ISSN: 2476-6909; Modares. Mech. Eng. *;*(*):*-*

Modares Mechanical Engineering

DOI:
journal homepage: mme.modares.ac.ir

Dynamic Modeling of Industrial Gas Turbine Performance Using NARX Optimal Neural Network Architecture

Hassan Shiri[1*], Morteza Montazeri[2], Mohammad Amin Shalchee[3]

[1] Mechanical Engineering Department, Iran University of Science and Technology, Tehran, Iran
[2] Mechanical Engineering Department, Iran University of Science and Technology, Tehran, Iran
[3] Mechanical Engineering Department, Iran University of Science and Technology, Tehran, Iran

ARTICLE INFO

Article Type
Original Research

Article History
Received: **** **, *
Revised: **** **, *
Accepted: *** **, *
ePublished: **** **, *

ABSTRACT

In this study, the dynamic behavior of the performance parameters of an industrial gas turbine used in natural gas compressor stations is modeled using an optimized Nonlinear Autoregressive network with exogenous inputs (NARX). The modeled performance parameters include the turbine fuel flow rate, compressor air mass flow rate, compressor pressure ratio, generator turbine speed, gas temperature at the generator turbine inlet, and exhaust gas temperature at the power turbine outlet. For each target parameter, an independent neural network was developed with two time-varying feedback inputs—namely the turbine speed and the generated power—and two time-invariant external inputs includes ambient temperature and installation altitude. To determine the optimal architecture of each network, a grid-search-based approach was employed to obtain the most efficient combination of neurons and delays. The training data for the neural networks were generated using a thermodynamic model of the gas turbine implemented in MATLAB Simulink. To validate the developed models, their simulated outputs were compared with experimental and thermodynamic model results. The obtained correlation coefficients (R) for compressor air flow, fuel flow rate, compressor pressure ratio, generator turbine speed, turbine inlet gas temperature, and turbine exhaust gas temperature were 0.981, 0.994, 0.979, 0.934, 0.987, and 0.968, respectively. Furthermore, comparison of the obtained optimal architectures with a similar previous study demonstrated that the proposed models exhibit lower structural complexity and therefore achieve faster computational performance.

Keywords: Industrial Gas Turbine, Dynamic Modeling, Compressor Station, Artificial Neural Networks, Optimum Architecture

How to cite this article
Hassan Shiri, Morteza Montazeri, Mohammad Amin Shalchee, Dynamic Modeling of Industrial Gas Turbine Performance Using NARX Optimal Neural Network Architecture. Modares Mechanical Engineering; *(*): ****-****.

*Corresponding author's email: hassan_shiri@mecheng.iust.ac.ir
*Corresponding ORCID ID: https://orcid.org/0000-0002-0834-2676

Copyright© 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.

Pre-Proof Version

شاپا: ۶۹۰۹-۲۴۷۶؛ مهندسی مکانیک مدرس. *؛*(*):* _*
مهندسی مکانیک مدرس
DOI:
صفحه اصلی مجله: mme.modares.ac.ir

مدل‌سازی دینامیکی عملکرد توربین گاز صنعتی با استفاده از معماری بهینهٔ شبکه عصبی NARX

حسن شیری[۱*]، مرتضی منتظری[۲]، محمدامین شالچی[۳]

[۱] گروه مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران
[۲] گروه مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران
[۳] گروه مهندسی مکانیک، دانشگاه تهران، تهران، ایران

اطلاعات مقاله

نوع مقاله
مقاله پژوهشی

تاریخچه مقاله
دریافت: **/**/****
بازنگری: **/**/****
پذیرش: **/**/****
ارائه آنلاین: **/**/****

چکیده

در این مقاله با استفاده از شبکهٔ عصبی خود پندارهٔ غیرخطی با ورودی خارجی با معماری بهینه، رفتار دینامیکی پارامترهای عملکردی توربین گاز صنعتی که در ایستگاه‌های تقویت فشار گاز استفاده می‌شود، مدل‌سازی شده است. در این مدل‌سازی، پارامترهای عملکردی توربین شامل دبی سوخت مصرفی توربین، دبی هوای ورودی به کمپرسور هوا، نسبت فشار کمپرسور هوا، سرعت توربین ژنراتور، دمای گاز ورودی به توربین ژنراتور و دمای گاز خروجی از توربین توان، به‌عنوان پارامترهای هدف در نظر گرفته شده‌اند؛ به‌طوری‌که برای هر پارامتر هدف، یک شبکهٔ عصبی مجزا با دو ورودی پس‌خور سرعت و توان تولیدی توربین قدرت به‌صورت متغیر با زمان به همراه دو ورودی خارجی شامل دما و ارتفاع از سطح دریا، که نامتغیر با زمان هستند، استخراج گردیده است. به‌منظور تعیین معماری شبکه‌های عصبی، رویکردی برگرفته از روش جستجوی شبکه، اتخاذ شده است تا معماری بهینه برای هرکدام از مدل‌ها حاصل شود. داده‌های موردنیاز برای آموزش شبکه‌های عصبی، با استفاده از مدل ترمودینامیکی توربین گاز در سیمولینک نرم‌افزار متلب استخراج گردید. به‌منظور صحت‌سنجی نتایج، با شبیه‌سازی مدل‌ها بر اساس داده‌های آزمایش، مقدار معیار R در مقایسه با مدل ترمودینامیکی، برای پارامترهای دبی هوای ورودی به کمپرسور، دبی سوخت، نسبت فشار کمپرسور، دور توربین ژنراتور، دمای گاز ورودی به توربین و دمای گاز خروجی از توربین به ترتیب ۰,۹۸۱، ۰,۹۹۴، ۰,۹۷۹، ۰,۹۳۴، ۰,۹۸۷ و ۰,۹۶۸ حاصل شده است. همچنین مقایسه نتایج معماری به‌دست‌آمده با یک پژوهش مشابه دیگر، نشان داد، مدل‌های بهینه حاصل در این مقاله، دارای پیچیدگی کمتر و بنابراین سرعت اجرای بالاتر است.

کلیدواژه‌ها: توربین گاز صنعتی، مدل‌سازی دینامیکی، ایستگاه تقویت فشار، شبکه‌های عصبی مصنوعی، معماری بهینه

نحوه ارجاع به این مقاله
حسن شیری، مرتضی منتظری، محمدامین شالچی، مدل‌سازی دینامیکی عملکرد توربین گاز صنعتی با استفاده از معماری بهینهٔ شبکه عصبی NARX، مهندسی مکانیک مدرس.
* (*): ****-****.

*پست الکترونیکی نویسنده عهده‌دار مکاتبات: hassan_shiri@mecheng.iust.ac.ir
*شناسه ارکید نویسنده عهده‌دار مکاتبات: https://orcid.org/0000-0002-0834-2676

Copyright© 2025, TMU Press. This open-access article is published under the terms of the Creative Commons Attribution-NonCommercial 4.0 International License which permits Share (copy and redistribute the material in any medium or format) and Adapt (remix, transform, and build upon the material) under the Attribution-NonCommercial terms.

Press, Pre Proof Version

۱- مقدمه

توربین‌های گاز صنعتی یکی از مهم‌ترین و اساسی‌ترین تجهیزات بسیاری از صنایع به‌ویژه پتروشیمی، پالایشگاه‌ها، نیروگاه‌ها و خطوط انتقال نفت و گاز می‌باشند که به‌صورت مولد به‌منظور تأمین توان موردنیاز کمپرسورها، پمپ‌ها و یا با اتصال به ژنراتور، به‌منظور تولید انرژی الکتریسیته مورداستفاده قرار می‌گیرند. با توجه به نقش اساسی توربین گاز در سیستم انتقال گاز و لزوم مدل‌سازی و شبیه‌سازی این سیستم به‌منظور پیش‌بینی، شبیه‌سازی تجمیعی، کنترل سیستم و مدیریت در تأمین گاز مصرف‌کننده‌ها، مدل‌سازی توربین گاز پایه‌ترین مسئله برای شروع چنین کارهایی است. مدل‌سازی و شبیه‌سازی موردنیاز در توربین‌های گاز، همانند سایر سیستم‌های دینامیکی، به دو صورت پایا (استاتیکی) و گذرا (دینامیکی) انجام می‌شود. برای این منظور، روش‌های مختلفی مانند مدل مبتنی بر فیزیک، مدل‌های شناسایی سیستم مانند مدل وینر- همرشتاین و مدل‌های شبکه عصبی قابل‌استفاده است [۴-۱]. در این راستا، خدائی مهر و همکارانش، رفتار دینامیکی موتور توربوجت تک‌محوره را بر اساس رویکرد فیزیک محور، مدل‌سازی کردند [۵]. محمدی و منتظری نیز [۶] به کمک مدل وینر، توربین گاز صنعتی را به‌صورت دینامیکی مدل‌سازی کردند. با ظهور قابلیت‌های شبکه‌های عصبی، در مدل‌سازی سیستم‌های مکانیکی نیز از این رویکرد استفاده گردیده است. به‌عنوان نمونه، امیرمحمد و امیرحسین شامخی با استفاده از شبکه عصبی، به مدل‌سازی استاتیکی محفظه احتراق موتور اشتعال جرقه‌ای پرداختند. همچنین در دهۀ اخیر با توجه به توانایی شبکه‌های عصبی در یادگیری رفتار غیرخطی و سری زمانی، مدل‌های دینامیکی مختلفی در زمینۀ توربین گاز به کمک انواع شبکه‌های عصبی صورت گرفته است. ما و همکاران ترکیبی از مدل شبکه عصبی خود پندارۀ غیرخطی با ورودی خارجی (NARX) و میانگین متحرک را برای پیش‌بینی دمای گاز خروجی در توربین‌های گازی پیشنهاد دادند که کاهش خطای پیش‌بینی را نشان داد [۷]. وو و همکاران از شبکه‌های عصبی کانولوشنی (CNN) و شبکه عصبی حافظۀ کوتاه‌مدت طولانی (LSTM) برای مدل‌سازی عملکرد گذرای توربین‌های گازی استفاده کردند که دقت بالایی در پیش‌بینی پارامترهای کلیدی را نشان دادند [۸]. در مقاله‌ای که روبن و همکارانش انجام داده‌اند؛ یک روش سیستماتیک برای طراحی مدل NARX به‌منظور شناسایی و مدل‌سازی رفتار غیرخطی توربین‌های گازی را معرفی کرده‌اند [۹]. در مقاله دیگری، امیرخانی و همکاران از مدل سری- موازی NARX برای شناسایی عیوب توربین گاز MGT-70 استفاده کرده‌اند [۱۰]. ابراهیم و همکارانش به طراحی یک کنترل‌کننده پیش‌بین غیرخطی مبتنی بر مجموعه‌ای از مدل‌های NARX برای کنترل توربین گاز صنعتی مدل Siemens SGT-A65 پرداخته‌اند. این کنترل‌کننده به‌صورت یک مدل پیش‌بینی‌کننده غیرخطی مبتنی بر الگوریتم ساخت اهرام جیزه (Giza Pyramids Construction) طراحی شده است که قادر است پاسخ‌های آینده سیستم را پیش‌بینی کند [۱۱]. در پژوهشی دیگر، از روش NARX برای شناسایی رفتار دینامیکی سیستم و پایش ارتعاشات توربین در شرایط عملیاتی استفاده شده است [۱۲]. پیام و همکارش با استفاده از شبکۀ عصبی NARX به‌عنوان مدلی که قابلیت یادگیری رفتار داده‌های دینامیکی غیرخطی را دارد، به شناسایی پارامترهای خروجی توربین گاز پرداختند و با به‌کارگیری توابع آموزشی مختلف برای نرون‌های لایه میانی و خروجی به این نتیجه رسیدند که تابع آموزشی لونبرگ-مارکوئارت عملکرد بهتری از نظر معیار خطای میانگین مربعات(Mean Square Error) نسبت به سایر توابع آموزشی دارد[۱۳]. در مطالعه‌ای دیگر، السریره و همکاران [۱۴] به مدل‌سازی یک توربین گاز دوگانه‌سوز واقعی با استفاده از شبکه عصبی دینامیکی NARX و شبکه عصبی عمیق کانولوشنی (CNN) پرداختند. در این پژوهش، با به‌کارگیری داده‌های عملیاتی و تنظیم دقیق ساختار شبکه و هایپرپارامترها، رفتار دینامیکی پارامترهایی مانند توان خروجی، سرعت شفت و دمای گاز خروجی با دقت بسیار بالا شبیه‌سازی شد. نتایج نشان داد که هر دو روش NARX و CNN عملکرد رضایت‌بخشی دارند، با این تفاوت که مدل NARX به دلیل بهره‌گیری از بازخورد خروجی‌ها دقت بالاتری در شبیه‌سازی پاسخ‌های گذرا ارائه می‌دهد. این یافته‌ها برتری نسبی مدل‌های دینامیکی مبتنی بر NARX را در شبیه‌سازی دقیق رفتار دینامیکی توربین‌های گازی نشان می‌دهد. همچنین تحقیقات متعددی در زمینۀ بهینه‌سازی معماری شبکه‌های عصبی (NAS) انجام شده است. انتخاب مناسب‌ترین ترکیب از هایپرپارامترها و توپولوژی به‌منظور دستیابی به بهترین عملکرد، از چالش‌های اصلی در طراحی مدل‌های یادگیری عمیق است. در زمینۀ بهینه‌سازی معماری شبکه‌های عصبی روش‌های مختلفی معرفی‌شده‌اند، از جمله جستجوی شبکه، جستجوی تصادفی و الگوریتم ژنتیک که هرکدام مزایا و محدودیت‌های خاص خود را دارند. در پژوهشی که توسط لیاشخینسکی و همکارش صورت گرفته، به مقایسۀ این سه الگوریتم برای جستجوی معماری شبکه‌های عصبی CNN پرداخته شده است و تفاوت‌های عملکردی میان این الگوریتم‌ها بر اساس زمان اجرای الگوریتم‌ها و دقت مدل‌های پیشنهادی نشان داده شد [۱۵]. کاپانوا و همکاران از الگوریتم ژنتیک برای بهینه‌سازی خودکار معماری شبکه‌های عصبی بهره بردند که به کاهش احتمال بیش برازش کمک می‌کند [۱۶]. پاسینی و همکاران یک روش مقیاس‌پذیر ارائه کرده‌اند که با استفاده از جستجوی حریصانه، کمترین تعداد لایه‌ها را برای دستیابی به عملکرد مطلوب شناسایی می‌کند. این الگوریتم در مقایسه با روش‌های بهینه‌سازی هایپرامترهای پیشرفته، دقت پیش‌بینی بالاتر و زمان حل کوتاه‌تری ارائه می‌دهد [۱۷]. در مقاله‌ای دیگر، از الگوریتم کلونی مورچگان برای بهینه‌سازی معماری و عملکرد شبکه‌های عصبی پرسپترون چندلایه (MLP) استفاده شده است [۱۸]. در مقاله‌ای توسط لاداج و همکاران، به توسعه الگوریتم‌هایی برای انتخاب معماری بهینۀ شبکه عصبی بازگشتی (RNN) پرداخته شده است. این الگوریتم‌ها بر پایۀ روش‌های بهینه‌سازی مانند الگوریتم‌های تکاملی و گرادیان نزولی طراحی شده و به‌منظور دستیابی به تعادلی میان اندازۀ شبکه و دقت شبیه‌سازی پاسخ مدل‌های ریاضی راکتور آب تحت‌فشار استفاده شده‌اند [۱۹]. تارون و رَضا از ترکیب روش جستجوی ممنوع و الگوریتم گرادیان نزولی با پس انتشار و مومنتوم، برای بهینه‌سازی همزمان تعداد لایه‌های مخفی و تعداد نرون‌ها در هر لایۀ شبکه عصبی پیش‌خور عمیق استفاده کرده‌اند [۲۰].

توربین‌های گاز صنعتی در شرایط کاری واقعی، تحت تأثیر عوامل متعددی نظیر تغییرات شرایط محیطی، فرسودگی و افت عملکرد قطعات، رفتارهای غیرخطی گذرا و محدودیت‌های سامانه‌های کنترلی قرار دارند. این عوامل سبب می‌شوند مدل‌سازی دینامیکی این سیستم‌ها با پیچیدگی قابل توجهی همراه باشد. از سوی دیگر، مدل‌های ترمودینامیکی دقیق، اگرچه توانایی بالایی در شبیه‌سازی رفتار واقعی توربین دارند، اما معمولاً دارای هزینه محاسباتی بالا بوده و استفاده از آن‌ها را در شبیه‌سازی‌های بلادرنگ، سامانه‌های کنترلی و شبیه‌سازی‌های تجمیعی محدود می‌کند. بنابراین توسعه مدل‌های دینامیکی سبک، سریع و در عین حال دقیق، به یکی از چالش‌های مهم در حوزه مدل‌سازی توربین‌های گاز صنعتی تبدیل شده است. تاکنون در تحقیقات صورت گرفته در زمینۀ مدل‌سازی توربین گاز با شبکه‌های عصبی، بهینه‌سازی معماری انجام نشده است. هدف اصلی در این مقاله، ارائۀ یک مدل از توربین گاز صنعتی بر اساس داده‌های حاصل از مدل ترمودینامیکی آن است که سرعت اجرای بالا و دقت مطلوب در تخمین پارامترهای هدف را داشته و جایگزین مدل ترمودینامیکی با حجم پردازشی بالا، باشد.

۱-۲ شبکه عصبی NARX

به‌طورکلی شبکه‌های عصبی را می‌توان در سه دسته تقسیم‌بندی کرد [۱۹], [۲۳-۲۱]:

۱. شبکه‌های عصبی پیش‌خور (FNNs): در این نوع از شبکه‌ها، ارسال سیگنال فقط در جهت روبه‌جلو و از نرون‌های لایه‌های ابتدایی به لایه‌های بعدی است. شبکه عصبی پرسپترون چندلایه نمونه‌ای از این مدل‌ها است.

۲. شبکه‌های عصبی بازگشتی (RNNs): در ساختار این مدل‌ها برخلاف مدل‌های FNNs، علاوه بر جریان روبه‌جلوی سیگنال، امکان ارسال سیگنال از هر نرون به نرون لایه‌های قبلی و یا حتی خود نرون وجود دارد. همین ویژگی باعث شده که این مدل‌ها حافظه‌مند شده و قابلیت یادگیری ویژگی‌های داده‌های سری زمانی را داشته باشند.

۳. شبکه‌های عصبی سلولی (CeNNs): در چنین شبکه‌هایی، اتصالات نرونی، خاص و محدود به نرون‌هایی در همسایگی نزدیک است. این اتصالات اغلب غیرخطی و با استفاده از سیستمی از معادلات دیفرانسیلی تعریف می‌شوند. یادگیری این مدل‌ها به‌صورت بدون نظارت و معمولاً به روش قانون هب است و برای مسائل خوشه‌بندی می‌توان از آن‌ها استفاده کرد.

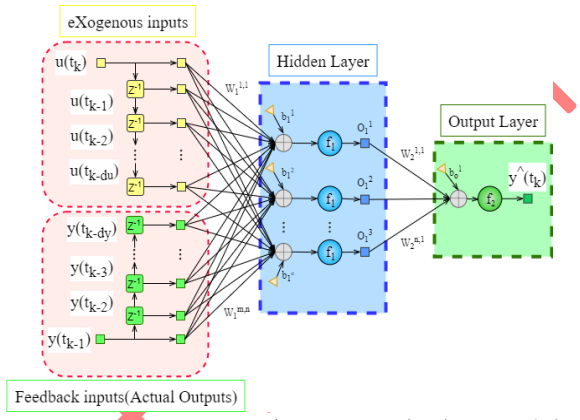
شبکۀ عصبی خود رگرسیون غیرخطی با ورودی خارجی یا NARX مبتنی بر مدل خود رگرسیون خطی با ورودی خارجی (ARX) بوده و جزو دستۀ شبکه‌های عصبی بازگشتی(RNN) با قابلیت پذیرش چندین لایۀ پنهان است. بنابراین، از مناسب‌ترین گزینه‌ها برای پیاده‌سازی روی داده‌های سری زمانی و مدل‌سازی رفتار دینامیکی سیستم‌های غیرخطی و پیچیده می‌باشند.

برای آموزش شبکه عصبی NARX می‌توان از دو حالت ساختاری سری- موازی و یا حالت موازی استفاده کرد. در نوع سری- موازی، خروجی واقعی سیستم به‌عنوان ورودی پس‌خور به شبکه داده می‌شود؛ اما در حالت موازی، خروجی تخمین زده شده توسط خود شبکه عصبی به این منظور استفاده می‌شود. معادلۀ حاکم بر مدل سری- موازی NARX به‌صورت زیر است:

In Press Pre-Proof Version

$$\hat{y}(t_k) = f(y(t_{k-1}), y(t_{k-2}), \dots, y(t_{k-d_y}), u(t_k), u(t_{k-1}), \dots, u(t_{k-d_u})) \quad (۱)$$

که در آن $\hat{y}(t_k)$ خروجی تقریب زده شده توسط شبکهٔ عصبی در نمونهٔ زمانی t_k بوده و در حالت کلی، تابعی از مقادیر خروجی واقعی نمونه‌های زمانی قبل $y(t_{k-1}), y(t_{k-2}), \dots, y(t_{k-d_y})$ و همچنین مقادیر ورودی نمونهٔ زمان حاضر $u(t_k)$ و مقادیر نمونه‌های قبلی آن است.



شکل ۱ ساختار کلی حالت سری- موازی مدل شبکه عصبی NARX

Fig. 1 General structure of the series–parallel configuration of the NARX neural network model

شکل ۱ ساختار کلی مدل سری- موازی NARX با تعداد تأخیر d_u برای ورودی‌های خارجی و تعداد تأخیر d_y برای ورودی‌های پس‌خور واقعی را نشان می‌دهد. با توجه به شکل ۱، $\hat{y}(t_k)$ که خروجی حاصل از شبکهٔ عصبی است، از رابطهٔ زیر حاصل می‌شود:

$$\hat{y}(t_k) = f_2\left(\sum_{i=1}^{n}\left(W_2^{i,1} \times o_1^{i}(t_k)\right) + b_o^{1}\right) \quad (۲)$$

به‌طوری‌که:

$$o_1^{i}(t_k) = f_1\left(b_1^{i} + \sum_{j=0}^{d_u}\left(W_1^{j+1,i} \times u_D(t_{k-j})\right) + \sum_{j=1}^{d_y}\left(W_1^{j,i} \times y_D(t_{k-j})\right)\right) \quad (۳)$$

و

$$u_D(t_k) = [u(t_k), u(t_{k-1}), \dots, u(t_{k-d_u})]^T \quad (۴)$$

و

$$y_D(t_k) = [y(t_{k-1}), y(t_{k-2}), \dots, y(t_{k-d_y})]^T \quad (۵)$$

در روابط بالا، f_1 و f_2 به ترتیب توابع فعال‌ساز لایه پنهان و لایه خروجی هستند. پارامترهای W و b نیز به‌همراه بالانویس و پایین‌نویس مربوط، به ترتیب بیانگر وزن بین اتصال نرون‌های مختلف در لایه‌های مختلف و همچنین وزن بایاس آن‌ها است. پارامتر o نیز بر اساس بالانویس و پایین‌نویس آن، به خروجی نرون‌های گوناگون در لایه‌های مختلف، اشاره دارد.

۲-۲ شاخص‌های ارزیابی:

در تحقیقات علمی، چندین معیار برای مقایسه و ارزیابی دقت مدل‌های رگرسیونی، مورداستفاده قرار می‌گیرد. در این مقاله از معیارهای ارزیابی زیر استفاده شده است.

معیار میانگین قدر مطلق خطا (MAE) به‌صورت زیر تعریف می‌شود:

$$MAE = \frac{1}{N}\sum_{i=1}^{N}|y(t_i) - \hat{y}(t_i)| \quad (۶)$$

معیار رگرسیون R نیز از رابطهٔ زیر به دست می‌آید که در آن، $\bar{y}$ مقدار متوسط نمونه است.

$$R = \sqrt{1 - \frac{\sum_{i=1}^{N}(y(t_i) - \hat{y}(t_i))^2}{\sum_{i=1}^{N}(y(t_i) - \bar{y})^2}} \quad (۷)$$

روابط مربوط به محاسبه معیارهای RSME و MAPE نیز در زیر ارائه شده است.

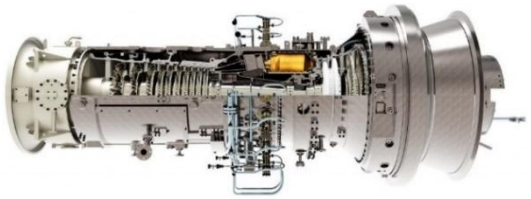
$$RSME = \sqrt{\frac{1}{N}\sum_{i=1}^{N}(y(t_i) - \hat{y}(t_i))^2} \quad (۸)$$

و

$$MAPE = \frac{100}{N}\sum_{i=1}^{N}\left|\frac{y(t_i) - \hat{y}(t_i)}{y(t_i)}\right| \quad (۹)$$

۳- مدل‌سازی عملکردی توربین گاز صنعتی با شبکهٔ عصبی NARX

توربین گاز صنعتی موردبررسی در این مقاله، اولین توربین گاز ملی به اسم IGT25 است که جایگزین توربین SGT600 ساخت شرکت زیمنس آلمان گردید. این توربین در ابتدا به‌عنوان محرک کمپرسور و پمپ‌ها طراحی شده بود، سپس به دلیل طراحی قوی و اقتصادی بودن آن، برای تولید برق در نیروگاه‌ها نیز مورداستفاده قرار گرفت [۲۴]. نمای برش خورده از این توربین در شکل۲ نشان داده شده است. همچنین مشخصات این توربین در جدول ۱ ارائه شده است. داده‌های موردنیاز برای مدل‌سازی توربین گاز صنعتی مدنظر، از شبیه‌سازی مدل ترمودینامیکی توربین در محیط سیمولینک نرم‌افزار متلب (T-MATS)، با نرخ داده‌برداری ۱۰۰ هرتز استخراج گردید. جعبه‌ابزار سیمولینک T-MATS به‌عنوان ابزاری با دقت بالا برای مدل‌سازی سیستم‌های ترمودینامیکی است که در مقالهٔ [۲۵] دقت آن با استفاده از داده‌های تجربی تأیید شده است. در ادامه، جزئیات و شرایط مدل‌سازی بررسی می‌شود.



شکل ۲ شماتیک توربین گاز IGT25 [۲۴]

Fig. 2 Schematic of the Gas Turbine IGT25 [24]

جدول ۱ مشخصات توربین گاز IGT25 [۲۴]

Table 1 Specifications of the IGT25 Gas Turbine [24]

Exhaust Gas Flow	**83 kg/s**
Compressor Pressure Ratio (PR_AC)	**14:1**
Turbine Speed	**7700 rpm**
Produced Mechanical Power	**25.4 MW**

شرایط محیطی اثر قابل‌توجهی در عملکرد توربین گاز و بازده گرمایی آن دارد. بنابراین در دسترس داشتن مدلی که دما و ارتفاع محیط را نیز در نظر گرفته است؛

In Press, Pre-Proof

برای بهینه کردن شرایط کاری توربین لازم و ضروری است. بر همین مبنا، در پژوهش حاضر، دما و ارتفاع محیط به‌عنوان ورودی‌های خارجی شبه‌استاتیکی در نظر گرفته شد. از طرفی دو پارامتر سرعت و توان درخواستی که به‌عنوان فرمان به توربین ارسال می‌گردد، در نقش ورودی‌های پس‌خور دینامیکی فرض شد. برای هر مدل شبکهٔ عصبی، یک خروجی در نظر گرفته شد که در واقع برای هر یک از پارامترهای دبی سوخت مصرفی توربین(Fuel Mass Flow)، دبی هوای ورودی به کمپرسور(Air Mass Flow)، نسبت فشار کمپرسور هوا(PR)، سرعت توربین ژنراتور(NGG)، دمای گاز ورودی به توربین(TIT) و دمای گاز خروجی از توربین(EGT)، یک مدل شبکهٔ عصبی مجزا تولید شده است. اما در این مدل‌سازی به این مهم نیز توجه شده است که در واقعیت، رفتار هر پارامتر عملکردی توربین گاز از تغییرات پارامترهای دیگر توربین نیز تأثیر می‌پذیرد و بهترین حالت برای مدل‌سازی با شبکه‌های عصبی این است که مدل‌های چند خروجی طراحی شود و در پیش‌بینی رفتار هر پارامتر، از مقادیر پارامترهای دیگر نیز به‌صورت سیگنال پس‌خور استفاده شود، اما این درحالی است که پیاده‌سازی چنین مدلی، به یک مدل پیچیده نیاز خواهد داشت که باعث افت سرعت اجرای شبیه‌سازی نیز خواهد شد. از طرفی با توجه به اینکه ایجاد مدلی با سرعت‌بالا به‌عنوان یکی از اهداف این مقاله است، بنابراین پیاده‌سازی چنین مدل پیچیده‌ای، برای این پژوهش مناسب نیست. بر همین اساس در این مقاله، به مدل‌های تک خروجی روی آورده شده است، اما به‌منظور عدم دوری از فیزیک واقعی توربین گاز، سعی شده است، فرایند داده‌برداری، در شرایط متنوعی از رفتار توربین گاز صورت گیرد تا اثرات رفتار پارامترها بر یکدیگر، به‌صورت ضمنی در داده‌های آموزشی لحاظ شده باشد. در این مقاله به‌منظور یادگیری بهتر و حصول مدل با دقت بالاتر، از حالت سری-موازی شبکه عصبی NARX برای مدل‌سازی پارامترهای مدنظر، استفاده گردید. قابل ذکر است که معرفی کردن دما و ارتفاع محیط به‌عنوان ورودی‌های شبه‌استاتیکی به این معنی است که تغییرات محیطی نسبت به تغییرات دور و توان درخواستی، با سرعت خیلی پایین‌تری اتفاق می‌افتد. بر همین اساس در داده‌های آموزشی، به ازای دما و ارتفاع‌های محیطی مختلف، سیگنال تصادفی از ورودی‌های دینامیکی تولید می‌شود. بنابراین، مدل‌های توسعه‌یافته قابلیت پیش‌بینی رفتار پارامترها را بر اثر تغییرات شرایط محیطی را دارند.

برای تعیین معماری مناسب برای مدل شبکهٔ عصبی هر پارامتر، مطابق جدول۲ بر اساس روش جستجوی شبکه، ترکیب معماری مختلف که شامل مجموعهٔ تعداد تأخیرهای ورودی خارجی و تعداد تأخیرهای ورودی پس‌خور، تعداد نرون‌های لایه میانی اول و همچنین تعداد نرون‌های لایه میانی دوم می‌شد، انتخاب‌شده و آموزش شبکه‌های عصبی برای این معماری‌ها صورت گرفت. از تابع فعال‌ساز tanh که در حالت کلی عملکرد خوبی از خود نشان می‌دهد، در لایه‌های میانی استفاده شد و تابع همانی در لایهٔ خروجی تنظیم گردید. با توجه به متفاوت بودن مقداردهی اولیهٔ[1] پارامترها برای آموزش شبکهٔ عصبی و تأثیر این موضوع بر کیفیت آموزش، مطابق فلوچارت که در ادامه، بیان شده است؛ هر ترکیب ۳ بار آموزش داده شد. سپس با استفاده از شاخص MAE بین تمام ساختارهای آموزش داده‌شده، رتبه‌بندی انجام گرفت و بهترین ساختارها بر مبنای مقدار خطا بر اساس معیار MAE جدا شد. به‌این‌ترتیب معماری‌های مناسب برای هر پارامتر عملکردی مشخص گردید. در ادامه، مراحل الگوریتم بهینه یابی برای معماری مدل‌های شبکه عصبی، به‌طور کامل تشریح شده است.

۱) آموزش ۳ مرتبه‌ای همه ساختارها و ذخیرهٔ دو مقدار میانگین MAE و کمترین MAE از بین هر ۳ معماری.

۲) انتخاب شبکه‌هایی با اختلاف کمتر از ۳۰% بین مقدار میانگین MAE و کمترین مقدار MAE آن‌ها.

۳) آموزش ۳ مرتبه‌ای معماری‌های منتخب مرحلهٔ قبل و مقایسهٔ کمترین مقدار MAE آن‌ها.

۴) ذخیرهٔ شبکه با کمترین مقدار MAE به‌عنوان بهینه‌ترین شبکه. محدوده انتخاب شده برای تعداد نرون‌ها و تأخیرها، بر اساس بررسی و تجربه‌های مقدماتی از آموزش شبکه عصبی و همچنین با درنظر گرفتن هزینه محاسباتی فرایند آموزش تعیین شد. نتایج اولیه نشان داد افزایش نرون‌ها و گام‌های تأخیر، با تعدادی فراتر از بازه انتخاب شده، علاوه بر اینکه بهبود قابل‌توجهی در دقت مدل ایجاد نکرده و موجب افزایش پیچیدگی مدل می‌شد، حتی در بیشتر موارد احتمال بیش‌برازش را افزایش می‌دادند. از این رو، بازه‌های محدودتر برای فرایند بهینه‌یابی در نظر گرفته شد.

[1] Initialization

جدول ۲ محدوده بهینه یابی معماری مدل‌ها

Table 2 Model architecture optimization range

Feedback Delay	Input Delay	Neurons (1th Hidden Layer)	Neurons (2nd Hidden Layer)
1-2	0-2	1-10	0-10

۴- ۱ نتایج و تحلیل

پس از آموزش شبکه‌ها، مطابق الگوریتم ارائه شده، ترکیب بهینه برای معماری شبکه‌های عصبی به همراه مقادیر معیارهای MAE، R، RSME و MAPE برای داده‌های آزمایشی حاصل شدند که نتایج آن‌ها در جدول ۳ ارائه شده است. مقدار شاخص MAE در جدول۳

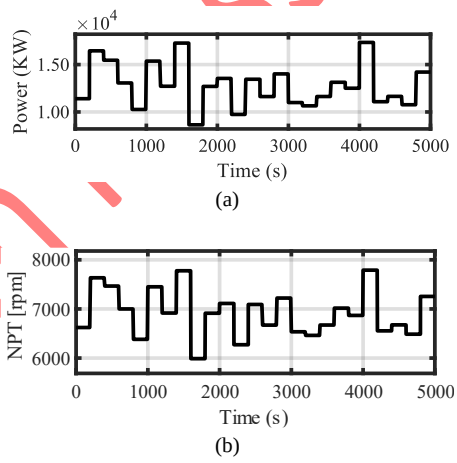
جدول ۳ معماری‌های بهینه مدل‌های شبکه عصبی پارامترهای توربین گاز و مقادیر شاخص‌های عملکرد

Table 3 Optimized neural network model architectures for gas turbine parameters and performance indices

Gas turbine parameter	Feedback Delay	Input Delay	Neurons (1th Hidden Layer)	Neurons (2nd Hidden Layer)	MAE	R	RMSE	MAEP
Air Mass Flow	1	0	4	5	0.012	0.981	0.014	0.013
Fuel Consumption	1	0	4	3	0.004	0.994	0.005	0.004
PR	1	0	4	3	0.009	0.979	0.01	0.01
NGG	1	0	5	2	0.004	0.934	0.006	0.005
TIT	1	0	5	5	0.006	0.987	0.007	0.006
EGT	1	0	5	4	0.004	0.968	0.005	0.005

به ازای مقادیر نرمالایز شده از رفتار پارامترهای عملکردی توربین، محاسبه شده‌اند. با توجه به مقادیر شاخص‌های ارزیابی، ملاحظه می‌شود مدل‌ها از دقت مناسبی برخوردار هستند. مقدار MAE برای دبی جرمی هوا (Air Mass Flow)، برابر ۰/۰۱۲ حاصل شده است که نسبت به مقدار این معیار برای مدل‌های دیگر اندکی بالاتر است.

پس از ایجاد مدل‌های شبکه عصبی با معماری بهینه برای هر یک از پارامترهای عملکردی توربین، به‌منظور ارزیابی دقت آن‌ها، شبیه‌سازی رفتار مدل‌ها با داده‌های آزمایشی انجام گرفت. در این شبیه‌سازی، مقادیر دو ورودی خارجی نامتغیر با زمان(شبه‌استاتیکی)، شرایط محیطی استاندارد(دمای ۱۵ درجه سانتی‌گراد و ارتفاع سطح دریا) در نظر گرفته شد. همچنین سرعت و توان درخواستی کمپرسور، به‌صورت سیگنال پله‌ای تصادفی، به‌عنوان ورودی‌های خارجی متغیر با زمان، اعمال شد. سیگنال در نظر گرفته شده برای این دو متغیر در شکل ۳ نمایش داده شده است.

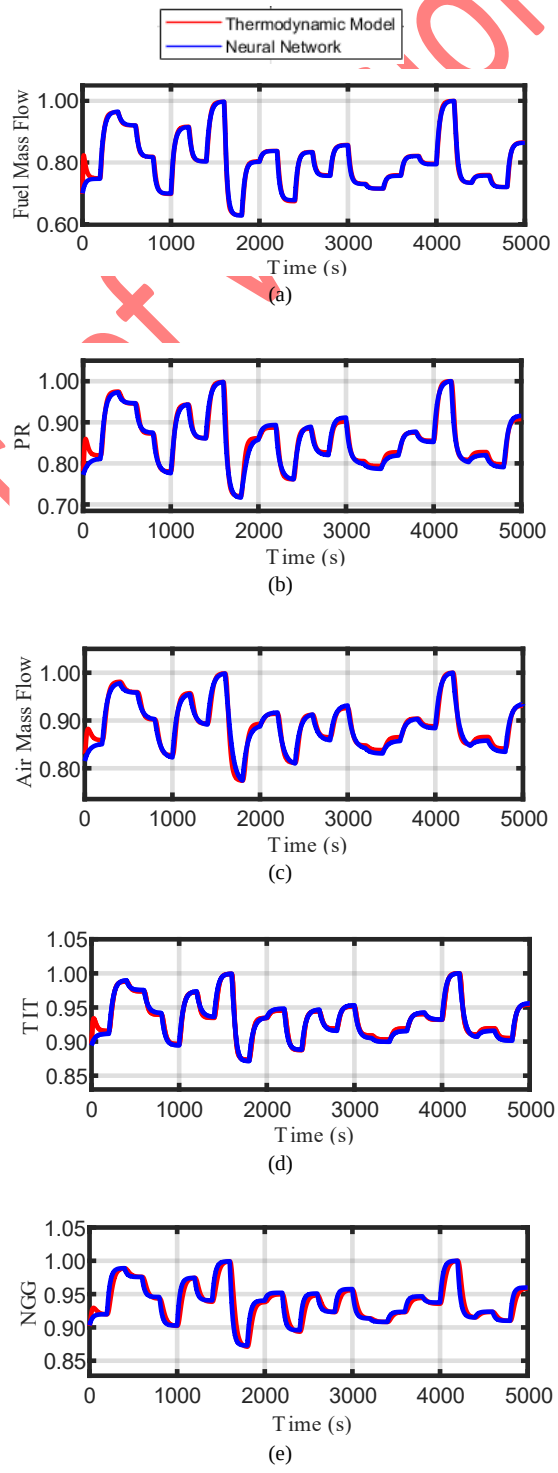


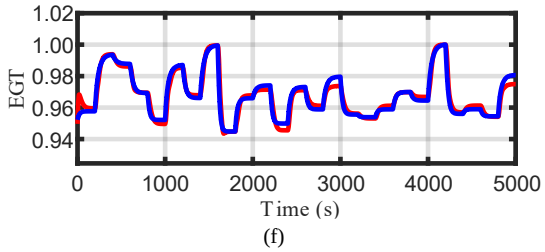
In Pre-Proof Version

شکل ۳ ورودی‌های دینامیکی مدل‌های شبکه عصبی؛ الف) توان تولیدی توربین گاز. ب) سرعت عملیاتی توربین گاز.

Fig. 3 Dynamic inputs of neural network models; (a) Gas turbine output power, (b) Gas turbine operating speed

نتایج شبیه‌سازی به ازای ورودی‌های دینامیکی (مطابق شکل ۳) و همچنین مقادیر ورودی‌های شبه‌استاتیکی(در اینجا ثابت با زمان)، شامل دمای ۱۵ درجه سانتی‌گراد و ارتفاع ۰ (شرایط استاندارد)، به‌صورت نرمالایز شده در شکل ۴ در کنار پاسخ مدل ترمودینامیکی توربین گاز در سیمولینک نرم‌افزار متلب (به رنگ قرمز) ارائه شده است. اختلاف زیاد پاسخ دو مدل در لحظات ابتدایی شبیه‌سازی، به دلیل تفاوت در مقدار اولیهٔ دو مدل است.





شکل ٤ نتایج شبیه‌سازی مدل شبکهٔ عصبی پارامترهای توربین گاز در شرایط استاندارد(دمای ۱۵ درجه سانتی‌گراد و ارتفاع سطح دریا)؛ الف) دبی سوخت مصرفی توربین، ب) نسبت فشار کمپرسور هوا پ) دبی هوای ورودی به کمپرسور ، ت) دمای گاز ورودی به توربین ژنراتور، ث) دمای گاز خروجی از توربین قدرت، ج) سرعت توربین ژنراتور

Fig. 4 Simulation results of the neural network model for gas turbine parameters under standard conditions (15 °C ambient temperature and sea level altitude); (a) Fuel mass flow rate, (b) Compressor pressure ratio, (c) Compressor inlet air mass flow rate, (d) Gas temperature at the generator turbine inlet, (e) Gas temperature at the power turbine outlet, (f) Generator turbine speed.

بر اساس نتایج شبیه‌سازی، ملاحظه گردید مدل‌های شبکه عصبی تولید شده، به‌خوبی توانسته‌اند رفتار پارامترهای عملکردی مدنظر توربین را یاد بگیرند و رفتار نزدیک و مشابهی با مدل ترمودینامیکی داشته باشند. از میان مدل‌های ایجاد شده، مدل شبکه عصبی مربوط به پارامتر دبی سوخت مصرفی توربین، با دقت خیلی بالایی، رفتار آن را تخمین زده است به‌طوری‌که مقدار معیار MAE برای آن برابر ۰،۰۰٤ و معیار R برابر ۰،۹۹٤ حاصل شده است.

از طرفی، مدل شبکهٔ عصبی تخمین‌گر رفتار پارامتر عملکردی دمای گاز خروجی از توربین(EGT) در برخی لحظات، دارای خطای جزئی حالت‌پایا بوده؛ اما همچنان، قابل‌قبول است و در مقایسه با نتایج مدل NARX و دیگر مدل‌هایی که در مقاله [۷] برای مدل‌سازی رفتار دینامیکی این پارامتر عملکردی در توربین گاز هوایی ایجاد شده است، مقدار MAE پایین‌تری دارد که نشان می‌دهد بهینه‌سازی معماری شبکه عصبی در دقت مدل، بی‌تأثیر نبوده است. مدل مربوط به پارامتر عملکردی سرعت محور توربین ژنراتور نیز با مقدار خطای خیلی ناچیزی در رفتار دینامیکی نسبت به مدل ترمودینامیکی عمل کرده است؛ اما همچنان با توجه به مقادیر به‌دست‌آمده برای معیارهای جدول ۳، عملکرد خیلی خوبی را در تقلید رفتار این پارامتر داشته است.

در ادامه همچنین به‌منظور مقایسه سرعت اجرای مدل‌های شبکه عصبی و مدل ترمودینامیکی، مدت زمان اجرای این دو نوع مدل در سیمولینک متلب، اندازه‌گیری شد. بر اساس نتیجه به‌دست‌آمده، مدت زمان اجرا شبیه‌سازی برای مدل ترمودینامیکی برابر با ۲۳،۲ ثانیه و برای تجمیع شده مدل‌های شبکه عصبی، برابر با ۲۲،۸ ثانیه حاصل شد. ملاحظه می‌شود این اختلاف، آنچنان قابل توجه نیست، اما باید در نظر داشت که به‌عنوان نمونه، در سیستم‌های انتقال گاز، تعداد زیادی توربین مورد استفاده قرار می‌گیرند که در شبیه‌سازی چنین سیستمی، اختلاف سرعت اجرا، قابل ملاحظه خواهد بود.

۲-۴ مقایسه نتایج معماری با پژوهش دیگر

همان‌گونه که در بخش‌های پیشین اشاره شد، تعیین تعداد نرون‌ها، لایه‌های پنهان و تأخیرهای ورودی و پس‌خور نقش اساسی در بهبود عملکرد مدل دارد. ازاین‌رو، مقایسهٔ معماری بهینه حاصل از پژوهش حاضر با سایر تحقیقات مشابه، می‌تواند بیانگر میزان کارایی و سادگی ساختارهای پیشنهادی باشد. یکی از پژوهش‌های مشابه و جدید در این زمینه، مقاله [۱۴] است که در آن از مدل NARX برای شناسایی رفتار یک توربین گاز دوگانه‌سوز استفاده شده است. در یک حالت از مدل‌سازی صورت گرفته در این مقاله، چهار پارامتر شامل دما و فشار خروجی از کمپرسور هوا، درصد بازشدگی شیر هوای ورودی به کمپرسور و شیر سوخت توربین به‌عنوان ورودی‌های مدل NARX و توان تولیدی توربین به‌عنوان خروجی مدل در نظر گرفته شده است. در دو حالت مدل‌سازی دیگر نیز، سرعت شفت توربین و دمای گاز خروجی از توربین به‌عنوان تک خروجی مدل فرض شده‌اند. معماری به‌دست‌آمده توسط مقاله [۱۴] در جدول۴ ارائه شده است. در حالیکه معماری بهینه مدل‌های مربوط به این پارامترها برای مقاله حاضر بصورت جدول ۵ حاصل شده است. مطابق جدول ٦ ملاحظه می‌شود تعداد وزن‌ها و تعداد توابع فعال‌ساز بکار گرفته شده در مدل‌های مقاله [۱٤] خیلی بیشتر از تعداد این

In Press, Pre-Print Version

فراپارامترها در پژوهش حاضر است. بنابراین مدل‌های حاصل در این پژوهش که معماری آن‌ها بهینه‌یابی شده است؛

جدول ٤ معماری مدل‌های مربوط به پارامترهای عملکردی توربین گاز توسط مقاله [۱۴]، با چهار ورودی شامل دما و فشار خروجی از کمپرسور هوا، درصد بازشدگی شیرهای هوای ورودی به کمپرسور و شیر سوخت توربین.

Table 4 Architecture of gas turbine performance parameter models presented in [14], with four input variables including compressor outlet temperature and pressure, inlet air valve opening percentage, and fuel valve opening percentage.

Output Parameter	No. Hidden Leyer Neurons	Feedback Delay
Turbine Speed	15	25
Exhaust Gas Temperature	20	30

جدول ٥ معماری بهینه مدل‌های مربوط به پارامترهای عملکردی سرعت توربین ژنراتور و دمای گاز خروجی از توربین قدرت(EGT) برای مقاله حاضر

Table 5 Optimized architectures of the models corresponding to the generator turbine speed and exhaust gas temperature (EGT) performance parameters for the present study.

Output Parameter	No. of Neurons in Hidden Leyer 1	No. of Neurons in Hidden Leyer 2	Feedback Delay
Turbine Speed	5	5	1
Exhaust Gas Temperature	5	4	1

جدول ٦ مقایسه پیچیدگی مدل‌های مربوط به پارامترهای عملکردی سرعت توربین ژنراتور و دمای گاز خروجی از توربین قدرت(EGT) برای پژوهش حاضر و مقاله [۱۴]

Table 6 Comparison of model complexities for the generator turbine speed and exhaust gas temperature (EGT) performance parameters between the present study and [14].

Output Parameter	Article	No. of Weight	No. of Tanh activation function
Turbine Speed	Present Study	66	10
	study [14]	466	15
Exhaust Gas Temperature	Present Study	59	9
	study [14]	721	20

ساختار سبک‌تر و درنتیجه اجرای سریع‌تری را به دنبال خواهند داشت.

۵- جمع‌بندی و نتیجه‌گیری

در این پژوهش، مدل‌سازی دینامیکی رفتار پارامترهای عملکردی توربین گاز صنعتی با استفاده از شبکهٔ عصبی خودرگرسیون غیرخطی با ورودی خارجی (NARX)و به کمک معماری بهینه انجام شد. با بهره‌گیری از یک الگوریتم مبتنی بر روش جستجوی شبکه، بهترین ترکیب از تعداد تأخیرهای ورودی خارجی و پس‌خور، همچنین تعداد نرون‌های لایه‌های پنهان برای هر یک از مدل‌های هدف تعیین گردید. نتایج شبیه‌سازی نشان داد که مدل‌های توسعه‌یافته توانسته‌اند رفتار پارامترهای اصلی توربین شامل دبی سوخت مصرفی، دبی هوای ورودی به کمپرسور، نسبت فشار کمپرسور، سرعت توربین ژنراتور، دمای گاز ورودی به توربین ژنراتور و دمای گاز خروجی از توربین قدرت را با دقت بالا بازتولید نمایند. مقادیر شاخص رگرسیون R در بازه‌ی ۰,۹۳ تا ۰,۹۹ قرار گرفت که بیانگر دقت بسیار مناسب مدل‌های آموزش‌دیده در شبیه‌سازی رفتار غیرخطی و دینامیکی توربین گاز می‌باشد.

علاوه‌بر این، مقایسه معماری مدل‌های بهینه‌شده در این پژوهش با معماری‌های ارائه‌شده در یکی از مطالعات پیشین، نشان داد که مدل‌های حاضر دارای پیچیدگی ساختاری به‌مراتب کمتر هستند؛ به‌طوری‌که تعداد وزن‌ها و توابع فعال‌ساز مورد نیاز در لایه‌های میانی کاهش قابل توجهی یافته است. این موضوع سبب شده است که مدل‌های پیشنهادی، ضمن حفظ دقت پیش‌بینی، از سرعت اجرای بالاتر و نیاز محاسباتی کمتر برخوردار باشند.

با وجود نتایج مناسب حاصل‌شده، یکی از محدودیت‌های اصلی این پژوهش آن است که داده‌های آموزشی شبکه‌های عصبی از مدل ترمودینامیکی شبیه‌سازی‌شده در محیط T-MATS استخراج شده‌اند. بنابراین دقت مدل‌های NARX توسعه‌یافته، تا حد زیادی وابسته به دقت مدل ترمودینامیکی پایه است. هرچند صحت مدل T-MATS در مطالعات پیشین با استفاده از داده‌های تجربی مورد تأیید قرار گرفته است، اما استفاده از داده‌های عملیاتی واقعی توربین گاز صنعتی برای اعتبارسنجی نهایی مدل‌ها، می‌تواند به افزایش قابلیت اطمینان و کاربردپذیری صنعتی آن‌ها منجر شود.

به‌طور کلی، مدل‌های شبکه عصبی NARX با معماری بهینه ارائه‌شده در این پژوهش، جایگزینی سبک، سریع و دقیق برای مدل‌های ترمودینامیکی از نظر محاسباتی به شمار می‌آیند. این مدل‌ها به دلیل دقت مناسب و کارایی محاسباتی بالا، قابلیت استفاده در شبیه‌سازی‌های تجمیعی سامانه‌های انتقال گاز، پایش و کنترل بلادرنگ توربین‌های گازی و همچنین بهینه‌سازی عملکرد و نگهداری پیش‌بینانه را نیز دارند که برای چنین کاری، باید از داده‌های واقعی توربین در یادگیری شبکه عصبی استفاده کرد. بر این اساس باید توجه کرد که مدل‌های ایجاد شده در این پژوهش قابل استفاده به‌عنوان مدل جایگزین توربین واقعی نیست. اما با توجه به اینکه، شبکه عصبی مورداستفاده در این پژوهش، توانایی یادگیری رفتار مشابه را داشته است، بنابراین درصورت دسترسی به داده‌های واقعی، می‌توان از این شبکه عصبی در یادگیری رفتار سیستم و ایجاد مدلی از آن، استفاده کرد.

همچنین تحلیل صریحی از تأثیر تک خروجی کردن مدل‌ها بر دقت آن‌ها، در پژوهش‌های آتی می‌تواند مفید واقع شود.

تأییدیه اخلاقی: محتویات علمی این مقاله حاصل پژوهش نویسندگان است و در هیچ نشریه ایرانی و غیرایرانی منتشر نشده است.

تعارض منافع: در این مقاله از نتایج حاصل از پایان‌نامه ارشد نویسنده اول استفاده شده است. هیچ تعارض منافع دیگری برای اظهار وجود ندارد.

منابع

[1] A. Kumar, A. Singhania, A. K. Sharma, R. Roy, B. K. Mandal, "Thermodynamic Analysis of Gas Turbine Power Plant", Int. J. Innov. Res. Eng. Manag., pp. 648-654, 2017, doi: 10.21276/ijirem.2017.4.3.2.

[2] N. Chiras, C. Evans, D. Rees, "NONLINEAR MODELLING OF GAS TURBINE DYNAMICS USING A WIENER STRUCTURE".

[3] M. G. De Giorgi, L. Strafella, A. Ficarella, "Neural Nonlinear Autoregressive Model with Exogenous Input (NARX) for Turboshaft Aeroengine Fuel Control Unit Model", Aerospace,
vol. 8, no. 8, pp. 206, 2021, doi: 10.3390/aerospace8080206.

[4] M. Akbari, A. Khoshnood, and S. Irani, "Designing l1 norm Based Sliding Mode Controller For Implementing in Hybrid Model of Gas Turbine," *Modares Mech. Eng. J.*, vol. 19, no. 10, pp. 2339–2350, Oct. 2019.

[5] J. Khodaei Mehra, A. Khakpour Komar Solfa, O. Ahmadi Khiyavi, M. A. Hamed, and S. Baheri Islami, "Dynamic Behavior of a Turbojet Engine in Response to Fuel Flow Rate," *Modares Mech. Eng. J.*, vol. 17, no. 1, pp. 23–30, Jan. 2017.

[6] E. Mohammadi and M. Montazeri-Gh, "A New Approach to the Gray-Box Identification of Wiener Models With the Application of Gas Turbine Engine Modeling," *J. Eng. Gas Turbines Power*, vol. 137, no. 7, p. 12, Jul. 2015, doi: 10.1115/1.4029170.

[7] S. Ma, Y. Wu, H. Zheng, L. Gou, "A Hybrid of NARX and Moving Average Structures for Exhaust Gas Temperature Prediction of Gas
Turbine Engines", Aerospace, vol. 10, no. 6, p. 496, 2023, doi: 10.3390/aerospace10060496.

[8] X. Wu, X. Hu, X. Xiang, S. Lin, "A neural network-based modeling approach for transient performance prediction of gas turbine engines", 2024, doi: 10.21203/rs.3.rs-4898293/v1.

In Press, Pre-Proof Version

(IETC), Orem, UT, USA: IEEE, pp. 1-5, 2022, doi: 10.1109/IETC54973.2022.979691.

[9] R. Aquize, A. Cajahuaringa, J. Machuca, D. Mauricio, J. M. Mauricio Villanueva, "System Identification Methodology of a Gas Turbine Based on Artificial Recurrent Neural Networks", Sensors, vol.23, no. 4, p. 2231, 2023, doi: 10.3390/s23042231.

[10] S. Amirkhani, A. Tootchi, A. Chaibakhsh, "Fault detection and isolation of gas turbine using series–parallel NARX model", ISA Trans., vol. 120, pp. 205-221, 2022, doi: 10.1016/j.isatra.2021.03.019.

[11] I. M. A. Ibrahem, O. Akhrif, H. Moustapha, M. Staniszewski, "Nonlinear generalized predictive controller based on ensemble of NARX models for industrial gas turbine engine", Energy, vol. 230, p. 120700, 2021, doi: 10.1016/j.energy.2021.120700.

[12] M. B. Rahmoune, A. Hafaifa, A. Kouzou, X. Chen, A. Chaibet, "Gas turbine monitoring using neural network dynamic nonlinear autoregressive with external exogenous input modelling", Math. Comput. Simul., vol. 179, pp. 23-47, 2021, doi: 10.1016/j.matcom.2020.07.017.

[13] A. Sajad, N. V. Mokrova, "Black-Box Identification of Gas Turbine Output Parameters Using Dynamic Neural Network", International Multi-Conference on Industrial Engineering and Modern Technologies (FarEastCon), Vladivostok, Russia: IEEE, pp. 1-6, 2020. doi: 10.1109/FarEastCon50210.2020.9271278.

[14] M. Alsarayreh, O. Mohamed, and M. Matar, "Modeling a Practical Dual-Fuel Gas Turbine Power Generation System Using Dynamic Neural Network and Deep Learning," *Sustainability*, vol. 14, no. 2, p. 870, Jan. 2022, doi: 10.3390/su14020870.

[15] P. Liashchynskyi, P. Liashchynskyi, "Grid Search, Random Search, Genetic Algorithm: A Big Comparison for NAS", 2019, arXiv: arXiv:1912.06059. doi: 10.48550/arXiv.1912.06059.

[16] K. G. Kapanova, I. Dimov, J. M. Sellier, "A genetic approach to automatic neural network architecture optimization", Neural Comput. Appl., vol. 29, no. 5, pp. 1481-1492, 2018, doi: 10.1007/s00521-016-2510-6.

[17] M. Lupo Pasini, J. Yin, Y. W. Li, M. Eisenbach, "A scalable algorithm for the optimization of neural network architectures", Parallel Comput., vol. 104-105, p. 102788, 2021, doi: 10.1016/j.parco.2021.102788.

[18] Y. Ghanou, G. Bencheikh, "Architecture Optimization and Training for the Multilayer Perceptron using Ant System", 2016.

[19] K. Laddach, R. Łangowski, T. A. Rutkowski, B. Puchalski, "An automatic selection of optimal recurrent neural network architecture for processes dynamics modelling purposes", Appl. Soft Comput., vol. 116, p. 108375, 2022, doi: 10.1016/j.asoc.2021.108375.

[20] T. K. Gupta, K. Raza, "Optimizing Deep Feedforward Neural Network Architecture: A Tabu Search Based Approach", Neural Process. Lett., vol. 51, no. 3, pp. 2855-2870, 2020, doi: 10.1007/s11063-020-10234-7.

[21] M. Z. Alom et all "A State-of-the-Art Survey on Deep Learning Theory and Architectures", Electronics, vol. 8, no. 3, p. 292, 2019, doi: 10.3390/electronics8030292.

[22] C. M. Bishop, Pattern recognition and machine learning. Information science and statistics. New York: Springer, 2006.

[23] S. S. Haykin, S. S. Haykin, Neural networks and learning machines, 3rd ed. New York: Prentice Hall, 2009.

[24] https://www.turbotec-co.com/products/igt25/.

[25] K. Wilson, M. P. Schoen, J.-C. Li, "Jet Engine Modeling Using T-MATS with Experimental Verification", 2022 Intermountain Engineering, Technology and Computing

In Press, Pre-Proof Version