JTAE

Journal of Technology in Aerospace Engineering

Vol. 10, No. 2, pp. 105-120, 2026

E- ISSN: 2676-4253

https://doi.org/1022034/jtae.10.2.8

Journal Homepage: https://www.jtae.ari.ac.ir



Original Research Paper

Classification And Identification Of Turbojet Engine Faults With Self-Organizing Neural Networks And Support Vector Machine Clustering

Farideh Sadat Hashemifard, Mehdi Jahromi, Mostafa Khazaee*, and Mostafa Mahmoodi

Faculty of Aerospace, Malek Ashtar University of Technology, Tehran, Iran

ARTICLE INFO

Article History:

Received 11 May 2025
Revised 09 December 2025
Accepted 27 December 2025
Available Online 28 January 2026

Keywords:

Engine health monitoring
Fault diagnosis and prognostics
Fault classification
Neural network
Turbojet engine

ABSTRACT

The development of engine health monitoring systems is one of the challenges of the aviation industry that can bring significant savings by improving engine availability and reliability. A health prediction framework reduces the unplanned repairs and maintenance through an accurate and timely estimate of the current engine health condition. In order to achieve higher efficiency in fault detection and also facilitate the rapid start of this process, an algorithm is required that be less sensitive to the amount of training data in this problem. This paper proposes a fault detection algorithm for a turbojet engine based on a self-organizing neural network that uses the clustered data. This training method specifies the independent clusters of data through support vector machine (SVM) and makes the training process more efficient. A two-layer feedforward neural network identifies the fault patterns, and an SVM technique classifies them. The results on health, corrosion, erosion, fouling, and fuel nozzle faults from a validated thermodynamic model of the J85 engine show the capability of the proposed method in performance diagnostics. In addition, despite the significant reduction in the training data, the accuracy of fault detection has decreased from 99.8 to 97.7 which is satisfactory.

* Corresponding Author's E-mail: khazaee_m@mut.ac.ir

How to Cite this Article:
F. S. Hashemifard, M. Jahromi, M. Khazaee, and M. Mahmoodi, "Classification and identification of turbojet engine faults with self-organizing neural networks and support vector machine clustering," *Journal of Technology in Aerospace Engineering*, vol. 10, no. 2, pp. 105-120, 2026, (in Persian), https://doi.org/1022034/jtae.10.2.8.

COPYRIGHTS
© 2026 by the authors. Published by ARI. This article is an open access article distributed under the terms and conditions of The Creative Commons Attribution 4.0 International (CC BY 4.0)



فناوری در مهندسی هوافضا

سال ۱۴۰۵، دوره ۱۰، شماره ۲، صفحه ۱۰۵-۱۲۰

https://doi.org/1022034/jtae.10.2.8

Journal Homepage: https://www.jtae.ari.ac.ir

JTAE

شاپای الکترونیکی: ۴۲۵۳-۲۶۷۶

مقاله پژوهشی

طبقه‌بندی و شناسایی عیوب موتور توربوجت با شبکه عصبی خودسازمان‌ده و خوشه‌بندی ماشین بردار پشتیبان

فریده‌سادات هاشمی‌فرد [۱]، مهدی جهرمی [۲]، مصطفی خزائی [۳*]، و مصطفی محمودی [۴]

۱- کارشناس ارشد، دانشکده مهندسی هوافضا، دانشگاه صنعتی مالک اشتر، تهران

۲،۴- دانشیار، دانشکده مهندسی هوافضا، دانشگاه صنعتی مالک اشتر، تهران

۳- استادیار، دانشکده مهندسی هوافضا، دانشگاه صنعتی مالک اشتر، تهران

اطلاعات مقاله

تاریخچه مقاله:

دریافت ۲۱ اردیبهشت ۱۴۰۴

بازنگری ۱۸ آذر ۱۴۰۴

پذیرش ۶ دی ۱۴۰۴

اولین انتشار ۸ بهمن ۱۴۰۴

واژه‌های کلیدی:

نظارت بر سلامت موتور

تشخیص و پیش‌بینی عیوب

طبقه‌بندی عیوب

شبکه عصبی

موتور توربوجت

چکیده

توسعه سیستم‌های نظارت بر سلامت موتور یکی از چالش‌های صنعت هوانوردی است که می‌تواند با بهبود قابلیت دسترسی‌پذیری و قابلیت اطمینان موتور، صرفه‌جویی قابل توجهی به‌همراه آورد. یک ساختار پیش‌بینی سلامت، با ارائه تخمینی دقیق و به‌موقع از وضعیت سلامت فعلی موتور، زمینه کاهش تعمیرات و نگهداری برنامه‌ریزی‌نشده را فراهم می‌کند. جهت دستیابی به راندمان بالاتر در تشخیص عیوب و نیز تسهیل شروع سریع این روند، نیاز به الگوریتم با حساسیت کمتر نسبت به حجم داده‌های آموزشی در این مسئله وجود دارد. در این مقاله یک الگوریتم تشخیص عیب موتور توربوجت، مبتنی بر شبکه عصبی خودسازمان‌ده ارائه شده است که از خوشه‌بندی داده‌ها برای این هدف استفاده می‌کند. این روش یادگیری، خوشه‌های مستقل داده‌ها را با روش ماشین بردار پشتیبان تعیین نموده و اثربخشی فرآیند آموزش را افزایش می‌دهد. برای شناسایی الگوی عیوب از شبکه عصبی پیشخور دولایه و برای طبقه‌بندی عیوب از تکنیک بردارهای پشتیبان ماشین استفاده شده است. بدین‌ترتیب، حجم داده‌های آموزشی مورد استفاده جهت راه‌اندازی الگوریتم به شدت کاهش می‌یابد و در نتیجه، هزینه و زمان تست‌های زمینی و پروازی مورد نیاز برای تأمین داده‌ها کمتر می‌شود. نتایج به‌دست آمده از پیاده‌سازی الگوریتم روی داده‌های شبیه‌سازی شده سنسورهای موتور J85 در حالات سالم، خوردگی، سایش، رسوب‌گرفتگی و خطای نازل سوخت، حاصل از یک مدل ترمودینامیکی صحه‌سنجی شده، نشان‌دهنده توانایی روش پیشنهادی در پایش سلامت به‌روش عملکردی است. همچنین به‌رغم کاهش داده مورد استفاده جهت آموزش شبکه به یک پنجم، دقت شناسایی عیوب از ۹۹/۸ به ۹۷/۷ کاهش یافته که مطلوب است.

پست الکترونیکی نویسنده مسئول: khazaee_m@mut.ac.ir

How to Cite this Article:

F. S. Hashemifard, M. Jahromi, M. Khazaee, and M. Mahmoodi, "Classification and identification of turbojet engine faults with self-organizing neural networks and support vector machine clustering," *Journal of Technology in Aerospace Engineering*, vol. 10, no. 2, pp. 105-120, 2026, (in Persian), https://doi.org/1022034/jtae.10.2.8.

COPYRIGHTS

© 2026 by the authors. Published by ARI. This article is an open access article distributed under the terms and conditions of The Creative Commons Attribution 4.0 International (CC BY 4.0)

علائم و اختصارات

سیستم استنتاج عصبی–فازی سازگار	Adaptive neurofuzzy inference system	ANFIS
شبکه عصبی مصنوعی	Artificial neural network	ANN
واحدبرق کمکی	Auxiliary power unit	APU
پس انتشار	Back propagation	BP
ظرفیت گرمایی در فشار ثابت	kj/kg/k	C_P
ماشین یادگیری افراطی	Extreme learning machine	ELM
دمای خروجی گاز	Exhaust gas temperature	EGT
الگوریتم ژنتیک	Genetic algorithm	GA
آنالیز مسیر گاز	Gas-path analysis	GPA
پارامتر مسیر گاز	Gas-path parameter	GPP
نزدیکترین همسایه K	K-nearest neighbors	K-NN
شبکه عصبی مدولار	Modular neural network	MNN
سری زمانی مدل برونی خودپندارنده غیرخطی	Nonlinear autoregressive exogenous	NARX
پیش بینی پایش سلامت	Predict health monitoring	PHM
شبکه عصبی شعاعی	Recurrent neural network	RN
شبکه عصبی احتمالی	Probabilistic neural network	PNN
طول عمر مفید	Remaining useful life	RUL
نقشه خودسازمانده	self-organization map	SOM
ماشین بردار پشتیبان	Support vector machine	SVM
دبی جرمی	Kg/s	MF
فشار توربین	Kpa	P_5
دمای کمپرسور	K	T_3
دمای خروجی توربین	K	T_5
ضریب یادگیری	–	α
راندمان	–	η
بردار وزن	–	$W_v(s)$
بردار ورودی	–	$D(t)$
نورون	–	v
تابع همسایگی	–	θ

۱. مقدمه

توسعه سیستم‌های نظارت بر سلامت موتور یکی از چالش‌های مستمر صنعت هوانوردی است. موتورهای توربین گازی سیستم‌های پیچیده‌ای هستند که هزینه عملیاتی بالایی دارند. پیاده‌سازی روش‌های توسعه‌یافته نظارت بر سلامت موتور می‌تواند میلیون‌ها دلار از طریق بهبود قابلیت دسترسی‌پذیری و قابلیت اطمینان موتور، صرفه‌جویی کند [۱]. پیشرفت‌های اخیر در تکنیک‌های محاسبات هوشمند و یادگیری ماشین این امکان را فراهم کرده است که روش‌های بهتری برای مدیریت و نظارت بر سلامت موتورهای جت در طول زمان به‌کار گرفته شود.

خرابی‌های مختلفی در یک موتور توربین گاز رخ می‌دهد و روش‌های بسیار زیادی برای نظارت بر آن‌ها وجود دارد. تلاش شده است تا روشی مناسب در ابزار نظارت از راه دور ارائه شود. تشخیص عیب دیجیتال توربین گازی به‌عنوان یکی از تجهیزات با ارزش و اصلی در نیروگاه‌ها موضوع بسیاری از تحقیقات در سال‌های اخیر بوده است. تولیدکنندگان توربین گازی با اتصال تجهیزات صنعتی، داده‌ها و اینترنت، بستری جهت بهینه‌سازی نظارت و مدیریت دارایی فراهم کرده اند. نمونه‌هایی از چنین فناوری‌هایی، سیستم پیش‌بینی GE و دوقلوهای دیجیتال هستند که در مورد توربین‌های گازی و موتورهای مختلف در سراسر جهان مورد شبیه‌سازی، نظارت و تجزیه و تحلیل قرار می گیرند. یکی دیگر از تکنولوژی های جدید در زمینه پایش سلامت استفاده از ابزار C-MAPSS40K به‌عنوان تسهیل‌کننده اصلی تولید بانک داده است. این ابزار که توسط ناسا ارائه شده است، یک مجموعه نرم‌افزاری قدرتمند شبیه‌سازی موتور توربین گاز است که طیف قابل توجهی از شرایط عملکردی موتور را ارائه می‌دهد.

تجزیه و تحلیل داده‌های عملکرد موتور برای تعیین سلامت موتور می‌تواند به روش‌های مختلفی ظاهر شود. برخی از رویکردهای تشخیص خطا و PHM[1] شامل مقایسه داده‌های عملکرد با داده‌های اسمی و غیر معیوب و شناسایی اختلافات به‌عنوان منابع بالقوه خطا است. سایر رویکردها از رگرسیون ریاضی خالص مانند فیلترهای کالمن برای شناسایی اختلافات استفاده می‌کنند. این مقاله به استفاده از سیستم‌های هوشمند برای حل این مشکل می پردازد. دو روش برای سیستم‌های هوشمند در دست بررسی وجود دارد: رویکردهای داده‌محور که تکنیک‌های یادگیری ماشینی (شبکه‌های عصبی) را در بر می‌گیرد و رویکردهای سیستم‌های خبره مبتنی بر استدلال زبانی (سیستم‌های مبتنی بر منطق فازی).

در این مقاله، روش استفاده شده توسط مکمن و همکاران [۲] برای افزایش دقت شبکه بررسی شده است. مکمن و همکاران خطاهای

1. Prognostic Health Monitoring

تشخیصی یک شبکه عصبی منفرد آموزش‌دیده را با ۸۷ و ۱۷۵ نمونه آموزشی در دو کارآزمایی مختلف مقایسه کردند. نتایج مکمن و همکاران نشان داد که خطای تشخیصی تنها به‌دلیل استفاده از یک مجموعه آموزشی بزرگتر از ۲/۴ دزصد به ۱/۶ درصد بهبود یافته است. چند تفاوت کلیدی بین روش پیشنهادی در این مقاله و روش استفاده شده توسط مکمن وجود دارد که در اینجا خلاصه شده است.

این مقاله استفاده از نگاشت خودسازمانده را برای خوشه‌بندی داده‌ها قبل از اعمال الگوریتم تشخیصی/ پیش‌بینی مبتنی بر شبکه عصبی پیشنهاد می‌کند. این روش یادگیری ابتدا استقلال داده‌ها را نشان می‌دهد و نسبت به رویکردهایی که داده‌ها را از قبل خوشه‌بندی نمی‌کنند، بهبودهایی ایجاد می‌کند. به‌منظور ارزیابی اثربخشی روش پیشنهادی، در این مقاله موتور توربوجت J85 برای عیب‌یابی انتخاب شده است.



شکل ۱- تصویر موتور J85 .

Fig. 1. Image of the J85 engine.

۱- ۱ مروری بر پژوهش‌های پیشین

مراجع بسیاری در زمینه عیب‌یابی موتورهای توربین گاز هوایی تحقیقات گسترده ای انجام داده‌اند و از روش‌های مختلف شبکه عصبی استفاده کردند. شبکه‌های عصبی برای اولین بار در سال ۱۹۸۹ توسط دتیز و همکاران برای کاربردهای تشخیص عیوب توربین گاز معرفی شدند و از آن زمان تا کنون بسیار مورد استفاده قرار گرفته‌اند. مزیت روش در این است که فقط داشتن دانش تجربی در مورد موتور برای آموزش شبکه‌های عصبی مورد نیاز و کافی است و زمان محاسبات لازم برای تشخیص عیوب پس از آموزش شبکه‌های عصبی، بسیار کوتاه است [۳]. این روش توسط اوگاجی که از یک روش شبکه‌های عصبی چندگانه برای جداسازی خطاهای سنسور و مؤلفه استفاده کرد، گسترش یافت [۴].

جین به بررسی روش عیب‌یابی توربین گازی تولید توان با استفاده از شبکه عمیق پرداخته است. پس از معرفی توربین گاز و شبکه عصبی اقدام به بررسی یک مدل خاص و بررسی تاثیر خطاهای مختلف در عملکرد آن سیستم دارد [۵]. جولی به بررسی عیب‌یابی با استفاده از شبکه عصبی برای یک موتور توربوفن پرداخته است [۶]. وی سعی نمود تا با استفاده از شبکه عصبی به عیب‌یابی هم‌زمان چند ایراد پرداخته شود. سپس با طرح چند سناریو اقدام به صحه‌سنجی کردند، بدین‌گونه که با این سناریوها، تأثیر تغییرات عملکرد موتور بررسی شده و با آموزش آن به شبکه یاد داده می‌شود که چند ایراد همزمان را شناسایی کند.

حناچی و همکاران از یک چارچوب ANFIS برای تشخیص عیب در یک توربین گاز تک محوره تحت شرایط عملیاتی متغیر با ۸۱ ترکیب مختلف خطا، یعنی چهار خطا، هر یک در سه سطح شدت استفاده کردند. آن‌ها نشان دادند که وقتی که پنج GPP به‌جای چهار پارامتر در فرآیند تشخیص الگو استفاده می‌شود، میانگین خطای تشخیصی از ۵/۸ درصد به ۲/۱ درصد کاهش می‌یابد. آن‌ها همچنین نشان دادند که بهبود ۱۰ دسی بل در نسبت سیگنال به نویز می‌تواند خطای تشخیصی نرمال شده را تا ۰/۳ کاهش دهد [۷].

SVM توسط ویرا و همکاران به‌عنوان یک تکنیک طبقه‌بندی جدید برای توصیف خرابی‌های اولیه در APU هواپیما استفاده شد. آن‌ها پارامترهای SVM را به‌گونه‌ای تنظیم کردند که ۵۰ درصد از ویژگی‌های ورودی در حین آموزش در حاشیه طبقه‌بندی‌کننده، طبقه‌بندی می‌شوند و الگوریتم برای نظارت بر وضعیت سلامت APU مورد استفاده قرار گرفت [۸]. یانگ و همکاران از بهینه‌سازی ازدحام ذرات با رفتار کوانتومی برای بهینه‌سازی پارامترهای شبکه در یک ELM برای طبقه‌بندی خرابی توربین گاز استفاده کرد. آن‌ها ۶ تا ۹ درصد دقت بهتری نسبت به ELM و SVM معمولی برای تشخیص خرابی در هشت سناریو خرابی و دو شرایط عملیاتی به‌دست آوردند [۹].

فاست و همکاران [۱۰] و عسگری و همکاران [۱۱]، مدل‌های شناسایی خرابی سیستم مبتنی بر ANN را توسعه دادند که پارامترهای توربین‌های گازی را در شرایط مختلف پیش‌بینی می‌کنند و به‌ویژه در ارزیابی سلامت عملکرد موتور مفید هستند، به‌خصوص اگر داده‌های واقعی فقط در یک زمان محدوده عملیاتی محدود در دسترس باشند. برای اجرای ترکیبی از پایش سلامت مکانیکی و عملکرد، باراد و همکاران یک شبکه عصبی چندلایه پیشخور (MNN) با دو لایه پنهان با استفاده از الگوریتم شیب نزولی محبوب پس‌انتشار (BP) برای آموزش شبکه توسعه دادند [۱۲]. نتیجه به‌دست آمده نشان می‌دهد که ابزار نظارت بر سلامت عملکرد مبتنی بر ANN به اندازه کافی قوی است و در مقایسه با پارامترهای مکانیکی یک هشدار اولیه ارائه می‌دهد.

شبکه‌های عصبی پویا نیز برای دستیابی به تشخیص عیب و جداسازی موتورهای توربین استفاده شدند. مدل‌های مبتنی بر شبکه‌های عصبی تطبیقی پویا که در منابع [۱۳, ۱۴] ارائه شده‌اند نشان می‌دهند که مشکل تشخیص و جداسازی عیب موتور دو محوره را می‌توان با استفاده از بانکی از شبکه‌های عصبی پویا حل کرد. لوبودا شبکه عصبی احتمالی (PNN) را با روش‌های پنجره Parzen (PW) و نزدیک‌ترین همسایه k (K-NN) برای طبقه‌بندی توربین گاز را با استفاده از تخمین چگالی احتمال، مقایسه نمود [۱۵].

یو و همکاران یک شبکه عصبی بهینه شده ازدحام ذرات را برای انجام یک پیش‌بینی سری زمانی پارامترهای سلامت به‌کار بردند [۱۶]. وطنی و همکاران دو روش هوش مصنوعی را برای پیش‌بینی تخریب موتورهای توربین گاز پیشنهاد کردند [۱۷]. اولین طرح، پیش‌بینی مبتنی بر یک شبکه عصبی بازگشتی (RNN) بود که یادگیری مربوط به تخریب موتور را از داده‌های قابل اندازه‌گیری موجود امکان‌پذیر می‌کند. طرح دوم بر اساس معماری شبکه عصبی خود رگرسیون غیرخطی با ورودی برون‌زا (NARX) بود. نشان داده شده است که شبکه NARX را می‌توان با نقاط داده کمتری آموزش داد و خطاهای پیش‌بینی، کمتر از خطاهای معماری RNN به‌دست آمده است. در مطالعه دیگری، داروغه و همکاران یک مدل ترکیبی برای ساختن پروفایل‌های مشاهده‌گر در افق‌های زمانی آینده توسعه دادند [۱۸]. در مدل پیشنهادی آن‌ها، رویکرد فیلتر ذرات به‌عنوان یک روش مبتنی بر مدل برای محاسبه وضعیت موتور و پارامترهای سلامت استفاده شده و به‌عنوان یک تکنیک محاسباتی، از رویکرد شبکه‌های عصبی مصنوعی برای پیش‌بینی طرح سلامت آینده موتور با استفاده از مشاهدات به‌دست آمده استفاده شد. مدلی ترکیبی از ویژگی‌های شبکه‌های عصبی و سیستم‌های خبره توسط دیولد و گاس برای تشخیص تغییر روند و پیش‌بینی موتورها توسعه داده شد [۱۹].

قهرمانی و کشاورز به بررسی تشخیص عیب توربین گاز با استفاده از مدل ترمودینامیکی و پارامترهای مؤثر بر آن در شرایط مختلف کارکردی پرداختند [۲۰]. خدادادیان و همکاران با استفاده از شبکه عصبی اقدام به طراحی سیستم عیب‌یابی برای یک موتور سوخت مایع کردند [۲۱]. در گام اول یک مدل سیمولینک کامل از موتور ارائه شده و در ادامه با بررسی دو عیب گرفتگی مسیر و بروز کاویتاسیون اقدام به بررسی تاثیرات آن در عملکرد نموده‌اند که این تأثیرات با استفاده از شبکه عصبی آموزش داده شده و داده‌های آن اعتبارسنجی شدند.

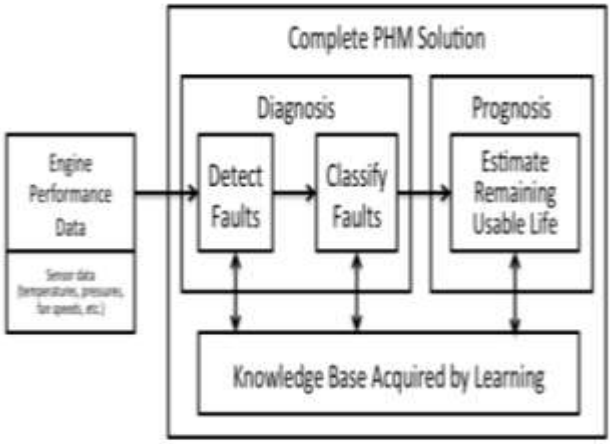
ژانگ و همکاران یک مدل ترکیبی CNN-LSTM برای پیش‌بینی باقی عمر مفید موتورهای هواپیما ارائه دادند که نقش کلیدی در عیب‌یابی پیش بینانه دارد [۲۲]. کولو و همکاران از یک شبکه عصبی عمیق برای تشخیص عیب با استفاده از داده های چندوجهی (ترکیب داده های ارتعاشی، حرارتی و فشار) استفاده کردند [۲۳]. یک الگوریتم هوشمند خودپایشی و اصلاح سیگنال برای موتور توربوشفت بالگرد مبتنی بر روش بهبود یافته LSTM جهت عیب سنسور توسعه داده شد [۲۴]. آسیف و همکاران یک مدل خطی پیوسته تکه‌ای برای افت عملکرد و پیش‌بینی عمر باقیمانده پیشنهاد دادند [۲۵]. کائو و همکاران با هدف رفع محدودیت تلفیق داده‌های سنسورهای موتور برای پیش‌بینی خرابی، از شبکه‌های عصبی گرافی جهت تطبیق دینامیکی بهره گرفتند [۲۶].

کوبایاشی و همکاران یک روش تشخیصی توربین گاز را با استفاده از شبکه‌های عصبی و الگوریتم‌های ژنتیک بررسی کرده اند [۲۷]. در این تحقیق، ANN برای تخمین سلامت داخلی موتور و GA برای تشخیص سوگیری سنسور در عدم قطعیت اندازه‌گیری استفاده شد. در کار مشابه ارائه شده توسط سمپس و سینق، توابع شبکه عصبی تو–در–تو به‌عنوان یک پیش‌پردازنده یا فیلتر برای کاهش تعداد کلاس‌های خطا که توسط مدل تشخیصی موتور مبتنی بر GA مورد بررسی قرار می‌گیرند، استفاده شد [۲۸]. نتایج بهبود در دقت، قابلیت اطمینان و ثبات تشخیص را نشان داده شده است. محمدی و همکاران در پژوهش خود، تکنولوژی جدید برای تشخیص فنی عیب در موتورهای توربین گاز با استفاده از شبکه‌های عصبی دینامیکی ارائه کردند [۲۹]. روشی که شبکه عصبی خودسازمان‌ده فازی را برای تشخیص عیب موتور توربین گازی به‌کار می‌برد توسط جیانگ و همکاران [۳۰] توسعه داده شد. در این روش رابطه بین علت خطا و علائم خطا بر اساس ریاضیات فازی برقرار شده است. تصاویر نقشه دو بعدی از خطای نمونه تنظیم‌شده و خطاهای واقعی از طریق یک شبکه عصبی خود سازمان‌ده به‌دست آمده است.

۲. روش شناسی

رویه فعلی برای جلوگیری از خرابی فاجعه‌بار در موتورهای جت، انجام کاری است که به آن تعمیر و نگهداری دوره‌ای یا برنامه‌ریزی شده می‌گویند. موتورها طبق برنامه‌هایی که برای انواع موتورها مشابه هستند، باز، بررسی، آزمایش و تنظیم می‌شوند. موتور جت توانایی زیادی برای اطلاع‌رسانی وضعیت سلامت خود به بازرسان فنی ندارد. لذا باید وضعیت سلامت آن از هر چیزی که در دسترس و قابل مشاهد است، با باز کردن قاب و بازرسی بصری درون آن (تا حد امکان)، یا با تجزیه و تحلیل عملکرد موتور و تعیین اینکه کجا و چه زمانی عملکرد خوبی ندارد، استنباط شود. به‌عبارت دیگر، یک سیستم PHM هوشمند مورد نیاز است که می‌تواند تاریخچه عملکرد یک موتور را تجزیه و تحلیل کند و با اطمینان بالا در مورد دلایل اصلی مشکلات استنباط کند. این

تاریخچه عملکرد به‌شکل مجموعه‌ای از خروجی‌های جمع‌آوری شده از سنسورهای موتور در طول زمان است. از آنجایی‌که موتورها دارای برخی سنسورها هستند، لذا به‌نظر می‌رسد که می‌توانند مجهز به ابزاری برای بررسی وضعیت سلامتی خود باشند، حتی اگر فاقد امکانات لازم برای انتقال این اطلاعات باشند. وقتی موتورها از کار می‌افتند، برای تعیین دلیل بروز خرابی، داده‌های سنسورهای موتور، کلید رفع مشکل است. داده‌های سنسورها اغلب توسط نویز و بایاس منحرف می‌شوند، در نتیجه وضعیت واقعی موتور را پنهان می‌کنند و منجر به تخمین نادرست می‌شوند [۲۸]. در نهایت، اثر ترکیبی غیرخطی بودن سیستم و انتخاب سنسور ممکن است منجر به سناریوهای متعدد موتور معیوب شود که تغییرات اندازه گیری مشابهی را ایجاد کرده است. پرداختن به این مسئله دشوار است زیرا تکنیک‌های تخمین، به‌طور کلی، تنها یک مجموعه از پارامترهای سلامت تخمین زده شده را برای مجموعه‌ای از اندازه‌گیری‌ها بدون قابلیت نشان دادن سطح اطمینان در نتایج ارائه می‌دهند. با در دسترس بودن یک بانک اطلاعاتی ضروری و یک تابع مدل که این داده‌ها را به پارامترهای سلامت مرتبط می‌کند، امکان شناسایی اجزای معیوب وجود دارد [۳۱].



شکل ۲- شماتیک جریان منطقی یک راه حل کامل PHM [۲].

Fig. 2. Logic flow schematic of a complete PHM solution [2].

رویکردهای تشخیصی عملکرد موتورهای توربینی را می‌توان به‌طور کلی به روش‌های مبتنی بر مدل و مبتنی بر داده دسته‌بندی کرد. در روش‌های مبتنی بر مدل، یک مدل تحلیلی از موتور باید توسعه داده شود و به‌تدریج به روز شود تا با وضعیت فعلی موتور مطابقت داشته باشد. با استفاده از این فرآیند می‌توان پارامترهای سلامت را به‌طور پیوسته محاسبه کرد و انحراف آن‌ها از شرایط عادی را برای نظارت بر عملکرد پیاده سازی کرد [۳۲]. در روش‌های مبتنی بر داده، اگرچه ماژول تشخیص عیب را می‌توان تنها با داده‌های مربوط به وضعیت سالم موتور توسعه داد، ماژول جداسازی خطا باید برای وضعیت سالم و همه شرایط مختلف معیوب ایجاد شود. بنابراین، داده‌های مورد نیاز را می‌توان به سه روش جمع‌آوری کرد: ۱- از موتور واقعی در طول عمر آن، ۲- از آزمایش‌های تجربی، و ۳- از یک مدل موتور. شبیه‌سازی‌های موتور هوایی امکان تولید داده‌های شبیه‌سازی شده ارزشمندی را برای توسعه و ارزیابی راه‌حل‌های PHM مبتنی‌برداده فراهم می‌نماید. داده‌های شبیه‌سازی‌شده می‌توانند به‌طور مشخص انتشار خطاها را در یک موتور در طول زمان نشان دهند و نتایج انتشار آن خطا را از نظر داده‌های سنسور واقعی پیش‌بینی کنند.

در این مقاله از روش مبتنی بر داده برای تشخیص عیب‌های رایج موتور توربوجت J85 با استفاده از شبکه عصبی و بر اساس الگوریتم ماشین بردار پشتیبان استفاده شده است. یک سیستم تشخیص/پیش‌بینی مبتنی بر شبکه عصبی پیشنهاد شده است که ازنقشه‌های خود سازمان‌دهی‌شده برای خوشه‌بندی داده‌ها بهره می‌گیرد. این روش یادگیری، میزان استقلال داده‌ها را نشان می‌دهد و نسبت به رویکردهای عیب‌یابی که داده‌ها را خوشه‌بندی نمی‌کنند، عملکرد تفکیک بهتری حاصل می‌کند. عیب‌های مورد بررسی شامل خوردگی، فرسایش، رسوب گرفتگی و اختلال در سیستم سوخت‌رسانی است. ابتدا باید مشخص شود که هر عیب چه تغییراتی را در اجزای موتور ایجاد می کند. این تغییرات در مدل کامپیوتری موتور اعمال و نتایج در بانک داده آموزشی ثبت می‌شود.

۲- ۱ عیوب اجزا و تأثیر آن‌ها

مهم‌ترین عیوب قطعات اغلب در بخش کمپرسور و توربین رخ می‌دهند، زیرا این قطعات مهم‌ترین و گران‌ترین اجزا در موتورهای توربینی هستند. نمی‌توان عیب محفظه احتراق را از طریق تجزیه و تحلیل مسیر گاز تشخیص داد [۳۳]. عیوب رایج اجزای موتور توربینی شبیه‌سازی شده در این مقاله شامل رسوب‌گرفتگی، خوردگی، فرسایش و اختلال در سیستم سوخت‌رسانی برای موتور J85 می‌باشد. توضیح مختصری از این عیوب در زیر قابل شرح است.

رسوب: رسوب‌گیری تجمع ذرات خارجی و/یا داخلی و رسوب روی سطوح تیغه است. این امر باعث تغییر در زبری سطح می‌شود و بر شکل آیرودینامیکی تیغه تأثیر می‌گذارد. رسوب همچنین می‌تواند باعث کاهش ناحیه گلوگاه شود و در نتیجه بر جریان تأثیر بگذارد. یکی از اثرات عمده کاهش در جریان جرمی و نسبت فشار کمپرسور خواهد بود. راندمان کمپرسور نیز می‌تواند تحت تأثیر قرار گیرد. رسوب، شایع‌ترین علت خرابی کمپرسور است و به‌عنوان منبع تقریبی ۷۰ تا ۸۵ درصد کاهش عملکرد در موتورهای توربین گاز شناخته می‌شود. با این‌حال، رسوب یک خرابی قابل باز یافت است و می‌تواند با تمیز کردن کاهش

یابد یا حتی از بین برود تا سطوح مسیر جریان موتور توربین گاز به شرایط اولیه نزدیک شود.

فرسایش: حذف مواد از اجزای مسیر جریان از طریق ذرات سخت ساینده مانند ماسه و خاکستر بادی به‌عنوان فرسایش شناخته می شود. فرسایش باعث کاهش عملکرد به‌دلیل کاهش زبری سطح، افزایش فاصله نوک تیغه، کند شدن لبه جلویی تیغه، نازک شدن لبه عقب و کوتاه شدن وتر تیغه می‌شود. استحکام قطعات نیز به خطر افتاده است و می‌تواند باعث شکست ناگهانی شود. اثرات فرسایش می‌تواند در سطوح مختلفی از خرابی باشد. در کمپرسورها، فرسایش می‌تواند منجر به کاهش نسبت فشار و سرعت جریان جرمی شود. فرسایش، جریان جرمی را افزایش می‌دهد و در نتیجه راندمان موتور را کاهش می‌دهد و بنابراین بر نیروی پیشران تولیدی تأثیر می‌گذارد. در بخش توربین، آسیب ناشی از ذرات فرسایشی که همراه با سوخت وارد می‌شوند بسیار شدید است، به‌ویژه اگر انسداد سوراخ‌های خنک‌کننده رخ دهد. افزایش بیش از حد دمای پره و شکستگی پره از پیامدهای اصلی این پدیده است. از آنجا که سیستم فیلتراسیون مورد استفاده در کاربردهای صنعتی اغلب می‌تواند بخش عمده ذرات بزرگ‌تر را حذف کند، فرسایش یکی از مشکلات عمده در موتورهای توربینی هوایی است.

خوردگی: از دست دادن یا تغییر ترکیب مواد در مسیر جریان ناشی از واکنش‌های شیمیایی بین قطعه و آلاینده‌های خاص که با هوا، سوخت، آب یا بخار ورودی به کمپرسور یا توربین وارد می‌شود. اجزای کمپرسور و توربین هر دو در معرض شرایط خورنده تهاجمی قرار دارند و از این‌رو، این خرابی اغلب به سه شکل تقسیم می‌شود، از جمله خوردگی بخش کمپرسور، خوردگی بخش داغ و خوردگی آماده به‌کار. خوردگی باعث افزایش دبی جرمی جریان در هر بخش می‌شود.

اختلال در سیستم سوخت‌رسانی: گرفتگی یا شل بودن نازل‌های سوخت از دلایل اصلی مشکل احتراق است و می‌تواند باعث ایجاد مشکلات شدید سوختگی در اجزای داغ پایانی موتور شود. احتراق ضعیف ممکن است منجر به گسترش دمای شعاعی غیریکنواخت و در نتیجه بروز نقاط داغ شود. چنین شرایطی به اجزای داغ موتور آسیب جدی وارد می‌کند و در نتیجه باعث کوتاه شدن عمر قطعات، زمان توقف برنامه‌ریزی نشده و افزایش هزینه تعمیر و نگهداری می‌گردد. مطابق مرجع [۳۴]، یکی از روش‌های مدل‌سازی وجود اشکال در سیستم سوخت‌رسانی، اعمال افت در بازده آیزنتروپیک محفظه احتراق می‌باشد اما تغییر این پارامتر در محیط خارج از طراحی امکان‌پذیر نیست. به‌همین دلیل جهت شبیه‌سازی این خرابی، بایستی این پارامتر را که جزو ورودی‌های نرم‌افزار جهت شروع مدل‌سازی در قسمت طراحی نرم‌افزار است، تغییر داد. مفهوم کاهش عملکرد پارامترهای سلامت در جدول ۱ نشان داده شده است.

جدول ۱- عیوب و پیامدهای آن بر پارامترهای سلامت [۱].

Table 1. Faults and consequences on health parameters [1].

Faults	Health parameters	
	ΔMF	$\Delta\eta$
Erosion	↑	↓
Corrosion	↑	-
Fouling	↓	↓
Fault in the fuel system	-	↓

با توجه به تمرکز این مقاله بر روی عیوب خوردگی، رسوب گرفتگی، فرسایش و اختلال در سیستم سوخت رسانی، تحلیل FMEA ذیل تنها برروی بخش‌های مستعد این عیوب در موتور توربوجت J85 متمرکز شده است. این بخش ها شامل پره‌ها و پوشش های کمپرسور و توربین، محفظه احتراق، نازل‌های سوخت و اجزای انتخابی از سیستم سوخت رسانی می‌باشند. با توجه به عدم دسترسی به داده‌های آماری کامل ناوگان هوایی موتور توربوجت J85، ارزیابی پارامترهای وقوع و کشف انجام نشده است.

جدول ۲- تحلیل FMEA برای موتور J85

Table 2. FMEA analysis for the J85 engine.

Section	Fault modes	Component-level symptoms	Effects on GT performance
compressor	-Compressor fouling -Blade/van erosion -Compressor corrosion	-Decrease in pressure ratio -Loss of isentropic efficiency -Reduction of flow capacity -Elevation of discharge temperature -Reduction of surge margine	-Increase of EGT for a given load -Loss of power -Loss of thrust -Increase of heat rate
Combustion chamber	-Corrosion and cracking of liners	-Drop in effectiveness of cooling air -Loss of combustor efficiency	-Increase of EGT for a given load -Loss of power -Loss of thrust

	-Clogging of fuel injectors -Malfunction of fuel delivery system	-Variation in fuel flow rate -Delayed or incomplete combustion -Loss of combustor efficiency	-Variation of EGT -Non-uniform EGT profile -Loss of power -Loss of thrust -Increase of heat rate
Turbine	-Turbine erosion	-Drop in turbine pressure ratio -Increase of mass flow capacity -Loss of isentropic efficiency	-Increase of EGT for a given load -Loss of power -Loss of thrust -Increase of heat rate -Increase of mass flow rate
	-Turbine fouling -Turbine corrosion	-Drop in turbine pressure ratio -Decrease in mass flow capacity -Loss of isentropic efficiency -Reduction of surge margine	-Increase of EGT for a given load -Loss of power -Loss of thrust -Decrease of heat rate

سناریو شدت عیب‌های کمپرسور و توربین و محفظه احتراق در شبیه‌سازی نرم‌افزاری در جدول ۳ نشان داده شده‌است. علامت منفی کاهشی بودن و علامت مثبت افزایشی بودن را نشان می دهد.

جدول ۳ –شدت عیب‌ها در موتور J85.

Table 3. Intensity of defects in the J85 engine.

Compressor blade fouling		
Intensity of defects	Percentage changes in efficiency isentropic	Percentage changes in compressor mass flow
Very little fouling	-2	-2
Low fouling	-4	-4
Middle fouling	-6	-6
Heavy fouling	-8	-8
Plenty fouling	-10	-10
Turbine blades erosion		
Percentage changes in turbine mass flow	Percentage changes in efficiency isentropic	Percentage changes in turbine mass flow
Very little erosion	-2	2
Low erosion	-4	4
Middle erosion	-6	6
Heavy erosion	-8	8
Plenty erosion	-10	10
Turbine corrosion		
Percentage changes in turbine mass flow		
2		
4		
6		
8		
10		
Malfunction of fuel delivery system		
Intensity of defects	burner p/p Percentage changes in	
Very little	-2	
Low	-4	
Middle	-6	
Heavy	-8	
Plenty	-10	

۲- ۲ مدل‌سازی و صحه‌سنجی موتور

برای مدل‌سازی عملکرد موتور توربوجت J85 از مرجع [۳۵] استفاده شده است که رفتار پایای موتور توربوجت J85 و شبیه‌سازی عیوب آن را مورد بررسی قرار داده است. در این بخش از مقاله، به بحث صحه‌سنجی نتایج مدل‌سازی پرداخته شده است. هدف از این کار

پی‌بردن به صحت عملکرد و قابل اعتماد بودن نتایج مدل‌سازی می‌باشد. جهت صحه‌سنجی نتایج، یکی از مطرح‌ترین نرم‌افزارهای موجود در زمینه مدل‌سازی توربین‌های گازی به‌نام نرم‌افزار GasTurb نسخه ۱۳ استفاده شد. این نرم‌افزار قادر است بیشتر انواع موتورهای هوایی از جمله توربوجت، توربوفن‌های مخلوط و غیرمخلوط یا بدون بوستر، توربوشفت یا بدون مبدل حرارتی و موتورهای توربوپراپ یک شفت یا دو شفت را شبیه‌سازی کند.

به واسطه استفاده مجزا از مشخصات نقطه طراحی در روند مدل‌سازی، این امکان ایجاد شده تا با تغییر منحنی‌های عملکردی توربین و کمپرسور و به‌روزرسانی مشخصات نقطه طراحی متناسب با موتور توربوجت J85 بتوان عملکرد پایا آن را شبیه‌سازی نمود. برای صحه‌سنجی لازم است تا مشخصات نقطه طراحی و منحنی‌های عملکردی (توربین و کمپرسور) یکسانی در مدل شبیه‌سازی شده در سیمولینک و مدل ایجاد شده در نرم‌افزار GasTurb مورد استفاده قرار گیرد، تا بتوان نتایج دو مدل را با یکدیگر مقایسه نمود.

صحه‌سنجی در حالت پایا برای ارتفاع و اعداد ماخ مختلف در نظر گرفته شده و حالت گذرا خارج از محدوده بررسی این مقاله است. با توجه به تحلیل در حالت پایا، پایه‌ی کارهای آینده شامل تحلیل گذرا ایجاد خواهد شد.

با تحلیل نتایج به‌دست آمده می‌توان به‌دقت مدل‌سازی انجام شده پی برد و متوجه شد که آیا مدل‌سازی انجام شده از صحت کافی برخوردار است یا خیر؟ در صحه‌سنجی حالت پایا نتایج به‌دست آمده بدون در نظر گرفتن اثر زمان و در نتیجه بدون در نظر گرفتن اثر اینرسی شفت و حجم کنترل اجزای موتور است، به‌بیان دیگر نتایج در زمانی که موتور به هم‌گرایی رسیده، حاصل شده است. در صحه‌سنجی پایا همه مقادیر مهم و مورد نیاز برای بررسی عملکرد موتور با هم مقایسه شده و در ارتفاع و ماخ‌های مختلف در نقاط طرح و خارج طرح انجام شده است. جدول ۴ مشخصات نقطه طراحی موتور توربوجت J85 را که جهت صحه‌سنجی انتخاب شده، نشان می دهد. در جدول ۵، نتایج مدل‌سازی در نقطه طرح با مدل GasTurb مقایسه شده است

جدول ۴- مشخصات نقطه طراحی موتور.

Table 4. Engine design point specifications.

Parameter	Engine J85
Inlet air mass flow rate (kg/s)	19.9
Engine speed at design point (RPM)	16540
Compressor efficiency	%82.5
Combustion chamber efficiency	%99.5
Fuel type	Jet-A
Turbine efficiency	0.88
Shaft mechanical efficiency	0.99
Thrust (kN)	14.392

جدول ۵- صحه‌سنجی نتایج در ارتفاع صفر و ماخ صفر.

Table 5. Validation of results at zero altitude and zero mach.

Parameter	Error(percentage)	GasTurb model	Simulink model
Inlet air mass flow rate (kg/s)	0	19.9	19.9
Compressor temperature(K)	0.51	542.10	547.33
Compressor pressure(kPa)	0.57	701.169	705.2
Compressor efficiency	0	0.825	0.825
Turbine outlet pressure(kPa)	1.17	268.561	271.725
Turbine outlet temperature(K)	1.74	1016.14	1033.85
Turbine efficiency	0.34	0.88	0.877
Thrust (kN)	0.71	14.47	14.574

جدول ۶- صحه‌سنجی در ارتفاع ۱۰۰۰ متری و عدد ماخ ۰/۸.

Table 6. Validation at 1000 meters altitude and Mach number 0.8.

Parameter	Error (%)	GasTurb model	Simulink model
Inlet air mass flow rate (kg/s)	0.88	8.945	9.024
Compressor temperature(K)	0.50	508.86	506.30
Compressor pressure (kPa)	0.90	319.188	316.287
Compressor efficiency	1.68	0.7824	0.7956
Turbine outlet pressure(kPa)	0.85	122.22	121.175

Turbine outlet temperature(K)	2.57	1036.83	1010.17
Turbine efficiency	1.40	0.8668	0.879
Thrust (kN)	2.85	5.68	5.518

در جدول ۶ مقایسه نتایج مدل‌سازی با GasTurb در ارتفاع ۱۰۰۰۰ متری و عدد ماخ ۰/۸ آورده شده است.

با بررسی نتایج مختلف می‌توان به این موضوع پی برد که داده‌های به‌دست آمده در مقایسه با مدل مرجع دارای صحت مناسبی است. برخی از خطاهای مربوط به کمپرسور و توربین می تواند مربوط به خوانش نمودارهای عملکردی باشد. از طرفی خطای مربوط به محاسبه ترم دمایی محفظه احتراق به نحوه محاسبه آن نیز مربوط است. در مدل‌سازی کنونی مقدار خواص جریان تابعی از دما در نظر گرفته شده و انتگرال دما به‌صورت $C_P \int T_3\, dt$ محاسبه شده است. در حالی‌که در محاسبات GasTurb این معادله به‌صورت $\int C_P\, T_3\, dt$ است که خود این عامل باعث بروز مقداری خطا در محاسبات می‌باشد.

۲- ۳ نحوه داده‌برداری از سیستم

بعد از بررسی صحت مدل شبیه‌سازی شده در سیمولینک برای آموزش شبکه عصبی باید از پارامترهای قابل اندازه‌گیری توسط سنسورهای واقعی در گام زمانی معین و دور موتور ثابت، بانک داده ایجاد کرد. تولید بانک داده با شبیه‌سازی موتور طی چندین چرخه سالم و موتور معیوب صورت می‌پذیرد.

که در این مقاله، عیوب رسوب گرفتگی در کمپرسور، فرسایش و خوردگی در توربین و اختلال در سیستم سوخت‌رسانی برای موتور J85 شبیه‌سازی شده است. با استفاده از یک مسیر تخریب از پیش تولید شده، پارامترهای متناظر با عیب را می‌توان به شبیه‌سازی اعمال کرد و داده‌های حاصله از خروجی‌های مربوط به سنسورهای موجود روی موتور جمع آوری کرد. نتیجه یک مجموعه کامل از داده‌های زمان کارکرد است که در کل طول عمر موتور امتداد می‌یابد.

داده‌ها به‌عنوان ورودی شبکه عصبی در نظر گرفته شده اند. این داده‌ها در حالت پایا و در ارتفاع و ماخ صفر از سیستم استخراج گردید. پارامترهای قابل اندازه‌گیری در این مدل با توجه به مطالعاتی که صورت گرفته است، دمای خروجی توربین، فشار خروجی کمپرسور، دور موتور و دبی جرمی موتور می‌باشد. به ازای هر ورودی سوخت، بعد از همگرا شدن نتایج، از مدل شبیه‌سازی شده در حالت سالم و شدت‌های مختلف عیب، داده‌ها استخراج شده اند. عیب می‌تواند در یک جزء و همچنین در چندین جزء به‌طور همزمان رخ دهد. همچنین ممکن است عیب‌های متعدد در یک جزء رخ دهد.

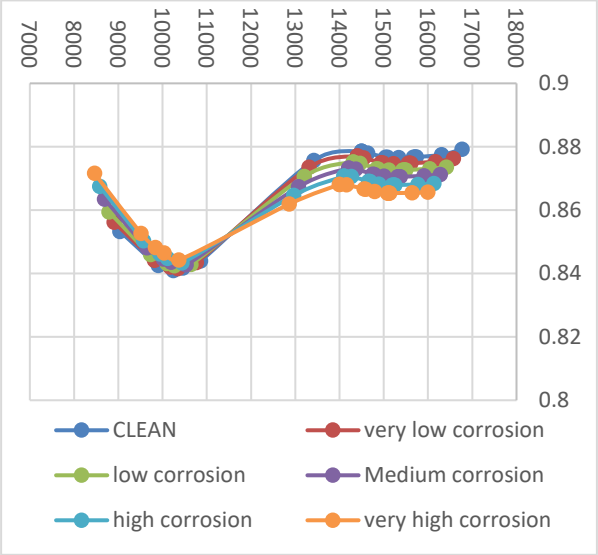
جدول ۷ یک نمونه از میزان انحراف در پارامترهای عملکردی موتور شامل دور، راندمان، دمای کمپرسور، محفظه احتراق و توربین، تراست و سرعت را در اثر اعمال عیب‌خوردگی در مدل نرم‌افزاری نشان می‌دهد.

جدول ۷- انحراف ایجاد شده در پارامترهای موتور در دورهای مختلف ناشی از بروز خوردگی در دبی MF = 0.2045.

Table 7. Deviations in engine parameters for different speeds due to corrosion at MF = 0.2045.

N	η_T	T3	P3	T5	Thrust	velocity	MF_T %	State
14639	0.878	0.489	49.73	0.800	8.452	0.513	1	Clean
14550	0.876	0.485	48.33	0.805	8.392	0.514	1.02	Very low
14460	0.875	0.480	47.01	0.810	8.333	0.515	1.04	Low
14366	0.873	0.476	45.74	0.814	8.255	0.516	1.06	Med
14264	0.871	0.472	44.49	0.819	8.219	0.516	1.08	High
14156	0.868	0.4679	43.28	0.826	8.157	0.515	1.10	Very high

در این مطالعه چهار عیب مطرح شده شبیه‌سازی شدند و میزان انحراف پارامترها در شدت‌های مختلف عیوب و در حالت سالم استخراج شده اند. یک نمودار از حالت خوردگی در شکل ۳ نمایش داده شده است، تغییرات راندمان توربین با افزایش دور موتور ابتدا کاهشی و بعد افزایشی می‌باشد. با اعمال شدت‌های مختلف خوردگی در توربین نسبت به حالت سالم موتور، راندمان به‌دلیل افزایش دبی جرمی توربین ابتدا افزایش و سپس با افزایش دور موتور کاهش می‌یابد.



شکل ۳- تغییرات بازده توربین در شدت‌های مختلف خوردگی توربین موتور J85

Fig. 3. Turbine efficiency changes in corrosion intensities in the turbine of the J85 engine.

۲-۴ شبکه عصبی

شبکه عصبی مصنوعی ابزاری بسیار کاربردی برای پیش‌بینی عملکرد توربین گاز و عیب‌یابی آن است. این الگوریتم رفتارهای غیرخطی موتور را بدون نیاز به معادلات پیچیده ترمودینامیکی که پارامترهای وابسته و مستقل را به یکدیگر مربوط می‌کنند، در پروسه یادگیری لحاظ می‌کند. این سیستم شامل گروهی از عناصر پردازشی ساده و بسیار به هم پیوسته (نورون‌ها)[1] با توابع انتقال خطی یا غیرخطی می‌باشد. این عناصر اطلاعات را با پاسخ حالت پویای خود به ورودی‌های خارجی پردازش می‌کنند. نورون‌ها در لایه‌های مختلفی از جمله لایه ورودی، لایه(های) پنهان و لایه خروجی قرار داده شده‌اند. تعداد نورون‌ها و لایه‌ها در یک مدل شبکه عصبی به درجه پیچیدگی دینامیک سیستم بستگی دارد. آزمایش شبکه عصبی با داده‌های مشابهی که در مجموعه آموزشی استفاده می‌شود، یکی از روش‌هایی است که برای تأیید کفایت یادگیری شبکه استفاده می‌شود. طرح اساسی سیستم را می‌توان به‌صورت زیر بیان کرد:

- تجزیه و تحلیل داده‌ها برای یافتن شواهد بروز خطا و طبقه‌بندی آن‌ها بر اساس مشابهت با داده‌های دیگر به‌طور خودکار، که در این مقاله با نگاشت خود سازمان‌ده انجام شده است.
- مجموعه داده‌ها با بهره‌گیری از طبقه‌بندها، تجزیه و تحلیل می‌شوند و تفکیک مقتضی بین عیوب را ایجاد می‌کنند.

1. Neurons

۲-۴-۱ نگاشت خود سازمان‌ده

یکی از انواع شبکه‌های عصبی مورد استفاده برای مسائل شناسایی عیب، نگاشت خود سازمان‌ده یا SOM است. گاهی اوقات این روش تحت عنوان نقشه کوهونن یا شبکه کوهونن نیز نامیده می‌شود. یک SOM با تغذیه تعدادی از بردارهای حاوی داده‌های نمونه‌برداری شده – فضای ورودی مورد انتظار– آموزش داده می‌شود. سپس فاصله اقلیدسی تا همه بردارهای وزنی را محاسبه می‌کند. نورونی که بردار وزن آن بیشترین مطابقت را با ورودی دارد، بهترین واحد تطبیق را نشان می‌دهد و وزن همه بردارها برای محاسبه بردار تازه‌وارد تغییر می‌کند. فرمول به‌روزرسانی برای یک نورون v با بردار وزن $W_v(s)$ در معادله (۱) آورده شده است.

این معادله یک بردار وزنی را برای مرحله زمانی بعدی $s+1$ نشان می‌دهد که بر اساس مقدار آن در مرحله زمانی قبلی به اضافه حاصل‌ضرب ارزیابی تابع همسایگی θ (با دادن فاصله بین نورون‌های u و v در s) ضریب یادگیری α (که به‌طور یکنواخت بر s کاهش می یابد) و فاصله بین بردار ورودی $D(t)$ و $W_v(s)$ در آن مرحله تنظیم می‌شود. با گذشت زمان، با کاهش θ، وزن‌ها شروع به همگرایی در تخمین‌های محلی می‌کنند، این تخمین‌ها گره‌های عضویت را تشکیل می‌دهند و با نزدیکی آن‌ها به گره‌های دیگر تعریف می‌شوند. از این‌رو، هر بردار ورودی، متعلق به یک گره طبقه‌بندی می‌شود، بنابراین نقشه ای ایجاد می‌شود که از نظر توپوگرافی، فضای ورودی را بر اساس میزان نزدیکی ورودی‌ها به یکدیگر نشان می‌دهد [۲].

$$W_v(s+1) = W_v(s) + \theta(u,v,s)\alpha(s)(D(t) - W_v(s)) \qquad (۱)$$

۲-۴-۲ طبقه‌بندی‌کننده

طبقه‌بندی (Classification) داده‌ها با روش یادگیری تحت نظارت (Supervised Learning) در یادگیری ماشین، با هدف نگاشت بین داده‌های ورودی و برچسب‌های خروجی صورت می‌پذیرد. داده‌های ورودی اغلب مجموعه‌ای از ویژگی‌ها (Features) هستند که ورودی را توصیف می‌کنند. در حالی‌که برچسب خروجی، یک کلاس یا دسته از پیش تعریف شده است که ورودی به آن تعلق دارد. هدف الگوریتم طبقه‌بندی، یادگیری یک مرز تصمیم است که کلاس‌های مختلف را در فضای ویژگی از هم جدا می‌کند، به‌طوری‌که بتواند کلاس ورودی‌های جدید و نادیده را بر اساس ویژگی‌های آن‌ها پیش‌بینی کند.

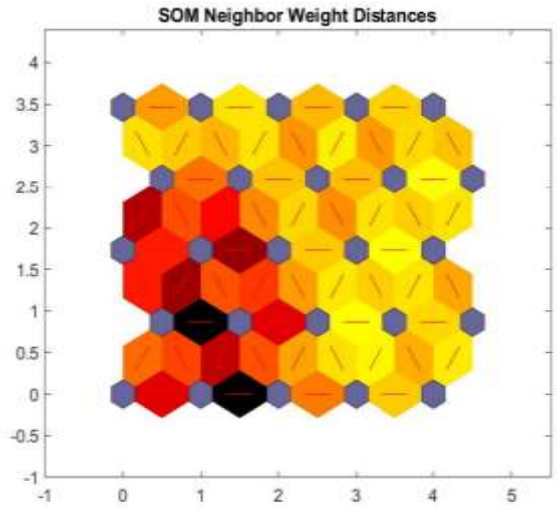
۳. نتایج

فرآیند تشخیصی دارای سه مرحله است: تشخیص خطا، جداسازی خطا و شناسایی خطا. در مجموعه داده‌های تولیدشده، در این مقاله، شناسایی حالت سالم و معیوب مد نظر بوده است. همچنین، طبقه‌بندی صحیح یک خطای در حال توسعه، با توجه به طبقه‌بندی‌هایی که تعریف شده است، صورت می‌پذیرد، تخصیص طبقه‌بندی بر اساس شباهت علائم یک موتور حاوی خرابی به علائم دیگر موتورها میسر شده است. در واقع، به مجموعه داده‌های مربوط به طول عمر یک موتور، یک طبقه‌بندی c از مجموعه همه طبقه‌بندی‌های ممکن C اختصاص داده می‌شود. اطلاع قبلی پیرامون بروز خطا وجود ندارد، به‌طور دقیق روشن نیست که کدام پارامترهای مرتبط با خرابی اعمال شده است و در چه زمان‌هایی چنین رویدادهایی رخ داده است. طبقه‌بندی‌های واقعی را می‌توان c* نامید. بنابراین، هر زمان که c با c* مطابقت داشته باشد، یک تشخیص موفقیت‌آمیز انجام شده است. اما در مورد طبقه‌بندی بدون نظارت نمی‌توان به این راحتی خطا را تعیین نمود. در این حالت C متفاوت است و بنابراین تأیید دقت طبقه‌بندی غیرممکن است. چنین طبقه‌بندی، نشان‌دهنده یک رویه‌ای برای توصیف فضای مسئله است، و قرار است به‌عنوان مرحله بعدی PHM یعنی مرحله پیش‌بینی، عمل کند.

در این بخش، نتایج در مجموعه‌ای از سه حالت مطالعه ارائه می‌شود: در بخش اول، نتایج سیستم تشخیصی هدایت شده بررسی می‌گردد که شامل یک ANN آموزش‌دیده برای تشخیص عیوب بر طبق توصیف مندرج در داده‌های آموزشی، به‌عنوان خرابی درکمپرسور، توربین و سیستم سوخت‌رسانی است. در بخش دوم، نگاشت خود سازمان‌ده برای همان داده‌ها، بدون هیچ دانش قبلی از روش تشخیصی و بر اساس فضای حالت حاصل از طبقه‌بندی‌ها مورد بحث قرار می‌گیرد. در بخش سوم، تلاش‌های انجام شده برای طبقه‌بندی و پیش‌بینی همزمان عیوب ارائه می‌گردد.

۳- ۱ نتایج سازمان دهی داده‌ها با SOM

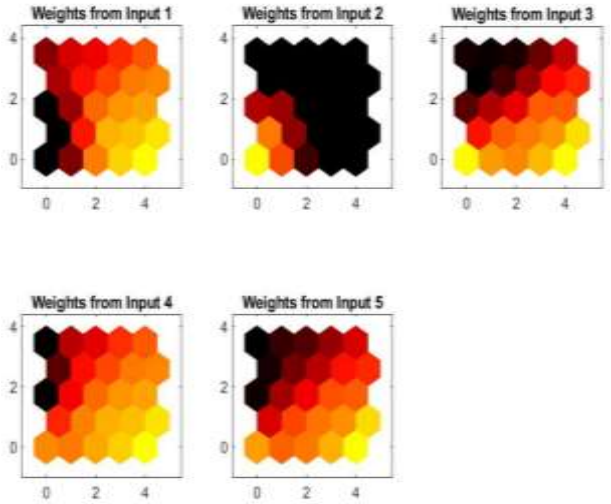
جعبه‌ابزار شبکه عصبی MATLAB پیاده‌سازی یک الگوریتم دسته‌ای SOM را برای شبکه‌های عصبی ارائه می دهد. تنها ورودی مورد نظر در ابتدای کار، اندازه نقشه است. از آنجایی‌که ۴ حالت معیوب و یک حالت سالم (۵ حالت خروجی) و ۵ ورودی وجود دارد، ۵ ورودی با یک ضریب افزایش داده می‌شوند و یک نقشه گره ۵ در ۵ را برای مجموع ۲۵ گره خوشه‌ای یا طبقه‌بندی بالقوه، تشکیل می‌دهند. از این رو، نقشه توپوگرافی مربوطه از فضای داده ۱۴۸۰ تایی ساخته می‌شود.



شکل ۴- شماتیک فاصله‌های همسایه SOM.

Fig. 4. Schematic of SOM neighbor distances.

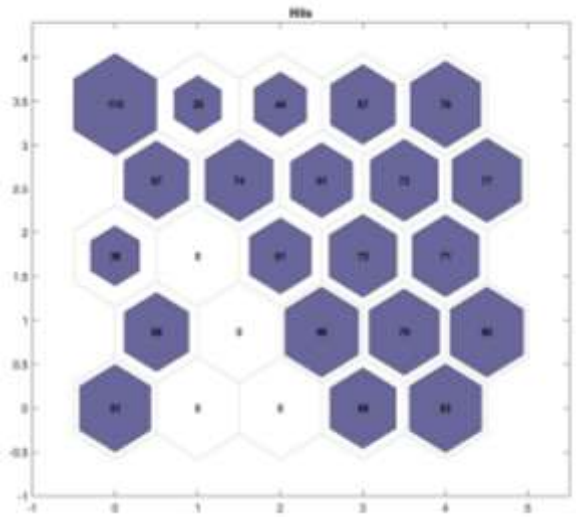
شکل ۴ نشان می‌دهد که چگونه گره‌های خوشه‌های مختلف با یکدیگر مرتبط هستند. رنگ‌های تیره نشان می‌دهد که فواصل بیشتر است.



شکل ۵- صفحات وزن SOM.

Fig. 5. SOM weight plates.

شکل ۵، نشان‌دهنده تعداد مجموعه‌ی ورودی اختصاص داده شده به هر گره خوشه برای ۵ ورودی و تأثیر هر کانال ورودی بر گره‌های مختلف خوشه است. رنگ‌های تیره‌تر نشانگر تاثیر کمتر است. ورودی دو (دمای کمپرسور) کمترین تأثیر را بر روی خروجی‌ها (حالت‌های معیوب) دارد.



شکل ۶- بازدیدهای نمونه SOM.

Fig. 6. Sample SOM visits.

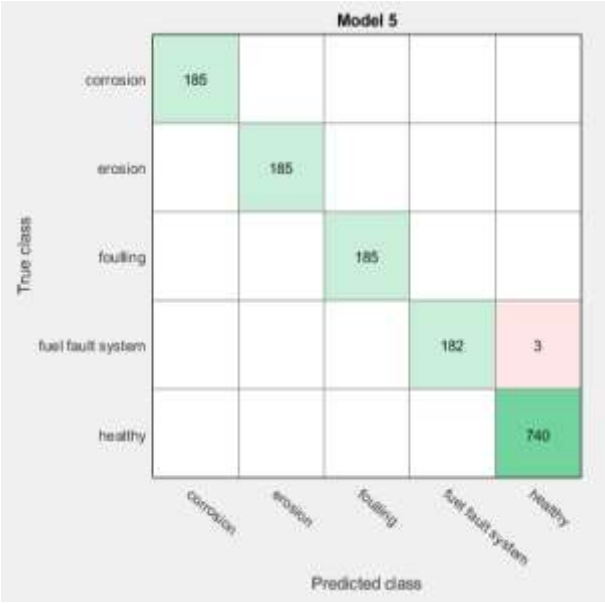
شکل ۶، تعداد مجموعه‌های ورودی اختصاص داده شده به هر گره خوشه را نشان می‌دهد.

۳- ۲ نتایج طبقه‌بندی عیوب

با توجه به اینکه SVM یک روش طبقه‌بندی مناسب برای تعیین دسته خطا است [۳۲]، از الگوریتم SVM Quadratic برای طبقه‌بندی داده‌ها قبل از سازماندهی استفاده شده است، که دقت ۹۹/۸ درصد برای آن به‌دست آمد. از الگوریتم SVM Linear برای طبقه‌بندی داده‌ها بعد از سازمان‌دهی بانک داده‌ها استفاده شده است و دقت آن برابر ۹۷/۷ درصد به‌دست آمد. در شکل ۷، ماتریس سردرگمی کلاس سالم و نتایج کلاس پیش‌بینی شده قبل از سازماندهی داده‌ها و در شکل ۱۰ بعداز سازماندهی داده‌ها مشاهده می‌شود. ماتریس سردرگمی با استفاده از پیش‌بینی‌های مشاهدات باقی‌مانده محاسبه می‌شود. سلول‌های قطر اصلی نشان می‌دهند که کلاس واقعی و کلاس پیش‌بینی شده به چه میزان مطابقت دارند. اگر این سلول‌ها سبز باشند، طبقه‌بندی به‌خوبی انجام شده و مشاهدات این کلاس واقعی را به‌درستی طبقه‌بندی کرده است.

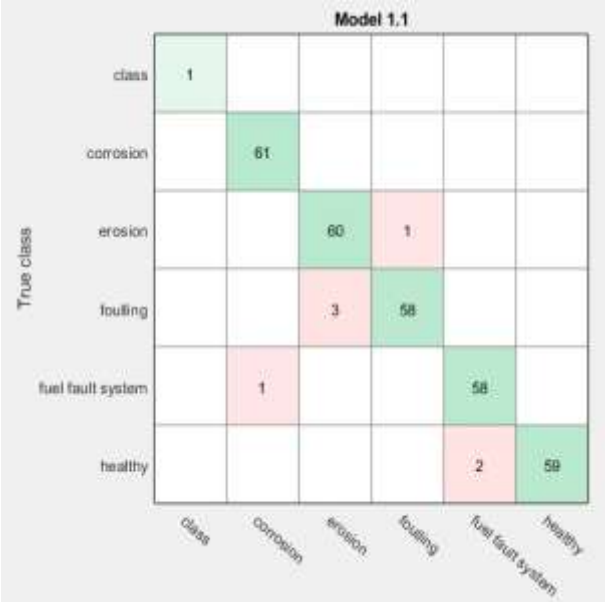
با بررسی سلول‌های خارج از قطر اصلی ماتریس که اعداد بالایی را نشان می‌دهند و قرمز هستند، طبقه‌بندی کننده در آن‌ها عملکرد پایین‌تری داشته است. در این سلول‌های قرمز، کلاس واقعی و کلاس پیش‌بینی شده مطابقت ندارند و داده‌ها به اشتباه طبقه‌بندی شده‌اند.

مطابق شکل ۹ و شکل ۱۰ از نمودار پراکندگی یا نمودار مختصات موازی برای بررسی ویژگی‌هایی که باید شامل یا حذف شوند، استفاده می‌شود. در شکل ۹ طبق نمودار پراکندگی دور موتور (N)، دمای خروجی توربین (T5)، دبی جرمی (MF) و فشار خروجی کمپرسور (P3) بهترین گزینه‌ها برای طبقه‌بندی و پیش‌بینی هستند. همچنین برای پیش‌بینی عیب فرسایش، دمای خروجی کمپرسور (T3) کاربرد چشمگیری دارد.



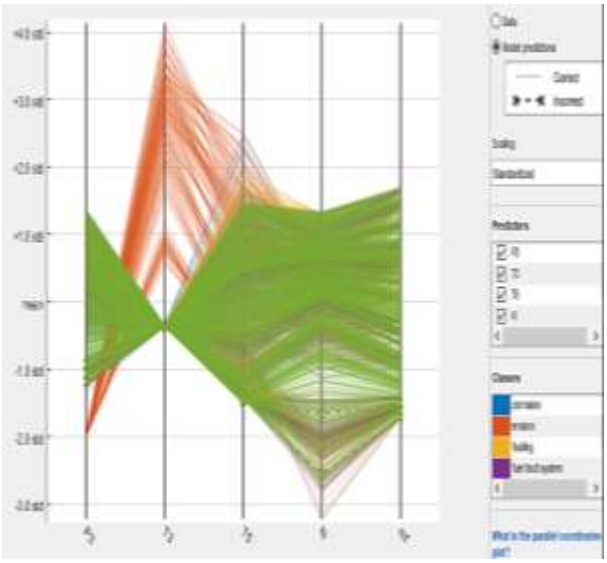
شکل ۷- ماتریس سردرگمی شبکه عصبی طبقه‌بندی‌کننده برای۱۴۸۰ داده و۲۰ نورون قبل از خوشه‌بندی بانک داده.

Fig. 7. Confusion matrix of the classifier neural network for 1480 data and 20 neurons before clustering the data bank.



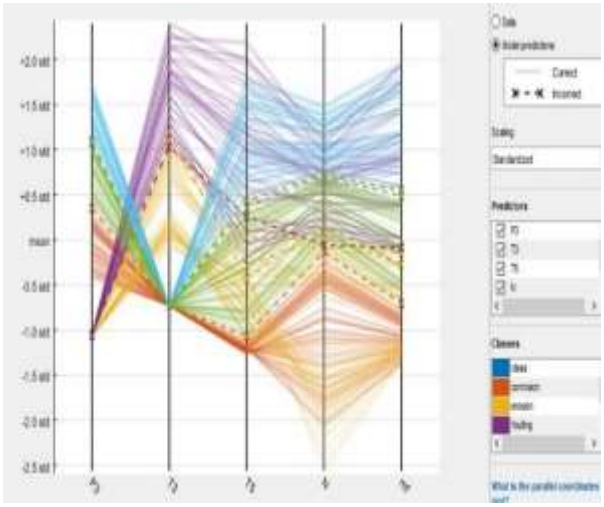
شکل ۸- ماتریس سردرگمی شبکه عصبی طبقه‌بندی‌کننده برای ۳۰۵ داده و ۲۰ نورون بعد از خوشه‌بندی پایگاه داده.

Fig. 8. Confusion matrix of the classifier neural network for 305 data and 20 neurons after clustering the database.



شکل ۹– نمودار مختصات موازی شبکه عصبی طبقه‌بندی‌کننده برای ۱۴۸۰ داده و ۲۰ نورون قبل از خوشه‌بندی پایگاه داده.

Fig. 9. Parallel coordinate diagram of the classifier neural network for 1480 data and 20 neurons before database clustering.



شکل ۱۰– نمودار مختصات موازی شبکه عصبی طبقه‌بندی‌کننده برای ۳۰۵ داده و ۲۰ نورون بعد از خوشه‌بندی بانک داده.

Fig. 10. Parallel coordinate diagram of the classifier neural network for 305 data and 20 neurons after database clustering.

۴. نتیجه‌گیری

در این پژوهش اثبات مفهومی یک چارچوب نظری برای PHM مبتنی بر داده با استفاده از بانک داده شبیه‌سازی شده از موتور توربوجت J85 در حضور عیوب فرسایش و خوردگی در توربین، رسوب در کمپرسور و اختلال در سیستم سوخت‌رسانی صورت گرفت. سازماندهی بانک داده‌ها و طبقه‌بندی همزمان چند عیب یک گام با دامنه محدود، به‌سمت سیستم های مدیریت سلامت موتور مستقل‌تر و ایمن‌تر است. با مقایسه دقت حاصل از شبکه عصبی که با خوشه‌بندی پایگاه داده‌ها و بدون خوشه‌بندی پایگاه داده‌ها قبل از اموزش شبکه عصبی طبقه‌بندی‌کننده حاصل شده است، در نهایت نتایج جدول ۸ به‌دست می‌آید.

جدول ۸- مقایسه دقت شبکه عصبی خوشه‌بندی‌شده با شبکه عصبی خوشه‌بندی نشده

Table 8- Accuracy comparison for clustered neural network with non-clustered dataset.

	Count data and neurons	Network accuracy
Organized data bank	305data and 20neurons	97.7
Unorganized data bank	1480data and 20neurouns	99.8

با توجه به جدول ۸ می‌توان به این نتیجه رسید که با سازمان‌دهی بانک داده‌ها و کاهش تعداد داده‌ها، مقدار دقت شبکه ۲/۱ درصد کاهش یافته و نوع الگوریتم SVM تغییر کرد. علت این کاهش دقت، کاهش قابل توجه حجم داده‌های آموزشی مورد استفاده است. دور موتور (N)، دمای خروجی توربین (T5)، دبی جرمی (MF) و فشار خروجی کمپرسور (P3)، بهترین گزینه‌ها برای طبقه‌بندی و پیش‌بینی هستند و دمای خروجی کمپرسور (T3) در پیش‌بینی عیب فرسایش شاخص است.

پدیده‌های نویز و خطای سنسورها در این مطالعه در نظر گرفته نشدند و به‌عنوان موضوع تحقیقات بیشتر واجد شرایط هستند. حساسیت سنسورهای موتور به نویز، با توجه به پتانسیل مخرب نویز برای مسدود کردن رفتارهای واقعی، شایستگی کاوش را دارد. همانطور که پیش‌تر اشاره شد بررسی عیوب در حالت گذار برای پژوهش آینده قابل بررسی است. در ادامه می‌توان تخمین عمر باقیمانده را با نتایج این مقاله، تقویت نمود. پیش‌بینی‌های حاصله در فرآیندهای تصمیم‌گیری در مقیاس بزرگ در مورد برنامه‌ریزی تعمیر و نگهداری و توسعه فناوری‌های جدید این حوزه کاربردی خواهند شد. تلفیق بین چارچوب ارائه شده در این مقاله، که بر یادگیری مؤثر تمرکز دارد، با روش‌های هوش مصنوعی جهت تصمیم‌گیری تعمیراتی، نوید کاربرد واقعی و توجیه‌پذیری توسعه الگوریتم‌های تکمیلی را می‌دهد.

تعارض منافع

هیچ گونه تعارض منافع توسط نویسندگان بیان نشده است.

مراجع

[1] A. M. Sajeev, "Gas Turbine Diagnostics Based on Gas Path Analysis," MSc. thesis, Delft University of Technology, 2015.

[2] O. B. Macmann, T. M. Seitz, A. R. Behbahani, and K. Cohen, "Performing diagnostics & prognostics on simulated engine failures using neural networks," in *52nd AIAA/SAE/ASEE Joint Propulsion Conference*, Salt Lake City, UT, USA, 2016, Art. no. 4807, https://doi.org/10.2514/6.2016-4807.

[3] W. P. Visser and M. J. Broomhead, "GSP: A generic object-oriented gas turbine simulation environment," *Proceedings of the ASME Turbo Expo 2000, Power for Land, Sea, and Air*, vol. 1, Aircraft Engine; Marine; Turbomachinery; Microturbines and Small Turbomachinery, Munich, Germany, 2000, https://doi.org/10.1115/2000-gt-0002.

[4] S. O. T. Ogaji, "Advanced gas-path fault diagnostics for stationary gas turbines," Ph.D. dissertation, Cranfield University, 2003.

[5] Y. Jin, Y. Ying, J. Li, and H. Zhou, "Gas path fault diagnosis of gas turbine engine based on knowledge data-driven artificial intelligence algorithm," *IEEE Access*, vol. 9, pp. 108932-108941, 2021. https://doi.org/10.1109/access.2021.3101647.

[6] R. Joly, S. Ogaji, R. Singh, and S. Probert, "Gas-turbine diagnostics using artificial neural-networks for a high bypass ratio military turbofan engine," *Applied Energy*, vol. 78, no. 4, pp. 397-418, 2004, https://doi.org/10.1016/j.apenergy.2003.10.002.

[7] H. Hanachi, L. Jie, and C. Mechefske, "Multi-mode diagnosis of a gas turbine engine using an adaptive neuro-fuzzy system," *Chinese Journal of Aeronautics*, vol. 31, no. 1, pp. 1-9, 2018. https://doi.org/10.1016/j.cja.2017.11.017.

[8] F. M. Vieira, C. de Oliveira Bizarria, C. L. Nascimento, and K. T. Fitzgibbon, "Health monitoring using support vector classification on an auxiliary power unit," in *Aerospace Conference*, Big Sky, MT, USA, 2009, https://doi.org/10.1109/aero.2009.4839655.

[9] X. Yang, S. Pang, W. Shen, X. Lin, K. Jiang, and Y. Wang, "Aero engine fault diagnosis using an optimized extreme learning machine," *International Journal of Aerospace Engineering*, vol. 2016, no. 1, 2016, Art. no. 7892875, https://doi.org/10.1155/2016/7892875.

[10] M. Fast, M. Assadi, and S. De, "Development and multi-utility of an ANN model for an industrial gas turbine," *Applied Energy*, vol. 86, no. 1, pp. 9-17, 2009, https://doi.org/10.1016/j.apenergy.2008.03.018.

[11] H. Asgari, X. Chen, M. B. Menhaj, and R. Sainudiin, "Artificial neural network–based system identification for a single-shaft gas turbine," *Journal of Engineering for Gas Turbines and Power*, vol. 135, no. 9, 2013, Art. no. 092601, https://doi.org/10.1115/1.4024735.

[12] S. G. Barad, P. Ramaiah, R. Giridhar, and G. Krishnaiah, "Neural network approach for a combined performance and mechanical health monitoring of a gas turbine engine," *Mechanical Systems and Signal Processing*, vol. 27, pp. 729-742, 2012, https://doi.org/10.1016/j.ymssp.2011.09.011.

[13] Z. S. Vanini, K. Khorasani, and N. Meskin, "Fault detection and isolation of a dual spool gas turbine engine using dynamic neural networks and multiple model approach," *Information Sciences*, vol. 259, pp. 234-251, 2014, https://doi.org/10.1016/j.ins.2013.05.032.

[14] S. S. Tayarani-Bathaie, Z. S. Vanini, and K. Khorasani, "Dynamic neural network-based fault diagnosis of gas turbine engines," *Neurocomputing*, vol. 125, pp. 153-165, 2014, https://doi.org/10.1016/j.neucom.2012.06.050.

[15] I. Loboda, "Gas turbine fault classification using probability density estimation," *Proceedings of the ASME Turbo Expo: Turbine Technical Conference and Exposition*, vol. 6, Ceramics; Controls, Diagnostics and Instrumentation; Education; Manufacturing Materials and Metallurgy. Düsseldorf, Germany, 2014, Art. no. V006T06A033, https://doi.org/10.1115/gt2014-27265.

[16] K. X. Zou, H. D. Ma, H. Z. Fang, and D. W. Yi, "Study of prognostics for spacecraft based-on particle swarm optimized neural network," in *Prognostics and System Health Management Conference*, Shenzhen, China, 2011, https://doi.org/10.1109/phm.2011.5939479.

[17] A. Vatani, K. Khorasani, and N. Meskin, "Health monitoring and degradation prognostics in gas turbine engines using dynamic neural networks," *Proceedings of the ASME Turbo Expo 2015: Turbine Technical Conference and Exposition*, vol. 6, Ceramics; Controls, Diagnostics and Instrumentation; Education; Manufacturing Materials and Metallurgy; Honors and Awards. Montreal, Quebec, Canada. 2015, Paper V006T05A030.2015, ttps://doi.org/10.1115/gt2015-44101.

[18] N. Daroogheh, A. Baniamerian, N. Meskin, and K. Khorasani, "A hybrid prognosis and health monitoring strategy by integrating particle filters and neural networks for gas turbine engines," in *Conference on Prognostics and Health Management (PHM)*, Austin, TX, USA, 2015, https://doi.org/10.1109/icphm.2015.7245020.

[19] H. R. DePold and F. D. Gass, "The application of expert systems and neural networks to gas turbine prognostics and diagnostics," *ASME Journal of Engineering for Gas Turbines and Power*, vol. 121, no. 4, pp. 607–612, 1999, https://doi.org/10.1115/1.2818515.

[20] A. Ghahremani, A. Keshavarz, "Implementation of an adaptive thermodynamic fault model to compensate the gas turbine degradationm," *Fluid Mechanics and Aerodynamics*, vol. 12, no. 1, pp.

107-121, 2023, (in Persian), https://dorl.net/dor/20.1001.1.23223278.1402.12.1.9.8.

[21] S. Khodadadiyan, R. Farokhi, D. Ramesh, "Design and algorithm for famage detection of a liquid propellant engine based on neural network in order to classification and identification of quantity and place of damage," *Aerospace Knowledge and Technology Journal*, vol. 7, no. 2, pp. 109-119, 2018, (in Persian).

[22] T. Huang, Q. Zhang, X. Tang, S. Zhao, and X. Lu, "A novel fault diagnosis method based on CNN and LSTM and its application in fault diagnosis for complex systems," *Artificial Intelligence Review*, vol. 55, no. 2, pp. 1289-1315, 2022, https://doi.org/10.1007/s10462-021-09993-z.

[23] O. Kullu and E. Cinar, "A deep-learning-based multi-modal sensor fusion approach for detection of equipment faults," *Machines*, vol. 10, no. 11, 2022, Art, no. 1105, https://doi.org/10.3390/machines10111105.

[24] S. Vladov, V. Vysotska, V. Lytvyn, N. Vladova, and Y. Sahun, "Intelligent self-monitoring and signal restoring system for the helicopter turboshaft engines gas temperature sensor with adaptive prediction," in *3rd International Workshop on Computer Information Technologies in Industry 4.0*, Ternopil, Ukraine.Ternopil, Ukraine, 2025, https://doi.org/10.31110/colins/2025-3/009.

[25] O. Asif, S. A. Haider, S. R. Naqvi, J. F. W. Zaki, K. S. Kwak, and S. M. R. Islam, "A eep learning model for remaining useful life prediction of aircraft turbofan engine on C-MAPSS dataset," *IEEE Access*, vol. 10, pp. 95425-95440, 2022, https://doi.org/10.1109/access.2022.3203406.

[26] X. Cao, B. Cheng, X. Yang, Y. Duan, and J. Gao, "Remaining useful life prediction method for turbofan engines based on graph neural network," *IEEE Sensors Journal*, vol. 25, no. 8, pp. 13566-13578, 2025, https://doi.org/10.1109/jsen.2025.3546498.

[27] T. Kobayashi and D. L. Simon, "Hybrid neural-network genetic-algorithm technique for aircraft engine performance diagnostics," *Journal of Propulsion and Power*, vol. 21, no. 4, pp. 751-758, 2005, https://doi.org/10.2514/1.9881.

[28] S. Sampath and R. Singh, "An integrated fault diagnostics model using genetic algorithm and neural networks," *Proceedings of the ASME Turbo Expo 2004: Power for Land, Sea, and Air*, vol. 2, Turbo Expo, Vienna, Austria, 2004, pp. 749-758, https://doi.org/10.1115/gt2004-53914.

[29] R. Mohammadi, E. Naderi, K. Khorasani, and S. Hashtrudi-Zad, "Fault diagnosis of gas turbine engines by using dynamic neural networks," in *International Conference on Quality and Reliability*, Bangkok, Thailand, 2011, pp. 25-30, https://doi.org/10.1115/gt2010-23586.

[30] D. X. Jiang, F. Wang, M. zhou, and W. Ni, "Application of fuzzy self-organizing neural network to aeroengine fault diagnosis," *Journal of Aerospace Power*, vol. 16, no. 1, pp. 80-82, 2001, (in Chinese), https://doi.org/10.7498/aps.52.1827.

[31] L. A. Urban, "Parameter selection for multiple fault diagnostics of gas turbine engines," *Journal of Engineering for Gas Turbines and Power*, vol. 97, no. 2, pp. 225-230, 1975, https://doi.org/10.1115/1.3445969.

[32] M. Tahan, E. Tsoutsanis, M. Muhammad, and Z. A. Karim, "Performance-based health monitoring, diagnostics and prognostics for condition-based maintenance of gas turbines: A review," *Applied Energy*, vol. 198, pp. 122-144, 2017, https://doi.org/10.1016/j.apenergy.2017.04.048.

[33] I. S. Diakunchak, "Performance improvement in industrial gas turbines," in *Turbo Expo: Power for Land, Sea, and Air*, 1993, vol. 79092: American Society of Mechanical Engineers, p. V001T01A005. Cincinnati, OH, USA, 1993. https://doi.org/10.1115/93-jpgc-gt-5.

[34] A. Razak and J. Carlyle, "An advanced model based health monitoring system to reduce gas turbine ownership cost," in *Turbo Expo: Power for Land, Sea, and Air*, vol. 78576, American Society of Mechanical Engineers, 2000, p. V004T04A032, Munich, Germany, https://doi.org/10.1115/2000-gt-0627.

[35] E. Mohammad, M. Jahromi, J. Pirkandi, M. Khazaee, M. Mahmoodi, "Development of an intelligent jet engine controller using a model-based deep deterministic policy gradient technique," *Journal of Mechanical Engineering and Sciences*, vol. 19, no. 3, 2025, https://doi.org/10.15282/jmes.19.3.2025.4.0842.