

상향식 머신러닝 기법을 활용한 한국의 인플레이션 예측*

이 동 재** · 위 승 현***

논문 초록

본 연구는 머신러닝 기법과 소비자물가지수를 구성하는 하위 품목군의 가격을 개별적으로 예측한 후 가중합산하는 상향식 접근 방식을 결합하여 우리나라 단기 인플레이션 예측의 정확도를 제고하고자 하였다. 보루타-랜덤포레스트 알고리즘과 다양한 설명변수를 활용해 품목별 예측을 수행하고, 집계 수준별 예측 결과를 비교한 결과, 30개 품목군을 개별 예측하고 가중합산하는 방식이 가장 높은 예측력을 보였으며, 기존의 직접 예측방식이나 전문가 서베이보다 우수한 성과를 나타냈다. 본 방법론은 예측력 향상뿐 아니라 품목군 수준의 상세한 전망 정보를 제공함으로써 물가 대응 정책과 민간 부문에서 유용하게 활용될 수 있으며, 향후 다양한 거시경제 지표의 예측에도 효과적으로 확장될 수 있다.

핵심 주제어: 머신러닝, 상향식, 인플레이션, 예측

경제학문헌목록 주제분류: C53, E31

투고 일자: 2025. 9. 20. 심사 및 수정 일자: 2025. 11. 20. 게재 확정 일자: 2025. 12. 12.

* 본 논문은 저자들이 이전에 작성한 한국은행 이슈노트 2024-25를 수정, 보완한 연구임을 밝힙니다. 본 논문의 결과는 한국은행의 공식견해가 아닌 집필자 개인의 견해이며, 남아있는 모든 오류는 저자들의 책임임을 밝힙니다. 연구 수행 과정에서 귀중한 조언을 해주신 한국은행 박창현 박사님과 이정익 박사님께 깊이 감사드립니다. 또한 성균관대학교 한희준 교수님께서 기초 예측 코드와 더불어 다양한 유익한 조언을 주신 데 대해 진심으로 감사드립니다. 아울러 44회 International Symposium on Forecasting의 본 연구 발표에서 유익한 조언을 해주신 참가자 여러분께 감사드리며, 익명의 심사위원들께서 보내주신 건설적인 논평에도 깊은 감사의 말씀을 드립니다.

** 제1저자 및 교신저자, 한국은행 인천본부 과장, e-mail: dongjae.lee@bok.or.kr

*** 공동저자, 한국은행 물가동향팀 조사역, e-mail: shwi@bok.or.kr


I. 서론

인플레이션 전망은 통화정책 결정뿐만 아니라, 기업·가계·금융시장 등 경제 주체 전반의 의사결정에 핵심적인 영향을 미친다. 이러한 중요성에 따라 다양한 인플레이션 예측 기법이 오랜 기간 개발·정교화되어 왔으나, 예측 정확도는 여전히 한계에 직면해 있다. 특히 단기 인플레이션 예측의 경우, 복잡한 모형을 통한 예측 방식이 단순 시계열 모형이나 전문가 설문 등 정성적 접근법보다도 성과가 낮은 것으로 나타난 바 있다(Stock and Watson, 2010; Faust and Wright, 2013).

COVID-19 팬데믹 이후에는 공급망 교란, 원자재 가격 급등, 정책 불확실성 등이 겹치면서 인플레이션의 단기 변동성이 크게 확대되었고, 이에 따라 정확한 단기 인플레이션 예측에 대한 수요와 정책적 중요성이 더욱 부각되었다. 단기 예측의 정교화는 경제 주체의 불확실성 대응을 지원하는 동시에, 중앙은행이 보다 신속하고 선제적인 정책 결정을 내리는 데에도 기여할 수 있다. 나아가 Krüger et al. (2017), Knotek and Zaman (2019) 등의 연구는 단기 예측의 개선이 중장기 인플레이션 전망의 정확성 향상에도 도움을 줄 수 있음을 시사하고 있다.

한편, 최근 머신러닝 기술의 발전과 빅데이터 활용의 확대는 인플레이션을 포함한 거시경제지표 예측 방식에 새로운 전기를 제공하고 있다. 본 논문은 이러한 기술적 진전을 바탕으로, 최신 머신러닝 기법과 세부 품목 단위의 물가 흐름을 활용한 상향식 접근 방식을 결합한 단기 인플레이션 예측 모델을 제시한다. 구체적으로는, 소비자물가지수를 구성하는 각 품목군의 가격을 머신러닝 기법을 통해 개별적으로 예측한 후, 해당 품목의 가중치를 적용해 전체 인플레이션을 집계하는 방식이다. 예측에는 한희준(2023)의 연구에서 국내 소비자물가지수 예측에 우수한 성과를 보인 보루타 랜덤포레스트 알고리즘을 사용하였으며, 이를 통해 품목군별 향후 가격 흐름을 추정한 뒤, 소비자물가지수의 품목별 가중치를 활용해 전체 물가상승률 예측치를 도출하였다. 이러한 접근은 소비자물가지수 또는 근원물가상승률과 주요 거시 변수 간 관계를 기반으로 한 필립스 커브 계열 이론모형, 한국은행 등 주요 기관에서 사용하는 구조 모형, 총지수 자체를 단일 대상으로 예측하는 시계열 및 머신러닝 방식과는 차별성을 지닌다(〈Figure 1〉 참고).

〈Figure 1〉 Bottom-Up vs. Aggregate Forecasting



한국의 소비자물가지수는 458개 품목으로 구성되며, 각 품목은 소분류에서 대부분 류로 집계되는 계층 구조를 이루고 있다.¹⁾ 소비자물가지수를 구성하는 개별 품목들의 가격 특성과 변동 요인은 상이하다. 이로 인해 동일한 기간에도 품목별로 매우 다른 가격 변동 패턴이 나타날 수 있다. 예를 들어, 국제유가가 급등할 경우 휘발유 등 유류 품목 가격에 직접적인 영향을 주는 반면, 국내 임금 상승은 외식비나 이미용 서비스 등 개인서비스 가격에 더 큰 영향을 미친다.

이처럼 품목별 가격 결정 요인이 상이하기 때문에, 소비자물가지수 전체를 예측 대상으로 삼을 경우 가중합산 과정에서 이질적인 가격 움직임이 상쇄되어 예측에 유용한 정보가 희석될 수 있다. 이는 예측 모델에서 의미 있는 설명 변수를 도출하기 어렵게 만든다. 반면, 하위 품목군 단위로 가격을 개별적으로 예측하는 방식은 각 품목군의 고유한 이질성과 지속성을 반영하는 데 유리하다(Barker, 2014). 또한 품목별 가격에 영향을 주는 거시·미시 변수들을 식별하고 활용함으로써, 예측 정확도를 높일 수 있다. Bernanke (2007)는 단기 인플레이션 예측에 있어 총지수를 직접 예측하는 방식보다 세부 품목의 예측치를 종합하는 상향식 접근법이 더 효과적이라고 지적한 바 있다. 특히, 물가 변동이 총수요의 변화보다는 지정학적 리스크, 기상이변, 공급망 교란 등 개별 품목 수준의 충격에 기인하는 경우에는 상향식 방식이 더욱 적합할 수 있다. 실제로 최근 주요국 중앙은행들도 소비자물가지수를

1) 예를 들어, 쌀은 물가지수의 가장 하위 항목에 해당하며, “빵 및 곡물”, “식료품”, “식료품 및 비주류 음료” 등 상위 품목군에 가중 평균 방식으로 집계된다.

구성하는 품목 수준의 변화를 세밀히 분석하고, 이를 정책 대응이나 대외 커뮤니케이션에 적극적으로 활용하고 있다.

다만, 상향식 접근은 품목별로 유효한 설명변수를 발굴하고 최적의 예측 모형을 설정하는 과정에서 상당한 복잡성과 시간 비용이 수반된다는 한계를 지닌다. 이에 따라 기존 연구들은 주로 과거 시차 변수에 의존한 단순 시계열 모형을 사용하거나, 모든 품목에 동일한 설명변수를 적용하는 방식으로 접근해왔으며(Benalal et al., 2004; Espasa and Albacete, 2007; Duarte and Rua, 2007; Clark et al., 2023), 이 방법론의 유효성에 대해서는 연구자별로 상이한 결론을 도출하였다.

그러나 최근 빠르게 발전하고 있는 머신러닝 기법을 상향식 예측 방식에 적용할 경우, 이러한 한계를 효과적으로 극복할 수 있다. 머신러닝 기법을 통해 세부 품목별로 유효한 설명변수와 예측 모형을 연구자의 개입 없이 자동으로 식별할 수 있어, 다수의 품목에 대해 보다 정확한 모형을 구축하는 동시에 모형 설정에 소요되는 시간 비용을 크게 절감할 수 있기 때문이다. 또한, 최근에는 품목 수준의 가격과 밀접한 관련이 있는 다양한 미시 데이터를 풍부하게 수집·활용할 수 있는 데이터 환경이 조성되면서, 이러한 방식의 실용성과 확장 가능성이 더욱 커지고 있다.

이러한 배경 속에서 머신러닝 기법과 상향식 방식을 결합한 예측 모형에 대한 연구도 활발히 진행되고 있으며, 대체로 상향식 머신러닝 접근이 여타 예측 방식보다 높은 정확성을 보이는 것으로 평가되고 있다. 다만, 예측 성과는 국가별 인플레이션의 시계열적 특성, 데이터 가용성, 적용된 머신러닝 기법 등에 따라 달라질 수 있다(Boaretto and Medeiros, 2023).

본 연구는 상향식 머신러닝 기법을 활용하여 한국의 단기 인플레이션 예측 모형을 구축하고, 해당 모형의 예측력을 직접 예측 방식의 머신러닝 모형, 일반 시계열 모형 그리고 전문가 설문조사 결과와 비교하였다. 기존 상향식 방식은 자기회귀모형과 같은 단순한 시계열 기법에 기반해 다양한 설명변수를 반영하지 못하는 한계가 있다. 본 연구는 이러한 제약을 극복하고자, 거시경제 변수뿐만 아니라 비전통적 미시정보를 포함한 다양한 설명변수를 수집하여 품목별 예측에 적용하였다. 구체적으로는 지역별 기후변수, 고속도로 통행량, 방한 외래 관광객 수, 공공요금 관련 뉴스 등 개별 품목 가격과 밀접한 관련이 있는 고빈도 데이터를 포함하였다. 이러한 세부 정보를 머신러닝과 결합함으로써, 상향식 모형은 당월(nowcasting)과 향후 1~2개월의 단기 인플레이션 예측에 있어 직접 예측식이나 시계열 모형 방식

보다 높은 성과를 나타냈다.

예측력 향상의 핵심 요인은, 상향식 접근법과 머신러닝의 결합을 통해 품목별 물가 흐름을 정밀하게 설명할 수 있는 이질적이고 다양한 정보를 효과적으로 활용한 데 있는 것으로 보인다. 실제로 보루타-랜덤포레스트 알고리즘을 통해 headline 인플레이션을 직접 예측할 경우 37개의 정보변수가 선택된 반면, 상향식 방식에서는 총 370개의 변수가 활용된 것으로 나타났다. 이는 상향식 접근법이 보다 방대한 정보 집합을 기반으로 정교한 예측을 가능하게 함을 시사한다.

본 연구에서 사용된 예측방식은 단순히 전체 인플레이션 전망뿐만 아니라, 농산물, 유류, 식료품 등 세부 품목군에 대한 물가 추세와 변동성 예측에도 유용한 도구를 제공한다. 이는 향후 단기 인플레이션 대응 정책 수립에 있어 실질적 시사점을 제시할 것으로 기대된다.

본 연구의 구성은 다음과 같다. II절에서는 관련 기존 연구를 검토하고, III절에서는 한국 소비자물가지수의 통계적 특성을 분석한다. IV절에서는 상향식 머신러닝 접근 방법과 데이터 구성, 예측 성과 평가 방법을 소개한다. V절에서는 예측방식별 성과를 비교하고 주요 결과를 제시하며, 마지막으로 VI절에서는 연구 결과를 요약하고 향후 과제를 논의한다.

II. 문헌리뷰

그간 인플레이션 예측에 대한 방대한 연구가 이루어졌음에도 불구하고, 인플레이션 예측은 여전히 어려운 과제로 남아 있다. 특히, 단순 시계열 모형의 예측력을 증가하는 새로운 인플레이션 예측방식을 구축하는 것이 쉽지 않다는 점이 잘 알려져 있다. 예를 들어, Stock and Watson (2010)은 여타 모형 대비 단순한 단변량 모형의 우월성을 실증적으로 보였으며, Faust and Wright (2013)는 단기 및 장기 인플레이션 서베이 예측치의 점진적 변화 경로가 다른 모형보다 더 높은 예측력을 제공한다고 강조했다.²⁾ 그러나 Verbrugge and Zaman (2024), Chan et al. (2018) 등 최근 연구들은 보다 정교한 모형의 도입을 통해 기존의 단순한 예측 모형을 개선

2) 또한 이들은 인플레이션 예측과 관련한 자세한 서베이를 제공한다.

할 수 있는 가능성을 시사하고 있다.

국내의 물가상승률 예측 관련 주요 연구로는 강규호 외(2021), 김현학(2015), 최인·황승진(2012) 등이 있으며, 이들 연구는 해외 사례와 유사하게 다양한 시계열 모형을 활용해 인플레이션 예측력을 평가하고 상호 비교하였다. 일부 연구는 복수의 예측 모형을 결합하는 방식이 예측 정확도 향상에 기여할 수 있음을 제시하였다. 다만, 이러한 연구들은 대부분 시계열 모형에 기반하고 있으며, 전체 인플레이션 수준을 직접 예측하는 방식에 주로 의존하고 있다.

한편, 최근에는 다양한 머신러닝 기법을 활용한 인플레이션 예측 연구가 활발히 이루어지고 있다. Medeiros et al. (2016)과 Medeiros et al. (2021)은 Ridge 및 LASSO와 같은 축소 기법, 베이지안 방법, Bagging, Boosting, 랜덤 포레스트, 완전 부분 집합 회귀(Complete Subset Regression) 등 다양한 머신러닝 기반 물가 예측 기법을 비교했으며, 그중 랜덤 포레스트 모형이 물가상승률 예측에서 우수한 성능을 보였다고 보고하였다. 또한, Almosova and Andresen (2023)은 뉴럴 네트워크 기반 예측 모형이 단순 시계열 모형보다 우수한 예측력을 보인다고 보고했으며, Theoharidis et al. (2023)은 딥러닝 기반 모델이 기존 머신러닝 기법보다 인플레이션 예측력이 우수함을 입증했다. 국내 연구로는 한희준(2023)이 경제예측에 활용되는 다양한 머신러닝 기법을 한국의 인플레이션 예측에 적용하고 예측력을 비교한 결과, 보루타-랜덤포레스트(Boruta-Random Forest) 방식이 가장 우수한 성능을 보인 것으로 나타났다. 또한, 이창훈 외(2024)는 선형 회귀 모형과 머신러닝 알고리즘을 결합한 앙상블 모형이 높은 예측력을 보였다고 보고하였다. 다만, 이들 연구는 공통적으로 총지수 또는 근원물가지수를 대상으로, 머신러닝 기법을 활용한 직접 예측 방식에 주로 기반하고 있다.

인플레이션은 소비자물가지수를 구성하는 수백 개 품목의 가격 변화를 집계한 결과이므로, 하위 품목 단위에서 예측을 수행한 후 이를 통합하는 상향식(bottom-up) 접근법에 대한 연구도 오래전부터 진행되어 왔다. 그러나 기존 연구(예: Benalal et al., 2004; Espasa and Albacete, 2007; Duarte and Rua, 2007)에서는 세부 품목 예측 시 동일한 설명 변수를 사용하거나 단순 시계열 모형을 활용하는 방식이 일반적이었다. 이는 세부 품목별 가격 변화에 대한 이론적 배경이 부족하고, 적절한 설명 변수를 찾기가 어렵다는 한계 때문이었다. 이러한 접근법은 직접 예측 방식과 비교할 때 예측력 개선 효과가 크지 않은 것으로 나타났다.

최근에는 머신러닝 기법과 상향식 예측 방식을 결합한 연구가 활발히 이루어지고 있다(Joseph et al., 2024; Barkan et al., 2023; Boaretto and Medeiros, 2023; Martínez-Rivera et al., 2023). 이들 연구는 상향식 머신러닝 접근법이 기존의 직접 예측 방식에 비해 우수한 예측 정확도를 제공할 수 있음을 보여준다. 그러나 한국의 경우, 머신러닝 기법과 상향식 예측 방식을 결합한 실증 연구는 물론, 단순 시계열 기반의 상향식 예측 방식에 대한 연구도 매우 제한적인 실정이다.

본 연구는 최신 연구 동향을 반영하여, 상향식 접근과 머신러닝 기법을 결합한 예측 모형을 제시하고 이를 우리나라 인플레이션 예측에 적용한 뒤, 직접 예측 방식의 머신러닝 모델 및 직접·상향식 시계열 모형과 그 성능을 비교한다. 이를 바탕으로 단기 인플레이션 예측의 실증적 유용성과 정보 활용 범위의 확장 가능성을 함께 살펴본다.


Ⅲ. 우리나라 품목별 소비자물가지수 통계의 특징³⁾

소비자물가지수(CPI)는 가계의 대표적인 지출 구조를 반영한 바스켓 내 재화 및 서비스 가격의 변화를 측정하는 지표로, 평균적인 생활비의 변동을 나타낸다. 비록 거시경제 지표로 널리 활용되지만, CPI는 개별 품목 수준의 가격 정보를 기반으로 산출된다.

우리나라의 CPI는 상품 단위 가격을 조사한 뒤, 지출 목적별 및 품목 성질별로 구성된 계층적 구조에 따라 집계된다. 지출 목적별 지수는 식료품 및 비주류 음료, 의류 및 신발, 교육, 통신, 오락 및 문화 등으로 분류되며, 최대로 세분화할 경우 458개의 세부 품목 지수가 제공된다. 한편, 품목 성질별 지수는 농축수산물, 공업 제품, 서비스 등 품목의 특성에 따라 분류되며, 최대 16개의 세부 품목군으로 나뉜다. 예를 들어, ‘쌀’은 지출 목적별 분류상 “빵 및 곡물” → “식료품” → “식료품 및 비주류 음료”로 상위 품목군에 가중 합산되며, 품목 성질별로는 “곡물” → “농축수산물” → “상품” 지수에 반영된다.

3) 이 절에서 소개하는 소비자물가지수 통계의 특성은 2001년부터 2024년까지의 월별 데이터를 기준으로 한다.

〈Figure 2〉 Distribution of Price Changes(YoY, %) for All CPI Items




Source: KOSIS

〈Figure 2〉는 전년 동월 대비 CPI 상승률과 458개 개별 품목의 전년 대비 가격 변동률의 중위값(median), 25% 및 75% 백분위값을 함께 제시한다. CPI 상승률과 품목별 중위값은 대체로 2% 내외에서 움직이는 경향을 보이지만, 25% 및 75% 백분위값 간의 간극은 세부 품목 단위에서 상당한 변동성이 존재함을 시사한다.

이러한 개별 품목들의 가격 움직임 특성을 보다 명확히 파악하기 위해, 소비자물가지수 상승률을 식료품, 에너지, 집세 등 여섯 가지 대분류 항목으로 구분하여 살펴해보았다. 〈Figure 3〉에서 확인할 수 있듯이, 품목군별 가격 변화 양상은 뚜렷한 차이를 보인다. 상품, 특히 에너지와 식료품은 서비스에 비해 전반적으로 더 큰 가격 변동을 보이는 경향이 있다. 반면, 서비스는 비교적 안정적인 흐름을 나타내지만, 세부적으로는 부동산 경기의 영향을 크게 받는 집세, 정부 정책에 따라 조정되

〈Figure 3〉 Changes in Inflation Rates(YoY, %) of Major CPI Item Groups



Source: KOSIS

Source: KOSIS

는 공공서비스, 그리고 전반적인 경기 상황에 민감한 개인 서비스 등 각 항목별로 상이한 추세로 움직인다.

중·장기적으로 소비 바스켓 전체의 가격 수준은 총수요와 총공급의 상호작용에 따라 결정된다. 이는 특정 품목의 가격 변동이 발생하더라도, 상대가격 조정을 통해 수요가 재배분되고 새로운 균형이 형성되기 때문이다. 반면, 단기적으로는 소비 패턴의 경직성, 대체재 탐색의 지연 등으로 인해 개별 품목에 발생한 충격이 가격에 직접적으로 반영되는 경향이 있다.

예를 들어, 기상이변이나 국제 유가 급등은 관련 품목에 대한 공급 충격으로 작용하여 농산물이나 유류 가격에 국지적 변화를 초래하고, 이는 단기적으로 전체 물가에도 영향을 미친다. 중·장기적으로는 소비자들의 상대가격 변화에 따른 지출 패턴 조정이 이루어지면서 가격 충격이 완화되지만, 단기적으로는 이러한 특정부문의 충격이 소비자물가지수에 직접적 영향을 미치는 양상이 관찰된다.

〈Table 1〉 Summary Statistics of YoY CPI Inflation Rates
for Level 4 COICOP Subcategories (71 categories)

Subcategories	Mean	SD	Skew	Kurt	Min	Max
Tobacco	5.6	16.3	3.7	15.9	-0.3	77.8
Vegetables and seaweed	5.5	15.3	0.9	5.7	-26.7	82.7
Other fuels and energy	5.8	14.1	0.8	4.4	-26.5	54.1
Fruits	5.8	13.2	0.2	2.4	-22.3	38.3
Fuels and lubricants for personal transport equipment	2.3	11.5	0.2	3.5	-26.6	38.3
Gas	4.0	10.5	0.0	3.8	-20.7	34.6
Edible oils and fats	5.1	9.8	1.5	5.1	-9.9	36.9
Kindergarten and primary education	1.0	9.4	-1.3	3.9	-25.2	10.2
Telephone and telefax equipment	-6.0	9.3	-0.8	3.8	-33.4	28.8
Other personal goods	6.5	7.5	1.8	6.7	-5.9	38.0
Information processing equipment	-4.6	6.9	-0.3	2.8	-20.4	12.5
Electricity	1.4	6.6	1.6	9.0	-17.6	29.4
Milk, cheese and eggs	4.3	6.6	1.2	4.8	-10.7	25.2
Air and water passenger transport	2.8	6.4	-0.1	3.4	-15.6	21.7
Other food products	4.9	6.4	1.6	6.3	-5.0	30.3
Meat	4.6	6.3	0.4	3.2	-10.9	24.7

Subcategories	Mean	SD	Skew	Kurt	Min	Max
Audio-visual equipment	-7.2	5.8	-0.8	3.3	-24.8	4.7
Medical services	2.8	5.6	5.3	33.3	-6.3	40.0
Hospital services	2.3	5.5	3.7	17.5	-4.2	28.1
Newspapers and periodicals	3.0	5.5	1.8	4.9	-2.6	21.6
Confectionery, ice cream, and sugar	4.3	5.4	2.0	7.9	-4.6	26.7
Other services	3.0	5.1	-2.3	9.5	-17.3	9.4
Package holidays	2.0	5.1	0.0	2.7	-11.8	15.8
Rail passenger transport	3.5	5.0	1.3	3.5	-1.1	17.7
Postal services	3.1	4.6	0.9	2.1	0.0	12.8
...	...	...	...	...	...	...
...	...	...	...	...	...	...
Casual clothing	3.1	2.3	0.3	2.6	-1.4	9.4
Other recreational goods	1.6	2.2	0.7	4.3	-5.1	9.8
Maintenance and repair of the dwelling	3.8	2.2	0.9	3.5	-0.4	10.2
Spare parts and accessories for personal transport equipment; maintenance and repair	2.4	2.2	1.1	3.7	-0.4	9.3
Alcoholic beverages	1.9	2.1	0.5	2.5	-2.3	6.8
Hairdressing and personal grooming services	3.0	2.0	0.5	3.1	-1.3	9.2
Medical products and therapeutic equipment	0.7	1.9	-1.1	7.5	-8.8	6.7
Transport equipment	0.7	1.9	0.0	3.2	-5.0	5.3
Books	2.5	1.7	0.2	2.8	-1.3	7.0
Food services	2.9	1.7	1.4	5.1	0.3	9.0
Other clothing and clothing accessories	1.5	1.7	0.7	4.1	-3.4	8.4
Other housing-related services	4.1	1.7	0.5	4.6	-1.0	10.9
Rent	1.9	1.6	0.7	3.1	-0.6	6.1
Medicines	0.9	1.4	-0.1	4.4	-4.2	4.9
Adult education and other education	2.7	1.4	0.5	3.6	-0.9	6.8
Recreational and sporting services	1.8	1.3	1.2	4.3	-1.1	5.7
Private tutoring and supplementary education	3.0	1.2	0.5	2.1	1.2	5.8
Cultural services	1.4	1.0	0.1	3.7	-1.4	4.0


〈Table 1〉은 지출 목적별 소비자물가지수의 4단계 세분 품목군(총 71개)에 대한 기초 통계량을 제시한다.⁴⁾ 각 품목의 연평균 가격 상승률, 표준편차, 왜도, 첨도

4) 지면상의 한계로 4단계 품목군 일부의 기초통계량을 제공한다. 4단계 전체 및 5단계 품목군의 통계량은 저자에게 요청하기 바란다.

등을 살펴보면, 품목별로 가격 특성이 상당히 상이함을 확인할 수 있다. 예컨대, 2001년 이후 연평균 상승률이 6%를 상회한 품목군으로는 과일, 채소, 에너지, 담배 등이 있으며, 반대로 정보처리기기, 전화 및 팩스 장비, 영상·음향 기기 등은 연평균 5% 이상의 하락세를 나타냈다.

가격 변동성 측면에서 농산물 및 에너지 관련 품목군이 높은 표준편차를 기록하였으며, 정부 정책에 따라 일회적으로 가격이 크게 조정된 담배 역시 예외적으로 높은 변동성을 나타냈다. 이에 비해 오락·스포츠 서비스, 학원·보습 교육, 문화 서비스 등이 상대적으로 낮은 변동성을 보였으며, 이들 품목군의 표준편차는 고변동 품목군의 10% 미만 수준에 그쳤다. 아울러 왜도와 첨도 역시 품목별로 큰 차이를 보여, 품목군별 가격 분포가 전반적으로 이질적인 특성을 지님을 시사한다.

〈Figure 4〉 Distribution of Price Changes(YoY, %) Across Detailed CPI Groups by Classification Level



Note: The box represents the distribution of price change rates for each classification level (from the first to the third quartile), the central line indicates the median, the whiskers denote the normal range ($1.5 \times \text{IQR}$), and the dots represent outliers.

이처럼 품목 간 이질적인 가격 특성은 상위 수준으로 가중 합산되는 과정에서 상쇄되며, 결과적으로 전체 CPI의 가격 변동성은 세부 품목군에 비해 낮아지는 경향을 보인다. 〈Figure 4〉는 지수 분류 단계별로 세분 품목군의 가격 상승률 분포를 시각화한 결과로, 품목군이 상위 단계로 통합될수록 가격 상승률의 변동성이 현저히 감소하는 패턴을 확인할 수 있다.

이러한 분석을 종합해보면, 하위 단계 품목군에서는 품목 간 가격 변화의 이질성이 크고 변동성 또한 높은 반면, 상위 단계로 통합될수록 이러한 특성은 점차 완화되는 경향을 보인다. 이는 가중평균 집계 과정에서 상이한 가격 흐름이 상쇄되기 때문이다. 다만, 앞서 〈Figure 3〉에서 확인한 바와 같이, 품목의 성격에 따라 일부 대분류 품목군은 통합 이후에도 고유한 시계열적 특성을 지속적으로 유지하는 것으로 나타난다.

IV. 예측기법, 데이터 및 평가방식

1. 상향식 전망 방식 소개

앞서 간략히 소개한 것처럼 상향식 물가전망은 물가지수 하위품목 단위에서 가격 변화를 예측한 후 가중합산하여 headline 인플레이션을 예측하는 방식이다. 상향식 예측 방식을 직접 예측 방식과 비교하여 수식으로 표현하면 다음과 같다.

$$\text{직접 예측 : } \hat{\pi}_{t+h}^D = f(I_t) \quad (1)$$

$$\text{상향식 예측 : } \hat{\pi}_{t+h}^B = \sum_{i=1}^M W_{i,t} \hat{\pi}_{i,t+h} \quad (2)$$

$$\hat{\pi}_{i,t+h} = f_i(I_t) \quad (3)$$

여기서 $\hat{\pi}_{t+h}^D$ 는 $t+h$ 시점의 headline 인플레이션에 대한 직접 예측치, $\hat{\pi}_{i,t+h}$ 는 i 품목군 가격상승률 예측치, $\hat{\pi}_{t+h}^B$ 는 품목별 예측치를 가중합산한 headline 인플레이션 예측치(상향식 예측치)이다. $W_{i,t}$ 는 i 품목군의 소비자물가지수 가중치, M 은 품목군 수, I_t 는 t 시점에 가용한 정보집합이다.

각 품목군별 물가 예측에는 한희준(2023; 2024)에서 사용된 보루타-랜덤포레스트 알고리즘을 활용하였다.⁵⁾ 본 연구의 보루타-랜덤포레스트를 통한 예측에는 한

5) 한희준(2023)은 우리나라 소비자물가지수의 단기 예측에 있어 보루타-랜덤포레스트 모형이 다른 머신러닝 및 시계열 모형보다 예측력이 우수하다는 것을 보였다. 실행한 예측 및 예측 평가 등은 한희준(2024)에서 제공하는 코드를 활용하였으며, R 프로그램에 공개된 패키지

희준(2023; 2024)과 동일하게 R의 Boruta 및 randomForest 패키지에서 제공하는 기본 하이퍼파라미터(default hyperparameters)를 사용하였다.⁶⁾ 예측 과정은 예측 변수가 주어졌을 때, 보루타 셀렉션(Boruta selection)을 이용해 전체 설명변수 중 해당 예측변수와 관련된 중요 변수들을 식별하고, 선정된 변수들에 대해 랜덤포레스트 알고리즘을 적용하여 품목군별 물가지수를 예측하는 순서로 이루어진다.⁷⁾ 구축된 예측모형은 headline 인플레이션의 수준을 직접적으로 맞추는 데 초점을 두기 보다는, 개별 하위 품목군의 가격상승률과 실적치 간 오차를 최소화함으로써 전체 인플레이션 예측의 정확도를 개선하는 데 중점을 둔다.

세부품목군 중 전기·도시가스요금과 같은 공공요금, 세금으로 인한 변동이 큰 석유류 품목 등은 가격의 변화가 뉴스 변수⁸⁾를 통해 사전에 일부 예측될 수 있음에도 데이터 상에서 조정 빈도가 낮고 무작위성이 커 머신러닝 기법을 통한 학습 및 예측이 어려운 점을 발견하였다.⁹⁾ 이 문제를 해결하고 예측력을 높이기 위해, 주요 공공요금 품목군의 뉴스 변수에 대해 우선 선형회귀를 실시한 뒤, 그 잔차 부분만을 머신러닝 기법으로 예측하였다. 이 방법의 구체적인 절차는 <부록 1>『공공요금 관련 뉴스 변수 및 분석 방식』에서 확인할 수 있다. 또한 <부록 1>에는 공공요금 변수와 해당 선형회귀 절차를 포함하지 않은 경우의 예측력을 주요 결과와 비교한 요소제거 실험(ablation test) 결과도 함께 제시하였다. 비교를 위한 시계열 모형으로는 랜덤워크(RW) 모형과 자기회귀(AR(2)) 모형을 사용하였다.

(Package)를 사용하였다.

- 6) 구체적으로, randomForest는 $n_{tree} = 500$, $m_{try} = \sqrt{p}$ (분류) 또는 $p/3$ (회귀), $replace = TRUE$, $nodesize = 1$ (분류) / 5 (회귀)의 기본값을 적용하였다. Boruta 알고리즘은 $n_{tree} = 500$, $maxRuns = 100$, $doTrace = 0$ 을 사용하였으며, 변수 중요도 산출에는 `getImpRfZ` 함수를 적용하였다. `seed_number`는 42를 사용하였다.
- 7) Kim and Han (2022)의 실증 분석 결과에 따르면, 보루타로 선별된 최적 개수의 변수만을 사용할 경우, 전체 설명변수를 모두 활용한 경우보다 예측 성능이 유의하게 개선되는 것으로 나타났다.
- 8) 전기·도시가스요금, 유류세, 대중교통요금 등 공공요금은 변경 1~2달 전 뉴스나 정부 정책 발표 등으로 시점 및 크기가 거의 정확하게 예측된다. 발표되는 정책 및 뉴스를 기반으로 공공요금 품목 관련 뉴스지수를 작성하고 변수목록에 포함시켰다.
- 9) Medeiros et al. (2021)은 관리물가(monitored prices) 품목들이 수요·공급 여건보다는 정부의 정책결정에 따라 예상치 못한 가격변동에 노출되어 있어 머신러닝 기법으로 예측하기 어렵다고 평가하며, 이들 품목에 대한 머신러닝 예측력은 단순한 AR모형보다 우수하지 않다고 분석하였다.

2. 상향식 전망을 위한 세부 품목군 설정

상향식 예측방식을 위해서는 소비자물가지수를 하위 품목군으로 구분하는 절차가 필요하다. 이를 위해 총지수를 우선 근원물가와 비근원물가 품목으로 구분한 후 소비자물가 통계의 상품분류별 대분류 기준을 이용하였다. 각 품목군에서 가중치가 크거나 미시 데이터가 가용한 품목군들을 추가적으로 분류하여 이들 물가지수를 예측변수로 설정하는 방식을 채택하였다. 세분화에 따른 예측 정확도를 비교하기 위해 <Table 2>와 같이 세분화 정도를 1단계(총지수)부터 6단계(33개 품목군)까지 세분화하였다.¹⁰⁾

<Table 2> Structure of Item Grouping by Classification Level

Level 1	Level 2	Level 3 (9 items)	Level 4 (23 items)	Level 5 (30 items)	Level 6 (33 items)
Head line	Core	Durable goods	Motor vehicles	Motor vehicles	Motor vehicles
			Excl. motor vehicles	Excl. motor vehicles	Excl. motor vehicles
		Textile products	Textile products	Textile products	Textile products
		Rent	Rent	Jeonse (lump-sum deposit lease)	Jeonse (lump-sum deposit lease)
				Monthly rent	Monthly rent
		Public services	Public services	Public services ¹⁾	Public services ¹⁾
				Public services ²⁾	Public services ²⁾
		Eating out	Eating out	Eating out	Eating out
		Personal services excl. eating out	Personal services excl. eating out	Personal services excl. eating out	Personal services excl. eating out
		Other core goods	Publications	Publications	Publications
			Medicines	Dispensed drugs	Dispensed drugs
				Medicines excl. dispensed drugs	Medicines excl. dispensed drugs
			Cosmetics	Cosmetics	Cosmetics

10) 단계별 구성 품목군에 대한 좀더 자세한 설명은 <부록 2>에서 확인할 수 있다.

Level 1	Level 2	Level 3 (9 items)	Level 4 (23 items)	Level 5 (30 items)	Level 6 (33 items)
Head line	Core	Other core goods	Other industrial goods	Other industrial goods	Other industrial goods
			Core processed food	Core processed food	Core processed food
			Flowers & Ginseng	Flowers & Ginseng	Flowers & Ginseng
			Water Supply	Water Supply	Water Supply
	Non- Core	Food	Non-core processed food	Non-core processed food	Non-core processed food
			Other agricultural products excl. flowers & ginseng	Other agricultural products excl. flowers & ginseng	Other agricultural products excl. flowers & ginseng
			Cereals	Cereals	Rice Cereals excl. rice
			Vegetables	Vegetables	Napa cabbage, Tomato, Garlic Other vegetables
			Fruits	Fruits	Apple, Grape, Tangerine, Strawberry Other Fruits
			Livestock products	Livestock products	Livestock products
			Fishery products	Fishery products	Fishery products
		Energy	Electricity, Gas & Heating	Electricity	Electricity
				Gas	Gas
				District heating	District heating
			Petroleum products	Gasoline	Gasoline
				Diesel	Diesel
				Petroleum products excl. gasoline & diesel	Petroleum products excl. gasoline & diesel

Note: 1) Outpatient care services, Mobile phone services, Hospital services, Intracity bus fare
2) Public services excluding public services 1

하위단계 품목군의 물가를 예측한 후 전체 인플레이션을 도출하기 위해, 소비자 물가지수의 품목별 가중치를 활용하여 예측값을 합산하였다. 소비자물가지수는 총 458개 세부 품목으로 구성되어 있어 예측 모형을 해당 수준까지 세분화하여 설정할 수도 있다. 그러나 30개 품목군 이상으로 세분화할 경우, 예측오차가 개선되지 않았을 뿐 아니라, 가중치가 낮은 품목들이 소비자 바스켓에서 빈번히 포함·제외되면서 시계열의 연속성이 저해되어 머신러닝 학습 및 합산 과정에 어려움이 발생하였다. 품목군을 별도로 재분류하지 않고, 통계청이 발표하는 소비자물가지수의 공식 하위 분류 체계를 그대로 사용하는 방법도 고려할 수 있다. 예를 들어, 통계청의 지출목적별 4단계(71개) 품목군을 활용하여 상향식 머신러닝 기법을 적용해본 결과, 본고에서 설정한 30개 품목군 기반 예측모형보다 낮은 예측력을 보였다.¹¹⁾

3. 데이터

본 연구에서는 2005년 1월부터 2024년 6월까지의 전월대비 품목군별 가격 변화율(품목별 가격 지수의 전월 대비 로그차분)을 종속변수로 사용하였다. 설명변수로 는 소비자·수출입·생산자물가지수, 실업률, 경기종합지수, 환율, 주가, 유가 등 국내·외 주요 거시변수와 함께 세부 품목별 물가지수, 주유소 판매가격, 국제식량 가격지수, 지역별 기후 관련 변수(기온, 강수량) 등 미시변수들도 포함하였다. 또한, 공공요금, 유류세 등 사전적으로 가격변화를 일부 예측할 수 있는 품목군에 대해서는 뉴스에 기반한 지수를 생성하여 반영하였다. 최종적으로 593개의 변수를 선정하고, 시차 영향을 고려하여 해당 변수의 과거 3개월간¹²⁾ 시차 변수까지 더해 총 2,372개의 설명변수를 활용하였다. 모든 설명변수는 정상시계열(stationary time series)로 변환하였으며, 자세한 설명변수 목록 및 설명변수별 변환방식은 〈부록 3〉「설명변수 목록」을 참조하기 바란다. 본 연구에서는 각 예측 시점에 이용 가능한

11) 본 연구에서는 현재 설정한 품목군 단계가 최적으로 나타났으나, 이는 절대적인 기준은 아니다. 향후 시계열 데이터가 추가되거나 품목별 가격 변동을 설명할 수 있는 미시데이터가 확충될 경우, 최적의 품목군 설정은 변경될 수 있다.

12) 보루타-랜덤포레스트 예측을 사용한 한희준(2023)의 방식을 따라 당월을 포함하여 총 4개 시차를 사용하였다. 보루타 알고리즘으로 선택되는 변수는 대부분 당월 및 과거 2개월까지의 변수로 확인되며, 과거 11개월간의 시차를 모두 포함해 보더라도 예측력이 유의하게 개선되지 않았다.

모든 데이터를 누적적으로 학습하여 예측을 수행하는 재귀적(recursive) 예측 방식을 채택하였다. 관련 연구에서는 통상적으로 일정 기간의 자료만을 활용하는 롤링(rolling) 윈도우를 사용하기도 하나, 일부 세부 품목 단위의 물가상승률은 변동 빈도가 낮거나 특정 시기에만 변동이 발생하는 경우가 많다. 이러한 특성에서 롤링 방식은 학습 정보의 손실과 단기 변동성에 대한 과도한 반응을 초래할 수 있다. 반면 재귀적 방식은 표본이 누적될수록 학습 정보가 확장되어 모형의 일관성과 안정성을 높이고, 가격 변화가 드문 품목의 변동을 보다 충실히 반영할 수 있다. 또한 세부 품목별 전년동기대비 물가상승률은 분석 기간 중 구조적 변동이 크지 않아, 재귀적 학습이 시계열의 장기 패턴을 안정적으로 포착하는 데 유리하다. 이러한 이유로 본 연구는 단기 물가예측의 실무적 효율성과 데이터 특성을 함께 고려하여 재귀적 예측 방식을 기본 구조로 설정하였다.

4. 예측력 평가방식

전체 데이터는 2005년 1월부터 2024년 6월까지의 월간 시계열로 구성되어 있다. 일반적으로 시계열 분석 및 머신러닝 기반 학습에서는 가능한 한 긴 데이터 시계를 활용하는 것이 유리하나, 설명변수의 가용 범위에 따라 활용 가능한 시점이 제한될 수 있다. 이에 본 연구는 주택매매지수, 지역 난방비 등 주요 설명변수와 종속변수가 모두 확보되는 시점부터 데이터를 사용하였다.

예측 평가 기간은 장기 예측력을 검토하기 위해 2014년 1월부터 2024년 6월까지로 설정하였다. 이 기간의 월별 소비자물가 상승률(전년 동월 대비)의 실적치를, 표본 외 예측으로 도출된 당월, 익월, 및 익익월 전망치와 비교하였다.¹³⁾ 예측 정확도 평가는 평균절대오차(Mean Absolute Error)와 평균제곱오차(Mean Squared Error)를 기준으로 측정하였다.

13) 예측에는 Medeiros et al. (2021)과 한희준(2023; 2024) 등 선행연구를 따라 전월대비 예측치를 산출하였다. 다만 인플레이션 지표로는 전년동월대비 물가상승률이 일반적으로 사용되므로, 전월대비 예측치를 전년동월대비 기준으로 변환한 후 실제 값과 비교하여 예측력을 평가하였다.

$$MAE = \frac{\sum_{t=1}^N |\pi_t - \hat{\pi}_t|}{N} \quad (4)$$

$$MSE = \frac{\sum_{t=1}^N (\pi_t - \hat{\pi}_t)^2}{N} \quad (5)$$

또한, 한희준(2023)에서 모형 간 예측력 비교에 사용된 Giacomini-White (2006) 검정 방법을 활용하여¹⁴⁾, 본 연구는 서로 다른 세분화 수준 간의 예측 성능 차이를 검토하였으며, 이를 일반 시계열 모형과의 예측력과의 비교하였다.

$$(\text{귀무가설}) \quad H_0 : E[L_{t+\tau}(\pi_{t+\tau}, \hat{\pi}_{t+\tau}^A) - L_{t+\tau}(\pi_{t+\tau}, \hat{\pi}_{t+\tau}^B) \mid G_t] = 0 \quad (6)$$

이 검정법은 t 시점의 정보(G_t)에 기반한 A모형의 예측오차($L_{t+\tau}(\pi_{t+\tau}, \hat{\pi}_{t+\tau}^A)$)가 B모형의 예측오차($L_{t+\tau}(\pi_{t+\tau}, \hat{\pi}_{t+\tau}^B)$)와 차이가 없다는 귀무가설(H_0)을 기각할 수 있는지를 점검한다.

V. 예측력 평가 및 주요 결과

앞서 서술한 방식으로 t 시점에서 당월(t), 익월($t+1$), 익익월($t+2$) 예측을 실시하였다.¹⁵⁾ 당월 예측에는 변수별 발표시점 차이로 인해 ‘ragged edge’ 문제¹⁶⁾가 발생하므로, t 시점에 발표된 변수는 실제 관측값을 사용하고, 미발표 변수는 직전 월($t-1$)의 값을 대체값으로 활용하였다.

14) Medeiros et al. (2021), 한희준(2024)과 같이 무조건부(Unconditional) Giacomini-White 검정을 실시하였다.

15) 한국의 소비자물가지수(CPI)는 대부분 해당 월 말일에 발표되며, 통계 발표 이전에 t 월의 물가상승률을 예측하는 것은 nowcasting에 해당한다. nowcasting은 같은 달 내에서도 수행 시점에 따라 이용 가능한 정보의 범위가 달라지므로, 예측력에도 차이가 발생할 수 있다. 이러한 시점별 예측력의 변화를 다음 〈Table 4〉에서 제시하였다.

16) 변수별 통계의 발표 시점이 상이하여 일부 최신 정보가 예측 시점별로 불균등하게 반영되는 현상이다.

예측력 평가를 위해 모형 및 세분화 수준별로 예측오차를 비교해 보았다. 세분화 수준은 예측 성능에 직접적인 영향을 미치는 요소로, 일종의 모형 선택(model selection) 차원을 내포한다. 본 연구에서는 세분화 수준을 외생적으로 고정하기보다, 다양한 수준 간의 예측력 차이를 실증적으로 비교함으로써 현실적인 예측 구조를 탐색하고자 하였다.¹⁷⁾

〈Table 3〉은 당월 전망(당월 20일경) 및 익월 전망에 대한 모형별 예측치의 평균 절대오차(MAE) 및 평균제곱오차(MSE)를 보여주고 있다. 우선 MAE 기준으로 당월 예측치를 살펴보면, BR 모형의 경우 직접 예측치 및 상향식 예측치 모두 AR 및 RW 모형에 비해 예측오차가 작다.¹⁸⁾ BR 모형 내에서는 품목 세분화 단계가 높은 상향식 예측일수록 예측력이 개선된다는 점이 확인된다. 하지만 6단계(33개 품목군)에서는 예측오차가 오히려 약간 커지는 것으로 나타난다. 그 결과 5단계(30개) 품목군을 보루타-랜덤포레스트 모형(BR)으로 예측한 후 이를 가중합계하는 상향식 기법의 예측력이 가장 우수한 것으로 확인되었다. 구체적으로 당월 전망의 경우 5단계로 세분화된 품목군별로 물가를 예측한 후 가중합산하는 방식의 MAE가 0.141%p로 나타나 직접 총지수를 전망하는 방식(1단계)에 비해 예측오차가 27% 가량 낮은 것으로 나타난다. 팬데믹 이후 기간(2021년 이후)에서는 당월 예측력이 더욱 개선되어 5단계 상향식의 MAE가 0.136%p로 직접 예측방식보다 오차를 26% 정도 줄일 수 있는 것으로 나타났다.

17) 익명의 심사위원께서는 세분화 수준을 사전에 최적화하는 절차의 필요성을 조언해 주셨으며, ‘세분화 수준에 대한 모형 불확실성(model uncertainty)’이 엄밀한 예측모형 설정 측면에서 중요한 논점이라는 점에 동의한다. 이에 대한 점검을 위해, 표본을 사전 선택 구간(2020년 이전)과 외부 검증 구간(2021 - 2024)으로 구분한 후 세분화 수준별 예측력을 점검하였다. 그 결과, 2020년 이전 구간에서 5단계가 최적 세분화 모형으로 결정되었으며, 이후 검증 구간에 서도 일관되게 우수한 성능을 보이는 것으로 나타났다.

18) 이는 한희준(2023)에서 확인된 결과와 일치한다.

〈Table 3〉 Forecast Errors by Model and Classification Level¹⁾²⁾

(단위: %p)

Model			Boruta - Random Forest(BR)						Auto-regressive [AR] ²⁾		Random Walk [RW] ²⁾	
Classification Level			Lv. 1	Lv. 2	Lv. 3	Lv. 4	Lv. 5	Lv. 6	Lv. 1	Lv. 6	Lv. 1	Lv. 6
M A E	Now-casting ³⁾	Full Sample	0.194	0.188	0.172	0.155	0.141	0.142	0.264	0.243	0.328	0.330
		Recent (2021 ~)	0.184	0.167	0.156	0.149	0.136	0.136	0.242	0.229	0.277	0.273
	1-Month-Ahead	Full Sample	0.227	0.226	0.209	0.205	0.188	0.189	0.264	0.243	0.328	0.330
		Recent (2021 ~)	0.221	0.223	0.212	0.219	0.201	0.203	0.242	0.229	0.277	0.273
M S E	Now-casting ³⁾	Full Sample	0.061	0.059	0.051	0.042	0.036	0.037	0.108	0.098	0.169	0.173
		Recent (2021 ~)	0.059	0.051	0.046	0.038	0.035	0.036	0.097	0.100	0.123	0.122
	1-Month-Ahead	Full Sample	0.083	0.080	0.069	0.068	0.062	0.062	0.108	0.098	0.169	0.173
		Recent (2021 ~)	0.079	0.081	0.073	0.073	0.070	0.072	0.097	0.100	0.123	0.122

Note: 1) Green shading denotes the lowest forecast error.

2) The AR and RW models use only data up to the previous month and no exogenous variables, so their information sets do not differ by forecast point. Accordingly, the two forecasts and their errors are identical.


3) Forecast produced as of the 20th day of the month.

〈Figure 5〉는 2018년 1월 이후 직접 예측방식과 상향식 예측방식 당월 예측 기준 MAE를 월별로 비교한 결과를 보여준다. 대부분의 시점에서 상향식 예측방식의 오차가 더 낮게 나타났으며, 이는 상향식 방식의 낮은 평균 오차가 특정 시점에 집중된 성과에 기인한 것이 아니라 전반적으로 더 우수한 예측력을 나타냄을 시사한다. 앞선 결과들은 예측오차를 제곱평균오차(MSE)로 측정하더라도 유사하게 나타난다.

또한 상향식 모형의 당월 예측오차는 시장 서베이나 기존 연구의 머신러닝 예측치에 비해서도 50~75% 정도 작은 것으로 확인된다. 기존 머신러닝 기반 직접 예측식 인플레이션 모형은 예측오차(MAE)¹⁹⁾가 예측 시계 및 평가 기간 등에 따라

다소 차이가 있지만 당월의 경우 0.25~0.30%p 정도이며, 시장·전문가의 당월 예측오차는 0.20~0.35%p 수준으로 본고의 상향식 모형(5단계: 0.14~0.19%p)의 예측오차에 비해 상당폭 큰 수준이다.

〈Figure 5〉 Nowcasting Errors(MAE, %p) by Forecasting Method



익월 전망의 경우에도 품목 세분화 단계가 높은 상향식 예측일수록 예측력이 개선되다가 6단계(33개 품목군)에서는 예측오차가 오히려 약간 커졌다. 5단계로 세분화된 품목군별로 물가를 예측한 후 가중합산하는 방식의 MAE가 0.188%p(2021년 이후 0.201%p)로 나타나 직접 총지수를 전망하는 방식(1단계)에 비해 예측오차가 17%(9%) 가량 낮은 것으로 나타났다. 다만 개선의 정도는 당월 예측에 비해서는 낮은 편이었다. 앞서와 마찬가지로 이러한 결과는 예측오차를 제곱평균오차(MSE)로 측정하더라도 유사하게 나타났다.

비교적 단순한 시계열 모형을 활용할 경우 상향식 접근법을 적용하더라도 예측오차의 개선은 유의미하게 나타나지 않았다. RW 모형 기반의 상향식 예측오차는 0.33%p 수준으로 총지수에 대한 직접 예측오차와 비슷한 수준이다. AR 모형 기반의 경우에는 상향식 접근을 통해 예측오차가 0.26%p에서 0.24%p로 소폭 감소하

19) 연구자에 따라 예측력 평가 기간이 다소 차이가 있지만 MAE로 본 예측오차가 한희준(2023)의 경우 1개월 앞 기준 0.22%p, 이창훈 외(2024)는 당월 기준 0.25~0.30%p, 수준으로 보고하고 있다. 시장 인플레이션 예측치(investing.com, 당월)의 MAE는 0.30~0.35%p, 전문가서베이(Bloomberg, 당월) 중위값 MAE는 0.20%p로 나타난다.

는 것으로 나타났다. 이러한 결과는 단순 시계열 모형과 상향식 방식을 결합한 기존 해외 연구와도 일치한다. 이러한 결과는 상향식 접근 자체보다는, 해당 방식이 머신러닝 기법과 결합될 때 예측력 개선 효과가 보다 뚜렷하게 나타난다는 점을 시사한다. 한편, 〈Table 3〉에서 AR 및 RW 모형의 당월과 익월 예측오차가 동일하게 나타나는 것은 모형의 구조적 특성에 기인한다. 두 모형은 모두 품목별 인플레이션의 과거 수치만을 사용하기 때문에, 당월 예측(예: 3월 중순 시점의 3월 물가 예측)과 익월 예측(2월 말 시점의 3월 물가 예측) 모두 동일한 2월까지의 데이터를 이용하게 된다. 따라서 결과 및 오차가 동일하게 산출된다.

다음으로, 상향식 방식으로 도출한 예측치의 오차를 예측 시점별로 비교하였다. 동일한 시점에 대한 예측이라 하더라도, 예측을 수행한 시점에 따라 활용할 수 있는 정보량이 달라지므로 예측 시점에 따라 오차 수준에도 차이가 발생할 수 있다. 예를 들어 6월의 물가상승률을 예측할 경우 5월 말이나 6월 초에는 대부분의 지표가 5월 수준까지만 공개되어 있으나, 월이 진행될수록 6월의 산업활동, 무역, 유가 등 추가 자료가 순차적으로 반영되기 때문이다. 앞서 언급한 것처럼 이에 따르는 ‘ragged edge’ 문제는 해당 시점에 발표된 변수는 실제 관측값을 사용하고, 아직 발표되지 않은 변수는 직전월의 값을 대체값으로 활용하였다. 〈Table 4〉은 5단계 상향식 방식으로 도출한 예측치의 오차를 한 달 전, 월초, 월중순, 월말 등 예측 시점별로 비교한 결과를 보여준다. 분석 결과, 예측 오차는 전월 소비자물가 발표일 기준인 한 달 전 시점에서 상대적으로 크게 나타났으나, 소비자물가 발표일에 가까워질수록 추가 정보의 반영에 따라 점진적으로 감소하는 경향을 보였다. 다만, 월중순(20일경) 이후에는 예측 정확도의 개선 폭이 제한적인 것으로 나타났다. 이러한 현상은 월중순 이후에도 경제지표가 일부 업데이트되지만, 소비자물가통계 자체가 월 중하순까지의 데이터를 바탕으로 산출되기 때문으로 해석된다. 즉, 이후에 입수된 정보는 이미 마감된 조사 시점 이후의 자료로써, 당월 소비자물가지수 예측에 미치는 영향이 제한적인 것으로 판단된다. 가령, 월 후반부에 유가나 기타 가격 지표가 추가로 확보되더라도, 소비자물가통계가 이미 집계된 이후이므로 공식 지표에 직접 반영되기 어렵다. 이러한 점을 고려할 때, 정확한 소비자물가지수 나우캐스팅(nowcasting)을 위해서는 월중순 시점에 확보된 정보를 바탕으로 한 예측이 가장 효율적일 가능성이 높다.

〈Table 4〉 MAE by Forecast Timing¹⁾

(단위: %, %p)

		1-Month -Ahead	Nowcasting (Early Month)	Nowcasting (Mid Month)	Nowcasting (Late Month)
Full Sample	BR (Lv. 5, A)	0.19	0.15	0.14	0.14
	BR (Lv. 1, B)	0.23	0.20	0.19	0.19
	(B-A)	0.04	0.05	0.05	0.05
Recent (2021~)	BR (Lv. 5, C)	0.20	0.14	0.14	0.13
	BR (Lv. 1, D)	0.22	0.19	0.18	0.18
	(D-C)	0.02	0.05	0.04	0.05

Note: 1-Month Ahead refers to the CPI release date of the previous month; Nowcasting (Early Month) corresponds to around the 10th; Nowcasting (Mid Month) to around the 20th; and Nowcasting (Late Month) to the last day of the month.

한편, 동일한 예측 시점에서 전망 시계 (forecast horizon) 에 따른 예측 성과를 비교해 보면, 1단계 직접 예측 방식 대비 상향식 방식의 개선 효과는 예측 대상이 당월인 경우 가장 두드러졌다. 동일한 시점에서 한 달 후, 두 달 후 등 더 먼 미래를 예측하더라도 상향식 방식이 직접 예측 방식에 비해 여전히 더 나은 성과를 보였으나, 그 개선 폭은 점진적으로 축소되는 양상을 보였다(〈Table 5〉 참조).

〈Table 5〉 MAE by Forecast Horizon

(단위: %, %p)

	Nowcasting	1-Month-Ahead	2-Month-Ahead
BR (Lv. 1) [A]	0.19	0.22	0.40
BR (Lv. 2)	0.19	0.23	0.41
BR (Lv. 3)	0.17	0.21	0.40
BR (Lv. 4)	0.15	0.21	0.38
BR (Lv. 5) [B]	0.14	0.19	0.37
BR (Lv. 6)	0.14	0.19	0.37
[A]-[B]	0.05	0.03	0.03

〈Table 6〉은 모형 간 예측력 차이가 통계적으로 유의한지를 검증하는 Giacomini-White (GW) 테스트의 결과를 보여준다. 양수(+) 값은 B 모형의 예측오차가 A 모형보다 작음을 의미하며, 귀무가설이 기각될 경우 B 모형의 예측력이 A 모형보다 통계적으로 우수함을 나타낸다.

예를 들어, 5행 9열의 값(4.98)은 보루타-랜덤포레스트(BR) 방식을 활용한 1단계 직접 예측 방식(BR 1단계)과 6단계 상향식 예측 방식(BR 6단계) 간의 예측력 차이에 대한 통계값이다. 이 값은 BR 6단계 방식의 예측오차가 BR 1단계 방식보다 작으며, 1% 수준에서 ‘두 모형 간 예측력 차이가 없다’는 귀무가설(H_0)을 기각할 수 있음을 의미한다.

검증 결과에 따르면, BR 모형의 예측력이 기존 시계열 모형에 비해 통계적으로 유의하게 우수한 것으로 나타났다. 또한, BR 모형 내에서는 세분화 단계가 높아질수록 예측력이 개선되는 경향이 통계적으로 뒷받침된다. 다만, BR 6단계와 BR 5단계 모형 간의 예측력 차이는 통계적으로 유의하지 않았으며, BR 2단계와 BR 1단계 간의 예측오차 차이도 통계적으로 유의하지 않은 것으로 분석되었다.

〈Table 6〉 Giacomini - White Test Results by Model & Disaggregation Level (Nowcasting)¹⁾

Model B Model A	RW (Lv. 6)	AR (Lv. 1)	AR (Lv. 6)	BR (Lv. 1)	BR (Lv. 2)	BR (Lv. 3)	BR (Lv. 4)	BR (Lv. 5)	BR (Lv. 6)
RW (Lv. 1)	-0.35	3.62 ***	3.79 ***	6.21 ***	6.09 ***	6.62 ***	7.74 ***	8.35 ***	8.29 ***
RW (Lv. 6)		3.63 ***	3.74 ***	6.16 ***	6.09 ***	6.58 ***	7.63 ***	8.19 ***	8.14 ***
AR (Lv. 1)			1.88 *	5.67 ***	5.58 ***	6.21 ***	7.46 ***	8.02 ***	7.94 ***
AR (Lv. 6)				3.96 ***	4.23 ***	5.24 ***	6.55 ***	7.29 ***	7.36 ***
BR (Lv. 1)					0.87	2.84 ***	4.86 ***	5.11 ***	4.98 ***
BR (Lv. 2)						2.40 **	4.21 ***	4.72 ***	4.56 ***
BR (Lv. 3)							2.75 ***	3.62 ***	3.46 ***
BR (Lv. 4)								2.43 **	2.15 **
BR (Lv. 5)									-0.49

Note: 1) Forecast reference date is mid-month (around the 20th).

2) *, **, and *** denote statistical significance at the 10%, 5%, and 1% levels, respectively.

이는 30개 품목군(BR 5단계)의 가격상승률을 추정한 후 이를 합산하여 전체 인플레이션을 전망하는 상향식 방식이 가장 효율적이고 우수한 예측력을 제공함을 시사한다. 한편, RW 모형의 경우, 상향식 예측 결과와 직접 예측 결과 간 통계적으로 유의한 차이가 없었다. 반면, AR 모형에서는 6단계 세분화를 적용한 예측 방식이 소폭 우수하며, 10% 유의 수준에서 통계적으로 유의한 것으로 나타났다.

익월(다음 달) 예측에서도 Giacomini-White 검정 결과 BR 5단계 모형의 예측력이 가장 우수한 것으로 나타났으며, 당월 예측과 마찬가지로 5단계 이상 세분화할 경우 예측력 차이가 통계적으로 유의하지 않은 것으로 나타났다(〈Table 7〉 참조). 다만 예측 시계가 2개월 이상으로 확장될 경우 상향식 방식이 직접 예측 방식에 비해 소폭 예측오차는 작지만 통계적으로 유의한 정도는 아닌 것으로 나타났다(〈Table 8〉 참조). 특이하게도 예측 시계가 2개월인 경우 AR 모형의 경우 상향식 예측 방식의 예측결과가 통계적으로 유의하게 우수한 것으로 나타났다.

〈Table 7〉 Giacomini - White Test Results by Model & Disaggregation Level (1M-Ahead)¹⁾

Model B Model A	RW (Lv. 6)	AR (Lv. 1)	AR (Lv. 6)	BR (Lv. 1)	BR (Lv. 2)	BR (Lv. 3)	BR (Lv. 4)	BR (Lv. 5)	BR (Lv. 6)
RW (Lv. 1)	-0.35	3.62 ***	3.79 ***	4.40 ***	4.25 ***	5.09 ***	5.36 ***	6.02 ***	5.92 ***
RW (Lv. 6)		3.63 ***	3.74 ***	4.44 ***	4.26 ***	5.11 ***	5.34 ***	5.92 ***	5.85 ***
AR (Lv. 1)			1.88 *	2.99 ***	2.76 ***	4.00 ***	4.06 ***	4.97 ***	4.92 ***
AR (Lv. 6)				1.46	1.37	2.61 ***	2.87 ***	3.93 ***	3.89 ***
BR (Lv. 1)					0.19	2.59 ***	2.60 ***	3.50 ***	3.49 ***
BR (Lv. 2)						2.56 **	2.71 ***	3.60 ***	3.56 ***
BR (Lv. 3)							0.69	2.63 ***	2.64 ***
BR (Lv. 4)								2.87 ***	2.71 ***
BR (Lv. 5)									-0.31

Note: 1) *, **, and *** denote statistical significance at the 10%, 5%, and 1% levels, respectively.

〈Table 8〉Giacomini - White Test Results by Model & Disaggregation Level (2M-Ahead)¹⁾


Model B Model A	RW (Lv. 6)	AR (Lv. 1)	AR (Lv. 6)	BR (Lv. 1)	BR (Lv. 2)	BR (Lv. 3)	BR (Lv. 4)	BR (Lv. 5)	BR (Lv. 6)
RW (Lv. 1)	-1.53	2.62 ***	3.92 ***	5.10 ***	5.43 ***	6.07 ***	7.11 ***	5.68 ***	5.66 ***
RW (Lv. 6)		2.81 ***	4.06 ***	5.03 ***	5.43 ***	6.04 ***	7.05 ***	5.65 ***	5.62 ***
AR (Lv. 1)			4.46 ***	2.46 **	2.22 **	2.43 **	2.53 **	3.07 ***	3.15 ***
AR (Lv. 6)				0.70	0.35	0.83	1.20	1.42	1.46
BR (Lv. 1)					-1.13	0.33	1.13	1.50	1.55
BR (Lv. 2)						1.63	2.50 **	2.33 **	2.35 **
BR (Lv. 3)							1.82 *	1.22	1.21
BR (Lv. 4)								0.15	0.15
BR (Lv. 5)									0.02

Note: 1) *, **, and *** denote statistical significance at the 10%, 5%, and 1% levels, respectively.

예측의 정확성 외에도, 상향식 방식은 직접 예측 방식과 달리 품목군별 물가상승률 예측치를 도출할 수 있다는 장점을 가진다. 이를 통해 물가상승률 전망치를 제공하는 중앙은행 및 주요 연구기관들은 향후 인플레이션 동학을 보다 정교하게 이해할 수 있으며, 대중에게 예측 결과를 제시할 때에도 세부적인 설명과 예측의 근거 및 특이 요인을 효과적으로 전달하는 데 도움이 될 것으로 기대된다(〈Figure 6〉 참조).²⁰⁾

20) 유럽중앙은행의 경우, 현재 인플레이션 전망치를 Headline 및 근원 인플레이션뿐만 아니라, Energy, Food, Non-energy industrial goods, Services 등 하위 항목까지 포함하여 발표하고 있다.

〈Figure 6〉 Examples of Item-Level Price Change Forecasts




Note: 1) Dashed lines in the shaded area indicate forecasts.

Source: 이동재 · 위승현 (2024), p. 11

또한 이러한 방식은 정부와 민간기업의 의사결정에도 활용될 수 있는데, 특정 품목의 가격 변동 예측은 정책 수립이나 기업 전략 결정에 있어 중요한 참고자료로 기능하기 때문이다²¹⁾.

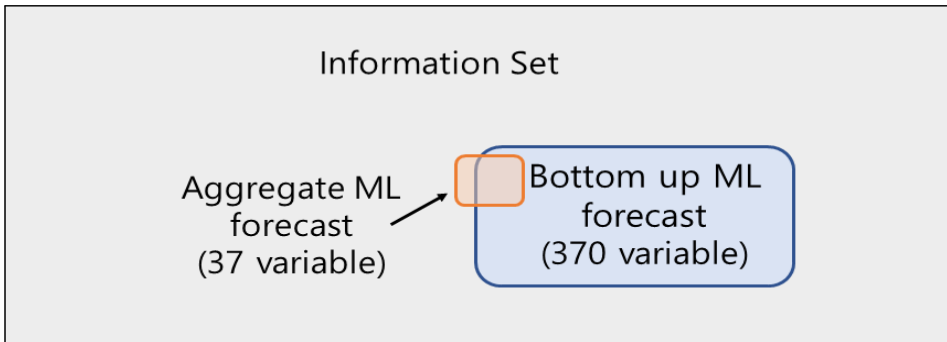
〈Figure 7〉 Subcomponent-Level Forecast Errors (MAE, %p)



21) 실제로 농림축산식품부는 농수산물 가격 전망의 정밀도를 높이기 위해 모형을 지속적으로 개선하고 예측 경진대회를 개최하는 등 품목 가격 예측에 많은 관심을 기울이고 있으며, 이러한 접근은 원자재 가격 예측 등 정책 분야 및 산업 현장에서도 적극적으로 활용되고 있는 것으로 알려져 있다.

〈Figure 7〉은 세부 품목군별 예측오차(MAE)를 보여준다.²²⁾ 농축수산물 및 식유류와 같이 변동성이 큰 비근원(non-core) 품목군의 오차가 상대적으로 크고, 근원 상품 및 서비스, 집세 등 근원 품목군과 비근원 품목 중 가공식품의 오차는 비교적 작은 것으로 나타났다. 비근원 품목 중에서는 유가 관련 에너지 품목들보다 농축수산물의 예측이 더 어려운 것으로 나타났다. 농축수산물 중에서도 예측이 어려운 기상 여건에 가장 큰 영향을 받는 채소 품목의 예측오차가 가장 컸으며, 수산물 및 곡물은 상대적으로 낮은 편이었다. 각 품목의 표준편차로 예측오차를 표준화하여 분석한 결과에서도 비근원 품목의 예측오차가 상대적으로 크게 나타나는 경향이 확인되었다. 이는 해당 품목들이 예측이 어려운 외생적인 충격에 더 많이 노출되어 있거나, 해당 품목을 예측하는 데 필요한 정보가 부족한 상태임을 시사한다. 이들 품목과 관련하여 보다 정교한 모형 설정 및 설명 변수의 추가를 통해 전체 모형의 예측 정확도를 개선할 수 있을 것으로 기대된다. 전체 30개 품목군별 MAE 및 MSE는 〈부록 4〉에서 확인할 수 있다.

〈Figure 8〉 Information Set Used by Forecasting Method¹⁾



Note: 1) Forecast reference date is mid-month (around the 20th)

한편 상향식 방식에서 예측력이 높아지는 주된 이유는 품목별 물가 흐름을 잘 설명하는 이질적이고 다양한 정보를 활용하기 때문²³⁾인 것으로 보인다. Headline 인플레이션을 직접 예측하는 경우 보루타 셀렉션을 통해 37개의 정보변수²⁴⁾만

22) 당월 예측(20일 실시) 기준

23) Barker(2014)는 상향식 예측의 장점으로 더 많고 이질적인 정보집합을 사용할 수 있다는 점을 제시하였다.

이용되지만, 상향식 예측 시에는 370개로 정보량이 대폭 늘어난다(〈Figure 8〉 참조).²⁵⁾

머신러닝을 통해 각 품목군의 설명변수로 선정된 정보들을 보면, 농산물은 기상 여건, 석유류는 주유소 가격정보와 유류세, 가공식품은 유제품가격 및 관련 생산자 물가지수 등으로 해당 품목군의 가격과 연관성이 높은 변수가 선정되고 있음을 알 수 있다(〈Table 9〉 참조).²⁶⁾

〈Table 9〉 Subcomponent-Specific Key Explanatory Variables¹⁾

Product	Key Explanatory Variables
Agricultural, livestock, and fishery products	Regional temperature and precipitation data, CPI for agricultural, livestock, and fishery products, PPI, etc.
Petroleum products	Retail fuel prices at gas stations, Dubai crude spot prices, Import Price Index for crude oil, PPI for gasoline, diesel, and kerosene, fuel tax information, etc.
Processed food	CPI for dairy products, PPI for confectionery, alcoholic beverages, etc.
Core goods	Supply Price Index, Retail Sales Index, etc.
Coer services	Service Industry Production Index, Service components of the CPI, PPI, etc.
Rent	CPI for Jeonse and Monthly rent, Housing Sales Price Index, Jeonse Price Index, etc.

Note: 1) Forecast reference date is mid-month (around the 20th)

24) 1단계 직접 예측 방식에서는 경제활동인구, 취업자수, 휘발유·경유판매가격, 기업경기조사(전산업)-업황전망, 국내공급물가지수-최종재, 수입물가지수-원유, 지역별 평균기온, CPI 총지수 및 주요 하위지수 등 37개 변수만 이용되었다.

25) 30개 품목별 예측에는 총 626개의 설명변수가 활용되었으며, 이 중 품목 간 중복되어 사용된 변수 등을 제외한 결과 최종적으로 370개의 변수가 예측에 사용되었다.

26) 개별 품목군별 모형의 설명변수는 〈부록 5〉를 확인하기 바란다.

〈Table 10〉 Giacomini - White Test Results by Model & Disaggregation Level
(Using Historical CPI Subcomponent Indices Only, Nowcasting)¹⁾

Model B Model A	RW (Lv. 6)	AR (Lv. 1)	AR (Lv. 6)	BR (Lv. 1)	BR (Lv. 2)	BR (Lv. 3)	BR (Lv. 4)	BR (Lv. 5)	BR (Lv. 6)
RW (Lv. 1)	-0.35	3.62 ***	3.79 ***	4.64 ***	4.76 ***	4.82 ***	4.84 ***	4.49 ***	4.60 ***
RW (Lv. 6)		3.63 ***	3.74 ***	4.69 ***	4.79 ***	4.80 ***	4.79 ***	4.47 ***	4.57 ***
AR (Lv. 1)			1.88 *	3.18 ***	3.26 ***	3.44 ***	3.34 ***	2.95 ***	3.14 ***
AR (Lv. 6)				1.13	1.58	2.22 **	2.41 **	1.82 *	2.05 **
BR (Lv. 1)					0.39	1.09	1.27	0.60	0.83
BR (Lv. 2)						1.05	1.22	0.37	0.61
BR (Lv. 3)							0.77	-0.71	-0.32
BR (Lv. 4)								-2.28 **	-1.37
BR (Lv. 5)									0.85

Note: 1) Forecast reference date is mid-month (around the 20th).

2) *, **, and *** denote statistical significance at the 10%, 5%, and 1% levels, respectively.

기존 문헌에서는 상향식 전망방식의 정확도가 높은 이유로 각 품목군 가격의 고유한 변동성과 지속성을 잘 반영한 결과일 수 있음을 제시한 바 있다(Bermingham and D'Agostino, 2014). 국내 소비자물가지수의 상향식 예측에도 품목별가격의 고유 변화를 반영했기 때문인지를 검증하기 위해 정보효과를 제거하고 각 품목군 가격 변동성 및 지속성만으로 상향식 예측방식의 예측력이 높아지는지 시험해 보았다. 이를 위해 설명변수 목록에서 CPI 품목군별 과거 지수만 남기고 여타 정보변수를 제거한 후 예측치를 도출하고 오차를 산출해 보았다. 이 경우에는 직접 예측방식과 상향식 예측방식 간의 예측력에 큰 차이가 없는 것으로 나타나 인플레이션 예측 시 사용되는 개별 품목 관련 정보활용이 예측력 개선에 도움이 되는 요인으로 판단된다(〈Table 10〉 참조).

VI. 결론 및 시사점

본 연구는 소비자물가지수를 구성하는 하위 품목군의 가격을 개별적으로 예측한 후 가중합산하는 상향식 접근 방식과 머신러닝 기법을 결합하여, 단기 인플레이션 예측의 정확성을 제고하는 방법론을 제시하였다. 과거 10년간의 예측오차를 바탕으로 평가한 결과, 본 모형은 기존의 직접 예측 방식, 전통적 시계열 모형, 전문가 서베이 결과에 비해 우수한 예측력을 보여주었으며, 이는 최근 물가 변동성이 높은 환경에서 유용한 도구로 기능할 수 있음을 시사한다.

본고의 중요한 기여 중 하나는 과거에 비해 미시수준의 통계와 각종 가격변화 관련 뉴스를 훨씬 쉽게 획득할 수 있게 된 현재의 환경에서, 이러한 품목별 가격변화 정보를 거시경제 변수 예측에 어떻게 효율적으로 활용할 수 있는지를 제시했다는 점이다. 직접 예측 방식의 뚜렷한 한계는, 중요한 가격정보를 담고 있는 다양한 미시변수를 모형에 적절히 포함시키기 어렵다는 데 있다. 전통적인 상향식 예측 방식은 이러한 미시정보를 개별 품목과 연관지을 수 있다는 장점이 있으나, 수많은 미시정보 가운데 어떤 변수를 어떤 품목에 연결할지 식별하는 데 상당한 시간과 노력이 필요하고 연구자의 주관이 개입될 소지가 크다는 한계가 있었다. 본고에서 구축한 상향식 머신러닝 기법은 이 두 접근법의 장점을 결합해 이러한 기존 방식의 단점을 대폭 개선한 것이다. 어떠한 사전적 가정이나 연구자의 주관적 판단 없이 다수의 설명변수를 활용해, 매우 짧은 시간 안에 각 품목별 가격변화의 예측변수를 자동으로 식별하고 이를 활용할 수 있으며, 이를 통해 전체 물가에 대한 예측력도 개선될 수 있음을 보여주었다.

또한, 상향식 방식은 전체 지수만이 아니라 품목군 단위의 예측치를 함께 제공함으로써, 물가 상승의 구성요소를 사전에 파악하고 대응하는 데 유리한 정보를 제공한다는 점에서 실무적 가치도 높다. 특히 물가 상승의 원인이 특정 품목군(예: 농축수산물, 에너지 등)에 집중될 때, 품목별 정보는 정책 판단의 근거나 커뮤니케이션에 활용될 수 있다.²⁷⁾

27) 정확한 품목별 가격 변화 예측은 미시적 차원에서 정부의 정책 수립이나 기업의 의사결정 정교화에 크게 기여할 수 있다. 예를 들어, 농산물이나 에너지 가격의 상승이 예상될 경우, 관련 물량 비축, 세금 감면, 수입 확대 등의 미시적 정책 수단으로 선제적 대응이 가능하다. 또한 통화당국의 입장에서조차 기초적 물가 흐름과 공급 요인에 따른 일시적 물가 변화를 구분함

그럼에도 불구하고 몇 가지 한계가 존재한다. 첫째, 품목별 예측에 동일한 머신러닝 알고리즘을 적용함으로써 품목 특성별로 모형의 최적화 가능성을 충분히 고려하지 못했다. 향후 연구에서는 품목군별 특성에 적합한 머신러닝 알고리즘을 적용함으로써 예측력을 더욱 향상시킬 수 있을 것이다. 또한 품목 세분화 수준이 예측력에 미치는 영향이 상당함에도 본 연구에서는 이를 외생적으로 설정한 측면이 있다. 예측 기간 이전의 훈련·검증 구간을 활용해 최적의 세분화 수준을 함께 선택하는 절차를 포함한다면, 제시된 상향식 예측력의 타당성을 더욱 강화할 수 있을 것이다.

마지막으로, 본고의 상향식 머신러닝 기법은 소비자물가지수 외에도 국내총생산, 산업생산지수, 주가지수 등 하위 항목으로 구성된 다양한 거시경제 지표 예측에 적용될 수 있는 일반화 가능한 프레임워크를 제공한다. 특히, 거시변수 중 세부 구성요소 간 이질성이 큰 경우 본 연구의 방법론이 예측력 개선뿐만 아니라 정책 방향 설정의 정밀도를 높이는 데에도 기여할 수 있을 것이다.

으로써 보다 효과적인 통화정책 운용이 가능하다. 나아가, 품목군별 향후 가격 변화에 대한 정보는 개인 및 기업의 소비와 투자 의사결정에도 유용하게 활용될 수 있다.

■ 참 고 문 헌

1. 강규호 · 김정성 · 신세림, “우리나라 소비자물가상승률 예측,” 『경제분석』, 제27권 제4호, 2021, pp. 1-42.
(Translated in English) Kang, Kyu Ho, Jungsung Kim, and Serim Shin, “Forecasting Korean CPI Inflation,” *Economic Analysis*, Vol. 27, No. 4, 2021, pp. 1-42.
2. 김현학, “예측조합 및 밀도함수에 의한 소비자물가 상승률 전망,” 『경제분석』, 제21권 제3호, 2015, pp. 103-136.
(Translated in English) Kim, Hyun Hak, “Forecasting Consumer Price Inflation Using Forecast Combinations and Density Forecasts,” *Economic Analysis*, Vol. 21, No. 3, 2015, pp. 103-136.
3. 이동재 · 위승현, “품목별 머신러닝 예측을 통한 단기 물가전망,” 『BOK 이슈노트』, 2024-25호, 2024.
(Translated in English) Lee, Dongjae and Seunghyun Wi, “Short-Term Inflation Forecasting Using Item-Level Machine Learning Predictions,” *Bank of Korea Issue Note*, No. 2024-25, 2024.
4. 이창훈 · 홍지연 · 이현창, “빅데이터와 기계학습 알고리즘을 활용한 실시간 인플레이션 전망,” 『BOK 이슈노트』, 2024-5호, 2024.
(Translated in English) Lee, Chang Hoon, Jiyeon Hong, and Hyunchang Lee, “Real-Time Inflation Forecasting Using Big Data and Machine Learning Algorithms,” *Bank of Korea Issue Note*, No. 2024-5, 2024.
5. 최인 · 황승진, “Forecasting Korean Inflation,” 『응용경제』, 제14집, 2012, pp. 133-168.
(Translated in English) Choi, In and Seungjin Hwang, “Forecasting Korean Inflation,” *Applied Economics*, Vol. 14, 2012, pp. 133-168.
6. 한희준, “랜덤 포레스트(Random Forest)의 시계열 적용에 관한 연구: 한국 물가상승률 예측 사례 분석,” 『경제학연구』, 제71집 제3호, 2023, pp. 37-73.
(Translated in English) Han, Hee Jun, “Random Forest for Stationary Time Series: The Case of Forecasting Inflation in Korea,” *The Korean Journal of Economic Studies*, Vol. 71, No. 3, 2023, pp. 37-73.
7. _____, “머신러닝 기법을 이용한 한국 인플레이션 예측: 시계열 지속성과 머신러닝 예측의 관계에 관한 사례 연구,” 『국제경제연구』, 제30권 제2호, 2024, pp. 21-56.
(Translated in English) Han, Heejoon, “Forecasting Korean Inflation: A Case Study on the Relationship between Time Series Persistence and Machine Learning Forecasting,” *Kukje Kyungje Yongu*, Vol. 30, No. 2, 2024, pp. 21-56.
8. Almosova, A. and N. Andresen, “Nonlinear inflation forecasting with recurrent neural networks,” *Journal of Forecasting*, Vol. 42, No. 2, 2023, pp. 240-259.
9. Barker, T. S. and M. H. Pesaran, “Disaggregation in econometric modelling—an introduction,” in T. Barker and M. H. Pesaran (eds.), *Disaggregation in Econometric Modelling (Routledge Revivals)*, Routledge, 2014, pp. 1-14.
10. Barkan, O., J. Benchimol, I. Caspi, E. Cohen, A. Hammer, and N. Koenigstein, “Forecasting CPI Inflation Components with Hierarchical Recurrent Neural Networks,” *International Journal of Forecasting*, Vol. 39, No. 3, 2023, pp. 1145-1162.

11. Benalal, N., J. L. Diaz del Hoyo, B. Landau, M. Roma, and F. Skudelny, "To aggregate or not to aggregate? Euro area inflation forecasting," *European Central Bank Working Paper Series*, No. 374, 2004.
12. Bermingham, C. and A. D'Agostino, "Understanding and forecasting aggregate and disaggregate price dynamics," *Empirical Economics*, Vol. 46, No. 2, 2014, pp.765-778.
13. Bernanke, B. S., "Inflation expectations and inflation forecasting," Speech at the Monetary Economics Workshop of the National Bureau of Economic Research Summer Institute, Cambridge, Massachusetts, July 2007.
14. Boaretto, R. and M. C. Medeiros, "Disaggregated Inflation Forecasting Using Machine Learning Models," *International Journal of Forecasting*, Vol. 39, 2023, pp.1060-1078.
15. Chan, J. C. C., T. E. Clark, and G. Koop, "A new model of inflation, trend inflation, and long-run inflation expectations," *Journal of Money, Credit and Banking*, Vol. 50, No. 1, 2018, pp.5-53.
16. Clark, T. E., M. V. Gordon, and S. Zaman, "Forecasting Core Inflation and Its Goods, Housing, and Supercore Components," *Federal Reserve Bank of Cleveland Working Paper Series*, No. 23-34, 2023.
17. Duarte, C. and A. Rua, "Forecasting inflation through a bottom-up approach: How bottom is bottom?," *Economic Modelling*, Vol. 24, No. 6, 2007, pp.941-953.
18. Espasa, A. and R. Albacete, "Econometric modelling for short-term inflation forecasting in the euro area," *Journal of Forecasting*, Vol. 26, No. 5, 2007, pp.303-316.
19. Faust, J. and J. H. Wright, "Forecasting inflation," in G. Elliott and A. Timmermann (eds.), *Handbook of Economic Forecasting*, Vol. 2, Elsevier, 2013, pp.2-56.
20. Giacomini, R. and H. White, "Test of conditional predictive ability," *Econometrica*, Vol. 74, No. 6, 2006, pp.1545-1578.
21. Hendry, D. F. and K. Hubrich, "Combining disaggregate forecasts or combining disaggregate information to forecast an aggregate," *Journal of Business & Economic Statistics*, Vol. 29, No. 2, 2011, pp.216-227.
22. Joseph, A., G. Potjagailo, C. Chakraborty, and G. Kapetanios, "Forecasting UK inflation bottom up," *International Journal of Forecasting*, Vol. 40, No. 4, 2024, pp.1521-1538.
23. Kim, B. Y., and H. Han, "Multi-step-ahead Forecasting of the CBOE Volatility Index in a Data-rich Environment: Application of Random Forest with Boruta Algorithm," *The Korean Economic Review*, Vol. 38, No. 3, 2022, pp.541-569.
24. Knotek II, E. S. and S. Zaman, "Financial nowcasts and their usefulness in macroeconomic forecasting," *International Journal of Forecasting*, Vol. 35, No. 4, 2019, pp.1708-1724.
25. Krüger, F., T. E. Clark, and F. Ravazzolo, "Using entropic tilting to combine BVAR forecasts with external nowcasts," *Journal of Business & Economic Statistics*, Vol. 35, No. 3, 2017, pp.470-485.
26. Martínez-Rivera, W., E. R. González-Molano, and E. Caicedo-García, "Forecasting Inflation from Disaggregated Data: The Colombian case," *Borradores de Economía*, No. 1251, 2023.

27. Medeiros, M. C. and G. F. Vasconcelos, "Forecasting macroeconomic variables in data-rich environments," *Economics Letters*, Vol. 138, 2016, pp.50-52.
28. Medeiros, M. C., G. F. Vasconcelos, Á. Veiga, and E. Zilberman, "Forecasting inflation in a data-rich environment: the benefits of machine learning methods," *Journal of Business & Economic Statistics*, Vol. 39, No. 1, 2021, pp.98-119.
29. Stock, J. H. and M. W. Watson, "Modeling inflation after the crisis," *National Bureau of Economic Research Working Paper Series*, No. w16488, 2010.
30. Theoharidis, S., P. Petroulas, and E. Karimalis, "Inflation Forecasting with Deep Learning: Evidence from Euro Area," *European Central Bank Working Paper Series*, No. 2783, 2023.
31. Verbrugge, R. J. and S. Zaman, "Improving Inflation Forecasts Using Robust Measures," *International Journal of Forecasting*, Vol. 40, No. 2, 2024, pp.735-745.

〈부록 1〉

공공요금 관련 뉴스변수 및 분석방식

상향식 머신러닝 예측방식을 개발하면서 세부 품목군 중 정책적인 요인에 영향을 많이 받는 품목들의 경우 머신러닝을 통한 예측이 어렵다는 것을 발견하였다. 이는 해당 품목들의 가격변화가 해당 품목의 수급여건 상황이나 거시경제 상황과는 다소 관련 없이 불규칙적으로 변경되는 경우가 많을 뿐더러, 변화 빈도도 매우 낮기 때문이다. 예를 들어 오랜기간 유지되던 특정 공공요금의 인상은 되는 경우 이는 일회성 인상 후 유지되는 경우가 많지만 머신러닝 기법은 해당 인상을 기반으로 이후에도 오르는 추세가 유지될 것으로 예측하거나 과거 수준으로 돌아갈 것으로 예상하면서 예측오차가 커지는 것으로 나타났다.

한편 이러한 품목군에 해당되는 전기, 가스요금, 공공요금, 유류세 등은 변경 1~2달 전 정부 정책 발표 및 뉴스 등으로 정보 입수가 가능함에 따라 해당 품목과 관련된 소비자물가지수의 변화 시점 및 크기가 대략적으로 예측이 가능하다. 이러한 부분을 상향식 단기 전망 예측기법에 포함시키기 위해 품목별 정책 관련 뉴스를 지수화하고 해당 뉴스의 효과를 선형회귀분석을 통해 제거한 후 정책 이외의 요인만을 머신러닝을 통해 예측하였다. 이를 다시 뉴스를 통해 예측된 부분과 결합하여 해당 품목군의 가격을 예측하는 방식을 택하였다. 공공요금 뉴스변수 및 예측의 구체적인 방식은 아래와 같다. 유류세의 경우에도 유사한 방식으로 분석하였다.

〔분석방식〕

① 공공요금 관련 품목의 가격변화 뉴스를 스크랩하고 이를 기반으로 전기, 가스, 조제약, 공공서비스(의료, 대중교통) 품목이 다음달 가격변화가 예측되는 경우 그 변화 정도에 따라 특정 숫자를 부여(0~5% 상승뉴스에 1, 5~10% 상승뉴스에 2를 부여) 하는 뉴스 변수($N_{i,t}$)를 구축하였다.

② 뉴스지수를 해당 품목군의 물가지수 변화와 선형회귀 후에 뉴스변수로 설명되는 부분의 회귀계수와 설명되지 않는 부분에 대한 시계열을 도출하였다.

$$\pi_{i,t} = \alpha^i + \beta^i N_{i,t-1} + \epsilon_{i,t}$$

$$\hat{\epsilon}_{i,t} = \pi_{i,t} - \hat{\alpha}^i - \hat{\beta}^i N_{i,t-1}$$

③ 뉴스변수로 설명되지 않는 부분만을 머신러닝을 통해 학습시키고 이를 기반으로 예측한다.

$$\hat{\epsilon}_{i,t}^f = f_i(I_t)$$

④ 머신러닝 예측치와 뉴스를 통해 예측된 부분을 결합하여 최종적인 해당 품목군의 예측치를 도출하였다.

$$\hat{\pi}_{i,t}^f = \hat{\alpha}^i + \hat{\beta}^i N_{i,t-1} + \hat{\epsilon}_{i,t}^f$$

[공공요금 뉴스 변수 예시]

〈Table A.1〉 News Variables for Public Utilities: Electricity and Gas Prices

Year/ Month	Elec- tricity	Gas	Year/ Month	Elec- tricity	Gas	Year/ Month	Elec- tricity	Gas	Year/ Month	Elec- tricity	Gas
17/1	0	0	19/1	0	0	21/1	0	0	23/1	0	0
17/2	0	1	19/2	0	0	21/2	0	0	23/2	0	0
17/3	0	0	19/3	0	0	21/3	0	0	23/3	0	0
17/4	0	1	19/4	0	0	21/4	0	0	23/4	1	1
17/5	0	0	19/5	0	0	21/5	0	0	23/5	1	1
17/6	0	0	19/6	-4	1	21/6	-3	0	23/6	-3	0
17/7	0	0	19/7	0	0	21/7	0	0	23/7	0	0
17/8	0	0	19/8	4	0	21/8	4	0	23/8	3	0
17/9	0	0	19/9	0	0	21/9	1	0	23/9	0	0
17/10	0	-2	19/10	0	0	21/10	0	0	23/10	0	0
17/11	0	0	19/11	0	0	21/11	0	0	23/11	0	0
17/12	0	0	19/12	0	0	21/12	0	0	23/12	0	0
18/1	0	0	20/1	0	0	22/1	0	0	24/1	0	0
18/2	0	0	20/2	0	0	22/2	0	0	24/2	0	0
18/3	0	0	20/3	0	0	22/3	2	1	24/3	0	0
18/4	0	0	20/4	0	0	22/4	0	2	24/4	0	0
18/5	0	0	20/5	0	0	22/5	0	0	24/5	0	0
18/6	-4	1	20/6	-4	-3	22/6	-2	2	24/6	0	0
18/7	0	0	20/7	0	0	22/7	0	0			
18/8	0	0	20/8	4	0	22/8	4	0			
18/9	0	0	20/9	0	0	22/9	2	4			
18/10	0	0	20/10	0	0	22/10	0	0			
18/11	0	0	20/11	0	0	22/11	0	0			
18/12	0	0	20/12	-1	0	22/12	2	0			

[요소제거 실험(ablation test)]

상향식 예측 시 공공요금 뉴스 변수의 포함 효과와 선형회귀 절차의 유효성을 검증하기 위해, 공공요금 변수와 해당 선형회귀 단계를 제외한 경우의 예측력을 기준 모형(Base Model) 결과와 비교하는 요소제거 실험(ablation test)을 수행하였다. 비교는 당월 예측 기준으로 진행하였으며, 결과는 <Table A.2>에 제시하였다. Test 1은 공공요금 뉴스 변수 추가와, 선형회귀 절차를 모두 생략한 경우의 예측 오차를, Test 2는 공공요금 뉴스 변수는 추가하되 선형회귀 절차를 제외한 경우의 결과를 각각 나타낸다. 기준모형의 결과는 본문의 <Table 3>의 결과와 동일하다.

<Table A.2> Forecast Errors by the Inclusion of Public Utility News and Linear Regression
(단위: %p)

	Model Specification	Lv. 1	Lv. 2	Lv. 3	Lv. 4	Lv. 5	Lv. 6
M A E	Test 1 (No utility news, no regression)	0.189	0.189	0.183	0.168	0.165	0.166
	Test 2 (Utility news, no regression)	0.192	0.193	0.174	0.152	0.156	0.157
	Baseline (Utility news + regression)	0.194	0.188	0.172	0.155	0.141	0.142
M S E	Test 1 (No utility news, no regression)	0.059	0.059	0.055	0.048	0.049	0.048
	Test 2 (Utility news, no regression)	0.061	0.062	0.051	0.042	0.043	0.042
	Baseline (Utility news + regression)	0.061	0.059	0.051	0.042	0.036	0.037

결과를 해석해 보면, 우선 공공요금 변수나 선형회귀 등 예측력을 높이기 위한 추가 절차를 포함하지 않더라도, 상향식 예측 방식이 직접 예측 방식에 비해 유의하게 높은 예측력을 보였다.

다음으로, 1~2단계 품목군을 활용한 예측에서는 기준 모형과 Test 1, Test 2 모형 간의 예측력 차이가 크지 않았다. 직접 예측의 경우, 세부 품목 단위의 미래 가격 변화를 비교적 명확히 설명할 수 있는 변수를 포함하더라도, 이 변수들이 보루타-랜덤포레스트 머신러닝 기법에서 주요 설명변수로 선택되지 않았다. 이러한 결과는 전체 소비자물가 상승률이 공공요금 외의 다양한 품목 변동에 의해 결정되므로, 개별 품목 수준에서 식별되는 유의한 설명변수가 존재하더라도 그 효과가 집계 단계에서 상쇄되거나 희석되어 전체 물가 변동과 직접적으로 연결되기 어렵다는 점

을 보여준다. 한편, 3단계 이하로 좀더 세분화된 품목군을 예측한 후 이를 합산하는 방식으로 갈수록, Test 2(공공요금 변수를 포함한 모형)의 예측오차가 Test 1보다 낮게 나타났다. 이는 선형회귀 방식을 채택하지 않더라도 본고의 머신러닝 기법이 품목별로 유효한 뉴스변수를 자동적으로 선택하고 예측에 반영하는 데 따른 결과이다. 마찬가지로, 기준 모형(공공요금 변수 및 선형회귀 절차 모두 포함)의 예측오차는 Test 2보다 더 낮게 관찰되었다.

이러한 결과는 개별 품목 단위의 뉴스나 마이크로 데이터가 직접 예측식에서는 유용하지 않더라도, 상향식 예측 구조와 머신러닝 기법을 결합할 경우 예측력을 크게 향상시킬 수 있음을 시사한다. 이는 최근 뉴스 스크래핑 기술의 발전과 마이크로 데이터 확보의 용이성이 확대되는 환경에서, 상향식 머신러닝 예측 접근법이 거시경제 변수 예측을 개선시킬 잠재력이 높다는 점을 보여준다.

〈부록 2〉

상향식 단계별 품목군

각 단계별 품목군들은 소비자물가지수 구성 458개 품목들의 집합으로 구성되어 있다. 높은 단계일수록 더 세분화한 기준을 적용하였으며, 각 품목군 내 세부품목들의 성질이 유사하도록 그룹화하였다. 담배는 관리품목으로 정부 통제에 의해 가격이 결정되는 데다 예측력 평가기간 중 1회만 변동이 있었기 때문에 물가지수의 정확한 예측이 가능하다고 가정하였다. 이에 따라 담배를 포함하는 품목군의 경우 담배를 제외한 지수를 예측의 대상으로 정하였다.

1~3단계는 통계청의 품목별 물가지수 분류 기준을 활용하였다. 1단계는 예측 대상인 총지수 1개로 구성하였고, 2단계는 근원(식료품·에너지 제외 지수)과 비근원(식료품·에너지) 2개의 품목군으로 구성하였다. 3단계는 근원·비근원 품목을 소비자물가 통계의 상품분류별 지수의 중간단계 품목군을 기반으로 나누었다.

4단계에서는 3단계에서 더 나아가 기타 근원상품, 식료품, 에너지를 각각 세분화하였다. 구성 품목군의 지수 변화 요인이 서로 다르다고 판단될 경우 나누었는데, 예를 들어 식료품 중 농축수산물 품목들은 곡물, 채소, 과일, 축산물, 수산물 등은 지수 변화의 주요한 요인들이 개별적이기 때문에 세분화하였다.

5단계에서는 4단계 품목군 중 전기·가스·난방, 의약품, 공공서비스, 석유류를 세분화하였다. 6단계는 곡물, 채소, 과실이 변동성이 특히 큰 품목군임을 고려하여 상위 가중치를 기준으로 각각 2개의 품목군으로 나누었다.

〈부록 3〉

설명변수 목록

각 품목군의 물가지수를 예측할 때, 소비자물가지수(품목별, 지출목적별)와 생산자물가지수(기본분류) 세부 품목지수에 더하여 다음 표의 변수들을 설명변수로 활용하였다. 또한 10일경, 20일경, 30일경의 전망 시에는 그 시점까지 보통회발유 및 자동차용경유 가격의 평균을 누적해서 변수로 활용하였다. tcode는 해당 변수를 정상시계열로 변환하기 위한 방식을 나타낸다.

〈Table A.3〉 List of Explanatory Variables

	Variable Code	Description	tcode ¹⁾
1	PL_CA	Production Index (S.A.) - Capital Goods	5
2	SL_CA	Producer's Shipment Index (S.A.) - Capital Goods	5
3	IL_CA	Producer's Inventory Index (S.A.) - Capital Goods	5
4	PL_I	Production Index (S.A.) - Intermediate Goods	5
5	SL_I	Producer's Shipment Index (S.A.) - Intermediate Goods	5
6	IL_I	Producer's Inventory Index (S.A.) - Intermediate Goods	5
7	PL_CO	Production Index (S.A.) - Consumer Goods	5
8	SL_CO	Producer's Shipment Index (S.A.) - Consumer Goods	5
9	IL_CO	Producer's Inventory Index (S.A.) - Consumer Goods	5
10	PL_W	Production Index (S.A.) - All items	5
11	SL_W	Producer's Shipment Index (S.A.) - All items	5
12	IL_W	Producer's Inventory Index (S.A.) - All items	5
13	PL_MM	Production Index (S.A.) - Mining & Manufacturing	5
14	SL_MM	Producer's Shipment Index (S.A.) - Mining & Manufacturing	5
15	IL_MM	Producer's Inventory Index (S.A.) - Mining & Manufacturing	5
16	PL_MQ	Production Index (S.A.) - Mining	5
17	SL_MQ	Producer's Shipment Index (S.A.) - Mining	5
18	PL_MF	Production Index (S.A.) - Manufacturing	5
19	SL_MF	Producer's Shipment Index (S.A.) - Manufacturing	5
20	IL_MF	Producer's Inventory Index (S.A.) - Manufacturing	5
21	PL_E	Production Index (S.A.) - Electricity & Gas	5

	Variable Code	Description	tcode ¹⁾
22	SI_E	Producer's Shipment Index (S.A.) - Electricity & Gas	5
23	Unemployment	Unemployment Rate (S.A.) - Total	2
24	Act_pop_total	Economically Active Population - Total	5
25	Employed_total	Employed persons - Total	5
26	Unemployed_3 mts	Unemployed (Job search < 3 months)	5
27	Unemployed_3 _6mts	Unemployed (Job search 3-6 months)	5
28	Unemployed_6 _12mts	Unemployed (Job search 6-12 months)	5
29	Unemployed_o v6	Unemployed (Job search > 6 months)	5
30	Unemployed_o v12	Unemployed (Job search > 12 months)	2
31	HousePrice	Housing Purchase Price Index	5
32	HousePrice_S	Housing Purchase Price Index - Capital Region	5
33	HousePrice_P	Housing Purchase Price Index - Non-Capital Region	5
34	BSI_BC	BSI (All Industries) - Business Outlook	1
35	BSI_SG	BSI (All Industries) - Sales Outlook	1
36	BSI_P	BSI (All Industries) - Profitability Outlook	1
37	BSI_FS	BSI (All Industries) - Financial Situation Outlook	1
38	BSI_HR	BSI (All Industries) - Manpower Situation Outlook	1
39	PI_P	Mining & Manufacturing Production Index by Province/Industry (S.A.) - All items	5
40	PI_C	Index of All Industry Production (S.A.) - Construction	5
41	PI_SI	Service Industry Production Index (S.A.) - All items	5
42	PI_PA	Index of All Industry Production (S.A.) - Public Administration	5
43	MB	Monetary Base (Avg, S.A.)	5
44	Currency_cir	Currency in Circulation	5
45	CBLIAB_DC	Central Bank Liabilities to Depository Corporations	5
46	M1	M1 (Avg, Original Series)	5
47	M2	M2 (Avg, Original Series)	5
48	CD	CD (91 days)	2
49	CP	CP (91 days)	2
50	YT_1	Treasury Bond (1yr)	2
51	YT_3	Treasury Bond (3yr)	2

	Variable Code	Description	tcode ¹⁾
52	YT_5	Treasury Bond (5yr)	2
53	YT_10	Treasury Bond (10yr)	2
54	CB_3_AA	Corporate Bond (3yr, AA-)	2
55	BaseRate	The Bank of Korea Base Rate	2
56	CB_3_BBB	Corporate Bond (3yr, BBB-)	2
57	FX_US	KRW/USD (Basic Rate) - Avg	5
58	FX_CH	KRW/CNY (Basic Rate) - Avg	5
59	FX_JP	KRW/JPY (100 Yen) - Avg	5
60	FX_EU	KRW/EUR - Avg	5
61	FX_BR	KRW/GBP - Avg	5
62	FX_CA	KRW/CAD - Avg	5
63	FX_SW	KRW/CHF	5
64	SPI_R	Domestic Supply Price Index - Raw Materials	5
65	SPI_I	Domestic Supply Price Index - Intermediate Goods	5
66	SPI_F	Domestic Supply Price Index - Final Goods	5
67	SPI_RI	Domestic Supply Price Index - Producer Goods	5
68	IPL_A	Import Price Index - Agri, Forestry & Fishery Products (KRW)	5
69	IPL_B	Import Price Index - Bituminous Coal (KRW)	5
70	IPL_C	Import Price Index - Crude Oil (KRW)	5
71	IPL_L	Import Price Index - Natural Gas (LNG) (KRW)	5
72	IPL_M	Import Price Index - Manufactured Products (KRW)	5
73	EPL_A	Export Price Index - Agri, Forestry & Fishery Products (KRW)	5
74	EPL_M	Export Price Index - Manufactured Products (KRW)	5
75	KOSPI	KOSPI_Closing Price	5
76	KOSDAQ	KOSDAQ_Closing Price	5
77	Expected_inf	Expected Inflation Rate	2
78	Oilprice	Bloomberg Arabian Gulf Dubai Fateh Crude Oil Spot Price Index	5
79	USCPI	CPI for All Urban Consumers (U.S city)-All items-Seasonally Adjusted-Index, 1982-84=100-Monthly	5
80	IR_House	Mortgage Loan	2
81	TB_spread	US Generic Govt 10 Year Yield - US Generic Govt 1 Year Yield	2
82	USB_10	US Generic Govt 10 Year Yield	2
83	LeadingCI	Composite Leading Indicator (2020=100)	5
84	LaggingCI	Composite Lagging Indicator (2020=100)	5
85	VKOSPI	VKOSPI Index	1
86	CLI_1	Gangwon Yeongseo - Avg. Temp.	1

	Variable Code	Description	tcode ¹⁾
87	CLI_2	Gangwon Yeongseo - Avg. Temp. YoY Change	1
88	CLI_3	Chungbuk - Avg. Temp.	1
89	CLI_4	Chungbuk - Avg. Temp. YoY Change	1
90	CLI_5	Chungnam - Avg. Temp.	1
91	CLI_6	Chungnam - Avg. Temp. YoY Change	1
92	CLI_7	Gyeongnam - Avg. Temp.	1
93	CLI_8	Gyeongnam - Avg. Temp. YoY Change	1
94	CLI_9	Jeonnam - Avg. Temp.	1
95	CLI_10	Jeonnam - Avg. Temp. YoY Change	1
96	CLI_11	Jeju - Avg. Temp.	1
97	CLI_12	Jeju - Avg. Temp. YoY Change	1
98	ADD_1	Production Index (S.A.) - Capital Goods	5
99	ADD_2	Production Index (S.A.) - Intermediate Goods	5
100	ADD_3	Producer's Shipment Index (S.A.) - Capital Goods	5
101	ADD_4	Producer's Shipment Index (S.A.) - Intermediate Goods	5
102	ADD_5	Producer's Inventory Index (S.A.) - Capital Goods	5
103	ADD_6	Producer's Inventory Index (S.A.) - Intermediate Goods	5
104	ADD_7	Domestic Shipment Index (S.A.) - Capital Goods	5
105	ADD_8	Domestic Shipment Index (S.A.) - Intermediate Goods	5
106	ADD_9	Production Index (S.A.) - Mining	5
107	ADD_10	Production Index (S.A.) - Manufacturing	5
108	ADD_11	Production Index (S.A.) - Electricity & Gas	5
109	ADD_12	Producer's Shipment Index (S.A.) - Mining	5
110	ADD_13	Producer's Shipment Index (S.A.) - Manufacturing	5
111	ADD_14	Producer's Shipment Index (S.A.) - Electricity & Gas	5
112	ADD_16	Producer's Inventory Index (S.A.) - Manufacturing	5
113	ADD_18	Service Industry Production Index (S.A.) - Water, Sewage, Waste & Recycling	5
114	ADD_19	Service Industry Production Index (S.A.) - Wholesale & Retail	5
115	ADD_20	Service Industry Production Index (S.A.) - Transport & Storage	5
116	ADD_21	Service Industry Production Index (S.A.) - Accommodation & Food	5
117	ADD_22	Service Industry Production Index (S.A.) - Information & Communication	5
118	ADD_23	Service Industry Production Index (S.A.) - Finance &	5

	Variable Code	Description	tcode ¹⁾
		Insurance	
119	ADD_24	Service Industry Production Index (S.A.) - Real Estate	5
120	ADD_25	Service Industry Production Index (S.A.) - Professional, Scientific & Technical	5
121	ADD_26	Service Industry Production Index (S.A.) - Business Support & Rental	5
122	ADD_27	Service Industry Production Index (S.A.) - Education	5
123	ADD_28	Service Industry Production Index (S.A.) - Health & Social Work	5
124	ADD_29	Service Industry Production Index (S.A.) - Arts, Sports & Recreation	5
125	ADD_30	Service Industry Production Index (S.A.) - Associations, Repair & Other	5
126	ADD_31	Service Industry Production Index (S.A.) - All items	5
127	ADD_32	Regular Gasoline Price - End of Month	5
128	ADD_33	Auto Diesel Price - End of Month	5
129	ADD_34	Foreign Tourist Arrivals	1
130	ADD_35	Expressway Traffic Volume	1
131	ADD_36	Import Price Index (Special) - Excl. Energy (KRW)	5
132	ADD_37	Import Price Index (Special) - Excl. Energy (USD)	5
133	ADD_38	Import Price Index (Basic) - Crude Oil (USD)	5
134	ADD_39	China PPI YoY	1
135	ADD_40	PPI (Basic) - All items	5
136	ADD_41	Cyclical Component of Coincident Index	2
137	ADD_42	Retail Sales Index - Current Index - All items	5
138	ADD_43	Employment Rate (S.A.) - Total (%)	1
139	ADD_44	Employed Persons (S.A.) - Total (Thousand)	1
140	ADD_45	National Jeonse Price Index (2021.06=100)	1
141	ADD_46	Federal Reserve Bank of New York Global Supply Chain Pressure Index (NSA)	1
142	RAIN_1	Gangwon Yeongseo - Precipitation	1
143	RAIN_2	Chungbuk - Precipitation	1
144	RAIN_3	Chungnam - Precipitation	1
145	RAIN_4	Gyeongnam - Precipitation	1
146	RAIN_5	Jeonnam - Precipitation	1
147	RAIN_6	Jeju - Precipitation	1
148	Dummy_CPI_20	Electricity Dummy	1
149	Dummy_CPI_21	Gas Dummy	1
150	Dummy_CPI_25	Dispensed drugs Dummy	1

	Variable Code	Description	tcode ¹⁾
151	Dummy_CPI_29	Public Services Highly-Weighted Item Dummy	1
152	FAO	FAO Food Price Index	5
153	FAO_M	FAO Food Price Index - Meat	5
154	FAO_D	FAO Food Price Index - Dairy	5
155	FAO_C	FAO Food Price Index - Cereals	5
156	FAO_O	FAO Food Price Index - Oils	5
157	FAO_S	FAO Food Price Index - Sugar	5
158	DIFF_RAIN_1	Gangwon Yeongseo - Diff from Monthly Avg Precip	1
159	DIFF_RAIN_2	Chungbuk - Diff from Monthly Avg Precip	1
160	DIFF_RAIN_3	Chungnam - Diff from Monthly Avg Precip	1
161	DIFF_RAIN_4	Gyeongnam - Diff from Monthly Avg Precip	1
162	DIFF_RAIN_5	Jeonnam - Diff from Monthly Avg Precip	1
163	DIFF_RAIN_6	Jeju - Diff from Monthly Avg Precip	1
164 - 593	-	CPI and PPI Detailed Item Indices	5

Note: 1) tcode represents the time series transformation method, where 1 indicates no transformation, 2 indicates month-over-month change, and 5 indicates month-over-month-growth rate.

〈부록 4〉

〈Table A.4〉 Subcomponent-Level Forecast Errors

	MAE	MSE
Cereals	0.65	0.94
Flowers & Ginseng	3.40	21.13
Other agricultural products excl. flowers & ginseng	1.03	3.43
Vegetables	4.47	36.67
Fruits	3.17	15.98
Livestock products	1.07	2.07
Fishery products	0.62	0.61
Core processed food	0.50	0.54
Non-core processed food	0.30	0.15
Motor vehicles	0.46	0.41
Durable goods excluding motor vehicles	0.45	0.35
Publications	0.26	0.15
Medicines	0.10	0.02
Cosmetics	0.81	1.16
Electricity & Gas	1.00	4.57
Water Supply	0.24	0.16
Electricity	0.67	6.19
Gas	0.29	0.25
District heating	0.98	5.46
Jeonse	0.05	0.00
Monthly rent	0.03	0.00
Dispensed drugs	0.03	0.00
Medicines excluding dispensed drugs	0.11	0.03
Other industrial goods excluding tobacco	0.44	0.53
Public services1	0.04	0.01
Public services2	0.22	0.15
Gasoline	0.74	1.71
Diesel	0.90	2.96
Petroleum products excluding gasoline & diesel	1.30	3.01

〈부록 5〉

〈Table A.5〉 Subcomponent-Specific Explanatory Variables¹⁾

Item	Explanatory Variables
Cereals	Cereals(PPI) (-1), Cereals(CPI) (-1), Rice(CPI) (-1), Other agricultural products excl. flowers & ginseng(CPI) (-1), Chungnam - Precipitation(-3), Cereals(PPI) (-2), Chungnam - Diff from Monthly Avg Precip(-3), Rice(CPI) (-2), Chungbuk - Precipitation(-3), Cereals(CPI) (-2)
Flowers & Ginseng	Gangwon Yeongseo - Avg. Temp. (-4), Gyeongnam - Avg. Temp. (-4), Chungbuk - Avg. Temp. (-4), Retail Sales Index - Current Index - All items(-2), Jeonnam - Avg. Temp. (-4), Chungnam - Avg. Temp. (-4), Jeju - Avg. Temp. (-4), Economically Active Population - Total(-1), Jeju - Avg. Temp. (-3), Jeonnam - Avg. Temp. (-3)
Other agricultural products excl. flowers & ginseng	Other agricultural products excl. flowers & ginseng(CPI) (-1), Other food products(CPI) (-1), Fish and seafood(CPI YOY) (-1), Fishery products(CPI YOY) (-1), Communication(CPI YOY) (-4), Fishery products(CPI YOY) (-2), Fish and seafood(CPI YOY) (-2), Chungbuk - Precipitation(-2), Other agricultural products excl. flowers & ginseng(CPI) (-2), Gangwon Yeongseo - Precipitation(-2)
Vegetables	Economically Active Population - Total(-1), Employed persons - Total (-1), Jeju - Avg. Temp. (-3), Vegetables(PPI) (-1), Other fruits(CPI) (-2), Chungbuk - Avg. Temp. (-1), Gangwon Yeongseo - Avg. Temp. (-1), Gyeongnam - Avg. Temp. (-3), Jeonnam - Avg. Temp. (-3), Gyeongnam - Avg. Temp. (-1)
Fruits	Accommodation services(CPI) (-2), Gyeongnam - Avg. Temp. (-1), Chungbuk - Avg. Temp. (-1), Employed persons - Total (-2), Chungnam - Avg. Temp. (-1), Jeonnam - Avg. Temp. (-1), Chungnam - Avg. Temp. (-3), Jeonnam - Avg. Temp. (-3), Jeju - Avg. Temp. (-3)
Livestock products	Dairy & Meat(PPI) (-1), Chungnam - Avg. Temp. (-3), Gyeongnam - Avg. Temp. (-3), Jeju - Avg. Temp. (-3), Jeonnam - Avg. Temp. (-3), Chungbuk - Avg. Temp. (-3), Air & water passenger transport(CPI) (-3), Gangwon Yeongseo - Avg. Temp. (-3), Flowers & Ginseng(CPI) (-3), Gangwon Yeongseo - Avg. Temp. (-4)
Fishery products	Chungnam - Avg. Temp. (-4), Gyeongnam - Avg. Temp. (-4), Jeonnam - Avg. Temp. (-4), Jeju - Avg. Temp. (-4), Employed persons - Total (-3), Chungbuk - Avg. Temp. (-4), Gangwon Yeongseo - Avg. Temp. (-4), Jeju - Avg. Temp. (-3), Jeonnam - Avg. Temp. (-3), Durable goods excl. motor vehicles(CPI YOY) (-4)

Item	Explanatory Variables
Processed food in Core CPI	Medical products, appliances and equipment (CPI) (-4), Milk, cheese and eggs (CPI) (-1), Beer (PPI) (-1), Medicines (CPI) (-4), Water supply and miscellaneous dwelling services (CPI) (-4)
Processed food excl. from Core CPI	Rice cake, Snacks and noodles (PPI) (-1), Non-core (CPI YOY) (-3), Energy (CPI YOY) (-1), Non-core (CPI YOY) (-2), Non-core (CPI YOY) (-4), Non-core (CPI YOY) (-1), Energy (CPI YOY) (-2), All items (excl. tobacco) (CPI YOY) (-1), Animal feed (PPI) (-2), Petroleum products excl. gasoline & diesel (CPI YOY) (-2)
Motor vehicles	Import Price Index - Bituminous Coal (KRW) (-3), Women's clothing (CPI) (-2), Air & water passenger transport (CPI) (-4), Dubai Oil Avg (1st-10th) (-2), Transport services (CPI) (-4), Accommodation services (CPI) (-1), Accommodation services (CPI) (-4)
Durable goods excl. motor vehicles	Other fuels & energy (CPI) (-1), Domestic Supply Price Index - Final Goods (-4), Core services (CPI YOY) (-1), Personal services Excl. eating out (CPI YOY) (-1)
Textile products	Air & water passenger transport (CPI) (-4), Jeju - Avg. Temp. (-3), Accommodation services (CPI) (-2), Jeonnam - Avg. Temp. (-3), Hospital services (CPI) (-4), Air & water passenger transport (CPI) (-2), Service Industry Production Index (S.A.) - Information & Communication (-4), Higher education (CPI) (-2)
Publications	Producer's Inventory Index (S.A.) - Capital Goods (-3), Unemployed (Job search 3-6 months) (-2), Recreational & sporting services (CPI) (-3)
Cosmetics	Cosmetics (CPI) (-1), Cosmetics (CPI YOY) (-1), Adult academies & other education (CPI YOY) (-4), Fuels and lubricants for personal transport equipment (CPI YOY) (-1)
Water Supply	Accommodation services (CPI) (-4), Cyclical Component of Coincident Index (-4), Forest products (PPI) (-3), Economically Active Population - Total (-1), Employed persons - Total (-1), Public services1 (Outpatient services, Mobile phone charges, Inpatient services, City bus charges) (CPI) (-3), Expressway Traffic Volume (-3), Fruits (PPI) (-4), Services (PPI) (-3)
Electricity	Electricity Dummy (-1), Gangwon Yeongseo - Diff from Monthly Avg Precip (-2), Electricity, Gas & Water (CPI) (-2), Electricity, gas and other fuels (CPI) (-2)
Gas	Apparel (PPI) (-1), Clothing and footwear (CPI) (-4), Other personal goods (CPI) (-3), Footwear (CPI) (-4), Recreation and culture (CPI YOY) (-3), Other services (CPI) (-4)
District Heating	Air & water passenger transport (CPI) (-4), KOSPI_Closing Price (-1), KOSDAQ_Closing Price (-1), Processed food excl. from Core CPI (CPI) (-4), Non-durable household goods (CPI) (-1)

Item	Explanatory Variables
Jeonse	Actual rentals for housing(CPI) (-1), Rent(CPI) (-2), Jeonse(CPI) (-1), Actual rentals for housing(CPI) (-2), Rent(CPI) (-1), Jeonse(CPI) (-2), Rent(CPI) (-3), Actual rentals for housing(CPI) (-3)
Monthly rent	Monthly rent(CPI) (-1), Monthly rent(CPI) (-2), Monthly rent(CPI YOY) (-1), Monthly rent(CPI) (-3), Monthly rent(CPI YOY) (-2), Monthly rent(CPI YOY) (-3), Actual rentals for housing(CPI) (-1), Monthly rent(CPI YOY) (-4), Rent(CPI) (-1)
Eating out	Food services(CPI) (-1), Eating out(CPI) (-1), Energy(CPI YOY) (-1), Energy(CPI YOY) (-2), Other fuels & energy(CPI YOY) (-1), Energy(CPI YOY) (-3), National Jeonse Price Index (2021.06=100) (-4), Restaurants and hotels(CPI) (-1), Transport(CPI YOY) (-2)
Excl. eating outPersonal services	Gangwon Yeongseo - Avg. Temp. (-3), Chungbuk - Avg. Temp. (-3), Jeju - Avg. Temp. (-2), Chungnam - Avg. Temp. (-3), Gyeongnam - Avg. Temp. (-3), Jeju - Avg. Temp. (-3), Jeonnam - Avg. Temp. (-3), Service Industry Production Index (S.A.) - Information & Communication(-2), Excl. eating outPersonal services(CPI) (-1), Employed persons - Total (-1)
Dispensed drugs	Maintenance and repair of personal transport equipment(CPI YOY) (-2), Diesel(CPI YOY) (-4), Medical products, appliances and equipment(CPI) (-4), Dubai Oil Avg (1st-20th) (-1)
Medicines excl. dispensed drugs	Hairdressing salons & personal grooming(CPI YOY) (-1), Recreational & sporting services(CPI YOY) (-4), Housing Purchase Price Index (-1), Napa cabbage, Tomato, Garlic(CPI YOY) (-4), Goods and services for routine household maintenance(CPI YOY) (-4), Fruits(CPI YOY) (-3), Housing Purchase Price Index - Capital Region (-3), Housing Purchase Price Index - Non-Capital Region(-1), Jeonse(CPI) (-1), Medicines excl. dispensed drugs(CPI) (-1)
Other industrial products excl. tobacco	Other industrial products excl. tobacco(CPI) (-1), Core commodities (Durable goods), Textile products, excl. Tobacco(CPI) (-1), Processed food excl. from Core CPI(CPI) (-2), Clothing and footwear(CPI) (-1), Kitchenware & household goods(CPI) (-1), Footwear(CPI) (-1), Kitchenware & household goods(CPI) (-1), Flowers & Ginseng(CPI) (-2), 03 Clothing and footwear(CPI) (-3)
Public services1	Public Services Highly-Weighted Item Dummy(-1), Monthly rent(CPI) (-1), Education(CPI YOY) (-4), Service Industry Production Index (S.A.) - Real Estate(-4)
Public services2	Gas Dummy(-1), Durable goods excl. motor vehicles(CPI) (-3), Accommodation services(CPI) (-4), Electricity(CPI) (-2), Electricity Dummy(-3), Expressway Traffic Volume(-2), Clothing(CPI) (-2), Expressway Traffic Volume(-1), Textile products(CPI) (-2)

Item	Explanatory Variables
Gasoline	Gasoline Avg (1st-20th) (-1), Gasoline Avg (1st-10th) (-1), Diesel Avg (1st-20th) (-1), Dubai Oil Avg (1st-10th) (-1), Diesel Avg (1st-10th) (-1), Regular Gasoline Price - End of Month(-1), Import Price Index - Crude Oil (KRW) (-1), Gasoline(PPI) (-1), Import Price Index (Basic) - Crude Oil (USD) (-1), Auto Diesel Price - End of Month(-1)
Diesel	Diesel Avg (1st-20th) (-1), Diesel Avg (1st-10th) (-1), Gasoline Avg (1st-20th) (-1), Dubai Oil Avg (1st-10th) (-1), Gasoline Avg (1st-10th) (-1), Auto Diesel Price - End of Month(-1), Import Price Index - Crude Oil (KRW) (-1), Kerosene(PPI) (-1), Regular Gasoline Price - End of Month(-1), Diesel(PPI) (-1)
Petroleum products excl. gasoline & diesel	Naphtha(PPI) (-2), Diesel Avg (1st-10th) (-1), Chemical products(PPI) (-1), Naphtha(PPI) (-1), Domestic Supply Price Index - Intermediate Goods (-1), Gasoline Avg (1st-10th) (-1), Domestic Supply Price Index - Producer Goods(-1), Auto Diesel Price - End of Month(-1), Diesel Avg (1st-20th) (-1), All items(PPI) (-1)

Note: 1) Due to space limitations, we present up to ten explanatory variables for each item group. For the full list of explanatory variables by item, please contact the authors.

Inflation Forecasting in Korea Using a Bottom-Up Machine Learning Approach*

Dongjae Lee** · Seunghyun Wi***

Abstract

This paper investigates short-term inflation forecasting in Korea using a bottom-up machine learning framework. Price changes of Consumer Price Index (CPI) subcomponents are predicted with the Boruta - Random Forest algorithm and aggregated via expenditure weights. Forecasts are compared across aggregation schemes. The results demonstrate that disaggregated forecasting of 30 CPI subgroups followed by weighted aggregation achieves the highest accuracy, surpassing both aggregate forecasting approaches and survey-based benchmarks. Beyond improved predictive performance, the framework delivers detailed subgroup-level projections valuable for monetary policy and private-sector decisions, and it offers a scalable methodology for forecasting other macroeconomic indicators.

Key Words: Machine learning, Bottom-up, Inflation, Forecasting
JEL Classification: C53, E31

Received: Sept. 20, 2025. Revised: Nov. 20, 2025. Accepted: Dec. 12, 2025.

* This work is a revised and expanded version of the authors' earlier working paper, BOK Issue Note 2024-25. The views expressed in this paper are solely those of the authors and do not necessarily reflect the views of the Bank of Korea. The authors acknowledge helpful comments from Changhyun Park and Jeongik Lee of the Bank of Korea, Professor Heejoon Han of Sungkyunkwanwan University, participants at the 44th International Symposium on Forecasting(2024), and anonymous reviewers.

** First and Corresponding Author, Economist, Incheon Branch, Bank of Korea, Incheon Branch, Bank of Korea, 10 Inhang-ro Jung-gu, Incheon 22333, Korea, Phone: +82-032-880-0033, e-mail: dongjae.lee@bok.or.kr

*** Co-Author, Junior Economist, Inflation Forecasting & Analysis Team, Research Department, Bank of Korea, 39 Namdaemun-ro, Jung-gu, Seoul, Korea 04531, Phone: +82-02-759-4267, e-mail: shwi@bok.or.kr