

# ارزیابی عملکرد شبکه های عصبی احتمالاتی و ماشین بردار پشتیبان در تشخیص عیب ملخ با استفاده از آنالیز ارتعاشات

تاریخ دریافت: ۱۴۰۳/۰۲/۲۴

تاریخ پذیرش: ۱۴۰۴/۰۱/۲۳

علی اصغر نادری

دانشیار، دانشکده مهندسی، دانشگاه امام علی (ع)، تهران، ایران. aa.naderi@modares.ac.ir

## چکیده

عیب یابی ملخ در هواگردها و شناورها از اهمیت بسزایی برخوردار می باشد. یکی از عیوب شایع در ملخها عدم تعادل می باشد که برای تشخیص این عیب، تکنیک های زیادی بر اساس تجزیه و تحلیل طیفی وجود دارد. این مقاله وجود عیب در یک ملخ را به روش آزمایشی و آنالیز ارتعاشی بررسی می کند. بعد از داده برداری در حوزه زمان برای چهار نمونه از ملخ به استخراج ویژگی در حوزه های زمانی و فرکانسی پرداخته شده است. در ادامه داده ها به ورودی شبکه های عصبی احتمالاتی و ماشین بردار پشتیبان اعمال شده است و نتایج حاصل از هر کدام بررسی و باهم مقایسه می شوند. داده هایی که در اختیار بود در دو بخش آموزش و آزمون مورد بررسی قرار گرفت. درصد طبقه بندی صحیح داده های آموزش تقریباً برای تمامی نمونه ها برابر ۱۰۰ درصد بوده است که این مورد دلالت بر انجام دقیق آزمون آزمایشگاهی و توانایی روش های شبکه های عصبی احتمالاتی و ماشین بردار پشتیبان در کلاس بندی دارد. تغییر دور به یک دور بهینه به همراه استفاده ترکیبی از هر دو مشخصه زمانی و فرکانسی بهترین پاسخ را برای طبقه بندی بدست می دهد. در ضمن از مقایسه روش های هوشمند، نتیجه می شود که استفاده از روش شبکه های عصبی احتمالاتی به نتایجی با صحت بالاتر منجر می شود و این مورد دلالت بر دقت بالا و کیفیت مناسب این روش دارد که قادر است با دقت قابل قبولی ملخ های معیوب را از دیگر ملخها تفکیک نماید.

واژه های کلیدی: تشخیص عیب، آنالیز ارتعاشات، ملخ، شبکه عصبی احتمالاتی، ماشین بردار پشتیبان

## Performance of probabilistic neural network and support vector machine for propeller fault detection using vibration analysis

Ali Asghar Naderi<sup>1</sup>

1- Associate Professor, Department of Engineering, Imam Ali University, Tehran, Iran.

### Abstract

Fault diagnosis in propellers for aircraft and ships is of great significance. Vibration monitoring can help predict and prevent propeller failures by detecting imbalances. There are many techniques based on the vibration analysis for fault diagnosis, and this study investigates propeller defects using experimental vibration analysis. Data were collected through feature extraction methods in both the time-domain and frequency-domain. Subsequently, dimensionality-reduced features were applied as inputs to probabilistic neural networks (PNN) and support vector machines (SVM), and their classification results were analyzed and compared. The dataset was divided into training and testing subsets. The training data achieved nearly 100% classification accuracy across all propeller fault conditions, demonstrating the precision of the experimental setup and the efficacy of PNN and SVM in fault classification. To compare healthy and defective datasets, adjusting rotational speed to an optimal value combined with time- and frequency-domain features yielded the highest accuracy for test data classification. The results indicate that PNN outperforms SVM, achieving superior classification accuracy and robustness. Specifically, PNN successfully distinguished all four propeller fault conditions with high accuracy, underscoring its reliability for vibration-based fault detection.

**Keywords:** Fault Detection, Vibrational Analysis, Propeller, Probabilistic Neural Network, Support Vector Machin.

۱۳۳

سال ۱۳ - شماره ۲

پاییز و زمستان ۱۴۰۳

نشریه علمی

دانش و فناوری هوا فضا



ملخ جزئی مهم در هواگردها و شناورها می‌باشد که همواره در معرض بارهای نوسانی ناشی از عیب قرار می‌گیرد. پهبادهای در صنایع مختلف و تدارکات مورد استفاده قرار می‌گیرند که با توجه به برخواست و فرود مکرر آنها تشخیص به موقع عیب و نظارت بر عملکرد اجزای مهم پیش‌رانه مانند ملخ در پهبادهای یک نیاز ضروری برای دستیابی به استانداردهای ایمنی پیشرفته در ترافیک است. عیب‌یابی برای نظارت بر عملکرد تیغه پروانه و تشخیص آسیب در ملخ‌ها که سریع‌ترین اجزای متحرک یک پهباد است انجام می‌شود زیرا حتی یک نقص جزئی در تیغه‌های پروانه می‌تواند باعث عملکرد خیلی ضعیف و یا حتی سقوط پرنده شود [۱]. دستیابی به دوران کاملاً متعادل، حتی در شرایط عملیاتی معمولی نیز آسان نیست. همه ماشین‌ها از مقداری عدم تعادل ذاتی برخوردار می‌باشند که یکی از عوامل اصلی لرزش است و این نامیزانی ناشی از توزیع نابرابر جرمی است. چالش اصلی در زمینه نظارت بر وضعیت ارتعاش، استخراج و شناسایی ویژگی‌های عیب قبل از بحرانی شدن شرایط است. از این رو، ملخ نیاز به نظارت مداوم برای تشخیص عیب دارد. توزیع نامتقارن جرم‌ها در یک ملخ علت عدم تعادل است که منجر به ایجاد نیروهای گریز از مرکز در جهت شعاعی می‌شود [۲]. معایب زیادی برای یک سیستم نامیزان وجود دارد. هنگامی که یک سیستم تحت تأثیر نامیزانی در حال چرخش است، احتمال زیادی وجود دارد که لرزش نامطلوب رخ دهد، که بیشتر ممکن است منجر به اشکالاتی مانند ناهماهنگی، صدای ناخواسته، تنش ارتعاشی بیش از حد، خستگی

سازه و درنهایت تخریب شود. این امر قابلیت اطمینان قطعات دوار را کاهش می‌دهد و ممکن است باعث خرابی زودرس شود [۳]. دوبلینگ و همکارانش [۴] و همچنین زون و همکارانش [۵] مروری جامع از روش‌های شناسایی آسیب بر اساس ارتعاشات ارائه داده‌اند. تشخیص عیوب در ماشین‌های دوار به طور گسترده مورد مطالعه قرار گرفته است و همچنین برای تشخیص عیب عدم تعادل، تکنیک‌های زیادی بر اساس تجزیه و تحلیل طیفی وجود دارد. در واقع، تجزیه و تحلیل دامنه فرکانس تکنیکی است که به طور گسترده برای مطالعه ارتعاشات سیستم مورد استفاده قرار گرفته است [۶] و نیاز به دانش فرکانسی سیستم دارد [۷]. توجه به این نکته مهم است که روش‌های عددی امکان شناسایی بهتری از مکان بهینه نقاط اندازه‌گیری را به منظور مدل‌سازی رفتار ارتعاشی سیستم‌ها فراهم می‌کنند [۸]. اخیراً روش‌های مبتنی بر داده توانایی زیادی در تشخیص هوشمند آسیب نشان داده‌اند [۹]. تعدادی از پژوهشگران پایش وضعیت آنی ماشین‌آلات رویکردهای مبتنی بر شبکه‌های عصبی مصنوعی را برای پیش‌بینی نقص و عدم تعادل بررسی کرده‌اند، این روش در سه مرحله اصلی، اندازه‌گیری، یادگیری و پیش‌بینی انجام می‌شود [۱۰]. یامان و همکاران [۱۱] برای چهار مورد (مدل هلیکوپتر، دواکوپتر، تریکوپتر و کوادکوپتر) با جمع‌آوری سیگنال‌های صوتی و استفاده از شبکه مصنوعی در طبقه‌بندی خطا یک روش برای تشخیص هوشمند عیب ارائه داده‌اند.

در این مقاله ابتدا وجود عیب در یک ملخ متصل به الکتروموتور بررسی می‌شود. از آنالیز ویژگی‌های ارتعاش یک دستگاه آزمایشی استفاده



می شود. سیستم راه اندازی آزمایشی شامل یک میز آزمایشی، یک موتور جریان مستقیم و یک ملخ است. با استفاده از پردازش داده‌های حاصل از آزمایش به وسیله شبکه‌های عصبی احتمالاتی و ماشین بردار پشتیبان سعی شده است تا روش معتبری برای تشخیص هوشمند عیب ارایه شود و در نهایت این دو روش ارزیابی و با هم مقایسه می‌شوند.

## ۲. دستگاه و نمونه های آزمایشی

به منظور تشخیص آسیب در ملخ در شرایطی که هیچگونه فرض محدود شونده‌ای گریبان‌گیر مساله نباشد، لزوم بر ساخت مجموعه آزمایشگاهی احساس می‌شود. دستگاه پس از طراحی ساخته شده که شکل ۱ نمایی از دستگاه آزمایش را نشان می‌دهد. چهار پایه میز آزمایشی از قوطی های  $40 \times 40$  و ضخامت ۴ میلی متر و قوطی های عرضی  $20 \times 20$  و ضخامت ۲ میلی متر با اتصال جوش به دو صفحه با ضخامت ۴ میلی متر در بالا و پایین ساخته شده است. از یک موتور جریان مستقیم ۵۰ وات با دور ۲۶۰۰ بر دقیقه که بر روی یک میز پیچ شده برای چرخاندن ملخ استفاده می‌شود. ملخ مورد استفاده به طول  $11\frac{1}{3}$  in و گام  $6\frac{1}{8}$  in با یک پیچ و یک بوش بر روی شفت موتور متصل شده است.



شکل ۱. مجموعه آزمایشی بر روی بستر صلب

همانگونه که در شکل ۲ دیده می‌شود به منظور شبیه سازی عیب، سه عدد ملخ تهیه و بر روی هر کدام عیبی متفاوت ایجاد شده است. این عیوب شامل ترکی به طول ۱۳ میلی متر، سوراخ به قطر ۷ میلی‌متر و چسباندن یک وزنه به جرم ۲ گرم بر روی ملخ می‌باشد. به منظور فراهم نمودن شرایط گیردار، میز آزمون توسط پیچ بر روی یک میز سنگین به طور کامل متصل شده است.

در این پروژه برای داده برداری شتاب از یک ماژول GY-25 استفاده شده که بر پایه اینرسی شش محوره است. سیستم سنجش موقعیت بر پایه اینرسی یکی از مهم ترین عناصر سیستم های کنترل موقعیت است. سنسور Mpu6050 در این ماژول یک سنسور شش محوره است.



الف) ملخ سالم



ب) ملخ دارای ترک



ج) ملخ دارای حفره



د) ملخ دارای جرم اضافه

شکل ۲. نمونه ملخ‌های مورد آزمایش



با استفاده از تکنیک های فیلترینگ دیجیتالی (فیلتر کالمن) به طور قابل ملاحظه ای نویز اندازه گیری را کاهش داده و دقت سنسور بهبود یافته است. این ماژول را می توان به راحتی با یک مبدل به کامپیوتر متصل کرده و با استفاده از نرم افزار، داده های خروجی را به صورت نمودار مشاهده نمود. این ماژول دارای ظرفیت ۱۰۲۴ بیت و نیز سنسور دما با رنج اندازه گیری ۴۰- تا ۸۵+ درجه سانتیگراد می باشد. این ماژول با تجمیع و ترکیب یک ژيروسکوپ ۳ محور با یک شتاب سنج ۳ محور روی یک چیپ سیلیکونی و بهره گیری از یک پردازشگر دیجیتال حرکت، قادر است الگوریتم های پیچیده را اجرا کند.

داده ها به صورت فایل ذخیره می شود تا بتوان برای تحلیل بیشتر آن را به اکسل و یا متلب برده و آنالیز کرد. از مزایای این ماژول دقت خروجی ۰.۰۱ درجه، پایداری بالا و کارایی می باشد. در ماژول یک رگولاتور تعبیه شده است و از طرفی پروتکل آن برای استفاده های خاص در دسترس است. با این کار نیازی به ترکیب داده و فیلتراسیون نیست. به منظور راه اندازی ماژول شتاب سنج از یک آردوینو یونو<sup>۱</sup> استفاده شده است که قابلیت بارگذاری برنامه و ارتباط با کامپیوتر را دارد.

### ۳. مدلسازی هوشمند

#### ۳-۱- شبکه عصبی احتمالاتی (PNN)

هندسه بررسی شده شبکه عصبی احتمالاتی اولین بار توسط دونالد اسپیجت در سال ۱۹۹۰ معرفی شد [۱۲]. مزیت این روش در امکان تفسیر ساختار آن به عنوان توزیع چگالی احتمال تخمینی یک متغیر وابسته است. همچنین روند

ساخت چنین شبکه هایی متفاوت است و نیازی به یادگیری ندارد. توزین در طرح ریزی یک بردار ورودی داده شده در طول شبیه سازی شبکه توسط توابع هسته گاوسی که در الگوهای آموزشی مرتب شده اند انجام می شود [۱۳]. ساختار شبکه عصبی احتمالاتی همان طور که در شکل ۳ مشاهده می شود، در حالت کلی از چهار لایه محاسباتی تشکیل شده است که عبارتند از: لایه ورودی، لایه الگو (توابع هسته جزء که چگالی احتمال را برای هر دسته تخمین می زند)، لایه جمع بندی و لایه خروجی [۱۲].

با یک شبکه تعیین شده، می توان پاسخ سیستم را به یک بردار ورودی چند بعدی  $X$  شبیه سازی کرد. سپس، در لایه الگو، برای یک بردار ورودی داده شده، مقادیر هر تابع هسته  $F_{k,i}(X)$  تعیین می شود. به این ترتیب مقدار فعال سازی تک تک توابع هسته به دست می آید. واحدهای محاسباتی در لایه الگو به گروه های  $k$ ، مربوط به دسته های خاص در خروجی شبکه تقسیم می شوند. توابع جداگانه هسته، منحنی های گاوسی هستند که به شکل رابطه (۱) نوشته شده اند.

$$f_i(X, w_j) = \exp\left[-\frac{x - w_j^T(x - w_j)}{2\sigma^2}\right] \quad (1)$$

در این رابطه  $w$  وزن داده ها،  $X$  بردار ورودی و  $\sigma$  پراکندگی آموزش شبکه حول مقادیر وزن داده ها می باشد.  $w_j$  وزن اتصالات از لایه میانی به لایه الگو می باشد. اتصالات نرون ها از لایه ورودی به لایه الگو به صورت کامل بوده و مقادیر این وزن ها برابر با داده های آموزشی است. در لایه جمع بندی تعداد نرون ها برابر با تعداد کلاس ها است، هر نرون در لایه الگو معرف یکی از

### ۳-۲- الگوریتم ماشین بردار پشتیبان (SVM)

در سال ۱۹۹۵ برای اولین بار الگوریتم ماشین بردار پشتیبان توسط کورتیس و وپنیک برای مسائل طبقه‌بندی خطی دو کلاسه ارائه شد [۱۴]. بعدها این الگوریتم برای مسائل طبقه‌بندی غیرخطی و همچنین مسائل رگرسیون تعمیم یافت [۱۵]. این نوع شبکه عصبی ریسک عملیاتی را به عنوان تابع هدف در نظر می‌گیرد و سعی می‌کند این مقدار را بهینه کند. در این مسئله بهینه‌سازی هدف این است که مرزی بین دو گروه بدست بیاید که حداقل خطای ممکن را داشته باشد و از طرفی مرز باید بیشترین فاصله را بین دو گروه داشته باشد.

در شبکه های ماشین بردار پشتیبان، وظیفه اصلی جداسازی الگوها بین دسته های متغیر وابسته است [۱۲]. با توجه به مجموعه الگوهای  $\{x_k, d_k\}$  که در آن مقدار  $K$  از ۱ تا  $N$  است،  $x_k$  بردار ورودی است و مقدار  $d_k$  مقادیر اختصاصی ۱ یا -۱ است، هدف یافتن تصمیم بهینه است. رابطه (۴) به عنوان تفکیک کننده داده‌های الگو برای دسته های اختصاص داده شده عمل می‌کند.

$$Y(X) = w^T x + b \quad (4)$$

برای افزایش شانس جداسازی الگوها، از قضیه کاور استفاده می‌شود [۱۳]. این شامل طرح ریزی الگوهای اصلی به فضای به اصطلاح ویژگی با ابعاد بالاتر است. با فرض اینکه طرح الگوهای اصلی در فضای ویژگی با استفاده از یک تبدیل خاص  $\varphi(x)$  انجام می‌شود، یک صفحه جداسازی به شکل رابطه (۵) به دست می‌آید.

$$Y(X) = w^T \varphi(x) + b = 0 \quad (5)$$

که در این رابطه  $X$  بردار داده‌های ورودی در فضای  $n$  بعدی،  $\varphi$ ، تبدیل خاصی است که

داده‌های آموزشی است و هر نرون در لایه جمع بندی یک کلاس را نشان می‌دهد. در نتیجه اگر داده‌ای از داده‌های آموزشی به کلاسی تعلق داشته باشد ضریب وزنی همان داده از لایه الگو به لایه جمع‌بندی برابر با ۱ خواهد بود. و اگر داده‌ای متعلق به کلاسی نباشد، ضریب وزنی همان داده از لایه الگو به لایه جمع‌بندی برابر با ۰ می‌باشد. در لایه جمع‌بندی، برای هر زیر گروه مشخص شده از نورون‌های الگو، که دسته‌های مختلف را در یک دسته معین نشان می‌دهند، جمع‌بندی مقادیر فعال‌سازی نورون انجام می‌شود. فرآیند جمع بندی را می‌توان به صورت رابطه (۲) نوشت:

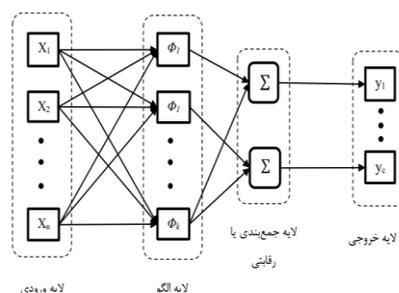
$$G_k(X) = \sum_{i=1}^{M_k} w_{ki} F_{k,i}(X) \quad (2)$$

$k \in \{1, \dots, K\}$

جایی که  $M_k$ ، تعداد نورون‌ها از لایه الگوی اختصاص داده شده به دسته  $k$  و  $w_{ki}$  فاکتورهای وزنی غیرمنفی است.

نتیجه نهایی طبقه‌بندی الگوی  $X$  ارائه شده در ورودی PNN بر اساس مقایسه مقادیر  $G_k$  تعیین شده در لایه جمع‌بندی و انتخاب آن دسته  $k$ ، که بیشترین مقدار را برای آن داشت، به دست می‌آید. بنابراین خروجی برابر رابطه (۳) تعیین می‌شود [۱۳].

$$C(X) = \operatorname{argmax}(G_k) \quad (3)$$



شکل ۳. ساختار شبکه عصبی احتمالی



داده‌های ورودی خام را به فضای ویژه می‌برد و  $W^T$  بردار وزن است.

برای محاسبه فاصله تفکیک کننده باید فاصله هر یک از خطوط محدوده نشان داده شده در شکل ۴ را نسبت به مبدا محاسبه کرد. در این حالت می‌توان فاصله عمودی خط تفکیک کننده، از مرکز مختصات را به صورت رابطه (۶) بدست آورد [۱۴].

$$x_0 = \frac{|b|}{\|w\|} \quad (6)$$

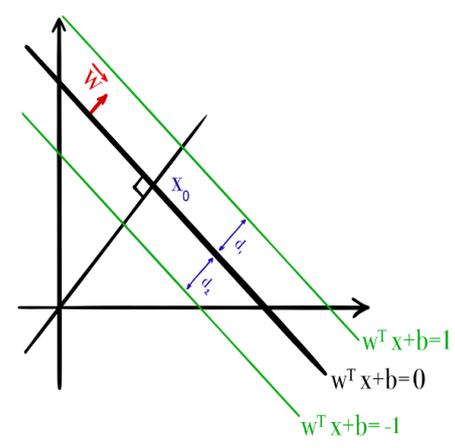
$\gamma$ ، فاصله بین دو خط تفکیک کننده است که از رابطه (۷) با توجه به شکل ۵ به دست خواهد آمد. و در ادامه با استفاده از رابطه (۴)، یعنی معادله حاکم بر تفکیک کننده به صورت رابطه (۸) بدست می‌آید.

$$\gamma = |\beta - \alpha| \quad (7)$$

$$\gamma = \left| \frac{|b-1|}{\|w\|} - \frac{|b|}{\|w\|} \right| = \frac{1}{\|w\|} \quad (8)$$

تابع هدف الگوریتم، رسیدن به حد ماکزیمم مقدار  $d_1+d_2$  است (شکل ۴) که این مقدار برابر رابطه (۹) است.

$$d_1 + d_2 = \frac{1}{\|w\|} + \frac{1}{\|w\|} = \frac{2}{\|w\|} \quad (9)$$



شکل ۴. فاصله عمودی خط تفکیک کننده از مرکز مختصات

با استفاده از رابطه اخیر دیده می‌شود که تابع هدف تبدیل به کمینه کردن مقدار  $\|w\|$  خواهد شد. حال به جای کمینه کردن  $\|w\|$  مقدار عبارت  $\frac{1}{2} \|w\|^2$  کمینه می‌شود. در نتیجه تابع هدف کمینه کردن رابطه (۱۰) خواهد بود.

$$\frac{1}{2} w^T w \quad (10)$$

با فرض یک مجموعه داده  $n$  تایی که به صورت  $\{x_i, d_i\}$  با مقدار  $i$  از ۱ تا  $N$ ، نشان داده می‌شوند، در حالت کلی  $x_i$  یک سری بردار در فضای  $N$  بعدی هستند. و  $y_i$ ها به عنوان متغیرهای وابسته دارای دو حالت  $d_i = \{1, -1\}$  هستند. رابطه ای که یک تفکیک کننده برای تفکیک کردن لازم دارد به صورت رابطه (۱۱) خواهد شد [۱۵].

$$d_i (w^T x_i + b) \geq 1 \quad \forall i = 1 \dots N \quad (11)$$

اگر نمونه های دو گروه داده آموزش کاملا تفکیک پذیر نباشند این الگوریتم به سبب داشتن قیدهای بسیار شدید در رابطه (۱۱) همگرا نخواهد شد و مرز مناسبی پیدا نخواهد کرد. چون قیدها بسیار شدید هستند و مدل زمانی به یک جواب همگرا می‌شود که خطا صفر شود. برای حل این مسئله از یک متغیر مجازی  $C$  می‌توان کمک گرفت و مسئله بهینه سازی رابطه (۱۰) و (۱۱) را می‌توان به صورت رابطه (۱۲) طوری تغییر داد که مدل اجازه داشتن کمی خطا در محاسبه مرز را داشته باشد [۱۵].

$$\Phi(w, \xi) = \frac{1}{2} w^T w + C \sum_i^N \xi_i \quad (12)$$

$$d_i (w^T x_i + b) \geq 1 - \xi_i \quad \forall i = 1 \dots N$$

$$\xi_i \gg 0$$

#### ۴. نتایج

مجموعه در حین آزمون نبایستی در شرایط تشدید قرار گیرد به همین منظور از آنالیز مودال در تعیین فرکانس طبیعی میز آزمایشی استفاده شده است.

بعد از مدل سازی سه بعدی میز در نرم افزار کتیا<sup>۲</sup> و وارد کردن این مدل به نرم افزار آباکوس<sup>۳</sup> از المان نوع C3D8R برای مش بندی میز یکسرگیردار و سر دیگر آزاد استفاده شده است. هر چهار پایه میز گیردار است و ورق رویی از یک طرف نقاط آن با قید تای به پایه ها مقید و از طرف دیگر آزاد است. نتایج حاصل از این نرم افزار به روش تحلیل عددی خطی برای تعیین فرکانس طبیعی در شکل ۶ آمده است.

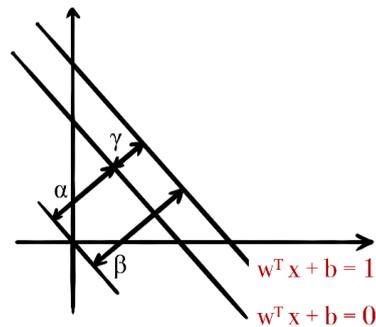
جرم موتور و ملخ نسبت به جرم میز خیلی کم است بنابراین می توان برای بدست آوردن فرکانس های پایین کل مجموعه از آنالیز مودال میز استفاده کرد و نرسیدن دور موتور به این مقادیر عدم تشدید کل مجموعه را تضمین خواهد کرد. نتایج حاکی از این مطلب است که فرکانس های طبیعی اول، دوم و سوم میز به ترتیب برابر ۲۸۵، ۳۰۱ و ۴۶۰ هرتز می باشد. با توجه به مقادیر بدست آمده برای فرکانس های طبیعی بایستی دقت نمود که در حین آزمون، دور موتور در نزدیکی این مقادیر قرار نگیرد.

برای چهار نمونه شامل ملخ سالم، و ملخ های دارای نابالانسی (اضافه جرم)، ترک (بریدگی با اره) و سوراخ، ویژگی های ارتعاشی در حوزه های زمانی و فرکانسی بدست آمده است. نتایج حوزه فرکانس بر اساس تبدیل سیگنال ارتعاشی از حوزه زمان بدست آمده است.

پارامتر C در این رابطه مقداری ثابت و مثبت برای کنترل مرز است که به وسیله کاربر تعیین و استفاده می شود. اگر مقدار بزرگی داشته باشد، قیدهای مسئله بهینه سازی شدید و خطای طبقه بندی صفر می شود و در مقابل با انتخاب مقدار خیلی کوچکی برای پارامتر C، شدت قیدهای مسئله بهینه سازی در رابطه (۱۲) خیلی کم می شود و به مدل اجازه می دهد خطای زیادی داشته باشد که در نتیجه آن ممکن است مرز مناسبی بدست نیاید. انتخاب مناسب و میانه برای پارامتر C، به مدل اجازه می دهد مقداری خطا داشته باشد و همین باعث می شود که قیدهای مسئله بهینه سازی مرز مناسبی برای مسئله طبقه بندی پیدا کند.

در طبقه بندی داده ها، تعیین مقادیر بهینه پارامترهای C و  $\gamma$  نقش خیلی مهمی دارد. پارامتر  $\gamma$  عرض توابع کرنل اتخاذ شده رابطه (۱۳) است که یک مقدار ثابت مثبت هست و این پارامتر همانند پارامتر C در حین اجرای برنامه مشخص می شود. داده ها با کمک کرنل به فضای خطی نگاشت می شود و در آن فضای خطی مرز بهینه پیدا می شود که معادل مرز غیرخطی در فضای اصلی غیرخطی است [۱۶].

$$K(X_k, X_j) = \exp\left(-\frac{(X_k - X_j)^2}{\gamma^2}\right) \quad (13)$$

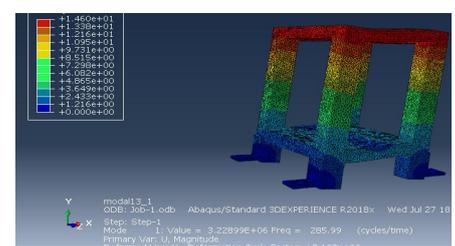


شکل ۵. فاصله دو خط تفکیک کننده

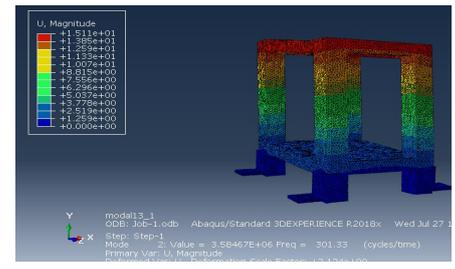
برای داده برداری شتاب از یک ماژول GY-25 با بهره‌گیری از سنسور Mpu6050 از تکیه‌گاه محور متصل به ملخ استفاده شده است. دور موتور در محدوده ۱۶.۶ تا ۳۳.۳ هرتز است بنابراین به مدت ۱۰ ثانیه برای اطمینان از ثبت چندین دور ملخ نتایج ثبت می‌شود. برای اطمینان از تکرارپذیری نتایج و کاهش اثرات نویز محیطی و خطای سنسور ۱۰ بار و هر بار به فاصله ۲ دقیقه‌ای از هم داده برداری انجام می‌شود. نرخ نمونه برداری با توجه به مشخصه سنسور و پوشش حداقل دو برابری بالاترین فرکانس مؤثر در سیگنال برابر ۵۰۰ هرتز انتخاب شده است. ماژول داده برداری با یک مبدل سریال به رایانه متصل شده و با استفاده از نرم افزار لب‌ویو<sup>۴</sup>، داده‌های خروجی به علت محدودیت ظرفیت سنسور (۱۰۲۴ بایت) به صورت فایل ذخیره شده‌اند.

بعد از اینکه داده برداری در حوزه زمان برای چهار نمونه ملخ انجام شد، با استفاده از یکی از روش‌های متداول برای تبدیل سیگنال حوزه زمان به سیگنال حوزه فرکانس تبدیل فوریه، طیف فرکانسی برای این نمونه‌ها بدست می‌آید. مزیت تجزیه و تحلیل در حوزه فرکانس نسبت به تجزیه و تحلیل در حوزه زمان، شناسایی و جداسازی مولفه‌های فرکانسی می‌باشد. در نهایت یک سری از ویژگی‌های سیگنال ارتعاشی را می‌توان استخراج کرد. الگوریتم‌ها و ابزارهای گوناگونی برای تجزیه و تحلیل داده‌ها جهت درک بهتر و تفسیر داده‌ها در دسترس هستند. که در اینجا از روش کاهش ابعاد فضای ویژگی‌ها (داده‌ها) استفاده می‌شود. از عوامل مهم در عملکرد و کارایی طبقه‌بندی کننده‌ها، کاهش ابعاد فضای ویژگی است.

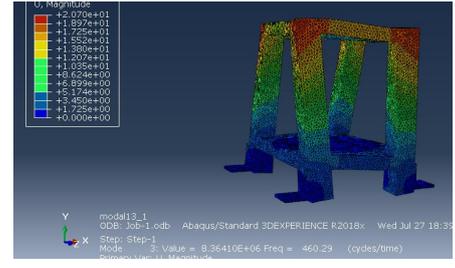
کاهش هزینه محاسباتی و افزایش عملکرد طبقه‌بندی، دو دلیل عمده کاهش فضای ویژگی است. همچنین برای یادگیری داده‌ها در هوش مصنوعی، به عملیات محاسباتی پیچیدتری نیاز نخواهد بود. بنابراین پردازش انجام شده بر روی مجموعه داده‌ها شامل تبدیل فوریه و بردن آن‌ها به حوزه فرکانس می‌باشد. در ادامه ویژگی‌های استخراج شده با استفاده از روش t-SNE<sup>۵</sup> کاهش بعد یافته و در نهایت از ۲ بعد مشخصه زمانی و فرکانسی کاهش یافته در تحلیل استفاده می‌شود. نتایج سیگنال زمانی شتاب درجهت‌های طولی و عمود بر محور موتور برای هر ۴ نمونه ملخ تحت دوران ۱۰۰۰ دور بر دقیقه در شکل ۷-الف و نتایج تبدیل فوریه آنها در شکل ۷-ب آورده شده‌اند. در شکل‌های ۸ و ۹ طیف فوریه سیگنال شتاب طولی و عمود برمحور برای نمونه‌ها در دوره‌های ۱۵۰۰ و ۲۰۰۰ دور بر دقیقه آورده شده است.



مود اول

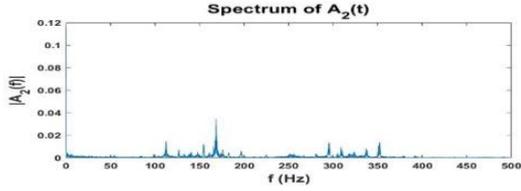
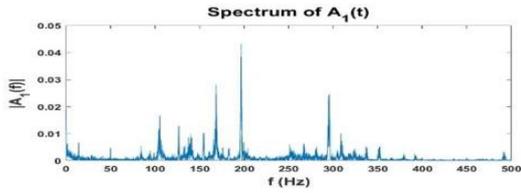


مود دوم

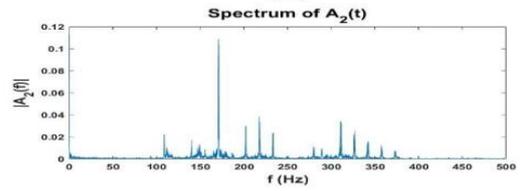
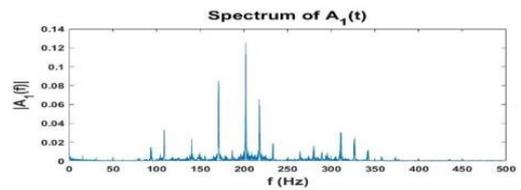


مود سوم

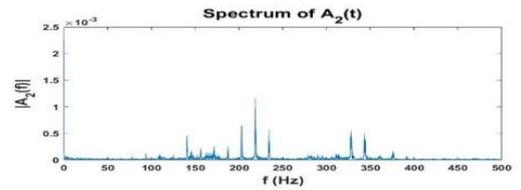
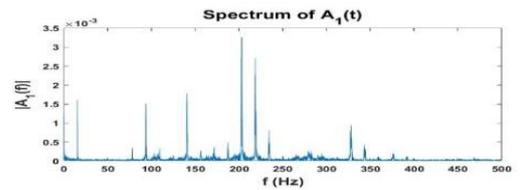
شکل ۶. شکل‌های مود میز آزمایشگاهی



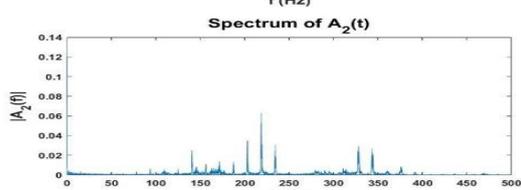
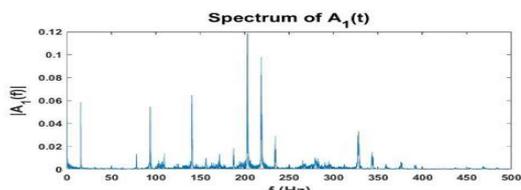
الف) ملخ سالم



ب) ملخ دارای ترک

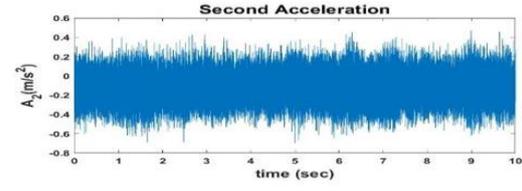
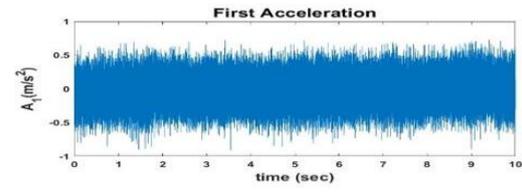


ج) ملخ دارای حفره

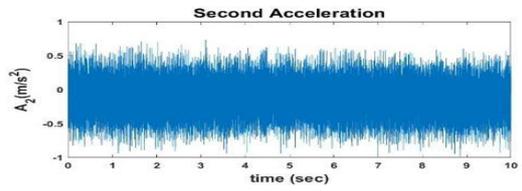
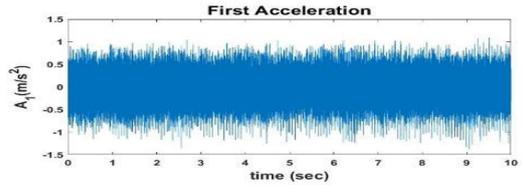


د) ملخ دارای جرم اضافه

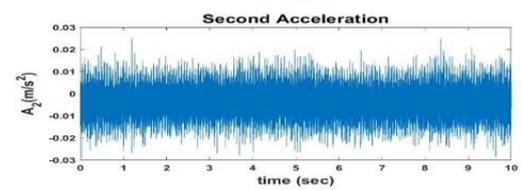
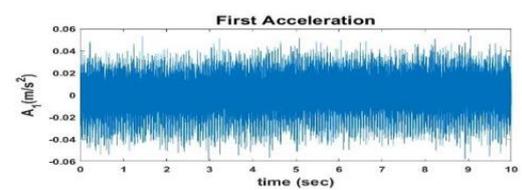
شکل ۷-ب. طیف فوریه سیگنال شتاب طولی و عمود بر محور نمونه ملخ‌های آزمایشی در دور ۱۰۰۰ rpm



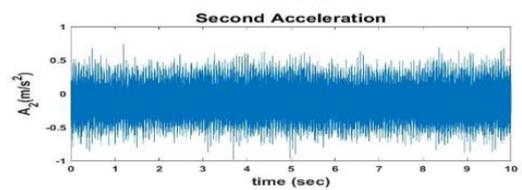
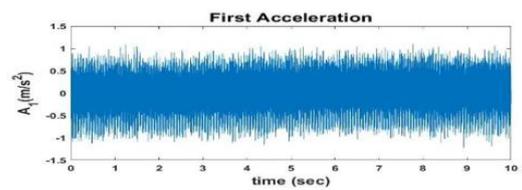
الف) ملخ سالم



ب) ملخ دارای ترک



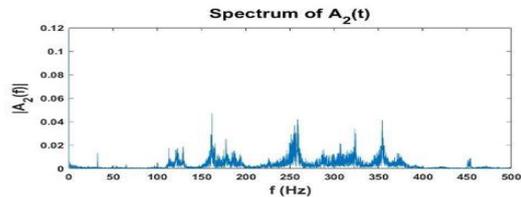
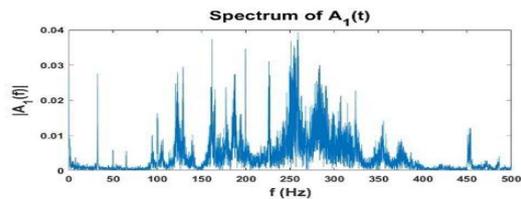
ج) ملخ دارای حفره



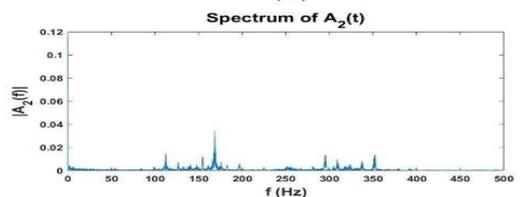
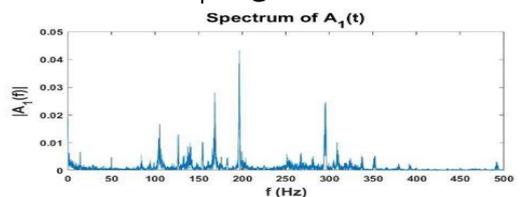
د) ملخ دارای جرم اضافه

شکل ۷-الف. سیگنال زمانی شتاب طولی و عمود بر محور نمونه ملخ‌های آزمایشی در دور ۱۰۰۰ rpm

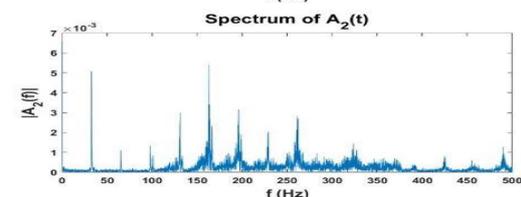
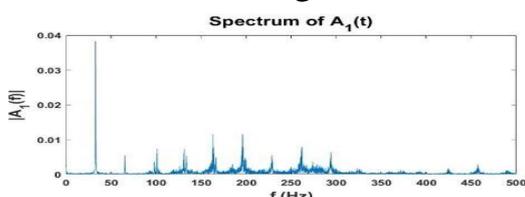




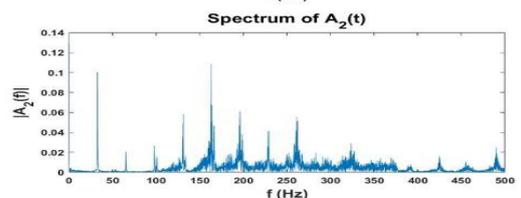
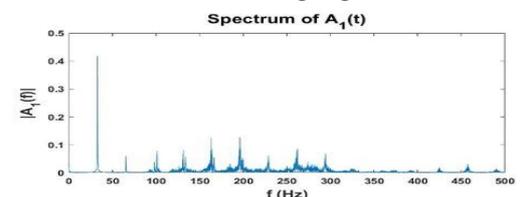
الف) ملخ سالم



ب) ملخ دارای ترک



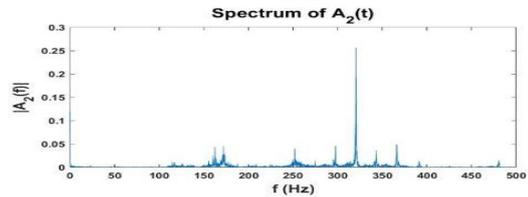
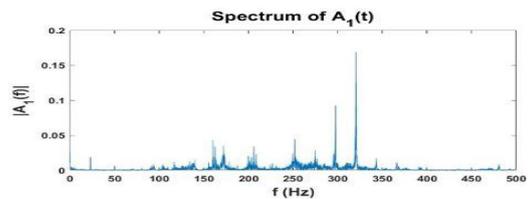
ج) ملخ دارای حفره



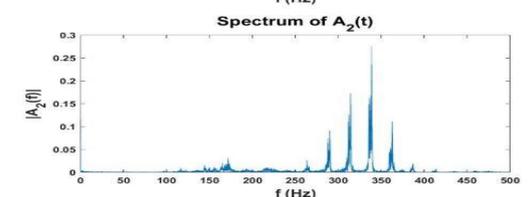
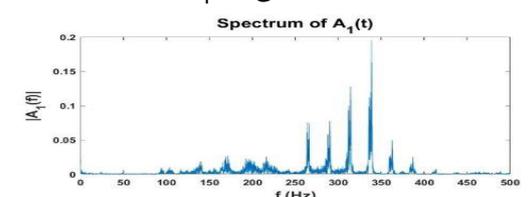
د) ملخ دارای جرم اضافه

شکل ۹. طیف فوریه سیگنال شتاب طولی و عمود برمحور

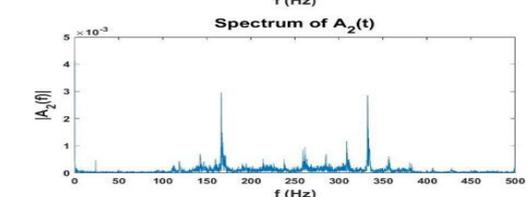
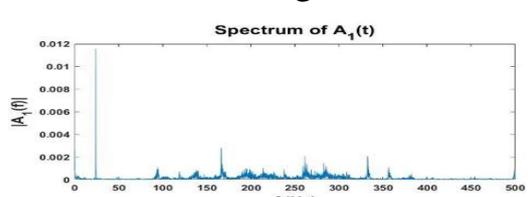
نمونه ملخ‌های آزمایشی در دور ۲۰۰۰ rpm



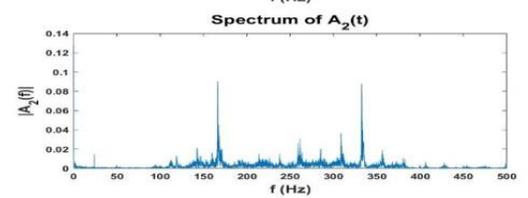
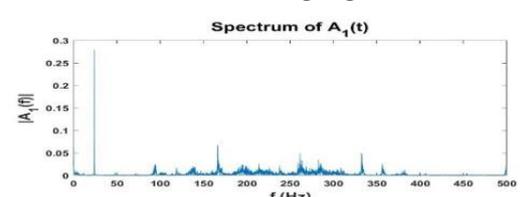
الف) ملخ سالم



ب) ملخ دارای ترک



ج) ملخ دارای حفره



د) ملخ دارای جرم اضافه

شکل ۸. طیف فوریه سیگنال شتاب طولی و عمود

برمحور نمونه ملخ‌های آزمایشی در دور ۱۵۰۰ rpm

همانطور که از این شکل‌ها مشخص است، قله‌های فرکانسی در دوره‌های منطبق بر دور موتور به طور برجسته قابل تمیز است. البته با توجه ذات تبدیل فوری، مضارب دور موتور نیز در طیف فرکانسی فوری قابل رویت می‌باشد.

استفاده صرف از نمودارهای طیف فرکانسی در دوره‌های مختلف، تفاوت بین نوع عیب ملخ را آشکار نمی‌سازد. لذا نیاز به روشی قابل اتکا به منظور شناسایی عیب و یا حتی تفکیک نوع عیب در ملخ احساس می‌شود که در این تحقیق از روش‌های هوشمند شبکه عصبی احتمالاتی و روش ماشین بردار پشتیبان استفاده شده است. به منظور اعمال این روش‌ها نیاز است تا عملیاتی بر روی داده‌های شتاب انجام گیرد تا بتوان ورودی مورد نیاز روش‌های مذکور را ایجاد نمود. ابتدا مجموعه داده‌های کاهش بعد داده شده به شبکه عصبی اعمال می‌شوند. سپس داده‌های مربوط به هر یک از حالت‌های خرابی به همراه حالت سالم را به عنوان یک بانک داده در نظر گرفته و تشخیص حالت سالم از حالت معیوب انجام پذیرفته است. در نهایت داده‌های مربوط به تمام حالت‌های خرابی به همراه حالت سالم را به عنوان یک بانک داده در نظر گرفته می‌شوند و در هر مرحله تشخیص یک نوع خرابی خاص از میان تمام حالت‌های موجود هدف قرار گرفته است.

همچنین، در هر یک از حالت‌های مذکور مراحل تشخیص عیب توسط سه گروه از ویژگی‌ها شامل مشخصه‌های زمانی، مشخصه‌های فرکانسی و ترکیب مشخصه‌های زمانی و فرکانسی انجام پذیرفته است. برای اجرای شبکه عصبی نیز از نرم افزار متلب استفاده شده است.

در این تحقیق داده‌هایی که در اختیار بود به دو بخش ۷۰٪ و ۳۰٪ تقسیم شد و ۷۰٪ داده‌ها

برای آموزش به شبکه‌های عصبی داده شد. ۳۰٪ درصد باقیمانده به عنوان داده آزمون برای آزمودن شبکه عصبی مورد بررسی قرار گرفت.

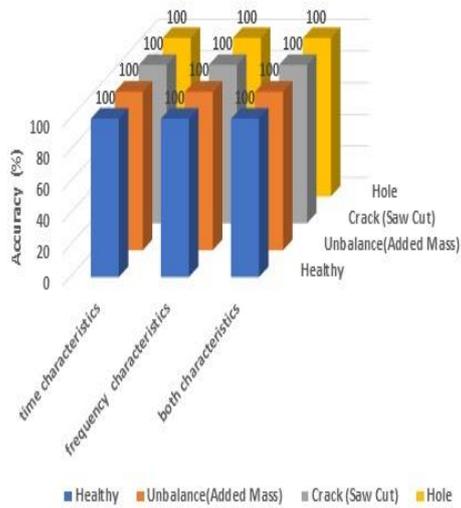
بعد از آموزش شبکه عصبی با داده‌های آموزشی نوبت به آزمون شبکه می‌رسد. در اینجا برای اطمینان از نتایج خروجی شبکه، کد نوشته شده را ۵۰ بار اجرا کرده و با میانگین‌گیری از خروجی، نتایج بدست آمد. مجموعه داده ورودی شامل ویژگی‌های ارتعاشی سیستم می‌باشد.

نتایج اجرای کد در حالت استفاده از مشخصه‌های زمان، مشخصه‌های فرکانسی و حالت استفاده همزمان از هر دو مشخصه زمانی و فرکانسی برای دوره‌های ۱۰۰۰، ۱۵۰۰ و ۲۰۰۰ دور بر دقیقه، در شکل ۱۰ برای درصد طبقه‌بندی صحیح داده‌های آموزش با شبکه عصبی احتمالاتی و در شکل ۱۱ برای درصد طبقه‌بندی صحیح داده‌های آموزش با الگوریتم هوشمند ماشین بردار پشتیبان آورده شده است.

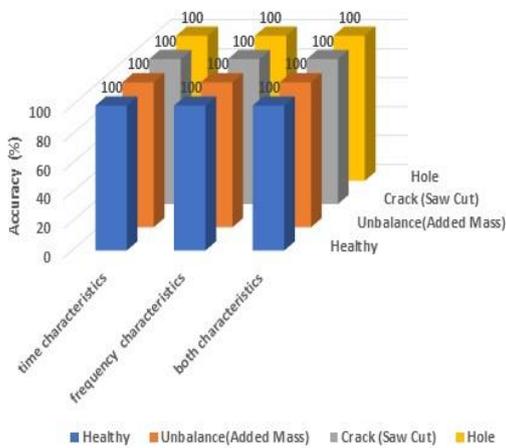
این طبقه‌بندی‌ها برای تشخیص بین حالت‌های ملخ سالم با ملخ‌های دارای عیوب جرم اضافه، ترک و سوراخ آورده شده است. مقایسه اختلاف درصد روش‌های شبکه عصبی احتمالاتی و الگوریتم ماشین بردار پشتیبان در طبقه‌بندی صحیح داده‌های آموزش در شکل ۱۲ آورده شده است.

از بررسی شکل‌های ۱۰ و ۱۱ و مقایسه آنها با شکل ۱۲ دیده می‌شود که درصد طبقه‌بندی صحیح داده‌های آموزش با روش‌های شبکه عصبی احتمالاتی و الگوریتم ماشین بردار پشتیبان برای دوره‌های ملخ ۱۰۰۰، ۱۵۰۰ و ۲۰۰۰ دور بر دقیقه و در تمام حالات عیب ملخ تقریباً برابر ۱۰۰ درصد بوده که این مورد دلالت بر انجام دقیق آزمون آزمایشگاهی و توانایی روش‌های هوشمند معرفی شده در کلاس‌بندی این نوع از داده‌ها را دارد.

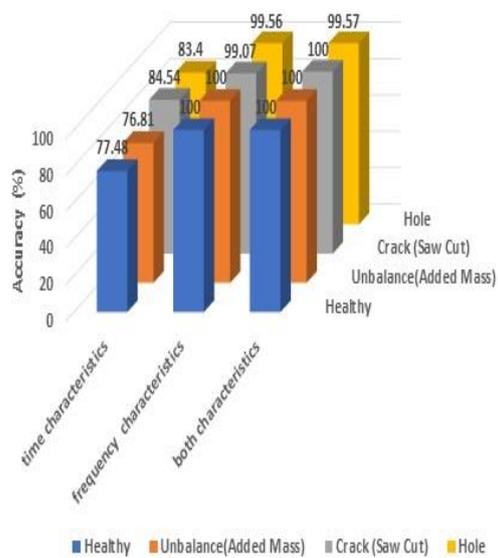




دور ۱۰۰۰ rpm



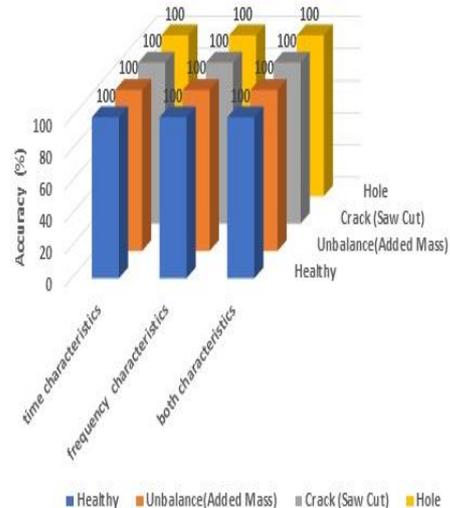
دور ۱۵۰۰ rpm



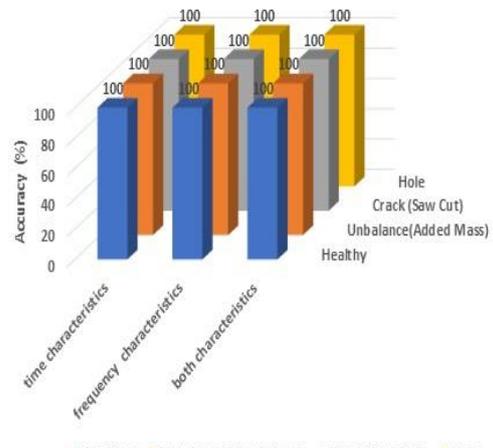
دور ۲۰۰۰ rpm

شکل ۱۱. درصد طبقه‌بندی صحیح داده‌های آموزش با

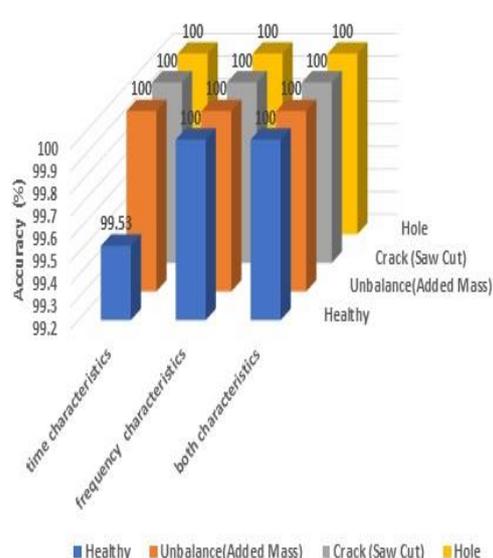
SVM



دور ۱۰۰۰ rpm



دور ۱۵۰۰ rpm



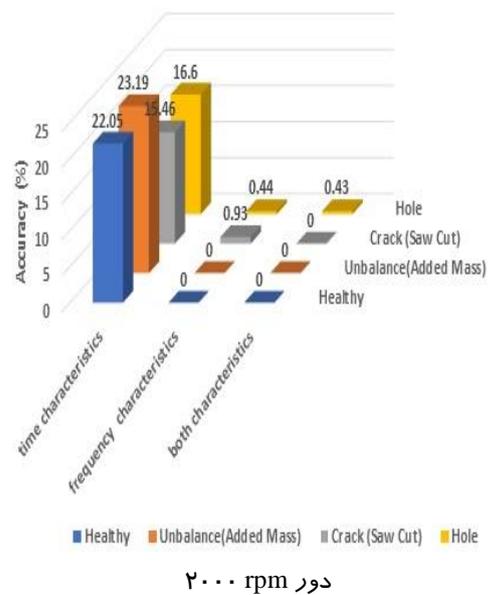
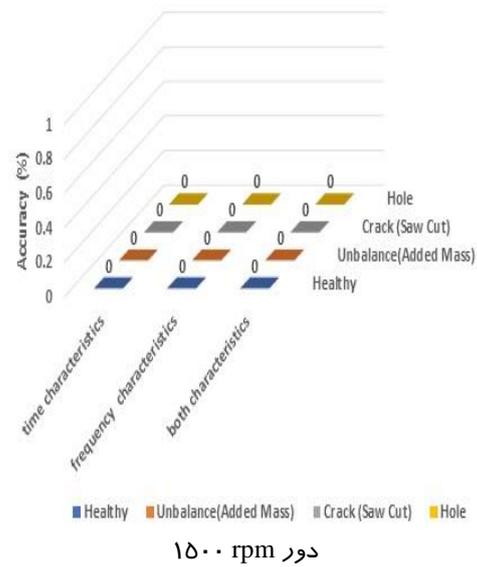
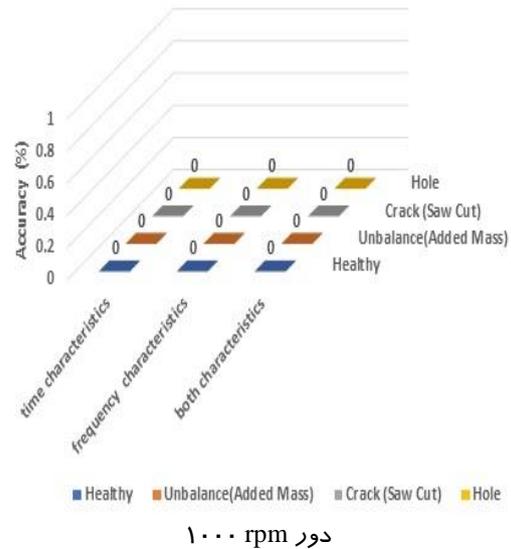
دور ۲۰۰۰ rpm

شکل ۱۰. درصد طبقه‌بندی صحیح داده‌های آموزش با

PNN

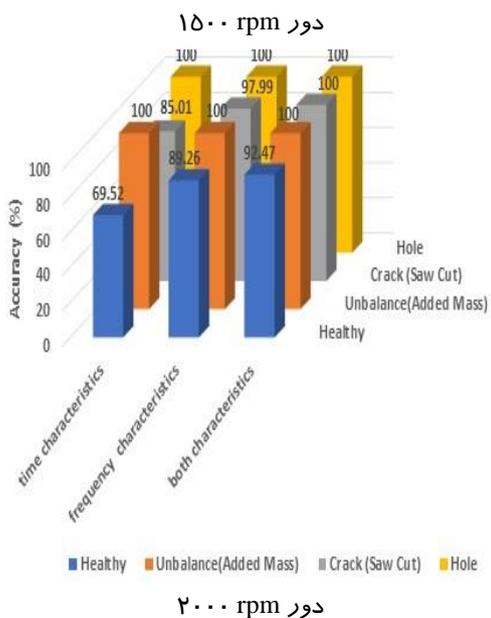
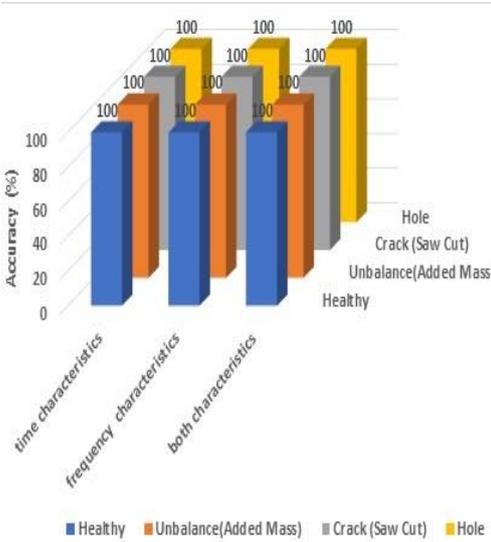
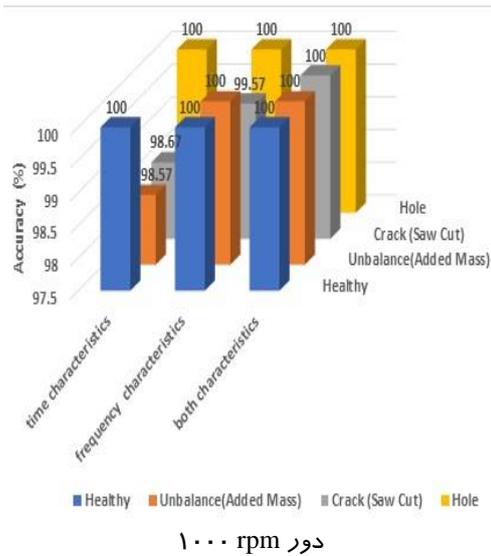


در مقایسه ملخ سالم با ملخ معیوب استفاده همزمان از هر دو ویژگی‌های زمانی و فرکانسی بهترین پاسخ را برای درصد طبقه‌بندی صحیح داده‌های آزمون را می‌دهد. بنابراین در مجموع انتخاب هر دو مشخصه زمانی و فرکانسی با هم منجر به نتایج بهتری می‌گردد. به طور مثال در طبقه‌بندی داده‌های آموزش الگوریتم ماشین بردار پشتیبان برای دوره‌های ۱۰۰۰ و ۱۵۰۰۰ دور بر دقیقه، استفاده از داده‌های ویژه زمانی، فرکانسی یا هر دو با هم تفاوتی ندارد اما در دور ۲۰۰۰ دور بر دقیقه، داده‌های مشخصه زمانی پاسخ ضعیفی در مقایسه فرکانسی می‌دهد. بنابراین می‌توان نتیجه گرفت برای طبقه‌بندی انتخاب هر دو مشخصه زمانی و فرکانسی با هم منجر به نتایج بهتری می‌گردد. عیوبی مانند ترک، عدم تعادل، یا سوراخ در ملخ‌ها، اغلب به صورت تغییرات دوره‌ای به ویژه برای فرکانس‌های تشدید در سیگنال‌های ارتعاشی ظاهر می‌شوند. این تغییرات در حوزه زمان ممکن است به دلیل نویز، یا هم‌پوشانی با سیگنال‌های دیگر، به‌راحتی شناسایی نشوند. بنابراین بدیهی است که در دوره‌های بالاتر به علت افزایش نویز استفاده از مشخصه فرکانسی به نتایج به مراتب بهتری خواهیم رسید. مشخصه‌های زمانی رویدادهای گذرا و تغییرات دینامیکی را ثبت می‌کنند و تبدیل سیگنال به حوزه فرکانس، اطلاعات مربوط به زمان وقوع عیب یا تغییرات گذرا را از بین می‌برد. برای شناسایی رفتار کامل سیستم بهتر است تحلیل با استفاده از داده‌های ترکیبی از مشخصه‌های زمانی و فرکانسی انجام شود. مدل ترکیبی هم پالس گذرا (زمانی) و هم تغییرات فرکانسی را شناسایی می‌کند و این رویکرد، احتمال تشخیص نادرست را کاهش می‌دهد.



شکل ۱۲. مقایسه اختلاف درصد طبقه‌بندی صحیح

داده‌های آموزش با PNN و SVM



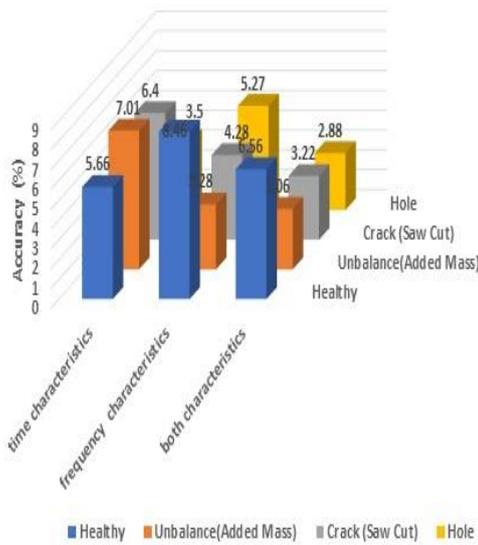
شکل ۱۳. درصد طبقه‌بندی صحیح داده‌های آزمون با PNN

درصد طبقه‌بندی صحیح داده‌های آزمون با شبکه عصبی احتمالاتی و ماشین بردار پشتیبان به نرم افزار اکسل گزارش شده است. که این مقادیر به ترتیب در شکل ۱۳ و شکل ۱۴ آورده شده‌اند. داده‌های مورد نظر مربوط به چهار نمونه ملخ مورد آزمایش است که هر کدام در یک طبقه قرار می‌گیرند. مقایسه اختلاف درصد روش‌های شبکه عصبی احتمالاتی و ماشین بردار پشتیبان در طبقه‌بندی صحیح داده‌های آزمون در شکل ۱۵ آورده شده است.

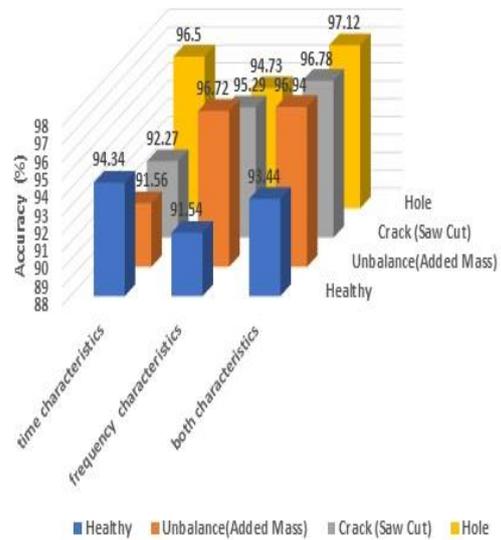
از بررسی شکل‌های ۱۳ و ۱۴ و مقایسه آنها با شکل ۱۵ دیده می‌شود که روش شبکه عصبی احتمالاتی در مقایسه ملخ سالم با ملخ معیوب در استفاده از هر دو ویژگی‌های زمانی و فرکانسی به صورت ترکیبی بهترین پاسخ را برای درصد طبقه‌بندی صحیح داده‌های آزمون ارائه می‌دهد. بنابراین در مجموع انتخاب هر دو مشخصه زمانی و فرکانسی با هم منجر به نتایج بهتری می‌گردد.

و همچنین دیده می‌شود که درصد طبقه‌بندی صحیح داده‌های آزمون برای دوره‌های ۱۰۰۰، ۱۵۰۰ دور بر دقیقه برای تمام حالات ملخ سالم و معیوب به روش الگوریتم ماشین بردار پشتیبان با تقریب مناسبی طبقه‌بندی انجام شده است اما هنوز خطا وجود دارد. از داده‌های زمانی ارتعاشی در دور ۲۰۰۰ دور بر دقیقه جواب مناسبی بدست نمی‌آید و بایستی از داده‌های ویژه زمانی و فرکانسی با هم استفاده کرد تا به جواب مطلوب رسید.

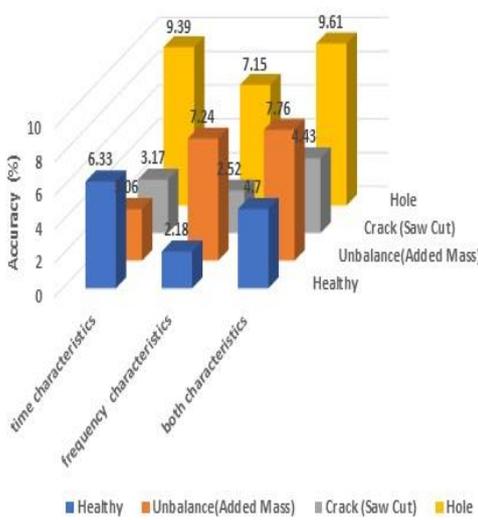
در حالت مقایسه ملخ سالم با ملخ دارای ترک، افزایش دور به همراه استفاده از هر دو ویژگی‌های زمانی و فرکانسی و یا فقط فرکانسی بهترین پاسخ را برای درصد طبقه‌بندی صحیح داده‌های آزمون می‌دهد.



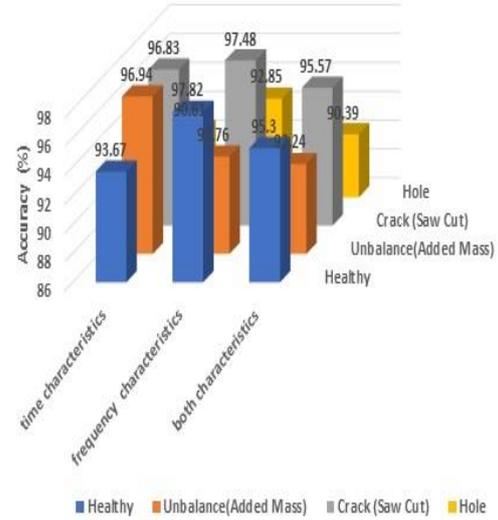
دور ۱۰۰۰ rpm



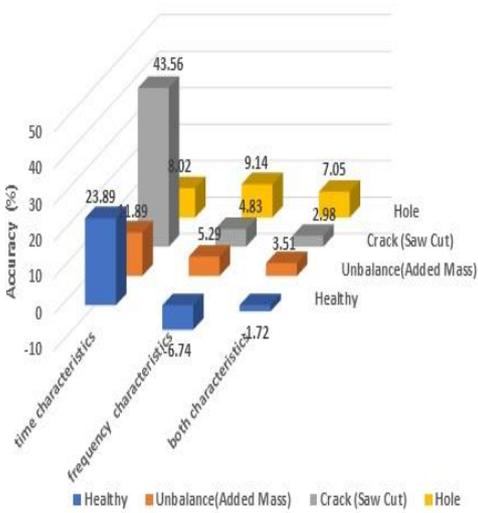
دور ۱۰۰۰ rpm



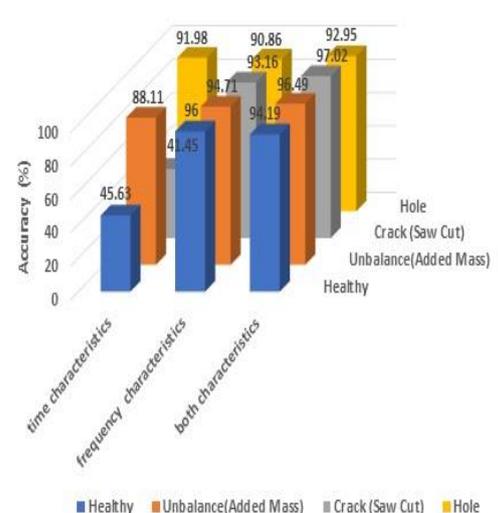
دور ۱۵۰۰ rpm



دور ۱۵۰۰ rpm



دور ۲۰۰۰ rpm



دور ۲۰۰۰ rpm

شکل ۱۵. مقایسه اختلاف درصد طبقه‌بندی صحیح داده‌های آزمون با SVM و PNN

شکل ۱۶. درصد طبقه‌بندی صحیح داده‌های آزمون با الگوریتم SVM





در حالت مقایسه ملخ سالم با ملخ دارای سوراخ افزایش دور به همراه استفاده از هر دو ویژگی‌های زمانی و فرکانسی بهترین پاسخ را می‌دهد البته برای ۱۵۰۰ دور در دقیقه، استفاده فقط از ویژگی فرکانسی بهترین پاسخ را برای درصد طبقه‌بندی صحیح داده‌های آزمون داده است. در تعیین ملخ نامیزان در دور ۱۵۰۰ بر دقیقه استفاده همزمان از هر دو مشخصه زمانی و فرکانسی با هم منجر به نتایج بهتری نمی‌گردد. و برای نتایج بهتر بایستی دور را افزایش داد.

از بررسی‌های اخیر می‌توان نتیجه گرفت که برای مقایسه ملخ سالم و نامیزان افزایش دور به همراه استفاده از ترکیب هر دو مشخصه زمانی و فرکانسی با هم برای درصد طبقه‌بندی صحیح داده‌های آزمون بهترین پاسخ را می‌دهد. هرچند استفاده از دوره‌های بالاتر به نتایج بهتری منجر شده اما در برخی از عیوب مقدار دور نباید چندان زیاد گردد زیرا سایر اثرات دینامیکی منجر به پنهان ماندن عیب در ملخ می‌گردد.

لذا بدست آوردن یک دور بهینه و استفاده از آن برای عیب‌یابی پیشنهاد می‌گردد. برای حالت مقایسه ملخ سالم و ملخ دارای عیب، افزایش دور به همراه استفاده از هر دو ویژگی‌های زمانی و فرکانسی بهترین پاسخ را برای درصد طبقه‌بندی صحیح داده‌های آزمون را بدست می‌دهد.

## ۵. جمع‌بندی و نتیجه‌گیری

برای حل چالش اصلی در زمینه نظارت بر وضعیت ارتعاش، استخراج و شناسایی ویژگی‌های خطا قبل از بحرانی شدن آن است. این مقاله وجود عیب در یک ملخ متصل به الکتروموتور را به روش تجربی و آنالیز ارتعاشی بررسی می‌کند.

بعد از داده برداری در حوزه شتاب برای چهار حالت از ملخ به استخراج ویژگی در حوزه‌های زمانی، فرکانسی پرداخته شده است. استفاده صرف از نمودارهای طیف فرکانسی در دوره‌های مختلف، حضور یا عدم حضور عیب در ملخ را نشان نمی‌دهد و یا اینکه حداقل تفاوت بین نوع عیب ملخ را آشکار نمی‌سازد. لذا نیاز به روشی قابل اتکا به منظور شناسایی عیب و یا حتی تفکیک نوع عیب در ملخ احساس می‌شود که در این تحقیق از روش هوشمند شبکه عصبی احتمالاتی و روش الگوریتم هوشمند ماشین بردار پشتیبان استفاده شده است. روش شبکه عصبی احتمالاتی قادر است تا با دقت قابل قبولی هر چهار حالت ملخ (سالم، دارای نابالانسی، ترک و سوراخ) را از یکدیگر تفکیک نماید. این روش نه تنها حالت‌های معیوب را از سالم جدا می‌نماید بلکه توانایی خوبی در تفکیک کلیه حالات از یکدیگر دارد.

استفاده از روش ماشین بردار پشتیبان نیز همانند روش شبکه عصبی احتمالاتی نتایج قابل قبولی داده است. در مجموع انتخاب هر دو مشخصه زمانی و فرکانسی با هم منجر به نتایج بهتری می‌گردد. در ضمن از مقایسه شبکه عصبی احتمالاتی و ماشین بردار پشتیبان نتیجه می‌شود که در چهار حالت ملخ (سالم، دارای نابالانسی، ترک و سوراخ) استفاده از روش شبکه عصبی احتمالاتی نتایجی با صحت بالاتر می‌دهد که این مورد دلالت بر دقت بالا و کیفیت مناسب این روش شبکه عصبی دارد. هرچند که انتظار می‌رود با استفاده از دوره‌های بالاتر به نتایج بهتری دست یافت اما در برخی از عیوب مقدار دور نباید چندان زیاد گردد زیرا سایر اثرات دینامیکی منجر به پنهان ماندن عیب در ملخ می‌گردد. لذا در

اینجا استفاده از دور بهینه برای عیب‌یابی پیشنهاد می‌گردد.

## ۶ مآخذ

- [1] Rajendra P Palanisamy, Chetan S. Kulkarni, Matteo Corbetta, Portia Banerjee, Fault detection and Performance Monitoring of Propellers in Electric UAV IEEE Conference Publication, pp. 05-12 2022.
- [2] S. Sastry, I. Bhargavi Rachana, K. Durga Rao, Stress Analysis of Helicopter Composite Blade Using Finite Element Analysis, International Journal of Engineering Research and Technology, Vol. 2, No. 12, pp. 1291-1299, 2018.
- [3] Seyyed Mohamad M., Mostafa K., AmirMahdi S., Sensitivity Analysis of Vibration Characteristics for Localization of Imbalance Fault on the Helicopter Blade, Aerospace Knowledge and Technology Journal, Vol. 13 (1), pp. 113-128, 2024, [in persian].
- [4] S.W. Doebbling, C.R. Farrar, M.B. Prime, D.W. Shevitz, Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: a literature review, Technical Report LA-13070-MS, Los Alamos National Laboratory, 1996.
- [5] H. Sohn, C.R. Farrar, F.M. Hemez, D.D. Shunk, D.W. Stinemates, B.R. Nadler, J.J. Czarnecki, A review of structural health monitoring literature: 1996-2001, Technical Report LA-13070-MS, Los Alamos National Laboratory, 2004.
- [6] Gangsar, P., & Tiwari, R., Signal based condition monitoring techniques for fault detection and diagnosis of induction motors: A state-of-the-art review, Mechanical systems and signal processing, Vol. 144:106908, 2020.
- [7] Ikpe, A. E., Etuk, E. M., & Adoh, A. U., Modelling and analysis of 2-stage planetary gear train for modular horizontal wind turbine application, Journal of applied research on industrial engineering, Vol. 6(4), pp. 268-282, 2019.
- [8] Bogard, F., Debray, K., Guo, Y. Q., & Pavan, A., Numerical methodology to easily detect defects in revolving machines by vibration analysis, Elsevier, Mécanique and industries, Vol. 3, pp. 79-87, 2002.
- [9] Zohreh M., MirMohammad E., Morteza S., seyednacer R., Identification and damage detection of beam-like structure using vibration signals based on simulated model real healthy state and deep

convolutional neural network, Amirkabir Journal of Mechanical Engineering, Vol. 53(4), pp. 2193-2216, 2022, [in persian].

- [10] Yezhong Lu, Haifeng Ma, Yuxin Sun, Qinghua Song, Zhanqiang Liu, Zhenhua Xiong, An interpretable anti-noise convolutional neural network for online chatter detection in thin-walled parts milling, Mechanical Systems and Signal Processing, Vol. 206:110885, 2024.
- [11] Orhan Yaman, Ferhat Yol, Ayhan Altinors, Fault Detection Method Based on Embedded Feature Extraction and SVM Classification for UAV Motors, Microprocessors and Microsystems, Vol. 94: 104683, 2022
- [12] D. F. Specht, Probabilistic neural networks, Neural Networks, Vol. 3, pp. 109-118, 1990.
- [13] S. Rutkowski L., Methods and techniques of artificial intelligence, Wydawnictwo Naukowe PWN, Warsaw, 2012.
- [14] S. S. Haykin, Neural networks and learning machines, Pearson Upper Saddle River, NJ, USA, 2009.
- [15] G. Zheng and et.al., Neural networks and learning machines, Pearson Upper Saddle River, Underground Space, Vol. 6(2), pp. 126-133, 2021.
- [16] Burdes C.J.C., A Tutorial on Support Vector Machines for Pattern Recognition Data Mining and Knowledge Discovery, Kluwer Academic Publishers, Boston, 1998.

## ۷. پی‌نوشت

1. Arduino UNO
2. CATIA software
3. ABAQUS software
4. LabVIEW software
5. T-Distributed Stochastic Neighbor Embedding

۱۴۹

سال ۱۳ - شماره ۲

پاییز و زمستان ۱۴۰۳

نشریه علمی

دانش و فناوری هوا فضا

