



A Model to Determining the State of Degradation and Remaining Useful Life of Rotating Equipment, With a New Approach to Combination and Predicting Health Index

ARTICLE INFO

Article Type

Original Research

Authors

Ramezani S.¹ PhD,

Moini A.*¹ PhD,

Riahi M.² PhD

How to cite this article

Ramezani S, Moini A, Riahi M. A Model to Determining the State of Degradation and Remaining Useful Life of Rotating Equipment, With a New Approach to Combination and Predicting Health Index. Modares Mechanical Engineering, 2019; 19(10): 2351-2365.

¹School of Industrial Engineering, Iran University of Science and Technology, Tehran, Iran

²School of Mechanical Engineering, Iran University of Science and Technology, Tehran, Iran

*Correspondence

Address: School of Industrial Engineering, Iran University of Science and Technology, Narmak, Tehran, Iran

Phone: -

Fax: +98 (21) 73021214

moini@iust.ac.ir

Article History

Received: July 30, 2018

Accepted: February 13, 2019

ePublished: October 22, 2019

ABSTRACT

Condition assessment is one of the most significant techniques of equipment health, repairs, maintenance, and management. Prognostics and Health Management (PHM) methodology cycle is a developed form of Condition Based Maintenance (CBM). Condition assessment is the most important step of this cycle. In this study, based on the presented model, the Remaining Useful Life (RUL) is estimated using equipment condition assessment. Using the simulation and forecasting of a new feature for the vibration of the equipment (Kurtosis-Entropy) by Autoregressive Markov Regime Switching (AMRS) method, equipment health condition is determined. Prior to forecasting the condition of the equipment, the equipment degradation state is determined by the fuzzy C-means clustering method. Based on the current state of equipment and pre-determined state of degradation, the remaining useful life of the equipment is estimated. In order to evaluate the model, the experimental data from the FEMTO-ST Institute, which is provided to estimate the remaining useful life of the bearing, was used and the results of the study are compared with the rival models. The innovation of this paper is the use of fuzzy C-means, a new approach to evidence theory for data fusion, and the use of the Markov switching model for prediction.

Keywords Remaining Useful Life (RUL); Prognostics & Health Management (PHM); Autoregressive Markov Regime Switching (ARMRS); Health Index (HI); Theory of Evidence; Fuzzy clustering; Kurtosis-Entropy; Feature; Degradation

CITATION LINKS

[1] Prognostics and health management design ... [2] Model-based systems engineering: An emerging ... [3] A review on prognostic techniques for non ... [4] Practical options for selecting data-driven or physics ... [5] A review on signal processing techniques utilized ... [6] Data-driven prognostic method based on Bayesian ... [7] Degradation modeling based on a time-dependent ... [8] Bearing life prediction based on vibration... [9] Estimation of remaining useful life of. [10] Machinery prognostic method based on multi-class... [11] An adaptive method for health trend prediction ... [12] Condition assessment for the performance degradation of bearing ... [13] Machinery health ... [14] Bearing health ... [15] Estimation of ... [16] Degradation feature ... [17] Multifeatures fusion ... [18] Time series ... [19] An improved ... [20] Reliability estimation ... [21] A reliable ... [22] A new method ... [23] Bearing life prognosis ... [24] Remaining useful ... [25] Residual useful ... [26] An empirical investigation ... [27] Bearing remaining ... [28] Prediction of bearing ... [29] An integrated ... [30] Bearing fault ... [31] A recurrent neural ... [32] Accurate bearing ... [33] Bearing remaining ... [34] Enhanced restricted ... [35] Real-time remaining ... [36] Remaining useful ... [37] A model-based ... [38] An HMM and ... [39] Rolling element ... [40] A neural network ... [41] Extended Kalman ... [42] A two-stage data ... [43] Data-driven prognostics ... [44] Remaining useful life ... [45] Machine health ... [46] Condition based ... [47] Remaining useful ... [48] Novel failure ... [49]... An artificial neural ... [50] Features selection ... [51] Outliers in process ... [52] A moving-average filter ... [53] FCM: The fuzzy c-means ... [54] Novelty Detection in ... [55] Time series forecasting ... [56] Simple condition ... [57] Dependability of ... [58] A hybrid ARIMA-SVM ... [59] A hybrid of nonlinear ... [60] Data-driven hybrid remaining ... [61] Lithium-ion batteries ... [62] Rolling element bearing ... [63] The use of MD-CUMSUM ... [64] Application of empirical ... [65] Artificial neural network ... [66] An integrated unscented ... [67] Comparative study of ... [68] A novel switching unscented ... [69] Adaptive prognostics for rolling ... [70] A new approach to the economic ... [71] MS_Regress-the Matlab package for ... [72] A mathematical theory of ... [73] Combination of evidence in ... [74] PRONOSTIA: An experimental platform for

مدلی جهت تعیین وضعیت زوال تجهیزات دوار و تعیین عمر مفید باقی‌مانده، با رویکرد جدیدی به تلفیق و پیش‌بینی شاخص سلامت

سعید رضائی PhD

دانشکده مهندسی صنایع، دانشگاه علم و صنعت ایران، تهران، ایران

علیرضا معینی* PhD

دانشکده مهندسی صنایع، دانشگاه علم و صنعت ایران، تهران، ایران

محمد ریاحی PhD

دانشکده مهندسی مکانیک، دانشگاه علم و صنعت ایران، تهران، ایران

چکیده

پایش وضعیت یکی از مهم‌ترین تکنیک‌های مدیریت سلامت تجهیزات و نگهداری و تعمیرات (نگهداشت) مبتنی بر شرایط است. در چرخه متدلوژی مدیریت سلامت و پیش‌بینی عیوب (PHM) که به‌نوعی شکل توسعه‌یافته‌تری برای نگهداشت مبتنی بر شرایط (CBM) است، ارزیابی وضعیت به‌عنوان مهم‌ترین جزء این چرخه به‌شمار می‌آید. در این تحقیق مدلی ارائه شده است که مبتنی بر آن می‌توان با استفاده از ارزیابی وضعیت تجهیز، عمر مفید باقی‌مانده (RUL) تخمین زده شود. در این مدل با استفاده از تعریف یک شاخص سلامت جدید برای ارتعاش تجهیز (Kurtosis-Entropy)، شبیه‌سازی و پیش‌بینی آن با استفاده از مدل مارکوف رژیم سوئیچینگ خودرگرسیون، وضعیت سلامت تجهیز تعیین می‌شود. پیش از پیش‌بینی وضعیت تجهیز، مراحل زوال، با استفاده از خوشه‌بندی C- میانگین فازی تعیین شده است. مطابق با وضعیت فعلی تجهیز و وضعیت‌های از پیش تعیین‌شده زوال، عمر مفید باقی‌مانده تجهیز تخمین زده می‌شود. به‌منظور ارزیابی مدل از داده‌های آزمایشگاهی انیستیتوی FEMTO-ST که به‌منظور پیش‌بینی عمر مفید باقی‌مانده بی‌رینگ فراهم شده، استفاده و نتایج مطالعه با مدل‌های رقیب مقایسه شده است. نوآوری این مقاله استفاده توأم از خوشه‌بندی فازی رویکرد جدیدی به تئوری شواهد برای تلفیق داده‌ها و استفاده از مدل مارکوف رژیم سوئیچینگ، برای پیش‌بینی است.

کلیدواژه‌ها: عمر مفید باقی‌مانده، مدیریت سلامت و پیش‌بینی عیوب، مدل مارکوف رژیم سوئیچینگ خودرگرسیون، شاخص سلامت، تئوری شواهد، زوال

تاریخ دریافت: ۱۳۹۷/۵/۸

تاریخ پذیرش: ۱۳۹۷/۱۱/۲۴

*نویسنده مسئول: moini@iust.ac.ir

۱- مقدمه

مدیریت سلامت و پیش‌بینی عیوب (PHM) ترکیبی است از متدلوژی‌های شناخته‌شده نگهداشت (نگهداری و تعمیرات) و تکنیک‌های عیب‌یابی همچون نگهداشت پیشگیرانه (PM)، نگهداشت مبتنی بر قابلیت اطمینان (RCM) و به‌ویژه نگهداشت مبتنی بر شرایط (CBM) یا پیش وضعیت. پیش وضعیت عبارت است از استخراج داده و پردازش آن، به‌گونه‌ای که بر مبنای اطلاعات حاصله، تصمیمات مربوط به نگهداری و تعمیرات تجهیزات، اتخاذشده و در نتیجه از اقدامات غیرضروری نگهداشت جلوگیری شود^[1]. تکنیک‌های نگهداشت مبتنی بر شرایط می‌توانند ورودی مدل پیش‌آگهی در مدیریت سلامت و پیش‌بینی عیوب را فراهم کنند و تجزیه و تحلیل مکانیسم خرابی در مدیریت سلامت و پیش‌بینی عیوب (خوردگی، خستگی، بارگیری، و غیره) در مدیریت چرخه عمر محصول مؤثر است. به علت توانایی ارزیابی وضعیت سلامت و پیش‌بینی خرابی، حتی مدیریت سلامت و پیش‌بینی عیوب می‌تواند مبنای تکنیک‌های مدرن در زمینه نگهداری به‌شمار آید^[2].

به‌طور کلی، محققان سه روش متفاوت برای تعیین وضعیت

تخریب تجهیزات ارائه می‌دهند: داده‌محور، فیزیک خرابی و روش ترکیبی^[3]. در رویکرد داده‌محور، تجهیز به‌صورت یک جعبه سیاه تفسیر می‌شود که به‌طور مستقیم از اطلاعات جمع‌آوری شده (مانند ارتعاش، نویز، فشار و غیره) رفتار سیستم را بررسی می‌کند. این رویکرد، مبتنی بر این ایده است که تا زمانی که سیستم خراب نشده است، ویژگی‌های استخراج‌شده از داده تغییر نخواهد کرد. در این روش داده‌های پردازش‌شده به اطلاعات و مدل‌های مناسب رفتاری تبدیل شده و تحلیل می‌گردند. از آنجایی که این روش‌ها بر اساس روند داده‌ها است، در پیش‌بینی رفتار آینده تجهیزات، به‌ویژه مراحل پایانی عمر، قدرتمند عمل می‌کنند^[4].

تاکنون تحقیقات بسیاری بر اساس رویکردهای اشاره‌شده برای ارزیابی عمر مفید باقی‌مانده (RUL) انجام شده است. تنوع در هوش مصنوعی، یادگیری ماشین و روش‌های آماری برای تعیین زوال و پیش‌بینی مدت‌زمان باقی‌مانده تا خرابی، فرآیندهای مختلفی را برای محاسبه عمر مفید باقی‌مانده توسعه داده است؛ به‌عنوان مثال در مرجع^[1] برخی از انواع این روش‌ها با توجه به نوع تجهیزات (بلبرینگ، شفت، چرخ‌دنده‌ها، پمپ‌ها و جرقیل‌ها) مورد بررسی قرار گرفته است. مهم‌ترین بخش در ماشین‌آلات دوار، بلبرینگ است و ۴۵ تا ۵۰٪ از کارافتادگی‌های سیستم ناشی از خرابی بلبرینگ است^[5]. تمرکز ما در این مقاله بر پیش‌بینی عمر مفید باقی‌مانده بلبرینگ بر اساس رویکرد داده‌محور است.

با وجود مزیت‌های رویکرد داده‌محور، گاهی اطلاعات استخراج‌شده ممکن است گمراه‌کننده باشد و تصمیم‌گیری را مشکل سازد. به‌ویژه هنگامی که منابع مختلفی از اطلاعات (سنسورها) وجود دارد، چگونگی استفاده از اطلاعات به‌صورت جداگانه و در ترکیب با یکدیگر، با مشکلاتی روبروست^[6]. از سوی دیگر، نوسانات بالا و تغییر رژیم میانگین و واریانس معمولاً یکی از ویژگی‌های اطلاعاتی است که از سنسورهای مکانیکی به‌دست می‌آید^[7]. در این مقاله، ما بر این دو موضوع تمرکز داریم. برای انجام این کار، ما با استفاده از ترکیبی از اطلاعات سنسور، یک روش داده‌کاوی را برای تعیین وضعیت خرابی یا تاقان ارائه می‌دهیم. روش پیشنهادی بر اساس قوانین ترکیب دمپستر- شفر و خوشه‌بندی است. ما همچنین از روش مارکوف رژیم سوئیچینگ خودرگرسیون (Autoregressive Markov Regime Switching) برای مدل‌سازی تغییر رژیم در سری زمانی ویژگی غیرخطی استخراج‌شده استفاده می‌کنیم.

ساختار مقاله بدین‌صورت است: در بخش ۲، ادبیات مربوط به تعیین عمر باقی‌مانده برای بلبرینگ‌ها ارائه شده است. در بخش ۳، روش پیشنهادی شرح داده شده است. در بخش ۴، نتایج اجرای مدل برای داده‌های تجربی ارائه شده است و در بخش ۵ نتیجه‌گیری مقاله عنوان شده است.

۲- مرور ادبیات

در سال‌های اخیر پژوهش‌های بسیاری در خصوص تشخیص وضعیت سلامت و تعیین عمر مفید باقی‌مانده تجهیزات دوار و بالأخص بلبرینگ با استفاده از رویکرد داده‌محور صورت پذیرفته است. در این میان داده‌های ارتعاش بیشترین سهم را در تحلیل نگهداشت مبتنی بر شرایط و مدیریت سلامت و پیش‌بینی عیوب این تجهیزات داشته است. در این پژوهش نیز بر داده‌های ارتعاش سنسور تمرکز شده است و پژوهش‌های مرتبط با تجزیه و تحلیل وضعیت خرابی تجهیز و تعیین عمر مفید باقی‌مانده آن با استفاده از داده‌های ارتعاش بررسی شده است.

سوم، با تعیین شبیه‌ترین مجموعه داده یادگیری به مورد مطالعه و برقراری تناسب میان شاخص سلامت در وضعیت‌های زوال آن‌ها، RUL تخمین زده می‌شود [9, 15, 23, 34, 47].

یکی از موارد پیش رو در این مسائل، تلفیق اطلاعات به‌دست‌آمده، در شرایطی است که از سنسورهای مختلف برای ثبت اطلاعات و تعیین وضعیت زوال تجهیز استفاده می‌شود. عموماً ویژگی‌های انتخابی به‌صورت مجزا به‌عنوان متغیرهای توضیح‌دهنده مقادیر آتی خود و یا متغیر عمر مفید باقی‌مانده در مدل‌های پیش‌بینی در نظر گرفته شده‌اند [11, 13, 27, 30, 40].

در این مقاله ویژگی‌های استخراج‌شده از سنسورهای ارتعاش افقی و عمودی با استفاده از قواعد ترکیب تئوری دمپستر شفر و خوشه‌بندی ویژگی‌ها تلفیق می‌گردند و وضعیت زوال مشخص می‌گردد؛ به‌عبارت‌دیگر، هر یک از ویژگی‌های سنسورهای افقی و عمودی به‌عنوان شاهد یک احتمال را به خوشه‌های زوال نسبت می‌دهند و در نهایت با تلفیق این اطلاعات، وضعیت کنونی زوال را مشخص می‌نمایند. رویکرد پیشنهادی قابلیت استفاده در سایر سامانه‌ها که پایش آن‌ها مبتنی بر سنسورهای ارتعاش است را داراست. در چارچوب پیشنهادی این مقاله هر سه گام تعیین عمر مفید باقی‌مانده اعمال می‌گردد. در گام نخست، ویژگی جدید کرتسیس‌ای (KURTOSISE) با الهام از ویژگی آر.ام.اس-آنتروپی (RMS-Entropy) که در مقاله [32] ارائه شده است، معرفی می‌گردد و قابلیت آن برای پیش‌بینی مورد ارزیابی قرار می‌گیرد. سپس خوشه‌بندی C- میانگین فازی (Fuzzy C-Means) و تئوری دمپستر شفر برای تعیین وضعیت زوال تجهیز استفاده می‌شود و در نهایت با استفاده از مدل مارکوف رژیم سویچینگ خودرگرسیون که تاکنون قابلیت‌های آن در پیش‌بینی شاخص‌های سلامت مورد بررسی قرار نگرفته است، عمر مفید باقی‌مانده تخمین زده می‌شود. در بخش بعدی چارچوب روش پیشنهادی به‌طور مفصل تشریح می‌گردد.

۳- تشریح روش پیشنهادی

شکل ۱ چارچوب روش پیشنهادی برای تخمین عمر مفید باقی‌مانده تجهیز را نشان می‌دهد. مطابق با شکل ۱، فرآیند تخمین عمر مفید باقی‌مانده در دو فاز کلی صورت می‌پذیرد: فاز یادگیری و فاز تست.

۳-۱- فاز یادگیری

۳-۱-۱- تجزیه سیگنال

در نخستین گام تعیین شاخص سلامت، ابتدا نویز سیگنال‌های ارتعاشات توسط تبدیل گسسته موجک (DWT) حذف شده و سپس تجزیه شده است. در ادبیات تحقیق، استفاده از تقریب سوم (A3) تا پنجم (A5) موجک دوشبی ۴ (D4) برای تحلیل سیگنال ارتعاشات توصیه شده است [48]. در روش پیشنهادی حاضر از تقریب چهارم (A4) موجک D4 استفاده شده است. همچنین از آنجایی که در مرجع [48] از روش بیز با قانون آستانه‌گذاری پسینی میانه (Posterior Median Threshold Rule) برای مجموعه داده‌های مشترک با تحقیق حاضر، استفاده شده و عملکرد آن مورد تأیید واقع شده است، ما نیز از این روش استفاده کرده‌ایم.

۳-۱-۲- استخراج ویژگی

در گام دوم تعیین شاخص سلامت، ویژگی‌هایی از ارتعاشات استخراج می‌گردد که بتوانند وضعیت زوال تجهیز را به‌خوبی نشان دهند. دو ویژگی جذر میانگین مربعات و کشیدگی بیشترین استفاده را برای تحلیل سیگنال‌های ارتعاش دارند [49]. یکی از

به‌طور کلی، در رویکرد داده‌محور فرآیند تعیین عمر مفید باقی‌مانده در ۳ گام صورت می‌پذیرد:
گام اول: تعیین یک شاخص سلامت برای ردیابی وضعیت سلامت تجهیز

گام دوم: تعیین وضعیت زوال

گام سوم: تخمین عمر مفید باقی‌مانده با استفاده از روش‌های پیش‌بینی، شاخص سلامت و مدت زمان تا خرابی

غالباً پژوهشگران مطابق با این سه گام، تحقیقات خود را صورت‌بندی می‌نمایند. در برخی از پژوهش‌ها [8-15] چارچوب‌هایی ارائه شده است که در آن هر سه گام تحلیل برای تعیین عمر مفید باقی‌مانده مورد بررسی قرار گرفته‌اند درحالی که در برخی تنها یکی از گام‌ها کانون توجه بوده است. به‌عنوان مثال در منابع [16, 17] تنها روش‌هایی برای تعیین یک شاخص سلامت مناسب ارائه شده است. در گام نخست رویکرد داده‌محور، پژوهشگران به دنبال تعیین شاخصی می‌باشند که وضعیت سلامت تجهیز را نمایندگی نماید تا با ردیابی آن بتوانند مرحله زوال را تشخیص دهند و با پیش‌بینی آن مدت زمان باقی‌مانده تا خرابی کامل تجهیز را تخمین بزنند. عموماً این گام شامل دو مرحله استخراج ویژگی و انتخاب ویژگی می‌گردد. در برخی مقالات از ویژگی‌های کلاسیک حوزه زمان نظیر میانگین، انحراف استاندارد، کشیدگی (Kurtosis)، جذر میانگین مربعات (RMS) و غیره [9, 10, 13, 6, 18-27] حوزه فرکانس نظیر حداکثر دامنه فرکانس [28] یا حوزه فرکانس- زمان نظیر ویژگی‌های تبدیل ویولت [29] استفاده شده است درحالی که در برخی پژوهش‌های دیگر [8, 30-35] ویژگی‌های جدیدی پیشنهاد شده است. همچنین در برخی از پژوهش‌ها به دلیل افزایش امکان تفکیک و خوشه‌بندی داده‌ها و کاهش پیچیدگی‌های محاسباتی از روش‌های انتخاب ویژگی و کاهش ابعاد نظیر تحلیل همبستگی، تجزیه و تحلیل مؤلفه اصلی (PCA)، ایزوما (ISOMA) و سایر روش‌های نوین‌تر در پژوهش‌ها [9, 17, 18, 20, 21, 26, 27, 34, 36, 37] استفاده شده است. در گام دوم رویکرد داده‌محور، وضعیت زوال تجهیز با استفاده از موقعیت فعلی شاخص سلامت (Health Index; HI) و اطلاعات به‌دست‌آمده از مجموعه داده‌های از پیش ثبت‌شده (مجموعه داده‌های یادگیری) مشخص می‌گردد. از آنجایی که اطلاعات پیشینی درباره مرز دقیق وضعیت‌های زوال وجود ندارد معمولاً از روش‌های یادگیری نظارت‌نشده مانند خوشه‌بندی با در نظر گرفتن تعداد خوشه‌های دلخواه که بیانگر وضعیت‌های زوال است استفاده می‌گردد [11-15, 38, 39]. در برخی دیگر از پژوهش‌ها [9, 10] تغییرات پیک فرکانس و در برخی دیگر مانند مرجع [8] وقوع عدم انطباق در شاخص سلامت به‌عنوان علامتی برای تغییر وضعیت زوال در نظر گرفته شده است. در گام سوم، عمر مفید باقی‌مانده با استفاده از سه رویکرد متفاوت به پیش‌بینی و معمولاً با برآزش یک مدل آماری و یا آموزش یک پیش‌بینی‌کننده هوشمند بر اساس مجموعه داده‌های یادگیری موجود برای برآزش یا آموزش مدل، تخمین زده می‌شود. در رویکرد نخست، متغیری که پیش‌بینی می‌شود، شاخص سلامت است. در این حالت، افق زمانی پیش‌بینی تا یک آستانه از پیش تعیین‌شده در نظر گرفته می‌شود و مدت زمان تا رسیدن شاخص به آستانه، به‌عنوان عمر مفید باقی‌مانده تعیین می‌گردد [8, 12, 22, 24, 30, 37, 40-42]. در رویکرد دوم، برآزش یا آموزش مدل با در نظر گرفتن متغیر مدت زمان تا خرابی (Run to Failure) به‌عنوان متغیر وابسته یا هدف انجام می‌پذیرد و نتیجه پیش‌بینی مستقیماً تخمین از عمر مفید نظیر پژوهش‌های [9-11, 13, 14, 21, 33, 36, 43-46] باقی‌مانده است. در رویکرد

از کشیدگی به جای جذر میانگین مربعات نزدیک‌تری بودن مقیاس این ویژگی برای نمونه‌های مختلف (به‌عنوان مثال بیرینگ‌های مختلف) است و به‌صورت رابطه ۲ تعریف می‌گردد:

$$KURTOSISE = \frac{1}{n} \sum_{i=1}^n Kurtosis(i) \log(Kurtosis(i)) \quad (2)$$

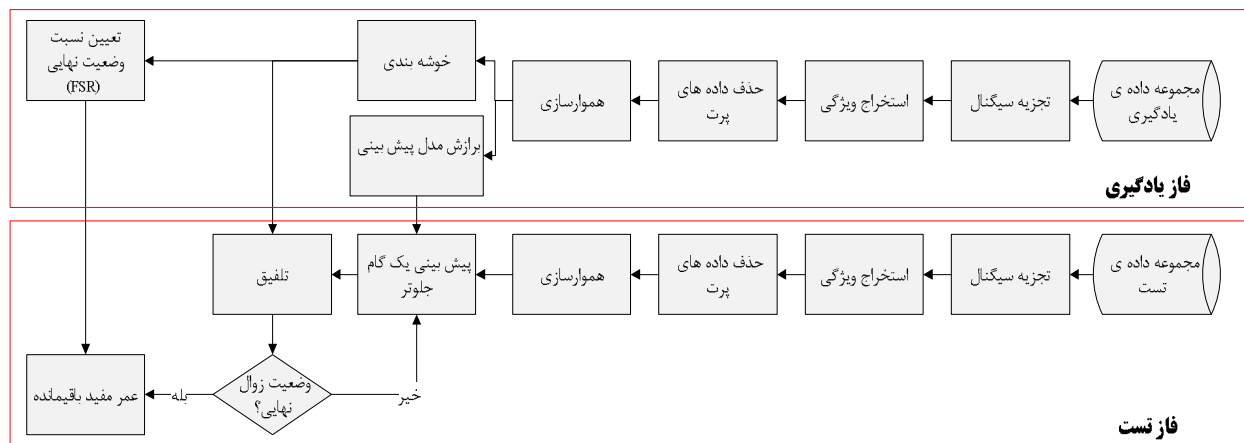
به‌طوری که n طول پنجره زمانی متحرک است که در اینجا ۱۰ در نظر گرفته شده است.

دو معیار اصلی برای یک پیش‌بینی موفق یک سری زمانی، روندپذیری (Trendability) و یکنواختی (Monotonicity) است [50]. با مقایسه دو ویژگی آر.ام.اس- آنتروپی و کرتسیس‌ای بر اساس این دو معیار، کرتسیس‌ای عملکرد بهتری را از خود نشان داده است. جزییات این بررسی در پیوست ارائه شده است.

نواقص این دو ویژگی، بالأخص به‌منظور تخمین عمر مفید باقی‌مانده، رفتار نوسانی شدید آن‌ها اندکی پیش از خرابی کامل است. برای مواجهه با این مسئله، پژوهشی [32] ویژگی آر.ام.اس- آنتروپی را برای مواجهه با این موضوع پیشنهاد نموده‌اند (رابطه ۱):

$$RMS - Entropy = \frac{1}{n} \sum_{i=1}^n -RMS(i) \log(RMS(i)) \quad (1)$$

این ویژگی نوسانات شدید در آستانه خرابی کامل بیرینگ را روندپذیرتر می‌کند و همچنین افت ناگهانی ویژگی جذر میانگین مربعات را وقتی که خرابی به نهایت پیشرفت خود می‌رسد از بین می‌برد. در این تحقیق از ویژگی جدید پیشنهادی کرتسیس‌ای به‌منظور مدل نمودن روند زوال استفاده شده است. مزیت استفاده



شکل ۱) چارچوب روش پیشنهادی تحقیق

احتمال تعلق به هر یک از خوشه‌ها تعیین می‌گردد. این احتمال با در نظر گرفتن نزدیکی به مراکز خوشه‌ها به دست می‌آید. در اینجا ما از الگوریتم مبتنی بر مرکز C- میانگین فازی استفاده نموده‌ایم (جزئیات فرآیند تلفیق در بخش ۳-۲-۲ ارائه شده است). C- میانگین فازی، یکی از روش‌های خوشه‌بندی است که به هر داده اجازه می‌دهد تا به چندین خوشه با درجات عضویت مختلف تعلق داشته باشد. این روش بر اساس حداقل نمودن تابع هدف رابطه ۴ صورت می‌پذیرد [53]:

$$J_m = \sum_{i=1}^D \sum_{j=1}^N \mu_{ij}^m \|x_i - c_j\|^2 \quad (4)$$

به‌طوری که D تعداد داده‌ها، N تعداد خوشه‌ها، m توان ماتریس فازی جزئی برای کنترل درجه همپوشانی فازی ($m > 1$), x_i , c_j مرکز C امین خوشه و μ_{ij} درجه عضویت x_i در C امین خوشه است. برای یک داده معین x_i , مجموع مقادیر عضویت برای همه خوشه‌ها یک است. C- میانگین فازی گام‌های زیر را طی خوشه‌بندی انجام می‌دهد:

مقادیر عضویت خوشه μ_{ij} اولیه را به‌صورت تصادفی تخصیص می‌دهد. مراکز خوشه با استفاده از فرمول ۵ محاسبه می‌گردد:

$$c_j = \frac{\sum_{i=1}^D \mu_{ij}^m x_i}{\sum_{i=1}^D \mu_{ij}^m} \quad (5)$$

μ_{ij} مطابق با فرمول ۶ آپدیت می‌گردد.

$$\mu_{ij} = \frac{1}{\sum_{k=1}^N \left(\frac{\|x_i - c_j\|}{\|x_i - c_k\|} \right)^{\frac{2}{m-1}}} \quad (6)$$

تابع هدف J_m محاسبه می‌گردد. این فرآیند تا زمانی که J_m از یک

۳-۱-۳ حذف داده‌های پرت و هموارسازی

در گام نهایی تعیین شاخص سلامت، پس از استخراج ویژگی، از فیلتر همپل (Hampel) و فیلتر میانگین متحرک به ترتیب برای حذف داده‌های پرت و هموار نمودن مسیر ویژگی استفاده شده است. فیلتر همپل داده‌های پرت را شناسایی و حذف می‌کند. این فیلتر برای هر نمونه سری زمانی، میانه کل نمونه و میانه شش داده اطراف هر داده (سه داده در هر طرف) را محاسبه می‌کند. همچنین انحراف استاندارد هر نمونه با استفاده از انحراف مطلق از میانه محاسبه می‌گردد. اگر اختلاف میان یک نمونه تا میانه اطراف آن، بیش از سه انحراف معیار باشد، با آن میانه جایگزین خواهد شد [51]. فیلتر میانگین متحرک (رابطه ۳)، داده‌ها را با جایگزین کردن هر داده با متوسط داده‌های مجاورش که محدوده این داده‌های مجاور از پیش تعیین می‌گردد، هموار می‌نماید [52]:

$$y_s(i) = \frac{1}{2N+1} (y(i+N) + y(i+N-1) + \dots + y(i-N))$$

به‌طوری که $y_s(i)$ مقدار هموار شده i امین داده، N ، تعداد داده‌های مجاور در هر سمت $y(i)$ و $2N+1$ محدوده در نظر گرفته شده است.

۳-۱-۴ خوشه‌بندی

برای تعیین وضعیت زوال، شاخص سلامت، خوشه‌بندی می‌گردد. هر خوشه، نشان‌دهنده یکی از وضعیت‌های زوال است. حد پایین خوشه نهایی، با بالاترین مقدار شاخص سلامت، نشان‌دهنده خرابی کامل و به‌عنوان آستانه پیش‌بینی در نظر گرفته می‌شود. در روش پیشنهادی این مقاله، ترکیب داده‌ها برای تعیین وضعیت زوال با

واریانس $\sigma_{S_t}^2$ پیروی می‌کند. این ساده‌ترین حالت یک مدل با یک دینامیک تغییر است. در این فرآیند توانایی تغییر رژیم در عرض از مبدا μ و واریانس σ^2 با توجه به متغیر نشانگر S_t وجود دارد. این بدین معناست که اگر k رژیم داشته باشیم، k مقدار برای μ و σ^2 وجود خواهد داشت. حال فرض می‌کنیم که مدل λ دارای دو رژیم $(k = 2)$ است. یک راه برای نمایش این حالت به صورت زیر است:

$$y_t = \mu_1 + \epsilon_t \text{ for regime 1} \quad (9)$$

$$y_t = \mu_2 + \epsilon_t \text{ for regime 2} \quad (10)$$

به طوری که:

$$\epsilon_t \sim (0, \sigma_1^2) \text{ for regime 1} \quad (11)$$

$$\epsilon_t \sim (0, \sigma_2^2) \text{ for regime 2} \quad (12)$$

این شیوه نوشتن، به خوبی دو فرآیند برای متغیر وابسته y_t را تصریح می‌نماید. نوسانات مختلف (σ_1^2 و σ_2^2) در هر رژیم، عدم قطعیت بالاتری را با توجه به توان پیش‌بینی مدل در هر رژیم نشان می‌دهد. در مدل مارکوف رژیم سوئیچینگ، انتقال رژیم‌ها تصادفی است (و نه قطعی). این بدین معناست که هیچ گاه اطمینانی در خصوص اینکه آیا تغییر رژیم صورت می‌گیرد یا خیر وجود ندارد؛ اما دینامیک موجود در یک فرآیند سوئیچینگ توسط یک ماتریس انتقال مشخص می‌گردد. این ماتریس احتمالات رویداد یک تغییر را از یک رژیم به رژیم دیگر کنترل می‌کند و به صورت زیر نمایش داده می‌شود:

$$p = \begin{bmatrix} p_{11} & \dots & p_{1k} \\ \vdots & \ddots & \vdots \\ p_{k1} & \dots & p_{kk} \end{bmatrix} \quad (13)$$

در رابطه بالا، عناصر سطر i و ستون j احتمال تغییر از رژیم i به رژیم j را کنترل می‌کند. برای مثال، فرض کنید که برای مدت زمانی، رژیم ۲ برقرار باشد. این بدین معناست که احتمال تغییر رژیم از رژیم ۲ به ۱ بین زمان t و $t + 1$ با p_{12} مشخص می‌گردد. بعلاوه، احتمال ماندن در رژیم ۲ با p_{22} تعیین می‌گردد. فرآیند تصادفی بودن تغییر رژیم یکی از نقاط کلیدی ساختار مدل مارکوف رژیم سوئیچینگ است.

یک مدل کلی مارکوف سوئیچینگ می‌تواند با دو روش مختلف تخمین زده شود: حداکثر درست‌نمایی یا استنباط بی‌زی. در این تحقیق ما از روش حداکثر درست‌نمایی برای تخمین پارامترهای مدل استفاده کرده‌ایم که با ساختار نرم‌افزارهای برنامه‌نویسی نیز منطبق‌تر است. مدل تغییر رژیم زیر را فرض کنید:

$$\begin{aligned} y_t &= \mu_{S_t} + \epsilon_t \\ \epsilon_t &\sim N(0, \sigma_{S_t}^2) \\ S_t &= 1, 2 \end{aligned} \quad (14)$$

لگاریتم درست‌نمایی مدل به صورت زیر تعیین می‌گردد:

$$\ln L = \sum_{t=1}^T \ln \left(\frac{1}{\sqrt{2\pi\sigma_{S_t}^2}} \exp \left(-\frac{y_t - \mu_{S_t}}{2\sigma_{S_t}^2} \right) \right) \quad (15)$$

اگر تمام رژیم‌های دنیا شناخته شده باشد، آنگاه مقدار S_t نیز در دسترس خواهد بود و تخمین مدل توسط حداکثر درست‌نمایی نیز آسان است. تنها نیاز به حداکثر کردن رابطه ۱۵ به عنوان تابعی از پارامترهای μ_1, μ_2, σ_1^2 و σ_2^2 وجود دارد اما می‌دانیم که این رژیم‌ها برای ما ناشناخته است. تابع $f(y_t | S_t = j, \theta)$ را به عنوان

مقدار مشخص آستانه کوچکتر گردد و یا تا حداکثر تعداد مشخصی از تکرار، تکرار می‌گردد.

۳-۱-۵- پرازش مدل پیش‌بینی

همان طور که در بخش ۲ اشاره گردید، به طور کلی دو رویکرد برای پیش‌بینی وجود دارد. در اینجا ما از رویکرد نخست استفاده می‌کنیم.

در سال‌های اخیر، پیشرفت‌های مهمی در زمینه مدل‌سازی ساختارهای غیرخطی سری‌های زمانی مشاهده می‌گردد و بهبودهای قابل توجهی روی روش‌های کلاسیک مدل‌سازی خطی و غیرخطی صورت پذیرفته است [54]. مثال‌هایی از این ساختارهای غیرخطی و غیرایستا عبارت‌اند از انتشار صدای ماشین‌آلات تولیدی، تقاضای مشتری و نرخ‌های تولیدی در یک شرکت تولیدی، بار انرژی الکتریکی در یک شبکه هوشمند، ترافیک در نودهای (تقاطع‌های) حمل‌ونقل و شبکه‌های ارتباطی، قیمت موجودی و سایر شاخص‌های بازار، سیگنال‌های نوار مغزی و نوار قلبی، و دما و سایر سیگنال‌های آب و هوایی [55]. برخی از مدل‌های کلاسیک پیش‌بینی استفاده شده در مدیریت سلامت و پیش‌بینی عیوب شامل هموارسازی نمایی [56] و مدل‌های خودرگرسیون [57-61] است. مدل‌های غیرخطی که توسط محققان در این زمینه استفاده شده شامل شبکه‌های عصبی و شبکه‌های عصبی ژرف [55, 62-65]، بسط فیلتر کالمن [41, 66, 67] و مدل‌های رژیم سوئیچینگ [68, 69] است. در روش پیشنهادی این تحقیق، از مدل مارکوف رژیم سوئیچینگ خودرگرسیون برای پیش‌بینی شاخص سلامت استفاده شده است. این مدل نخستین بار توسط همیلتون [70] ارائه گردید و یکی از معروف‌ترین مدل‌های غیرخطی سری‌های زمانی است. از کاربردهای اصلی این روش تاکنون می‌توان به پرازش تغییرات بازده و نوسانات شاخص‌های اقتصادی به دلیل تغییرات سیاست‌های پولی، شوک‌های اقتصادی نظیر بلایای طبیعی، جنگ، تحریم و غیره اشاره نمود. دلیل استفاده از این روش در این تحقیق، قابلیت آن برای تبیین تغییرات رژیم میانگین و نوسان ویژگی‌های مسئله است. به طور کلی، تغییر رژیم در مسیر ویژگی به دلیل پیشرفت فرآیند زوال تجهیز و وقوع خرابی‌هایی نظیر ترک، خوردگی، فرسایش و سایر حالت‌های خرابی بر سطوح مختلف آن است.

در روش مارکوف رژیم سوئیچینگ، رویدادها به k رویداد تقسیم می‌شوند که S_t رویداد t ام و $(t = 1, 2, \dots, k)$ است. در اینجا هر واقعه می‌تواند بیانگر یک تغییر رژیم باشد. همچنین که S_t می‌تواند واقعه‌ای باشد که در زمان t رخ داده است و منجر به تغییر متغیر مورد نظر (مثلاً Y_t) در زمان t شود. به عبارت دیگر فرض می‌شود که Y_t همراه با تغییر متغیر غیرقابل مشاهده S_t تغییر جهت می‌دهد. بنابراین می‌توان نوشت [71]:

$$P(Y_t | Y_1, Y_2, \dots, Y_{t-1}) = P(Y_t | Y_{t-1}) \quad (16)$$

معادله ۱۶ بیان می‌کند که توزیع احتمال Y در هر زمانی مانند t ، فقط بستگی به وضعیت آن در زمان $t - 1$ دارد، لذا در فرآیندهای مارکوف، وابستگی مسیر برای متغیرها قابل تصور نیست. قوت این مدل در انعطاف‌پذیری است که امکان در نظر گرفتن تغییرات واریانس بین فرآیندها را همراه با تغییر در میانگین فراهم می‌سازد.

فرآیند λ را در نظر بگیرید:

$$y_t = \mu_{S_t} + \epsilon_t \quad (17)$$

به طوری که $S_t = 1, \dots, k$ و ϵ_t از توزیع نرمال با میانگین صفر و

$$\epsilon_t \sim P(\Phi_{S_t})$$

(۲۳)

این شکل از ارائه مدل مارکوف رژیم سویچینگ تنوع گسترده‌ای از حالت‌های مختلف را شامل می‌گردد. مقادیر N_{NS_a} و N_{NS_e} تعداد ضرایب بدون تغییر رژیم را برای متغیرهای بیرونی و خودرگرسیون نشان می‌دهد. همچنین N_{S_a} و N_{S_e} همین تعداد را برای ضرایب با قابلیت تغییر رژیم نشان می‌دهد. همچنین متغیر $x_{i,t}^{NS_e}$ شامل همه متغیرهای بیرونی بدون اثر تغییر رژیم و $y_{t-j}^{NS_a}$ شامل همه متغیرهای خودرگرسیون بدون تغییر رژیم را نشان می‌دهد. به همین ترتیب، $x_{k,t}^{S_e}$ و $y_{t-z}^{S_a}$ همین متغیرها را با قابلیت تغییر رژیم نشان می‌دهد. $\beta_i, \alpha_j, \gamma_k, \eta_z$ هم ضرایب متغیرهای توضیحی می‌باشند. عبارت $P(\Phi_{S_t})$ نیز تابع چگالی احتمال مفروض جملات خطا است. در این تحقیق به منظور شبیه‌سازی و پیش‌بینی روند ویژگی‌های سیگنال‌ها از مدل مارکوف رژیم سویچینگ خودرگرسیون بدون متغیرهای بیرونی استفاده شده است. قابلیت تغییر رژیم برای متغیرهای خودرگرسیون و همچنین واریانس مدل نیز در نظر گرفته شده است.

از آنجایی که داده‌های یادگیری موجود برای پیش‌بینی روند آتی ویژگی‌های تست، داده‌های یادگیری است، لذا می‌توان برای تعیین وقفه مدل مارکوف رژیم سویچینگ برای ویژگی‌های تست از وقفه انتخابی برای ویژگی‌های یادگیری استفاده نمود. بدین منظور تخمین مدل مارکوف رژیم سویچینگ با در نظر گرفتن دو رژیم، برای هر یک از ویژگی‌های استخراجی از قطعات یادگیری (که در مطالعه موردی این تحقیق بیرینگ است) تا ۳ وقفه صورت پذیرفته است. سپس با استفاده از معیار اطلاعات بیزی (BIC)، مناسب‌ترین وقفه انتخاب شده است. وقفه انتخابی، وقفه‌ای است که کمترین مقدار معیار اطلاعات بیزی را داراست.

۳-۶- تعیین نسبت وضعیت نهایی

غالباً شاخص سلامت با گذشت زمان دچار تغییر رفتار می‌گردد. این تغییر رفتار در نوسان‌های شدید شاخص سلامت آشکار می‌گردد و معمولاً نشان‌دهنده نزدیک شدن به زمان خرابی کامل تجهیز است. به همین دلیل، پیش‌بینی بر اساس مدل‌های خودرگرسیون ممکن است در وضعیت نهایی دقیق نباشد. برای حل این مشکل، از رابطه بین خوشه نهایی و زمان اجرا تا خرابی استفاده می‌کنیم که ما آن را نسبت وضعیت نهایی (Final State Ratio; FSR) می‌نامیم. ایده استفاده از نسبت‌های وضعیت برای پیش‌بینی، پیش‌تر در پژوهشی^[9] استفاده شده است. با فرض تکرار الگوی وضعیت‌های زوال در داده‌های از پیش ثبت شده (داده‌های یادگیری) برای آینده، نسبت وضعیت نهایی به صورت زیر تعریف می‌گردد:

$$FSR = \frac{t_{End} - t_{FS}}{t_{End}} \quad (24)$$

به طوری که t_{End} زمان اجرا تا خرابی و t_{FS} زمان ورود به خوشه آخر است (شکل ۲). در فاز یادگیری، نسبت وضعیت نهایی برای هر بلبرینگ محاسبه می‌گردد و برای پیش‌بینی مدت زمان خوشه نهایی استفاده می‌گردد (جزئیات این فرآیند در بخش ۳-۳ ارائه شده است).

۳-۲- فاز تست

در مرحله تست، عمر مفید باقی‌مانده برای هر یک از بلبرینگ‌ها محاسبه می‌شود. بدین منظور، شاخص سلامت، مشابه با فاز یادگیری برای بلبرینگ محاسبه می‌گردد و سپس وضعیت زوال با پیش‌بینی شاخص سلامت به دست آمده از ارتعاش سنسور افقی و

تابع درست‌نمایی برای رژیم j ، مشروط بر مجموعه‌ای از پارامترهای (θ) مفروض بگیرد. آنگاه تابع درست‌نمایی کامل برای مدل به صورت رابطه ۱۶ تعیین می‌گردد:

$$\ln L = \sum_{t=1}^T \ln \sum_{j=1}^2 (f(y_t | S_t = j, \theta) Pr(S_t = j)) \quad (16)$$

که در واقع میانگین موزون تابع درست‌نمایی در هر رژیم است، به طوری که در هر رژیم این وزن توسط احتمالات رژیم مشخص می‌گردد. وقتی این احتمالات قابل مشاهده نیست، ما نمی‌توانیم به صورت مستقیم از رابطه (۱۶) استفاده نماییم اما می‌توانیم استنباطی از آن بر اساس اطلاعات موجود داشته باشیم. این موضوع ایده اصلی فیلتر همیلتون است که برای محاسبه احتمال‌های فیلترشده برای هر رژیم بر اساس کسب اطلاعات جدید شکل می‌گیرد.

فرض کنید ψ_{t-1} ، ماتریس اطلاعات موجود در زمان $t-1$ است. با استفاده از فیلتر همیلتون، تخمین‌های $Pr(S_t = j)$ با استفاده از الگوریتم تکرارشونده زیر قابل دسترس خواهد بود:

گام ۱: یک حدس برای احتمال‌های آغازین $(t=0)$ هر رژیم $Pr(S_0 = j)$ برای $j=1,2$ بزنید. در این حالت می‌توان از حدس خامی نظیر $Pr(S_0 = j) = 0.5$ یا از احتمالات غیرشرطی S_t استفاده نمود یعنی:

$$Pr(S_0 = 1 | \psi_0) = \frac{1-p_{11}}{2-p_{11}-p_{12}} \quad (17)$$

$$Pr(S_0 = 2 | \psi_0) = \frac{1-p_{22}}{2-p_{22}-p_{11}} \quad (18)$$

گام ۲: $t=1$ قرار دهید و احتمالات هر رژیم را با توجه به اطلاعات تا زمان $t-1$ محاسبه کنید:

$$Pr(S_t = j | \psi_{t-1}) = \sum_{i=1}^2 p_{ji} (Pr(S_{t-1} = i | \psi_{t-1})) \quad (19)$$

به طوری که p_{ji} احتمالات انتقال زنجیره مارکوف می‌باشد.

گام ۳: احتمال هر رژیم را با اطلاعات جدید از زمان t آپدیت کنید. این کار با استفاده از پارامترهای مدل در هر رژیم که در اینجا $\mu_1, \sigma_1^2, \mu_2, \sigma_2^2$ و احتمالات انتقال p_{11} و p_{22} برای محاسبه تابع درست‌نمایی در هر رژیم برای زمان t است، صورت می‌پذیرد. سپس از فرمول زیر برای آپدیت احتمال هر رژیم با توجه به اطلاعات جدید استفاده کنید:

$$Pr(S_t = j | \psi_t) = \frac{f(y_t | S_t = j, \psi_{t-1}) Pr(S_t = j | \psi_{t-1})}{\sum_{j=1}^2 f(y_t | S_t = j, \psi_{t-1}) Pr(S_t = j | \psi_{t-1})} \quad (20)$$

$t = t + 1$ قرار دهید و گام‌های ۲-۳ را تکرار کنید تا $t = T$. در این حالت عملیات روی همه مشاهدات نمونه صورت گرفته است. در این حالت مجموعه‌ای از احتمالات فیلترشده برای هر رژیم از $t = T$ تا $t = 1$ به دست می‌آید.

گام‌های اشاره شده احتمالاتی را که برای محاسبه لگاریتم درست‌نمایی مدل که به عنوان تابعی از مجموعه پارامترها وجود دارد فراهم می‌نماید:

$$\ln L = \sum_{t=1}^T \ln \sum_{j=1}^2 (f(y_t | S_t = j, \theta) Pr(S_t = j)) \quad (21)$$

تخمین مدل با یافتن مجموعه‌ای از پارامترهایی که رابطه ۲۱ را حداکثر می‌نماید به دست می‌آید.

یک مدل مارکوف رژیم سویچینگ را می‌توان در حالت کلی به همراه متغیرهای بیرونی و خودرگرسیون به صورت زیر نوشت:

$$y_t = \sum_{i=1}^{N_{NS_e}} \beta_i x_{i,t}^{NS_e} + \sum_{j=1}^{N_{NS_a}} \alpha_j y_{t-j}^{NS_a} + \sum_{k=1}^{N_{S_e}} \gamma_k x_{k,t}^{S_e} + \sum_{z=1}^{N_{S_a}} \eta_z y_{t-z}^{S_a} + \epsilon_t \quad (22)$$

به طوری که $P(X)$ مجموعه توانی X ، \emptyset مجموعه تهی و A متعلق به مجموعه توانی است ($A \in P(X)$). برای همه مجموعه‌های A که عضوهایی از مجموعه توانی می‌باشند ($A \in P(X)$) داریم [73]:

$$Bel(A) = \sum_{B|B \subseteq A} m(B) \quad (28)$$

$$Pl(A) = \sum_{B|B \cap A \neq \emptyset} m(B) \quad (29)$$

تابع $Bel(A)$ مقدار کل احتمالی که باید در میان عناصری از A باشد را اندازه‌گیری می‌کند و به معنای حتمیت و معنی‌داری از باور A و به منزله حد پایینی روی احتمال A است. تابع $Pl(A)$ حداکثر احتمالی را که می‌تواند در میان عناصر A توزیع شود را اندازه‌گیری می‌کند. $Pl(A)$ درجه باور کلی مربوط به A را توصیف می‌کند و به منزله تابع حد بالایی روی احتمال A است. مطابق با تعاریف ارائه‌شده، قوانین ترکیب شواهد به صورت زیر صورت‌بندی می‌گردد:

فرض کنید m_1 و m_2 دو تابع جرم به دست آمده از دو منبع اطلاعات متفاوت، بر اساس اطلاعات در دسترس باشد. چارچوب تشخیص θ برای هر دو منبع اطلاعاتی، یکسان است. مطابق با قانون متعامد دمپستر، داریم [73]:

$$m(\Phi) = 0 \quad (30)$$

$$m(A) = \frac{1}{1-k} \sum_{B \cap C = A} m_1(B) \cdot m_2(C) \quad (31)$$

$$k = \sum_{B \cap C = A} m_1(B) \cdot m_2(C) > 0 \quad (32)$$

k جرم احتمال پایه مربوط ناسازگاری میان منابع شواهد ارائه می‌دهد. طبق رابطه (۳۲)، k از مجموع ضرب توابع جرم تمام زیرمجموعه‌هایی که اشتراک آن‌ها تهی است، به دست می‌آید. عموماً k را به عنوان اندازه ناسازگاری بین منابع اطلاعات تفسیر می‌کنند. مقدار بزرگتر k بیانگر ناسازگاری بیشتر منابع است. مخرج $1 - k$ در تساوی رابطه (۳۱)، فاکتور نرمال‌سازی است. m نیز، تابع جرم در چارچوب تشخیص یکسان θ است. توجه کنید که جمع متعامد $m = m_1 \oplus m_2$ ، ترکیب m_1 و m_2 را نشان می‌دهد و اطلاعات مشترکی از دو منبع را در بر دارد. در حالت کلی برای n تابع جرم m_1, m_2, \dots, m_n اندازه ناسازگاری k به صورت رابطه ۳۳ محاسبه می‌شود [73]:

$$k = \sum_{\bigcap_{i=1}^n A_i = \Phi} m_1(A_1) \cdot m_2(A_2) \dots m_n(A_n) > 0 \quad (33)$$


پس ترکیب (تلفیق) تابع جرم به صورت رابطه ۳۴ محاسبه می‌گردد [73]:

$$m(A) = (m_1 \oplus m_2 \oplus \dots \oplus m_n)(A) = \frac{1}{1-k} \sum_{\bigcap_{i=1}^n A_i = A} m_1(A_1) \cdot m_2(A_2) \dots m_n(A_n) \quad (34)$$

حال، با توجه به توضیحات ارائه‌شده پیرامون تئوری دمپستر- شفر و قواعد ترکیب شواهد، فرض کنید که n سنسور متصل به ماشین که اطلاعات زوال ماشین را مخابره می‌نماید، به عنوان n شاهد عمل می‌کنند (برای مثال شاخص سلامت به دست آمده از ارتعاشات سنسور افقی (شاهد اول) و سنسور عمودی (شاهد دوم)). همچنین فرض می‌کنیم که $C = \{c(1), c(2), \dots, c(q)\}$ مراکز خوشه‌های (q خوشه) سنسور n است که توسط الگوریتم C - میانگین فازی برای ویژگی‌های هر یک از سنسورهای داده‌های یادگیری به دست آمده است. در این حالت، احتمال تعلق شاخص سلامت سنسور n در زمان t (HI_t) به Z امین خوشه به صورت رابطه ۳۵ محاسبه می‌گردد:

$$m_n(c(j)) = \frac{1}{\sum_{l=1}^q \frac{1}{D(HI_t, c(l))}} \quad (35)$$

عمودی و تلفیق آن‌ها تعیین می‌شود. این روند ادامه خواهد یافت تا به خوشه نهایی برسد. روند پیش‌بینی و ترکیب در ادامه شرح داده شده است.



شکل ۲) مدت زمان اجرا تا خرابی و زمان ورود به خوشه نهایی

۳-۲-۳- پیش‌بینی یک گام جلوتر

در این فاز، با در نظر گرفتن t به عنوان زمان فعلی، شاخص سلامت تجهیز تست با استفاده از روش مارکوف رژیم سوییچینگ خودرگرسیون برای $t + 1$ شبیه‌سازی شده است. فرآیند پیش‌بینی با استفاده از مدل‌هایی که در فاز یادگیری برازش شده‌اند انجام می‌شود. بنابراین، اگر N نمونه یادگیری وجود داشته باشد، فرآیند پیش‌بینی با توجه به مدل‌هایی که برای این N نمونه برازش شده است، صورت می‌پذیرد.

۳-۲-۳- تلفیق


در این بخش، ابتدا مقدماتی در مورد تئوری شواهد ارائه شده است و سپس روش استفاده از آن برای ترکیب ویژگی‌های مسئله توضیح داده شده است. دمپستر تئوری ریاضی شواهد را ارائه نمود و شفر آن را توسعه داد [72]. از مهم‌ترین نتایج این نظریه تلفیق باورهای موجود درباره یک حالت و یا حالاتی از یک سیستم است. باورها در مورد رویدادها از دید شاهدان مختلف یکسان نیست اما با کمک این نظریه می‌توان شواهد موجود را ترکیب نمود. در مجموع، هدف از ادغام اطلاعات به دست آمده از منابع مختلف، ساده‌سازی و کاهش داده‌های حجیم است که از منابع چندگانه به دست می‌آید. در ادامه قواعد تلفیق این تئوری ارائه می‌گردد [73]. سه تابع اصلی در تئوری دمپستر- شفر عبارتند از: تابع تخصیص احتمال پایه (bpa یا m)، تابع باور (Bel) و تابع موجه بودن (Pl). bpa که با m نیز نمایش داده می‌شود، یک نگاشت از مجموعه توانی به بازه بین ۰ و ۱ را تعریف می‌نماید به طوری که تخصیص احتمال پایه مجموعه تهی ۰ است و مجموع تابع تخصیص احتمال پایه‌ها برای همه زیرمجموعه‌های مجموعه توانی ۱ است. مقدار تابع تخصیص احتمال پایه برای یک مجموعه معین A که با $m(A)$ نمایش داده می‌شود، نسبتی از همه شواهد مربوط و در دسترس را مشخص می‌نماید به طوری که یک عضو مشخص از X (مجموعه جهانی) متعلق به مجموعه A است اما به هیچ زیرمجموعه مشخصی از A تعلق ندارد. مقدار $m(A)$ تنها وابسته به مجموعه A است و هیچ ادعای اضافه‌ای در مورد زیرمجموعه‌های A ندارد. هر شهادت دیگری درباره زیرمجموعه‌های A با تابع تخصیص احتمال پایه دیگری ارائه می‌گردد. یعنی $B \subset A$ ، $m(B)$ ، تابع تخصیص احتمال پایه برای زیرمجموعه B است. موارد اشاره شده درباره m می‌تواند توسط سه معادله زیر توصیف گردد [73]:

$$m: P(X) \rightarrow [0,1] \quad (25)$$

$$m(\emptyset) = 0 \quad (26)$$


$$\sum_{A \in P(X)} m(A) = 1 \quad (27)$$

انستیتوی FEMTO-ST طراحی شده است. هدف اصلی پرونوستیا تهیه کردن داده‌های عمر واقعی است که فرآیند زوال بیرینگ را در کل طول عمر آن، یعنی تا خراب شدن کلی آن، توصیف نماید [74].



شکل ۵) پلتفرم آزمایشگاهی پرونوستیا [74]

پلتفرم پرونوستیا انجام آزمایش‌های عملیات تا خرابی را ممکن می‌سازد. برای پرهیز از انتشار خرابی به کل بستر آزمون (و به دلایل ایمنی)، زمانی که بزرگی ارتعاش سیگنال از ۲۰g تجاوز نماید، متوقف می‌شود. شکل ۶ مثالی از آنچه قبل و بعد از خرابی برای بلبرینگ‌ها رخ می‌دهد و همچنین سیگنال خام ارتعاش که طی کل آزمایش گردآوری شده است را نشان می‌دهد. توجه کنید که زوال بیرینگ‌ها رفتارهای متفاوتی را از خود نشان می‌دهند و در نتیجه منجر به مدت آزمایش‌های متفاوت (تا خرابی) می‌گردد.



شکل ۶) قبل و بعد از خرابی بلبرینگ‌ها (چپ): سیگنال ارتعاشات بلبرینگ (راست)

مجموعه داده گردآوری شده توسط این سامانه، تحت سه شرایط تولید شده است (جدول ۱):

- شرایط عملیاتی اول: 1800rpm و 4000N
- شرایط عملیاتی دوم: 1650rpm و 4200N
- شرایط عملیاتی سوم: 1500rpm و 5000N

جدول ۱) شمای کلی داده‌های تولید شده توسط انستیتوی FEMTO-ST

مجموعه داده‌ها	شرایط عملیاتی اول	شرایط عملیاتی دوم	شرایط عملیاتی سوم
مجموعه یادگیری	بیرینگ ۱-۱	بیرینگ ۱-۲	بیرینگ ۱-۳
	بیرینگ ۲-۱	بیرینگ ۲-۲	بیرینگ ۲-۳
مجموعه تست	بیرینگ ۳-۱	بیرینگ ۳-۲	بیرینگ ۳-۳
	بیرینگ ۴-۱	بیرینگ ۴-۲	
	بیرینگ ۵-۱	بیرینگ ۵-۲	
	بیرینگ ۶-۱	بیرینگ ۶-۲	
	بیرینگ ۷-۱	بیرینگ ۷-۲	

۶ مجموعه داده اجرا تا خرابی برای ایجاد مدل‌های پیش‌بینی

به طوری که $D(HI_t, c(j))$ فاصله اقلیدسی داده HI_t از مرکز $c(j)$ است (شکل ۳). بر اساس رابطه (۳۴)، ترکیب احتمالات $m_n(c(j))$ با استفاده از رابطه (۳۶) محاسبه می‌گردد:


$$m_{1,\dots,n}(c(j)) = (m_1 \oplus m_2 \oplus \dots \oplus m_n) \frac{1}{k-1} \sum_{\cap_{i=1}^n C(i)=c(j)} m_1(C(1)) \cdot m_2(C(2)) \dots m_n(C(n))$$

به طوری که:

$$(37)$$

$$k = \sum_{\cap_{i=1}^n C(i)=\Phi} m_1(C(1)) \cdot m_2(C(2)) \dots m_n(C(n)) > 0$$

در نهایت مطابق با رابطه (۳۷) HI_t متعلق به خوشه زام است که دارای بیشترین مقدار تابع تخصیص احتمال پایه ترکیبی (تلفیقی) $m_{1,\dots,n}(c(j))$ می‌باشد.




شکل ۳) فاصله HI_t از خوشه‌ها

۳-۳- تخمین RUL

پس از تعیین وضعیت (خوشه) HI پیش‌بینی شده با استفاده از روش تلفیق پیشنهادی، اگر HI در خوشه پایانی وارد شده باشد، با توجه به معادله ۳۸، RUL محاسبه می‌گردد:

$$RUL = TT + (t_{End} - t_{FS}) = TT + \left(\frac{t_{FS} FSR}{1 - FSR} \right) \quad (38)$$

به طوری که TT ، مدت زمان تا ورود به خوشه نهایی است (شکل ۴). در شکل ۴، t_c زمان فعلی (زمان محاسبه عمر مفید باقی‌مانده) است.



شکل ۴) محاسبه RUL با استفاده از نسبت وضعیت نهایی

۴- مطالعه موردی

۴-۱- داده‌های پلتفرم پرونوستیا

پرونوستیا (PRONOSTIA) که در شکل ۵ نشان داده شده است، یک پلتفرم آزمایشگاهی است که برای تست و راستی‌آزمایی شناسایی خرابی بیرینگ و رویکردهای تشخیص و پیش‌بینی عیوب تهیه گردیده است [74]. این پلتفرم در دپارتمان AS2M

بیرینگ‌های یادگیری هر یک از شرایط به‌دست‌آمده است. با داشتن مراکز خوشه‌ها می‌توان خوشه‌های افقی و عمودی را برای هر بیرینگ تلفیق نمود. نمودار ۳، به‌عنوان نمونه، دو ویژگی افقی و عمودی و تلفیق خوشه‌های این دو ویژگی را برای بیرینگ‌های ۱-۱ و ۲-۱ نشان می‌دهد.

با انجام خوشه‌بندی برای همه بیرینگ‌های یادگیری در شرایط مختلف، مدت‌زمان ورود به آستانه (زمان ابتدای خوشه چهارم) تا خرابی کامل (زمان آخرین داده سیگنال)، برای هر یک از بیرینگ‌های یادگیری محاسبه شده است و سپس مقدار نسبت وضعیت نهایی با توجه به زمان کل سیگنال‌های یادگیری به‌دست‌آمده است (جدول ۲).

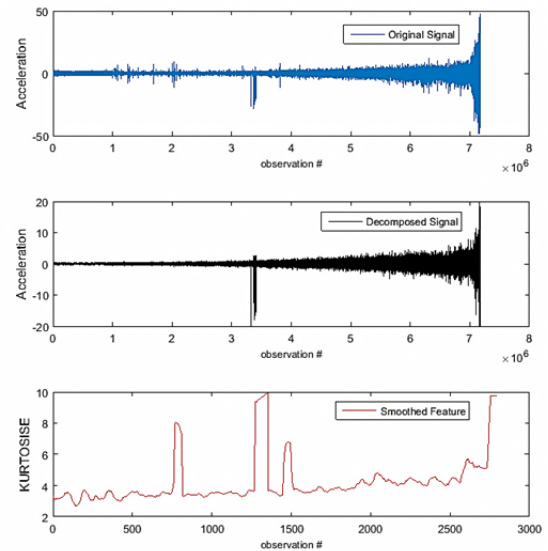
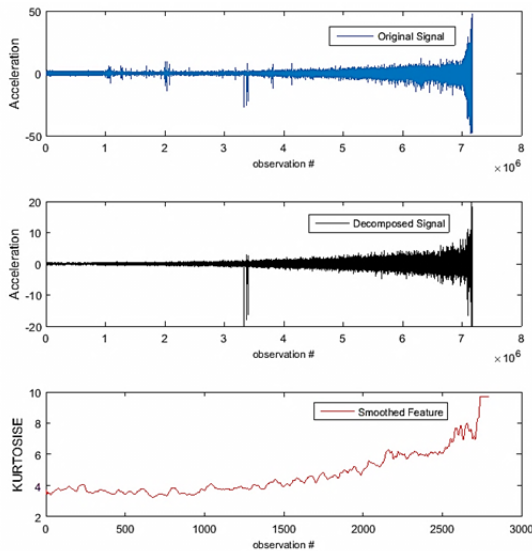
پس از تعیین نسبت وضعیت نهایی، مدل مارکوف رژیم سویچینگ خودرگرسیون برای همه بیرینگ‌ها یادگیری با در نظر گرفتن ۱ تا ۳ وقفه برازش می‌گردد. با استفاده از معیار اطلاعات بیزی، بهترین وقفه برای هر مدل برازش شده، انتخاب شده است (جدول ۳).

(مجموعه داده‌های یادگیری) فراهم شده است و تخمین عمر مفید باقی‌مانده برای ۱۱ بیرینگ دیگر خواسته شده است. سیگنال‌های ارتعاش و دما برای همه اجزای آزمایش جمع‌آوری شده است. هیچ فرضی برای نوع خرابی رخ داده وجود ندارد (هیچ اطلاعاتی درباره ریشه و منشأ زوال: ساچمه‌ها، حلقه داخلی، حلقه خارجی، قفسی و غیره وجود ندارد).

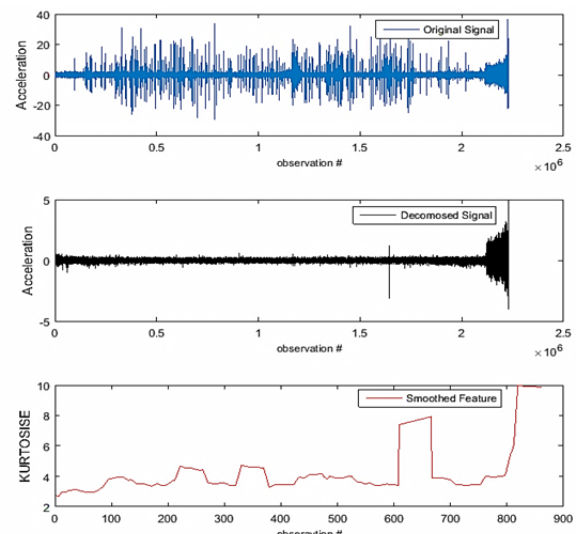
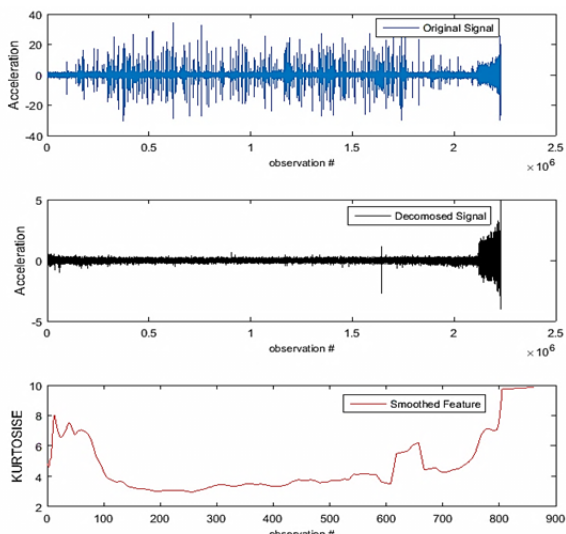
۲-۴ نتایج فاز یادگیری

در این فاز فرآیند اولیه پردازش داده‌ها برای تمامی ارتعاشات بیرینگ‌های یادگیری یعنی بیرینگ‌های شماره (۱-۱، ۲-۱، ۱-۲، ۲-۲، ۱-۳، ۲-۳) صورت پذیرفته است. در نمودارهای ۱ و ۲، سیگنال اصلی در بالای نمودار، سیگنال تجزیه‌شده در وسط نمودار و ویژگی استخراج شده و هموار شده در پایین نمودار را به ترتیب برای بیرینگ‌های ۱-۱ و ۲-۱، نشان می‌دهد.





با استفاده از روش C- میانگین فازی و با در نظر گرفتن ۴ خوشه به‌منزله ۴ مرحله از زوال بیرینگ (وضعیت سلامت تا خرابی کامل)، مراکز خوشه‌ها به‌طور مجزا برای ویژگی‌های افقی و عمودی



نمودار ۱) سیگنال اصلی (نمودار بالا)، سیگنال تجزیه‌شده (نمودار وسط) و ویژگی استخراج شده (نمودار پایین) برای ارتعاشات حاصل از سنسورهای افقی (نمودارهای چپ) و عمودی (نمودارهای راست) بیرینگ ۱-۱



نمودار ۲) سیگنال اصلی (نمودار بالا)، سیگنال تجزیه‌شده (نمودار وسط) و ویژگی استخراج شده (نمودار پایین) برای ارتعاشات حاصل از سنسورهای افقی (نمودارهای چپ) و عمودی (نمودارهای راست) بیرینگ ۲-۱



نمودار (۳) ویژگی‌های افقی و عمودی (نمودارهای بالا) و تلفیق خوشه‌ها (نمودارهای پایین) برای بیرینگ‌های ۱-۱ (نمودارهای چپ) و ۲-۱ (نمودارهای راست)

جدول (۲) مقادیر نسبت وضعیت نهایی برای بیرینگ‌های یادگیری

نسبت وضعیت نهایی	بیرینگ ۱-۱	بیرینگ ۲-۱	بیرینگ ۱-۲	بیرینگ ۲-۲	بیرینگ ۱-۳	بیرینگ ۲-۳
	۰/۰۱۷	۰/۰۵۳	۰/۰۴۵	۰/۰۰۶	۰/۰۶۳	۰/۰۲۲

جدول (۳) معیار اطلاعات بیزی برای ویژگی‌های بیرینگ‌های یادگیری

بیرینگ یادگیری	۱-۱		۲-۱		۱-۲		۲-۲		۱-۳		۲-۳	
	ویژگی افقی	ویژگی عمودی	ویژگی افقی	ویژگی عمودی	ویژگی افقی	ویژگی عمودی	ویژگی افقی	ویژگی عمودی	ویژگی افقی	ویژگی عمودی	ویژگی افقی	ویژگی عمودی
۱	-۲۰۹۹۵/۱	-۲۱۶۸۷/۸	-۵۶۴۴/۹	-۵۲۶۹/۹	-۵۸۸۶/۷	-۸۳۷۷/۴	-۶۲۰۰/۴	-۵۸۱۹/۳	-۳۴۳۷/۱	-۴۰۳۹/۱	-۱۴۰۷۵/۳	-۱۴۰۲۸/۲
۲	-۲۰۴۱۷	-۲۱۲۵۵/۶	-۵۸۵۷/۹	-۵۵۳۴/۴	-۵۹۵۱/۴	-۸۴۷۸/۵	-۶۲۰۲/۵	-۵۰۲۹/۵	-۳۴۰۹/۶	-۴۰۷۱/۲	-۱۳۸۵۷/۶	-۱۲۳۹۶/۵
۳	-۲۰۶۸۴/۳	-۲۱۳۲۷/۰	-۵۵۲۵/۹	-۴۹۱۰/۴	-۱۱۱۴۶/۱	-۵۱۸۸/۶	-۶۰۸۵/۴	-۶۶۸۸/۷	-۳۳۵۱/۵	-۴۰۰۷/۶	-۱۴۰۲۸/۲	-۱۲۳۳۶/۲

۳-۴ نتایج فاز تست

در فاز تست، در ابتدا وضعیت زوال بیرینگ، با استفاده از روش خوشه‌بندی تشریح شده، صورت پذیرفته است و سپس شبیه‌سازی مارکوف رژیم سویچینگ خودرگرسیون برای پیش‌بینی TT و عمر مفید باقی‌مانده با توجه به رابطه ۳۸ به دست آمده است. شبیه‌سازی برای ۱۰۰ مسیر (Path) انجام گرفته است و برای هر نقطه از مسیرها، مرحله زوال و TT تعیین شده است. با توجه به تابع توزیع احتمالی به دست آمده از TT ‌های پیش‌بینی شده، TT نهایی بر اساس سه سطح برش ۱۰، ۵۰ و ۹۰٪ به دست آمده است. همچنین برای هر بیرینگ تست، ۲ مقدار عمر مفید باقی‌مانده با توجه به دو بیرینگ یادگیری مربوطه در هر یک از شرایط محاسبه شده است. برای ارزیابی روش تلفیق پیشنهادی، نتایج به دست آمده در سه حالت مقایسه شده‌اند:

- تعیین عمر مفید باقی‌مانده با در نظر گرفتن سنسور افقی.

- تعیین عمر مفید باقی‌مانده با در نظر گرفتن سنسور عمودی.

- میانگین سنسورهای افقی و عمودی برای تعیین وضعیت زوال که در این حالت، به جای تلفیق سنسورهای افقی و عمودی، از مقدار میانگین دو سنسور برای تعیین وضعیت (خوشه) استفاده شده است.

در جدول ۴، نرخ خطای پیش‌بینی برای آمین بیرینگ و برای هر یک از سطوح برش، نشان داده شده است. نرخ خطا به صورت رابطه ۳۹ تعریف می‌گردد:

$$Er = \frac{ActRUL_i - PredRUL_i}{ActRUL_i} \times 100\% \quad (39)$$

چون بیرینگ ۴-۱ پیش از پیش‌بینی به وضعیت نهایی وارد شده بود، عمر مفید باقی‌مانده آن از فرمول $RUL = \frac{t_{FS} FSR}{1 - FSR}$ محاسبه

شده است. همان طور که در جدول ۴ مشاهده می‌شود، در برخی از بیرینگ‌ها تفاوت زیادی در تخمین عمر مفید باقی‌مانده با توجه به دو بیرینگ یادگیری وجود دارد. به نظر می‌رسد که دلیل این موضوع شباهت بیشتر فرآیند زوال بیرینگ تست به یکی از دو بیرینگ یادگیری نسبت به دیگری است. در بیرینگ‌های ۱-۱، ۳-۱، ۴-۱، ۶-۱، ۷-۱، ۲-۲، ۵-۲، ۴-۲ و ۷-۲، ویژگی افقی، ویژگی مناسب‌تری برای پیش‌بینی عمر مفید بوده است و می‌توان گفت سهم بیشتری را در توصیف خرابی تجهیز داراست. در سایر بیرینگ‌های تست ویژگی‌های عمودی عملکرد بهتری را در پیش‌بینی نشان داده‌اند. عمر مفید باقی‌مانده برای سه بیرینگ ۱-۱، ۳-۱، ۴-۱، ۶-۱، ۳-۳، بیش از مقدار واقعی تخمین زده شده است (منفی بودن نرخ خطا)، در حالی که در ۱۲ بیرینگ باقی‌مانده، تخمین عمر کمتر از مقدار واقعی است. استفاده از روش تلفیق سنسورها نقش تعدیل‌کننده‌ای در خطای پیش‌بینی در مقایسه با پیش‌بینی فقط با سنسور افقی و فقط با سنسور عمودی داشته است؛ به عبارت دیگر در برخی از بیرینگ‌ها تخمین عمر مفید باقی‌مانده بر اساس ویژگی افقی (بیرینگ ۱-۱، ۳-۱، ۴-۱، ۶-۱، ۲-۲، ۵-۲، ۴-۲، ۷-۲) و در برخی دیگر بر اساس ویژگی عمودی (بیرینگ ۱-۱، ۳-۱، ۴-۱، ۵-۱، ۷-۱، ۳-۲، ۳-۳) دقیق‌تر است. از آنجایی که اطلاعاتی در خصوص فیزیک خرابی وجود ندارد و در نتیجه تصمیم‌گیری درباره انتخاب سنسور (افقی یا عمودی) برای تعیین وضعیت زوال و تعیین عمر مفید باقی‌مانده دشوار است، استفاده از روش تلفیق اطلاعات سنسورها می‌تواند مفید باشد. در نهایت با در نظر گرفتن ۲۲ مورد پیش‌بینی (۱۰ حالت برای شرایط ۱، ۱۰ حالت برای شرایط ۲ و ۲ حالت برای شرایط ۳)، در ۲۰ مورد، روش تلفیق عملکرد بهتری را نسبت به روش میانگین‌گیری

از خود نشان داده است. نمودار ۴ نتایج این مقایسه را نشان می‌دهد.


۴-۴- مقایسه روش‌های پیش‌بینی

برای ارزیابی روش پیش‌بینی مدل مارکوف رژیم سویچینگ خودرگرسیون، نتایج به‌دست‌آمده توسط این روش با دو روش خودرگرسیون یعنی روش میانگین متحرک خودرگرسیون (Autoregressive Moving Average) و شبکه عصبی خودرگرسیون (Autoregressive Neural Network)، با توجه به دو معیار امتیاز (SCORE) [74] و خطای جذر میانگین مربعات (RMSE) مقایسه شده است. این دو معیار به‌صورت زیر تعریف می‌گردند:

$$A_i = \begin{cases} \exp^{-\ln(0.5) \cdot (\frac{Er_i}{5})} & \text{if } Er_i \leq 0 \\ \exp^{+\ln(0.5) \cdot (\frac{Er_i}{20})} & \text{if } Er_i > 0 \end{cases} \quad (40)$$

$$SCORE = \frac{1}{N} \sum_{i=1}^N A_i \quad (41)$$

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (ActRUL_i - PredRUL_i)^2}{N}} \quad (42)$$



نمودار ۴) نتایج مقایسه روش تلفیق و روش میانگین‌گیری

جدول ۴) نرخ خطای پیش‌بینی عمر مفید باقی‌مانده

بیرینگ ۲-۱			بیرینگ ۱-۱			سنسور	بیرینگ تست
%۱۰	%۵۰	%۹۰	%۱۰	%۵۰	%۹۰		
۵۷/۰۳	۵۵/۹۲	۵۰/۷۳	۴۴/۲۰	۳۸/۱۴	۲۹/۰۶	افقی ^b	بیرینگ ۳-۱
۱۴۴/۷۶	۱۳۰/۴۷	۱۰۲/۷۳	۹۷/۴۱	۸۸/۰۳	۴۴/۲۱	عمودی ^c	
۱۰۲/۸۶	۸۷/۱۶	۷۵/۸۷	۸۱/۹۸	۷۷/۱۶	۳۹/۲۳	میانگین‌گیری	
۶۱/۹۰	۶۱/۱۶	۶۰/۴۲	۷۰/۷۰	۶۵/۶۴	۳۵/۰۸	تلفیق	بیرینگ ۴-۱
۲۶/۶۳	۲۶/۶۳	۲۶/۶۳	۱۱۱/۵۲	۱۱۱/۵۲	۱۱۱/۵۲	افقی	
۷۶/۳۱	۷۶/۳۱	۷۶/۳۱	۱۹۶/۰۳	۱۹۶/۰۳	۱۹۶/۰۳	عمودی	
۵۶/۹۶	۵۶/۹۶	۵۶/۹۶	۱۷۸/۴۱	۱۷۸/۴۱	۱۷۸/۴۱	میانگین‌گیری	بیرینگ ۵-۱
۴۲/۹۷	۴۲/۹۷	۴۲/۹۷	۱۶۶/۶۰	۱۶۶/۶۰	۱۶۶/۶۰	تلفیق	
۲۶/۱۱	۱۷/۶۸	۱۲/۸۸	۷۳/۴۸	۵۵/۹۲	۴۸/۴۳	افقی	
-۲/۳۹	-۱۲/۰۸	-۲۲/۰۴	۳۳/۰۶	۲۳/۹۵	۱۶/۸۲	عمودی	بیرینگ ۶-۱
۱۱/۰۱	۷/۱۴	۵/۰۳	۶۳/۱۵	۴۵/۴۰	۳۸/۲۴	میانگین‌گیری	
۰/۶۹	۰/۰۳	-۰/۶۳	۵۲/۴۵	۳۷/۹۱	۳۱/۵۹	تلفیق	
-۱۷/۶۴	-۳۳/۴۱	-۵۴/۵۱	۴۶/۳۹	۴۴/۷۳	۴۱/۶۶	افقی	بیرینگ ۷-۱
۱۶/۲۲	۱۲/۰۳	-۴/۷۲	۸۹/۷۳	۸۳/۲۶	۷۷/۲۸	عمودی	
-۱۲/۰۲	-۲۲/۱۶	-۳۰/۹۵	۷۱/۶۹	۶۷/۴۸	۶۱/۸۳	میانگین‌گیری	
-۹/۵۲	-۱۵/۳۱	-۲۶/۸۸	۵۳/۱۴	۵۲/۴۴	۵۱/۷۵	تلفیق	بیرینگ ۸-۱
۸۸/۱۹	۸۰/۹۲	۷۶/۸۱	۷۵/۱۱	۶۹/۲۱	۴۳/۹۱	افقی	
۴۱/۲۵	۳۳/۴۶	۲۷/۱۸	۳۱/۳۰	۲۴/۰۷	۱۲/۱۷	عمودی	
۶۹/۳۲	۶۴/۲۰	۶۰/۲۲	۶۵/۵۵	۶۰/۲۶	۴۰/۶۹	میانگین‌گیری	بیرینگ ۹-۱
۵۱/۲۰	۵۱/۰۶	۵۰/۷۹	۵۸/۵۶	۵۱/۷۰	۳۶/۹۱	تلفیق	

بیرینگ ۲-۲			بیرینگ ۱-۲			سنسور	بیرینگ تست
%۱۰	%۵۰	%۹۰	%۱۰	%۵۰	%۹۰		
۷۶/۵۱	۷۴/۳۱	۷۰/۹۹	۶۹/۹۰	۵۱/۱۷	۴۲/۲۱	افقی	بیرینگ ۲-۲
۶۲/۱۳	۶۱/۹۷	۶۱/۲۳	۴۶/۶۶	۳۰/۰۷	۲۸/۷۱	عمودی	
۶۸/۱۸	۶۶/۸۴	۶۶/۸۱	۶۱/۶۴	۴۵/۹۹	۳۶/۶۳	میانگین‌گیری	
۶۲/۸۸	۶۲/۷۴	۶۲/۶۱	۵۳/۴۷	۴۲/۷۶	۳۲/۳۳	تلفیق	
۳۸/۲۱	۳۷/۰۱	۳۶/۱۴	۳۲/۰۷	۳۰/۰۰	۲۶/۶۷	افقی	بیرینگ ۴-۲
۶۹/۱۲	۶۳/۳۷	۵۸/۷۱	۶۶/۰۱	۶۲/۳۱	۵۶/۲۰	عمودی	
۵۴/۹۲	۵۱/۱۵	۴۸/۵۱	۴۸/۲۴	۴۶/۶۱	۴۳/۳۶	میانگین‌گیری	
۴۱/۸۰	۴۱/۰۸	۳۹/۲۱	۳۶/۸۹	۳۶/۱۳	۳۵/۳۸	تلفیق	
۸۰/۳۱	۷۸/۲۲	۷۳/۱۳	۴۱/۹۰	۳۲/۱۱	۲۶/۶۴	افقی	بیرینگ ۵-۲
۱۶۹/۰۴	۱۶۱/۰۳	۱۵۲/۰۱	۱۷۹/۰۰	۱۷۲/۱۲	۱۶۱/۲۲	عمودی	
۱۲۸/۳۴	۱۲۷/۰۹	۱۱۴/۶۷	۱۲۰/۷۶	۱۱۸/۷۰	۱۲۲/۵۶	میانگین‌گیری	
۹۳/۴۰	۹۲/۱۰	۹۰/۷۹	۹۰/۶۴	۸۹/۹۶	۸۸/۱۱	تلفیق	
۱۸/۸۱	۱۱/۸۷	۱/۳۰	۲۹/۷۰	۱۸/۰۰	۱۵/۷۰	افقی	بیرینگ ۶-۲
۶۱/۲۱	۵۲/۱۰	۱۷/۶۹	۱۲۶/۴۲	۱۱۳/۷۷	۹۶/۱۴	عمودی	
۴۸/۷۸	۴۰/۱۱	۱۱/۴۰	۲۷/۲۷	۲۸/۶۶	۲۲/۷۱	میانگین‌گیری	
۳۸/۰۹	۳۰/۲۹	۶/۱۰	۴۰/۲۶	۳۹/۵۰	۳۶/۲۰	تلفیق	
۵۷/۳۳	۴۱/۱۵	۲۷/۱۲	۴۱/۰۱	۲۹/۹۱	۱۱/۱۲	افقی	بیرینگ ۷-۲
۱۳۰/۱۰	۱۲۱/۰۶	۱۱۵/۳۳	۷۸/۱۴	۶۶/۰۴	۳۴/۴۱	عمودی	
۶۴/۸۰	۵۵/۷۱	۵۰/۵۸	۶۶/۸۳	۵۳/۱۸	۲۵/۲۴	میانگین‌گیری	
۶۸/۵۹	۶۳/۳۸	۶۱/۱۲	۵۷/۲۸	۴۴/۴۷	۱۹/۱۹	تلفیق	
بیرینگ ۲-۳			بیرینگ ۱-۳			سنسور	بیرینگ تست
%۱۰	%۵۰	%۹۰	%۱۰	%۵۰	%۹۰		
-۴۳/۲۱	-۵۰/۱۱	-۶۶/۰۹	۱۳۴/۶۱	۱۲۷/۱۲	۱۱۱/۰۹	افقی	بیرینگ ۳-۳
-۲۵/۰۷	-۲۶۵/۱۲	-۲۷۶/۰۴	۶۲/۸۱	۵۶/۱۹	۴۴/۱۵	عمودی	
-۱۷۷/۳۶	-۱۷۳/۴۸	-۱۹۰/۰۶	۱۰۳/۹۱	۱۰۴/۰۱	۹۴/۹۳	میانگین‌گیری	
-۲۴۶/۴۳	-۲۴۷/۶۸	-۲۵۹/۰۳	۸۲/۶۹	۸۲/۳۲	۸۰/۸۲	تلفیق	

ا: سطح برش؛ ب: سیگنال افقی؛ ج: سیگنال عمودی

جدول (۵) نتایج مقایسه روش‌های پیش‌بینی

معیار ارزیابی	بیرینگ تست											روش پیش‌بینی	
	۳-۳	۶-۲	۵-۲	۴-۲	۳-۲	۲-۲	۱-۲	۶-۱	۵-۱	۴-۱	۳-۱		
مارکوف رژیم سویچینگ خودرگرسیون	۲۲۳۳/۹۸	۰/۰۰۸۷۳۵	۱۶۵	۵۳/۹۲۵	۳۴/۸۹۵	۹۱/۰۳	۳۸/۶۰۵	۵۲/۷۵	۵۱/۳۸	۳۳/۸۷۵	۱۸/۹۷	۱۰۴/۷۸۵	۶۳/۴
میانگین متحرک خودرگرسیون شبکه عصبی خودرگرسیون	۲۹۸۲/۴۲	۰/۰۰۱۷۲۸	۱۹۱/۱۲	۵۵/۸۴	-۶۶/۱	۱۶۴/۹	-۲۸/۸۷	۹۲/۷	۱۴۱/۱۴	۶۲/۷۷	۷۶/۶۴	۲۰۹/۳۵	۱۰/۲
	۲۲۷۱/۸۱	۰/۰۱۲۶۲۸	۱۷/۸	۸۴/۲	۴۳/۲	۲۰۶/۵۴	۷۵/۲	۲۶/۳	۹۸/۷	۵۵/۹۱	-۲۶/۷	۱۱۱/۲۱	۵۷/۳

نتایج روش تلفیق پیشنهادی این مطالعه عملکرد بهتری را نسبت به روش میانگین‌گیری برای تلفیق، نشان داده است. همچنین روش پیش‌بینی مارکوف رژیم سویچینگ خودرگرسیون می‌تواند عملکرد مناسبی را در شرایط پیش‌بینی با تغییرات در رژیم داشته باشد. با توجه به تقارن در خطای پیش‌بینی، عملکرد این روش بهتر از روش‌های رقیب میانگین متحرک خودرگرسیون و شبکه عصبی خودرگرسیون است.

۶- پیوست

معیار یکنواختی، بیانگر افزایش و یا کاهش روند یک سری زمانی است و با استفاده از رابطه زیر به دست می‌آید:

$$\dot{M} = \left| \frac{no.of \frac{d}{dx} > 0}{m-1} - \frac{no.of \frac{d}{dx} < 0}{m-1} \right| \quad (۴۳)$$

به طوری که m تعداد مشاهدات است. \dot{M} می‌تواند مقادیر بین ۰ و ۱ را به خود اختصاص دهد (در یک سری زمانی یکنواخت $\dot{M} = 1$ و یک سری غیریکنواخت $\dot{M} = 0$).

معیار روندپذیری، همبستگی یک سری زمانی با زمان است و به صورت زیر محاسبه می‌گردد:

$$R = \frac{n(\sum xt) - (\sum x)(\sum t)}{\sqrt{[n \sum x^2 - (\sum x)^2][n \sum t^2 - (\sum t)^2]}} \quad (۴۴)$$

۵- بحث و نتیجه‌گیری

در این مقاله، یک مدل ارزیابی وضعیت زوال و تعیین عمر مفید باقی‌مانده برای بیرینگ ارائه شده است. در این مدل، از روش مارکوف رژیم سویچینگ خودرگرسیون برای پیش‌بینی و شبیه‌سازی شاخص سلامت به دست آمده از داده‌های ارتعاشات، از خوشه‌بندی فازی برای تعیین وضعیت زوال اولیه تجهیزات و از رویکرد جدید به تئوری دمپستر- شفر برای تلفیق اطلاعات استفاده شده است. در روش پیشنهادی، برای تلفیق اطلاعات سنسورها، از هر سنسور به عنوان یک شاهد (مرجع) استفاده شده است. احتمال تعلق سیستم به هر یک از وضعیت‌های زوال، بر اساس فاصله شاخص سلامت از مراکز خوشه‌ها تعیین می‌گردد. همچنین در این مقاله شاخص سلامت جدیدی به نام کرتسیس‌ای معرفی شده است که توانایی تعدیل نوسانات شدید در آستانه خرابی را داراست. برای ارزیابی مدل، از مجموعه داده‌های انیستتو FEMTO-ST استفاده شده است. از نتیجه ارزیابی و مقایسه، می‌توان نتیجه گرفت که روش تلفیق پیشنهادی می‌تواند در مواردی استفاده شود که اطلاعات در مورد فیزیک خرابی وجود ندارد و باید از مدل داده‌محور استفاده شود و تصمیم‌گیری در مورد وضعیت زوال، با توجه به اطلاعات جداگانه سنسورها، می‌تواند گمراه‌کننده باشد.

evolution-particle swarm optimization. *Chemical Engineering Transactions*. 2013;33:619-624.

11- Hong Sh, Zhou Z, Zio E, Wang W. An adaptive method for health trend prediction of rotating bearings. *Digital Signal Processing*. 2014;35:117-123.

12- Hong Sh, Zhou Z, Zio E, Hong K. Condition assessment for the performance degradation of bearing based on a combinatorial feature extraction method. *Digital Signal Processing*. 2014;27:159-166.

13- Lei Y, Li N, Guo L, Li N, Yan T, Lin J. Machinery health prognostics: A systematic review from data acquisition to RUL prediction. *Mechanical Systems and Signal Processing*. 2018;104:799-834.

14- Soualhi A, Medjaher K, Zerhouni N. Bearing health monitoring based on Hilbert-Huang transform, support vector machine, and regression. *IEEE Transactions on Instrumentation and Measurement*. 2015;64(1):52-62.

15- Nie Y, Wan J. Estimation of remaining useful life of bearings using sparse representation method. *Prognostics and System Health Management Conference (PHM)*, 21-23 Oct 2015, Beijing, China. Piscataway: IEEE; 2015.

16- Zhang B, Zhang L, Xu J. Degradation feature selection for remaining useful life prediction of rolling element bearings. *Quality and Reliability Engineering International*. 2016;32(2):547-554.

17- Guo L, Gao H, Huang H, He X, Li SC. Multifeatures fusion and nonlinear dimension reduction for intelligent bearing condition monitoring. *Shock and Vibration*. 2016;2016:4632562.

18- Mosallam A, Medjaher K, Zerhouni N. Time series trending for condition assessment and prognostics. *Journal of Manufacturing Technology Management*. 2014;25(4):550-567.

19- Li N, Lei Y, Lin J, Ding SX. An improved exponential model for predicting remaining useful life of rolling element bearings. *IEEE Transactions on Industrial Electronics*. 2015;62(12):7762-7773.

20- Wang L, Zhang L, Wang XZ. Reliability estimation and remaining useful lifetime prediction for bearing based on proportional hazard model. *Journal of Central South University*. 2015;22(12):4625-4633.

21- Ahmad W, Khan SA, Islam MM, Kim JM. A reliable technique for remaining useful life estimation of rolling element bearings using dynamic regression models. *Reliability Engineering & System Safety*. 2019;184:67-76.

22- Lei Y, Li N, Lin J. A new method based on stochastic process models for machine remaining useful life prediction. *IEEE Transactions on Instrumentation and Measurement*. 2016;65(12):2671-2684.

23- Niu G, Qian F, Choi BK. Bearing life prognosis based on monotonic feature selection and similarity modeling. *Proceedings of the Institution of Mechanical Engineers Part C Journal of Mechanical Engineering Science*. 2016;230(18):3183-3193.

24- Huang Z, Xu Z, Ke X, Wang W, Sun Y. Remaining useful life prediction for an adaptive skew-Wiener process model. *Mechanical Systems and Signal Processing*. 2017;87(Pt A):294-306.

25- Cheng Z. Residual useful life prediction for rolling element bearings based on multi-feature fusion regression. *International Conference on Sensing, Diagnostics, Prognostics, and Control (SDPC)*, 16-18 Aug 2017, Shanghai, China. Piscataway: IEEE; 2017.

26- Trinh HC, Kwon YK. An empirical investigation on a multiple filters-based approach for remaining useful life prediction. *Machines*. 2018;6(3):35.

به طوری که t نشان دهنده زمان است.

در این تحقیق با استفاده از داده‌های یادگیری (۶ بیریگ)، میانگین معیارهای یکنواختی و روندپذیری برای دو ویژگی آرام.اس- آنتروپی و کرتسیس‌ای به دست آمده است (جدول ۶).

جدول ۶ روندپذیری و یکنواختی برای دو ویژگی آرام.اس- آنتروپی و کرتسیس‌ای

ویژگی		آرام.اس- آنتروپی		کرتسیس‌ای	
معیار		R	\dot{M}	R	\dot{M}
میانگین مقدار برای ۶ بیریگ یادگیری		۰/۴۱	۰/۵۲	۰/۲۸	۰/۳۱

تشکر و قدردانی: موردی توسط نویسندگان بیان نشد.

تابیدیه اخلاقی: موردی توسط نویسندگان بیان نشد.

تعارض منافع: موردی توسط نویسندگان بیان نشد.

سهم نویسندگان: سعید رضانی (نویسنده اول)، پژوهشگر اصلی (۶۰٪)؛ علیرضا معینی (نویسنده دوم)، پژوهشگر کمکی (۲۰٪)؛ محمد ریاحی (نویسنده سوم)، پژوهشگر کمکی (۲۰٪)؛ منابع مالی: موردی توسط نویسندگان بیان نشد.

منابع

1- Lee J, Wu F, Zhao W, Ghaffari M, Liao L, Siegel D. Prognostics and health management design for rotary machinery systems-reviews, methodology and applications. *Mechanical Systems and Signal Processing*. 2014;42(1-2):314-334.

2- Ramos AL, Ferreira JV, Barceló J. Model-based systems engineering: An emerging approach for modern systems. *IEEE Transactions on Systems Man and Cybernetics Part C Applications and Reviews*. 2012;42(1):101-111.

3- Kan MS, Tan ACC, Mathew J. A review on prognostic techniques for non-stationary and non-linear rotating systems. *Mechanical Systems and Signal Processing*. 2015;62-63:1-20.

4- An D, Kim NH, Choi JH. Practical options for selecting data-driven or physics-based prognostics algorithms with reviews. *Reliability Engineering & System Safety*. 2015;133:223-236.

5- Rai A, Upadhyay SH. A review on signal processing techniques utilized in the fault diagnosis of rolling element bearings. *Tribology International*. 2016;96:289-306.

6- Mosallam A, Medjaher K, Zerhouni N. Data-driven prognostic method based on Bayesian approaches for direct remaining useful life prediction. *Journal of Intelligent Manufacturing*. 2016;27(5):1037-1048.

7- Deng Y, Barros A, Grall A. Degradation modeling based on a time-dependent ornstein-uhlenbeck process and residual useful lifetime estimation. *IEEE Transactions on Reliability*. 2016;65(1):126-140.

8- Wang T. Bearing life prediction based on vibration signals: A case study and lessons learned. *IEEE Conference on Prognostics and Health Management*, 18-21 June 2012, Denver, CO, USA. Piscataway: IEEE; 2012.

9- Sutrisno E, Oh H, Vasan ASS, Pecht M. Estimation of remaining useful life of ball bearings using data driven methodologies. *IEEE Conference on Prognostics and Health Management*, 18-21 June 2012, Denver, CO, USA. Piscataway: IEEE; 2012.

10- Kimotho JK, Sondermann-Woelke C, Meyer T, Sextro W. Machinery prognostic method based on multi-class support vector machines and hybrid differential

- 42- Wang Y, Peng Y, Zi Y, Jin X, Tsui KL. A two-stage data-driven-based prognostic approach for bearing degradation problem. *IEEE Transactions on Industrial Informatics*. 2016;12(3):924-932.
- 43- Medjaher K, Zerhouni N, Baklouti J. Data-driven prognostics based on health indicator construction: Application to PRONOSTIA's data. *European Control Conference (ECC), 17-19 July 2013, Zurich, Switzerland*. Piscataway: IEEE; 2013.
- 44- Loutas TH, Roulias D, Georgoulas G. Remaining useful life estimation in rolling bearings utilizing data-driven probabilistic e-support vectors regression. *IEEE Transactions on Reliability*. 2013;62(4):821-832.
- 45- Pan Y, Er MJ, Li X, Yu H, Gouriveau R. Machine health condition prediction via online dynamic fuzzy neural networks. *Engineering Applications of Artificial Intelligence*. 2014;35:105-113.
- 46- Fumeo E, Oneto L, Anguita D. Condition based maintenance in railway transportation systems based on big data streaming analysis. *Procedia Computer Science*. 2015;53:437-446.
- 47- Liu Y, Hu X, Zhang W. Remaining useful life prediction based on health index similarity. *Reliability Engineering & System Safety*. 2019;185:502-510.
- 48- Javed K, Gouriveau R, Zerhouni N. Novel failure prognostics approach with dynamic thresholds for machine degradation. *39th Annual Conference of the IEEE Industrial Electronics Society (IECON), 10-13 Nov 2013, Vienna, Austria*. Piscataway: IEEE; 2013.
- 49- Tian Z. An artificial neural network method for remaining useful life prediction of equipment subject to condition monitoring. *Journal of Intelligent Manufacturing*. 2012;23(2):227-237.
- 50- Javed K, Gouriveau R, Zemouri R, Zerhouni N. Features selection procedure for prognostics: An approach based on predictability. *IFAC Proceedings Volumes*. 2012;45(20):25-30.
- 51- Pearson RK. Outliers in process modeling and identification. *IEEE Transactions on Control Systems Technology*. 2002;10(1):55-63.
- 52- Narendra Babu C, Eswara Reddy B. A moving-average filter based hybrid ARIMA-ANN model for forecasting time series data. *Applied Soft Computing*. 2014;23:27-38.
- 53- Bezdek JC, Ehrlich R, Full W. FCM: The fuzzy c-means clustering algorithm. *Computers & Geosciences*. 1984;10(2-3):191-203.
- 54- Aguayo L, Barreto GA. Novelty Detection in Time Series Using Self-Organizing Neural Networks: A Comprehensive Evaluation. *Neural Processing Letters*. 2018;47(2):717-744.
- 55- Cheng C, Sa-Ngasoongsong A, Beyca O, Le T, Yang H, Kong ZJ, et al. Time series forecasting for nonlinear and non-stationary processes: A review and comparative study. *IIE Transactions*. 2015;47(10):1053-1071.
- 56- Cempel C. Simple condition forecasting techniques in vibroacoustical diagnostics. *Mechanical Systems and Signal Processing*. 1987;1(1):75-82.
- 57- Elghazel W, Bahi J, Guyeux C, Hakem M, Medjaher K, Zerhouni N. Dependability of wireless sensor networks for industrial prognostics and health management. *Computers in Industry*. 2015;68:1-5.
- 58- Ordóñez C, Lasheras FS, Roca-Pardiñas J, de Cos Juez FJ. A hybrid ARIMA-SVM model for the study of the remaining useful life of aircraft engines. *Journal of Computational and Applied Mathematics*. 2019;346:184-191.
- 27- Ren L, Sun Y, Cui J, Zhang L. Bearing remaining useful life prediction based on deep autoencoder and deep neural networks. *Journal of Manufacturing Systems*. 2018;48(Pt C):71-77.
- 28- Ren L, Sun Y, Wang H, Zhang L. Prediction of bearing remaining useful life with deep convolution neural network. *IEEE Access*. 2018;6:13041-13049.
- 29- Wang J, Liang Y, Zheng Y, Gao RX, Zhang F. An integrated fault diagnosis and prognosis approach for predictive maintenance of wind turbine bearing with limited samples. *Renewable Energy*. 2019;145:642-650.
- 30- Bošković P, Gašperin M, Petelin D. Bearing fault prognostics based on signal complexity and Gaussian process models. *IEEE Conference on Prognostics and Health Management, 18-21 June 2012, Denver, CO, USA*. Piscataway: IEEE; 2012.
- 31- Guo L, Li N, Jia F, Lei Y, Lin J. A recurrent neural network based health indicator for remaining useful life prediction of bearings. *Neurocomputing*. 2017;240:98-109.
- 32- Ali JB, Chebel-Morello B, Saidi L, Malinowski S, Fnaiech F. Accurate bearing remaining useful life prediction based on Weibull distribution and artificial neural network. *Mechanical Systems and Signal Processing*. 2015;56-57:150-172.
- 33- Zhao M, Tang B, Tan Q. Bearing remaining useful life estimation based on time-frequency representation and supervised dimensionality reduction. *Measurement*. 2016;86:41-55.
- 34- Liao L, Jin W, Pavel R. Enhanced restricted Boltzmann machine with prognosability regularization for prognostics and health assessment. *IEEE Transactions on Industrial Electronics*. 2016;63(11):7076-7083.
- 35- Wang ZQ, Hu CH, Fan HD. Real-time remaining useful life prediction for a nonlinear degrading system in service: Application to bearing data. *IEEE ASME Transactions on Mechatronics*. 2018;23(1):211-222.
- 36- Benkedjough T, Medjaher K, Zerhouni N, Rechak S. Remaining useful life estimation based on nonlinear feature reduction and support vector regression. *Engineering Applications of Artificial Intelligence*. 2013;26(7):1751-1760.
- 37- Lei Y, Li N, Gontarz S, Lin J, Radkowski S, Dybala J. A model-based method for remaining useful life prediction of machinery. *IEEE Transactions on Reliability*. 2016;65(3):1314-1326.
- 38- Kumar A, Chinnam RB, Tseng F. An HMM and polynomial regression based approach for remaining useful life and health state estimation of cutting tools. *Computers & Industrial Engineering*. 2019;128:1008-1014.
- 39- Li Y, Li H, Wang B, Gu H. Rolling element bearing performance degradation assessment using variational mode decomposition and gath-geva clustering time series segmentation. *International Journal of Rotating Machinery*. 2017;2017:2598169.
- 40- Bektas O, Jones JA, Sankararaman S, Roychoudhury I, Goebel K. A neural network filtering approach for similarity-based remaining useful life estimation. *The International Journal of Advanced Manufacturing Technology*. 2019;101(1-4):87-103.
- 41- Singleton RK, Strangas EG, Aviyente S. Extended Kalman filtering for remaining-useful-life estimation of bearings. *IEEE Transactions on Industrial Electronics*. 2015;62(3):1781-1790.

67- Andre D, Nuhic A, Soczka-Guth T, Sauer DU. Comparative study of a structured neural network and an extended Kalman filter for state of health determination of lithium-ion batteries in hybrid electricvehicles. *Engineering Applications of Artificial Intelligence*. 2013;26(3):951-961.

68- Cui L, Wang X, Xu Y, Jiang H, Zhou J. A novel switching unscented Kalman filter method for remaining useful life prediction of rolling bearing. *Measurement*. 2019;135:678-684.

69- Li YS, Billington S, Zhang C, Kurfess T, Danyluk S, Liang S. Adaptive prognostics for rolling element bearing condition. *Mechanical Systems and Signal Processing*. 1999;13(1):103-113.

70- Hamilton JD. A new approach to the economic analysis of nonstationary time series and the business cycle. *Econometrica: Journal of the Econometric Society*. 1989;57(2):357-384.

71- Perlin M. MS_Regress-the Matlab package for markov regime switching models. SSRN. 2015 Apr.

72- Shafer G. A mathematical theory of evidence. Princeton: Princeton University Press; 1976.

73- Sentz K. Combination of evidence in Dempster-Shafer theory. Albuquerque: Sandia National Laboratories; 2002.

74- Nectoux P, Gouriveau R, Medjaher K, Ramasso E, Chebel-Morello B, Zerhouni N, et al. PRONOSTIA: An experimental platform for bearings accelerated degradation tests. *IEEE International Conference on Prognostics and Health Management, PHM'12*, Jun 2012, Denver, Colorado, United States. Villeurbanne: HAL; 2012.

59- Pham HT, Tran VT, Yang BS. A hybrid of nonlinear autoregressive model with exogenous input and autoregressive moving average model for long-term machine state forecasting. *Expert Systems with Applications*. 2010;37(4):3310-3317.

60- Song Y, Liu D, Yang C, Peng Y. Data-driven hybrid remaining useful life estimation approach for spacecraft lithium-ion battery. *Microelectronics Reliability*. 2017;75:142-153.

61- Zhou Y, Huang M. Lithium-ion batteries remaining useful life prediction based on a mixture of empirical mode decomposition and ARIMA model. *Microelectronics Reliability*. 2016;65:265-273.

62- Hinch AZ, Tkiouat M. Rolling element bearing remaining useful life estimation based on a convolutional long-short-term memory network. *Procedia Computer Science*. 2018;127:123-132.

63- Rai A, Upadhyay SH. The use of MD-CUMSUM and NARX neural network for anticipating the remaining useful life of bearings. *Measurement*. 2017;111:397-410.

64- Ali JB, Fnaiech N, Saidi L, Chebel-Morello B, Fnaiech F. Application of empirical mode decomposition and artificial neural network for automatic bearing fault diagnosis based on vibration signals. *Applied Acoustics*. 2015;89:16-27.

65- Samanta B, Al-Balushi KR. Artificial neural network based fault diagnostics of rolling element bearings using time-domain features. *Mechanical Systems and Signal Processing*. 2003;17(2):317-328.

66- Zheng X, Fang H. An integrated unscented Kalman filter and relevance vector regression approach for lithium-ion battery remaining useful life and short-term capacity prediction. *Reliability Engineering & System*