

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 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.

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

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


- 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


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), 149-176.


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

زهرا میلا 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^۱ و غیرساختاری^۲ تقسیم‌بندی می‌شوند (Peirano, et al., 2021). برای پیش‌بینی تورم الزاما نیازی نیست که همواره کله‌های پولی^۳ محوریت تحلیل‌های تورم قرار گیرد و می‌توان با استفاده از شبکه‌های عصبی مصنوعی^۴ و روش‌های آماری ناپارامتریک^۵ پیش‌بینی مناسب‌تری را انجام داد (Binner, et al., 2010).

در مقاله مک‌نایت و دیگران^۶ (۲۰۲۰) به دو رویکرد در مواجهه با پیش‌بینی تورم پرداخته شده است؛ اولی مربوط به استفاده از تئوری‌های اقتصادی منحنی فیلیپس در مکتب نوکینزین‌ها^۷ (NKPC) و دومی مربوط به استفاده از الگوهای غیرساختاری و خطی خودرگرسیون میانگین متحرک انباشته (ARIMA)^۸ است. با توجه به غیرخطی^۹ 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 کاملا 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^{۱۰}، در بخش الگوی غیرخطی و ساختاری از الگوی خود برازش برون‌زای غیرخطی (NARX)^{۱۱}، از الگوی

-
- 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
 00. Autoregressive Distributed Lag
 11. Nonlinear Autoregressive Network with Exogenous Inputs

حافظه کوتاه‌مدت طولانی^۱ (LSTM) به‌عنوان الگوی غیرخطی و غیرساختاری و از الگوی ARDL-D-LSTM^۲ به‌عنوان الگوی ترکیبی^۳ استفاده شده است. در الگوی ترکیبی هر دو قسمت خطی و غیرخطی پوشش داده می‌شود 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 پیش‌بینی تورم نیز استفاده کرد. در واقع در این پژوهش تنها به روش‌های کمی در الگوهای سری زمانی توجه نشده، بلکه به مبانی نظری تورم و متغیرهای اقتصادی نیز توجه ویژه‌ای شده است.

نکته بسیار مهم در برآورد الگوها این است که از وقفه متغیرها استفاده می‌شود؛ یعنی ویژگی‌های استخراجی از فیلتر هدریک-پرسکات^۴ به‌عنوان متغیر مجازی نیز با وقفه وارد الگو می‌شود. همچنین برای آزمایش داده‌ها بعد از برآورد به صورت پنجره متحرک^۵ در نرم‌افزار^۶ استفاده شده است (تمام ویژگی‌هایی که تا زمان $t-1$ موجود است) و پیش‌بینی‌ها به صورت یک گام رو به جلو برآورد می‌شوند.

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 پیش‌بینی تورم از خود نشان می‌دهند؟

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 می‌شود. در بخش سوم ادبیات نظری پژوهش، در بخش چهارم روش‌شناسی 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.


-
1. Long Short-Term Memory
 2. Hybrid of ARDL and LSTM
 3. Hybrid Models
 4. Hodrick-Prescott Filter
 5. Rolling Window

۶. نرم افزار پایتون (Python).

۲. پیشینه پژوهش

مطالعات بسیاری در مقایسه الگوهای هوش مصنوعی^۱ و اقتصادسنجی در مواجهه با تورم کشورهای در حال توسعه انجام شده است؛ در بررسی تورم ترکیه و با مقایسه دو الگوی ANN^۲ و ARIMA اختلافی بین دو الگو وجود نداشت (Işık et al., 2020). استیکو و وهی یودین^۳ (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 می دهند.

ژانگ^۴ (۲۰۰۳) و خاشعی و بیجاری^۵ (۲۰۱۱) در زمینه پیش بینی 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 می دهد. با توجه به اهمیت الگوهای پیش بینی و با توجه به وسعت الگوها در جدول (۱) به جمع بندی مطالعات در زمینه الگوهای پیش بینی پرداخته شده است.



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

جدول ۱. جمع‌بندی مطالعات انجام شده در بخش الگوهای پیش‌بینی

پژوهش‌های داخلی		
نویسنده	توضیحات	نتیجه
پورکاظمی و دیگران (۱۳۹۴)	به بررسی عوامل تاثیرگذار بر تورم و طراحی یک سیستم هشدار شدید در اقتصاد ایران پرداخته‌اند.	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.
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 ^۱ 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 ^۲ نشان دادند که نوبزگیری 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 ^۳ و یادگیری عمیق ^۴ 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.

1. Diebold - Mariano

۲. آزمون مورگان-گرنجر-نیوبولد

3. Machine Learning

4. Deep Learning

ادامه جدول ۱.

پژوهش‌های خارجی		
نویسنده	توضیحات	نتیجه
کومار و دیگران ^۱ (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 ^۲ (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.
بایوزا ^۳ (۲۰۱۸)	با الگوی یادگیری ماشین و الگوریتم‌های جنگل‌های تصادفی ^۴ ، متد LASSO ^۵ ، ریج ^۶ ، شبکه الاستیک ^۷ و مدل‌های بوستینگ ^۸ استفاده کرده و تورم روسیه را پیش‌بینی کردند.	الگوریتم بوستینگ و جنگل‌های تصادفی به‌مراتب از سایر روش‌ها، عملکرد بهتری را از خود نشان می‌دهند.
باتو و می ^۹ (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 ^{۱۰} (۲۰۲۱)	این مطالعه پیشنهاد می‌کند نرخ تورم در پنج اقتصاد نوظهور آمریکای لاتین براساس رویکرد SARIMA ^{۱۱} همراه با LSTM ^{۱۲} پیش‌بینی شود. پیش‌بینی‌های مبتنی بر سیستم‌های استنتاج فازی (FIS) ^{۱۳} ، شبکه‌های عصبی مصنوعی (ANFIS) ^{۱۴} ، SARIMA و ANN ^{۱۵} به‌عنوان معیارهایی برای مقایسه عملکرد الگوی ترکیبی SARIMA-LSTM اتخاذ می‌شود. SARIMA-LSTM ترکیبی 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. Kumar, M., & Thenmozhi, M.
2. C. Hanif, M. N., & Malik, M. J.
3. Random forests
4. Least Absolute Shrinkage and Selection Operator
5. Ridge regression
6. Elastic net
7. Boosting
8. Baybuza, I.
9. Bao, T. Q. & My, B. T. T.
10. Seasonal ARIMA
11. Long Short-Term Memory
22. Fuzzy Inference System
33. Adaptive Neuro-Fuzzy Inference System
44. Artificial Neural Network
55. 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^۱ 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^۲ تورم را یک پدیده پولی عنوان می‌دارد. وی برای ادعای خود از روش تجربه متقابل^۳ 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^۴ است؛ افزایش قیمت نهاده‌ها به صورت افزایش هزینه تولید از طریق انتقال منحنی عرضه کل به سمت بالا و چپ موجب تورم (رکود تورمی)^۵ می‌شود.

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

ساختارگرایان^۱ 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^۲ است. عمده طرفداران نظریه مقداری پول^۳ 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^۴ 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^۵ و تورم انتظاری^۶)، 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. 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

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

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^۱ به دایره الگوهای غیرساختاری پیش‌بینی اضافه شد. بعد از آن برای پیش‌بینی تورم از سیستم معادلات همزمان^۲ در سال ۱۹۵۵ استفاده شد (Klein & Goldberger, 1955). در اواخر دهه ۱۹۷۰ میلادی با نقد لوکاس^۳ 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^۴ 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 به‌عنوان 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).

۲-۳. الگوهای پیش‌بینی در هوش مصنوعی

مک کولوچ و پیتس^۵ (۱۹۴۳) و روزنبلات^۶ (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

-
1. Autoregressive Moving Average
 2. Simultaneous Equations models
 3. Lucas Critique
 4. Rational Expectations
 5. McCulloch, W. & Pitts, W.
 6. Rosenblatt, F.

اقتصاد در آمدند و هم اکنون 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 (Eëstanović & 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 گرادیان کاهش^۱ آموزش می‌بینند، اما آموزش این شبکه‌ها، هنگامی که وابستگی‌های بلندمدت زمانی بین ورودی‌ها و 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

به‌عنوان الگوهای کارا و قابل مقایسه و برای حل مشکل یادگیری سیستم و همچنین حل مشکل وقفه‌های دور که در الگوها، عموماً ضریب پایین تری 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^۱ می‌شود که LSTM کمتر دچار این مشکلات است. رنج اطلاعاتی^۲ 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 به‌صورت 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 به‌وسیله آن می‌توان تغییرات اجزای معماری شبکه را به‌خوبی مشخص و آثار مختلف آن را مقایسه کرد؛ این الگو اولین بار توسط گریوز و اشمیتهابر^۳ 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. 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 به‌صورت رابطه (۲) است:

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

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

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

$$\sigma_c^2(w) = w^2\sigma_1^2 - (1-w)\sigma_2^2 + 2w(1-w)\sigma_{12} \quad (۳)$$

در رابطه (۳) واریانس خطاها به ترتیب σ_1^2 ، σ_2^2 و σ_{12} کوواریانس بین خطاها است. برای کمینه کردن میزان واریانس طبق فرض می توان 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)):

$$w^* = \frac{\sigma_2^2 - \sigma_{12}}{\sigma_1^2 + \sigma_2^2 - 2\sigma_{12}} \quad (۴)$$

$$1 - w^* = \frac{\sigma_1^2 - \sigma_{12}}{\sigma_1^2 + \sigma_2^2 - 2\sigma_{12}} \quad (۵)$$


طبق رابطه‌های (۴) و (۵) می توان گفت که وزن بیشتر به الگویی اختصاص دارد که پیش بینی دقیق تری را داراست. بنابراین، الگوهای ترکیبی می تواند 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 ویژگی‌های منحصربه‌فرد الگوی LSTM در برآورد غیرخطی و به دلیل کاراتر بودن الگوهای ترکیبی در پیش‌بینی سری‌های زمانی، این مقاله از هر سه نقطه قوت استفاده کرده و الگوی ترکیبی ARDL-D-LSTM ارائه می دهد.

۴. پایه‌های 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 ارزش 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^۱ (۱۹۹۵) و پسران و دیگران^۲ (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^۳ نامیده می‌شود (Jorgenson, 1996).

1. Pesaran, M. H. & Shin, Y.
2. Pesaran, H. M. et al.
3. Rational Lag Model

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: inf_t نرخ تورم ماهانه در زمان t ، inf_{t-j} وقفه نرخ تورم ماهانه (انتظارات تورمی)، rm_{t-j} وقفه‌های رشد حجم نقدینگی ماهانه، rex_{t-j} وقفه‌های رشد نرخ ارز ماهانه، rdeb_{t-j} وقفه‌های رشد بدهی دولت به بانک مرکزی، rgdp_{t-j} رشد درآمد ناخالص داخلی، D_{t-1}^+ متغیر مجازی به دست آمده از فیلتر هدریک-پرسکات^۱ مربوط به پرش‌های مثبت بیش از میانگین در پرش از نقطه تعادل در وقفه دوره $t-1$ ، D_{t-1}^- متغیر مجازی به دست آمده از فیلتر هدریک-پرسکات مربوط به پرش‌های منفی بیش از میانگین در پرش از نقطه تعادل در وقفه دوره $t-1$.

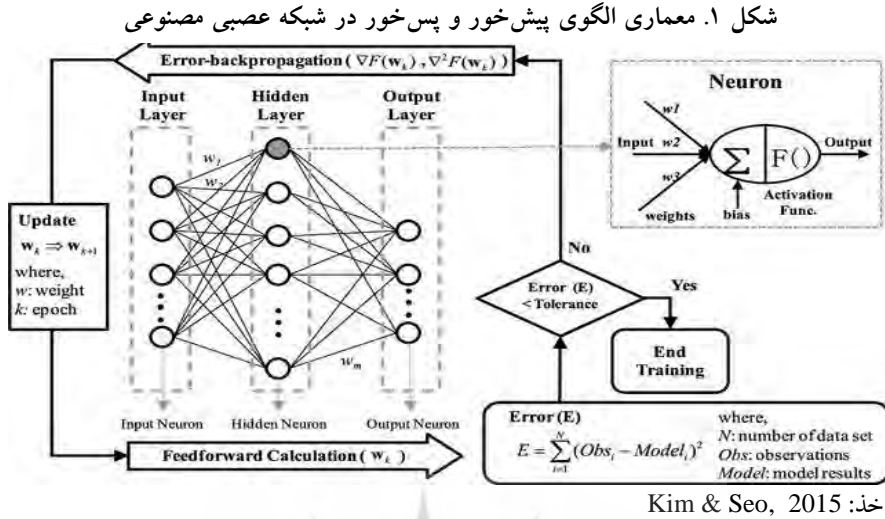
۴-۲. الگوی NARX

الگوی NARX، جزء دسته سیستم‌های غیرخطی ناپیوسته زمانی است که به صورت ریاضی به صورت رابطه (۸) نمایش داده می‌شود (Hornik, 1993).

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

معماری یک شبکه عصبی پیش‌خور و پس‌خور در قالب الگوی شبکه عصبی به صورت شکل (۱) قابل ارائه است.

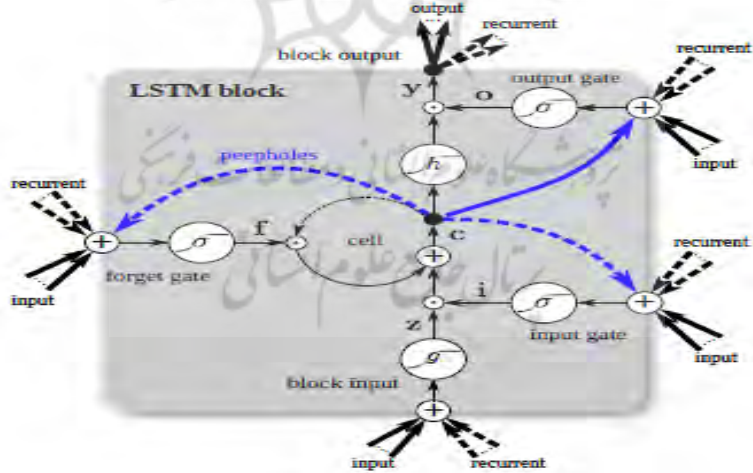
1. Hodrick-Prescott (HP) filter



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

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

شکل ۲. معماری الگوی LSTM وانیلا



ماخذ: Greff, et al., 2016

1. Vanilla

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:

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

متغیرها در رابطه (۹) به این شرح است: g, σ, 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، o 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^۱ (۲۰۰۳) مطرح است، ابتدا قسمت خطی بر اساس الگوی ARDL به صورت رابطه (۱۰) برآورد می‌شود.

$$(inf_t)_L = c + \sum_{j=1}^p \gamma_j inf_{t-j} + \sum_{j=1}^q \beta_j rm_{t-j} + u_t \quad (10)$$

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)).

$$u_t = inf_t - (inf_t)_L \quad (11)$$

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

1. Zhang, G.

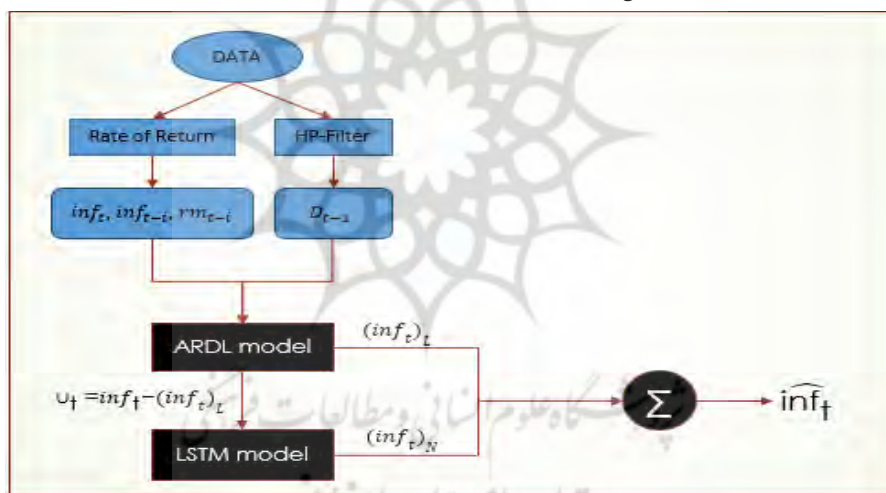
همان‌طور که در رابطه‌های (۱۱) و (۱۲) نشان داده شده است در این روش اجزای اخلاص الگوی خطی ARDL-D به روش غیرخطی LSTM برآورد می‌شود و بعد از آن طبق رابطه (۱۳) به مقدار پیش‌بینی شده در قسمت خطی اضافه خواهد شد و در نهایت طبق رابطه (۱۴) خطای الگوی ترکیبی ARDL-D-LSTM به دست می‌آید که می‌توان با استفاده از شاخص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

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

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

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.

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

۱-۵. تجزیه و تحلیل ARDL-D

در جدول (۲) حاصل تخمین الگوی ARDL-D آورده شده است که روش انتخاب الگو به وسیله معیار آکائیک^۱ (تعداد داده‌ها ۱۵۴ ماه) بوده است^۲. برآورد تخمین از آبان ۱۳۸۴ 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)^۳ 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	۰/۰۱۶	-۳/۳	۰۰
C	۰/۵۴	۰/۰۱۷	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

۱. 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 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.

۳. 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.³


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 کوتاه مدت متغیرهای مستقل الگو بر نرخ تورم، معنادار بودن ضرایب هر یک از متغیرهای الگو بررسی شد. 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 معنی دار بوده و می‌تواند الگو را در تفسیر مناسب‌تر هدایت کند. خوبی برازش الگو نیز تقریباً ۶۰ درصد است که مقدار قابل قبولی تلقی می‌شود.^۱ 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^۲ 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 معنی دار ۵ درصد رد می‌شود (Granger & Terasvirta, 1993; Krämer, et al., 1988; Krämer & Sonnberger, 1986). طبق $CUSUM_{\Gamma}$ و $CUSUM_{SQ}$ 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.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

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

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

با استفاده از آزمون BDS^۱ می‌توان نشان داد که رفتار اجزای اخلاص باقی‌مانده در الگو به صورت غیرخطی قابل تبیین است^۲. همچنین نرمال‌سازی داده‌های ورودی به الگوی LSTM به روش Rescaling^۳ انجام شده که ساده‌ترین روش برای تغییر بازه عددی مقادیر یک مجموعه به [۰, ۱] یا [-۱, ۱] است^۴. با توجه به حجم مقاله نتایج این سه الگو در جدول (۳) به طور خلاصه ارائه شده است.

پژوهشگاه علوم انسانی و مطالعات فرهنگی
پرتال جامع علوم انسانی

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

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

* 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.

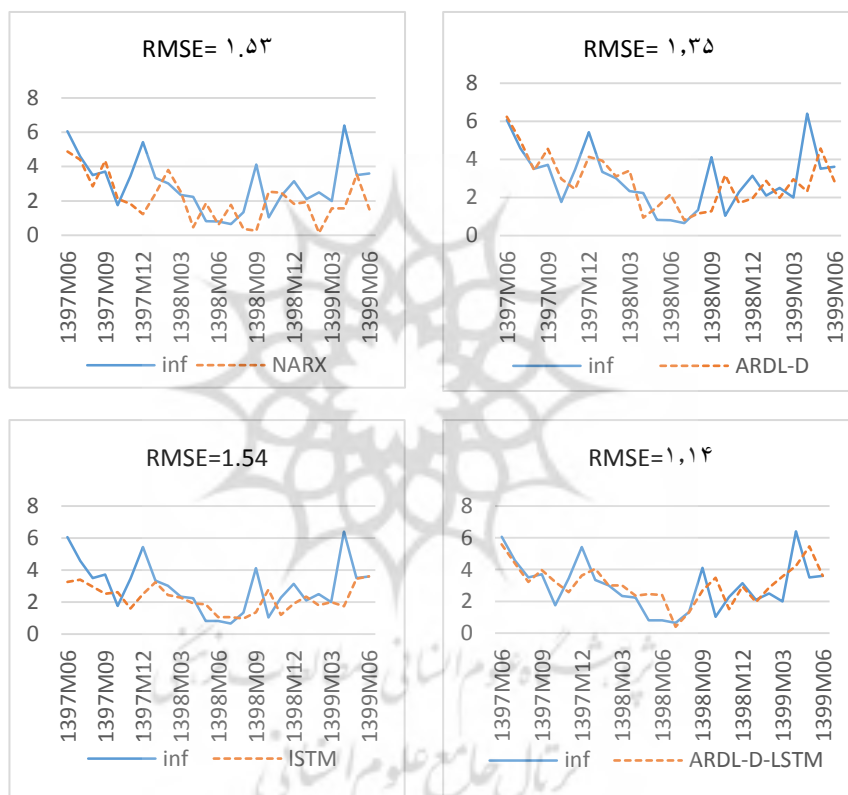
جدول ۴. جدول مقایسه و رتبه‌بندی عملکرد الگوها بر اساس معیار RMSE

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



ماخذ: 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، قیمت‌های 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		http://orcid.org/0000-0002-3318-1560
Ahmad Jafari Samimi		http://orcid.org/0000-0002-9047-6189
Zahra Mila Elmi		http://orcid.org/0000-0002-2913-7292
Amir Mansour Tehranchian		http://orcid.org/0000-0002-1635-3666

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.
- پورکاظمی، محمد حسین، بیرانوند، امین و دلفان، محبوبه. (۱۳۹۵). تعیین عوامل تاثیرگذار 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(۴۲)، ۱۳۸-۱۷۱.
- شاکری، عباس. (۱۳۸۹). *اقتصاد کلان، نظریه‌ها و سیاست‌ها*. ج ۲، چ ۳. تهران: انتشارات رافع.
- عباسی‌نژاد، حسین و گودرزی، یزدان. (۱۳۹۲). *اقتصادسنجی 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, (9999) Analysis o 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.
- Iş 1 ğ 1 çok, 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 (IJE OE)*, 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 economic [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.
- Pestanović, 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: عزیزگی 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)، ۱۴۹-۱۷۶.



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