



Original Research Paper

A Model for Equipment Deterioration Prediction in Aviation Industry Using Deep Learning Methods (Case Study: Airplane Turbofan Engine)

Saeed Ramezani¹, Hamzeh Soltanali^{2*} , and Amir Beirami³

1,2. Faculty of Engineering, University of Iman Hossein (IHU), Tehran, Iran

3. Faculty of Engineering, University of Iman Hossein (IHU), Tehran, Iran

ARTICLE INFO**Article History:**

Received 20 June 2023

Revised 15 July 2023

Accepted 05 August 2023

Available Online 05 August 2023

Keywords:

Aviation industry
Deterioration prediction
Deep learning
Turbofan engine
Supervised learning
Artificial neural networks

ABSTRACT

One of the main propositions of predictive maintenance is Prognostics and Health Management (PHM), which plays a special role in identifying, diagnosing, and predicting the health status of physical assets. To that end, one of the fundamental solutions is to assess the condition of the equipment in the aviation sector in order to provide maintenance plans by determining the trend of deterioration or destruction. In this study, a developed model of an artificial neural network was presented, focusing on the concept of deep learning and its comparison with other conventional methods in response to the limitations and uncertainties in conventional prediction methods in determining the deterioration process of the equipment. The comparative results revealed that the deep learning neural network method with a prediction accuracy of 94% had a high performance in determining the deterioration process in aircraft turbine engines compared to other conventional methods. The results of this research can be used to predicting the remaining useful life and also providing appropriate maintenance programs in aviation industry equipment.

* Corresponding Author's E-mail: h.soltanali@ihu.ac.ir

How to Cite this Article:

S. Ramezani, H. Soltanali, and A. Beirami, "A Model for Equipment Deterioration Prediction in Aviation Industry Using Deep Learning Methods (Case Study: Airplane Turbofan Engine)," *Journal of Technology in Aerospace Engineering*, Vol. 8, No. 2, pp. 1-12, 2024, (in Persian), <https://doi.org/10.22034/jtae.2024.8.2.1>

COPYRIGHTS

Authors retain the copyright and full publishing rights.

Published by Aerospace Research Institute. This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).



ارائه مدلی جهت پیش‌بینی روند زوال تجهیزات در صنایع هوایی مبتنی بر مفهوم یادگیری عمیق (مطالعه موردی: موتور توربوفن هواپیما)

سعید رضانی^۱، حمزه سلطانعلی^{۲*}، و امیر بیرامی^۳

۱-۲- استادیار، دانشکده فنی و مهندسی، دانشگاه جامع امام حسین (ع)، تهران، ایران
۳- کارشناس ارشد، دانشکده فنی و مهندسی، دانشگاه جامع امام حسین (ع)، تهران، ایران

چکیده

مدیریت سلامت و پیش‌بینی عیوب به‌عنوان یکی از گزاره‌های اصلی نگهداری و تعمیرات پیشگویانه، نقش ویژه‌ای به‌منظور شناسایی، تشخیص و پیش‌بینی وضعیت سلامت انواع دارایی‌های فیزیکی ایفا می‌نماید. ارزیابی وضعیت سلامت انواع دارایی‌ها در صنعت هوایی، با هدف ارائه برنامه‌های نگهداشت، از طریق برآورد وضعیت زوال / تخریب یکی از راهکارهای اساسی است. در این مطالعه، با توجه به محدودیت‌ها و عدم قطعیت‌های موجود در روش‌های مرسوم پیش‌بینی در حوزه تعیین روند زوال تجهیزات، یک مدل توسعه‌یافته شبکه عصبی مصنوعی با محوریت مفهوم یادگیری عمیق و مقایسه آن با سایر روش‌های مرسوم ارائه شد. نتایج مقایسه‌ای نشان داد که روش شبکه عصبی پرسپترون عمیق با دقت پیش‌بینی ۹۴ درصد دارای عملکرد بالایی در تعیین روند زوال در موتورهای توربینی هواپیما در مقایسه با سایر روش‌های مرسوم داشته است. نتایج حاصل از این تحقیق می‌تواند در پیش‌بینی عمر مفید باقی‌مانده و نیز ارائه برنامه‌های مناسب نگهداشت در تجهیزات صنایع هوایی مورد استفاده باشد.

اطلاعات مقاله

تاریخچه مقاله:

دریافت ۳۰ خرداد ۱۴۰۲
بازنگری ۲۴ تیر ۱۴۰۲
پذیرش ۱۴ مرداد ۱۴۰۲
اولین انتشار ۱۴ مرداد ۱۴۰۲

واژه‌های کلیدی:

صنعت هوایی
پیش‌بینی زوال
یادگیری عمیق
موتور توربوفن
یادگیری با نظارت
شبکه‌های عصبی مصنوعی

* پست الکترونیکی نویسنده مسئول: h.soltanali@ihu.ac.ir

How to Cite this Article:

S. Ramezani, H. Soltanali, and A. Beirami, "A Model for Equipment Deterioration Prediction in Aviation Industry Using Deep Learning Methods (Case Study: Airplane Turbofan Engine)," *Journal of Technology in Aerospace Engineering*, Vol. 8, No. 2, pp. 1-12, 2024, (in Persian), <https://doi.org/10.22034/jtae.2024.8.2.1>

COPYRIGHTS



Authors retain the copyright and full publishing rights.

Published by Aerospace Research Institute. This article is an open access article licensed under the [Creative Commons Attribution 4.0 International \(CC BY 4.0\)](https://creativecommons.org/licenses/by/4.0/).



۱ مقدمه

باتوجه به اهمیت آماده به کاری و قابلیت اطمینان کارکردی انواع هواپیماها در پیشبرد اهداف صنعت حمل و نقل هوایی، پایش و ارزیابی مستمر سلامت تجهیزات و زیرسامانه‌های اصلی در این بخش بسیار حائز اهمیت است. در واقع برخورداری از دارایی‌های فیزیکی پویا و با قابلیت اطمینان بالا در صنعت هوایی، به طور مستقیم در مدیریت انواع هزینه‌های عملیاتی و نگهداشت و نیز ارتقاء عوامل ایمنی و کاهش ریسک‌های احتمالی اثرگذار است. در کشور ایران به علت عدم توجه کافی به پایگاه‌های اطلاعاتی موجود، تنها به بازرسی دیداری از ظاهر تجهیز بسنده شده و تحلیل جامع به منظور تعیین وضعیت زوال تجهیزات کم‌تر صورت گرفته است.

از سوی دیگر آماده به کار بودن تجهیزات دوار در بخش‌های هوایی (موتورهای هوایی شامل انواع جت) باتوجه به امکان وقوع حوادث غیرقابل جبران برای شرکت‌ها، صاحبان امتیاز و همچنین دینفغان بسیار مهم می‌باشد، چرا که در صورت عدم توجه به آن، خطوط هواپیمایی می‌بایست هزینه‌هایی همچون هزینه جدا نمودن موتور از بدنه، هزینه جابه‌جایی (انتقال موتور به وسیله تریلر کفی از فرودگاه تا مرکز تعمیرات و بالعکس)، بازرسی اولیه موتور و آزمایش عملکردی موتور را پرداخت نمایند. شایان ذکر است در صورتی که هواپیما نتواند پروازهای خود را طبق برنامه زمان‌بندی شده انجام دهد، می‌بایست سود از دست‌رفته به علت عدم پروازهای به موقع را در قالب هزینه‌های پنهان پرداخت نماید.

در این راستا، به کارگیری رویکرد مدیریت و پایش سلامت و نیز پیش‌بینی عیوب^۱ (PHM) در تجهیزات و محصولات مختلف هوایی، علم جدیدی است که با هدف رفع نیازهای مذکور در دهه‌های اخیر مورد توجه پژوهشگران و صنعت‌گران بوده است. در واقع، یکی از جنبه‌های چالش برانگیز در سیستم‌های مدرن نگهداشت امروزی، پیش‌بینی عیوب بوده که ارتقاء ایمنی بسیاری از سیستم‌های پیچیده شامل انواع موتورها، رتورها، گیربکس و باتری‌ها را بر عهده دارد که در این بین تکامل سیستم‌های پایش تشخیص عیوب^۲ بسیار کمک‌کننده بوده است [۱].

به طور کلی مبحث تشخیص و پیش‌بینی^۳ و نیز روش‌های مرتبط با آن، در ابتدا در حوزه پزشکی و درمان مطرح گردیده است. اما به مرور زمان با تکامل تکنولوژی‌های نوین به عرصه دارایی‌های فیزیکی و صنایع ورود پیدا کرده است، به طوری که اولین بار در صنعت دفاعی آمریکا با هدف کاهش هزینه‌های پیش‌بینی و نیز بهبود قابلیت اطمینان و

دسترس‌ی سیستم‌ها مدنظر قرار گرفته است. امروزه این رویکرد، به عنوان یکی از کاربردی‌ترین و جذاب‌ترین موضوعات در حوزه مهندسی نگهداشت پیشگویانه^۴ (Pd.M.) یا نگهداشت مبتنی بر پایش وضعیت^۵ (CBM) شناخته می‌شوند. هدف نهایی از به کارگیری این روش‌ها، در واقع تشخیص و پیش‌بینی روند زوال عیوب و نیز تخمین عمر مفید باقیمانده^۶ (RUL) تجهیز می‌باشد که در نهایت امکان تعیین فواصل بهینه نگهداری و تعمیرات انواع دارایی‌های فیزیکی فراهم می‌گردد. رویکرد PHM، به سازوکارهای خرابی چون خوردگی، خستگی، بار اضافی، ارتعاش، تنش، ترک، شکست و غیره پرداخته و نیز ارتباط آن با مدیریت چرخه عمر دارایی را به صورت روش‌های تخمین عمر باقیمانده فراهم می‌کند [۲].

باتوجه به توانایی ارزیابی وضعیت سلامت و نیز پیش‌بینی عیوب از طریق دانش PHM، در دنیای امروز به عنوان بنیان نگهداشت هوشمند در انواع دارایی‌های فیزیکی پیشرفته شناخته می‌شود. در این راستا، امروزه تکنولوژی‌های نوین نرم‌افزاری و سخت‌افزاری به همراه ابزارهای حرفه‌ای منطقی شامل انواع سنسورها (حسگرها)، کنترلرها و نیز دستگاه‌های مرکب، مهم‌ترین منابع در مدیریت PHM و نیز تخمین عمر مفید باقیمانده هستند. این ابزارها می‌توانند برای به دست آوردن و آنالیز سیگنال‌های حاصله از ماشین و فرآیند استفاده شوند و به خوبی می‌توانند در صنایعی که به دنبال تکنولوژی‌های تشخیص و پیش‌بینی عیوب به صوت بلادرنگ یا برخط هستند، قابلیت کاربرد داشته باشند [۳]. به طور کلی براساس بررسی منابع صورت گرفته روش‌های پیش‌بینی روند زوال و تخمین عمر مفید باقیمانده شامل روش‌های مبتنی بر مدل فیزیکی، رویکردهای داده محور^۷، رویکرد تجربه یا متخصص محور و یا روش‌های ترکیبی می‌باشند. در حقیقت کار روش‌های PHM تجزیه و تحلیل رفتار دارایی فیزیکی از طریق جمع‌آوری داده‌های سنسوری شامل لرزش، تنش، ارتعاش، دما، فشار، ولتاژ، سرعت، نیرو، صدا و سایر ابزارهای پایشی می‌باشد [۴، ۵]. در این تحقیق عمدتاً روش‌های داده محور باتوجه به ماهیت داده‌های کسب شده از صنعت حمل و نقل هوایی (مطالعه موردی: موتور هواپیماها) به منظور تحلیل و تخمین روند زوال مورد استفاده قرار گرفته است که نتایج حاصل از آن می‌تواند در پیش‌بینی عمر مفید باقی‌مانده و نیز دستیابی به یک برنامه مناسب نگهداری و تعمیرات مورد کاربرد باشد. همچنین باتوجه به عدم قطعیت‌ها و محدودیت‌های روش‌های مرسوم داده محور به منظور دقت در پیش‌بینی‌ها، روش‌های هوش مصنوعی با بهره‌گیری از الگوی یادگیری

5. Condition Based Maintenance (CBM)
6. Remaining Useful Life (RUL)
7. Data Driven.

1. Prognostics and Health Management (PHM)
2. Diagnostic Monitoring System
3. Diagnostic and Prognostic
4. Predictive Maintenance (Pd.M.)

مدل‌های دانشی و یادگیری عمیق^{۱۰} مورد بررسی قرار گرفت. نتایج نشان داد به کارگیری مدل دانشی توانست دقت پیش‌بینی‌ها با کمک مدل یادگیری عمیق را تا ۵/۵ درصد در مقایسه با مطالعات پیشین بهبود بخشد [۱۶]. تشخیص عیوب و تعیین روند زوال خرابی‌ها در بیرینگ‌ها با محوریت دامنه‌های چند منبع از طریق یک شبکه یادگیری انتقال عمیق تقویت شده^{۱۱} مورد مطالعه قرار گرفت. روش پیشنهادی با داده‌های واقعی ارزیابی شد که بیانگر اثربخشی و برتری آن در مقایسه با سایر روش‌های موجود بوده است [۱۷]. پیش‌بینی روند زوال و تخمین عمر مفید باقی‌مانده در تجهیزات دوار با رویکرد بهینه‌سازی چندهدفه و یادگیری عمیق ترکیبی^{۱۲} مورد انجام گرفت. هدف از به کارگیری مدل ترکیبی ارزیابی دقت و پراکندگی بود که در نتایج نشان داد که الگوریتم پیشنهادی دارای اثربخشی و برتری در تخمین عمر مفید باقی‌مانده تجهیزات بوده است [۱۸]. در پژوهشی یک مدل توسعه یافته از شبکه یادگیری عمیق با ماهیت کانولوشن دو بعدی^{۱۳} در تخمین عمر مفید یاقان‌های بیرینگ‌ها پیشنهاد شد. نتایج نشان داد که روش توسعه یافته دارای مزایا و برتری‌های قابل توجهی در پیش‌بینی‌ها در مقایسه با روش‌های مرسوم یادگیری عمیق بوده است [۱۹]. در مطالعه‌ای دیگری بررسی شاخص سلامت و نیز تخمین عمر مفید باقی‌مانده در تجهیزات دوار با رویکرد مقایسه‌ای شبکه‌های یادگیری عمیق پر کاربرد شامل شبکه عصبی مکرر یا برگشتی^{۱۴} (RNN)، شبکه عصبی واحد بازگشتی دروازه‌دار^{۱۵} (GRU) و شبکه عصبی حافظه طولانی کوتاه مدت^{۱۶} (LSTM) بر اساس داده‌های پایش وضعیت از قبیل داده‌های ارتعاشی صورت پذیرفت [۲۰].

مطابق با ادبیات تحقیق، هدف از مطالعه حاضر ارزیابی وضعیت سلامت موتورهای توروفوفن از طریق پایش روند زوال/تخریب آن‌ها، به منظور افزایش آماده‌به‌کاری هواپیماها در حمل‌ونقل‌های هوایی کشور و نیز متعاقب آن استفاده از نتایج تحلیل‌ها در تخمین عمر مفید باقی‌مانده و دست‌یابی به یک برنامه مناسب نگهداری و تعمیرات (نت) بود. بدین منظور با هدف افزایش دقت پیش‌بینی‌های وضعیت زوال یا تخریب، شبکه‌های عصبی پیشرفته با ماهیت رویکرد یادگیری عمیق استفاده شد. علاوه بر این در این مطالعه حاضر،

عمیق^۱ (DLs) در این مطالعه مورد استفاده قرار گرفته و مقایسه‌ها مربوطه انجام پذیرفته است. بنابراین، مهم‌ترین اهداف اصلی تحقیق به شرح زیر می‌باشد:

- یافتن ویژگی‌ها و پارامترهای مرتبط جهت تعیین وضعیت زوال موتور توربوفن هواپیما
- شناسایی و مقایسه روش‌های داده‌محور شامل روش‌های مرسوم و یادگیری عمیق جهت تعیین وضعیت زوال موتور توربوفن هواپیما
- استفاده از نتایج تحقیق حاضر در پیش‌بینی عمر مفید باقیمانده و نیز دست‌یابی به یک برنامه مناسب نگهداری و تعمیرات در موتور توربوفن هواپیما در تحقیقات آتی.

۲ پیشینه تحقیق

مطالعات قابل توجهی در زمینه روند پیش‌بینی زوال/تخریب تجهیزات و برآورد عمر مفید باقی‌مانده توسط محققان در دهه‌های اخیر با محوریت روش‌های داده‌محور صورت گرفته است که در جدول ۱ آورده شده است. مطابق با پیشینه تحقیق صورت گرفته، مهم‌ترین روش‌ها و الگوریتم‌های مرسوم و پرکاربرد داده‌محور بدین منظور شامل تئوری‌های بیزی^۲ [۶-۷]، روش‌های رگرسیونی و ماشین بردار پشتیبان^۳ (SVM) [۸]، شبکه‌های عصبی^۴ (NNs) [۹-۱۱]، مدل‌های مارکوف^۵ [۱۲]، درخت تصمیم^۶ [۱۳] و مدل‌های بیز ساده^۷ (NBs) [۱۴] در انواع تجهیزات دوار، تورها، موتورهای القایی، بیرینگ‌ها، گیربکس‌ها، بلبرینگ‌ها، باتری‌ها و... در صنایع مختلف بوده است. علاوه بر مرور ادبیات مدل‌های مرسوم، در سال‌های اخیر، انواع الگوریتم‌های شبکه عصبی با یادگیری عمیق با قابلیت کاربردهای صنعتی به ویژه در زمینه پیش‌بینی زوال/تخریب تجهیزات و برآورد عمر مفید باقی‌مانده، گسترش یافته است: بر این اساس، در تحقیقی لی^۸ و همکاران (۲۰۲۳)، از مدل یادگیری عمیق^۹ (CNN) به منظور استخراج ویژگی‌های مرتبط با داده‌های خام ارتعاشی در بیرینگ‌ها استفاده شد. نتایج نشان داد که مدل پیشنهادی دارای دقت بالایی از پیش‌بینی به منظور شناسایی وضعیت سلامت بیرینگ‌ها در لوکوموتیو قطارها بوده است [۱۵]. در همین راستا، طی تحقیقی پیش‌بینی عمر مفید باقی‌مانده موتور هواپیما بر اساس ترکیب

11. Reinforcement Ensemble Deep Transfer Learning Network (REDTLN)
12. Ensemble Deep Learning with Multi-Objective Optimization (EDL-MO)
13. 2-D Convolutional Neural Network (CNN)
14. Recurrent Neural Network (RNN)
15. Gated Recurrent Unit (GRU)
16. Long Short-Term Memory (LSTM)

1. Deep Learnings (DLs)
2. Bayesian Theories
3. Support Vector Machine (SVM)
4. Neural Networks (NNs)
5. Markov Models
6. Decision Tree
7. Naive Bayes (NBs)
8. Li
9. Convolutional Neural Network (CNN)
10. Knowledge and Deep Learning Models

هوافضایی کشور است که کم‌تر در مطالعات و پژوهش‌های پیشین داخلی بدان پرداخته شده‌است. به عبارتی دیگر مطالعه حاضر می‌تواند بستر جدیدی برای پژوهشگران در این کشور عرصه فراهم کند و متعاقب آن نتایج حاصل از این تحقیق می‌تواند در اختیار مدیران و متخصصین در این حوزه قرار گیرد. نکته قابل توجه دیگر این است که اکثر فعالیت‌های نگهداری و تعمیرات، اورهال‌ها و بازرسی‌ها در سیستم‌های هوایی کشور عمدتاً بر پایه اطلاعات تجربی یا داده‌های تاریخی برنامه‌ریزی می‌شود، حال آنکه این تحقیق به بررسی وضعیت موتورهای هواپیما براساس داده‌های پایشی یا سنسوری استوار بوده که شرایط واقعی‌تر و دقیق‌تری به منظور دستیابی به برنامه بازرسی و نگهداشت فراهم خواهد کرد.

رویکرد مقایسه‌ای روش‌های یادگیری عمیق با روش‌های مرسوم داده‌محور از قبیل الگوریتم بیز ساده (NBS)، K نزدیک‌ترین همسایگی^۱ (KNN) و درخت تصمیم به کار رفته است که کم‌تر در مطالعات پیشین مورد توجه بوده است. مطابق با پیشینه تحقیق صورت‌گرفته که عمدتاً در بحث تعیین وضعیت زوال مدل‌های پیچیده ریاضی را مطرح کرده‌اند، نوآوری و برتری مقاله حاضر، ارائه یک ایده جدید و درعین‌حال ساده در خوشه‌بندی به منظور تعریف و تفسیر انواع وضعیت‌های زوال در توربوفن‌ها بوده است. علاوه بر این، مهم‌ترین مزیت این تحقیق ارائه چارچوبی با هدف تعیین وضعیت زوال در موتورهای هواپیماهای داخل کشور متناسب با شرایط ویژه سیستم‌های

جدول ۱- مرور ادبیات موضوع در زمینه روش‌های مدل‌سازی زوال و پیش‌بینی عمر مفید باقی‌مانده در انواع تجهیزات

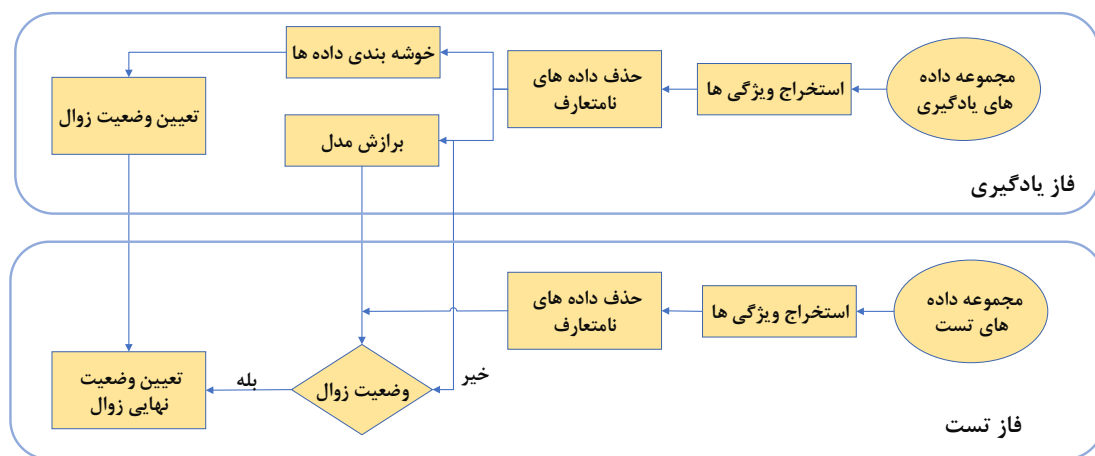
ردیف	عنوان	سال	روش
۱	استخراج ویژگی‌های مرتبط با داده‌های خام ارتعاشی در بیرینگ‌های لوکوموتیو قطار [۱۵]	۲۰۲۳	CNN-HI
۲	پیش‌بینی عمر مفید باقی‌مانده موتور هواپیما بر اساس ترکیب مدل‌های دانشی و یادگیری عمیق [۱۶]	۲۰۲۳	CNN-LSTM
۳	تشخیص عیب و تعیین روند زوال در بیرینگ‌ها با دامنه‌های چند منبع از طریق یک شبکه یادگیری انتقال عمیق تقویت شده [۱۷]	۲۰۲۲	REDTLN
۴	پیش‌بینی روند زوال و تخمین عمر مفید باقی‌مانده در تجهیزات دوار با رویکرد بهینه‌سازی چندهدفه و یادگیری عمیق ترکیبی [۱۸]	۲۰۲۱	EDL-MO
۵	یک مدل توسعه‌یافته از شبکه یادگیری عمیق با ماهیت کانولوشن در تخمین عمر مفید یاتاقان‌های بیرینگ‌ها [۱۹]	۲۰۲۱	2D-CNN
۶	بررسی شاخص سلامت و نیز تخمین عمر مفید باقی‌مانده در تجهیزات دوار با رویکرد مقایسه‌ای شبکه‌های یادگیری عمیق پر کاربرد [۲۰]	۲۰۲۰	RNN- GRU- LSTM
۷	ارائه یک الگوریتم پیش‌آگهی مبتنی بر شباهت بهبود یافته برای تخمین RUL با استفاده از یک طرح رمزگذار خودکار RNN [۲۱].	۲۰۲۰	RNN
۸	ارائه تشخیص عیب هوشمند مبتنی بر انتقال یادگیری از یاتاقان‌های آزمایشگاهی به یاتاقان‌های لوکوموتیو [۲۲]	۲۰۱۹	CNN
۹	ارائه یک شبکه عصبی ساخته شده با تکنیک یادگیری عمیق و کاربرد آن در تشخیص خطای ماشین‌ها [۲۳]	۲۰۱۸	NSAE-LCN
۱۰	ارائه یک شاخص سلامت مبتنی بر شبکه عصبی مکرر برای پیش‌بینی عمر مفید [۲۴]	۲۰۱۸	RNN-HI
مطالعه حاضر	پیش‌بینی روند زوال در موتور توربوفن هواپیما با رویکرد مقایسه‌ای	-	مقایسه روش‌های یادگیری عمیق و روش‌های مرسوم (درخت، تصمیم، بیز ساده و KNN)

1. K-Nearest Neighbors (KNN)

۳ روش تحقیق


به منظور دستیابی به نتایج مورد نظر و انجام تحقیق از روش های متنوعی استفاده شده است. روش های گردآوری داده ها در این تحقیق را می توان بر اساس روش کتابخانه ای و اطلاعات ذخیره شده در سامانه های هواپیما

دسته بندی کرد. شکل ۱ چارچوب روش پیشنهادی برای تعیین وضعیت زوال موتور توربو فن هواپیما را نشان می دهد که اجرای این تحقیق در دوفاز کلی صورت می پذیرد: فاز یادگیری و فاز تست.



شکل ۱- چارچوب روش پیشنهادی تحقیق

E.G.T Margine بین مقادیر (0 , 10] را نشان دهد. وضعیت زوال شماره ۳: تفاوت E.G.T and E.G.T Margine بین مقادیر (0 , -5] را نشان دهد. وضعیت زوال شماره ۴: تفاوت E.G.T and E.G.T Margine کم تر از مقدار ۵ را نشان دهد. در وضعیت شماره ۱، موتور بدون مشکل و قابل خدمت می باشد. در وضعیت شماره ۲، موتور به شرط استفاده در شرایط خاص مانند استفاده موتور در TT2 کم تر از حالت استاندارد گفته شده در کتب، قابل خدمت می باشد. در وضعیت شماره ۳، موتور پس از بررسی جهت تعمیرات ارسال می گردد. در وضعیت شماره ۴، موتور غیر قابل خدمت می باشد. در شکل ۲ و ۳ طیف وضعیت زوال و نیز نحوه خوشه بندی نمایش داده شده است.



شکل ۲- طیف وضعیت زوال به صورت گرافیکی

به منظور اجرای فاز یادگیری داده های لازم جمع آوری شد. در این مقاله، به منظور کسب ماهیت داده های موتور توربو فن ابتدا پایگاه های داده ای PHM08 و C-MAPSS به عنوان اصلی ترین مراجع شناخته شده ملاک قرار گرفت و بر اساس ماهیت و نوع داده های مورد استفاده، داده های این پژوهش از پایگاه اطلاعاتی^۱ (F.D.R) در یک سازمان هوافضایی در کشور از ۱۳۹۷ تا ۱۴۰۰ استخراج گردید. از این رو، در فاز یادگیری پس از جمع آوری داده های موجود، فرآیند استخراج ویژگی به کار گرفته می شود که در این مرحله، ویژگی حسگر دما خروجی گازها از اگزوز^۲ (E.G.T) به عنوان شاخص تعیین سلامت، استخراج گردید تا وضعیت زوال تجهیز را نشان دهد. در این مرحله جذر میانگین مربعات^۳ (RMS) بیش ترین استفاده برای تحلیل را داراست. در فرآیند بعدی داده های کسب شده مورد بررسی و ارزیابی قرار می گیرد، به طوری که اگر داده های اولیه با کتب و تجارب مفید خبره مطابقت نکند، به عنوان داده های نامتعارف از کل داده ها به دست آمده حذف می گردد. بدین ترتیب تمامی داده نیز با کمک خبره هموار می گردد. به دنبال آن در فرآیند خوشه بندی داده ها برای تعیین وضعیت زوال، شاخص سلامت، خوشه بندی می گردد. هر خوشه، نشان دهنده یکی از وضعیت های زوال است. به عبارت دیگر هر یک از وضعیت های زوال از شماره ۱ تا ۴ به صورت زیر تعریف شده است. وضعیت زوال شماره ۱: تفاوت E.G.T and E.G.T Margine بیش از مقدار ۱۰ را نشان دهد. وضعیت زوال شماره ۲: تفاوت E.G.T and

3. Root Mean Square (RMS)

1. Flight Data Recorder
2. Exhaust Gas Temperature (E.G.T)

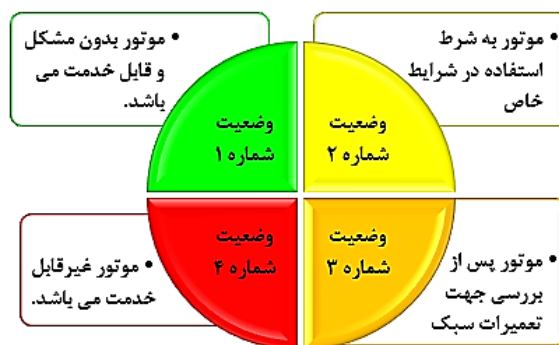
بر این اساس، F مؤلفه اصلی به‌دست‌آمده در مرحله‌ی پیشین، به‌عنوان ورودی‌های مدل، و تعیین وضعیت موتور به‌عنوان خروجی مدل در نظر گرفته شده‌است. بنابراین N شبکه‌ی عصبی آموزش‌دیده، برای N مجموعه داده‌ی یادگیری به‌دست می‌آید. از بانک شبکه‌های آموزش داده شده، در مرحله‌ی تست، جهت تعیین وضعیت زوال موتورها در مجموعه داده‌های جدید استفاده می‌شود. در فاز تست وضعیت زوال برای هر یک از موتورها محاسبه می‌شود. الگوریتم عمیق توسعه یافته، یک شبکه MLP با حداقل سه لایه گره است: یک لایه ورودی، یک لایه پنهان و یک لایه خروجی. به جز گره‌های ورودی، هر گره یک نورون است که از یک تابع فعال‌سازی غیر خطی استفاده می‌کند. پرسپترون یک نوع دسته‌بند دودویی است که ورودی خود x (یک بردار متشکل اعداد حقیقی) را به مقدار خروجی $f(x)$ (یک اسکالر با مقادیر باینری) که به‌صورت رابطه ۱ حساب می‌شود، متناظر می‌کند:

$$f(x) = \begin{cases} 1 & \text{if } w \cdot x + b > 0 \\ 0 & \text{otherwise} \end{cases} \quad (1)$$

وب سرور با استفاده از شبکه عصبی پرسپترون چند لایه‌ای مدل‌سازی می‌شود. به‌طور کلی یک الگوریتم عصبی است که باتوجه به ازدحام وب سرویس در شبکه چندلایه‌ای پیش‌بینی‌هایی را صورت می‌دهد تا سرور از کار نیافتد. بر اساس رابطه ۲ داریم:


$$w \cdot x = \sum_{i=1}^m w_i x_i \quad (2)$$

رابطه ۲ ضرب داخلی بردار وزن و بردار ورودی است، w یک بردار از وزن‌هایی با مقادیر حقیقی است و m تعداد ورودی‌های پرسپترون است. b نشان‌دهنده بایاس است که وظیفه آن جابجا کردن مرز تصمیم‌گیری از مبدأ است و مقدار آن به ورودی‌ها بستگی ندارد. در مسئله دسته‌بندی دودویی مقدار $f(x)$ برای دسته‌بندی x بین دو کلاس $+$ و $-$ استفاده می‌شود. اگر b عددی منفی باشد، جمع وزن‌دار ورودی‌ها باید عدد مثبت بزرگ‌تر از $|b|$ باشد تا خروجی پرسپترون برابر یک شود. به‌عبارت دیگر دسته‌بندی پرسپترون مانند یک ابر صفحه است که فضای m بعدی را به دو قسمت تقسیم می‌کند، در این صورت w نشان‌دهنده بردار عمود بر صفحه و b نشان‌دهنده عرض از مبدأ صفحه جداکننده است. به‌ازای نقاط داده‌شده به همراه برجسب آن‌ها $(X_1, Y_1), \dots, (X_n, Y_n)$ الگوریتم پرسپترون مقادیر w و b را به گونه‌ای می‌یابد که تمام نمونه‌ها توسط تابع f به‌درستی برجسب‌گذاری شوند، تا رابطه ۳ برقرار گردد.



شکل ۳- خوشه‌بندی تعیین وضعیت زوال‌ها

به‌منظور درک بهتر از خوشه‌بندی تعیین وضعیت زوال‌ها، شکل ۴ ارائه شده‌است که بیانگر مدت زمان کارکرد تا خرابی براساس وضعیت‌های زوال تعریف شده (وضعیت یک تا چهار) می‌باشد و بیانگر آن است که تجهیز به ویژه در وضعیت‌های ۳ و ۴ دارای شدت زوال افزایشی است.



عمر تجهیز (بر حسب زمان)

شکل ۴- مدت زمان کارکرد تا خرابی براساس وضعیت‌های زوال تعریف شده

در ادامه در گام برازش مدل، یک مدل پیش‌بینی‌کننده برای هر یک از N مجموعه‌داده یادگیری برازش شده‌است. هر یک از این مجموعه‌های داده، می‌تواند یکی از وضعیت زوال را نمایندگی کند. بنابراین می‌توان از اطلاعات آن‌ها جهت پیش‌بینی روندهای جدید استفاده نمود. در این تحقیق از رویکرد یادگیری عمیق از طریق توسعه یک مدل شبکه‌ی عصبی پرسپترون چند لایه 1 (MLP) با اضافه کردن لایه‌های پنهان استفاده شده‌است. دلیل استفاده شبکه‌ی عصبی پرسپترون عمیق 2 (DMLP) این تحقیق، اهمیت به‌کارگیری آن باتوجه به نوع ماهیت داده‌ها، تعداد کم ویژگی تک‌بعدی و عدم پیچیدگی بیش از اندازه می‌باشد.

1. Multi-layer Perceptron (MLP)
2. Deep Multi-Layer Perceptron (DMLP)

روش مذکور به نمایش داده می‌شود و می‌توان به صورت مقایسه‌ای دقت الگوریتم پرسپترون چندلایه ساده را مورد بررسی قرار داد.

۳.۳ معیارهای ارزیابی

برای ارزیابی و مقایسه عملکرد روش پیشنهادی با سایر مدل‌های موجود در ادبیات موضوع، از معیارهای خطای میانگین مربعات^۲ (MSE) و نیز خطای جذر میانگین مربعات^۳ (RMSE)، روش‌های شناخته شده برای برآورد میزان خطا است که در غالب مقالات در حوزه حوزه مدل‌سازی روند زوال و تخمین عمر مفید تجهیزات استفاده شده است [۲۵، ۲۶]. خطای میانگین مربعات در واقع تفاوت بین مقادیر تخمینی و آنچه تخمین زده شده، است. به دو دلیل تقریباً همه جا مثبت است (صفر نیست)؛ اول این که تصادفی است و ثانياً به دلیل اینکه تخمین‌گر اطلاعاتی که قابلیت تولید تخمین دقیق‌تری دارد را حساب نمی‌کند. پس این شاخص که مقداری همواره نامنفی دارد، هرچقدر مقدار آن به صفر نزدیک‌تر باشد، نشان دهنده میزان کمتر خطاست. به عبارت دیگر پیش‌بینی بهتری صورت گرفته شده است. برای به دست آوردن خطای میانگین مربعات از یک مجموعه یا n داده می‌توان از رابطه ۵ استفاده کرد.

$$MSE = \frac{1}{n} \sum_{i=1}^n (X_i - \hat{X}_i)^2 \quad (5)$$

که در آن $\frac{1}{n} \sum_{i=1}^n$ عمل میانگین‌گیری را انجام می‌دهد $(\hat{X}_i - X_i)$ مقدار مربع خطای هر داده را محاسبه می‌کند. پس MSE میانگین مربع خطاها است. برای ارزیابی روش پیش‌بینی مدل با نتایج به دست آمده توسط این روش با سه روش مذکور با معیار ثانوی خطای جذر میانگین مربعات مقایسه شده است. این معیار به صورت رابطه ۶ تعریف می‌گردد.

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (ACT X_i - PRE X_i)^2}{N}} \quad (6)$$

۴ نتایج و بحث

برای ارزیابی روش پیش‌بینی نتایج به روش پرسپترون، نتایج به دست آمده توسط این روش را با دو روش K نزدیک‌ترین همسایگی و بیز ساده، با توجه به دو معیار خطای جذر میانگین مربعات (RMSE) جهت مقایسه و قدرت این روش از طریق ارائه جواب و نتایج سایر روش‌های پیش‌بینی و خطای میانگین مربعات (MSE)، جهت تعیین

$$w \cdot x = \sum_{i=1}^m w_i x_i \quad (3)$$

بدین منظور که پارامترهای بایاس b و بردار وزن را به صورت یک بردار واحد در نظر بگیریم بردارهای ورودی x و بردار وزن w را به گونه‌ای تغییر می‌دهیم که $X_0 = 1$ و $W_0 = 1$ در این صورت رابطه ۴ به صورت زیر می‌باشد.

$$w \cdot x = w_0 x_0 + \sum_{i=1}^m w_i x_i = b + \sum_{i=1}^m w_i x_i \quad (4)$$

از بین شاخص‌ها و ویژگی‌های مطرح شده، شاخص یا ویژگی سنسور دمای گاز خروجی از اگزوز موتور (E.G.T) براساس مشاهدات به دست آمده، دارای اثر معنی داری قابل توجه بر روی وضعیت روند زوال توربوفاها بوده است و بنابراین در این مطالعه مورد استفاده بوده است.

۱.۳ انتخاب بهترین شاخص‌های ارزیابی در راستای تعیین وضعیت زوال

به منظور انتخاب بهترین شاخص‌های ارزیابی وضعیت زوال توربوفاها مورد مطالعه از اطلاعات مربوط به^۱ (F.D.R) سازمان هوافضایی مد نظر جهت جمع‌آوری استفاده شده است که در برخی از این اطلاعات همخوانی با شرایط موتور مورد نظر نداشته و می‌بایست از این اطلاعات جهت روابی و پایایی موضوع صرفه نظر نمود. علائم و پارامترهای متعددی در این روش مورد استفاده قرار گرفته شده است که تعریف هر یک در زیر آمده است:

کد مشتری: تخصیص اعداد ۱ تا ۴ به موتورهای هر یک از مشتریان
C.I.T = TT2: به عنوان دمای ثبتی در زمان مشاهده می‌باشد.
N2 R.P.M: دور دوم یا دور شفت فشار بالای موتور محل سنسور آن پس از محفظه احتراق می‌باشد.
E.P.R = PT7/PT2: سنسور نسبت فشار ابتدا کمپرسور به انتهای توربین می‌باشد.

E.G.T: سنسور دمای گاز خروجی از اگزوز موتور می‌باشد.
E.G.T MARGINE: حد قبولی با E.G.T محاسبه شده و CORRECTED آن تشخیص وضعیت موتور.

۲.۳ مدل‌های تحت مقایسه

در راستای ارزیابی دقت اطلاعات حسگرها در این مقاله، جهت ارزیابی مقایسه بین الگوریتم منتخب و سه روش درخت تصمیم، بیز ساده و K نزدیک‌ترین همسایگی مورد بررسی قرار می‌گیرد. با اجرا این فرآیند، قدرت و دقت طبقه‌بندی وضعیت زوال الگوریتم پرسپترون در مقابل سه

3. Root Mean Squared Error (RMSE)

1. Flight Data Recorder
2. Mean Squared Error (MSE)

جهت تعیین تغییر مقدار MSE بر اساس تغییرات تعداد لایه‌های پنهان و تعداد نورون‌ها در لایه پنهان می‌توان از طریق کمترین اختلاف مربعات خطا یا همان MSE استفاده نمود که نتایج آن در جدول ۳ بیان شده‌است. همان‌طور که در جدول ۳ ملاحظه می‌شود، لایه اول پنهان با نورون ۶ کمترین مقدار خطا را در جدول ۴ نشان می‌دهد؛ بنابراین این مدل دارای ۶ نورون و تنها یک لایه می‌باشد. ماتریس‌های پیچیدگی شکل ۸ مشاهده می‌شود، ماتریس پیچیدگی برای طبقه‌بندی فاز یادگیری با دقت ۹۸/۳٪، ماتریس پیچیدگی برای طبقه‌بندی فاز آزمون با دقت ۷۶/۹٪، ماتریس پیچیدگی اعتبارسنجی با دقت ۹۲/۳٪ و دقت کل شبکه عصبی ۹۴/۱۲٪ می‌باشد.

تغییر مقدار MSE بر اساس تغییرات تعداد لایه‌های پنهان و تعداد نورون‌ها در لایه پنهان روش پرسپترون در شکل ۵، جدول ۳ استفاده گردیده است. در جدول ۲ نتایج مقایسه بین این سه روش با روش قبلی ارائه شده‌است. برای هر موتور فاز تست، نرخ خطای جذر میانگین روش با توجه به دو روش مقایسه‌ای دیگر محاسبه شده‌است. همان‌طور که در جدول ۴ مشاهده می‌گردد، روش شبکه عصبی پرسپترون، عملکرد بهتری را با توجه به معیار خطای جذر میانگین مربعات داشته است، به عبارت دیگر، خطای اندازه‌گیری، عملکرد پرسپترون، از عملکرد بهتری نسبت به دو روش دیگر برخوردار است. در راستای اندازه‌گیری خطای موجود در هر یک از موتورهایی که برای فاز تست تعیین گردیده است، از محاسبات خطای مربعات نیز می‌توان برای مقایسه دو روش مقایسه‌ای با روش مدنظر استفاده نمود که نمودار مستطیلی خطاهای هر یک روش اندازه‌گیری در شکل‌های ۶ و ۷ زیر نشان داده شده‌است.

جدول ۲- نتایج مقایسه تفاوت E.G.T and E.G.T Margin بین این سه روش با روش قبلی


شماره سریال توربوفا														روش پیش‌بینی
۳۴۰۵	۳۰۰۲	۰۳۰۴	۱۹۸۵	۱۴۷۲	۷۷۴۵	۷۷۴۸	۳۵۶۲	۴۱۵۷	۰۳۰۴	۶۵۵۰	۴۸۲۰	۰۰۶۷	۳۳۴۰	
تفاوت E.G.T														
۱۲/۰۱	۱۴/۱۴	۱۳/۰۹	۸/۷۱	۱۱/۹۱	۱۳/۱۷	۱۱/۷۸	۹/۱۱	۱۳/۵۸	-۰/۰۷	۸/۰۹	۱۳/۷۳	۱۴/۹۹	۱۱/۱۲	۶/۹۹
E.G.T & Margine														
پیش‌بینی روش پرسپترون														
۱۲/۸	۱۳/۷۴	۱۲/۸۴	۷/۹۱	۱۱/۴۹	۱۲/۹۵	۱۱/۶۸	۱۰/۰۵	۱۳/۲۶	-۰/۰۳	۸/۰۱	۱۳/۶۵	۱۴/۳	۱۱/۰۱	۶/۸۴
پیش‌بینی روش KNN														
۱۱/۸۴	۱۳/۶۲	۱۳/۴۲	۹/۱	۱۱/۶۵	۱۳/۱۱	۱۱/۴۹	۱۰/۰۱	۱۳/۱۴	-۰/۸۴	۸/۵۲	۱۳/۱۵	۱۴/۳۷	۱۱/۸۸	۷/۱
پیش‌بینی روش بیز ساده														
۱۱/۴۴	۱۳/۳۹	۱۲/۲۶	۷/۸۴	۱۲/۲۸	۱۲/۳۴	۱۲/۲۶	۸/۲۶	۱۴/۳۱	-۰/۷۴	۷/۳۱	۱۲/۸۹	۱۴/۲	۱۰/۵۷	۶/۷۱

جدول ۴- خطای جذر میانگین مربعات در فاز تست

روش مقایسه‌ای	خطای جذر میانگین مربعات
روش پرسپترون	۰/۱۲۰
روش KNN	۰/۱۳۰
روش بیز	۰/۱۸۱

جدول ۳- خطای میانگین مربعات به‌منظور پیدا کردن تعداد نورون‌های بهینه در لایه‌های پنهان و تغییرات لایه‌های پنهان

تعداد نورون	لایه پنهان				
	۵	۴	۳	۲	۱
۱	۰/۲۵	۰/۲۸	۰/۲۵	۰/۲۹	۰/۰۶۱
۲	۰/۲۸	۰/۳۱	۰/۲۵	۰/۱۹	۰/۲۳
۳	۰/۱۸	۰/۲۵	۰/۱۳	۰/۱۲	۰/۰۶۵
۴	۰/۲۳	۰/۲۵	۰/۲۲	۰/۲۴	۰/۱۵
۵	۰/۲۶	۰/۱۴	۰/۳۴	۰/۱۴	۰/۰۵۰
۶	۰/۲۲	۰/۲۲	۰/۲۵	۰/۲۷	۰/۰۱۵




شکل ۵- منحنی نتایج پرسپترون چندلایه مساله

فرایند جهت انتخاب بهترین روش از طریق محاسبات خطاها انجام می‌گردد. پس از آن جهت اندازه‌گیری دقت الگوریتم، دسته سوم اطلاعات که برای تست سیستم می‌باشد را در الگوریتم منتخب قرار داده و دقت آن را اندازه‌گیری می‌شود. این سیستم دارای چهار طبقه وضعیت می‌باشد که در محور افقی با عنوان TARGET نشان داده شده‌است. همچنین برای پیش‌بینی وضعیت زوال نیز چهار دسته‌بندی با عنوان OUTPUT در نظر گرفته شده‌است. این ماتریس‌ها جهت دقت‌سنجی سیستم استفاده می‌شود که عملکرد سیستم را بر اساس وضعیت پیش‌بینی واقعی سنجیده و میزان خطا را نشان می‌دهد. به‌عنوان مثال همان‌طور که در ماتریس پیچیدگی وضعیت به‌درستی در حالت ۳ پیش‌بینی گردیده است و تنها یک وضعیت در کلاس ۲ پیش‌بینی شده‌است که دقت در این وضعیت را ۸۰٪ نشان می‌دهد. برای ارزیابی الگوریتم منتخب و مقایسه آن با سه روش درخت تصمیم، بیز ساده و K نزدیک‌ترین همسایگی در تعیین وضعیت زوال موتورهای توربینی استفاده می‌شود که در شکل ۹ نشان داده شده‌است.



True Class	1	2	3	4
1	44	0	0	1
2	8	0	4	1
3	0	3	4	1
4	1	0	3	0

True Class	1	2	3	4
1	44	4	3	0
2	12	8	2	0
3	0	4	2	2
4	1	1	1	1

شکل ۹- از بالا به پایین به ترتیب: ماتریس پیچیدگی درخت تصمیم تحقیق انجام شده با دقت کلی ۶۷/۱٪، روش بیز ساده-با دقت کلی ۶۴/۷٪، و روش K نزدیک‌ترین همسایگی با دقت کلی ۶۸/۲٪



شکل ۶- مربوط به تفاوت E.G.T and E.G.T margin به روش قبل با پیش‌بینی تفاوت E.G.T and E.G.T margin به روش پرسپترون



شکل ۷- نمودار مستطیلی خطاهای روش پرسپترون چندلایه (بالا) و بیز ساده (پایین)

Training Confusion Matrix					Validation Confusion Matrix					
1	37	0	0	0	100%	7	0	0	0	100%
2	0	14	1	0	93.3%	0	4	0	0	100%
3	0	0	4	0	100%	0	0	0	0	NaN%
4	0	0	0	3	100%	0	0	1	1	50.0%
	62.7%	0.0%	0.0%	0.0%	0.0%	53.8%	0.0%	0.0%	0.0%	0.0%
	0.0%	23.7%	1.7%	0.0%	6.7%	0.0%	30.8%	0.0%	0.0%	0.0%
	0.0%	0.0%	6.8%	0.0%	0.0%	0.0%	0.0%	0.0%	0.0%	NaN%
	0.0%	0.0%	0.0%	5.1%	0.0%	0.0%	0.0%	7.7%	7.7%	50.0%
	100%	100%	80.0%	100%	98.3%	100%	100%	0.0%	100%	92.3%
	0.0%	0.0%	20.0%	0.0%	1.7%	0.0%	0.0%	100%	0.0%	7.7%

Test Confusion Matrix					All Confusion Matrix					
1	7	2	0	0	77.8%	51	2	0	0	96.2%
2	0	2	1	0	66.7%	0	20	2	0	90.9%
3	0	0	1	0	100%	0	0	5	0	100%
4	0	0	0	0	NaN%	0	0	1	4	80.0%
	53.8%	15.4%	0.0%	0.0%	22.2%	60.0%	2.4%	0.0%	0.0%	3.8%
	0.0%	15.4%	7.7%	0.0%	33.3%	0.0%	23.5%	2.4%	0.0%	9.1%
	0.0%	0.0%	7.7%	0.0%	0.0%	0.0%	0.0%	5.9%	0.0%	0.0%
	0.0%	0.0%	0.0%	0.0%	NaN%	0.0%	0.0%	1.2%	4.7%	20.0%
	100%	50.0%	50.0%	NaN%	76.9%	100%	90.9%	62.5%	100%	94.1%
	0.0%	50.0%	50.0%	NaN%	23.1%	0.0%	9.1%	37.5%	0.0%	5.9%

شکل ۸- ماتریس پیچیدگی شبکه عصبی پرسپترون چندلایه

جهت ارزیابی عملکرد سیستم عصبی تشکیل شده، اطلاعات موجود به چند دسته تقسیم می‌شود. دسته اول برای آموزش، دسته دوم جهت صحت‌سنجی عملکرد و مابقی داده‌ها برای تست قرار داده می‌شود. این

پیچیدگی‌های ریاضی کم‌تری در مقایسه با روش‌های گذشته برخوردار است. براساس نتایج به‌دست آمده در وضعیت‌های چهارگانه سلامت موتور توربوفا، شبکه عصبی پرسپترون دارای قابلیت و دقت بالایی در پیش‌بینی روند زوال در مقایسه با سایر روش‌های مرسوم یادگیری ماشین به‌دست آمد. چارچوب توسعه داده شده در این مطالعه با هدف تعیین وضعیت زوال در موتورهای هواپیماهای داخل کشور متناسب با شرایط ویژه سیستم‌های هوافضایی کشور بوده است با توجه به این‌که اکثر فعالیت‌های نگهداری و تعمیرات، اورهال‌ها و بازرسی‌ها در سیستم‌های هوایی کشور عمدتاً بر پایه اطلاعات تجربی یا داده‌های تاریخی برنامه‌ریزی می‌شود، تحقیق حاضر به بررسی وضعیت موتورهای هواپیما براساس داده‌های پایشی یا سنسوری استوار بوده که شرایط واقعی‌تر و دقیق‌تری به‌منظور دست‌یابی به برنامه بازرسی و نگهداشت فراهم می‌کند. در تحقیقات آتی در قالب یک پیشنهاد راهبردی، می‌توان از نتایج پیش‌بینی وضعیت زوال در تحقیق حاضر، به‌منظور تخمین عمر مفید باقی‌مانده بر پایه مفهوم یادگیری عمیق بهره برد.

تعارض منافع

هیچ‌گونه تعارض منافع توسط نویسندگان بیان نشده‌است.


مراجع

- [1] S. Ramezani and A. Moini, "Estimation of the remaining useful life of defense equipment using the equipment health management model and defect prediction (PHM), (case study: Radar system)," *Supply Chain Management Quarterly*, vol. 18, no. 51, pp. 4-14, 2015. (in Persian).
- [2] S. Ramezani, M. Yousefi and M. Moghan, "The application of vibration analysis and wavelet neural network in intelligent diagnosis and prediction of mechanical defects, a case study of determining the remaining life of chiller bearings," in *The 6th National Conference on Maintenance*, Tehran, Iran, 2010, (in Persian).
- [3] A. Heydari, S. H. Shahbi Haghghi, and A. Ahmadi, "Prediction of remaining useful life of equipment based on condition monitoring and expert knowledge using neuro-fuzzy inference system," *International Journal of Industrial Engineering and Production Research*, vol. 28, no. 1, pp. 27-42, 2017.
- [4] J. Sikorska, M. Hodkiewicz, A. D'Cruz, L. Astfalck, and A. Keating, "A collaborative data library for testing prognostic models," in *The 3rd European Conference of the Prognostics and Health Management Society, Bilbao, Spain*, vol. 3, no. 1, 2016, <https://doi.org/10.36001/phme.2016.v3i1.1579>.
- [5] T. Xia, Y. Dong, L. Xiao, S. Du, E. Pan, and L. Xi, "Recent advances in prognostics and health management for advanced manufacturing paradigms," *Reliability Engineering and System Safety*, vol. 178, pp. 255-268, 2018, <https://doi.org/10.1016/j.ress.2018.06.021>.
- [6] Y. Lin, M. Chen, and D. Zhou, "Online probabilistic operational safety assessment of multi-mode engineering systems using Bayesian methods," *Reliability Engineering and*

True Class	1	2	3	4
1	43	8		
2	8	11	2	1
3		5	3	
4			3	1

ادامه شکل ۹- از بالا به پایین به ترتیب: ماتریس پیچیدگی درخت تصمیم تحقیق انجام شده با دقت کلی ۶۷/۱٪، روش بیز ساده با دقت کلی ۶۴/۷٪، و روش K نزدیکترین همسایگی با دقت کلی ۶۸/۲٪

از طرفی همان‌طور که در ماتریس‌های پیچیدگی طبقه‌بندی وضعیت زوال هر یک از الگوریتم‌های مورد مقایسه و الگوریتم منتخب به‌وضوح نمایش داده شده است، می‌توان به نتیجه کلی رسید که قدرت دقت الگوریتم منتخب که همان الگوریتم پرسپترون چندلایه می‌باشد، بسیار بالاتر از سایر الگوریتم‌های مقایسه‌ای می‌باشد، شکل ۱۰.



شکل ۱۰- دقت کل شبکه هر الگوریتم

۵ نتیجه‌گیری و پیشنهادها

در این پژوهش به ارزیابی وضعیت سلامت تجهیزات صنعت هوایی به‌طور خاص موتور توربوفا هواپیما از طریق پیش‌بینی روند زوال یا تخریب پرداخته شد. بدین منظور یک چارچوب توسعه‌یافته با محوریت روش‌های شبکه عصبی مصنوعی عمیق و نیز روش‌های مرسوم یادگیری ماشین شامل تئوری بیز ساده، روش نزدیک‌ترین همسایه و درخت تصمیم با هدف مدل‌سازی و پیش‌بینی روند زوال موتور توربوفا پیشنهاد شد. در این مطالعه یک ایده جدید و درعین‌حال ساده در خوشه‌بندی وضعیت‌های زوال در توربوفا ارائه شد که از

- Safety*, vol. 229, 2023, Art. no. 108869, <https://doi.org/10.1016/j.res.2022.108869>.
- [17] X. Li, H. Jiang, M. Xie, T. Wang, R. Wang, and Z. Wu, "A reinforcement ensemble deep transfer learning network for rolling bearing fault diagnosis with Multi-source domains," *Advanced Engineering Informatics*, vol. 51, 2022, Art. no. 101480, <https://doi.org/10.1016/j.aei.2021.101480>.
- [18] M. Ma, C. Sun, Z. Mao, and X. Chen, "Ensemble deep learning with multi-objective optimization for prognosis of rotating machinery," *ISA transactions*, vol. 113, pp. 166-174, 2021, <https://doi.org/10.1016/j.isatra.2020.09.017>.
- [19] B. Zhao and Q. Yuan, "A novel deep learning scheme for multi-condition remaining useful life prediction of rolling element bearings," *Journal of Manufacturing Systems*, vol. 61, pp. 450-460, 2021, <https://doi.org/10.1016/j.jmsy.2021.10.004>.
- [20] Y. Chen, G. Peng, Z. Zhu, and S. Li, "A novel deep learning method based on attention mechanism for bearing remaining useful life prediction," *Applied Soft Computing*, vol. 86, 2020, Art. no. 105919, 2020, <https://doi.org/10.1016/j.asoc.2019.105919>.
- [21] W. Yu, I. Y. Kim, and C. Mechevske, "An improved similarity-based prognostic algorithm for RUL estimation using an RNN autoencoder scheme," *Reliability Engineering and System Safety*, vol. 199, 2020, Art. no. 106926, 2020, <https://doi.org/10.1016/j.res.2020.106926>.
- [22] B. Yang, Y. Lei, F. Jia, and S. Xing, "An intelligent fault diagnosis approach based on transfer learning from laboratory bearings to locomotive bearings," *Mechanical Systems and Signal Processing*, vol. 122, pp. 692-706, 2019, <https://doi.org/10.1016/j.ymssp.2018.12.051>.
- [23] F. Jia, Y. Lei, L. Guo, J. Lin, and S. Xing, "A neural network constructed by deep learning technique and its application to intelligent fault diagnosis of machines," *Neurocomputing*, vol. 272, pp. 619-628 2018, <https://doi.org/10.1016/j.neucom.2017.07.032>.
- [24] S. Jin, X. Sui, X. Huang, S. Wang, R. Teodorescu, and D.-I. Stroe, "Overview of machine learning methods for lithium-ion battery remaining useful lifetime prediction," *Electronics*, vol. 10, no. 24, 2021, Art. no. 3126, <https://doi.org/10.3390/electronics10243126>.
- [25] P. Li *et al.*, "An end-to-end neural network framework for state-of-health estimation and remaining useful life prediction of electric vehicle lithium batteries," *Renewable and Sustainable Energy Reviews*, vol. 156, 2022, Art. no. 111843, <https://doi.org/10.1016/j.rser.2021.111843>.
- [26] J. Liu, F. Lei, C. Pan, D. Hu, and H. Zuo, "Prediction of remaining useful life of multi-stage aero-engine based on clustering and LSTM fusion," *Reliability Engineering and System Safety*, vol. 214, 2021, Art. no. 107807, <https://doi.org/10.1016/j.res.2021.107807>.
- System Safety*, vol. 119, pp. 150-157, 2013, <https://doi.org/10.1016/j.res.2013.05.018>.
- [7] A. Mosallam, K. Medjaher, and N. Zerhouni, "Data-driven prognostic method based on Bayesian approaches for direct remaining useful life prediction," *Journal of Intelligent Manufacturing*, vol. 27, pp. 1037-1048, 2016, <https://doi.org/10.1007/s10845-014-0933-4>.
- [8] H. Z. Huang, H. K. Wang, Y. F. Li, L. Zhang, and Z. Liu, "Support vector machine based estimation of remaining useful life: Current research status and future trends," *Journal of Mechanical Science and Technology*, vol. 29, pp. 151-163, 2015, <https://doi.org/10.1007/s12206-014-1222-z>.
- [9] Z. Tian, "An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring," *Journal of Intelligent Manufacturing*, vol. 23, pp. 227-237, 2012, <https://doi.org/10.1007/s10845-009-0356-9>.
- [10] Z. Tian, L. Wong, and N. Safaei, "A neural network approach for remaining useful life prediction utilizing both failure and suspension historie," *Mechanical Systems and Signal Processing*, vol. 24, no. 5, pp. 1542-1555, 2010, <https://doi.org/10.1016/j.ymssp.2009.11.005>.
- [11] J. B. Ali, B. Chebel-Morello, L. Saidi, S. Malinowski, and F. Fnaiech, "Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network," *Mechanical Systems and Signal Processing*, vol. 56-57, pp. 150-172, 2015, <https://doi.org/10.1016/j.ymssp.2014.10.014>.
- [12] A. Giantomassi, F. Ferracuti, A. Benini, G. Ippoliti, S. Longhi, and A. Petrucci, "Hidden markov model for health estimation and prognosis of turbofan engines," in *International Design Engineering Technical Conferences and Computers and Information in Engineering Conference*, Washington, DC, USA, 2011, pp. 681-689, Paper 48174, <https://doi.org/10.1115/DETC2011-48174>.
- [13] P. Kundu, A. K. Darpe, and M. S. Kulkarni, "An ensemble decision tree methodology for remaining useful life prediction of spur gears under natural pitting progression," *Structural Health Monitoring*, vol. 19, no. 3, pp. 854-872, 2020, <https://doi.org/10.1177/1475921719865718>.
- [14] S. S. Ng, Y. Xing, and K. L. Tsui, "A naive Bayes model for robust remaining useful life prediction of lithium-ion battery," *Applied Energy*, vol. 118, pp. 114-123, 2014, <https://doi.org/10.1016/j.apenergy.2013.12.020>.
- [15] M. Gupta, R. Wadhvani, and A. Rasool, "A real-time adaptive model for bearing fault classification and remaining useful life estimation using deep neural network," *Knowledge-Based Systems*, vol. 259, Art. no. 1100710, 2022, <https://doi.org/10.1016/j.knosys.2022.110070>.
- [16] Y. Li, Y. Chen, Z. Hu, and H. Zhang, "Remaining useful life prediction of aero-engine enabled by fusing knowledge and deep learning models," *Reliability Engineering and System*