

예측 조합을 활용한 양념채소 가격 예측 및 예측성과 분석

한은수*, 김선웅**, 윤병삼***

Contents

1. 서론	3
2. 연구 방법 및 절차	5
3. 분석 결과	15
4. 요약 및 결론	28

Keywords

양념채소(Spice Vegetables), 가격 예측(Price Forecasting), 예측 조합(Forecast Combination)

Abstract

본 연구는 주요 양념채소인 양파, 마늘, 건고추를 대상으로 ETS 지수평활, ARIMA, 인공 신경망 등의 가격 예측 모형을 추정하고, 이로부터 도출된 가격 예측치들을 조합하여 새로 만들어진 예측치가 개별 모형의 예측치보다 예측력이 향상되는지를 평가하였다. 예측 조합방식으로는 평균 및 중앙값을 이용한 단순 조합, 회귀 분석에 기반한 조합, 평균 제곱 오차(MSE) 및 평균 제곱 오차의 순위(MSE RANK)를 활용한 성과 기반의 조합, AIC 정보 기준에 기반한 조합방식을 적용하였다. 개별 모형으로부터 얻은 예측치를 조합한 결과, 전 품목에 걸쳐 예측력이 향상되었고, 예측 기간이 1개월에서 6개월로 이행할수록 예측 조합의 예측 오차가 개별 모형보다 상대적으로 더 작아져 예측 조합의 효과가 두드러지게 나타났다. 예측 조합방식에서는 MSE 및 MSE RANK를 활용한 성과 기반의 조합방식이 상대적으로 우수한 예측성적을 보였다. 본 연구는 주로 단일 모형의 예측력 평가에 중점을 둔 국내 선행연구와 달리 예측 조합방식을 국내 농산물 가격 예측에 적용했다는 점에서 학술적 의의가 있다.

* 충북대학교 농업경제학과 박사과정.

** 충북대학교 농업경제학과 부교수.

*** 충북대학교 농업경제학과 교수, 교신저자. e-mail: bsyoon@chungbuk.ac.kr

Forecasting Spice Vegetable Prices Using Forecast Combinations and Assessment of Forecasting Performance

Han Eun-Su^{*}, Kim Seon-Woong^{**}, Yoon Byung-Sam^{***}

Keywords

Spice Vegetables, Price Forecasting, Forecast Combination

Abstract

This study aims to determine whether forecast combinations improve predictive accuracy compared to individual price forecasting models. This study estimated forecasting models, including ETS, ARIMA, and Artificial Neural Networks, for three major spice vegetables: onion, garlic, and dried red pepper. The analysis evaluated whether combining forecasts from individual models improved predictive accuracy compared to using each model separately. The forecast combination methods employed included simple averaging and median-based combinations, regression-based combinations, performance-based combinations using Mean Squared Error (MSE) and MSE rank, and combinations based on the Akaike Information Criterion (AIC). The results showed that combining forecasts from individual models improved predictive accuracy for all three spice vegetables. Moreover, as the forecast horizon extended from 1 to 6 months, the prediction errors of the combined forecast were smaller than those of the individual models, highlighting the effectiveness of the combination approach. Among the methods, performance-based approaches using MSE and MSE ranks yielded the best forecasting performance. This study is academically significant because, unlike previous domestic studies that mainly focused on evaluating individual models, it applied forecast combination methods to agricultural price forecasting in Korea.

^{*} Ph.D Student, Department of Agricultural Economics, Chungbuk National University.

^{**} Associate Professor, Department of Agricultural Economics, Chungbuk National University.

^{***} Professor, Department of Agricultural Economics, Chungbuk National University, Corresponding author.
e-mail: bsyoon@chungbuk.ac.kr

1. 서론

농산물 가격 예측은 과거 데이터와 현재의 정보를 기반으로 미래 특정 시점의 가격 추세와 수준을 추정하는 것이다. 가격 예측치는 여러 전문가로부터 수집된 정보나 과학적인 방법 등을 통해 도출되고, 사전적으로 제공되는 예측 정보는 생산 농가, 유통 및 가공 관련 기업, 정부 등 다양한 경제주체의 의사 결정과 계획 수립에 영향을 미친다(Sun et al., 2023). 농가는 가격 예측 정보를 고려하여 생산 품목, 재배 규모, 최적의 출하 시기 등을 결정하는 경영 전략을 수립한다. 유통 및 가공 관련 기업은 수요와 공급 상황에 맞춰 구매와 재고관리 등의 계획을 세운다. 정부도 수급 예측을 담당하는 한국농촌경제연구원 농업관측센터 등 여러 경로를 통해 입수된 수급 전망자료에 기초하여 수급 안정 대책을 마련한다(윤민정 외, 2024). 이처럼 가격 예측 정보는 다양한 경제주체에 의해 활용되는 만큼 신속하고 정확하게 제공되는 것이 중요하다. 그러나 최근 기후 변화 등의 영향으로 주요 농산물의 가격 변동성이 확대되고 있고, 가격 예측에 대한 불확실성도 커지고 있다(Zhang, 2023).

농산물 가격 예측의 불확실성에 대응하고, 예측력을 강화하기 위해서는 다양한 예측 기법이 고려될 수 있다. 예측 방법은 크게 정성적인(qualitative) 방법과 정량적인(quantitative) 방법으로 구분된다. 정성적 분석은 생산 지역 및 시장의 공급 상황을 종합적으로 파악하고, 전문가의 경험과 직관을 바탕으로 가격 추세에 대한 방향성을 예측하는 방법이다. 이 방법은 기상 여건에 따라 가격 변동이 심한 농산물을 대상으로 신속한 예측이 필요한 경우 유용할 수 있다. 그러나 정성적 판단을 통해 입수된 예측 정보는 개별 전문가에 따라 차이가 날 수 있어 객관적인 전망치를 도출하는데 한계가 있고, 이를 보완하기 위해 정량적 분석이 고려된다. 정량적 분석은 회귀모형, 시계열(time series) 모형, 머신러닝 알고리즘(machine learning algorithm) 등의 다양한 기법을 통해 가격 예측치를 만들어 냈으므로 보다 객관적이고 구체적인 수치를 제공할 수 있다(Sun et al., 2023).

정량적 분석을 시행할 때는 다양한 개별 모형의 구조(structure)를 이해하고, 농산물 가격 자료에 포함된 추세(trend), 계절성(seasonality) 등의 복잡한 패턴과 시간에 따라 변화는 특성을 적절하게 반영하는 모형의 선택이 중요하다(Sun et al., 2023). 그러나 분석대상 자료에 적합한 최적의 모형은 표본의 크기, 빈도, 예측 범위, 평가지표 등 연구자가 설정한 다양한 시나리오에 따라 예측력이 크게 달라질 수 있다. 즉, 개별 모형이 특정 데이터에 대해 우수한 예측력을 보이더라도 구조적 변화(structural breaks) 등 데이터의 변동에 따라 예측력이 일정하게 유지되지 않을 수 있다(Hyndman & Athanasopoulos, 2021).

개별 예측 모형 선택의 한계 및 불확실성을 완화하는 전략 중 하나로 여러 개별 모형의 예측치를 먼저 도출한 후 각기 다른 가중치를 부여하여 결합하는 예측 조합(forecast combination) 방식이 널리 적용되고 있다. 예측 조합은 한 마디로 여러 개의 예측 모형에서 나온 서로 다른 예측치를 결합하여 더 나은 예측치를 얻기 위한 접근방법이다. 예측 조합은 단일 예측 모형의 불완전성을 상호 보완하고, 포트

폴리오 이론과 유사하게 전체적인 예측 오차의 분산을 감소시키며, 단일 모형 선택에 따른 불확실성과 오류를 완화함으로써 예측의 정확성과 안정성을 동시에 제고할 수 있는 효과적인 접근법으로 평가되고 있다(Bates & Granger, 1969; Clemen, 1989; Aiolfi & Timmermann, 2006; Wang et al., 2022). 특히 가격 시계열은 비선형성, 구조적 변화, 외부적 충격 등을 종종 내포하는데, 이러한 복잡하고 동적인 환경에서는 단일 예측 모형에 본질적인 한계가 존재할 수밖에 없어 예측 조합 전략의 유용성이 더욱 두드러진다고 할 수 있다.

예측 조합 방법은 Bates & Granger(1969), Clemen(1989) 등 다수의 실증 연구를 통해 적용되었고, 개별 예측치를 단순히 평균하는 방법으로도 예측력이 향상되는 결과가 제시되었다. 이러한 이점을 가지는 예측 조합방식은 국외의 소매, 에너지, 경제학, 농업 등 다양한 분야에 응용되었다. 그리고 평균 방식의 단순한 조합법 외에도 개별 예측치를 조합하기 위한 가중치 추정 방법으로 회귀분석의 추정 계수를 이용하는 방법, 예측 오차 및 예측 오차의 순위를 이용하는 방법, 정보 기준(information criterion)을 이용하는 방법 등 다양한 시도가 이루어져 왔다(Wang et al., 2022).²⁾ 국외 농업 분야에서도 예측 조합과 관련된 많은 연구 문제가 논의되고 있고, 가격 예측뿐만 아니라 단수, 생산량, 정성적 예측 등으로 확대 적용되고 있다. 특히, 연간 농산물 생산량 등 시계열의 빈도가 낮은 농업 데이터의 특성을 고려하면 여러 정량적, 정성적 예측 정보를 결합하는 시도는 예측 오차에 대한 위험을 완화하는 전략으로 긍정적인 평가를 받고 있다(Brandt & Bessler, 1981; Vere & Griffith, 1990; Gil & Albus, 1993; Colino et al., 2012; Gurung et al., 2017; Xu, 2017; Cuaresma et al., 2021; Heydari, 2023; Ramsey & Adjemian, 2024).

국외의 선행연구에서 활발하게 적용된 예측 조합방식은 국내의 비농업 분야에도 적용되어 GDP, 소비자물가, 산업 부가가치율, 고용 비중 등 다양한 관심 변수에 대한 예측 전략으로 활용되었다(이진희·김덕파, 2014; 최병재·한진현, 2014; 김현학, 2015; 배두람·성병찬, 2019; 김정우, 2020a; 김정우, 2020b; 김정우, 2022; 이선홍·성병찬, 2022).

국내 농업 분야의 경우 전통적인 시계열 모형에서부터 최근의 머신러닝 알고리즘까지 다양한 방법론이 적용됐으나, 대부분의 선행연구는 개별 예측 모형에 의한 농축산물 가격 예측치 도출 및 예측력 평가에 그치고 있을 뿐 예측 조합방식을 활용하는 단계까지는 확장하지 못하였다(김배성, 2005; 최병욱·최익창, 2007; 남국현·최영찬, 2015; 유도일, 2016; 윤성주 외, 2016; 배경태, 2016; 이형용 외, 2017; 장수희 외, 2017; 신성호 외, 2018; 이창민 외, 2022; 오승원 외, 2020; 박소연 외, 2022; 최현오 외, 2022; 김재휘 외, 2023; 박찬·이경순, 2023; 박종현 외, 2023; 오유미 외, 2023; 강동곤 외, 2024; 양성준, 2024; 윤민정 외, 2024; 허다솜·정승권, 2024; Gu et al., 2022).

한편, 일부 국내 농산물 특정 품목을 대상으로 예측 조합방식이 적용되었으나(이석일 외, 2015; 하지

2) 웹 데이터베이스 Web of Science에 포함된 1969~2021년의 예측 관련 실증 연구 중 예측 조합방식을 적용한 연구는 꾸준히 증가하여 2021년 기준 13.8%의 비중을 차지하는 것으로 나타났다(Wang et al., 2022).

희 외, 2017; Yin et al., 2020),³⁾ 국외 실증 연구에서와 같이 회귀분석, 예측성과, 정보 기준 등에 기반하여 조합 가중치를 추정하고, 예측치를 조합하는 예측 시스템은 거의 적용되지 않았다. 이러한 측면에서 볼 때, 본 연구는 농산물 가격 예측을 위해 개별 예측 모형의 예측력 평가에 그치지 않고, 다양한 예측 조합 전략을 국내 농산물 가격 예측에 폭넓게 적용한다는 점에서 차별성을 가진다.

최근 국내 농산물 가격의 불확실성이 증대되고 있는 상황을 고려하면 국외에서 우수한 예측력으로 주목받는 예측 조합방식 등 다양한 가격 예측 기법의 적용을 통해 안정된 가격 예측 시스템을 구축해 나갈 필요가 있다.

따라서 본 연구의 목적은 양념채소 주요 품목 중 양파, 마늘, 건고추 3개 품목을 대상으로 다양한 가격 예측 모형들을 적용하여 개별 가격 예측치를 추정하고, 이를 조합하여 얻은 새로운 가격 예측치의 예측성과를 밝혀내는 데 있다. 구체적인 세부 목적으로 첫째, 지수평활, AIRMA 등의 시계열 모형과 인공 신경망 등 다양한 예측 기법을 통해 품목별 가격 예측치를 추정한다. 둘째, 개별 모형으로부터 도출된 예측치들에 대해 다양한 방법으로 각기 다른 가중치를 부여하여 조합함으로써 새로운 가격 예측치를 도출한다. 셋째, 예측 조합을 통해 얻은 예측치와 개별 예측 모형의 다양한 예측치 간 예측력을 비교 평가하여 예측 조합 전략의 예측력 향상 여부를 밝혀낸다.

본 연구는 제2절에서 연구 방법 및 절차를 제시하고, 제3절에서는 분석 결과를, 마지막 제4절에서는 요약 및 결론을 제시한다.

2. 연구 방법 및 절차

본 연구에서는 먼저 다양한 가격 예측 모형들을 제시한 후 개별 예측 모형에서 얻어진 예측치들을 조합하여 새로운 가격 예측치를 도출하는 방법을 제시한다. 채소가격에 대한 예측은 주로 단기적인 예측이 많이 이루어지는 점을 고려하여 각 예측 모형의 예측 기간(forecast horizon; h)은 1개월부터 6개월까지로 설정한다.

가격 예측 모형에는 현재의 가격이 미래의 가격으로 그대로 이어진다는 단순 모형(naive model)에서부터 시계열 모형, 인공 신경망 알고리즘 등이 포함된다. 지수평활과 ARIMA의 시계열 모형은 선행 연구를 통해 폭넓게 적용되었고, 예측력도 우수한 것으로 널리 알려져 있다. 또한, 지수평활은 추세와 계절성을 고려할 수 있고, AIRMA는 계절성과 외생변수를 포함하는 다양한 구조의 모형 구축이 가능하

3) 이석일 외(2015)와 하지희 외(2017)는 육계, 마늘, 양파를 대상으로 ARIMA, GARCH 등의 시계열 모형 가격 예측치와 농업관측 센터에서 제공하는 전망치를 대상으로 Encompassing 검정을 적용하였다. Encompassing 검정은 선호되는 예측치가 대안의 다른 예측치를 포괄하는지 평가하는 것으로, 만약 대안의 예측치가 선호되는 예측치에 포함되지 않은 고유의 정보를 지니고 있다면, 두 예측치를 선행 결합하는 방식이다. Yin et al.(2020)은 시계열 분해 기법인 STL(seasonal trend decomposition using the Loess)을 이용하여 주요 채소류 품목의 월별 가격 자료를 추세, 계절성, 나머지 성분으로 분해한 후 각 성분을 딥러닝 알고리즘인 LSTM(long short term memory)으로 학습하여 도출된 예측치를 다시 조합하는 분석을 수행하였다.

여 예측 모형으로 선정하였다. 인공 신경망의 경우에는 최근 딥러닝에 대한 적용 빈도가 증가하고 있는 만큼 본 연구에서는 비교적 단순한 구조의 딥러닝인 인공 신경망을 적용코자 한다.

마지막으로, 선정된 최종 개별 예측 모형의 예측치들과 조합을 통하여 도출된 새로운 예측치 간에 예측의 정확도 측면에서 유의한 차이가 존재하는지를 밝혀낸다.

본 연구는 분석을 위해 통계 프로그램 R을 이용하였고, 개별 예측 모형을 구축하기 위해 R의 forecast, rugarch 패키지에 포함된 다양한 함수를 이용하였다. 단순 기법(naive) 추정을 위한 함수는 naive(), ETS 지수평활은 ets(), ARIMA는 auto.arima(), Arima(), ARIMA-GARCH는 ugarchspec(), ugarchfit(), 인공 신경망은 nnetar()이다.

2.1. 가격 예측 모형(Price forecasting models)

2.1.1. 단순한 예측 기법(Naive forecasting method)

단순 기법(naive method)은 시계열 자료의 마지막 값이 미래에도 지속될 것이라는 가정하에 미래를 예측하는 모형이다(즉, $\hat{y}_{t+h} = y_t$). 분석 대상 자료가 긴 주기의 상승 또는 하락 추세를 보이거나 예측할 수 없는 방향 변화가 있는 확률 보행(random walk) 패턴을 따를 때 가장 합리적인 예측 모형으로 단순 기법이 적용될 수 있다. 즉, 미래를 예측하기 어렵고, 상승 또는 하락 확률이 같은 상황에서 마지막 관측값이 최적의 예측치가 된다. 이러한 단순 기법의 예측 정확도는 과거의 패턴이나 외생변수를 반영하여 예측력 향상을 시도하는 상대적으로 복잡한 예측 모형에 대한 기준치(baseline)로 고려될 수 있다.

2.1.2. ETS(Error, Trend, Seasonality) 지수평활(Exponential smoothing) 모형

지수평활은 과거 관측값의 가중평균(weighted average)을 통해 예측치를 도출하고, 관측값이 오래 될수록 지수적으로(exponentially) 감소하는 가중치를 부여하는 기법이다. 그동안 대표적인 지수평활 법으로 Holt-Winters 모형이 폭넓게 사용됐으나, 최근에는 보다 일반화한 형태의 ETS(Error, Trend, Seasonality) 모형이 널리 사용되고 있다. ETS 모형은 Holt-Winters 모형을 포함하는 보다 일반적이고 확장된 모형이다.

ETS 모형은 시계열의 구조를 오차(E), 추세(T), 계절성(S)의 세 가지 구성요소로 나눈다. <표 1>에서 보는 바와 같이, ETS 모형은 오차, 추세, 계절성 각각을 additive 또는 multiplicative의 형태로 조합하여 다양한 모형을 구성할 수 있다. Additive(A)는 시계열의 변동폭이 일정한 수준일 때, 그리고 multiplicative(M)는 시계열의 변동폭이 일정한 비율일 때를 말한다. 한편, 추세(T) 구성요소에서 additive damped(Ad)는 시간이 지나면서 추세의 증가폭이나 감소폭이 점차 감쇠하는 것을 의미한

다. ETS 모형의 표현 방식은 오차, 추세, 계절성의 결합 방식에 따라 매우 다양하게 나타날 수 있다. 예컨대, ETS(A, A, A)는 additive error, additive trend, additive seasonality를 나타내고, ETS(M, Ad, N)는 multiplicative error, additive damped trend, no seasonality를 나타낸다.

표 1. 오차, 추세, 계절성을 고려한 ETS 지수평활 모형

구성요소	가능한 형태	내용
Error(E)	Additive(A), Multiplicative(M)	오차 구조(실제값과 예측치의 차이를 다루는 방식)
Trend(T)	None(N), Additive(A), Additive damped(Ad)	추세(시간에 따른 증가 또는 감소 경향)
Seasonality(S)	None(N), Additive(A), Multiplicative(M)	계절성(주기적인 패턴)

2.1.3. ARIMA(Autoregressive integrated moving average) 모형

ARIMA 모형은 자기회귀(autoregressive: AR) 과정과 이동평균(moving average: MA) 과정을 결합하여 수식화한 모형이다. ARIMA 모형의 차수는 일반적으로 $ARIMA(p, d, q)$ 로 표시되는데, p 는 자기회귀(AR) 차수, d 는 차분(differencing) 횟수, q 는 이동평균(MA) 차수를 나타낸다.

y_t 가 정상(stationary) 시계열인 경우 ARIMA 모형은 식(1)과 같이 표현되며, 이 경우 차수는 $ARIMA(p, 0, q)$ 로 표시된다.

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (1)$$

여기서, ϕ_i 는 자기회귀항(AR)의 계수, θ_j 는 이동평균항(MA)의 계수를 나타내고, ε_t 는 백색잡음(white noise)이다.

한편, y_t 가 비정상(non-stationary) 시계열인 경우는 원시계열 y_t 를 차분(즉, $\Delta y_t = y_t - y_{t-1}$)하여 정상적인 시계열로 변환한 후 ARIMA 모형을 적용하는데, 이 경우 차수는 $ARIMA(p, d, q)$ 로 표시된다.⁴⁾ 1차 차분한 시계열에 적용되는 ARIMA 모형은 식 (2)와 같이 표현된다.

$$\Delta y_t = c + \sum_{i=1}^p \phi_i \Delta y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (2)$$

ARIMA 모형을 구축하는 과정에서 시계열에 계절적 패턴이 관측되면 계절성(seasonality) 항을 추

⁴⁾ ARIMA의 차수는 통계 프로그램 R의 forecast 패키지 `auto.arima()` 함수를 통해 자동으로 선택할 수 있다. `auto.arima()` 함수는 Hyndman-Khadakar(2008) 알고리즘의 변형된 형태를 적용한 것이다(Hyndman & Athanasopoulos, 2021).

가로 포함하는 Seasonal ARIMA, 즉 SARIMA 모형을 고려할 수 있다. SARIMA 모형은 한 마디로 ARIMA 모형에 계절 성분을 추가한 모형이라고 할 수 있는데, 비계절(non-seasonal) ARIMA 모형 (p, d, q) 와 계절(seasonal) ARIMA 모형 $(P, D, Q)_s$ 의 두 부분으로 구성된다. SARIMA 모형은 일반적으로 $SARIMA(p, d, q)(P, D, Q)_s$ 로 표기되는데, 여기서 p : 비계절 AR 차수, d : 비계절 차분 차수, q : 비계절 MA 차수를 나타내고, P : 계절 AR 차수, D : 계절 차분 차수, Q : 계절 MA 차수를 나타내는 한편, s 는 계절 주기(예: 월별 데이터라면 $s=12$, 분기별이면 $s=4$)를 나타낸다.

또한, 본 연구에서는 외생변수(exogenous variables)를 추가하여 ARIMA 모형을 확장한 ARIMAX(ARIMA with exogenous variables) 모형도 개별 예측 모형에 포함하였다. 여기서, 외생변수는 양파, 마늘, 건고추 도매가격에 영향을 미치는 도매시장 반입량, 수입량, 계절성 더미변수(dummy variable) 등을 고려하였다. ARIMAX 모형의 차수는 $ARIMAX(p, d, q; r)$ 로 표시되는데, p 는 자기회귀(AR) 차수, d 는 차분(differencing) 횟수, q 는 이동평균(MA) 차수, 그리고 r 은 외생변수의 차원 또는 개수를 나타낸다. ARIMAX 모형을 수식으로 표현하면, 식 (3)과 같다.

$$y_t = c + \sum_{i=1}^p \phi_i y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \sum_{k=0}^r \beta_k x_{t-k} + \varepsilon_t \quad (3)$$

여기서, $x_{k,t}$ 는 시점 t 의 외생변수 k , 그리고 β_k 는 외생변수의 계수를 나타낸다.

2.1.4. ARIMA-GARCH(Generalized autoregressive conditional heteroskedasticity)

ARIMA 모형은 시간의 경과에도 분산이 일정하다고 가정하나, 시계열 자료의 경우 시기별로 분산이 달라지는 이분산(heteroskedasticity)이 빈번하게 발견된다. 오차의 분산을 모형에 포함하여 이분산을 적절하게 처리한다면, 정확한 신뢰구간의 추정과 효율적인 추정량을 얻을 수 있다. Bollerslev(1986)는 이러한 분산 또는 변동성을 모형화하기 위해 GARCH 모형을 고안하였다.

ARIMA-GARCH 모형은 평균 방정식(mean equation)인 ARIMA 모형과 분산 방정식(variance equation)인 GARCH 모형의 두 부분으로 구성된다. ARIMA 모형은 시계열의 평균 구조를 설명하는 한편 GARCH 모형은 시계열의 변동성 구조(즉, 조건부 분산)를 설명한다. $ARIMA(p, d, q)$ -GARCH (p, q) 모형은 일반적으로 식 (4-1) 및 식 (4-2)와 같이 표현된다.

$$\Delta y_t = c + \sum_{i=1}^p \phi_i \Delta y_{t-i} + \sum_{j=1}^q \theta_j \varepsilon_{t-j} + \varepsilon_t \quad (4-1)$$

$$\sigma_t^2 = c + \sum_{i=1}^p \alpha_i \varepsilon_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2, \quad \varepsilon_t = \sigma_t z_t, \quad z_t \sim i.i.d. N(0, 1) \quad (4-2)$$

여기서 σ_t^2 는 오차항의 과거 정보에 기초한 분산이기 때문에 조건부 분산(conditional variance)이라 불린다. α_i 와 β_j 는 ARCH와 GARCH 계수를 각각 나타낸다.

ARIMA-GARCH 모형은 시계열 자료의 선형(linear) 및 비선형(nonlinear) 패턴을 효과적으로 설명하기 위해 적용되는 기법이다. 분석 절차를 살펴보면, 먼저 분석 대상 시계열 자료의 추세(trend), 계절성(seasonality), 자기상관성(autocorrelation) 등의 선형 패턴을 반영하는 최적의 ARIMA 모형을 추정한다. ARIAM 모형으로부터 도출된 오차는 선형적 패턴이 제거된 후 남은 정보이다. 이러한 오차에 이분산성의 특성이 보이면 GARCH로 모형화하여 ARIMA와 조합함으로써 선형 및 비선형 특성을 반영한 최종 예측치를 도출하게 된다(Yaziz et al., 2013).

2.1.5. 인공 신경망(Neural network: NN) 모형


인공 신경망은 1957년 Frank Rosenblatt에 의해 고안된 퍼셉트론(perceptron)이다. 퍼셉트론은 다수의 신호를 받아 하나의 신호를 출력하는 알고리즘이다. <그림 1>과 같이 단층(single-layer) 퍼셉트론은 입력층(input layer)과 출력층(output layer)으로 구성되고, 입력층과 출력층 사이에 하나 이상의 은닉층(hidden layer)을 추가할 경우, 비선형 자료에 대한 학습이 강화된 다층(multi-layer) 퍼셉트론이 된다(서지영, 2022; 조태호, 2023; Hyndman & Athanasopoulos, 2021).

단층 퍼셉트론의 구조에서 x_1 과 x_2 는 입력신호, y 는 출력 신호, b 는 편향, w_1 , w_2 는 각 신호의 가중치를 나타내는 매개변수이다. 그림의 원을 뉴런 혹은 노드(node)라고 부르고, 입력신호가 뉴런에 보내질 때 각각의 고유한 가중치가 곱해진다. 입력신호에 가중치를 곱한 값과 편향을 합하여, 그 값이 임계값(θ)을 넘으면 1을 출력한다. 다층 퍼셉트론에서는 각 노드의 입력신호에 가중치를 곱하고 편향을 더한 값, 즉 가중합은 은닉층에 보내진다. 은닉층에 취합된 가중합은 비선형 함수인 활성화 함수(activation function)⁵⁾를 통해 n_1 과 n_2 가 계산된다. 이러한 결과값은 출력층으로 전달되어 다시 활성화 함수를 이용하여 y_1 예측값을 출력하게 된다.

본 연구에 이용된 NNAR(Neural network autoregression)은 시계열 자료에 대해 추정된 인공 신경망 모형으로 $NNAR(p, P, k)[m]$ 으로 표현된다. 여기서, p 는 입력값에 대한 비계절성 시차(lags)의 수, P 는 계절성 시차의 수, k 는 은닉층의 노드 수, 그리고 m 은 계절 주기를 나타낸다. 즉, $NNAR(p, P, k)[m]$ 모형에는 입력값 $(y_{t-1}, y_{t-2}, y_{t-3}, \dots, y_{t-p}, y_{t-m}, y_{t-2m}, y_{t-Pm})$ 이 있고, 은닉층에 k 개의 신경 세포가 있다. 본 연구에서는 입력값에 양파, 마늘, 건고추 가격에 대한 시차값뿐만 아니라 도매시장 반입량과 수입량을 입력값으로 추가하여 개별 예측 모형을 추정하였다.

⁵⁾ 활성화 함수는 S자 형태로 그래프가 그려지는 시그모이드 함수(sigmoid function)를 이용하였다(조태호, 2023).

그림 1. 퍼셉트론(perceptron) 구조



2.2. 예측 조합법(Forecast combination methods)

2.2.1. 단순 평균(Simple average)에 의한 가중치 부여 방식

예측치를 조합하는 가장 단순한 방법은 여러 개별 예측치를 단순히 평균하는 것으로, 각각의 가격 예측치에는 동일한 가중치($=1/N$)가 부여된다. 이 방법은 직관적으로 이해하기 쉽고, 계산이 용이할 뿐만 아니라 여러 실증 연구에서 우수한 예측력이 입증되었다. Bates & Granger(1969)와 Clemen(1989)은 단순 평균 조합방식을 통해서도 예측력이 향상될 수 있음을 주장하였다. 또한, 복잡한 가중치 산출 방식은 이론적 강건성에도 불구하고 단순 평균 조합 대비 예측력이 오히려 낮은 결과가 여러 실증 연구를 통해 밝혀졌다.⁶⁾ 따라서 단순 평균에 의한 예측 조합은 가중치 산출에 대한 불확실성을 해소하는 동시에 개별 예측치의 편향과 분산을 줄이는 예측 기법으로 적용될 수 있다(Bec & Mogliani, 2013; Granziera et al., 2013; Wang et al., 2022).

h 단계 앞선 N 개의 개별 예측치($\hat{y}_{t+h,i}$)를 평균 조합한 예측치는 식 (5)와 같다.

$$\hat{y}_{t+h}^c = \frac{1}{N} \sum_{i=1}^N \hat{y}_{t+h,i} \quad (5)$$

여러 개별 예측치를 평균하는 방식 이외에도 비교적 단순한 조합법으로 개별 예측치의 중앙값(median)을 이용하기도 한다. 이는 단순 평균 대비 극단값(outlier: 이상치)을 가지는 개별 예측치에 덜 민감하다는 이점이 있다. 본 연구에서는 단순 조합방식 중 평균과 중앙값을 모두 이용하여 개별 예측치를 조합하였다.

⁶⁾ 이러한 현상을 “forecast combination puzzle”이라 한다(Wang et al., 2022). 이 용어는 한 마디로 단순 평균에 의한 예측 조합이 복잡하고 정교하게 산정된 가중치에 의한 조합방식보다 더 안정적이고 예측력이 높은 경우가 많은 현상을 말한다.

2.2.2. 회귀 분석에 기초한(regression-based) 가중치 부여 방식

Granger & Ramanathan(1984)는 식 (6)과 같이 선형 회귀 분석에 기초한 가중치 추정 방법을 제시하였다. 여기서 종속변수는 과거 관측치(실제값)이고, 독립변수는 개별 모형의 예측치로 구성된다. 식 (6)의 회귀방정식을 통해 추정된 회귀계수가 각각의 개별 예측치에 부여되는 가중치이다(Bec & Mogliani, 2013; Granziera et al., 2013; Wang et al., 2022).

$$y_{t+h} = c + w^1 \hat{y}_{t+h}^1 + w^2 \hat{y}_{t+h}^2 + \dots + w^N \hat{y}_{t+h}^N + \varepsilon_{t+h} \quad (6)$$

여기서, $\hat{y}_{t+h}^i$ ($i = 1, 2, \dots, N$)는 개별 모형 i 에 의한 가격 예측치, 그리고 회귀계수 w^i 는 개별 가격 예측치 i 에 부여되는 가중치를 나타낸다.

회귀 분석에 기반한 조합방식은 각 예측 모형의 상대적 설명력을 반영하여 통계적으로 최적화된 가중치를 도출해 낼 수 있는 장점이 있다. 그러나 학습 데이터가 적을 경우 과적합(overfitting) 위험이 존재하고, 다중 공선성(multicollinearity) 등의 영향으로 가중치 추정이 불안정해지는 문제가 발생할 수 있다. 이러한 문제에 대처하기 위해 다양한 제약조건을 부과하는데, 대표적으로 가중치의 합이 1(즉, $\sum_{i=1}^N w^i = 1$)이 되도록 하거나 비음(nonnegative)의 제약조건(즉, $w^i \geq 0$)을 부과한다. 실제로 Gunter(1992, 재인용, Wang et al., 2022)는 가중치의 합 1과 비음의 제약조건을 부과함으로써 안정된 조합 예측치 도출은 물론 예측력도 높아질 수 있음을 증명한 바 있다. 본 연구는 가중치의 합이 1이고 각각의 가중치가 비음이라는 제약조건 하에서 개별 예측치에 부여되는 가중치를 추정하였다.

2.2.3. 예측성가에 기초한(performance-based) 가중치 부여 방식

이 방식은 각 예측 모형의 과거 예측성가에 따라 가중치를 차등 부여하는 방법이다. 즉, MSE(mean squared error: 평균 제곱 오차), RMSE(root mean squared error: 평균 제곱근 오차), MAE(mean absolute error: 평균 절대 오차) 등과 같이 예측 모형의 정확도를 평가하는 지표를 이용하여 예측력이 좋은 모형에 더 큰 가중치를 부여한다(Bec & Mogliani, 2013; Granziera et al., 2013; Wang et al., 2022). Stock & Watson(1999)은 식 (7)과 같이 MSE에 기초한 가중치 산출 방식을 제안하였다.

$$w_{t+h,i} = \frac{(MSE_{t+h,i})^{-1}}{\sum_{j=1}^N (MSE_{t+h,j})^{-1}}, \text{ where } MSE_{t+h,i} = \frac{1}{N} \sum_{t=1}^N (y_{t+h} - \hat{y}_{t+h,i})^2 \quad (7)$$

가중치의 산식에는 예측 오차인 MSE의 역수(inverse)가 등장하는데, 분모는 개별 예측 모형의 MSE 역수를 모두 합산한 것이고, 분자는 개별 해당 예측 모형의 MSE 역수다. 따라서, MSE가 클수록(즉, 예측 오차가 클수록) 낮은 가중치가 도출되는 반면 MSE가 작을수록(즉, 예측 오차가 작을수록) 높은 가중치가 도출된다. 이와 관련한 연구에서는 MSE 외에 RMSE 등을 이용하기도 한다.

한편, Aiolfi & Timmermann(2006)은 MSE 순위(rank)를 이용한 가중치 추정 방법을 제안하였다. 모든 개별 예측 모형은 예측 오차인 MSE 결과에 기초하여 순위가 부여되는데, MSE가 가장 낮으면(즉, 예측 오차가 가장 작으면) 순위는 가장 높은 1이 되고, MSE가 두 번째로 낮으면 순위는 두 번째로 높은 2가 되는 식이다. 식 (8)에서 보는 바와 같이, 가중치 산식의 분모와 분자에는 순위의 역수가 등장한다. 따라서, 순위가 높을수록(즉, 예측 오차가 작을수록) 가중치가 커지는 반면 순위가 낮을수록(즉, 예측 오차가 클수록) 가중치가 작아지게 된다.

$$w_{t+h,i} = \frac{(RANK_{t+h,i})^{-1}}{\sum_{j=1}^N (RANK_{t+h,j})^{-1}}, \text{ where } RANK_{t+h,i} = 1, 2, \dots, N \quad (8)$$

2.2.4. 정보 기준에 기초한(information criteria-based) 가중치 부여 방식

특정 데이터에 적합한 예측 모형을 선택하는 방법으로 AIC(Akaike's information criterion), BIC(Bayesian information criterion) 등의 정보 기준(information criterion)이 활용된다. 일반적으로 AIC, BIC 값이 상대적으로 작을수록 적합도가 높은 모형으로 평가된다. 정보 기준은 여러 대안의 모형 중 하나의 개별 모형을 선택하는 데 유용하나, 선택되지 않은 모형에 대한 정보가 활용되지 못하는 한계가 있다. 이러한 점을 고려하여 Burnham & Anderson(2002)은 정보 기준에 기초하여 하나의 모형을 선택하지 않고, 여러 모형을 조합하는 방법을 제안하였다(Kolassa, 2011; Wang et al., 2022).

정보 기준에 기반한 예측 조합의 가장 일반적인 접근방식은 AIC 가중치(Akaike weights)를 적용하는 것이다. AIC 값이 제안된 모형과 데이터 생성 과정(data generating process) 간의 Kullback-Leibler 거리⁷⁾를 측정한다는 관점에서 모형 간 AIC 차이를 비교하여 가중치를 추정한다.

AIC 가중치를 도출하기 위해서는 우선, 식 (9-1)을 통해 모형 i 가 AIC 값이 가장 작은 최적 모형 j 에 비해 얼마나 떨어져 있는지 측정하고, 이를 식 (9-2)에 포함하여 최종 가중치를 도출한다.

⁷⁾ Kullback-Leibler 거리(Kullback-Leibler divergence: KL divergence)는 두 확률 분포 간의 차이(비유사성, dissimilarity)를 측정하는 방법이다.

$$\Delta AIC_i = AIC_i - \min_{j \in N} AIC(j) \quad (9-1)$$

$$w_{t+h,i} = \frac{\exp(-0.5 \Delta AIC_i)}{\sum_{j=1}^N \exp(-0.5 \Delta AIC_j)} \quad (9-2)$$

식 (9-2)에서 분자의 $\exp(-0.5 \Delta AIC_i)$ 는 AIC가 가장 낮은 최적 모형 j 와 비교하여 개별 모형 i 가 데이터에 얼마나 적합한지 나타내는 상대적 우도(likelihood)이다. 이를 모형 전체(N)에 포함된 다른 모형 j 에 대한 우도의 합인 $\sum_{j=1}^N \exp(-0.5 \Delta AIC_j)$ 로 정규화(normalize)하여 가중치를 도출한다. 따라서 AIC 가중치는 데이터 생성 과정에 가장 근사하는(approximating) 최적 모형에 대한 선택 확률로 AIC 값이 낮은 모형일수록 데이터에 적합한 모형으로 평가하여 높은 가중치가 부여된다.

이러한 정보 기준에 따른 가중치 추정 방식은 AICc(AIC corrected for small sample bias), BIC 등을 적용하기도 하는데, 본 연구는 AIC 가중치 추정 방식을 활용하였다.

2.3. 가격 예측의 정확도(Forecasting accuracy) 측정 방법

가격 예측의 정확도는 일반적으로 실제값과 예측치 간의 차이인 예측 오차($e_{t+h} = y_{t+h} - \hat{y}_{t+h}$)에 기반하여 평가한다. 본 연구에서는 예측력을 평가하는 여러 방법 중 RMSE(root mean squared error: 제곱근 평균 제곱 오차)와 MAPE(mean absolute percentage error: 평균 절대 백분율 오차)를 활용하였다. RMSE는 예측 오차의 평균적인 크기(규모)를 보여준다. 예측 모형 간 RMSE를 비교하면, 예측 오차의 크기 차이를 수치적으로 파악할 수 있기 때문에 동일한 시계열 자료를 대상으로 하는 경우 직접적인 비교가 가능하다는 장점이 있다. 또한 RMSE는 분석자료의 물리적 단위와 동일한 단위로 표시되기 때문에 예측 오차의 절대적인 크기를 정량적으로 비교하기가 용이하다. RMSE는 오차를 제곱하기 때문에 큰 오차일수록 더욱 크게 계산되는 특징이 있어 값이 작을수록 좋은 모형으로 평가된다.

한편, MAPE는 예측이 평균적으로 몇 %의 오차를 나타내는지 보여준다. MAPE는 실제값에 대비한 예측 오차의 크기를 평균하여 백분율(%)로 표현하기 때문에 예측 오차의 상대적인 크기를 나타낸다. MAPE는 백분율로 표시되기 때문에 자료의 측정 단위와 관련 없는(unit-free) 이점으로 인해 서로 다른 단위나 규모의 시계열 간 비교에 많이 활용된다. MAPE도 RMSE와 마찬가지로, 값이 작을수록 좋은 모형으로 평가된다.

RMSE와 MAPE의 산출식은 각각 식 (10-1)과 식 (10-2)으로 표현된다.

$$RMSE = \sqrt{\frac{1}{N} \sum_{i=1}^N (y_{t+h,i} - \hat{y}_{t+h,i})^2} \quad (10-1)$$

$$MAPE = \frac{1}{N} \sum_{i=1}^N \frac{|y_{t+h,i} - \hat{y}_{t+h,i}|}{y_{t+h,i}} \times 100 \quad (10-2)$$

2.4. 분석자료

본 연구에 이용된 양념채소는 양파, 마늘과 건고추 세 가지 품목이다. 양파의 가격은 서울시농수산식품공사에서 제공하는 가락시장 상품 기준의 가격이고, 마늘과 건고추 가격은 한국농수산식품유통공사(aT)에서 제공하는 서울, 부산, 대구, 광주, 대전의 5대 도매시장 평균 가격자료를 이용한다.⁸⁾ 마늘은 깬마늘 기준으로 가격 단위는 원/kg이고, 건고추는 화건 기준으로 가격 단위는 원/600g이다.

본 연구에 이용된 가격자료의 표본기간은 2003년 1월부터 2024년 12월까지(22년)이고, 각 품목의 가격은 월별 가격이다. 본 연구는 가격 예측 모형을 구축하여 개별 가격 예측치를 도출하고, 예측 조합을 위한 가중치를 산출하는 한편 예측의 정확도를 측정하기 위해 전체 가격자료를 학습 데이터(training set), 검증 데이터(validation set), 테스트 데이터(test set)로 구분하였다.


우선, 학습 데이터의 설정 방법은 구간이동법(rolling window)을 고려하였다. 구간이동법은 예측 시점이 1단계 증가하면 학습 데이터의 시작과 마지막 시점이 1단계씩 동시에 이동하여 학습 표본의 크기가 동일하게 유지되는 특징이 있고, 구조변화 등을 빠르게 반영할 수 있는 이점이 있다(이진희·김덕파, 2014).

〈그림 2〉는 2003년 1월부터 2024년 11월까지의 학습 데이터를 대상으로 구간이동법에 따라 1단계 앞선(1-step-ahead), 즉 1개월 후의 가격을 예측하는 방법을 예시하고 있다. 가장 먼저 2003년 1월~2018년 12월(N=192)의 학습 데이터(train 1)를 이용하여 개별 예측 모형의 모수(parameters)를 추정하고, 1개월 후인 2019년 1월의 예측치를 도출한다. 그다음 한 구간을 이동하여 2003년 2월~2019년 1월의 학습 데이터(train 2)를 통해 2019년 2월의 예측치를 추정한다. 이러한 구간이동법을 통해 구성된 72개의 학습 데이터를 순차적으로 적용하여 2019년 1월~2024년 12월의 월별 가격 예측치를 도출한다.

8) 건고추와 마늘은 양파와 달리 가락동 농수산물도매시장의 상장 예외 품목으로 5대 도매시장 가격자료를 분석에 적용하였다.

그림 2. 구간이동법(Rolling window)에 따라 1개월 후의(1-step-ahead) 가격을 예측하기 위한 분석자료의 구성:

학습(training), 검증(validation) 및 테스트(test) 자료



검증 데이터는 2019년 1월부터 2021년 12월까지(3년)이고, 테스트 데이터는 2022년 1월부터 2024년 12월까지(3년)이다.⁹⁾ 학습 데이터를 이용하여 얻은 검증 데이터(2019년 1월~2021년 12월)의 가격 예측치는 실제값과 더불어 여러 예측 조합 방법의 조합 가중치를 도출하는 데 사용된다. 여기서 추정된 가중치를 테스트 데이터(2022년 1월~2024년 12월)에 적용하여 개별 예측 모형의 가격 예측치를 조합함으로써 새로운 조합 예측치를 도출한다. 최종적으로 테스트 데이터의 개별 예측치와 조합 예측치를 실제값과 비교하여 예측력을 평가한다.

3. 분석 결과

3.1. 기초 통계량

본 연구에 이용된 양파, 마늘, 건고추 도매가격에 대한 기초 통계량은 <표 2>와 같다.

양파의 2003~2024년 평균 도매가격은 908원/kg이고, 최댓값과 최솟값은 각각 2,342원/kg, 275원/kg, 표준편차는 354원/kg이다. 마늘의 평균 도매가격은 5,428원/kg이고, 최솟값 3,036원/kg에서 최댓값 8,791원/kg 사이의 가격 분포를 나타냈다. 건고추의 평균 가격은 8,764원/600g이고, 최솟값과 최댓값은 각각 8,110원/600g, 17,830원/600g이다.

⁹⁾ 일반적으로 예측치를 도출하고, 예측력을 평가하기 위해 활용되는 검증 및 테스트 데이터는 전체 표본의 약 20~30% 수준임을 고려하여 본 연구에서는 전체 데이터 표본 수 264개 중 27.3% 수준인 72개를 검증 및 테스트 데이터로 이용하였다.


표 2. 양파, 마늘, 건고추 도매가격에 대한 기초 통계량 (N=264)

구분	평균	중앙값	최대값	최소값	표준편차	왜도	첨도
양파(원/kg)	907.8	869.8	2,342.4	274.6	353.9	0.78	3.52
마늘(원/kg)	5,428.0	5,626.0	8,791.0	3,036.0	1,706.0	0.22	1.72
건고추(원/600g)	8,763.6	8,109.0	17,826.2	3,562.2	3,535.5	0.52	2.04

자료: 서울특별시농수산물공사, 한국농수산물유통공사.


〈그림 3〉은 2003~2024년의 기간 동안 각 품목의 월별 도매가격 변동 추세와 전월 대비 가격 변동성(volatility)을 나타내고 있다. 양파의 가격 추세를 살펴보면, 매년 공급 수준에 따라 가격은 등락을 반복하는 패턴을 나타내고 있다. 2010년 이후에는 양파의 주 수확기인 5~6월 고온 등의 이상기상 발생 빈도 증가로 가격 변동성이 확대된 것이 특징이다. 양파의 전월 대비 가격 변동성은 수확이 본격적으로 이루어지는 4~5월에 크고, 수확이 마무리되는 6월 이후에는 저장 출하기로 변동성이 크지 않다. 마늘과 건고추는 양파에 비해 2010년 이후 가격 상승 패턴이 뚜렷하게 나타났다. 이는 주산지 기상 악화 영향뿐만 아니라 양파가 2003년 이후 재배면적이 연평균 2.0%씩 증가한 것과 달리 마늘과 건고추의 재배면적은 각각 1.6%, 3.7%씩 감소하여 가격 상승을 견인한 것으로 분석된다(한국농촌경제연구원, 2025). 마늘의 계절별 가격 변동성은 5~8월이 상대적으로 크고,¹⁰⁾ 건고추는 8월이 가장 크다.

그림 3. 2003~2024년 품목별 도매가격 변동 추세와 전월 대비 가격 변동성(volatility)



10) 마늘은 양파와 유사하게 5~6월에 수확이 많이 이루어지는 특징이 있으나, 7~8월 마늘의 가격 변동성은 양파와 달리 큰 것으로 나타났다. 양파의 경우 수확 후 바로 출하 및 유통되어 산지와 시장가격이 5~6월에 형성되나, 마늘은 5~6월 수확 후 건조 작업과 농협 수매 등으로 산지 가격 형성이 상대적으로 늦어 7~8월까지 가격 변동성이 큰 것으로 나타났다.

(계속)



주: 가격 변동성은 (전월 대비 증감률_t - 전월 대비 증감률 평균값)²과 같은 산출 근거에 따라 제시될 수 있고, 여기서 전월 대비 증감률에 대한 산출식은 $100 \times [\ln(P_t) - \ln(P_{t-1})]$ 와 같음.

자료: 서울특별시농수산물공사, 한국농수산식품유통공사.

3.2. 품목별 가격 예측 모형 선정 결과

〈표 3〉은 품목별로 개별 가격 예측 모형을 선정한 결과를 총괄하여 제시하고 있다. 본 연구는 각종 정보 기준 및 통계 패키지 R의 최적 모형 자동 선택 기능의 도움을 받아 개별 가격 예측 모형별로 최적 차수의 모형을 선정하였다. 본 연구는 개별 가격 예측 모형을 추정하는 데 있어서 rolling window 방식을 적용함에 따라 학습 데이터에서 자료의 구간이 한 단계씩 이동할 때마다 매번 새롭게 모형을 추정하였다. 또한 품목별로 6개씩(1~6개월)의 예측 기간을 고려한 만큼 각 예측 기간별로 수많은 횟수의 모형 추정 시도가 이루어졌다. 다행히도 rolling window가 1개월씩 바뀌는 과정에서는 모형의 차수에도 변화가 크지 않아 공통의 차수를 지닌 소수의 모형으로 집약되었다. 그 가운데 출현 빈도가 상대적으로 높은 모형을 최적 차수를 지닌 대표 모형으로 선정하였다.

본 연구의 가격 예측 모형은 단순 예측 기법, ETS 지수평활 모형, ARIMA, ARIMA-GARCH, ARIMAX, 인공 신경망으로 구분된다. ETS 지수평활 모형과 ARIMA 모형에서 2개씩의 세부 모형을 포함한 결과 양파의 경우 총 8개의 예측 모형을 선정하였고, 마늘과 건고추의 경우는 GARCH 효과가 확인되지 않아 ARIMA-GARCH 모형을 제외한 총 7개의 예측 모형을 각각 선정하였다.

양파의 경우 ARIMA-GARCH 모형을 포함하는데, 학습 데이터별로 ARIMA 모형에 대한 차수를 R의 `auto.arima()`에 의해 자동으로 추정하고, ARCH 효과¹¹⁾가 나타나면 GARCH(1,1)을 조합하여 예측치를 도출하였다. 여기서 72개의 학습 데이터 중 ARCH 효과가 없는 시계열에 대해서는 단순히 ARIMA 모형을 적용하였다.

11) ARCH-LM 검정은 Lagrange multiplier 검정으로 귀무가설(H_0) '시차 q 까지 동시적으로 고려할 때 ARCH 효과(ARCH effect)가 없다'에 대한 기각 여부를 평가하게 된다.

표 3. 양파, 마늘, 건고추의 개별 가격 예측 모형 선정 결과

[양파] 가격 예측 모형 구조		
단순 예측 기법	① 단순 기법(naive)	• 예측값: 가장 마지막 관측값
ETS 지수평활모형	② ETS(A,N,A)	• 덧셈 오차(A), 추세 없음(N), 덧셈 계절성(A)
	③ ETS(M,A,M)	• 곱셈 오차(M), 덧셈 추세(A), 곱셈 계절성(M)
ARIMA	④ ARIMA(1,0,2)	• 비계절성 ARIMA(p,d,q)
	⑤ SARIMA(2,1,1)(1,0,2) ₁₂	• 계절성 ARIMA(p,d,q)(P,D,Q) _s
ARIMA-GARCH	⑥ ARIMA(p,d,q)+GARCH(1,1)	• ARIMA 차수 자동 선택: R의 auto.arima() • GARCH(1,1)
ARIMAX	⑦ ARIMAX(1,0,1:12)	• ARIMAX(p,d,q;r) • 외생변수(12개): 가락시장 반입량, 월별 더미
인공 신경망	⑧ NNAR(13,1,8)[12]	• 계절성 NNAR(p,P,k)[m] • 비 계절 시차(p): AR(p)로 최적 시차 결정(AIC 기준) • 계절 시차(P): 기본값 1 • 은닉층의 노드 수(size): 8 • 외생변수: 가락시장 반입량 • 반복 학습 횟수(repeat): 기본값 20 • 자료 전처리(scale.input=TRUE): 표준화
[마늘] 가격 예측 모형 구조		
단순 예측 기법	① 단순 기법(naive)	• 예측값: 가장 마지막 관측값
ETS 지수평활모형	② ETS(A,N,A)	• 덧셈 오차(A), 추세 없음(N), 덧셈 계절성(A)
	③ ETS(M,Ad,N)	• 곱셈 오차(M), 감쇠 추세(Ad), 계절성 없음(N)
ARIMA	④ ARIMA(1,1,3)	• 비계절성 ARIMA(p,d,q)
	⑤ SARIMA(0,1,1)(1,0,0) ₁₂	• 계절성 ARIMA(p,d,q)(P,D,Q) _s
ARIMAX	⑥ ARIMAX(0,1,1:2)	• ARIMAX(p,d,q;r) • 외생변수(2개): 전국 도매시장 반입량, 수입량 • 냉동마늘 수입량(HSCODE: 0710802000) 적용
인공 신경망	⑦ NNAR(2,1,3)[12]	• 계절성 NNAR(p,P,k)[m] • 비 계절 시차(p): AR(p)로 최적 시차 결정(AIC 기준) • 계절 시차(P): 기본값 1 • 은닉층의 노드 수(size): 3 • 외생변수: 전국 도매시장 반입량, 수입량 • 냉동마늘 수입량(HSCODE: 0710802000) 적용 • 반복 학습 횟수(repeat): 기본값 20 • 자료 전처리(scale.input=TRUE): 표준화
[건고추] 가격 예측 모형 구조		
단순 예측 기법	① 단순 기법(naive)	• 예측값: 가장 마지막 관측값
ETS 지수평활모형	② ETS(A,Ad,A)	• 덧셈 오차(A), 감쇠 추세(Ad), 덧셈 계절성(A)
	③ ETS(M,N,A)	• 곱셈 오차(M), 추세 없음(N), 덧셈 계절성(A)
ARIMA	④ ARIMA(0,1,1)	• 비계절성 ARIMA(p,d,q)
	⑤ SARIMA(0,1,1)(0,0,2) ₁₂	• 계절성 ARIMA(p,d,q)(P,D,Q) _s
ARIMAX	⑥ ARIMAX(1,0,1:12)	• ARIMAX(p,d,q;r) • 외생변수(12개): 수입량, 월별 더미 • 냉동고추 수입량(HSCODE: 0710807000) 적용
인공 신경망	⑦ NNAR(2,1,2)[12]	• 계절성 NNAR(p,P,k)[m] • 비 계절 시차(p): AR(p)로 최적 시차 결정(AIC 기준) • 계절 시차(P): 기본값 1 • 은닉층의 노드 수(size): 2 • 외생변수: 수입량 • 냉동고추 수입량(HSCODE: 0710807000) 적용 • 반복 학습 횟수(repeat): 기본값 20 • 자료 전처리(scale.input=TRUE): 표준화

3.3. 예측 조합을 위한 가중치 추정 결과

예측 조합을 시행하기에 앞서 <표 3>의 품목별 가격 예측 모형을 통해 도출된 검증 데이터(2019. 1. ~2021. 12.)의 예측치와 실제값을 이용하여 개별 예측치에 부여되는 가중치 추정 결과는 <표 4>와 같다.¹²⁾

표 4. 양파, 마늘, 건고추의 개별 예측 모형에 부여되는 가중치 추정 결과(1~6개월 예측 기간 평균)

구분		단순 조합법		회귀 분석	예측성과		정보 기준
		평균값	중앙값		MSE	MSE RANK	
양파	1) 단순 기법(naive)	0.125	0.204	0.000	0.131	0.132	-
	2) ETS(A,N,A)	0.125	0.044	0.068	0.103	0.055	0.000
	3) ETS(M,A,M)	0.125	0.083	0.019	0.123	0.072	0.000
	4) ARIMA(1,0,2)	0.125	0.111	0.000	0.139	0.194	0.000
	5) SARIMA(2,1,1)(1,0,2)12	0.125	0.229	0.410	0.132	0.181	0.731
	6) ARIMA(p,d,q)+GARCH(1,1)	0.125	0.090	0.000	0.140	0.235	0.000
	7) ARIMAX(1,0,1;12)	0.125	0.144	0.071	0.111	0.058	0.269
	8) NNAR(13,1,8)[12]	0.125	0.095	0.431	0.121	0.074	-
마늘	1) 단순 기법(naive)	0.143	0.181	0.000	0.150	0.096	-
	2) ETS(A,N,A)	0.143	0.070	0.000	0.147	0.077	0.000
	3) ETS(M,Ad,N)	0.143	0.060	0.000	0.117	0.055	0.000
	4) ARIMA(1,1,3)	0.143	0.130	0.000	0.154	0.129	0.452
	5) SARIMA(0,1,1)(1,0,0)12	0.143	0.227	0.000	0.158	0.386	0.389
	6) ARIMAX(0,1,1;2)	0.143	0.310	0.784	0.158	0.193	0.158
	7) NNAR(2,1,3)[12]	0.143	0.023	0.224	0.117	0.064	-
건고추	1) 단순 기법(naive)	0.143	0.093	0.000	0.118	0.084	-
	2) ETS(A,Ad,A)	0.143	0.162	0.274	0.179	0.166	0.000
	3) ETS(M,N,A)	0.143	0.264	0.052	0.193	0.354	0.000
	4) ARIMA(0,1,1)	0.143	0.185	0.000	0.113	0.066	0.003
	5) SARIMA(0,1,1)(0,0,2)12	0.143	0.111	0.082	0.147	0.147	0.388
	6) ARIMAX(1,0,1;12)	0.143	0.069	0.000	0.168	0.123	0.609
	7) NNAR(2,1,2)[12]	0.143	0.116	0.651	0.081	0.060	-

단순 조합법에서 단순 평균을 이용한 조합은 모든 개별 모형에 동일한 가중치가 부여된다. 양파는 8개의 예측 모형을 이용하므로 예측치별로 1/8의 가중치가 부여되고, 마늘과 건고추는 각각 7개의 예측 모형을 이용하므로 예측치별로 1/7씩의 가중치가 부여되었다. 한편, 중앙값을 이용하는 경우 양파는 8개(짝수)의 개별 예측 모형을 이용하므로 순서상 가운데 위치한 두 예측치에 각각 50%의 가중치가 부여되었다. 마늘과 건고추는 7개(홀수)의 예측 모형을 이용하므로 중앙값에 해당하는 예측치에 100%의

¹²⁾ 가중치는 예측 모형 및 예측 기간(forecast horizon: 1~6개월)별로 각각 달리 추정하였으나, <표 4>에서는 지면 제약으로 인해 예측 기간별 가중치 추정 결과를 개별적으로 제시하지 못하고, 전체적으로 평균하여 제시함으로써 전반적인 경향성을 파악하는데 도움이 되도록 하였다.

가중치가 부여되었다.

회귀분석을 이용한 조합법에서는 비음(nonnegative) 제약조건을 통해 음의 계수값이 나타나는 예측 모형에 대해 회귀계수 값(가중치)이 0으로 추정되었다. 본 연구는 사전 분석을 통해 회귀 분석에 기반한 가중치 추정 시 음수값을 제약하지 않을 경우 특정 개별 모형에 상대적으로 큰 음수값의 가중치가 부여되어 예측치가 편향되고 예측력도 낮아지는 것을 확인하였다. MSE와 MSE RANK의 예측성능에 기반한 조합법은 모든 개별 예측 모형에 대해 비교적 고르게 가중치를 부여하는 것으로 나타났다. 본 연구에 포함된 개별 예측 모형은 대부분 독자적인 예측력이 뛰어난 것으로 알려진 만큼 각 모형의 예측성능에 기초한 가중치는 모형 간 차이가 크지 않은 것으로 분석된다.

마지막으로, 정보 기준에 기초한 조합법에서는 개별 예측 모형의 상대적 적합도인 AIC의 차이 (ΔAIC)가 10 이상이면 AIC가 낮은 특정 모형에 가중치가 집중되는 것으로 나타났다. 또한, AIC의 산출식이 $AIC = -2\ln(L) + 2K$ 인 점을 고려할 때, naive와 인공 신경망의 두 기법은 우도 함수(likelihood function)를 기반으로 추정되지 않는 만큼 가중치 부여 대상에서 제외되었다(Burnham & Anderson, 2002). AIC 기반의 가중치 추정 방식은 제약조건이 부과된 회귀 분석 방식에서와 마찬가지로 모든 개별 모형을 예측 조합에 포함하지 않는 특징을 보인다.

3.4. 가격 예측의 정확도 측정 결과


검증 데이터(2019. 1.~2021. 12.)를 대상으로 추정한 조합 가중치를 테스트 데이터(2022. 1.~2024. 12.)에 적용한 결과 조합방식별로 새로운 예측치가 도출되었다. 예측 기간(forecast horizon)은 개별 가격 모형과 예측 조합모형 모두 1~6개월이다. 개별 예측 모형과 예측 조합모형에서 도출된 예측치들은 평가지표인 RMSE와 MAPE를 이용하여 예측력을 평가하였다. RMSE는 예측 오차의 평균적인 크기(규모)를 정량적인 수치로 제시하는 만큼 모형 간 예측 오차의 크기 차이를 직접적으로 비교할 수 있는 장점이 있기 때문에 본 연구는 MAPE보다는 RMSE 지표에 보다 의존하여 예측력을 평가하였다.

〈표 5〉는 양파의 가격 예측 모형에 대한 예측의 정확도 평가 결과를 보여주고 있다. 표에서 음영으로 표시된 부분은 개별 가격 예측 모형과 예측 조합 모형에서 RMSE나 MAPE가 가장 낮은 값으로 나타나 예측력이 가장 높다는 것을 보여준다. 예컨대, 1개월 예측 결과에서는 RMSE를 기준으로 할 때 개별 예측 모형의 경우 단순 기법(naive)의 예측력(RMSE=172.5)이 가장 우수한 한편, 예측 조합 모형에서는 MSE를 기준으로 한 예측 조합의 예측력(RMSE=163.1)이 가장 우수한 것으로 나타났다.

표 5. 양파의 가격 예측 모형에 대한 예측 정확도 평가

구분			1개월 예측		2개월 예측		3개월 예측		4개월 예측		5개월 예측		6개월 예측	
			RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
개별 예측 모형	1) 단순 기법(naive)		172.5	10.21	257.4	17.98	320.4	22.29	357.1	24.72	387.6	26.96	408.4	27.82
	2) ETS(A,N,A)		183.1	12.13	280.8	20.05	363.5	24.88	419.7	28.64	454.9	31.11	472.7	32.36
	3) ETS(M,A,M)		186.3	11.61	255.9	17.65	325.8	22.95	373.0	26.82	401.2	26.82	424.1	29.42
	4) ARIMA(1,0,2)		173.1	11.59	255.1	18.56	315.3	24.31	346.0	27.76	368.2	30.07	383.4	31.49
	5) SARIMA(2,1,1)(1,0,2)12		184.7	12.06	272.6	17.27	312.3	22.30	340.0	26.69	376.7	30.43	394.1	32.54
	6) ARIMA(p,d,q)+GARCH(1,1)		173.5	11.60	255.1	18.55	313.8	24.29	343.8	27.76	366.7	30.12	382.7	31.59
	7) ARIMAX(1,0,1:12)		184.9	12.47	268.1	19.15	344.0	23.80	400.8	27.97	432.5	30.38	454.4	32.40
	8) NNAR(13,1.8)[12]		190.1	12.28	286.9	19.46	342.7	23.80	371.1	25.93	384.6	27.81	387.4	29.06
예측 조합	단순 조합	평균(mean)	163.1	10.12	233.3	15.94	289.7	19.81	325.1	22.21	351.5	24.65	366.2	26.00
		중앙값(median)	166.9	10.60	237.7	16.47	290.9	20.11	318.0	22.18	341.5	23.88	357.3	26.16
	회귀 분석	가중치 합=1, 비음(nonnegative) 제약	176.9	10.69	260.7	16.96	299.7	21.31	329.9	23.98	363.2	27.42	375.0	29.30
		평균 제곱 오차(MSE)	163.1	10.10	233.6	16.01	289.0	19.89	322.3	22.27	347.8	24.75	361.9	25.99
	예측성과	평균 제곱 오차 순위(MSE RANK)	163.3	9.91	237.1	16.73	291.8	20.69	321.9	23.89	347.9	26.98	362.0	28.07
		정보 기준	AIC 가중치(Akaike weights)	181.6	11.88	263.6	17.02	308.1	21.75	338.3	24.55	369.4	27.96	385.8

그림 4. 양파: RMSE 기준 가격 예측력이 가장 우수한 조합방식의 예측값과 실제값 비교



예측 조합방식의 예측성과를 살펴보면, 평균이나 중앙값을 이용하는 단순 조합방식이 가장 여러 차례(2, 4, 5, 6개월)에 걸쳐 예측력이 가장 우수한 것으로 나타났고, MSE에 의한 성과 기반의 조합방식(1, 3개월)이 그다음을 차지하였다. 회귀분석에 기반한 예측 조합방식은 이론적 강건성에도 불구하고 전체 예측 기간에 걸쳐 예측력이 가장 우수한 모형으로 한 번도 선정되지 못하였다. 그리고 AIC 정보 기준에 의한 예측 조합방식은 일부 예측치에 가중치가 쏠리는(편중되는) 현상으로 인해 예측 오차가 가장 크게 나타남으로써 가장 저조한 예측성과를 보였다.

〈표 6〉은 1~6개월까지 전체 예측 기간에 걸쳐 RMSE 기준 최적으로 선정된 개별 모형 예측치와 조합 예측치 간의 예측 오차 차이를 구한 것이다. 즉, 개별 예측 모형 중 예측력이 가장 우수한 것으로 판명된 모형의 예측 오차와 예측 조합 모형 중 예측력이 가장 우수한 것으로 판명된 모형의 예측 오차 간 차이를 구한 결과다. 1개월 예측 기간에서는 평균적인 예측 오차의 차이가 9.4원/kg으로 나타났는데, 이것은 예측 조합을 통하여 예측 오차가 9.4원/kg만큼 줄어들었으므로 그만큼 예측력이 향상된다는 것을 의미한다. 마찬가지로, 예측 기간 6개월의 경우는 예측 조합을 통하여 예측 오차가 25.4원/kg만큼 줄어들었으므로 예측력이 크게 향상된다는 것을 의미한다. 이러한 결과는 개별 예측 모형을 사용할 때보다 예측 조합을 통하여 전반적인 예측력을 향상시킬 수 있다는 것을 시사한다.

표 6. 양파: 개별 모형 예측치와 조합 예측치 간의 예측 오차 차이(RMSE 기준)

단위: 원/kg						
구분	1개월	2개월	3개월	4개월	5개월	6개월
개별 모형	172.5	255.1	312.3	340.0	366.7	382.7
예측 조합	163.1	233.3	289.0	318.0	341.5	357.3
차이	9.4	21.8	23.3	22.0	25.2	25.4


한편, 〈표 5〉에서 예측 기간이 1개월로부터 6개월로 이행하는 동안 예측 오차의 크기 변화를 살펴보면, 예측 기간이 길어질수록 예측 오차도 커지는 경향이 나타났다. 이러한 경향은 개별 예측 모형과 예측 조합 모형 모두에서 공통적으로 나타나고 있다. 이는 예측 기간이 길어질수록(떨어질수록) 미래에 대한 불확실성이 커지기 때문에 그와 동반하여 예측 오차도 커지는 현상에 기인하는 것으로 해석된다.

〈그림 4〉는 1개월에서 6개월까지의 예측 기간에 걸쳐 RMSE 기준으로 예측력이 가장 우수한 것으로 판명된 조합방식의 예측치와 실제값을 동시에 나타낸 것이다. 각 그림은 테스트 데이터(2022. 1. ~ 2024. 12.)에 적용하여 연출되었다. 그림에서 예측 기간이 길어질수록 예측 오차가 커지는 경향을 반영하여 조합 예측치와 실제값 간의 차이가 확대되는 것을 확인할 수 있다. 1개월 예측 기간에서는 조합 예측치와 실제값이 거의 중첩되는 모습을 보이다가 6개월 예측 기간으로 이행할수록 조합 예측치와 실제값이 차츰 더 동떨어지는 모습을 확인할 수 있다.

표 7. 마늘의 가격 예측 모형에 대한 예측 정확도 평가

구분			1개월 예측		2개월 예측		3개월 예측		4개월 예측		5개월 예측		6개월 예측	
			RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
개별 예측 모형	1) 단순 기법(naive)		234.7	1.69	388.7	2.88	496.4	4.18	580.6	5.27	648.8	6.20	704.9	7.01
	2) ETS(A,N,A)		245.2	1.86	393.7	3.27	497.9	4.24	585.9	5.20	650.3	6.17	697.2	6.94
	3) ETS(M,Ad,N)		242.3	1.98	441.6	3.89	584.6	5.67	701.8	6.92	804.8	8.00	879.4	8.89
	4) ARIMA(1,1,3)		215.9	1.71	384.0	3.17	494.8	4.31	580.7	5.46	653.5	6.42	711.6	7.12
	5) SARIMA(0,1,1)(1,0,0)12		211.5	1.59	379.3	3.03	492.2	4.18	579.7	5.35	650.9	6.34	708.5	7.05
	6) ARIMAX(0,1,1:2)		212.3	1.57	379.9	3.05	491.2	4.17	578.2	5.29	650.6	6.30	708.1	6.99
	7) NNAR(2,1,3)[12]		241.8	2.10	441.3	4.15	556.5	5.56	656.7	7.02	744.7	8.36	821.3	9.38
예측 조합	단순 조합	평균(mean)	214.5	1.54	376.0	2.97	482.0	4.17	568.7	5.30	640.3	6.40	694.9	7.12
		중앙값(median)	213.5	1.60	374.5	2.97	488.2	4.13	577.2	5.34	648.2	6.35	705.0	7.02
	회귀 분석	비음(nonnegative) 제약	222.3	1.74	411.2	3.81	525.8	5.03	625.9	6.32	725.6	7.73	813.1	8.82
		평균제곱오차(MSE)	213.8	1.54	375.6	2.95	481.5	4.12	567.9	5.27	639.0	6.35	693.8	7.09
	예측성과	평균제곱오차 순위(MSE RANK)	211.6	1.55	376.3	2.94	484.9	4.09	571.3	5.28	639.6	6.27	692.5	7.03
		정보 기준	AIC 가중치(Akaike weights)	212.3	1.63	380.6	3.08	492.1	4.21	579.3	5.38	651.5	6.37	709.6

그림 5. 마늘: RMSE 기준 가격 예측력이 가장 우수한 조합방식의 예측값과 실제값 비교



〈표 7〉은 마늘의 가격 예측 모형에 대한 예측 정확도 평가 결과다. 표에서 음영으로 표시된 부분은 개별 가격 예측 모형과 예측 조합 모형에서 RMSE나 MAPE가 가장 낮은 값으로 나타나 예측력이 가장 높다는 것을 보여준다. 예컨대, 1개월 예측 결과에서는 RMSE를 기준으로 할 때 개별 예측 모형의 경우 SARIMA 모형의 예측력(RMSE=211.5)이 가장 우수한 한편, 예측 조합 모형에서는 MSE RANK를 기준으로 한 예측 조합의 예측력(RMSE=211.6)이 가장 우수한 것으로 나타났다.

예측 조합방식의 예측성가를 살펴보면, MSE 및 MSE RANK에 의한 성과 기반의 조합방식이 가장 여러 차례(1, 3, 4, 5, 6개월)에 걸쳐 예측력이 가장 우수한 것으로 나타났고, 중앙값을 이용한 단순 조합방식(2개월)이 그다음을 이었다. 회귀분석에 기반한 예측 조합방식과 AIC 정보 기준에 의한 예측 조합방식은 전체 예측 기간에 걸쳐 예측력이 가장 우수한 모형으로 한 번도 선정되지 못하였다.

〈표 8〉은 1개월부터 6개월까지 전체 예측 기간에 걸쳐 RMSE 기준 최적으로 선정된 개별 모형 예측치와 조합 예측치 간의 예측 오차 차이를 구한 결과다. 1개월 예측 기간에서는 평균적인 예측 오차의 차이가 -0.1원/kg으로 극히 미미한 수준인데, 이것은 개별 모형의 예측력이 예측 조합과 동일한 수준이라는 것을 의미한다. 반면, 2개월 이후의 예측 기간에서는 예측 조합의 예측 오차가 개별 모형의 예측 오차보다 줄어들었으므로 예측 조합을 통해 예측력이 향상되는 결과가 뚜렷하게 나타났다. 이러한 결과는 예측 조합을 통하여 전반적인 예측력이 향상될 수 있다는 것을 시사한다.

표 8. 마늘: 개별 모형 예측치와 조합 예측치 간의 예측오차 차이(RMSE 기준)

단위: 원/kg						
구분	1개월	2개월	3개월	4개월	5개월	6개월
개별 모형	211.5	379.3	491.2	578.2	648.8	697.2
예측 조합	211.6	374.5	481.5	567.9	639.0	692.5
차이	-0.1	4.8	9.7	10.3	9.8	4.7


한편, 〈표 7〉에서 예측 기간이 1개월로부터 6개월로 이행하는 동안 예측 오차의 크기 변화를 살펴보면, 예측 기간이 길어질수록 전반적으로 예측 오차도 커지는 경향이 나타났다. 이러한 경향은 개별 예측 모형과 예측 조합 모형 모두에서 공통적으로 나타나는데, 예측 기간이 길어질수록(멀어질수록) 미래에 대한 불확실성이 확대되는 만큼 예측 오차도 커지기 때문으로 해석된다.

〈그림 5〉는 1개월에서 6개월까지의 예측 기간에 걸쳐 RMSE 기준으로 예측력이 가장 우수한 것으로 판명된 조합방식의 예측치와 실제값을 동시에 나타낸 것이다. 각 그림은 테스트 데이터(2022. 1.~2024. 12.)에 적용하여 연출되었다. 양파의 경우와 마찬가지로, 예측 기간이 길어질수록 예측 오차가 커지는 경향을 반영하여 조합 예측치와 실제값 간의 차이가 확대되는 것을 확인할 수 있다. 1개월 예측 기간에서는 조합 예측치와 실제값이 거의 중첩되는 모습을 보이다가 6개월 예측 기간으로 이행할수록 조합 예측치와 실제값이 차츰 더 동떨어지는 모습을 확인할 수 있다.

표 9. 건고추의 가격 예측 모형에 대한 예측 정확도 평가

구분		1개월 예측		2개월 예측		3개월 예측		4개월 예측		5개월 예측		6개월 예측	
		RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE	RMSE	MAPE
개별 예측 모형	1) 단순 기법(naive)	658.2	2.30	798.1	3.37	932.5	4.39	1,024.8	5.29	1,098.5	6.05	1,349.0	7.59
	2) ETS(A,Ad,A)	502.8	2.30	632.4	3.48	742.5	4.58	837.6	5.31	893.2	5.90	1,234.0	7.33
	3) ETS(M,N,A)	497.5	2.24	612.6	3.35	710.4	4.25	790.9	4.88	845.2	5.47	1,200.3	6.92
	4) ARIMA(0,1,1)	688.6	2.34	820.1	3.43	954.9	4.46	1,048.1	5.44	1,107.4	6.10	1,357.5	7.66
	5) SARIMA(0,1,1)(0,0,2)12	843.4	3.51	873.2	3.99	862.6	4.20	917.3	4.89	878.6	4.89	951.4	5.60
	6) ARIMAX(1,0,1:12)	552.6	2.94	673.5	4.06	761.7	4.77	849.0	5.36	895.3	5.80	1,217.1	7.23
	7) NNAR(2,1,2)[12]	658.5	2.76	825.0	4.47	1,040.4	6.45	1,325.1	8.38	1,741.2	10.66	2,194.1	12.96
예측 조합	단순 조합												
	평균(mean)	544.4	2.08	599.5	2.79	665.9	3.52	724.0	4.03	749.2	4.41	896.7	5.44
	중앙값(median)	593.3	2.21	657.2	3.07	720.3	3.87	786.7	4.45	820.3	4.95	1,127.0	6.43
	회귀 분석												
	비음(nonnegative) 제약	562.7	2.82	698.6	4.42	786.4	5.14	907.5	5.84	1,052.4	6.55	1,045.2	6.71
	예측성과												
	평균 제곱 오차(MSE)	522.6	2.15	589.4	2.88	651.6	3.50	707.9	3.94	719.9	4.19	903.0	5.06
	평균 제곱 오차 순위(MSE RANK)	507.8	2.18	588.1	3.05	652.3	3.70	717.2	4.20	693.7	4.10	803.2	4.36
	정보 기준												
	AIC 가중치(Akaike weights)	637.1	2.77	616.4	2.94	628.5	3.44	676.5	3.77	713.8	4.25	978.7	5.56

그림 6. 건고추: RMSE 기준 가격 예측력이 가장 우수한 조합방식의 예측값과 실제값 비교



〈표 9〉는 건고추의 가격 예측 모형에 대한 예측 정확도 평가 결과를 제시하고 있다. 표에서 음영으로 표시된 부분은 개별 가격 예측 모형과 예측 조합 모형에서 RMSE나 MAPE가 가장 낮은 값으로 나타나 예측력이 가장 높다는 것을 보여준다. 예컨대, 1개월 예측 결과에서는 RMSE를 기준으로 할 때 개별 예측 모형 중 ETS(M,N,A) 모형의 예측력(RMSE=497.5)이 가장 우수한 한편, 예측 조합 모형 중에서는 MSE RANK를 기준으로 한 예측 조합의 예측력(RMSE=507.8)이 가장 우수한 것으로 나타났다.

예측 조합방식의 예측성결과를 살펴보면, MSE 및 MSE RANK에 의한 성과 기반의 조합방식이 가장 여러 차례(1, 2, 5, 6개월)에 걸쳐 예측력이 가장 우수한 것으로 나타났고, AIC 정보 기준에 의한 예측 조합방식(3, 4개월)이 그다음을 차지하였다. 한편, 평균이나 중앙값을 이용하는 단순 조합방식과 회귀 분석에 기반한 예측 조합방식은 전체 예측 기간에 걸쳐 예측력이 가장 우수한 모형으로 한 번도 선정되지 못하였다.

〈표 10〉은 1개월부터 6개월까지 전체 예측 기간에 걸쳐 RMSE 기준 최적으로 선정된 개별 모형 예측치와 조합 예측치 간의 예측 오차 차이를 구한 결과다. 1개월 예측 기간에서는 평균적인 예측 오차의 차이가 -10.3원/600g으로 나타났는데, 이것은 개별 모형의 예측력이 예측 조합보다 오히려 우수하다는 것을 의미한다. 반면, 2개월 이후의 예측 기간에서는 예측 조합의 예측 오차가 개별 모형의 예측 오차보다 대폭 줄어들었으므로 예측 조합을 통해 예측력이 크게 향상되는 결과가 나타났다. 특히, 예측 기간이 길어질수록 예측 조합을 통한 예측력 향상 효과가 더욱 크게 나타났다. 이러한 결과는 극히 소수의 예외적인 경우를 제외한 대부분은 예측 조합을 통하여 전반적인 예측력이 향상될 수 있음을 시사한다.

표 10. 건고추 : 개별 모형 예측치와 조합 예측치 간의 예측오차 차이(RMSE 기준)

단위: 원/600g						
구분	1개월	2개월	3개월	4개월	5개월	6개월
개별 모형	497.5	612.6	710.4	790.9	845.2	951.4
예측 조합	507.8	588.1	628.5	676.5	693.7	803.2
차이	-10.3	24.5	81.9	114.4	151.5	148.2

한편, 〈표 9〉에서 예측 기간이 1개월로부터 6개월로 이행하는 동안 예측 오차의 크기 변화를 살펴보면, 예측 기간이 길어질수록 전반적으로 예측 오차도 커지는 경향이 나타났다. 이러한 경향은 개별 예측 모형과 예측 조합 모형 모두에서 공통적으로 나타나는데, 예측 기간이 길어질수록(멀어질수록) 미래에 대한 불확실성이 확대되는 만큼 예측 오차도 커지기 때문으로 해석된다.

〈그림 6〉은 1개월에서 6개월까지의 예측 기간에 걸쳐 RMSE 기준으로 예측력이 가장 우수한 것으로 판명된 조합방식의 예측치와 실제값을 동시에 나타낸 것이다. 각 그림은 테스트 데이터(2022. 1. ~ 2024. 12.)에 적용하여 연출되었다. 양파 및 마늘의 경우와 마찬가지로, 예측 기간이 길어질수록 예측 오차가 커지는 경향을 반영하여 조합 예측치와 실제값 간의 차이가 확대되는 것을 확인할 수 있다. 1개월 예측 기간에서는 조합 예측치와 실제값이 거의 중첩되는 모습을 보이다가 6개월 예측 기간으로 이행

할수록 조합 예측치와 실제값이 차츰 더 동떨어지는 모습을 확인할 수 있다.

이상의 분석 결과를 종합해 보면, 양파, 마늘, 건고추 세 품목, 그리고 전체 예측 기간(1~6개월)에 걸쳐 예측 조합방식의 예측 오차가 개별 예측 모형의 예측 오차보다 훨씬 더 작게 나타남으로써 예측 조합을 통하여 전반적으로 가격 예측력이 향상될 수 있다는 것이 확인되었다. 다만, 가장 짧은 예측 기간인 1개월의 경우 예측 조합의 예측력이 개별 예측 모형과 같은 수준이거나 오히려 개별 예측 모형이 예측 조합의 예측력을 앞서는 사례가 나타나기도 했다. 건고추의 경우 개별 예측 모형의 예측 오차와 예측 조합 모형의 예측 오차 간 차이가 가장 크게 나타남으로써 예측 조합에 의한 가격 예측력 향상 효과가 가장 큰 것으로 나타났으며, 그다음으로 양파, 마늘의 순이었다. 특히 예측 기간이 길어질수록 예측 오차의 상대적 차이가 현저하게 나타나 예측 조합방식의 효과가 더욱 두드러졌는데, 이러한 결과는 장기 가격 예측에 관한 연구에서 예측 조합방식의 유용성이 매우 크다는 것을 시사한다.¹²⁾

한편, 예측 조합방식의 선택에 있어서는 MSE나 MSE RANK를 활용한 성과 기반의 조합방식이 개별 예측치에 비교적 고르게 가중치를 부여함으로써 예측력이 가장 우수한 사례를 가장 많이 만들어 냈다. 이러한 점에 비춰볼 때 MSE나 MSE RANK를 활용한 성과 기반의 조합방식은 어떤 예측 조합방식을 선택할 것인가를 두고 고민할 때 가장 무난하게 선택할 수 있는 방안으로 평가된다. 회귀분석에 기반한 조합방식은 이론적 강건성에도 불구하고 본 실증 연구에서는 가장 저조한 예측성고를 나타냈다. 단순 평균에 의한 조합방식의 예측성고를 면밀히 살펴보면, 예측력이 가장 우수한 것으로 판명된 다른 예측 조합모형에 비해 예측력이 크게 뒤지지 않는 것을 확인할 수 있는데, 계산의 간편성, 신속성, 직관적 이해의 용이성 등을 고려하면 예측력이 다소 뒤떨어지더라도 여전히 유용한 대안으로 평가된다.

이러한 예측 조합 전략은 KREI 농업관측센터의 품목별 전망치 도출에도 활용될 수 있다. 농업관측센터에서는 매월 발간하는 품목별 관측 정보에 관련 전문가들의 의견이 반영된 정성적 가격 예측치를 제공한다. 본 연구 결과를 농업관측에 적용하면, 농업관측의 정성적 예측치를 개별 예측 모형의 가격 예측치 중 하나로 포함시키는 한편 다른 정량적 예측 모형의 가격 예측치들과 조합하여 새로운 가격 예측치를 만들어 냄으로써 농업관측의 가격 예측력 제고에 기여할 수 있을 것으로 기대한다.

12) 본 연구의 예측력 평가 결과에 대해 통계적으로 유의미한 차이가 있는지 평가하기 위해 Modified Diebold and Mariano(MDM) 검정을 수행하였다. MDM 검정과 관련된 구체적인 내용은 Harvey et al.(1997)을 참고하길 바란다. 본 연구는 검정을 위한 손실 함수(loss function)로 제곱 오차(squared error)와 절대 오차(absolute error)를 고려하였고, 비교 대상은 예측 기간별로 예측력이 가장 우수한 개별 예측 모형과 조합 모형이다. 검정 결과, 제곱 오차를 적용한 경우 대부분 통계적으로 유의하지 않았고, 절대 오차를 적용하면 양파와 건고추에 대해서는 2개월 예측부터 10%, 5% 유의수준에서 각각 통계적으로 유의한 결과가 도출되었다. 즉, 절대 오차 기준에서 보면 양파와 건고추는 2개월 예측부터 조합 모형과 개별 예측 모형의 예측 정확도 차이가 있고, 조합 모형의 예측력이 더 우수하다는 것을 증명하였다. 따라서 양파와 건고추는 예측 기간이 길어질수록 조합 모형의 예측성고가 높아진다는 본 연구의 분석 결과를 MDM의 통계적 검정을 통해 재확인하였다. 다만 마늘은 조합 모형의 예측성고를 예측력 평가를 통해 확인하였으나, 개별 모형도 조합모형과 비교하여 예측력이 크게 떨어지지 않아 MDM 검정에서는 통계적으로 유의한 결과를 도출하지 못하였다. 본 연구에서 적용한 분석 대상 품목의 가격 변동성이 크지 않고, 예측 모형의 예측력이 전반적으로 우수하여 예측 조합에 의한 성과가 통계적으로 유의하지 않은 결과가 나타난 것은 연구의 한계점으로 남는다. 향후 연구에서는 배추, 무와 같은 가격 변동성이 상대적으로 큰 품목을 대상으로 다양한 예측 모형과 조합법을 도입하여 예측 조합의 성과를 검증함으로써 예측 조합 전략을 확대하여 나갈 필요가 있다.

4. 요약 및 결론

농산물 수급 예측 정보는 생산 농가, 정부 등 다양한 경제주체의 의사결정과 계획 수립에 활용되고 있는 만큼 예측 정확도 제고를 위한 실증 연구가 최근까지도 활발하게 진행되고 있다. 선행연구에서는 시계열 모형, 머신러닝 등의 다양한 예측 기법이 도입되고, 예측력 평가를 통해 상대적으로 우수한 모형이 제안되고 있다. 그러나 대부분의 선행연구는 개별 예측 모형 간의 예측력을 비교하는 데 중점을 두고 있다. 이에 반해 본 연구는 여러 개별 예측 모형을 통해 도출된 예측치에 각기 다른 가중치를 부여하여 조합하는 예측 조합방식을 국내 농산물 가격 예측에 적용했다는 점에서 차별성을 지닌다.

따라서 본 연구의 목적은 예측 조합을 통하여 개별 가격 예측 모형보다 더 나은 예측성적을 달성함으로써 예측력을 향상시킬 수 있는지를 밝혀내는 데 있다.

본 연구는 양념채소 중 양파, 마늘, 건고추를 대상으로 하고, 가격자료는 도매시장의 월별가격을 이용하였으며, 표본 기간은 2003년 1월부터 2024년 12월까지 22년이다. 본 연구에 이용된 개별 가격 예측 모형은 단순 예측(naive) 모형, ETS 지수평활 모형, ARIMA(SARIMA 포함), ARIMA-GARCH, ARIMAX, 인공 신경망 등이다. 개별 예측 모형은 추세와 계절성을 반영하거나 도매시장 반입량, 수입량 등의 외생변수를 포함하기도 하였다. 이러한 개별 모형으로부터 도출된 가격 예측치를 조합하는 방법으로는 단순 평균 및 중앙값을 이용한 조합, 회귀 분석에 기반한 조합, MSE와 MSE RANK를 활용한 성과 기반의 조합, AIC 정보 기준에 기반한 조합이 이용되었다.

본 연구의 분석 결과, 전 품목에 걸쳐 예측 조합방식의 예측 오차가 개별 예측 모형의 예측 오차보다 작게 나타남으로써 예측 조합을 통하여 전반적인 가격 예측력이 향상될 수 있다는 점이 확인되었다. 특히 예측 기간이 길어질수록 예측 조합 모형의 예측 오차가 개별 예측 모형의 예측 오차보다 훨씬 작게 나타남으로써 예측 조합방식의 효과가 현저하게 나타났다. 예측 조합방식의 선택에 있어서는 MSE나 MSE RANK를 활용한 성과 기반의 조합방식이 우수한 예측성적을 가장 많이 만들어 냄으로써 가장 무난하게 선택할 수 있는 조합방식으로 평가되었다.

본 연구는 국내 농산물 가격 예측에 있어서 개별 예측 모형의 예측치를 조합하는 다양한 방법을 제시하고 분석 결과를 도출하는 한편 예측성적을 검증했다는 점에서 의미가 있다. 본 연구는 예측 조합을 통하여 단일 예측 모형이 가지는 구조적 한계를 극복하고 예측 오차를 상호 보완함으로써 보다 안정적이고 신뢰성 있는 예측치를 도출할 수 있다는 점을 실증한 사례라고 할 수 있다.

예측 조합방식은 국외에서는 이미 다양한 분야에 적용되어 긍정적인 평가를 받아왔고, 본 연구에서도 개별 예측 모형 대비 예측력이 더 우수하다는 결과가 확인되었다. 향후 연구에서는 스택킹(stackings), 앙상블 학습(ensemble learning) 등 머신러닝 기반의 다양한 조합방식도 추가 적용하여 농산물 가격 예측의 정확도(accuracy) 및 예측 기법의 다양성(diversity)을 확보해 나갈 필요가 있다. 이를 통해 예측 조합방식의 실용성과 일반화 가능성을 한층 더 높여 나가길 기대한다.

참고문헌

- 강동곤, 장영민, 이주석, 이성수. (2024). 장단기 기억 신경망을 사용한 다변수 데이터 농산물 가격 예측 모델. *전기전자 학회논문지*, 28(3), 451-457. <http://doi.org/10.7471/ikeee.2024.28.3.451>
- 김배성. (2005). 채소가격 예측을 위한 응용기법별 예측력 비교. *농업경제연구*, 46(4), 89-113.
UCI : G704-000586.2005.46.4.009
- 김정우. (2020a). 머신러닝 기법 기반의 예측조합 방법을 활용한 산업 부가가치율 예측 연구. *한국콘텐츠학회논문지*, 22(12), 49-57. <http://doi.org/10.5392/JKCA.2020.20.12.049>
- 김정우. (2020b). 제약하의 예측조합 방법을 활용한 산업별 고용비중 예측. *한국융합학회논문집*, 11(1), 257-267.
<http://doi.org/10.15207/JKCS.2020.11.11.257>
- 김정우. (2022). 우리나라 고령층의 경제활동 수준 예측 -머신러닝 기법과 연계한 예측조합법을 중심으로-. *한국융합학회논문집*, 13(5), 237-247. <http://doi.org/10.15207/JKCS.2022.13.05.237>
- 김재휘, 김치운, 노호영. (2023). 대파 도매가격 예측모형 고도화 방안. *농업생명과학연구*, 57(4), 143-150.
- 김현학. (2015). 예측조합 및 밀도함수에 의한 소비자물가 상승률 전망. *경제분석*, 21(3), 103-136.
<http://doi.org/10.23299/bokeri.2015.21.3.004>
- 남국현, 최영찬. (2015). 양파 출하시기 도매가격 예측모형 연구. *농촌지도와 개발*, 22(4), 423-434.
UCI : G704-SER000009844.2015.22.4.001
- 양성준. (2024). 품종별 양파 수급모형 개발과 응용기법별 가격 예측력 비교 연구. 제주대학교 대학원 석사학위 논문.
- 오유미, 최동오, 유천. (2023). 인공지능경망을 이용한 쌀가격 예측모형 개발과 국제통상 시사점. *e-비즈니스연구*, 24(3), 93-102.
- 오승원, 임남희, 이상현, 김민수. (2020). Prophet 모형을 이용한 마늘 가격의 장기 예측 및 트렌드 분석, *한국자료분석학회*, 22(6), 2325-2336. <http://doi.org/10.37727/jkdas.2020.22.6.2325>
- 유도일. (2016). 기상변인을 고려한 채소가격 예측모형 개발. *농업경제연구*, 57(1), 1-24.
UCI : G704-000586.2016.57.1.001
- 윤민정, 최수현, 이소현, 김희웅. (2024). 농산물 가격 예측을 위한 딥러닝 모델 개발: 날씨와 경제 변수를 중심으로. *경영정보학연구*, 26(3), 221-237. <http://doi.org/10.14329/isr.2024.26.3.223>
- 윤성주, 이춘수, 양승룡. (2016). 인공 신경망을 이용한 국제곡물가격 예측 모형 개발. *농업경제연구*, 57(2), 83-101.
UCI : G704-000586.2016.57.2.003
- 이석일, 김선웅, 윤병삼. (2015). 육계가격 예측모형의 예측력 비교 평가. *농업경영·정책연구*, 42(2), 232-248.
UCI : G704-000650.2015.42.2.005
- 이선홍, 성병찬. (2022). 단변량 시계열 모형들의 단순 결합의 예측 성능. *응용통계연구*, 32(6), 851-865.
- 이진희, 김덕파. (2014). 한국 경제변수에 대한 자기회귀 및 벡터자기회귀 모형의 예측성과 비교. *경제분석*, 20(4), 115-151.
- 이창민, 송성광, 정성욱. (2022). 앙상블 Voting 기법을 활용한 배추 가격 예측에 관한 연구. *융합정보논문지*, 12(3), 1-10. <http://doi.org/10.22156/CS4SMB.2022.12.03.001>
- 이형용, 여민수, 홍승지. (2017). 마늘 도매가격 시계열 예측 모형 비교. *농촌경제*, 40(2), 55-73.
<http://doi.org/10.36464/jrd.2017.40.2.003>
- 박소연, 김동연, 김민수. (2022). 생육시기 기상을 활용한 배추 가격 예측. *한국자료분석학회*, 24(5), 1667-1679.
<http://doi.org/10.37727/jkdas.2022.24.5.1667>
- 박종현, 임영우, 임도현, 최윤성, 안현철. (2023). 중장기 농산물 가격 예측을 위한 다단계 시계열 예측 모델. *한국컴퓨터정보학회논문지*, 28(2), 201-207. <http://doi.org/10.9708/jksci.2023.28.02.201>
- 박찬, 이경순. (2023). 농산물 가격의 특이치 탐지 및 처리를 통한 딥러닝 기반 가격 예측. *디지털콘텐츠학회논문지*, 24(8), 1899-1906.
- 배경태. (2016). 인공지능경망 기법을 이용한 최적의 농산물 가격 예측모델 개발. 숭실대학교 대학원 석사학위 논문.

- 배두람, 성병찬. (2019). 다중 결합 예측 알고리즘을 이용한 교통사고 발생건수 예측. *응용통계연구*, 32(6), 851-865.
- 서울특별시농수산식품공사, 유통정보 홈페이지. <<https://www.garak.co.kr>>. 검색일: 2025. 4. 15.
- 서지영(2022). *딥러닝 파이토치 교과서*. 길벗.
- 신성호, 이미경, 송사광. (2018). LSTM 네트워크를 활용한 농산물 가격 예측 모델. *한국콘텐츠학회논문지*, 18(11), 416-429.
- 장수희, 전희주, 조인호, 김동환. (2017). 비정형 농업기상자료를 활용한 배추 도매가격 예측모형 연구. *한국데이터정보과학회지*, 28(3), 617-624.
- 조태호. (2023). *모두의 딥러닝*. 길벗.
- 최병옥, 최익창. (2007). 시계열 분석방법을 이용한 과채류 월별가격 예측. *농촌경제*, 30(1), 129-148.
- 최병재, 한진현. (2014). *월별자료를 이용한 예측조합에 의한 GDP 전망*. 한국은행 경제전망보고서.
- 최현오, 여현, 이명훈, 박장우. (2022). 생산지 환경에 따른 도매시장 농산물 가격 예측 연구. *한국지식정보기술학회 논문지*, 17(6), 1285-1295.
- 하지희, 서상택, 김선웅. (2017). 양파와 마늘가격 예측모형의 예측력 고도화 방안. *농촌계획*, 25(4), 109-117.
- 허다솜, 정승권. (2024). 고랭지배추의 생육 시기별 주산지 기상정보를 활용한 출하시기 도매가격 예측모형. *한국정보기술학회논문지*, 22(9), 11-22.
- 한국농수산식품유통공사, KAMIS 홈페이지. <<https://www.kamis.or.kr/customer/main/main.do>>. 검색일: 2025. 4. 15.
- 한국농촌경제연구원. (2025). *농업전망 2025: 한국 농업·농촌, 변화를 준비한다*. <<https://www.krei.re.kr/krei/page/53?cmd=view&biblioId=542351&pageIndex=1>>. 검색일: 2025. 4. 20.
- Aiolfi, M. & A. Timmermann. (2006). Persistence in Forecasting Performance and Conditional Combination Strategies. *Journal of Econometrics*, 135(1), 31-53.
<https://doi.org/10.1016/j.jeconom.2005.07.015>
- Bates, J. M. & C. W. J. Granger. (1969). The Combination of Forecasts. *Journal of the Operational Research Society*, 20(4), 451-468.
- Bec, F. & M. Mogliani. (2013). Nowcasting French GDP in Real-Time from Survey Opinions: Information or Forecast Combinations?. *Banque de France Working Paper*, 436.
<https://doi.org/10.2139/ssrn.2283165>
- Bollerslev, T. (1986). Generalized Autoregressive Conditional Heteroskedasticity. *Journal of the Econometrics*, 31(3), 307-327. [https://doi.org/10.1016/0304-4076\(86\)90063-1](https://doi.org/10.1016/0304-4076(86)90063-1)
- Brandt, J. A. & D. A. Bessler. (1981). Composite Forecasting: An Application with U.S. Hog Prices. *American Journal of Agricultural Economics*, 63(1), 135-140. <https://doi.org/10.2307/1239819>
- Burnham, K. P. & D. R. Anderson. (2002). *Model Selection and Multi-Model Inference: A Practical Information Theoretic Approach*. Springer.
- Clemen, R. T. (1989). Combining Forecasts: A Review and Annotated Bibliography. *International Journal of Forecasting*, 5(4), 559-583. [https://doi.org/10.1016/0169-2070\(89\)90012-5](https://doi.org/10.1016/0169-2070(89)90012-5)
- Colino, E. V., S. H. Irwin, P. Garcia, & X. Etienne. (2012). Composite and Outlook Forecast Accuracy. *Journal of Agricultural and Resource Economics*, 37(2), 228-246.
- Cuaresma, J. C., J. Hlouskova, & M. Obersteiner. (2021). Agricultural Commodity Price Dynamics and their Determinants: A Comprehensive Econometric Approach. *Journal of Forecasting*, 40(7), 1245-1273. <https://doi.org/10.1002/for.2768>
- Gil, J. & L. Albu. (1993). Composite Forecasting Methods: an Application to Spanish Maize Prices. *Journal of Agricultural Economics*, 44(2), 264-271.
<https://doi.org/10.1111/j.1477-9552.1993.tb00270.x>
- Granger, C. W. J. & R. Ramanathan. (1984). Improve methods of Combining Forecasts. *Journal of Forecasting*, 3(2), 197-204.

- Graziera, E., C. Luu, & P. St-Amant. (2013). The Accuracy of Short-Term Forecast Combinations. Bank of CANADA Review.
- Gu, Y. H., D. Jin, H. Yin, R. Zheng, X. Piao, & S. J. Yoo. (2022). Forecasting Agricultural Commodity Prices Using Dual Input Attention LSTM. *Agriculture*, 12(2), 256.
<https://doi.org/10.3390/agriculture12020256>
- Gurung, B., K. N. Singh, R. K. Paul, S. Panwar, B. Gurung, & L. Lepcha. (2017). An Alternative Method for Forecasting Price Volatility by Combining Models. *Communications in Statistics-Simulation and Computation*, 46(6), 4627-4636. <https://doi.org/10.1080/03610918.2015.1124115>
- Harvey, D., S. Leybourne, & P. Newbold. (1997). Testing The Equality of Prediction Mean Squared Errors. *International Journal of Forecasting*, 13(2), 281-291.
[https://doi.org/10.1016/s0169-2070\(96\)00719-4](https://doi.org/10.1016/s0169-2070(96)00719-4)
- Heydari, R. (2023). A Flexible Combination Forecasting Method for Modeling Agricultural Commodity Prices: A Case Study Iran's Livestock and Poultry Meat Market. *Journal of Agricultural Economics and Development*, 37(2), 177-202.
- Hyndman, R. J. & G. Athanasopoulos. (2021). *Forecasting: Principles and Practice*. OTexts.
- Kolassa, S. (2011). Combining Exponential Smoothing Forecasts Using Akaike Weights. *International Journal of Forecasting*, 27(2), 238-251. <https://doi.org/10.1016/j.ijforecast.2010.04.006>
- Ramsey, A. F. & M. K. Adjemian. (2024). Forecast Combination in Agricultural Economics: Past, Present, and the Future. *Applied Economic Perspectives and Policy*, 46(4), 1450-1478.
<https://doi.org/10.1002/aep.13445>
- Stock, J. H. & M. W. Watson. (1999). Forecasting Inflation. *Journal of Monetary Economic*, 44(2), 293-335.
<https://doi.org/10.3386/w7023>
- Sun, F., X. Meng, Y. Zhang, Y. Wang, H. Jiang, & P. Liu. (2023). Agricultural Product Price Forecasting Method: A Review. *Agriculture*, 13(9), 1671. <https://doi.org/10.3390/agriculture13091671>
- Vere, D. T. & G. R. Griffith. (1990). Comparative Forecast Accuracy in the New South Wales Prime Lamb Market. *Australian Journal of Agricultural Economics*, 34(2), 103-117.
<https://doi.org/10.1111/j.1467-8489.1990.tb00696.x>
- Wang, X., R. J. Hyndman, F. Li, & Y. Kang. (2022). Forecast Combinations: an over 50-year review. *International Journal of Forecasting*, 39(4), 1518-1547.
- Xu, X. (2017). Short-Run Price Forecasting Performance of Individual and Composite Models for 496 Corn Cash Markets. *Journal of Applied Statistics*, 44(14), 2593-2620.
<https://doi.org/10.1080/02664763.2016.1259399>
- Yaziz, S. R., N. A. Azizan, R. Zakaria, & M. H. Ahmad. (2013). The Performance of Hybrid ARIMA-GARCH Modeling in Forecasting Gold Price. 20th International Congress on Modeling and Simulation.
- Yin, H. L., D. Jin, Y. H. Gu, C. J. Park, S. K. Han, & S. J. Yoo. (2020). STL-ATTTLSTM: Vegetable Price Forecasting Using STL and Attention Mechanism-Based LSTM. *Agriculture*, 10(12), 612.
<https://doi.org/10.3390/agriculture10120612>
- Zhang, G. (2023). Comparison of Machine Learning Models and Traditional Models for Forecasting in the Economy. *Computer Life*, 11(3), 1-6.



이 저작물은 크리에이티브 커먼즈 저작자표시-비영리-변경금지 4.0 국제 라이선스에 따라 이용할 수 있습니다.

This work is licensed under CC BY-NC-ND 4.0.