충격이 출산율에 미치는 영향을 실증적으로 설명할 수 있는 기반이 마련되고 있다. 둘째, 정책 연구기관 차원에서는 이러한 학문적 성과를 반영하여 인공지능 기반 인구전망 모형을 개발·적용하는 움직임이 확대되고 있다. 이는 기존의 인구추계 체계에 사회·경제적 맥락(contextual factors)을 통합함으로써, 보다 현실적이고 정책 대응 중심의 인구전망 시스템으로 발전하고 있음을 보여준다.

향후에는 사회·경제적 변화와 인구변동 간의 동적 상호작용을 시뮬레이션 할 수 있는 AI 기반 통합 인구모형(Integrated AI-Demographic Model) 연구가 더욱 활발히 전

개될 것으로 전망된다. 이러한 연구는 저출산과 고령화라는 구조적 도전에 대응할 수 있는 장기 전략 수립과 정책적 의사결정의 근거를 제공할 뿐 아니라, 인구학적 전망의 신뢰성과 정책 활용성을 동시에 제고하는 데 기여할 것으로 기대된다.

## 2.2. 인공지능 학습데이터 구분과 데이터 전처리

### 2.2.1 인공지능 학습 데이터

인공지능(AI) 모델을 구축할 때는 전체 데이터를 한꺼번에 사용하는 것이 아니라, 훈련(Training), 평가(Validation), 검증(Test)의 세 부분으로 나누어 활용한다. 이러한 절차는 모델이 훈련된 데이터뿐만 아니라 새로운 데이터(new data)를 접했을 때도 안정적이고 일반화된 성능을 유지하도록 하기 위한 핵심적인 과정이다.

학습용 데이터 분할(Data Splitting)은 인공지능 모델이 데이터의 패턴을 학습하고, 이를 토대로 새로운 입력에 대해 합리적인 예측을 수행할 수 있도록 돕는 기초적 절차이다. 만약 모델이 전체 데이터를 모두 학습에 사용한다면, 학습 단계에서는 높은 정확도를 보이더라도 실제로는 데이터의 특수한 패턴에 과도하게 의존하게 되어, 새로운 데이터에 적용할 때 성능이 급격히 저하될 가능성이 크다. 이를 과적합(Overfitting)이라 하며, 반대로 데이터의 주요 특성과 구조를 충분히 학습하지 못하는 경우를 과소적합(Underfitting)이라 한다. 두 현상 모두 모델의 일반화 성능을 저해하므로, 이들을 방지하기 위해서는 데이터를 역할별로 구분하여 사용하는 것이 필수적이다.

예를 들어, 10,000개의 데이터가 주어졌다고 가정하자. 이 중 약 60%(6,000개)는 훈련 데이터(Training data)로 사용되어 모델의 가중치와 구조를 학습하는 데 활용된다. 다음 20%(2,000개)는 평가 데이터(Validation data)로 사용되어 학습된 모델의 하이퍼파라미터(예: 학습률, 은닉층 수, 노드 수 등)를 조정하고 과적합 여부를 모니터링하는 데 사용된다. 마지막 20%(2,000개)는 학습과 평가 과정에서 완전히 배제된 검증 데이터(Test data)로 남겨두었다가, 학습이 완료된 최종 모델의 예측 성능을 객관적으로 검증하는 데 사용된다.

이와 같은 과정을 비유적으로 설명하면 다음과 같다.

된장찌개를 만들 때 재료를 한 번에 모두 사용하는 대신 일부는 조리법을 시험해보

는 데 사용하고, 또 다른 일부는 간을 맞추거나 향을 조정하는 데 사용하며, 마지막으로 남겨둔 재료는 최종 완성된 조리법의 품질을 검증하는 데 사용하는 것과 같다. 즉, 각 데이터 집합은 모델 학습의 “훈련 - 조정 - 검증” 과정에서 서로 다른 역할을 수행한다.


일반적으로 인공지능 학습에서는 데이터의 분할 비율을 훈련:평가:검증 = 6:2:2 또는 5:2.5:2.5로 설정하는 경우가 많다. 훈련 데이터는 모델이 주어진 입력과 출력 간의 패턴을 학습하는 데 사용된다. 평가 데이터는 학습 도중 모델의 성능을 점검하고 최적의 매개변수나 구조를 선택하는 기준으로 활용된다. 검증 데이터는 학습이 완료된 후 최종 모델의 일반화 성능을 객관적으로 평가하는 데 사용된다. 이 세 단계의 분리는 모델의 신뢰성과 예측 안정성을 높이기 위한 표준적인 절차로, 통계적 검증과정과 동일한 의미를 갖는다.

과적합은 모델이 훈련 데이터에 포함된 우연적 잡음(noise)이나 비본질적 특성까지 학습함으로써, 훈련 데이터에서는 높은 정확도를 보이지만 새로운 데이터에서는 성능이 급격히 저하되는 현상을 말한다. 그 원인으로서는 (1) 모델 구조의 과도한 복잡성, (2) 훈련 데이터의 양 부족, (3) 데이터 대표성의 결여 등을 들 수 있다.

반면, 과소적합은 모델이 지나치게 단순하거나 학습 시간이 충분하지 않아 데이터의 주요 패턴조차 제대로 학습하지 못하는 경우를 의미한다. 일반적으로 (1) 모델의 용량이 제한적이거나, (2) 입력 변수(특징, feature) 선택이 부적절할 때 발생한다.

이러한 관계를 시각적으로 표현하면, [그림 2-1]과 같이 과소적합 → 일반화(적정 학습) → 과적합의 구간으로 구분할 수 있다.

[그림 2-1] 과소적합, 일반화, 과적합 비교



적정한 데이터 분할과 검증 체계를 통해 이들 중간지점, 즉 모델의 최적 일반화 상태(optimal generalization)를 확보하는 것이 인공지능 학습의 핵심 목표라 할 수 있다.

인공지능 모델의 성능 저하 요인인 과적합(Overfitting)과 과소적합(Underfitting) 문제를 최소화하기 위해서는 학습 데이터의 품질과 모델의 일반화 능력을 함께 개선하는 전략이 필요하다. 이를 위한 대표적인 접근법으로는 데이터 증강 및 확장(Data Augmentation and Expansion), 교차검증(Cross-Validation), 그리고 모델 단순화(Model Simplification)가 있다.

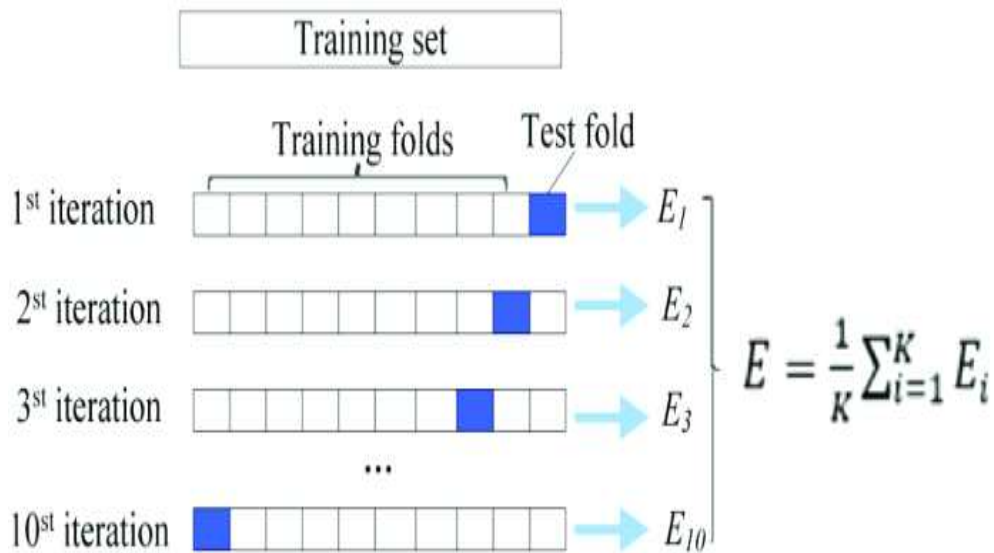
학습데이터가 부족할 경우, 인공지능 모델은 특정한 훈련 데이터의 패턴에 과도하게 의존하여 새로운 데이터에 대한 예측력이 떨어질 수 있다. 이를 방지하기 위해 데이터 증강(data augmentation) 또는 데이터 확장(data expansion) 방법을 활용한다. 데이터 증강은 원본 데이터에 다양한 변형(예: 노이즈 추가, 스케일 변화, 회전, 시간 이동 등)을 적용하여 학습 가능한 표본을 늘리는 방식으로, 모델이 보다 다양한 입력 상황을 학습할 수 있게 한다. 결과적으로 데이터의 대표성을 높이고, 모델의 일반화(generalization) 성능을 강화할 수 있다.

교차검증은 인공지능 학습 과정에서 모델의 성능을 보다 신뢰성 있게 평가하기 위해 사용되는 통계적 기법이다. 동일한 데이터를 단 한 번만 훈련과 검증에 사용하는 대신, 데이터를 여러 개의 부분집합(fold)으로 나누어 학습과 검증을 반복 수행함으로써 모델이 특정 데이터 분할에 의존하지 않도록 한다. 이 방법은 특히 데이터 양이 충분하지 않거나, 모델이 복잡하여 과적합 위험이 높은 경우에 효과적이다. 교차검증은 데이터 활용 효율성을 극대화하면서도, 예측 성능의 일관성과 안정성을 높이는 장점이 있다. K-폴드 교차검증(K-fold cross validation; CV)은 교차검증 중 가장 널리 사용되는 방식으로, 전체 데이터를 크기가 동일한 K개의 부분집합으로 나누어 진행한다. 이후 K번의 반복 학습을 수행하며, 각 반복마다 한 개의 부분집합을 검증 세트로, 나머지 K-1개의 부분집합을 훈련 세트로 사용한다. 예를 들어, [그림 2-2]의 10-폴드 교차검증(10-fold CV) 과정을 살펴보면, 전체 데이터를 10개의 그룹으로 무작위 분할한다.

첫 번째 단계에서는 1~9번째 그룹 데이터를 이용하여 모델을 학습(훈련)하고, 10번째 그룹을 검증용으로 사용한다. 두 번째 단계에서는 2~10번째 그룹을 이용해 학습하고, 1번째 그룹을 검증용으로 사용한다. 이러한 과정을 총 10회 반복하여, 각 단계별 검증 결과(정확도, 오차율 등)를 종합적으로 평균하거나 통계적으로 분석함으로써 모델의 성능을 평가한다. 이 방식은 모든 데이터가 한 번씩은 검증용으로 사용된다는 점에

서 평가의 공정성을 보장하며, 데이터가 적은 상황에서도 모델의 신뢰도를 높이는 데 매우 효과적이다. [그림 2-2]는 이러한 10-폴드 교차검증의 반복적 구조를 도식화한 것이다. 그리고  $E$ 는  $i$ 번째 그룹의 교차검정의 *error* ( $MAE$  또는  $MAPE$  등)를 의미한다.

[그림 2-2] 10-폴더 교차검증



자료: [www.researchgate.net/figure/Ten-fold-cross-validation-diagram-The-dataset-was-divided-into-ten-parts-and-nine-of\\_fig1\\_326465007](http://www.researchgate.net/figure/Ten-fold-cross-validation-diagram-The-dataset-was-divided-into-ten-parts-and-nine-of_fig1_326465007)

또한, 모델의 복잡도를 불필요하게 높이면 훈련 데이터에 포함된 잡음까지 학습하는 과적합 문제가 발생하기 쉽다. 이를 방지하기 위해 모델 단순화(model simplification)를 적용하여 파라미터 수를 줄이거나, 정규화(regularization) 기법을 도입함으로써 모델이 데이터의 핵심적 구조만 학습하도록 유도한다. 이는 모델의 예측 안정성과 해석 가능성을 함께 높이는 방법이다.

요약하면, 인공지능 학습에서 데이터를 훈련, 평가, 검증용으로 구분하는 이유는 최종 모델의 성능을 객관적이고 신뢰성 있게 평가하기 위함이다. 동일한 데이터를 학습과 평가에 동시에 사용하면 모델의 성능이 실제보다 과대평가될 수 있으며, 이는 새로운 데이터에 대한 예측력 저하로 이어질 위험이 있다. 따라서 체계적인 데이터 분할과 교차검증 절차는 인공지능 모델 개발의 핵심 과정이자, 과적합을 방지하고 일반화 성능을 확보하기 위한 필수적 단계라 할 수 있다.

## 2.2.2 데이터 표준화와 정규화

인공지능(AI) 모델을 구축하기 전에 수행되는 데이터 전처리(Data Preprocessing) 과정은 모델 학습의 효율성과 안정성을 확보하기 위한 필수 단계이다. 원자료(raw data)는 수집 과정에서 다양한 단위와 범위를 갖는 변수들로 구성되어 있다. 이러한 데이터를 아무런 조정 없이 학습에 활용할 경우, 특정 변수의 값이 다른 변수에 비해 상대적으로 크거나 작아 모델이 일부 변수에 과도하게 의존하거나, 반대로 중요 변수를 무시하는 문제가 발생할 수 있다. 따라서 데이터의 규모와 분포를 일정한 기준으로 맞추는 작업이 필요하며, 이를 위해 일반적으로 데이터 표준화(Standardization)와 데이터 정규화(Normalization) 기법이 활용된다.

데이터 표준화는 각 변수의 값을 평균이 0, 분산이 1이 되도록 변환하는 과정이다. 이는 각 데이터에서 평균( $\mu$ )을 빼고 표준편차( $\sigma$ )로 나누는 방식으로 수행되며, 식 (2.1)과 같이 표현된다.

$$z = \frac{x - \mu}{\sigma} \quad (2.1)$$

여기서  $x$ 는 원자료,  $\mu$ 는 평균,  $\sigma$ 는 표준편차이다.

표준화를 적용하면 변수 간 단위나 척도 차이가 제거되어, 서로 다른 규모를 가진 데이터라도 동일한 기준에서 비교 및 학습이 가능하다. 예를 들어, 키(단위: cm)와 체중(단위: kg)을 함께 입력 변수로 사용할 경우, 단위의 차이로 인해 키 변수가 모델 학습 과정에서 과도한 영향을 미칠 수 있다.

그러나 표준화를 적용하면 두 변수 모두 평균 0, 표준편차 1의 동일한 척도로 환산되어 공정한 학습 환경을 제공한다. 표준화는 특히 통계적 가정을 기반으로 하는 알고리즘에서 효과적이다. 선형회귀(Linear Regression), 로지스틱회귀(Logistic Regression), 서포트벡터머신(Support Vector Machine; SVM), 주성분분석(Principal Component Analysis; PCA) 등은 데이터가 정규분포를 따른다고 가정하기 때문에 표준화를 적용함으로써 모델의 수렴 속도와 예측 정확도를 향상시킬 수 있다.

데이터 정규화는 각 변수의 값을 특정한 범위(일반적으로 0과 1 사이)로 변환하는 방법이다. 가장 널리 사용되는 정규화 방식은 최소-최대 정규화(Min-Max Scaling)이며, 식 (2.2)와 같이 정의된다.

$$x' = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (2.2)$$

여기서  $x$ 는 원자료,  $x_{\min}$ 과  $x_{\max}$ 는 원자료의 최솟값과 최댓값이다.

정규화를 수행하면 모든 데이터가 동일한 구간에 위치하게 되어, 변수 간 값의 크기 차이로 인해 발생하는 학습 불균형을 방지할 수 있다. 예를 들어, 한 변수의 값의 범위가 110이고 다른 변수의 범위가 110,000이라면, 모델은 후자의 변수 변화에 훨씬 더 민감하게 반응하게 된다. 그러나 정규화를 거치면 두 변수 모두 [0,1] 범위 내에서 동일한 수준으로 학습되어, 균형 잡힌 모델 훈련이 가능해진다. 정규화는 특히 딥러닝(Deep Learning), 순환신경망(LSTM), 합성곱신경망(CNN) 등 신경망 기반 모델(Neural Network-based Models)에서 필수적으로 활용된다. 이 과정은 학습 속도를 향상시키고, 역전파(Backpropagation) 과정에서 발생할 수 있는 기울기 소실(Gradient Vanishing) 문제를 완화시켜, 모델의 안정적 수렴을 유도한다.

두 방법의 주요 차이는 데이터 변환의 기준과 목적에 있다.

표준화는 데이터의 평균과 분산을 기준으로 변환하므로, 변환 후에도 음수와 양수 값이 모두 존재할 수 있으며, 데이터가 정규분포에 근접할 때 특히 효과적이다. 반면 정규화는 데이터의 최솟값과 최댓값을 기준으로 변환하여 모든 값을 [0,1] 구간으로 제한하며, 데이터의 분포 형태와 무관하게 일정한 스케일로 맞추는 데 유용하다.

요약하면, 데이터 분할이 인공지능 모델의 일반화 성능 평가를 위한 절차라면, 데이터 표준화와 정규화는 학습 효율성과 안정성을 높이기 위한 전처리 과정이다.

표준화는 변수 간 단위 차이를 제거하여 데이터의 비교 가능성을 확보하고, 정규화는 값의 범위를 일정하게 조정하여 학습 속도와 수렴 안정성을 높인다.

두 방법 모두 인공지능 모델의 성능 향상과 과적합 방지에 핵심적인 역할을 하며, 모델의 학습 품질을 결정짓는 기반적 절차라 할 수 있다.

### 2.2.3 인공지능 학습용 데이터 전처리의 추가 과정

데이터 전처리(Data Preprocessing)는 인공지능 모델의 성능, 일반화 능력, 신뢰성을 좌우하는 핵심 단계이다. 표준화(Standardization)와 정규화(Normalization) 외에도 다양한 전처리 기법이 존재하며, 각각은 데이터의 품질을 향상시키고 학습 안정성을 확

보하는 데 중요한 역할을 한다. 다음에서는 인공지능 학습에서 널리 활용되는 여섯 가지 주요 전처리 방법을 살펴본다.

첫째 결측치 처리 (Handling Missing Values)이다. 현실에서 수집된 데이터에는 측정 오류, 응답 누락 등으로 인해 결측치(Missing Values)가 빈번히 발생한다. 결측치를 적절히 처리하지 않으면 모델 학습 과정에서 오류가 발생하거나, 예측 성능이 저하될 수 있다. 결측치 처리 방법은 다음과 같다. 삭제법(Deletion)은 결측치가 포함된 행(row) 또는 열(column)을 제거하는 방식으로, 단순하지만 결측 비율이 높을 경우 데이터 손실이 크다는 한계가 있다. 대체법(Imputation)은 평균, 중앙값, 최빈값 등 대표값으로 결측치를 대체하거나, K-최근접이웃(KNN) 또는 회귀모형을 활용해 예측값으로 보정한다. 다중 대체법(Multiple Imputation)은 결측치에 여러 개의 대체값을 생성하여 불확실성을 반영하고, 이후 통계적 통합을 통해 일관된 추정치를 얻는 방법으로, 신뢰도 높은 분석을 가능하게 한다.

둘째 이상치 처리 (Outlier Detection and Treatment)이다. 이상치(Outlier)는 다른 데이터들과 현저히 다른 극단값으로, 이를 그대로 학습에 반영하면 모델이 왜곡된 패턴을 학습할 수 있다. 이상치 탐지 및 처리에는 다음과 같은 방법이 있다. 탐지(Detection)는 상자그림(Boxplot), z-점수(z-score), 사분위 범위(IQR, Interquartile Range) 등을 활용하여 이상값을 식별한다. 처리(Treatment)는 이상치를 제거하거나, 상·하한값으로 대체하는 윈저라이징(Winsorizing), 로그 변환(Log Transformation) 등으로 영향을 완화하는 방법이 있다.

셋째 범주형 변수 인코딩 (Categorical Encoding)이다. 인공지능 모델은 수치형 입력 데이터를 필요로 하므로, 범주형 변수(Categorical Variable)는 반드시 수치로 변환되어야 한다. 주요 인코딩 방법은 다음과 같다. 원-핫 인코딩(One-Hot Encoding)은 각 범주를 0과 1로 구성된 벡터로 변환하는 방식으로, 순서가 없는 명목형 변수에 적합하다. 레이블 인코딩(Label Encoding)은 범주에 정수값을 부여하는 방식으로, 순서형 변수(예: 학력 수준 등)에 적합하다. 임베딩(Embedding)은 딥러닝 모델에서 사용되는 방식으로, 범주형 변수를 저차원 밀집 벡터(dense vector)로 변환하여 학습 효율을 높인다.

넷째 차원 축소 (Dimensionality Reduction)이다. 데이터의 변수(특징, feature)가 지나치게 많을 경우, 과적합(Overfitting)이 발생하거나 학습 속도가 저하될 수 있다. 이러한 문제를 해결하기 위한 과정이 차원 축소(Dimensionality Reduction)이다. 대표적

인 기법은 다음과 같다. 주성분분석(PCA, Principal Component Analysis)은 데이터의 분산을 가장 잘 설명하는 새로운 축(principal component)을 추출하여 차원을 축소한다. 변수 선택법(Feature Selection)은 상관관계가 높거나 중요도가 낮은 변수를 제거하여 모델 단순화를 유도한다. 자동 인코더(Autoencoder)는 신경망 기반 차원 축소 방법으로, 입력 데이터를 저차원 잠재공간(latent space)으로 압축한 후 복원하는 방식이다.

다섯째 데이터 증강(Data Augmentation)이다. 데이터 증강은 데이터의 양이 부족하거나 특정 패턴에 편중된 경우에 인위적으로 데이터를 확장하는 방법이다. 분야별 대표적인 접근은 다음과 같다. 이미지 데이터 분야는 회전, 확대, 반전, 색상 변형 등의 기법을 통해 새로운 이미지를 생성한다. 자연어 처리(NLP)는 문장 순서 변경, 유의어 치환(synonym replacement) 등으로 데이터 다양성을 확보한다. 시계열 데이터 부문은 잡음 추가(noise injection), 구간 잘라내기(segmentation), 신호 변형(signal distortion) 등을 활용하여 학습 안정성을 높인다.

여섯째 불균형 데이터 처리(Imbalanced Data Handling)이다. 분류(classification) 문제에서 특정 집단의 데이터가 과소표집된 경우, 모델이 다수 집단에 편향되어 학습하는 데이터 불균형 문제(class imbalance)가 발생한다. 이를 보완하기 위한 주요 기법은 다음과 같다. 오버샘플링(Oversampling)은 소수 집단의 데이터를 복제하거나, SMOTE(Synthetic Minority Over-sampling Technique) 알고리즘을 이용해 새로운 샘플을 합성한다. 언더샘플링(Undersampling)은 다수 집단의 일부 데이터를 제거하여 균형을 맞춘다. 가중치 조정(Class Weight Adjustment)은 학습 과정에서 소수 집단의 오차에 더 큰 가중치를 부여함으로써, 균형 잡힌 학습을 유도한다. 이러한 기법들은 모델이 모든 집단의 특성을 고르게 학습하도록 하여, 정확성과 공정성을 동시에 제고한다.

요약하면, 인공지능 학습 데이터 전처리는 데이터 분할, 표준화, 정규화 외에도 결측치 처리, 이상치 처리, 범주형 변수 인코딩, 차원 축소, 데이터 증강, 불균형 데이터 처리 등의 과정을 포함한다. 이들 전처리 단계를 적절히 수행하면 모델의 학습 안정성(stability), 일반화 성능(generalization performance), 신뢰성(reliability)이 크게 향상된다. 이상의 과정을 요약하면 다음 <표 2-1>과 같다.

〈표 2-1〉 인공지능 학습용 데이터 전처리 기법 비교

구분	주요 내용	대표 기법
데이터 분할	훈련, 평가, 검증용 데이터 분리	6:2:2, 5:2.5:2.5 비율
표준화	평균 0, 분산 1 변환	z-점수 표준화
정규화	[0,1] 구간 변환	Min - Max Scaling
결측치 처리	누락값 보정	삭제, 평균/회귀/다중대체
이상치 처리	극단값 완화	IQR, z-점수, 원저라이징
범주형 인코딩	비수치형 데이터 변환	One-Hot, Label, Embedding
차원 축소	변수 수 축소	PCA, Autoencoder
데이터 증강	데이터 확장	이미지·텍스트·시계열 변형
불균형 처리	클래스 비율 보정	SMOTE, 언더샘플링, 가중치 조정

## 2.3. 인공지능 기법과 시계열 예측 기본 원리


이번 절은 최근 시계열 자료에 특화된 순차적 인공신경망(recurrent Neural Network, RNN)의 대표인 LSTM, Transformer, TimeGPT를 소개한다.

### 2.3.1 순환신경망 (RNN: Recurrent Neural Network)

순환신경망(Recurrent Neural Network, RNN)은 시계열(Time Series), 음성(Speech), 텍스트(Text)와 같이 시간적 순서(Sequential Order)가 존재하는 데이터를 처리하기 위해 고안된 신경망 구조이다. 전통적인 인공신경망(Artificial Neural Network, ANN)은 입력과 출력이 고정되어 있으며, 각 입력 데이터가 서로 독립적으로 처리된다. 반면, RNN은 이전 단계의 출력 정보를 현재 입력과 함께 고려하여 학습함으로써 데이터 내의 시간적 의존성(Temporal Dependency)을 반영할 수 있다는 점에서 차별화된다. 이러한 특성 덕분에 RNN은 과거의 정보가 현재의 예측에 영향을 미치는 문제(예: 자연어 문장 해석, 주가 예측, 음성 인식 등)에 특히 적합하다. RNN의 핵심은 은닉층(Hidden Layer)이 순환 구조를 가진다는 점이다. 즉, 이전 시점의 은닉 상태  $h_{t-1}$ 이 현재 시점의 입력  $x_t$ 와 함께 다음 시점의 은닉 상태  $h_t$ 를 결정한다.

[그림 2-3]은 RNN의 기본 구조를 나타낸다.  $x_t$ 는 t시점 입력층의 입력 벡터이고,  $y_t$ 는 t시점 출력층의 출력벡터이다.

[그림 2-3] RNN



$h_t$ 는 t의 은닉 상태(Hidden State)이다. Cell(셀)은 은닉층 내부에서 입력값과 이전 상태값을 결합하여 출력을 생성하는 노드이다. 이 셀(cell)은 일종의 메모리(memory)

역할을 수행한다. 즉, 과거 시점의 정보를 일정 기간 동안 저장하고, 이를 바탕으로 현재 시점의 출력을 결정한다. 이러한 성질 때문에 셀을 메모리 셀(Memory Cell) 또는 RNN 셀(Recurrent Cell)이라 부른다.

은닉층의 각 메모리 셀은 시점별(time step)로 연속적으로 연결되어 있으며, 이전 시점( $t-1$ )에서의 은닉 상태값이 현재 시점( $t$ ) 입력으로 전달된다. 이와 같이 은닉층 내에서 정보가 재귀적으로(recurrently) 전달되는 과정을 통해 RNN은 시계열 데이터의 시간적 흐름을 반영하게 된다(참조: [그림 2-3]의 (1)). 그리고 메모리 셀이 출력층 방향 또는 다음 시점인  $t+1$ 의 자신에게 보내는 값을 은닉 상태(hidden state)라고 한다. 다시 말해  $t$ 시점의 메모리 셀은  $t-1$ 시점의 메모리 셀이 보낸 은닉 상태값을  $t$ 시점의 은닉 상태 계산을 위한 입력값으로 사용한다.

RNN을 표현할 때는 일반적으로 [그림 2-3]의 (2)와 같이 화살표로 사이클을 그려서 재귀 형태로 표현하기도 하지만, 우측과 같이 사이클을 그리는 화살표 대신 여러 시점으로 펼쳐서 표현하기도 한다.

또한 RNN은 현재 시점  $t$ 에서의 은닉 상태값  $h_t$ 을 라고 정의할 때, 은닉층의 메모리 셀은  $h_t$ 를 계산하기 위해서 총 두 개의 가중치를 가진다. 하나는 입력층을 위한 가중치  $W_x$ 이고, 또 다른 하나는 이전 시점  $t-1$ 의 은닉 상태값인  $h_{t-1}$ 을 위한 가중치  $W_h$ 이다(참조: [그림 2-3]의 (3)). 이들 관계를 식으로 표현하면 식 (2.3)과 같다.

$$\begin{aligned}
 h_t &= \tanh(W_h h_{t-1} + W_x x_t + b) \\
 y_t &= f(W_y h_t + c), \quad f: \text{비선형 활성화 함수}
 \end{aligned}$$

$$\left\{ \begin{array}{l}
 h_t : t\text{시점의 은닉 상태} (hidden\ state) \\
 x_t : t\text{시점의 입력 데이터} \\
 y_t : t\text{시점의 출력} \\
 W_h, W_x, W_y : \text{가중치 행렬}
 \end{array} \right. \quad (2.3)$$

식 (2.3)에서 일반적으로 사용하는 비선형 활성화함수는 하이퍼볼릭탄젠트함수(tanh)이다. tanh는 수식 (2.4)와 같다.

$$f(x) = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (2.4)$$

역사적으로 tanh 함수는 시그모이드(sigmoid) 함수보다 더 넓은 출력 범위를 제공하여, 다층 신경망(multi-layer network)에서 상대적으로 나은 성능을 보였다. 그러나 tanh 역시 시그모이드 함수와 마찬가지로 기울기 소실(Vanishing Gradient) 문제를 완전히 해결하지는 못했다. 이후 ReLU(Rectified Linear Unit) 함수의 등장으로 이러한

문제가 크게 완화되었으며, ReLU는 빠른 학습 속도와 깊은 네트워크 구조에서의 안정적인 학습을 가능하게 했다. 그럼에도 불구하고, tanh 함수는 여전히 RNN의 내부 은닉층에서 널리 사용되며, 때로는 출력층의 활성화 함수로도 활용된다.

요약하면, RNN은 과거의 은닉 상태를 현재 입력에 반영하여 시계열 정보를 학습하는 순환 구조의 신경망이다. 이전 시점의 출력이 다음 시점의 입력으로 연결됨으로써, 데이터 간의 시간적 연속성과 의존성을 포착할 수 있다. 활성화 함수로는 주로 tanh 함수가 사용되지만, 최근에는 ReLU 기반 구조가 확산되면서 LSTM(Long Short-Term Memory)과 GRU(Gated Recurrent Unit) 같은 개선된 순환 구조로 발전하고 있다.

### 2.3.2. 장단기 메모리 네트워크 (LSTM: Long Short-term Memory)

장단기 메모리 네트워크(Long Short-Term Memory, LSTM)는 Hochreiter와 Schmidhuber(1997)<sup>1)</sup>가 제안한 순환신경망(RNN)의 확장 구조이다. 기존 RNN은 시계열 데이터의 시간적 의존성을 학습할 수 있으나, 시간이 길어질수록 역전파(Backpropagation) 과정에서 기울기 소실(Vanishing Gradient) 문제가 발생하여 장기 의존 관계(Long-Term Dependency)를 학습하기 어렵다는 한계를 가진다.

LSTM은 이러한 한계를 극복하기 위해 셀 상태(Cell State)와 게이트 메커니즘(Gating Mechanism)을 도입하여, 중요한 정보는 오랫동안 유지하고 불필요한 정보는 자동으로 제거할 수 있도록 설계되었다.

LSTM 셀은 [그림 2-4]와 같이 3개의 게이트(망각 게이트, 입력 게이트, 출력 게이트)와 1개의 셀 상태(Cell State)로 구성된다. 이들 구성요소는 네트워크 내에서 정보의 흐름을 제어하며, 각 게이트는 시그모이드 또는 하이퍼볼릭탄젠트(tanh)와 같은 비선형 활성화함수를 사용하여 0과 1 사이의 값을 출력한다. 이 값은 해당 정보의 “유지(1)” 혹은 “폐기(0)” 여부를 결정하는 역할을 한다.

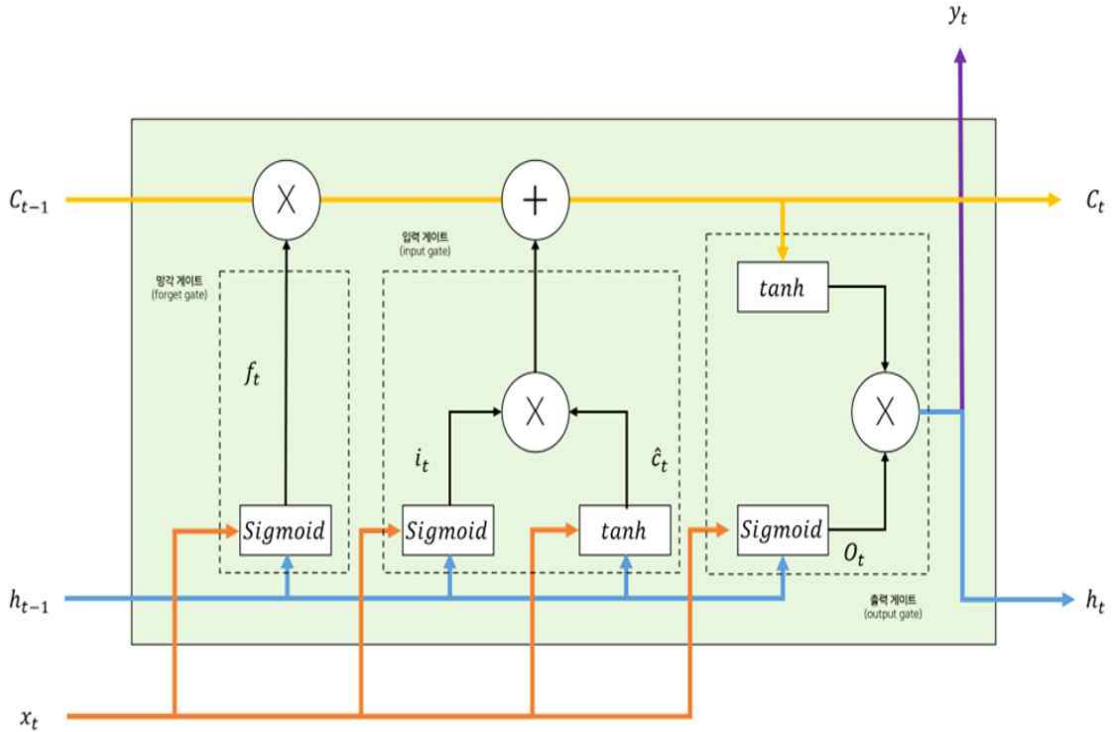
[그림 2-4]에서 망각 게이트(Forget Gate)는 현재 입력과 비교하여 이전 상태에 0과 1 사이의 값을 할당하여 이전 상태에서 삭제할 정보를 결정한다. 값 1은 정보를 유지한다는 의미이고, 값 0은 폐기를 의미한다. 입력 게이트(Input Gate)는 망각 게이트와 동일한 시스템을 사용하여 현재 상태에 저장할 새로운 정보 조각을 결정한다. 출력 게이트

---

1) Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. Neural computation, 9(8), 1735 - 1780.

트(Output Gate)는 이전 상태와 현재 상태를 고려하여 정보에 0부터 1까지의 값을 할당하여 현재 상태의 출력할 정보를 제어한다. 현재 상태에서 관련 정보를 선택적으로 출력하면 LSTM 네트워크가 유용하고 장기적인 종속성을 유지하여 현재와 미래의 시간 단계 모두에서 예측을 할 수 있다.

[그림 2-4] LSTM 구조



자료: <https://ctkim.tistory.com>

[그림 2-4]에서 망각 게이트(Forget Gate)는 현재 입력값  $x_t$ 와 직전 시점의 은닉 상태  $h_{t-1}$ 을 바탕으로 이전 셀 상태  $C_{t-1}$ 에서 어떤 정보를 유지하고, 어떤 정보를 제거할지를 결정한다. 출력값은 0과 1 사이이며, 1은 정보를 완전히 유지함을, 0은 완전히 폐기함을 의미한다. 망각 게이트의 계산은 시그모이드 함수(식 (2.5)참고, 이 함수는 입력값이 클수록 1에, 작을수록 0에 가까워지므로, 정보의 유지·폐기 결정을 자연스럽게 표현할 수 있다. 망각 게이트에서는 시그모이드 함수  $f(x)$ 가 0이면 완전 폐기, 1이면 완전 유지로 작용하며, 중간값은 부분적 반영을 의미)로 정의되며, 식 (2.6)과 같이 표현된다. 이 게이트는 불필요한 과거 정보를 제거함으로써 네트워크의 기억 용량을 효율적으로 관리한다.

$$f(x) = \frac{1}{1 + e^{-x}} = \frac{e^x}{e^x + 1} \quad (2.5)$$

$$f_t = \sigma(W_{h_f} h_{t-1} + W_{x_f} x_t + b_f) \quad (2.6)$$

입력 게이트는 새로운 정보를 셀 상태에 얼마나 반영할지를 결정한다. 일반적으로 두 단계로 구성된다. 먼저 시그모이드 함수를 통해 반영할 정보의 비율을 결정한다. 다음으로 tanh 함수를 통해 후보값  $\hat{C}_t$ 을 생성한다. 최종적으로 두 결과를 곱하여 셀 상태에 더한다. 이를 수식으로 표현하면, 식 (2.7)과 같다.

입력 게이트는 현재 시점에서 새롭게 저장할 정보의 양을 결정한다. 현재 입력  $x_t$ 와 이전 은닉 상태  $h_{t-1}$ 을 입력으로 받아 시그모이드 함수를 거쳐 어느 정도의 새로운 정보가 셀 상태에 반영될지를 계산한다. 또한, 후보 셀 상태( $\hat{C}_t$ )를 tanh 함수를 통해 생성하여 새로운 정보의 내용을 결정한다(참고 식(2.7)).

$$\begin{aligned} i_t &= \sigma(W_{h_i} h_{t-1} + W_{x_i} X_t + b_i) \\ \hat{C}_t &= \tanh(W_{h_c} h_{t-1} + W_{x_c} X_t + b_c) \\ C_t &= f_t C_{t-1} + i_t \hat{C}_t \end{aligned} \quad (2.7)$$

출력 게이트는 현재 시점에서 은닉 상태로 내보낼 정보의 양을 조절한다. 현재 입력  $x_t$ 와 이전 은닉 상태  $h_{t-1}$ 로부터 시그모이드 함수를 통해 출력 비율을 계산하고, 셀 상태의 tanh 변환 결과와 곱하여 최종 은닉 상태를 결정한다. 이런 일련의 과정은 식 (2.8)과 같다.

$$\begin{aligned} O_t &= \sigma(W_{h_o} h_{t-1} + W_{x_o} X_t) \\ h_t &= O_t \otimes \tanh(C_t) \end{aligned} \quad (2.8)$$

여기서  $\otimes$ 은 원소별 곱(element-wise product)을 의미한다.

LSTM의 핵심은 셀 상태(Cell State)에 있다. 셀 상태는 네트워크의 상단을 따라 흐르며, 과거의 정보를 장기적으로 유지하거나 필요에 따라 갱신한다.

이전 시점의 셀 상태  $C_{t-1}$ 는 망각 게이트를 통해 일부 정보가 제거되고, 입력 게이트를 통해 새로운 정보가 추가되어 현재 시점의 셀 상태  $C_t$ 가 계산된다. 그 수식은 식 (2.9)와 같다.

$$C_t = f_t \otimes C_{t-1} + i_t \otimes C_t \quad (2.9)$$

식 (2.9)는 과거의 정보(첫 번째 항)와 새로운 정보(두 번째 항)가 어떻게 결합되어 다음 시점으로 전달되는지를 보여준다. 따라서 LSTM은 단기적 입력 변화에 민감하면서도, 장기적 정보의 흐름을 안정적으로 유지할 수 있는 구조를 갖는다.

요약하면, LSTM은 RNN의 기울기 소실 문제를 해결하기 위해 기억 구조(Cell State)와 세 가지 게이트(Forget, Input, Output)를 도입한 모델이다. 이 구조는 불필요한 정보의 누적을 방지하고, 중요한 정보를 장기적으로 보존함으로써 RNN보다 훨씬 안정적인 시계열 학습을 가능하게 한다. LSTM의 등장 이후, GRU(Gated Recurrent Unit) 등 다양한 변형 구조가 제안되어, 시계열 예측, 자연어 처리, 음성 인식 등 다양한 분야에서 핵심적인 인공지능 알고리즘으로 활용되고 있다.

### 2.3.3 Transformer

앞 절에서 살펴본 LSTM(Long Short-Term Memory)은 순차적인 데이터 구조를 따라 입력을 단계별로 처리하면서 시간적 의존성(temporal dependency)을 학습할 수 있다는 장점을 지닌다. 그러나 시계열이 길어질수록 장기 의존성(Long-Term Dependency) 문제가 발생하여, 멀리 떨어진 과거의 정보가 점차 희석되고 모델이 이를 효과적으로 반영하기 어려워지는 한계를 가진다. 이러한 문제를 해결하기 위해 Vaswani 등(2017)<sup>2)</sup>이 제안한 구조가 Transformer(Attention-based Model)이다. Transformer는 순환(RNN)이나 합성곱(CNN) 구조를 사용하지 않고, Self-Attention 메커니즘만으로 문맥적 관계(Contextual Relationship)를 학습할 수 있음을 처음으로 입증하였다.

이 혁신적인 접근은 이후 BERT, GPT, T5, TimeGPT 등 현대 인공지능 모델의 기본 골격이 되었으며, 특히 시계열 분석과 자연어 처리 분야에서 구조적 전환을 이끌었다.

Transformer는 시계열 데이터를 순차적으로 처리하지 않고, 전체 시점을 동시에 고려(Self-Attention 구조)함으로써 모든 시점 간의 상호 관계를 효율적으로 학습할 수 있다. 핵심 원리는 '특정 시점이 다른 시점에 얼마나 주의를 기울여야 하는가

---

2) Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). Attention is all you need. In Advances in Neural Information Processing Systems, 5998 - 6008.

(Attention)'을 계산하여, 전체 데이터에서 중요한 시점이나 패턴을 자동으로 찾아내는 것이다. 이 과정을 통해 Transformer는 장기적 종속성과 단기적 변동을 동시에 반영할 수 있는 비순차적 병렬 학습 구조를 구현한다.

Transformer의 주요 구성요소는 입력 임베딩(Input Embedding), Self-Attention 메커니즘, Multi-Head Attention, Feed Forward Network, Residual 연결로 구분된다.

먼저 입력 임베딩(Input Embedding)은 시계열 데이터는 모델이 이해할 수 있도록 먼저 벡터 형태의 임베딩(embedding)으로 변환된다. Transformer는 전통적인 RNN과 달리 순서를 내재적으로 인식하지 않기 때문에, 각 시점의 상대적 위치 정보를 추가하기 위해 포지셔널 인코딩(Positional Encoding)을 사용한다. 이를 통해 모델은 입력 데이터의 시간적 순서를 인식하고, 시계열 구조를 학습할 수 있다.

Self-Attention은 각 시점의 데이터를 Query(Q), Key(K), Value(V)의 세 벡터로 변환하여 모든 시점 간의 유사도(Attention Score)를 계산한다. 즉, '현재 시점이 과거의 어느 시점 정보를 중요하게 참고해야 하는가'를 학습하는 과정이다. 이 결과로 Transformer는 시계열 전체에서 예측에 중요한 시점을 가중치(weight) 형태로 반영하며, 이를 통해 맥락적 의존성(Contextual Dependency)을 효율적으로 학습한다.

다음으로 Multi-Head Attention은 단일 Attention 메커니즘만으로는 다양한 시간적 관계를 포착하기 어렵기 때문에, Transformer는 여러 개의 Attention Head를 병렬적으로 학습한다. 이 구조를 Multi-Head Attention이라 하며, 각 Head가 서로 다른 관점에서 시계열 패턴을 해석한다. 예를 들어, 한 Head는 장기 추세(Long-term trend)를, 다른 Head는 단기 변동(Short-term fluctuation)을 포착할 수 있다. 이를 통해 Transformer는 복합적이고 다층적인 시간 관계를 학습한다.

끝으로 Feed Forward Network와 Residual Connection은 Attention 층에서 계산된 출력은 비선형 변환(Feed Forward Network)을 거쳐 정보 표현을 심화시킨다. 또한 Residual Connection(잔차 연결)을 추가하여, 역전파 과정에서의 기울기 소실을 방지하고 학습 안정성을 높인다. 이 두 과정은 여러 층(Layer)으로 적층되어, 시계열의 복잡한 비선형 구조를 심층적으로 학습하는 데 기여한다.

Transformer 기반 시계열 예측 모델은 LSTM처럼 한 시점씩 순차적으로 예측하지 않는다. 대신, 전체 입력 시퀀스를 동시에 인식하여 다음 시점(또는 여러 시점)의 값을 병렬적으로 예측(parallel prediction)한다.

예측 구조는 크게 두 가지 형태로 구분된다.

Encoder - Decoder 구조는 과거 데이터를 Encoder가 요약하여 잠재 표현(latent representation)으로 압축하고, Decoder가 이를 이용해 미래 시점의 값을 예측한다.

이 구조는 기계 번역 및 문장 생성 등에서 주로 사용되며, 시계열에서도 과거 - 미래 간 변환 관계를 명시적으로 학습할 수 있다.

Encoder-only 구조는 Informer, TimeTransformer, TimeGPT 등은 Encoder만을 사용하여 과거 시계열로부터 직접 미래를 추정한다. 이 구조는 긴 시계열에서도 계산 효율성이 높고, 메모리 사용량이 적어 대규모 시계열 분석에 적합하다.

Transformer는 단기 패턴, 주기성, 비선형 추세, 구조적 전환점을 동시에 포착할 수 있는 능력을 지닌다. 이에 따라 인구, 출산율, 기후 변화, 교통량, 금융 지표 등 복합적 사회·경제 시계열의 장기 예측에서 폭넓게 활용되고 있다. 최근에는 Transformer 구조를 확장한 다양한 시계열 특화 모델이 등장하였다.

Temporal Fusion Transformer (TFT)는 시계열의 불확실성과 외생 변수(예: 정책, 경기지표)를 통합 반영하고, Informer는 긴 시계열의 효율적 처리와 계산 복잡도 감소하며, TimeGPT는 대규모 시계열 데이터에 대한 범용 예측 기능 제공한다. 이들 모델은 기존 LSTM 대비 계산 효율성, 장기 패턴 인식 능력, 변수 간 상호작용 반영력 측면에서 우수한 성능을 보인다.

Transformer와 LSTM의 주요 차이를 처리 방식, 학습 구조, 정보 의존성 반영 방식 등의 측면에서 정리하면 다음 <표 2-2>와 같다.

<표 2-2> LSTM과 Transformer 비교

구분	LSTM	Transformer
처리 방식	순차적 처리 (시점별 반복)	병렬 처리 (전체 시점 동시 고려)
의존성 학습	단기 및 제한된 장기 의존성	전 구간의 장기 의존성 완전 반영
구조적 요소	순환 구조 (RNN 기반)	Self-Attention 기반
주요 구성	셀 상태, 3가지 게이트 (Forget/Input/Output)	Multi-Head Attention, Positional Encoding
입력 순서 인식	내재적으로 보유	포지셔널 인코딩으로 보완
계산 효율성	낮음 (순차 처리)	높음 (병렬 계산)
주요 활용 분야	단기 시계열, 음성·언어	복합 시계열, 언어·예측·생성
대표 모델	LSTM, GRU	BERT, GPT, TimeGPT, Informer

### 2.3.4 TimeGPT (Time Series Forecasting Foundation Model)

TimeGPT(Time Series Generative Pre-trained Transformer)는 Vaswani et al.(2017)이 제안한 Transformer 아키텍처, 즉 자가 주의(Self-Attention) 메커니즘을 기반으로 개발된 대규모 사전학습 시계열 예측 모델로, 시계열 분석 분야에서의 대표적인 파운데이션 모델(Foundation Model for Time Series Forecasting)로 분류된다. 해당 모델은 Garza 등(2023)<sup>3)</sup>이 제안한 TimeGPT-1 연구(arXiv:2310.03589v3, 2024)를 통해 처음 소개되었으며, 자연어 처리 영역에서 ChatGPT가 다양한 언어 데이터를 사전 학습하여 범용적인 언어 이해 및 생성 능력을 확보한 것과 유사한 방식으로, 이질적인 시계열 데이터를 통합적으로 학습함으로써 범용 시계열 예측 기능을 수행하도록 설계되었다.

기존의 시계열 예측 모델인 RNN이나 LSTM 계열은 데이터셋 또는 적용 분야별로 개별 모델을 구축하고 반복적으로 학습해야 하는 구조적 한계를 지니고 있었다. 반면, TimeGPT는 대규모 사전학습(pre-training)과 전이학습(fine-tuning)을 결합한 학습 전략을 채택함으로써, 단일 모델로 경제, 기후, 수요 예측, 에너지, 헬스케어 등 다양한 영역의 시계열 데이터를 동시에 처리할 수 있는 범용성(generality)과 새로운 도메인에 대한 높은 적응성(adaptability)을 확보하였다.

TimeGPT의 핵심 구조는 Transformer 기반 아키텍처에 있으며, 특히 자가 주의(Self-Attention) 메커니즘이 모델 성능을 좌우하는 핵심 요소로 작용한다. [그림 2-5]는 TimeGPT의 전체적인 구조를 도식화한 것으로, 입력 시계열의 각 시점이 다른 모든 시점과의 관계를 동시에 고려하여 표현 학습이 이루어짐을 보여준다. 이 모델은 공개적으로 이용 가능한 대규모 시계열 데이터셋을 활용하여 사전학습되었으며, 실험 결과를 통해 별도의 추가 학습 없이도 학습에 포함되지 않은 새로운(Unseen) 시계열 데이터에 대해 유의미한 예측 성능을 보이는 것이 확인되었다.

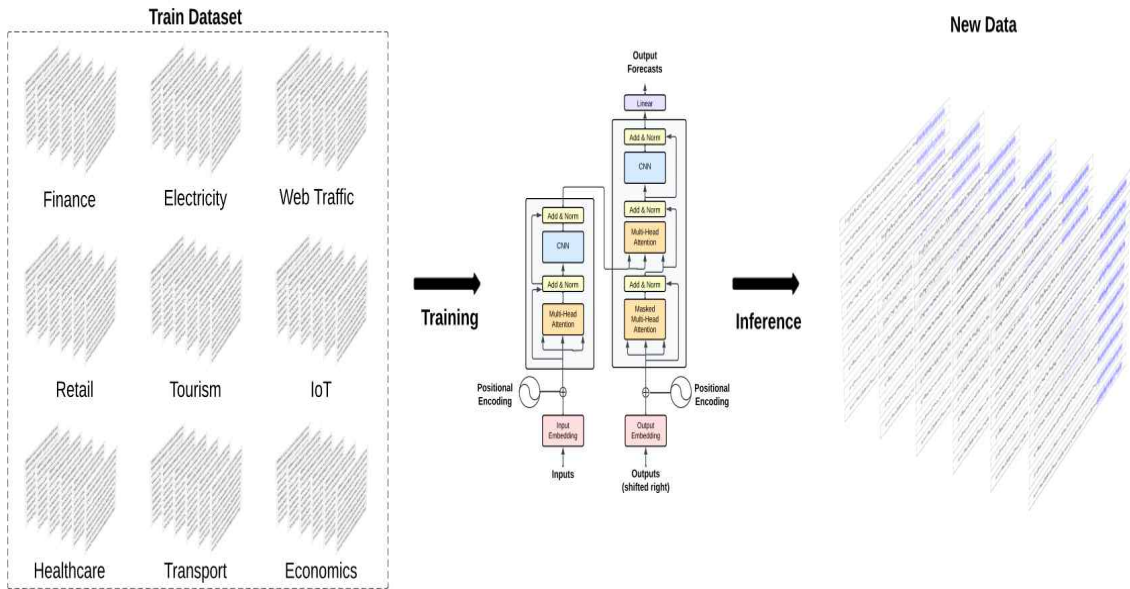
Transformer 기반 구조를 통해 TimeGPT는 시계열 데이터를 시간 순서대로 순차 처리하는 방식에서 벗어나, 전체 시점(time steps)을 병렬적으로 고려하여 장·단기 의존 관계를 동시에 학습한다. 이러한 접근은 LSTM 계열 모델에서 빈번히 지적되어 온 장기 의존성(long-term dependency) 손실 문제를 효과적으로 완화하며, 특히 장기간에

---

3) Garza, A., Challu, C., and Mergenthaler-Canseco, M. (2023). TimeGPT-1, arXiv:2310.03589. <https://doi.org/10.48550/arXiv.2310.03589>.

결친 시계열 데이터에서도 안정적이고 일관된 예측 성능을 가능하게 한다.

[그림 2-5] TimeGPT



자료: Garza 외 (2023)

한편, TimeGPT는 사전학습 단계에서 주기, 길이, 변동 패턴이 상이한 다양한 시계열 데이터를 대규모로 학습함으로써, 일반화된 시계열 표현 능력을 확보한다. 이후 금융, 기후, 인구, 에너지 등 특정 도메인에 적용할 경우에는 전이학습(fine-tuning)을 통해 소량의 도메인 특화 데이터만으로도 높은 예측 성능을 달성할 수 있다. 이러한 학습 구조는 모델의 학습 효율성과 도메인 적응력을 동시에 향상시키는 한편, 기존의 데이터셋 의존적 모델에 비해 반복 학습에 따른 계산 비용과 시간 부담을 크게 절감하는 장점을 가진다.

TimeGPT의 입력 데이터는 시계열의 각 시점을 토큰(token) 단위로 변환하여 모델에 입력된다. 각 시점의 토큰은 세 가지 벡터(Query(Q), Key(K), Value(V))로 표현된다. Query(Q)는 현재 시점이 다른 시점으로부터 어떤 정보를 받아들일지를 결정하고, Key(K)는 각 시점의 정보가 얼마나 중요한지를 판단을, Value(V)는 실제 전달되는 정보의 내용이다.

Self-Attention 메커니즘은 각 시점의 Query와 다른 시점들의 Key 간 유사도를 계산하여 가중치를 부여하고, 이를 Value에 반영함으로써 전체 시계열의 문맥(Context)을 학습한다. 이 Attention 연산은 일반적으로 다음 식 (2.9)로 표현된다.

$$Attention(Q, K, V) = softmax\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (2.9)$$

여기서  $Q, K, V$ 는 각각 Query, Key, Value 행렬이며, 시계열 토큰 간 관계를 반영하는 역할을 담당한다. 그리고  $d_k$ 는 Key 벡터의 차원 수를 의미하며, 내적 결과를 정규화하여 안정적인 학습을 보장한다.


이후 다층 Transformer 블록(Multi-layer Transformer Block)을 거치면서 TimeGPT는 긴 시계열 내에서 발생하는 복잡한 패턴(추세, 계절성, 비선형 변동 등)을 포착하고, 미래 값을 예측한다.

TimeGPT의 가장 큰 강점은 범용 시계열 예측(Generalized Time Series Forecasting) 능력이다. 하나의 사전학습된 모델로 다양한 데이터의 예측이 가능하며, 별도의 재학습 없이도 새로운 시계열에 대한 예측, 이상 탐지(Anomaly Detection), 패턴 식별, 추세 및 계절성 반영을 동시에 수행할 수 있다. 이러한 특징 덕분에 TimeGPT는 기존의 통계적 예측모형(ARIMA, Prophet)이나 딥러닝 기반의 RNN·LSTM 모델을 대체 또는 보완할 수 있는 차세대 시계열 예측 모델로 평가된다.

TimeGPT의 주요 장점은 다음과 같다. 첫째 장기 의존성 학습이다. Transformer 구조를 기반으로 긴 시계열 패턴을 안정적으로 학습한다. 둘째 범용성(Generality)이다. 단일 모델로 금융, 기후, 수요예측, 헬스케어 등 다양한 도메인에 적용이 가능하다. 셋째 전이학습(Fine-tuning)이다. 사전학습된 모델을 활용하여 소량의 데이터만으로도 높은 성능 확보한다. 넷째 예측 정확도 향상이다. 기존 RNN·LSTM 대비 예측 오차가 감소한다. 다섯째 불확실성 추정 가능하다. 확률적 예측 및 신뢰 구간 산출을 통한 결과의 신뢰성 향상한다.

[그림 2-6]은 TimeGPT와 주요 시계열 예측 모델 그룹 간의 월별 빈도별 상대 평균 절대 오차(Relative Mean Absolute Error, RMAE)를 비교한 결과이다.

[그림 2-6] TimeGPT와 다른 기법과의 RMAE 비교



자료: Garza 외 (2023)

그래프의 각 빈(bin)은 모델 그룹별 RMAE 분포를 나타내며, 중앙선은 평균값을 의미한다. 분석 결과, TimeGPT가 딥러닝, 통계, 머신러닝, 기준 모델(Base Model)보다 전반적으로 더 낮은 RMAE, 즉 우수한 예측 성능을 보임을 확인할 수 있다. 논문에서는 다른 빈도(주간, 분기별, 연간)에서도 유사한 결과가 나타났음을 보고하였다.

그리고 <표 2-3>은 RNN, LSTM, TimeGPT를 주요 속성별로 비교한 것이다.

<표 2-3> RNN, LSTM, TimeGPT 비교

구분	RNN	LSTM	TimeGPT
기본 구조	순환(Recurrent)	순환 + 게이트(Gating)	Transformer (Self-Attention)
처리 방식	순차적 (Sequential)	순차적(Sequential)	병렬적(Parallel)
장기 의존성 처리	약함	개선됨(게이트 구조)	우수(Self-Attention기반)
학습 방식	개별 학습	데이터셋별 학습	사전학습 + 전이학습
학습 데이터 요구	많음	많음	적음 (사전학습 활용)
예측 대상	단일 시계열	단일 시계열	다중 시계열 (범용 예측)
불확실성 추정	불가능	제한적	가능 (확률 기반 예측)
대표 활용분야	단순 시계열	음성·텍스트·단기 예측	금융·기후·인구·수요 예측 등
예측 성능	보통	높음	매우 높음

요약하면, TimeGPT는 Transformer 기반의 대규모 사전학습 시계열 모델로서, 기존 RNN과 LSTM이 가지는 구조적 한계를 근본적으로 개선하였다. 순차 처리 대신 병렬 Attention 구조를 통해 장기 패턴을 효율적으로 학습하며, 사전학습된 지식을 다양한 도메인으로 전이함으로써 적은 데이터로도 높은 예측 성능을 달성한다. 이러한 점에서 RNN → LSTM → TimeGPT로 이어지는 발전은 인공지능 기반 시계열 예측 기술의 진화 과정을 잘 보여준다. 특히 TimeGPT는 향후 인구, 출산율, 기후, 교통, 금융 등 사회·경제적 복합 시계열 예측 연구의 새로운 표준 모델로 활용될 가능성이 크다.

### 2.3.5 인공지능(AI) 시계열 예측 기본 원리

전통적 통계모형(예: 선형회귀, ARIMA, VAR, 회귀분석 기반 인구모형 등)은 명시적 수학적(explicit mathematical formulation)을 통해 종속변수(목표변수)와 독립변수(설명변수) 간의 관계를 규정한 후, 이 식에 미래의 독립변수 값을 대입하여 예측값을 계산한다. 예측 절차는 다음과 같다. 첫째, 과거 데이터를 이용하여 회귀계수 등 모형의 파라미터를 추정한다. 둘째, 미래의 설명변수(즉, 외생변수)의 값을 외부에서 예측하거나 가정한다. 셋째, 이 예측된 독립변수 값을 모형식에 대입하여 종속변수의 미래값을 계산한다. 이러한 방식은 '독립변수의 미래값을 알아야만 종속변수를 예측할 수 있는 구조'를 전제로 한다.

따라서 사회·경제 변수가 불확실하거나, 미래값을 예측하기 어려운 상황에서는 결과가 불안정해지거나 비현실적인 예측이 도출될 가능성이 높다. 즉, 전통적 통계모형은 이론적 해석력(인과관계 설명)은 강하지만, 불확실성이 높은 현실 세계의 데이터를 다루는 데에는 제약이 존재한다.

이에 반해 인공지능(AI) 기반 시계열 예측의 핵심 원리는 '과거의 패턴을 학습하여 미래를 추론한다'는 점에 있다. 즉, 미래의 독립변수를 사전에 예측하거나 가정하지 않고, 과거의 데이터 패턴 그 자체로부터 시간적 규칙성을 학습하여 미래 값을 확률적으로 추정한다. 시계열(Time Series)이란 일정한 시간 간격으로 관측된 데이터의 연속체를 의미하며, 각 시점의 관측치는 시간의 흐름에 따라 서로 종속적(temporally dependent)이다. 따라서 시계열 예측은 단순한 회귀분석 문제가 아니라, 시간적 의존성(temporal dependency)과 순서적 패턴(sequential pattern)을 동시에 고려해야 하는 고차원적 학습 문제라 할 수 있다.

〈표 2-4〉는 전통적 통계모형과 인공지능 시계열 예측의 차이를 요약한 것이다. 즉, 통계모형은 '왜 그런가(인과관계)'를 밝히는 데 강점을 가지며, 인공지능은 '어떻게 변할까(패턴 예측)'에 우수한 성능을 보인다. 두 접근법은 상호 보완적이며, 최근에는 AI 모델의 비선형 학습 능력과 통계모형의 해석력을 결합하는 하이브리드 예측 모델 연구가 활발히 진행되고 있다.

인공지능 기반 시계열 예측에서는 과거의 일정 구간 데이터를 입력(Input)으로 하여 다음 시점의 값을 예측(Output)한다. 이때 입력 구간의 길이를 시차(lag) 또는 윈도우(window)라고 하며, 예측은 일반적으로 한 시점(one-step ahead) 또는 여러 시점

(multi-step ahead)에 대해 수행된다.

〈표 2-4〉 통계 모형과 인공지능 예측 차이

구분	통계모형	인공지능(AI)
접근방식	명시적 모형식 기반 (수학적 규정)	데이터 기반 패턴 학습
예측구조	독립변수의 미래값 필요	과거 데이터 패턴으로 미래 추론
모델구조	명시적 수식 $Y_t = \beta_{0,t} + \beta_1 x_{1,t} + \dots + \beta_p x_{p,t} + \epsilon_t$	비선형 신경망 함수 $Y_t = f(Y_{t-1}, Y_{t-2}, Y_{t-3}, \dots, Y_{t-p})$
강점	인과관계 설명력 (Why)	패턴 기반 예측력 (How)
한계	불확실성에 취약	해석은 어렵지만 적응적 예측 가능

AI 모델은 전통적인 ARIMA나 VAR 모형과 달리, 비선형 관계, 복잡한 주기성, 상호작용 효과, 변동성의 비정상성(non-stationarity) 등을 자동으로 학습할 수 있다. 특히 LSTM(Long Short-Term Memory)과 Transformer는 시계열의 장기 의존성을 유지하는 능력이 뛰어나, 인구·출산율·기후·금융 등 장기 추세 분석에 효과적으로 활용된다.

LSTM은 과거 입력값 중 중요한 정보는 오랫동안 기억하고, 덜 중요한 정보는 잊는 구조(게이트 메커니즘)를 가진다. 이로써 급격한 변동(예: 출산율 급락, 경기침체 등)이 발생하더라도 과거의 장기 패턴을 반영한 안정적인 예측이 가능하다.

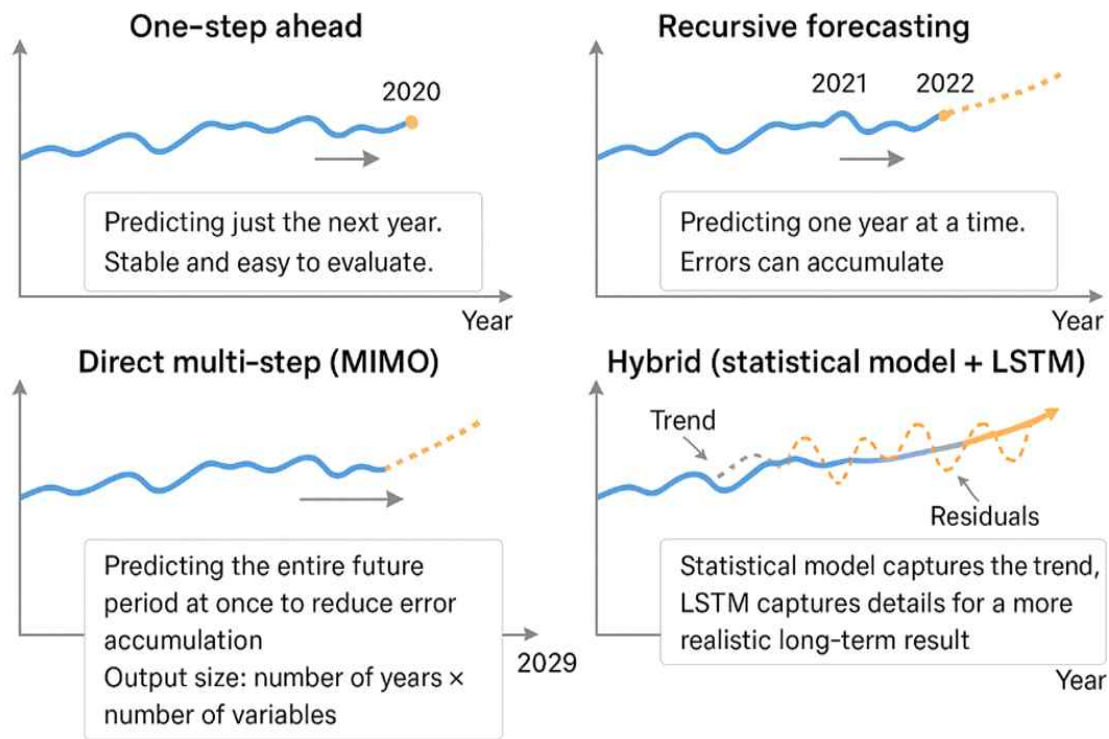
LSTM은 과거의 입력값 중 중요한 정보는 오래 기억하고, 덜 중요한 정보는 잊어버리도록 설계된 구조를 가지고 있다. 이를 통해 급격한 변동(예: 출산율 하락, 경기침체)에도 과거의 장기 패턴을 반영한 안정적인 예측이 가능하다. LSTM의 입력은 시계열의 과거 구간( $y_t, y_{t-1}, \dots, y_{t-L}$ )이며, 출력( $\hat{y}_{t+1}$ )은 다음 시점 또는 다수 시점의 예측값이다. 이를 수식으로 표현하면  $\hat{y}_{t+1} = f(y_t, y_{t-1}, \dots, y_{t-L})$ 이 되고, 여기서  $L$ 은 시차(lag)이고  $f(\cdot)$ 은 학습된 비선형 함수(LSTM 신경망)이다.

인공지능 LSTM 기반 시계열 예측은 일반적으로 두 가지 방식으로 구분된다. 첫째 재귀적 예측(Recursive Forecasting)은 한 시점씩 순차적으로 예측을 수행하고, 예측값을 다음 시점의 입력으로 사용하는 방식이다. 단기 예측(예: 출산율, 단기 인구 변동 등)에 주로 활용된다. 둘째 직접 예측(Direct Forecasting, MIMO: Multi-Input Multi-Output)<sup>4)</sup>은 여러 시점을 동시에 예측하는 방식으로, 장기적인 패턴을 안정적으

로 학습할 때 유리하다. 기후, 인구구조, 경제성장률 등 중·장기 전망에 자주 적용된다.

[그림 2-7]은 인공지능 예측방법을 보여준다. 재귀적 예측은 상단 우측, 직접예측은 하단 좌측이다. 그 외에 과거 lag만큼의 데이터를 보고 다음 1년(예: 1981~2019로 학습 → 2020년 값을 예측)을 예측하는 방법으로 가장 안정적이며 평가하기 쉬운 one-step ahead 방법과, GAM, ARIMA, 코호트요인법 같은 전통 모형으로 큰 틀(추세)을 먼저 추정하고 LSTM은 잔차(세부 변동)만 학습하여, 장기 예측에서 더 현실적인 결과를 줄 수도 있는 하이브리드 방법도 있다.

[그림 2-7] 인공지능 예측 방법



4) LSTM 예측 방법의 유형은 One-step ahead (단일 시점 예측), Recursive forecasting (재귀 예측), Direct multi-step (MIMO, 다지평 직접 예측), Hybrid (통계모형 + LSTM) 등이 있다. 단일시점 예측은 과거 lag만큼의 데이터를 보고 다음 1년(예: 1981~2019로 학습 → 2020년 값을 예측)을 예측하는 방법이다. 가장 안정적이며 평가하기 쉽다. Recursive forecasting (재귀 예측)은 One-step 모델을 여러 번 반복해서 여러 해 앞을 예측하는 것이다. 예를 들어, 2020년 예측, 그 결과를 입력에 붙여서 2021년 예측, 그리고 다시 2022년 예측으로 것으로, 오차가 누적되어 갈수록 평평해지거나 왜곡될 수 있다. Direct multi-step (MIMO, 다지평 직접 예측)은 입력 창을 보고 한 번에 여러 해(예: 향후 10년) 전체를 예측하는 것이다. 오차 누적 문제를 줄이고, 미래 패턴을 더 안정적으로 학습할 수 있다. 출력층 크기를 “예측 연도 수 × 변수 수”로 설정하여 진행한다. 이 외에도 Hybrid (통계모형 + LSTM) 학습으로 GAM, ARIMA, 코호트요인법 같은 전통 모형으로 큰 틀(추세)을 먼저 추정하고 LSTM은 잔차(세부 변동)만 학습하여, 장기 예측에서 더 현실적인 결과를 줄 수 있다.

[그림 2-8]은 인공지능이 시계열 자료를 재귀적(recursive) 방식으로 예측하는 과정을 나타낸 것이다. 예를 들어, 시차(lag)가 15로 설정된 경우, 모델은 2010년부터 2024년까지 약 15년간의 데이터를 학습하여 먼저 1년 후인 2025년 값을 예측한다. 이후, 새로 예측된 2025년 값을 포함하여 2011년부터 2025년까지의 자료로 다시 학습을 수행하고, 이를 통해 다음 해인 2026년을 예측한다. 이러한 절차를 반복함으로써 매년 예측값을 갱신하며 10년 이후까지의 장기 예측을 수행하게 된다. 이러한 방식은 과거의 예측 결과를 입력으로 다시 사용하는 점에서 자기회귀(Auto-Regressive) 시계열 모델의 원리와 유사하다고 할 수 있다.

[그림 2-8] 인공지능 연령별출산율 재귀적 예측 방법 (lag = 15)

연령 연도	15	...	49	연령 연도	15	...	49	연령 연도	15	...	49
	2010	$f_{15,2010}$			$f_{49,2010}$	2011	$f_{15,2011}$			$f_{49,2011}$	2012
2011	$f_{15,2011}$		$f_{49,2011}$	2012	$f_{15,2012}$		$f_{49,2012}$	2013	$f_{15,2013}$		$f_{49,2013}$
...				...				...			
2023	$f_{15,2023}$		$f_{49,2023}$	2024	$f_{15,2024}$		$f_{49,2024}$	2025	$f_{15,2025}$		$f_{49,2025}$
2024	$f_{15,2024}$		$f_{49,2024}$	2025	$f_{15,2025}$		$f_{49,2025}$	2026	$f_{15,2026}$		$f_{49,2026}$
2025	$f_{15,2025}$		$f_{49,2025}$	2026	$f_{15,2026}$		$f_{49,2026}$	2027	$f_{15,2027}$		$f_{49,2027}$

여기서 주요한 점은 인공지능 시계열 예측의 목적은 단순히 '다음 값을 맞히는 것'이 아니다. 그 핵심은 시간의 흐름 속에 내재된 패턴, 추세, 주기성, 변동성, 비정상성을 탐지하고 이를 수학적으로 모델링하는 것이다. 즉, 데이터에 숨어 있는 시간적 규칙성과 변화 구조를 학습하여 미래를 설명 가능한 형태로 제시하는 과정이 바로 인공지능 시계열 분석의 본질이라 할 수 있다.

### Ⅲ. 출산율 영향변수 선정


이번 절은 통계청(2023, 2024) 저출생 통계지표체계에 속하는 여러 변수 가운데 출산율에 유의미한 영향을 미치는 변수를 선정하고 소개한다.

#### 3.1. 1993~2024년 연령출산율 추이

이 연구는 통계청의 국가통계포털(KOSIS)에서 제공하는 연령별 출산율(age-specific fertility rate, ASFR) 자료를 결과변수(outcome)로 활용한다. [그림 3-1]과 [그림 3-2]는 합계출산율과 연령별 출산율의 변화 추이를 각각 보여준다.

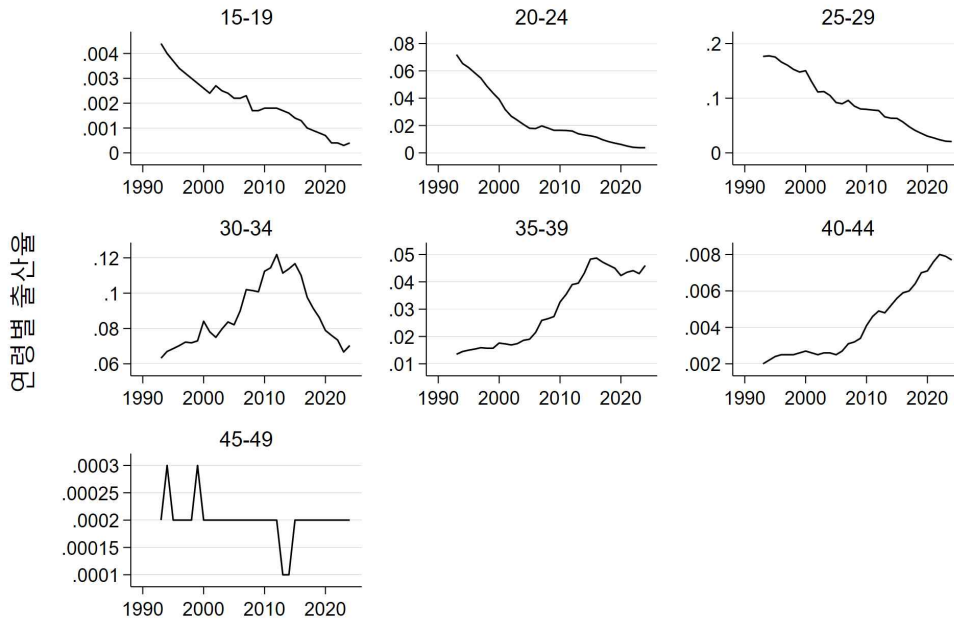
전체적으로 보면 합계출산율은 빠르게 하락하는 추세인데, 2000년 초반부터 2010년대 중반까지 합계출산율은 뚜렷한 추세를 보여주지 않고 1.2 수준에서 변동하다가 이후 급격히 하락했다. 2023년에는 0.72까지 하락했다가 2024년에 0.75로 다소 상승했으며 현재까지 공표된 2025년도 출생 통계에 따르면 2025년에도 출산율의 반등이 지속되는 것으로 예측되고 있다.

[그림 3-1] 합계출산율 추이



출처: 국가통계포털 ([www.kosis.kr](http://www.kosis.kr))

[그림 3-2] 연령별 출산율 추이



출처: 국가통계포털 ([www.kosis.kr](http://www.kosis.kr))

연령별 출산율 변화 추이는 연령대마다 다르게 나타나고 있다. 30세 미만의 출산율은 빠르게 하락하고 있으며 30대 이상의 출산율은 증가하는 추세이다. 40대 후반의 출산율은 매우 낮은 수준에서 유지되고 있으며 뚜렷한 추이를 보여주지 않는다. 단, 30대의 출산율은 2010년대 중반 이후 하락하는 추세인데, 출산율의 수준이 높은 30대 초반에서 이러한 하락이 더욱 두드러지게 나타나고 있다. 결국 2010년대 중반 이후 출산율의 급격한 하락은 30대의 출산율 하락에 그 원인이 있다고 할 수 있다.

이 연구는 연령대별 출산율에 영향을 미치는 다양한 사회경제적 요인들을 기존 연구에 근거해서 선별하고 AI를 활용한 방법론을 적용하여 단기출산율 예측에 활용하는 것을 목적으로 한다.

## 3.2. 선행연구 검토

### 3.2.1 출산율 반등에 대한 이론과 거시동태 패널분석을 통한 출산율 분석

2000년대 초반 유럽에서 나타난 합계출산율 반등 현상에 많은 연구가 주목했고, 그 원인을 규명하기 위해 거시적 변수들과 출산율의 관계를 분석한 연구들이 축적되어 왔다. 대표적으로 인간개발지수(HDI)와 합계출산율의 관계 변화(Myrskylä et al. 2009), 성평등주의 진전에 따른 출산율 반등 가능성(McDonald 2000; Goldscheider et al. 2015; Esping-Andersen and Billari 2015), 문화적 가치관 변화에 초점을 둔 제2차 인구변천 이론(Lesthaghe 1995; Sobotka 2008), 고용 및 경제적 불확실성과 출산율의 관계(Vignoli et al. 2020) 등을 들 수 있다. 이들 연구는 출산율 변동의 외생적 요인을 규명하고, 이를 활용한 출산율 추계의 가능성을 제시한다는 점에서 의의를 지닌다.

경험적인 분석들은 대부분 거시동태 자료 분석을 활용했다. 주요한 최근 연구들을 정리하면 다음과 같다. 우선, 황인도 외(2023)의 한국은행 보고서가 주목할 만한데, 이 연구는 2000-2021년 OECD 35개 국가 자료를 분석하여 가족 관련 정부 지출, 청년층 고용률, 도시 집중도, 혼외 출산 비중 등이 출산율의 주요한 결정요인임을 보여주었다. 시뮬레이션 분석 결과, 한국의 외생적 조건들이 OECD 평균 수준으로 수렴할 경우 합계출산율이 상당한 수준으로 상승할 수 있음을 보여주었다.

Fluchtman et. al (2023)의 OECD 보고서는 26개 OECD 국가의 2002-2019년 패널 자료를 활용하여 가족·노동 정책 및 노동시장 조건이 합계출산율에 미치는 영향을 분석하였다. 분석 결과, 1990년대 이전 고용률과 합계출산율 간 부(-)적 관계가 이후 정(+ )적 관계로 전환되었음이 확인되었으며, 육아휴직 지원, 보육시설 확충, 아동수당 등 출산 친화적 정책이 합계출산율 제고에 기여하는 것으로 나타났다.

계봉오 외(2024)의 연구는 역시 OECD 국가를 분석 단위로 삼았는데, 성평등주의의 진전 초기에는 출산율이 하락하지만 이후에는 출산율이 상승하는 경향이 있음을 보여주었다. 계봉오 외(2024)는 또한 한국의 시도 자료를 활용해서 거시노동시장 조건의 변화에 따라 시도의 출산율이 변화하는 것을 보여주었다.

### 3.2.2. 외생변수를 활용한 출산율 추계

출산율 추계에 사회경제적 조건의 변화를 활용한 연구는 드문데, 이는 기본적으로 출산율보다 외생변수의 추이 예측이 더 어렵다는 데 기인한다. 오진호·계봉오의 연구(2024a, 2024b)는 예외적인 경우에 해당한다. 우선, 오진호·계봉오(2024a)는 인구주택총조사 마이크로 자료를 사회경제적 요인을 활용한 출산율 단기 예측에 활용했다. 적생아법(own children method)을 활용해서 출산율을 추정했고, 여성의 교육수준, 고용상태, 거주지역, 혼인상태 등을 출산율의 결정요인으로 활용했다. 출산율 결정요인들의 변화 추이는 수정지수 모형을 통해서 예측했고, 기준연도인 2020년부터 15년 이후인 2035년까지의 출산율을 예측했다. 분석결과는 2022년부터 합계출산율이 반등해서 2025년에는 1.035까지 상승하는 것으로 예측했다. 이 모형은 2015년 이후의 급격한 출산율 하락 추이를 제대로 예측하지 못하는 한계를 지니고 있다. 이는 출산율 결정요인들의 변화추이를 예측하는 모형에 한계가 있음을 보여준다고 할 수 있다. 오진호·계봉오(2024b)는 같은 연령대의 남성과 여성의 고용률, 결혼에 대한 태도, 가족정책 지출 규모를 출산율의 결정요인으로 모형화하고, 이를 토대로 2035년까지의 출산율을 추계한 결과를 제시하고 있다. 분석결과는 합계출산율이 2030년대 중반까지 1.5 수준으로 상승할 것으로 예측하고 있는데, 이러한 예측의 타당성에 대해서는 의구심이 든다. 이 두 연구는 외생변수를 활용해서 출산율을 예측하는 작업의 난이도가 상당히 높다는 것을 잘 보여준다. 출산율과 외생변수의 관계를 적절히 모형화할 수 있다고 하더라도 외생변수의 변화 추이를 예측하는 것은 대단히 어려운 작업이며, 이러한 어려움으로 인해서 장래 출산율을 정확히 예측하는 데 한계가 존재할 수 있음을 잘 보여준다. AI를 활용한 예측은 이러한 한계를 극복하는 데 기여할 것으로 기대할 수 있다.

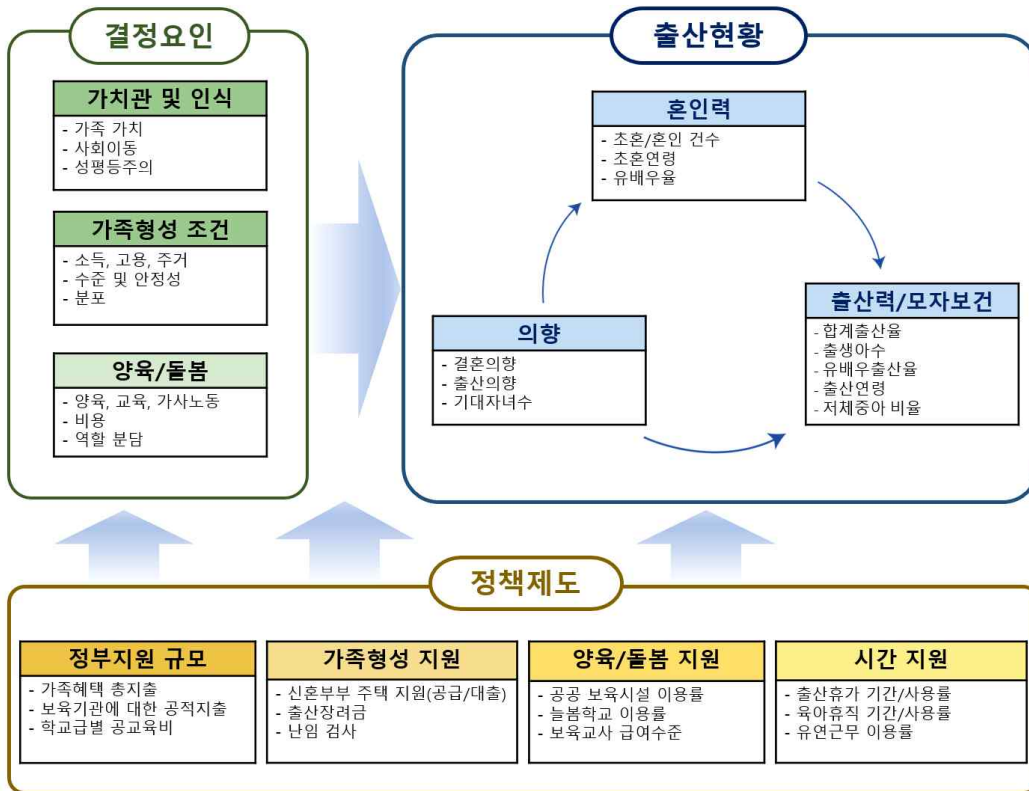
### 3.3. 저출생통계지표

[그림 3-3]은 계봉오 외(2024)에서 제시한 저출생 통계지표체계 이론적 프레임워크를 보여준다. 저출생 통계지표체계 프레임워크는 출산현황을 혼인력, 의향, 출산력/모자보건으로 나누어 파악하고 출산에 영향을 미치는 요인들을 가치관 및 인식, 가족형성 조건, 양육 및 돌봄으로 나누어서 파악하는 특징을 갖고 있다.

본 연구는 AI 기법을 활용해서 단기 출산율 예측에 초점을 맞추는데, 예측의 정확성

을 높이기 위해서는 적절한 추정 방법의 활용뿐만 아니라 출산율의 예측변수를 선정하는 작업 또한 중요하다. 저출생 통계지표 체계는 이를 위한 기본적인 가이드라인을 제공해 준다고 할 수 있다. 특히 위에 제시된 저출생통계지표체계 이론적 프레임워크는 다음과 같은 특징이 있다.

[그림 3-3] 저출생 통계지표체계 이론적 프레임워크



출처: 계봉오 외(2024, p.11)

첫째, 남성과 여성의 사회경제적 조건을 함께 고려할 필요가 있음을 강조한다. 출산율 변화에 대한 전통적인 이론들은 대부분 여성의 교육수준 향상과 고용 증가에 따른 출산 비용의 증가에 초점을 맞추고 있는데 여성뿐만 아니라 남성의 사회경제적 조건이 출산율에 큰 영향을 미친다는 경험적 증거들이 축적되고 있다(Oppenheimer 1988; Sweeney 2002; Doepke et al. 2023). 또한, 최근 연구에 따르면 같은 연령대 남성의 고용률 하락과 연령별 출산율 간에 강한 상관관계가 존재한다(한신원, 2025). 따라서 여성의 사회경제적 조건뿐만 아니라 남성의 사회경제적 조건을 함께 고려하는 것이 출산율을 이해하는 데 매우 중요하다는 것을 알 수 있다.

둘째, 주관적인 가치관과 인식을 고려한다. 많은 연구들의 객관적인 사회경제적 조건과 출산율의 관계에 주목하고 있는데, 이러한 연구들은 암묵적으로 현대 사회에서 사람들이 여러 가지 제한으로 인해서 원하는 수준의 자녀를 갖지 않는다고 가정한다 (Morgan 2003). 그리고 이러한 제한은 대부분 객관적인 사회경제적 조건으로 파악한다. 그런데, 현재 합계출산율이 1.0 미만인 한국사회의 현실을 고려할 때 사람들이 객관적인 제약 때문에 원하는 수의 자녀를 갖지 않는다고 이해하는 것이 타당한지는 의심스럽다. 사람들의 가족과 자녀에 대한 가치관의 변화가 1.0 미만의 합계출산율이 지속되는 원인으로 이해할 필요가 있다. 따라서 저출생 통계지표체계 프레임워크는 가치관 및 인식의 변화를 출산율 변화의 주요한 원인으로 파악하고 한다.

셋째, 양육과 돌봄이 출산에 미치는 영향을 강조한다. 양육 및 돌봄 환경이 출산에 미치는 영향에 대한 경험적인 증거는 충분히 축적되어 있다. 양질의 양육시설의 제공이 추가 출산의향 및 실제 출산율을 높이는 효과가 있음을 보여주는 경험적인 증거는 노르웨이, 이탈리아 등 다양한 국가에서 반복적으로 확인되고 있으며(Rindfuss et al. 2010; Miaci 2025), 이러한 경험적 분석결과를 기반으로 양육 및 돌봄 환경을 개선하기 위한 정책적 개입을 진행하고 있다. 뿐만 아니라 강한 성별 역할 분리의 극복이 초저출산 현상 반등의 전제조건일 수 있다는 연구성과를 반영해서(Esping-Andersen and Billari 2015) 양육과 돌봄의 역할 분담 또한 고려할 필요가 있다. 저출생 통계지표 프레임워크는 이러한 측면을 고려해서 양육 및 돌봄 환경에 대한 지표를 저출생 통계지표에 포함할 것으로 제안하고 있다.

넷째, 정부의 정책적 개입에 의한 출산율 반등을 이해하기 위해서 정책과 제도와 관련된 지표를 포함할 필요가 있다. 저출생 통계지표체계를 위해서는 재정적 지원, 가족형성 지원, 양육/돌봄 지원, 시간 지원 등 저출생 현상에 대응하기 위한 정책적 개입을 지표화해서 포함하고 있다.

<표 3-1>은 이 프레임워크에 따른 저출생통계 지표체계의 지표 리스트를 제시하고 있다. 본 연구에서는 출산율의 결정요인을 선정하기 위해서 저출생 통계지표체계의 지표를 우선적으로 고려하되 자료의 가용성과 이론적 적합성을 고려하여 다른 요인들 또한 고려하도록 한다.

<표 3-1> 저출생 통계지표 체계

영역	부문	지표명	비고
출산 현황	출산력	1. 출생아수	대표
		2. 합계출산율	대표
		3. 연령별 출산율	주요
		4. 출산순위별 연령별 출산율	보조
		5. 조정합계출산율	보조
		6. 코호트 완결 출산율	주요
		7. 코호트 무자녀 비율	보조
		8. 유배우 합계출산율	주요
		9. 혼외출산 비중	보조
		10. 여성의 평균 출산연령	대표
		11. 신혼부부 무자녀 비율	주요
	모자보건	12. 저체중아 출생 비율	대표
		13. 영아사망률	보조
		14. 조산아 비율	보조
		15. 신생아 중 다태아 비중	보조
		16. 자연유산비	보조
	혼인력	17. 조혼인율	대표
		18. 혼인건수	주요
		19. 초혼건수	보조
		20. 평균초혼연령	대표
		21. 연령별 유배우율	주요
		22. 연령별 초혼율	보조
	의향	23. 결혼의향	주요
		24. 출산의향	대표
		25. 기대자녀수	보조
결정 요인	가치관 및인식	26. 자녀 필요성 인식	대표
		27. 결혼에 대한 인식	주요
		28. 가족 내 성역할 인식	주요
		29. 자기실현주의	보조
		30. 사회이동 가능성 인식	주요
	가족 형성 조건	31. 청년층 평균 소득	대표
		32. 청년 고용률	주요
		33. 청년 정규직 근로자비율	보조
		34. 청년층소득이동률	보조
		35. 소득분배지표(10분위 배율)	보조
		36. 청년층 소득대비 주택임대료 비율	주요
		37. 청년층 자가 / 전세비율	보조
		38. 신혼부부 가구소득 대비 부채 비율	보조
		39. 청년층 수도권 집중도	주요
	양육/돌봄	40. 학교급별 사교육비	대표
		41. 자녀 1명당 월평균양육비	보조
		42. 성별 가사노동시간	주요
		43. 성별 육아시간	주요
	정책 제도	정부 지원 규모	44. 가족혜택 총지출
45. 영유아기 지원수당 규모			대표
46. 보육기관에 대한 공적지출			보조
47. 학교급별 공교육비			보조
가족 형성 지원		48. 청년 고용 지원 지출	대표
		49. 임대주택공급현황 (신혼부부 대상 주택공급)	주요
		50. 출산장려금 지급 액수	보조
양육/돌봄 지원		51. 난임검사 지원건수	보조
		52. 보육시설 이용률	대표
		53. 공공 보육시설 이용률	주요
		54. 보육시설 이용 비용	보조
		55. 보육교사 1명당 보육아동 수	보조
		56. 중위소득 대비 보육교사 급여수준 (신규)	보조
		57. 놀봄학교 이용률	주요
58. 비공식 돌봄서비스 이용률	보조		

영역	부문	지표명	비고
	시간 지원	59. 출산휴가 사용비(남/여)	주요
		60. 출산휴가 기간(남/여)	보조
		61. 출산휴가 소득 대체율(남/여)	보조
		62. 출생아 부모의 육아휴직 사용률 (남/여)	대표
		63. 유급 육아휴직 소득대체율 (남/여)	보조
		64. 유연근무 활용률	주요
		65. 출산전후 모의 취업비중	보조
		66. 기혼여성 고용률	보조
		67. 가족친화 기업 인증률	주요

출처: 계봉오 외(2024, p.14-15)

### 3.4. 출산율 영향 주요 변수 대상 선정

저출생통계지표체계에 제시된 지표들을 AI 기법을 활용한 출산율 예측에 모두 활용할 수는 없다. 출산율에 미치는 영향에 차이가 있고, 지표들 간에 강한 상관관계가 존재하는 경우가 있으며, 시계열 자료는 짧은 지표들 또한 있다. 뿐만 아니라 추세 예측이 어려운 지표들 또한 있다. 따라서 각각의 영역에서 다음 지표들을 AI기법을 적용한 단기출산율 예측을 위해 활용하고자 한다.

#### 3.3.1 출산현황

출산현황은 혼인력, 의향, 출산력으로 구성되는데, 출산율 예측에 활용할 수 있는 지표는 연령대별 유배우율, 기대자녀 수 등이다. <표 3-2>은 15-49세 남녀의 연령별 유배우율, <표 3-3>은 연령별 유배우자의 기대자녀 수를 제시하고 있다. 이 자료는 인구주택총조사 마이크로 데이터에서 추출되므로 5년마다 업데이트할 수밖에 없는 한계를 지니는데 이 AI 기법을 활용하여 출산율을 추계할 때에는 내삽방법을 적용해서 중간 시점들의 자료를 추정하도록 한다.

<표 3-2> 연령별 유배우율 (15-49세)

	남성						
	15-19	20-24	25-29	30-34	35-39	40-44	45-49
2000	0.5	6.4	43.8	78.6	88.6	89.7	89.1
2005	0.3	3.9	28.9	67.7	82.4	86.5	86.5
2010	0.3	2.4	22.0	58.5	75.7	81.7	83.6
2015	0.1	1.9	15.6	51.6	70.2	75.6	78.4


2020	0.0	1.2	12.0	42.0	65.8	72.9	74.8
여성							
	15-19	20-24	25-29	30-34	35-39	40-44	45-49
2000	0.5	6.4	43.8	78.6	88.6	89.7	89.1
2005	0.3	3.9	28.9	67.7	82.4	86.5	86.5
2010	0.3	2.4	22.0	58.5	75.7	81.7	83.6
2015	0.1	1.9	15.6	51.6	70.2	75.6	78.4
2020	0.0	1.2	12.0	42.0	65.8	72.9	74.8

<표 3-3> 연령대별 유배우 여성의 기대자녀 수

	2010년	2015년	2020년
전체	1.96	1.83	1.68
25 ~ 34	1.97	1.75	1.49
15 ~ 29	1.87	1.59	1.42
25 ~ 29	2.01	1.72	1.46
30 ~ 34	1.95	1.76	1.51
35 ~ 39	1.91	1.82	1.64
40 ~ 44	1.97	1.83	1.74
45 ~ 49	1.98	1.89	1.77

### 3.3.2 가족형성조건

[그림 3-4] 청년층 고용률

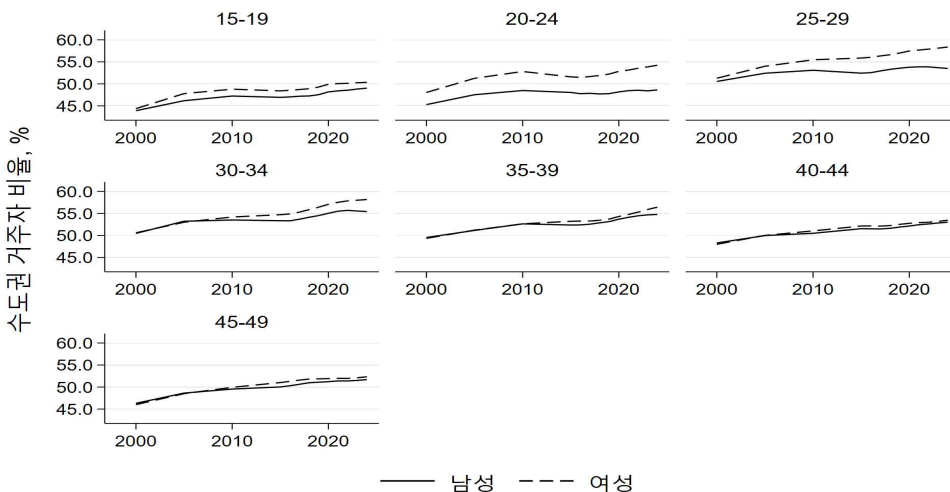


출처: 경제활동인구조사, 각년도

저출생 통계지표체계는 가족형성 조건으로 청년층의 소득, 고용, 주거, 수도권 집중도 등을 고려하고 있다. 이 요인들은 결혼 및 출산 이행의 주요한 결정요인들로 출산율 예측을 위해서 필요한 변수들이라고 할 수 있다. 단, 소득과 주거 변수의 경우에는 충분한 시계열 자료 확보에 어려움이 있으므로 이 연구에서는 청년층의 고용과 수도권 집중도를 중심으로 고려하고자 한다. 이 때 여성뿐만 아니라 남성의 고용과 수도권 집중도를 함께 고려하도록 한다. [그림 3-4]는 청년층의 고용률을 5세 단위 자료를 활용해서 보여주고 있다. 자료를 통해서 확인할 수 있듯이 20대 초반까지는 여성의 고용률이 남성보다 높는데 이후에는 남성의 고용률이 높은 패턴이 관찰된다. 단, 20대 후반 이후 여성의 고용률이 꾸준히 상승해서 2020년대가 되면 20대 후반과 30대 초반의 경우에는 남녀 간 고용률의 차이가 크지 않다. 단, 30대 후반 이후에는 여전이 남성과 여성의 고용률 격차가 유지되고 있다.

[그림 3-5]는 15-49세 인구의 연령별 수도권 거주자 비율을 보여주고 있다. 모든 연령대에서 수도권 거주자 비율이 증가하고 있음을 확인할 수 있는데, 30대 초반까지는 여성보다 남성의 수도권 거주자 비율이 낮게 나타나고 있음을 확인할 수 있다. 특히 20대의 경우에는 남녀 간 수도권 거주자 비율의 차이가 크고 점차 증가하는 추세이다. 이는 지역 간 산업구조 차이 등에 의한 것으로 해석할 수 있는데 수도권 거주자 비율의 이러한 성별 차이는 혼인율 등에도 부정적인 영향을 미칠 것으로 예상할 수 있다.

[그림 3-5] 청년층의 수도권 거주자 비율



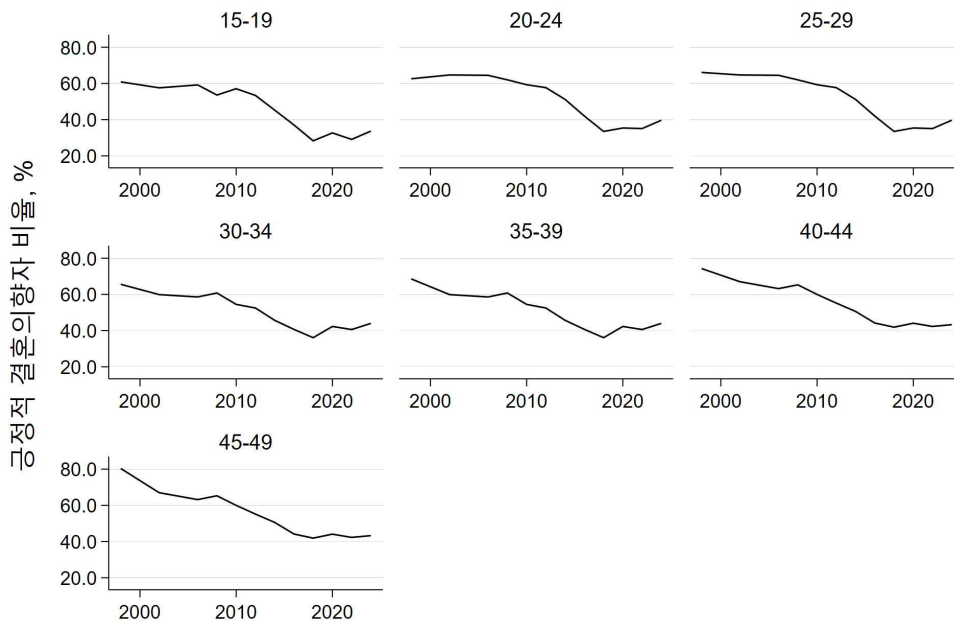
출처: 주민등록연앙인구, 각년도

### 3.3.3 양육 및 돌봄

저출생 통계지표체계는 양육 및 돌봄 지표로 사교육비, 양육비, 가사노동시간, 육아 시간 등을 포함하고 있다. 양육 및 돌봄은 출산율의 중요한 결정요인으로 출산율 예측을 위한 외생변수로 포함할 필요성이 높다. 그런데, 저출생 통계지표체계에 포함되어 있는 양육 및 돌봄 영역의 지표들은 시계열 자료를 확보하기 어렵다. 따라서 이 연구에서는 양육 및 돌봄 관련 변수들은 분석에 포함하지 않는다.

### 3.3.4 가치관 및 인식

[그림 3-6] 긍정적 결혼의향자 비율



출처: 사회조사, 각년도


저출생 통계지표 체계는 가치관 및 인식 영역으로 자녀, 결혼, 성역할태도, 자기실현 주의, 사회이동 가능성 등을 포함하고 있다. 제2인구변천 이론 등에서 강조하는 개인주의적 가치관의 확산을 포착하기 위해서는 자기실현주의적 태도의 변화를 활용하는 것이 필요하다고 할 수 있지만 이에 대한 적절한 측정치가 부재하며 시계열 자료 또한 부족한 상황이다. 가치관 및 인식을 파악할 수 있는 지표는 행정자료로 파악할 수 없고 서베이 자료를 활용해야 하는데 이 목적으로 위해서 활용할 수 있는 가장 신뢰성이 높

은 자료원은 국가데이터처의 <사회조사> 자료이다. 2008년 이후 결혼 및 자녀에 대한 태도 변수를 측정하고 있는데, 성역할 인식 변수의 시계열은 이보다 짧다. 자녀에 대한 인식은 자녀의 필요성과 비혼 출산에 대한 태도를 포함하고 있는데 자녀의 필요성에 대한 인식 변수는 2018년 이후 조사항목에 포함되어 있다. 따라서 가치관 및 인식 영역에서 가장 긴 시계열 자료를 확보할 수 있는 지표는 결혼에 대한 태도라고 할 수 있다. 따라서 이 연구에서는 결혼에 대한 태도를 활용하도록 한다.

[그림 3-6]은 결혼에 대한 인식변화 추이를 보여주는데 모든 연령대에서 결혼의향이 떨어지고 있음을 확인할 수 있다. 특히 2010년까지는 30대 이전 연령대의 결혼의향이 안정적으로 유지되었는데 2010년대 이후에는 지속적으로 하락하고 있음을 확인할 수 있다. 한편 2018년 이후에는 결혼의향이 더 이상 하락하지 않고 20-30대에서는 상승하는 경향을 보여주고 있다. 보다 엄밀한 연구를 필요로 하겠지만 2010년대 초반에 결혼의향이 하락한 이후 4-5년 후인 2015년부터 출산율이 가파르게 하락했으며, 결혼의향의 하락 현상이 멈춘 2018년 이후 6년이 지난 시점인 2024년에 출산율이 반등했다. 이는 결혼의향의 변화가 시차를 갖고 출산율에 영향을 미칠 가능성이 있음을 보여준다고 할 수 있다.

### 3.3.5 정책과 제도

[그림 3-7] GDP 대비 가족공공 지출 비율



출처: OECD 각년도

저출생 통계지표체계는 결정요인, 가치관 및 인식, 양육 및 돌봄 영역과 더불어 정책과 제도를 별도의 영역으로 설정하고 있는데, 이는 출산에 영향을 미치는 영역들이 정부의 정책과 제도에 의해서 영향을 받기 때문이다. 다양한 정책과 제도 변수들이 존재하지만 이 연구에서는 출산과 관련된 정책을 가장 포괄적으로 대표하는 가족혜택 총지출을 포함하도록 한다. [그림 3-7]은 2000년 이후 GDP 대비 가족혜택 지출의 비율을 제시하고 있다.

## IV. 인공지능 활용 출산율 예측

### 4.1. 인공지능 활용 연령별출산율 예측

#### 4.1.1 연령별출산율 인공지능 학습용 데이터 전처리

이번 절은 연령별출산율 자료를 인공지능 학습용으로 처리하기 위한 데이터전처리를 소개한다.

먼저 연령별표준화이다. 연령별 표준화는 연령별 출산율 패턴을 제거한다기 보다는 수준(level)을 제거하는 효과가 큰 데이터 전처리과정이다. 즉, 우리나라 연령별출산율은 28~37세 구간의 높은 출산수준을 보이고 그 이외의 연령에서는 낮은 출산 수준을 나타낸다. 이런 자료에 대해 연령별표준화를 적용하면 절대적 높낮이는 제거되지만 피크(peak)형태, 좌우 비대칭에서 대칭, 한해에서 다음 해로의 곡선 흐름은 같은 형태로 유지된다. 다만 연령대별 수준 차이는 LSTM, Transformer, TimeGPT 등의 입력에서 사라진다. 예를 들어 30세 A여성의 1981~2024년 출산율은 0.05~0.12이고, 20세 B여성의 1981~2024년 출산율은 0.002~0.08이다. 이를 표준화하면 대략 30세 A 여성은 0~1 사이, 20세 B 여성도 0~1사이로 나타난다. 즉 모든 연령이 동일 스케일에 들어가므로, LSTM, Transformer, TimeGPT 등은 '어떤 연령이 상대적으로 높고 낮은지'보다 '각 연령의 변동 패턴'만 학습하게 된다.

다음으로 정규화는 많은 인구학 연구(Lee와 Carter, 1992; Li와 Lee, 2005; Hyndman과 Booth, 2008; Hyndman 외, 2013)에서 연령별 출산율, 사망률 같은 연령-시계열 자료에 정규화를 적용하는 이유가 표준화에서 발생하는 문제 때문이다. 일반적인 연령 전체에서 min/max를 구해 통합 정규화는 식(4.1)과 같다.

$$\text{정규화} f_x = \frac{f_x - \min(f_x)}{\max(f_x) - \min(f_x)}, f_x : \text{연령별출산율} \quad (4.1)$$

그런데 연령별출산율, 사망률 자료를 소수점 자료이므로 log1p변환을 적용하는 정규화 식(4.2)를 많이 사용한다.

$$\text{정규화} f_x = \frac{\log(f_x + 1) - \min(f_x)}{\max(f_x) - \min(f_x)}, f_x : \text{연령별출산율} \quad (4.2)$$

이처럼 인공지능 학습용 시계열 ASFR 예측(LSTM + 연령 패턴 유지) 목적에는 정규화(normalization)가 더 적합하다고 볼 수 있다. 왜냐하면, ASFR 예측의 핵심은 '30대 초반 피크', '10대/40대의 낮은 비중' 등 연령 패턴 형태를 보존하는 것이기 때문이다. z-score는 연령별 평균·분산을 제거하기 때문에 '연령 간 수준 차이'라는 인구학적 구조를 다소 약화시킨다.

요약하면 연령별출산율은 인공지능 학습용으로 활용하는 조합 데이터전처리는 ㉠ log1p 변환, ㉡ 전체 구간 0 - 1 정규화(연령×연도 전체에서 min/max 사용), ㉢역변환 후 expm1로 복귀이다. 이 조합의 장점은 낮은 연령 ASFR의 미세 변화도 학습 가능하고, 높은 연령의 피크(peak) 구조 유지, 전체 구조 왜곡 최소화, 모든 연령이 '원 스케일 기반 상대 구조'를 유지한다.

끝으로 연령별출산율의 연령차분이다. 1981~2024년 연령별출산율은 15세에서 시작해 28~32세에 정점을 찍고 그 이후에는 하락하는 종형(bell-shaped) 또는 우측 이동 가우시안(right-shifted Gaussian) 형태의 연령곡선 형태로, 이런 곡선은 단순 시계열이 아니라 연령 연속함수에 가깝다. 그리고 연령별출산율은 생리적, 의학적 제약, 사회경제적 행동 패턴, 혼인, 교육, 고용요인 등에 의해 결정되는 경향이 있다. 이런 변수들은 급격한 연령변화를 만들지 않고 완만한 증가, 정점, 완만한 감소의 곡선을 나타내며, 곡률이 갑자기 커지지 않는다. 즉, 2차 차분 최소화는 바로 이런 생물학적 부드러움(smoothness) 조건을 수학적으로 강제하는 장치이다. 이런 연령별출산율에 2차 차분을 적용이 연령별출산율은 패턴 예측문제이고 모델이 학습해야 하는 대상은 절대값보다는 양상(shape)의 구조적 안전성이다. 따라서 이런 구조적 안전성을 위해 2차 차분을 적용하면, ① 예측곡선이 현실적인 shape 유지, ② 극단적 진동이 사라져 test MAE, RMSE가 크게 개선, ③ TFR(합계출산율) 예측도 안정성 확보, ④ 장기예측(2025 - 2034)에서 발산 문제 감소한다.

그런데 2차 차분은 1981~2024년에서 2개 연도의 자료를 차분에 활용하여 분석에 이용되지 않는 자료 손실이 발생한다. 따라서 본 연구에서는 2차 차분과 자료의 손실 가운데서 어느 것이 효용성이 있는지를 살펴보았으며, 2차 차분 결과의 장점보다는 자료 손실이 더 큰 비효율성을 보여 차분을 적용하지 않고 진행하였음을 밝힌다.

정리하면 본 연구는 연령별출산율을 LSTM, Transformer, TimeGPT 인공지능 학습용으로 처리하기 위한 데이터전처리과정으로 log1p와 정규화만 적용하여 모델 예측의 구조적 안정성과 수렴성을 강화한다.

#### 4.1.2 LSTM 모델 기반 연령별출산율 예측

이번 절에서는 LSTM(Long Short-Term Memory) 기반의 연령별 출산율 예측 과정을 설명한다. 먼저, 과적합(overfitting)과 과소적합(underfitting) 문제를 완화하기 위해 1981년부터 2024년까지의 연령별 출산율 자료를 훈련(train) 구간(1981~2020년)과 검증(test) 구간(2021~2024년)으로 구분하여 학습에 활용하였다.

그런 다음 검증 구간(2021~2024년)에 대한 재귀적 방법으로 예측값을 산출하고, 합계출산율(TFR) 기준으로 RMSE, MAE, MAPE 지표를 통해 예측 성능을 평가하였다. 이런 일련의 과정과 모델 하이퍼파라미터 lag 선정을 위해 lag을 5~15까지 변화를 주어 적합력 지수 MSE, MAE, MAPE를 살펴 합리적인 lag을 정하였다.

〈표 4-1〉은 연령별출산율 정규화, log1p 변환을 적용한 이후의 자료에 대하여 LSTM 모형 결과를 보여준다. 분석결과는 LSTM 모형 적용이 하이퍼파라미터 시차의 적절한 선정과 데이터 전처리가 적합도에 중요한 역할을 한다는 것을 보여준다. lag 5, 10의 결과는 적합력 지표를 기준으로 평가했을 때 다른 시차 결과보다 우수함을 알 수 있다. [그림 4-1]은 LSTM모형을 활용하여 재귀적 방법으로 Test자료를 예측한 결과를 보여준다.


〈표 4-1〉 데이터 전처리 후, LSTM 2021~2024년 예측 출산율과 적합력  
〈TFR〉

구분 연도	실측치	Lag=5 예측치	Lag=6 예측치	Lag=7 예측치	Lag=10 예측치	Lag=12 예측치	Lag=15 예측치
2021	0.808	<b>0.819</b>	0.786	0.792	<b>0.836</b>	0.808	0.794
2022	0.778	<b>0.786</b>	0.740	0.750	<b>0.795</b>	0.759	0.747
2023	0.721	<b>0.761</b>	0.702	0.712	<b>0.761</b>	0.718	0.705
2024	0.748	<b>0.742</b>	0.673	0.680	<b>0.734</b>	0.685	0.667
적 합 력	RMSE	<b>0.021</b>	0.044	0.037	<b>0.026</b>	0.033	0.044
	MAE	<b>0.016</b>	0.038	0.030	<b>0.024</b>	0.021	0.035
	MAPE(%)	<b>2.190</b>	4.999	3.957	<b>3.253</b>	2.822	4.643

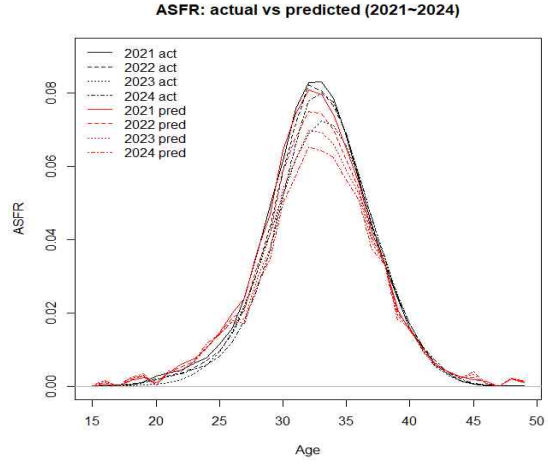
〈ASFR〉

구분 지표	Lag=5	Lag=6	Lag=7	Lag=10	Lag=12	Lag=15
RMSE	<b>0.004</b>	0.004	0.004	<b>0.004</b>	0.003	0.004
MAE	<b>0.003</b>	0.003	0.003	<b>0.003</b>	0.002	0.002
MAPE	<b>424.156</b>	715.148	189.329	<b>652.956</b>	659.957	558.759


[그림 4-1] (LSTM 적용) 연령별출산율 2021~2024년 예측  
 〈lag = 5〉 〈lag = 6〉



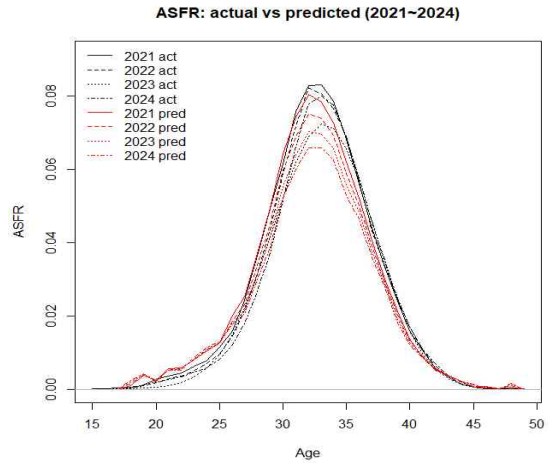
〈lag = 7〉





〈lag = 10〉



〈lag = 12〉



〈lag = 15〉



본 연구에서는 선정된 lag 값(5년, 10년)을 기준으로 LSTM 기반의 재귀형(one-step recursive) 예측 방식을 적용하여, 향후 10년(2025~2034년)의 연령별 출산율(ASFR)과 합계출산율(TFR)을 산정하였다. 이를 위해 lag=5 모형은 2020~2024년을 검증용(test) 자료, lag=10 모형은 2015~2024년을 검증용 자료로 설정하여 동일한 하이퍼파라미터 조건에서 비교·평가하였다.

우선 lag 5 모형의 2020~2024년 검증 결과, 합계출산율 예측오차는 RMSE 0.021, MAE 0.016, MAPE 2.190로 나타났으며, 연령별 출산율의 오차는 RMSE 0.004, MAE 0.003, MAPE 424.157로 분석되었다. 이러한 예측력을 기반으로 산출한 TFR은 2025년 0.728명에서 출발하여 2030년 0.715명, 2034년 0.734명 수준으로 나타나, 중기적으로 완만한 저점을 형성한 뒤 회복하는 경향을 보인다.

반면 lag 10 모형은 더 긴 학습구간(2015~2024년)을 반영함에 따라, 검증 결과는 TFR 기준 RMSE 0.048, MAE 0.042, MAPE 5.506이고, ASFR 기준 RMSE 0.005, MAE 0.003, MAPE 398.126로 나타났다. 예측된 TFR 경로는 2025년 0.624명에서 시작해 2030년 0.598명까지 하락한 후, 2034년 0.626명으로 소폭 반등하는 형태를 보였다.

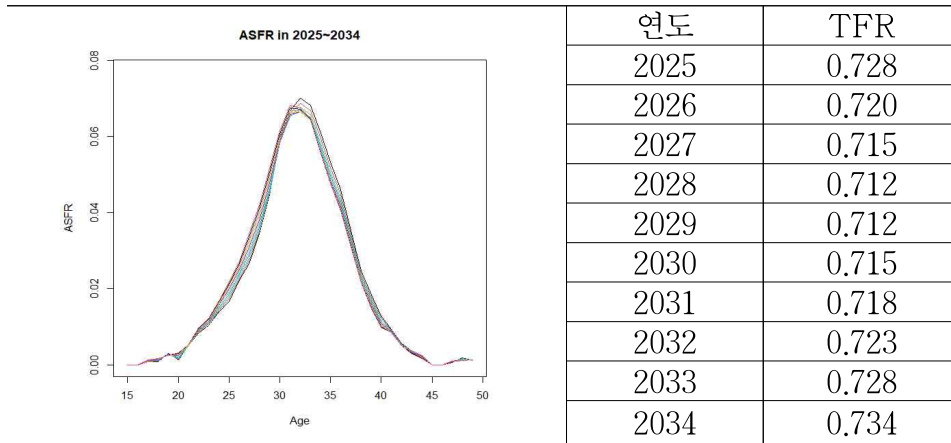
이와 같은 차이는 학습에 사용된 시계열의 패턴 자체가 서로 상이하기 때문이다. lag 5 모형은 직전 5개년(2020~2024년)의 자료를 기반으로 재귀 예측을 수행하므로, 해당 기간의 출산율 흐름으로, 특히 2024년에 관측된 반등(0.721 → 0.748명, 약 +0.027명)이 예측에 크게 반영된다. 즉, 2020~2023년까지 약 0.08명 감소한 뒤 2024년에 0.27명 반등한 단기 변동성이 모델에 직접적으로 학습된다.

반면 lag 10 모형은 2015~2024년 전체의 장기 추세를 학습하며, 이 기간은 1.237명(2015년)에서 0.721명(2023년)까지 약 0.516명에 달하는 큰 폭의 하락을 포함한다. 이후 2024년에 0.747명으로 소폭 반등하였으나, 전체적으로는 장기적 하락경로가 지배적이므로 예측에서도 점진적 감소→완만한 반등의 형태가 나타난다.


요약하면, lag 5 모형은 최근(2020~2024년)의 단기 반등 패턴을 강하게 반영하는 반면, lag 10 모형은 2015년 이후 지속된 중장기 하락 추세를 중심으로 학습하였기 때문에 두 모형의 예측 패턴이 상이하게 나타난다.

그러나 두 모형 모두 2028~2030년을 전후하여 TFR이 저점을 형성한 뒤 소폭 반등하는 경향이 공통적으로 관측된다. 이는 향후 합계출산율이 지속적인 하락을 이어가기 보다는 일정 시점에서 완만한 회복 국면에 진입할 가능성을 시사하는 중요한 결과로 해석할 수 있다.

[그림 4-2] LSTM 기반 연령별출산율, 합계출산율 10년간 예측 (lag 5)



[그림 4-3] LSTM 기반 연령별출산율, 합계출산율 10년간 예측 (lag 10)



본 결과는 과적합과 과소적합을 방지하기 위해 1981~2024년 연령별출산율 자료를 train 1981~2020년, test 2021~2024년으로 분할하고, 이들 자료에 log1p, 정규화를 적용한 다음 LSTM 인공지능 기법을 도입한 결과이다. 자료 손실은 방지하기 위해 연령별 차분을 적용하기 않았으며, 원자료의 패턴을 희생시키지 않는 최소한의 데이터 전처리만을 적용한 결과로 볼 수 있다.

다음 두 절은 Transformer와 TimeGPT를 LSTM과 동일한 데이터 전처리를 적용한 후 이들의 결과를 소개하고 비교한다.

### 4.1.3 Transformer 모델 기반 연령별출산율 예측

이번 절은 Transformer 기반의 연령별 출산율 예측 과정을 설명한다. 예측 절차는 앞 절에서 다룬 LSTM 기반 방법과 동일한 방식으로 진행되며, LSTM 모형처럼 Transformer 모형에서 적절한 하이퍼파라미터를 선정하기 위해 lag 5에서부터 15까지 적용하여 성능을 비교하였다. 그런 다음 LSTM과 동일한 재귀적(one-step recursive) 예측 방법을 사용하여 향후 10년(2025~2034년) 동안의 연령별 출산율(ASFR)과 합계 출산율(TFR)을 예측하였다.

〈표 4-2〉는 연령별출산율 정규화, log1p 변환을 적용한 이후의 자료에 대하여 Transformer 모형 결과를 보여준다. lag 7, 15의 결과는 적합력 지표를 기준으로 평가했을 때 다른 시차 결과보다 우수함을 알 수 있다. [그림 4-4]는 Transformer 모형을 활용하여 재귀적 방법으로 Test자료를 예측한 결과를 보여준다. lag 5부터 15까지의 예측 결과는 전반적인 출산율 수준 양상을 비슷하게 묘사하지만 정점이 빠른 연령대에서 나타나고, 25세 미만, 40세 이상 부분에서의 출산율 수준을 비합리적으로 예측하고 있다. 특히 출산율이 0이 부분, 변동이 크게 나타나는 부분은 LSTM 결과와는 다른 양상이다. 또한 합계출산율 수준은 LSTM 결과와 비교하면, lag에 따라 약간 높거나 낮은 수준을 보인다.

〈표 4-2〉 데이터 전처리 후, Transformer 2021~2024년 예측 출산율과 적합력


〈TFR〉

구분 연도	실측치	Lag=5 예측치	Lag=6 예측치	<b>Lag=7</b> <b>예측치</b>	Lag=10 예측치	Lag=12 예측치	<b>Lag=15</b> <b>예측치</b>
2021	0.808	0.840	0.725	<b>0.782</b>	0.775	0.705	<b>0.798</b>
2022	0.778	0.851	0.722	<b>0.768</b>	0.759	0.692	<b>0.782</b>
2023	0.721	0.867	0.726	<b>0.758</b>	0.746	0.681	<b>0.770</b>
2024	0.748	0.890	0.735	<b>0.754</b>	0.740	0.674	<b>0.761</b>
적 합 력	RMSE	0.109	0.050	<b>0.023</b>	0.023	0.079	<b>0.026</b>
	MAE	0.098	0.039	<b>0.019</b>	0.021	0.075	<b>0.019</b>
	MAPE(%)	13.160	4.987	<b>2.604</b>	2.779	9.799	<b>2.591</b>


〈ASFR〉

구분 지표	Lag=5	Lag=6	<b>Lag=7</b>	Lag=10	Lag=12	<b>Lag=15</b>
RMSE	0.012	0.010	<b>0.009</b>	0.011	0.011	<b>0.007</b>
MAE	0.008	0.007	<b>0.007</b>	0.008	0.008	<b>0.005</b>
MAPE	2532.579	294.471	<b>554.867</b>	1116.308	1937.228	<b>416.030</b>

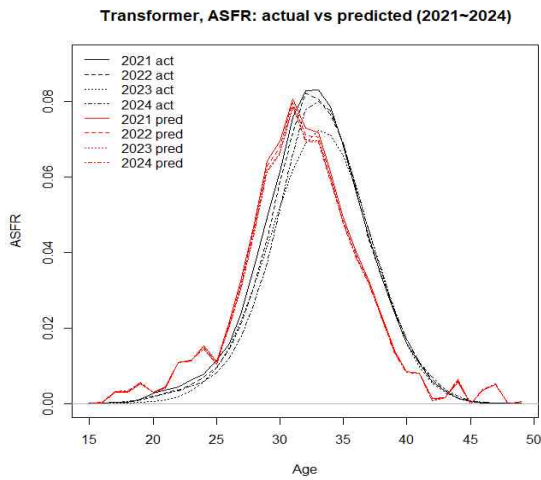
[그림 4-4] (Transformer 적용) 연령별출산율 2021~2024년 예측  
 <lag = 5> <lag = 6>




<lag = 7>





<lag = 10>



<lag = 12>

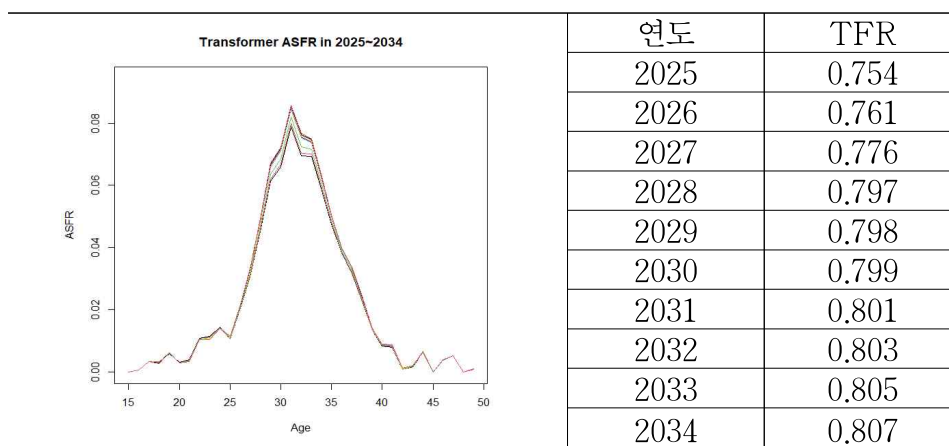


<lag = 15>




다음은 선정된 lag 값(7년, 15년)을 기준으로 Transformer 기반의 재귀형(one-step recursive) 예측 방식을 적용하여, 향후 10년(2025~2034년)의 연령별 출산율(ASFR)과 합계출산율(TFR)을 산정하였다. 이를 위해 lag=7 모형은 2018~2024년을 검증용(test) 자료, lag=15 모형은 2010~2024년을 검증용 자료로 설정하여 동일한 하이퍼파라미터 조건에서 비교·평가하였다.

[그림 4-5] Transformer 기반 연령별출산율, 합계출산율 10년간 예측 (lag 7)



[그림 4-6] Transformer 기반 연령별출산율, 합계출산율 10년간 예측 (lag 15)



우선 lag 7 모형의 2018~2024년 검증 결과, 합계출산율 예측오차는 RMSE 0.0231, MAE 0.019, MAPE 2.604로 나타났으며, 연령별 출산율의 오차는 RMSE 0.009, MAE 0.007, MAPE 554.867로 분석되었다. 이러한 예측력을 기반으로 산출한 TFR은 2025년 0.754명에서 출발하여 2030년 0.799명, 2034년 0.807명 수준으로 나타나, 중기적으로 완

만한 상승 기조를 보인다고 볼 수 있다.

반면 lag 15 모형은 더 긴 학습구간(2010~2024년)을 반영함에 따라, 검증 결과는 TFR 기준 RMSE 0.026, MAE 0.019, MAPE 2.591이고, ASFR 기준 RMSE 0.007, MAE 0.005, MAPE 416.030으로 나타났다. 예측된 TFR 경로는 2025년 0.669명에서 시작해 2030년 0.600명까지 하락한 후, 2034년 0.583으로 점진적 감소 형태를 보인다.

이와 같은 차이는 학습에 사용된 시계열의 패턴 자체가 서로 상이하기 때문이다. lag 7 모형은 직전 7개년(2018~2024년)의 자료를 기반으로 재귀 예측을 수행하므로, 해당 기간의 출산율 흐름으로, 특히 2024년에 관측된 반등(0.721 → 0.748명, 약 +0.027명)이 예측에 반영된다. 즉, 2020~2023년까지 약 0.08명 감소한 뒤 2024년에 0.27명 반등한 단기 변동성이 모델에 직접적으로 학습된다.

반면 lag 15 모형은 2010~2024년 전체의 장기 추세를 학습하며, 이 기간은 1.223명(2010년), 2012년 1.296명 정점을 찍고 2023년까지 0.721명까지 약 0.575명에 달하는 큰 폭의 하락을 학습자료를 포함한다. 그리고 2024년에는 0.747명으로 소폭 반등하였으나, 전체적으로는 장기적 하락경로가 지배적이므로 예측에서도 점진적 감소기조를 보인다.

요약하면, lag 7 모형은 최근(2018~2024년)의 단기 반등 패턴을 강하게 반영하는 반면, lag 15 모형은 2010년 이후 정점이후에 지속된 중장기 하락 추세를 중심으로 학습하였기 때문에 두 모형의 예측 패턴이 상이하게 나타난다.

Transformer 결과는 앞 절의 LSTM 와는 상이한 결과를 보인다.

먼저 LSTM 하이퍼파라미터는 5, 10인 반면, Transformer는 7, 15이다. 이런 선택으로 10년간의 예측에서 상이한 결과를 보인다. LSTM은 저점을 보이다가 상승을 나타내지만, Transformer는 7은 점진적인 상승, 15는 하락의 결과를 나타낸다. 이런 결과는 연령별출산율, 합계출산율 자료의 시계열 패턴에 영향을 받는다고 할 수 있다.

다음으로 연령별출산율 예측 양상이다. 전반적으로 피크, 저연령, 고연령 출산율 양상을 비슷하지만 변동성과 피크 수준 차이를 보인다. 32~33세에 출산율 정점을 나타내지만 저연령과 고연령의 출산율 수준은 조금 다르다.

#### 4.1.4 TimeGPT 모델 기반 연령별출산율 예측

이번 절은 TimeGPT 기반의 연령별 출산율 예측 과정을 설명한다. 예측 절차는 앞에서 다룬 LSTM, Transformer 기반 방법과 동일한 방식으로 진행되며, 앞의 두 모형처럼 TimeGPT 모형에서 적절한 하이퍼파라미터를 선정하기 위해 lag 5에서부터 15까지 적용하여 성능을 비교하였다. 그런 다음 위 2개 모형과 동일한 재귀적(one-step recursive) 예측 방법을 사용하여 향후 10년(2025~2034년) 동안의 연령별 출산율(ASFR)과 합계출산율(TFR)을 예측한다.

〈표 4-3〉는 연령별출산율 정규화, log1p 변환을 적용한 이후의 데이터전처리 자료에 대한 TimeGPT 모형 적용 결과를 보여준다. lag 7년 결과는 적합력 지표를 기준으로 평가했을 때 다른 시차 결과보다 우수함을 알 수 있다. [그림 4-7]은 TimeGPT 모형을 활용하여 재귀적 방법으로 Test자료를 예측한 결과를 보여준다. lag 5부터 15까지의 예측 결과는 lag 10을 제외하고는 전반적인 출산율 수준 양상을 비슷하게 묘사하지만 정점과 25세 미만, 40세 이상 부분에서의 출산율 수준을 비합리적으로 예측하고 있다. 특히 출산율이 0이 부분, 변동이 크게 나타나는 부분은 LSTM 결과보다는 Transformer 결과와 유사하다고 볼 수 있다. 그리고 합계출산율 수준은 LSTM, Transformer 결과보다 약간 높은 수준을 보인다.

〈표 4-3〉 데이터 전처리 후, TimeGPT 2021~2024년 예측 출산율과 적합력

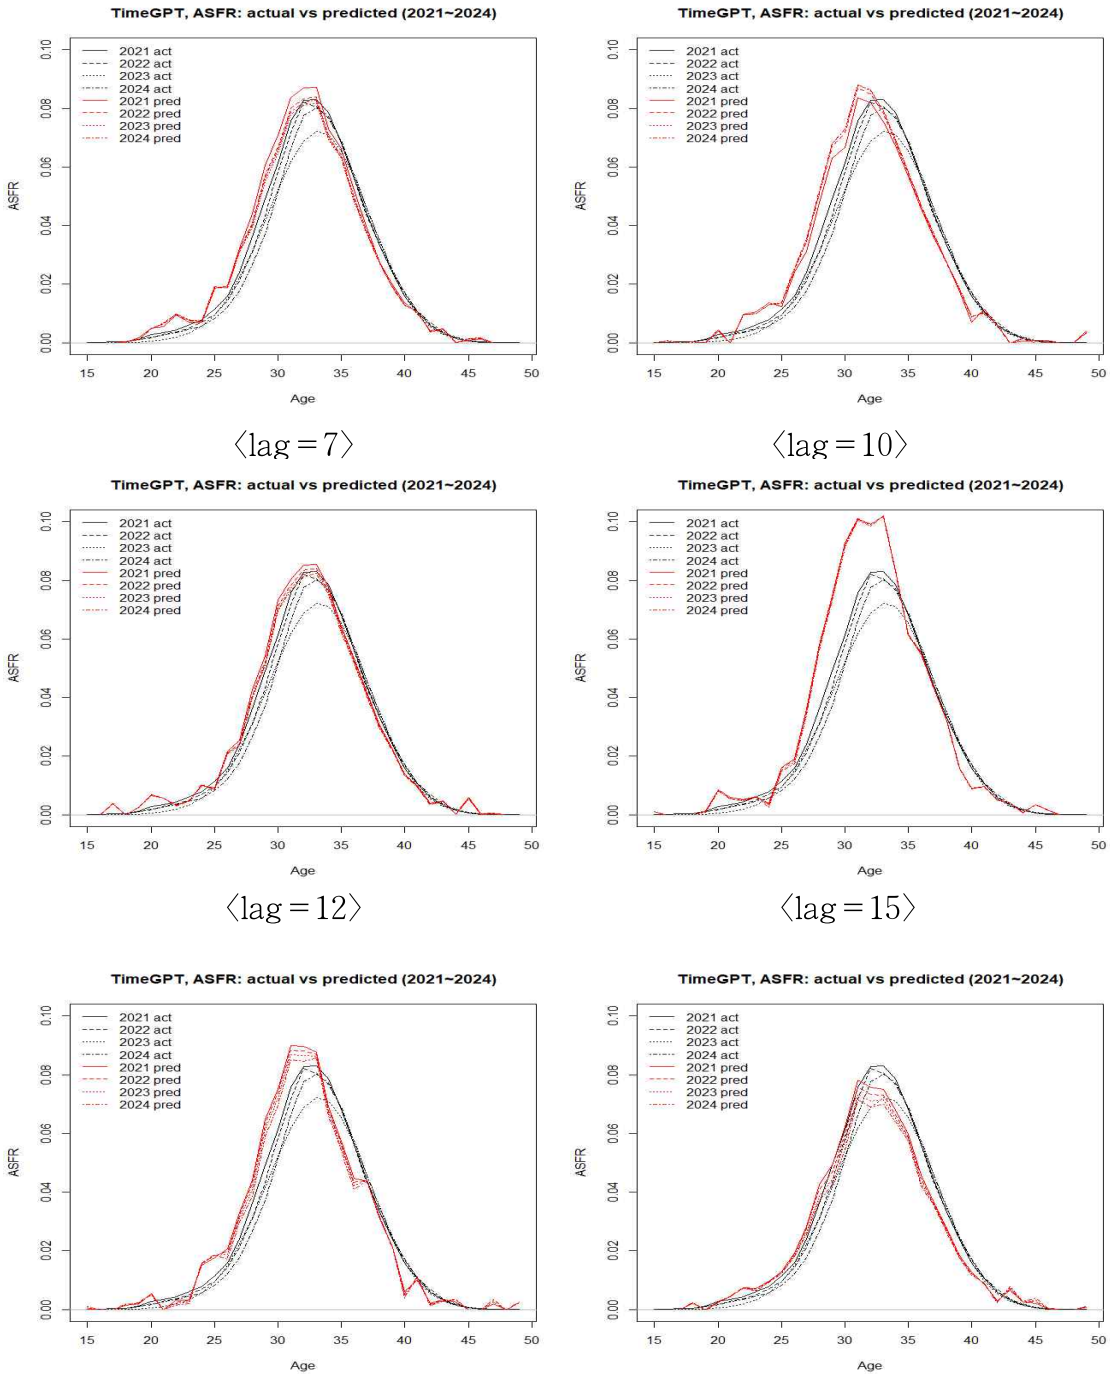
〈TFR〉

구분 연도	실측치	Lag=5 예측치	Lag=6 예측치	Lag=7 예측치	Lag=10 예측치	Lag=12 예측치	Lag=15 예측치
2021	0.808	0.804	0.786	0.841	0.953	0.848	<b>0.769</b>
2022	0.778	0.833	0.772	0.825	0.952	0.837	<b>0.949</b>
2023	0.721	0.843	0.767	0.816	0.946	0.822	<b>0.730</b>
2024	0.748	0.845	0.762	0.809	0.941	0.802	<b>0.714</b>
적 합 력	RMSE	0.083	0.026	0.064	0.187	0.067	<b>0.029</b>
	MAE	0.070	0.022	0.059	0.184	0.064	<b>0.027</b>
	MAPE(%)	9.434	2.908	7.956	24.410	8.479	<b>3.561</b>

〈ASFR〉

구분 지표	Lag=5	Lag=6	Lag=7	Lag=10	Lag=12	Lag=15
RMSE	0.008	0.005	<b>0.005</b>	0.013	0.008	<b>0.005</b>
MAE	0.005	0.003	<b>0.004</b>	0.007	0.005	<b>0.004</b>
MAPE	1090.126	893.949	<b>195.015</b>	236.148	931.198	<b>349.882</b>

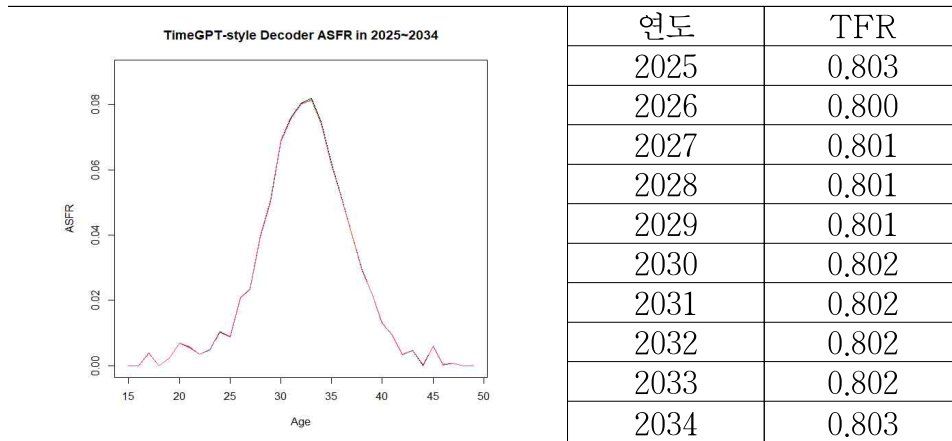
[그림 4-7] (TimeGPT 적용) 연령별출산율 2021~2024년 예측  
 〈lag = 5〉 〈lag = 6〉



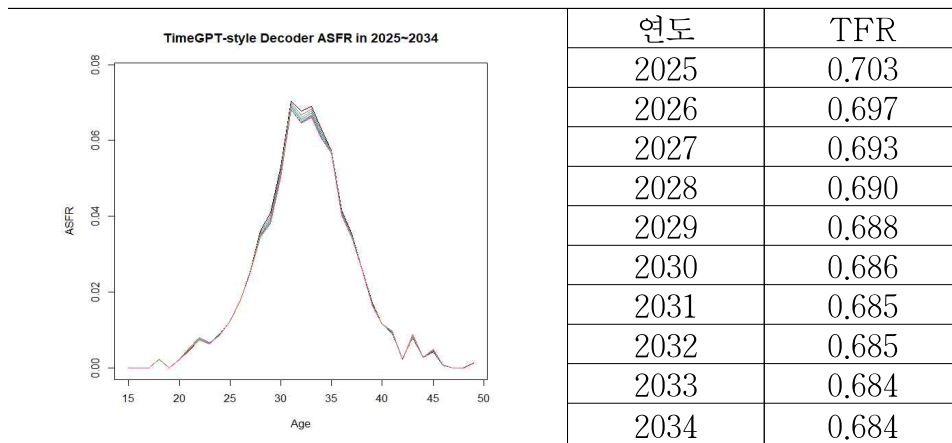
다음은 선정된 lag 6을 기준으로 Transformer 기반의 재귀형(one-step recursive) 예측 방식을 적용하여, 향후 10년(2025~2034년)의 연령별 출산율(ASFR)과 합계출산율(TFR)을 산정하였다. 이를 위해 lag=6 모형은 2018~2024년을 검증용(test) 자료,

lag=15 모형은 2010~2024년을 검증용 자료로 설정하여 동일한 하이퍼파라미터 조건에서 비교·평가하였다.

[그림 4-8] TimeGPT 기반 연령별출산율, 합계출산율 10년간 예측 (lag 6)



[그림 4-9] TimeGPT 기반 연령별출산율, 합계출산율 10년간 예측 (lag 15)



우선 lag 7 모형의 2018~2024년 검증 결과, 합계출산율 예측오차는 RMSE 0.064, MAE 0.059, MAPE 7.956로 나타났으며, 연령별 출산율의 오차는 RMSE 0.005, MAE 0.004, MAPE 195.015로 분석되었다. 이러한 예측력을 기반으로 산출한 TFR은 2025년 0.803명에서 출발하여 2030년 0.802명, 2034년 0.803명 수준으로 나타나, Transformer 결과보다 2025~2030년에는 약간 높은 수준이지만, 이후에는 낮은 수준으로 0.80명을 유지하는 예측을 보인다.

반면 lag 15 모형은 더 긴 학습구간(2010~2024년)을 반영함에 따라, 검증 결과는

TFR 기준 RMSE 0.029, MAE 0.027, MAPE 3.562이고, ASFR 기준 RMSE 0.005, MAE 0.004, MAPE 349.882으로 나타났다. 예측된 TFR 경로는 2025년 0.703명에서 시작해 2030년 0.686명까지 하락한 후, 2034년까지 0.686~0.684명 수준을 유지하는 형태를 보인다.

이와 같은 차이는 학습에 사용된 시계열의 패턴 자체가 서로 상이하기 때문이다. 이 결과는 앞의 Transformer 결과와 일치하는 대목이다. lag 7 모형은 직전 7개년(2018~2024년)의 자료를 기반으로 재귀 예측을 수행하는 반면 lag 15 모형은 2010~2024년 전체의 장기 추세를 학습한다. 이 기간에 따른 연령별출산율과 합계출산율의 경향을 상이하기 때문에 예측 결과에도 반영된다.

TimeGPT 결과는 앞 절의 LSTM, Transformer와는 상이한 결과를 보인다.

LSTM 하이퍼파라미터는 5, 10인 반면, Transformer와 TimeGPT는 7, 15이다. 이런 선택으로 10년간의 예측에서 상이한 결과를 보인다. LSTM은 저점을 보이다가 상승을 나타내지만, Transformer, TimeGPT에서는 lag 7은 점진적인 상승, lag 15는 하락의 결과를 나타낸다. 이런 결과는 연령별출산율, 합계출산율 자료의 시계열 패턴에 영향을 받는다고 할 수 있다.

#### 4.1.5 LSTM, Transformer, TimeGPT 모델 기반 연령별출산율 결과 비교

지금까지 연령별출산율 test 자료와 10년간의 예측을 3가지 서로 다른 방법으로 접근하였다. 결과를 살펴보면 TimeGPT, Transformer, LSTM 방법 순으로 출산율이 높게 전망한다. 이 결과는 각각의 구조적 접근 방법 차이에서 기반을 둔다.

먼저 LSTM은 기억 기반 순차 추정이다. 과거 몇 개 시점(lag)에 대해 은닉 상태가 누적되지만, 정보 전달이 순차적이기 때문에 멀리 떨어진 연도 간의 상호작용이 희미해 짐. 이 때문에 예측은 부드럽지만 다소 보수적이며, 추세가 완만하게 된다. 따라서 LSTM은 단기예측(1~4년) RMSE·MAE 성능이 좋지만, 장기예측에서는 다소 평활화된 결과 제공한다. 다음으로 Transformer는 자가집중(Self-Attention) 기반으로 모든 시점을 한꺼번에 연결한다. 즉, 1980년대와 2010년대의 패턴이 함께 직접 비교되며, 비선형적 장기 상관관계를 반영한다. 이로 인해 모델은 최근 하락 추세를 그대로 연장하기보다, 과거 변동 패턴을 종합적으로 재평가하여 예측값을 살짝 상향시키는 경향을 보인다. 특히 ASFR 곡선에서는 30대 초반~중반 피크가 약간 상승하

며, 전체적으로 TFR이 높게 산출한다. 끝으로 TimeGPT는 디코더 전용 (Self-Attention 기반) 구조로, 과거 모든 시점을 주목하면서 시간적 의존성을 보다 깊게 학습한다. 이들 방법 차이로부터 연령별출산율과 합계출산율은 다른 전망을 보인다.

〈표 4-4〉 LSTM, Transformer, TimeGPT 비교

구분	구조	연결방식	장점	결과 경향
LSTM	순차형 RNN	이전 시점만 연결	단기 예측 우수	부드럽고 보수적
Transformer	인코더 (Self-Attention)	모든 시점 상호 연결	장기 패턴 반영	중간정도 상승
TimeGPT	디코더 (Autoregressive)	과거 전체 → 다음 시점	장기 추세 반영	높은 ASFR/ TFR

정리하면, LSTM은 순차적 기억에 기반하고, Transformer가 전 구간을 병렬적으로 연결하는 반면, TimeGPT는 자기회귀(autoregressive) 방식으로 과거 시퀀스를 인코딩하면서 다음 시점을 직접 생성(decoding)하기 때문에, 최근 시계열의 변화뿐 아니라 장기적 변동 패턴까지 종합적으로 반영한다. 이로 인해 전반적으로 ASFR과 TFR이 TimeGPT, Transformer 기반 예측값은 LSTM보다 약간 높은 수준으로 나타나며, 특히 장기 예측(10년 이상) 구간에서 상승 편향이 두드러진다(참고 〈표 4-4〉).

즉, TimeGPT는 장기 예측에서 추세 전환 가능성을 과감하게 반영하는 경향이 있어, 정책적 시나리오 탐색이나 상한 전망(upper-bound forecast) 분석에 적합한 모델로 평가된다.

## 4.2. 사회, 경제 공변량에 따른 출산율 변동 예측

### 4.2.1 사회, 경제학 공변량 보정

본 절에서는 제2장에서 논의한 연령별출산율에 영향을 미칠 수 있는 사회·경제적 요인을 공변량으로 설정하고, 이를 인공지능 모형의 학습 자료로 구축하는 과정을 상세히 설명한다. 본 연구는 출산율 변화가 개인의 인구학적 특성뿐만 아니라 결혼, 노동시장, 정책 환경 등 다양한 구조적 요인의 영향을 받는다는 점에 착안하여, 이들 요인을 정량적으로 반영할 수 있는 공변량을 선정하였다.

본 연구에서 고려한 공변량은 수도권 거주비율, 유배우자 비율, 결혼태도(‘결혼을 해야 한다’ 또는 ‘하는 것이 좋다’고 응답한 비율), 경제활동참가율, 실업률, 고용률, 그리고 GDP 대비 가족정책 지출 비율이다. 이 중 결혼태도와 가족정책 지출 비율을 제외한 모든 변수는 전체, 남성, 여성으로 구분된 자료가 제공된다.

그러나 본 연구에서는 인공지능 학습자료로 전체 자료를 사용하지 않고, 남성 및 여성 자료만을 활용하였다. 이는 전체 지표가 남성과 여성 지표의 선형결합으로 표현될 수 있어, 전체 자료를 함께 사용할 경우 공변량 간 강한 선형관계로 인한 다중공선성 문제가 발생할 가능성이 높기 때문이다.

이에 따라 본 연구에서 최종적으로 사용한 사회·경제적 공변량은 성별 수도권 거주 비율, 성별 유배우자 비율, 성별 경제활동참가율, 성별 실업률, 성별 고용률과 함께, 성별 구분이 없는 결혼태도 및 가족정책 지출 비율이다.

이들 자료는 인구주택총조사, 경제활동인구조사, OECD 통계 등 공신력 있는 공식 통계자료를 통해 수집하였다. <표 4-5>는 R 프로그램에서 적용한 변수명, 변수 설명, 자료원, 그리고 각 변수의 시계열 범위를 보여준다.

다음으로 공변량 자료의 시계열 보정 과정을 설명한다. 수집된 공변량 자료는 5세 연령구간, 격년 단위, 혹은 서로 상이한 관측기간으로 구성되어 있어, 1981~2024년 연령별출산율 자료와 동일한 구조를 갖추고 있지 않다. 이에 본 연구에서는 다음과 같은 단계적 절차를 통해 공변량 데이터를 보정하였다.

첫째, 5년 단위 또는 격년 단위로 제공되는 자료의 결측 연도 값을 cubic spline 보간법을 적용하여 2000~2024년의 연속적인 연도별 자료로 변환하였다. 둘째, 2000년 이전

시점의 자료는 2000~2024년 기간의 관측치를 단순선형회귀모형에 적합시켜 기울기와 절편을 추정 한 후, 이를 이용하여 1981~1999년 값을 역추정하였다.

〈표 4-5〉 사회, 경제분야 공변량 자료원과 시계열

변수명 (표기)	변수 설명	자료원	시계열
p_cap_tot (capT)	수도권 거주 비율, 전체 인구	센서스전수	2000, 2005, 2010, 2015-2024(매년)
p_cap_m (capM)	수도권 거주 비율, 남성	센서스전수	2000, 2005, 2010, 2015-2024(매년)
p_cap_w (capF)	수도권 거주 비율, 여성	센서스전수	2000, 2005, 2010, 2015-2024(매년)
cm_tot (marrT)	유배우자 비율, 전체 인구	센서스 전수/표본	2000/2010: 전수, 2015/2020: 표본
cm_m (marrM)	유배우자 비율, 남성	센서스 전수/표본	2000/2010: 전수, 2015/2021: 표본
cm_w (marrF)	유배우자 비율, 여성	센서스 전수/표본	2000/2010: 전수, 2015/2022: 표본
mar_positive (marriage)	결혼을 해야 한다/하는 게 좋다고 응답한 비율	사회조사	1998, 2002, 2006, 2008-2024(격년)
p_active_tot (actT)	경제활동 참가율, 전체 인구	경제활동인구조사	2000-2024 (매년)
p_unemp_tot (unempT)	실업률, 전체인구	경제활동인구조사	2000-2024 (매년)
p_emp_tot (empT)	고용률, 전체인구	경제활동인구조사	2000-2024 (매년)
p_active_m (actM)	경제활동 참가율, 남성	경제활동인구조사	2000-2024 (매년)
p_unemp_m (unempM)	실업률, 남성	경제활동인구조사	2000-2024 (매년)
p_emp_m (empM)	고용률, 남성	경제활동인구조사	2000-2024 (매년)
p_active_w (actF)	경제활동 참가율, 여성	경제활동인구조사	2000-2024 (매년)
p_unemp_w (unempF)	실업률, 여성	경제활동인구조사	2000-2024 (매년)
p_emp_w (empF)	고용률, 여성	경제활동인구조사	2000-2024 (매년)
p_fam_spend (famexp)	GDP 대비 가족정책 지출 비율	OECD 통계	2000-2020 (매년)

이 과정에서 음수 값이 발생하거나 현실적으로 해석이 곤란한 값은 0으로 처리하였다. 특히 가족정책 지출 비율의 경우 2000년 이전에는 공식 통계가 존재하지 않으므로, 해당 기간의 값은 모두 0으로 설정하였다. 이러한 보정 과정의 예시는 [그림 4-10]에 수도권 거주비율을 중심으로 제시하였으며, 유배우자 비율, 결혼태도, 경제활동참가율, 실업률, 고용률, 가족정책 지출 비율 역시 동일한 방식으로 처리하였다. 이 두 단계를 거쳐 15~19세부터 45~49세까지 5세 연령구간별 1981~2024년 시계열 자료를 구축하였다.

셋째, 5세 연령구간으로 구성된 공변량 자료를 1세 단위 자료로 세분화하기 위해 KOSIS(2025)의 주민등록 인구자료를 활용하였다. 각 5세 연령구간 내에서 연령별 인구비율을 적용하여 공변량 값을 분해함으로써, 1세 단위의 연령별 공변량 시계열을 생성하였다. 이 결과는 [그림 4-11]에 제시하였다.

마지막으로, 앞서 구축한 공변량 자료와 연령별출산율 자료를 결합하여 LSTM, Transformer, TimeGPT 기반 예측 모형에 활용할 인공지능 학습자료를 완성하였다. 구체적으로 1981~2024년 연령별출산율과 함께, cubic spline 보간, 선형회귀 추정, 인구비율 보정을 거쳐 동일 기간으로 정합화된 수도권 거주비율, 유배우자 비율, 결혼태도, 경제활동참가율, 실업률, 고용률, 가족정책 지출 비율을 [그림 4-12]와 같이 구성하였다.

이 자료를 각 인공지능 모형에 입력하여 1981~2020년을 학습자료(train data)로, 2021~2024년을 검증자료(test data)로 분할하였으며, 재귀적 예측(recursive forecasting) 방식을 적용하여 향후 10년간의 연령별출산율을 예측하였다.

[그림 4-10] 수도권 거주비율 원본자료와 Cubic spline 보간 및 회귀분석

✓ 원본: 2000, 2005, 2010, 2015, 2016~2024

p_cap_tot	2000	2005	2010	2015	2016	2017	2018	2019	2020	2021	2022	2023	2024
15-19	44.1327	46.9385	47.9611	47.6389	47.7515	47.9208	48.0341	48.38	49.0099	49.2032	49.3108	49.5129	49.6656
20-24	46.5878	49.3087	50.5086	49.6962	49.4951	49.6359	49.664	49.8756	50.3961	50.6907	50.9277	51.003	51.2789
25-29	50.909	53.1944	54.2552	54.0455	54.1781	54.5297	54.8374	55.1524	55.4975	55.6467	55.7434	55.7509	55.776
30-34	50.536	53.1165	53.8492	54.0029	54.0723	54.4621	54.9537	55.42	56.0011	56.4619	56.7084	56.6912	56.6916
35-39	49.4401	51.1782	52.6336	52.7834	52.8117	52.9067	53.1489	53.4216	53.9907	54.4314	54.8621	55.2588	55.5532
40-44	48.1494	49.9896	50.761	51.8336	51.8213	51.7937	51.9257	52.2089	52.4363	52.6698	52.798	53.0075	53.2267
45-49	46.1587	48.5638	49.7398	50.5169	50.7842	51.1015	51.3916	51.4767	51.5653	51.6785	51.6745	51.802	52.0123

✓ 보간: 2001~2004, 2006~2009, 2011~2014, Cubic spline

p_cap_tot	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
15-19	44.133	44.762	45.374	45.952	46.479	46.939	47.316	47.608	47.813	47.931	47.961	47.909	47.810	47.704	47.634	47.639
20-24	46.588	47.186	47.770	48.328	48.845	49.309	49.706	50.031	50.277	50.438	50.509	50.486	50.380	50.205	49.972	49.696
25-29	50.909	51.407	51.896	52.363	52.799	53.194	53.538	53.823	54.043	54.189	54.255	54.242	54.178	54.099	54.043	54.045
30-34	50.536	51.140	51.723	52.261	52.733	53.117	53.397	53.589	53.714	53.794	53.849	53.898	53.941	53.975	53.997	54.003
35-39	49.440	49.784	50.128	50.475	50.825	51.178	51.534	51.875	52.185	52.444	52.634	52.742	52.787	52.793	52.784	52.783
40-44	48.149	48.584	49.001	49.386	49.721	49.990	50.184	50.327	50.580	50.584	50.761	51.000	51.269	51.527	51.729	51.834
45-49	46.159	46.694	47.216	47.711	48.165	48.564	48.898	49.174	49.400	49.586	49.740	49.873	50.001	50.140	50.306	50.517

✓ 1981~1999년 보간: 2000~2024년 자료를 활용하여 선형회귀분석으로 Backprogration

p_cap_tot	1981	1982	1983	1984	1985	1986	1987	1988	1989	1990	1991	1992	1993	1994	1995	1996	1997	1998	1999	2000	2001	2013	2014	slope	inter
15	4.4334	8.4572	8.4810	8.5948	8.5286	8.5324	8.5763	8.6001	8.6239	8.6477	8.6715	8.6954	8.7192	8.7430	8.7668	8.7906	8.8144	8.8381	8.8619	7.9208	7.9133	10.2372	9.8678	0.0238	-7.7088
16	1.2442	8.2796	8.3130	8.3474	8.3818	8.4162	8.4507	8.4851	8.5195	8.5539	8.5883	8.6227	8.6571	8.6915	8.7259	8.7603	8.7947	8.8291	8.8636	8.1500	8.1266	10.0289	10.3790	0.0148	-9.5207
17	8.4149	8.4491	8.4833	8.5176	8.5518	8.5861	8.6203	8.6546	8.6888	8.7231	8.7573	8.7916	8.8258	8.8601	8.8943	8.9285	8.9628	8.9970	9.0313	9.0758	9.1789	9.3871	10.1596	0.0142	-9.4256
18	6.2296	6.637	6.9504	6.7809	6.7851	6.7992	6.8333	6.8674	6.9015	6.9357	6.9698	6.9999	7.0291	7.0583	7.0875	7.1167	7.1459	7.1751	7.2043	9.6120	9.7144	9.6118	9.5074	0.0141	-8.9659
19	5.8966	6.804	6.742	6.7811	6.7619	6.8057	6.8495	6.8933	6.9371	6.9809	6.9947	6.9685	6.9423	6.9161	6.8899	6.8637	6.8375	6.8113	6.7851	9.7021	10.2886	10.2279	9.7558	0.0148	-8.1919
20	8.8337	9.3753	9.6669	9.5555	9.5501	9.5447	9.5393	9.5339	9.5285	9.5231	9.5177	9.5123	9.5069	9.5015	9.4961	9.4907	9.4853	9.4799	9.4745	9.5165	9.9697	8.7553	9.0801	-0.0094	26.5107
21	5.5405	5.5485	5.5564	5.5644	5.5724	5.5804	5.5884	5.5964	5.6044	5.6124	5.6203	5.6283	5.6363	5.6443	5.6523	5.6603	5.6683	5.6763	5.6843	9.2287	9.8896	9.3361	9.2704	0.0090	-6.2827
22	9.6557	9.7943	9.1228	9.1513	9.1798	9.2084	9.2369	9.2654	9.2940	9.3225	9.3510	9.3795	9.4081	9.4366	9.4651	9.4937	9.5222	9.5507	9.5793	8.5564	8.136	9.8850	9.8850	0.0285	-9.4503
23	8.7330	8.7774	8.8219	8.8664	8.9109	8.9553	8.9998	9.0443	9.0887	9.1332	9.1777	9.2222	9.2666	9.3111	9.3556	9.4000	9.4445	9.4890	9.5335	9.2052	9.0804	11.2388	11.8847	0.0445	-9.3642
24	8.7036	8.7530	8.8024	8.8518	8.9011	8.9505	8.9999	9.0493	9.0987	9.1480	9.1974	9.2468	9.2962	9.3456	9.3950	9.4444	9.4938	9.5432	9.5926	9.2809	9.1805	11.1497	11.8047	0.0494	-8.1203
25	8.8367	8.8915	8.9464	9.0012	9.0560	9.1108	9.1657	9.2205	9.2754	9.3302	9.3850	9.4399	9.4947	9.5495	9.6044	9.6592	9.7141	9.7689	9.8237	9.4223	9.4223	10.4226	10.4226	0.0548	-9.7824
26	9.1692	9.2175	9.2657	9.3140	9.3623	9.4106	9.4588	9.5071	9.5554	9.6037	9.6519	9.7002	9.7485	9.7968	9.8450	9.8933	9.9416	9.9899	10.0381	10.0275	9.9289	10.8459	10.8459	0.0483	-8.4622
27	8.6262	8.6640	8.7017	8.7394	8.7771	8.8148	8.8525	8.8902	8.9280	8.9657	8.9999	9.0341	9.0683	9.1025	9.1367	9.1709	9.2051	9.2393	9.2735	10.2419	10.3011	11.2641	11.2216	0.0177	-6.0865
28	10.2820	10.3488	10.2716	10.2944	10.3172	10.3400	10.3628	10.3856	10.4084	10.4312	10.4540	10.4768	10.4996	10.5224	10.5453	10.5681	10.5909	10.6137	10.6365	10.5362	10.6794	11.5245	11.5245	0.0228	-34.9550
29	10.8920	10.8982	10.9041	10.9099	10.9158	10.9217	10.9276	10.9335	10.9394	10.9453	10.9512	10.9571	10.9629	10.9688	10.9747	10.9806	10.9865	10.9924	10.9983	10.6811	10.7655	11.7613	11.7613	0.0059	-4.7726
30	8.7608	8.8210	8.8812	8.9414	9.0015	9.0616	9.1218	9.1820	9.2421	9.3023	9.3624	9.4226	9.4828	9.5429	9.6031	9.6632	9.7234	9.7836	9.8437	10.5263	10.5263	12.0806	11.6929	0.0602	-110.4162
31	8.3143	8.3597	8.4051	8.4505	8.4960	8.5414	8.5868	8.6322	8.6777	8.7231	8.7685	8.8139	8.8594	8.9048	8.9502	8.9956	9.0410	9.0864	9.1318	10.5842	10.4354	12.0162	11.7901	0.0454	-80.6731
32	8.7177	8.7530	8.7882	8.8235	8.8587	8.8940	8.9292	8.9644	8.9997	9.0349	9.0702	9.1054	9.1407	9.1759	9.2111	9.2464	9.2816	9.3169	9.3521	10.2388	10.4890	11.1051	11.7258	0.0152	-60.0910
33	8.8424	8.9761	9.0988	9.5435	9.9772	10.0109	10.0445	10.0782	10.1119	10.1456	10.1793	10.2130	10.2467	10.2804	10.3141	10.3478	10.3815	10.4152	10.4489	9.6175	10.1459	10.7072	11.0332	0.0337	-56.9048
34	9.7092	9.7508	9.7924	9.8341	9.8757	9.9173	9.9590	10.0006	10.0422	10.0839	10.1255	10.1671	10.2088	10.2504	10.2920	10.3337	10.3753	10.4169	10.4586	9.5693	9.5336	10.5821	10.4496	0.0016	-72.7647
35	10.1208	10.1249	10.1289	10.1330	10.1370	10.1411	10.1452	10.1492	10.1533	10.1573	10.1614	10.1655	10.1695	10.1736	10.1776	10.1817	10.1858	10.1898	10.1939	9.6215	9.7913	10.5972	11.0236	0.0041	-2.0776
36	9.6187	9.6422	9.6657	9.6892	9.7127	9.7362	9.7596	9.7831	9.8066	9.8301	9.8536	9.8771	9.9006	9.9241	9.9476	9.9710	9.9945	10.0180	10.0415	9.3021	9.9094	10.6074	10.9040	0.0235	-36.9007
37	9.0981	9.1425	9.1868	9.2311	9.2755	9.3198	9.3641	9.4085	9.4528	9.4971	9.5414	9.5858	9.6301	9.6744	9.7188	9.7631	9.8074	9.8517	9.8961	9.5927	9.5790	10.8965	10.9147	0.0443	-8.7175
38	8.7125	8.7745	8.8366	8.8986	8.9607	9.0227	9.0848	9.1469	9.2089	9.2710	9.3330	9.3951	9.4572	9.5193	9.5813	9.6433	9.7054	9.7675	9.8295	10.3267	9.8761	11.1786	11.2122	0.0621	-114.2277
39	9.3726	8.4512	8.5298	8.6084	8.6870	8.7656	8.8442	8.9228	9.0014	9.0800	9.1585	9.2371	9.3157	9.3943	9.4729	9.5515	9.6301	9.7087	9.7873	10.5971	10.6279	11.9791	11.4988	0.0786	-147.1179
40	10.0134	10.0385	10.0636	10.0887	10.1138	10.1389	10.1640	10.1891	10.2142	10.2393	10.2644	10.2895	10.3146	10.3397	10.3648	10.3899	10.4150	10.4401	10.4652	10.8376	10.7554	10.2625	9.4194	0.0051	-41.3059
41	9.4756	9.5005	9.5255	9.5504	9.5753	9.6002	9.6251	9.6500	9.6749	9.6998	9.7247	9.7496	9.7745	9.7994	9.8243	9.8492	9.8741	9.8990	9.9239	9.9845	10.4109	10.8551	10.4792	0.0249	-39.8604
42	9.0511	9.0659	9.1053	9.1447	9.1840	9.2234	9.2628	9.3022	9.3416	9.3810	9.4204	9.4598	9.4992	9.5386	9.5780	9.6173	9.6567	9.6961	9.7355	9.5218	9.5911	10.9427	11.0820	0.0394	-69.0063
43	8.5902	8.6424	8.6946	8.7468	8.7990	8.8512	8.9034	8.9556	9.0078	9.0600	9.1122	9.1644	9.2166	9.2688	9.3210	9.3732	9.4255	9.4777	9.5299	9.0465	9.1415	10.8521	11.1700	0.0522	-64.8230
44	8.1145	8.1805	8.2464																						

[그림 4-11] 수도권 거주비율 5세 간격 연령 보간

✓ 15~49세(15~19세, 20~24세, ..., 40~44세, 45~49세) 5세간격을 1세로: 인구비율 적용

p_cap_tot	2000	2001	2002	2003	2004	2005	2006	2007	2008	2009	2010	2011	2012	2013	2014	2015
15	7.5928	7.7522	7.7511	8.1237	8.3055	8.2022	8.6390	8.7489	8.6684	9.1881	9.2492	9.1240	9.4987	9.5574	9.3764	9.6437
16	8.1500	8.2819	8.3621	8.3426	8.4687	8.4889	8.8787	9.0015	8.8984	9.1912	9.2207	9.1613	9.3812	9.3765	9.3290	9.5190
17	9.0758	9.1882	9.3492	8.9508	9.0428	9.1544	9.1147	9.1752	9.2058	9.4455	9.4864	9.4032	9.3829	9.3453	9.3668	9.4010
18	9.6120	9.7264	9.9067	9.9727	10.0395	10.2383	9.7836	9.8029	9.9308	9.6971	9.6729	9.7255	9.6429	9.6187	9.6104	9.4055
19	9.7021	9.8129	10.0046	10.5621	10.6225	10.8547	10.8998	10.8790	11.1095	10.4091	10.3319	10.4954	9.9045	9.8065	9.9511	9.6698
20	9.9165	10.0247	10.1883	10.2110	10.3523	10.3842	10.2542	10.3414	10.3505	9.7472	9.7788	9.7377	8.8920	8.9008	8.7781	8.5459
21	9.2287	9.3885	9.4191	10.1290	10.2070	10.3669	10.3488	10.4333	10.4496	10.3187	10.3490	10.3118	9.9049	9.8825	9.8120	9.1732
22	8.5564	9.0937	9.1601	9.4352	9.5669	9.5940	10.2715	10.2942	10.4366	10.4181	10.4440	10.4162	10.4921	10.4612	10.4011	10.2229
23	9.2052	9.2557	9.4683	9.1478	9.2567	9.3219	9.5609	9.6381	9.6550	10.3360	10.2984	10.4008	10.5878	10.5557	10.4971	10.8265
24	9.2809	9.3831	9.5344	9.4048	9.4622	9.6416	9.2708	9.3239	9.3852	9.6179	9.6384	9.6196	10.5036	10.4047	10.4841	10.9277
25	9.4223	9.4980	9.6225	9.4515	9.5296	9.6022	9.9408	9.9976	10.0303	10.1530	10.2169	10.1093	10.7563	10.8012	10.6665	11.5138
26	10.0275	10.0798	10.2703	10.0514	10.1225	10.2242	10.0225	10.0905	10.1016	10.4395	10.4447	10.4576	10.4304	10.4438	10.3749	10.7177
27	10.2419	10.3170	10.4671	10.6964	10.7453	10.9086	10.6564	10.7182	10.7516	10.5190	10.5347	10.5263	10.7177	10.6695	10.7251	10.3878
28	10.5362	10.6974	10.6790	10.9257	10.9981	11.1187	11.3371	11.3735	11.4689	11.1820	11.1874	11.2015	10.7972	10.7584	10.7945	10.6739
29	10.6811	10.8153	10.8567	11.2382	11.4039	11.3407	11.5814	11.6435	11.6901	11.8954	11.8716	11.9470	11.4761	11.4264	11.4821	10.7522
30	10.5283	10.6518	10.7739	10.7672	10.9383	10.8663	10.6767	10.8146	10.6367	10.4669	10.4627	10.5027	10.3995	10.3604	10.4578	10.0126
31	10.5842	10.6532	10.8933	10.6641	10.7782	10.8201	10.8193	10.9256	10.8135	10.7660	10.8483	10.7126	10.6193	10.6039	10.6534	10.6446
32	10.2388	10.2198	10.6284	10.7188	10.7760	10.7131	10.7629	10.7651	10.9070	10.9564	10.8882	10.9164	10.9658	10.8625	10.8649	
33	9.6175	9.7896	9.7830	10.3682	10.3354	10.6702	10.7695	10.7617	10.8819	10.7998	10.7930	10.8394	11.0588	11.0977	11.0369	11.1690
34	9.5693	9.8260	9.6438	9.7424	9.9048	9.8242	10.4187	10.3248	10.6172	10.8541	10.7888	10.9550	10.9470	10.9272	10.9861	11.3119
35	9.6215	9.6478	9.7985	9.9272	10.0439	10.0143	10.3540	10.3818	10.5285	11.0806	10.9260	11.3477	11.2455	11.1804	11.3135	11.0005
36	9.3021	9.4190	9.3761	10.0470	10.0340	10.2754	10.2995	10.4172	10.3770	10.4077	10.4690	10.4420	10.8793	10.7287	11.0359	11.0578
37	9.5927	9.7553	9.6244	9.7120	9.7950	9.8305	10.4233	10.4081	10.6451	10.3550	10.5072	10.2935	10.2186	10.2793	10.1560	10.6949
38	10.3267	10.4038	10.4648	10.0133	10.1419	10.0894	10.0741	10.1577	10.1835	10.4772	10.4944	10.5584	10.1629	10.3111	10.0096	10.0434
39	10.5971	10.5579	10.8646	10.7754	10.8098	10.9687	10.3828	10.5107	10.4510	10.1236	10.2370	10.1006	10.2811	10.2935	10.2686	9.9869
40	10.8176	10.8716	11.0964	10.9330	10.9509	11.1255	10.4419	10.5325	10.4338	9.6669	9.6046	9.6046	9.5346	9.6602	9.5387	10.1038
41	9.9845	10.0883	10.1467	10.5828	10.5942	10.7756	10.7157	10.6871	10.8341	10.4044	10.4838	10.4449	9.8261	9.9931	9.7910	9.7607
42	9.5218	9.6783	9.6160	9.7494	9.8280	9.8557	10.3721	10.3376	10.4938	10.6734	10.6318	10.8437	10.5726	10.6451	10.6471	10.0567
43	9.0465	9.1701	9.1623	9.2925	9.4218	9.3366	9.5509	9.5830	9.5963	10.3300	10.2810	10.5040	10.8435	10.7930	11.0507	10.8175
44	8.7589	8.7753	8.9798	8.8281	8.9259	8.8963	9.1032	9.1864	9.0916	9.5093	9.5281	9.6025	10.4926	10.4355	10.7019	11.0949
45	11.1323	11.2632	11.3856	11.1538	11.2531	11.3601	11.0176	11.1772	11.0299	11.0600	11.1866	11.0286	10.9627	11.0143	11.0077	11.3852
46	9.5790	9.7304	9.7566	10.5301	10.6344	10.7141	10.6654	10.6893	10.8124	10.5041	10.5920	10.5078	10.4482	10.5554	10.4310	10.4826
47	9.3872	9.4701	9.6294	9.0612	9.1867	9.1824	10.0701	10.1033	10.1978	10.1684	10.1307	10.2991	9.9213	9.9920	9.9371	9.9886
48	8.5579	8.6457	8.7660	8.8764	8.9352	9.0616	8.6599	8.7203	8.7367	9.5984	9.5703	9.7140	9.6035	9.5535	9.7415	9.4831
49	7.5022	7.5849	7.6787	8.0894	8.1551	8.2456	8.4855	8.4841	8.6234	8.2548	8.2602	8.3236	9.0653	9.0245	9.1890	9.1775

[그림 4-12] 연령별출산율과 공변량의 인공지능 학습용 자료

연령 연도	연령			수도권 거주 비율 15~49	유배우율 15~49	결혼 대도 15~49	경제활동 참가율 15~49	실업률 15~49	고용률 15~49	가족정책 지출 비율 15~49
	15	...	49							
1981	$f_{15,1981}$		$f_{49,1981}$							
1982	$f_{15,1982}$		$f_{49,1982}$							
...										
2000	$f_{15,2000}$		$f_{49,2000}$							
2001	$f_{15,2001}$		$f_{49,2001}$							
...										
2023	$f_{15,2023}$		$f_{49,2023}$							
2024	$f_{15,2024}$		$f_{49,2024}$							

선형회귀분석, Backprogration 추정자료

원자료+보간자료

(예시: 유배우율과 실업률 자료 형태)

연령 연도	15	...	49	유배우율 15	유배우율 16	...	유배우율 48	유배우율 49	실업률 15	실업률 16	...	실업률 48	실업률 49
1981	$f_{15,1981}$		$f_{49,1981}$	0.155	0.156	...	18.417	15.426	3.703	3.695	...	0.524	0.434
1982	$f_{15,1982}$		$f_{49,1982}$	0.151	0.153	...	18.339	15.434	3.647	3.640	...	0.521	0.434
...	...		...	...	...	...	...	...	...	...	...	...	...
2000	$f_{15,2000}$		$f_{49,2000}$	0.090	0.096	...	16.511	14.475	2.494	2.677	...	2.035	1.784
2001	$f_{15,2001}$		$f_{49,2001}$	0.079	0.085	...	16.392	14.380	2.494	2.664	...	1.986	1.743
...						...					...		
2023	$f_{15,2023}$		$f_{49,2023}$	0.000	0.000		13.874	13.139	1.202	1.123		1.451	1.374
2024	$f_{15,2024}$		$f_{49,2024}$	0.000	0.000	...	14.736	13.558	1.538	1.528	...	1.916	1.763

#### 4.2.2 공변량 반영과 LSTM 모델 기반 연령별출산율 예측

본 절에서는 앞 절에서 구축한 보정 자료를 LSTM 모형에 적용하여 연령별출산율 예측 결과를 제시한다. 분석에는 1981~2024년의 연령별출산율 자료와 7개 부문 공변량을 활용하였으며, 이를 1981~2020년은 학습자료(train data), 2021~2024년은 검증자료(test data)로 분할하였다. 또한 모형 학습의 안정성과 예측 성능 향상을 위해 모든 변수에 log1p 변환을 적용한 후 정규화를 수행하여 LSTM 모형에 입력하였다.

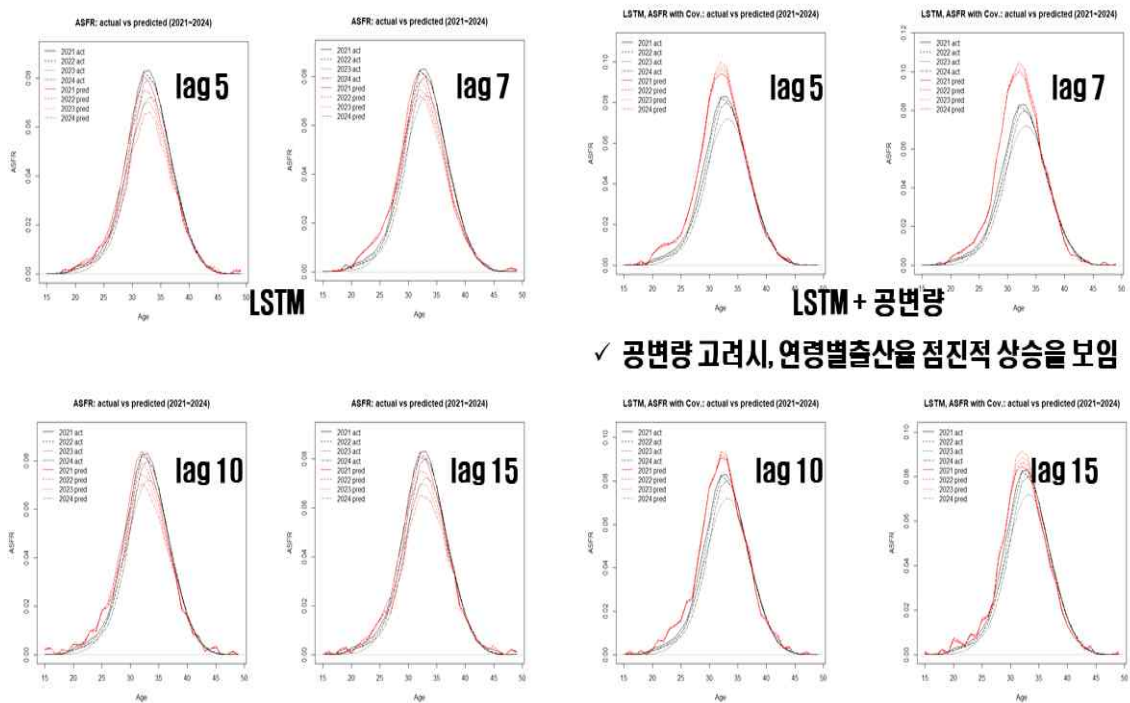
LSTM 모형의 하이퍼파라미터 가운데 핵심적인 시차(lag)는 5부터 15까지 단계적으로 적용하여 성능을 비교하였다. 그 결과, 시차 5와 10에서 예측 안정성과 현실 적합성이 가장 우수한 것으로 나타나, 이후 분석에서는 이 두 값을 중심으로 결과를 제시한다.

[그림 4-13]은 공변량 반영 여부에 따른 LSTM 기반 2021~2024년 연령별출산율 예측 결과를 비교하여 보여준다. 수도권 거주비율부터 GDP 대비 가족정책 지출 비율까지 7개 공변량을 모두 고려한 경우가 공변량을 반영하지 않은 경우보다 전반적으로 연령별출산율이 상승하는 경향을 보였다. 특히 상대적으로 높은 출산율 수준을 나타내는 28~35세 연령대에서 상승 효과가 다른 연령대에 비해 더 크게 나타나, 공변량이 핵심가임연령층의 출산행태에 중요한 영향을 미치고 있음을 시사한다.

이러한 결과는 기존 연령별출산을 추정 및 예측 방식에 대해 몇 가지 중요한 시사점을 제공한다. 첫째, 전통적인 출산율 예측은 주로 인구동태 통계에 기반을 둔 연령별 패턴을 통계모형에 적용하고, 과거 추세가 지속된다는 가정 하에 미래 값을 추정하는 방식에 의존해 왔다. 그러나 본 연구 결과는 사회·경제적 공변량을 함께 고려할 경우, 연령별출산율 예측 결과가 유의미하게 달라질 수 있음을 보여준다. 특히 가임연령 중 출산율 수준이 높은 연령대일수록 공변량의 영향력이 상대적으로 크게 작용하는 것으로 나타났다.

둘째, LSTM 모형의 예측 결과는 시차 설정에 따라 상이한 양상을 보였다. 시차를 10 미만으로 설정한 경우에는 단기적인 변동성을 비교적 잘 반영하며, 최근 출산율 반등 가능성을 포착하는 반면, 시차를 10 이상으로 확대할 경우에는 전반적으로 하락 추세를 유지하는 상반된 예측 결과를 보였다. 이는 2012년 이후 장기간 지속된 출산율 감소 국면이 모형 학습 과정에서 강하게 반영된 결과로 해석할 수 있다.

[그림 4-13] 공변량 반영 여부에 따른 LSTM 기반 Test 자료 예측




✓ 공변량 고려시, 연령별출산율 점진적 상승을 보임

주: lag5: TFR[RMSE(0.168), MAE(0.162), MAPE(21.549)], ASFR[RMSE(0.008), MAE(0.005), MAPE(357.045)]  
 lag7: TFR[RMSE(0.109), MAE(0.102), MAPE(13.634)], ASFR[RMSE(0.005), MAE(0.003), MAPE(13.634)]  
 lag10: TFR[RMSE(0.154), MAE(0.148), MAPE(19.760)], ASFR[RMSE(0.007), MAE(0.005), MAPE(1081.256)]  
 lag15: TFR[RMSE(0.076), MAE(0.067), MAPE(8.941)], ASFR[RMSE(0.005), MAE(0.003), MAPE(220.810)]

다음으로, 재귀적 예측(recursive forecasting) 방식을 적용하여 도출한 2025~2034년의 단기 출산율 예측 결과를 살펴본다. 공변량을 고려하지 않은 경우, 시차 5에서는 2025년 0.728명에서 2034년 0.734명 수준을, 시차 10에서는 2025년 0.641명에서 2034년 0.626명 수준을 예측하였다. 반면, 7개 부문 공변량을 반영한 경우에는 시차 5에서 2025년 0.948명에서 2034년 0.949명으로, 시차 10에서는 2025년 0.926명에서 2034년 0.930명으로 점진적인 상승 경로를 나타냈다. 이에 따라 공변량을 반영할 경우, 시차 5에서는 약 0.21~0.22명, 시차 10에서는 약 0.29~0.30명의 출산율 상승효과가 나타나는 것으로 분석되었다(참고 [그림 4-11]).

한편, LSTM 모형은 단기 예측에 강점을 가지며 최근 정보를 상대적으로 강하게 기억하는 특성을 지닌다. 이러한 특성으로 인해, 이후에 제시할 Transformer 및 TimeGPT 기반 예측 결과에 비해 전반적으로 높은 출산율 수준을 예측하는 경향을 보였다. 특히 출산율에 유의미한 영향을 미치는 공변량과 함께 일정 수준의 노이즈를 포함한 공변량을 동시에 고려할 경우, LSTM은 다른 모형에 비해 예측 값의 변동 폭이 크게 나타나는 특성을 보였다. 이는 LSTM 모형이 공변량 변화에 민감하게 반응함을 의미하며, 공변량을 포함한 예측을 수행할 때 변수 선택과 전처리 과정에 각별한 주의가 필요함을 시사한다.

[그림 4-14] 공변량 반영 여부에 따른 LSTM 기반 연령별출산율 10년 예측



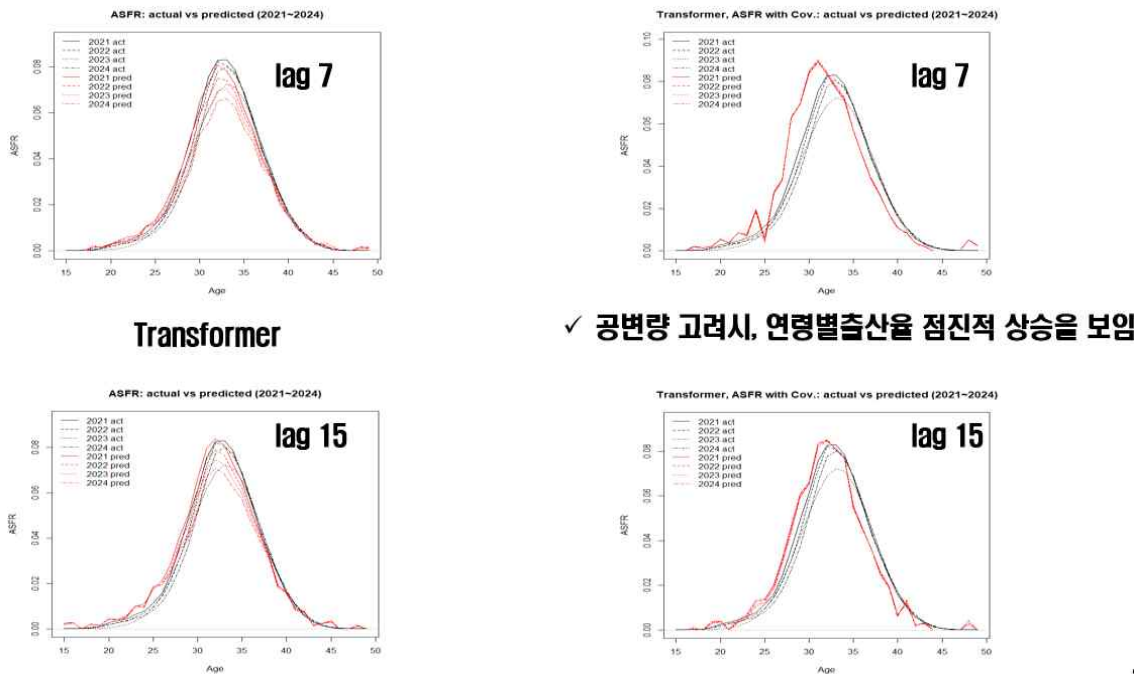
#### 4.2.3 공변량 반영과 Transformer 모델 기반 연령별출산율 예측

본 절에서는 앞 절에서 구축한 보정 자료를 Transformer 모형에 적용하여 연령별출산율 예측 결과를 제시한다. LSTM 기반 분석 결과와의 직접적인 비교를 위해, 데이터 분할 방식과 전처리 절차는 동일하게 적용하였다. 즉, 1981~2020년을 학습자료(train

data), 2021~2024년을 검증자료(test data)로 설정하고, 모든 변수에 대해 log1p 변환과 정규화를 수행한 후 Transformer 모형에 입력하였다. Transformer 모형의 하이퍼파라미터 중 시차(lag)는 5에서 15까지 단계적으로 적용하여 성능을 비교하였으며, 그 결과 시차 7과 15에서 예측의 안정성과 현실 적합성이 가장 우수한 것으로 확인되었다.

[그림 4-15]는 공변량 반영 여부에 따른 Transformer 기반 2021~2024년 연령별출산을 예측 결과를 제시한다. LSTM 기반 결과와 유사하게, 수도권 거주비율부터 GDP 대비 가축정책 지출 비율까지 7개 공변량을 반영한 경우에는 공변량을 반영하지 않은 경우에 비해 전반적인 연령별출산을 상승효과가 나타났다. 특히 출산율 수준이 상대적으로 높은 28~35세 연령대에서 상승효과가 두드러지게 나타났으나, 그 절대적 상승 폭은 LSTM 모형에서 추정된 결과보다는 다소 낮은 수준을 보였다.

[그림 4-15] 공변량 반영 여부에 따른 Transformer 기반 Test 자료 예측



주: lag7: TFR[RMSE(0.105), MAE(0.100), MAPE(13.313)], ASFR[RMSE(0.011), MAE(0.007), MAPE(1279.929)]  
lag15: TFR[RMSE(0.044), MAE(0.035), MAPE(4.734)], ASFR[RMSE(0.007), MAE(0.005), MAPE(406.073)]

Transformer 기반 예측 결과의 또 다른 특징은 공변량을 반영할 경우, 출산율 수준이 높은 연령대에서 상대적으로 높은 값을 유지하는 동시에 출산율 정점이 다소 이른 시점에 형성된다는 점이다. 실제 인구동태 통계에 따르면 2020년대 이후 평균출산연령의 정점은 약 32세 전후에서 나타나지만, Transformer 모형에 공변량을 반영한 예측 결과


에서는 이보다 이른 30대 초반에서 출산율 정점이 형성되는 것으로 나타났다. 이는 사회·경제적 공변량이 출산율 수준을 제고하는 효과와 함께, 평균출산연령을 앞당기는 방향으로 작용할 가능성을 시사한다.

다음으로 재귀적 예측(recursive forecasting) 방식을 적용하여 도출한 2025~2034년의 단기 출산율 예측 결과를 살펴본다. 공변량을 반영하지 않은 경우, 시차 7에서는 2025년 0.754명에서 2034년 0.807명으로, 시차 15에서는 2025년 0.669명에서 2034년 0.583명으로 예측되어 시차 설정에 따라 상이한 추세를 보였다. 반면, 7개 부문 공변량을 반영한 경우에는 시차 7에서 2025년 0.868명에서 2034년 0.878명으로, 시차 15에서는 2025년 0.784명에서 2034년 0.774명으로 전반적인 완만한 상승 또는 안정적인 수준을 유지하는 결과를 나타냈다(참고 [그림 4-16]). 이에 따라 공변량을 반영할 경우, 시차 7에서는 약 0.07~0.12명, 시차 15에서는 약 0.12~0.19명의 출산율 상승효과가 발생하는 것으로 분석되었다. 이러한 상승 폭은 LSTM 기반 예측 결과보다는 상대적으로 작은 수준이다.

종합하면, LSTM 모형은 단기 예측에 강점을 가지며 최근 정보에 대한 기억 효과가 강해 Transformer 모형보다 높은 출산율 수준을 예측하는 경향을 보인다. 반면, Transformer 모형은 출산율에 유의미한 공변량과 일정 수준의 노이즈를 포함한 공변량을 동시에 고려할 경우, LSTM에 비해 보다 안정적인 예측 결과를 도출하는 특징을 보였다. 이는 Transformer가 공변량 변화에 상대적으로 덜 민감하며, 학습 과정에서 전반적인 패턴과 구조를 중시하는 특성을 지니고 있음을 의미한다.

따라서 Transformer 모형은 공변량 반영이 LSTM에 비해 예측 안정성과 강건성(robust) 측면에서 장점을 가지는 것으로 해석할 수 있다.

[그림 4-16] 공변량 반영 여부에 따른 Transformer 기반 연령별출산율 10년 예측



#### 4.2.4 공변량 반영과 TimeGPT 모델 기반 연령별출산율 예측

본 절에서는 앞 절에서 구축한 보정 자료를 TimeGPT 모형에 적용하여 연령별출산율 예측 결과를 제시한다. LSTM 및 Transformer 기반 분석 결과와의 비교 가능성을 확보하기 위해 데이터 분할 방식과 전처리 절차는 동일하게 적용하였다. 구체적으로 1981~2020년을 학습자료(train data), 2021~2024년을 검증자료(test data)로 설정하고, 모든 변수에 대해 log1p 변환과 정규화를 수행한 후 TimeGPT 모형에 입력하였다. TimeGPT 모형의 하이퍼파라미터 중 시차(lag)는 5에서 15까지 단계적으로 적용하였으며, 예측의 안정성과 현실 적합성을 종합적으로 고려한 결과 시차 7과 15가 가장 합리적인 설정으로 확인되었다.

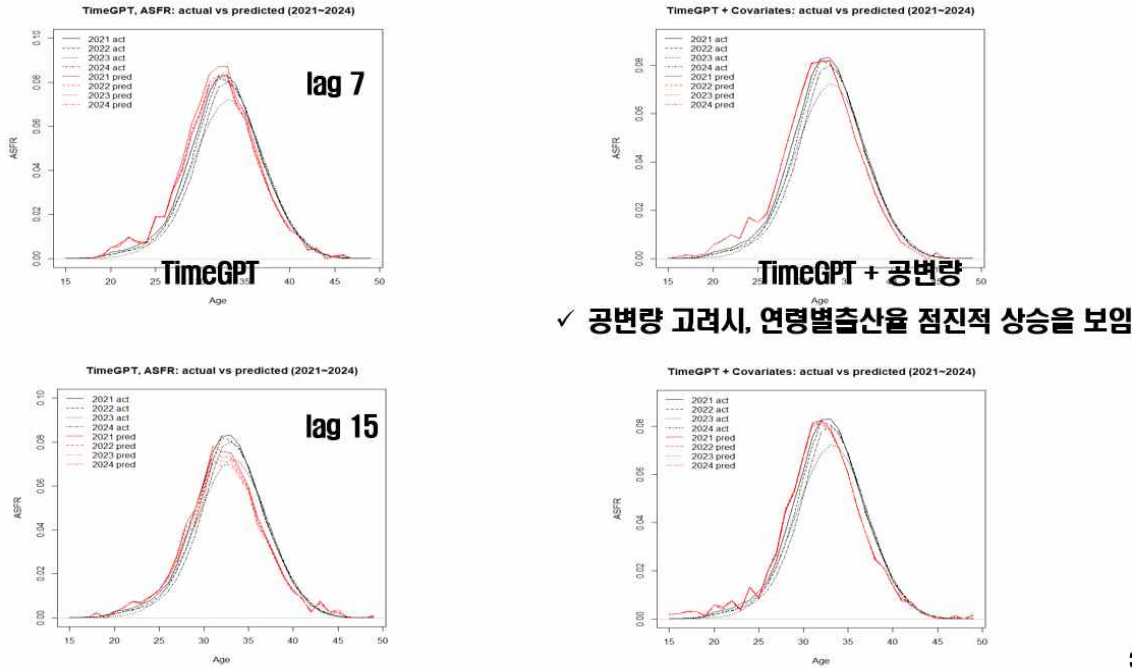
[그림 4-17]은 공변량 반영 여부에 따른 TimeGPT 기반 2021~2024년 연령별출산율 예측 결과를 보여준다. LSTM 및 Transformer 기반 결과와 유사하게, 수도권 거주비율부터 GDP 대비 가축정책 지출 비율까지 7개 공변량을 반영한 경우 전반적인 연령별출산율 상승효과가 나타났다. 특히 출산율 수준이 상대적으로 높은 28~35세 연령대에서 상승효과가 두드러졌으나, 그 상승 폭은 LSTM 기반 예측 결과보다는 낮은 수준으로 나타났다. 이를 종합하면, 2021~2024년 기간의 인공지능 기반 연령별출산율 및 합계출산율 예측 수준은 LSTM, Transformer, TimeGPT 순으로 나타난다.

TimeGPT 기반 예측 결과의 또 다른 특징은 공변량을 반영할 경우, 출산율 수준이 높은 연령대에서 상대적으로 높은 값을 유지하는 동시에 출산율 정점이 다소 이른 시점에 형성된다는 점이다. 이는 Transformer 기반 결과와 유사한 패턴으로, 사회·경제적 공변량이 출산율 수준을 제고하는 효과와 함께 평균출산연령을 앞당기는 방향으로 작용할 가능성을 시사한다.

다음으로 재귀적 예측(recursive forecasting) 방식을 적용하여 도출한 2025~2034년의 단기 출산율 예측 결과를 살펴본다. 공변량을 반영하지 않은 경우, 시차 7에서는 2025년과 2034년 모두 0.803명으로 비교적 안정적인 수준을 유지하는 반면, 시차 15에서는 2025년 0.703명에서 2034년 0.684명으로 점진적인 감소를 보였다. 반면, 7개 부문 공변량을 반영한 경우에는 시차 7에서 2025년과 2034년 모두 0.823명으로 소폭 상승하였으며, 시차 15에서는 2025년 0.785명에서 2034년 0.770명으로 완만한 하락 경로를 나타냈다(참고 [그림 4-18]). 이에 따라 공변량을 반영할 경우, 시차 7에서는 약 0.02명, 시차 15에서는 약 0.08명의 출산율 상승효과가 나타났으며, 이는 LSTM 및


Transformer 기반 예측 결과에 비해 상대적으로 작은 상승 폭이다.

[그림 4-17] 공변량 반영 여부에 따른 TimeGPT 기반 Test 자료 예측



주: lag7: TFR[RMSE(0.032), MAE(0.026), MAPE(3.451)], ASFR[RMSE(0.006), MAE(0.004), MAPE(131.881)]  
 lag15: TFR[RMSE(0.060), MAE(0.054), MAPE(7.289)], ASFR[RMSE(0.006), MAE(0.004), MAPE(1121.897)]

[그림 4-18] 공변량 반영 여부에 따른 TimeGPT 기반 연령별출산율 10년 예측



세 모형의 예측 결과를 종합적으로 비교하면, LSTM은 단기 예측에 강점을 가지며 최근 정보에 대한 기억 효과가 강해 TimeGPT과 Transformer보다 전반적으로 높은 출산율 수준을 예측하는 경향을 보인다. 반면, 출산율에 유의미한 공변량과 함께 일정 수준의 노이즈를 포함한 공변량을 동시에 고려할 경우, TimeGPT와 Transformer는

LSTM에 비해 보다 안정적인 예측 결과를 도출하는 특성을 보였다.

특히 공변량 반영 여부에 따른 단기 출산율 변동 폭은 LSTM 모형에서 가장 크게 나타났으며, Transformer와 TimeGPT 기반 모형에서는 상대적으로 제한적인 수준에 그쳤다(참고 <표 4-6>). 이는 공변량을 고려할 때 LSTM 기반 예측이 다른 인공지능 모형에 비해 더 민감하게 반응함을 의미한다. 추가적으로 공변량을 반영하지 않은 경우 2025~2034년 합계출산율 예측 수준은 TimeGPT, Transformer, LSTM 순으로 나타난 반면, 공변량을 반영할 경우에는 LSTM, Transformer, TimeGPT 순으로 예측 순위가 변화하였다.

종합하면, TimeGPT 모형은 공변량 반영 여부에 따른 출산율 변동 폭이 가장 작아 예측 안정성이 높으며, 공변량 변화에 가장 강건한 모형으로 평가할 수 있다. 반대로 LSTM 모형은 공변량 반영에 가장 민감하게 반응하는 특성을 보였으며, Transformer 모형은 이 두 모형의 중간적 성격을 지니는 것으로 해석할 수 있다.

<표 4-6> (공변량 반영 여부) 인공지능 모델별 연령별출산율 10년 예측 비교

공변량 반영 여부	LSTM		Transformer		TimeGPT	
	Lag 5	Lag 10	Lag 7	Lag 15	Lag 7	Lag 15
공변량 미반영	0.728~0.734	0.641~0.626	0.754~0.807	0.669~0.583	0.803~0.03	0.703~0.684
공변량 반영	<b>0.965~0.972</b>	<b>0.984~0.987</b>	0.868~0.878	0.784~0.774	0.823~0.823	0.785~0.770

### 4.3 사회, 경제 공변량 중요도

본 절에서는 앞서 제시한 공변량 반영 여부에 따른 LSTM, Transformer, TimeGPT 기반 연령별출산을 예측 결과를 바탕으로, 각 모형에서 공변량이 예측에 기여하는 상대적 중요도를 분석한다. 이를 위해 본 연구에서는 공변량 중요도 지표로 PFI(Permutation Feature Importance, Breiman (2001), Fisher, Rudin과 Dominici (2019))를 적용하였다.

PFI는 특정 공변량의 시간적 순서를 무작위로 섞는 방식(셔플, shuffle)을 통해, 해당 공변량이 모델의 예측 과정에서 활용되지 못하도록 만드는 실험적 방법이다. 이때 공변량을 셔플한 후 산출된 RMSE가 기존의 RMSE에 비해 얼마나 악화되는지를 통해 해당 공변량의 중요도를 평가한다. 즉, 공변량을 반영하지 않은 상태에서의 RMSE를 기준값(baseline RMSE)으로 설정하고, 특정 공변량을 셔플했을 때 발생하는 RMSE의 변화량을 통해 공변량의 중요도를 산출한다. 이 값이 양(+)이면 해당 공변량이 연령별 출산을 예측에 중요한 역할을 수행함을 의미하며, 음(-)일 경우에는 상대적으로 중요하지 않거나 예측 과정에서 잡음(noise)에 가까운 변수로 해석할 수 있다.

PFI는 변수의 영향 방향이나 인과관계를 직접적으로 제시하지는 않지만, 예측 성능에 미치는 영향의 크기(impact magnitude)를 정량적으로 비교할 수 있다는 장점이 있다. 따라서 PFI 값이 클수록 해당 공변량이 연령별출산을 예측에 상대적으로 더 중요한 변수임을 의미한다. 이하에서는 LSTM, Transformer, TimeGPT 세 가지 인공지능 기반 모형에 대해 공변량 중요도 순위를 비교·분석한다.

앞 절에서 소개한 바와 같이 고려하는 사회, 경제 공변량은 남성 수도권 거주 비율(capM), 여성 수도권 거주 비율(capF), 남성 유배우자 비율(marrM), 여성 유배우자 비율(marrF), 결혼을 해야 한다/하는 게 좋다고 응답한 비율 (marriage), 남성 경제활동 참가율(actM), 여성 경제활동 참가율(actF), 남성 고용률 (empM), 여성 고용률 (empF), 남성 실업률 (unempM), 여성 실업률 (unempM), GDP 대비 가족정책 지출 비율(famexp)으로 총 7개 부문 12개 공변량이다.

먼저 LSTM 기반 공변량 중요도를 살펴보면, 모형 하이퍼파라미터가 증가함에 따라 연령별출산을 예측에 가장 중요한 변수는 가족정책 지출 비율과 결혼인식태도, 여성 고용률, 여성 수도권거주비율, 여성 실업률, 여성 유배우율, 남성 수도권 거주비율, 남성 유배우율, 여성 경제활동참가율, 여성, 남성 실업률, 남성 실업률, 남성 고용률 순으로 중요

도가 높게 평가되었다. 공변량 중요도의 양과 음 구분 및 세부 수치는 <표 4-7>에 제시하였다.

<표 4-7> LSTM 기반 사회, 경제분야 공변량 중요도 순위

importance lag rank	1	2	3	4	5	6	7	8	9	10	11	12
lag 5	<i>famexp</i>	<i>marriage</i>	<i>empF</i>	<i>capF</i>	<i>unempF</i>	<i>capM</i>	<i>marF</i>	<i>actF</i>	<i>marM</i>	<i>unempM</i>	<i>actM</i>	<i>empM</i>
lag 7	<i>famexp</i>	<i>marriage</i>	<i>empF</i>	<i>unempF</i>	<i>capF</i>	<i>marF</i>	<i>marM</i>	<i>actF</i>	<i>capM</i>	<i>actM</i>	<i>unempM</i>	<i>empM</i>
lag 10	<i>famexp</i>	<i>marriage</i>	<i>empF</i>	<i>capF</i>	<i>unempF</i>	<i>capM</i>	<i>marM</i>	<i>actF</i>	<i>unempM</i>	<i>marF</i>	<i>empM</i>	<i>actM</i>
lag 15	<i>famexp</i>	<i>marriage</i>	<i>empF</i>	<i>capF</i>	<i>unempF</i>	<i>marF</i>	<i>actF</i>	<i>marM</i>	<i>capM</i>	<i>unempM</i>	<i>empM</i>	<i>actM</i>

LSTM 모형의 하이퍼파라미터인 시차(lag)를 5에서 15까지 변화시키며 공변량 중요도를 분석한 결과, 시차가 작을수록 모델 학습을 방해하거나 노이즈 가능성이 높은 공변량이 다수 도출되는 경향이 나타났다. 반면, 시차가 10 이상으로 커질 경우 이러한 공변량의 수는 약 2개 내외로 감소하는 특징을 보였다.

<표 4-7>에서 연령별출산을 예측에 중요한 공변량을 진한 기울임체로 구분하였다. 예를 들어, LSTM 모형에서 시차 10을 적용한 경우 여성 실업률, 남성 경제활동참가율, 여성 유배우자 비율, 남성 실업률, 남성 고용률은 가족정책 지출 비율, 결혼인식태도, 여성 경제활동참가율, 여성 수도권 거주비율, 여성 고용률, 여성 유배우자 비율, 남성 수도권 거주비율 등에 비해 상대적으로 중요도가 낮은 공변량으로 분류되었다.

다음으로 Transformer 기반 공변량 중요도를 살펴보면, 연령별출산을 예측에 있어 1순위와 2순위 변수는 LSTM 결과와 동일하게 가족정책 지출 비율과 결혼인식태도로 나타났다. 그러나 3순위 이후의 중요도 순위는 LSTM과 크게 상이한 결과를 보였다. 특히 주목할 점은 Transformer 모형의 경우, 하이퍼파라미터 설정에 따른 중요도 판별 결과가 매우 안정적으로 나타난다는 것이다. <표 4-8>에 따르면, 시차 설정과 무관하게 가족정책 지출 비율, 결혼인식태도, 남녀 고용률, 남성 실업률, 남녀 유배우자 비율, 남성 경제활동참가율, 여성 수도권 거주비율이 모두 중요한 공변량으로 분류되었다. 반면, 여성 경제활동참가율, 남성 수도권 거주비율, 여성 실업률은 상대적으로 중요도가 낮은 공변량으로 평가되었다.

이러한 결과는 LSTM 기반 분석과 뚜렷한 차이를 보인다. Transformer는 자기집중(self-attention) 구조를 통해 변수 간 관계를 안정적으로 학습하는 특성을 지니므로, 예측에 기여하지 않는 특성은 학습 과정에서 자연스럽게 가중치가 낮아진다. 그 결과,

중요하지 않은 공변량을 셔플하더라도 RMSE가 baseline RMSE와 큰 차이를 보이지 않으며, 음의 PFI 값으로 나타날 가능성 또한 낮아진다. 반대로 중요한 공변량을 셔플할 경우에는 RMSE가 유의미하게 증가하여, 변수 중요도가 명확히 구분되는 특징을 보인다.

〈표 4-8〉 Transformer 기반 사회, 경제분야 공변량 중요도 순위

importance lag rank	1	2	3	4	5	6	7	8	9	10	11	12
lag 7	<i>famexp</i>	<i>marriage</i>	<i>empF</i>	<i>marF</i>	<i>unempF</i>	<i>capF</i>	<i>unempM</i>	<i>empM</i>	<i>marM</i>	<i>actM</i>	<i>actF</i>	<i>capM</i>
lag 15	<i>famexp</i>	<i>marriage</i>	<i>empM</i>	<i>unempM</i>	<i>marF</i>	<i>empF</i>	<i>capF</i>	<i>actF</i>	<i>actM</i>	<i>marF</i>	<i>unempF</i>	<i>capM</i>

다만, Transformer 모형에서도 시차 설정에 따라 공변량 중요도의 세부 순위에는 차이가 나타났다. 시차 7을 적용한 경우에는 가족정책 지출 비율, 결혼인식태도, 여성 고용률, 여성 유배우자 비율, 여성 실업률, 여성 수도권 거주비율, 남성 실업률, 남성 고용률, 남성 유배우자 비율, 남성 경제활동참가율 순으로 중요도가 나타났다. 반면, 시차 15에서는 1~2순위는 동일하나, 이후 순위는 남성 고용률, 남성 실업률, 여성 유배우자 비율, 여성 고용률, 여성 수도권 거주비율, 여성 경제활동참가율, 남성 경제활동참가율 등으로 재배열되었다. 이는 Transformer 모형이 공변량의 절대적 중요도는 안정적으로 유지하되, 시차 설정에 따라 변수 간 상대적 영향 구조는 일부 조정될 수 있음을 시사한다.

끝으로 TimeGPT 기반 모형에서의 공변량 중요도를 살펴본다. TimeGPT 기반 공변량 중요도 분석 결과, 연령별출산율 예측에 있어 상위 1~2순위(일부 설정에서는 3순위까지)의 핵심 공변량은 Transformer 기반 결과와 동일하게 나타났으나, 그 이후 3(4)순위부터 12순위까지의 세부적인 중요도 순위는 서로 상이한 것으로 확인되었다. 이는 TimeGPT와 Transformer가 공변량의 핵심 변수에 대해서는 공통된 인식을 보이되, 변수 간 상대적 영향 구조에서는 차이를 보임을 의미한다.

특히 주목할 점은 TimeGPT 기반 공변량 중요도는 모형 하이퍼파라미터 설정과 무관하게 매우 안정적인 패턴을 보인다는 것이다. 〈표 4-9〉에 제시된 바와 같이, 시차 설정에 관계없이 가족정책 지출 비율과 결혼인식태도를 포함하여 남녀 고용률, 남녀 실업률, 남녀 유배우자 비율, 남녀 경제활동참가율, 남녀 수도권 거주비율이 모두 연령별출산율 예측에 중요한 공변량으로 분류되었다. 이는 TimeGPT 모형이 특정 소수 변수에 의존하기보다는, 다양한 사회·경제적 요인의 정보를 비교적 균형 있게 활용하고 있

음을 시사한다. 다만, 시차(lag) 설정에 따라 공변량의 상대적 중요도 순위에는 일부 차이가 나타났다. 시차 7을 적용한 경우, 가족정책 지출 비율과 결혼인식태도가 가장 중요한 변수로 나타났으며, 이후 여성 유배우자 비율, 여성 고용률, 남성 유배우자 비율, 남성 고용률, 남성 실업률, 여성 경제활동참가율, 여성 실업률, 남성 수도권 거주비율, 남성 경제활동참가율, 여성 수도권 거주비율 순으로 중요도가 평가되었다. 반면, 시차 15에서는 상위 1~2순위는 동일하게 유지되었으나, 이후 순위는 여성 고용률, 여성 유배우자 비율, 남성 유배우자 비율, 여성 실업률, 여성 경제활동참가율, 남성 고용률, 남성 경제활동참가율, 남성 실업률, 여성 수도권 거주비율, 남성 수도권 거주비율 등으로 재배열되었다. 이러한 결과는 TimeGPT 모형이 공변량의 절대적 중요도 판단은 안정적으로 유지하면서도, 시차 설정에 따라 변수 간 상대적 영향 구조를 유연하게 조정함을 보여준다.

〈표 4-9〉 TimeGPT 기반 사회, 경제분야 공변량 중요도 순위

importance lag rank	1	2	3	4	5	6	7	8	9	10	11	12
lag 7	<i>famexp</i>	<i>marriage</i>	<i>marF</i>	<i>empF</i>	<i>marM</i>	<i>empM</i>	<i>unempM</i>	<i>actF</i>	<i>unempF</i>	<i>capM</i>	<i>actM</i>	<i>capF</i>
lag 15	<i>famexp</i>	<i>marriage</i>	<i>empF</i>	<i>marF</i>	<i>marM</i>	<i>unempF</i>	<i>actF</i>	<i>empM</i>	<i>actM</i>	<i>unempM</i>	<i>capF</i>	<i>capM</i>

이상으로 LSTM, Transformer, TimeGPT 세 가지 인공지능 기반 모형의 공변량 중요도를 비교·분석하였다. 분석 결과를 종합하면, LSTM 기반 연령별출산율 예측은 공변량을 추가하기 전과 후에 연령별출산율 곡선의 형태, 합계출산율 예측 경로, 검증 단계의 RMSE 및 MAE 값이 크게 변하는 특성을 보였다. PFI 분석에서도 공변량에 대해 양·음의 값을 포함한 비교적 큰 중요도 분포가 나타났으며, 이는 공변량이 예측과 일정 수준의 상관관계를 가질 경우 해당 방향으로 강하게 적합되는 경향이 있음을 의미한다. 특히 분석 기간이 1981~2020년으로 상대적으로 짧은 시계열( $T \approx 40$ ) 환경에서는 이러한 특성이 과적합 또는 예측 불안정성으로 이어질 가능성이 존재한다.

반면, Transformer와 TimeGPT 기반 연령별출산율 예측은 공변량을 추가하더라도 예측 곡선의 변화 폭이 상대적으로 작고, 성능 개선 또한 제한적인 수준에 그쳤다. PFI 값 역시 대부분 작은 양의 값에 집중되었으며, 음의 중요도를 보이는 공변량은 두 개 이하로 나타났다. 이는 두 모형이 공변량 정보를 보다 보수적이고 안정적으로 반영하고 있음을 시사한다. 따라서 본 연구의 결과를 종합하면, LSTM 모형은 공변량 변화에 가장 민감한 반면, Transformer와 TimeGPT 모형은 상대적으로 강건하고 안정적인 예측 특성을 지닌 모델로 판단할 수 있다.

## V. 결론 및 제언

본 연구는 2025~2034년을 대상으로 한 단기 출산율 패턴과 예측을 목적으로, 인공지능 기반 시계열 예측 기법인 LSTM(Long Short-Term Memory), Transformer, TimeGPT 모형을 적용하여 연령별출산율과 합계출산율의 변화를 분석하였다. 특히 출산율이 단순한 인구학적 추세의 결과가 아니라 사회·경제적 환경 변화와 밀접하게 연동된다는 점에 주목하여, 수도권 거주비율, 혼인 관련 지표, 노동시장 지표, 가족정책 지출 비율 등 7개 부문 12개의 다양한 사회·경제학적 변수를 공변량으로 정의하고, 공변량 반영 여부에 따른 10년 단기 출산율 예측 결과를 비교·분석하였다.

본 연구를 통해 도출된 주요 결과는 다음과 같이 요약할 수 있다. 첫째, 공변량 반영 여부에 따라 인공지능 모형별 출산율 예측 특성에는 뚜렷한 차이가 나타났다. LSTM 기반 예측은 공변량을 반영할 경우 연령별출산율과 합계출산율 모두에서 Transformer와 TimeGPT에 비해 상대적으로 큰 출산율 증가 경향을 보였다. 이는 출산율 예측에 유의미한 공변량뿐만 아니라 일정 수준의 잡음(noise)을 포함한 공변량이 함께 반영될 경우, LSTM 모형이 다른 두 모형에 비해 예측 값의 변동 폭이 크게 확대되는 특성을 지님을 의미한다. 따라서 LSTM 기반 출산율 예측에서는 공변량의 선정과 전처리 과정이 예측 결과에 결정적인 영향을 미치며, 정책적 해석을 수반하는 경우에는 공변량 선택에 각별한 주의가 요구된다.

반면, Transformer와 TimeGPT 기반 인공지능 기법은 공변량을 반영할 경우에도 연령별출산율과 합계출산율이 일정 수준 제고되는 효과를 보이지만, 그 변화 폭은 LSTM에 비해 상대적으로 제한적인 수준에 머물렀다. 즉, 공변량을 추가하더라도 예측 곡선의 형태 변화가 비교적 작고 성능 개선 역시 점진적으로 나타나는 특징을 보였다. 다만, 본 연구에서 고려한 모든 공변량을 연령별출산율 예측에 있어 의미 있는 변수로 인식하고 있다는 점에서, Transformer와 TimeGPT는 공변량을 보다 보수적이고 안정적으로 활용하는 인공지능 기법으로 평가할 수 있다. 이러한 결과는 우리나라 출산율 예측 맥락에서 LSTM은 공변량 변화에 민감하게 반응하는 모형인 반면, Transformer와 TimeGPT는 상대적으로 안정성과 강건성이 높은 모형임을 시사한다.

구체적인 예측 수치를 살펴보면, LSTM 기반 합계출산율의 경우 2025~2034년 기간 동안 공변량을 반영하지 않았을 때는 0.728~0.734명(lag 5), 0.641~0.626명(lag 10)으로

예측된 반면, 공변량을 반영할 경우에는 각각 0.947~0.948명(lag 5), 0.926~0.930명(lag 10)으로 크게 상승하는 결과를 보였다. Transformer 기반 예측에서는 동일 기간 합계 출산율이 공변량 미반영 시 0.754~0.807명(lag 7), 0.669~0.583명(lag 15)으로 나타났으며, 공변량 반영 시에는 0.823~0.834명(lag 7), 0.793~0.768명(lag 15)으로 예측되었다. TimeGPT 기반 예측의 경우에도 공변량 미반영 시 0.803~0.803명(lag 7), 0.703~0.684명(lag 15)으로 나타났으나, 공변량을 반영하면 0.823~0.823명(lag 7), 0.785~0.770명(lag 15)으로 예측되어 전반적으로 완만한 상승효과를 보였다.

둘째, 모형 하이퍼파라미터 설정에 따라 예측 결과가 상이하게 나타났다. 시차(lag)가 5 또는 7인 경우에는 단기적인 출산율 변동과 최근의 반등 가능성을 비교적 잘 반영하는 반면, 시차가 10 이상, 특히 12~15 수준으로 증가할 경우에는 2010년 이후 지속되어 온 출산율 감소 기조가 학습 과정에 강하게 반영되어, 향후에도 감소 추세가 지속되는 예측 결과를 도출하였다. 이는 인공지능 기반 출산율 예측에서 시차 설정이 단순한 기술적 선택을 넘어, 예측 결과의 방향성에 중대한 영향을 미치는 요소임을 의미한다.

셋째, 공변량 중요도 분석 결과에서도 모형 간 뚜렷한 차이가 확인되었다. LSTM 모형은 하이퍼파라미터가 증가함에 따라 연령별출산율 예측에 중요한 공변량의 수가 점차 확대되는 경향을 보인 반면, Transformer와 TimeGPT 모형은 소수의 핵심 공변량만을 중요 변수로 인식하거나, 반대로 대부분의 공변량을 고르게 중요한 변수로 평가하는 안정적인 특성을 보였다. 이는 LSTM이 공변량의 미세한 변화를 적극적으로 학습하는 반면, Transformer와 TimeGPT는 전반적인 구조와 패턴을 중심으로 예측을 수행함을 시사한다.

이러한 분석 결과를 바탕으로, 본 연구는 향후 인공지능 기반 인구추계 연구 및 정책적 활용을 위한 몇 가지 제언을 제시한다. 첫째, 공변량 구조의 고도화와 비선형 상호작용 변수 개발이 필요하다. 단순한 사회·경제 지표의 나열을 넘어, 소득 분위별 출산행태, 지역·혼인·교육 수준의 결합 효과, 정책 변화에 따른 더미 변수 등을 도입함으로써 공변량의 설명력과 정책적 해석 가능성을 한층 강화할 수 있을 것이다.

둘째, GPU 기반 클라우드 인구추계 플랫폼 구축이 중요하다. 인공지능 기반 인구추계 기법을 실무적으로 활용하기 위해서는 기관 차원의 고성능 GPU 환경 또는 클라우드 서버 기반 계산 인프라가 필수적이다. 실제로 개인용 PC에서 R 통계 프로그램을 활용하여 인공지능 모형을 실행할 경우, 메모리 부족이나 연산 오류로 인해 분석이 중단되는 사례가 빈번히 발생한다는 점에서, 안정적인 분석 환경 구축은 연구의 재현성과

실용성을 높이기 위한 선결 조건이라 할 수 있다.

셋째, 공변량이 출산율에 미치는 영향의 방향성과 크기를 동시에 해석할 수 있는 분석 도구의 활용이 요구된다. 본 연구에서 적용한 PFI(Permutation Feature Importance)는 공변량의 상대적 중요도를 파악하는 데 유용하지만, 영향 방향을 직접적으로 제시하지는 않는다. 향후 연구에서는 Partial Dependence Plot(PDP, Friedman 2001), ICE curves(Goldstein et al. 2015), Integrated Gradients(IG, Sundararajan et. al, 2017), SHAP (Lundberg and Lee (2017)) 등과 같은 기법을 활용하여 공변량의 방향성과 민감도를 보다 정교하게 분석할 필요가 있다. 다만, SHAP의 경우 Python 환경에서는 비교적 안정적으로 구현되지만, R 환경에서는 TensorFlow와 Keras 버전 간 호환성 문제로 인해 적용에 제약이 존재한다는 점 역시 향후 연구 인프라 구축 과정에서 고려되어야 할 사항이다.

종합하면, 본 연구는 연령별출산율 예측에 인공지능 기반 기법인 LSTM, Transformer, TimeGPT를 적용함으로써, 기존 통계적 모형과 시계열 예측 방식에 기반을 둔 전통적인 접근과는 차별화된 결과와 시사점을 도출하였다. 인공지능 기반 출산율 예측은 기존 방법을 완전히 대체하기보다는, 단기적인 연령별 변화 감지와 공변량 반영이 용이한 보완적 예측 프레임워크로 활용될 때 그 가치가 극대화될 수 있을 것이다.

## 〈참고문헌〉

- 계봉오·유삼현·황선재. (2023). 저출산 통계지표 체계구축 및 세부지표 발굴. 통계청 연구용역과제.
- 계봉오·유삼현·황선재·고원태·임준경 (2024). 저출생 통계지표 영역별 지표구성을 위한 심층분석. 통계청 연구용역과제.
- 김유현, 김동현 (2023), 해석 가능한 기계학습을 적용한 소지역 인구 추정에 관한 연구: 부산광역시를 대상으로. 한국지리정보학회지, 26(4), 97-115.
- 박성훈 (2023), 여성의 경제활동은 출산율을 낮추는가?, 사회통합연구, 4(2), 27~48.
- \_\_\_\_\_ (2024), 인구밀도가 출산율에 미치는 영향\_남녀 나이와 지가의 매개효과, 아시아태평양융합연구교류논문지, 10(10), 71-87.
- 변상영, 이동찬, 김기환 (2023), CNN 기반 주간 위성 이미지를 활용한 격자 단위 인구추정, 한국자료분석학회, 25(2), 467-479.
- 신윤정 (2020). 국내 코호트 합계출산율의 장기 추이 분석, 보건사회연구, 40(3), 534-562.
- 오진호·계봉오 (2024a). 장래인구추계 장단기 모형 고도화. 국회예산정책처 연구용역보고서
- 오진호·계봉오 (2024b). 장래인구추계 출산력 및 시도 인구추계 개선 방안 연구. 통계청 연구용역보고서
- 유삼현 (2022). 출산의 지연변천 분석과 완결출산율 추계, 통계연구, 27(1), 29-55.
- 이상희, 김규석, 정태양, 서예진 (2023), 딥러닝을 활용한 출산율 예측 모형의 제안, 산업기술연구논문지, 28(4), 15-24.
- 조성호, 문승현(2021), 일자리 관련 요인과 출산 의향에 관한 연구, 보건사회연구, 41(4), 262~279.
- 통계청 (2023), 장래인구추계: 2022~2072년.
- 통계청 (2023), 저출생 통계지표.
- 통계청 (2024), 저출생지표체계 연구.
- 한신원. (2025). 청년 노동시장 불안정과 혼인·출산의 지연: 한국과 일본 비교. 불평등연구회 월례발표회 발표자료.
- 황인도·남윤미·성 원·심세리·염지인·이병주·이하림·정종우·조태형·최영준·황설웅·손민규. (2023). 초저출산 및 초고령사회: 극단적 인구구조의 원인, 영향, 대책. 경제전망보고서. 한국은행.
- Breiman, Leo. (2001). Random Forests. Machine Learning 45 (1): 5 - 32.

<https://doi.org/10.1023/A:1010933404324>.

- Chen, Y., F. Guo., J. Wang., W. Cai., C. Wang., K. and Wang. (2020a). Provincial and gridded population projection for China under shared socioeconomic pathways from 2010 to 2100. *Scientific Data* 7(1), 83.
- Chen, Y., X. Li., K. Huang., M. Luo., and M. Gao. (2020b). High resolution gridded population projections for China under the shared socioeconomic pathways. *Earth's Future* 8(6):e2020EF001491.
- Doepke, M., Hannusch, A., Kindermann, F. and Tertilt, M. (2023). The economics of fertility: a new era. In: Lundberg, Shelly and Voena, Alessandra, (eds.) *Handbook of the Economics of the Family*. North-Holland.
- Esping-Anderson, G. and F. Billari. (2015). Re-theorizing Family Demographics. *Population and Development Review*, 41(1): 1-31.
- Fisher, Aaron, Cynthia Rudin, and Francesca Dominici. (2019). All Models Are Wrong, but Many Are Useful: Learning a Variable's Importance by Studying an Entire Class of Prediction Models Simultaneously. *Journal of Machine Learning Research : JMLR* 20: 177. <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC8323609/>.
- Fluchtmann, J., Veen, V., & Adema, W. (2023). Fertility, employment and family policy: A cross- country panel analysis.
- Garza, A., Challu, C. and Mergenthaler-Canseco, M. (2023). TimeGPT-1, arXiv:2310.03589. <https://doi.org/10.48550/arXiv.2310.03589>.
- Goldscheider, F., V. Bernhardt, and T. Lappegard. (2015). The Gender Revolution: A Framework for Understanding Changing Family and Demographic Behavior. *Population and Development Review*, 41 (2): 207-239.
- Grossman, I., Bandara, K., Wilson, T., and Kirley, M. (2022); Can machine learning improve small area population forecasts? A forecast combination approach, *Computers, Environment and Urban Systems*, 95, 101806.
- Hochreiter, S. and Schmidhuber, J. (1997). Long short-term memory. *Neural computation*, 9(8), 1735 - 1780.
- Huwei, W., Junjie S., and Xuan-Hoa N. (2025). Does artificial intelligence matter for the population aging-inclusive growth nexus? *International evidence, Telecommunications Policy*, 49(4), 102932.
- Hyndman, R. J. and Booth, H. (2008). Stochastic population forecasts using functional data models for mortality, fertility and migration, *International Journal of Forecasting*, 24(3), 323-342.

- Hyndman, R. J., Booth, H. and Yasmeen, F. (2013). Coherent mortality forecasting: The product-ratio method with functional time series models, *Demography*, 50(1), 261-283.
- Lee, R. D. and Carter, L. R. (1992). Modeling and forecasting U.S. mortality, *Journal of the American Statistical Association*, 87, 659-671.
- Lesthaeghe, R. (1995). The Second Demographic Transition in Western Countries: An Interpretation. in K.O. Mason and A.M. Jensen (Eds.), *Gender and Family Change in Industrialized Countries* (pp.17-62). Oxford: Clarendon Press.
- Li, N. and Lee R. (2005). Coherent mortality forecasts for a group of populations: an extension of the Lee-Carter method, *Demography*, 42, 575-594. <https://doi.org/10.1353/dem.2005.0021>
- Lundberg, Scott M., and Su-In Lee. (2017). A Unified Approach to Interpreting Model Predictions. In *Proceedings of the 31st International Conference on Neural Information Processing Systems*, 4768 - 77. NIPS'17. Red Hook, NY, USA: Curran Associates Inc.
- McDonald, P. (2000). Gender Equity in Theories of Fertility Transition. *Population and Development Review* 26(3): 427-439.
- Morgan, S. (2003). Is Low Fertility a Twenty-First-Century Demographic Crisis?. *Demography* , 40(4): 589-603.
- Myrskylä, M., Kohler, H.-P., and Billari, F. (2009). Advances in development reverse fertility declines. *Nature* 6:460:741-3.
- Oppenheimer, V. (1988). A theory of marriage timing. *American Journal of Sociology* 94(3): 563-591.
- Ribeiro, Marco Tulio, Sameer Singh, and Carlos Guestrin. (2016a). Model-Agnostic Interpretability of Machine Learning. arXiv Preprint arXiv:1606.05386.
- \_\_\_\_\_. (2016b). Why Should I Trust You?: Explaining the Predictions of Any Classifier. In *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, 1135 - 44. KDD '16. New York, NY, USA: Association for Computing Machinery. <https://doi.org/10.1145/2939672.2939778>.
- Sobotka, T. (2008). Overview Chapter 6: The diverse faces of the Second Demographic Transition in Europe. *Demographic Research*, 19: 171-224
- Sweeney, M. (2002). Two Decades of Family Change: The Shifting Economic Foundations of Marriage. *American Sociological Review* 67(1): 132-147

- Vignoli, D., L. Mencarini and G. Alderotti. (2020). Is the effect of job uncertainty on fertility intentions channeled by subjective well-being?. *Advances in Life Course Research*, 46: 100343
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). Attention is all you need. In *Advances in Neural Information Processing Systems*, 5998 - 6008.
- Wilson, T., Grossman, I., and Temple, J. (2023). Evaluation of the best M4 competition methods for small area population forecasting, *International Journal of Forecasting.*, 39(1). 110-122.
- Yoo, S. H. and Sobotka, T. (2018). Ultra-low fertility in South Korea: The role of the tempo effect, *Demographic Research*, 38(22), 549-576.

인터넷 사이트

[https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT\\_ZTITLE&menuId=M\\_01\\_01](https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT_ZTITLE&menuId=M_01_01)  
[www.researchgate.net/figure/Ten-fold-cross-validation-diagram-The-dataset-was-divided-into-ten-parts-and-nine-of\\_fig1\\_326465007](https://www.researchgate.net/figure/Ten-fold-cross-validation-diagram-The-dataset-was-divided-into-ten-parts-and-nine-of_fig1_326465007)

[https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT\\_ZTITLE&menuId=M\\_01\\_01](https://kosis.kr/statisticsList/statisticsListIndex.do?vwcd=MT_ZTITLE&menuId=M_01_01)

