



The Effective Use of SVM to Detect Faults in Electric Machines by Finite Element Analysis

Seyed Hamid Rafiei¹, Mansour Ojaghi², Mahdi Sabouri^{3*}

¹PhD Student, Department of Electrical Engineering, Zanjan University (ZNU), Zanjan, Iran.

²Professor, Department of Electrical Engineering, Zanjan University (ZNU), Zanjan, Iran.

³Assistant Professor, Department of Electrical & Computer Engineering, Technical and Vocational University (TVU), Tehran, Iran.

ARTICLE INFO

ABSTRACT

Article Type:

Original Research

Received: 04.16.2023

Revised: 09.02.2023

Accepted: 10.04.2023

Keyword:

Current Signature

Fault Detection

Finite Element

Support Vector Machine

*Corresponding Author:

Mahdi Sabouri

Email: msabouri@tvu.ac.ir

This article presents a new approach to using Support Vector Machine (SVM) in the diagnosis of machine faults by finite element analysis (FEA). The requirement of using SVM in fault diagnosis is to go through their initial training phase, which requires access to sufficient data. The simulation dataset has been limited only to that simulation platform, and the laboratory dataset requires several motors to prepare data. In addition to the data of the healthy motor, the faults must be introduced intentionally into other motors to collect data under faulty conditions. However, a dataset of the faulty motor is not available in natural situations. On the other hand, due to the time consumption and cost, it is not possible to use this method to collect data from the unique, expensive, and non-stopping motors. The proposed method only uses the healthy motor and does not consist of the costs associated with purchasing several motors and damaging them. The dataset in this method was provided from motor simulation and then used in the laboratory environment. First, the stator inter-turn short circuit, broken rotor bar, and eccentricity faults were simulated using the FEA to create a dataset for the considered motor. Then, the indicators were extracted by the motor current signature analysis to design suitable SVM models. By the correction factor, the inputs of the trained SVM models were adjusted to detect faults in a laboratory motor. The results confirmed the high capability of the proposed approach to distinguish defects in similar laboratory motors.



EXTENDED ABSTRACT

Introduction

All SVM models for accurate decision-making require initial training with valid data. Furthermore, the educational and testing platforms are the same in all cases. Therefore, these models may not have acceptable accuracy in other platforms for the same motor. This paper introduces a new approach to solving these problems. Firstly, the exact date of the FEA simulation was used for the training and testing of SVM models. Then, the SVM models were evaluated in same real machine by applying the correction factor:

Methodology

Two datasets were prepared: One dataset of simulation results using the FEA in Ansys Electronic Desktop software (Figure 1), and another of the experimental results. The experimental set was equipped with the Lab-view software, DAQ card type with PCI-1716, LTS6-NP, and LV25-P sensors according to Figure 2.




Figure 1. Simulated SCIM with FEA.




Figure 2. Experimental setup.




Figure 3. Healthy rotor, one BRB, and two BRB (Top to down).

Datasets contained the balanced and unbalanced voltage in healthy, SC, BRB, and ME results. The FEA dataset was used to acquire suitable SVM models. These SVM models were designed based on the indicators of stator inter-turn short circuits (SC), broken rotor bars (BRB), and mix eccentricity (ME) faults. By applying the correction factor, the inputs of the trained SVM models were adjusted to detect faults in a similar motor. Then, it investigated the capability of the FEA approach for SVM training to detect defects in similar laboratory motors. The block diagram of the proposed SVM method based on simulation and laboratory data are shown in Figure 3.

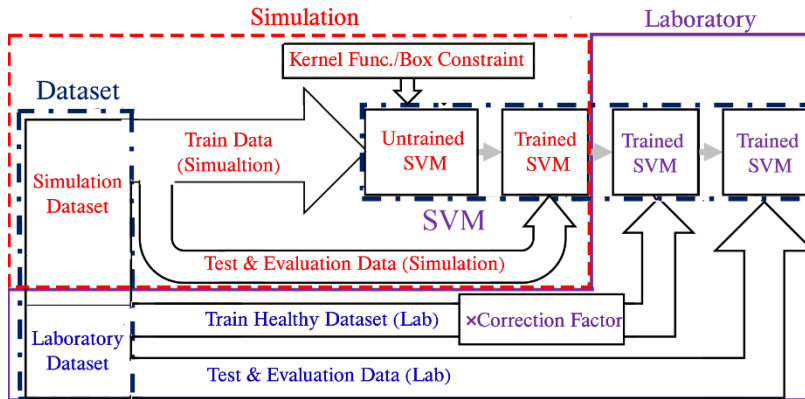


Figure 4. Proposed SVM diagram.

Results and discussion

Three SVMs were provided using simulation datasets to diagnose SC, BRB, and ME. The box constraint for the Soft Margin was 10, and the kernel function was considered the Radial Basic Function (RBF) with a sigma value of 0.7 in SVM.

SC Detection

The CCP as an indicator was employed to detect SC. In a healthy state with a balanced supply, CCP is in a circle shape. However, the SC fault or the supply imbalance causes the circle changes to an oval. So, the value of the negative sequence component (NSC) of voltage is selected to separate them. Therefore, this SVM had two inputs: the ratio of oval diameters and the NSC amplitude. Fifty samples of simulation (29 and 21 cases of healthy motor and two shorted circuit (2SC) turn, respectively) with different NSC were utilized to train SVM. Then, another 80 samples of simulation (2SC-20SC) were used for the initial evaluation of the SVM. The simulation results indicated a high accuracy (100%). Twenty experimental samples consisting of healthy and faulty samples (2SC-20SC) with 2-4volts imbalance were studied to evaluate SVM. The experimental result indicated the diagnostic accuracy of 100%.

BRB Detection

The BRB adds f_{bb} harmonics to the stator current spectrum that could be used to discriminate BRB:

$$f_{bb} = |1 \mp 2ks|f_s \quad (1)$$

where s is the slip, and f_s is the fundamental frequency. The amplitude of the two frequencies for $k=1$ was appointed as the input of SVM. A dataset consisting of 54 simulation samples (24 and 30 samples of the healthy and BRB, respectively) were prepared. Twenty-four samples were employed to train, and the rest of the samples were utilized for the evaluation. The accuracy rate of the evaluation was high (100%). Then, thirty samples of experiment (10 and 20 samples of the healthy and BRB, respectively) were studied to evaluate SVM. The accuracy rate was 100%.

ME Detection

The ME fault adds f_{me} harmonics to the stator current spectrum that could be used to detect this fault:

$$f_{me} = |f_s \mp kf_r| \tag{2}$$

where f_r is the rotor speed in rounds/second, and $k=1$ gives high and low sidebands. The amplitude of two sidebands was selected as the input of the SVM. The simulation dataset consisted of 87 samples (27 healthy samples and 60 ME samples with SE and DE from 5%-20%) prepared to train and evaluate the SVM model for ME diagnosis. Twenty-four samples were applied to train this SVM, and the remaining samples were utilized to evaluate the SVM. The evaluation accuracy of this model was 100%. Next, the trained SVM model was evaluated with the experimental results, and the accuracy rate was 98.6%.

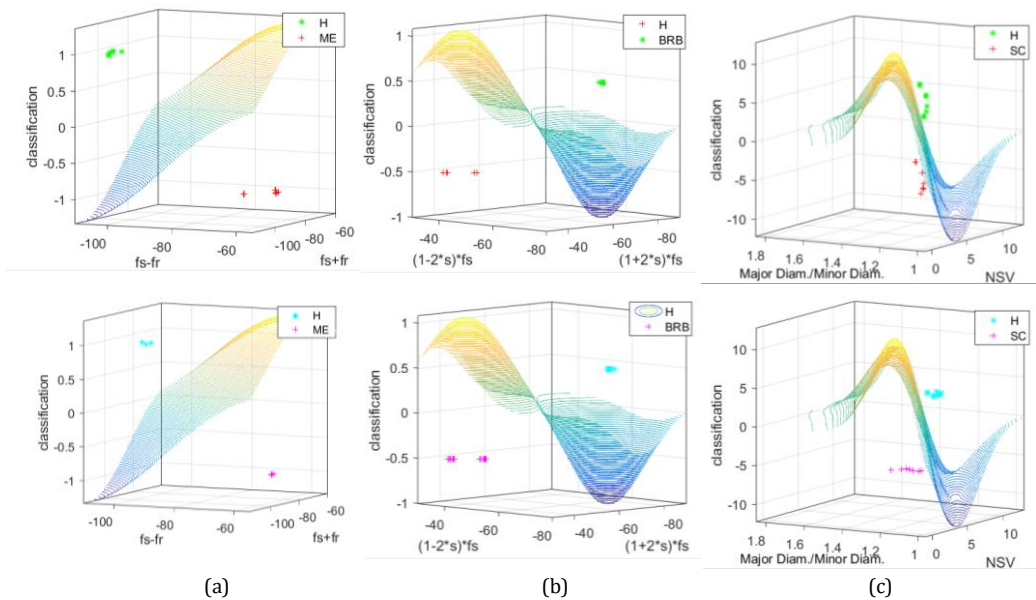


Figure 5. the SVMs to detect SC (a), BRB (b) and ME (c).

Conclusion

In the present research, SVM trained based on FEA acquired the necessary capability to perform in laboratory environments. Despite the high simulation accuracy of FEA, it still had minor differences with the laboratory motor. The proposed solution of this article was to create compatibility between the input indicators of SVM models by using simulated and experimental healthy motor data and applying a correction factor. Three SVM models were trained by FEA results to diagnose SC, BRB, and ME faults and their accuracy were 100% in the evaluated section. After applying the correction factors, they were evaluated using the experimental results. Their classification accuracies were 100%, 100%, and 98.6%, respectively. These results confirmed the high capability of the FEA approach for SVM training to distinguish defects in similar laboratory motors.

استفاده مؤثر از روش SVM جهت تشخیص معایب موتورهای الکتریکی به کمک آنالیز اجزای محدود

سید حمید رفیعی^۱، منصور اوجاقلی^۲، مهدی صبوری^{۳*}

- ۱- دانشجوی دکتری، گروه مهندسی برق، دانشکده مهندسی برق، دانشگاه زنجان، زنجان، ایران.
- ۲- استاد، گروه مهندسی برق، دانشکده مهندسی برق، دانشگاه زنجان، زنجان، ایران.
- ۳- استادیار، گروه مهندسی برق، گروه مهندسی برق و کامپیوتر، دانشگاه فنی و حرفه‌ای، تهران، ایران.

چکیده

اطلاعات مقاله

نوع مقاله: مقاله پژوهشی

دریافت مقاله: ۱۴۰۲/۰۱/۲۷

بازنگری مقاله: ۱۴۰۲/۰۶/۱۱

پذیرش مقاله: ۱۴۰۲/۰۷/۱۲

کلید واژگان:

ماشین بردار پشتیبان
شناسایی خطا
اجزای محدود
اثر جریان

*نویسنده مسئول: مهدی صبوری

پست الکترونیکی:

msabouri@tvu.ac.ir

مقاله حاضر حاوی رویکردی کاربردی برای استفاده از روش ماشین بردار پشتیبان (SVM) در تشخیص خطاهای ماشین‌های الکتریکی با استفاده از آنالیز اجزای محدود (FEA) است. لازمه استفاده از روش SVM در تشخیص خطاها، طی شدن فاز آموزش آن است که خود مستلزم دسترسی به داده‌های کافی می‌باشد. مجموعه داده‌ها براساس شبیه‌سازی، در همان بستر شبیه‌سازی محدود هستند و مجموعه داده‌های آزمایشگاهی نیازمند تهیه چندین موتور می‌باشند تا از یک موتور به صورت سالم داده‌برداری شود و بقیه موتورها معیوب‌سازی شده و در شرایط معیوب داده‌برداری گردند. حال آن‌که در شرایط واقعی، مجموعه داده‌ای از موتور معیوب در دسترس نیست. از طرفی به دلیل زمان‌بری و هزینه‌بری، امکان معیوب‌سازی و داده‌برداری از موتورهای الکتریکی منحصر به فرد، دائم‌کار در خطوط تولید و گران‌قیمت فراهم نمی‌باشد. روش پیشنهادی در این مقاله، استفاده از همان موتور واقعی سالم است و نیازی به هزینه‌های مرتبط با تهیه چندین موتور و معیوب‌سازی آنها را ندارد. مجموعه داده در این روش با تکیه بر شبیه‌سازی و ایجاد ارتباط بین محیط شبیه‌سازی و آزمایشگاهی فراهم می‌شود. در ابتدا، با استفاده از روش FEA عیوب اتصال حلقه استاتور، شکست میله روتور و ناهم‌محوری شبیه‌سازی شده و مجموعه داده آنها تهیه می‌شود. سپس با تحلیل اثر جریان موتور، شاخص‌های عیوب استخراج شده و در طراحی شبکه‌های SVM مناسب استفاده می‌شوند. با اعمال ضرایب اصلاحی، انطباق لازم در ورودی‌های شبکه‌های SVM آموزش‌دیده جهت تشخیص عیوب موتور واقعی مشابه فراهم می‌شود. نتایج حاکی از قابلیت بالای روش پیشنهادی جهت تفکیک عیوب در موتورهای آزمایشگاهی مشابه است.

مقدمه

امروزه استفاده از روش‌های هوش مصنوعی و SVM^۱ در تشخیص و تفکیک خطاهای ماشین‌های الکتریکی بسیار مورد توجه بوده است. برای تشخیص عیب اتصال حلقه استاتور در موتورهای القایی از بعضی هارمونیک‌های جریان استاتور، مؤلفه‌های متقارن جریان‌ها و ولتاژهای سه فاز استاتور و نیز شاخص‌های ترسیمی مانند الگوی جریان کنکور دبا و نوسان پاندولی استفاده شده است [۱-۳]. روش کلاس‌بندی خطا با استفاده از مدل SVM براساس برخی شاخص‌های فوق نیز انجام شده است. مرجع [۴] به بررسی و تشخیص انواع خطاهای موتور القایی با روش SVM و kNN پرداخته است. تشخیص خطای اتصال حلقه در سیم‌پیچ استاتور با استفاده از نامتعدالی ولتاژ در [۵] و با استفاده از شاخص الگوی جریان کنکور دیا در [۶] با داده تجربی و با استفاده از SVM بررسی شده است. در [۷]، از MCSA^۲ و آنالیز تبدیل موجک در روش SVM و بر روی داده عملی برای تشخیص خطای اتصال کوتاه در استاتور بهره گرفته شده است. در [۸]، تشخیص خطای SC^۳ و خطای شکست عایقی براساس روش بردار پارک با لحاظ نامتعدالی ولتاژ در سه مدل کلاس‌بندی مختلف SVM انجام شده و دارای دقت مناسبی بوده است. تشخیص خطای SC براساس ANN با پیش داده عملی در [۹] مطالعه شده است. همچنین، استفاده از روش SVM در تشخیص خطای SC در موتور PMSM با پیش داده‌های عملی در [۱۰] و در موتور القایی با تغذیه اینورتری با داده شبیه‌سازی در سیمولینک متلب در [۱۱] و نیز با داده‌های عملی در [۱۲] انجام شده است.

شاخص شناسایی خطاهای BRB^۴ و ME^۵ در هارمونیک‌های جریان استاتور [۱۳]، نیروی روتور [۱۴]، گشتاور [۱۵]، هارمونیک‌های چگالی شار مغناطیسی [۱۶] و شار پراکندگی [۱۷] ارائه شده است. تشخیص خطاهای مکانیکی در موتور القایی با طرح همجوشی چند حسگر براساس جریان روتور و شار فاصله هوایی در [۱۸] مطرح شده است. همچنین برای شناسایی عیب شکست میله روتور با استفاده از تبدیل موجک جریان در روش‌های SVM و تشخیص الگو در بارهای مختلف و با داده‌های تجربی بررسی شده است [۱۹]. در [۲۰]، تشخیص خطای BRB با روش SVM ترکیبی براساس شاخص هارمونیک و آنالیز موجک و در [۲۱] براساس SVM با داده‌های شبیه‌سازی و عملی انجام شده است. در مرجع [۲۲]، از روش‌های تبدیل موجک و ویژگی‌های دامنه زمانی با استفاده از کلاس‌بندی SVM، جهت بررسی خطاهای ناهم‌محوری در اثر عیب بلبرینگ و حلقه داخلی و خارجی استفاده شده است. بررسی خطای ناهم‌محوری و یاتاقان‌ها با داده‌های تجربی و به روش SVM در [۲۳-۲۷] مورد توجه بوده است. بررسی خطای ناهم‌محوری حاصل از بلبرینگ‌ها با تکیه بر استفاده از دامنه هارمونیک‌های جریان در دو بعد با داده‌های عملی مورد بررسی قرار گرفته است [۲۸] و بررسی خطای ناهم‌محوری و یاتاقان‌ها با استفاده از روش ترکیبی SVM و منطق فازی و سه روش کلاس‌بندی SVM براساس مجموعه داده عملی مورد مطالعه و مقایسه قرار گرفته است [۲۳]. با توجه به قوت روش SVM، این روش برای بررسی خطاهای مرکب نیز در IM^۶ مورد استفاده بوده است. تشخیص خطای BRB و ناهم‌محوری با استفاده از روش طبقه‌بندی چند برچسب با توجه به جریان راه‌اندازی در [۲۹]، روش تشخیص الگو براساس شبکه عصبی NN و هارمونیک‌های جریان استاتور در [۳۰] مطالعه شده است. مرجع [۳۱] برای تشخیص خطای استاتور و روتور شامل حالات نامتعدالی، کج بودن محور، شل بودن قطعات مکانیکی، اتصال کوتاه، نامتعدالی فاز و میله شکسته روتور در موتور القایی از روش SVM متکی بر RBF استفاده کرده است. در [۳۲] از کلاس‌بندی SVM برای تشخیص خطاهای یاتاقان‌ها، نامتعدالی، روتور با میله شکسته و خطاهای سیم‌پیچی استفاده شده است. تشخیص خطاهای جداگانه BRB،

¹ Support Vector Machine (SVM)

² Motor current signature analysis (MCSA)

³ Short Circuit (SC)

⁴ Broken Rotor Bar (BRB)

⁵ Mix Eccentricity (ME)

⁶ Induction Motor (IM)

SE و ME با استفاده از شاخص‌های فرکانسی در جریان استاتور به کمک روش‌های SVM و سیستم خبره اتوماتیک و با داده تجربی در [۳۳] مورد بررسی قرار گرفته است. مقایسه SVM تک کلاسه و دو کلاسه برای تشخیص حالت سالم با لحاظ نامتعادلی تغذیه از خطاهای BRB و انواع خطاهای SC و ناهم‌محوری با تکیه بر شاخص‌های فرکانسی انجام شده است [۳۲]. براساس نوسانات مکانیکی و شاخص جریانی تشخیص حالت سالم و خطاهای ناهم‌محوری روتور، نامتعادلی و بلبرینگ براساس داده عملی مورد مطالعه قرار گرفته‌اند [۳۴].

از روش آنالیز اجزای محدود^۱ برای شبیه‌سازی خطای مختلف موتورهای الکتریکی از جمله خطای اتصال کوتاه در سیم‌پیچ استاتور [۳۵؛ ۳۶]، روتور میله شکسته [۳۷؛ ۳۸] و ناهم‌محوری [۳۹-۴۲] استفاده شده است. همچنین از روش فوق برای آموزش شبکه‌های عصبی برای شناسایی انواع عیوب [۳۵] و آموزش شبکه SVM جهت تشخیص خطای BRB [۳۷] استفاده شده است. در اکثر مقالات، استفاده از FEA همراه با پردازش سیگنال جزو رایج‌ترین روش‌های مورد استفاده است، اما استفاده از آن برای یادگیری ماشین و سایر تکنیک‌های پیشرفته بسیار کم بوده است [۳۵] که یکی از اهداف مقاله حاضر استفاده از روش FEA برای آموزش شبکه SVM است و توانمندسازی این شبکه برای به‌کارگیری در محیط عملی است. لازم به ذکر است که SVM آموزش دیده در این مقاله، برای موتورهای هم‌نوع و مشابه کارایی دارد و برای سایر موتورها نیازمند تحقیقات گسترده‌تر و شبیه‌سازی دقیق‌تر آنها خواهد بود.

بیان مسأله

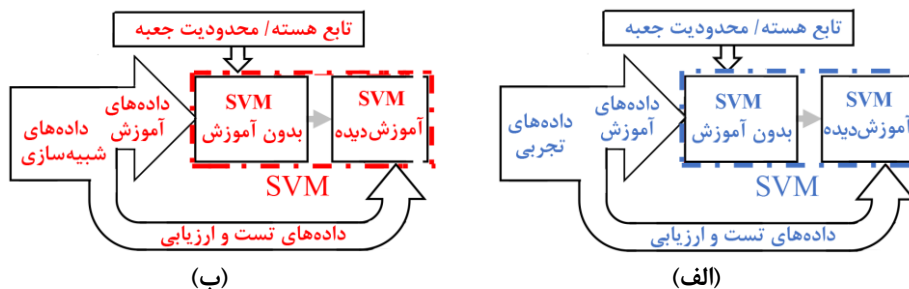
همه مقالاتی که در زمینه یادگیری ماشین^۲ ارائه شده‌اند برای تصمیم‌گیری دقیق، نیازمند آموزش اولیه با یک مجموعه داده کامل و معتبر هستند. اغلب مقالاتی که دارای صحت‌سنجی بالایی هستند، براساس مجموعه داده آزمایشگاهی می‌باشند. اما تهیه این‌گونه مجموعه داده برای موتورهای دائم‌کار در خط تولید، موتورهای منحصر به فرد^۳ و گران‌قیمت امکان‌پذیر نبوده و با هزینه زیادی در پی دارد. در شرایط عادی، اطلاعاتی از موتور واقعی معیوب در دسترس نمی‌باشد و امکان مطالعه بر روی آن موتور معیوب فراهم نیست. یک راهکار متداول، تهیه موتور سالم با همان مشخصات می‌باشد تا با اعمال عیب در آن، یک مجموعه داده برای آن موتور معیوب ایجاد کرد. همچنین برای هر عیب خاص، باید یک موتور با همان عیب تهیه و تست نمود. این روش علاوه بر این که منطقی نیست، هزینه‌بر بوده و چنانچه بیان شد، گاهی نیز امکان‌پذیر نمی‌باشد. نکته قابل توجه دیگر در مراجع فوق این است که در همه موارد، بستر آموزشی و بستر تست برای موتور مدنظر یکسان است. مطابق نمودار بلوکی^۴ در شکل ۱، شبکه‌های SVM آموزش دیده در محیط آزمایشگاهی یا محیط شبیه‌سازی هستند و هیچ پل ارتباطی بین این محیط‌ها وجود ندارد. لذا شبکه SVM در همان محیط فرآیند یادگیری را طی می‌کند و سپس در همان بستر نیز مورد تست و ارزیابی قرار می‌گیرد. لذا ممکن است شبکه SVM آموزش دیده در محیط شبیه‌سازی در محیط آزمایشگاهی برای همان نوع موتور دقت لازم را نداشته باشد و از توانایی SVM آموزش دیده در محیط عملی استفاده نشود. برای رفع این مشکلات بایستی چاره‌ای اندیشید.

¹ Finite element analysis (FEA)

² Machine learning

³ Unique

⁴ Block diagram

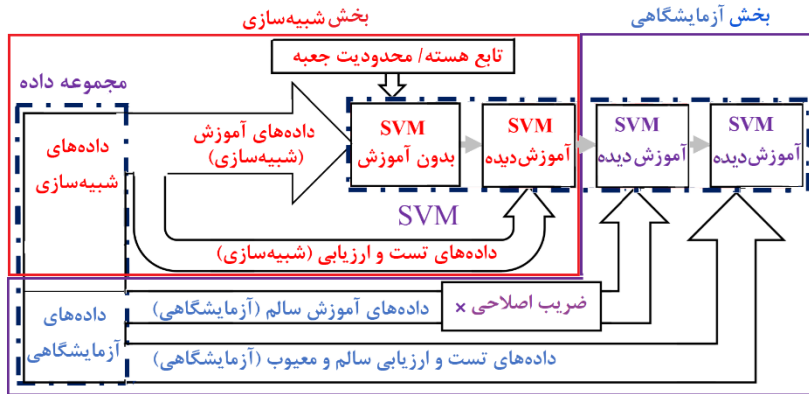


شکل ۱. روش‌های SVM متداول (الف) براساس داده‌های شبیه‌سازی (ب) براساس داده‌های آزمایشگاهی .

روش شناسی

پیشنهاد ارائه شده در این مقاله، فقط نیازمند یک موتور واقعی سالم است که در ابتدای امر از سازنده خریداری شده است. تنها با همین موتور سالم، مجموعه داده توسط شبیه‌سازی و حالت سالم آزمایشگاهی ایجاد شده و عیوب مختلف موتور شناسایی می‌شود. در این مقاله، هر دو مجموعه داده شبیه‌سازی و آزمایشگاهی تهیه شده است تا میزان قوت روش پیشنهادی مورد بررسی قرار گیرد ولی مطابق واقعیت، فرض بر این است که مجموعه داده آزمایشگاهی موتور معیوب در مرحله آموزش در دسترس نمی‌باشد و فقط در مرحله ارزیابی استفاده خواهد شد تا دقت روش مدنظر مطالعه شود. این مقاله با تکیه بر شبیه‌سازی و ایجاد ارتباط بین محیط شبیه‌سازی و آزمایشگاهی این امر را محقق می‌کند. در شبیه‌سازی‌ها، از روش آنالیز اجزای محدود که از پرکاربردترین و دقیق‌ترین روش‌های تحلیل موتورهای الکتریکی است [۴۳؛ ۴۴]، استفاده شده است. این روش، می‌تواند به عنوان یک روش دقیق، کم‌هزینه و غیرمخرب برای شبیه‌سازی انواع عیوب و تهیه مجموعه داده مناسب جهت یادگیری ماشین استفاده شود. این روش می‌تواند ساختار مدار مغناطیسی پیچیده، طرح‌بندی سیم‌پیچ‌های گسسته، خواص مواد مغناطیسی غیرخطی موتور و اشباع مغناطیسی موضعی ناشی از خطاها را مدل‌سازی کند و پارامترهای توزیع میدان مغناطیسی، چگالی شار، گشتاورهای الکترومغناطیسی و جریان استاتور را تعیین نماید [۳۵]. این روش می‌تواند مشکلات ناشی از فقدان پایگاه‌های داده جامع برای عیوب و دشواری تشخیص آنها را برطرف کند و تعداد آزمایش‌های مخرب مورد نیاز در زمینه آزمایشگاهی را کاهش دهد. لذا این مقاله روش آنالیز اجزای محدود را جهت تهیه مجموعه داده پیشنهاد می‌دهد. براساس این روش، شبیه‌سازی رفتار موتور القایی در شرایط سالم و معایب اتصال حلقه استاتور، شکست میله روتور و ناهم‌محوری انجام شده و شاخص‌های شناخته شده معایب مذکور، در سیگنال‌های الکتریکی استاتور استخراج و مرتب می‌شوند. سپس برای طراحی شبکه SVM مناسب، حدود ۷۰٪ داده شبیه‌سازی متعلق به کمترین میزان خطا صرف آموزش و مابقی داده‌های شبیه‌سازی صرف تست و ارزیابی آن قرار می‌گیرند. اکنون باید بررسی کرد که آیا شبکه SVM آموزش دیده قابلیت تشخیص خطا در موتور مشابه آزمایشگاهی را دارد یا نه؟! جواب این سؤال وابسته به میزان انطباق شبیه‌سازی FEA بر موتور آزمایشگاهی است. روش FEA با وجود دقت بالای شبیه‌سازی، ممکن است باز هم دارای اختلافات جزئی با موتور آزمایشگاهی باشد و ایجاد انطباق کامل امری دست‌نیافتنی باشد. دلیل این اختلاف می‌تواند ناشی از عوامل مختلفی همانند میزان دقت مدل‌سازی دو بعدی نرم‌افزار FEA، عدم لحاظ جریان‌های گردابی و شارهای پراکندگی، عدم دسترسی دقیق به جنس مواد و منحنی‌های چگالی آنها، عدم لحاظ ناهم‌محوری ذاتی موتور و بار چرخان و خطاهای نمونه‌برداری باشد. از طرفی، لحاظ همه موارد فوق ممکن است مدت زمان شبیه‌سازی را افزایش دهد و مدت زمان تهیه پایگاه داده را بسیار طولانی کند. لذا در این مرحله، باید میزان انطباق شبیه‌سازی FEA با مدل آزمایشگاهی تعیین شده و در صورت عدم انطباق کامل، چاره‌های اندیشیده شود. راهکار این مقاله، ایجاد انطباق بین شاخص‌های ورودی SVM با استفاده از داده‌های موتور سالم

شبیه‌سازی و آزمایشگاهی است. برای این امر، کافی است که شاخص‌های خطا در مجموعه داده موتور سالم شبیه‌سازی و آزمایشگاهی استخراج گردد و به SVM مربوطه اعمال شده و نمودار خروجی SVM ترسیم شود. سپس با اعمال ضریب اصلاحی، نقطه ثقل مربوط به پراکندگی شاخص نمونه‌های منتجه از دو روش در نمودار خروجی SVM بر هم منطبق شوند و در فاصله یکسانی از صفحه ابری شبکه SVM قرار گیرند. اکنون SVM با ضریب اصلاحی در ورودی خود، قابلیت پایش وضعیت خطای مدنظر در موتورهای آزمایشگاهی مشابه^۱ را خواهد داشت که در ادامه مورد بررسی قرار می‌گیرد. نمودار ترسیم شده در شکل ۲، مراحل کار روش فوق را تبیین می‌کند.



شکل ۲. نمودار بلوکی روش SVM پیشنهادی براساس داده‌های شبیه‌سازی و آزمایشگاهی.

مدل طبقه‌بندی SVM

یکی از پرکاربردترین روش‌های طبقه‌بندی خطاها، روش SVM است که نیاز به یادگیری تحت نظارت دارد و جزو الگوریتم‌های تشخیص الگو دسته‌بندی می‌شود. مزیت اصلی SVM این است که برخلاف شبکه‌های عصبی مصنوعی در ماکزیمم‌های محلی به دام نمی‌افتد. این روش برای مسائل با داده‌های حجیم جواب قابل قبولی ارائه می‌دهد و حاوی مصالحه‌ای بین پیچیدگی دسته‌بندی و میزان خطا است [۴۵]. روش SVM، به یک تابع هسته^۲ مناسب و انتخاب پارامتر محدودیت جعبه^۳ نیاز دارد. تابع هسته، انتقال داده‌ها به یک فضای با بعد بالاتر جهت کلاس‌بندی دقیق‌تر را فراهم می‌کند و محدودیت جعبه برای انتخاب حاشیه نرم^۴ جهت آموزش شبکه SVM است. وقتی داده‌ها کاملاً قابل تفکیک نیستند، الگوریتم آموزشی باید امکان طبقه‌بندی اشتباه را با اعمال ضریب جریمه‌ای در مجموعه آموزشی فراهم نماید. هر چه مقدار محدودیت جعبه بیشتر باشد، هزینه ضریب جریمه نقاط طبقه‌بندی اشتباه بیشتر می‌شود و منجر به جداسازی دقیق‌تر داده‌ها می‌شود. در این روش، مجموعه داده‌های آزمایشی D شامل n عضو به صورت زیر است [۴۵]:

$$D = \{(x_i, y_i) | x_i \in R^p, y_i \in \{-1, 1\}\}_{i=1}^n \quad (1)$$

¹ Type

² Kernel Function

³ Box Constraint

⁴ Soft Margin

جایی که مقدار y_i برابر 1 یا -1 و هر x_i یک بردار حقیقی p بعدی است. در SVM، هدف یافتن بیشترین فاصله از نقاط حاشیه‌ای یا ابرصفحه جداکننده است که نقاط با $y_i=1$ را از نقاط با $y_i=-1$ جدا کند. هر صفحه جداساز می‌تواند به صورت مجموعه‌ای از نقاط x که شرط زیر را برآورده نماید، تعیین شود:

$$w \cdot x - b = 0 \quad (2)$$

به طوری که علامت " " همان علامت ضرب است و w بردار نرمالی است که به صفحه جداکننده عمود است. مقدار w و b طوری انتخاب می‌شود که بیشترین فاصله بین صفحه‌های جداکننده موازی که داده‌ها را از هم جدا می‌کنند، ایجاد شود. این صفحه‌های جداکننده با استفاده از رابطه زیر توصیف می‌شوند.


$$w \cdot x - b = 1, \quad w \cdot x - b = -1 \quad (3)$$

اگر داده یادگیری از نوع داده جداکننده خطی باشند، امکان دارد که دو صفحه جداساز در حاشیه نقاط بدون هیچ نقطه مشترکی لحاظ شوند و سپس فاصله آنها به حداکثر مقدار افزایش یابد. شکل ۳، صفحه جداساز با حداکثر حاشیه برای یک ماشین بردار پشتیبانی برای دو دسته را نشان می‌دهد. داده‌ای که بر روی این صفحه جداساز در مرز قرار دارند بردارهای پشتیبانی نامیده می‌شوند. فاصله این دو صفحه با توجه به روابط هندسی معادل $\|w\|/2$ به دست می‌آید که باید مینیمم شود. برای این که از ورود نقاط به حاشیه جلوگیری شود، شرایط زیر باید به ازای هر مقدار i لحاظ شود.

$$w \cdot x - b \geq 1, \text{ if } y_i = 1; \quad w \cdot x - b \leq -1, \text{ if } y_i = -1 \quad (4)$$

که می‌تواند به صورت زیر بیان شود:

$$y_i(w \cdot x - b) \geq 1, \forall 1 \leq i \leq n \quad (5)$$



شکل ۳. صفحه جداساز SVM برای آموزش دو دسته [۴۵].

با لحاظ این دو قید، یک مسئله بهینه‌سازی (OP) به دست می‌آید:

$$\begin{aligned} \min_{(w,b)} \|w\| \\ \text{s. t. } y_i(w \cdot x_i - b) \geq 1; \quad \forall 1 \leq i \leq n \end{aligned} \quad (6)$$

می‌توان برای تبدیل مسأله بهینه‌سازی با قیدهای بیان شده به یک مسأله بهینه‌سازی غیرخطی مرتبه دوم، $||w||$ را با $||w||^2/2$ جایگزین نمود و مسأله فوق را به صورت یک مسأله بهینه‌سازی با برنامه‌ریزی غیرخطی (QP) بررسی نمود:

$$\min_{(w,b)} \frac{1}{2} ||w||^2 \quad (7)$$

$$s. t. y_i(w \cdot x_i - b) \geq 1; \forall 1 \leq i \leq n$$

با استفاده از ضرایب نامنفی لاگرانژ (α_i) می‌توان معادله فوق را به صورت زیر نوشت:

$$\min_{(w,b)} \max_{(\alpha)} \left\{ \frac{1}{2} ||w||^2 - \sum_{i=1}^n \alpha_i (y_i (w \cdot x_i - b) - 1) \right\} \quad (8)$$

برای یافتن نقاط زینی^۱، می‌توان این مسأله را به کمک برنامه‌ریزی غیرخطی استاندارد حل کرد و جواب را به صورت ترکیب خطی از بردارهای یادگیری بیان نمود:

$$w = \sum_{i=1}^n \alpha_i y_i x_i \quad (9)$$

تنها چند α_i بزرگتر از صفر خواهد بود. x_i متناظر، دقیقاً همان بردار پشتیبان خواهد بود که شرط را برآورده خواهد کرد. لذا بردارهای پشتیبان باید شرط زیر را ارضا کنند:

$$y_i (w \cdot x_i - b) = 1 \quad (10)$$

بردار b بصورت زیر تعریف می‌شود که در آن N_{sv} میانگین همه بردارهای پشتیبان بوده و باعث می‌شود الگوریتم مقاوم‌تر باشد [۴۵].

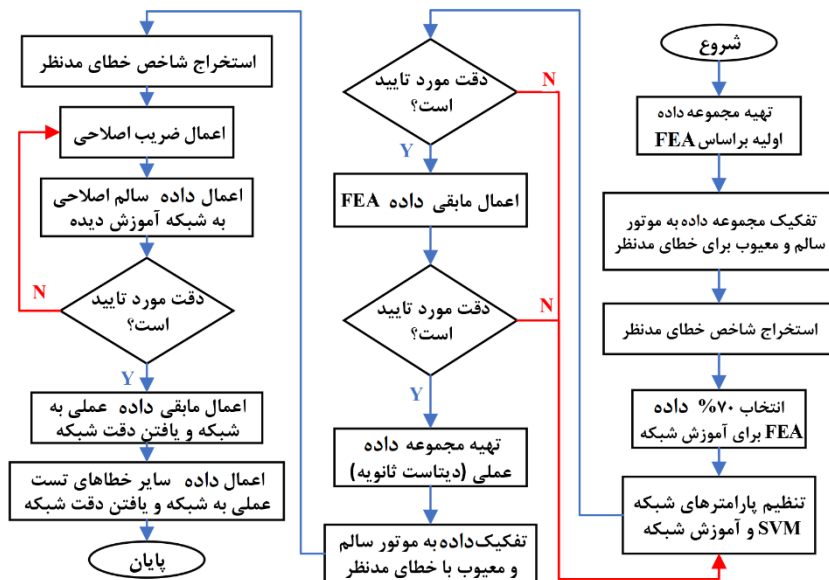
$$b = \frac{1}{N_{sv}} \sum_{i=1}^{N_{sv}} (w \cdot x_i - y_i) \quad (11)$$

تهیه مجموعه داده

دو دسته مجموعه داده^۲ گسترده و دقیق در این مقاله تهیه شده است که یک مجموعه داده حاصل از شبیه‌سازی با روش FEA و مجموعه داده دیگر براساس موتور آزمایشگاهی می‌باشد. هر یک از مجموعه داده‌ها مشتمل بر داده‌های موتور سالم و موتور معیوب شامل SC، BRB و ME با لحاظ ولتاژ تغذیه متعادل و نامتعادل هستند. مطابق شکل ۲، ابتدا تست و ارزیابی شبکه SVM براساس مجموعه داده اول انجام می‌شود و بعد از حصول نتیجه مطلوب، ارزیابی دیگری برای همان SVM با استفاده از مجموعه داده دوم انجام می‌گیرد. با حصول نتیجه مطلوب از ارزیابی دوم، در واقع قابلیت تشخیص خطا در موتور واقعی توسط SVMهای آموزش دیده توسط روش FEA به اثبات می‌رسد. روندنمای روش پیشنهادی در شکل ۴ ارائه شده است.

¹ Saddle points

² Dataset



شکل ۴. روندنمای روش پیشنهادی.

تهیه مجموعه داده اول براساس شبیه‌سازی

برای تهیه مجموعه داده اول، از شبیه‌سازی توسط FEA براساس ویژگی RMxprt در Ansys Electronic Desktop 2020 مطابق جدول ۱ و شکل ۵ استفاده شده است. در این مدل، موتور سالم و موتورهای معیوب با خطاهای مذکور در درجات مختلف شبیه‌سازی می‌شوند و شاخص‌های معروف معایب مورد مطالعه قرار می‌گیرند. برای اعمال خطای SC، میزان تعداد دورهای اتصال کوتاه شده در درون شیارهای مورد نظر کاهش یافته است. تعداد دورهای اتصال کوتاه شده را می‌توان به صورت یک فاز جداگانه در درون شیارهای مدنظر لحاظ نمود [۳]. برای اعمال خطای ME از ویژگی Maxwell Eccentricity در Maxwell ACT بخش Extensions Wizards نرم‌افزار استفاده شده است. برای اعمال خطای BRB می‌توان با انتخاب مواد با مقاومت بالا برای میله مذکور، مقاومت میله معیوب را افزایش داد تا میزان جریان آن کاهش یابد [۳]. همچنین می‌توان با توجه به ساختار دو بعدی شبیه‌سازی FEA، میله روتور را نسبت به حالت سالم در شیار مدنظر لحاظ نکرد. در این مقاله روش دوم مدنظر بوده است.

تهیه مجموعه داده دوم براساس موتور واقعی

برای تهیه مجموعه داده دوم یک موتور واقعی سالم با مشخصات ارائه شده در جدول ۱ که امکان اعمال خطاهای SC، BRB و ME بر روی آن به طور موقت وجود دارد، استفاده می‌شود. مطابق شکل ۶، محور موتور نمونه با محور یک دستگاه ژنراتور سنکرون متصل شده^۱ تا امکان بارگذاری موتور فراهم شود. برای ممانعت از انتقال آثار ناهم‌محوری از ژنراتور سنکرون به موتور القایی از کوپلینگ^۲ مخصوص دیسکی با اتصال کلمپی نوع DMPA-C مطابق شکل ۷-الف استفاده می‌شود. ترمینال‌های استاتور ژنراتور سنکرون به یک بار اهمی متغیر متصل می‌شود. با تغییر مقاومت بار می‌توان


¹ Coupled

² Coupling


میزان بار موتور القایی را تنظیم نمود. برای انجام نمونه برداری از ولتاژها و جریان های خط استاتور، کارت DAQ نوع PCI ۱۷۱۶ به همراه سنسورهای جریان نوع LTS۶-NP و سنسورهای ولتاژ نوع LV۲۵-P همراه با نرم افزار Labview-۷۲۰۱۲ با بلوک رابط DAQNAVI مورد استفاده قرار می گیرند. همچنین سرعت نمونه برداری از پارامترها برابر ۲۵/۰ ms در طول مدت زمان ۱۰/۵ ثانیه تنظیم شده بود.

جدول ۱. اطلاعات موتور شبیه سازی شده مطابق موتور واقعی

پارامتر	مقدار
Rated Power and Voltage	۱.۱ [kW], ۳۸۰ [V]
Frequency and Pole Pairs Number	۵۰ [Hz], ۲
Phases Configuration	Star
Stator and Rotor Slots Number	۳۶, ۲۸
Healthy Air Gap Length	۰.۳ [mm]
Air Gap Mean Radius	۴۰ [mm]
Stack Length	۶۰ [mm]
Stator Winding Turn Per Coil	۶۳ [Turn]
Stator Resistance Per Phase	۷.۸ [Ω /Phase]
Rotor Bar Resistance	۹.۷۲ [$\mu\Omega$]
End Ring Resistance	۸ [$\mu\Omega$]
Leakage inductance of Stator	۱۸.۸ [mH/Phase]
Leakage inductance of Rotor Bar	۰.۵۷۱ [μ H]
Leakage inductance of End Ring	۰.۰۵۱ [μ H]
Inertia Moment	۰.۰۰۲۳۸۵ [Kg.m ²]
Winding Scheme of Phase "A"	A-۱-۱۲'-۲-۱۱'-۳-۱۰'-۱۹-۳۰'-۲۰-۲۹'-۲۱-۲۸'-X



شکل ۶. مجموعه تست آزمایشگاهی.



شکل ۵. مش بندی دو بعدی ماشین نمونه در FEA.

برای ایجاد خطای ME به طور موقت بلبرینگ های موتور سالم با کد ۶۲۰۵RS با بلبرینگ های کد ۶۹۰۶ZZ مطابق شکل ۷-ب جایگزین می شوند. بلبرینگ جدید در مقایسه با بلبرینگ اصلی موتور دارای قطر داخلی بزرگتر و قطر خارجی کوچکتر است. اختلاف قطرهای داخلی و خارجی بلبرینگ جدید با ساخت و نصب حلقه های مناسب در داخل و خارج

آن جبران می‌شود. حال اگر حلقه‌های ساخته شده دارای ناهم‌محوری باشند یعنی دایره‌های داخلی و خارجی آنها هم مرکز نباشند موجب ایجاد ناهم‌محوری مرکب در موتور خواهد شد. برای اعمال خطای BRB، روتور سالم با روتورهای معیوب جایگزین می‌شود. مطابق شکل ۸، با انجام سوراخ‌کاری روی میله یا میله‌های قفس روتور می‌توان خطای BRB را اعمال نمود. روتورهای معیوب دارای یک و دو میله شکسته هستند که ضعیف‌ترین میزان این نوع خطا است.



شکل ۷. الف. کوپلینگ انعطاف پذیر، ب. بلبرینگ اصلی (سمت راست) و بلبرینگ جایگزین (سمت چپ).



شکل ۸. سه روتور مشابه، روتور سالم (بالا)، روتور با یک میله شکسته (وسط) و دو میله شکسته (پایین).


استفاده از مدل SVM برای تشخیص عیوب

در این بخش برای تشخیص و تفکیک خطاهای SC، BRB و ME سه مدل SVM با استفاده از ۷۰٪ مجموعه داده حاصل از شبیه‌سازی فراهم می‌شوند. سپس این مدل‌ها با بقیه داده‌های شبیه‌سازی با میزان بالاتر خطا مورد ارزیابی قرار می‌گیرند. در نهایت ارزیابی با نتایج آزمایشگاهی انجام می‌شود. همچنین مقاوم بودن هر کدام از مدل‌های SVM در برابر دو خطای دیگر با استفاده از مجموعه داده آزمایشگاهی مورد بررسی قرار می‌گیرد.

تشخیص خطای SC با SVM

در این مقاله، برای اولین بار از نسبت قطر بزرگ به قطر کوچک شکل بیضی حاصل از شاخص الگوی جریان کنکوردیا جهت آموزش و ارزیابی SVM برای تشخیص این نوع خطا استفاده می‌شود [۳؛ ۹]. شکل ۹، الگوی جریان کنکوریا را در موتور سالم (H) و عیب SC نشان داده است که بیضی شدن الگو در اثر بروز عیب در آن مشخص می‌باشد. اما مشکل استفاده از این الگو در تشخیص عیب اتصال حلقه استاتور، این است که موتور سالم با نامتعادلی ولتاژهای سه فاز تغذیه استاتور (H, Un-V) نیز موجب بیضی شدن این الگو خواهد شد. برای رفع این مشکل، میزان نامتعادلی ولتاژهای استاتور در مرحله آموزش و ارزیابی مدل SVM مدنظر قرار داده شده است. بنابراین نسبت قطر بزرگ به قطر کوچک

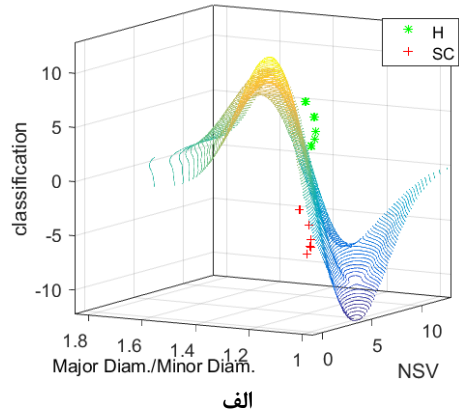

بیضی (MajorDiam./MinorDiam.) در الگوی جریان کنکوردیا و دامنه ولتاژ توالی منفی استاتور^۱ به عنوان ورودی‌های مدل SVM انتخاب می‌شوند.





شکل ۹. شاخص کنکوردیا برای موتور سالم بدون نامتعادلی (H) و با نامتعادلی (H, Un-V) و عیب SC.

با استفاده از اطلاعات مجموعه داده اول، ۱۰۰ نمونه برای آموزش و ارزیابی اولیه SVM استفاده می‌شود که حاوی نامتعادلی ولتاژ هستند که میزان نامتعادلی ولتاژ توالی منفی با دامنه‌های صفر، دو، چهار، هشت و دوازده ولت هستند. برای آموزش شبکه، ده نمونه از موتور سالم و ده نمونه از موتور با کمترین میزان خطای اتصال کوتاه ۲ دور (SC 2) با میزان نامتعادلی‌های فوق استفاده شده است و خروجی آموزش این شبکه SVM در شکل ۱۰-الف نمایش داده شده است. سپس برای تست اولیه این شبکه از ۸۰ نمونه استفاده شده که شامل ۱۴ نمونه بدون نامتعادلی ولتاژ و بقیه دارای نامتعادلی ولتاژ با دامنه‌های اشاره شده بودند. از این ۸۰ نمونه، ۵ نمونه سالم و بقیه دارای خطای اتصال کوتاه دو، چهار، شش، هشت و بیست دور بوده‌اند که نتایج این تست در شکل ۱۰-ب نمایش داده شده است. همان‌طور که ملاحظه می‌شود صحت ارزیابی اولیه این شبکه ۱۰۰٪ است. برای یافتن ضریب اصلاحی در این مدل، تعداد ده نمونه آزمایشگاهی مطابق شکل ۱۱-الف به شبکه SVM آموزش‌دیده اعمال و ضریب تصحیح به مقدار ناچیز ۰.۳٪ برای ورودی‌های SVM لحاظ شد. بعد از اعمال ضریب تصحیح مطابق شکل ۱۱-ب، تعداد ۲۰ نمونه آزمایشگاهی مورد مطالعه قرار گرفتند که ۱۰ نمونه سالم و ۱۰ نمونه معیوب با میزان خطای دو تا بیست دور با گام دو دور بودند. با توجه به استفاده از سیستم برق شهری همه موارد دارای نامتعادلی ولتاژی دو ولت تا چهار ولت بودند. شکل ۱۱-ب نتیجه ارزیابی شبکه SVM آموزش‌دیده را برای داده‌های عملی سالم و معیوب با صحت قبولی ۱۰۰٪ نشان می‌دهد.

¹ Negative sequence voltage (NSV)



شکل ۱۰. آموزش شبکه SVM برای تشخیص خطای SC با داده‌های شبیه‌سازی (الف) آموزش (ب) تست.



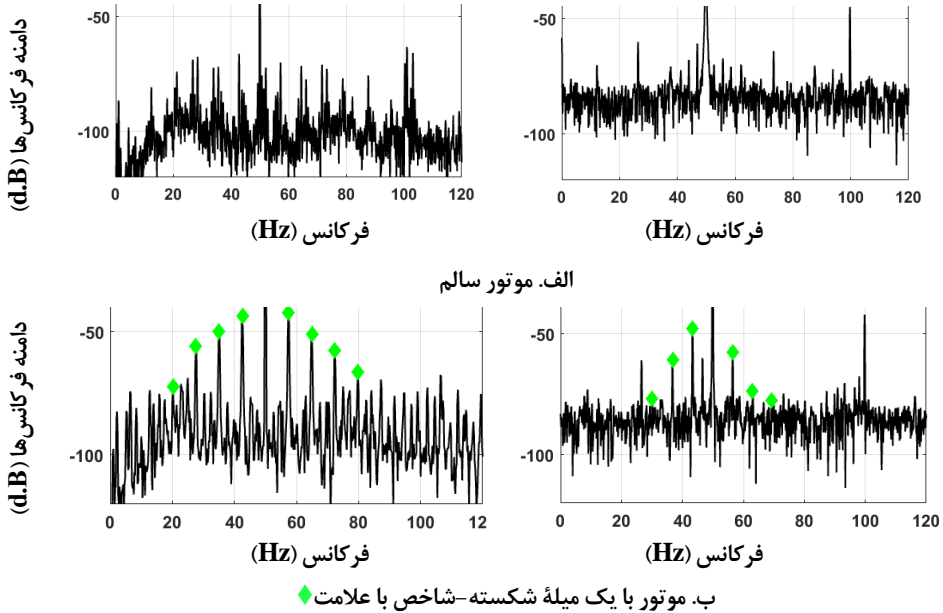
شکل ۱۱. تست نهایی SVM برای تشخیص SC با داده‌های عملی (الف) قبل از اصلاح (ب) بعد اصلاح.

تشخیص خطای BRB با SVM

برای شناسایی خطای BRB می‌توان از دامنه مؤلفه‌های فرکانسی جریان استاتور استفاده کرد [۴۶؛ ۴۷]:


$$f_{bb} = |1 \mp 2ks|f_s \quad (۱۲)$$

که در آنها "s" لغزش، "f_s" فرکانس اصلی تغذیه استاتور و "k" عدد صحیح مثبت است. مطابق اطلاعات بیان شده در جدول ۱، نمونه طیف فرکانسی جریان استاتور برای موتور سالم و موتور با عیب یک میلیه شکسته در شکل ۱۲ ارائه شده است.




شکل ۱۲. طیف فرکانسی نرمالیزه موتور شبیه‌سازی شده (سمت چپ) و موتور واقعی (سمت راست).

در این مقاله، دامنه فرکانس‌های شاخص BRB به ازای $k=1$ مطابق رابطه (۱۲) به عنوان ورودی SVM انتخاب شدند. برای آموزش و ارزیابی اولیه SVM تشخیص خطای BRB از یک مجموعه داده شامل ۵۴ نمونه شبیه‌سازی استفاده شده است که ۲۴ نمونه از موتور سالم و ۳۰ نمونه از موتور معیوب با روتور میله شکسته با یک میله و دو میله معیوب است. برای آموزش این شبکه بیست نمونه شامل ۱۲ نمونه از موتور سالم و ۱۲ نمونه از موتور معیوب استفاده شد. خروجی آموزش این شبکه SVM در شکل ۱۳-الف نمایش داده شده است. برای تست اولیه این شبکه از ۳۰ نمونه استفاده شده که شامل ۱۲ نمونه سالم و ۱۸ نمونه با عیب BRB هستند که نتایج این تست در شکل ۱۳-ب نمایش داده شده است. همان‌طور که ملاحظه می‌شود ارزیابی اولیه این شبکه ۱۰۰٪ است. برای بررسی انطباق دو مدل، تعداد ده نمونه سالم آزمایشگاهی مطابق شکل ۱۴-الف به شبکه SVM اعمال و ضریب اصلاحی کاهشی به میزان ۵٪ تعیین گردید. بعد از اعمال ضریب تصحیح، تعداد ۳۰ نمونه آزمایشگاهی مورد مطالعه قرار گرفتند که ۱۰ نمونه سالم و ۲۰ نمونه معیوب با خطای یک میله و دو میله شکسته بود. شکل ۱۴-ب نتیجه ارزیابی شبکه SVM آموزش‌دیده را برای داده عملی سالم و معیوب با صحت قبولی ۱۰۰٪ نشان می‌دهد.




ب




الف

شکل ۱۳. آموزش شبکه SVM برای تشخیص خطای BRB با داده شبیه‌سازی (الف) آموزش (ب) تست.



ب



الف


شکل ۱۴. تست نهایی SVM برای تشخیص خطای BRB با داده عملی (الف) قبل اصلاح (ب) بعد اصلاح.

تشخیص خطای ناهم‌محوری مرکب با SVM

برای تشخیص خطای ME از حالت سالم نیز از دامنه مؤلفه‌های فرکانسی ایجاد شده در طیف جریان استاتور در اثر بروز عیب مذکور استفاده می‌شود. رابطه ۱۳ فرکانس دقیق این مؤلفه‌ها را بیان می‌کند [۱]:

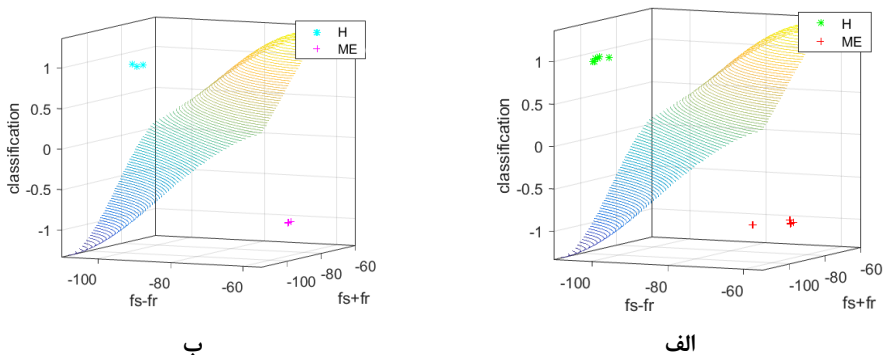
$$f_{me} = |f_s \mp k f_r| \quad (۱۳)$$

که در آن " f_r " فرکانس سرعت چرخش روتور برحسب r.p.s است. در (۱۳)، به ازای $k=1$ ، دو هارمونیک به فاصله یکسان در دو طرف هارمونیک اصلی بدست می‌آیند که باند کناری پایین (LSB) و باند کناری بالا (HSB) نامگذاری شده‌اند [۱]. نمونه طیف فرکانسی جریان استاتور برای موتور با عیب ME با مؤلفه استاتیکی (SE) ۳۰٪ و مؤلفه دینامیکی (DE) ۲۰٪ در شکل ۱۵ ارائه شده است. بروز یا تقویت دامنه دو فرکانس باند کناری مذکور در اثر بروز عیب در نتایج شبیه‌سازی و همچنین نتایج آزمایشگاهی نسبت به طیف فرکانسی موتور سالم در شکل ۱۲-الف مشهود است.

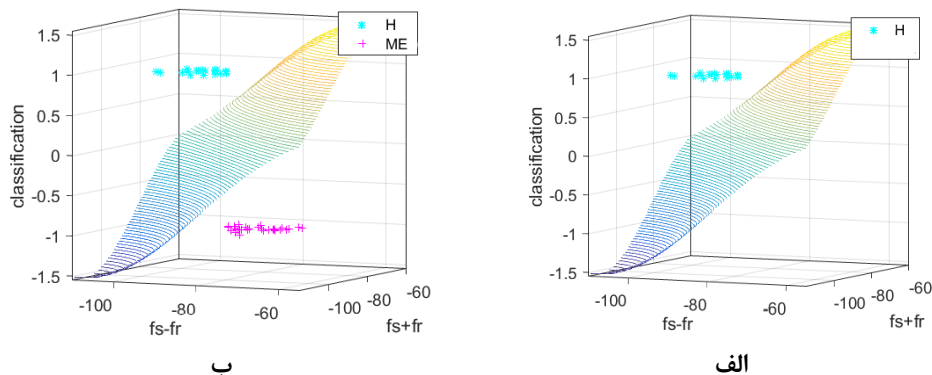


شکل ۱۵. طیف فرکانسی نرمالیزه شده موتور شبیه‌سازی شده (سمت چپ) و موتور واقعی (سمت راست) - موتور با ۳۰٪ SE و ۲۰٪ DE - شاخص با علامت *.

دامنه نرمالیزه دو فرکانس باند کناری به عنوان ورودی مدل SVM انتخاب شدند. برای آموزش و ارزیابی اولیه SVM تشخیص خطای ME از یک مجموعه داده شامل ۸۷ نمونه شبیه‌سازی شده است. تعداد ۲۷ نمونه از موتور سالم و ۶۰ نمونه از موتور با عیوب ناهم‌محوری ترکیبی استاتیکی و دینامیکی، هر یک با میزان خطای ۵٪ تا ۲۰٪ است. برای آموزش این شبکه بیست نمونه شامل ۱۲ نمونه از موتور سالم و ۱۲ نمونه از موتور معیوب با ناهم‌محوری استاتیکی ۵٪ تا ۲۰٪ و ناهم‌محوری دینامیکی ۵٪ استفاده شد. خروجی آموزش این شبکه SVM در شکل ۱۶-الف نمایش داده شده است. برای تست اولیه این شبکه از ۶۳ نمونه استفاده شده که شامل ۱۵ نمونه سالم و ۴۸ نمونه با عیب ME هستند که نتایج این تست در شکل ۱۶-ب نمایش داده شده است. همان‌طور که ملاحظه می‌شود صحت ارزیابی اولیه این شبکه ۱۰۰٪ است. سپس تعداد ۲۰ نمونه آزمایشگاهی مطابق شکل ۱۷-الف به شبکه SVM اعمال شد. با اعمال ضریب اصلاحی ۳۸/۴٪، مرکز ثقل پراکندگی شاخص‌های آزمایشگاهی سالم بر مرکز ثقل نمونه‌های شبیه‌سازی سالم منطبق شده و در فاصله مناسبی از مرز صفحه جداساز شبکه آموزش‌دیده SVM قرار می‌گیرد. بعد از اعمال ضریب تصحیح، تعداد ۵۰ نمونه آزمایشگاهی مورد مطالعه قرار گرفتند که تعداد ۲۰ نمونه سالم و ۳۰ نمونه معیوب با ناهم‌محوری‌های مختلف بودند. میزان ناهم‌محوری عملی مورد مطالعه عبارتند از: نمونه اول 20% DE - 30% SE، نمونه دوم 15% SE - 25% DE، نمونه سوم 40% DE، نمونه چهارم 20% DE و نمونه آخر 40% SE. شکل ۱۷-ب نتیجه ارزیابی شبکه SVM آموزش‌دیده را برای داده عملی سالم و معیوب با صحت قبولی ۹۸/۶٪ را نشان می‌دهد. بایستی توجه داشت که به دلیل وجود ناهم‌محوری ذاتی ناهم‌محوری‌های ساده در آزمایش‌های عملی شامل میزان اندکی ناهم‌محوری‌های ترکیبی خواهند بود.



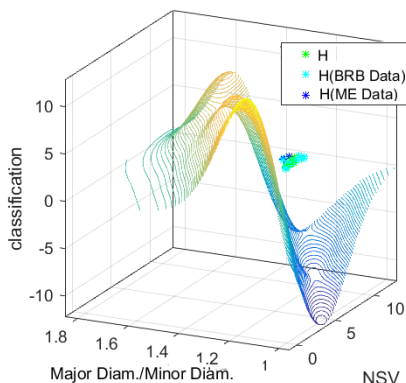
شکل ۱۶. آموزش شبکه SVM برای تشخیص خطای ME با داده شبیه‌سازی (الف) آموزش (ب) تست.



شکل ۱۷. تست نهایی SVM برای تشخیص خطای ME با داده عملی (الف) قبل اصلاح (ب) بعد اصلاح.

ارزیابی مدل‌های SVM با داده معایب دیگر

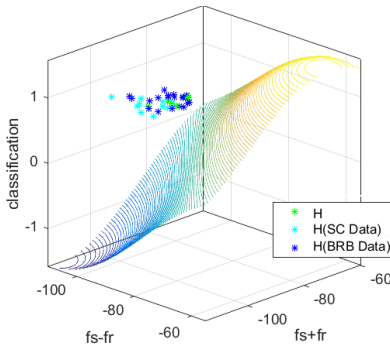
در این بخش مدل‌های SVM آموزش دیده برای تشخیص معایب اتصال حلقه استاتور، شکست میله روتور و ناهم‌محوری مرکب هر کدام به ترتیب با استفاده از داده‌های آزمایشگاهی حاصله به ازای دو عیب دیگر مورد ارزیابی قرار می‌گیرند تا احتمال تشخیص نادرست معایب بررسی شود. شکل ۱۸، نتیجه ارزیابی SVM آموزش دیده برای تشخیص عیب اتصال حلقه استاتور با نمونه‌های آزمایشگاهی مربوط به معایب شکست میله روتور (BRB Data) و ناهم‌محوری (ME Data) را نشان داده و صحت قبولی هر دو مجموعه داده ۱۰۰٪ است. همان‌گونه که ملاحظه می‌شود از دید این SVM، نمونه‌ها سالم هستند. بنابراین این احتمال که معایب ناهم‌محوری و یا شکست میله روتور به اشتباه عیب اتصال حلقه تشخیص داده شوند، وجود ندارد.




شکل ۱۸. مدل SVM تشخیص عیب SC به ازای داده‌های میله شکسته روتور و ناهم‌محوری مرکب.

شکل ۱۹، نتیجه ارزیابی SVM آموزش دیده برای تشخیص عیب شکست میله روتور با نمونه‌های آزمایشگاهی مربوط به معایب اتصال حلقه استاتور (SC Data) و ناهم‌محوری (ME Data) را نشان داده است. همان‌گونه که ملاحظه می‌شود از دید این SVM، نمونه‌ها سالم هستند و صحت قبولی هر دو مجموعه داده ۱۰۰٪ است. بنابراین این احتمال که معایب اتصال حلقه استاتور یا ناهم‌محوری به اشتباه عیب شکست میله روتور تشخیص داده شوند، وجود ندارد.

شکل ۲۰، نتیجه ارزیابی SVM آموزش دیده برای تشخیص عیب ناهم‌محوری با نمونه‌های آزمایشگاهی مربوط به معایب اتصال حلقه استاتور (SC Data) و شکست میله روتور (BRB Data) را نشان داده است. همان‌گونه که ملاحظه می‌شود از دید این SVM، نمونه‌ها سالم هستند و صحت قبولی هر دو مجموعه داده ۱۰۰٪ است. بنابراین این احتمال که معایب اتصال حلقه استاتور یا شکست میله روتور به اشتباه عیب ناهم‌محوری تشخیص داده شوند، وجود ندارد.



شکل ۲۰. مدل‌های SVM تشخیص عیب ME به ازای داده عیوب اتصال کوتاه و میله شکسته روتور.



شکل ۱۹. مدل‌های SVM تشخیص عیب BRB به ازای داده‌های عیوب اتصال کوتاه و ناهم‌محوری.

جمع‌بندی اطلاعات و ارزیابی مدل‌های SVM پیشنهادی برای موتور با مشخصات جدول ۱ جدول‌های ۲ تا ۴، بیانگر جمع‌بندی اطلاعات و دقت ارزیابی مدل SVM‌های ارائه شده در بخش‌های ۶ و ۷ می‌باشند که در ادامه ارائه شده‌اند.

جدول ۲. صحت و دقت ارزیابی مدل SVM تشخیص خطای اتصال کوتاه سیم‌پیچ استاتور.

روش	تعداد نمونه	C	Rbf sigma	دقت	
				مرحله آموزش	مرحله ارزیابی
FEA	۱۰۰	۱۰۰	۰.۷	۱۰۰	۱۰۰
آزمایشگاهی	۲۰	-	-	-	۱۰۰

جدول ۳. صحت و دقت ارزیابی مدل SVM تشخیص خطای شکست میله روتور.

روش	تعداد نمونه	C	Rbf sigma	دقت	
				مرحله آموزش	مرحله ارزیابی
FEA	۵۴	۱۰	۰.۷	۱۰۰	۱۰۰
آزمایشگاهی	۳۰	-	-	-	۱۰۰

جدول ۴. صحت و دقت ارزیابی مدل SVM تشخیص خطای ناهم‌محوری.

روش	تعداد نمونه	C	Rbf sigma	دقت		
				مرحله آموزش	مرحله ارزیابی	داده‌های SC
FEA	۸۷	۱۰	۲	۱۰۰	-	داده‌های BRB
آزمایشگاهی	۵۰	-	-	-	۹۸.۶	۱۰۰

نتیجه‌گیری

مقاله حاضر رویکردی کاربردی و کم‌هزینه برای تشخیص خطا در موتورهای الکتریکی با استفاده از روش FEA و آموزش شبکه SVM ارائه داده است. این مقاله، مشکل عدم دسترسی به مجموعه داده از موتور معیوب را برطرف کرده و تنها با تکیه بر اطلاعات موتور واقعی سالم، هزینه تهیه موتور و قطعات اضافی و معیوب‌سازی آنها را رفع نمود. در این مقاله، SVM تعلیم داده شده براساس FEA، توانایی لازم برای کار در محیط‌های آزمایشگاهی را کسب کرد. مجموعه داده براساس FEA با وجود دقت بالای شبیه‌سازی باز هم دارای اختلافات جزئی با موتور آزمایشگاهی بود. راهکار پیشنهادی این مقاله، ایجاد انطباق بین شاخص‌های ورودی SVMها بود که با استفاده از داده‌های موتور سالم شبیه‌سازی و آزمایشگاهی میسر شد. سه شبکه SVM جداگانه تحت مجموعه داده FEA برای تشخیص معایب اتصال حلقه استاتور، میله شکسته روتور و ناهم‌محوری آموزش داده شدند و صحت قبولی ۱۰۰٪ در مرحله ارزیابی کسب کردند. در ادامه، با لحاظ ضریب اصلاحی در شبکه‌های SVM، داده‌های آزمایشگاهی مورد مطالعه قرار گرفته و صحت قبولی آنها به ترتیب برای خطاهای مذکور ۱۰۰٪، ۱۰۰٪، و ۹۸.۶٪ شد. در نهایت، تاثیرگذاری خطاها بر همدیگر برای جلوگیری از تداخل تشخیص خطاها، در سه شبکه SVM به ازای سایر خطاها نیز مورد ارزیابی قرار گرفت و صحت قبولی ۱۰۰٪ حاصل شد. لذا این مقاله، قابلیت بالای روش پیشنهادی جهت تفکیک عیوب در موتورهای آزمایشگاهی هم‌نوع، گران‌قیمت، تعداد محدود و دایم‌کار را براساس شبیه‌سازی نشان داد.

References

- [1] Solodkiy, E., Dadenkov, D., & Salnikov, S. (2019 January 30- February 02). *Detection of stator inter-turn short circuit in three-phase induction motor using current coordinate transformation*. 2019 26th International Workshop on Electric Drives: Improvement in Efficiency of Electric Drives, Moscow, Russia. <https://doi.org/10.1109/TWED.2019.8664353>
- [2] Abad, H. B. B., Ojaghi, M., & Taheri, A. (2021). Efficient index for detecting the stator winding interturn fault in six-phase squirrel-cage induction motors. *Measurement*, 184, 109912. <https://doi.org/10.1016/j.measurement.2021.109912>
- [3] Ojaghi, M., Sabouri, M., & Faiz, J. (2018). Performance analysis of squirrel-cage induction motors under broken rotor bar and stator inter-turn fault conditions using analytical modeling. *Institute of Electrical and Electronics Engineers Transactions on Magnetics*, 54(11), 1-5. <https://doi.org/10.1109/TMAG.2018.2842240>.
- [4] Sridhar, S., Rao, K. U., Umesh, R., & Harish, K. (2016 November 22-25). *Condition monitoring of Induction Motor using statistical processing*. 2016 Institute of Electrical and Electronics Engineers Region 10 Conference (TENCON), Singapore, Asia. <https://doi.org/10.1109/TENCON.2016.7848597>
- [5] Seshadrinath, J., Singh, B., & Panigrahi, B. K. (2013). Incipient turn fault detection and condition monitoring of induction machine using analytical wavelet transform. *Institute*

- of Electrical and Electronics Engineers Transactions on Industry Applications*, 50(3), 2235-2242. <https://doi.org/10.1109/IAS.2012.6374026>
- [6] Das, S., Koley, C., Purkait, P., & Chakravorti, S. (2010, July 25-29). *Wavelet aided SVM classifier for stator inter-turn fault monitoring in induction motors*. Institute of Electrical and Electronics Engineers Power and Energy Society general meeting, Minneapolis, Minnesota, United States. <https://doi.org/10.1109/PES.2010.5589595>
- [7] Jagadanand, G., & Dias, F. L. (2015, February 19-21). *ARM based induction motor fault detection using wavelet and support vector machine*. 2015 Institute of Electrical and Electronics Engineers International Conference on Signal Processing, Informatics, Communication and Energy Systems, Kozhikode, India. <https://doi.org/10.1109/SPICES.2015.7091503>
- [8] Das, S., Purkait, P., Koley, C., & Chakravorti, S. (2014). Performance of a load-immune classifier for robust identification of minor faults in induction motor stator winding. *Institute of Electrical and Electronics Engineers Transactions on Dielectrics and Electrical Insulation*, 21(1), 33-44. <https://doi.org/10.1109/TDEI.2013.003549>
- [9] Mohamed, M., Mohamed, E., Mohamed, A-A., Abdel-Nasser, M., & Hassan, M. M. (2020). *Detection of inter turn short circuit faults in induction motor using artificial neural network*. 2020 26th Conference of Open Innovations Association (FRUCT), Yaroslavl, Russia. <https://doi.org/10.23919/FRUCT48808.2020.9087535>
- [10] Shih, K-J., Hsieh, M-F., Chen, B-J., & Huang, S-F. (2022). Machine Learning for Inter-Turn Short-Circuit Fault Diagnosis in Permanent Magnet Synchronous Motors. *Institute of Electrical and Electronics Engineers Transactions on Magnetics*, 58(8), 1-7. <https://doi.org/10.1109/TMAG.2022.3169173>
- [11] Vinayak, B. A., Uddin, R., & Jagadanaand, G. (2017, November 16-18). *Inter phase fault detection in inverter fed induction motor using wavelet transform*. 2017 3rd International Conference on Condition Assessment Techniques in Electrical Systems, Rupnagar, India. <https://doi.org/10.1109/CATCON.2017.8280193>
- [12] Husari, F., & Seshadrinath, J. (2021). Incipient Interturn fault detection and severity evaluation in electric drive system using hybrid HCN-SVM based model. *Institute of Electrical and Electronics Engineers Transactions on Industrial Informatics*, 18(3), 1823-1832. <https://doi.org/10.1109/TII.2021.3067321>
- [13] Ishkova, I., & Vitek, O. (2015, May 20-22). *Diagnosis of eccentricity and broken rotor bar related faults of induction motor by means of motor current signature analysis*. 2015 16th international scientific conference on electric power engineering, Kouty nad Desnou, Czech Republic. <https://doi.org/10.1109/EPE.2015.7161130>
- [14] Fireteanu, V., Constantin, A-I., Zorig, A., & Chouder, A. (2018, October 4-6). *Impact of the Stator Short-circuit, Rotor Broken Bar and Eccentricity Faults on Rotor Force for Loaded and No-load Induction Motors Operation*. 2018 International Conference on Applied and Theoretical Electricity, Craiova, Romania. <https://doi.org/10.1109/ICATE.2018.8551471>
- [15] Fireteanu, V., Constantin, A., & Popa, M. (2018, September 3-6). *Influence of single or multiple faults short-circuit, broken rotor bar and eccentricity on the torque and rotor force in induction motors*. 2018 XIII International Conference on Electrical Machines, Alexandroupoli, Greece. <https://doi.org/10.1109/ICELMACH.2018.8507008>
- [16] Seghiour, A., Seghier, T., & Zegnini, B. (2015, May 25-27). *Diagnostic of the simultaneous of dynamic eccentricity and broken rotor bars using the magnetic field spectrum of the air-gap for an induction machine*. 2015 3rd International Conference on Control,

- Engineering & Information Technology, Tlemcen, Algeria <https://doi.org/10.1109/CEIT.2015.7233158>
- [17] Antonino-Daviu, J., Quijano-López, A., Climente-Alarcon, V., & Razik, H. (2017, October 1-5). *Evaluation of the detectability of rotor faults and eccentricities in induction motors via transient analysis of the stray flux*. 2017 Institute of Electrical and Electronics Engineers Energy Conversion Congress and Exposition, Cincinnati, Ohio, United States. <https://doi.org/10.1109/ECCE.2017.8096633>
- [18] Luo, G., Habetler, T. G., & Hurwitz, J. (2019, September 29- October 03). *A multi-sensor fusion scheme for broken rotor bar and air-gap eccentricity detection of induction machines*. 2019 Institute of Electrical and Electronics Engineers Energy Conversion Congress and Exposition, Baltimore, Maryland, United States. <https://doi.org/10.1109/ECCE.2019.8912275>
- [19] Zgarni, S. E., & Braham, A. (2016, March 21-23). *Intelligent induction motor diagnosis system: A new challenge*. 2016 2nd International Conference on Advanced Technologies for Signal and Image Processing, Monastir, Tunisia. <https://doi.org/10.1109/ATSIP.2016.7523125>
- [20] Keskes, H., & Braham, A. (2015). Recursive undecimated wavelet packet transform and DAG SVM for induction motor diagnosis. *Institute of Electrical and Electronics Engineers Transactions on Industrial Informatics*, 11(5), 1059-1066. <https://doi.org/10.1109/TII.2015.2462315>
- [21] Pezzani, C. M., Fontana, J. M., Donolo, P. D., De Angelo, C. H., Bossio, G. R., & Silva, L. I. (2018, August 22-24). *Svm-based system for broken rotor bar detection in induction motors*. 2018 Institute of Electrical and Electronics Engineers ANDESCON, Santiago de Cali, Colombia. <https://doi.org/10.1109/ANDESCON.2018.8564627>
- [22] Vishwakarma, H. O., Sajan, K., Maheshwari, B., & Dhiman, Y. D. (2015, August 12-14). *Intelligent bearing fault monitoring system using support vector machine and wavelet packet decomposition for induction motors*. 2015 international conference on power and advanced control engineering, Bengaluru, India. <https://doi.org/10.1109/ICPA CE.2015.7274969>
- [23] Zarei, J., Arefi, M. M., & Hassani, H. (2015, May 27-29). *Bearing fault detection based on interval type-2 fuzzy logic systems for support vector machines*. 2015 6th International Conference on Modeling, Simulation, and Applied Optimization, Istanbul, Turkey. <https://doi.org/10.1109/ICMSAO.2015.7152214>
- [24] Choudhary, A., Goyal, D., & Letha, S. S. (2020). Infrared thermography-based fault diagnosis of induction motor bearings using machine learning. *Institute of Electrical and Electronics Engineers Sensors Journal*, 21(2), 1727-1734. <https://doi.org/10.1109/JSEN.2020.3015868>
- [25] Abid, F. B., Zgarni, S., & Braham, A. (2016, October 23-26). *Bearing fault detection of induction motor using SWPT and DAG support vector machines*. IECON 2016-42nd Annual Conference of the Institute of Electrical and Electronics Engineers Industrial Electronics Society, Florence, Italy. <https://doi.org/10.1109/IECON.2016.7793237>
- [26] Gunasekaran, S., Pandarakone, S. E., Asano, K., Mizuno, Y., & Nakamura, H. (2018, September 23-26). *Condition monitoring and diagnosis of outer raceway bearing fault using support vector machine*. 2018 Condition Monitoring and Diagnosis, Perth, Western Australia, Australia. <https://doi.org/10.1109/CMD.2018.8535744>
- [27] Abid, F. B., Zgarni, S., & Braham, A. (2018). Distinct bearing faults detection in induction motor by a hybrid optimized SWPT and aiNet-DAG SVM. *Institute of Electrical*

- and Electronics Engineers transactions on Energy Conversion*, 33(4), 1692-1699. <https://doi.org/10.1109/TEC.2018.2839083>
- [28] Pandarakone, S. E., Akahori, K., Matsumura, T., Mizuno, Y., & Nakamura, H. (2017, March 22-25). *Development of a methodology for bearing fault scrutiny and diagnosis using SVM*. 2017 Institute of Electrical and Electronics Engineers International Conference on Industrial Technology, Toronto, Ontario, Canada. <https://doi.org/10.1109/ICIT.2017.7913097>
- [29] Georgoulas, G., Climente-Alarcon, V., Antonino-Daviu, J. A., Stylios, C. D., Arkkio, A., & Nikolakopoulos, G. (2016, July 19-21). *A multi-label classification approach for the detection of broken bars and mixed eccentricity faults using the start-up transient*. 2016 Institute of Electrical and Electronics Engineers 14th International Conference on Industrial Informatics, Poitiers, France. <https://doi.org/10.1109/INDIN.2016.7819198>
- [30] Singh, H., Seera, M., & Abdullah, M. Z. (2013, August 4-9). *Detection and diagnosis of broken rotor bars and eccentricity faults in induction motors using the fuzzy min-max neural network*. The 2013 international joint conference on neural networks, Dallas, Texas, United States. <https://doi.org/10.1109/IJCNN.2013.6707003>
- [31] Silva, V. A., & Pederiva, R. (2013, October 29-30). *Fault detection in induction motors based on artificial intelligence*. Proceedings of the International Conference on Surveillance, Chartres, France. <https://www.semanticscholar.org/paper/Fault-detection-in-induction-motors-based-on-Silva-Pederiva/6d9793d397cf6d9f8359c6e7930ed083f25d0833>
- [32] Smart, E., Brown, D., & Axel-Berg, L. (2013, September 22-25). *Comparing one and two class classification methods for multiple fault detection on an induction motor*. 2013 Institute of Electrical and Electronics Engineers Symposium on Industrial Electronics & Applications, Kuching, Malaysia. <https://doi.org/10.1109/ISIEA.2013.6738982>
- [33] Valencia, J. B., Sanchez, M. P., Roman, J. M., Panadero, R. P., & Bano, A. S. (2014, November 18-20). *Study of performance of several techniques of fault diagnosis for induction motors in steady-state with svm learning algorithms*. 2014 2nd International Conference on Artificial Intelligence, Modelling and Simulation, Madrid, Spain. <https://doi.org/10.1109/AIMS.2014.47>
- [34] Kandukuri, S. T., Senanyaka, J. S. L., Huynh, V. K., & Robbersmyr, K. G. (2019). A two-stage fault detection and classification scheme for electrical pitch drives in offshore wind farms using support vector machine. *Institute of Electrical and Electronics Engineers Transactions on Industry Applications*, 55(5), 5109-5118. <https://doi.org/10.1109/TIA.2019.2924866>
- [35] Liang, X., Ali, M. Z., & Zhang, H. (2019). Induction motors fault diagnosis using finite element method: A review. *Institute of Electrical and Electronics Engineers Transactions on Industry Applications*, 56(2), 1205-1217. <https://doi.org/10.1109/TIA.2019.2958908>
- [36] Gyftakis, K. N., & Cardoso, A. M. (2017, April 20-21). *A new space vector approach to detect stator faults in induction motors*. 2017 Institute of Electrical and Electronics Engineers Workshop on Electrical Machines Design, Control and Diagnosis, Nottingham, United Kingdom. <https://doi.org/10.1109/WEMDCD.2017.7947752>
- [37] Halder, S., Bhat, S., & Dora, B. (2022). Prediction of broken rotor bar in induction motor using spectral entropy features and tlbo optimized svm. *Turkish Journal of Electrical Engineering and Computer Sciences*, 30(5), 1962-1979. <https://doi.org/10.55730/1300-0632.3916>

- [38] Mazouji, R., Khaloozadeh, H., & Arasteh, M. (2020, February 4-6). *Fault Diagnosis of Broken Rotor Bars in Induction Motors Using Finite Element Analysis*. 2020 11th Power Electronics, Drive Systems, and Technologies Conference, Tehran, Iran <https://doi.org/10.1109/PEDSTC49159.2020.9088429>
- [39] Polat, A., Yilmaz, A., & Ergene, L. T. (2018). Investigation of The Effects of Eccentricity on Induction Motor via Multi-Resolution Wavelet Analysis. *Electrica*, 18(2), 187-197. <https://doi.org/10.5152/ijjee.2018.1821>
- [40] Tian, K., Zhang, T., Ai, Y., & Zhang, W. (2018). Induction motors dynamic eccentricity fault diagnosis based on the combined use of WPD and EMD-simulation study. *Applied Sciences*, 8(10), 1709. <https://doi.org/10.3390/app8101709>
- [41] Fantin Irudaya Raj, E., & Appadurai, M. (2022). Static 2D-Finite Element Analysis of Eccentricity Fault in Induction Motor. In: M. L. Kolhe, S. B. Jaju, & P. M. Diagavane (Eds.) *Smart Technologies for Energy, Environment and Sustainable Development, Vol 1*. Springer. https://doi.org/10.1007/978-981-16-6875-3_33
- [42] Priya, B. H., Karthick, R., Lokprakash, B., Vasanth, S., & Praveen, N. K. (2020, April 9-10). *Static eccentricity fault analysis in inverter fed induction motor using finite element method*. Institute of Physics Conference Series: Materials Science and Engineering: Second International Conference on Materials Science and Manufacturing Technology, Hotel Aloft, Coimbatore, Tamil Nadu, India. <https://doi.org/10.1088/1757-899X/872/1/012049>
- [43] Kuczmann, M., Gadó, K., Horváth, S., Vajda, I., Marcsa, D., & Belahcen, A. (2018). Analysis of an Induction Machine by the Finite Element Method. *Recent Innovations in Mechatronics*, 5(1), 1-5. <https://doi.org/10.17667/riim.2018.1/5>
- [44] Ding, Z., Bu, W., Cai, X., Wu, X., & Liu, S. (2019, October 12-13). *Finite Element Analysis and Modeling of Three-Phase Induction Motor*. Institute of Physics Conference Series: Materials Science and Engineering, Melbourne, Australia. <http://dx.doi.org/10.1088/1757-899X/677/5/052055>
- [45] Pascual, D. G. (2015). *Artificial intelligence tools: decision support systems in condition monitoring and diagnosis*. Crc Press. <https://www.routledge.com/Artificial-Intelligence-Tools-Decision-Support-Systems-in-Condition-Monitoring/Pascual/p/book/9780367738358>
- [46] Martinez-Herrera, A. L., Ferrucho-Alvarez, E. R., Ledesma-Carrillo, L. M., Mata-Chavez, R. I., Lopez-Ramirez, M., & Cabal-Yepez, E. (2022). Multiple fault detection in induction motors through homogeneity and kurtosis computation. *Energies*, 15(4), 1541. <https://doi.org/10.3390/en15041541>
- [47] Garcia-Calva, T., Morinigo-Sotelo, D., Fernandez-Cavero, V., & Romero-Troncoso, R. (2022). Early Detection of Faults in Induction Motors—A Review. *Energies*, 15(21), 7855. <https://doi.org/10.3390/en15217855>