

Research Article

Improving the Accuracy of Economic Growth Rate Forecasting Using a Combination of Wavelet Transform and Artificial Neural Network

Bahareh Karami¹ , Saeed Kian Poor*² 

1. Ph.D. in Public Sector Economics, Auditor of the Kurdistan Province Tax Office, Sanandaj, Iran.
2. Assistant Professor, Department of Economics, Payame Noor University, Tehran, Iran.

Received 06 September 2024 Revise 08 December 2024 Accepted 09 December 2024 Publish 21 March 2026

Abstract

Forecasting macroeconomic and financial variables plays a vital role in guiding policymakers' decisions. However, this task is particularly complex in developing economies such as Iran, where numerous factors overlooked by conventional economic theories significantly influence the economic landscape and outlook. As a result, economic relationships in these settings tend to be more unstable and exhibit pronounced nonlinear patterns. In recent years, the integration of wavelet transforms and artificial neural networks (ANNs) has gained attention as a powerful approach for mathematical modeling. This hybrid method effectively denoises time series data, thereby enhancing forecasting accuracy. The present study seeks to develop a predictive model for Iran's economic growth using this combined wavelet-ANN framework. The forecasting performance of the hybrid model is further compared with that of a standalone ANN. Empirical findings reveal a marked improvement in the predictive performance of the neural network when applied to denoised data. Moreover, the results underscore the superior accuracy of the hybrid model relative to traditional benchmark models such as XGBoost and ARIMA. Model performance was evaluated using criteria including the root mean square error (RMSE) and the Diebold-Mariano test.

Keywords: Wavelet Analysis, Neural Network, Economic Growth Forecasting.

JEL Classification: C22, C45, C53.

* **Corresponding Author:** Saeed Kian Poor

E-mail: S_kianpoor@pnu.ac.ir

Tel: +989123753340

Cite This Article (APA): Karami, B. & Kian Poor, S. (2026). Improving the Accuracy of Economic Growth Rate Forecasting Using a Combination of Wavelet Transform and Artificial Neural Network. *Journal of Economic Policies and Research*, 5(1), 137-165. <https://doi.org/10.22034/jepr.2024.142083.1171>

Homepage of this Article: https://jepr.uok.ac.ir/article_63560.html?lang=en



© The Author(s), 2026. *Economic Policies and Research*, Published online by University of Kurdistan. This is an Open Access article distributed under the terms of the [Creative Commons Attribution 4.0 International License](https://creativecommons.org/licenses/by-nc/4.0/), which permits unrestricted use, distribution, and reproduction in any medium, provided the original author and source are credited.

Introduction

Economic information serves as a cornerstone for policymaking; however, key macroeconomic indicators such as GDP are typically released with considerable delays and are frequently subject to revisions. These time lags significantly reduce their usefulness for capturing real-time economic dynamics, underscoring the need for effective forecasting models.

Accurate GDP growth forecasting is essential for sound planning and policy formulation. Nonetheless, in developing economies like Iran, this task is particularly challenging due to unstable and nonlinear patterns driven by factors often omitted in mainstream economic frameworks. The inherent unpredictability of such economies causes traditional forecasts to deviate substantially from actual outcomes. This situation highlights the necessity of evaluating forecasting performance and fuels the demand for more reliable and adaptive predictive models.

In the past two decades, computational intelligence techniques—especially Artificial Neural Networks (ANNs) and other non-parametric regression methods—have gained traction for their strong ability to model complex economic time series. ANNs, inspired by the functioning of the human brain, possess notable adaptability and flexibility. Nevertheless, they face certain limitations, such as slow convergence rates and difficulties in handling non-stationary data without appropriate preprocessing.

To overcome these issues, the present study introduces a hybrid Wavelet–Artificial Neural Network (WANN) model for forecasting Iran’s economic growth over the period 1961–2022. The proposed WANN framework integrates the strengths of wavelet transforms and ANNs to effectively capture the nonlinear and non-stationary features inherent in financial and economic time series. Specifically, in this approach, the economic growth series is first decomposed using the Discrete Daubechies Wavelet, and the resultant sub-series components are subsequently used as inputs to the ANN for forecasting.

This research constitutes the first attempt to apply a WANN-based algorithm to predict Iran’s economic growth. The study further aims to assess and compare the forecasting performance of the hybrid WANN model against that of a conventional standalone ANN using raw, unprocessed data.

Methodology

The data for this study consists of time series representing Iran's economic indicators over a specified period. The dependent variable, economic growth, is analyzed in conjunction with various macroeconomic factors acting as independent variables. To enhance the quality of predictions, the wavelet transform technique is employed as a preprocessing step. This method decomposes the time series data into different frequency components, enabling the removal of noise while retaining meaningful patterns essential for accurate forecasting.

Following the denoising process, the artificial neural network (ANN) model is applied. The ANN is structured to identify and capture nonlinear relationships within the data, utilizing advanced learning algorithms for optimal performance. The combined wavelet-ANN model is then benchmarked against two widely used forecasting methods: ARIMA, a classical statistical model, and XGBoost, a machine learning approach known for its predictive capabilities. To evaluate the performance of these models, two key metrics are employed: Root Mean Square Error (RMSE) and the Diebold-Mariano test. RMSE provides a quantitative measure of forecast accuracy, while the Diebold-Mariano test assesses the statistical significance of differences in prediction errors between competing models. These metrics ensure a thorough and unbiased comparison, highlighting the strengths and limitations of each method.

Results and Discussion

The study's findings demonstrate the superior performance of the hybrid wavelet-ANN model compared to both XGBoost and ARIMA. The inclusion of the wavelet transform significantly enhances the predictive power of the ANN by reducing noise and isolating relevant patterns within the data. This improvement is particularly evident in the lower RMSE values achieved by the combined model, indicating its effectiveness in capturing the complexities of Iran's economic dynamics. Further analysis reveals that the wavelet-ANN model outperforms the traditional methods not only in accuracy but also in robustness across various economic scenarios. The comparative results, supported by detailed tables and graphs, highlight the consistency of the hybrid approach in providing reliable forecasts.

Additionally, the Diebold-Mariano test confirms the statistical significance of the observed differences, reinforcing the validity of the proposed method. The implications of these findings extend beyond the scope of this study, suggesting that integrating wavelet transforms with machine learning models can serve as a powerful tool for economic forecasting in developing economies. By addressing the inherent challenges of instability and nonlinearity, this approach offers valuable insights for policymakers and researchers seeking to navigate complex economic environments.

Conclusion

This research underscores the potential of the hybrid wavelet-ANN model as a superior forecasting tool for Iran's economic growth. By leveraging the denoising capabilities of wavelet transforms and the nonlinear analytical power of ANN, the combined approach achieves remarkable improvements in prediction accuracy compared to traditional models like XGBoost and ARIMA. The study highlights the practical applications of this method in aiding policymakers with more precise and reliable economic forecasts. Future research could explore the application of similar hybrid models in other developing economies, investigating their adaptability and effectiveness across diverse economic contexts. The findings also pave the way for further refinement of forecasting techniques, incorporating additional variables and methodologies to enhance predictive accuracy and robustness.

Additional Information

Authors' Contributions

All Authors Contributed Equally to The Writing of The Article.


Conflict of interest

The authors declare that there is no conflict of interest regarding the publication of this article.


Financial Support

The authors received no financial support for the research and publication of this article.

ORCID

 Bahareh karami

<http://orcid.org/0000-0003-3903-5780>

 Saeed kian poor

<http://orcid.org/0000-0002-4827-4970>



بهبود دقت پیش‌بینی نرخ رشد اقتصادی با استفاده از ترکیب تبدیل موجک و شبکه عصبی مصنوعی

بهاره کرمی ^۱، سعید کیان‌پور ^{۲*}

۱. دکتری اقتصاد بخش عمومی، حسابرس اداره امور مالیاتی استان کردستان، سنندج، ایران.

۲. استادیار، گروه اقتصاد، دانشگاه پیام‌نور، تهران، ایران.

تاریخ دریافت: ۱۴۰۳/۰۶/۱۳ تاریخ بازنگری: ۱۴۰۳/۰۹/۱۸ تاریخ پذیرش: ۱۴۰۳/۰۹/۱۹ تاریخ انتشار: ۱۴۰۵/۰۱/۰۱

چکیده

پیش‌بینی رفتار متغیرهای کلان و مالی اقتصاد برای سیاست‌گذاران از اهمیت بالایی برخوردار است. این امر برای اقتصادهای درحال توسعه از جمله ایران یک کار چالش‌برانگیز است؛ زیرا مجموعه‌ای از عوامل که در نظریه‌های اصلی اقتصاد در نظر گرفته نشده‌اند، اغلب نقش مهمی در شکل دادن به محیط و چشم‌انداز کلی اقتصاد آنان دارد. روابط اقتصادی در این نوع محیط‌ها بی‌ثبات‌تر و همراه با روند غیرخطی است. ترکیب تبدیل موجک و شبکه عصبی مصنوعی یک تحلیل مدل‌سازی ریاضی نوظهور در سال‌های اخیر است که به منظور نوین‌سازی در سری‌های زمانی و افزایش دقت پیش‌بینی پیشنهاد شده است. در این پژوهش تلاش شد با استفاده از ترکیب تبدیل موجک و شبکه عصبی مصنوعی، مدلی به منظور پیش‌بینی رشد اقتصادی ایران ارائه گردد تا دقت پیش‌بینی روش ترکیبی با شبکه عصبی مصنوعی مقایسه شود. نتایج مطالعه بهبود معنادار در پیش‌بینی شبکه عصبی با استفاده از داده‌های نوین‌سازی شده را نشان داد. نتایج همچنین برتری مدل ترکیبی را نسبت به مدل‌های XGBoost و ARIMA تأیید کرد. دقت پیش‌بینی این مدل‌ها بر اساس معیارهایی مانند ریشه میانگین مربع خطا و آزمون دیبولد - ماریانو ارزیابی و مقایسه شده است.

واژگان کلیدی: تجزیه موجک، شبکه عصبی، پیش‌بینی رشد اقتصادی.

طبقه‌بندی JEL: C22, C45, C53

تلفن تماس: ۰۹۱۲۳۷۵۳۳۴۰

آدرس رایانامه: S_kianpoor@pnu.ac.ir

* نویسنده مسئول: سعید کیان‌پور

استناد به مقاله (APA): کرمی، بهاره و کیان‌پور، سعید. (۱۴۰۵). بهبود دقت پیش‌بینی نرخ رشد اقتصادی با استفاده از ترکیب تبدیل موجک

و شبکه عصبی مصنوعی. نشریه سیاست‌ها و تحقیقات اقتصادی، ۵(۱)، ۱۳۷-۱۶۵. <https://doi.org/10.22034/jepr.2024.142083.1171>

https://jepr.uok.ac.ir/article_63560.html

صفحه اصلی مقاله در سامانه نشریه:



۱. مقدمه

اطلاعات در مورد وضعیت فعلی اقتصادی یک عنصر حیاتی برای سیاست‌گذاری است؛ زیرا انتخاب سیاست مناسب، بر دانش به‌روز شده از چارچوب اقتصاد کلان متکی است. آمارهای کلیدی اقتصاد کلان اغلب با تأخیر منتشر می‌شوند و یا در معرض تجدیدنظرهای مکرر قرار دارند. زمانی که داده‌های ملی با وقفه زمانی در دسترس قرار می‌گیرند، اثرگذاری‌شان در سیاست‌گذاری و شناخت وضعیت اقتصادی موجود کم‌رنگ می‌شود؛ بنابراین برای درک اینکه اقتصاد در حال حاضر کجا قرار دارد و یا ممکن است در آینده کجا باشد، نیاز به پیش‌بینی متغیرهای اقتصادی پیشین است (Türsoy, 2013).

یکی از قدرتمندترین شاخص‌های آماری اقتصادی برای ارزیابی عملکرد اقتصادی و توسعه کشورها که همواره با تأخیر قابل توجهی منتشر می‌شود، تولید ناخالص داخلی^۱ است. پیش‌بینی رشد تولید ناخالص داخلی برای برنامه‌ریزی اقتصادی ضروری است، زیرا به دولت‌ها، کسب‌وکارها و سرمایه‌گذاران کمک می‌کند تا روندها را پیش‌بینی کنند، تصمیمات آگاهانه بگیرند و ثبات و رشد را ارتقا دهند. با این وجود رشد اقتصادی ناپایدار و غیرمستمر همراه با نوسان‌های متعدد اقتصاد ایران باعث شده که دشواری‌هایی برای پیش‌بینی آن ایجاد شود و در برخی موارد، پیش‌بینی‌های اقتصادی فقط پیش‌بینی باقی می‌مانند.

یک پیش‌بینی زمانی موفق است که نزدیک به واقع باشد، اما این موفقیت به روش مورد استفاده و اندازه‌گیری میزان نزدیکی آن بستگی دارد (Clements & Hendry, 2004). هنر پیش‌بینی ذاتاً دشوار است و تصمیم‌گیری در مورد اینکه آیا می‌توان از پیش‌بینی‌های ارائه شده توسط متخصصین امر استفاده کرد و یا چگونه؟ چالشی است که یک سیاست‌گذار همواره با آن مواجه است. با این حال، سیاست‌گذاران به طور مداوم از پیش‌بینی‌ها استفاده می‌کنند؛ بنابراین لازم است صحت پیش‌بینی‌ها مورد ارزیابی قرار گیرد. اقتصاددانان و پیش‌بینی‌گران که شهرت آنها می‌تواند به راحتی بادقت پیش‌بینی‌شان، افزایش یا کاهش یابد، اغلب علاقه‌مند هستند که برای بهبود دقت پیش‌بینی‌های خود بین تکنیک‌های مختلف رقیب تمایز قائل شوند. این امر باعث شده مطالعاتی که بتواند به بهبود و ارتقای مدل‌های پیش‌بینی کمک کند، تقاضای روبه‌رشدی داشته باشد.

روش‌ها و ابزارهای جدید پیش‌بینی متغیرهای اقتصادی از جمله سیستم‌های هوش محاسباتی - به‌ویژه شبکه‌های عصبی مصنوعی^۲ (ANN) - و روش‌های رگرسیون ناپارامتریک^۳ به دلیل توانایی تقریب توابع بادقت بالا در پیش‌بینی سری‌های زمانی اقتصادی و مالی در دو دهه گذشته محبوبیت زیادی پیدا کرده‌اند. مدل‌های مبتنی بر سیستم‌های هوش محاسباتی که فرایندهای بیوشیمیایی مغز^۴ انسان را تقلید می‌کنند، از طریق انعطاف‌پذیری عملکردی و توانایی ذاتی خود برای انطباق با شرایط متغیر از طریق فرایندهای آموزشی و یادگیری، مزیت دارند. در واقع مزایای شبکه‌های عصبی مصنوعی به‌عنوان مدل‌های پیش‌بینی به دلیل افزایش قابل توجه میزان در دسترس بودن داده‌ها و همچنین ظرفیت محاسباتی بالاتر است (Jordan & Mitchell, 2015). با این وجود،

1. Gross Domestic Product
2. Artificial Neural Networks
3. Nonparametric regression
4. Brain biochemistry

الگوریتم شبکه‌های عصبی مصنوعی در همگرایی کند است و اگر پردازش اولیه داده‌های ورودی و خروجی انجام نشود، ممکن است قادر به مقابله با داده‌های ناماننا نباشد (Isa & Shabri, 2013). از آنجاکه امروزه، ترکیب روش‌های مدل‌سازی رقابتی موجود یک حوزه فعال تحقیقاتی است، در این مطالعه سعی می‌شود با ترکیب دو رویکرد نسبتاً جدید مبتنی بر شبکه‌های عصبی و تبدیل موجک، رشد اقتصادی در ایران برای سال‌های ۱۹۶۱ تا ۲۰۲۲ پیش‌بینی شود. مدل ترکیبی موجک - شبکه عصبی^۱ (WANN) پیشنهادی، قابلیت موجک‌ها و شبکه‌های عصبی را برای لحاظ کردن ویژگی‌های غیرخطی ناماننا که در سری‌های زمانی مالی تعیبه شده‌اند، ترکیب می‌کند. سری‌های WANN با مقیاس در تجزیه به دست می‌آیند و مطالعات نشان داده‌اند که ظرفیت رویکرد WANN قوی‌تر از شبکه عصبی پس انتشار^۲ (BPNN) است (Yu, 2009). در این مدل ترکیبی ابتدا سری زمانی رشد اقتصادی با استفاده از موجک گسسته دابیشز، تجزیه شده سپس اجزای زیرسری جمع‌آوری شده با افزودن مؤلفه‌های موجک گسسته غالب به‌عنوان ورودی‌های مدل شبکه عصبی مصنوعی (ANN) برای پیش‌بینی رشد اقتصادی خروجی انتخاب می‌شوند. در پایان، این پژوهش به مقایسه بین دقت پیش‌بینی رشد اقتصادی ایران در دو مدل شبکه عصبی با استفاده از داده‌های نویززدایی شده با تبدیل موجک و شبکه عصبی با استفاده از داده‌های اولیه از سال ۱۹۶۱ تا ۲۰۲۲ می‌پردازد؛ بنابراین، روش‌ها و آزمایش‌های مورد بحث در این مطالعه، این حدس را بررسی می‌کند که مجموعه داده‌های بزرگ‌تر و بهتر منجر به پیش‌بینی دقیق‌تر نرخ رشد اقتصادی می‌شود. فرضیه اخیر از اظهارات معروف پیتر نورویگ^۳ پیروی می‌کند، یعنی «داده‌های بیشتر الگوریتم‌های هوشمندانه را شکست می‌دهد؛ اما داده‌های بهتر بر داده‌های بیشتر غلبه می‌کند». گرچه در حوزه پیش‌بینی متغیرهای کلان اقتصادی در ایران مطالعات متعددی با تکنیک‌های مختلف صورت پذیرفته است لکن تا زمان انجام پژوهش حاضر، این مطالعه اولین تلاش در استفاده از الگوریتم مبتنی بر WANN برای پیش‌بینی نرخ رشد اقتصادی کشور است. در این راستا ادامه مقاله به شرح زیر سازماندهی می‌شود. در بخش دوم، ادبیات و پیشینه پژوهش ارائه می‌شود. در بخش سه به روش‌شناسی پرداخته می‌شود. بخش چهارم، نتایج مدل پیش‌بینی را مورد تجزیه و تحلیل قرار می‌دهد و نتیجه‌گیری در بخش پایانی بیان می‌گردد.

۲. ادبیات پژوهش

۲-۱. مبانی نظری

گرچه پیش‌بینی اقتصاد کلان به‌نوعی سابقه طولانی دارد؛ اما ماهیت فعلی آن محصول انقلاب کینزی است. پیش‌بینی‌های رسمی به‌طور منظم بلافاصله پس از جنگ جهانی دوم در کشورهای اسکاندیناوی ارائه شدند و این عمل در اوایل دهه ۱۹۵۰ به بریتانیا و در دهه ۱۹۶۰ در بیشتر اقتصادهای پیشرفته دیگر گسترش یافت (Hawkins, 2005). پس از آن علاقه‌مندان به پیش‌بینی، مانند محققان اقتصادی و ریاضی‌دانان، روش‌های بسیاری را برای پیش‌بینی اقتصادی آینده توسعه داده‌اند.

1. Wavelet - Artificial Neural Network
 2. Back Propagation Neural Network
 3. Peter Norvig

تکنیک‌های پیش‌بینی توسعه‌یافته را می‌توان به روش‌های آماری سنتی و روش‌های هوشمند تقسیم کرد (Yu, 2009). در زمینه روش‌های آماری دیدگاه غالب، مدل‌های سری زمانی است. روش‌های تجزیه و تحلیل سری زمانی به طور سنتی بر دو مفهوم مانایی و خطی بودن بنیاد نهاده شده‌اند. مدل‌های خطی نظیر خودرگرسیون^۱ (AR)، میانگین متحرک^۲ (MA) و مدل‌های میانگین متحرک خودهمبسته یکپارچه^۳ (ARIMA) اغلب تحت این فرض بکار گرفته می‌شوند (عباسی نژاد و محمدی، ۱۳۸۶). استفاده از مدل ARIMA در مدل‌سازی مسائل کاربردی اقتصادی و اجتماعی در نقاط مختلف جهان کاملاً مشهود است. لوگوبایوم و همکاران^۴ (۲۰۱۳) در این باره استدلال می‌کنند که روش هموارسازی نمایی (ESM)^۵ و ARIMA بیشترین رویکردهای مورد استفاده برای پیش‌بینی تولید ناخالص داخلی هستند. با این وجود مدل‌های اقتصادسنجی سنتی، از جمله سری‌های زمانی و تحلیل‌های رگرسیونی، اغلب در به‌تصویر کشیدن پویایی‌های پیچیده و غیرخطی در داده‌های اقتصادی شکست می‌خورند (Hameed Ashour & Ahmed, 2024). تجزیه و تحلیل سری‌های زمانی اغلب برای پیش‌بینی کوتاه‌مدت و میان‌مدت مفید است؛ زیرا در این مدل‌ها فرض می‌شود که رفتار گذشته متغیر در آینده ادامه خواهد داشت. یکی از محدودیت‌های عمده این روش‌ها نیاز به مشاهدات بسیار برای ارائه نتایج مناسب از پیش‌بینی است. علاوه بر این، این‌گونه مدل‌ها از جملات خطا برای پیش‌بینی استفاده می‌کنند.

شبکه عصبی، سیستم فازی و الگوریتم ژنتیک از مدل‌های هوش مصنوعی هستند که در بین آنها شبکه عصبی باتوجه به ویژگی‌های آن، کاربرد گسترده‌ای یافته است و بسیاری از محققان موافق هستند که شبکه عصبی مصنوعی بهترین پیش‌بینی‌کننده و بهترین روش تحلیل غیرخطی به شمار می‌رود (Gu et al., 2020). شبکه عصبی مصنوعی، چندین لایه پردازش را با استفاده از عناصر ساده که به صورت موازی کار می‌کنند، ترکیب می‌کند. از یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی تشکیل شده است. هر لایه حاوی چندین نرون است که می‌توانند ورودی‌ها را با وزن‌ها و توابع فعال‌سازی برای به‌دست آوردن خروجی تغییر دهند.

استفاده از شبکه‌های عصبی در علم اقتصاد هنوز در مراحل نسبتاً ابتدایی خود است. مقاله کوان و وایت^۶ (۱۹۹۴) احتمالاً معرفی قطعی شبکه‌های عصبی به ادبیات اقتصادسنجی است. کوان و وایت بسیاری از تشابهات بین اقتصادسنجی و شبکه‌های عصبی را ترسیم می‌کنند، سهم نظری آنان با برخی از کارهای کاربردی از جمله مطالعه معصومی و همکاران (۱۹۹۴) دنبال شده است. این نویسندگان نشان می‌دهند که چهارده سری زمانی اقتصاد کلان که در مقاله اصلی توسط نلسون و پلوسر^۷ (۱۹۸۲) تحلیل شده‌اند، می‌توانند به خوبی با استفاده از شبکه‌های عصبی مدل‌سازی شوند و این شک قوی را ایجاد می‌کنند که این سری‌ها از فرایندهای ریشه واحد پیروی می‌کنند. این نتیجه با نتایج پرون^۸ (۱۹۸۹) که اشاره می‌کند سری‌های زمانی با یک یا دوشکست ساختاری

-
1. Autoregressive
 2. Moving-Average
 3. Autoregressive Integrated Moving Average
 4. Logubayom et al. (2013)
 5. Exponential Smoothing
 6. Kuan & White (1994)
 7. Nelson & Plosser (1982)
 8. Perron (1989)

هم پایدار می‌شوند، سازگار است. در واقع، نقطه قوت اصلی مدل‌های شبکه عصبی این است که آن‌ها توانایی بهتری در مدل‌سازی شکست‌هایی مانند سقوط بازار سهام و شوک‌های نفتی دارند، زیرا ممکن است نشان‌دهنده انحرافات قابل توجه از خطی بودن این مدل‌ها باشد.

از لحاظ آماری، شبکه‌های عصبی مصنوعی به‌عنوان، یک روش استنباط غیرخطی، غیر پارامتری، چندمتغیره و کاملاً داده‌محور توصیف می‌شود. شبکه‌های عصبی مصنوعی که رقیبی برای روش‌های سنتی به شمار می‌روند، می‌توانند روابط و همبستگی بین داده‌ها را به دست آورند حتی اگر قانون حاکم بر آنها ناشناخته و بسیار پیچیده باشد (هاشمی و همکاران، ۱۳۹۹). برخی از محققان در جهت ارزیابی عملکرد و توانایی روش‌های مختلف پیش‌بینی، شبکه عصبی مصنوعی را با تکنیک‌های سنتی مورد مقایسه قرار دادند از جمله گو و همکاران (۲۰۲۰)؛ پوچالسکی و همکاران^۱ (۲۰۱۸)؛ سافاری و همکاران^۲ (۲۰۱۶)؛ یو و همکاران^۳ (۲۰۰۶) و نیز ژانگ و همکاران^۴ (۲۰۱۹). نتایج مؤید آن است که به‌طور کلی، شبکه عصبی مصنوعی از این تکنیک‌ها بهتر عمل کرده و توانسته است روندهای غیرخطی پویا، الگوهای فصلی و تعاملات بین آنها را ثبت کند (Matt et al., 2021).

علی‌رغم مزایا و محبوبیت ظاهری مدل‌های شبکه عصبی مصنوعی و مدل‌های رگرسیون ناپارامتریک، آنچه مشاهده می‌شود این است که آن‌ها به‌ندرت برای پیش‌بینی سری‌های زمانی اقتصادی یا مالی در اقتصادهای در حال توسعه به کار گرفته شده‌اند، حتی زمانی که برنامه‌های کاربردی متعددی در اقتصادهای توسعه‌یافته وجود داشته باشد و عملکرد برتر آنان را نسبت به مدل‌های پیش‌بینی سنتی نشان دهد. به‌عنوان مثال، تیکچ^۵ (۲۰۰۱) دریافت که شبکه‌های عصبی در پیش‌بینی رشد تولید ناخالص داخلی سالانه برای کانادا از مدل‌های خطی بهتر عمل می‌کنند. هروی و همکاران^۶ (۲۰۰۴) نشان می‌دهند که مدل‌های شبکه‌های عصبی در پیش‌بینی جهت تغییر تولید صنعتی برای اقتصادهای اروپایی بر مدل‌های خطی ارجح هستند، اما مدل‌های خطی عموماً در پیش‌بینی‌های خارج از نمونه در افق‌های حداکثر یک سال، از مدل‌های شبکه عصبی بهتر عمل می‌کنند. به‌طور مشابه، فنگ و ژانگ^۷ (۲۰۱۴) از مدل‌های شبکه عصبی مصنوعی در مقابل مدل پیش‌بینی خاکستری^۸ (GM) برای انجام پیش‌بینی گرایش رشد اقتصادی در شهرهای ژجیانگ چین استفاده می‌کنند و دریافتند که نتایج پیش‌بینی‌شده از شبکه‌های عصبی مصنوعی بهتر و کارآمدتر از نتایج مدل GM است.

مدل ترکیبی موجک شبکه‌های عصبی (WANN) دسته جدیدی از مدل‌ها هستند که تحلیل موجک^۹ (WA) و شبکه‌های عصبی کلاسیک (NN) را ترکیب می‌کنند. WANN‌ها با موفقیت زیادی در طیف وسیعی از کاربردها استفاده شده‌اند، باین‌حال، یک چارچوب پذیرفته شده عمومی برای استفاده از WANN‌ها در ادبیات وجود ندارد (Alexandridis & Zapranis, 2013). تجزیه و تحلیل موجک (WA) ثابت کرده است که یک ابزار ارزشمند برای

1. Puchalsky et al. (2018)
2. Safari et al. (2016)
3. Yu et al. (2006)
4. Zhang et al. (2014)
5. Tkacz (2001)
6. Heravi et al. (2004)
7. Feng & Zhang (2014)
8. Grey model
9. Wavelet Analysis

تجزیه و تحلیل طیف گسترده‌ای از سری‌های زمانی است و قبلاً با موفقیت در پردازش تصویر، حذف نویز سیگنال، تخمین چگالی، فشرده‌سازی سیگنال و تصویر و نیز تجزیه در مقیاس زمانی استفاده شده است. WA اغلب به‌عنوان یک «میکروسکوپ» در ریاضیات در نظر گرفته می‌شود (Cao et al., 1995) و ابزار قدرتمندی برای نمایش روند غیرخطی‌ها است (Fang & Chow, 2006). مهم‌ترین ویژگی موجک‌ها تعریف آنها در فضا و زمان است. این ویژگی موجک‌ها همراه با تعریف آنها در محدوده فرکانس باعث می‌شود که بتوان آن‌ها را کاندیداهای بسیار ایدئال جهت تحلیل نامانایی و یا غیرساکن بودن سیگنال‌ها (و نیز سیگنال‌های زودگذر و یکینه) بکار برد (عباسی نژاد و محمدی، ۱۳۸۶). باین‌حال WA محدود به کاربردهای ابعاد ورودی کوچک است، زیرا ساخت یک موجک، زمانی که ابعاد بردار ورودی نسبتاً زیاد است، از نظر محاسباتی پرهزینه است (Zhang, 1997).

از طرف دیگر گرچه شبکه‌های عصبی مصنوعی توانایی تقریب هر فرایند غیرخطی قطعی را با دانش اندک و بدون فرضیات در مورد ماهیت فرایند دارند باین‌حال، دارای اشکالاتی هستند. از جمله اینکه حتی اگر داده‌های ورودی بازتابی از رفتار سیستم واقعی باشند، شبکه آموزش‌دیده به دلیل وجود سیگنال غیرثابت فرایند، عدم نرمال‌سازی داده‌ها و یا نرمال‌سازی با استفاده از روش نامناسب، نتایجی با درجه خطای بالا تولید می‌کند.

مشاهده شده است که به‌طور کلی بیشتر داده‌های سری زمانی اقتصادی و داده‌های رشد به‌طور خاص ماهیت غیرخطی، غیرثابت، غیرعادی و ناهمسانی دارند؛ بنابراین، استفاده از مدل‌های پارامتری خطی و غیرخطی معمولی مانند آریما (ARIMA)، گارچ (GARCH)، و مدل‌های مشابه آن‌ها نتوانسته است تغییرپذیری موجود در سری را به تصویر بکشد. در چنین شرایطی، پیش‌پردازش داده‌های زمانی و مکانی ممکن است یک رویکرد مؤثر برای غلبه بر اشکالات باشد. تکنیک تجزیه موجک تا حد زیادی بر روی سیگنال غیرثابت اعمال شده است (Nason & Von Sachs, 1999) و اثربخشی آن در تجزیه سری‌های زمانی غیرساکن به زیر سری‌ها در مقیاس‌ها (سطوح) مختلف برای درک بهتر فرایند مفید است. در این رابطه برخی از محققان دریافته‌اند که استفاده از تجزیه و تحلیل موجک (WA) برای تجزیه سری‌های زمانی می‌تواند به استخراج بهتر ویژگی‌ها بینجامد و در نتیجه دقت مدل‌های پیش‌بینی را بهبود بخشد (Zhang et al., 2023). برای نمونه، الوادی و اسماعیل^۱ (۲۰۱۱) ضمن ارائه مزیت تبدیل موجک در پیش‌بینی داده‌های سری زمانی مالی بیان می‌دارند نتیجه سری تقریبی تحت تبدیل موجک از نظر میانگین و واریانس بهتر و پایدارتر از داده‌های اصلی است. به عقیده سزر و همکاران^۲ (۲۰۲۰) نیز مدل‌های ترکیبی شبکه عصبی با تکنیک‌های پردازش سیگنال، مانند توابع موجک به‌طور بالقوه سودمندتر از NNها هستند و این ترکیب تأثیر مثبتی بر عملکرد پیش‌بینی دارند. وگل و همکاران^۳ (۲۰۲۲) با پیاده‌سازی رویکردهای مختلف نشان می‌دهند که هم شبکه‌های عصبی موجک و هم شبکه‌های عصبی با داده‌های از پیش‌پردازش شده توسط موجک‌ها از شبکه کلاسیک بهتر عمل می‌کنند؛ بنابراین، ترکیب شبکه عصبی مصنوعی با تبدیل موجک به‌عنوان یک مدل ترکیبی (WANN) که می‌تواند اطلاعات طیفی و زمانی سیگنال را به‌طور هم‌زمان توضیح دهد، ابزار مؤثری برای پیش‌بینی فرایندهای اقتصادی ایجاد می‌کند.

1. Wadia & Ismail (2011)
 2. Sezer et al. (2020)
 3. Vogl et al. (2022)

تجزیه و تحلیل مطالعات گذشته نشان می‌دهد که WANN‌ها در زمینه‌های متعدد و به اشکال مختلف کاربرد داشته‌اند برای مثال: پیش‌بینی سری زمانی (Sugiartawan et al., 2017)، طبقه‌بندی و فشرده‌سازی سیگنال (Zhang, 2007)، حذف نویز سیگنال (Subasi et al., 2005; Pittner et al., 1998)، مدل‌سازی غیرخطی (Billings & Wei, 2005) و حتی به‌عنوان یک روش کالیبراسیون چندمتغیره که در پژوهش خیامیان و همکاران^۱ (۲۰۰۵) به چشم می‌خورد. در این مقاله تلاش می‌شود تا به‌منظور حذف نویز داده‌های ورودی و ارائه یک پیش‌بینی دقیق از WANN استفاده گردد.

۲-۲. پیشینه پژوهش

طی سال‌های اخیر پژوهش‌های متعددی پیرامون پیش‌بینی رشد اقتصادی کشورها انجام گرفته است که در آن‌ها از تکنیک‌های مختلف سری زمانی (کلاسیک) و هوش مصنوعی (غیرکلاسیک) بهره برده شده است. در ادامه به برخی از این مطالعات، در قالب جدول (۱) اشاره می‌شود. در یک نگاه کلی گرچه در سال‌های اخیر پژوهش‌های خارجی و داخلی پیرامون انواع روش‌های پیش‌بینی متغیرهای مالی - اقتصادی افزایش چشمگیری داشته است؛ اما تاکنون هیچ مطالعه‌ای به‌منظور حصول به نتایج قابل اعتمادتر، به‌صورت هم‌زمان دو تکنیک تبدیل موجک و شبکه‌های عصبی را در قالب یک مدل ترکیبی برای پیش‌بینی رشد اقتصادی ایران بررسی نکرده است. تلاش حاضر بر این اساس مسیره‌های جدیدی را در این زمینه باز می‌کند که از سایر مطالعات متمایز و منحصر به فرد است. نوآوری این پژوهش در استفاده هم‌زمان و نوآورانه از تکنیک‌های تبدیل موجک و شبکه عصبی برای بررسی دقت پیش‌بینی رشد اقتصادی ایران است که با توجه به ویژگی‌های خاص و چالش‌های اقتصادی کشور، به یک مدل پیش‌بینی جدید و کاربردی تبدیل می‌شود. این ترکیب منحصر به فرد می‌تواند به طور مؤثری به تصمیم‌گیرندگان اقتصادی در ایران کمک کند تا پیش‌بینی‌های دقیق‌تری داشته باشند و از این طریق سیاست‌های اقتصادی بهتری اتخاذ نمایند.

جدول ۱: مروری بر مطالعات تجربی

نویسندگان (سال)	نمونه (دوره)	روش‌های مورد استفاده	نتایج پژوهش
قدیمی و مشیری (۱۳۸۱)	ایران (۱۳۱۵-۱۳۷۳)	ARIMA و ANN	یافته‌ها کارایی بالاتر مدل شبکه عصبی مصنوعی را نسبت به مدل رگرسیون خطی در پیش‌بینی نرخ رشد اقتصادی نشان می‌دهد.
شایگانی و همکاران (۱۳۹۳)	ایران (۱۳۶۷-۱۳۸۹)	تبدیل موجک، ARIMA و ANN	نتیجه اعمال این روش پیشنهادی برای پیش‌بینی رشد اقتصادی در مقایسه با مدل شبکه عصبی خود توضیح غیرخطی با لوپ بسته و مدل ARIMA دقیق‌تر و کارآتر است.
صالحی سربیزن (۱۳۹۵)	ایران (۱۳۳۸-۱۳۹۲)	مدل‌های ARIMA، مارکوف سوئیچینگ و شبکه عصبی فازی (ANFIS)	مقایسه معیارهای مذکور برای هر مدل نشان داد بهترین عملکرد به ترتیب متعلق به روش ANFIS سپس مارکوف سوئیچینگ و در نهایت ARIMA است.
حکیمی پور و همکاران (۱۳۹۸)	ایران (۱۳۸۵-۱۳۹۵)	مدل شبکه عصبی فازی تطبیقی (ANFIS)	رشد اقتصادی بدون نفت کشور در سال ۱۳۹۵ حدود ۶ درصد برآورد شده که پیش‌بینی گردیده این مقدار در سال‌های ۱۳۹۶ و ۱۳۹۷ نیز به ترتیب حدود ۲ و ۳/۵ درصد باشد.

1. Khayamian et al. (2005)

نویسندگان (سال)	نمونه (دوره)	روش‌های مورد استفاده	نتایج پژوهش
ژانگ و کی ^۱ (۲۰۰۵)	آمریکا (دسامبر ۲۰۰۱)	ARIMA و ANN	پیش‌پردازش داده‌ها از جمله فصل‌زدایی و کاهش روند نقش مؤثری در عملکرد پیش‌بینی رشد اقتصادی دارد.
تورسوی ^۲ (۲۰۱۳)	قبرس (۲۰۰۲-۲۰۱۳)	ARIMA	نتایج پژوهش مشخص کرد پیش‌بینی‌های پیشین از نرخ رشد اقتصادی واقعی مدل سوم به پیش‌بینی‌های سازمان برنامه‌ریزی کشور قبرس برای سال‌های بین ۲۰۱۱ و ۲۰۱۳ نزدیک‌تر بود.
جان ^۳ (۲۰۱۸)	۱۵ کشور منتخب صنعتی (۲۰۱۶-۱۹۹۲)	ANN	شبکه عصبی مصنوعی پیش‌بینی‌های دقیق‌تر و انعطاف‌پذیرتری را در مقایسه با مدل‌های خطی، به‌ویژه در ثبت روندهای زمانی ارائه می‌دهد.
تومر و آکاس ^۴ (۲۰۱۸)	۱۳ کشور منتخب OECD (۲۰۱۵-۱۹۹۶)	ANN	بر اساس قدرت تخمینی تقریباً ۹۶ درصدی مدل، می‌توان نتیجه گرفت که شبکه‌های عصبی مصنوعی می‌توانند به‌عنوان ابزاری مؤثر برای برآورد تولید ناخالص داخلی استفاده شوند.
روستان و روستان ^۵ (۲۰۱۸)	اسپانیا و منطقه یورو (۲۰۱۶-۱۹۶۰)	چارچوب تحلیل موجک گسسته و مقایسه با ARIMA	پیش‌بینی GDP با تحلیل طیفی برای ۲۰۱۷-۲۰۲۶ به‌اندازه گزارش سازمان‌ها و نهادهای دولتی خوش‌بینانه نیست. مقایسه این مدل با روش ARIMA، افزودن آن را به ابزارهای اقتصادسنجی تأیید می‌کند.
چوکو و همکاران ^۶ (۲۰۱۹)	آفریقای جنوبی، نیجریه و کنیا (۲۰۱۶-۱۹۹۷)	ARIMA و ANN	در بسیاری از موارد، مدل شبکه‌های عصبی مصنوعی نسبت به مدل‌های اقتصادسنجی ساختاری و مدل‌های ARIMA برتری دارد. توضیح اصلی آنها این است که اقتصادهای درحال توسعه در معرض تأثیرات بالقوه شوک‌های خارجی و نوساناتی مانند قیمت کالاها، تجارت خارجی یا شوک‌های مالی و حتی عدم اطمینان سیاسی هستند.
دا کوستا و همکاران ^۷ (۲۰۲۱)	برزیل (۲۰۲۰-۱۹۹۶)	Holt-SARIMA Winters، مدل‌های خطی پویا و شبکه‌های عصبی خودرگرسیون (NNAR)	پرسپترون چندلایه (MLP) در پیش‌بینی‌های درون نمونه و خارج از نمونه عملکرد بهتری از سایرین داشت و به‌طور مؤثر نرخ رشد تولید ناخالص داخلی را ثبت کرد.
آلسینگلاو و همکاران ^۸ (۲۰۲۳)	اردن (۲۰۲۱-۱۹۹۶)	مدل تبدیل موجک (WT) و ARIMA	انتظار می‌رود تولید ناخالص داخلی با نرخ رشد مثبت حدود ۳/۲۲ درصد برای ده سال آینده افزایش یابد.
ژانگ و همکاران (۲۰۲۳)	۳۸ منطقه استان جاوه شرقی اندونزی (۲۰۱۴-۲۰۰۸)	مدل ترکیبی شبکه عصبی حافظه طولانی کوتاه‌مدت (LSTM) مبتنی بر یادگیری عمیق و تحلیل موجک (WA)	یافته‌ها برای داده‌های GDP فصلی، برتری نتایج پیش‌بینی مدل ترکیبی در مقایسه با مدل LSTM بدون تجزیه و تحلیل موجک را نشان داد، همان‌طور که افزایش دقت پیش‌بینی بر اساس معیارهایی مانند MAPE مشهود است.
چوداری و اوپرتی ^۹ (۲۰۲۳)	نیپال (۲۰۲۱ - ۱۹۶۰)	مدل‌های ترکیبی ANN-ARIMA	یافته‌ها نشان داد که مدل‌های ترکیبی از نظر دقت پیش‌بینی از سایر رویکردها پیشه گرفتند.

منبع: بررسی‌های محقق

- Zhang & Qi (2005)
- Türsoy (2013)
- Jahn (2018)
- Tümer & Akkuş (2018)
- Rostan & Rostan (2018)
- Chuku et al. (2019)
- Da Costa et al. (2021)
- Alsinglawi et al. (2023)
- Chaudhary & Uprety (2023)

۳. روش‌شناسی پژوهش

پژوهش حاضر از حیث هدف در زمره تحقیقات کاربردی قرار می‌گیرد و از نظر شیوه جمع‌آوری داده‌ها جزء پژوهش‌های توصیفی طبقه‌بندی می‌شود. جامعه آماری این تحقیق کشور ایران است و داده‌های نرخ رشد اقتصادی با اتکا به آخرین آمار موجود از سایت بانک جهانی و با توجه به محدودیت‌های آن از سال ۱۹۶۱ تا ۲۰۲۲ استخراج می‌شود. از آنجاکه هدف اصلی بررسی دقت شبکه عصبی ترکیبی در پیش‌بینی شاخص رشد اقتصادی با استفاده از داده‌های نوپزدایی شده حاصل از تبدیل موجک و سپس انتقال داده‌ها به‌عنوان ورودی به شبکه عصبی است؛ لذا در این بخش سعی می‌شود به طور مجزا به تکنیک‌های تبدیل موجک، شبکه عصبی و ترکیب آن‌ها پرداخته شود.

۳-۱. تبدیل موجک

موجک‌ها، تابع‌هایی محدود و موضعی‌اند که انرژی خود را در زمان متمرکز می‌کنند و برای تجزیه و تحلیل پدیده‌های گذرا و نامانا به کار می‌روند. برخلاف تبدیل فوری که فقط اطلاعات فرکانسی می‌دهد، تبدیل موجک می‌تواند هم‌زمان اطلاعاتی درباره زمان، مکان و فرکانس یک سیگنال فراهم کند و برای تحلیل بهتر، یک تابع را به ترکیبی از موجک‌های مناسب تجزیه می‌کند (Debnath & Shah, 2017). یک موجک را می‌توان به‌عنوان یک تابع بارزش واقعی $\psi(t)$ توصیف کرد که شرایط زیر را برآورده می‌کند:

$$\int_{-\infty}^{\infty} \psi(t) dt = 0 \quad \text{و} \quad \int_{-\infty}^{\infty} |\psi(t)|^2 dt = 1 \quad (1)$$

شرط اول به این معنی است که $\psi(t)$ باید یک تابع نوسانی با میانگین صفر باشد و شرط دوم تضمین می‌کند که تابع موجک دارای انرژی واحد است. به طور دقیق‌تر، موجک‌ها به‌صورت رابطه ۲ تعریف می‌شوند:

$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right), \quad a \neq 0, b \in R \quad (2)$$

که در آن a و b به ترتیب نمایانگر مقیاس و انتقال هستند؛ مقادیر کوچک a نشان‌دهنده اجزای فرکانس بالا و مقادیر بزرگ آن نشان‌دهنده اجزای فرکانس پایین سیگنال است. با افزایش مقیاس، تابع پایه کشیده و فرکانس به سمت پایین جابه‌جا می‌شود (Cody, 1994).

تبدیل موجک‌ها به دودسته پیوسته^۱ (CWT) و گسسته^۲ (DWT) قابل تفکیک‌اند (Conlon et al., 2008). رابطه ۳ تبدیل موجک پیوسته در زمان t برای سری زمانی $f(t)$ را نشان می‌دهد:

$$W_{\psi} f(a, b)(t) = \frac{1}{\sqrt{a}} \int_{-\infty}^{\infty} f(t) \bar{\psi}\left(\frac{t-b}{a}\right) dt \quad (3)$$

براین‌اساس تبدیل موجک معکوس را می‌توان طوری تعریف کرد که $f(t)$ را بتوان با استفاده از رابطه (۴) بازسازی کرد:

$$f(t) = \frac{1}{C_{\psi}} \int_{-\infty}^{\infty} \int_{-\infty}^{\infty} \frac{1}{\sqrt{a}} \psi\left(\frac{t-b}{a}\right) W_f(a, b)(t) \frac{dad b}{a^2} \quad (4)$$

1. Continuous Wavelet Transformation
2. Discrete Wavelet Transformation

که در آن $C\psi$ شرط قابل قبولی است که توسط رابطه ۵ داده شده است:

$$C\psi = \int_0^\infty \psi \frac{|\hat{\psi}(\omega)|^2}{|\omega|} d\zeta < \infty \quad (5)$$

در رابطه فوق $\psi(\omega)$ تبدیل فوریه تابع $\psi(t)$ است. برای کاربردهای عملی، اقتصاددان فرایند سیگنال زمان پیوسته را در اختیار ندارد، بلکه به سیگنال زمان گسسته به صورت رابطه ۶ دسترسی دارند.

$$\psi_{j,k}(t) = \frac{1}{a_0^{j/2}} \psi\left(\frac{t - kb_0 a_0^j}{a_0^j}\right) \quad (6)$$

تقریب هر تابع گسسته و یا سری زمانی با استفاده از توابع موجک به صورت زیر بدست می‌آید:

$$f(t) = \sum_k a_{j,k} \phi_{j,k}(t) + \sum_k d_{j,k} \psi_{j,k}(t) + \sum_k d_{j-1,k} \psi_{j-1,k}(t) + \dots + \sum_k d_{1,k} \psi_{1,k}(t) \quad (7)$$

که در آن J تعداد مؤلفه‌ها یا مقیاس‌های چند تحلیلی است. K مقدار شیفت زمانی در هر سطح را نشان می‌دهند و از ۱ تا تعداد ضرایب در مؤلفه‌های متناظر متغیر است. توابع ϕ و ψ توابع متعامد موجک و ضرایب $a_{j,k}$, $d_{j,k}$, $d_{2,k}$, $d_{1,k}$ ضرایب تقریبات (هموار شده) و جزئیات موجک هستند. این ضرایب با روابط زیر قابل تقریب‌اند:

$$a_{j,k} = \int_{-\infty}^{\infty} f(t) \phi_{j,k}(t) dt, \quad d_{j,k} = \int_{-\infty}^{\infty} f(t) \psi_{j,k}(t) dt, \quad j = 1, 2, \dots, J \quad (8)$$

بنابراین، نمایش تقریب سری موجک، به صورت رابطه (۹) بیان شود:

$$f(t) = A_j(t) + D_j(t) + D_{j-1}(t) + \dots + D_1(t) \quad (9)$$

۳-۲. شبکه عصبی مصنوعی

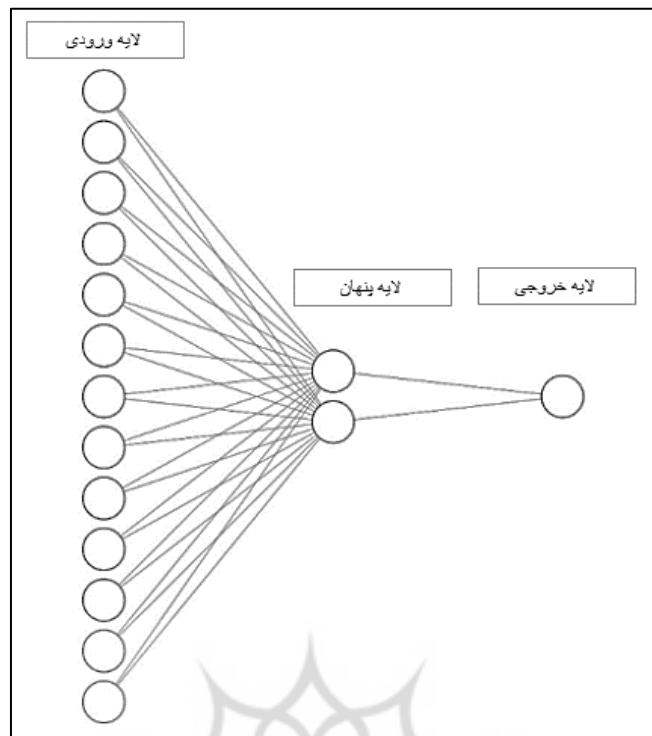
شبکه‌های عصبی مصنوعی مدل‌هایی هستند که برای تقلید از عملکردهای بیولوژیکی مغز طراحی شده‌اند و با استفاده از نرون‌های مصنوعی اطلاعات را پردازش می‌کنند. یکی از محبوب‌ترین انواع شبکه‌های عصبی مصنوعی، شبکه‌های پرسپترون چندلایه^۱ (MLP) است که دارای یک لایه ورودی، یک یا چند لایه پنهان و یک لایه خروجی است و سیگنال‌ها را در جهت ورودی به خروجی منتقل می‌کند. لایه‌های پنهان نقش کلیدی در بهبود توانایی پیش‌بینی مدل دارند و نرون‌های هر لایه با نرون‌های لایه‌های دیگر در ارتباط‌اند. شکل (۱)، روندی را که در یک مدل شبکه عصبی مصنوعی سه‌لایه ساده در جریان است نشان می‌دهد.

هر نرون وزن‌دار ورودی‌ها را جمع کرده، با بایاس^۲ ترکیب می‌کند و به تابع فعال‌سازی می‌فرستد تا خروجی باینری تولید شود. این فرایند را می‌توان به صورت خلاصه در رابطه (۱۰) بیان کرد:

$$a_{out} = f(w \times p + b)$$

$$f\left(\begin{pmatrix} w_{11} & w_{12} & \dots & w_{1r} \\ w_{21} & \ddots & \dots & \vdots \\ \vdots & \dots & \ddots & \vdots \\ w_{s1} & \dots & \dots & w_{sr} \end{pmatrix} \times \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_r \end{pmatrix} + \begin{pmatrix} b_1 \\ b_2 \\ \vdots \\ b_s \end{pmatrix}\right) = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_s \end{pmatrix} \quad (10)$$

1. Multi-layer Perceptron
2. bias



شکل ۱: شبکه عصبی پرسپترون چندلایه معمولی (MLP)

منبع: برگرفته از (Matta et al., 2021)

در شبکه‌های عصبی، P ورودی به نرون، W_{ij} وزن ارتباط و b_i بایاس است. تابع فعال‌سازی رایج لجستیک یا تانژانت هایپربولیک است. آموزش شبکه دو نوع دارد: نظارت شده (با تنظیم وزن‌ها برای نزدیکی خروجی به هدف) و بدون نظارت (تشخیص الگوها مستقل از خروجی). داده‌ها به دو مجموعه آموزش (برای تنظیم وزن‌ها) و آزمون (برای ارزیابی) تقسیم می‌شوند (جهرمی و غلامی، ۱۳۹۴). بردار ورودی در ماتریس وزن ضرب شده و تابع تحریک حدی باینری به این بردارهای وزن‌دار اعمال می‌شود.

$$a_j = \begin{cases} 1 \rightarrow \sum (WP + b) > \theta_j \\ 0 \rightarrow \sum (WP + b) \leq \theta_j \end{cases} \quad (11)$$

می‌توان مقدار خطا برای هر سلول عصبی را به صورت اختلاف خروجی عملی و خروجی هدف محاسبه کرد:

$$error_i = t_i - a_i \quad (12)$$

در شبکه‌های عصبی، با اصلاح وزن‌ها و کاهش خطا، فرایند آموزش تکرار می‌شود تا خطای شبکه به حد قابل قبول برسد. شبکه‌های پرسپترون تک‌لایه فقط مسائل خطی را حل می‌کنند، اما شبکه‌های پرسپترون چندلایه این محدودیت را برطرف می‌کنند. الگوریتم آدام یک نسخه بهینه از گرادینان نزولی است که برای یادگیری‌های عمیق استفاده می‌شود و به تنظیم نرخ یادگیری تطبیقی برای پارامترها کمک می‌کند. این الگوریتم محاسباتی کارآمد است، به حافظه کمی نیاز دارد و برای داده‌ها و مسائل بزرگ مناسب است (Kingma & Ba, 2015).

معیارهای مختلفی برای ارزیابی عملکرد شبکه عصبی استفاده می‌شود که از جمله آنها می‌توان به زمان آموزش، زمان مدل‌سازی و... اشاره کرد (راعی و همکاران، ۱۳۹۴). در این مقاله، معیار جذر میانگین مربع خطا^۱ (RMSE) برای ارزیابی دقت و صحت مدل مورد استفاده قرار می‌گیرد:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (y_i - \hat{y}_i)^2}{N}} \quad (13)$$

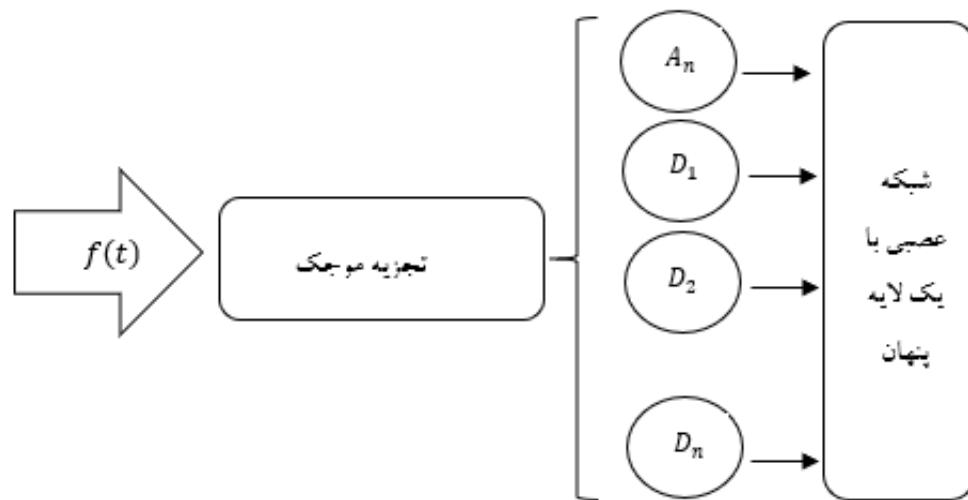
در رابطه (۱۳)، N تعداد داده استفاده شده، y_i و \hat{y}_i به ترتیب مقدار واقعی و پیش‌بینی شده در زمان i هستند. بدیهی است که مقدار کوچک RMSE نشان‌دهنده میزان نزدیکی پیش‌بینی‌های یک شبکه به داده‌های واقعی و کارایی بالای مدل است.

۳-۳. شبکه عصبی موجک ترکیبی

طراحی مدل ترکیبی موجک - شبکه عصبی^۲ (WANN) معمولاً از چهار بخش تشکیل شده است: DWT (تبدیل موجک گسسته)^۳، بازسازی ضرایب موجک، پیش‌بینی شبکه عصبی مصنوعی (AAN) و بازسازی سری داده‌ها. شکل ۲ نمودار شماتیک مدل توسعه‌یافته را نشان می‌دهد. برای ایجاد مدل ترکیبی WANN پیشنهاد می‌شود که بخش‌های تحلیل موجک و شبکه عصبی به طور جداگانه انجام شوند: سری زمانی $f(t)$ ابتدا به زیر سری‌ها با مقیاس‌های مختلف با استفاده از تبدیل موجک گسسته تجزیه می‌شود، به طوری که ساختارهای زمانی نامشخص می‌توانند برای ارزیابی بیشتر و آسان‌تر سیگنال در معرض دید قرار گیرند. برای این منظور، سری‌های زمانی با استفاده از تبدیل موجک گسسته، به تابع موجک تبدیل می‌شوند. برخی از توابع موجک گسسته شناخته‌شده عبارت‌اند از موجک هار^۴، دابیشز^۵، سیملتس^۶، کوایفلتس^۷ و موجک گسسته میر^۸ که در میان این خانواده موجک، تابع تبدیل دابیشز^۹ پرکاربردترین آنهاست.

انتخاب موجک مادر برای سیگنال‌های سری زمانی ورودی مختلف بر اساس عملکرد مدل است. سطح بهینه از طریق روش آزمون - خطا به دست می‌آید. برای داشتن یک دید کلی از سطح تجزیه، ابتدا باید حداکثر سطح تجزیه را به دست آورد. پس از فرایند تجزیه، همه زیر سری‌های به دست آمده (مجموع ضرایب تقریب و ضرایب جزئیات) به عنوان ورودی‌های مدل ANN استفاده شدند. رفتار هر زیر سری متمایز است و هر جزء زیر سری نقش متفاوتی در سری‌های زمانی اصلی بازی می‌کند. این مرحله مهم‌ترین و مؤثرترین بخش عملکرد تخمین ANN است. مدل ترکیبی همانند مدل شبکه عصبی ابتدا با یک ورودی و تعداد نرون متفاوت آموزش و آزمون می‌شود و بر اساس کمترین خطا تعداد بهینه نرون پنهان گزارش می‌گردد.

1. Root Mean Squared Error
2. Wavelet - Artificial Neural Network
3. Discrete wavelet transform
4. Haar
5. Daubechies
6. Symmelets
7. Coiflets
8. Meyer
9. Daubechies wavelets

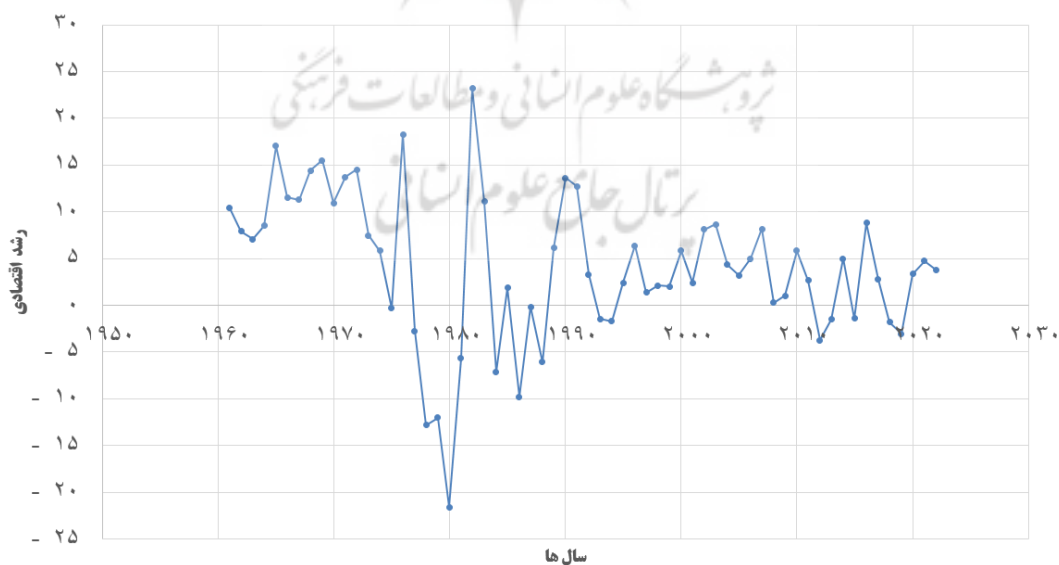


شکل ۲: ساختار مدل ترکیبی پیشنهادی (WANN)

منبع: برگرفته از (Debnath & Shah, 2017)

۴. یافته‌های پژوهش

در این مقاله از داده‌های نرخ رشد اقتصادی برای یک دوره تقریباً ۶۲ ساله از ۱۹۶۱ تا ۲۰۲۲ به‌عنوان داده‌های ورودی مدل انتخاب شده است. ۷۰ درصد از این داده‌ها برای آموزش (۴۳ سال) و ۳۰ درصد باقی‌مانده برای آزمون (۱۹ سال) به‌صورت تصادفی انتخاب شده‌اند. این تقسیم‌بندی متداول در ادبیات علمی است که به‌منظور ارزیابی عمومی‌تر عملکرد مدل و کاهش احتمال وقوع بیش‌برازش انجام می‌شود. نمودار شاخص رشد اقتصادی ایران در شکل (۳) نمایش داده شده است:



شکل ۳: نمودار نرخ رشد اقتصادی ایران ۱۹۶۱-۲۰۲۲

در مرحله اول، یک شبکه عصبی پرسپترون چندلایه بدون هیچ‌گونه پردازش خاصی بر روی داده‌ها آموزش داده شده است. شبکه‌های پرسپترون چندلایه به‌عنوان یکی از مدل‌های پرکاربرد در حوزه مدل‌سازی و پیش‌بینی عناصر اقتصادی شناخته می‌شوند. در این نوع شبکه‌ها، هر نرون در هر لایه به تمام نرون‌های لایه قبل متصل است. در طراحی یک شبکه عصبی پرسپترون، تعداد نرون‌های ورودی، تعداد لایه‌های پنهان و نرون‌های پنهان، و تعداد نرون‌های خروجی مشخص می‌شوند. در این مقاله، ۶ وقفه سری زمانی از نرخ رشد اقتصادی به‌عنوان ورودی استفاده شده‌اند. انتخاب ۶ وقفه سری زمانی بر اساس مطالعات پیشین و تجربه‌های عملی در مدل‌سازی رشد اقتصادی انجام شده است که نشان می‌دهد این تعداد وقفه به طور مؤثر ویژگی‌های زمان‌بندی گذشته را مدل کرده و از پیچیدگی اضافی در مدل جلوگیری می‌کند، همچنین با استفاده از معیارهای آماری همچون AIC و BIC، این تعداد وقفه به طور بهینه انتخاب شده است. با توجه به محدودیت‌های شبکه عصبی در مواجهه با داده‌های ناماننا، برای ارزیابی مانایی سری زمانی مورد مطالعه، از آزمون دیکی فولر تعمیم‌یافته استفاده شده است. نتایج آزمون (ADF) بر اساس ضوابط شوارز بیزین نشان می‌دهد که سری زمانی متغیر نرخ رشد اقتصادی در حالت با روند مانا است، بنابراین استفاده از شبکه‌های عصبی مصنوعی برای پیش‌بینی مشکلی ایجاد نمی‌کند.

جدول ۲: نتایج آزمون ریشه واحد دیکی فولر

متغیر	آماره ADF	مقادیر بحرانی (در سطح ۵ درصد)	احتمال
نرخ رشد اقتصادی	-۴/۶۲۶۲	-۲/۹۱۰۰	۰/۰۰۰۴

منبع: نتایج پژوهش

علاوه بر این، به‌منظور بهبود مدل‌سازی، تمام داده‌های ورودی و هدف در بازه [۱, ۱] نرمال شده‌اند. انتخاب تعداد لایه‌های پنهانی مسئله بسیار حیاتی است؛ زیرا تعداد زیاد این لایه‌ها می‌تواند عملکرد شبکه را کاهش دهد (Uzair, 2020). از نظر تئوری، یک شبکه عصبی با دولایه پنهان قادر است هر تابع غیرخطی را با یک درجه دلخواه دقت تخمین بزند؛ بنابراین، دلیلی برای استفاده از شبکه‌های عصبی با بیش از دولایه پنهان وجود ندارد. ثابت شده است که تنها یک‌لایه پنهان برای تقریب هر شبکه عصبی پیچیده و غیرخطی با هر میزان دقت کافی است؛ بنابراین، شبکه عصبی مورد استفاده در این مدل نیز تنها یک‌لایه پنهان دارد (Tej, 2018).

مسئله مهم دیگر انتخاب تعداد بهینه نرون‌های پنهان در شبکه‌های عصبی است. اگر تعداد نرون‌ها خیلی کم باشد، سیستم دچار خطای آموزش می‌شود و خطای زیاد تعمیم‌سازی در رابطه با کم‌برازشی روی خواهد داد. در مقابل، اگر تعداد نرون‌های پنهان خیلی زیاد باشد، مدل ممکن است خطای آموزش کمی داشته باشد، ولی خطای تعمیم‌سازی زیادی در رابطه با بیش‌برازشی خواهد داشت. برخی پژوهش‌ها ادعا کرده‌اند که اگر تعداد نرون‌های ورودی I باشد، تعداد نرون‌های پنهان نباید بیش از 2I باشد. همچنین ادعا شده است تعداد نرون‌های پنهان برابر با 2I+1 است بنابراین، در این مدل، تعداد نرون‌های پنهان از ۱ تا ۱۳ افزایش یافته است. تعداد نرون‌های خروجی بستگی به موضوع مورد مطالعه دارد و برای مسئله پیش‌بینی سری زمانی، تعداد نرون‌های خروجی برابر با ۱ در نظر گرفته شده است (Shafil, 2006).

بنابراین، از آنجاکه قاعده مشخصی برای تعیین تعداد نرون‌های ورودی و پنهان وجود ندارد، توجه به یک روش آزمون و خطا برای انتخاب بهترین ترکیب ضروری است. به این منظور، کد مربوط به آموزش و آزمون شبکه عصبی در نرم‌افزار Matlab به نحوی نوشته شده است که ابتدا با یک ورودی و تعداد نرون‌های متفاوت (از ۱ تا ۱۳)، شبکه آموزش و آزمون می‌شود و تعداد نرون پنهان بهینه که مرتبط با کمترین RMSE است، گزارش می‌شود. این فرایند با تغییر تعداد نرون‌های ورودی تکرار می‌شود تا بهترین ترکیب انتخاب شود. جدول ۳ فرایند شبکه عصبی و نرون‌ها را به صورت زیر نشان می‌دهد.

جدول ۳: نتایج عملکرد شبکه عصبی با تعداد نرون ورودی و پنهان مختلف

تعداد نرون ورودی	تعداد نرون پنهان	RMSE	
		آموزش	آزمون
۱	۲	۷/۳۲۳۶	۶/۷۵۹۴
۲	۲	۴/۹۲۸۳	۲/۲۰۹۰
۳	۳	۴/۰۳۵۰	۱/۴۱۰۳
۴	۳	۳/۲۵۵۳	۱/۳۹۴۹
۵	۴	۲/۶۳۰۶	۲/۲۵۷۵
۶	۶	۲/۲۷۰۰	۲/۱۰۴۱

منبع: نتایج پژوهش

باتوجه به معیار RMSE، بهترین عملکرد مدل با ترکیبی از ۴ نرون در لایه ورودی، ۳ نرون در لایه پنهان، و ۱ نرون در لایه خروجی (۴-۳-۱) حاصل می‌شود. در این حالت، مقدار RMSE برابر با ۱/۳۹۴۹ است.

۴-۱. برازش مدل ترکیبی تبدیل موجک و شبکه عصبی

مراحل برآوردی مدل ترکیبی تبدیل موجک و شبکه عصبی (WANN) به صورت زیر در نرم‌افزار Matlab انجام شد:

ورودی‌های مدل: سری‌های زمانی رشد اقتصادی ابتدا به وسیله موجک دابیشز تجزیه شدند. تعداد سطوح تجزیه (L) با تعداد داده‌های سری زمانی N بر اساس فرمول زیر تعیین شد:

$$L = \text{int}[\log(N)] \quad (14)$$

که مقدار آن برابر با ۳ به دست آمد. خروجی فرایند تجزیه شامل ضرایب جزئیات (D1, D2, D3) و تقریب (A3) است. این ضرایب به عنوان ورودی به شبکه عصبی استفاده شدند.

مراحل برآورد: ابتدا سری زمانی اصلی با استفاده از موجک دابیشز به سه سطح تجزیه شد. سپس ضرایب جزئیات و تقریب، پس از حذف نویز، به شبکه عصبی پرسپترون چندلایه (MLP) وارد شدند. برای شبکه عصبی از یک لایه پنهان با تعداد نرون‌های بهینه که بر اساس الگوریتم سعی و خطا انتخاب شده‌اند استفاده شد. تابع فعال‌سازی در این شبکه از نوع سیگموئید بوده و الگوریتم بهینه‌سازی آدام (Adam) برای آموزش مدل به کار گرفته شده است. در نهایت، پیش‌بینی شبکه بر اساس ضرایب وزنی بهینه محاسبه شد.


تحلیل نتایج: برای ارزیابی مدل ترکیبی، مقایسه‌ای با مدل شبکه عصبی ساده (بدون تبدیل موجک) انجام شد. نتایج نشان داد که استفاده از تبدیل موجک منجر به بهبود دقت پیش‌بینی با کاهش خطاهای مدل (MSE و RMSE) شده است. این تحلیل به تفصیل در بخش نتایج آمده است.

مزایا و معایب روش ترکیبی: جدولی برای توضیح مزایا و معایب روش ترکیبی موجک و شبکه عصبی (WANN) در مقایسه با شبکه عصبی ساده اضافه شد (جدول شماره ۴). این جدول به خواننده کمک می‌کند تا دلایل استفاده از این روش ترکیبی به‌وضوح درک شود.

جدول ۴: مقایسه مزایا و معایب روش‌ها

معایب	مزایا	روش
حساسیت به نویز در داده‌ها؛ نیاز به داده‌های بزرگ برای آموزش؛ احتمال بیش‌برازش (Overfitting) در مدل؛	توانایی یادگیری الگوهای غیرخطی؛ انعطاف‌پذیری بالا برای مدل‌سازی روابط پیچیده؛ عدم نیاز به توزیع خاص برای داده‌ها؛	شبکه عصبی مصنوعی (ANN)
عدم توانایی در پیش‌بینی و مدل‌سازی مستقل؛ نیاز به انتخاب مناسب موجک و تعداد سطوح تجزیه؛	جداسازی مؤثر نویز و استخراج ویژگی‌های مهم؛ توانایی تحلیل داده‌ها در حوزه زمان-فرکانس؛	تبدیل موجک (WT)
افزایش پیچیدگی محاسباتی؛ نیاز به تنظیم دقیق پارامترهای موجک و ساختار شبکه عصبی؛	ترکیب قدرت پیش‌بینی ANN و قابلیت نویززدایی WT؛ بهبود دقت پیش‌بینی؛ کاهش اثر نویز در داده‌ها؛	مدل ترکیبی (WANN)

منبع: بررسی‌های محقق



شکل ۴: سیگنال نویززدایی شده و جزئیات

منبع: نتایج پژوهش

در این تحقیق، هدف ما نه تنها پیش‌بینی روند رشد اقتصادی با استفاده از مدل‌های پیشرفته مانند ترکیب تبدیل موجک و شبکه عصبی، بلکه تفسیر دقیق این پیش‌بینی‌ها به منظور ارائه تحلیل‌های اقتصادی عمیق و کاربردی بود. به طور خاص، با تفکیک سیگنال رشد اقتصادی به اجزای مختلف مانند روند (a1) و جزئیات (d1) و همچنین بخش S، امکان شناسایی الگوهای بلندمدت، نوسانات کوتاه‌مدت و سیگنال‌های فیلتر شده فراهم شد. این تجزیه و تحلیل به سیاست‌گذاران کمک می‌کند تا تصمیمات بهتری در مواجهه با نوسانات اقتصادی و پیش‌بینی رشد در آینده اتخاذ کنند.

a1 نمایانگر روند کلی رشد اقتصادی است که بیشتر تحت تأثیر سیاست‌های کلان و تغییرات جهانی است، در حالی که d1 جزئیات نوسانات کوتاه‌مدت و اثرات بحران‌های اقتصادی را نمایان می‌کند. بخش S که معمولاً نمایانگر سیگنال نویز زدایی شده است، به ما کمک می‌کند تا اثرات واقعی و خالص رشد اقتصادی را بدون تأثیرات نویز و نوسانات غیرضروری شبیه‌سازی کنیم. این اطلاعات می‌تواند به تحلیل دقیق‌تر شرایط اقتصادی و اتخاذ سیاست‌های مناسب در سطح کلان اقتصادی کمک کند.

در اینجا، a1 روند کلی رشد اقتصادی را نشان می‌دهد که بیشتر تحت تأثیر شروط اقتصادی جهانی و سیاست‌های کلان قرار دارد، در حالی که d1 جزئیات نوسانات کوتاه‌مدت و اثرات بحران‌های اقتصادی مقطعی را مشخص می‌کند. بخش S به عنوان سیگنال تمیز شده نمایانگر سیگنال واقعی و بدون نویز است که می‌تواند به سیاست‌گذاران کمک کند تا درک بهتری از روند واقعی اقتصاد پیدا کنند و تصمیمات دقیق‌تری بگیرند.

بنابراین، هدف اصلی این تحقیق تنها ارائه یک مدل ریاضی نبود، بلکه تبدیل نتایج آن به داده‌های قابل استفاده و کاربردی برای تصمیم‌گیران اقتصادی و تحلیلگران است. با تفکیک دقیق سیگنال‌ها به اجزای مختلف، از جمله بخش S که به ما امکان حذف نویز و مشاهده سیگنال واقعی را می‌دهد، می‌توانیم تحلیل‌های بسیار عمیق‌تری در مورد شرایط اقتصادی ارائه دهیم.

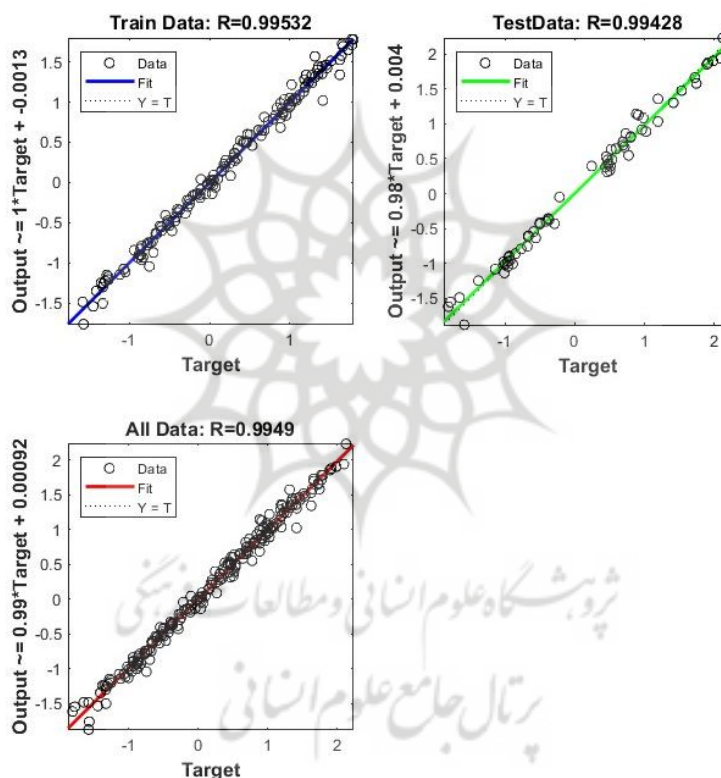
همانند مدل شبکه عصبی ابتدا با یک ورودی و تعداد نرون‌های متفاوت (از ۱ تا ۱۳) شبکه آموزش آزمون می‌شود و تعداد نرون پنهان بهینه مربوط به کمترین RMSE گزارش می‌شود این روند با تعداد نرون‌های ورودی متفاوت تکرار می‌شود. جدول (۵) عملکرد شبکه عصبی با تعداد نرون ورودی و پنهان مختلف را نشان می‌دهد. بر اساس معیار RMSE برای داده‌های آموزش و آزمون بهترین عملکرد دارای ۴ نرون در لایه ورودی ۴ نرون در لایه پنهان و ۱ نرون در لایه خروجی (۱-۴-۴) است که در این حالت RMSE داده‌های آزمون برابر با ۱/۰۴۱۹ است.

با مقایسه نتایج عملکرد دو مدل (مقایسه جدول ۳ و ۵) به طور کلی مشاهده می‌شود عملکرد مدل ترکیبی تبدیل موجک و شبکه عصبی در مقایسه با مدل شبکه عصبی بهبود یافته است. این نتایج نشان‌دهنده اثر مثبت نویز زدایی داده‌های ورودی با استفاده از تبدیل موجک بر نتایج مدل شبکه عصبی است. به ویژه، نویز زدایی باعث کاهش خطاهای پیش‌بینی شده (کاهش RMSE) و دقت بیشتر پیش‌بینی‌ها در بخش‌های مختلف اقتصادی می‌شود. این بهبود در عملکرد مدل ترکیبی می‌تواند به تصمیم‌گیری‌های اقتصادی دقیق‌تر در خصوص پیش‌بینی رشد اقتصادی و تحلیل روندهای کلان اقتصادی کمک کند.

جدول ۵: نتایج عملکرد مدل ترکیبی تبدیل موجک و شبکه عصبی با تعداد نرون ورودی و پنهان مختلف

تعداد نرون ورودی	تعداد نرون پنهان	RMSE	
		آموزش	آزمون
۱	۱	۳/۸۶۵۲	۲/۳۹۵۹
۲	۶	۲/۶۴۶۷	۲/۲۰۹۰
۳	۴	۲/۲۰۸۸	۱/۷۶۷۷
۴	۴	۱/۳۲۱۱	۱/۰۴۱۹
۵	۲	۱/۷۰۵۹	۱/۸۲۵۴
۶	۶	۱/۱۳۱۵	۱/۳۵۳۱

منبع: نتایج پژوهش



شکل ۵: نمودار رگرسیون برآورد شده آموزش، اعتبارسنجی و رگرسیون اصلی

منبع: نتایج پژوهش

جدول ۶: مقایسه مدل شبکه عصبی مصنوعی و WANN

مدل	RMSE
مدل شبکه عصبی ANN	۱/۳۹۴۹
مدل ترکیبی تبدیل موجک و شبکه عصبی WANN	۱/۰۴۱۹

منبع: نتایج پژوهش

جدول ۲ نتایج عملکرد مدل شبکه عصبی را با تعداد نرون‌های مختلف نشان می‌دهد، جایی که مشاهده می‌کنیم با افزایش تعداد نرون‌ها در لایه پنهان و ورودی، خطای مدل کاهش می‌یابد. در جدول ۶، نتایج مدل ترکیبی نشان می‌دهد که با استفاده از ترکیب تبدیل موجک و شبکه عصبی، خطاها به طور قابل توجهی کاهش یافته و دقت مدل در پیش‌بینی رشد اقتصادی بهبود یافته است. این بهبود می‌تواند به سیاست‌گذاران کمک کند تا تحلیل‌های دقیق‌تری از شرایط اقتصادی و پیش‌بینی‌های بهتر برای مدیریت بحران‌ها و نوسانات اقتصادی داشته باشند.

۴-۲. مقایسه صحت پیش‌بینی

به منظور مقایسه صحت پیش‌بینی از آزمون دیبولد - ماریانو^۱ استفاده می‌شود. فرض صفر این آزمون، برابری قدرت پیش‌بینی در هر دو الگو است؛ لذا زمانی که $|DM| > 1.96$ باشد، فرضیه قدرت پیش‌بینی یکسان در سطح ۹۵ درصد رد می‌شود. آماره آزمون دیبولد - ماریانو به صورت رابطه (۱۵) است:

$$DM = \frac{\bar{d}}{\sqrt{\frac{2\pi\hat{f}_d(0)}{T}}} \rightarrow N(0, 1) \quad (15)$$

که در آن $2\pi\hat{f}_d(0)$ برابر با تخمین زن سازگار واریانس مجانبی $\sqrt{T}\bar{d}$ و $L(e_{1,t})$ و $L(e_{2,t})$ به ترتیب مربع (قدر مطلق) توابع زبان ANN و WANN است. آزمون دیبولد - ماریانو را برای خطای پیش‌بینی مدل شبکه عصبی و مدل ترکیبی به کار برده شده برابر $DM=2/0.1845$ به دست آمد؛ بنابراین همان‌طور که نتایج آزمون نشان می‌دهد، در سطح اطمینان ۹۵ درصد قدرت پیش‌بینی مدل ترکیبی بهتر از مدل شبکه عصبی است و آزمون دیبولد - ماریانو صحت پیش‌بینی مدل ترکیبی را تأیید می‌کند.

در این مطالعه، پیش‌بینی نرخ رشد اقتصادی ایران در بازه زمانی ۱۹۶۱ تا ۲۰۲۲ با استفاده از دو مدل مختلف انجام شده است: مدل شبکه عصبی (ANN) و مدل ترکیبی تبدیل موجک و شبکه عصبی (WANN). برای ارزیابی صحت پیش‌بینی‌ها، نتایج پیش‌بینی شده توسط مدل‌های مختلف با داده‌های واقعی نرخ رشد اقتصادی ایران مقایسه شدند. این مقایسه‌ها در جداول و نمودارهای مقاله آورده شده‌اند تا نشان‌دهنده میزان تطابق پیش‌بینی‌ها با واقعیت باشند. در این زمینه، نتایج نشان می‌دهند که مدل ترکیبی تبدیل موجک و شبکه عصبی نسبت به مدل شبکه عصبی منفرد توانسته است پیش‌بینی‌های دقیق‌تری در طول زمان ارائه دهد. این تفاوت‌ها به‌ویژه در سال‌های اخیر که تغییرات عمده‌ای در شرایط اقتصادی ایران رخ داده است، مشهود است.

انتخاب دقیق مدل: مدل‌های شبکه عصبی (ANN) و ترکیبی تبدیل موجک و شبکه عصبی (WANN) به دلیل توانایی آن‌ها در شبیه‌سازی الگوهای پیچیده داده‌های زمانی و برخورد با نویز در داده‌ها، به‌عنوان مدل‌های اصلی این مطالعه انتخاب شدند. انتخاب دقیق این مدل‌ها بر اساس بررسی‌های مقدماتی و آزمون‌های مختلف آماری انجام شده است تا اطمینان حاصل شود که مدل‌های انتخابی، مناسب‌ترین گزینه‌ها برای پیش‌بینی نرخ رشد اقتصادی ایران هستند.

مقایسه پیش‌بینی‌ها با داده‌های واقعی: برای ارزیابی صحت پیش‌بینی‌ها، نتایج پیش‌بینی مدل‌ها با داده‌های واقعی مقایسه شد. نتایج این مقایسه‌ها در جداول و نمودارهای مقاله نشان‌دهنده میزان تفاوت پیش‌بینی‌ها و داده‌های واقعی هستند. به‌ویژه مدل ترکیبی، توانسته است پیش‌بینی‌های دقیق‌تری ارائه دهد و این موضوع به‌ویژه در دوره‌هایی که تغییرات اقتصادی قابل‌توجهی در کشور رخ داده است، مشهود است. این مقایسه نشان می‌دهد که مدل ترکیبی در پیش‌بینی رشد اقتصادی ایران عملکرد بهتری داشته است.

آزمون دیبولد - ماریانو: برای مقایسه دقت پیش‌بینی‌های مدل‌ها، آزمون دیبولد - ماریانو به کار گرفته شد. نتایج این آزمون نشان‌دهنده برتری مدل ترکیبی (WANN) در پیش‌بینی نرخ رشد اقتصادی ایران با آماره DM بود که در سطح اطمینان ۹۵ درصد برتری این مدل تأیید شد.

باتوجه‌به نتایج پیش‌بینی و مقایسه آن‌ها با داده‌های واقعی و همچنین نتایج آزمون دیبولد - ماریانو، مدل ترکیبی تبدیل موجک و شبکه عصبی به طور کلی توانسته است پیش‌بینی دقیق‌تری از نرخ رشد اقتصادی ایران ارائه دهد. در آینده، ارزیابی‌های بیشتر می‌تواند به بهبود دقت پیش‌بینی‌ها کمک کند، به‌ویژه در شرایط متغیر اقتصادی.

به‌منظور تأکید بر استحکام مدل‌ها (Robustness check)، پیش‌بینی نرخ رشد اقتصادی ایران با استفاده از مدل‌های مختلف انجام شد. در اینجا علاوه بر مدل‌های شبکه عصبی مصنوعی و WANN، مدل‌های دیگری نظیر ARIMA و XGBoost نیز برای مقایسه به کار گرفته شده‌اند.

مقایسه نتایج پیش‌بینی: در جدول زیر، نتایج مقایسه‌ای از پیش‌بینی نرخ رشد اقتصادی با استفاده از مدل‌های مختلف آورده شده است. این نتایج شامل RMSE و DM است که نشان‌دهنده تفاوت دقت پیش‌بینی‌ها برای هر مدل است.

جدول ۷: آزمون استحکام مدل‌ها

مدل	آزمون (RMSE)	آزمون دیبولد - ماریانو (DM)
مدل شبکه عصبی (ANN)	۶/۷۵۶۴	-
مدل ترکیبی (WANN)	۲/۳۹۵۹	۲/۰۱۸۴۵
مدل ARIMA	۳/۲۱۲۳	۱/۶۵۲۳
مدل XGBoost	۲/۴۳۸۹	۲/۰۴۱۲

منبع: نتایج پژوهش

مقایسه نتایج نشان می‌دهد که مدل ترکیبی تبدیل موجک و شبکه عصبی (WANN) بهترین دقت پیش‌بینی را در مقایسه با سایر مدل‌ها داشته است. این مدل نه تنها از لحاظ RMSE عملکرد بهتری نسبت به مدل‌های دیگر داشته، بلکه آزمون دیبولد - ماریانو نیز این برتری را تأیید می‌کند. از سوی دیگر، مدل‌های XGBoost و ARIMA نیز عملکرد قابل‌قبولی ارائه دادند، اما نسبت به مدل ترکیبی نتایج ضعیف‌تری را نشان دادند.

۵. نتیجه‌گیری و پیشنهادها

رشد اقتصادی به‌عنوان عنصری استراتژیک مطرح است؛ بنابراین، پیش‌بینی رشد اقتصادی اجتناب‌ناپذیر است تاکنون مدل‌های متفاوت و گوناگونی برای پیش‌بینی رشد اقتصادی ارائه شده که تلاش همه مدل‌ها پیش‌بینی با خطای کمتر بوده است. در این مقاله با فرض اینکه اطلاعات بسیاری در رشد اقتصادی نهفته است که می‌توان آن‌ها را با بهره‌گیری از تبدیل موجک استخراج کرد، تلاش شده با استفاده از مدل ترکیبی تبدیل موجک و شبکه عصبی الگوی مناسب‌تری برای پیش‌بینی دقیق رشد اقتصادی در مقایسه با مدل‌های پیشین ارائه کرد. برای این منظور ابتدا سری‌های زمانی رشد اقتصادی به‌وسیله تبدیل موجک تجزیه شد و بر اساس ضریب همبستگی بین ضرایب تجزیه شده (تقریباً و جزئیات) و سری زمانی رشد اقتصادی، ضرایب جزئیات مؤثر تشخیص داده شد. سپس مجموع ضرایب تقریباً و جزئیات مؤثر (به‌عنوان ورودی شبکه عصبی) استفاده شد. نتایج حاکی از آن است که بر اساس معیار خطای پیش‌بینی RMSE عملکرد مدل ترکیبی تبدیل موجک و شبکه عصبی در مقایسه با مدل شبکه عصبی بهبود یافته است. این نتیجه بیانگر این است که نوپزدایی داده‌های ورودی توسط موجک اثر درخور توجهی بر نتایج مدل شبکه عصبی داشته است. در پایان آزمون دیبولد - ماریانو نیز این نتیجه را تأیید کرده است. یافته‌های اخیر استحکام نتایج قبلی از جمله مطالعات وگل و همکاران (۲۰۲۲)، شاه و دبنت (۲۰۱۷)، شبری و روهیدا (۲۰۱۴)، راعی و همکاران (۱۳۹۴)، محمدی و همکاران (۱۳۹۶) و عباسی نژاد و محمدی (۱۳۸۶) را فراهم می‌کند. این پژوهشگران پیش‌تر مدل ترکیبی تبدیل موجک و شبکه عصبی را برای پیش‌بینی متغیرهایی همچون اختلاف بازده، قیمت انرژی، شاخص قیمت بورس سهام و نرخ ارز مورد استفاده قرار داده بودند. در پایان پیشنهادها زیر ذکر می‌شود:

بهبود دقت پیش‌بینی‌های اقتصادی: بر اساس نتایج این تحقیق، ترکیب تبدیل موجک (Wavelet Transform) با شبکه عصبی مصنوعی (ANN) به طور قابل توجهی دقت پیش‌بینی رشد اقتصادی را در مقایسه با مدل‌های پیشین افزایش داده است؛ بنابراین، پیشنهاد می‌شود که سیاست‌گذاران اقتصادی و بانک‌های مرکزی از این مدل ترکیبی برای پیش‌بینی متغیرهای کلیدی اقتصادی مانند تولید ناخالص داخلی (GDP)، نرخ تورم، و نرخ بیکاری استفاده کنند. به‌ویژه در شرایط عدم قطعیت و تغییرات ناگهانی در اقتصاد، این مدل می‌تواند ابزار مفیدی برای تصمیم‌گیری‌های بلندمدت و کوتاه‌مدت باشد.

کاربرد مدل‌های ترکیبی در پیش‌بینی‌های اقتصادی بلندمدت: نتایج این تحقیق نشان می‌دهد که مدل‌های ترکیبی به‌ویژه در پیش‌بینی‌های بلندمدت مؤثرتر هستند، زیرا قادرند اطلاعات پیچیده و نویز موجود در داده‌ها را بهتر استخراج و فیلتر کنند. به طور خاص، در پیش‌بینی نرخ رشد اقتصادی در افق‌های زمانی بلندمدت، استفاده از این مدل‌ها می‌تواند به دقت بیشتر پیش‌بینی‌ها کمک کند و از تصمیمات اشتباه ناشی از خطای پیش‌بینی جلوگیری کند.

توسعه مدل‌های ترکیبی برای سیاست‌های مالی و اقتصادی: در این تحقیق، مدل ترکیبی تبدیل موجک و شبکه عصبی توانسته است پیش‌بینی دقیق‌تری نسبت به مدل‌های دیگر ارائه دهد. این نتیجه می‌تواند به طور مستقیم در طراحی سیاست‌های مالی و اقتصادی مورد استفاده قرار گیرد. برای مثال، با استفاده از این مدل

می‌توان تأثیر تغییرات در سیاست‌های پولی، نرخ‌های بهره و قیمت نفت را بر رشد اقتصادی پیش‌بینی کرد و از این طریق به سیاست‌گذاران ابزار بهتری برای تصمیم‌گیری ارائه داد.

کاربرد در پیش‌بینی‌های اقتصاد کلان: مدل ترکیبی می‌تواند در پیش‌بینی متغیرهای کلان اقتصادی، مانند رشد اقتصادی، نرخ تورم، و نرخ بیکاری در کشورهای در حال توسعه نیز کاربرد داشته باشد. به‌ویژه برای کشورهای مانند ایران که در آن‌ها داده‌های اقتصادی به طور مرتب دچار تغییرات ناگهانی می‌شود، استفاده از مدل‌های ترکیبی می‌تواند پیش‌بینی‌های دقیق‌تری ارائه دهد که به تصمیم‌گیرندگان در زمان‌های بحرانی کمک می‌کند. پیشنهاد برای تحقیقات آتی: این مطالعه نشان داد که مدل‌های ترکیبی می‌توانند در پیش‌بینی رشد اقتصادی به طور مؤثری عمل کنند. تحقیقات آتی می‌توانند به بررسی کارایی این مدل‌ها در پیش‌بینی دیگر شاخص‌های اقتصادی مانند نرخ تورم، بیکاری و تولید ناخالص داخلی در کشورهای مختلف بپردازند. همچنین، مقایسه این مدل‌ها با مدل‌های پیچیده‌تر یا داده‌های بزرگ (Big Data) می‌تواند به ارتقا دقت پیش‌بینی‌ها کمک کند.

توضیحات تکمیلی

مشارکت نویسندگان

همه نویسندگان در نگارش مقاله سهم و نقش یکسان داشته‌اند.

تضاد منافع

نویسندگان اعلام می‌کنند که هیچ‌گونه تضاد منافع در این پژوهش وجود ندارد.

حامی مالی

نویسندگان هیچ‌گونه حمایت مالی برای تحقیق، تألیف و انتشار این مقاله دریافت نکرده‌اند.

شناسه اُرکید (ORCID)

<http://orcid.org/0000-0003-3903-5780>

بهاره کرمی



<http://orcid.org/0000-0002-4827-4970>

سعید کیان پور



منابع و مأخذ

حکیمی پور، نادر، فرامرزی، ایوب و عسکری، ابوالفضل. (۱۳۹۸). پیش‌بینی رشد اقتصادی بدون نفت در اقتصاد ایران به تفکیک بخش‌های اقتصادی با استفاده از مدل فازی - عصبی تطبیقی (ANFIS). *نشریه اقتصاد مقداری*، ۱۶(۱)، ۲۵-۴۸. <https://doi.org/10.22055/jqe.2019.22217.1644>

راعی، رضا، محمدی، شاپور و فندرسکی، حنظله. (۱۳۹۴). پیش‌بینی شاخص قیمت بورس سهام با استفاده از شبکه عصبی و تبدیل موجک. *نشریه مدیریت دارایی و تأمین مالی*، ۳(۱)، ۷۴-۵۵. <https://dor.isc.ac/dor/20.1001.1.23831170.1394.3.1.4.4>

شایگانی، بیتا، سلامی، امیر بهداد و خوجیانی، رامین. (۱۳۹۳). مدل پیشنهادی برای پیش‌بینی تولید ناخالص داخلی کاربرد مدل‌های ARIMA، شبکه‌های عصبی و تبدیل موجک. *نشریه دانش مالی تحلیل اوراق بهادار (مطالعات مالی)*، ۷(۲۴)، ۱۴۷-۱۶۲. <https://sanad.iau.ir/Journal/jfksa/Article/803494>

- صالحی سر بیژن، مرتضی. (۱۳۹۵). مدل‌سازی و پیش‌بینی رشد اقتصادی ایران با استفاده از مدل‌های ARIMA، مارکف سوئیچینگ و ANFIS. *نشریه پژوهش‌های رشد و توسعه اقتصادی*، ۶(۲۴)، ۵۵-۶۸.
<https://dor.isc.ac/dor/20.1001.1.22285954.1395.6.24.3.2>
- عباسی نژاد، حسین و محمدی، احمد. (۱۳۸۶). پیش‌بینی نرخ ارز با استفاده از شبکه‌های عصبی و تبدیل موجک. *نشریه مطالعات و سیاست‌های اقتصادی*، ۱۰(۱۱)، ۱۹-۴۲.
https://economic.mofidu.ac.ir/article_47088.html?lang=fa
- قدیمی، محمدرضا و مشیری، سعید. (۱۳۸۱). مدل‌سازی و پیش‌بینی رشد اقتصادی در ایران با استفاده از شبکه‌های عصبی مصنوعی (ANN). *نشریه پژوهش‌های اقتصادی ایران*، ۴(۱۲)، ۹۷-۱۲۶.
https://ijer.atu.ac.ir/article_3831.html
- محمدی، تیمور، تکلیف، عاطفه و زمانی، ساحل. (۱۳۹۶). پیش‌بینی قیمت گاز طبیعی با استفاده از ترکیب تبدیل موجک و شبکه عصبی مصنوعی (مطالعه موردی: بازار آمریکا). *نشریه پژوهش‌های اقتصادی ایران*، ۲۲(۷۱)، ۱-۲۶.
<https://doi.org/10.22054/ijer.2017.8277>
- هاشمی دیزج، عبدالرحیم؛ حاضری نیری، هاتف و پوروحدانی، رسول. (۱۳۹۹). مقایسه عملکرد مدل‌های شبکه عصبی مصنوعی برای پیش‌بینی نرخ ارز در ایران. *مطالعات و سیاست‌های اقتصادی*، ۷(۲)، ۵۳-۸۰.
<https://doi.org/10.22096/esp.2020.43397>

References

- Abbasi Nejad, H., & Mohammadi, A. (2007). Forecasting exchange rate using neural networks and wavelet transform. *The Journal of Economic Studies and Policies*, 0(11), 19-42.
https://economic.mofidu.ac.ir/article_47088.html?lang=en [In Persian]
- Al Wadia, M. T. I. S., & Ismail, M. T. (2011). Selecting wavelet transforms model in forecasting financial time series data based on ARIMA model. *Applied Mathematical Sciences*, 5(7), 315-326. (URL of Article)
- Alexandridis, A. K., & Zapranis, A. D. (2013). Wavelet neural networks: A practical guide. *Neural Networks*, 42, 1-27. <https://doi.org/10.1016/j.neunet.2013.01.008>
- Billings, S. A., & Wei, H. L. (2005). A new class of wavelet networks for nonlinear system identification. *IEEE Transactions on neural networks*, 16(4), 862-874.
<https://doi.org/10.1109/TNN.2005.849842>
- Cao, L., Hong, Y., Fang, H., & He, G. (1995). Predicting chaotic time series with wavelet networks. *Physica D: Nonlinear Phenomena*, 85(1-2), 225-238. [https://doi.org/10.1016/0167-2789\(95\)00119-0](https://doi.org/10.1016/0167-2789(95)00119-0)
- Chaudhary, S., & Upreti, D. (2023). *Hybrids ARIMA-ANN models for GDP forecasting in Nepal*. NRB Working Paper No. 56. (URL of Article)
- Chuku, C., Simpasa, A., & Oduor, J. (2019). Intelligent forecasting of economic growth for developing economies. *International Economics*, 159, 74-93.
<https://doi.org/10.1016/j.inteco.2019.06.001>
- Clements, M., & Hendry, D. (2002). An overview of economic forecasting. A Companion to Economic Forecasting. *Oxford: Blackwell*, 1-18. <https://doi.org/10.1002/9780470996430>
- Cody, M. A. (1994). The wavelet packet transform: Extending the wavelet transform. *Dr. Dobb's Journal*, 19, 44-46. (URL of Article)
- Conlon, T., Crane, M., & Ruskin, H. J. (2008). Wavelet multiscale analysis for hedge funds: Scaling and strategies. *Physica A: Statistical Mechanics and its Applications*, 387(21), 5197-5204.
<https://doi.org/10.1016/j.physa.2008.05.046>

- da Costa, K. V. S., da Silva, F. L. C., & da Silva Cordeiro, J. (2021). Time Series Models Combination for Forecasting Quarterly GDP Components by the Expenditure Side. *Trabalho apresentado em Anais do LIII Simpósio Brasileiro de Pesquisa Operacional*. <http://dx.doi.org/10.59254/sbpo-2021-131469>
- Debnath, L., & Shah, F. (2017). *Lecture notes on wavelet transforms*. Springer. <https://doi.org/10.1007/978-3-319-59433-0>
- Fang, Y., & Chow, T. W. (2006, May). Wavelets based neural network for function approximation. In *International symposium on neural networks* (pp. 80-85). Berlin, Heidelberg: Springer Berlin Heidelberg. https://doi.org/10.1007/11759966_12
- Feng, L., & Zhang, J. (2014). Application of artificial neural networks in tendency forecasting of economic growth. *Economic Modelling*, 40, 76-80. <https://doi.org/10.1016/j.econmod.2014.03.024>
- Ghadimi, M. R., & Moshiri, S. (2002). Modeling and forecasting economic growth in Iran using artificial neural networks (ANN). *Iranian Economic Research*, 4(12), 97-125. (URL of Article) [In Persian]
- Hakimipour, N., Faramarzi, A., & Askari, A. (2019). Predicting non-oil economic growth in Iran by economic sectors using the adaptive neuro-fuzzy inference system (ANFIS). *Journal of Quantitative Economics*, 16(1), 25-48. <https://doi.org/10.22055/jqe.2019.22217.1644> [In Persian].
- HameedAshour, M. A., & Ahmed, A. S. (2024, August). Forecasting Iraqi GDP Using Artificial Intelligence. In *2024 IEEE 15th Control and System Graduate Research Colloquium (ICSGRC)* (pp. 97-101). IEEE. <https://doi.org/10.1109/ICSGRC62081.2024.10691310>
- Hashemi Dizaj, H., Hazari Niri, H., & Pourvahdani. (2020). Comparing the performance of artificial neural network models for forecasting exchange rates in Iran. *Semi-annual Journal of Economic Studies and Policies*, 7(2), 53-80. <https://doi.org/10.22096/esp.2020.43397> [In Persian].
- Hawkins, J. (2005). Economic forecasting: history and procedures. *Economic Round-up*, (Autumn 2005), 1-10 (URL of Article)
- Heravi, S., Osborn, D. R., & Birchenhall, C. R. (2004). Linear versus neural network forecasts for European industrial production series. *International Journal of forecasting*, 20(3), 435-446. [https://doi.org/10.1016/S0169-2070\(03\)00062-1](https://doi.org/10.1016/S0169-2070(03)00062-1)
- Isa, N. M., & Shabri, A. (2013, September). A hybrid group method of data handling with discrete wavelet transform for GDP forecasting. In *AIP Conference Proceedings (Vol. 1557, No. 1, pp. 566-570)*. American Institute of Physics. <https://doi.org/10.1063/1.4823978>
- Jahn, M. (2018). *Artificial neural network regression models: Predicting GDP growth* (No. 185). HWWI Research Paper. <https://hdl.handle.net/10419/182108>
- Jordan, M. I., & Mitchell, T. M. (2015). Machine learning: Trends, perspectives, and prospects. *Science*, 349(6245), 255-260. <https://doi.org/10.1126/science.aaa8415>
- Khayamian, T., Ensafi, A. A., Tabaraki, R., & Esteki, M. (2005). Principal Component-Wavelet Neural Networks as a New Multivariate Calibration Method. *Analytical Letters*, 38(9), 1477-1489. <https://doi.org/10.1081/AL-200062265>
- Kingma, D. P., & Ba, J. (2015). Adam: A method for stochastic optimization. *3rd International Conference for Learning Representations (ICLR)*, San Diego. arXiv. <https://doi.org/10.48550/arXiv.1412.6980>

- Kuan, C. M., & White, H. (1994). Artificial neural networks: An econometric perspective. *Econometric reviews*, 13(1), 1-91. <https://doi.org/10.1080/07474939408800273>
- Logubayom, I. A., Nasiru, S., & Luguterah, A. (2013). Modelling the rate of treasury bills in Ghana. *Mathematical Theory and Modeling*, 3(4). ([URL of Article](#))
- Maasoumi, E., Khotanzed, A., & Abaye, A. (1994). Artificial neural networks for some macroeconomic series: a first report. *Econometric Reviews*, 13(1), 105-122. <https://doi.org/10.1080/07474939408800276>
- Matta, C., Bianchesi, N., Oliveira, M., Balestrassi, P., & Leal, F. (2021). A comparative study of forecasting methods using real-life econometric series data. *Production*, 31, e20210043. <http://dx.doi.org/10.1590/0103-6513.20210043>
- Mohammadi, T., Taklif, Z., & Sahel. (2017). Forecasting natural gas prices using a hybrid model of wavelet transform and artificial neural network (Case study: U.S. market). *Iranian Economic Research*, 22(71), 1-26. <https://doi.org/10.22054/ijer.2017.8277> [In Persian]
- Nason, G. P., & Sachs, R. V. (1999). Wavelets in time-series analysis. *Philosophical transactions of the royal society of London. Series A: Mathematical, Physical and Engineering Sciences*, 357(1760), 2511-2526. <https://doi.org/10.1098/rsta.1999.0445>
- Nelson, C. R., & Plosser, C. R. (1982). Trends and random walks in macroeconomic time series: some evidence and implications. *Journal of monetary economics*, 10(2), 139-162. [https://doi.org/10.1016/0304-3932\(82\)90012-5](https://doi.org/10.1016/0304-3932(82)90012-5)
- Perron, P. (1989). The great crash, the oil price shock, and the unit root hypothesis. *Econometrica: journal of the Econometric Society*, 1361-1401. <https://doi.org/10.2307/1913712>
- Raei, R., Mohammadi, S., & Fandreski, H. (2015). Predicting stock price index using neural network and wavelet transform. *Asset Management and Financing*, 3(1), 55-74. <https://dor.isc.ac/dor/20.1001.1.23831170.1394.3.1.4.4> [In Persian]
- Rostan, P., & Rostan, A. (2018). Forecasting Spanish GDPs with spectral analysis. *Studies of Applied Economics*, 36(1), 217-234. <https://doi.org/10.25115/eea.v36i1.2526>
- Salehi Sarbijan, M. (2016). Modeling and forecasting Iran's economic growth using ARIMA, Markov-switching, and ANFIS models. *Growth and Economic Development Research*, 6(24), 55-68. <https://dor.isc.ac/dor/20.1001.1.22285954.1395.6.24.3.2> [In Persian].
- Shabri, A., & Samsudin, R. (2014). Daily crude oil price forecasting using hybridizing wavelet and artificial neural network model. *Mathematical Problems in Engineering*, 2014(1), 201402. <https://doi.org/10.1155/2014/201402>
- Shafil, I., Ahmad, J., Shah, S. I., Mieee, S., & Kashif, F. M. (2006). Impact of varying neurons and hidden layers in neural network architecture for a time frequency application. *2006 IEEE International Multitopic Conference*. <https://doi.org/10.1109/INMIC.2006.358160>
- Shaygani, B., Salami, A. B., & Khuchiani, R. (2015). The Proposed Model for Prediction of GDP Using With ARIMA, Neural Networks and Wavelet Transform. *Financial Knowledge and Securities Analysis*, 7(24), 147-162. <https://sanad.iau.ir/Journal/jfksa/Article/803494> [In Persian]
- Subasi, A., Alkan, A., Koklukaya, E., & Kiyimik, M. K. (2005). Wavelet neural network classification of EEG signals by using AR model with MLE preprocessing. *Neural networks*, 18(7), 985-997. <https://doi.org/10.1016/j.neunet.2005.01.006>
- Tej, M. L., & Holban, S. (2018). Determining optimal neural network architecture using regression methods. *2018 International Conference on Development and Application Systems (DAS)*. <https://doi.org/10.1109/DAAS.2018.8396093>

- Tkacz, G. (2001). Neural network forecasting of Canadian GDP growth. *International Journal of Forecasting*, 17(1), 57-69. [https://doi.org/10.1016/S0169-2070\(00\)00063-7](https://doi.org/10.1016/S0169-2070(00)00063-7)
- Tümer, A. E., & Akkuş, A. (2018). Forecasting gross domestic product per capita using artificial neural networks with non-economical parameters. *Physica A: Statistical Mechanics and its Applications*, 512, 468-473. <https://doi.org/10.1016/j.physa.2018.08.047>
- Türsoy, T. (2013). Forecasting Economic Growth Rate: The Case of North Cyprus. *Journal of Social Sciences*, 6(1), 193-20. https://www.researchgate.net/publication/260647374_Forecasting_Economic_Growth_Rate_the_Case_of_North_Cyprus
- Uzair, M., & Jamil, N. (2020). Effects of hidden layers on the efficiency of neural networks. *2020 IEEE 23rd International Multitopic Conference (INMIC)*. <https://doi.org/10.1109/INMIC50486.2020.9318195>
- Vogl, M., Rötzel, P. G., & Homes, S. (2022). Forecasting performance of wavelet neural networks and other neural network topologies: A comparative study based on financial market data sets. *Machine Learning with Applications*, 8, 100302. <https://doi.org/10.1016/j.mlwa.2022.100302>
- Yu, Y. (2009). Evaluation of wavelet neural network for predicting financial market crisis. *In 2009 First International Conference on Information Science and Engineering* (pp. 4861-4864). IEEE. <https://doi.org/10.1109/ICISE.2009.567>
- Zhang, G. P., & Qi, M. (2005). Neural network forecasting for seasonal and trend time series. *European journal of operational research*, 160(2), 501-514. <https://doi.org/10.1016/j.ejor.2003.08.037>
- Zhang, Q. (1993). Regressor Selection and Wavelet Network Construction. *Proceedings of 32nd IEEE Conference on Decision and Control*, San Antonio, TX, USA, 1993, pp. 3688-3693 vol.4 <https://doi.org/10.1109/CDC.1993.325905>
- Zhang, Q., & Benveniste, A. (1992). Wavelet networks. *IEEE transactions on Neural Networks*, 3(6), 889-898. <https://doi.org/10.1109/72.165591>
- Zhang, Y., Shang, W., Zhang, N., Pan, X., & Huang, B. (2023). Quarterly GDP forecast based on coupled economic and energy feature WA-LSTM model. *Frontiers in Energy Research*, 11, 1329376. <https://doi.org/10.3389/fenrg.2023.1329376>