

## Comparing Inflation Forecasting Models in Iran: New Evidences from ARDL-D-LSTM Model

Hamed Azizi Ganzagh 

The Student of PhD, Economics,  
University of Mazandaran, Babolsar,  
Iran

Ahmad Jafari Samimi \* 

Professor, Economics, University of  
Mazandaran, Babolsar, Iran

Zahra Mila Elmi 

Professor, Economics, University of  
Mazandaran, Babolsar, Iran

Amir Mansour Tehranchian 

Professor, Economics, University of  
Mazandaran, Babolsar, Iran

### Abstract

Inflation forecasting is one of the most important issues for the economies of countries, As the existing literature suggests, hybrid models will bring better prediction accuracy due to attention to both linear and non-linear dimensions. Furthermore, the use of ARDL model can include lags of other variables in tandem with having linear features. It should also be noted that LSTM models have a forgetting gate due to their non-linear estimation characteristics, and they can incorporate data with very distant lags in the model. Therefore, the combination of these two models can significantly improve the prediction accuracy. Accordingly, attempts have been made in the current study to compare ARDL, NARX, LSTM and ARDL-D-LSTM models with one another and to introduce a suitable model for

- This article has been extracted from a PhD dissertation conducted in the field of Economics at University of Mazandaran

\* Corresponding Author: [Jafarisa@umz.ac.ir](mailto:Jafarisa@umz.ac.ir)

**How to Cite:** Azizi Ganzagh, H., Jafari Samimi, A., Mila Elmi, Z., Tehranchian, A. M. (2023). Comparing Inflation Forecasting Models in Iran: New Evidences from ARDL-D-LSTM Model. *Iranian Journal of Economic Research*, 27 (93), 177-208.

predicting Iran's monthly inflation rate in the short-term and long-term time horizon. After estimating the monthly inflation rate of Iran in the period of 4/21/2005 to 8/22/2018 and testing the model on the data for the period of 9/22/2018 to 12/21/ 2020 it was found that the NARX model and the ARDL-D-LSTM hybrid model performed well respectively for short-term time horizon and the long-term horizon according to the RMSE criteria.

## **1. Introduction**

Researchers always seek to select a model that minimizes the prediction error to forecast the future of economic variables accurately, which is crucial for properly effective management. Among the various economic variables, inflation rate is of utmost importance in evaluating macroeconomic performance. Data analysis methods can be classified into structural and non-structural approaches. Considering the non linearity of macroeconomic indicators due to the shocks caused by economic cycles, it is often more effective to estimate these indicators with non-linear models. Hence, relying solely on linear models to make predictions may not yield completely accurate results when modeling economic policies. Numerous studies have emphasized the importance of developing models that can capture both linear and non-linear aspects of time series data. The present study aimed to compare different modeling approaches for forecasting the inflation rate. Specifically, the study focused on the following models: Autoregressive Distributed Lag (ARDL) as a linear and structural model, Nonlinear Autoregressive Exogenous (NARX) as a non-linear and structural model, Long Short-Term Memory (LSTM) as a non-linear and non-structural model, and ARDL-D-LSTM as a hybrid model that incorporates both linear and non-linear components and is theoretically supported by the inflation rate. The study also relied on other macroeconomic variables. The ARDL model was used because it allows for the inclusion of economic variables in forecasting inflation. The research actually paid special attention to the theoretical foundations of inflation and other economic variables.

## **2. Materials and Methods**

In the econometric literature, non-structural models were the first approach used to predict the inflation rate. These models were originally presented in the form of simple linear differential equations in the 1920s, providing a robust framework for modeling and forecasting various economic variables. The development of the Autoregressive Moving Average (ARMA) model in the mid-20th century further expanded the toolkit of non-structural forecasting models for time series data. Subsequently, in 1955, the system of simultaneous equations was introduced for predicting inflation. In the late 1970s, criticism of the system of simultaneous equations by Lucas in 1976 led to a decline in prediction based on Keynesian structural models. In response to this criticism, two approaches emerged. The first approach aimed to improve the accuracy of the system of simultaneous equations by incorporating the hypothesis of rational expectations. The second approach focused on developing non-linear models to better capture the complexities of data. Later on, neural network models became a powerful tool in various scientific fields, including economics. These models are now commonly used to forecast key economic variables such as inflation, economic growth, stock index, taxes, etc. To improve the accuracy of these forecasts, a combination of methods is often employed. Showing a better forecasting performance, combined or hybrid models are generally more practical, economical, and useful than a single model.

## **3. Results and Discussion**

In this study, individual linear and non-linear models were analyzed, followed by the analysis of the hybrid model. Economic theories were used in the case of ARDL and NARX. The method of each econometric model and artificial neural network were used to obtain coefficients and weights for the models. Concerning non-structural models, a Vanilla LSTM model was used. Finally, in the case of hybrid models, the research developed the ARDL-D-LSTM model by nonlinearly estimating the disturbance components of the ARDL-D. Applying the

Hodrick-Prescott filter in the linear estimation of ARDL was effective in capturing the unique characteristics of Iran's inflation, including the sudden and excessive shifts in the equilibrium point of the model. The stability of the coefficients in ARDL was assessed through the CUSUM and CUSUMSQ statistics. All time series used in the seasonal and monthly modeling were valid, and suitable conditions were met for fitting the models. After estimating and forecasting the monthly inflation through the RMSE criterion, the study evaluated the performance of ARDL-D, NARX, LSTM, and ARDL-D-LSTM models for short-term (3–6 months) and long-term (12–24 months) horizons. The NARX model showed good performance in short-term forecasting of Iran's monthly inflation, while the ARDL-D-LSTM model performed well in long-term forecasting.

#### **4. Conclusion**

Incorporating the theoretical foundations of the inflation variable is essential in accurately predicting the inflation rate. In this respect, four influential variables were included in the model: 1) growth of the volume of liquidity, 2) growth of the monthly exchange rate, 3) growth of government debt to the central bank, and 4) growth of gross domestic income.

The ARDL and NARX models, which were developed based on the selected variables, as well as ARDL-D-LSTM, demonstrated good performance in predicting inflation. For other economic indicators with high volatility, such as those related to the investment sector (e.g., stock market index, asset prices, and risk forecasting), the ARDL-D-LSTM model could potentially be used. Considering the various types of linear and non-linear models and optimization algorithms, there are still many high-performance hybrid methods that researchers can use to enhance the accuracy of economic forecasting. This opens up opportunities for future research in this field.

**Keywords:** Inflation Forecasting, Hybrid Models, ARDL, LSTM.

**JEL Classification:** C01 ,C02 ,C38 ,C45 ,C61.




پژوهش‌های اقتصادی ایران


دوره ۲۷، شماره ۹۳، زمستان ۱۴۰۱، ۱۷۷-۲۰۸


ijer.atu.ac.ir


DOI: <https://doi.org/10.22054/ijer.2022.63376.1037>

## مقایسه الگوهای پیش‌بینی تورم در ایران: شواهد جدید از الگوی ترکیبی ARDL-D-LSTM

حامد عزیزی گنزق  دانشجوی دکتری رشته علوم اقتصادی، دانشگاه مازندران، بابلسر، ایران

احمد جعفری صمیمی  \* استاد، گروه اقتصاد، دانشگاه مازندران، بابلسر، ایران

زهرامیلا علمی  استاد، گروه اقتصاد، دانشگاه مازندران، بابلسر، ایران

امیرمنصور طهرانچیان  استاد، گروه اقتصاد، دانشگاه مازندران، بابلسر، ایران

### چکیده

پیش‌بینی تورم یکی از مهم‌ترین مسائل برای اقتصاد کشورها است. دولت‌ها و بانک‌های مرکزی برای اتخاذ تصمیمات و سیاست‌گذاری‌های اقتصادی خود، شاخص‌های تورم را رصد می‌کنند. هدف از انجام این پژوهش مقایسه الگوهای ARDL، NARX، LSTM و ARDL-D-LSTM با یکدیگر و همچنین معرفی الگوی مناسب برای پیش‌بینی نرخ تورم ماهانه ایران در افق زمانی کوتاه‌مدت و بلندمدت است. در این پژوهش با توجه به استفاده از الگوی ترکیبی، هر دو بعد خطی و غیرخطی پوشش داده می‌شود و بعد از برآورد نرخ تورم ماهانه ایران در بازه ۱۳۸۴/۱/۳۰ تا ۱۳۹۷/۵/۳۰ با استفاده از آزمایش این الگوها در بازه ۱۳۹۷/۶/۳۱ تا ۱۳۹۹/۶/۳۱ می‌توان نتیجه گرفت که الگوی NARX برای افق زمانی کوتاه‌مدت و الگوی ترکیبی ARDL-D-LSTM برای افق زمانی بلندمدت عملکرد خوبی را براساس معیار RMSE از خود نشان دادند.

واژگان کلیدی: پیش‌بینی تورم، الگوهای ترکیبی، ARDL، LSTM.

طبقه‌بندی JEL: C01، C02، C38، C45، C61.

مقاله حاضر برگرفته از رساله دکتری رشته علوم اقتصادی دانشگاه مازندران است.

\* نویسنده مسئول: Jafarisa@umz.ac.ir

## ۱. مقدمه

محققان همواره در پی انتخاب الگویی با حداقل خطای ممکن هستند که از طریق آن پیش‌بینی درستی از آینده متغیرهای اقتصادی داشته باشند تا بتوانند مدیریت مناسبی را اعمال کنند. نرخ تورم به‌عنوان یکی از مهم‌ترین متغیرهای اقتصادی به لحاظ ارزیابی عملکرد اقتصاد کلان از اهمیت بسزایی برخوردار است. روش‌های تحلیل داده در قالب دو بخش ساختاری<sup>۱</sup> و غیرساختاری<sup>۲</sup> تقسیم‌بندی می‌شوند (Peirano, et al., 2021). برای پیش‌بینی تورم الزاماً نیازی نیست که همواره کله‌های پولی<sup>۳</sup> محوریت تحلیل‌های تورم قرار گیرد و می‌توان با استفاده از شبکه‌های عصبی مصنوعی<sup>۴</sup> و روش‌های آماری ناپارامتریک<sup>۵</sup> پیش‌بینی مناسب‌تری را انجام داد (Binner, et al., 2010).

در مقاله مک‌نایت و دیگران<sup>۶</sup> (۲۰۲۰) به دورویکرد در مواجهه با پیش‌بینی تورم پرداخته شده است؛ اولی مربوط به استفاده از تئوری‌های اقتصادی منحنی فیلیپس در مکتب نئوکینزین‌ها<sup>۷</sup> (NKPC) و دومی مربوط به استفاده از الگوهای غیرساختاری و خطی خودرگرسیون میانگین متحرک انباشته (ARIMA)<sup>۸</sup> است. با توجه به غیرخطی<sup>۹</sup> بودن شاخص‌های کلان اقتصادی به دلیل شوک‌های ایجاد شده از چرخه‌های اقتصادی بهتر است که این شاخص‌ها با الگوهای غیرخطی برآورد شوند (LeBaron, 1994). از این رو، پیش‌بینی‌های مبتنی بر فرض خطی بودن، هنگام الگوسازی سیاست‌های اقتصادی، پاسخ‌های کاملاً دقیق ارائه نمی‌دهند. ارائه الگویی که ماهیت خطی و غیرخطی سری‌های زمانی را به تصویر بکشد، دغدغه‌ای است که در مطالعات مختلف به آن پرداخته شده است. در این پژوهش برای مقایسه در بخش الگوی خطی و ساختاری از ARDL<sup>۱۰</sup>، در

- 
1. Theoretical
  2. Non-Theoretical
  3. Monetary Aggregates
  4. Artificial Neural Network
  5. Nonparametric
  6. McKnight, S., et al.
  7. New Keynesian Phillips Curve
  8. Autoregressive Integrated Moving Average Models
  9. Nonlinear
  10. Autoregressive Distributed Lag

بخش الگوی غیرخطی و ساختاری از الگوی خود برازش برونزای غیرخطی (NARX)<sup>۱</sup>، از الگوی حافظه کوتاه مدت طولانی<sup>۲</sup> (LSTM) به عنوان الگوی غیرخطی و غیرساختاری و از الگوی ARDL-D-LSTM<sup>۳</sup> به عنوان الگوی ترکیبی<sup>۴</sup> استفاده شده است. در الگوی ترکیبی هر دو قسمت خطی و غیرخطی پوشش داده می شود و از جهتی پشتوانه نظری نرخ تورم را داراست. به عبارت دیگر، در این پژوهش از سایر متغیرهای اقتصاد کلان نیز استفاده خواهد شد. استفاده از الگوی ARDL در این پژوهش به این دلیل است که بتوان از متغیرهای اقتصادی در پیش بینی تورم نیز استفاده کرد. در واقع در این پژوهش تنها به روش های کمی در الگوهای سری زمانی توجه نشده، بلکه به مبانی نظری تورم و متغیرهای اقتصادی نیز توجه ویژه ای شده است.

نکته بسیار مهم در برآورد الگوها این است که از وقفه متغیرها استفاده می شود؛ یعنی ویژگی های استخراجی از فیلتر هدریک-پرسکات<sup>۵</sup> به عنوان متغیر مجازی نیز با وقفه وارد الگو می شود. همچنین برای آزمایش داده ها بعد از برآورد به صورت پنجره متحرک<sup>۶</sup> در نرم افزار<sup>۷</sup> استفاده شده است (تمام ویژگی هایی که تا زمان  $t-1$  موجود است) و پیش بینی ها به صورت یک گام رو به جلو برآورد می شوند.

سوالات اصلی این مقاله به این شرح است: ۱- آیا الگوی ترکیبی ARDL-D-LSTM نسبت به الگوهای انفرادی مدنظر برتری دارد؟ ۲- از میان الگوهای پیشنهادی کدام الگو عملکرد بهتری را در پیش بینی تورم از خود نشان می دهند؟

ساختار مقاله حاضر به این شرح است: در قسمت اول به مقدمه مقاله اشاره شد که معرفی اجمالی از پژوهش حاضر در کنار بیان مساله، هدف تحقیق، پرسش و فرضیات بود. در بخش دوم به پیشینه پژوهش پرداخته می شود. در بخش سوم ادبیات نظری پژوهش، در

1. Nonlinear Autoregressive Network with Exogenous Inputs
2. Long Short-Term Memory
3. Hybrid of ARDL and LSTM
4. Hybrid Models
5. Hodrick-Prescott Filter
6. Rolling Window

۷. نرم افزار پایتون (Python).

بخش چهارم روش شناسی الگوهای پژوهش، در بخش پنجم برآورد الگو و تجزیه و تحلیل الگوها و در بخش ششم یا بخش آخر به بررسی نتایج و پیشنهادها پرداخته خواهد شد.

## ۲. پیشینه پژوهش

مطالعات بسیاری در مقایسه الگوهای هوش مصنوعی<sup>۱</sup> و اقتصاد سنجی در مواجهه با تورم کشورهای در حال توسعه انجام شده است؛ در بررسی تورم ترکیه و با مقایسه دو الگوی ANN<sup>۲</sup> و ARIMA اختلافی بین دو الگو وجود نداشت (Işığışok, et al., 2020). استیکو و وهی یودین<sup>۳</sup> (۲۰۱۹) به بررسی تورم اندوزی پرداختند و با مقایسه دو الگوی ANN و ARIMA نشان دادند که الگوهای مبتنی بر هوش مصنوعی عملکرد بهتری را ارائه می‌دهند.

ژانگ<sup>۴</sup> (۲۰۰۳) و خاشعی و بیجاری<sup>۵</sup> (۲۰۱۱) در زمینه پیش‌بینی به ترکیب دو روش خطی و غیرخطی پرداخته و به برآورد الگوی ترکیبی ARIMA-ANN اقدام کردند و نشان دادند که الگوی ترکیبی عملکرد بهتری را از خود نشان می‌دهد. با توجه به اهمیت الگوهای پیش‌بینی و با توجه به وسعت الگوها در جدول (۱) به جمع‌بندی مطالعات در زمینه الگوهای پیش‌بینی پرداخته شده است.

جدول ۱. جمع‌بندی مطالعات انجام شده در بخش الگوهای پیش‌بینی

پژوهش‌های داخلی		
نتیجه	توضیحات	نویسنده
پس از آن با استفاده از مبانی الگوریتم ژنتیک، متغیرهای اساسی اثرگذار بر تورم تعیین شد که در نتیجه هفت متغیر حجم نقدینگی، شاخص نرخ دستمزد، مخارج دولتی، تولید ناخالص داخلی، تورم با وقفه، شاخص قیمت جهانی نفت خام و نرخ سود بانکی به‌عنوان متغیرهای اساسی تاثیرگذار بر تورم تشخیص داده شدند.	به بررسی عوامل تاثیرگذار بر تورم و طراحی یک سیستم هشدار شدید در اقتصاد ایران پرداخته‌اند.	پورکاظمی و دیگران (۱۳۹۴)

1. Artificial Intelligence
2. Artificial Neural Networks
3. Estiko, F. & Wahyuddin, S.
4. Zhang, G.
5. Khashei, M. & Bijari, M.



پژوهش‌های داخلی		
نویسنده	توضیحات	نتیجه
محمدی و دیگران (۱۳۹۷)	با استفاده از الگوهای ARIMA، شبکه عصبی و همچنین ترکیب این دو الگو به پیش‌بینی حد بالا، حد پایین و قیمت پایانی انس طلا پرداختند.	با استفاده از روش دایبولد- ماریانو <sup>۱</sup> به این نتیجه رسیدند الگوی ترکیبی ARIMA-ANN عملکرد بهتری نسبت به سایر الگوهای انفرادی داشته است.
رئوفی و محمدی (۱۳۹۷)	به پیش‌بینی بازده بازار سهام تهران با استفاده از الگوی ترکیبی تبدیل موجک و شبکه عصبی فازی تطبیقی پرداختند.	با استفاده از آزمون MGN <sup>۲</sup> نشان دادند که نویزگیری از متغیر و استفاده از الگوی ترکیبی، عملکرد بهتری را به همراه دارد.
ذوالفقاری و دیگران (۱۳۹۹)	به پیش‌بینی شاخص کل بورس اوراق بهادار با استفاده از دو متغیر مستقل نفت و طلا پرداختند. اتکای آن‌ها روی الگوهای آموزش ماشین <sup>۳</sup> و یادگیری عمیق <sup>۴</sup> بوده است و مهم‌ترین ویژگی این الگوها را عدم محدودیت به الگوهای معین عنوان می‌دارند.	نشان دادند که الگوهای ترکیبی در مقابل الگوهای انفرادی از عملکرد بهتری برخوردار بوده و الگوی ترکیبی RNN-LSTM-EGARCH به نسبت سایر الگوها عملکرد بالاتری را از خود نشان می‌دهد.
پژوهش‌های خارجی		
کومار و دیگران <sup>۵</sup> (۲۰۱۲)	با استفاده از الگوهای ANN, ARIMA و الگوی ترکیبی ARIMA-ANN به پیش‌بینی بازده سهام نیویورک پرداختند.	الگوی ترکیبی عملکرد بهتری را نسبت به الگوهای فردی از خود نشان می‌دهد.
حنیف و مالیک <sup>۶</sup> (۲۰۱۵)	پیش‌بینی تورم در کشور پاکستان با استفاده از مدل‌های VAR, ARDL, ARIMA, AR(1) صورت گرفت.	در این مطالعه نشان داده شده که مدل ARDL بهترین انتخاب بوده و تورم‌های میان‌مدت و بلندمدت بهتر است با این روش پیش‌بینی شود.

1. Diebold - Mariano

۲. آزمون مورگان-گرنجر-نیوبولد

3. Machine Learning

4. Deep Learning

5. Kumar, M., & Thenmozhi, M.

6. Hanif, M. N., & Malik, M. J.

ادامه جدول ۱.

پژوهش‌های خارجی		
نویسنده	توضیحات	نتیجه
بایبوزا <sup>۶</sup> (۲۰۱۸)	با الگوی یادگیری ماشین و الگوریتم‌های جنگل‌های تصادفی <sup>۱</sup> ، متد LASSO <sup>۲</sup> ، ریدج <sup>۳</sup> ، شبکه الاستیک <sup>۴</sup> و مدل‌های بوستینگ <sup>۵</sup> استفاده کرده و تورم روسیه را پیش‌بینی کردند.	الگوریتم بوستینگ و جنگل‌های تصادفی به مراتب از سایر روش‌ها، عملکرد بهتری را از خود نشان می‌دهد.
بائو و می <sup>۷</sup> (۲۰۱۹)	شاخص سهام ویتنام را با استفاده از الگوهای ترکیبی ARIMA-ANN پیش‌بینی کردند.	مدل‌های ترکیبی پیش‌بینی دقیق‌تری در مقایسه با مدل‌های شبکه عصبی و اتورگرسیو میانگین متحرک به‌طور مجزا ارائه می‌دهند.
پیرانو و دیگران <sup>۱۳</sup> (۲۰۲۱)	این مطالعه پیشنهاد می‌کند نرخ تورم در پنج اقتصاد نوظهور آمریکای لاتین براساس رویکرد SARIMA <sup>۸</sup> همراه با LSTM <sup>۹</sup> پیش‌بینی شود. پیش‌بینی‌های مبتنی بر سیستم‌های استنتاج فازی (FIS) <sup>۱۰</sup> ، شبکه‌های عصبی مصنوعی (ANFIS) <sup>۱۱</sup> ، SARIMA و ANN <sup>۱۲</sup> به‌عنوان معیارهایی برای مقایسه عملکرد الگوی ترکیبی SARIMA-LSTM اتخاذ می‌شود. ترکیبی SARIMA-LSTM جنبه‌های خطی سری زمانی و جنبه‌های غیرخطی را داراست.	الگوی پیشنهادی مبتنی بر ترکیب SARIMA و LSTM، دقت بالاتری در پیش‌بینی تورم را داراست.

منبع: یافته‌های پژوهش

1. Random forests
2. Least Absolute Shrinkage and Selection Operator
3. Ridge regression
4. Elastic net
5. Boosting
6. Baybuza, I.
7. Bao, T. Q. & My, B. T. T.
8. Seasonal ARIMA
9. Long Short-Term Memory
10. Fuzzy Inference System
11. Adaptive Neuro-Fuzzy Inference System
12. Artificial Neural Network
13. Peirano, R., et al.

همان‌طور که در مطالعات پیشین نیز اشاره شد بیشتر پژوهش‌ها معطوف به ترکیب الگوهای ARIMA با الگوهای غیرخطی هوش مصنوعی بوده است، اما در این پژوهش در الگوی ترکیبی در بخش خطی از یک الگوی ساختاری خطی (ARDL) و در بخش غیرخطی نیز از الگوی غیرخطی (LSTM)، استفاده شده است.

### ۳. ادبیات موضوع

تورم عبارت است از رشد شاخص قیمت‌ها. از آنجا که شاخص قیمت‌ها گروه وسیعی از کالاها را شامل می‌شود در محاسبه تورم، نخست متوسط تغییر قیمت کالاها در کل اقتصاد مورد نظر است و دوم، رشد قیمت هر کالا با یک وزن مناسب در محاسبه رشد شاخص مذکور لحاظ می‌شود. پس تورم رشد مستمر و همه‌گیر قیمت کالاها و خدمات است؛ یعنی در صورتی به افزایش قیمت‌ها تورم اطلاق می‌شود که این افزایش مربوط به همه کالا یا اکثر آن‌ها باشد و مستمر (یک‌دفعه و مقطعی نبوده) باشد. ماهیت تورم یک ماهیت پویا بوده، اما افزایش یک‌دفعه‌ای قیمت‌ها ماهیت ایستا است (Romer, 2018)، در تعاریف دیگر از تورم به افزایش متوسط کالاها و خدمات برحسب پول اشاره شده است و پی بردن به رفتار تورم را منوط بر تحلیل بازار پول عنوان می‌دارند.

طبق نظر کلاسیک‌ها و مکتب پولیون، تورم از طریق جاذبه تقاضا<sup>۱</sup> و بر اثر رشد پول اسمی ایجاد می‌شود. در این نگرش تورم فقط از طریق حجم پول در جریان و افزایش تقاضا ایجاد می‌شود. فریدمن<sup>۲</sup> تورم را یک پدیده پولی عنوان می‌دارد. وی برای ادعای خود از روش تجربه متقابل<sup>۳</sup> استفاده کرد و نشان داد که افزایش انباره پول دلیل تورم بوده است. همچنین سیاست مالی اگر از طریق پولی کردن کسری بودجه توسط بانک مرکزی تامین شود به تناسب افزایش حجم پول موجب تورم می‌شود. برخی نظرات در مورد تورم مربوط به هزینه‌های تولید یا به اصطلاح تورم مبتنی بر فشار هزینه<sup>۴</sup> است؛ افزایش قیمت

- 
1. Demand Pull Inflation
  2. Friedman, M.
  3. Counter Factual Approach
  4. Cost Push Inflation

نهادها به صورت افزایش هزینه تولید از طریق انتقال منحنی عرضه کل به سمت بالا و چپ موجب تورم (رکود تورمی)<sup>۱</sup> می‌شود.

ساختارگرایان<sup>۲</sup> در عین حال که نقش پول در تورم را می‌پذیرند برای فشار هزینه‌ها و تشکیل تورم نیز نقش قائل بوده و معتقدند برای شناخت صحیح تورم باید به عوامل ساختاری و نهادی هم توجه شود و تعامل این عوامل با عوامل پولی و هزینه‌ای را نیز در نظر گرفت. از دید ساختارگرایان تورم نتیجه تضاد توزیعی<sup>۳</sup> است. عمده طرفداران نظریه مقداری پول<sup>۴</sup> و پولیون جدید با فرض برون‌زا بودن، پول را علت تورم دانسته و جریان علیت را از پول به تورم مطرح کردند؛ عده‌ای مخالف برون‌زا بودن پول بوده و رابطه علت و معلول بودن پول و تورم را نامشخص می‌دانند، اما فریدمن و شوارتز<sup>۵</sup> اذعان می‌کنند که پول فعال و برون‌زاست، در شرایط رونق اقتصادی قیمت‌ها رو به افزایش است و سود انتظاری و آینده بازار کسب و کار ارتقا پیدا کرده است، بانک‌ها به پرداخت وام مشغول بوده و بانک مرکزی نیز ذخایر را تامین می‌کند که موجب افزایش پول پر قدرت می‌شود؛ یعنی پول به صورت منفعل نسبت به مقتضیات اقتصاد از جمله تورم عکس‌العمل نشان می‌دهد (شاکری، ۱۳۸۹).

طبق مبانی نظری مطرح شده از رشد ماهانه بدهی دولت به بانک مرکزی (طبق مبانی نظری مربوط به فشار جاذبه سمت تقاضا و نظریه مقداری پول)، رشد نرخ ارز (طبق نظریه فشار هزینه<sup>۶</sup> و تورم انتظاری<sup>۷</sup>)، رشد حجم نقدینگی ماهانه (طبق مبانی نظری مربوط به فشار جذب سمت تقاضا و نظریه مقداری پول)، وقفه‌های تورم (طبق نظریه تورم انتظاری) و رشد درآمد ناخالص داخلی (طبق نظریه فشار هزینه) به عنوان متغیرهای توضیحی استفاده می‌شود.

- 
1. Stagflation
  2. Structural and Institutional Factors
  3. Distributional Conflicts
  4. Quantity Theory of Money
  5. Schwartz, A.
  6. Cost Push Inflation
  7. Expected inflation

در این پژوهش، علاوه بر توجه به مبانی نظری مربوط به سری‌های زمانی از تئوری‌های اقتصاد کلان برای پیش‌بینی تورم استفاده می‌شود که باعث بنیادی بودن پیش‌بینی الگوهای این مقاله نیز خواهد شد.

### ۳-۱. الگوهای پیش‌بینی در اقتصادسنجی

در ادبیات اقتصادسنجی نخستین رهیافتی که برای پیش‌بینی نرخ تورم مورد استفاده قرار گرفت، الگوهای غیرساختاری است که در قالب معادلات تفاضلی خطی ساده در دهه ۱۹۲۰ ارائه شد. این الگوها چهارچوب قوی مناسبی برای مدل‌سازی و پیش‌بینی گسترده و وسیع از متغیرهای اقتصادی را فراهم آوردند؛ به این ترتیب نسل جدیدی از مدل‌های سری زمانی به نام ARMA<sup>۱</sup> به دایره الگوهای غیرساختاری پیش‌بینی اضافه شد. بعد از آن برای پیش‌بینی تورم از سیستم معادلات همزمان<sup>۲</sup> در سال ۱۹۵۵ استفاده شد (Klein & Goldberger, 1955). در اواخر دهه ۱۹۷۰ میلادی با نقد لوکاس<sup>۳</sup> در سال ۱۹۷۶ بر سیستم معادلات همزمان، پیش‌بینی مبتنی بر الگوهای ساختاری کینزی تضعیف و رو به افول نهاد (Lucas, 1976). در پاسخ به انتقاد وارده بر الگوهای ساختاری، دو نگرش پدیدار شد؛ در واکنش اول تلاش شد سیستم معادلات هم‌زمان را به نحوی ارتقا داد که دقت پیش‌بینی آن ارتقا یابد؛ به این صورت که تلاش شد تا فرضیه انتظارات عقلایی<sup>۴</sup> را وارد سیستم معادلات هم‌زمان کنند و در واکنش دوم توسعه الگوهای غیرخطی هدف قرار گرفت. همچنین در سال ۱۹۸۰ توسعه گسترده الگوهای اقتصادسنجی به الگوهای VAR منتهی شد؛ این الگوها عموماً به عنوان جایگزین سیستم معادلات هم‌زمان معرفی می‌شدند (آقایان و دیگران، ۱۳۹۷).

در بسیاری از الگوهای اقتصاد کلان تاثیر سیاست‌های اقتصادی با تاخیرهای قابل توجهی همراه هستند؛ به عنوان مثال، سیاست‌های پولی انبساطی بر نرخ تورم با تاخیر ظاهر می‌شود. در اقتصادسنجی الگوهایی که برای بررسی اثرات تاخیری ارائه می‌شوند، معروف به الگوهای ARDL هستند (Pesaran & Shin, 1995).

- 
1. Autoregressive Moving Average
  2. Simultaneous Equations models
  3. Lucas Critique
  4. Rational Expectations

### ۲-۳. الگوهای پیش‌بینی در هوش مصنوعی

مک کولوج و پیتس<sup>۱</sup> (۱۹۴۳) و روزنبلات<sup>۲</sup> (۱۹۵۸) اولین بار ساختار سیستم شبکه عصبی مصنوعی را که برگرفته از عملکرد سیستم عصبی بدن است، معرفی کردند. شبکه عصبی مصنوعی در پیش‌بینی متغیرهای اقتصادی رویکردی جدیدی به شمار می‌رود، اما شواهد مختلف بسیاری از کارایی قابل قبول آن حکایت دارد. در واقع بعد از شکل‌گیری و تکامل این الگوها، شبکه‌های عصبی به‌عنوان ابزاری قدرتمند در خدمت سایر علوم از جمله علم اقتصاد درآمدند و هم‌اکنون از این الگوها در زمینه پیش‌بینی متغیرهای اساسی اقتصاد از جمله تورم، رشد اقتصادی، شاخص کل سهام بورس، مالیات و... استفاده می‌شود.

الگوهای مربوط به حوزه هوش مصنوعی با استفاده از بهینه‌یابی روی وزندهی متغیرها و با استفاده از الگوهای شبکه عصبی که براساس محاسبات روی داده‌های عددی قادر هستند قوانین کلی را فراگیرند، به همین دلیل توانایی خارق‌العاده‌ای در تبیین و پیش‌بینی سری‌های زمانی را دارا هستند و هرچه داده‌های وسیع‌تر و بیشتری از متغیرها موجود باشد، کارایی این الگو نیز بیشتر می‌شود. برخی از انواع الگوهای شبکه عصبی مصنوعی علاوه به بهینه‌یابی اوزان داده‌های ورودی می‌توانند مشکل شکست‌های ساختاری را حل کنند (Vapnik, 2013). با توجه به ماهیت غیرخطی روابط بین ویژگی‌های اقتصاد کلان و تورم، علاقه به استفاده از الگوهای غیرخطی افزایش یافته است و الگوهایی که از شبکه‌های عصبی مصنوعی ساخته شده‌اند به دلیل سازگاری، غیرخطی و فارغ بودن از انواع توزیع‌های آماری (ناپارامتریک بودن) مورد استقبال قرار گرفته‌اند (Šestanović & Arnerić, 2021; Xu, et al., 2019).

الگوی NARX، شبکه‌های عصبی با تاخیر زمانی نام دارند که به راحتی می‌توان آن‌ها را به شبکه‌های عصبی بازگشتی ساده با برگشت دادن خروجی‌های نرون‌های لایه پنهان و خروجی به لایه ورودی تبدیل کرد (Bengio, et al., 1994). این گونه شبکه‌ها معمولاً به وسیله الگوریتم‌های پس انتشار خطا براساس گرادینان کاهشی<sup>۳</sup> آموزش می‌بینند، اما آموزش این شبکه‌ها، هنگامی که وابستگی‌های بلندمدت زمانی بین ورودی‌ها و

1. McCulloch, W. & Pitts, W.

2. Rosenblatt, F.

3. Gradient Descent

خروجی‌های وجود دارد، بسیار مشکل است (Lin, et al., 1998). بردار ورودی این شبکه‌ها دارای دو خط تاخیر زمانی است: ۱- تاخیر زمانی برای تمام ورودی‌ها، ۲- تاخیر زمانی برای خروجی‌های شبکه (Leontaritis & Billings, 1985).

الگوهای LSTM دارای گره‌های بازگشتی هستند؛ یعنی ویژگی‌های استخراج شده از وقفه‌های خیلی دور از طریق نرون‌های قبلی به عنوان بخشی از داده‌های ورودی به شبکه مخابره می‌شود؛ با این اقدام، مشکلاتی که شبکه‌های عصبی بازگشتی در داده‌های آموزش، تایید و آزمایش با آن مواجه بودند، رفع می‌شود (Greff, et al., 2016). الگوهای LSTM به عنوان الگوهای کارا و قابل مقایسه و برای حل مشکل یادگیری سیستم و همچنین حل مشکل وقفه‌های دور که در الگوها، عموماً ضریب پایین‌تری دریافت می‌کنند، ساخته شدند.

شواهد نشان می‌دهد که در شبکه عصبی بازگشتی ساده دچار تورش در نقطه بهینه گرادیان و همچنین به میزان زیادی دچار مشکل، توجه بیشتر به داده‌های آموزش<sup>۱</sup> می‌شود که LSTM کمتر دچار این مشکلات است. رنج اطلاعاتی<sup>۲</sup> که شبکه عصبی بازگشتی در عمل با آن مواجه می‌شود در LSTM محدود است، چون تاثیر یک ورودی داده شده روی لایه‌های مخفی و در نتیجه روی خروجی شبکه، ده‌ها برابر یا به صورت توانی در چرخه‌های بازگشتی شبکه افزایش می‌یابد (Hochreiter, S, 1991; Hochreiter, et al., 2001).

در این پژوهش از محبوب‌ترین الگوی LSTM (Vanilla) استفاده شده است که به وسیله آن می‌توان تغییرات اجزای معماری شبکه را به خوبی مشخص و آثار مختلف آن را مقایسه کرد؛ این الگو اولین بار توسط گریوز و اشمیتهابر<sup>۳</sup> در سال ۲۰۰۵ ارائه شد.

### ۳-۳. الگوهای پیش‌بینی ترکیبی

آگاهی از خصوصیات و تبیین صحیح رفتار سری‌های زمانی کار بسیار پیچیده و دشواری است و برای افزایش عملکرد پیش‌بینی ناگزیر باید از روش‌های ترکیبی استفاده کرد.

---

1. Overfit  
2. Turture Data  
3. Graves, A. & Schmidhuber, J.

الگوهای ترکیبی؛ عملی، اقتصادی و مفید هستند و بدون شک عملکرد بهتری نسبت به الگوهای انفرادی دارند (Clemen, 1989; Timmermann, 2006). اگر مجموع اوزان مربوط به پیش‌بینی الگوی ترکیبی برابر یک فرض شود در آن صورت دو ترکیب وزن به ترتیب  $w$  و  $(1-w)$  برای الگوهای اول و دوم برقرار است که خطای الگوی ترکیبی طبق رابطه (۱) است:

$$e^c = y - w\hat{y}_1 - (1-w)\hat{y}_2 \quad (1)$$

که به شکل کلی به صورت رابطه (۲) است:

$$e^c = we_1 - (1-w)e_2 \quad (2)$$

در نتیجه واریانس خطای الگوی ترکیبی به صورت رابطه (۳) خواهد بود.

$$\sigma_c^2(w) = w^2\sigma_1^2 - (1-w)\sigma_2^2 + 2w(1-w)\sigma_{12} \quad (3)$$

در رابطه (۳) واریانس خطاها به ترتیب  $\sigma_1^2$ ،  $\sigma_2^2$  و  $\sigma_{12}$  کوواریانس بین خطاها است. برای کمینه کردن میزان واریانس طبق فرض می‌توان میانگین مربع خطا را کمینه کرد و با مشتق گرفتن از رابطه (۳) نسبت به  $w$  و برابر صفر قرار دادن آن، اوزان بهینه را به دست آورد (رابطه (۴) و (۵)):

$$w^* = \frac{\sigma_2^2 - \sigma_{12}}{\sigma_1^2 + \sigma_2^2 - 2\sigma_{12}} \quad (4)$$

$$1 - w^* = \frac{\sigma_1^2 - \sigma_{12}}{\sigma_1^2 + \sigma_2^2 - 2\sigma_{12}} \quad (5)$$

طبق رابطه‌های (۴) و (۵) می‌توان گفت که وزن بیشتر به الگویی اختصاص دارد که پیش‌بینی دقیق‌تری را داراست. بنابراین، الگوهای ترکیبی می‌تواند نتایج خوبی را داشته باشد. این در حالی است که افزایش ترکیب الگوها به تعداد سه و بالاتر موجب پیچیدگی



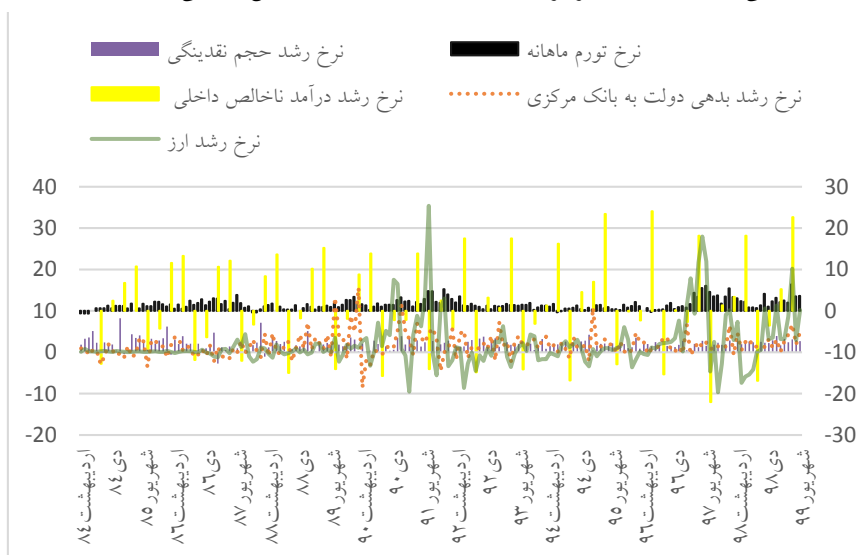
مساله بالا شده و لزوما می تواند موجب افزایش دقت الگو نشود ( Babu & Reddy, 2015).

با توجه به پویایی و استفاده از متغیرهای برونزا در الگوی خطی ARDL و همچنین ویژگی های منحصر به فرد الگوی LSTM در برآورد غیرخطی و به دلیل کارا تر بودن الگوهای ترکیبی در پیش بینی سری های زمانی، این مقاله از هر سه نقطه قوت استفاده کرده و الگوی ترکیبی ARDL-D-LSTM ارائه می دهد.

#### ۴. پایه های آماری و روش شناسی الگوها

بعد از بررسی نماگرهای اقتصادی بانک مرکزی، موارد مربوط به نرخ تورم ماهانه مصرف کنندگان، نرخ رشد حجم نقدینگی ماهانه، نرخ رشد قیمت ارز ماهانه، نرخ رشد بدهی دولت به بانک مرکزی ماهانه و رشد درآمد ناخالص داخلی در بازه فروردین ۱۳۸۴ تا شهریور ۱۳۹۹ به دست آمد که در نمودار (۱) به بررسی آن پرداخته شده است. همچنین بعد از الگوسازی برای به دست آوردن نتایج پژوهش از آنها استفاده شده است.

نمودار ۱. نرخ تورم ماهانه، نرخ رشد حجم نقدینگی ماهانه، نرخ رشد ارز ماهانه، نرخ رشد بدهی دولت به بانک مرکزی ماهانه و رشد درآمد ناخالص داخلی به درصد



ماخذ: نماگرهای بانک مرکزی

#### ۴-۱. الگوی ARDL-D

روش ARDL-D توسط پسران و شین<sup>۱</sup> (۱۹۹۵) و پسران و دیگران<sup>۲</sup> (۲۰۰۱) با عنوان رویکرد وقفه‌های توزیعی خودرگرسیون معرفی شد که فرم متغیرهای وقفه به صورت رابطه (۶) است (عباسی نژاد و گودرزی، ۱۳۹۲).

$$Y_t = \frac{\mu}{1-\gamma_1-\gamma_2-\dots-\gamma_p} + \sum_{i=0}^{\infty} \beta_j X_{t-j} + \sum_{i=0}^{\infty} \theta_j u_{t-j} \quad (6)$$

همچنین الگوی ARDL (1,1) مشابه الگو به وقفه‌های توزیعی نامحدود است که وقفه عقلایی<sup>۳</sup> نامیده می‌شود (Jorgenson, 1996).

شکل کلی الگوی ARDL در نظر گرفته شده در این پژوهش به صورت رابطه (۷) است.

$$\begin{aligned} \text{inf}_t = c + \sum_{j=1}^p \gamma_j \text{inf}_{t-j} + \sum_{j=1}^q \beta_j \text{rm}_{t-j} + \sum_{j=1}^m \mu_j \text{rex}_{t-j} + \sum_{j=1}^n \theta_j \text{rdeb}_{t-j} \\ + \sum_{i=1}^n \theta_j \text{rgdp}_{t-j} + \zeta_1 D_{t-1}^+ + \zeta_2 D_{t-1}^- + u_t \end{aligned} \quad (7)$$

متغیرهای رابطه (۷) عبارتند از:  $\text{inf}_t$  نرخ تورم ماهانه در زمان  $t$ ،  $\text{inf}_{t-j}$  وقفه نرخ تورم ماهانه (انتظارات تورمی)،  $\text{rm}_{t-j}$  وقفه‌های رشد حجم نقدینگی ماهانه،  $\text{rex}_{t-j}$  وقفه‌های رشد نرخ ارز ماهانه،  $\text{rdeb}_{t-j}$  وقفه‌های رشد بدهی دولت به بانک مرکزی،  $\text{rgdp}_{t-j}$  رشد درآمد ناخالص داخلی،  $D_{t-1}^+$  متغیر مجازی به دست آمده از فیلتر هدریک-پرسکات<sup>۴</sup> مربوط به پرش‌های مثبت بیش از میانگین در پرش از نقطه تعادل در وقفه دوره  $t-1$ ،  $D_{t-1}^-$

- 
1. Pesaran, M. H. & Shin, Y.
  2. Pesaran, H. M. et al.
  3. Rational Lag Model
  4. Hodrick-Prescott (HP) filter

متغیر مجازی به دست آمده از فیلتر هدریک- پرسکات مربوط به پرش های منفی بیش از میانگین در پرش از نقطه تعادل در وقفه دوره  $t-1$ .


### ۲-۴. الگوی NARX

الگوی NARX، جزء دسته سیستم های غیرخطی ناپیوسته زمانی است که به صورت ریاضی به صورت رابطه (۸) نمایش داده می شود (Hornik, 1993).

$$\text{inf}_t = f[\text{inf}_{t-1}, \dots, \text{inf}_{t-j}; (\text{rm}_{t-1}, \dots, \text{rm}_{t-j}), (\text{rex}_{t-1}, \dots, \text{rex}_{t-j}), (\text{rdeb}_{t-1}, \dots, \text{rdeb}_{t-j}), (\text{rdeb}_{t-1}, \dots, \text{rdeb}_{t-j}), (\text{rgdp}_{t-1}, \dots, \text{rgdp}_{t-j})] \quad (8)$$

معماری یک شبکه عصبی پیش خور و پس خور در قالب الگوی شبکه عصبی به صورت شکل (۱) قابل ارائه است.

شکل ۱. معماری الگوی پیش خور و پس خور در شبکه عصبی مصنوعی




ماخذ: Kim & Seo, 2015

### ۳-۴. الگوی روش شبکه عصبی مصنوعی بازگشتی عمیق LSTM

ساختار شبکه عصبی مصنوعی بازگشتی عمیق از نوع LSTM وانیلا<sup>۱</sup> در شکل (۲) نشان داده شده است.

شکل ۲. معماری الگوی LSTM وانیلا



ماخذ: Greff, et al., 2016

برخلاف الگوهای شبکه عصبی بازگشتی که ساختار ساده‌ای دارند الگوی LSTM دارای ساختار پیچیده‌تر و دارای بلوک‌های متفاوتی است که ورود و خروج داده‌ها به نوعی که در شکل (۲) و رابطه (۹) نشان داده شده است قابل تبیین است:

$$\left\{ \begin{array}{l} \text{Block input unit: } z^t = g(W_z X^t + R_z Y^{t-1} + b_z) \\ \text{Input gate unit: } i^t = \sigma(W_i X^t + R_i Y^{t-1} + b_i) \\ \text{Forget gate unit: } f^t = \sigma(W_f X^t + R_f Y^{t-1} + b_f) \\ \text{Cell state unit: } c^t = i^t \odot z^t + f^t \odot c^{t-1} \\ \text{Output gate unit: } o^t = \sigma(W_o X^t + R_o Y^{t-1} + b_o) \\ \text{Block output unit: } Y^t = (o^t \odot h(c^t)) \end{array} \right. \quad (9)$$

1. Vanilla

متغیرها در رابطه (۹) به این شرح است:  $\sigma, g, h$  زیگموئید لجستیک است،  $W$  ماتریس‌های اوزان ورودی،  $x$  گام ورودی جاری،  $R$  ماتریس‌های اوزان از خروجی گام قبلی،  $b$  بردارهای بایاس،  $i$  پارامترهای گیت ورودی،  $\odot$  ضرب نقطه‌ای دو بردار،  $f$  پارامترهای گیت فراموشی،  $c^{t-1}$  وضعیت سلول از گام قبلی،  $0$  پارامترهای گیت خروجی و  $C$  پارامتر وضعیت سلول است.

#### ۴-۴. الگوی ARDL-D-LSTM

همانند آن چیزی که در الگوهای ترکیبی ARIMA-ANN به روش ژانگ<sup>۱</sup> (۲۰۰۳) مطرح است، ابتدا قسمت خطی بر اساس الگوی ARDL به صورت رابطه (۱۰) برآورد می‌شود.

$$(\text{inf}_t)_L = c + \sum_{j=1}^p \gamma_j \text{inf}_{t-j} + \sum_{i=1}^q \beta_i r_{m_{t-j}} + u_t \quad (10)$$

حال اگر اختلاف حاصل از تفاضل داده‌های اصلی از پیش‌بینی خطی محاسبه شود، می‌توان آن را به روش غیرخطی LSTM برآورد کرد (رابطه‌های (۱۱) و (۱۲)).

$$u_t = \text{inf}_t - (\text{inf}_t)_L \quad (11)$$

$$(\text{inf}_t)_N = f(u_t, u_{t-1}, \dots, u_{t-A}) + \gamma_t \quad (12)$$

همان‌طور که در رابطه‌های (۱۱) و (۱۲) نشان داده شده است در این روش اجزای اخلاص الگوی خطی ARDL-D به روش غیرخطی LSTM برآورد می‌شود و بعد از آن طبق رابطه (۱۳) به مقدار پیش‌بینی شده در قسمت خطی اضافه خواهد شد و در نهایت طبق رابطه (۱۴) خطای الگوی ترکیبی ARDL-D-LSTM به دست می‌آید که می‌توان با استفاده از شاخص RMSE<sup>۲</sup> عملکرد آن را مورد سنجش قرار داد.

1. Zhang, G.

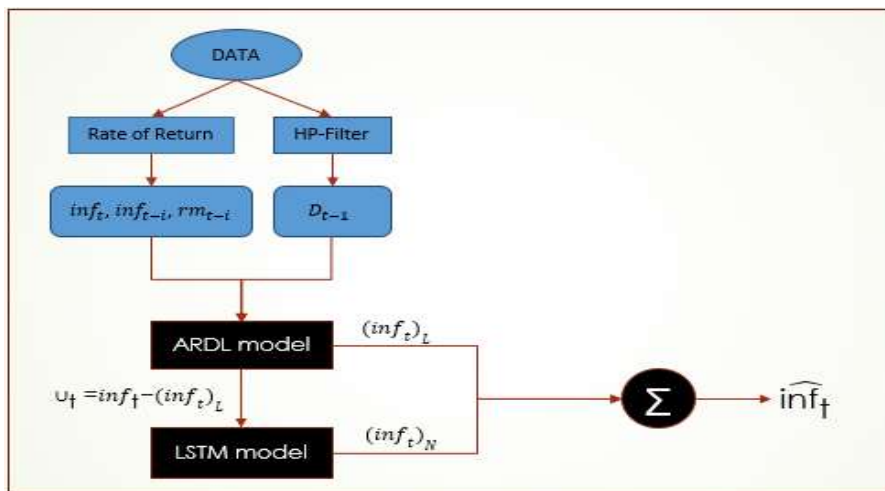
2. Root Mean Square Error =  $\sqrt{\frac{\sum_{i=1}^n (Y_i - \hat{Y}_i)^2}{n}}$

$$\widehat{\text{inf}}_t = (\widehat{\text{inf}}_t)_L + (\widehat{\text{inf}}_t)_N \quad (13)$$

$$e = \text{inf}_t - \widehat{\text{inf}}_t \quad (14)$$

معماری این الگو در شکل (۳) نشان داده شده است.

شکل ۳. معماری الگوی ARDL-D-LSTM



ماخذ: یافته‌های پژوهش

## ۵. برآورد الگوها

در این قسمت به برآورد و تجزیه و تحلیل الگوها پرداخته می‌شود. در ابتدا الگوهای انفرادی خطی و غیرخطی و سپس به الگوی ترکیبی پرداخته خواهد شد.

### ۵-۱. تجزیه و تحلیل ARDL-D

در جدول (۲) حاصل تخمین الگوی ARDL-D آورده شده است که روش انتخاب الگو به وسیله معیار آکائیک<sup>۱</sup> (تعداد داده‌ها ۱۵۴ ماه) بوده است<sup>۲</sup>. برآورد تخمین از آبان ۱۳۸۴

#### 1. Akaike criterion

۲. قبل از برآورد الگوی ARDL باید وضعیت مانایی متغیرهای توضیحی و وابسته الگو را مورد بررسی قرار داد؛ آزمون ریشه واحد روی نرخ تورم به عنوان متغیر وابسته، رشد حجم نقدینگی، رشد نرخ ارز، رشد بدهی دولت به بانک

تا مرداد ۱۳۹۷ بوده است که از شهریور ۱۳۹۷ تا شهریور ۱۳۹۹ نیز جز داده‌های آزمایش این پژوهش در تمام الگوها در نظر گرفته شده است. الگو به صورت خودکار برآورد شده و طبق آماره آکائیک بهترین برآورد  $ARDL(6,6,4,1)$  است.

جدول ۲. جدول برآورد الگوی  $ARDL$  و آماره‌های آن

متغیر	ضرایب	انحراف معیار	آزمون (t)	احتمال
inf(-1)	۰/۴۱	۰/۰۶	۶/۸۷	۰۰
inf(-6)	۰/۲۶	۰/۰۶	۴/۳	۰۰
rm(-2)	-۰/۰۷۵	۰/۰۴	-۲/۰	۰/۰۵
rm(-4)	-۰/۰۸۴	۰/۰۳۷	-۲/۲۴	۰/۰۲
rm(-6)	۰/۰۹	۰/۰۳۷	۲/۴۷	۰/۰۱
rex(-1)	۰/۰۶۶	۰/۰۱۲	۵/۴	۰۰
rex(-4)	۰/۰۵	۰/۰۱	۳/۹۸	۰۰
$D^+$	-۰/۵۵	۰/۱۶	-۳/۳	۰۰
C	۰/۵۴	۰/۱۷	۳/۰۴	۰/۰۰۲
R-squared	۰/۶۱	Akaike info criterion		۲/۱
Adjusted R-squared	۰/۶۰	Schwarz criterion		۲/۳
Log likelihood	-۱۵۴	Hannan-Quinn criter.		۲/۲

ماخذ: یافته‌های پژوهش

در الگوی  $ARDL-D$  از نرخ رشد ارز و نرخ رشد درآمد ناخالص داخلی به عنوان متغیرهای بخش عرضه و از نرخ رشد نقدینگی و نرخ رشد بدهی دولت به بانک مرکزی به عنوان متغیرهای بخش تقاضا استفاده شد. بعد از برآورد اثرات کوتاه‌مدت متغیرهای مستقل الگو بر نرخ تورم، معنادار بودن ضرایب هر یک از متغیرهای الگو بررسی شد.

مرکزی و رشد درآمد ناخالص داخلی به عنوان متغیرهای توضیحی انجام شده است. متغیرها در تمام سطوح احتمالی و تمام حالت‌های با عرض از مبدا، با عرض از مبدا و روند، بدون عرض از مبدا و روند مانا هستند؛ یعنی شرایط برآورد الگوی  $ARDL$  که  $I(0)$  یا حداکثر  $I(1)$  بودن متغیرهای الگو فراهم است.

۱. آزمون جارک-برا (Jarque-Bera Test) یا آزمون نرمال بودن برابر با  $۳/۹$  با سطح احتمال  $۰/۱۴$  بوده که نشان از نرمال بودن اجزای اخلال است.

همانطور که در جدول (۲) نیز مشخص است برخی متغیرها با حفظ ساختار الگو از آن خارج شدند. همچنین با توجه به اثرگذاری معنادار وقفه‌های نرخ تورم، نرخ رشد نقدینگی و نرخ رشد ارز بر تورم ماهانه ایران می‌توان گفت که نظریات تورم انتظاری، تورم جاذبه تقاضا و فشار هزینه ویژگی‌های مناسبی از رفتار تورمی کشور را مخابره می‌کنند که برای افزایش صحت پیش‌بینی نرخ تورم می‌توان از آن‌ها استفاده کرد. همچنین متغیر مجازی در پرش‌های بیش از اندازه و مثبت دارای آماره  $t$  معنی‌دار بوده و می‌تواند الگو را در تفسیر مناسب‌تر هدایت کند. خوبی برازش الگو نیز تقریباً ۶۰ درصد است که مقدار قابل قبولی تلقی می‌شود.<sup>۱</sup>


در تحلیل آماره CUSUM اگر این شاخص از خط صفر خیلی دور باشد، دلیلی بر عدم وجود پایداری ساختاری در الگو است که این آزمون توسط براون و دیگران<sup>۲</sup> در سال (۱۹۷۵) پیشنهاد شده است. اگر CUSUM خط  $\pm 0.948 \left[ \sqrt{T-k} + \frac{2(\Gamma-k)}{\sqrt{T-k}} \right]$  را قطع کند، پایداری الگو در سطح معنی‌دار ۵ درصد رد می‌شود (Granger & Terasvirta, 1993; Krämer, et al., 1988; Krämer & Sonnberger, 1986). طبق  $CUSUM_{\Gamma}$  و  $CUSUM_{SQ}$  و با توجه به اینکه خطوط ناپایداری قطع نشده است، می‌توان گفت که الگو به صورت پایدار برآورد شده است. در نمودار (۱) به این موضوع پرداخته شده است.

۱. اجزای اخلاص دارای توزیع نرمال بوده و برآورد الگو با استفاده از حداقل مربعات معمولی شرایط بهترین تخمین زن خطی و بدون تورش (BLUE) را داراست و با توجه به آزمون بروش-گادفری (Brush-Godfrey) می‌توان گفت که این الگو عدم خودهمبستگی سریالی را داراست: در رابطه با شناسایی مشکل ناهمسانی نیز در این الگو از آزمون ARCH استفاده شده است که با توجه به بیشتر از سطح احتمال ۵ درصد بودن برای آماره آن می‌توان گفت که الگو ناهمسانی ندارد.

2. Brown, R. L., et al.



### نمودار ۱. $CUSUM_{\Gamma}$ و $CUSUM_{SQ}$ در الگوی ARDL



ماخذ: یافته‌های پژوهش

### ۲-۵. تجزیه و تحلیل LSTM، NARX و ARDL-D-LSTM

با استفاده از آزمون BDS<sup>۱</sup> می‌توان نشان داد که رفتار اجزای اخلال باقی‌مانده در الگو به صورت غیرخطی قابل تبیین است<sup>۲</sup>. همچنین نرمال‌سازی داده‌های ورودی به الگوی LSTM به روش Rescaling<sup>۳</sup> انجام شده که ساده‌ترین روش برای تغییر بازه عددی مقادیر یک مجموعه به  $[0, 1]$  یا  $[-1, 1]$  است<sup>۴</sup>. با توجه به حجم مقاله نتایج این سه الگو در جدول (۳) به طور خلاصه ارائه شده است.

#### 1. Brock-Dechert-Scheinkman Test

۲. طبق آزمون به عمل آمده، نرخ تورم ماهانه ایران در ۲ تا ۶ بعد دارای رفتار معنادار است و سطح احتمال آزمون BDS برای این ابعاد تقریباً صفر به دست آمد. همچنین مقدار آماره Raw epsilon برابر ۱/۷۱ به دست آمد.

#### 3. Min-Max Normalization

$$4. Y_{\text{Norm}} = \frac{Y - \text{Min}(Y)}{\text{Max}(Y) - \text{Min}(Y)}$$

### جدول ۳. بررسی ویژگی‌های الگوهای LSTM، NARX و ARDL-D-LSTM

ARDL-D-LSTM	LSTM	NARX	عنوان
**۱۴۴	۱۵۶	۱۵۶	تعداد داده آموزش
۲۵	۲۵	۲۵	تعداد داده آزمایش
۱۰	۵	۵	تعداد وقفه متغیر وابسته
۸	۲	۱۵	تعداد لایه پنهان اول*
۷	۳	۲۰	تعداد لایه پنهان دوم
Tanh	Tanh	Relu	تابع فعال‌ساز
Adam	Adam	Adam	الگوریتم بهینه‌یابی
MSE	MSE	MSE	تابع هزینه
۲۰۰	۲۰۰	۲۰۰	Epochs
۰/۸۸	۰/۶۸	۰/۷۸	خوبی برآزش

\* تعداد لایه‌های پنهان اول و دوم بعد از آزمون و خطا بین ۱۰ تا ۱۰۰ لایه پنهان و با استفاده از کاهش خطای الگو بر اساس MSE انتخاب شده است  
 \*\* ۱۲ وقفه در الگوی ARDL استفاده شده است.  
 ماخذ: یافته‌های پژوهش

### ۶. نتایج پژوهش

بعد از برآورد و پیش‌بینی تورم ماهانه با استفاده از الگوهای بیان شده باید عملکرد آن‌ها با یکدیگر مقایسه شود. در جدول (۴) با استفاده از معیار RMSE به بررسی عملکرد الگوهای ARDL-D، LSTM، NARX، و ARDL-D-LSTM در افق کوتاه‌مدت (۳ و ۶ ماهه) و بلندمدت (۱۲ و ۲۴ ماهه) پرداخته شده است.

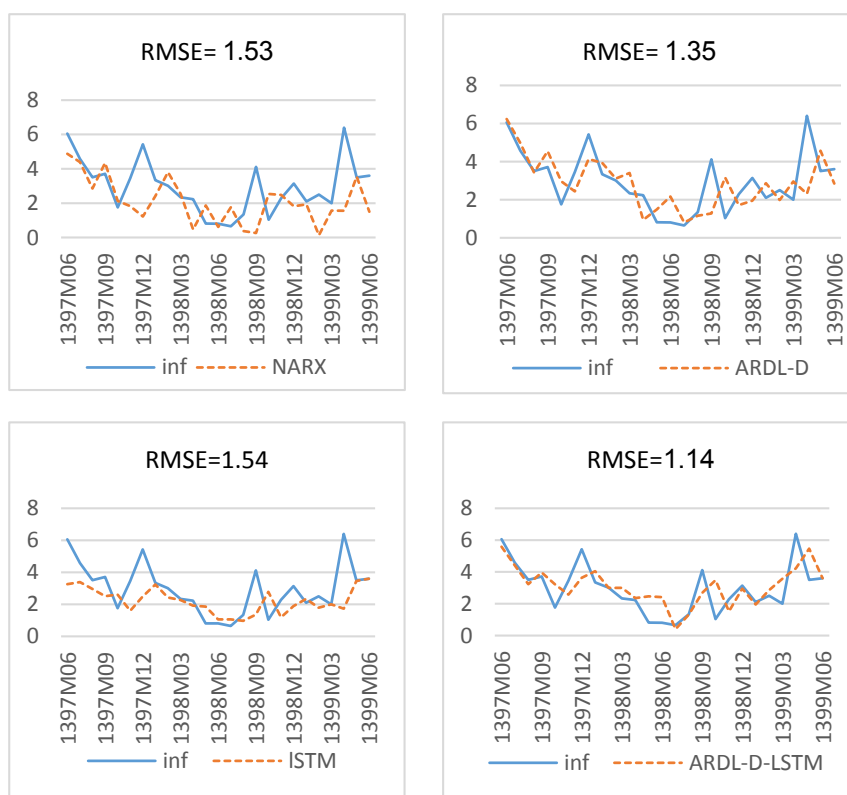
### جدول ۴. جدول مقایسه و رتبه‌بندی عملکرد الگوها بر اساس معیار RMSE

معیار	الگوی ساختاری و انفرادی	الگوی ساختاری و ترکیبی	الگوی ساختاری و انفرادی	الگوی ساختاری و انفرادی
	ARDL-D	ARDL-D-LSTM	NARX	LSTM
تخمین	۰/۶۵	۰/۴۹	*۰/۴۶	۰/۵۳
پیش‌بینی ۳ ماهه	۱/۲	۰/۹	*۰/۴۴	۱/۷۶
پیش‌بینی ۶ ماهه	۱/۳۱	۱/۰۴	*۰/۶۷	۱/۴۶
پیش‌بینی ۱۲ ماهه	۱/۴۳	*۱/۰۱	۱/۳۷	۱/۵۳
پیش‌بینی ۲۴ ماهه	۱/۳۶	*۱/۱۴	۱/۵۳	۱/۵۴

ماخذ: یافته‌های پژوهش

با توجه به جدول (۴) می‌توان گفت که الگوی NARX در افق زمانی کوتاه‌مدت عملکرد خوبی در پیش‌بینی تورم ماهانه ایران و الگوی ARDL-D-LSTM در افق زمانی بلندمدت عملکرد خوبی را داشته است. در نمودار (۲)، اشکال مربوط به داده‌های تست در این مقاله آورده شده که عملکرد الگوی ARDL-D-LSTM در ۲۵ ماه آزمایشی نسبت به سایر الگوهای این پژوهش بهتر است.

نمودار ۲. بررسی سطح خطای الگوهای پژوهش در داده‌های آزمایش (واحد RMSE، درصد)



مآخذ: یافته‌های پژوهش

## ۷. جمع‌بندی و نتیجه‌گیری

همان‌طور که در این مقاله نشان داده شده است رفتار تورم ماهانه ایران یک رفتار غیرخطی بوده و بهتر است که با الگوهای غیرخطی و ترکیبی اقدام به پیش‌بینی تورم کرد. الگوی غیرخطی NARX براساس معیار RMSE در کوتاه‌مدت عملکرد بسیار خوبی را از خود

نشان داد و الگوی ARDL-D-LSTM در بلندمدت توانست عملکرد خوبی را براساس معیار RMSE نشان دهد.

یکی از مهم‌ترین مسائلی که در پیش‌بینی نرخ تورم می‌تواند چاره‌ساز باشد، استفاده از مبانی نظری متغیر تورم است؛ از این رو چهار متغیر: ۱- رشد حجم نقدینگی، ۲- رشد نرخ ارز ماهانه، ۳- رشد بدهی دولت به بانک مرکزی و ۴- رشد درآمد ناخالص داخلی به‌عنوان ویژگی‌های تاثیرگذار در الگو وارد شدند. همان‌طور که مشاهده شد الگوی ARDL و NARX که با استفاده از این متغیرها الگوسازی شده بود یا الگوهای ساختاری ترکیبی دیگر همانند ARDL-D-LSTM توانستند به‌خوبی پیش‌بینی تورم را انجام دهند.

با توجه به عملکرد مناسب الگوی ترکیبی در پیش‌بینی نرخ تورم در این پژوهش به محققین، سیاست‌گذاران اقتصادی و تمام اشخاصی که علاقه‌مند به مطالعه در این حوزه هستند، پیشنهاد می‌شود برای پیش‌بینی نرخ تورم از الگوهای ترکیبی استفاده کنند. برای پیش‌بینی کوتاه‌مدت نرخ تورم در این پژوهش عملکرد الگوی NARX براساس معیار RMSE بسیار خوب بوده است؛ به همین دلیل استفاده از روش‌های غیرخطی هوش مصنوعی در کوتاه‌مدت می‌تواند موثر باشد.

سایر شاخص‌های اقتصادی که دارای نوسانات بسیار زیادی است - به خصوص شاخص‌هایی که مرتبط با بخش سرمایه‌گذاری است، همانند شاخص کل بورس، قیمت دارایی‌ها و پیش‌بینی ریسک - می‌توانند از الگوی ترکیبی ARDL-D-LSTM استفاده کنند. با توجه به انواع الگوهای خطی و غیرخطی و همچنین انواع الگوریتم‌های بهینه‌یابی می‌توان گفت بسیاری از روش‌های ترکیبی با عملکرد بالا همچنان وجود دارد که محققین می‌توانند با استفاده از آن‌ها ادامه این پژوهش را تکمیل کنند.

## تعارض منافع

تعارض منافع وجود ندارد.

## سپاسگزاری

با تشکر از اساتید گرامی، داوران و مجموعه همکاران پژوهش‌های اقتصادی ایران که با راهنمایی‌های خود موجب ارتقا و پیشرفت کار شدند.

## ORCID

Hamed Azizi Ganzagh		<a href="http://orcid.org/0000-0002-3318-1560">http://orcid.org/0000-0002-3318-1560</a>
Ahmad Jafari Samimi		<a href="http://orcid.org/0000-0002-9047-6189">http://orcid.org/0000-0002-9047-6189</a>
Zahra Mila Elmi		<a href="http://orcid.org/0000-0002-2913-7292">http://orcid.org/0000-0002-2913-7292</a>
Amir Mansour Tehranchian		<a href="http://orcid.org/0000-0002-1635-3666">http://orcid.org/0000-0002-1635-3666</a>

## منابع

- آقایان، بهنوش، سادات، بهرامی، جاوید و جهانگرد، اسفندیار. (۱۳۹۷). پیش‌بینی تورم اقتصاد ایران با استفاده از مدل DSGE-VAR (تئوری و تکنیک). *نظریه های کاربردی اقتصاد*، ۵(۲)، ۱۴۹-۱۷۶.
- پور کاظمی، محمد حسین، بیرانوند، امین و دلفان، محبوبه. (۱۳۹۵). تعیین عوامل تاثیر گذار بر تورم و طراحی سیستم هشداردهنده تورم شدید برای اقتصاد ایران. *پژوهشها و سیاستهای اقتصادی*، ۲۳(۷۶)، ۱۴۵-۱۶۶.
- رئوفی، علی و محمدی، تیمور. (۱۳۹۷). پیش‌بینی بازده بازار سهام تهران با استفاده از ترکیب تجزیه موجک و شبکه عصبی فازی تطبیقی. *پژوهشهای اقتصادی ایران*، ۲۳(۷۶)، ۱۳۶-۱۰۷.
- ذوالفقاری، مهدی، سحابی، بهرام و بختیاران، محمدجواد. (۱۳۹۹). طراحی مدلی جهت پیش‌بینی بازده شاخص کل بورس اوراق بهادار (با تاکید بر مدل‌های ترکیبی شبکه یادگیری عمیق و مدل‌های خانواده GARCH). *مهندسی مالی و مدیریت اوراق بهادار*، ۱۱(۴۴)، ۱۳۸-۱۷۱.
- شاکری، عباس. (۱۳۸۹). *اقتصاد کلان، نظریه‌ها و سیاست‌ها*. ج ۲. چ ۳. تهران: انتشارات رافع.
- عباسی‌نژاد، حسین و گودرزی، یزدان. (۱۳۹۲). *اقتصاد سنجی کاربردی با نرم افزار ایویوز و ماکروفیت*، ج ۱. تهران: انتشارات نورعلم.
- محمدی، شاپور، راعی، رضا و رحیمی، محمدرضا. (۱۳۹۷). پیش‌بینی دامنه تغییرات طلا با استفاده از مدل ترکیبی ARIMA و شبکه عصبی. *مهندسی مالی و مدیریت اوراق بهادار*، ۹(۳۴)، ۳۳۵-۳۷۵.

## References

- Aghayan, B. S., Bahrami, J., & Jahangard, E. (2018). Forecasting Iran's economy inflation with DSGE-VAR model (theory and technique). *Quarterly Journal of Applied Theories of Economics*, 5(2), 149-176. [In Persian]
- Babu, C. N., & Reddy, B. E. (2015). Performance comparison of four new ARIMA-ANN prediction models on Internet traffic data. *Journal of Telecommunications and Information Technology*, 1(2), 67-75.

- Bao, T. Q., & My, B. T. T. (2019). Forecasting stock index based on hybrid artificial neural network models. *Science & Technology Development Journal-Economics-Law and Management*, 3(1), 52–57.
- Baybuza, I. (2018). Inflation forecasting using machine learning methods. *Russian Journal of Money and Finance*, 77(4), 42–59.
- Bengio, Y., Simard, P., & Frasconi, P. (1994). Learning long-term dependencies with gradient descent is difficult. *IEEE Transactions on Neural Networks*, 5(2), 157–166.
- Binner, J. M., Tino, P., Tepper, J., Anderson, R., Jones, B., & Kendall, G. (2010). Does money matter in inflation forecasting? *Physica A: Statistical Mechanics and Its Applications*, 389(21), 4793–4808.
- Brown, R. L., Durbin, J., & Evans, J. M. (1975). Techniques for testing the constancy of regression relationships over time. *Journal of the Royal Statistical Society: Series B (Methodological)*, 37(2), 149–163.
- Clemen, R.T. (1989). Combining forecasts: A review and annotated bibliography. *International journal of forecasting*, 5(4), 559-583.
- Estiko, F. I., & Wahyuddin, S. (2019). Analysis of Indonesia's Inflation Using ARIMA and Artificial Neural Network. *Economics Development Analysis Journal*, 8(2), 151–162.
- Graves, A., & Schmidhuber, J. (2005). Frame wise phoneme classification with bidirectional LSTM and other neural network architectures. *Neural networks*, 18(5-6), 602-610.
- Granger, C. W. J., & Terasvirta, T. (1993). Modelling non-linear economic relationships. *OUP Catalogue*.
- Greff, K., Srivastava, R. K., Koutník, J., Steunebrink, B. R., & Schmidhuber, J. (2016). LSTM: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, 28(10), 2222–2232.
- Hanif, M. N., & Malik, M. J. (2015). Evaluating performance of inflation forecasting models of Pakistan, *SBP Research Bulletin*, 11(1).
- Hornik, K. (1993). Some new results on neural network approximation. *Neural Networks*, 6(8), 1069–1072.
- Hochreiter, S. (1991). Untersuchungen zu dynamischen neuronalen Netzen [in German] Diploma thesis. *TU München*.
- Hochreiter, S., Bengio, Y., Frasconi, P., & Schmidhuber, J. (2001). Gradient flow in recurrent nets: the difficulty of learning long-term dependencies.
- Işığışok, E., Öz, R., & Tarkun, S. (2020). Forecasting and Technical Comparison of Inflation in Turkey With Box-Jenkins (ARIMA) Models and the Artificial Neural Network. *International Journal of Energy Optimization and Engineering (IJEEO)*, 9(4), 84–103.

- Jorgenson, D. W. (1966). Rational distributed lag functions. *Econometrica: Journal of the Econometric Society*, 135-149.
- Khashei, M., & Bijari, M. (2011). A novel hybridization of artificial neural networks and ARIMA models for time series forecasting. *Applied Soft Computing*, 11(2), 2664–2675.
- Kim, S. E., & Seo, I. W. (2015). Artificial Neural Network ensemble modeling with conjunctive data clustering for water quality prediction in rivers. *Journal of Hydro-Environment Research*, 9(3), 325–339.
- Klein, L. R., & Goldberger, A. S. (1955). Econometric model of the United States, *Amsterdam: North-Holland Publishing Co*, 66(262) 1929-1952.
- Krämer, W., Ploberger, W., & Alt, R. (1988). Testing for structural change in dynamic models. *Econometrica: Journal of the Econometric Society*, 56(6), 1355–1369.
- Krämer, W., & Sonnberger, H. (1986). Diagnostic checking in practice. In *The Linear Regression Model Under Test* (pp. 123-155). Physica-Verlag HD.
- Kumar, M., & Thenmozhi, M. (2012). Stock index return forecasting and trading strategy using hybrid ARIMA-neural network model. *International Journal of Financial Management*, 2(1), 1-15.
- LeBaron, B. (1994). Chaos and nonlinear forecastability in economics and finance. *Philosophical Transactions of the Royal Society of London. Series A: Physical and Engineering Sciences*, 348(1688), 397–404.
- Leontaritis, I. J., & Billings, S. A. (1985). Input-output parametric models for non-linear systems part I: deterministic non-linear systems. *International Journal of Control*, 41(2), 303–328.
- Lin, T., Horne, B. G., & Giles, C. L. (1998). How embedded memory in recurrent neural network architectures helps learning long-term temporal dependencies. *Neural Networks*, 11(5), 861–868.
- Lucas Jr, R. E. (1976). Econometric policy evaluation: A critique. *Carnegie-Rochester Conference Series on Public Policy*, 1, 19–46.
- McCulloch, W. S., & Pitts, W. (1943). A logical calculus of the ideas immanent in nervous activity. *The Bulletin of Mathematical Biophysics*, 5(4), 115–133.
- McKnight, S., Mihailov, A., & Rumler, F. (2020). Inflation forecasting using the New Keynesian Phillips Curve with a time-varying trend. *Economic Modelling*, 87, 383–393.
- Mohammadi, S., Raeie, R., & Rahimi, M. (2018). Interval forecasting for gold price with hybrid model of ARIMA and ANN.[In Persian]
- Peirano, R., Kristjanpoller, W., & Minutolo, M. C. (2021). Forecasting inflation in Latin American countries using a SARIMA–LSTM combination. *Soft Computing*, 25(16), 10851-10862.

- Pesaran, H. M., Shin, Y., & Smith, R. J. (2001). Bounds testing approaches to the analysis of long-run relationships (Working paper no. 9907). *Cambridge, United Kingdom: Department of Applied Economics, University of Cambridge.*
- Pesaran, M. H., & Shin, Y. (1995). An autoregressive distributed lag modelling approach to cointegration analysis, *Cambridge University Press*, Cambridge, 371-413.
- Pourkazemi, M. H., Biranvand, A., & Delfan, M. (2016). Designing a warning system for hyperinflation for Iran's economy. [In Persian]
- Raofi, A., & Mohammadi, T. (2018). Forecasting Tehran stock exchange index returns using a combination of wavelet decomposition and adaptive neural fuzzy inference systems. *Iranian Journal of Economic Research*, 23(76), 107-136. [In Persian]
- Romer, D. (2018). *Advanced macroeconomics. Mcgraw-hill.*
- Rosenblatt, F. (1958). The perceptron: a probabilistic model for information storage and organization in the brain. *Psychological Review*, 65(6), 386.
- Šestanović, T., & Arnerić, J. (2021). Neural network structure identification in inflation forecasting. *Journal of Forecasting*, 40(1), 62-79.
- Timmermann, A. (2006). Forecast combinations. *Handbook of economic forecasting*, 1, 135-196.
- Vapnik, V. (2013). The nature of statistical learning theory. *Springer science & business media.*
- Xu, Q., Zhuo, X., Jiang, C., & Liu, Y. (2019). An artificial neural network for mixed frequency data. *Expert Systems with Applications*, 118, 127-139.
- Zhang, G. P. (2003). Time series forecasting using a hybrid ARIMA and neural network model. *Neurocomputing*, 50, 159-175.
- Zolfaghari, M., & Sahabi, B. (2020). Designing a model for forecasting the stock exchange total index returns (emphasizing on combined deep learning network models and GARCH family models). [In Persian]

---

**استناد به این مقاله:** عزیزی گنزق، حامد، جعفری صمیمی، احمد، میل‌علمی، زهرا، طهرانچیان، امیرمنصور. (۱۴۰۱). مقایسه الگوهای پیش‌بینی تورم در ایران: شواهد جدید از الگوی ترکیبی ARDL-D-LSTM، پژوهش‌های اقتصادی ایران، ۲۷ (۹۳)، ۱۷۷-۲۰۸.



Iranian Journal of Economic Research is licensed under a Creative Commons Attribution-NonCommercial 4.0 International License.