

پیش‌بینی عمر مفید یاتاقان غلتشی مبتنی بر آنالیز ارتعاشی باروش تجزیه سیگنال به مولفه مدهای ذاتی

در این تحقیق از روشی مبتنی بر پردازش سیگنال و هوش مصنوعی برای تخمین عمر باقی مانده یاتاقان استفاده شد. سیگنال‌ها توسط روش تجزیه مدهای ذاتی (EMD) پردازش شدند. سپس ده ویژگی استخراج شد. سپس از ویژگی‌های استخراجی جهت مدل‌سازی روش تخمین عمر باقی مانده استفاده شد. ضریب همبستگی بین مقدار پیش‌بینی شده توسط شبکه عصبی و مقدار واقعی به ازای ویژگی‌های استخراجی از روش EMD ۰/۹۲۶۰ به دست آمد. سپس شبکه عصبی به ازای ویژگی‌های برتر مدل‌سازی شد و نتایج نشان داد که ضریب همبستگی بین مقدار واقعی و مقدار پیش‌بینی شده برای روش و EMD ۰/۹۴۳۰۷ به دست آمد.

زهرا دهرویه^۱

کارشناس ارشد

شهرام اعتمادی حقیقی^۲

استادیار

سید اشکان موسویان^۳

استادیار

علی علی‌نیا زیازی^۴

استادیار

واژه‌های راهنما: یاتاقان، ارتعاشات، تخمین عمر، تجزیه مدهای ذاتی

۱- مقدمه

یاتاقان‌ها استعداد زیادی در جهت خرابی دارند، این امر به خاطر کار پیوسته و مداوم این المان‌ها می‌باشد. این استعداد تا حدی است که به یاتاقان‌ها به‌عنوان اجزاء مصرفی یک دستگاه نگریسته می‌شود [1]. برای دستگاه‌های کوچک و غیرکلیدی تا حدی خرابی متناوب یاتاقان‌ها در زمان‌های مشخص از طرف بخش نت (نگهداری و تعمیرات) یک کارخانه پذیرفتنی است. ولی در دستگاه‌ها و ماشین‌آلات بزرگ و کلیدی، جایی که امکان دارد خرابی یک موتور باعث از کار افتادگی خط یک محصول یا یک بخش از نیروگاه و عواقب دیگر شود تشخیص عیب یاتاقان‌ها به‌صورت به‌هنگام یا دوره‌ای می‌تواند باعث صرفه‌جویی در وقت و هزینه شود [2]. در کاربردهای صنعتی یاتاقان‌ها به‌عنوان اجزاء مکانیکی بحرانی شناخته می‌شوند و یک عیب اولیه در این اجزاء

^۱ کارشناس ارشد، گروه مهندسی مکانیک، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران marjandehrouyeh@gmail.com

^۲ نویسنده مسئول، استادیار، گروه مهندسی مکانیک، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران setemadi@srbiau.ac.ir

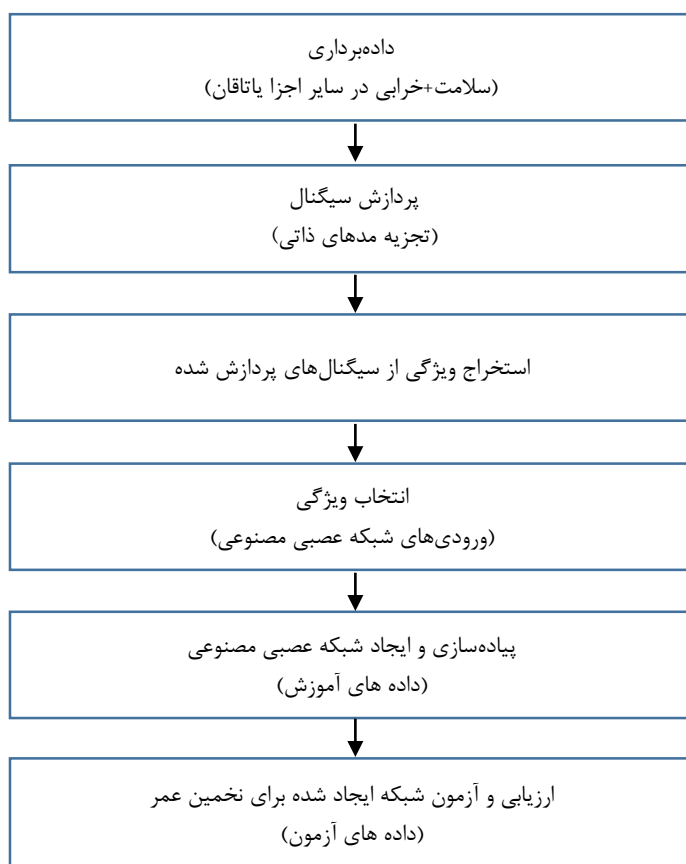
^۳ استادیار، گروه مهندسی کشاورزی، دانشگاه فنی و حرفه‌ای، تهران a_moosavian@tvu.ac.ir

^۴ استادیار، گروه مهندسی مکانیک، دانشگاه آزاد اسلامی، واحد علوم و تحقیقات، تهران Ali_alinia@yahoo.com


اگر به موقع تشخیص داده نشود به از کارافتادگی کلی دستگاه منجر می‌شود. عیوب یاتاقان‌ها امکان دارد در هنگام استفاده یا در هنگام فرآیند ساخت آن‌ها ایجاد شود و تشخیص این عیوب برای پایش وضعیت و نیز برای بالا بردن کیفیت بازرسی یاتاقان‌ها بسیار مهم است [3]. پس از تشخیص خرابی، پیش‌بینی عمر مفید باقیمانده قطعات گامی فراتر از پایش وضعیت است که اگر پیش‌بینی درستی از عمر مفید باقیمانده قطعات به عمل آید، می‌توان برنامه ریزی دقیقی برای زمان تعویض یا تعمیر آن تدوین کرد که به تبع آن، از تحمیل هزینه‌های سنگین خرابی‌ها و توقفات ناگهانی ماشین‌آلات و نیز زمان زیاد رسیدگی به خرابی و همچنین ضررهای جانی جلوگیری کرد. پیش‌بینی عمر مفید باقیمانده جهت یک نگهداری وابسته به شرایط اثربخش ضروری است و نقش مهمی در بهبود قابلیت اطمینان و هزینه‌های ناشی از تعمیرات و نگهداری دارد [4]. عمر مفید باقیمانده یک متغیر تصادفی است و مقادیر آن وابسته است به عمر جاری تجهیز و شرایط عملیاتی که در آن مشغول به کار است [5]. از طرفی جهت تخمین عمر باقیمانده باید از تکنیک‌های پایش وضعیت بهره گرفت. پایش وضعیت تجهیزات صنعتی با روش‌های متنوعی از قبیل آنالیز ارتعاشات، آنالیز صدا، آنالیز دمایی، آنالیز روغن و... انجام می‌گیرد [6]؛ که در این میان آنالیز ارتعاشات [7]، آنالیز صدا [8]، تلفیق داده‌های چند حسگری [9]، گرمانگاری [10] به ترتیب بیشترین اثرگذاری و کارایی در عیب‌یابی یاتاقان‌ها و پیش‌بینی عمر آن‌ها را داشته‌اند. در سال‌های اخیر استفاده از روش‌های پردازش سیگنال نقش چشمگیری در افزایش دقت عیب‌یابی و تخمین عمر مفید تجهیزات صنعتی داشته است که از جمله این روش‌ها می‌توان به تبدیل فوریه، تبدیل موجک، تجزیه مدهای ذاتی، تبدیل هیلبرت و Spectral Kurtosis اشاره کرد [6, 11-12]. در این راستا نیو و یانگ [13] در پژوهشی با استفاده از راهبرد تلفیق داده‌ها به پیش‌بینی عمر مفید باقیمانده (RUL) یک کمپرسور گاز متان پرداختند. آنها روش ماشین‌بردار پشتیبان و شبکه عصبی مصنوعی را به کار گرفته شد که بهترین نتایج در استفاده از ماشین‌بردار پشتیبان با دقت ۹۸/۷٪ به دست آمد. در تحقیقی الیو و همکاران [15] با استفاده از بررسی رفتار ارتعاشی عمر باقیمانده یک پمپ هیدرولیک را تخمین زدند. آنها رفتار ارتعاشی پمپ هیدرولیک را به صورت پیوسته از حالت سالم تا خرابی اندازه‌گیری کردند که با پایش رفتار ارتعاشی پمپ هیدرولیک و مقایسه آن با حد آستانه تعیین شده، عمر مفید باقیمانده پمپ هیدرولیک تخمین زده شد. لی و همکاران [16] از روش تلفیق داده‌های چندحسگری برای پیش‌بینی عمر مفید چرخ‌دنده‌ها در یک گیربکس سیاره‌ای استفاده کردند. به منظور تخمین عمر باقیمانده از روش انفیس استفاده شد. بررسی نتایج نشان داد بالاترین دقت روش ارائه شده برای تخمین عمر باقی مانده در چرخ‌دنده‌ها ۱۰۰٪ به دست آمد. گو و همکاران [17] در تحقیقی عیوب متداول در یاتاقان را با استفاده از پردازش سیگنال‌های ارتعاشی توسط تبدیل بسته‌ای موجک بررسی کردند. نتایج تشخیص عیب توسط روش SVM و شبکه عصبی به ترتیب برابر با ۹۵/۴۱٪ و ۸۲/۸۱٪ به دست آمد اما با تلفیق در حد تصمیم دقت کلی تشخیص عیب ۹۷/۴۴٪ افزایش یافت. لی و همکاران [18] در تحقیقی روشی مبتنی بر تلفیق ویژگی برای تشخیص عیوب یاتاقان ارائه کردند. آنها در این تحقیق از مدل شبکه عصبی مصنوعی کانولوشن استفاده کردند که این روش توانست با دقت ۹۹٪ عیوب یاتاقان را تشخیص دهد. سمانتا و البلوشی [19] در تحقیقی عیوب یاتاقان را با استفاده از تحلیل رفتار ارتعاشی بررسی کردند. آنها در این تحقیق از مدل‌های مختلف هوش مصنوعی استفاده کردند که در نهایت مدل شبکه عصبی با دقت ۹۸/۴٪ توانست عیوب مختلف یاتاقان را طبقه بندی کند. روی لی و همکاران [27] برای بهبود

تشخیص عیب یاتاقان غلتکی، از یک روش ترکیبی مبتنی بر مجموعه تکمیلی بهبود یافته تجزیه مدهای ذاتی (ICEEMDAN)، آنتروپی دینامیک غیرخطی و ESVM برای تشخیص چند عیب استفاده کرده و نتایج نشان داد که این روش، نتایج تشخیص عیب بهتری در مقایسه با روش های تشخیص عیب موجود دارد. جینگ بائو و همکاران [28] از روش های تشخیص عیب یاتاقان غلتشی براساس روش مجموعه تجزیه مدهای ذاتی (EEMD) آنتروپی جایگشت (PE)، تمایز خطی تجزیه و تحلیل تمایز خطی (LDA)، و الگوریتم Gath – Geva (GG) استفاده شده است و نتیجه این می باشد که با مقایسه روش های تشخیص عیب در این مقاله و روش های دیگر بهترین روش بهینه و بهره ور را انتخاب کرد.

مروری بر پیشینه تحقیق نشان می دهد که بیشتر روش های کاربردی برای تخمین عمر و تشخیص عیوب یاتاقان ها بر اساس بررسی سیگنال های زمانی است که اطلاعات کلی از وضعیت یاتاقان را می دهد، همچنین پیشتر از روش تجزیه مدهای ذاتی برای تشخیص عیب دریاتاقان استفاده شده است اما تحقیق حاضر با هدف ارائه روشی برای تخمین عمر باقی مانده یاتاقان با استفاده از تجزیه سیگنال به مولفه های ذاتی انجام شد. در این تحقیق سیگنال های ارتعاشی حاصل از کارکرد یاتاقان توسط روش تجزیه مدهای ذاتی پردازش شده و از خروجی های حاصل از پردازش ویژگی های آماری استخراج شد که در نهایت از ویژگی های استخراج شده، برای پیاده سازی الگوریتم هوش مصنوعی جهت پیش بینی عمر باقی مانده و معرفی دقیق ترین روش پیش بینی عمر مفید بر پایه مقایسه عملکرد استفاده شد. روند و مراحل مختلف تحقیق حاضر در شکل (۱) نشان داده شده است.



شکل ۱- فلوچارت تحقیق حاضر



شکل ۲- مجموعه آزمایشی پیاده‌سازی شده برای داده برداری [21]

۲- روش انجام تحقیق

۲-۱- مجموعه مورد آزمایش

در این تحقیق چهار یاتاقان بر روی یک محور نصب شدند و از طریق تسمه و پولی این محور یاتاقان‌ها با یک الکتروموتور AC کوپل شده و با سرعت ثابت ۲۰۰۰ دور در دقیقه گردش می‌کند. یک بار شعاعی به مقدار ۶۰۰۰ پوند از طریق مکانیسم فنر به محور اعمال شد. در شکل (۲) تصویر مجموعه مورد بررسی نشان داده شده است. نوع یاتاقان‌های استفاده شده در این تحقیق ZA-2115 بودند. این مدل یاتاقان فقط بار شعاعی را تحمل می‌کند و از نوع یاتاقان‌های دو ردیفه خود میزان از برند REXNORD بودند [21]. به منظور بررسی رفتار ارتعاشی از لحظه شروع به کار گردش یاتاقان‌ها تا مرحله ایجاد خرابی داده‌های ارتعاشی ضبط شدند. یاتاقان‌ها از ۱۲ فوریه ۲۰۰۴ ساعت ۱۰:۳۲:۳۹ شروع به کار کردند و در تاریخ ۱۹ فوریه ۲۰۰۴ ساعت ۶:۲۲:۳۹ مجموعه با پیدایش خرابی در خرابی قاب بیرونی در یاتاقان شماره ۱ پایان یافت. مجموعه داده برداری طوری برنامه ریزی شده بود که به ازای هر ۱۰ دقیقه ضبط دیتا آن را به عنوان یک داده ارتعاشی به طور جداگانه ذخیره می‌نمود. در طی مدت زمان کارکرد مجموعه ۹۸۴ سیگنال ارتعاشی ضبط شد.

۲-۲- پردازش سیگنال

در این تحقیق به منظور حذف اطلاعات ناخواسته (نویز) و همچنین استخراج اطلاعات مفید تشخیصی اقدام به پردازش سیگنال شد. برای این منظور از روش تجزیه مدهای ذاتی برای پردازش سیگنال‌های ارتعاشی یاتاقان استفاده گردید.

۲-۲-۱- تجزیه مدهای ذاتی

روش تجزیه مدهای ذاتی یا EMD^۱ نخستین بار در مطالعات مکانیک سیالات پیشنهاد شد و به سرعت کاربردهایی در علوم مهندسی پیدا کرد. بخش اصلی این روش فرایند الگ کردن برای تجزیه هر سری زمانی به

^۱ Empirical mode decomposition

مجموعه‌ای از اجزای^۱ AM-FM (مدولاسیون فرکانس و دامنه) یا IMF است. اجزای IMF حالت‌های نوسانی را بیان می‌کنند که در سیگنال قرار گرفته‌اند. در مورد تحلیل فوریه، اجزای IMF به صورت موج‌های سینوسی و کسینوسی تعریف می‌شوند. در روش EMD هر IMF سیگنالی است که شرایط زیر را برآورده کند [22]:

۱- در تمام سری زمانی، تعداد اکسترمم‌ها و تعداد عبور از صفرها باید برابر باشند یا حداکثر اختلاف یک داشته باشند.

۲- در هر نقطه از سری زمانی، مقدار میانگین پوش بالا و پایین سری زمانی برابر با صفر باشد. در روش EMD، سیگنال به بخش‌های زمان-مقیاس مختلفی تجزیه می‌شود. با این حال، روش EMD کاملاً بر اساس ماهیت داده عمل می‌کند و نیازی به توابع مادر از پیش تعیین شده ندارد. روش EMD، برای تجزیه سیگنال S(t) به IMF‌های تشکیل دهنده شامل مراحل زیر است:

۱- برای سیگنال S(t)، متغیر کمکی X و r_0 تعریف می‌شود و متغیر k که تعداد IMF‌ها است برابر با صفر قرار داده می‌شود.

۲- پس از تعیین بیشینه و کمینه‌های مطلق سیگنال، پوش‌های بالا^۲ (UE) و پایین^۳ (LE) آن به کمک اسپلاین مکعبی^۴ محاسبه می‌شوند.

۳- پوش میانگین m با محاسبه نقطه به نقطه میانگین حسابی از UE و LE محاسبه می‌شود.

۴- IMF کاندید h با محاسبه اختلاف بین X و m تخمین زده می‌شود.

۵- اگر h معیارهای تعریف شده برای یک IMF را نداشته باشد به عنوان x جدید در نظر گرفته می‌شود و مراحل ۲ تا ۴ تکرار می‌شود؛ در غیر این صورت روند کار با مرحله ۶ ادامه می‌یابد.

۶- اگر h یک IMF باشد به عنوان c_k ذخیره می‌شود (منظور از k جزء-k ام است).

۷- خطای مربعات میانگین^۵ (MSE) یا e_{k-1} بین دو IMF پشت سر هم c_k و c_{k-1} محاسبه، و با شرط توقف مقایسه می‌شود.

۸- مانده جزئی r_k به صورت اختلاف بین مانده جزئی قبلی r_{k-1} و c_k تخمین زده می‌شود و محتوای آن به عنوان متغیر X در نظر گرفته می‌شود و مراحل ۲ تا ۴ تکرار می‌شود.

۹- اگر شرط توقف برآورده شود فرایند الگ شدن به اتمام می‌رسد و مانده نهایی S(t) می‌تواند با محاسبه اختلاف بین S(t) و مجموع تمامی IMF‌ها محاسبه شود.

زمانی که فرایند الگ شدن متوقف می‌شود، سیگنال اولیه S(t) می‌تواند با n حالت نوسانی $c_k(t)$ و یک مانده نهایی $r_{final}(t)$ را به شکل زیر بیان شود:

$$S(t) = \sum_{k=1}^n C_k(t) + r_{final}(t) \quad (1)$$


¹ Amplitude modulation-Frequency Modulation

² Upper Envelope

³ Lower Envelope

⁴ Cubic Spline

⁵ Mean Square Error



شکل ۳- روال اعمال EMD بر روی یک سیگنال (a): مجموع دو سیگنال. b: پوش‌های بالا و پایین. c: اولین IMF. d: اولین باقی‌مانده از سیگنال اصلی) [23]

در این تحقیق از هشت زیرباند (IMF) آخر حاصل از تجزیه سیگنال توسط روش EMD استفاده شد که این هشت زیرباند نماینده سیگنال اصلی هستند.

۳-۲- استخراج، انتخاب و تلفیق ویژگی

پس از پردازش سیگنال، به منظور به دست آوردن مقادیر قابل مقایسه، لازم است ویژگی‌هایی از سیگنال‌های پردازش شده استخراج شود. در این میان، ویژگی‌های آماری جزو ویژگی‌های پرکاربرد و کارا در تشخیص و پیش‌بینی عیوب هستند که تحقیقات فراوانی از آنها تاکنون بهره برده اند [25]. بدین منظور در این تحقیق از ده ویژگی میانگین^۱، انحراف معیار^۲، جذر میانگین مربعات^۳، مقدار دامنه قله سیگنال، ضریب تیزی^۴، واریانس^۵، ضریب پراکندگی، لغزش، چولگی^۶ و کورتوسیس^۷ که ویژگی‌های کارا برای یاتاقان‌ها هستند، استفاده شد. از این پس، ویژگی‌ها با F برچسب گذاری شدند. اما برای برچسب گذاری ویژگی‌هایی که از بخش‌های مختلف سیگنال به دست می‌آیند مطابق جدول (۱) ویژگی‌ها برچسب گذاری شدند. به عنوان مثال ویژگی F1-IMF2 یعنی میانگین استخراجی از IMF.

جدول ۱- برچسب گذاری ویژگی‌ها

توضیحات	برچسب
برچسب ویژگی‌ها	F1, F2, ..., F10
برچسب مدهای ذاتی از سطح یک تا سطح n	IMF1, IMF2, ..., IMFn

¹ mean

² Standard deviation

³ Root mean square

⁴ Crest Factor

⁵ Variance

⁶ Skewness

⁷ Kurtosis

در این روش پس از جمع‌آوری و پردازش سیگنال‌ها، ابتدا ویژگی‌های تعریف‌شده از آن‌ها استخراج می‌گردد. این عملیات می‌بایست بر روی داده‌های خروجی از هر حسگر انجام پذیرد. ویژگی‌های استخراج‌شده از هر روش پردازش سیگنال در واقع مجموعه‌ای از توابع هستند که معرف تعابیر خاصی از یک سیگنال می‌باشند که آن را از سایرین متمایز می‌نماید. بسیاری از ویژگی‌ها معمولاً با یک الگوریتم یادگیری برای تولید خصوصیات کامل عمل طبقه‌بندی تهیه می‌شوند. با این حال، در اغلب موارد بسیاری از ویژگی‌ها کاندید برای عمل یادگیری، نامربوط و زائد هستند و کارایی الگوریتم یادگیری را کاهش می‌دهند. ممکن است دقت یادگیری (طبقه‌بندی) و سرعت آموزش به میزان قابل توجهی با این ویژگی‌های زائد بدتر شود. انتخاب ویژگی که به عنوان انتخاب زیر مجموعه نیز شناخته می‌شود، فرایندی است که معمولاً در یادگیری ماشین، در جایی که یک زیر مجموعه از ویژگی‌ها از داده‌ها برای کاربرد یک الگوریتم یادگیری انتخاب شده است، استفاده می‌شود.

۴-۲- شبکه‌های عصبی مصنوعی

ایجاد یک سیستم هوش مصنوعی که توانایی یادگیری، خلاقیت و انعطاف‌پذیری انسان را داشته باشد، هدف اصلی تحقیقات در ارتباط با هوش مصنوعی می‌باشد. اصلی‌ترین جزء شبکه عصبی سلول نام دارد. اساساً سلول‌های بیولوژیکی با دریافت ورودی‌ها از برخی منابع، آن‌ها را از طرق مختلفی با یکدیگر ترکیب می‌نمایند و سپس با انجام عملیات غیرخطی بر روی نتایج، خروجی نهایی را ارائه می‌نمایند. ورودی در وزن مربوط به خودش ضرب می‌گردد. در ساده‌ترین حالت خروجی‌ها و بایاس‌ها با یکدیگر جمع و سپس از تابع فعالسازی جهت تولید خروجی‌ها عبور می‌نمایند. شکل (۴) پردازش اطلاعات را در یک سلول شبکه عصبی نشان می‌دهد [26]. شبکه‌های دارای بایاس، رابطه بین ورودی‌ها و خروجی‌ها را راحت‌تر از شبکه‌های بدون بایاس بدست می‌آورند. در شکل (۴)، خروجی برای سلول α به صورت رابطه (۶) می‌باشد [26]:

$$\alpha_i = f \left(\sum_{j=1}^n X_j W_{ij} \right) \quad (5)$$

توابع فعالسازی به طور کلی از روابط جبری خطی و یا غیرخطی تشکیل شده‌اند. مهمترین مرحله در شبکه‌های عصبی، بخش آموزش شبکه می‌باشد. در حالت کلی دو روش مختلف برای آموزش شبکه وجود دارد که عبارت‌اند از: آموزش کنترل پذیر و آموزش غیرقابل کنترل. مرسوم‌ترین الگوریتم آموزش، الگوریتم آموزشی پس انتشار خطا می‌باشد. شبکه عصبی به کمک الگوریتم پس انتشار خطا از طریق تغییر وزن لایه‌های میانی آموزش می‌بیند و این تغییرات به عنوان مفروضات شبکه ذخیره می‌گردند. برخی از روش‌های آماری نظیر ریشه میانگین مربعات خطا (RMSE) و میانگین مربعات خطا (MSE) جهت بررسی صحت نتایج مورد استفاده قرار می‌گیرند. خطا در طول آموزش با این دو پارامتر مشخص می‌شود که به صورت روابط (۶) و (۷) محاسبه می‌گردند [26]:

$$RMS = \left(\left(\frac{1}{n} \right) \sum_j |t_j - O_j|^2 \right)^{\frac{1}{2}} \quad (۶)$$

$$MSE = \frac{1}{n} \sum_{j=1}^n (t_j - o_j)^2 \quad (۷)$$

که در آن t مقدار هدف (پیش‌بینی شده)، O مقدار خروجی (مشاهده شده) و n بیانگر تعداد خروجی‌های شبکه عصبی (تعداد مشاهدات) می‌باشد. جهت افزایش دقت و یادگیری شبکه، مقادیر ورودی و خروجی به شبکه عصبی بین $[-1, 1]$ نرمالیزه می‌شوند [4]. در تحقیق حاضر برای تخمین باقی‌مانده عمر مفید یاتاقان از شبکه عصبی مصنوعی استفاده شد. در این تحقیق از روش آموزشی لوببرگ-مارکوئت (Levenberg-Marquardt) برای پیاده‌سازی شبکه عصبی مصنوعی برای تخمین عمر باقی‌مانده یاتاقان استفاده شد. در این تحقیق ۷۰٪ از داده‌ها برای آموزش شبکه عصبی و ۳۰٪ برای آزمون و ارزیابی به کار برده شد. شبکه عصبی مورد استفاده در این تحقیق از نوع شبکه عصبی پرسپترون سه لایه بود. لایه اول شامل ویژگی‌های منتخب بود. لایه خروجی عمر باقی‌مانده یاتاقان و در لایه میانی نیز ۱۰ نرون در نظر گرفته شد. هدف از استفاده از شبکه عصبی، پیاده‌سازی مدلی جهت یافتن یک ارتباط منطقی بین ورودی‌های مدل و خروجی آن است تا بتوان از طریق این رابطه به راحتی عمر باقی‌مانده یاتاقان را پیش‌بینی کرد.

۳- نتایج و بحث

۳-۱- رفتار ارتعاشی مجموعه


بعد از ایجاد خرابی در یاتاقان‌ها و توقف داده برداری، مشاهده شد که عیب ایجاد شده در یاتاقان، خرابی در قاب بیرونی یاتاقان A بوده است. لذا عیب مورد بررسی در تحقیق حاضر خرابی در قاب بیرونی یاتاقان است. در شکل ۵، رفتار ارتعاشی یاتاقان A نشان داده شده است و هدف از ارائه طیف ارتعاشی ایجاد مقایسه ای بین رفتار ارتعاشی حالت سلامت و خرابی در یاتاقان A است. تغییرات دامنه ارتعاشات در سیگنال ارتعاشی یاتاقان A سیر صعودی با شیب بسیار کمی دارد اما در مرحله ایجاد خرابی این افزایش دامنه با شیب تندی تغییر کرده است که مقدار دامنه آن در مقایسه با حالت کارکرد سالم یاتاقان تقریباً ده برابر شده است (شکل ۵). نتیجه‌ای که از تحلیل رفتار ارتعاشی سیگنال در حوزه زمان گرفته شد این است که هر چه مدت زمان کارکرد یاتاقان بیشتر باشد دامنه ارتعاشی آن افزایش خواهد یافت و این موضوع نشان از استهلاک یاتاقان و افزایش اصطکاک بین اجزاء یاتاقان دارد که به تبع این موضوع سبب افزایش دامنه ارتعاشات در یاتاقان شده است.

۳-۲- نتایج پردازش سیگنال


۳-۲-۱- تجزیه مدهای ذاتی

در شکل (۶) و (۷) تجزیه سیگنال‌های ارتعاشی به مؤلفه‌های ذاتی در حالت سلامت یاتاقان و حالت خراب نشان داده شده است. بررسی و مقایسه تجزیه سیگنال‌های ارتعاشی نشان داد که مؤلفه‌های فرکانس پایین در

حالت‌های مختلف در یاتاقان تقریباً رفتار مشابهی دارند. با توجه به نکات ارائه‌شده عیوب یاتاقان خود را در فرکانس‌های بالا نشان می‌دهند و رفتار کلی یاتاقان که در حالت‌های مختلف یکسان است و در فرکانس‌های پایین حادث می‌شود. با مقایسه کمی دامنه‌ها در حالت سلامت و خرابی مشاهده میکنیم که برای هر IMF دامنه فرکانس در حال تغییر می‌باشد، به طور مثال برای IMF1 در حالت سالم، دامنه فرکانس بین بازه $[-0.2, +0.2]$ می‌باشد و در حالت خراب دامنه فرکانس به بازه $[-5, +5]$ تغییر می‌یابد، این مورد برای IMF2~IMF8 نیز تکرار می‌شود و در هر IMF بازه دامنه فرکانس در مرحله خرابی نسبت به حالت سالم افزایش می‌یابد لذا آنچه مسلم است دامنه نوسانات همه مولفه‌های بدست آمده برای یاتاقان معیوب تقریباً ده برابر مقدار این مولفه‌ها برای یاتاقان سالم است. از طرفی مقایسه مدهای تجربی یا مؤلفه‌های ذاتی نشان می‌دهد که بیشترین تفاوت در سیگنال‌های ارتعاشی برای حالت‌های مختلف عیوب مربوط به مدهایی با فرکانس بالا است.



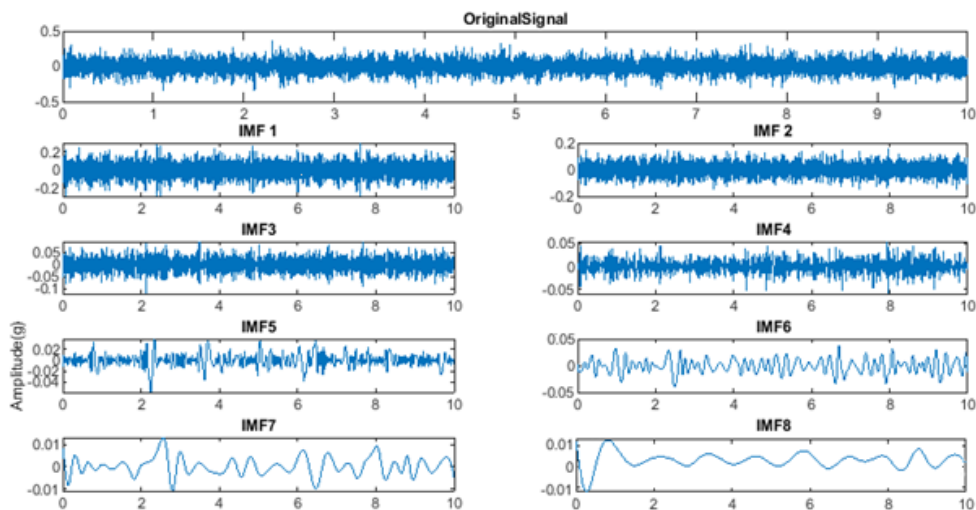
شکل ۴- پردازش اطلاعات در یک سلول شبکه عصبی [26].



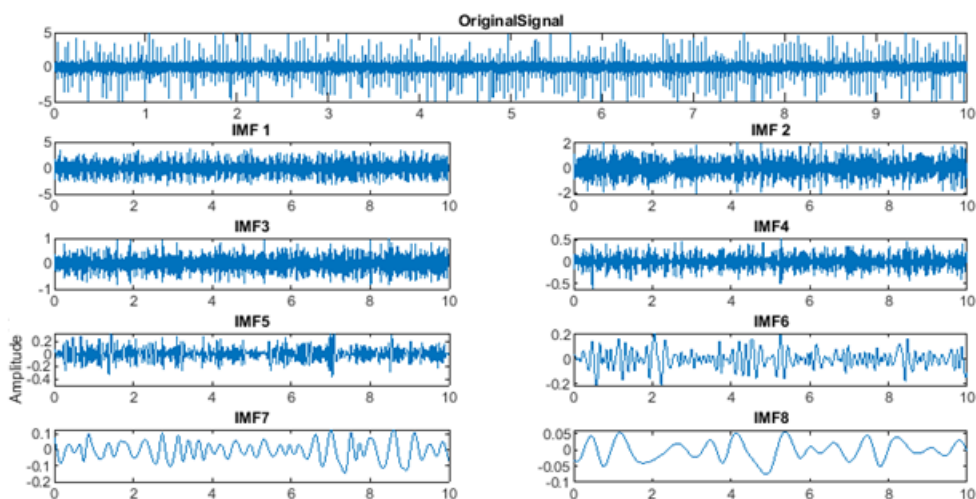
شکل ۵- رفتار ارتعاشی یاتاقان A قبل (بالا) و بعد (پایین) از خرابی

۳-۳- استخراج و انتخاب ویژگی

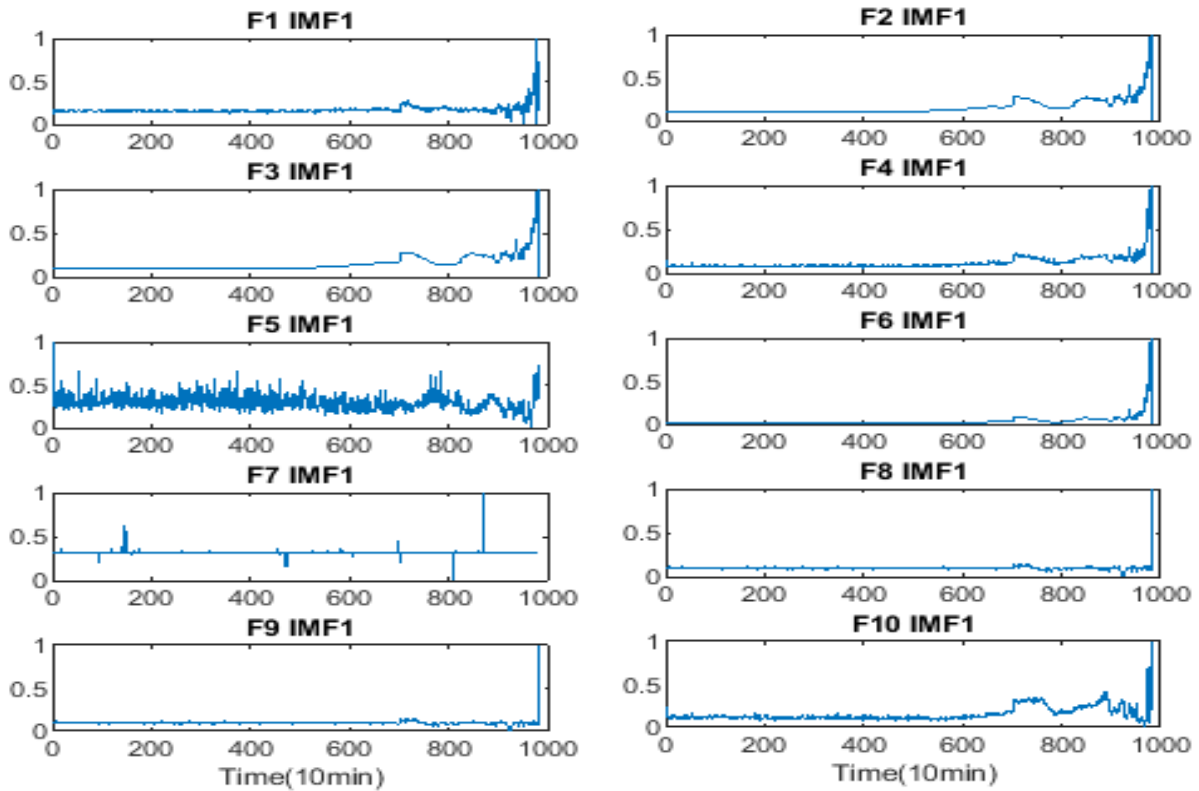
از سیگنال‌های پردازش شده توسط روش EMD ده ویژگی استخراج شد. ویژگی‌ای مطلوب است که با گذشت زمان از کارکرد یاتاقان مقدار آن یا صعودی یا نزولی باشد و اگر یک ویژگی با گذشت زمان مقدار آن ثابت باشد و از الگوی خاصی پیروی نکند آن ویژگی نمی‌تواند حاوی اطلاعات مفیدی برای تخمین عمر باقی‌مانده یاتاقان باشد. در مجموع از ۸۰ ویژگی استخراج شده از روش EMD، هفت ویژگی به عنوان ویژگی‌های بهینه انتخاب شد. معیار انتخاب ویژگی‌های برتر براساس تغییرات مقادیر این ویژگی‌ها و اختلاف مقدار ابتدایی و انتهایی و روند صعودی و نزولی آنها (شکل ۸ تا ۱۵) است. با گذشت زمان، اختلاف مقادیر سیگنال‌ها با توجه به روند صعودی و نزولی از حالت سالم تا ایجاد خرابی، نمایانگر این می‌باشد که این ویژگی می‌تواند به عنوان ویژگی بهینه برای پیش‌بینی عمر باقی‌مانده انتخاب گردد. بررسی تغییرات ویژگی‌های استخراج شده از خروجی روش EMD برای مقادیر مختلف IMFها نشان داد که ویژگی‌های برتر انتخابی -F10-IMF1, F4-IMF1, F2-IMF2, F3-IMF2 و F1-IMF1 بودند.



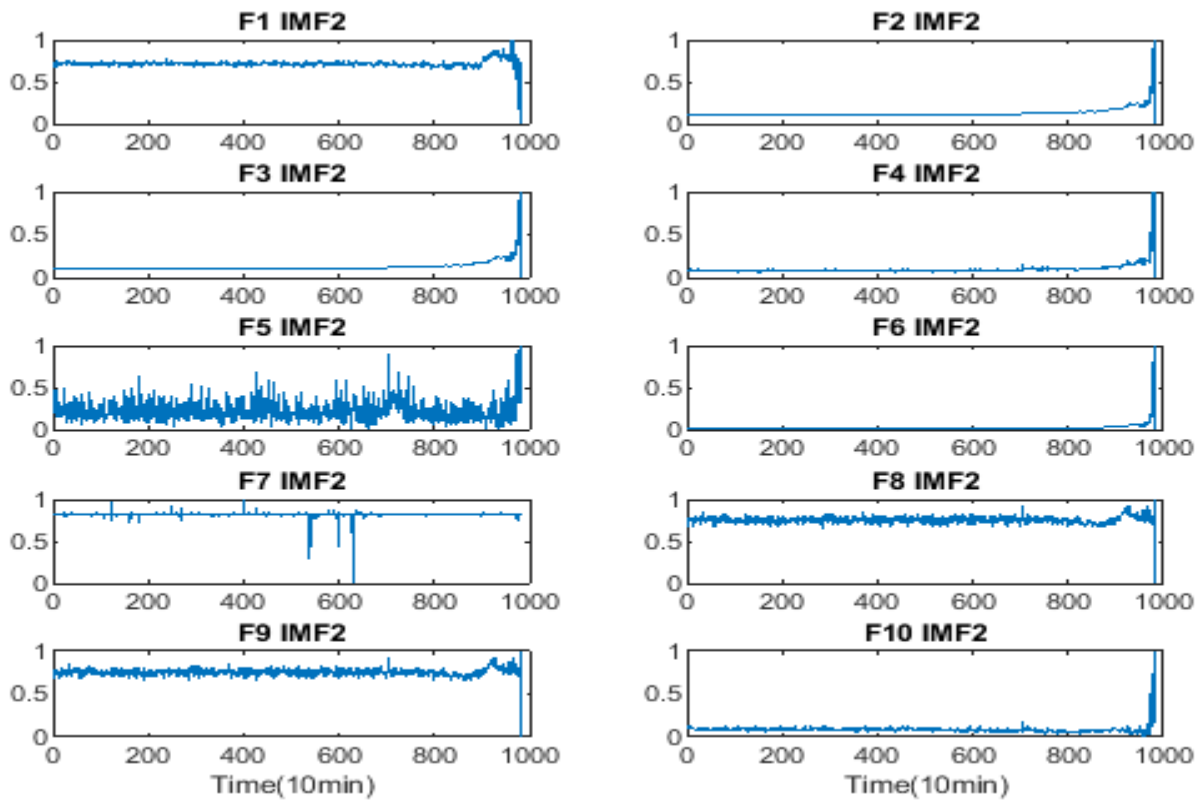
شکل ۶- تجزیه سیگنال ارتعاشی یاتاقان در حالت سالم توسط روش EMD



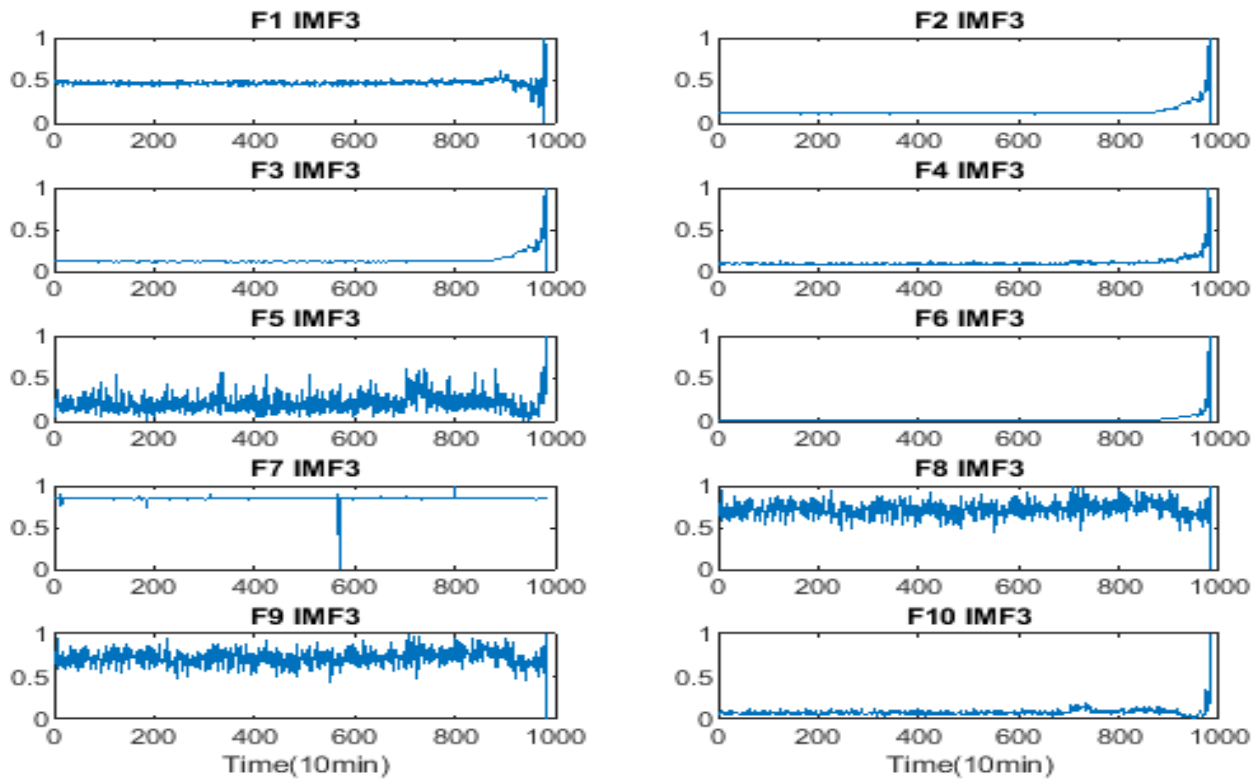
شکل ۷- تجزیه سیگنال ارتعاشی یاتاقان در حالت خرابی توسط روش EMD



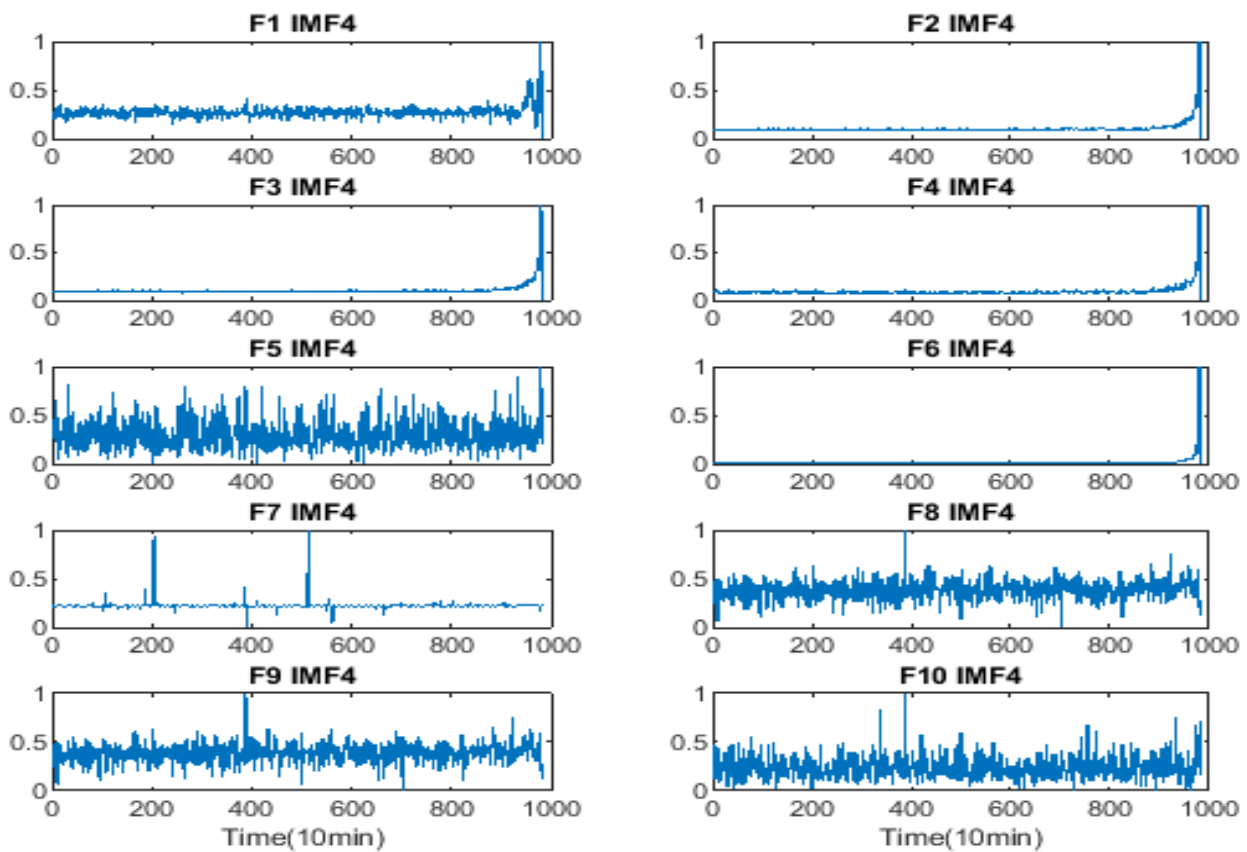
شکل ۸- تغییرات ویژگی‌های استخراج شده از IMF1



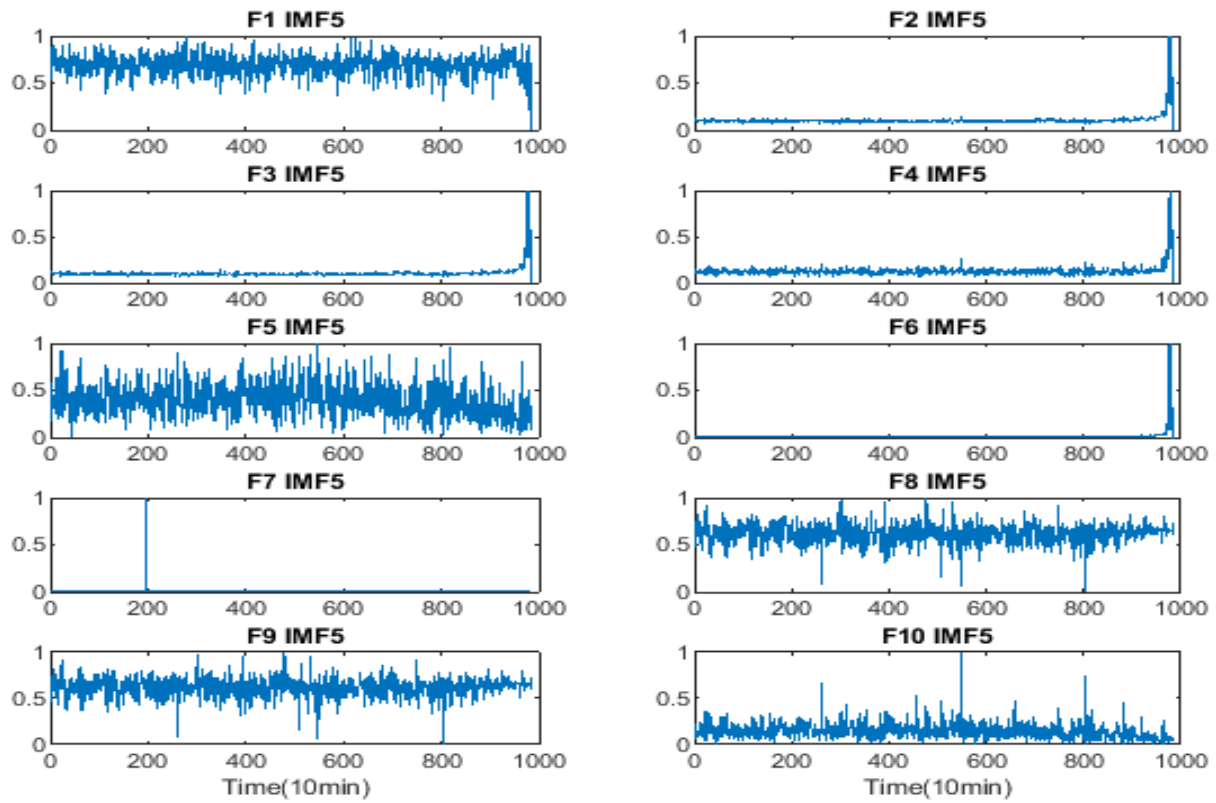
شکل ۹- تغییرات ویژگی‌های استخراج شده از IMF2



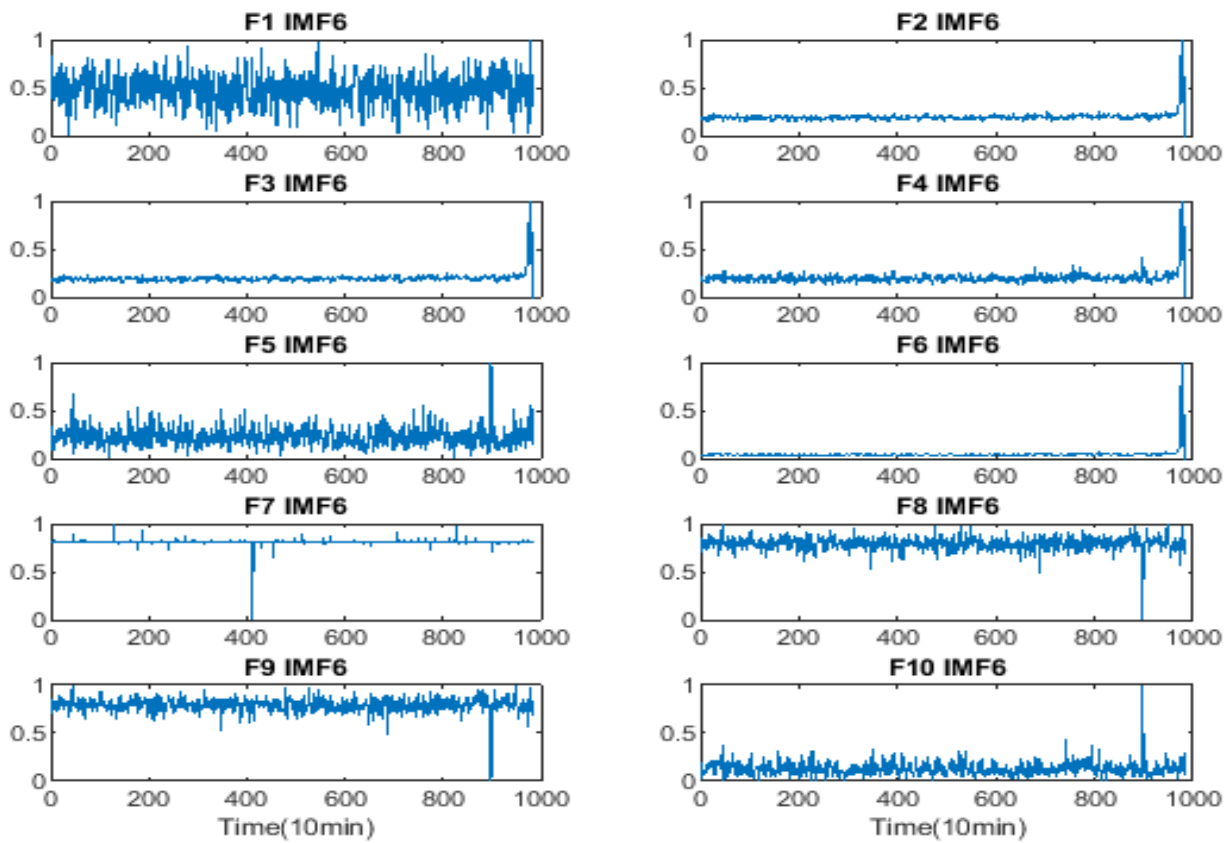
شکل ۱۰- تغییرات ویژگی‌های استخراج شده از IMF3



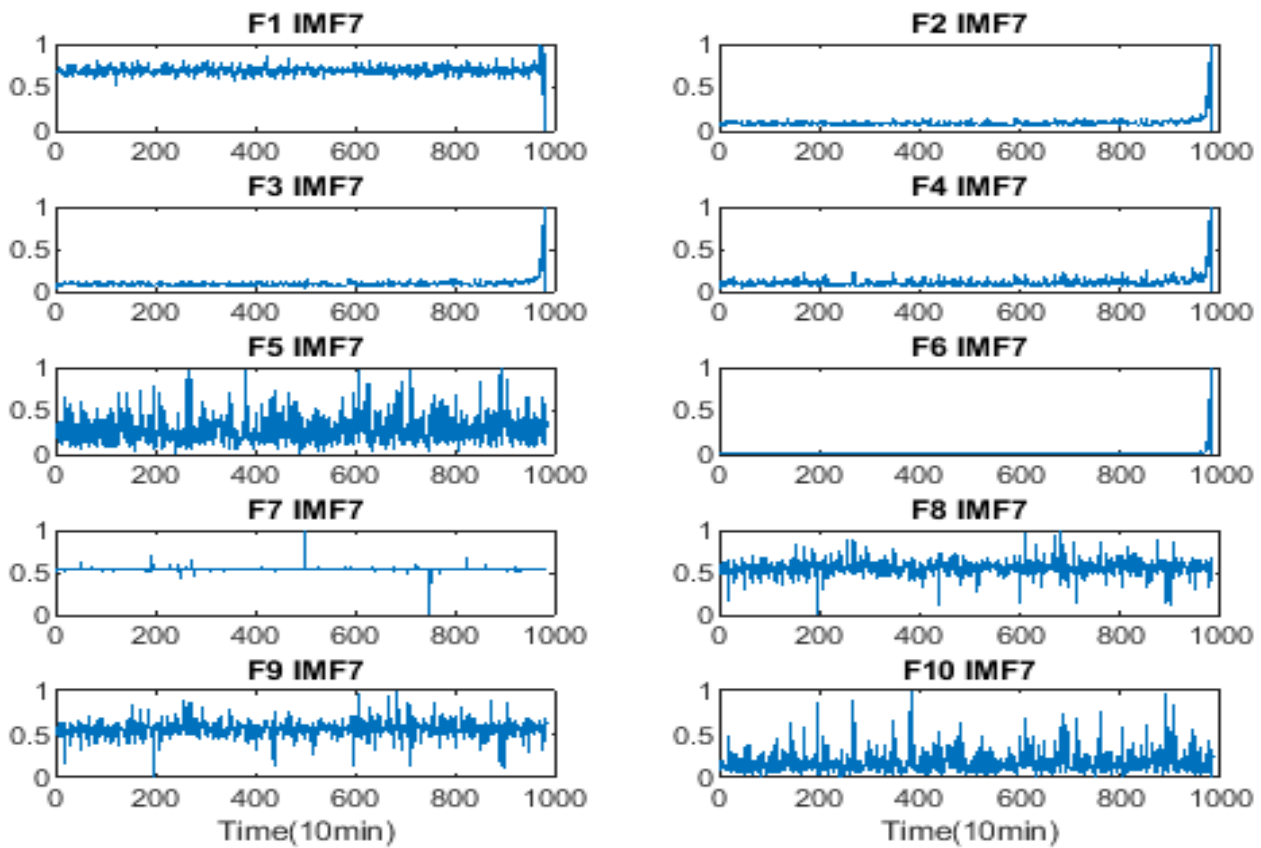
شکل ۱۱- تغییرات ویژگی‌های استخراج شده از IMF4



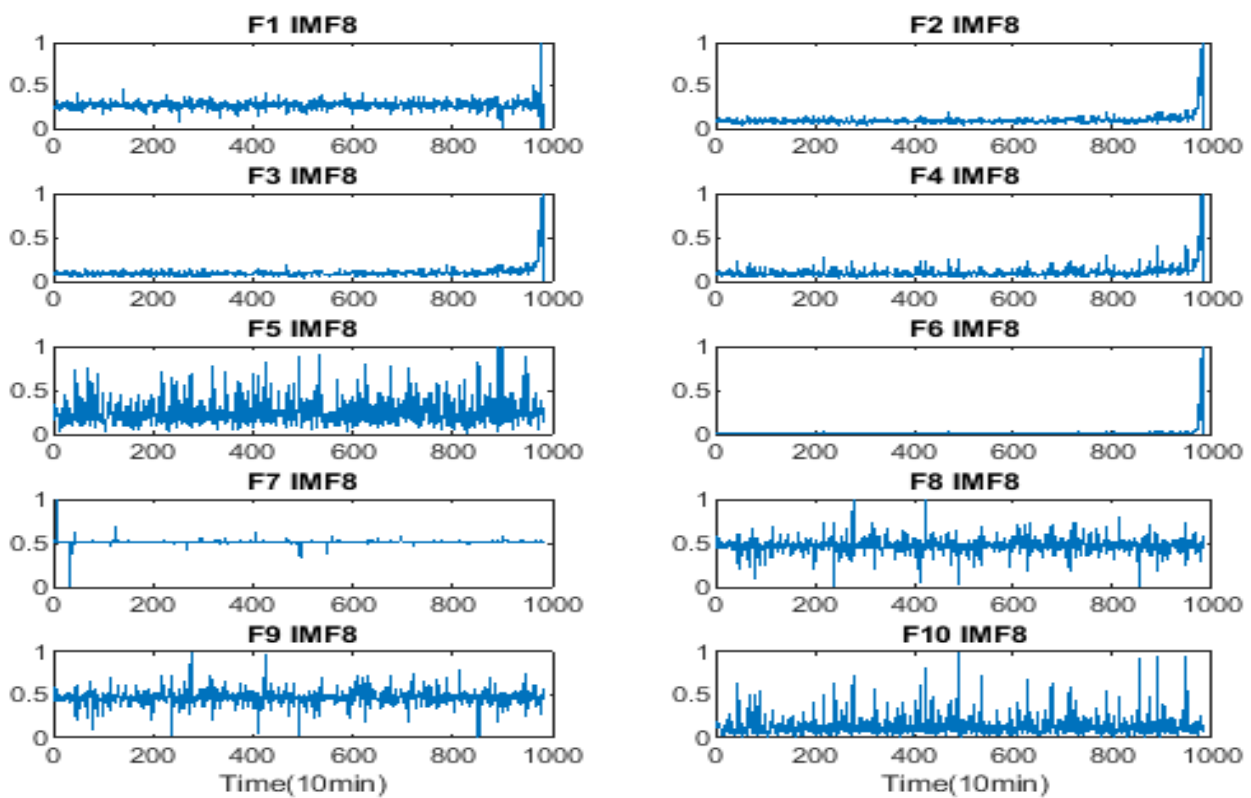
شکل ۱۲- تغییرات ویژگی‌های استخراج شده از IMF5



شکل ۱۳- تغییرات ویژگی‌های استخراج شده از IMF6



شکل ۱۴- تغییرات ویژگی‌های استخراج شده از IMF7




شکل ۱۵- تغییرات ویژگی‌های استخراج شده از IMF8


۳-۴- تخمین عمر باقی مانده یاتاقان

ابتدا با استفاده از کل ویژگی‌ها شبکه عصبی آموزش داده شد و نتایج پیاده سازی شبکه عصبی به ازای ویژگی‌های استخراجی از روش تجزیه مدهای ذاتی در شکل (۱۶) نشان داده شده است. مقدار ضریب همبستگی برای شبکه عصبی مدل شده با ویژگی‌های استخراجی از روش تجزیه مدهای ذاتی به ازای داده‌های آموزش، ارزیابی و آزمون به ترتیب ۰/۹۴۹۵، ۰/۸۸۲۵ و ۰/۸۶۶۸ به دست آمد.

نتایج حاصل از پیاده سازی شبکه عصبی با ویژگی‌های منتخب در شکل (۱۷) ارائه شده است. عملاً نتایج نشان داد که با حذف ویژگی‌های اضافی و انتخاب ویژگی‌های منتخب در روش تجزیه مدهای ذاتی مقدار دقت شبکه عصبی در پیش‌بینی عمر مفید باقی مانده افزایش یافت به طوری که مقدار ضریب همبستگی برای کل داده‌ها برای قبل و بعد از انتخاب ویژگی به ترتیب ۰/۹۲۶۰۸ و ۰/۹۴۳۰۷ بود. روش انتخاب ویژگی و ویژگی برتر نشان داد که در هر روش پردازش سیگنال یک سری اطلاعات منحصر به فرد استخراج می‌شود که دارای نشانه‌هایی از وجود عیب و خرابی یاتاقان است لذا با انتخاب ویژگی برتر این نشانه‌ها می‌توان به دقت‌های بیشتری در تخمین عمر باقی مانده دست یافت به همین دلیل پیشنهاد می‌گردد در تمامی تحقیقات انجام شده در این حوزه از چندین روش پردازش سیگنال استفاده کرده و در نهایت با انتخاب ویژگی‌های برتر استخراجی می‌توان دقت کلی را افزایش داد.



شکل ۱۶- همبستگی بین مقدار پیش‌بینی شده عمر باقی مانده یاتاقان توسط شبکه عصبی و مقدار واقعی به ازای ویژگی‌های استخراجی از روش تجزیه مدهای ذاتی



شکل ۱۷- همبستگی بین مقدار پیش‌بینی شده عمر باقی مانده یاتاقان توسط شبکه عصبی و مقدار واقعی به ازای ویژگی‌های منتخب استخراجی در روش تجزیه مدهای ذاتی

۵-۳- نتیجه‌گیری

بررسی شکل ظاهری سیگنال‌های ارتعاشی نشان داد که با گذشت زمان از کارکرد یاتاقان، سطح و دامنه ارتعاشات تولیدی افزایش می‌یابد اما این افزایش دامنه ارتعاشی تا قبل از خرابی در یاتاقان داری شیب تغییرات خیلی کمی است. در تخمین عمر باقی‌مانده یاتاقان از شبکه عصبی مصنوعی استفاده شد. شبکه عصبی مصنوعی با دو روش مختلف ارزیابی شد. در روش اول با استفاده از تمام ویژگی‌ها برای پیش‌بینی عمر یاتاقان در روش تجزیه مدهای ذاتی شبکه عصبی پیاده سازی شد. در مرحله بعد شبکه عصبی با ویژگی‌های منتخب پیاده سازی شد که در مقایسه با حالت اول دقت شبکه عصبی به ازای ویژگی‌های برتر روش تجزیه مدهای ذاتی افزایش یافت که این موضوع نشان داد که با کاهش ابعاد ورودی به شبکه عصبی می‌توان دقت آن را بهبود داد.

مراجع

- [1] Hamadache, M., and Lee, D., "Principal Component Analysis Based Signal-to-noise Ratio Improvement for Inchoate Faulty Signals: Application to Ball Bearing Fault Detection", *International Journal of Control, Automation and Systems*, Vol. 15, No. 2, pp. 506-517, (2017).
- [2] Hinch, A.Z., and Tkiouat, M., "Rolling Element Bearing Remaining Useful Life Estimation Based on a Convolutional Long-short-term Memory Network, *Procedia Computer Science*, Vol. 127, pp. 123-132, (2018).
- [3] Zhu, J., Chen, N., and Peng, W., "Estimation of Bearing Remaining Useful Life Based on Multiscale Convolutional Neural Network, *IEEE Transactions on Industrial Electronics*, Vol. 66, No. 4, pp. 3208-3216, (2018).
- [4] Ammar, D.M., Younes, M.A., and Elsayed, E.S., "Prediction of Bearing Remaining Useful Life Based on Euclidean Distance using an Artificial Neural Network Approach", *Proceedings of the Fifth International Conference on Advances in Mechanical and Robotics Engineering (AMRE)*, Rome, Italy, (2017).
- [5] Si, X.S., Wang, W., Hu, C.H., and Zhou, D.H., "Remaining Useful Life Estimation—A Review on the Statistical Data Driven Approaches", *European Journal of Operational Research*, Vol. 213, No. 1, pp. 1-14, (2011).
- [6] Eftekharnjad, B., and Mba, D., "Seeded Fault Detection on Helical Gears with Acoustic Emission", *Applied Acoustics*, Vol. 70, No. 4, pp. 547-555, (2009).
- [7] Faghidi, H., and Liang, M., "Bearing Fault Identification by Higher Order Energy Operator Fusion: A Non-resonance Based Approach", *Journal of Sound and Vibration*, Vol. 381, pp. 83-100, (2016).

- [8] Wang, W.J., Cui, L.L., and Chen, D.Y, "Multi-scale Morphology Analysis of Acoustic Emission Signal and Quantitative Diagnosis for Bearing Fault", *Acta Mechanica Sinica*, Vol. 32, No. 2, pp. 265-272, (2016).
- [9] Chen, S.L., Craig, M., Wood, R.J.K., Wang, L., Callan, R., and Powrie, H.E.G., "Bearing Condition Monitoring using Multiple Sensors and Integrated Data Fusion Techniques", In 9th International Conference in Vibrations in Rotating Machinery, Oxford, United Kingdom, pp. 586-600, (2008).
- [10] Schulz, R., Verstockt, S., Vermeiren, J., Loccufier, M., Stockman, K., and Van Hoecke, S., "Thermal Imaging for Monitoring Rolling Element Bearings", In 12th International Conference on Quantitative Infrared Thermography, July 7-11, Bordeaux, France, pp. 7-11, (2014).
- [11] Da Silva Vicente, S.A., Fujimoto, R.Y., and Padovese, L.R., "Rolling Bearing Fault Diagnostic System using Fuzzy Logic", In 10th IEEE International Conference on Fuzzy Systems, December 2, Melbourne, Australia, Vol. 2, pp. 816-819, (2001).
- [12] Safizadeh, M.S., and Latifi, S.K., "Using Multi-sensor Data Fusion for Vibration Fault Diagnosis of Rolling Element Bearings by Accelerometer and Load Cell", *Information Fusion*, Vol. 18, pp. 1-8, (2018).
- [13] Niu, G., and Yang, B.S., "Dempster-shafer Regression for Multi-step-ahead Time-series Prediction Towards Data-driven Machinery Prognosis", *Mechanical Systems and Signal Processing*, Vol. 23, No. 3, pp. 740-751, (2009).
- [14] Yu, M., Wang, D., and Luo, M., "Model-based Prognosis for Hybrid Systems with Mode-dependent Degradation Behaviors", *IEEE Transactions on Industrial Electronics*, Vol. 61, No. 1, pp. 546-54, (2013).
- [15] Liu, Q., Dong, M., Lv, W., Geng, X., and Li, Y., "A Novel Method using Adaptive Hidden Semi-markov Model for Multi-sensor Monitoring Equipment Health Prognosis", *Mechanical Systems and Signal Processing*, Vol. 64, pp. 217-32, (2015).
- [16] Lei, Y., Lin, J., He, Z., and Kong, D., "A Method Based on Multi-sensor Data Fusion for Fault Detection of Planetary Gearboxes", *Sensors*, Vol. 12, No. 2, pp. 2005-17, (2012).
- [17] Gu, Y.K., Zhou, X.Q., Yu, D.P., and Shen, Y.J., "Fault Diagnosis Method of Rolling Bearing using Principal Component Analysis and Support Vector Machine", *Journal of Mechanical Science and Technology*, Vol. 32, No. 11, pp. 5079-88, (2018).
- [18] Li, H., Huang, J., and Ji, S., "Bearing Fault Diagnosis with a Feature Fusion Method Based on an Ensemble Convolutional Neural Network and Deep Neural Network", *Sensors*, Vol. 19, No. 9, pp. 2034, (2019).
- [19] Samanta, B., and Al-Balushi K.R., "Artificial Neural Network Based Fault Diagnostics of Rolling Element Bearings using Time-domain Features", *Mechanical Systems and Signal Processing*, Vol. 17, No. 2, pp. 317-28, (2003).

- [20] Farokhzad, S., Ahmadi, H., Jaefari, A., Abad, M.R., and Kohan, M.R., "Artificial Neural Network Based Classification of Faults in Centrifugal Water Pump", *Journal of Vibroengineering*, Vol. 14(4), pp. 1734-1744, (2012).
- [21] Qiu, H., Lee, J., Lin, J., and Yu, G., "Wavelet Filter-based Weak Signature Detection Method and its Application on Rolling Element Bearing Prognostics", *Journal of Sound and Vibration*", Vol. 289, No. 4-5, pp. 1066-90, (2006).
- [22] Naji, M., Firouzabadi, S.M., and Kahrizi, S., "Empirical Mode Decomposition-based Elimination of Electrocardiogram Artifact from Electromyogram Signals", *Iranian Journal of Biomedical Engineering*, Vol. 7, No. 1, pp. 13-20, (2013).
- [23] Oonincx, P.J., and Hermand, J.-P., "Empirical Mode Decomposition of Ocean Acoustic Data with Constraint on the Frequency Range", In *Proceedings of the 7th European Conference on Underwater Acoustics (ECUA)*, July 5-8, Delft, The Netherlands, (2004).
- [24] Antoni, J., "The Spectral Kurtosis: A Useful Tool for Characterizing Non-stationary Signals", *Mechanical Systems and Signal Processing*", Vol. 20, No. 2, pp. 282-307, (2006).
- [25] Lou, X., and Loparo, K.A., "Bearing Fault Diagnosis Based on Wavelet Transform and Fuzzy Inference", *Mechanical Systems and Signal Processing*", Vol. 18, No. 5, pp. 1077-95, (2004).
- [26] Poor Asiabi, H., Poor Asiabi, H., and Saghafian, H., "Application of Multi-layered Perceptron Artificial Neural Networks in Estimating the Phase of Full Carbon Residual Austenite in Austempered Cast Iron", *Journal of Advanced Process in Materials Engineering*, Vol. 6, No. 2, pp. 71-82, (2012).
- [27] Li, R., Ran, C., Zhang, B., Han, L., and Feng, S., "Rolling Bearings Fault Diagnosis Based on Improved Complete Ensemble Empirical Mode Decomposition with Adaptive Noise, Nonlinear Entropy, and Ensemble SVM", *Applied Sciences*, Vol. 10, No. 16, pp. 5542, (2020).
- [28] Hou, J., Wu, Y., Gong, H., Ahmad, A.S., and Liu, L., "A Novel Intelligent Method for Bearing Fault Diagnosis Based on EEMD Permutation Entropy and GG Clustering", *Applied Sciences*, Vol. 10, No. 1, pp. 386, (2020).

Abstract

In this study, a method based on signal processing and artificial intelligence was used to estimate the remaining life of the bearing. The data base used in study it was prepared from Qiu et al database. The vibration signals was processed by EMD. Then 10 features were extracted from each signals (mean, standard deviation, mean square root, signal peak amplitude value, sharpness coefficient, variance, scattering coefficient, slip, skewness and kurtosis) Then the neural network model was trained by features (the Levenberg-Marquardt training algorithm). Examination of the appearance of vibration signals showed that over time the level and amplitude of the vibrations produced increased, but this increase in the amplitude of the vibrations before the failure in the bearing has a very small change slope, but with approaching the failure time the vibration amplitude changes with a very steep slope and its value increased tenfold. The correlation coefficient between the value predicted by the neural network and the actual value for the extracted features by EMD method was 0.9260. Then the neural network was modeled by the best features and the results showed that the correlation coefficient between the actual value and the predicted value for EMD method was 0.94307.