BOK 이슈노트

한국은행

2024년 8월 26일

품목별 머신러닝 예측을 통한 단기 물가전망

이동재
한국은행 인천본부
인천업무팀 팀장보
Tel. 032-880-0053
dongjae.lee@bok.or.kr

위승현
한국은행 조사국
물가동향팀 조사역
Tel. 02-759-4267
shwi@bok.or.kr

① 인플레이션은 경제 전반에 큰 영향을 미치는 주요 지표일 뿐 아니라, 팬데믹 이후 물가 변동성이 크게 높아짐에 따라 새로 입수되는 데이터에 기반한data-dependent 물가 판단과 단기적인 인플레이션 예측의 중요성이 어느 때보다 높아졌다. 본고는 국내 인플레이션에 대한 단기 예측력을 향상시키기 위해 머신러닝 기법과 상향식bottom-up 추정을 결합한 예측모형을 소개한다. 이 방식은 소비자물가지수를 구성하는 세부 품목군별 가격 변화를 머신러닝 기법으로 예측한 후 이를 가중합산하여 전체 인플레이션의 단기 흐름을 전망하는 방법이다.

② 품목군별 물가 예측에는 보루타-랜덤포레스트Boruta-Random Forest 알고리즘을 이용한 머신러닝 기법을 적용하였다. 설명변수로 각 품목군의 가격과 연관성이 높은 주요 거시변수뿐만 아니라 세부품목별 물가지수, 주유소 판매가격, 농축수산물가격, 지역별 기후, 공공요금 관련 뉴스 등 미시변수와 이들의 시차변수까지 포함하여 총 2,300여개의 정보를 활용하였다. 또한 상향식 예측에는 품목군의 세분화 정도가 크게 영향을 미치는데, 그 정도에 따라 1단계(총지수)부터 6단계(33개 품목군)까지 구분한 후 과거 10년 간의 월별 소비자물가 상승률을 이용하여 단계별 예측력을 비교하였다.

③ 분석 결과 상향식 예측방식이 전체 소비자물가지수를 직접 예측하는 방식이나 전통적인 시계열 모형을 통한 전망에 비해 예측력이 우수한 것으로 확인되었으며, 30개 품목군(5단계)으로 세분화한 후 예측·집계하는 방식의 정확도가 가장 높은 것으로 나타났다. 특히 상향식 모형의 예측오차는 당월 예측기준 0.141%p(21년 이후: 0.136%p), 익월 예측기준 0.188%p(0.201%p)로 시장 서베이나 기존 연구의 머신러닝 예측오차에 비해 30~60% 정도 작은 것으로 분석되었다. 이는 상향식 머신러닝 예측에는 개별 품목 단위의 물가 흐름과 연관성이 높은 정보들이 효과적으로 활용되었기 때문인 것으로 판단된다. 예측의 정확성 외에도 상향식 방식은 직접 예측방식과 달리 품목군별 물가상승률 예측치를 도출하고 변동요인을 점검해 볼 수 있다는 장점이 있다.

④ 5단계 상향식 모형을 사용하여 이번달(24.8월)과 다음달(9월)의 인플레이션을 추정해본 결과, 7월에 소폭 반등하였던 소비자물가 상승률이 8월 2%대 초반, 9월 2.0% 내외로 수준으로 둔화되는 것으로 모형은 예측하였다. 근원물가 상승률은 8~9월중 2.1% 내외 수준에서 하향 안정될 것으로 추정었다. 품목별로는 최근 유가가 다소 하락한 가운데 농산물가격도 둔화되면서 농산물·석유류 등 비근원물가 상승률의 둔화 흐름이 이어질 것으로 예측되었다. 근원물가의 경우 더딘 수요회복 등으로 당분간 낮은 수준에서 안정될 것으로 나타나는데, 모형에서는 근원상품가격 상승률이 1%대 후반 수준, 근원서비스물가(집세 제외) 상승률은 2%대 중반 수준에서 완만한 둔화 흐름을 이어갈 것으로 예측되었다.

▪ 본 자료의 내용은 한국은행의 공식견해가 아니라 집필자 개인의 견해라는 점을 밝힙니다. 따라서 본 자료의 내용을 보도하거나 인용할 경우에는 집필자명을 반드시 명시하여 주시기 바랍니다.
▪ 본 자료의 내용은 저자가 한국은행 조사국 물가동향팀 근무시 연구결과입니다.
▪ 본 자료 작성에 도움을 주신 이정익 정책보좌관, 박창현 물가동향팀장, 광주전남본부 최열매 조사역 그리고 유익한 코멘트를 주신 성균관대학교 한희준 교수님과 2024년 International Symposium of Forecasting 참가자분들께 감사를 표합니다.

Ⅰ. 검토배경

인플레이션의 양상과 향후 흐름은 기업, 가계, 금융시장 등 경제 전반의 의사결정에 큰 영향을 미치는 통화정책 결정의 핵심 지표이기에, 오랜 기간 다양한 예측방식이 발전해왔다. 그러나 많은 연구에도 불구하고 대내외 불확실성이 한층 커진 상황에서 정확한 인플레이션 전망은 어려운 과제로 남아있다. 특히 단기 시계 전망의 경우에는 경제모형을 이용한 예측이 단순 시계열 모형이나, 전문가 서베이와 같은 정성적 예측보다 정확하기가 어렵다고 알려져 있다(Stock·Watson, 2010; Faust·Wright, 2013).

팬데믹 이후에는 인플레이션의 변동성이 크게 확대됨에 따라 단기 인플레이션 예측의 중요성이 더욱 강조되고 있으며, 발전된 예측기법과 늘어난 정보량을 바탕으로 관련 연구가 활발히 진행되고 있다. 이는 불확실한 경제환경에서 단기 전망의 예측력을 높일 경우, 경제여건 변화가 경제주체들과 금융시장에 미치는 충격을 줄일 수 있을 뿐만 아니라 중앙은행의 신속하고 적절한 대응에도 도움을 줄 수 있기 때문이다. 또한 최근 연구들은 단기 전망의 정확도를 제고함으로써 중장기 전망의 개선에도 크게 기여할 수 있음을 밝히고 있다[1].

본고에서는 최신의 머신러닝$_{\text{Machine-Learning}}$ 기법을 이용한 단기 인플레이션 전망모형을 소개하고자 하는데, 전망의 정도를 높이기 위해 기존 머신러닝 연구들과 달리 품목별 물가 흐름을 예측·통합하는 상향식$_{\text{Bottom-up}}$ 전망을 제시한다. 이 방식은 소비자물가지수를 구성하는 세부 품목군들의 가격을 먼저 머신러닝 기법을 통해 개별적으로 추정한 후 가중합산하여 집계$_{\text{aggregate}}$ 인플레이션을 예측하는 방법이다. 소비자물가$_{\text{headline}}$ 혹은 근원물가$_{\text{core}}$ 상승률과 거시변수와의 직접적 관계를 활용하는 이론기반 전망기법, 한국은행을 비롯한 주요 기관에서 사용하는 거시모형이나 전체 소비자물가지수를 직접 예측하는 머신러닝 모형(이하 「직접 예측방식」)[2]과는 다른 형식을 가지고 있다.(**[그림 1]** 참조)

우리나라 소비자물가지수는 458개 품목으로 구성되어 있으며, 각 품목 단위에서 보면 상당히 다른 가격 변화가 관측된다. 따라서 하위품목들의 이질적인 변동성·지속성을 고려하고 품목 단위에서 가격변화를 잘 설명할 수 있는 변수들을 활용할 경우 좀 더 정확한 예측이 가능해진다. 실제로 단기 인플레이션 예측에서는 전체 지수를 통한 예측보다 물가지수를 구성하는 세부 품목들의 예측을 통한 상향식 접근 방식이 보다 유용한 것으로 알려져 있으며(Bernanke, 2007)[3], 주요국 중앙은행들도 물가지수 내 구성요소들의 변화와 향후 흐름을 인플레이션 분석 및 커뮤니케이션에 활용[4]하고 있다. 또한 이 예측방식은 최근처럼 물가의 변동이 총수요의 변화보다는 지정학적 불안, 기상이변 등에 따른 개별품목 수준의 충격$_{\text{sectoral-level shock}}$에 기인하는 상황에서 더 적합할 수 있다.

[그림1] 상향식(Bottom-up) 전망 방식

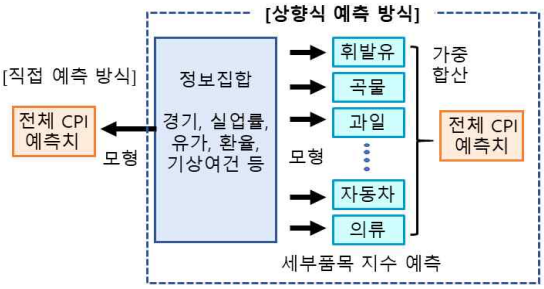

자료: 저자 작성

1) Faust · Wright (2013), Krüger et al. (2017), Knotek · Zaman (2019) 등을 참조하기 바란다.
2) Medeiros et al.(2021), 한희준(2024), 이창훈 외(2024) 등을 참조하기 바란다.
3) Bernanke(2007)은 당분기와 익분기 인플레이션 전망에서 품목별 관련 정보를 활용한 개별 단위 예측을 합계하는 방식이 유용하며 2분기 이후 전망에는 거시지표(GDP · 실업률갭, 기대인플레이션 등)에 기반한 계량모형이 유용하다고 밝히고 있다.
4) 미 연준에서는 팬데믹 이후 인플레이션 흐름을 분석하고 대중에게 설명하기 위해 에너지 · 식료품과 근원품목을 구분할 뿐 아니라 근원물가 내에서도 상품(good excluding food and energy), 집세제외 근원서비스(services excluding energy and housing) 및 집세(housing)를 구분하여 활용하고 있다(Clark et al., 2023). 또한 품목군별 물가 흐름 예측이 물가안정정책 및 사회보장정책 등에 기초자료로 활용될 수 있다(Barkan et al., 2023)는 점에서 품목 수준의 가격변화에 대한 예측은 중앙은행 및 정부의 정책 수행에 도움이 될 수 있다.

또한 상향식 전망방식은 최근 빠르게 발전하는 머신러닝 기법과 효과적으로 결합하여 활용할 수 있다는 장점이 있다. 상향식 예측방식 구축에 따르는 어려운 점은 세부 품목별 가격변화와 유의한 관계를 갖는 설명변수들을 찾고 적합한 모형을 설정하는 데에 따르는 복잡성과 시간 비용이 크다는 것이다[5]. 하지만 머신러닝 기법을 상향식 예측방식에 접목할 경우 세부 품목별로 유효한 설명변수 및 모형의 식별에 대한 자동화가 가능하며, 여러 하위품목에 대해서도 더 정확한 예측모형을 비교적 용이하게 구축할 수 있다. 이 외에도 품목별 가격과 연관성이 높은 미시Micro데이터를 많이 수집할 수 있는 근래의 여건에서 잠재력이 큰 방식이다[6].

본고에서는 상향식 머신러닝 기법을 활용하여 우리나라의 단기 인플레이션 예측을 위한 모형을 구축하고, 전망오차를 직접 예측식 머신러닝 모형, 일반적인 시계열 모형, 전문가 서베이 등과 비교해 보았다. 그 결과 상향식 머신러닝 모형이 당월Nowcasting 및 1~2개월 후의 단기 예측에 있어 여타 방식보다 예측력이 우수한 것으로 확인되었다. 뿐만 아니라 이를 통해 소비자물가지수 개별품목들의 단기적인 가격변화 예측에도 유용한 것으로 나타났다.

본고의 구성은 다음과 같다. Ⅱ장에서는 머신러닝 기법에 상향식 방식을 결합한 예측 방법, 이용 데이터, 예측력 평가 방법 등을 자세히 소개한다. Ⅲ장에서는 상향식 머신러닝 기법의 예측력을 다른 방법들과 비교하고, 이를 통해 도출할 수 있는 다양한 결과와 특징을 제시한다. Ⅳ장에서는 새롭게 개발한 예측 방법을 바탕으로 단기(24년 8월·9월) 인플레이션을 전망한다. 마지막으로 Ⅴ장에서는 연구 내용을 요약하고 향후 과제를 제시한다.

Ⅱ. 데이터, 모형 및 평가방식

1 상향식 전망을 위한 세부 품목군 설정

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

[직접 예측]

$$\hat{\pi}^{D}_{t+h} = f(I_t) \quad \cdots (1)$$

[상향식 예측]

$$\hat{\pi}_{i,t+h} = f_i(I_t) \quad \cdots (2)$$

$$\hat{\pi}^{B}_{t+h} = \sum_{i=1}^{N} W_{i,t}\hat{\pi}_{i,t+h} \quad \cdots (3)$$

여기서 $\hat{\pi}^{D}_{t+h}$는 $t+h$ 시점의 headline 인플레이션에 대한 직접 예측치, $\hat{\pi}_{i,t+h}$는 i품목군 가격 상승률 예측치, $\hat{\pi}^{B}_{t+h}$는 품목별 예측치를 가중합산한 headline 인플레이션 예측치(상향식 예측치)이다. $W_{i,t}$ 는 i품목군의 소비자물가지수 가중치, N은 품목군 수, I_t는 t시점에 가용한 정보집합이다.

5) 이에 따라 과거에 상향식 예측을 시도한 연구들(Benalal et al (2004); Espasa · Albacete(2007), Duarte · Rua(2007) 등)은 세부 품목 예측에 동일한 설명변수를 사용하거나 자기회귀(AR)와 같은 단순한 시계열 모형을 이용하는데, 이 방식들은 직접 예측 방식에 비해 예측력의 개선이 미미했다. 최근 Clark et al.(2023)은 미국 소비자물가지수를 주요 5개 품목군으로 나눈 후 베이지안(Bayesian) 벡터자기회귀모형으로 상향식 예측을 시도하였으나 직접 예측식에 비해 예측력이 개선되지 않았다고 밝혔다.

6) 이에 따라 최근 들어 머신러닝 기법과 상향식 예측방식을 결합한 인플레이션 예측모형 연구가 활발히 진행되고 있으며(Joseph et al., 2024; Barkan et al., 2023; Boaretto · Medeiros, 2023; Martínez-Rivera et al., 2023 등), 대체로 상향식 머신러닝 방식이 다른 예측방식에 비해 정확도가 높은 것으로 평가하고 있다. 다만 예측의 정확도는 국가별 인플레이션의 시계열적 특성, 활용 가능한 정보집합 크기, 머신러닝 기법 등에 따라 차이가 나는 것으로 나타나, 특정 국가의 인플레이션 예측에 유용한 방법을 확인하는 것은 실증적으로 확인해야 할 문제로 남아있다(Hendry · Hubrich, 2011; Faust · Wright, 2013; Boaretto · Medeiros, 2023 등).

상향식 예측방식을 위해서는 소비자물가지수를 하위품목군으로 구분하는 절차가 필요하다[7]. 이를 위해 물가지수를 구성 품목 중 유사한 성질을 가진 품목들을 묶어 주요 품목군으로 분류하고, 이들 물가지수를 예측변수로 설정하였다. 세분화에 따른 예측 정확도를 비교하기 위해 [그림 2]와 같이 세분화 정도를 1단계(총지수)부터 6단계(33개 품목군)까지 세분화하였다[8]. 세분화를 위해 총지수를 우선 근원과 비근원non-core 품목으로 구분한 후 소비자물가 통계의 상품분류별 기준을 이용하였다[9]. 하위단계 품목군의 물가를 예측한 후 전체 인플레이션 예측치를 도출하기 위해 소비자물가지수의 품목별 가중치를 이용하여 합산하였다.

2 설명변수

설명변수로는 소비자·수출입·생산자물가지수, 실업률, 경기종합지수, 환율, 주가, 유가 등 국내·외 주요 거시변수와 함께 세부 품목별 물가지수, 주유소 판매가격, 국제식량가격지수, 지역별 기후(기온, 강수량) 등 미시변수들도 포함하였다. 또한, 공공요금, 유류세 등 사전적으로 가격변화를 일부 예측할 수 있는 품목군에 대해서는 뉴스에 기반한 지수를 생성하여 반영하였다. 최종적으로 593개 변수[10]가 포함되었으며, 시차 영향을 고려하여 해당 변수의 과거 3개월간[11] 시차 변수까지 더해 총 2,372개의 설명변수를 활용하였다.

[그림 2] 단계별 품목 구성[1)]

주: 1) 「공공서비스 1」은 가중치가 높은 외래진료비, 입원진료비, 휴대전화료 및 시내버스료이며, 「공공서비스 2」는 여타 공공서비스
자료: 저자 작성

7) 품목군을 자체적으로 설정하지 않고, 통계청이 발표하는 소비자물가지수의 하위품목 분류를 사용하는 방법도 가능하다. 통계청의 지출목적별 최하위 분류(77개 품목군)를 사용하여 상향식 머신러닝 기법을 적용시켜 보았으나 예측력이 저자들이 설정한 30개 품목군 기반으로 도출한 수준보다 낮은 것으로 나타났다.

8) 소비자물가통계 상품분류별 지수의 대분류 항목들로 세분화한 후 각 품목군에서 가중치가 크거나 미시데이터가 가용한 품목군들을 추가적으로 분류하였다. 소비자물가지수는 458개 세부 품목으로 이루어져 있어 모형 또한 동일한 수준까지 세분화 가능하지만, 30개 품목군 이상으로 세분화할 경우 예측오차가 개선되지 않았을 뿐 아니라 시계열 단절 등으로 머신러닝 학습 및 합산에 어려움이 따른다.

9) 자세한 세분화 단계별 품목 분류는 <참고 1> 「상향식 단계별 품목군」을 확인하기 바란다.

10) 모든 설명변수는 정상시계열(stationary time series)로 변환하였으며, 자세한 설명변수 목록 및 설명변수별 변환 방식은 <참고 2> 「설명변수 목록」을 참조하기 바란다.

11) 보루타-랜덤포레스트 예측을 사용한 한희준(2024)의 방식을 따라 당월을 포함하여 총 4개 시차를 사용하였다. 보루타 알고리즘으로 선택되는 변수는 대부분 당월 및 과거 2개월까지의 변수로 확인되며, 과거 11개월 간의 시차를 모두 포함해 보더라도 예측력이 유의하게 개선되지 않았다.

3 예측 모형

각 품목군별 물가 예측에는 한희준(2024)에서 사용된 보루타-랜덤포레스트 알고리즘을 활용[12]하였다. 예측 과정은 예측변수(품목군별 물가지수)가 주어졌을 때, 보루타 셀렉션Boruta selection을 이용해 전체 설명변수 중 중요 변수들을 식별하고, 선정된 변수들에 대해 랜덤포레스트Random Forest 알고리즘을 적용하여 품목군별 물가지수를 예측[13]하는 순서로 이루어진다.

랜덤포레스트는 무작위로 생성된 여러 개의 의사결정나무decesion tree를 통한 예측을 결합하여 정확성을 높이는 머신러닝 기법중 하나로 대량의 데이터를 학습하고 데이터의 비선형적인 관계를 포착하는데 뛰어나며, 여러 연구를 통해 인플레이션 예측에도 효과적이라고 알려져 있다. 그러나 종속변수와의 관계가 확실치 않은 다양한 설명변수를 사용할 경우, 모형이 과거 데이터에 지나치게 비중을 둠으로써 새로운 데이터를 통한 예측력이 저하되는 과적합overfitting 문제 등이 발생할 수 있다. 이러한 문제를 해결하기 위해 보루타 알고리즘을 통해 중요한 설명변수로 선별된 변수들만을 랜덤포레스트 모형에 적용하여 예측을 시행하였다. 이를 통해 모형의 복잡성을 줄이고, 불필요한 변수를 제거하여 더 빠르고 예측력이 높은 모형을 만들 수 있다.

세부품목군 중 전기·도시가스요금과 같은 공공요금, 세금으로 인한 변동이 큰 석유류 품목 등은 가격의 변화가 뉴스 변수[14]를 통해 일부 예측될 수 있음에도 조정 빈도가 낮고 무작위성이 커 머신러닝 기법을 통한 학습 및 예측이 어려운 점을 발견하였다[15]. 이 문제를 해결하고 예측력 향상을 위해 주요 공공요금 품목군에 대해서는 뉴스 변수에 대해 일차적으로 선형회귀를 한 후 잔차 부분만을 머신러닝 방식을 활용하여 예측하였다[16].

4 예측력 평가 방식

전체 데이터는 2005년 1월부터 2024년 6월까지의 시계열로 구성[17]되며, 2014.1월부터 2024.6월까지 약 10년 간의 월별 소비자물가 상승률의 실적치(전년동월대비)를 모형의 표본외out of sample 예측으로 도출한 당월Nowcasting 및 익월 전망치와 비교하였다[18]. 평가 기준이 되는 예측오차는 평균절대오차Mean Absolute Error와 평균제곱오차Mean Squared Error로로 측정하였다.

---

12) 한희준(2024)은 우리나라 소비자물가지수의 단기 예측에 있어 보루타-랜덤포레스트 모형이 다른 머신러닝 및 시계열 모형보다 예측력이 우수하다는 것을 보였다.
13) 따라서 구축된 예측모형은 headline 인플레이션 실적치 대비 오차를 최소화하는 것이 아닌 개별 하위품목군 가격상승률의 실적치 대비 오차를 최소화하는 방식이다.
14) 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 품목관련 뉴스지수를 작성하고 변수목록에 포함시켰다.
15) 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.
16) 이 방식에 대한 자세한 설명은 <참고 3>「공공요금 관련 뉴스변수 및 분석방식」에서 확인할 수 있다.
17) 시계열 분석 및 머신러닝 학습을 위해서는 가용한 데이터 시계를 최대화하는 것이 유리하다고 알려져 있다. 그러나 데이터 시계를 지나치게 확장할 경우 가용한 설명변수의 수가 줄어드는 단점도 있어 기존 연구들은 중요한 설명변수들이 최대로 가용 가능한 수준에서 기간을 설정한다. 본고는 주택매매지수, 지역난방비 등 분석에 중요한 설명변수와 종속변수가 가용 가능한 최대 시계에서 데이터 시작 시점을 설정하였다. 평가기간의 경우에는 장기간의 모형 예측력을 검토하기 위해 2014.1월부터 2024.6월까지로 설정하였다. 평가기간을 최근으로 한정하더라도 결과는 유사하다.
18) 각 예측 시점에 가용한 모든 데이터를 활용(recursive window)하였다. 관련 연구에서는 recursive window 대신 예측에 사용되는 데이터를 일정 기간으로 한정하는(rolling window) 방식을 사용하기도 한다.

[예측오차 측정 방식]

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

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

또한 한희준(2024)에서 모형 간 예측력 비교에 사용된 것과 같이 Giacomini-White(2006)의 방법을 적용[19]하여 품목을 얼마나 세분화할수록 통계적으로 유의하게 더 좋은 예측력을 가지는지 검정하였다.

[귀무가설]

$$H_0 : E[L_{t+\tau}(\pi_{t+\tau}, \hat{\pi}^A_{t+\tau}) - L_{t+\tau}(\pi_{t+\tau}, \hat{\pi}^B_{t+\tau}) | G_t] = 0 \quad \cdots (6)$$

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

Ⅲ. 예측력 평가 및 주요 결과

예측력 평가를 위해 모형별로 예측오차를 비교해 보면, 보루타-랜덤포레스트 모형[BR]이 일반적인 시계열 모형(자기회귀[AR], 랜덤워크[RW])보다 예측력이 우수한 것으로 확인되었다. [표 1]은 당월 전망(당월 20일경) 및 익월 전망에 대한 모형별 예측치의 평균절대오차(MAE)를 보여주고 있는데, BR 모형의 경우 직접 예측치 및 상향식 예측치 모두 여타 시계열 모형에 비해 예측오차가 작다. BR 모형 내에서는 품목 세분화 단계가 높은 상향식 예측일수록 예측력이 개선된다는 점이 확인된다. 하지만 5단계(30개 품목군) 이상에서는 예측오차가 오히려 오히려 커지는 것으로 나타난다.

좀 더 구체적으로 살펴보면 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(21년 이후)에서는 당월 예측력이 더욱 개선되어 5단계 상향식의 MAE가 0.136%p로 직접 예측방식보다 오차를 26% 정도 줄일 수 있는 것으로 나타났다[20]. [그림 3]는 2023년 1월 이후 직접 예측방식과 상향식 예측

[표 1] 모형 및 세분화 단계별 예측오차[1)]

(%p)

모형			보루타-랜덤포레스트[BR][1)]						자기회귀[AR][2)]		랜덤워크[RW][2)]	
분류단계			1단계 (=직접 예측)	2단계	3단계	4단계	5단계	6단계	1단계	6단계	1단계	6단계
MAE	당월 (20일경)	전 기간	0.194	0.188	0.172	0.155	0.141	0.142	0.264	0.243	0.328	0.330
		최근(21년~)	0.184	0.167	0.156	0.149	0.136	0.136	0.242	0.229	0.277	0.273
	익월	전 기간	0.227	0.226	0.209	0.205	0.188	0.189	0.264	0.243	0.328	0.330
		최근(21년~)	0.221	0.223	0.212	0.219	0.201	0.203	0.242	0.229	0.277	0.273
MSE	당월 (20일경)	전 기간	0.061	0.059	0.051	0.042	0.036	0.037	0.108	0.098	0.169	0.173
		최근(21년~)	0.059	0.051	0.046	0.038	0.035	0.036	0.097	0.100	0.123	0.122
	익월	전 기간	0.083	0.080	0.069	0.068	0.062	0.062	0.108	0.098	0.169	0.173
		최근(21년~)	0.079	0.081	0.073	0.073	0.070	0.072	0.097	0.100	0.123	0.122

주: 1) 초록색 음영은 최저 오차

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

방식의 오차를 비교하고 있는데, 대부분 시점에서 상향식 예측방식의 오차가 작은 것으로 나타났다. 익월 전망의 경우에도 5단계 상향식의 예측오차가 0.188%p(21년 이후 0.201%p)로 직접 예측방식 대비 약 17%(9%) 작은 것으로 분석되었다. 이러한 결과는 예측오차를 제곱평균오차(MSE)로 측정하더라도 유사하게 나타난다.

또한 상향식 모형의 예측오차는 시장 서베이나 기존 연구의 머신러닝 예측치에 비해서도 30~60% 정도 작은 것으로 확인된다. 기존 머신러닝 기반 직접 예측식 인플레이션 모형은 예측오차(MAE)[21]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%p)의 예측오차에 비해 상당폭 큰 수준이다.

[그림 3] 예측 방식에 따른 나우캐스팅 오차[1)]

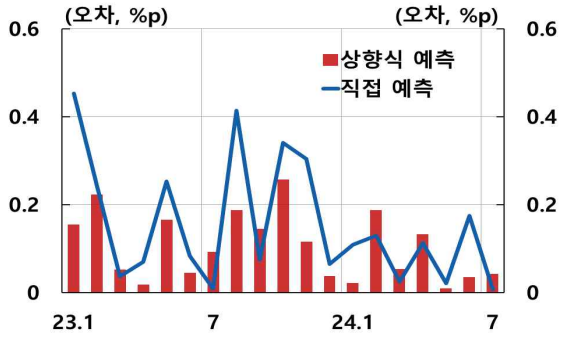

주: 1) 절댓값 오차 자료: 저자 작성

[표 2]는 모형 간 예측력의 차이가 통계적으로 유의한지를 검증하는 Giacomini-White(GW) 테스트의 통계량으로, 양수(+)일 경우 B모형의 예측오차가 A모형보다 작다는 것을 나타내고, 귀무가설이 기각될 경우 B모형의 예측력이 A모형보다 통계적으로 우수하다는 것을 의미한다[22].

[표 2] 모형간 예측력 차이 평가(Giacomini-White test)[1)]

A 모형 \ B 모형	RW (6단계)	AR (1단계)	AR (6단계)	BR (1단계)	BR (2단계)	BR (3단계)	BR (4단계)	BR (5단계)	BR (6단계)
RW (1단계)	-0.54	3.62***	3.75***	6.21***	6.09***	6.62***	7.74***	8.35***	8.29***
RW (6단계)		3.67***	3.74***	6.20***	6.13***	6.63***	7.67***	8.24***	8.19***
AR (1단계)			1.78*	5.67***	5.58***	6.22***	7.46***	8.02***	7.94***
AR (6단계)				4.11***	4.36***	5.39***	6.73***	7.48***	7.57***
BR (1단계)					0.88	2.86***	4.87***	5.12***	4.99***
BR (2단계)						2.41**	4.20***	4.72***	4.56***
BR (3단계)							2.74***	3.61***	3.45***
BR (4단계)								2.43**	2.16**
BR (5단계)									-0.49

주: 1) 당월 중순(20일경) 예측기준, 2) *, **, ***은 각각 10%, 5%, 1% 수준에서 통계적으로 유의함을 의미
자료: 저자 추정

20) 익월 예측치의 경우 팬데믹 이후 기간의 MAE가 전체기간에 비해 소폭 커지는데, 이는 팬데믹 이후의 인플레이션의 단기 변동성이 확대된 데 기인하는 것으로 판단된다. 보다 최근의 시기인 23년 이후 기간의 오차수준은 0.11%p(당월기준) 수준으로 나타났다.

21) 연구자에 따라 예측력 평가 기간이 다소 차이가 있지만 MAE로 본 예측오차가 한희준(2024)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.

22) 예를 들어, 5행 9열 칸의 수치(4.99)는 보루타-랜덤포레스트 방식을 활용한 1단계 직접 예측방식(BR 1단계)과 6단계 상향식 예측방식(BR 6단계)의 예측력 차이에 대한 통계값으로 BR 6단계 방식의 예측오차가 BR 1단계 방식에 비해 작고, 통계적으로 1% 수준에서 '두 모형 간 예측력 차이가 없다'는 귀무가설(H_0)을 기각할 수 있음을 뜻한다.

검증 결과에서 나타나듯이, BR 모형의 예측력이 여타 시계열 모형에 비해 통계적으로 유의하게 우위에 있는 것으로 나타나며, BR 모형 내에서는 앞서 살펴본 바와 같이 세분화 단계가 높아질수록 예측력이 개선되는 점이 통계적으로 뒷받침된다. 다만, BR 6단계와 BR 5단계 모형의 예측력의 차이는 통계적으로 유의하게 나타나지 않았다[23]. 이는 30개 품목군(BR 5단계)의 가격 상승률을 추정하고 이를 합산하여 전체 인플레이션을 전망하는 상향식 방식의 예측력이 가장 효율적이고 우수함을 의미한다[24].

다음으로 예측 시점에 따라 정보량이 차이가 나고 오차도 달라지기 때문에 예측 시점의 설정이 중요하다. [그림 4]은 5단계 상향식 방식으로 도출한 예측치의 오차를 예측 시점별로 비교한 것이다. 예측오차는 한 달 전(전월 CPI 발표일) 시점에서 당월 소비자물가 발표일에 가까워질수록 정보변수가 추가적으로 입수되면서 예측오차가 줄어드는 경향이 있다. 다만, 당월 중순(20일경) 이후에는 오차의 개선 정도가 크지 않은 것으로 나타났다[25].

[그림 4] 예측 시점[1]에 따른 예측오차

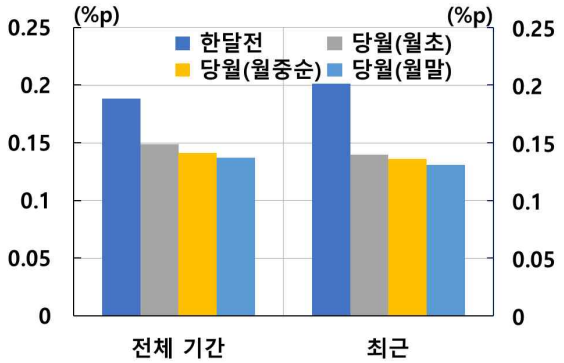

주: 1) 한달전: 전월 CPI발표일, 당월(월초): 10일경, 당월(월중순): 20일경, 당월(월말): 월 마지막 일
자료: 저자 작성

한편 전망 시계별로 비교해 보면, 1단계의 직접 예측방식과 비교한 상향식 방식의 예측력은 전망 시계가 당월일 경우 가장 크며, 예측 시계가 늘어날 경우 개선 정도가 다소 줄어드는 것으로 나타났다([그림 5] 참조).

[그림 5] 전망 시계별 예측오차

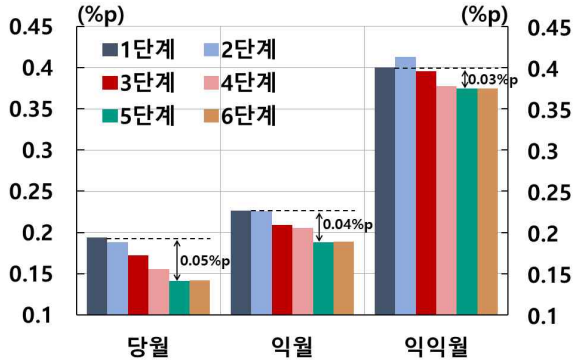

자료: 저자 작성

예측의 정확성 외에도 상향식 방식은 직접 예측방식과 달리 품목군별 물가상승률 예측치를 도출할 수 있다는 장점이 있다. [그림 6]은 주요 품목군 물가상승률의 2023년 1월 이후 실적치와 예측치를 비교한 것이다. 품목군별 물가의 예측오차(MAE)를 보면, 농축수산물과 석유류와 같이 변동성이 높은 비근원(non-core) 품목은 오차가 비교적 큰 반면, 근원상품·서비스, 집세 등 근원품목과 비근원품목 중 가공식품은 오차가 작은 것으로 나타났다([그림 7] 참조).

23) BR 2단계와 BR 1단계 간의 예측오차 차이도 통계적으로 유의하지 않다.
24) 익월 예측 또한 Giacomini-White 검정 결과 5단계 이상 세분화할 경우 예측력의 차이가 통계적으로 유의하지 않는 것으로 나타났다. 자세한 결과는 <참고4>를 확인하기 바란다.
25) 소비자물가통계 조사가 대체로 월 중하순에 이루어져 이후 입수된 정보들이 당월 지수 예측에 크게 도움이 되지 않을 가능성이 있다.

[그림 6] 주요 품목별 물가상승률 실적치 vs 전망치

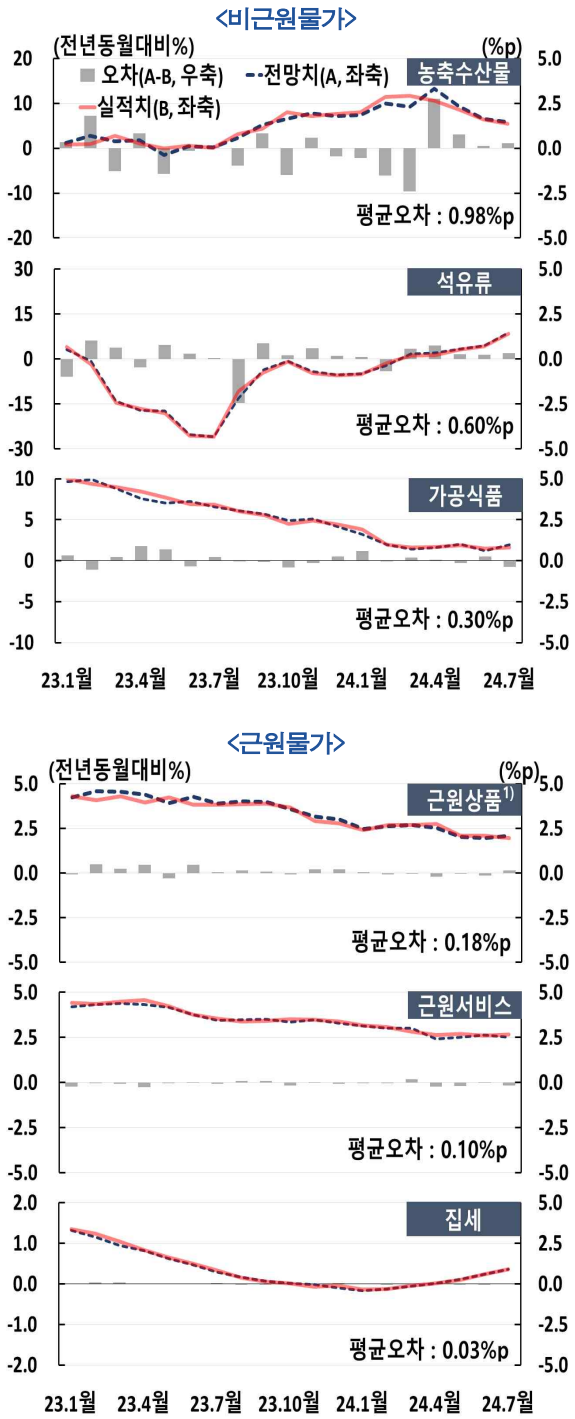

주: 1) 가공식품 제외 자료: 저자 작성

[그림 7] 품목별 물가상승률 예측오차(전기간)

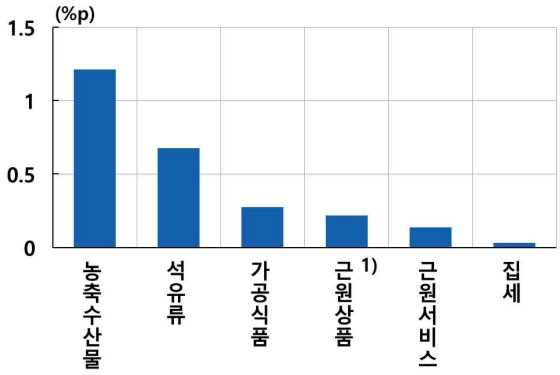

주: 1) 가공식품 제외 자료: 저자 작성

한편 상향식 방식에서 예측력이 높아지는 주된 이유는 품목별 물가 흐름을 잘 설명하는 이질적이고 다양한 정보를 활용하기 때문[26]인 것으로 판단된다. headline 인플레이션을 직접 예측하는 경우 보루타 셀렉션을 통해 37개의 정보변수[27]만 이용되지만, 상향식 예측 시에는 523개로 정보량이 대폭 늘어난다([그림 8] 참조).

[그림 8] 예측방식별 사용정보량[1)]

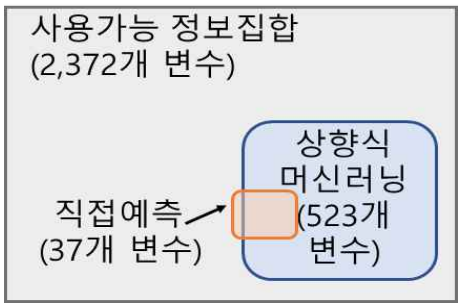

주: 1) 당월예측 기준 자료: 저자 작성

머신러닝을 통해 각 품목군의 설명변수로 선정된 정보들을 보면, 농산물은 기상여건, 석유류는 주유소 가격정보와 유류세, 가공식품은 유제품가격 및 관련 생산자물가지수 등으로 해당 품목군의 가격과 연관성이 높은 변수가 선정되

26) Barker(2014)는 상향식 예측의 장점으로 더 많고 이질적인 정보집합을 사용할 수 있다는 점을 제시하였다.
27) 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.

고 있음을 알 수 있다([표 3] 참조). 기존 연구들에서도 상향식 전망방식의 정확도가 높은 이유로 각 품목군 가격의 고유한 변동성과 지속성을 잘 반영한 결과일 수 있음을 제시한 바 있다(Bermingham· D'Agostino, 2014)[28].

[표 3] 품목군별 모형의 주요 설명변수[1)]

	주요 정보변수
농축수산물	지역별 기온·강수량, 농축수산물 관련 소비자물가지수, 생산자물가지수 등
석유류	주유소 판매가격, 두바이현물가격, 원유 수입물가지수, 휘발유·경유·등유 생산자물가지수, 유류세 정보 등
가공식품	유제품 관련 소비자물가지수, 과자·주류 등 생산자물가지수
근원상품	공급물가지수, 소매판매액지수 등
근원서비스 (집세 제외)	서비스업 생산지수, 소비자물가지수 중 서비스 품목, 생산자물가지수 등
집세	전세·월세 소비자물가지수, 매매가격지수, 전세가격지수 등

주: 1) 당월예측 기준 자료: 저자 작성

IV. 단기 인플레이션 예측 결과

5단계 상향식 모형을 사용하여 이번달(24.8월)과 다음달(9월)의 인플레이션을 추정해본 결과, 7월에 소폭 반등하였던 headline 인플레이션율이 8월 2.1% 내외, 9월 2.0% 내외로 다시 둔화되는 것으로 예측되었다. core 인플레이션율은 8·9월 모두 2.1% 내외 수준으로 모형에서 예측되었다([그림 9] 참조)[29].

품목별 가격상승률에 대한 모형 예측에 따르면, 비근원품목에서는 농산물가격 오름세가 양호한 기상여건 등으로 완만한 둔화세를 이어가고 오름세가 확대되던 석유류가격 상승률은 최근 국제유가 하락 등을 반영하여 앞으로 둔화될 것으로 나타났다. 가공식품 가격상승률은 2% 내외 수준에서 안정될 것으로 예측되었다. 근원품목의 경우 근원상품가격 상승률은 최근의 더딘 소비회복세 등으로 2%를 소폭 밑도는 수준으로 나타나며, 근원서비스물가(집세 제외)는 2%대 중반 수준에서 완만한 오름세 둔화 흐름을 이어갈 것으로 모형은 예측하였다. 반면, 집세는 그간 전세가격지수 상승세 등이 반영되면서 완만한 상승 흐름을 이어나갈 것으로 추정되었다([그림 10] 참조).

이상에서 설명한 예측치는 현 시점에서 가용한 정보를 바탕으로 한 것으로, 추가적인 데이터가 입수되면 수정될 수 있으며, 소비자물가총지수 기준으로 예측 시계에 따라 평균 0.14~0.37%p의 오차를 가진다는 점을 고려하여 해석에 유의할 필요가 있다.

[그림 9] 향후 인플레이션 예측(모형 예측)

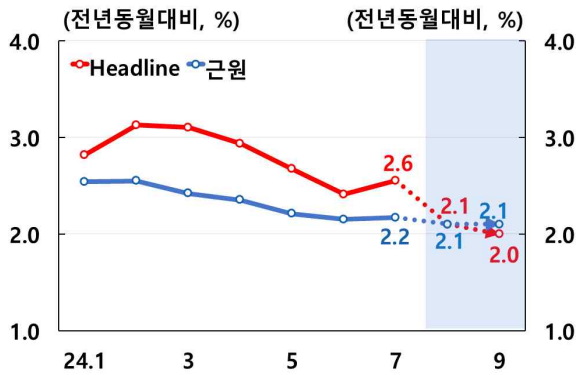

자료: 저자 추정

28) 국내 소비자물가지수의 상향식 예측에도 품목별가격의 고유 변화가 영향을 미치는지 검증하기 위해, 정보효과를 제거하고 변동성 및 지속성만으로 상향식 예측방식의 예측력이 높아지는지 실험해 보았다. 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 품목에 대한 정보량이 예측력 개선에 도움이 되는 요인으로 판단된다(<참고5> 참조).

29) 동 예측치는 현 시점에서 가용한 정보를 바탕으로 머신러닝을 통해 추정된 것으로 한국은행 8월 전망과는 차이가 있다.

[그림 10] 품목별 인플레이션 예측(모형 예측)

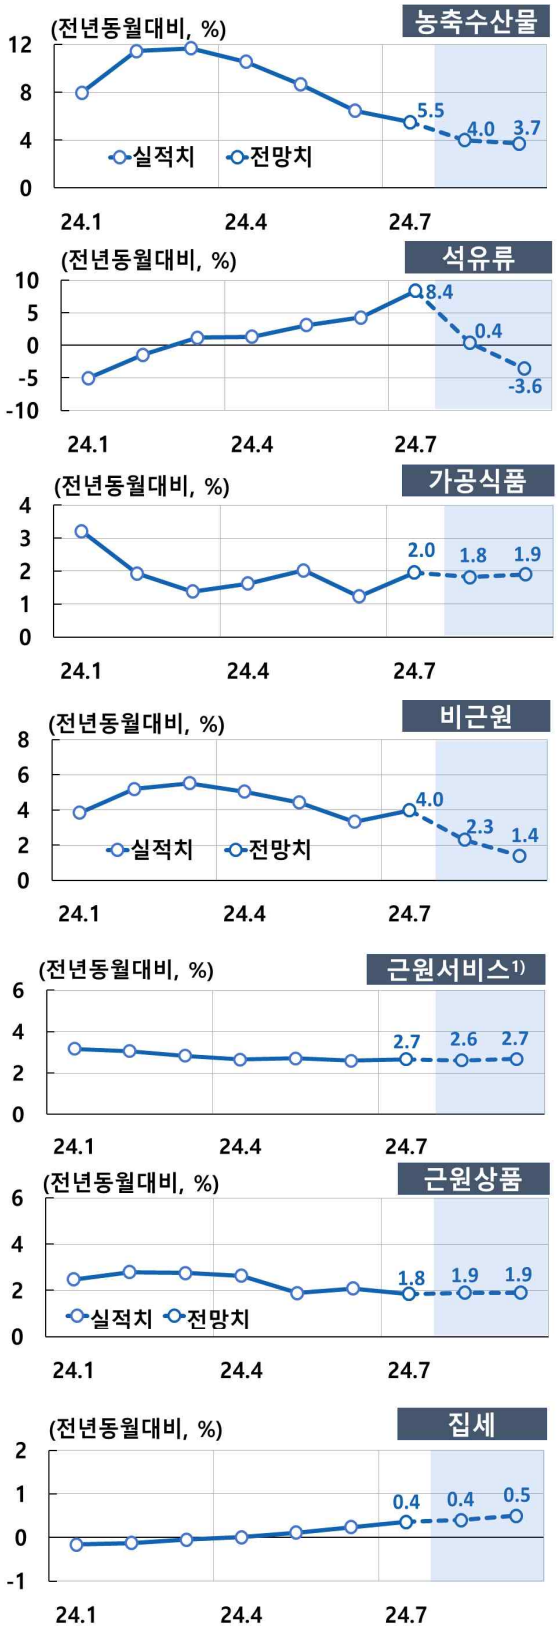

주: 1) 집세제외 자료: 저자 추정

Ⅴ. 요약 및 시사점

본고에서는 최근 중요성이 강조되고 있는 단기 인플레이션 전망의 예측력 향상을 위해 상향식 머신러닝 기반 모형을 구축하여 분석하였다. 과거 10년간 예측오차를 기반으로 평가해 본 결과, 상향식 머신러닝 기법을 통한 인플레이션 예측이 직접 예측식 머신러닝 모형, 전통적인 시계열 모형, 전문가 서베이 등에 비해 상당히 우수한 것으로 나타났다. 또한 이 방식을 통해 향후 소비자물가의 전체 상승률뿐만 아니라 세부 품목들의 단기적인 가격 변화도 예측할 수 있음을 보였다.

다음과 같은 한계점도 존재한다. 본 연구는 전체 인플레이션을 효율적으로 예측하는 데 중점을 두기 위해 품목별로 공통적인 머신러닝 모형을 사용하였다. 하지만 특정 품목군에 대해서는 보루타-랜덤포레스트 알고리즘 이외의 머신러닝 모형이 더 적합하고 예측력이 향상될 가능성이 있다. 향후 연구에서는 품목군별 최적의 머신러닝 기법을 선정하여 예측력을 비교해 본다면, 품목군별 가격예측력을 더욱 개선시킬 수 있을 것으로 기대된다.

또한 본 연구는 1~2개월 이내의 나우캐스팅 및 단기 인플레이션 예측에 초점을 맞추고 있으나, 본고에서 사용된 방식을 활용하여 좀 더 긴 시계의 예측 체계를 개발해 볼 수 있겠다.

마지막으로 본고에서 개발된 상향식 예측방식과 머신러닝 기법의 결합을 국민총생산, 산업활동지수, 주가종합지수 등 하위 단계지표들로 구성된 다양한 거시변수를 예측하는 데에도 응용해볼 수 있을 것이다.

<참고 1>

상향식 단계별 품목군

[표 A.1] 각 단계별 구성 품목군

Level 1	Level 2	Level 3 (9개 품목)	Level 4 (23개 품목)	Level 5 (30개 품목)	Level 6 (33개 품목)
총지수	근원	내구재	차량	차량	차량
			차량제외	차량제외	차량제외
		섬유제품	섬유제품	섬유제품	섬유제품
		집세	집세	전세	전세
				월세	월세
		공공서비스	공공서비스	공공서비스1[1]	공공서비스1[1]
				공공서비스2[2]	공공서비스2[2]
		외식	외식	외식	외식
		외식제외 개인서비스	외식제외 개인서비스	외식제외 개인서비스	외식제외 개인서비스
		기타 근원상품	출판물	출판물	출판물
			의약품	조제약	조제약
				조제약제외의약품	조제약제외의약품
			화장품	화장품	화장품
			기타공업제품	기타공업제품	기타공업제품
			근원가공식품	근원가공식품	근원가공식품
			화초·인삼	화초·인삼	화초·인삼
			상수도료	상수도료	상수도료
	비근원	식료품	비근원가공식품	비근원가공식품	비근원가공식품
			화초·인삼 제외 기타농산물	화초·인삼 제외 기타농산물	화초·인삼 제외 기타농산물
			곡물	곡물	쌀
					쌀 제외 곡물
			채소	채소	배추, 토마토, 마늘
					기타 채소
			과실	과실	사과, 포도, 귤, 딸기
					기타 과실
			축산물	축산물	축산물
			수산물	수산물	수산물
		에너지	전기·가스·난방	전기료	전기료
				도시가스	도시가스
				지역난방비	지역난방비
			석유류	휘발유	휘발유
				경유	경유
				휘발유, 경유 제외 석유류	휘발유, 경유 제외 석유류

주: 1) 외래진료비, 휴대전화료, 입원진료비, 시내버스료 2) 공공서비스 중 공공서비스1 제외

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·에너지제외 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, 과실, 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.

<참고 2>

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 보통휘발유 및 자동차용경유 가격의 평균을 누적해서 변수로 활용하였다. tcode는 해당 변수를 정상시계열로 변환하기 위한 방식을 나타낸다.

[표A.2] 설명변수 목록(소비자, 생산자물가 제외)

	변수 코드	설명	tcode[1)]
1	PI_CA	생산지수(계절조정)-자본재	5
2	SI_CA	생산자제품 출하지수(계절조정)-자본재	5
3	II_CA	생산자제품 재고지수(계절조정)-자본재	5
4	PI_I	생산지수(계절조정)-중간재	5
5	SI_I	생산자제품 출하지수(계절조정)-중간재	5
6	II_I	생산자제품 재고지수(계절조정)-중간재	5
7	PI_CO	생산지수(계절조정)-소비재	5
8	SI_CO	생산자제품 출하지수(계절조정)-소비재	5
9	II_CO	생산자제품 재고지수(계절조정)-소비재	5
10	PI_W	생산지수(계절조정)-총지수	5
11	SI_W	생산자제품 출하지수(계절조정)-총지수	5
12	II_W	생산자제품 재고지수(계절조정)-총지수	5
13	PI_MM	생산지수(계절조정)-광업 및 제조업	5
14	SI_MM	생산자제품 출하지수(계절조정)-광업 및 제조업	5
15	II_MM	생산자제품 재고지수(계절조정)-광업 및 제조업	5
16	PI_MQ	생산지수(계절조정)-광업	5
17	SI_MQ	생산자제품 출하지수(계절조정)-광업	5
18	PI_MF	생산지수(계절조정)-제조업	5
19	SI_MF	생산자제품 출하지수(계절조정)-제조업	5
20	II_MF	생산자제품 재고지수(계절조정)-제조업	5
21	PI_E	생산지수(계절조정)-전기업 및 가스업	5
22	SI_E	생산자제품 출하지수(계절조정)-전기업 및 가스업	5
23	Unemployment	실업률(계절조정)-계	2
24	Act_pop_total	경제활동인구-계	5
25	Employed_total	취업자-계	5
26	Unemployed_3mts	실업자수(구직기간3개월미만)	5
27	Unemployed_3_6mts	실업자수(구직기간3개월-6개월)	5
28	Unemployed_6_12mts	실업자수(구직기간6개월-12개월)	5
29	Unemployed_ov6	실업자수(구직기간6개월이상)	5
30	Unemployed_ov12	실업자수(구직기간12개월이상)	2
31	HousePrice	매매가격지수	5
32	HousePrice_S	매매가격지수-수도권	5
33	HousePrice_P	매매가격지수-지방권	5
34	BSI_BC	기업경기조사(전산업)-업황전망	1
35	BSI_SG	기업경기조사(전산업)-매출전망	1
36	BSI_P	기업경기조사(전산업)-채산성전망	1
37	BSI_FS	기업경기조사(전산업)-자금사정전망	1
38	BSI_HR	기업경기조사(전산업)-인력사정전망	1
39	PI_P	시도/산업별 광공업생산지수(계절조정)-총지수	5
40	PI_C	전산업 생산지수(계절조정)-건설업	5
41	PI_SI	산업별 서비스업 생산지수(계절조정)-총지수	5
42	PI_PA	전산업 생산지수(계절조정)-공공행정	5
43	MB	본원통화(평잔,계절조정계열)	5
44	Currency_cir	현금통화	5
45	CBLIAB_DC	중앙은행 대 예금취급기관부채	5
46	M1	M1(평잔, 원계열)	5
47	M2	M2(평잔, 원계열)	5
48	CD	CD(91일)	2

49	CP	CP(91일)	2
50	YT_1	국고채(1년)	2
51	YT_3	국고채(3년)	2
52	YT_5	국고채(5년)	2
53	YT_10	국고채(10년)	2
54	CB_3_AA	회사채(3년, AA-)	2
55	BaseRate	한국은행 기준금리	2
56	CB_3_BBB	회사채(3년, BBB-)	2
57	FX_US	원/미국달러(매매기준율)-평균자료	5
58	FX_CH	원/위안(매매기준율)-평균자료	5
59	FX_JP	원/일본엔(100엔)-평균자료	5
60	FX_EU	원/유로-평균자료	5
61	FX_BR	원/영국파운드-평균자료	5
62	FX_CA	원/캐나다달러-평균자료	5
63	FX_SW	원/스위스프랑	5
64	SPI_R	국내공급물가지수-원재료	5
65	SPI_I	국내공급물가지수-중간재	5
66	SPI_F	국내공급물가지수-최종재	5
67	SPI_RI	국내공급물가지수-생산재(원재료+중간재)	5
68	IPI_A	수입물가지수-농림수산품-원화기준	5
69	IPI_B	수입물가지수-유연탄-원화기준	5
70	IPI_C	수입물가지수-원유-원화기준	5
71	IPI_L	수입물가지수-천연가스(LNG)-원화기준	5
72	IPI_M	수입물가지수-공산품-원화기준	5
73	EPI_A	수출물가지수-농림수산품-원화기준	5
74	EPI_M	수출물가지수-공산품-원화기준	5
75	KOSPI	KOSPI_종가	5
76	KOSDAQ	KOSDAQ_종가	5
77	Expected_inf	기대인플레이션율	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	주택담보대출	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	경기종합지수-선행종합지수(2020=100)	5
84	LaggingCI	경기종합지수-후행종합지수(2020=100)	5
85	VKOSPI	VKOSPI 지수	1
86	CLI_1	강원영서-평균기온	1
87	CLI_2	강원영서-평균기온 전년동월대비 상승률	1
88	CLI_3	충북-평균기온	1
89	CLI_4	충북-평균기온 전년동월대비 상승률	1
90	CLI_5	충남-평균기온	1
91	CLI_6	충남-평균기온 전년동월대비 상승률	1
92	CLI_7	경남-평균기온	1
93	CLI_8	경남-평균기온 전년동월대비 상승률	1
94	CLI_9	전남-평균기온	1
95	CLI_10	전남-평균기온 전년동월대비 상승률	1
96	CLI_11	제주-평균기온	1
97	CLI_12	제주-평균기온 전년동월대비 상승률	1
98	ADD_1	생산지수(계절조정)-자본재	5
99	ADD_2	생산지수(계절조정)-중간재	5
100	ADD_3	생산자제품 출하지수(계절조정)-자본재	5
101	ADD_4	생산자제품 출하지수(계절조정)-중간재	5
102	ADD_5	생산자제품 재고지수(계절조정)-자본재	5
103	ADD_6	생산자제품 재고지수(계절조정)-중간재	5
104	ADD_7	내수출하지수(계절조정)-자본재	5
105	ADD_8	내수출하지수(계절조정)-중간재	5
106	ADD_9	생산지수(계절조정)-광업	5
107	ADD_10	생산지수(계절조정)-제조업	5

108	ADD_11	생산지수(계절조정)-전기업 및 가스업	5
109	ADD_12	생산자제품 출하지수(계절조정)-광업	5
110	ADD_13	생산자제품 출하지수(계절조정)-제조업	5
111	ADD_14	생산자제품 출하지수(계절조정)-전기업 및 가스업	5
112	ADD_16	생산자제품 재고지수(계절조정)-제조업	5
113	ADD_18	서비스업 생산지수(계절조정)-수도, 하수 및 폐기물 처리, 원료 재생업	5
114	ADD_19	서비스업 생산지수(계절조정)-도매 및 소매업	5
115	ADD_20	서비스업 생산지수(계절조정)-운수 및 창고업	5
116	ADD_21	서비스업 생산지수(계절조정)-숙박 및 음식점업	5
117	ADD_22	서비스업 생산지수(계절조정)-정보통신업	5
118	ADD_23	서비스업 생산지수(계절조정)-금융 및 보험업	5
119	ADD_24	서비스업 생산지수(계절조정)-부동산업	5
120	ADD_25	서비스업 생산지수(계절조정)-전문, 과학 및 기술 서비스업	5
121	ADD_26	서비스업 생산지수(계절조정)-사업시설 관리, 사업지원 및 임대 서비스업	5
122	ADD_27	서비스업 생산지수(계절조정)-교육 서비스업	5
123	ADD_28	서비스업 생산지수(계절조정)-보건업 및 사회복지 서비스업	5
124	ADD_29	서비스업 생산지수(계절조정)-예술, 스포츠 및 여가 관련 서비스업	5
125	ADD_30	서비스업 생산지수(계절조정)-협회 및 단체, 수리 및 기타 개인 서비스업	5
126	ADD_31	서비스업 생산지수(계절조정)-총지수	5
127	ADD_32	보통휘발유가격-월 말일	5
128	ADD_33	자동차용경유말-월 말일	5
129	ADD_34	방한외래관광객수	1
130	ADD_35	고속도로통행량	1
131	ADD_36	수입물가지수(특수분류)(2015=100)-에너지이외-원화기준	5
132	ADD_37	수입물가지수(특수분류)(2015=100)-에너지이외-달러기준	5
133	ADD_38	수입물가지수(기본분류)(2015=100)-원유-달러기준	5
134	ADD_39	China PPI YoY	1
135	ADD_40	생산자물가지수(기본분류)(2015=100)-총지수	5
136	ADD_41	경기종합지수(2020＝100) (10차) (월 1970.01~2023.01)-경기종합지수-동행지수 순환변동치	2
137	ADD_42	재별 및 상품군별 소매판매액지수(2020＝100.0) (월,분기,년 1995.01~2023.01)-경상지수-총지수-2020＝100	5
138	ADD_43	계절조정 경제활동인구 총괄 (월,분기 1999.06~2021.11)-고용률-계-%	1
139	ADD_44	계절조정 경제활동인구 총괄 (월,분기 1999.06~2021.11)-취업자-계-천명	1
140	ADD_45	전국 주택가격 동향조사-전세가격지수-2021.06=100	1
141	ADD_46	Federal Reserve Bank of New York Global Supply Chain Pressure Index (NSA)	1
142	RAIN_1	강원영서-강수량	1
143	RAIN_2	충북-강수량	1
144	RAIN_3	충남-강수량	1
145	RAIN_4	경남-강수량	1
146	RAIN_5	전남-강수량	1
147	RAIN_6	제주-강수량	1
148	Dummy_CPI_20	전기료 더미	1
149	Dummy_CPI_21	도시가스 더미	1
150	Dummy_CPI_25	조제약 더미	1
151	Dummy_CPI_29	공공서비스 상위 가중치 품목 더미	1
152	FAO	국제식량가격지수	5
153	FAO_M	국제식량가격지수 - 육류	5
154	FAO_D	국제식량가격지수 - 유제품	5
155	FAO_C	국제식량가격지수 - 시리얼	5
156	FAO_O	국제식량가격지수 - 기름	5
157	FAO_S	국제식량가격지수 - 설탕	5
158	DIFF_RAIN_1	강원영서 강수량 월중평균 대비 차이	1
159	DIFF_RAIN_2	충북 강수량 월중평균 대비 차이	1
160	DIFF_RAIN_3	충남 강수량 월중평균 대비 차이	1
161	DIFF_RAIN_4	경남 강수량 월중평균 대비 차이	1
162	DIFF_RAIN_5	전남 강수량 월중평균 대비 차이	1
163	DIFF_RAIN_6	제주 강수량 월중평균 대비 차이	1

주: 1) tcode는 시계열 변환 방식을 나타내고, 1은 변환하지 않음, 2는 전월대비 상승분, 5는 전월대비 상승률로 변환한다는 것을 의미

<참고 3>

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 많을뿐더러, 변화 빈도도 매우 낮기 때문이다. 예를 들어 오랜기간 유지되던 특정 공공요금이 인상되는 경우 이는 일회성 인상 후 유지되는 경우가 많지만 머신러닝 모형은 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 예상이 가능하다. 이러한 부분을 상향식 단기 전망 예측기법에 포함시키기 위해 품목별 정책관련 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.

① 과거 뉴스를 기반으로 전기, 가스, 조제약, 공공서비스(의료, 대중교통) 품목이 다음달 가격 변화가 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 선형회귀후에 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.

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

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

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

<참고 4>

익월 예측치의 Giacomini-White test 결과

[표A.3] 모형간 예측력 차이 평가(Giacomini-White test)[1)]

A 모형 \ B 모형	RW (6단계)	AR (1단계)	AR (6단계)	BR (1단계)	BR (2단계)	BR (3단계)	BR (4단계)	BR (5단계)	BR (6단계)
RW (1단계)	-0.54	3.62***	3.75***	4.40***	4.25***	5.09***	5.36***	6.02***	5.92***
RW (6단계)		3.67***	3.74***	4.47***	4.29***	5.14***	5.37***	5.97***	5.89***
AR (1단계)			1.78*	2.99***	2.76***	4.00***	4.06***	4.97***	4.92***
AR (6단계)				1.57	1.47	2.72***	2.99***	4.08***	4.05***
BR (1단계)					0.19	2.59***	2.60***	3.50***	3.49***
BR (2단계)						2.56**	2.71***	3.60***	3.56***
BR (3단계)							0.70	2.63***	2.65***
BR (4단계)								2.87***	2.72***
BR (5단계)									-0.31

주: 1) *, **, ***은 각각 10%, 5%, 1% 수준에서 통계적으로 유의함을 의미 자료: 저자 추정

<참고 5>

과거 시차변수만 포함한 모형의 세분화 단계별 예측오차

[표A.4] 모형 및 세분화 단계별 예측오차

(%p)

모형		보루타-랜덤포레스트[BR]						자기회귀[AR]		랜덤워크[RW]	
분류단계		1단계 (=직접 예측)	2단계	3단계	4단계	5단계	6단계	1단계	6단계	1단계	6단계
MAE	전 기간	0.229	0.226	0.220	0.216	0.223	0.221	0.264	0.243	0.328	0.330
	최근(21년~)	0.213	0.209	0.216	0.217	0.229	0.225	0.242	0.229	0.277	0.273
MSE	전 기간	0.083	0.083	0.077	0.076	0.078	0.078	0.108	0.098	0.169	0.173
	최근(21년~)	0.076	0.073	0.077	0.077	0.080	0.079	0.097	0.100	0.123	0.122

참고문헌

이창훈, 홍지연, 이현창. (2024) "빅데이터와 기계학습 알고리즘을 활용한 실시간 인플레이션 전망", BOK 이슈노트, 제2024-5호.

한희준. (2024) 머신러닝 기법을 이용한 한국 인플레이션 예측: 시계열 지속성과 머신러닝 예측의 관계에 관한 사례연구, 국제경제연구, 30(2), 21-56.

Barker, T. S., & Pesaran, M. H. (2014). Disaggregation in econometric modelling—an introduction. In Disaggregation in Econometric Modelling (Routledge Revivals) (pp. 1-14). Routledge.

Barkan, O., Benchimol, J., Caspi, I., Cohen, E., Hammer, A., & Koenigstein, N. (2023). Forecasting CPI inflation components with hierarchical recurrent neural networks. International Journal of Forecasting, 39(3), 1145-1162.

Benalal, N., Diaz del Hoyo, J. L., Landau, B., Roma, M., & Skudelny, F. (2004). To aggregate or not to aggregate? Euro area inflation forecasting. Euro Area Inflation Forecasting (July 2004).

Bermingham, C., & D'Agostino, A. (2014). Understanding and forecasting aggregate and disaggregate price dynamics. Empirical Economics, 46(2), 765-788.

Bernanke, B. S. (2007, July). Inflation expectations and inflation forecasting. In Speech at the Monetary Economics Workshop of the National Bureau of Economic Research Summer Institute, Cambridge, Massachusetts (Vol. 10, p. 11).

Boaretto, G., & Medeiros, M. C. (2023). Forecasting inflation using disaggregates and machine learning. arXiv preprint arXiv:2308.11173.

Clark, T. E., Gordon, M. V., & Zaman, S. (2023). Forecasting Core Inflation and Its Goods, Housing, and Supercore Components (No. 23-34). Federal Reserve Bank of Cleveland.

Duarte, C., & Rua, A. (2007). Forecasting inflation through a bottom-up approach: How bottom is bottom? Economic Modelling, 24(6), 941-953.

Espasa, A., & Albacete, R. (2007). Econometric modelling for short-term inflation forecasting in the euro area. Journal of Forecasting, 26(5), 303-316.

Faust, J., & Wright, J. H. (2013). Forecasting inflation. In Handbook of economic forecasting (Vol. 2, pp. 2-56). Elsevier.

Giacomini, R., & White, H. (2006). Test of conditional predictive ability. Econometrica, 74:6, 1545-1578.

참고문헌

Hendry, D. F., & Hubrich, K. (2011). Combining disaggregate forecasts or combining disaggregate information to forecast an aggregate. Journal of Business & Economic Statistics, 29(2), 216-227.

Joseph, A., Potjagailo, G., Chakraborty, C., & Kapetanios, G. (2024). Forecasting UK inflation bottom up. International Journal of Forecasting.

Knotek II, E. S., & Zaman, S. (2019). Financial nowcasts and their usefulness in macroeconomic forecasting. International Journal of Forecasting, 35(4), 1708-1724.

Krüger, F., Clark, T. E., & Ravazzolo, F. (2017). Using entropic tilting to combine BVAR forecasts with external nowcasts. Journal of Business & Economic Statistics, 35(3), 470-485.

Martínez-Rivera, W., González-Molano, E. R., & Caicedo-García, E. (2023). Forecasting Inflation from Disaggregated Data: The Colombian case. Borradores de Economía; No. 1251.

Medeiros, M. C., Vasconcelos, G. F., Veiga, Á., & Zilberman, E. (2021). Forecasting inflation in a data-rich environment: the benefits of machine learning methods. Journal of Business & Economic Statistics, 39(1), 98-119.

Stock, J. H., & Watson, M. W. (2010). Modeling inflation after the crisis (No. w16488). National Bureau of Economic Research.

Copyright ⓒ BANK OF KOREA. All Rights Reserved

- 본 자료의 내용을 인용하실 때에는 반드시 "BOK 이슈노트 No. 2024-25에서 인용"하였다고 표시하여 주시기 바랍니다.
- 자료 내용에 대하여 질문 또는 의견이 있는 분은 커뮤니케이션국 커뮤니케이션기획팀(02-759-4759)으로 연락하여 주시기 바랍니다.
- 본 자료는 한국은행 홈페이지(http://www.bok.or.kr)에서 무료로 다운로드 받으실 수 있습니다.