



## پیش بینی عمر مفید باقیمانده موتورهای توربین گاز به روش دسته بندی سنی و بررسی مقاوم بودن روش پیشنهادی در شرایط کمبود داده

علی محمودیان، محمد دورعلی\*، محمود سعادت

دانشکده مهندسی مکانیک، دانشگاه شریف، تهران، ایران

### تاریخچه داوری:

دریافت: ۱۳۹۸/۰۳/۲۸

بازنگری: ۱۳۹۸/۰۶/۲۵

پذیرش: ۱۳۹۸/۰۸/۱۴

ارائه آنلاین: ۱۳۹۸/۰۹/۱۳

### کلمات کلیدی:

پیش بینی وضعیت

قابلیت اطمینان

داده های آموزش محدود

پروگنوسیس

مدیریت سلامت

**خلاصه:** روش های داده-پایه برای پیش بینی عمر، معمولاً نیازمند مقدار زیادی داده برای دستیابی به عملکرد مطلوب می باشند. لذا عملکرد آن ها به طور معمول برای مقادیر کم داده های آموزش مطلوب نمی باشد. روش پیش بینی به کمک دسته بندی سنی حجم داده های آموزش را از طریق باز تولید مجموعه اولیه داده ها افزایش می دهد، لذا این روش می تواند در مواردی که داده های آموزش اندک می باشد، استفاده شود. همچنین، ساختار پیشنهادی می تواند با بسیاری از روش های پیش بینی، ترکیب و دقت آن ها را به طور قابل توجهی بهبود بخشد. در این مقاله، ساختار مدل پیش بینی عمر پیشنهادی شرح و اثربخشی آن برای پیش بینی در یک مطالعه موردی در موتورهای توربین گاز بررسی شده است. در بخش نخست، داده های کافی برای آموزش در دسترس بوده و نتایج آن با بهترین مقالات ارائه شده بر روی داده های مشابه مقایسه شده است. در بخش دوم، مقاوم بودن روش پیشنهادی در شرایط حجم داده های آموزش محدود بررسی شده است. در این قسمت خطای پیش بینی عمر برای موارد مختلف با حجم محدود داده های آموزش مقایسه شده است. نتایج این تحقیق اولاً بهره وری روش پیشنهادی را در مقایسه با سایر رویکردهای موجود نشان می دهد، و دوم مقاوم بودن روش را (در شرایط داده های محدود) نشان می دهد.

باقیمانده وجود دارد که اساساً به سه گروه اصلی تقسیم می شوند:

رویکرد داده-پایه، مدل-پایه و رویکرد ترکیبی.

روش پیش بینی عمر مدل-پایه، روی یک مدل فیزیکی از سیستم شکست های مدنظر را پیاده و علائم آن را شبیه سازی می کند. در این روش برای تخمین زمان شکست از مدل های انتشار نقص<sup>۱</sup> استفاده می شود. مدل مناسب مدلی است که حالت شکست را توصیف و اثرات عوامل مخرب را به پیشرفت آسیب فیزیکی نگاشت کند. روش های امان محدود و مدل های تجربی برای این کار مناسب می باشند. مهم ترین مزایای روش مدل-پایه این است که پیش بینی ها بر اساس روابط علی معلولی هستند و هنگامی که یک مدل ایجاد شد، برای موارد مختلف تنها کالیبراسیون ممکن است مورد نیاز باشد. با این حال، مدل های فیزیکی قادر به توصیف کامل و پیچیدگی یک سیستم

### ۱- مقدمه

در سال های اخیر، پیش بینی و تخمین عمر باقیمانده سیستم های مکانیکی پیچیده مانند توربین گاز توجهات زیادی را به خود جلب کرده است. این موضوع هم به دلیل ملاحظات اقتصادی و هم عملیاتی حائز اهمیت می باشد. در حال حاضر پیش بینی عمر باقیمانده، هسته اصلی سیستم مدیریت سلامت برای دستیابی به کارایی قابل اعتماد و ایمن ماشین ها محسوب می شود. یک الگوریتم پیش بینی عمر باقیمانده وضعیت سلامت فعلی سیستم را تخمین میزند، و با توجه به شرایط کاری و محیطی پیش بینی می کند چه زمانی سیستم کار نخواهد کرد [۱-۳].

البته پیش بینی عمر مفید یک ماشین پیچیده مانند توربین گاز کار پیچیده ای است. تکنیک های بسیاری برای پیش بینی عمر

1 Fault Propagation Models

\* نویسنده عهده دار مکاتبات: durali@sharif.edu



در دنیای واقعی و دینامیک سیستم نیستند و ضمناً تنظیم پارامترها نیاز به یادگیری از داده‌های میدانی دارد. یکی از دلایل اصلی که استفاده از روش‌های مدل-پایه متداول نیست، این است که درک دقیق مکانیزم خرابی اگر غیرممکن نباشد بسیار دشوار است. دلیل دیگر این است که مدل فیزیکی اگر موجود باشد بسیار مفید خواهد بود، اما در بیشتر سیستم‌های پیچیده مدل فیزیکی سیستم به خاطر ساده‌سازی‌ها، صرف‌نظر کردن از رفتارهای غیرخطی و کمبود اطلاعات، اختلاف زیادی با واقعیت دارد [۴].

روش‌های داده-پایه از دانش یادگیری ماشین و هوش مصنوعی و تکنیک‌هایی مانند خوشه‌بندی، طبقه‌بندی و تخمین حالات آینده و همچنین تعریف آستانه و مرز برای تصمیم‌گیری، استفاده می‌کند. چالش‌های اصلی این روش‌ها، یادگیری با حجم زیادی از اطلاعات با بعد بالا، درک وابستگی‌های متقابل بین متغیرها و فیزیک سیستمی که داده‌ها از آن جمع‌آوری شده‌اند، به‌علاوه مدیریت عدم قطعیت داده‌ها و نویز اطلاعات می‌باشد. عیب دیگر این روش عدم رویکرد علی-معلولی می‌باشد. در این روش پیش‌بینی از طریق یکی از این دو راه صورت می‌گیرد [۵ و ۶]:

۱. تهیه نگاشتی بین اندازه‌گیری‌ها و عمر مفید باقیمانده در صورت وجود اطلاعات کافی کار-تا-خرابی<sup>۱</sup>

۲. استخراج روند تغییر و ویژگی، شاخص سلامت یا ابعاد خرابی و مقایسه آن تا آستانه شکست با توابع ریاضی و رگرسیون

مزایای روش داده-پایه عبارتند از:

- امکان دسترسی جامع به داده‌های مختلف مانند صوت، ارتعاشات، دما، فشار، کرنش، شرایط سیستم‌های جانبی مثل خنک‌کاری و ... که در مدل فیزیکی یا قابل جمع نیست یا بسیار سخت است.

- امکان درک رفتارهای فیزیکی از مقادیر زیاد داده که در تئوری نیز آشکار نمی‌شوند

- امکان پایش تمام متغیرهای عملکردی و ارتعاشی در تمام اجزای مسیر گاز که در مدل فیزیکی ممکن است نادیده گرفته شود.

- در مقایسه با رویکرد مدل-پایه، پیاده‌سازی آن نسبتاً در دسترس و سریع است.

رویکردهای ترکیبی سعی می‌کنند از مزایای هر دو روش بهره‌مند شوند. در این روش همزمان از دانش مرتبط با روند فیزیکی و نیز

اطلاعات بدست آمده از داده‌های آزمایش استفاده می‌شود. ترکیب دو روش به سبک‌های گوناگون ممکن است: یادگیری و تنظیم پارامترهای مدل به تناسب داده، پیش‌بینی توسط مدل و اصلاح بر اساس داده‌های مشاهده شده، یادگیری وضعیت آسیب در حال حاضر از داده‌ها و انتشار با استفاده از مدل، استفاده از معلومات رفتار فیزیکی برای هدایت فرایند یادگیری از داده، تجزیه و تحلیل داده‌ها برای توسعه مدل، هم‌جوشی تخمین‌ها از دو روش متفاوت و غیره. مهم‌ترین اشکال این روش آن است که هم به داده‌برداری و هم به مدل نیاز است. همچنین مدل نادرست یا داده‌برداری مغشوش می‌تواند اثر مخرب بر دیگری بگذارد [۷]. به عنوان نمونه‌ای از این روش می‌توان به مقاله راگوان و همکاران [۸] اشاره کرد که کمپرسور را با روش شبکه عصبی مدل کرد و با مقایسه پاسخ سیستم واقعی با مدل، سلامت کمپرسور را پایش نمود. در نمونه دیگر ماتوس و همکاران [۹] یک روش نوین با استفاده ترکیبی از مدل شبکه عصبی و مدل فیزیکی برای تشخیص عیب کمپرسور پیشنهاد کردند. سیستم تحت مطالعه آن‌ها یک توربین گاز کمپرسور بود. در این مقاله برای مدل‌سازی کمپرسور فقط طبقه اول مدل فیزیکی شد که خطای انباشته به حداقل برسد و سایر طبقات کمپرسور با شبکه عصبی مدل‌سازی شد. استدلال نویسنده این بود که اکثر خرابی‌ها در طبقه اول رخ می‌دهد و لذا می‌توان خرابی‌های مختلف را با جابجایی پارامترهای فیزیکی ایجاد نمود. از سوی دیگر یک مدل شبکه عصبی خالص تهیه کردند که ورودی خروجی‌های کمپرسور را به خوبی به هم نگاشت می‌کند. لذا با ایجاد اشکال در مدل ترکیبی و مقایسه با مدل شبکه عصبی خالص، یک مرجع از انواع خرابی‌ها، علل آن و نمودار پاسخ سیستم تهیه کردند. در نمونه دیگر سخون [۱۰] روی مدل‌سازی توربین و پیش‌بینی رفتار آن مطالعه نمود. او یک مدل ریاضی توسعه داد که رفتار گذرا و پایدار توربین گاز را توصیف می‌کرد. همچنین از دو روش آماری و موجک برای پیش‌بینی عملکرد سیستم استفاده کرد. در روش آماری، یک توصیف تجربی چند بعدی روند غالب داده‌ها را نشان می‌داد. در روش موجک با استفاده از ضرایب موجک مرتبه دوم و چهارم، سیگنال تقریبی برای پیش‌بینی آینده پلنت تولید می‌کرد. به نظر می‌رسد با توجه به مزایا و معایب استراتژی‌های سه‌گانه، رویکرد داده-پایه برای بسیاری از سیستم پیچیده از جمله توربین گاز روش بهتری می‌باشد. از همین رو اغلب تحقیقات انجام‌شده در دنیا،

1 Run to Failure

است. برای تخمین آینده مشاهده‌گر مود لغزشی نیز استفاده شده است. صالحی و همکاران [۲۹] با چنین مشاهده‌گری از مرتبه اول دینامیک وضعیت آینده یک موتور توربوشارژر را تخمین زدند. پوگینا و ونتورینی [۳۰-۳۲] یک روش آماری (مونت کارلو) مبتنی بر روند اطلاعات و تاریخچه سیستم، برای پیش‌بینی وضعیت کاری آینده توربین گاز ارائه نمود. نویسندگان ادعا کرده‌اند در شبیه‌سازی‌ها به خطای کمتر از ۲ درصد رسیده است. از مدل شبکه عصبی دینامیک نیز برای تخمین عمر باقی‌مانده موتور استفاده شده. در مرجع [۳۳] خرابی جرم‌گرفتن برای کمپرسور مدل شده و نویسنده شاخص راندمان را برای تشخیص خرابی پیشنهاد کرده. دو نوع شبکه دینامیک یعنی شبکه بازگشتی و شبکه غیرخطی اتو-رگرسیون برای پیش‌بینی توربین گاز استفاده و عملکردشان مقایسه شده. گروه دیگری از محققان روی روش‌های شناسایی سیستم متمرکز شدند تا بستر مناسبی برای پایش وضعیت توربین گاز داشته‌باشند. هولکومب [۳۴] از این روش برای شناسایی دینامیک توربین گاز استفاده نمود تا در تشخیص، پایش وضعیت و طراحی کنترلر از آن بتوان بهره برد. مدل‌های شناسایی شده مناسب برای استفاده در روش‌های نظارتی مبتنی بر خصوصیات رفتار گذرا هستند. استفاده از تئوری بیزین و فیلترهای غیرخطی مانند فیلتر ذره برای پیش‌بینی، روشی است که روی توربین باد و توربین گاز پاسخ قابل قبولی داشته است. ژائو [۱۵] یک روش پیش‌بینی عمر مفید مبتنی بر داده پیشنهاد کرد، او در این روش ابتدا شاخص شرایط و پس از آن شاخص سلامت را استخراج می‌کند، ناهنجاری داده‌ها را به عنوان عیب تشخیص می‌دهد، عیب را بر اساس طبقه‌بندی داده‌ها شناسایی و بر اساس روند داده‌ها خرابی را پیش‌بینی می‌کند. در این پژوهش، برای درک وابستگی متغیرها و پیش‌بینی رفتار سیستم، از تئوری بیزین و فیلتر ذره استفاده شده است. استفاده از ابزار مویک کاربرد گسترده‌ای در تشخیص و پیش‌بینی عیب داشته، از جمله روش‌های مختلف مانند تبدیل مویک، ضرایب مویک و ترکیب تبدیل مویک با شبکه عصبی<sup>۱</sup>. شبکه عصبی مویک دینامیک در مرجع [۳۵] برای تخمین عمر مفید به‌کار رفته و تخمین‌های آن با رسیدن اطلاعات جدید عیب‌یابی بروزرسانی شده است. یان و همکاران [۳۶] در سال ۲۰۱۳ مروری راجع به کاربرد مویک در عیب‌یابی ماشین‌های دوار کرده‌اند. در پژوهشی که لی [۱۲] در سال ۲۰۰۹ انجام داد، یک روش

مبتنی بر روش‌های داده-پایه بوده‌اند. رویکرد مقاله حاضر نیز مبتنی بر داده می‌باشد، البته یک معیار دیگر برای دسته‌بندی روش‌ها لحاظ شده و بر این اساس به دو گروه عمده تقسیم شده‌اند: روش‌های مقاوم و روش‌های غیرمقاوم. یک روش پیش‌بینی عمر غیرمقاوم، تنها زمانی می‌تواند تخمین عمر قابل قبولی بدهد که داده‌های فراوانی آموزش الگوریتم در دسترس باشد. در غیر این صورت، آموزش الگوریتم ممکن است به خوبی انجام نشود و متعاقباً نتیجه حاصل غیرقابل اعتماد باشد. این واقعیت روش‌های پیش‌بینی عمر غیرمقاوم را در مواجهه با مسائلی که حجم داده کمی برای آموزش دارند، محدود می‌کند. بارالد و همکاران [۱۱] یک استراتژی ارائه کرده‌اند که بهترین رویکرد پیش‌بینی عمر را با توجه به اطلاعات موجود ماشین پیشنهاد می‌کند. با مرور تحقیقات انجام شده در دنیا، روش‌های بسیاری برای پیش‌بینی عمر مشاهده می‌شود. به عنوان مثال، برخی از محققان از تکنیک‌های رگرسیون ترکیب شده، از جمله مدل‌های خطی و درجه دوم برای پیش‌بینی عمر مفید موتورهای توربین گاز استفاده کرده‌اند [۱۲ و ۱۳]. روش‌های دیگری مانند شبکه عصبی [۱۴]، فیلترهای خطی و غیرخطی ذرات [۱۵ و ۱۶]، کاپلان میر [۱۷]، مونت کارلو [۱۸] و ماشین‌بردار پشتیبان [۱۹ و ۲۰] برای پیش‌بینی عمر استفاده شده‌اند. یو و همکاران [۲۱] یک سیستم پیش‌بینی عمر برای ارزیابی سلامت موتور بر اساس رگرسیون لجستیک و مدل حالت-فضایی ایجاد کرده‌اند. سیمون [۲۲]، مک‌کلینتیک [۲۳] و سوانسان [۲۴]، دقت تخمین و تلاش محاسباتی انواع مختلفی از فیلتر کالمن مانند فیلتر کالمن خطی، فیلتر کالمن پیشرفته و فیلتر کالمن با نمونه‌گیری قطعی برای ارزیابی سلامت موتور هواپیما را مقایسه کرده‌اند. لو و همکاران [۲۵] روش تخمین حالت غیرخطی بر اساس فیلتر کالمن پیشرفته ارائه کرده‌اند و به بهبود قابل توجهی در دقت رسیده‌اند. دینگ و همکاران [۲۶] ماشین‌بردار پشتیبان و الگوریتم ژنتیک را با هم ترکیب کرده و روش پیش‌بینی عمر هوشمندی را پیشنهاد کرده‌اند. گوئل و همکاران [۲۷] نتایج یک مدل ماشین‌بردار پشتیبان، یک مدل رگرسیون گاوسی و یک مدل شبکه عصبی مصنوعی را در پیش‌بینی عمر مقایسه کرده‌اند. ژو [۲۸] نقاط قوت روش پیش‌بینی عمر مبتنی بر تجربه و رویکرد مبتنی بر داده‌ها را یکپارچه کرده است. چارچوب پیش‌بینی عمر ترکیبی توسعه‌یافته برای پیش‌بینی عمر مفید موتور توربین گاز به عنوان یک مثال کاربردی استفاده شده

پیش‌بینی به منظور برآورد عمر مفید باقی‌مانده از موتورهای توربین گازی بر اساس تاریخچه اطلاعات سلامت آن پیشنهاد شد. برای این منظور از تکنیک‌های رگرسیون، شامل مدل‌های خطی و درجه دوم، استفاده شد. برای عیب‌یابی نیز از روش تحلیل مسیر گاز استفاده شد. برخلاف روش‌های غیرمقاوم، روش‌های مقاوم می‌توانند در شرایط فقدان داده غنی برای آموزش الگوریتم، عمر مفید ماشین را با دقت قابل قبول تخمین بزنند. به عنوان مثال می‌توان به اصلاح ساختار شبکه عصبی برای یادگیری از داده‌های کم [۳۷] و برخی مدل‌های جدید مانند ساختار چندمرحله‌ای پیش‌بینی عمر [۳۸] اشاره کرد. مقدس و ژو [۳۸] نشان داده‌اند که فرآیند خرابی برای یک ماشین می‌تواند در یک ساختار چندمرحله‌ای قبل از خرابی کامل آن مدل شود و این مدل با بسیاری از موارد واقعی در صنعت تطابق دارد. شیانگ و لیو [۳۹] یک روش احتمالاتی برای پیش‌بینی عمر با استفاده از روش قابلیت اطمینان مرتبه اول معکوس پیشنهاد کرده‌اند. غلامرضایی و قربانیان [۴۰] در سال ۲۰۱۵، از تکنیک‌های نوروفازی برای پیش‌بینی عملکرد توربین استفاده کرده. او ادعا کرده مدل پیشنهادی مقاوم بوده و می‌توان برای شبیه‌سازی و عیب‌یابی توربین از آن استفاده نمود. ژائو و همکاران [۴۱] در سال ۲۰۱۴، ابتدا دو روش متداول برای نگهداری سیستم‌ها را معرفی کرد. یکی روش پیش‌بینی است که با استفاده از سابقه پارامترهای عملکردی سیستم، با بهره‌گیری از تکنیک‌های رگرسیون، بیزین، کالمن و... عملکرد سیستم را پیش‌بینی می‌کند. دیگری، روش آماری است که با توجه به تاریخچه خرابی‌های سیستم منحنی توزیع قابلیت اطمینان را استخراج می‌کند. سپس روش جدیدی برای پیش‌بینی کاهش سطح عملکرد ماشین مبتنی بر ترکیب دو روش فوق پیشنهاد کرده است. روش پیش‌بینی، سابقه عملکرد سیستم را در مد نظر قرار می‌دهد و اطلاعات مربوط به سوابق خرابی ماشین را در نظر نمی‌گیرد. از سوی دیگر روش‌های آماری، سوابق خرابی را در نظر گرفته و حالت سلامتی فعلی ماشین را در نظر نمی‌گیرد. مدل پیشنهادی در این مقاله مبتنی بر ترکیب موثر این دو روش است. با این حال، مقاوم بودن روش‌های پیش‌بینی عمر به ندرت بررسی شده‌اند. در این پژوهش هدف این است که دقت پیش‌بینی عمر برای یک ساختار مقاوم در دو حالت وجود و فقدان داده‌های غنی برای یک مورد مطالعاتی (داده‌های آزمون پیش‌بینی عمر ناسا [۴۲]) مقایسه شود.

مقالات بسیاری روی داده‌های آزمون پیش‌بینی عمر ناسا منتشر شده‌اند، اما همه آن‌ها فقط در شرایط وجود داده‌های غنی تست و ارزیابی شده‌اند و در هیچکدام آزمون مقاوم بودن گزارش نشده است. بهترین نتایج گزارش شده با استفاده از الگوریتم‌های ارائه شده در مراجع [۴۳-۴۵] به‌دست آمده است. این نتایج به عنوان نقطه مرجع مطالعه فعلی مورد استفاده قرار می‌گیرد. هدف اصلی در اینجا پیشنهاد یک مدل برای پیش‌بینی عمر باقیمانده است که در حالت فقدان داده‌های غنی مقاوم باشد. برای توسعه این مدل، از روش تحلیل مؤلفه‌های اصلی استفاده می‌شود. روش پیش‌بینی عمر به کمک دسته‌بندی سنی<sup>۱</sup> داده‌های آموزش را چندین بار بازتولید می‌کند. این بازتولید در حالت مواجهه با فقدان داده‌های آموزش کافی، در بهبود نتایج موثر است [۴۶].

ساختار کلی این مقاله به شرح زیر است: در بخش ۲ طرح مطالعه ارائه شده است. شاخص سلامتی در بخش ۳ توسعه یافته است. در بخش‌های ۴ و ۵، چارچوب روش پیشنهادی و پیاده‌سازی آن شرح داده شده است. این مقاله با ارائه نتایج و جمع‌بندی در دو بخش آخر به پایان می‌رسد.

## ۲- طرح مطالعه

### ۲-۱- معرفی داده

برای نشان دادن نتایج این روش در پیش‌بینی عمر، مطالعه موردی روی موتورهای توربین گاز از بانک اطلاعات ناسا انجام شده است. این مجموعه داده شامل ۲۱ اندازه‌گیری، از جمله اندازه‌گیری‌های ذکر شده در جدول ۱ می‌باشد که در طی هر سیکل پرواز اندازه‌گیری شده‌اند [۴۲]. مجموعه داده‌های آموزش شامل اطلاعات موتورهایی است که تا زمان وقوع خرابی کامل کار کرده‌اند. مجموعه داده‌های تست شامل اطلاعات موتورهای مشابه دیگری است که تا سطوح مختلف افت عملکرد کار کرده و قبل از وقوع خرابی کامل داده‌برداری متوقف شده است. چالش پیش‌رو، پیش‌بینی عمر مفید موتورهای مجموعه تست است. این مجموعه داده یکی از پرکاربردترین مجموعه‌های داده‌ای است که برای توسعه و اعتبارسنجی الگوریتم‌های پیش‌بینی عمر استفاده می‌شود. شکل ۱ مؤلفه‌های اصلی مدل موتور توربین گاز را نشان می‌دهد.

جدول ۱: لیست سنسورها و اندازه‌گیری‌ها [۴۲]

Table 1. A list of sensors and measurements [42]

نماد	توضیح
T24	دمای خروجی کمپرسور فشار ضعیف
T30	دمای خروجی کمپرسور فشار قوی
P30	فشار خروجی کمپرسور فشار قوی
Nc	دور هسته مرکزی
Pr	نسبت فشار موتور
Phi	نسبت دبی سوخت به فشاراستاتیک خروجی کمپرسور فشار
BPR	نسبت بای‌پس
BE	بلید آنتالپی
T50	دمای خروجی توربین فشار ضعیف
Ps30	فشار استاتیک خروجی کمپرسور فشار قوی
farB	نسبت سوخت/هوا برنر




Fig. 1. Simplified diagram of the gas turbine engine [42]

شکل ۱. شماتیک موتور توربین گاز [۴۲]

## ۲-۲- سنجه‌های پیش‌بینی عمر

میانگین مربعات خطا<sup>۱</sup> و میانگین مطلق خطا<sup>۲</sup> دو سنجه دیگر است که برای ارزیابی عملکرد روش‌های پیش‌بینی عمر معمولاً استفاده می‌شود.

$$e_{mse} = \frac{1}{N} \sqrt{\sum_{t=1}^N err^2} \quad (1)$$

$$e_{mae} = \frac{1}{N} \sum_{t=1}^N |err| \quad (2)$$

- 1 Mean of Squared Errors (MSE)
- 2 Mean of Average Errors (MAE)

برای ارزیابی کارایی الگوریتم‌های پیش‌بینی عمر، یک سری سنجه معمولاً استفاده می‌شود که در این بخش معرفی شده است. یکی از سنجه‌های بسیار معروف و پرکاربرد بر این اساس طراحی شده که بیشتر اوقات پیش‌بینی زود هنگام در مقایسه با پیش‌بینی دیر هنگام مطلوبیت بیشتری دارد. بنابراین، برای ارزیابی عملکرد یک بازه نامتقارن [۱۳ : -۱۰] در اطراف عمر باقیمانده واقعی در نظر گرفته شده است. درصد تخمین‌هایی که در درون بازه فوق قرار می‌گیرد به عنوان دقت الگوریتم پیش‌بینی عمر تعریف می‌شود [۴۷].

در ۲۰۱۶، خرابی پره توربین باد را با بررسی پارامترهای مبتنی بر مدل و تغییر شکل‌های غیر خطی آن تشخیص دادند. تحقیقاتشان نشان داد که خرابی‌های موضعی را می‌توان با بررسی پارامترهایی مثل شکل مود و انرژی کششی مودال تشخیص داد. پارامترهای ترمودینامیکی نیز برای این منظور استفاده شده‌اند که برای ذکر مثال می‌توان به پژوهش محمدی و منتظری [۶۰] اشاره نمود که با استفاده از بهره‌وری و ظرفیت جریان به عنوان شاخص‌های سلامت، افت عملکرد توربین گاز را مدل کرده‌اند؛ همچنین ژو و بهیماواراپو [۶۱] افت عملکرد توربین بخار را با پارامترهای ترمودینامیکی آن مدل کرده‌اند.

رویکرد دوم ترکیبی از سنسورهای ترمودینامیکی و ارتعاشی است که سنسورهای مختلف با تکنیک‌های گوناگون ادغام شده‌اند. روشی دوم از مزیت نظارت بر تمام سنسورها استفاده می‌کند. دیالو [۱۷] در تحقیق خود نشان داده که رویکرد تلفیق داده‌های چند سنسور قابل اعتمادتر است. تحقیق دیالو در سال ۲۰۱۰ با مشارکت دانشگاه فنی جورجیا و شرکت جنرال-الکترونیک یکی از بهترین کارهای انجام شده در این زمینه است. او از ادغام داده‌های سنسورهای مانیتورینگ گاز و ارتعاشات برای تشخیص علائم خرابی توربین گاز استفاده کرده است. یک روش گام به گام توسط دیالو توسعه یافت که در این مقاله از آن استفاده شده و این روش به شرح زیر است:

۱. **نرمال‌سازی داده‌ها:** برای جلوگیری از اثرات نامطلوب مقیاس‌های مختلف داده‌ها، یک فرایند پیش‌پردازش لازم است. برای مثال، انواع مختلف سنسورها در یک توربین گاز، از جمله حسگرهای فرآیند (مثل فشار، دما، جریان و غیره) که استاتیک هستند و حسگرهای با پهنای باند بالا (مانند سنسورهای ارتعاش) وجود دارد. فرکانس، مقیاس و بزرگی داده‌های ثبت شده توسط هر کدام از این حسگرها کاملاً متفاوت می‌باشد. لذا برای ادغام سنسورها حتماً باید همه آن‌ها در یک مقیاس قرار بگیرند. تمام اندازه‌گیری‌ها با رابطه زیر نرمالایز می‌شوند:

$$S_n = \frac{S_a}{S_m} \quad (4)$$

که در رابطه بالا  $S_n$  مقدار نرمالایز شده خروجی حسگر،  $S_m$  مقدار متوسط حسگر در هر بازه اندازه‌گیری و  $S_a$  مقدار واقعی حسگر

که در روابط بالا  $N$  تعداد واحدهای تحت مطالعه،  $t$  شمارشگر واحد و  $err$  از رابطه زیر تعریف می‌شود:

$$err = RUL_t - RUL_s \quad (3)$$

که  $RUL_t$  عمر باقیمانده صحیح و  $RUL_s$  عمر باقیمانده تخمینی است.

### ۳-۲- شاخص سلامت

در یک فرآیند پیش‌بینی عمر داده-پایه، پس از جمع‌آوری داده، چالش نخست آن است که چگونه بین اطلاعات حسگرهای یک سیستم پیچیده با سطح سلامت آن نگاشت ایجاد شود. با بررسی تاریخچه تحقیقات، دو روش کلی برای استخراج ویژگی‌ها و طراحی شاخص سلامت مشاهده می‌شود. اولین روش آن است که از پارامترهای مسیر گاز مانند دما، ارتعاشات، دبی جریان، فشار، بهره‌وری کمپرسور، کارایی فن و ... استفاده شود [۴۷]. در این بین تحلیل ارتعاش و مودال به‌طور گسترده‌ای برای تخمین عمر سیستم‌های مکانیکی استفاده شده است [۴۸-۵۰]. همچنین آنالیز روغن به‌خاطر قابلیت خوب در توضیح عملکرد ماشین از دیرباز مورد توجه بوده است [۵۱]. بهزاد و همکاران [۵۲]، تعدادی موتور سالم از یک خط تولید را به عنوان نمونه انتخاب کرده و عمداً دستکاری و معیوب نمودند. عیب‌ها در ۱۴ عنوان کلاسه‌بندی و سپس رفتارهای ارتعاشی و سایر پارامترهای برقی موتورها مطالعه شد. بر اساس رفتار این نمونه‌ها، الگوریتمی برای تشخیص عیوب موتورها پیشنهاد شد. همچنین بهزاد و همکاران [۵۳-۵۵] عیب‌یابی بر اساس آنالیز ارتعاشات انجام داد. زمانیان و اوحدی [۵۶] در سال ۲۰۱۱، عیب‌یابی گیربکس را با کشف ارتباط گوسی بین ثوابت موجک و سیگنال‌های ارتعاشی انجام داد. محمودی و لاری [۵۷] با آنالیز ارتعاشی به تعیین وضعیت عملکرد اجزاء دوار توربین گاز پرداخت. نامیزانی و عدم هم‌محوری نصب نادرست یاتاقان‌ها، یا موازنه نادرست قسمت‌های دوار، عیوبی بود که قابل رصد بود. همچنین حلیم [۵۸] در سال ۲۰۰۹، عیب‌یابی با تمرکز بر ارتعاشات و تحلیل موجک انجام داد. تکنیک تحلیل شکل مود و تغییر شکل‌های هندسی نیز از روش‌های جدید و کارا می‌باشد که می‌توان آسیب را به موقع تشخیص داد. رضایی و همکاران [۵۹]



در هر گام زمانی است.

که در روابط بالا  $E_{ref}$  محتوای انرژی سیگنال شاخص سلامت است که در یک بازه کارکرد سالم ماشین اندازه‌گیری شده است و  $E(j)$  محتوای انرژی شاخص سلامت در هر گام زمانی است. ثابت‌های دو منحنی  $SAD$  و  $SSD$  ویژگی‌هایی هستند که با عمر باقیمانده ماشین همبستگی دارند و ویژگی‌های شاخص سلامت<sup>۴</sup> نامیده می‌شود. جزئیات بیشتر راجع به پردازش داده و ایجاد شاخص سلامت در مرجع [۶۲] قابل دسترسی می‌باشد. مراحل مختلف پردازش داده‌ها برای موتور شماره ۱ در شکل ۲ نشان داده شده است.

### ۳- ساختار مدل پیش‌بینی عمر به کمک دسته‌بندی سنی

ساختار پیش‌بینی عمر به کمک دسته‌بندی سنی در شکل ۳ نشان داده شده است. برآورد عمر باقیمانده، از طریق دسته‌بندی سن موتورها و پس از آن ساخت یک ماژول پیش‌بینی خاص برای هر دسته انجام می‌شود. ساختار پیشنهادی در مراحل زیر اجرا می‌شود:

#### ۳-۱ دسته‌بندی

در مرحله اول، دسته‌بندی موتورها انجام می‌شود. زمان شروع پیش‌بینی برای هر موتور تحت تست با نماد  $tc$  نشان داده شده است. برای یک ناوگان از موتورهای تست، زمان شروع پیش‌بینی برای هر موتور می‌تواند متفاوت باشد و لذا یک بازه  $tc$  وجود دارد. در مرحله دسته‌بندی، این بازه به چند دسته تقسیم می‌شود. عرض هر دسته به شرح زیر تعریف شده است:

$$CW_i = t_i - t_{i-1}, \quad \sum_{i=1}^n CW_i = t_n - t_0 \quad (8)$$

در رابطه بالا  $CW$  عرض دسته،  $t_i$ ها مرزهای دسته‌ها،  $t_0$  کوچکترین  $tc$ ،  $t_n$  بزرگترین  $tc$  و  $n$  تعداد دسته‌ها است. در ساده‌ترین حالت، عرض همه دسته‌ها به صورت برابر فرض شوند. البته برای دستیابی به نتایج دقیق‌تر، تعداد دسته‌ها و عرض هر دسته را می‌توان در یک فرایند بهینه‌سازی پیدا کرد.

#### ۳-۲ بازتولید

هدف از بازتولید داده‌های آموزش آن است که به جای این‌که

۲. حذف نویز: پس از انتخاب سنسورهای مناسب و نرمال کردن مقادیر خروجی سنسورها، نویز سیگنال باید حذف شود. تکنیک‌های فیلترینگ مبتنی بر موجک جدیدترین تکنیک‌های بردارسازی فرکانس-زمان هستند که محدودیت‌های روش‌های سنتی را ندارند. بنابراین روش تبدیل موجک گسسته برای حذف نویز داده‌ها استفاده شده است [۱۷].

۳. تلفیق داده‌ها: هدف این مرحله کاهش تعداد متغیرها و ترکیب همزمان اطلاعات چند حسگر برای رسیدن به نتایج دقیق‌تر می‌باشد. از بین روش‌های مختلف تلفیق، مانند روش‌های آماری، منطق فازی، موجک و غیره، روش تحلیل مؤلفه‌های اصلی انتخاب شده است. این رویکرد علاوه بر سادگی، دارای قابلیت بالایی در کاهش ابعاد داده است. در پایان این مرحله، از ترکیب اجزای اصلی به دست آمده از مرحله هم‌جوشی داده‌ها، یک سیگنال بازسازی شده یک‌بعدی حاصل می‌شود که نشان‌دهنده وضعیت سلامت کلی سیستم تحت نظارت است. سیگنال بازسازی شده برای هر موتور، شاخص سلامت آن است که به صورت زیر محاسبه می‌شود:

$$HI = \sum_{j=1}^n PC_j y_j \quad (5)$$

که  $HI$  سیگنال بازسازی شده بیانگر شاخص سلامت<sup>۱</sup>،  $PC_j$  سیگنال مربوط به  $j$  زمین مولفه اصلی و  $y_j$  سهم  $j$  زمین مقدار ویژه است.

۴. استخراج ویژگی: پس از محاسبه سیگنال  $HI$ ، محتوای انرژی و دو شاخص آسیب مجموع مطلق اختلافات<sup>۲</sup> و مجموع مربعات اختلافات<sup>۳</sup> محاسبه می‌شود تا مستقیماً نظارت بر تغییر  $HI$  انجام شود.  $SAD$  و  $SSD$  به شرح زیر تعریف می‌شوند:

$$SAD = \sum_{j=1}^n |E(j) - E_{ref}| \quad (6)$$

$$SSD = \sum_{j=1}^n (E(j) - E_{ref})^2 \quad (7)$$

- 
- 1 Health Index
  - 2 Sum of Absolute Difference (SAD)
  - 3 Sum of Square Difference (SSD)

4 Health Indicator Features (HIF)

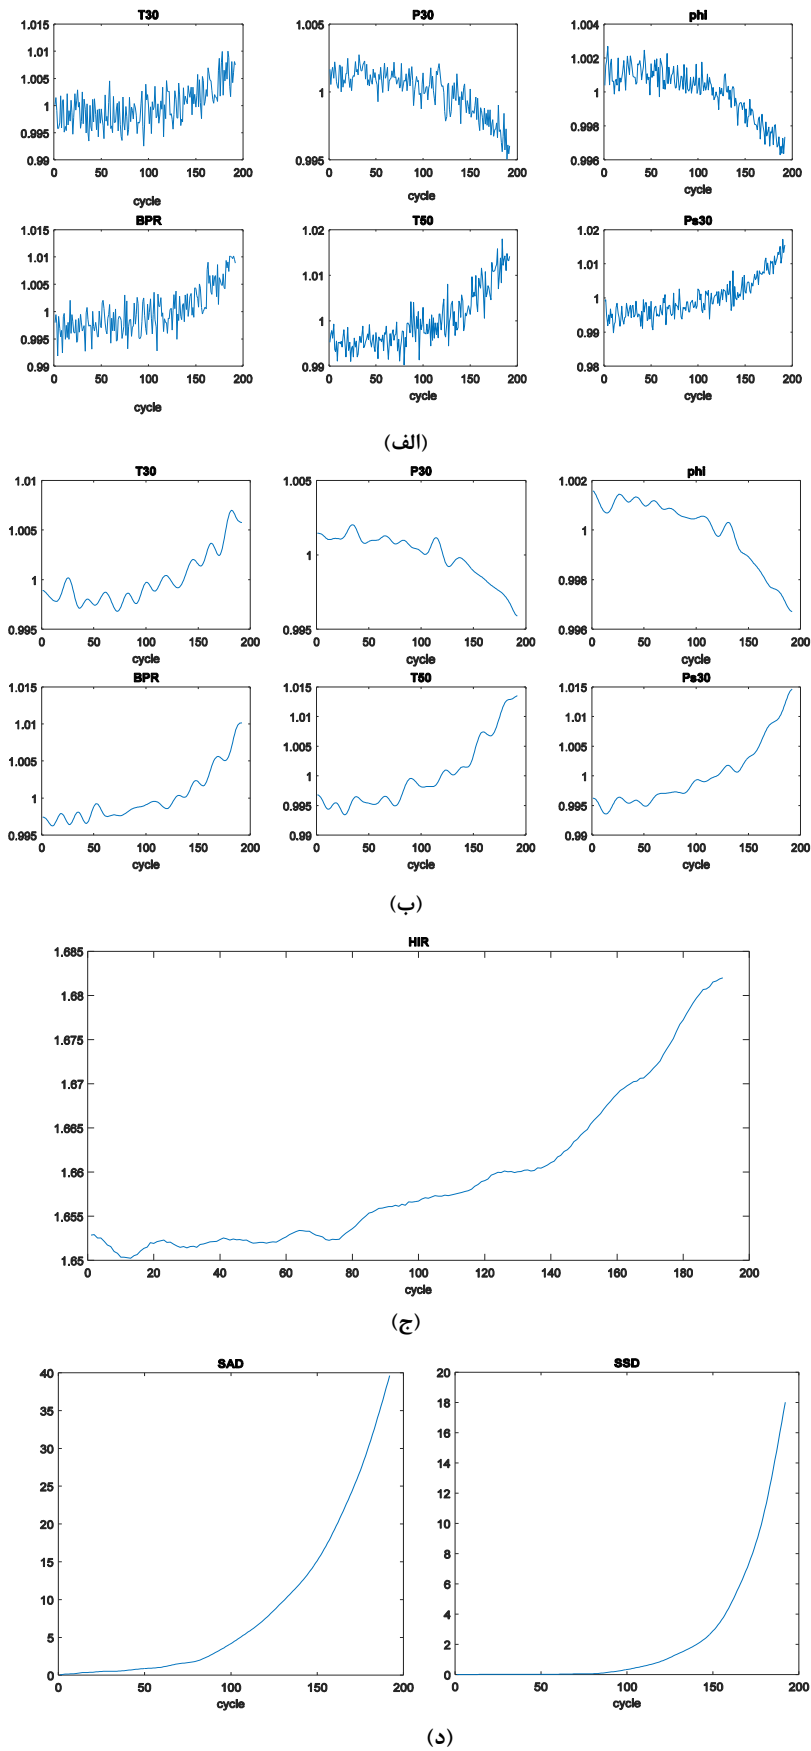


Fig. 2. Different stages of data process for Engine #1 [46]; (a) Normalized sensors, (b) Denoised sensors, (c) Reconstructed signal from multi-sensors, (d) Energy content, SAD and SSD of HI

شکل ۲: مراحل مختلف پردازش داده برای موتور #۱ [۴۶]: (الف) نرمال‌سازی داده‌ها، (ب) حذف نویز حسگرها، (ج) سیگنال بازسازی شده از چندین حسگر، (د) منحنی SAD و SSD سیگنال HI



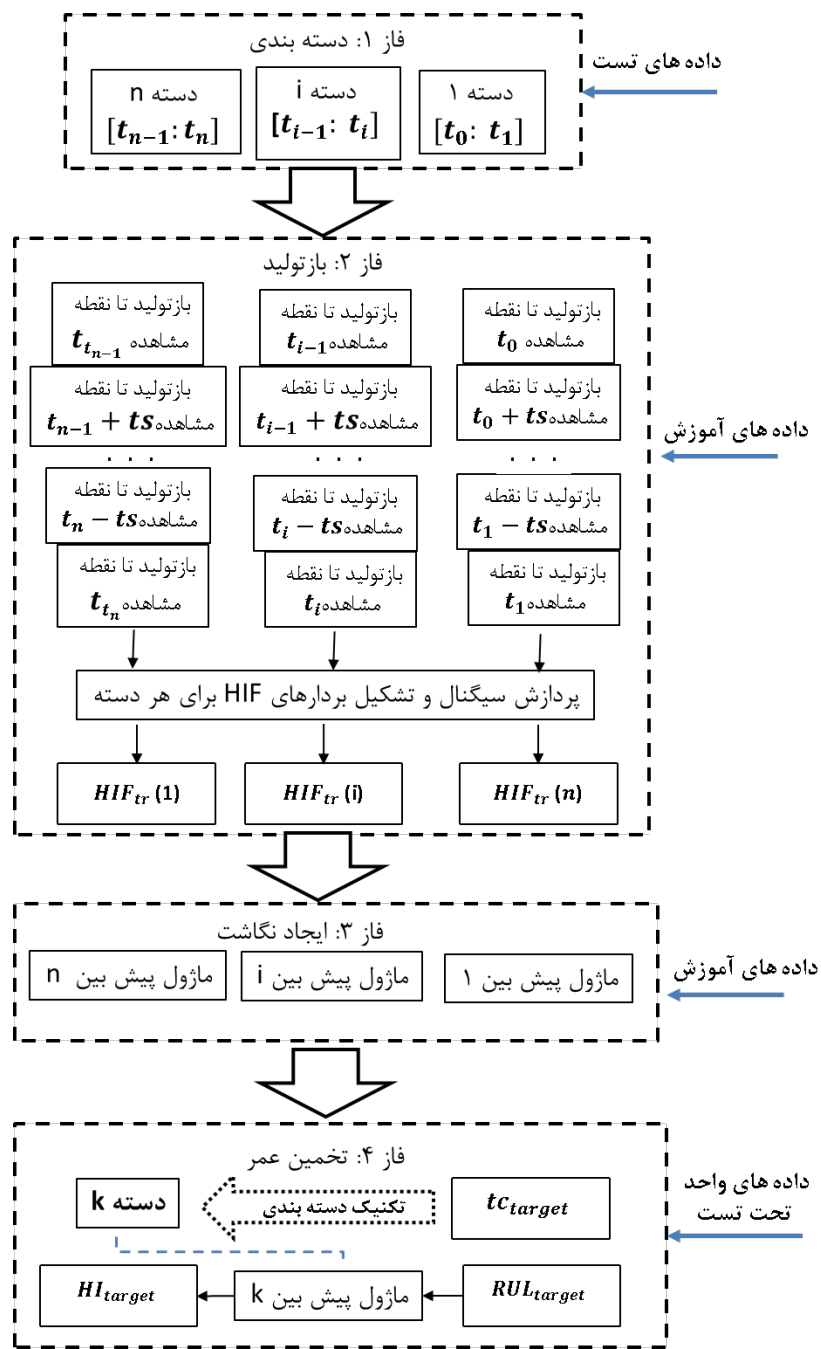


Fig. 3. The framework of ABC prognostics

شکل ۳: ساختار پیش‌بینی عمر به کمک دسته‌بندی سنی

یک گام زمانی  $ts$  در این مرحله در نظر گرفته می‌شود که در هر گام زمانی یک نقطه مشاهده تعریف و مجموعه داده‌های آموزش در آن نقطه بازتولید می‌شود. مثلاً اگر در یک حالت ساده بازتولید داده‌ها با حداکثر رزولوشن انجام شود یا به عبارت دیگر هر گام زمانی مساوی یک سیکل پرواز باشد، همچنین عرض دسته  $t_{am}$ ،  $m_i$  سیکل باشد، آنگاه مجموعه داده‌های آموزش  $m_i$  بار بازتولید شده‌اند که متعلق به

یکسری داده غیرمتجانس مبنای آموزش باشد، چند سری داده که سن آن‌ها نزدیک به هم است برای آموزش الگوریتم تخمین ایجاد شود. برای این منظور یکسری نقاط زمانی که نقاط مشاهده نامیده می‌شود، در نظر گرفته می‌شود. در هر بازتولید، ماشین‌های با طول عمر کمتر از نقطه مشاهده مربوطه حذف می‌شوند؛ و تعداد  $2$  واحد دیگر می‌مانند و اطلاعات‌شان تا آن نقطه ثبت می‌شود.

دسته نام می‌باشد.

در ادامه، پردازش اطلاعات واحدهای هر بازتولید انجام می‌شود و  $m_i$  بردار مشخصات شاخص سلامت  $HIF$  تولید می‌شوند. طول هر بردار  $HIF$  مساوی  $r$  واحدی است که تا نقطه مشاهده مربوطه مانده‌اند. در آخرین گام از این مرحله، بردارهای  $HIF$  برای هر دسته ادغام می‌شوند.

نهایتاً  $n$  بردار  $HIF$  انباشته برای  $n$  دسته باقی می‌مانند. شکل ۳ این مرحله را نشان می‌دهد. در پایان این مرحله به جای این که کل داده‌ها با یک بردار مشخصه تحلیل شوند، اولاً برای هر دسته سنی یک بردار موجود است ( $n$  بردار برای  $n$  دسته)، ثانیاً برای هر دسته نیز با یک رزولوشن بالا حداکثر اطلاعات گردآوری شده است.

### ۳-۳- ایجاد نگاشت

در فاز قبلی، اطلاعات آموزش چندین بار تکثیر شد و  $n$  بردار  $HIF$  انباشته به دست آمد. در مرحله سوم، یک ابزار تخمین مانند شبکه عصبی برای پیدا کردن رابطه بین  $HIF$ ها و  $RUL$ ها برای داده‌های آموزش استفاده می‌شود. بردارهای  $HIF$  به عنوان ورودی انتخاب می‌شوند و داده‌های مربوط به  $RUL$  واقعی به عنوان مقادیر هدف برای آموزش ماژول‌های پیش‌بینی انتخاب می‌شوند. خروجی این فاز ایجاد  $n$  ماژول پیش‌بینی برای  $n$  دسته مختلف سنی است.

### ۳-۴- تخمین عمر

در مرحله چهارم، برآورد عمر باقیمانده برای واحد آزمون هدف انجام می‌شود. در ابتدا، پردازش سیگنال برای واحد آزمون انجام می‌شود و بردار مربوطه  $HIF$  محاسبه می‌شود. سپس، انتخاب دسته با توجه به سن شروع پیش‌بینی  $tc$  واحد آزمون انجام می‌شود. این کار را می‌توان به دو صورت انجام داد:

۱. راه کلاسیک، به طوری که هر واحد متعلق به یک دسته است اگر  $tc$  آن بین سن حداقل و حداکثر آن دسته باشد
۲. روش فازی، که در آن هر واحد با یک درجه‌ای به یک دسته متعلق است که این درجه توسط یک تابع عضویت مشخص شده است. پس از انتخاب دسته،  $HIF$  بردار واحد تست به ماژول پیش‌بینی مربوطه وارد و عمر باقیمانده دستگاه برآورد می‌شود.

### ۴- پیاده‌سازی مدل پیش‌بینی عمر به کمک دسته‌بندی سنی

برای روشن شدن مدل پیشنهادی در این مرحله یک مثال تشریح می‌شود. داده‌های این مثال همان داده‌های ناسا است که در بخش‌های قبلی معرفی گردید. مراحل انجام شده در این مثال بر اساس چارچوب داده شده در شکل ۳ است. پارامترهای اصلی چارچوب مدل پیشنهادی، تعداد دسته‌ها ( $n$ )، عرض دسته ( $CW$ ) و گام زمانی بازتولید داده‌های آموزش می‌باشد. مقادیر بهینه برای این پارامترها برای هر مسأله متفاوت هستند و باید بهینه‌سازی شوند. برای این منظور، سنجه‌های مختلف پیش‌بینی عمر می‌تواند به عنوان تابع هدف تعریف، فازهای متوالی مدل به پیش‌بینی کمک دسته‌بندی سنی اجرا و پارامترهای بهینه از طریق یک فرآیند بهینه‌سازی پیدا شوند.

#### ۴-۱- فاز ۱

برای مثال حاضر، به ازای  $n < 2$  سنجه‌های پیش‌بینی عمر، همانطور که در شکل ۴ نشان داده شده، تقریباً تغییری نمی‌کنند. بنابراین، برای فرار از محاسبات پرهزینه  $n=4$  انتخاب شده است. متعاقباً، پهنای دسته ( $CW$ ) مطلوب توسط الگوریتم ژنتیک به دست می‌آید. طرح بهینه دسته‌بندی در جدول ۲ خلاصه شده است.

#### ۴-۲- فاز ۲

در این مثال بازتولید داده‌های آموزش با بیشترین رزولوشن انجام می‌شود و گام زمانی برابر با یک سیکل پرواز در نظر گرفته شده است. لذا داده‌ها در هر سیکل پروازی یک بار بازتولید می‌شوند. به عنوان مثال، در سیکل  $c$ ام، تمام موتورهایی که سن آن‌ها بیش از  $c$  سیکل هست در سیکل  $c$ ام متوقف می‌شوند. سپس پردازش داده‌ها انجام و مشخصه‌های شاخص سلامت  $HIF_{tr}(c)$  استخراج می‌شوند. در نهایت  $HIF$ های مربوطه برای هر دسته با هم ادغام می‌شوند، به عنوان مثال  $HIF_{tr}(31)$ ،  $HIF_{tr}(32)$ ، ... و  $HIF_{tr}(75)$  به یک بردار تجمعی برای دسته اول ادغام می‌شوند،  $HIF_{tr}(76)$ ،  $HIF_{tr}(77)$ ، ... و  $HIF_{tr}(126)$  به یک بردار انباشته برای دسته دوم ادغام می‌شوند و به همین ترتیب برای دسته‌های دیگر از جدول ۲ بردارهای انباشته  $HIF$  تشکیل می‌شود. خلاصه‌ای از بازتولید مجموعه داده‌های آموزش در جدول ۳ نشان و جزئیات بیشتر نیز در

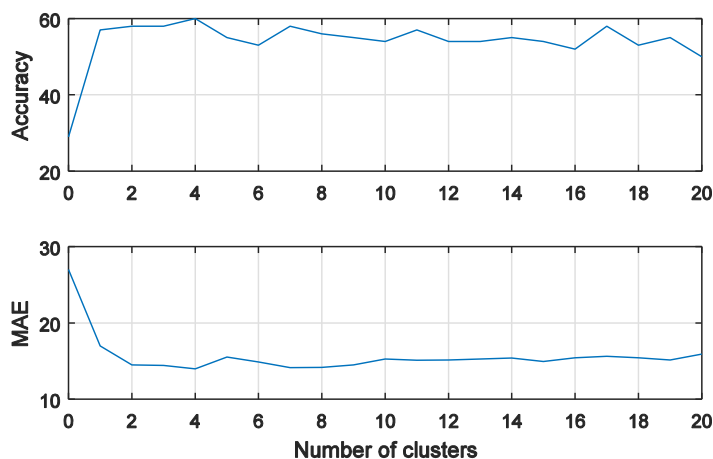


Fig. 4. Prognostic measures via. number of clusters

شکل ۴: تغییر سنج‌های پیش‌بینی عمر بر حسب تعداد دسته‌ها

جدول ۳: خلاصه بازتولید داده‌های آموزش

Table 3. Summary of train data set reproductions

دسته	طول بردار انباشته $HIF$
۱	۴۵۰۰
۲	۵۰۰۰
۳	۵۹۷۱
۴	۲۲۴۰
مجموع	۱۷۷۱۱

جدول ۲: طرح بهینه دسته‌بندی

Table 2. Optimal clustering scheme

دسته	عرض دسته	بازه سنی
۱	۴۵ سیکل	سیکل ۳۱-۷۵
۳	۵۰ سیکل	سیکل ۷۶-۱۲۵
۳	۷۱ سیکل	سیکل ۱۲۶-۱۹۶
۴	۱۰۷ سیکل	سیکل ۱۹۷-۳۰۳

تخمین‌گر در جدول ۴ ارائه شده است.

۴-۴- فاز ۴

برآورد  $RUL$  از طریق مراحل زیر انجام می‌شود:

۱. برای موتور تست  $ZAM$ ،  $tc$  در نظر گرفته شده است ( $tc_j$ ).

۲. بسته به سن آن، گروه مناسب از جدول ۲ انتخاب شده است.

(گروه  $k$ ام)

۳. بردار مربوط به  $HIF$  موتور تست  $ZAM$  استخراج شده است

$(HIF_{te}(i))$ .

۴.  $HIF_{te}(i)$  به عنوان یک ورودی به شبکه  $k$  استفاده می‌شود.

۵. خروجی شبکه عمر باقیمانده تخمین زده شده برای موتور

تست  $ZAM$  است.

نتایج به‌دست آمده از پیش‌بینی عمر در بخش بعدی بررسی

می‌شود.

ضمیمه الف ارائه شده است. یادآور می‌شود طول حداکثر بردار  $HIF$  در حالت معمولی بیشتر از ۱۰۰ نمی‌شود (با توجه به ۱۰۰ واحد موتور داده‌های آموزش). در اینجا مجموعه آموزش که متشکل از ۴ بردار انباشته  $HIF$  است، ۱۷۷۱۱ واحد دارد.

۴-۳- فاز ۳

در مرحله سوم، یک نگرانی بین  $HIF$  ها و  $RUL$  ها برای هر دسته ایجاد می‌شود. برای این منظور، از ابزار شبکه عصبی استفاده شده است [۶۳]. در این مطالعه، از الگوریتم رو به جلوی چندلایه پرسپترون به همراه آموزش شبکه بیزی<sup>۱</sup> رو به عقب برای ایجاد شبکه عصبی استفاده شده است. شبکه مذکور ۱۰ لایه پنهان دارد، ۷۰ درصد داده‌ها برای آموزش، ۱۵ درصد برای تست و ۱۵ درصد برای صحت‌گذاری استفاده شده است. خلاصه‌ای از تشکیل چهار شبکه

جدول ۴: خلاصه تشکیل چهار شبکه تخمین‌گر

Table 4. Summary of the formation of the prediction modules

هدف	ورودی	شبکه تخمین‌گر
ماتریس $۱ \times ۴۵۰۰$ ، بیانگر $RUL$ موتور ۴۵۰۰	ماتریس $۲ \times ۴۵۰۰$ ، بیانگر ۲ مشخصه از ۴۵۰۰ سیگنال شاخص سلامت	۱
ماتریس $۱ \times ۵۰۰۰$ ، بیانگر $RUL$ موتور ۴۵۰۰	ماتریس $۲ \times ۵۰۰۰$ ، بیانگر ۲ مشخصه از ۵۰۰۰ سیگنال شاخص سلامت	۲
ماتریس $۱ \times ۵۹۷۱$ ، بیانگر $RUL$ موتور ۵۹۷۱	ماتریس $۲ \times ۵۹۷۱$ ، بیانگر ۲ مشخصه از ۵۹۷۱ سیگنال شاخص سلامت	۳
ماتریس $۱ \times ۲۲۴۰$ ، بیانگر $RUL$ موتور ۲۲۴۰	ماتریس $۲ \times ۲۲۴۰$ ، بیانگر ۲ مشخصه از ۲۲۴۰ سیگنال شاخص سلامت	۴

جدول ۵: مقایسه دقت روش‌های مختلف

Table 5. Comparison of accuracy for different methods

روش	صحیح (درصد)	زود هنگام (درصد)	دیر هنگام (درصد)
روش پیش‌بینی به کمک دسته‌بندی سنی (استفاده از ماژول‌های تخمین شبکه عصبی)	۷۱	۲۳	۶
راموسو و همکاران [۴۵]	۶۷	-	-
خلیف و همکاران [۴۴]	۵۴	۱۸	۲۸
راموسو و همکاران [۴۳]	۵۳	۳۶	۱۱
جاود و همکاران [۶۶]	۵۳	۲۷	۲۰
وانگ و همکاران [۶۵]	۴۴	۱۹	۳۷

۵- بحث و بررسی نتایج

عملکرد روش پیش‌بینی عمر پیشنهاد شده در دو حالت ارزیابی می‌شود:

۱) اطلاعات آموزش کامل: در این حالت، تمام موتورهای مجموعه داده‌های آموزش ناسا (۱۰۰ واحد) برای آموزش الگوریتم استفاده می‌شوند. این شبیه شرایطی است که اکثر مقالات برای آموزش الگوریتم‌های پیش‌بینی عمر استفاده کرده و نتایج‌شان را ارائه کرده‌اند.

۲) اطلاعات آموزش محدود: در این حالت، بخشی از مجموعه داده‌های آموزش ناسا برای آموزش الگوریتم استفاده می‌شود. تست‌ها با ۵۰ درصد، ۳۰ درصد، ۲۰ درصد، ۱۰ درصد و ۵ درصد از اطلاعات

آموزش (معادل تعداد ۵۰، ۳۰، ۲۰، ۱۰ و ۵ موتور) انجام می‌شود. این وضعیت بیشتر مشابه آن چیزی که در دنیای واقعی و صنعت روی می‌دهد، زمانی که داده‌های آموزش محدود می‌باشد.

۵-۱- نتایج در حالت اطلاعات کامل

برای ارزیابی اثربخشی الگوریتم، مقایسه با روش‌های دیگر انجام شده است. بر اساس جستجوهای انجام شده، طبق گزارش مرجع [۶۴] فقط تعداد محدودی از مقالات مجموعه کامل داده‌های تست را استفاده کرده‌اند: راموسو و همکاران [۴۳ و ۴۵]، خلیف و همکاران [۴۴] و وانگ و همکاران [۶۵] که بالاترین امتیاز را در چالش بین المللی PHM ۲۰۰۸ به دست آورد. در جدول ۵ نتایج روش پیشنهادی

جدول ۶: خلاصه نتایج پیش‌بینی عمر در حالت اطلاعات محدود

Table 6. Summary of prognostic measures under limited train data condition

MAE	MSE	صحت (درصد)		تعداد واحدهای آموزش
		میانگین انحراف معیار	صحت	
۱۴/۵	۲	۳/۱	۵۷	۵۰
۱۴/۴	۲	۳/۴	۵۶	۳۰
۱۷/۳	۲/۳	۳/۱	۴۶.۶	۲۰
۲۱/۲	۲/۹	۵/۷	۴۲	۱۰
۳۱/۷۵	۴/۴	۷/۸	۳۲	۵




Fig. 5. Comparison of prognosis measures for different sizes of train data

شکل ۵: مقایسه سنج‌های مختلف پیش‌بینی عمر برای ابعاد گوناگون داده‌های آموزش

مختلف اطلاعات آموزش در شکل ۵ نشان داده شده است. از آنجایی که در الگوریتم پیش‌بینی به کمک دسته‌بندی سنی، داده‌های آموزش چندین بار برای هر دسته سنی بازتولید می‌شود، اندازه مجموعه آموزش چندین برابر بیشتر از داده‌های اولیه آموزش می‌شود. به همین دلیل، حتی وقتی اطلاعات آموزش به یک سوم کاهش می‌یابد سنج‌های پیش‌بینی عمر تقریباً بدون تغییر باقی می‌مانند. متعاقباً، دقت پیش‌بینی عمر با یک شیب ملایم کاهش می‌یابد؛ به طوری که هنگامی که داده‌های آموزشی از ۱۰۰ واحد تا ۱۰ واحد کاهش می‌یابد، دقت نتایج از ۵۸ درصد به ۴۲ درصد کاهش می‌یابد. تحقیقات بیشتری می‌توان راجع به پایداری الگوریتم پیشنهادی تحت شرایط محدود اطلاعات آموزشی انجام داد. در ادامه مقاله نتایج پیش‌بینی عمر هر موتور در سیکل‌های مختلف مورد بررسی قرار گرفته است. مقدار واقعی و تخمین عمر باقیمانده

با روش‌های فوق‌الذکر مقایسه شده است. دقت مناسب روش پیشنهادی در مقایسه با سایر روش‌ها مشهود می‌باشد.

#### ۵-۲- نتایج در حالت اطلاعات محدود

در بخش قبلی نشان داده شد که دقت روش پیش‌بینی به کمک دسته‌بندی سنی برای شرایط وجود داده‌های آموزش غنی در مقایسه با سایر روش‌ها قابل اعتماد است. در این بخش تحلیل حساسیت تحت شرایط محدود اطلاعات انجام می‌شود. همانطور که قبلاً ذکر شد، در این بخش، چهار آزمون با ۵۰ درصد، ۳۰ درصد، ۲۰ درصد، ۱۰ درصد و ۵ درصد از اطلاعات آموزش استفاده می‌شود. هر آزمون چندین بار تکرار می‌شود تا بخش‌های مختلف اطلاعات آموزش انتخاب شوند. در نهایت، میانگین مقادیر پیش‌بینی عمر برای هر آزمون در جدول ۶ خلاصه شده است. مقایسه مقادیر پیش‌بینی عمر برای اندازه‌های




Fig. 6. Prognosis results of engines #97-100 in different cycles with limited train data set (10 units for training)

شکل ۶: نتایج پیش‌بینی عمر برای موتورهای شماره ۹۷-۱۰۰ در سیکل‌های مختلف در شرایط فقدان داده آموزش غنی (استفاده از ۱۰ موتور برای آموزش)

می‌تواند با الگوریتم پیش‌بینی به کمک دسته‌بندی سنی یکپارچه و اصلاح شود تا برآوردهای دقیق‌تر و قوی‌تری از عمر باقیمانده به دست آید.

برای یک مطالعه موردی ۷۱ درصد عمرهای تخمین زده شده با این روش صحیح بود که در مقایسه با سایر روش‌های متعارف بهتر بوده و مشاهده شد که طبقه‌بندی سنی می‌تواند در پیش‌بینی عمر بسیار موثر باشد. بازتولید داده‌های آموزش با حداکثر ریزنگری، یعنی به جای این‌که یک موتور آموزش از ابتدا تا انتهای عملکردش فقط یک‌بار اطلاعاتش استفاده شود، در هر گام زمانی یک‌بار اطلاعاتش استفاده می‌شود. در این روش بردار داده‌های آموزش که سایز اولیه آن ۱۰۰ واحد بود، ۱۷۷۱۱ واحد شد که این افزایش چند برابری حجم داده‌های آموزشی، در شرایط داده‌های محدود می‌تواند جبران‌کننده کمبود داده باشد. بنابراین پس از تست روش پیشنهادی در شرایط عادی، نتایج آن در شرایط داده‌های محدود آموزش مورد بررسی قرار گرفت، که غالباً در صنایع اتفاق می‌افتد. مقایسه نتایج حاصل از تعداد مختلف داده‌های آموزشی نشان داد که دقت الگوریتم پیش‌بینی عمر حتی با استفاده از ۳۰ درصد داده‌های اولیه، افت چندانی نداشته است. بعد از آن نیز دقت پیش‌بینی با شیب کمی کاهش یافته، طوری که هنگامی که تعداد داده‌های آموزش ۹۰ درصد کاهش یافته،

با داده‌های آموزش محدود (فقط ۱۰ واحد برای آموزش) در شکل ۶ برای موتورهای شماره ۹۷-۱۰۰ نشان داده شده است. نتایج موتورهای دیگر (شماره ۹۶-۸۱) در ضمیمه ب نشان داده شده است. نتایج نشان می‌دهد که تخمین عمر باقیمانده با بهره‌گیری از داده‌های محدود برای آموزش، به‌طور منطقی به عمر باقی‌مانده نزدیک است (به‌ویژه در سیکل‌های بالاتر). به‌طور کلی، نتایج به‌طور غیرمستقیم از این فرضیه حمایت می‌کند که روش دسته‌بندی سنی به نتایج قابل قبول در شرایط فقدان داده‌های آموزش غنی منجر می‌شود.

## ۶- جمع‌بندی

در این مقاله، یک الگوریتم پیش‌بینی عمر پیشنهاد شده است که ابتدا واحدهای آزمون را در گروه‌های سنی مختلف طبقه‌بندی می‌کند و سپس عمر باقیمانده آن‌ها را با استفاده از تکنیک‌های پیش‌بینی تخمین می‌زند. یک مزیت این الگوریتم این است که طراحی آن آسان است؛ تکنیک پیش‌بینی یکی از روش‌های پیش‌بینی معمول و قابل دسترس (مانند شبکه عصبی است که در این مطالعه ارائه شده است) و الگوریتم پیشنهادی اصلاح این روش برای رسیدن به نتایج قابل اعتمادتر و قوی‌تر است. مزیت دیگر این روش آن است که هر روش کلاسیک مانند شبکه عصبی، رگرسیون، ماشین‌بردار پشتیبان و غیره



- rotary machinery systems-Reviews, methodology and applications, Mechanical systems and signal processing, 42 (2014) 20.
- [8] S.M. Raghavan, A. Palatel, J. Simon, Health Assessment of Gas Turbine Compressor Using Process History Based Modelling Approach, ASME 2015 Gas Turbine India Conference (pp. V001T08A001-V001T08A001). American Society of Mechanical Engineers., (2015).
- [9] M. Garsia A. Munoz, A. Sola, Hybrid model-based fault detection and diagnosis for the axial flow compressor of a combined-cycle power plant, Journal of Engineering for Gas Turbines and Power, 135 (2013).
- [10] R. Sekhon, Real Time Prognostic Strategies Application to Gas Turbines, Clemson university Technical Report (2007).
- [11] P. Baraldi, F. Cadini, F. Mangili, E. Zio, Model-based and data-driven prognostics under different available information, Probabilistic Engineering Mechanics, 32 (2013) 66-79.
- [12] Y.G. Li, P. Nilkitsaranont, Gas turbine performance prognostic for condition-based maintenance, Applied energy, 86 (2009) 2152-2161.
- [13] F. Lu, J. Wu, J. Huang, X. Qiu, Aircraft engine degradation prognostics based on logistic regression and novel OS-ELM algorithm, Aerospace Science and Technology, (2019) 661-671.
- [14] D. An, N.H. Kim, J.H. Choi, Statistical aspects in neural network for the purpose of prognostics, . Journal of Mechanical Science and Technology, 29 (2015) 1369-1375.
- [15] W. Zhao, A Probabilistic Approach for Prognostics of Complex Rotary Machinery Systems, Doctoral dissertation, University of Cincinnati, (2015).
- [16] J. Son, S. Zhou, C. Sankavaram, X. Du, Y. Zhang, Remaining useful life prediction based on noisy condition monitoring signals using constrained Kalman filter, Reliability Engineering & System Safety, 152 (2016) 38-50.
- [17] O.N. Diallo, A data analytics approach to gas turbine prognostics and health management, Doctoral dissertation, دقت پیش‌بینی ۱۶ درصد افت کرده و به ازای کاهش ۹۵ درصد داده‌های آموزش، دقت پیش‌بینی ۲۶ درصد کاهش یافته است. در مرحله نهایی، موارد بیشتر مورد آزمایش قرار گرفت و نتایج الگوریتم پیش‌بینی عمر با استفاده از تعداد کم داده‌های آموزشی (۱۰ موتور) بررسی شد. نتایج حاصل از این مطالعه نشان داد که روش پیش‌بینی به کمک دسته‌بندی سنی یک ابزار پیش‌بینی عمر قوی در شرایط عادی است. علاوه بر این، در شرایط محدود اطلاعات نیز تا حدی مقاوم است. بنابراین این روش می‌تواند با اطمینان بیشتر با شرایط واقعی مواجه شود. روش پیشنهاد شده در این مقاله محدود به استفاده از پیش‌بینی موتور توربین گاز نیست. این را می‌توان به ماشین‌های دیگر نیز گسترش داد.
- مراجع**
- [1] E. khavasi, S. Nasiri, Analysis and Simulation of Surge phenomena in the axial Compressor of GE-frame 6 gas Turbine, Amirkabir Journal of Mechanical Engineering, online published (2019) (in persian).
- [2] R. Jiang, C. Huang, Predicting distribution of time to degradation limit using a weighted approach, Journal of Mechanical Science and Technology, 32(11) (2018) 5133-5138 (in Persian) .
- [3] R. Bannazadeh, R. M, A. M., Failure Analysis of a Gas Turbine Blade Made of Inconel 738LC Super Alloy, Amirkabir Journal of Mechanical Engineering, 50 (2018) 103-112.
- [4] D. Kwon, J. Yoon, A model-based prognostic approach to predict interconnect failure using impedance analysis, Journal of Mechanical Science and Technology, 30(10) (2016) 4447-4452.
- [5] D. An, J.H. Choi, K. N, Prediction of remaining useful life under different conditions using accelerated life testing data, Journal of Mechanical Science and Technology, 32 (2018) 2497-2507.
- [6] F.O. Heimes, Recurrent neural networks for remaining useful life estimation, international conference on prognostics and health management (IEEE), (2008) 1-6.
- [7] J. Lee, F. Wu, W. Zhao, M. Ghaffari, L. Liao, D. Siegel, Prognostics and health management design for

- [28] J. Xu, Y. Wang, L. Xu, PHM-oriented integrated fusion prognostics for aircraft engines based on sensor data, *IEEE Sensors Journal*, 14 (2013) 1124-1132.
- [29] R. Salehi, A. Alasty, G.R. Vossoughi, Sliding Mode Observers to Detect and Isolate Faults in a Turbocharged Gasoline Engine, *SAE International Journal of Engines*, 8 (2015) 399-410.
- [30] N. Puggina, M. Venturini, Development of a Statistical Methodology for Gas Turbine Prognostics, *ASME 2011 Turbo Expo, Turbine Technical Conference and Exposition*, 4 (2011) 981-992.
- [31] M. Venturini, D. Therkorn, Application of a statistical methodology for gas turbine degradation prognostics to alstom field data, *Journal of Engineering for Gas Turbines and Power*, 135 (2013).
- [32] M. Venturini, N. Puggina, Prediction reliability of a statistical methodology for gas turbine prognostics, *Journal of Engineering for Gas Turbines and Power*, 134 (2012).
- [33] Musavi A, R. H., Failure analysis of compressor blades in a gas turbine, *International Power System Conference*, 22 (2009) (in Persian).
- [34] C.M. Holcomb, *Diagnostics and Control of Gas Turbines Through System Identification*, Doctoral dissertation, UC San Diego, (2015).
- [35] P. Wang, G. Vachtsevanos, Fault prognostics using dynamic wavelet neural networks, *AI EDAM*, 15 (2001) 349-365.
- [36] R. Yan, R.X. Gao, X. Chen, Wavelets for fault diagnosis of rotary machines: A review with applications, *Signal processing*, 96 (2014) 1-15.
- [37] R. Mao, H. Zhu, L. Zhang, A. Chen, A new method to assist small data set neural network learning, *Sixth International Conference on Intelligent Systems Design and Applications* 1(2006) 17-22.
- [38] R. Moghaddass, M.J. Zuo, An integrated framework for online diagnostic and prognostic health monitoring using a multistate deterioration process, *Reliability Engineering & System Safety*, (2014) 92-104.
- [39] Y. Xiang, Y. Liu, Application of inverse first-order Georgia Institute of Technology, (2010).
- [18] M. Daigle, S. Sankararaman, Predicting remaining driving time and distance of a planetary rover under uncertainty, *ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering*, 2 (2016).
- [19] W. Caesarendra, W. , A. , B.S. Yang, Combination of probability approach and support vector machine towards machine health prognostics, *Probabilistic Engineering Mechanics*, 26 (2011) 165-173.
- [20] H.Z. Huang, H.K. Wang, Y.F. Li, L. Zhang, Z. Liu, Support vector machine based estimation of remaining useful life: current research status and future trends, *Journal of Mechanical Science and Technology*, (2015) 151-163.
- [21] F. Lu, J. Wu, J. Huang, X. Qiu, Aircraft engine degradation prognostics based on logistic regression and novel OS-ELM algorithm, *Aerospace Science and Technology*, 84 (2019) 661-671.
- [22] D. Simon, A comparison of filtering approaches for aircraft engine health estimation, *Aerospace Science and Technology*, (2008) 276-284.
- [23] K.T. McClintic, *Feature prediction and tracking for monitoring the condition of complex mechanical systems*, Doctoral dissertation, Pennsylvania State University, (1998).
- [24] D.C. Swanson, A general prognostic tracking algorithm for predictive maintenance, *IEEE Aerospace Conference Proceedings*, (2001) 2971-2977.
- [25] F. Lu, H. Ju, J. Huang, An improved extended Kalman filter with inequality constraints for gas turbine engine health monitoring, *Aerospace Science and Technology*, (58) (2016) 36-47.
- [26] C. Ding, J. Xu, L. Xu, ISHM-based intelligent fusion prognostics for space avionics, *Aerospace Science and Technology*, 29 (2013) 200-205.
- [27] Goebel K, Saha B, S. A.. A comparison of three data-driven techniques for prognostics. In 62nd meeting of the society for machinery failure prevention technology, (2008) 119-131.

- vibration based fatigue analysis, *Journal of Mechanical Science and Technology*, 32 (2018) 4071-4078.
- [50] C. Fisher, N.C. Baines, . Multi-sensor condition monitoring systems for gas turbines, *Journal of Condition Monitoring*, (1988) 57-68.
- [51] D. Muir, B. Taylor, Oil debris monitoring for aero-derivative gas turbine, *ASME Power Division (Publication) PWR*, (1997).547-553.
- [52] M. Behzad, A. Ebrahimi, M. Heydari, M. Asadi, Experimental investigation on the fault diagnosis of permanent magnet DC electromotors, *Insight*, 55 (2013) 1-8.
- [53] M. Behzad, M.R. Hoseini, H. Salmasi, M. Asayesh, Fault Diagnosis In Two Industrial Applications By Vibration Analysis, *Proceeding of IMEC 2004*, (2004) 591-603.
- [54] M. Behzad, A.R. Bastami, M. Maassoumian, Fault diagnosis of a centrifugal pump by vibration analysis, *ASME 7th Biennial Conference on Engineering Systems Design and Analysis* (2004) 221-226.
- [55] M. Behzad, M. Asoyesh, Steam turbine coupling misalignment detection by vibrational analysis, *Journal of Electrical Science and Technology*, 13 (2001) 47-53.
- [56] A.H. Zamanian, A. Ohadi, 2011, Gear fault diagnosis based on Gaussian correlation of vibrations signals and wavelet coefficients, *Applied Soft Computing*, 11 (2011) 4807-4819.
- [57] N Mahmoodi, Lari H, Using vibrating properties of gas turbines to prevent failure, *15th International Power System Conference*, (1999).
- [58] E. Halim, Fault Detection And Diagnosis Of Rotating Machineries, *Doctoral dissertation, Alberta university*, (2009).
- [59] M. Rezaei, B. .M., M. , Moradi, H. , H. Haddadpour, Modal-based damage identification for the nonlinear model of modern wind turbine blade, *Renewable energy*, 94 (2016) 391-409.
- [60] E. Mohammadi, M. Montazeri-Gh, Simulation of full and part-load performance deterioration of industrial two-shaft gas turbine, *Journal of Engineering for Gas Turbines and Power*, 136 (2014).
- reliability method for probabilistic fatigue life prediction, *Probabilistic Engineering Mechanics*, 26 148-156.
- [40] M. Gholamrezaei, K. Ghorbanian, Application of integrated fuzzy logic and neural networks to the performance prediction of axial compressors, *Proceedings of the Institution of Mechanical Engineers, Part A: Journal of Power and Energy*, 229 (2015) 928-947.
- [41] D. Zhou, H. Zhang, S. Weng, A novel prognostic model of performance degradation trend for power machinery maintenance, *Energy*, 78 (2014) 740-746.
- [42] A. Saxena, K. Goebel, D. Simon, Damage propagation modeling for aircraft engine run-to-failure simulation, *international conference on prognostics and health management (IEEE)*, (2008 ) 1-9.
- [43] E. Ramasso, M. Rombaut, N. Zerhouni, Joint prediction of observations and states in time-series: a partially supervised prognostics approach based on belief functions and KNN, networks, (2013).
- [44] R. Khelif, S. Malinowski, B. Chebel-Morello, N. Zerhouni, RUL prediction based on a new similarity-instance based approach, *23rd International Symposium on Industrial Electronics (ISIE)*, (2014) 2463-2468.
- [45] E. Ramasso, Investigating computational geometry for failure prognostics, *International Journal of Prognostics and Health Management*, 5 (2014).
- [46] A, Mahmoodina. M Durali, Saadat M, A Data Driven Prognostics Method for Gas Turbines with Limited Information Using an Age Based Clustering Algorithm, *20th International Conference on Gas Turbines*, (2018) (in Persian).
- [47] M. Tahan, E. Tsoutsanis, M. Muhammad, Z.A. Karim, Performance-based health monitoring, diagnostics and prognostics for condition-based maintenance of gas turbines: A review, *Applied energy*, 198 (2017) 122-144.
- [48] M. Makvandi H , Moradi.S., Crack identification in postbuckled plates using differential quadrature element method and sequential quadratic programming, *Amirkabir Journal of Mechanical Engineering*, online published (2018).
- [49] S.R. Prasad, A.S. Sekhar, Life estimation of shafts using

- 45 (2013) 105:118
- [64] E. Ramasso, A. Saxena, . Review and analysis of algorithmic approaches developed for prognostics on CMAPSS dataset, International Journal of Prognostics and Health Management,, (2014).
- [65] T. Wang, J. Yu, Siegel, J. D. and Lee, A similarity-based prognostics approach for remaining useful life estimation of engineered systems, In 2008 international conference on prognostics and health management, (2008) 1-6.
- [66] K. Javed, R. Gouriveau, N. Zerhouni, Novel failure prognostics approach with dynamic thresholds for machine degradation, In IECON 2013-39th Annual Conference of the IEEE Industrial Electronics Society, (2013) 4404-4409.
- [61] B. Zhou, K. Bhimavarapu, . Effect of Condition Monitoring on Risk Mitigation for Steam Turbines in the Forest Products Industry, ASCE-ASME Journal of Risk and Uncertainty in Engineering Systems, Part B: Mechanical Engineering, 3 (2017).
- [62] A Mahmoodian,. M Durali, Saadat M, Investigating Different Structures for Mapping Sensor Information of a Complex Mechanical System to Its Health Status, Proceedings of the 26th ISME Conference, (2018) 110-114 (in persian)
- [63] M Kamari,G Payeganeh., Implementation of Neuro–Fuzzy and Multi-Layer Perceptron System Intelligent Techniques for Main Fault Diagnosis of Rotating Machinery, Amirkabir Journal of Mechanical Engineering,

### ضمیمه الف

جزئیات بازتولید داده های آموزش برای دسته های ۱ و ۲ در جدول ۷ نشان داده شده است.

### جدول ۷: جزئیات بازتولید داده های آموزش برای دسته های ۱ و ۲

Table 7. Details of reproductions of train data set for clusters 1 and 2

طول بردار HIF برای دسته ۲	طول بردار HIF	زمان مشاهده	بازتولید	طول بردار HIF تجمعی برای دسته ۱	طول بردار HIF	زمان مشاهده	بازتولید
	100	76	46		100	31	1
	100	77	47		100	32	2
	100	78	48		100	33	3
	100	79	49		100	34	4
	100	80	50		100	35	5
	100	81	51		100	36	6
	100	82	52		100	37	7
	100	83	53		100	38	8
	100	84	54		100	39	9
	100	85	55		100	40	10
	100	86	56		100	41	11
	100	87	57		100	42	12
	100	88	58		100	43	13
	100	89	59		100	44	14
	100	90	60		100	45	15
	100	91	61		100	46	16
	100	92	62		100	47	17
	100	93	63		100	48	18
	100	94	64		100	49	19
	100	95	65		100	50	20
	100	96	66		100	51	21
	100	97	67		100	52	22
	100	98	68		100	53	23
5000	100	99	69	4500	100	54	24
	100	100	70		100	55	25
	100	101	71		100	56	26
	100	102	72		100	57	27
	100	103	73		100	58	28
	100	104	74		100	59	29
	100	105	75		100	60	30
	100	106	76		100	61	31
	100	107	77		100	62	32

ادامه جدول ۷: جزئیات بازتولید داده های آموزش برای دسته های ۱ و ۲

continued Table 7. Details of reproductions of train data set for clusters 1 and 2

طول بردار HIF تجمعی برای دسته ۲	طول بردار HIF	زمان مشاهده	بازتولید	طول بردار HIF تجمعی برای دسته ۱	طول بردار HIF	زمان مشاهده	بازتولید
100	100	108	78	100	100	63	33
100	100	109	79	100	100	64	34
100	100	110	80	100	100	65	35
100	100	111	81	100	100	66	36
100	100	112	82	100	100	67	37
100	100	113	83	100	100	68	38
100	100	114	84	100	100	69	39
100	100	115	85	100	100	70	40
100	100	116	86	100	100	71	41
100	100	117	87	100	100	72	42
100	100	118	88	100	100	73	43
100	100	119	89	100	100	74	44
100	100	120	90	100	100	75	45
100	100	121	91				
100	100	122	92				
100	100	123	93				
100	100	124	94				

ضمیمه ب

نتایج پیش بینی عمر موتورهای شماره ۸۱-۹۶ در سیکل های مختلف با مجموعه داده های محدود آموزش در شکل ۷ نشان داده شده است.

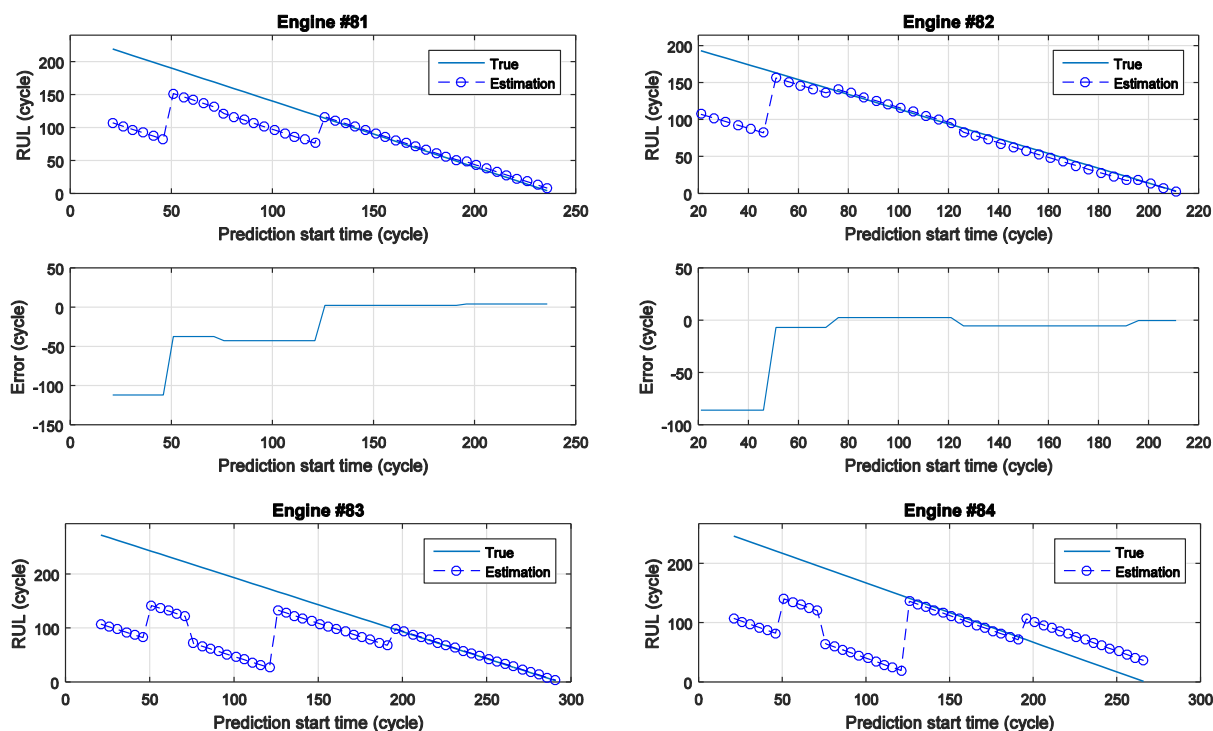
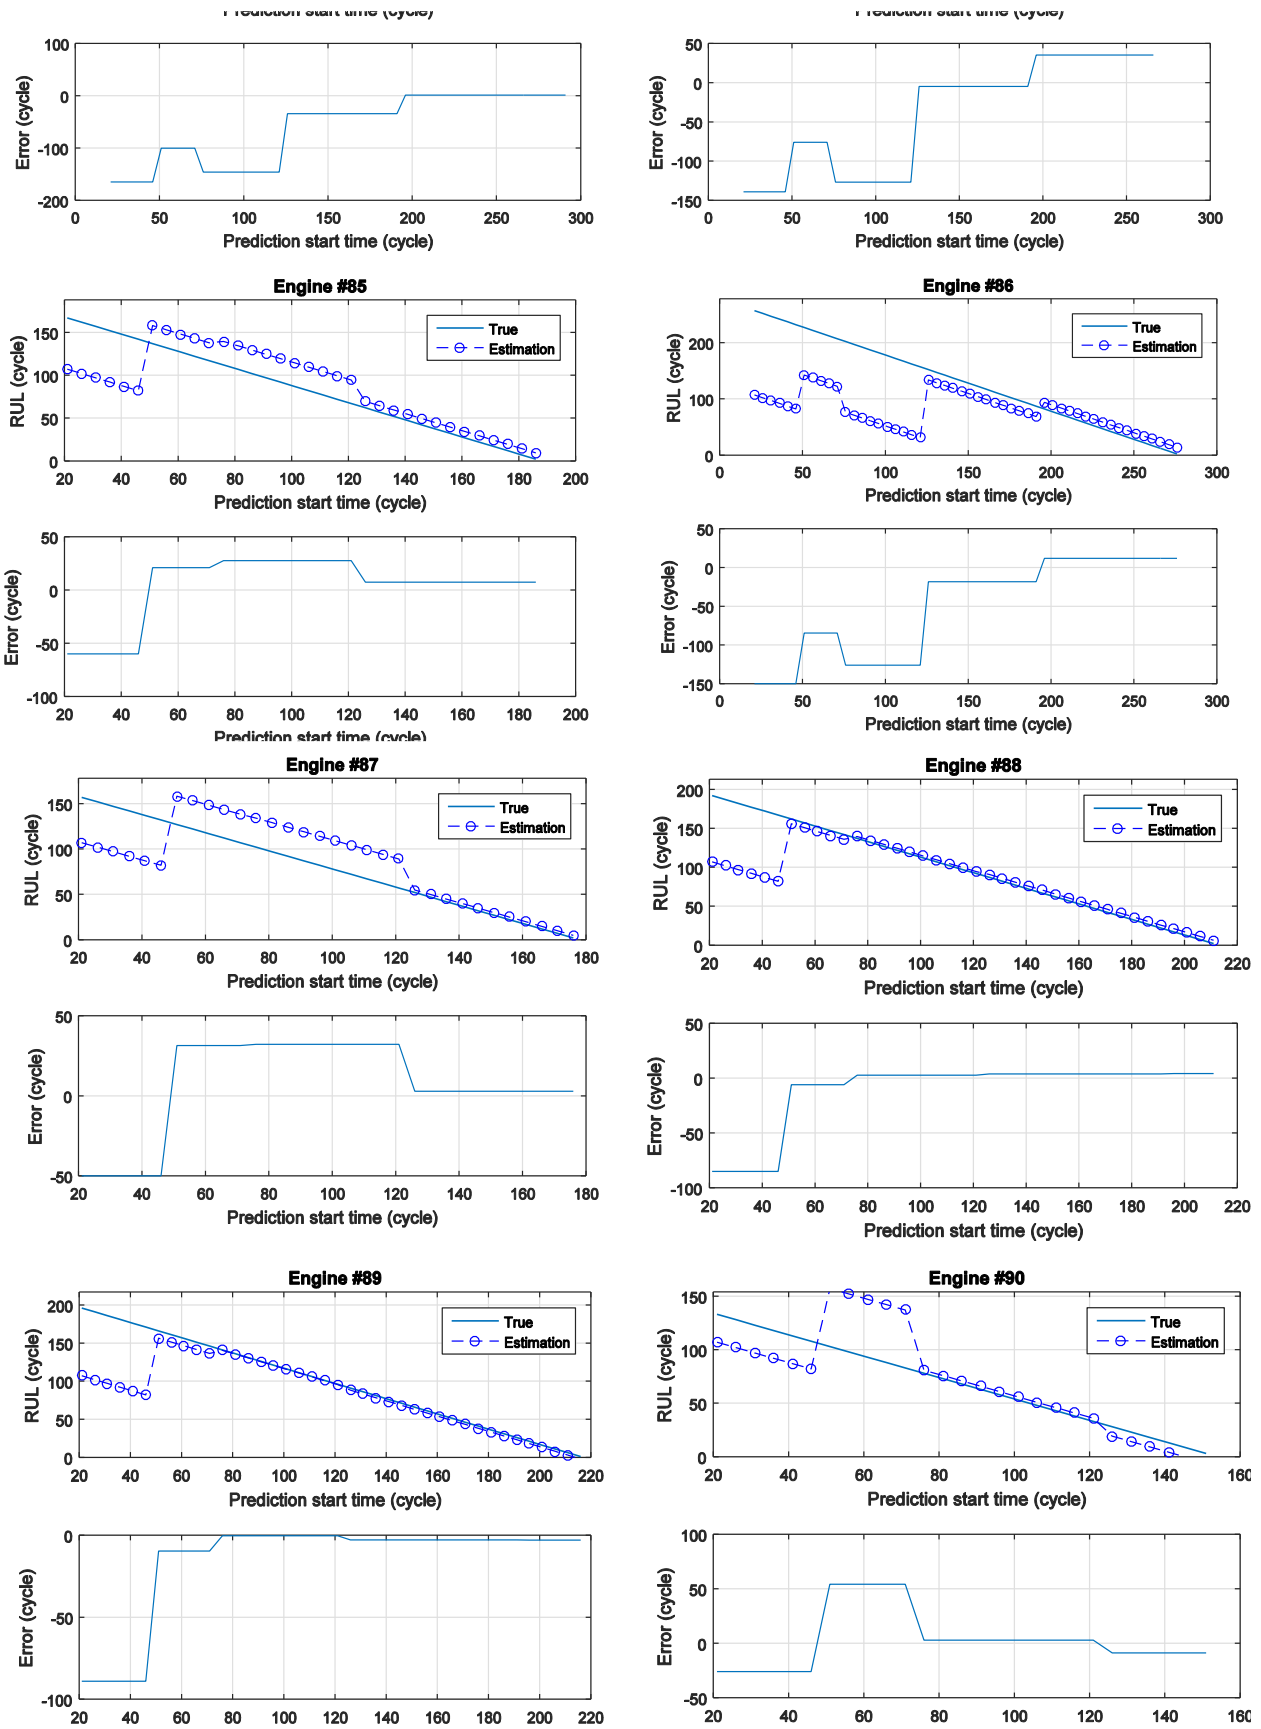


Fig. 7. Prognosis results of engines #81-96 in different cycles with limited train data set

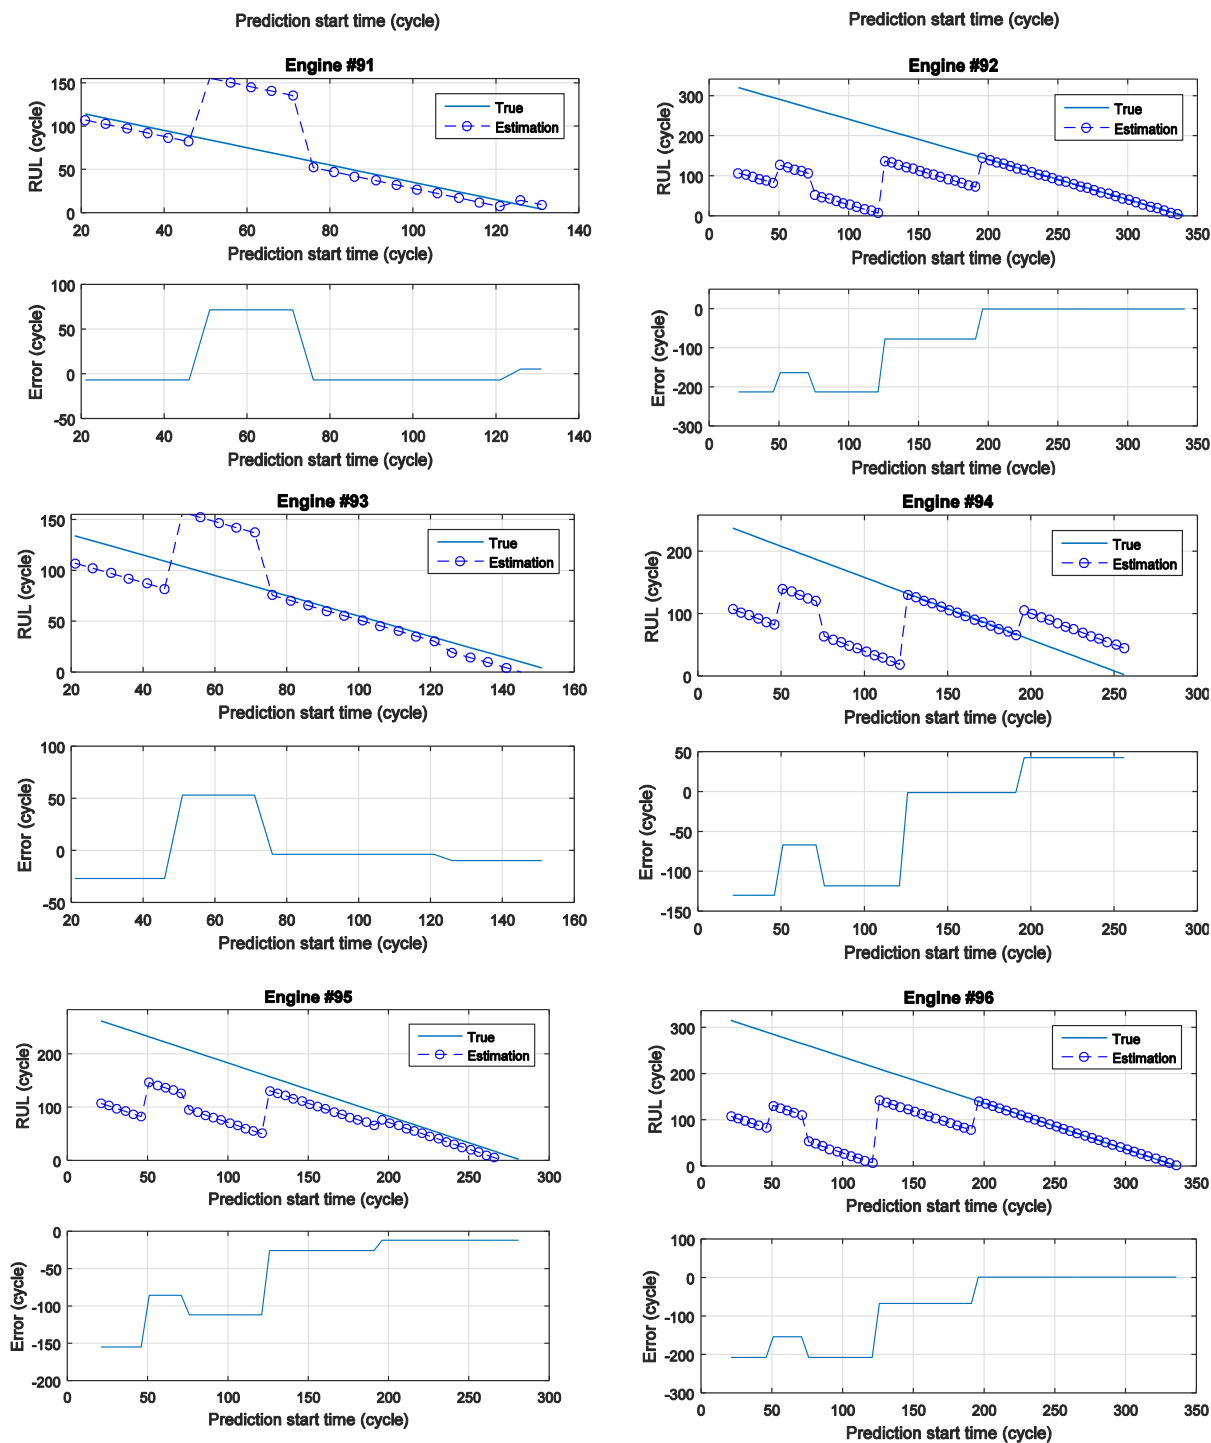
شکل ۷: نتایج پیش بینی عمر موتورهای شماره ۸۱-۹۶ در سیکل های مختلف با مجموعه داده های محدود آموزش



continued Fig. 7. Prognosis results of engines #81-96 in different cycles with limited train data set

ادامه شکل ۷: نتایج پیش‌بینی عمر موتورهای شماره ۸۱-۹۶ در سیکل‌های مختلف با مجموعه داده‌های محدود آموزش





continued Fig. 7. Prognosis results of engines #81-96 in different cycles with limited train data set  
ادامه شکل ۷: نتایج پیش‌بینی عمر موتورهای شماره ۸۱-۹۶ در سیکل‌های مختلف با مجموعه داده‌های محدود آموزش

برای ارجاع به این مقاله از عبارت زیر استفاده کنید:

A. Mahmoodian, M. Durali, M. Saadat, Age-Based Clustering Prognostics of Gas Turbines and Evaluation of the Proposed Method Robustness in Data Deficient Conditions, Amirkabir J. Mech. Eng., 53(2) (2021) 777-798.

DOI: [10.22060/mej.2019.16574.6398](https://doi.org/10.22060/mej.2019.16574.6398)



