

Ensemble Learning based Model for Multi-Sensor Vibration Data Fusion in Gearbox Diagnosis

Hesam Addin Arghand^{1*}, Amir Hossein Kheybarinejhad¹

¹Department of Mechanical Engineering, University of Zanjan, Zanjan, Iran. Email: arghand@znu.ac.ir

ABSTRACT

This study investigates recorded vibration signals from a laboratory gearbox to assess health condition and identify fault types, using a proposed ensemble-based machine learning algorithm. A single-stage gearbox was designed and tested in laboratory under four health states: no faults, tooth root crack, tooth breakage, and pitting on the tooth, across varying loads and speeds. Vibration was recorded at six points. Totally 792 signals (6 signals from 132 tests) were collected. For the data from each sensor, a support vector machine (SVM) classifier with a linear kernel was trained. Next, fault detection accuracy was assessed and compared for each transducer individually. A new data fusion algorithm, inspired by random forest (RF), was developed to combine data from the six sensors. The results showed that the proposed ensemble algorithm provides higher detection accuracy rather than the individual classifiers for each sensor. In addition, a novel method is introduced to estimate the confidence level (CL) of the classification by the proposed algorithm. In addition, it is demonstrated that the proposed algorithm can effectively diagnose faults with incomplete data (regardless of how many sensors are used from the total of six). As expected, using data from fewer sensors resulted in reduced accuracy and CL.

KEYWORDS

Vibration Condition Monitoring, Gearbox Diagnosis, Ensemble Machine Learning, Confidence Level, Sensor Fusion.

* Corresponding Author: Email: arghand@znu.ac.ir

1. Introduction

Gearboxes are common rotating machinery used in various industrial applications. They are employed to transmit power for given input to output ratio of rotating speed or torque. Their harsh operating conditions increase the risk of component failures, especially gears. Common gear failures include tooth breakage, root cracks, pitting due to fatigue, plastic deformation of teeth, and wear [1]. Condition-based maintenance (CBM) is one of the most efficient maintenance strategies that can be used to detect the faults of gearbox in the early stage [2]. Vibration condition monitoring (VCM) is one of the most powerful and commonly used techniques for diagnostics of the industrial gearbox. Detecting of faults signatures in the vibration signals requires complicated analysis of experts. Consequently, the application of various artificial intelligence (AI) methods to interpret vibration signals and fault detection has attracted significant attention of researchers [1-6].

In this article a new ensemble-based model is introduced to be employed for diagnostics of gearbox from vibration signals. Various features regarding the gearbox faults [4-6] were extracted from vibration signals recorded from 6 sensors of experimental set-up. The data of each sensor are used for building a base support vector machine (SVM) model. Six built models are employed for making an ensemble model that provides fusion of data. Additionally, a new approach is suggested to estimate the confidence-level (CL) of diagnosis. The proposed ensemble model can also effectively be used with the data of limited number of sensors.

2. Methodology

In this study, the suggested vibration features for gearbox diagnostics in the literature [4-6] have been utilized to construct a dataset from multi-sensor recorded data of gearbox VCM. Then, SVM algorithm is employed to develop a base classifier for the data of each single sensor. These base classifiers are used to construct an ensemble model that is shown in Figure 1. The output of the model is derived through a voting of the outputs of each individual classifier.

To implement weighted voting, the output of each base model is weighted corresponding to the recall value obtained from training dataset for that specific class. To estimate the CL of the proposed model output the following procedure is suggested. If the dataset comprises m distinct classes and the ensemble model consists of n base models, and the prediction of the i -th model for a given data is denoted as y_i , then, in the

present study, equation (1) is proposed to calculate the initial CL for the j -th class (ICL_j).

$$ICL_j = \sum_{i=1}^{n_j} R_i^j ; \quad j = 1, 2, \dots, m \quad (1)$$

where R_i^j is i^{th} recall values of n_j models which their output is the j -th class (where $n_j \leq n$). The value of ICL_j is calculated for the classes where at least one of the base models has produced that class as its output. If none of the base models generate an output corresponding to a specific class, the value of ICL_j for that class is considered to be zero. Although the calculated ICL s are comparable with each other, they are not in a specific range of [0,1]. To make these values easier to understand, Equation (2) is proposed to normalize the ICL s and find CL_j in the range of [0,1] so that the summation of CL s for all classes will be unit.

$$CL_j = \frac{ICL_j}{\sum_{i=1}^m ICL_i} \quad (2)$$

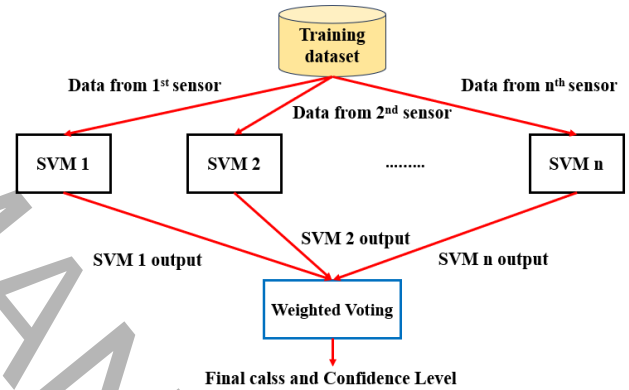


Figure 1: The proposed ensemble model

A key feature of the proposed ensemble model, illustrated in Figure 1, is its flexibility in practical applications. Even if the model is trained using data from all available sensors, it can still be effectively utilized with a limited number of sensors as input (less than total number of sensors). This allows the model to classify new data points reasonably, albeit with reduced certainty. This capability enhances the practical applicability of the proposed model applications.

3. Results and Discussion

To investigate the performance of the proposed method in this article, a set of experiments has been planned and conducted. Vibration signals from six different points are recorded for various health conditions and operating conditions. The recorded signals belong to 4 classes. Class 1 is for healthy

condition of gear. Classes 2, 3 and 4 is for faulty conditions (tooth breakage, root crack and pitting, respectively). To evaluate the performance of classifier models on data from different sensors, six SVM classifiers with a linear kernel were developed. Each classifier was trained using the training dataset from one sensor and tested using the corresponding test dataset. Then the proposed model in Figure 1 was constructed and its performance tested on the train and test sets. The average accuracy of base models as well as the accuracy of the proposed ensemble model are reported in Table 1. These results show the better performance and considerable higher accuracy of the proposed model.

Table 1: The accuracy of the proposed ensemble model on the training and test datasets

Dataset	Average of base models	Proposed Model
Train set	84.7%	96.2%
Test set	78.2%	96.1%

In Figure 2, the confusion matrix of the proposed model on training and testing sets are presented.



Figure 2: Confusion matrix of the proposed ensemble model for the train data (left) and the test data (right)

To determine the CL of each prediction on the test data, the procedure described in Section 2 was applied to all 26 samples in test dataset. Using Equation (2), the CL for all existing classes can be calculated for each sample, and the class with the highest CL is reported as the final output of the proposed ensemble model. In Figure 3, the CL obtained using the data of all 6 sensors for each class are illustrated with different colors for all 26 test samples, represented by hollow markers and solid lines. The similar results extracted from only the data of 4 sensors (out of 6) are depicted with hollow markers and dashed lines. Additionally, the true class label of each sample is indicated by a solid marker above the plot. The correctness of model output is accompanied by the letters "T" (True) or "F" (False) to above the solid markers. The first row of T/F corresponds to the model performance with six sensor data as inputs and the second row corresponds to that with four sensor data as inputs. It can be observed that only for samples #14 and #17, the output of models with different number of inputs are varied. However, the CL of classification is different for almost all the samples.




Figure 3: The confidence level of classifying each class by the proposed ensemble model across all 26 samples of the test dataset

4. Conclusions

In this study, a novel ensemble model is proposed. The base SVM classifiers (with each utilizing data from a single sensor as input) were constructed. The proposed model offers the capability to integrate data from multiple sensors in such a way that after training, the model can be employed with the data from any number of sensors. Additionally, a method for estimating the CL of detecting each class was proposed.

The proposed method was evaluated on vibration data recorded from a laboratory gearbox under various health and operating conditions. It was demonstrated that, as expected, the proposed ensemble model achieves higher accuracy compared to the base models. Furthermore, when the number of sensors used as inputs to the ensemble model is reduced, the classification accuracy decreases to some extent, and the average CL of the predictions also declines.

5. References

- [1] P. Ku, Gear failure modes—importance of lubrication and mechanics, *ASLe Transactions*, 19(3) (1976) 239-249.
- [2] R.B. Randall, *Vibration-based condition monitoring: industrial, automotive and aerospace applications*, John Wiley & Sons, 2021.
- [3] V. Singh, P. Gangsar, R. Porwal, A. Atulkar, Artificial intelligence application in fault diagnostics of rotating industrial machines: A state-of-the-art review, *Journal of Intelligent Manufacturing*, 34(3) (2023) 931-960.
- [4] P. Večeř, M. Kreidl, R. Šmíd, Condition indicators for gearbox condition monitoring systems, *Acta Polytechnica*, 45(6) (2005).
- [5] V. Sharma, A. Parey, A review of gear fault diagnosis using various condition indicators, *Procedia Engineering*, 144 (2016) 253-263.
- [6] H. Ahmed, A.K. Nandi, *Condition monitoring with vibration signals: Compressive sampling and learning algorithms for rotating machines*, John Wiley & Sons, 2020.

مدل مبتنی بر یادگیری جمعی برای ترکیب داده‌های ارتعاشی چند حسگر در عیب‌یابی جعبه‌دنده

حسام الدین ارغند^{۱*}، امیرحسین خیبری نژاد^۱

۱- گروه مهندسی مکانیک، دانشکده مهندسی، دانشگاه زنجان، زنجان، ایران، arghand@znu.ac.ir

چکیده

در پژوهش حاضر سیگنال‌های ثبت شده از یک جعبه‌دنده آزمایشگاهی به منظور شناسایی وضعیت سلامت و نوع عیوب، توسط الگوریتم نوین پیشنهاد شده مبتنی بر یادگیری جمعی (الهام گرفته شده از الگوریتم جنگل تصادفی) مورد مطالعه قرار گرفته است. به همین جهت، یک جعبه‌دنده آزمایشگاهی یک مرحله‌ای طراحی و ساخته شده و در چهار وضعیت سلامت مختلف با شرایط کاری متنوع آزمایش شده است. ارتعاشات در ۶ نقطه جهت ثبت گردیده و در مجموع ۷۹۲ سیگنال اندازه‌گیری شده است. برای داده‌های ثبت شده توسط هر حسگر یک طبقه‌بند ماشین بردار پشتیبان با کرنل خطی آموزش داده شده و دقت تشخیص عیوب توسط داده‌های هر یک از حسگرها (به صورت جداگانه) استخراج و مقایسه شده است. سپس یک الگوریتم جدید برای ترکیب داده‌های ۶ حسگر توسعه داده شده است. نتایج نشان می‌دهد که الگوریتم پیشنهادی دقت تشخیص بالاتری نسبت به طبقه‌بندهای ساخته شده از هر حسگر دارد. همچنین روشی برای محاسبه سطح اطمینان تشخیص الگوریتم پیشنهادی نیز ارائه گردیده است. نشان داده شده است که روش پیشنهادی می‌تواند با در دست داشتن داده‌های کمتر (هر تعداد حسگر از مجموع ۶ حسگر) نیز برای هدف عیب‌یابی به کار رود و در این صورت، مطابق انتظار دقت و سطح اطمینان تشخیص‌های آن کاهش می‌یابد.

کلمات کلیدی

پایش وضعیت ارتعاشات، عیب‌یابی جعبه‌دنده، یادگیری ماشین جمعی، سطح اطمینان، ترکیب حسگرها

جعبه‌دنده‌ها از ماشین‌های دوار رایج در صنعت هستند. جعبه‌دنده‌ها گشتاور تولید شده توسط محرک را به مصرف‌کننده منتقل می‌کنند. این کار از طریق درگیری چرخنده‌ها اتفاق می‌افتد و در نسبت سرعت و جهت دوران محور ورودی و خروجی اثر می‌گذارد. شرایط کاری دشوار جعبه‌دنده، پتانسیل خرابی اجزای آن مانند چرخنده‌ها را افزایش می‌دهد. خرابی این اجزا سبب اختلال در عملکرد جعبه‌دنده خواهد شد و خرابی آن را به دنبال خواهد داشت. بعد از خرابی یاتاقان‌های غلتشی، خرابی چرخنده‌ها رایج‌ترین حالت خرابی جعبه‌دنده است [۱]. از این رو، شناسایی به موقع عیب در اجزای جعبه‌دنده مانند چرخنده‌ها به افزایش قابلیت اطمینان آنها و دسترس‌پذیریشان کمک کرده و از خرابی‌های ناگهانی جلوگیری می‌کند. از حالت‌های خرابی رایج چرخنده‌ها می‌توان به شکستگی دندان، ترک ریشه دندان، حفره‌دار شدن سطح^۱ ناشی از خستگی، تغییر شکل پلاستیک دندان و سایش اشاره کرد [۲]. نگهداری و تعمیرات (نت) مبتنی بر وضعیت^۲ امروزه به عنوان کارآمدترین استراتژی نت در بسیاری از صنایع شناخته می‌شود [۳]. روش‌های مختلفی برای پایش وضعیت ماشین‌ها وجود دارد که می‌توان به آنالیز ارتعاشات، آنالیز روغن [۴]، آنالیز انتشار صدا^۵، آنالیز جریان [۵] و آنالیز ترموگرافی^۶ [۶، ۷] اشاره کرد. از این میان، آنالیز ارتعاشات به دلیل حساسیت بالا نسبت به تغییرات ویژگی‌های دینامیکی ماشین، توانایی زیادی در تشخیص عیب، حتی در مراحل اولیه پیدایش و رشد آن دارد. تشخیص عیوب در جعبه‌دنده‌ها نیازمند تحلیل پیچیده توسط فرد متخصص و با تجربه است. از این رو، استفاده از روش‌های مختلف هوش مصنوعی برای تفسیر سیگنال‌های ارتعاشی و تشخیص عیب مورد توجه محققین قرار گرفته است [۸].

تحقیقات مختلفی روی تشخیص عیب هوشمند تجهیزات مختلف مانند جعبه‌دنده با استفاده از آنالیز ارتعاشات توسط محققین انجام شده است. تیان و زو [۹] از داده‌های جعبه‌دنده آزمایشگاهی برای توسعه مدل شبکه عصبی مصنوعی^۵ استفاده کردند. هدف این مدل، تشخیص وضعیت سلامت جعبه‌دنده بر اساس سطح ارتعاشات آن بوده است. آنها برای آموزش شبکه عصبی از خصیصه ریشه میانگین مربعات^۶ سیگنال استفاده کردند. در این پژوهش مشاهده گردید که خروجی مدل شبکه عصبی مصنوعی، با دقت مناسبی منطبق بر مقادیر واقعی ریشه میانگین مربعات می‌باشد و می‌توان با استفاده از آن روند زوال و وضعیت سلامت جعبه‌دنده را تشخیص داد. در پژوهشی دیگر که روی همان مجموعه داده آزمایشگاهی انجام شده است، کلفتی و همکاران [۱۰]، با استفاده از مدل مخفی مارکوف^۷ به دنبال عیب‌یابی و تخمین عمر مفید باقی‌مانده جعبه‌دنده بودند. آنها ریشه میانگین مربعات سیگنال را معرف مناسبی برای تعیین وضعیت جعبه‌دنده در نظر گرفتند. یانگ و همکاران [۱۱] با استفاده از الگوریتم درخت تصمیم^۸ به تشخیص عیب تجهیزات دوار از روی سیگنال ارتعاشات پرداختند. آنها برای آموزش مدل از داده‌های تجربی استفاده کردند. نتایج ارزیابی مدل توسعه داده شده توسط ایشان نشان دهنده تشخیص ناهنجاری‌های موجود در سیگنال ارتعاشات با قابلیت اطمینان بالا بود. جمادار و همکاران [۱۲] به عیب‌یابی چرخنده ساده با استفاده از ماشین بردار پشتیبان^۹ پرداختند. در این پژوهش از داده‌های ارتعاشات یک جعبه‌دنده آزمایشگاهی استفاده شده است. طراحی آزمایش‌های انجام شده به گونه‌ای است که ۸۴ آزمایش با در نظر گرفتن تغییر شرایط کاری (سرعت و بارگذاری)، وضعیت چرخنده (سالم و معیوب) و شدت عیب شکستگی دندان و حفره سطح (در سه وضعیت ۲۵، ۵۰ و ۱۰۰ درصد) انجام شده است. در این پژوهش سیگنال‌های ارتعاشات در سه حوزه زمان، فرکانس و زمان-فرکانس پردازش شده‌اند و خصیصه‌های مختلفی از آنها استخراج شده است. نشان داده شد که خصیصه ریشه میانگین مربعات و کورتوسیس^{۱۰} می‌توانند روند رشد عیب را به خوبی نشان دهند. همچنین مدل ساخته شده با ماشین بردار پشتیبان به خوبی وضعیت چرخنده را طبقه‌بندی کرده

¹ Pitting

² Condition Based Maintenance (CBM)

³ Acoustic Emission (AE)

⁴ Thermography

⁵ Artificial Neural Network (ANN)

⁶ Root Mean Square (RMS)

⁷ Hidden markov model

⁸ Decision tree

⁹ Support Vector Machine (SVM)

¹⁰ Kurtosis

است. سامانتا [۱۳] از سیگنال ارتعاشات در حوزه زمان برای استخراج خصیصه‌های معرف وضعیت سلامت چرخنده‌ها استفاده کرده است. خصیصه‌های استخراج شده برای آموزش مدل‌های طبقه‌بند شبکه عصبی مصنوعی و ماشین بردار پشتیبان بکار گرفته شده‌اند. همچنین از الگوریتم ژنتیک^۱ برای کاهش ابعاد خصیصه‌های بکار رفته استفاده شده است. با مقایسه نتایج بدست آمده مشاهده گردید که دقت طبقه‌بند ماشین بردار پشتیبان، در هر دو حالت استفاده از الگوریتم ژنتیک، بالاتر از شبکه عصبی مصنوعی می‌باشد. سراوانان و راماجاندران [۱۴] خصیصه‌های استخراج شده از تبدیل موجک گسسته^۲ سیگنال ارتعاشات را به عنوان ورودی شبکه عصبی مصنوعی جهت طبقه‌بندی عیوب چرخنده مخروطی استفاده کردند. نتایج بدست آمده نشان می‌دهد که روش توسعه یافته با اطمینان بالا می‌تواند وضعیت سلامت چرخنده را تشخیص دهد. همچنین نشان داده شد که تبدیل موجک یک ابزار قدرتمند برای پایش وضعیت و تشخیص عیب چرخنده می‌باشد. چن و همکاران [۱۵] با استفاده از یادگیری عمیق شبکه عصبی کانولوشن^۳ به تشخیص عیوب مختلف در چرخنده مانند حفره‌دار شدن سطح، سایش و شکستگی دندان‌ها پرداختند. آنها پارامترهای آماری مختلفی از سیگنال ارتعاشات در حوزه زمان مانند انحراف معیار، کورتوسیسی و چولگی^۴ را استخراج کردند. سپس در حوزه فرکانس، طیف بدست‌آمده از تبدیل فوریه سریع^۵ را به چند باند فرکانسی تقسیم کردند تا انرژی هر قسمت توسط میانگین ریشه مربعات محاسبه گردد. دقت بدست آمده برای مدل طبقه‌بند نشان می‌دهد که روش پیشنهادی در تشخیص عیوب جعبه‌دنده‌ها قابل اعتماد و استفاده می‌باشد.

در پژوهش حاضر تشخیص عیوب جعبه‌دنده با استفاده از پردازش سیگنال‌های ارتعاشات و بکارگیری الگوریتم‌های یادگیری ماشین مورد بررسی قرار می‌گیرد. برای این منظور، یک چیدمان آزمایشگاهی برای مطالعه ارتعاشات جعبه‌دنده معیوب در آزمایشگاه نت مبتنی بر وضعیت دانشگاه زنجان طراحی و ساخته شده است و داده‌های متنوعی به ازای وضعیت عیوب مختلف و شرایط کاری متنوع از آن ثبت گردیده است. خصیصه‌های معرف وضعیت سلامت چرخنده که توسط محققین پیشنهاد شده است [۱۶-۱۸] از سیگنال‌های ارتعاشات بدست آمده از آزمایش‌های انجام شده استخراج شده است. سپس با استفاده از خصیصه‌های استخراج شده، مدل‌های طبقه‌بند هوشمندی مبتنی بر یادگیری ماشین نظارت شده برای عیب‌یابی هوشمند و تعیین سطح اطمینان تشخیص توسط داده‌های هر یکی از حسگرها (به طور جداگانه) توسعه داده شده و عملکرد آنها با یکدیگر مقایسه می‌گردد. در ادامه مدل جدیدی مبتنی بر الگوریتم ترکیبی جنگل تصادفی^۶ معرفی می‌گردد که قابلیت استفاده هم‌زمان از داده‌های تمام حسگرهای ارتعاشی مورد استفاده برای تفسیر وضعیت ماشین را ایجاد می‌کند. مدل ترکیبی ساخته شده با رویکرد پیشنهادی، می‌تواند با داشتن داده‌های هر تعداد حسگر ارتعاش‌سنج نیز، به شکل مطلوبی عمل کند و مطابق انتظار با داشتن داده‌های تعداد بیشتری از حسگرها، با سطح اطمینان بالاتری وضعیت سلامت یا نوع عیب را تعیین کند.

۲- معرفی روش‌ها

در مدلسازی داده‌محور که فرآیند آن صرفاً مبتنی بر در دست داشتن داده‌های ورودی و خروجی و بدون توجه به قواعد فیزیکی حاکم بر مسئله دنبال می‌گردد، دو گام اساسی وجود دارد. گام نخست انتخاب مناسب ورودی‌ها و گام دوم پیکربندی مناسب از بکارگیری الگوریتم‌های هوش مصنوعی است. در پژوهش حاضر ورودی‌ها شامل خصیصه‌های معرف وضعیت سلامت چرخنده هستند که از سیگنال‌های ارتعاشات اندازه‌گیری شده بدست آمده‌اند. برای ساخت مدل‌های طبقه‌بند نیز از الگوریتم ماشین بردار پشتیبان استفاده شده است که در ادامه به تشریح آنها پرداخته شده است.

¹ Genetic Algorithm (GA)

² Discrete Wavelet Transform (DWT)

³ Convolutional Neural Network (CNN)

⁴ Skewness

⁵ Fast Fourier Transform (FFT)

⁶ Random forest

۱-۲- استخراج خصیصه‌های ارتعاشی

سیگنال‌های ارتعاشات اندازه‌گیری شده خام متأثر از عوامل مختلف ایجاد ارتعاش و همچنین نویز بوده و حاوی اطلاعات زیادی هستند و به طور معمول تفسیر آنها دشوار است. از این رو عملیات پردازش مختلفی روی سیگنال‌های اندازه‌گیری شده اعمال می‌شود تا نویز و عوامل ناخواسته را حذف کند و اثر عوامل مختلف روی سیگنال از هم تفکیک شود. همچنین خصیصه‌های آماری مختلفی از سیگنال ارتعاشات استخراج می‌شود که بیانگر وضعیت سلامت تجهیز است. معمولاً برای استخراج خصیصه‌هایی که معرف وضعیت سلامت چرخنده هستند از سه نوع خاص سیگنال استفاده می‌شود که به سیگنال باقی‌مانده^۱، سیگنال دیفرانسیل^۲ و سیگنال منظم^۳ معروف می‌باشند و از طریق فیلتر کردن سیگنال بدست می‌آیند. در ادامه به معرفی خصیصه‌های قابل استخراج از سیگنال و نحوه استخراج سه نوع سیگنال مذکور پرداخته می‌شود.

۱-۱-۲- خصیصه‌های حوزه زمان

سیگنال‌های اندازه‌گیری شده از تجهیزات دوار در حوزه زمان ثبت می‌شوند، یعنی نمونه‌های اندازه‌گیری شده در یک توالی زمانی با فرکانس مشخص (فرکانس نمونه‌برداری) به صورت گسسته ذخیره می‌شوند. خصیصه‌های آماری مختلفی از سیگنال خام ارتعاشات استخراج می‌شود. با استفاده از این خصیصه‌ها می‌توان وضعیت کلی سلامت تجهیزات را مشخص کرد. در جدول ۱، خصیصه‌های آماری استخراج شده از سیگنال خام ارتعاشات ارائه شده است [۱۶-۱۸].

جدول ۱: خصیصه‌های استخراج شده از سیگنال خام ارتعاشات و تعریف ریاضی آنها

Table 1: Extracted features from raw vibration signals and their mathematical definitions

رابطه ریاضی	نوع سیگنال	نماد	نام خصیصه
$\sigma_x^2 = \frac{\sum (x_i - \bar{x})^2}{N-1}$	سیگنال خام	VAR	واریانس
$\sigma_x = \sqrt{\frac{\sum (x_i - \bar{x})^2}{N-1}}$	سیگنال خام	STD	انحراف معیار
$RMS = \sqrt{\frac{1}{N} \sum_{i=1}^N x_i ^2}$	سیگنال خام	RMS	ریشه میانگین مربعات
$P = \max(x)$	سیگنال خام	P	پیک
$P2P = x_{\max} - x_{\min}$	سیگنال خام	P2P	پیک به پیک
$CF = \frac{P}{RMS}$	سیگنال خام	CF	فاکتور کرس
$K = \frac{\sum_{i=1}^N (x_i - \bar{x})^4}{N\sigma_x^4}$	سیگنال خام	K	کور تویسیس
$S = \frac{\sum_{i=1}^N (x_i - \bar{x})^3}{N\sigma_x^3}$	سیگنال خام	S	چولگی
$EO = \frac{N \sum_{i=1}^N (\Delta s_i - \Delta \bar{s})^4}{\left(\sum_{i=1}^N (\Delta s_i - \Delta \bar{s})^2 \right)^2}$	سیگنال خام	EO	عملگر انرژی
$\vec{J}(t) = \frac{d\vec{a}(t)}{dt}$	سیگنال خام	J	جرک

¹ Residual signal

² Differential signal

³ Regular signal

$$IF = \frac{Peak}{\frac{1}{N} \sum_{i=1}^N |x_i|}$$

۲-۱-۲- میانگین‌گیری همگام زمانی

میانگین‌گیری همگام زمانی^۱، x_{TSA} ، به عنوان یک روش برای پردازش سیگنال‌های ارتعاشات پایا تعریف می‌شود. این روش موج‌های متناوب را از داده‌های ارتعاشی خام که عموماً شلوغ و پر از نویز هستند، استخراج می‌کند. فرمول ریاضی برای محاسبه سیگنال میانگین‌گیری همگام زمانی در رابطه (۱) نشان داده شده است [۱۸، ۱۹].

$$x_{TSA} = \frac{1}{N} \sum_{n=0}^{N-1} x(t+nT) \quad (1)$$

در رابطه فوق x سیگنال خام، T زمان یک دور چرخش محور و N تعداد دفعات دوران کامل محور در طول مدت اندازه‌گیری سیگنال خام است. بدین ترتیب، دامنه‌هایی که تکرار آنها تصادفی است یا ضریب صحیحی از دور محور نیستند، در اثر میانگین‌گیری از رابطه فوق تضعیف می‌گردند و سیگنال x_{TSA} بدست آمده حاوی اثر پدیده‌های تکرار شده به صورت ضریب صحیحی از دور محور خواهد بود.

۲-۱-۳- حوزه فرکانس و فرکانس‌های مشخصه

در حوزه فرکانس، هر موج سینوسی به عنوان یک جزء طیفی ارائه می‌شود. آنالیز فرکانس که آنالیز طیفی نیز نامیده می‌شود، یکی از رایج‌ترین روش‌های تحلیل ارتعاشات برای پایش وضعیت ماشین‌ها است. این روش، توانایی نشان دادن اطلاعات سیگنال بر اساس ویژگی‌های تفکیک شده در فرکانس‌های مختلف که به راحتی در حوزه زمانی قابل مشاهده نیستند، را دارد. بررسی سیگنال در حوزه فرکانس، دیدن هر یک از منابع مولد ارتعاش را آسان می‌کند. برای انتقال سیگنال ارتعاشاتی گسسته از حوزه زمان به حوزه فرکانس از تبدیل فوریه سریع^۲ استفاده می‌شود.

از مهم‌ترین فرکانس‌های مورد بررسی در جعبه‌دنده‌ها می‌توان به فرکانس درگیری چرخنده‌ها^۳، باندهای کناری^۴ فرکانس درگیری چرخنده‌ها و فرکانس دورانی هر یک از محورهای جعبه‌دنده اشاره کرد.

سرعت دورانی هر محور در جعبه‌دنده، فرکانس تحریک موج متناوبی است که دامنه آن به شدت عیوب مربوط به آن محور بستگی دارد. عیوبی مانند نامیزانی بر دامنه این فرکانس تأثیر می‌گذارد. همچنین مضارب صحیح این فرکانس می‌تواند در طیف فرکانسی مشاهده شود که بیانگر وجود عیوبی مانند ناهمراستایی محورها یا پدیده متناوب دیگر مانند تفاوت در درگیری چرخنده‌ها ناشی از خروج از مرکزیت هندسی و ... است.

مهمترین خصیصه فرکانسی جعبه‌دنده که در عیب‌یابی چرخنده‌ها از آن استفاده می‌شود، دامنه فرکانس درگیری چرخنده‌ها (F_{mesh}) است. برای هر دو چرخنده درگیر، یک فرکانس درگیری چرخنده در طیف فرکانسی وجود دارد. چرخنده‌ها چه سالم باشند و چه معیوب، به دلیل درگیری مداوم با یکدیگر، دامنه قابل توجه در این فرکانس همیشه در طیف فرکانسی قابل مشاهده می‌باشد. برای محاسبه فرکانس درگیری چرخنده‌ها از رابطه (۲) استفاده می‌شود.

$$F_{mesh} = \omega_{pinion} \times N_{pinion} = \omega_{gear} \times N_{gear} \quad (2)$$

که در آن N_{pinion} و N_{gear} به ترتیب تعداد دندانه‌های پینیون و چرخنده و ω_{pinion} و ω_{gear} نیز به ترتیب سرعت دورانی پینیون و چرخنده هستند.

¹ Time Synchronous Averaging (TSA)

² Fast Fourier Transform (FFT)

³ Gear Mesh Frequency (GMF)

⁴ Sidebands

علاوه بر فرکانس درگیری چرخنده‌ها، در طیف فرکانسی دو دامنه نیز در طرفین فرکانس درگیری چرخنده‌ها و به فاصله دور محوری که هر چرخنده روی آن سوار است، ظاهر می‌شود که به آن فرکانس باندهای کناری (F_{SB}) می‌گویند. این فرکانس از رابطه (۳) محاسبه می‌شود. با اینکه فرکانس درگیری چرخنده‌ها برای هر دو چرخنده برابر است، اما هر چرخنده فرکانس باند کناری مرتبط با سرعت دورانی محور خود را دارد.

$$F_{SB} = F_{mesh} \pm \omega_{shaft} \quad (3)$$

در رابطه فوق ω_{shaft} سرعت دورانی محوری است که چرخنده روی آن نصب شده است.

۴-۱-۲- سیگنال‌های زمانی فیلتر شده

به طور رایج در تحلیل وضعیت سلامت جعبه‌دنده‌ها از سه نوع سیگنال فیلتر شده به نام‌های سیگنال باقی‌مانده، سیگنال دیفرانسیل و سیگنال منظم استفاده می‌شود. با حذف فرکانس درگیری دندانه، فرکانس دوران محورها و هارمونیک‌های آن دو فرکانس از سیگنال میانگین همگام زمانی، سیگنال باقی‌مانده بدست می‌آید. اگر علاوه بر موارد فوق، باندهای کناری فرکانس‌های درگیری دندانه‌ها از سیگنال میانگین همگام زمانی حذف شوند، سیگنال دیفرانسیل بدست خواهد آمد. لازم به توضیح است که برای استخراج این سیگنال‌ها، محققین با سلاقی متفاوتی در مورد در نظر گرفتن تعداد هارمونیک‌های فرکانس درگیری چرخنده و باندهای کناری عمل می‌کنند. در این پژوهش، برای استخراج سیگنال‌های باقی‌مانده و دیفرانسیل فرکانس درگیری چرخنده و هارمونیک دوم آن، دامنه در فرکانس باندهای کناری معرفی شده و فرکانس دوران محور و هارمونیک دوم به ازای هر محور از جعبه‌دنده، حذف شده است. سیگنال منظم نیز از اختلاف سیگنال همگام زمانی و سیگنال باقی‌مانده بدست می‌آید و در بردارنده فرکانس دورانی محور، فرکانس درگیری دندانه‌ها و هارمونیک‌های این دو فرکانس است. در ادامه از سیگنال‌های فیلتر شده، خصیصه‌های آماری دیگری که معرف وضعیت سلامت چرخنده هستند، استخراج می‌شوند. در جدول ۲ به معرفی خصیصه‌های مذکور و نحوه استخراج آنها اشاره شده است [۱۶].

جدول ۲: معرفی خصیصه‌های معرف وضعیت سلامت چرخنده استخراج شده از سیگنال‌های فیلتر شده به روش میانگین‌گیری همگام زمانی

Table 2: Introducing health indicator features of gears extracted from filtered signals using time synchronous averaging method

نام خصیصه	نماد	نوع سیگنال	تعریف ریاضی
FM0	FM0	سیگنال خام	$FM0 = \frac{P2P}{\sum_{i=1}^N A(i)}$
FM4	FM4	سیگنال دیفرانسیل (d)	$FM4 = \frac{N \cdot \sum_{i=1}^N (d_i - \bar{d})^4}{\left(\sum_{i=1}^N (d_i - \bar{d})^2 \right)^2}$
M6A	M6A	سیگنال دیفرانسیل (d)	$M6A = \frac{N^2 \sum_{i=1}^N (d_i - \bar{d})^6}{\left(\sum_{i=1}^N (d_i - \bar{d})^2 \right)^3}$
M8A	M8A	سیگنال دیفرانسیل (d)	$M8A = \frac{N^3 \sum_{i=1}^N (d_i - \bar{d})^8}{\left(\sum_{i=1}^N (d_i - \bar{d})^2 \right)^4}$
نرخ انرژی	ER	سیگنال دیفرانسیل (d) و سیگنال منظم (r)	$ER = \frac{\sigma(d)}{\sigma(r)}$

۲-۲- الگوریتم‌های یادگیری ماشین

روش‌های یادگیری ماشین نظارت شده به دو دسته طبقه‌بند و تخمین تابع (رگرسیون) تقسیم می‌شوند. مسأله طبقه‌بند به دو دسته طبقه‌بند دو کلاسه و طبقه‌بند چند کلاسه تقسیم می‌شود. در مسائل طبقه‌بندی هدف یافتن ابرصفحه‌هایی برای دسته‌بندی داده‌ها از روی ویژگی‌های آنها می‌باشد.

برای ساخت مدل‌های یادگیری ماشین روش معمول این است که داده‌ها را با استفاده از روشی منطقی (برای مثال به صورت تصادفی) به دو دسته شامل مجموعه آموزشی و مجموعه آزمایشی تقسیم می‌کنند. داده‌ها شامل تعدادی ویژگی انتخاب شده و همچنین کلاس هر نمونه (برچسب داده) است. مدل طبقه‌بند، با استفاده از مجموعه آموزشی ایجاد می‌شود. فرآیند یادگیری در مدل طبقه‌بند با استفاده از مجموعه آموزشی انجام می‌شود. مجموعه داده آزمایشی در ساخت (یا به اصطلاح آموزش) مدل استفاده نشده است. بلکه پس از تکمیل ساخت مدل، به مدل طبقه‌بند خوراند می‌شود تا دقت عملکرد طبقه‌بند روی آن سنجیده شود. بنابراین، فرآیند طبقه‌بندی شامل دو مرحله است: اعمال یک الگوریتم یادگیری برای آموزش داده‌ها جهت ساخت مدل و ارزش‌یابی مدل ساخته شده. البته در برخی روش‌های یادگیری ماشین (مانند شبکه عصبی مصنوعی) خود مجموعه داده آموزشی مجدد به دو دسته تقسیم می‌شود و بخشی از آن برای صحنه‌سنجی^۱ و کنترل بیش‌برازش^۲ در هر مرحله از آموزش مورد استفاده قرار می‌گیرد. در پژوهش حاضر از روش ماشین بردار پشتیبان به عنوان الگوریتم پایه پیشنهادی استفاده خواهد شد که در ادامه به اختصار معرفی می‌گردد.

۲-۲-۱- ماشین بردار پشتیبان

مفهوم اساسی در طبقه‌بندی توسط الگوریتم ماشین بردار پشتیبان، یافتن ابرصفحه‌ای است که به عنوان مرز تصمیم عمل کند و بتواند داده‌هایی با دو کلاس مثبت (+۱) و منفی (-۱) را با حداکثر حاشیه ممکن از یکدیگر جدا کند. حاشیه مجموع فواصل مرزها از ابرصفحه می‌باشد که توسط نزدیک‌ترین داده‌های هر دو کلاس تعریف شده است. داده‌های ذکر شده که در تعریف مرزها نقش دارند، بردارهای پشتیبان نامیده می‌شوند.

فرض شود که مجموعه داده D به صورت $D = \{(x_i, y_i), i=1,2,\dots,n\}$ وجود دارد که در آن $x_i \in R^d$ نشان دهنده ویژگی‌های ورودی (شامل d ویژگی اسکالر) و $y_i \in \{-1, +1\}$ نشان دهنده کلاس‌های داده‌ها است. در این صورت معادله ابرصفحه به صورت رابطه (۴) تعریف می‌شود.

$$w^T x + b = 0 \quad (4)$$

که در آن w ضرایب ویژگی‌ها و b مقدار ثابت (شبهه عرض از مبدأ) است. هدف از ساخت مدل ماشین بردار پشتیبان پیدا کردن بهترین مقادیر برای ضرایب مذکور است به طوری که حاشیه جداکننده دو کلاس از هم به بیشترین مقدار ممکن برسد. انجام این کار منجر به یک مسأله بهینه‌سازی می‌گردد که جزئیات روش حل آن برای دستیابی به طبقه‌بند در مرجع [۲۰] تشریح شده است. لازم به توضیح است که در شرایطی که داده‌ها به صورت خطی قابل تفکیک نیستند، روش ماشین بردار پشتیبان می‌تواند با استفاده از کرنل‌ها^۳ به فضای ویژگی‌های بالاتر انتقال یابد و بتواند یک طبقه‌بند با مرزهای غیرخطی را در فضای ویژگی‌ها شناسایی کند. برخی از کرنل‌های محبوب شامل کرنل خطی، کرنل چند جمله‌ای و کرنل گاوسی هستند [۲۰].

۲-۲-۲- یادگیری ترکیبی و الگوریتم جنگل تصادفی

با افزایش تعداد ویژگی‌های مجموعه داده آموزشی، در صورت پیکربندی مناسب مدل داده محور در بیشتر موارد می‌توان انتظار داشت که عملکرد مدل بهبود یابد. یکی از روش‌های مورد توجه که به خصوص برای داده‌های با تعداد ویژگی زیاد بسیار کارآمد است، ساختاری تشکیل شده از ترکیب مدل‌های پایه است که به عنوان مدل مرکب یا مدل جمعی^۴ شناخته می‌شود. برای جلوگیری از

¹ Validation

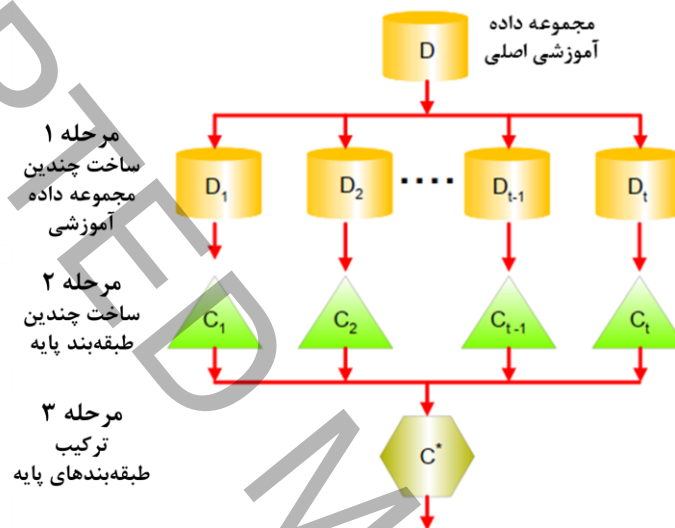
² Overfit

³ Kernels

⁴ Ensemble Model

پیچیدگی طبقه‌بندهای مرکب، می‌توان از مدل‌های طبقه‌بند ساده و ضعیف استفاده کرد که به آنها طبقه‌بندهای پایه می‌گویند. در مدل جمعی، تعدادی طبقه‌بند پایه مستقل از هم (با به کار بردن ویژگی‌هایی که ممکن است از هم متفاوت باشد) به تعیین کلاس آن داده می‌پردازند. اگر طبقه‌بندهای پایه دقیقاً مشابه یکدیگر باشند، تشخیص آنها روی داده‌های یکسان، مشابه خواهد بود. اما اگر طبقه‌بندهای پایه مستقل از یکدیگر باشند، یعنی تنوع آنها زیاد باشد و ورودی‌های متفاوتی هم داشته باشند، روی داده‌های یکسان تشخیص متفاوت خواهند داشت. در این صورت کلاس نهایی تعیین شده در مدل جمعی، کلاسی خواهد بود که بیشتر طبقه‌بندها به آن رسیده باشند.

در شکل ۱، مراحل ایجاد مدل طبقه‌بند مرکب نشان داده شده است که شامل سه مرحله ساخت مجموعه داده‌های آموزشی از مجموعه داده اصلی برای آموزش طبقه‌بندها، ساخت طبقه‌بندهای پایه و آموزش آنها توسط مجموعه داده‌های ساخته شده در مرحله قبل و ترکیب طبقه‌بندها است که شامل نحوه ترکیب پیش‌بینی طبقه‌بندهای پایه است.



شکل ۱: شماتیک ساخت الگوریتم‌های مرکب [۲۰]

Figure 1: The schematic of constructing ensemble algorithms [20]

ترکیب مدل‌های طبقه‌بند از دستکاری مجموعه داده آموزشی، دستکاری مجموعه ویژگی‌های ورودی، دستکاری برچسب دسته‌ها و دست‌کاری الگوریتم یادگیری می‌تواند ایجاد شود. لازم به ذکر است که برای تعیین خروجی نهایی، روش‌های مختلفی مانند رأی اکثریت، میانگین‌گیری، میانگین‌گیری وزن‌دار و ... وجود دارد.

برای دستکاری مجموعه داده آموزشی که با هدف افزایش تنوع صورت می‌پذیرد، الگوریتم‌های مختلفی وجود دارد که یکی از آنها بگینگ^۱ است. بگینگ، روشی است که با نمونه‌برداری با توزیع احتمال یکنواخت و همراه با جای‌گذاری از روی مجموعه داده آموزشی D ، یک مجموعه داده جدید به نام D_i ایجاد می‌کند که هم‌اندازه با D است. به این کار نمونه‌برداری بوت‌استرپ^۲ نیز گفته می‌شود. هر

نمونه با احتمال $1 - (1 - \frac{1}{N})^N$ می‌تواند در مجموعه داده D_i انتخاب شود که N اندازه مجموعه داده اصلی است. اگر N به اندازه

کافی بزرگ باشد، به طور متوسط، یک نمونه بوت‌استرپ تقریباً شامل ۶۳ درصد از داده‌های آموزشی اصلی خواهد بود [۲۰].

یکی از رایج‌ترین الگوریتم‌های مرکب، جنگل تصادفی است که اغلب از توابع پایه مبتنی بر درخت تصمیم در آن استفاده می‌شود. جنگل تصادفی بر اساس ایده بگینگ ایجاد شده است با این حال، یک تفاوت کلیدی میان بگینگ و جنگل تصادفی وجود دارد. در الگوریتم جنگل تصادفی، برای انتخاب بهترین معیار تقسیم در هر گره، از مجموعه کوچکی از ویژگی‌هایی که به صورت تصادفی انتخاب شده‌اند، استفاده می‌شود. در نتیجه نه تنها با دستکاری نمونه‌های آموزشی (استفاده از الگوریتم بگینگ)، بلکه همچنین با دستکاری ویژگی‌های ورودی هر طبقه‌بند، مجموعه‌هایی از درخت‌های تصمیم ایجاد می‌شود [۲۰].

¹ Bagging

² Bootstrap

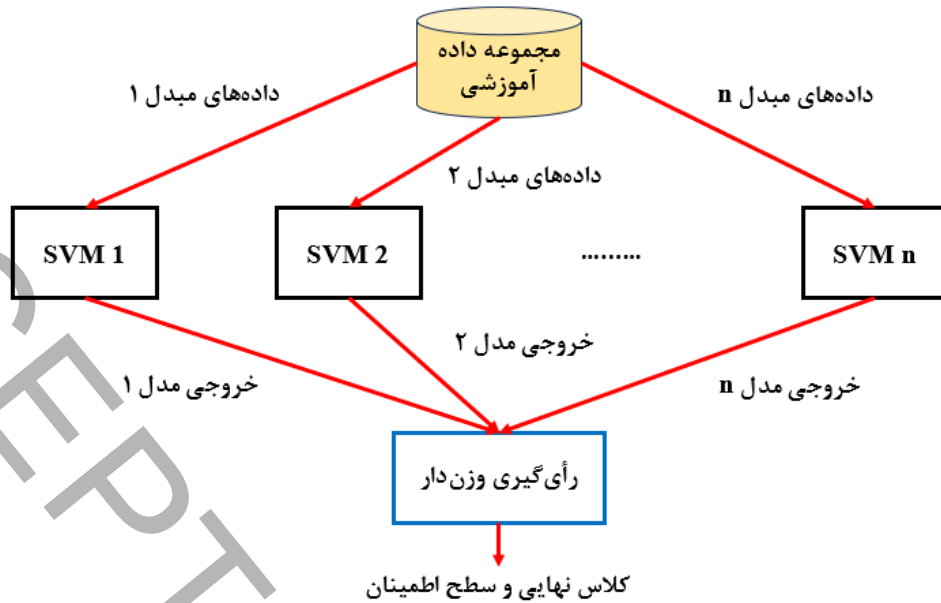
با توجه به ایده مورد نظر در طراحی الگوریتم جنگل تصادفی، در این پژوهش رویکردی معرفی می‌شود که از طبقه‌بند پایه ماشین بردار پشتیبان برای ساختن یک مدل مرکب استفاده می‌کند. لازم به یادآوری است که در پایش وضعیت ارتعاشات، اغلب از داده‌های چند حسگر که در نقطه-جهت‌های مختلف نصب می‌شوند استفاده می‌گردد و از سیگنال بدست آمده از هر نقطه-جهت، ویژگی‌های مختلفی استخراج می‌شود. بنابراین تعداد ورودی‌های موجود به مدل ترکیبی برابر با حاصلضرب تعداد نقطه-جهت‌های اندازه‌گیری شده در تعداد ویژگی‌های استخراج شده از هر سیگنال خواهد بود. اما بر خلاف روش معمول بگینگ در الگوریتم جنگل تصادفی، در اینجا ویژگی‌های استخراج شده از سیگنال هر حسگر، به یک مدل پایه خورنده می‌شود. لذا برای ساخت مدل مرکب در روش پیشنهادی، تعداد مدل‌های پایه به تعداد حداکثر نقطه-جهت‌های اندازه‌گیری شده از تجهیز خواهد بود. از آنجایی که اثر عیوب مختلف تجهیز در نقطه-جهت‌های مختلف تأثیر متفاوتی روی سیگنال ارتعاشی دارد، به طور طبیعی انتظار می‌رود که مدل‌های پایه نیز که ورودی‌های متفاوت از هم دارند، عملکرد متفاوتی در مورد تشخیص وضعیت داشته باشند. برای مثال در صورت وجود نامیزانی روی یکی از محورها، انتظار معمول این است که اثر آن روی جهات شعاعی یاتاقان‌های همان محور با شدت بیشتری ظاهر گردد. از این روی، لازم است در تصمیم نهایی نیز به جای رأی‌گیری عادی بین خروجی مدل‌های پایه، از رأی‌گیری وزن‌دار جهت بیشتر کردن سهم نقطه-جهت‌هایی که انتظار بیشتری برای تشخیص صحیح از آنها هست، استفاده گردد. برای اعمال رأی‌گیری وزن‌دار، تشخیص هر مدل با وزنی برابر با مقدار فراخوانی^۱ محاسبه شده آن کلاس در ماتریس درهم‌ریختگی^۲ همان مدل که بر اساس اعمال مدل روی مجموعه داده‌های آموزشی بدست آمده است، لحاظ می‌گردد. محاسبه مقدار فراخوانی، R ، برای هر کلاس به کمک رابطه (۵) انجام می‌شود [۲۰]:

$$R = \frac{TP}{TP + FN} \quad (۵)$$

که در آن TP تعداد تشخیص‌های صحیح کلاس مربوطه توسط مدل و FN تعداد مواردی از کلاس مربوطه است که توسط مدل به اشتباه متعلق به کلاس دیگری تشخیص داده شده‌اند. بدین ترتیب مقدار فراخوانی همواره عددی بین صفر تا ۱ خواهد بود و هر چه این مقدار به ۱ نزدیک‌تر باشد، نشان می‌دهد که تشخیص آن کلاس توسط مدل اعتبار بیشتری دارد. بدین ترتیب انتظار معمول برای تعیین خروجی نهایی با دادن سهم بیشتر به داده‌هایی که بیشتر قابل اعتماد هستند تأمین می‌گردد. شکل ۲ پیکربندی مدل مرکب پیشنهاد شده را نشان می‌دهد.

^۱ Recall

^۲ Confusion Matrix



شکل ۲: مدل طبقه‌بند پیشنهادی بر اساس عملکرد مدل جنگل تصادفی

Figure 2: The proposed classification model based on the Random Forest algorithm

در روش پیشنهادی، علاوه بر تعیین کلاس، می‌توان سطح اطمینان را نیز بر اساس روشی که در ادامه توضیح داده می‌شود برای هر تشخیص بدست آورد. اگر داده‌ها در مجموع از m کلاس مختلف باشند و مدل مرکب از n مدل پایه تشکیل شده باشد و تشخیص مدل i ام روی یک داده y_i در نظر گرفته شود، در این صورت، در مقاله حاضر رابطه (۶) جهت محاسبه وزن اولیه (ICL_j) برای کلاس j ام پیشنهاد می‌گردد. برای این منظور از جمع کردن مقادیر فراخوانی کلاس j مدلهایی که خروجی‌شان کلاس j بوده است (R_i^j) (شامل n_j مدل به طوری که $n_j \leq n$)، بدست می‌آید:

$$ICL_j = \sum_{i=1}^{n_j} R_i^j \quad ; \quad j = 1, 2, \dots, m \quad (6)$$

بر اساس آنچه گفته شد، مقدار ICL_j برای کلاس‌هایی محاسبه می‌شود که حداقل یکی از مدل‌های پایه، آن کلاس را به عنوان خروجی تولید کرده باشد. در صورتی که هیچ یک از مدل‌های پایه، خروجی معادل با کلاس خاصی را نداشته باشند، مقدار ICL_j برای آن کلاس صفر در نظر گرفته می‌شود. لازم است توجه گردد که مقادیر ICL_j محاسبه شده در حالت معمول دارای محدودیت بازه‌ای خاصی نیستند، اما مقادیر آنها برای کلاس‌های مختلف به ازای هر داده با یکدیگر قابل مقایسه است. برای اینکه بتوان این مقادیر را بهتر و راحت‌تر تفسیر کرد، مقادیر ICL_j بدست آمده مربوط به تمام کلاس‌ها برای هر کلاس، رابطه (۷) جهت نرمال کردن مقادیر ICL_j قبلی پیشنهاد می‌گردد:

$$CL_j = \frac{ICL_j}{\sum_{i=1}^m ICL_i} \quad (7)$$


پارامتر CL_j مقدار نرمال شده ICL_j بوده و همواره عددی بین صفر تا ۱ است که در این مقاله به عنوان سطح اطمینان پیش‌بینی مدل مرکب برای تعلق داده به کلاس j ام تفسیر می‌شود. بر این اساس، مجموع سطح اطمینان‌های محاسبه شده برای تمام کلاس‌ها برای هر داده برابر با مقدار واحد خواهد بود.

ویژگی بسیار مهم در مدل ترکیبی پیشنهاد شده در شکل ۲ این است که چنانچه آموزش و ساخت مدل، با داشتن داده‌های تمام حسگرهای ممکن انجام شود، در موقع استفاده از مدل (پس از آموزش) می‌توان با در دست داشتن تعداد داده‌های محدودتری از حسگرهای ارتعاش‌سنج نیز بدون هیچ مشکلی از مدل ساخته شده استفاده کرد و انتظار داشت که مدل به طور منطقی (البته با

قطعیته کم‌تر) به تعیین کلاس داده‌های جدید بپردازد. این ویژگی امکان استفاده عملی از مدل توسعه داده شده پیشنهادی در کاربردهای علمی و صنعتی را فراهم خواهد کرد که بسیار حائز اهمیت بوده و نقطه قوت مدل مرکب پیشنهاد شده است.

۳- معرفی داده‌های تجربی


برای اهداف مورد نظر در این پژوهش یک چیدمان آزمایشگاهی در آزمایشگاه نت مبتنی بر وضعیت دانشگاه زنجان جهت انجام آزمایش‌های مختلف روی عیوب چرخدنده طراحی و ساخته شده است (شکل ۳). جعبه‌دنده این چیدمان، دارای دو محور است که روی هر یک از آنها، دو چرخدنده نصب شده است. هر محور سوار بر دو یاتاقان غلتشی با کد ۶۸۰۴ است. گشتاور از الکتروموتور ۱/۴۹ کیلووات توسط مکانیزم تسمه-پولی به جعبه‌دنده منتقل می‌شود. روی محور خروجی جعبه‌دنده نیز یک پولی نصب شده است. با استفاده از یک تسمه ثابت (غیرچرخان) که نیروی کشش آن توسط جرم متصل به آن تنظیم می‌گردد، بارگذاری روی محور خروجی جعبه‌دنده به صورت اصطکاک تسمه با پولی اعمال می‌گردد تا در خروجی توان جعبه‌دنده تلف شود (شکل ۳-ج). با تغییر وزنه، می‌توان نیروی کششی تسمه (و در نتیجه اصطکاک و میزان توان تلف شده) را به شکل دلخواه تنظیم کرد. چرخدنده‌هایی که در جعبه‌دنده استفاده شده‌اند از نوع ساده بوده و روی محور ورودی، چرخدنده ۲۵ دندانه و روی محور خروجی چرخدنده پینیون ۲۲ دندانه نصب شده است. همچنین مدول، زاویه فشار و عرض چرخدنده‌ها به ترتیب برابر با ۲ میلی‌متر، ۲۰ درجه و ۲۰ میلی‌متر است.



شکل ۳: الف) چیدمان کامل طراحی شده در نرم‌افزار سالیدورک، ب) جزئیات جعبه‌دنده طراحی شده، ج) جزئیات مکانیزم اعمال بارگذاری روی محور خروجی جعبه‌دنده توسط تسمه تحت کشش با نیروی ثقلی وزنه

Figure 3: a) The designed testrig in SolidWorks, b) Detailed design of the gearbox, c) The loading mechanism applied to the output shaft of the gearbox using a belt under tension of a weight

شماتیک مسیر انتقال قدرت و چیدمان داخلی جعبه‌دنده در شکل ۴ ارائه شده است. مشاهده می‌شود که در هر آزمایش تنها یک جفت از چرخدنده‌ها درگیر می‌باشند. این موضوع به سهولت و کاهش عملیات مونتاژ و دیمونتاژ جعبه‌دنده کمک می‌کند؛ چرا که در هر بار مونتاژ می‌توان ۴ حالت درگیری را مورد آزمایش قرار داد.



شکل ۴: شماتیک مسیر انتقال قدرت با نسبت انتقال خروجی به ورودی ۱/۱۳ و چیدمان داخل جعبه‌دنده

Figure 4: The schematic of the power transmission path with an output-to-input ratio of 1.13 and the arrangement of the gearbox

جهت بررسی اثر عیوب رایج چرخدنده‌ها روی ارتعاشات جعبه‌دنده، عیوب مصنوعی مختلف روی چرخدنده پینیون واقع روی شفت خروجی ایجاد شده است. در هر آزمایش، پینیون‌های سالم و معیوب با چرخدنده‌های سالم (۲۵ دندانه) درگیر شده و ارتعاشات جعبه‌دنده تحت شرایط مشخص اندازه‌گیری می‌شود. شکستگی دندانه، ترک ریشه و سطح حفره‌دار عیوب مصنوعی ایجاد شده روی پینیون هستند که در شکل ۵ نشان داده شده است. برای سطح حفره دار، چهار سوراخ به قطر ۱ میلی‌متر و عمق ۰/۲ میلی‌متر و برای ایجاد ترک در ریشه دندانه از برش وایرکات به ضخامت ۰/۲ میلی‌متر و طول ۲ میلی‌متر استفاده شده است.



شکل ۵: چرخدنده‌های دارای عیوب مصنوعی. الف) عیب شکستگی دندانه، ب) عیب سطح حفره‌دار و ج) عیب ترک ریشه

Figure 5: Gears with artificial faults. a) tooth breakage, b) pitting and c) root crack

از فاکتورهای قابل کنترل و تغییر در جعبه‌دنده چیدمان حاضر می‌توان به سرعت دورانی، بارگذاری روی محور خروجی جعبه‌دنده و وضعیت سلامت چرخدنده‌های درگیر اشاره کرد. مطابق با اهداف پژوهشی مطرح شده، تعیین وضعیت سلامت و طبقه‌بندی عیوب چرخدنده از اهداف مورد نظر در این پژوهش است. از این رو برای فراهم آوردن داده‌های مناسب برای مسئله طبقه‌بندی، طراحی آزمایش بر مبنای فاکتوریل کامل انجام شده است و برهم‌کنش‌های بین فاکتورهای آزمایش در نظر گرفته نشده است. سناریوهای انجام آزمایش مطابق جدول ۳ انجام شده است. لازم به ذکر است کنترل سرعت کاری در آزمایش‌های مختلف توسط فرکانس اینورتر (مقادیر مذکور در جدول ۳) انجام شده است. الکتروموتور مورد استفاده از نوع سه فاز ۴ قطبی است و دور شفت آن در حالت نامی حدود ۰/۴۷۵ فرکانس اینورتر است. دور شفت الکتروموتور نیز توسط تسمه-پولی (با نسبت ۲/۷۷) به محور ورودی جعبه‌دنده منتقل می‌شود. بنابراین می‌توان گفت که سرعت دوران شفت ورودی بر حسب هرتز، تقریباً $1/316 \times (2/77 \times 0/475) = 0/475$ برابر فرکانس اینورتر است. برای تبدیل فرکانس اینورتر (بر حسب هرتز) به سرعت دوران شفت ورودی جعبه‌دنده (بر حسب دور بر دقیقه) کافی است ضریب ۷۸/۹ را روی فرکانس خروجی اینورتر اعمال کرد. اما نکته‌ای که باید توجه داشت این است که با تغییر شرایط بارگذاری، مقداری انحراف (در حدود ۱۰-۱۵ دور بر دقیقه) نسبت به آنچه که با اعمال ضریب تبدیل مذکور بدست می‌آید، مورد انتظار است. البته در سرعت‌های پایین، این انحراف و حساسیت نسبت سرعت به توان مصرفی بیشتر بوده است.

جدول ۳: سناریوی‌های انجام آزمایش روی چیدمان آزمایشگاهی

Table 3: The experiment plan for conducting on the experimental setup


وضعیت درگیری چرخنده‌ها	پینیون	سالم، شکستگی دندان، ترک ریشه، سطح حفره‌دار
	چرخنده	سالم، سالم، سالم، سالم
بارگذاری:	بدون بارگذاری	بدون وزنه
نیروی کشش (گرم)	بارگذاری متوسط	۶۳۰
	بارگذاری سنگین	۹۱۰
فرکانس اینورتر (هرتز)	۱۱ سرعت	۳۰، ۲۸، ۲۶، ۲۴، ۲۲، ۲۰، ۱۸، ۱۶، ۱۴، ۱۲، ۱۰

تجهیز اندازه‌گیری مورد استفاده در این پژوهش، دستگاه ارتعاش‌سنج دوکاناله شرکت تکنکون^۱ مدل STD-3300 است. پارامترهای تنظیم شده جهت اندازه‌گیری در پژوهش حاضر مطابق با جدول ۴ صورت گرفته است. اندازه‌گیری ارتعاشات در سمت ورودی و خروجی جعبه‌دنده در سه جهت (در مجموع شامل ۶ نقطه-جهت) انجام شده است. در شکل ۶ محل نصب حسگرهای شتاب‌سنج در این ۶ نقطه-جهت نشان داده شده است. اندازه‌گیری برای هر شرایط کاری (بار و سرعت) به ازای هر حالت عیب، در سه مرحله پشت سر هم (در بازه زمانی حدود ۱-۲ دقیقه‌ای) صورت گرفته است. طوری که، حسگرها در سه وضعیت نشان داده شده در شکل ۶ نصب می‌شدند و ثبت داده‌های دو کانال (به صورت هم‌زمان) در هر وضعیت قرارگیری حسگرها انجام شده است. در مجموع ۷۹۲ سیگنال ارتعاشات در آزمایش‌های طرح‌ریزی شده که پیشتر در جدول ۳ معرفی گردید، ثبت شده است.


جدول ۴: مؤلفه‌های تنظیم شده برای اندازه‌گیری آزمایش‌های مطرح شده

Table 4: The configured parameters for the measurement in the planned experiments


تنظیمات داده‌برداری	نوع یا مقدار
فرکانس نمونه‌برداری	۶۵۵۳۶ نمونه
تعداد خطوط فرکانسی	۲۵۶۰۰ خط فرکانسی
فرکانس حداکثر	۱۶۰۰۰ هرتز
فرکانس حداقل	۱۰ هرتز
نوع اندازه‌گیری	دو کاناله



ج



ب



الف

شکل ۶: موقعیت (نقطه-جهت) نصب حسگرهای شتاب‌سنج روی جعبه‌دنده (مشخص شده با خط چین قرمز). الف) اندازه‌گیری افقی و عمودی نقطه ۱ (سمت ورودی جعبه‌دنده)، ب) اندازه‌گیری افقی و عمودی نقطه ۲ (سمت خروجی جعبه‌دنده) و ج) اندازه‌گیری محوری نقاط ۱ و ۲

¹ Technekon

Figure 6: The mounting position (point-direction) of accelerometers on the gearbox (indicated by a red dashed ovals). a) Horizontal and vertical measurements at point 1 (input of the gearbox), b) Horizontal and vertical measurements at point 2 (output of the gearbox) and c) Axial measurements at points 1 and 2

در شکل ۷ نمونه‌هایی از سیگنال‌های ارتعاشات اندازه‌گیری شده نشان داده شده است. در این شکل، سیگنال ارتعاشات در ۴ وضعیت سلامت مختلف چرخنده پینیون (سالم، شکستگی دندانه، ترک ریشه دندانه و سطح حفره‌دار) در شرایط کاری تنظیم شده یکسان (سرعت ۱۰ هرتز اینورتر و بارگذاری شدید) ارائه شده است. چنانچه مشاهده می‌گردد، هم الگوی سیگنال‌های زمانی و هم محدوده تغییرات شتاب در سیگنال‌های مختلف، متفاوت از هم‌دیگر است.

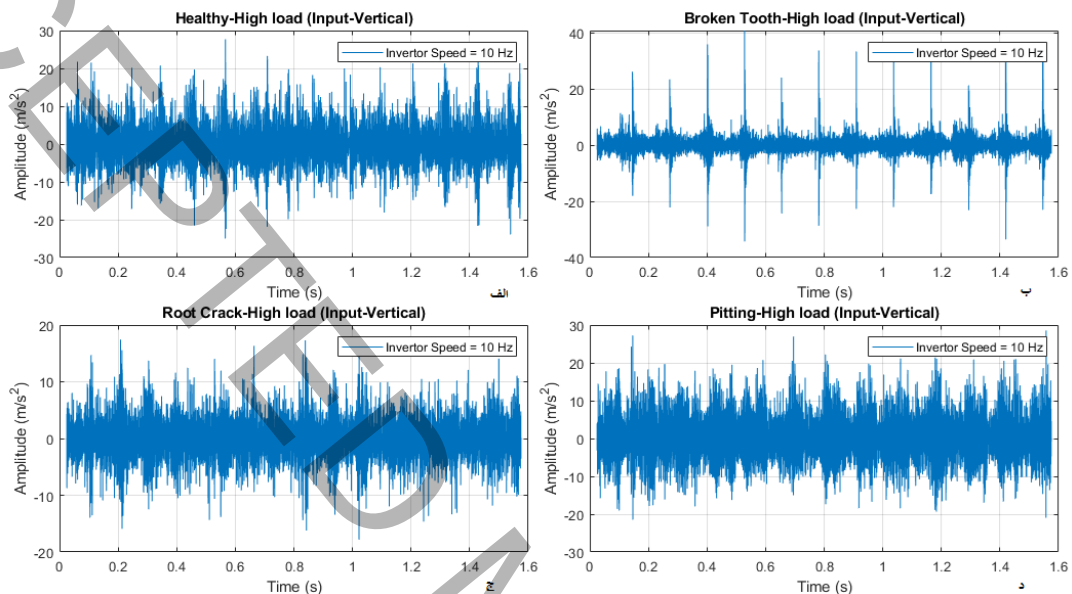


Figure 7: Sample vibration signals measured at the input point in the vertical direction for different health conditions (a: healthy, b: tooth breakage, c: root crack, and d: pitting) under operating speed correspond to the inverter frequency of 10 Hz and heavy loading

شکل ۷: نمونه سیگنال ارتعاشات اندازه‌گیری شده در نقطه ورودی در جهت قائم به ازای وضعیت‌های سلامت مختلف (الف: سالم، ب: شکستگی دندانه، ج: ترک ریشه دندانه و د: سطح حفره‌دار) در سرعت کاری معادل با فرکانس ۱۰ Hz اینورتر و بارگذاری شدید

شکل ۷: نمونه سیگنال ارتعاشات اندازه‌گیری شده در نقطه ورودی در جهت قائم به ازای وضعیت‌های سلامت مختلف (الف: سالم، ب: شکستگی دندانه، ج: ترک ریشه دندانه و د: سطح حفره‌دار) در سرعت کاری معادل با فرکانس ۱۰ Hz اینورتر و بارگذاری شدید

۴- نتایج

در ابتدا تأکید می‌گردد یکی از پارامترهای تأثیرگذار در دقت مدل‌های یادگیری ماشین، تقسیم‌بندی داده‌ها برای آموزش و آزمایش است. در پژوهش حاضر، برای اینکه اثر این پارامتر در مقایسه مدل‌های مختلف وارد نگردد، تقسیم‌بندی داده‌ها در ابتدا یکبار انجام شده و در تمام مراحل که در ادامه ذکر خواهد شد، همان تقسیم‌بندی استفاده خواهد شد. به عبارت دیگر، داده‌های استفاده شده برای آموزش و آزمایش در تمام مراحل پیش‌رو یکسان خواهد بود. برای این منظور، به صورت تصادفی ۸۰ درصد از داده‌ها (۱۰۶ داده از مجموع ۱۳۲ داده) برای آموزش و ۲۰ درصد باقیمانده (۲۶ داده از مجموع ۱۳۲ داده) برای آزمایش انتخاب می‌شوند.

۱-۴- استخراج خصیصه‌ها و پیاده‌سازی مدل‌های پایه

در گام نخست، از سیگنال‌های ارتعاشات ثبت شده از هر یک از ۶ نقطه-جهت اندازه‌گیری، ۱۶ خصیصه معرفی شده در جدول ۱ و جدول ۲ استخراج می‌شود و به کمک آنها مجموعه داده آموزشی و آزمایشی مورد استفاده در این پژوهش تشکیل می‌گردد. لذا در مجموع ۹۶ خصیصه (۶×۱۶=۹۶) برای ۱۳۲ آزمایش بدست آمده است. با توجه به اینکه در صنعت ممکن است امکان اندازه‌گیری از همه نقاط یک جعبه‌دنده وجود نداشته باشد. از این رو باید بتوان با نقطه-جهت‌های در دسترس تا حد ممکن، تحلیل درستی را انجام داد. همچنین اندازه‌گیری از تمام نقطه-جهت‌های در دسترس زمان‌بر بوده و علاوه بر فضای ذخیره‌سازی بیشتر به تحلیل پیچیده‌تر و طولانی نیاز دارد. از این رو یافتن نقطه-جهت(هایی) که بیشترین اطلاعات مفید از وضعیت سلامت تجهیز را در بر داشته باشد، از اهمیت بالایی برخوردار است.

برای داده‌های دسته‌بندی شده برای آموزش و آزمایش، کلاس داده‌ها متناسب با نوع عیب چرخنده مطابق جدول ۵ در نظر گرفته می‌شود. به منظور مطالعه عملکرد مدل‌های یادگیری ماشین روی داده‌های حسگرهای مختلف، ۶ مدل طبقه‌بند مبتنی بر ماشین بردار پشتیبان با کرنل خطی ساخته شده است که هر یک از آنها توسط مجموعه داده آموزشی یکی از حسگرها، آموزش می‌بیند و دقت آن توسط مجموعه داده آزمایش همان حسگر بدست می‌آید. تمام ویژگی‌های این ۶ مدل کاملاً یکسان بوده و تنها در داده‌های مورد استفاده برای آموزش و آزمایش تفاوت وجود دارد. در جدول ۶، دقت مدل‌های ساخته شده روی مجموعه داده آموزشی و آزمایشی توسط داده‌های هر حسگر ارائه شده است.

جدول ۵: کلاس‌های موجود در مجموعه داده بدست آمده
Table 5: The existing classes in the prepared dataset

وضعیت چرخنده	سالم	شکستگی دندانه	ترک ریشه دندانه	حفره سطح دندانه
کلاس وضعیت	۱	۲	۳	۴

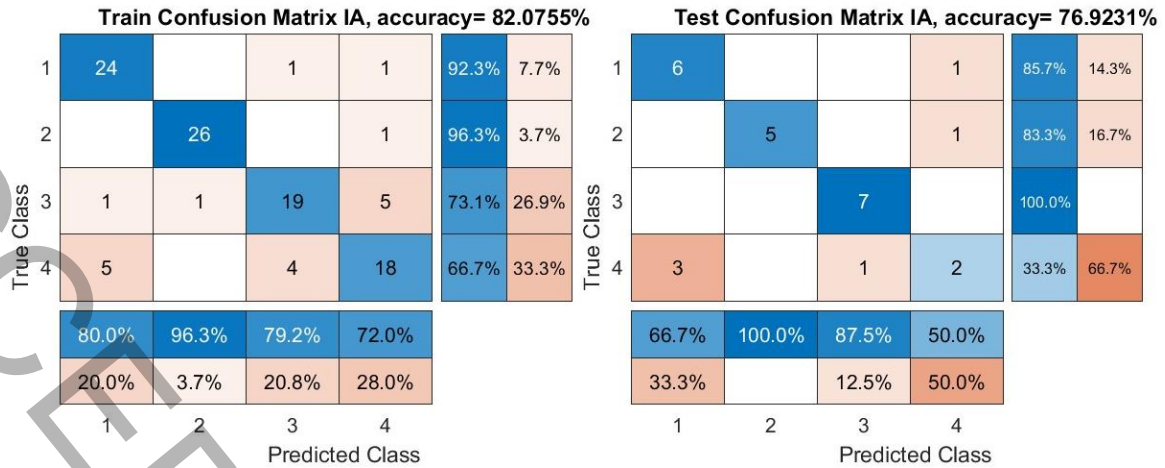
جدول ۶: دقت مدل‌های طبقه‌بند مبتنی بر ماشین بردار پشتیبان روی مجموعه داده آموزشی و آزمایشی هر نقطه-جهت

Table 6: The accuracy of SVM classifiers on the train and the test datasets for each point-direction

نام مدل	SVM1	SVM2	SVM3	SVM4	SVM5	SVM6
داده‌های مورد استفاده (نقطه-جهت اندازه‌گیری)	ورودی-محوری	ورودی-افقی	ورودی-عمودی	خروجی-محوری	خروجی-افقی	خروجی-عمودی
دقت مجموعه آموزش (درصد)	۸۲/۰۸	۷۷/۳۵	۸۶/۷۹	۸۹/۶۲	۸۳/۹۶	۸۸/۶۸
دقت مجموعه آزمایش (درصد)	۷۶/۹۲	۷۳/۰۸	۶۹/۲۳	۸۰/۷۷	۷۶/۹۲	۹۲/۳۱


معمولاً انتظار می‌رود که دقت مدل روی مجموعه آموزش بیشتر از مجموعه آزمایش باشد. علت این امر این است که مجموعه داده آزمایش در ساخت مدل هیچ نقشی نداشته است. در نتایج ارائه شده در جدول ۶ نیز مطابق انتظار در بیشتر مدل‌های مبتنی بر ماشین بردار پشتیبان، دقت روی مجموعه داده آزمایشی کمتر از مجموعه داده آموزشی است. اما چنانچه قابل مشاهده است، دقت یکی از مدل‌ها (مدل SVM6) روی مجموعه آزمایش بیشتر از دقت این مدل روی مجموعه آموزش شده است. با توجه به تقسیم‌بندی تصادفی داده‌ها به مجموعه آموزش و آزمایش (که پیش‌تر به آن اشاره گردید)، وقوع چنین وضعیتی غیرممکن نبوده و می‌تواند به صورت تصادفی روی دهد. با توجه به نتایج ارائه شده، بیشترین دقت روی مجموعه داده آموزش مربوط به نقطه خروجی جعبه‌دنده در جهت محوری است. اما در مجموعه داده آزمایش، نقطه خروجی جعبه‌دنده در جهت عمودی بیشترین دقت را دارد. اعداد متناظر با بیشترین دقت‌ها در جدول ۶ به صورت پررنگ نمایش داده شده است. در شکل ۸ تا شکل ۱۳، ماتریس درهم‌ریختگی مدل‌های ساخته شده ارائه گردیده است. در این شکل‌ها، اعداد نشان داده شده به صورت درصد در پایین هر ماتریس درهم‌ریختگی، نشان دهنده درستی^۱ مدل در پیش‌بینی نتایج مربوط به آن کلاس است؛ یعنی از کل تشخیص‌های انجام داده شده برای هر کلاس توسط طبقه‌بند، چند درصد صحیح می‌باشد. همچنین اعداد نشان داده شده در سمت راست، نشان دهنده فراخوانی مدل است. یعنی از کل نمونه‌هایی که از یک کلاس به خصوص در مجموعه داده موجود می‌باشد، چند درصد توسط طبقه‌بند به طور صحیح شناسایی شده است. به عنوان نمونه در شکل ۱۳، درستی کلاس ۱ که وضعیت سالم را نشان می‌دهد در مجموعه داده آموزش برابر با ۹۶/۳ درصد است. به عبارت دیگر، ۲۶ مورد از ۲۷ موردی که در کلاس ۱ تشخیص داده شده‌اند، واقعاً به این کلاس تعلق دارند. میزان فراخوانی این کلاس نیز ۱۰۰ درصد است؛ به معنی آنکه از ۲۷ مورد از داده‌هایی که برچسب کلاس آنها ۱ می‌باشد، ۲۷ مورد صحیح تشخیص داده شده است و هیچ موردی به اشتباه تشخیص داده نشده است.

^۱ Precision




شکل ۸: ماتریس درهم‌ریختگی طبقه‌بند مبتنی بر ماشین بردار پشتیبان برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست) نقطه ورودی جعبه‌دنده، جهت محوری

Figure 8: Confusion matrix of SVM classifier for training data (left) and test data (right) at the input point of the gearbox, in axial direction




شکل ۹: ماتریس درهم‌ریختگی طبقه‌بند مبتنی بر ماشین بردار پشتیبان برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست) نقطه ورودی جعبه‌دنده، جهت افقی

Figure 9: Confusion matrix of SVM classifier for training data (left) and test data (right) at the input point of the gearbox, in horizontal direction




شکل ۱۰: ماتریس درهم‌ریختگی طبقه‌بند مبتنی بر ماشین بردار پشتیبان برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست) نقطه ورودی جعبه‌دنده، جهت عمودی

Figure 10: Confusion matrix of SVM classifier for training data (left) and test data (right) at the input point of the gearbox, in vertical direction



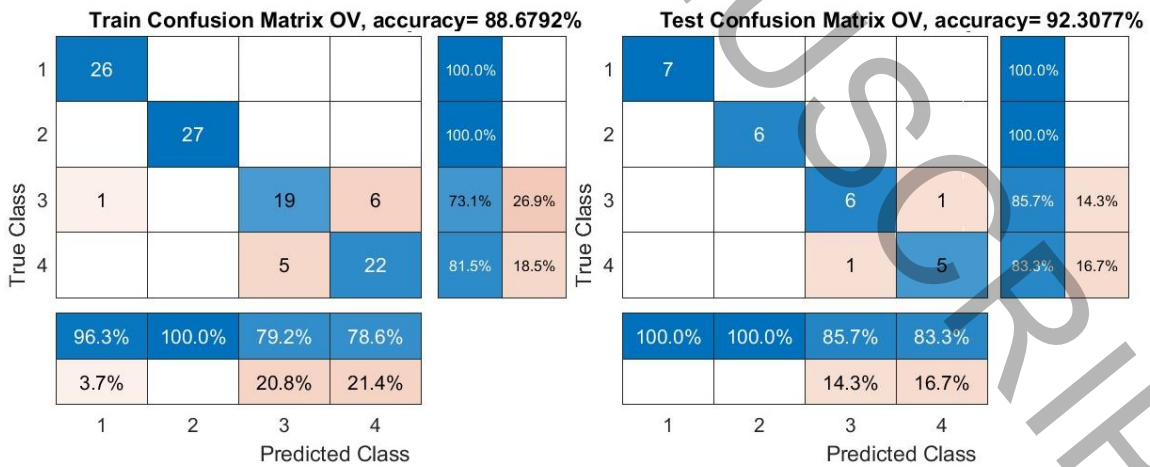
شکل ۱۱: ماتریس درهم‌ریختگی طبقه‌بند مبتنی بر ماشین بردار پشتیبان برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست) نقطه خروجی جعبه‌دنده، جهت محوری

Figure 11: Confusion matrix of SVM classifier for training data (left) and test data (right) at the output point of the gearbox, in axial direction



شکل ۱۲: ماتریس درهم‌ریختگی طبقه‌بند مبتنی بر ماشین بردار پشتیبان برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست) نقطه خروجی جعبه‌دنده، جهت افقی

Figure 12: Confusion matrix of SVM classifier for training data (left) and test data (right) at the output point of the gearbox, in horizontal direction



شکل ۱۳: ماتریس درهم‌ریختگی طبقه‌بند مبتنی بر ماشین بردار پشتیبان برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست) نقطه خروجی جعبه‌دنده، جهت عمودی

Figure 13: Confusion matrix of SVM classifier for training data (left) and test data (right) at the output point of the gearbox, in vertical direction

دقت مدل‌های ساخته شده روی مجموعه داده آموزش، به خصوص در مدل ساخته شده با داده‌های حسگر نقطه ورودی جعبه‌دنده در جهات افقی و عمودی که به ترتیب در شکل ۹ و شکل ۱۰ نشان داده شده است، پایین می‌باشد. در این مدل‌ها بیشترین تشخیص نادرست مربوط به کلاس ۳ (ترک ریشه) و کلاس ۴ (سطح حفره‌دار) است. این احتمال وجود دارد که خصیصه‌های استخراج شده، به خوبی معرف وضعیت ترک ریشه نمی‌باشند و یا تداخل داده‌ها به گونه‌ای است که طبقه‌بند مبتنی بر ماشین بردار پشتیبان امکان یافتن ابرصفحه خطی را ندارد. در مقابل، در اکثر نتایج ارائه شده، درستی تشخیص طبقه‌بند مبتنی بر ماشین بردار پشتیبان روی کلاس ۲ (شکستگی دندان) ۱۰۰ درصد یا نزدیک به آن است. در درگیری دندان‌ها در چرخنده دارای دندانۀ شکسته، انتقال گشتاور و بارگذاری روی دندان چرخنده به صورت آرام و ایده‌آل انجام نمی‌شود و با ضربه همراه است. از این رو سیگنال‌های مربوط به دندان شکسته حاوی ضرباتی خواهند بود که با هر بار درگیری دندان ایجاد می‌شود (شکل ۷-ب). خصیصه‌هایی مانند P و CF که از سیگنال خام ارتعاشات استخراج می‌شوند و همینطور خصیصه‌های FMO و FM4، که برای عیب‌یابی جعبه‌دنده پیشنهاد شده‌اند، به خوبی توانایی تشخیص ضربه‌ای بودن سیگنال زمانی و تفکیک عیوب متناظر با این وضعیت از جمله شکستگی دندان را دارند. از این رو، مدل‌های توسعه داده شده توانسته‌اند به خوبی این عیب را از میان سایر عیوب دیگر تفکیک کنند.

۲-۴- پیاده‌سازی مدل مرکب پیشنهادی

افزایش نقاط اندازه‌گیری و ترکیب داده‌های آنها، می‌تواند بر دقت طبقه‌بند تأثیرگذار باشد. اما باید در نظر داشت که ترکیب داده‌ها از نظر اجرایی با حالت‌های بسیار متنوعی مواجه است. این احتمال وجود دارد که ترکیب داده‌ها در حالت‌هایی دقت خیلی خوبی داشته باشد. تمام حالت‌های ترکیب داده‌های حسگرهای ارتعاش‌سنج (حداقل دو حسگر) از رابطه $m - 1 - m^m$ بدست می‌آید که در آن m تعداد حسگرها است. حال آنکه مدل پیشنهاد شده در پژوهش حاضر (معرفی شده در شکل ۲) می‌تواند هر ترکیبی از داده‌های تمام حسگرها موجود را استفاده کند. به عبارت دیگر نیازی به ساخت مدل‌های متنوع برای ترکیب‌های مختلف داده‌ها وجود ندارد. در ادامه، ابتدا به بررسی عملکرد مدل پیشنهادی در این پژوهش با به کار بردن داده‌های همه حسگرها (۶ حسگر) پرداخته می‌شود و سپس با حذف داده‌های ۲ حسگر، عملکرد مدل روی تشخیص وضعیت سلامت به کمک داده‌های ۴ حسگر دیگر مطالعه می‌شود. در این دو حالت، دقت عملکرد مدل و سطح اطمینان تشخیص استخراج و مقایسه خواهد شد.

۱-۲-۴- مطالعه عملکرد مدل ترکیبی بر اساس داده‌های تمام حسگرها


در جدول ۷، دقت مجموعه داده آموزش و آزمایش، روی تک مدل‌های ساخته شده با داده‌های هر حسگر و همچنین دقت نهایی مدل مرکب پیشنهادی ارائه شده است. مشاهده می‌شود که دقت مدل نهایی روی مجموعه داده آزمایش به ۹۶/۱۵ درصد رسیده است که ۳/۸۵ درصد بیشتر از بهترین دقت مدلی است که صرفاً با داده‌های یک نقطه-جهت (مربوط به SVM6) ساخته شده است. همچنین دقت روی مجموعه داده آموزش از ۸۹/۶۲ درصد که مربوط به بهترین مدل ساخته شده با استفاده از یک نقطه-جهت (مدل SVM4) است، با ۶/۶ درصد افزایش به ۹۶/۲۲ درصد در مدل پیشنهادی رسیده است.

جدول ۷: دقت طبقه‌بند‌های ساخته شده با هر نقطه-جهت به همراه دقت طبقه‌بند مرکب پیشنهادی روی مجموعه داده آموزشی و آزمایشی

Table 7: The accuracy of classifiers built with the data of each point-direction, along with the accuracy of the proposed ensemble classifier on the train and the test datasets

مدل مرکب پیشنهادی	SVM6	SVM5	SVM4	SVM3	SVM2	SVM1	مدل
تمام نقطه-جهت‌ها	خروجی- عمودی	خروجی- افقی	خروجی- محوری	ورودی- عمودی	ورودی- افقی	ورودی- محوری	داده‌های مورد استفاده (نقطه-جهت اندازه‌گیری)
۹۶/۲۲	۸۸/۶۷	۸۳/۹۶	۸۹/۶۲	۸۶/۷۹	۷۷/۳۵	۸۲/۰۷	دقت مجموعه آموزش (درصد)
۹۶/۱۵	۹۲/۳۰	۷۶/۹۲	۸۰/۷۶	۶۹/۲۳	۷۳/۰۷	۷۶/۹۲	دقت مجموعه آزمایش (درصد)


ماتریس درهم‌ریختگی تک مدل‌های ساخته شده با هر نقطه-جهت پیش‌تر در شکل ۸ تا شکل ۱۳ ارائه گردید. در شکل ۱۴، ماتریس درهم‌ریختگی مدل مرکب پیشنهادی ارائه شده است. با توجه به عملکرد ارائه شده، دقت مدل پیشنهادی، خصوصاً روی مجموعه داده آزمایش بالا بوده و چنانچه مشاهده می‌شود، تنها یک نمونه اشتباه تشخیص داده شده است.



شکل ۱۴: ماتریس درهم‌ریختگی طبقه‌بند پیشنهادی برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست)
Figure 14: Confusion matrix of the proposed classifier for training data (left) and test data (right)

برای محاسبه سطح اطمینان هر طبقه‌بند، ابتدا کلاس تشخیص داده شده برای یک نمونه آزمایش، توسط هر مدل، تعیین می‌شود. در ادامه پارامتر فراخوانی کلاس‌های تشخیص داده شده، از روی ماتریس درهم‌ریختگی محاسبه می‌شود. سپس برای تخمین سطح اطمینان هر کلاس، مقادیر فراخوانی هر کلاس جمع می‌شود. مطابق با توضیحات فوق، همه ۲۶ نمونه آزمایش به مدل داده شده و تشخیص عیب توسط مدل پیشنهادی انجام شده و سطح اطمینان تشخیص نیز محاسبه شده است.

برای تعیین سطح اطمینان هر تشخیص روی داده‌های آزمایشی از روند شرح داده شده در بخش ۲-۲-۲ و رابطه (۷) استفاده می‌گردد. به کمک این رابطه، برای تمام کلاس‌های موجود، سطح اطمینان تشخیص قابل محاسبه است و کلاسی که دارای بیشترین سطح اطمینان محاسبه شده باشد، به عنوان تشخیص نهایی مدل مرکب پیشنهادی گزارش گردیده است. در شکل ۱۵، سطح اطمینان تشخیص هر کلاس با رنگ‌های مختلف برای تمام ۲۶ نمونه آزمایش با نشانگر توخالی نشان داده شده است. همچنین برچسب واقعی کلاس هر نمونه نیز توسط نشانگر توپر در بالای شماره نمونه مورد نظر نشان داده شده است و بالای آن نیز حروف T و F (به ترتیب مخفف True و False) برای نشان دادن درست یا نادرست بودن تشخیص نوشته شده است.



شکل ۱۵: سطح اطمینان تشخیص هر کلاس توسط مدل مرکب پیشنهادی روی تمام ۲۶ نمونه مجموعه داده‌های آزمایش (با به کار بردن داده‌های هر ۶ حسگر موجود)

Figure 15: The confidence level correspond to each class by the proposed ensemble model across all 26 samples of the test dataset (using data of all 6 available accelerometers)

مشاهده می‌شود که تنها در نمونه ۱۳ ام، مدل مرکب پیشنهادی دچار تشخیص غلط شده است. در خصوص این نمونه، قابل توجه است که سطح اطمینان کلاس تشخیص داده شده (کلاس ۴ مربوط به سطح حفره‌دار) نسبتاً پایین است (حدود ۴۷ درصد) است و در عین حال، سطح اطمینان محاسبه شده داده برای کلاس ۳ (مربوط به عیب ترک ریشه که برچسب واقعی این نمونه است) نیز در حدود ۳۵ درصد (قابل مقایسه با سطح اطمینان کلاس ۴) می‌باشد. همچنین در مورد برخی نمونه‌ها (مانند نمونه شماره ۱۴ و ۱۶) نیز مشاهده می‌شود که علیرغم تشخیص کلاس صحیح، سطح اطمینان متناظر با آن کلاس نسبتاً پایین است. لذا تأکید می‌گردد که گزارش کردن سطح اطمینان مربوط به تمام کلاس‌ها (مانند نمودار شکل ۱۵) در کنار گزارش تشخیص و طبقه‌بندی انجام شده (مانند ماتریس درهم‌ریختگی شکل ۱۶) بسیار مهم بوده و برای تصمیم‌گیری در مورد وضعیت ماشین و برنامه‌ریزی جهت انجام اقدامات اصلاحی لازم بسیار مؤثر و مفید خواهد بود.

۴-۲-۲- مطالعه عملکرد مدل ترکیبی بر اساس داده‌های تعداد محدودی از حسگرها


در این قسمت داده‌های نقاط ورودی و خروجی جعبه‌دنده در جهات محوری کنار گذاشته شده و تشخیص به کمک همان مدل قبلی (مدل مرکب پیشنهادی) و صرفاً با استفاده از داده‌های جهات افقی و عمودی در نقاط ورودی و خروجی (یعنی داده‌های ۴ حسگر از ۶ حسگر موجود) انجام می‌گردد. نتایج بدست آمده از دقت مدل در این حالت در جدول ۸ ارائه شده است.

جدول ۸: دقت مدل مرکب پیشنهادی روی مجموعه داده آموزشی و آزمایشی با به کار بردن داده‌های تعداد محدودی از حسگرها

Table 8: The accuracy of the proposed ensemble model on the train and the test datasets using data from limited number of accelerometers

مدل مرکب پیشنهادی	مدل
جهات افقی و عمودی در نقاط ورودی و خروجی (۴ حسگر از ۶ حسگر موجود)	داده‌های مورد استفاده (نقطه-جهت اندازه‌گیری)
۹۲/۴۵	دقت مجموعه آموزش (درصد)
۸۸/۴۶	دقت مجموعه آزمایش (درصد)

با مقایسه نتایج مربوط به دقت مدل مرکب پیشنهادی روی داده محدود در جدول ۸ با نتایج گزارش شده قبلی در جدول ۷، مشاهده می‌شود که همچنان دقت مدل مرکب روی مجموعه داده آموزش بیشتر از تمام مدل‌های تکی است و روی داده‌های آزمایش نیز، مدل مرکب از اکثر مدل‌های تکی عملکرد بهتری داشته است. در شکل ۱۶ ماتریس درهم‌ریختگی مدل مرکب پیشنهادی با به کار بردن داده‌های محدود (۴ حسگر از ۶ حسگر) نشان داده شده است.

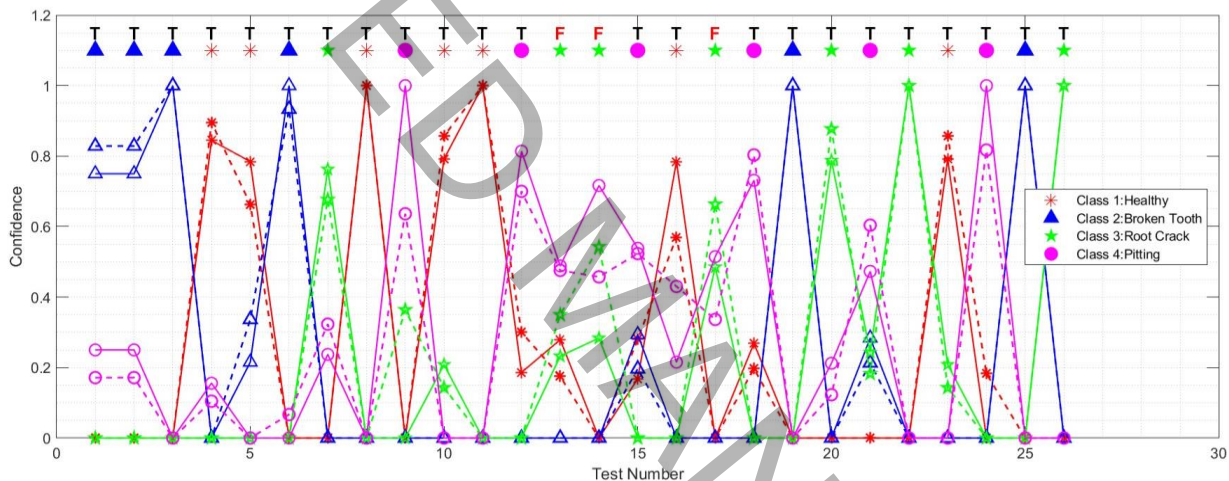


شکل ۱۶: ماتریس درهم‌ریختگی طبقه‌بند پیشنهادی با ۴ حسگر برای داده‌های آموزش (چپ) و داده‌های آزمایش (راست)

Figure 16: Confusion matrix of the proposed classifier with 4 accelerometers for training data (left) and test data (right)

در مقایسه با شکل ۱۴، مشاهده می‌شود که در اینجا نیز تشخیص‌های اشتباه مدل مربوط به کلاس ۳ (ترک ریشه دندان) است و تعداد تشخیص‌های اشتباه از ۱ مورد به ۳ مورد افزایش یافته است که با توجه به کم‌تر شدن داده‌های ورودی به مدل، این افزایش دور از انتظار نیست.

مشابه آنچه که پیش‌تر در شکل ۱۵ ارائه شد، سطح اطمینان تشخیص هر کلاس توسط مدل مرکب پیشنهادی بر اساس داده‌های ۴ حسگر مجدد محاسبه شده و نتایج آن در شکل ۱۷ با نمودارهای نمایش داده شده با خط‌پر ارائه شده است. لازم است توجه شود که نمودارهای خط‌چین در این شکل، همان نتایج استفاده از مدل مرکب پیشنهادی روی داده‌های تمام حسگرها است که قبلاً در شکل ۱۵ نیز ارائه شده بود و در اینجا برای راحت‌تر بودن مقایسه دو حالت، مجدد نمایش داده است. در نتایج نشان داده شده در شکل ۱۷ مشاهده می‌گردد سه مورد تشخیص اشتباه مدل مرکب پیشنهادی مربوط به نمونه‌های ۱۳، ۱۴ و ۱۷ است. در اینجا نیز قابل توجه است که اولاً سطح اطمینان کلاس‌های اشتباه تشخیص داده شده، نسبتاً پایین بوده و ثانیاً سطح اطمینان کلاس واقعی داده نیز اختلاف کمی با سطح اطمینان کلاس تشخیص داده شده توسط مدل دارد. ضمناً، مشاهده می‌شود که مطابق انتظار، با کمتر شدن داده‌های مورد استفاده توسط مدل، سطح اطمینان تشخیص در بیشتر نقاط کاهش یافته است. هرچند، این موضوع عمومیت نداشته و در برخی نمونه‌ها نیز خلاف آن رخ داده است.



شکل ۱۷: سطح اطمینان تشخیص هر کلاس توسط مدل مرکب پیشنهادی روی تمام ۲۶ نمونه مجموعه داده‌های آزمایش (با به کار بردن داده‌های ۴ حسگر از ۶ حسگر موجود)

Figure 17: The confidence level correspond to each class by the proposed ensemble model across all 26 samples of the test dataset (using data of 4 out of the 6 available accelerometers)

۵- نتیجه‌گیری

در این پژوهش با ایده گرفتن از یادگیری جمعی، یک چارچوب جدید به عنوان مدل مرکب ساخته شده از چند مدل پایه پیشنهاد گردید. طبقه‌بندهای پایه، مبتنی بر ماشین بردار پشتیبان بوده و هر یک فقط از داده‌های یک حسگر به عنوان ورودی استفاده می‌کنند. مدل مرکب پیشنهادی قابلیت ترکیب داده‌های چند حسگر را به گونه‌ای ارائه می‌دهد که در صورت آموزش با داده‌های کامل (تمام حسگرهای ممکن)، امکان استفاده از آن روی نمونه‌های جدید با در دست داشتن داده‌های هر تعداد حسگر فراهم باشد. همچنین، در مدل مرکب پیشنهادی روشی برای تخمین سطح اطمینان تشخیص کلاس نیز به ازای داشتن هر تعداد داده از تمام حسگرهای ممکن ارائه شد. این ویژگی مدل مرکب پیشنهادی، در استفاده صنعتی بسیار حائز اهمیت خواهد بود. چرا که در عمل ممکن است در بسیاری از مواقع اندازه‌گیری از نقاط کمتری انجام شود و داده‌های محدودتری برای تفسیر در دست باشد.

روش پیشنهادی روی داده‌های ارتعاشی ثبت شده از یک جعبه‌دنده آزمایشگاهی در وضعیت‌های مختلف عیوب و شرایط کاری متنوع مورد مطالعه قرار گرفت. نشان داده شد که مطابق انتظار، مدل مرکب پیشنهادی، دقت بالاتری نسبت به مدل‌های پایه دارد. همچنین در صورت کاهش تعداد حسگرها به عنوان ورودی‌های مدل مرکب، دقت تشخیص تا حدی کاهش یافته و در عین حال به

طور متوسط سطح اطمینان تشخیص‌های بدست آمده نیز کاهش می‌یابد. یعنی برای یک نمونه ممکن است خروجی مدل مرکب با داده‌های کامل و داده‌های محدود یک کلاس باشد. اما سطح اطمینان کلاس تعیین شده در دو حالت متفاوت باشد. همچنین نشان داده شد که در برخی نمونه‌های آزمایش، سطح اطمینان تشخیص کلاس‌های مختلف ممکن است بسیار به هم نزدیک باشد و لذا ممکن است صرف داشتن یک خروجی به صورت تعیین کلاس برای تصمیم‌گیری در مورد اقدام اصلاحی کافی نباشد. به عبارت دیگر داشتن اطلاعات از سطح اطمینان هر کلاس می‌تواند در تصمیم‌گیری کارشناس و بهره‌بردار در خصوص میزان اطمینان از خروجی مدل و برنامه‌ریزی انجام اقدامات اصلاحی مؤثر باشد.

۶- مراجع

- [1] P. Goswami, R.N. Rai, A systematic review on failure modes and proposed methodology to artificially seed faults for promoting PHM studies in laboratory environment for an industrial gearbox, *Engineering Failure Analysis*, 146 (2023) 107076.
- [2] P. Ku, Gear failure modes—importance of lubrication and mechanics, *ASLe Transactions*, 19(3) (1976) 239-249.
- [3] R.B. Randall, *Vibration-based condition monitoring: industrial, automotive and aerospace applications*, John Wiley & Sons, 2021.
- [4] Y. Zhao, X. Wang, S. Han, J. Lin, Q. Han, Fault diagnosis for abnormal wear of rolling element bearing fusing oil debris monitoring, *Sensors*, 23(7) (2023) 3402.
- [5] A.R. Mohanty, C. Kar, Fault detection in a multistage gearbox by demodulation of motor current waveform, *IEEE transactions on Industrial Electronics*, 53(4) (2006) 1285-1297.
- [6] A.M. Younus, B.-S. Yang, Intelligent fault diagnosis of rotating machinery using infrared thermal image, *Expert Systems with Applications*, 39(2) (2012) 2082-2091.
- [7] X. Lu, P. Li, Research on gearbox temperature field image fault diagnosis method based on transfer learning and deep belief network, *Scientific Reports*, 13(1) (2023) 6664.
- [8] V. Singh, P. Gangsar, R. Porwal, A. Atulkar, Artificial intelligence application in fault diagnostics of rotating industrial machines: A state-of-the-art review, *Journal of Intelligent Manufacturing*, 34(3) (2023) 931-960.
- [9] Z. Tian, M.J. Zuo, Health condition prediction of gears using a recurrent neural network approach, *IEEE transactions on reliability*, 59(4) (2010) 700-705.
- [10] P. Calefati, B. Amico, A. Lacasella, E. Muraca, M.J. Zuo, Machinery faults detection and forecasting using hidden Markov models, in: *Engineering Systems Design and Analysis*, 2006, pp. 895-901.
- [11] B.S. Yang, C.H. Park, H.J. Kim, An efficient method of vibration diagnostics for rotating machinery using a decision tree, *International Journal of Rotating Machinery*, 6(1) (2000) 19-27.
- [12] I. Jamadar, R. Nithin, S. Nagashree, V.P. Prasad, M. Preetham, P. Samal, S. Singh, Spur Gear Fault Detection Using Design of Experiments and Support Vector Machine (SVM) Algorithm, *Journal of Failure Analysis and Prevention*, 23(5) (2023) 2014-2028.
- [13] B. Samanta, Gear fault detection using artificial neural networks and support vector machines with genetic algorithms, *Mechanical systems and signal processing*, 18(3) (2004) 625-644.
- [14] N. Saravanan, K. Ramachandran, Incipient gear box fault diagnosis using discrete wavelet transform (DWT) for feature extraction and classification using artificial neural network (ANN), *Expert systems with applications*, 37(6) (2010) 4168-4181.
- [15] Z. Chen, C. Li, R.-V. Sanchez, Gearbox fault identification and classification with convolutional neural networks, *Shock and Vibration*, 2015(1) (2015) 390134.
- [16] P. Večeř, M. Kreidl, R. Šmíd, Condition indicators for gearbox condition monitoring systems, *Acta Polytechnica*, 45(6) (2005).

- [17] V. Sharma, A. Parey, A review of gear fault diagnosis using various condition indicators, *Procedia Engineering*, 144 (2016) 253-263.
- [18] H. Ahmed, A.K. Nandi, *Condition monitoring with vibration signals: Compressive sampling and learning algorithms for rotating machines*, John Wiley & Sons, 2020.
- [19] E. Bechhoefer, M. Kingsley, A review of time synchronous average algorithms, in: *Annual Conference of the PHM society*, 2009.
- [20] W.I.D. Mining, *Introduction to data mining*, Springer, 2006.

Ensemble Learning based Model for Multi-Sensor Vibration Data Fusion in Gearbox Diagnosis

Hesam Addin Arghand^{a1}, Amir Hossein Kheybarinejhad^a

^aDepartment of Mechanical Engineering, University of Zanjan, Zanjan, Iran

ABSTRACT

This study investigates recorded vibration signals from a laboratory gearbox to assess health condition and identify fault types, using a proposed ensemble-based machine learning algorithm. A single-stage gearbox was designed and tested in laboratory under four health states: no faults, root tooth crack, tooth breakage, and pitting on the tooth, across varying loads and speeds. Vibration measurements were recorded at six points (vertical, horizontal, and axial directions at input and output). A total of 792 signals (6 signals from 132 tests) were collected. For the data from each sensor, a support vector machine (SVM) classifier with a linear kernel was trained, and fault detection accuracy was assessed and compared for each transducer individually. A new data fusion algorithm, inspired by random forest (RF), was developed to combine data from the six sensors. The results showed that the proposed ensemble algorithm provides higher detection accuracy than the individual classifiers for each sensor. In addition, a method is introduced to calculate the confidence level of the diagnoses from the proposed algorithm. It demonstrated that the ensemble algorithm can effectively diagnose faults with incomplete data (regardless of how many sensors are used from the total of six). As expected, using data from fewer sensors resulted in reduced accuracy and confidence levels for the detected fault.

KEYWORDS

Vibration Condition Monitoring, Gearbox Diagnosis, Ensemble Machine Learning, Confidence Level, Sensor Fusion

¹ Corresponding Author: arghand@znu.ac.ir