

# دسته‌بندی شدت عیب اتصال کوتاه بین دور موتورهای سنکرون مغناطیس دائم با استفاده از درخت تصمیم‌گیری و شبکه عصبی بیزین

عباس درویشی، سید محسن سید موسوی و بهزاد مشیری

چکیده: این مقاله به بررسی شناسایی شدت عیب اتصال کوتاه بین دور در یک موتور سنکرون مغناطیس دائم با توان ۳ کیلووات با استفاده از درخت تصمیم‌گیری و شبکه عصبی عمیق بیزین می‌پردازد. مجموعه داده اصلی شامل سیگنال‌های جریان سه‌فاز در شرایط سالم و دارای عیب بوده که شش سطح از شدت عیب را شامل می‌شود. یک مرحله پیش‌پردازش برای تحلیل داده‌ها در حوزه‌های زمان و فرکانس انجام می‌شود. در این فرآیند از تبدیل موجک گسسته و تحلیل چگالی طیفی توان استفاده شده است. برای کاهش ابعاد فضای آموزشی، ابتدا معیارهای آماری مانند میانگین، انحراف معیار، کشیدگی و چولگی به دست می‌آیند. سپس از تحلیل مولفه‌های اصلی کرنل برای تعیین برجسته‌ترین ویژگی‌ها استفاده می‌شود. الگوریتم درخت تصمیم‌گیری برای شناسایی وضعیت عیب موتور آموزش داده می‌شود. در نهایت، یک شبکه عصبی عمیق مبتنی بر تئوری بیزین برای تشخیص شدت عیب اتصال کوتاه بین دور به کار گرفته می‌شود. عملکرد الگوریتم پیشنهادی از نظر دقت، صحت، بازخوانی و امتیاز F1 با در نظر گرفتن تعداد متفاوتی از ویژگی‌های غالب منتخب ارزیابی می‌شود.

عملیاتی موتور ضروری است [۲]. عیوب اتصال کوتاه بین دور (ITSC) یکی از نگرانی‌های عمده در PMSMها است و متداول‌ترین عیب الکتریکی محسوب می‌شود. این عیوب زمانی رخ می‌دهد که عایق‌بندی بین دورهای مجاور در سیم‌پیچ استاتور دچار خرابی شود و موجب اتصال کوتاه گردد. عیوب ITSC می‌توانند منجر به آسیب مکانیکی به محور و انتهای سیم‌پیچ به دلیل جریان‌های گذرای ضربه‌ای شوند و همچنین ممکن است باعث مغناطیس‌زدایی غیرقابل برگشت آهنربای دائمی شوند [۳]. تأثیرات منفی این عیب شامل افزایش جریان، ایجاد گرمای موضعی، اغوجاج در میدان مغناطیسی و نوسانات گشتاور است. طراحی موتور با اندوکتانس بالا برای محدود کردن جریان اتصال کوتاه بسیار مهم است [۴]. تشخیص دقیق، عیب‌یابی و استراتژی‌های کاهش عیوب برای حفظ قابلیت اطمینان و طول عمر PMSMها ضروری است.

یک روش موثر برای ارزیابی ITSC در PMSMها شامل تحلیل ساختاری با استفاده از مدل دینامیکی سیستم است. مدل عیبی که ولتاژهای PWM را در برمی‌گیرد در [۵] معرفی شده است و نشان می‌دهد که هارمونیک‌های PWM می‌توانند بیش از ۵۰٪ از مولفه اصلی در جریان‌های عیب را تشکیل دهند. تأثیر EMF معکوس و ولتاژهای PWM بر جریان‌های عیب در محدوده‌های مختلف سرعت تجزیه و تحلیل شده است. در [۶]، مدلی غیرخطی که دینامیک ITSC را در خود جای می‌دهد، با استفاده از قانون فارادی و یک مدار مغناطیسی معادل ارائه شده است. شناسایی عیب به عنوان یک مسئله بهینه‌سازی فرموله شده و با استفاده از روش گرادینان کاهش‌یافته حل شده است. در [۷] بر روی شناسایی ITSC در مراحل اولیه در PMSMهای مورد استفاده در آسانسورها متمرکز شده است. از یک مشاهده‌گر ورودی ناشناخته غیرخطی همراه با تخمین کمترین مربعات برای بهبود حساسیت تشخیص عیب استفاده شده است. تخمین‌گر معکوس حلقه بازی در [۸] معرفی شده است که حساسیت بالایی در سرعت‌ها و بارهای هارمونیک مختلف دارد و از طریق آزمایش‌های و تحلیل المان محدود تایید شده است. تحلیل المان محدود (FEA) دقت بیشتری در مدل‌سازی عیوب ITSC دارد و شبیه‌سازی‌های دقیقی فراتر از مدل‌های مداری تجمعی فراهم می‌کند. رویکرد نوینی با استفاده از FEA در [۹] مبتنی بر شبیه‌سازی رفتارهای غیرخطی مغناطیسی و دینامیکی PMSM ارائه شده است. تحلیل FFT روی جریان‌های استاتور و گشتاور الکترومغناطیسی مولفه‌های عیب را شناسایی می‌کند. مدل مدار معادل مبتنی بر FEA برای تحلیل

کلیدواژه: اتصال کوتاه بین دور، موتور سنکرون مغناطیس دائم، استخراج ویژگی، انتخاب ویژگی، درخت تصمیم‌گیری، شبکه عصبی بیزین.

## ۱- مقدمه

موتورهای سنکرون مغناطیس دائم (PMSM) به دلیل راندمان بالا، دوام و قابلیت اطمینان خود در کاربردهای مختلف مورد استفاده قرار می‌گیرند. با این حال، عیب در سیستم‌های درایو آن‌ها، مانند مشکلات اینورترها، سیم‌پیچ‌های استاتور یا حسگرها، می‌تواند منجر به کاهش عملکرد و راندمان آنها شود. این عیوب ممکن است باعث مشکلاتی از جمله شکست عایق، نوسانات گشتاور، جریان بیش از حد و حتی در موارد شدید، خرابی کامل سیستم شوند [۱]. نقش حیاتی PMSMها، به‌ویژه در کاربردهای حساس به ایمنی مانند وسایل نقلیه الکتریکی، اهمیت تشخیص زودهنگام عیوب را برجسته می‌کند. شناسایی به‌موقع عیوب برای اطمینان از ایمنی مسافران، حفظ قابلیت اطمینان سیستم، بهینه‌سازی عملکرد و اجرای اقدامات پیشگیرانه برای افزایش طول عمر

این مقاله در تاریخ ۲۹ شهریور ماه ۱۴۰۳ دریافت و در تاریخ ۲۷ بهمن ماه ۱۴۰۳ بازنگری شد.

عباس درویشی، دانشکده مهندسی برق، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران، (email: abbas.darvishi2018@gmail.com).

سید محسن سید موسوی (نویسنده مسئول)، دانشکده مهندسی برق، واحد اهواز، دانشگاه آزاد اسلامی، اهواز، ایران، (email: m.moosavi@srbiau.ac.ir).

بهزاد مشیری، دانشکده مهندسی برق و کامپیوتر، دانشگاه تهران، تهران، ایران، (email: moshiri@ut.ac.ir).

2. Inter-Turn Short Circuit

3. Finite Element Analysis

1. Permanent Magnet Synchronous Machine

یادگیری عمیق برای استخراج خودکار ویژگی‌ها از سیگنال‌های جریان استاتور استفاده می‌کند. روش تشخیص عیب با استفاده از CNN باقی‌مانده چندمقیاسی و شبکه حافظه کوتاه‌مدت دووجهی در [۲۳] معرفی شده است که دقت و پایداری بالایی را نشان داده است. در [۲۴]، رویکردی جامع برای تشخیص ITSC در PMSM‌ها ارائه شده است. این روش از اینورتر و اسیلوسکوپ برای جمع‌آوری داده‌های جریان سه‌فاز استاتور استفاده می‌کند و الگوریتم یادگیری عمیق بهینه‌سازی شده از طریق بهینه‌سازی بیزین به‌طور خودکار ویژگی‌ها را استخراج می‌کند و عملکرد بهتری نسبت به روش‌هایی مانند LSTM<sup>۸</sup> و انواع CNN دارد. در [۲۵]، روشی برای تشخیص عیب PMSM با استفاده از CNN باقی‌مانده چندمقیاسی و LSTM پیشنهاد شده است. این معماری ویژگی‌ها را در مقیاس‌های مختلف و وابستگی‌های زمانی ثبت می‌کند. بهینه‌سازی بیزین باعث بهبود عملکرد شده و دقت و پایداری بالایی در شبیه‌سازی‌ها نشان داده است.

یکی از مسائل حیاتی در تشخیص عیب، طبقه‌بندی دقیق شدت عیب است. تشخیص دقیق شدت عیوب در PMSM‌ها برای جلوگیری از خرابی‌های فاجعه‌بار و به حداقل رساندن زمان توقف بسیار مهم است. با ارزیابی دقیق میزان عیب، اپراتورها می‌توانند اقدامات تعمیر و نگهداری مناسبی مانند برنامه‌ریزی برای تعمیرات تعویض قطعات را قبل از وارد شدن آسیب غیرقابل‌جبران به موتور انجام دهند. تشخیص زود هنگام شدت عیب همچنین امکان بهینه‌سازی برنامه‌های نگهداری را فراهم می‌کند. علاوه بر این، درک شدت عیوب می‌تواند بینش‌های ارزشمندی در مورد علل اساسی تخریب فراهم کند و اقدامات پیشگیرانه‌ای برای کاهش عیوب آینده را ممکن سازد [۲۶]. روشی برای تخمین تعداد دوره‌های اتصال کوتاه‌شده با استفاده از تحریک ولتاژ AC کم در [۲۷] پیشنهاد شده است. روشی مؤثر برای نظارت بر شدت عیب با استفاده از یک ناظر تناسبی-انتگرالی در [۲۸] ارائه شده است. استراتژی کنترلی با نام حداکثر گشتاور به ازای جریان چرخشی در [۲۹] معرفی شده است. این روش گشتاور خروجی را حفظ می‌کند در حالی که جریان چرخشی را در محدوده‌های ایمن نگه می‌دارد. روشی برای تخمین تعداد دوره‌های اتصال کوتاه‌شده با استفاده از تحریک ولتاژ سینوسی کم در [۳۰] ارائه شده است که ساده‌سازی توصیف عیب و بهبود استراتژی‌های کاهش عیب ITSC را به همراه دارد.

علیرغم پیشرفت‌های قابل توجه در تشخیص و عیب‌یابی ITSC در PMSM‌ها، روش‌های فعلی با چالش‌های متعددی مواجه هستند. روش‌های سنتی، از جمله تکنیک‌های مبتنی بر مدل و الگوریتم‌های یادگیری عمیق به دلیل محدودیت‌های ذاتی آن‌ها، اغلب با دشواری در طبقه‌بندی دقیق شدت عیب مواجه هستند. روش‌های مبتنی بر مدل، با وجود دقت بالا، می‌توانند محاسبات فشرده‌ای داشته باشند و ممکن است به‌طور کامل دینامیک پیچیده عیوب تحت شرایط مختلف عملیاتی را به تصویر نکشند. روش‌های یادگیری عمیق، اگرچه در دقت تشخیص عیب امیدوارکننده هستند، اغلب به حجم بالایی از داده‌های آموزشی نیاز دارند و ممکن است در شرایطی با داده‌های محدود یا نویزی کمتر مؤثر باشند. این روش‌ها خروجی‌های قطعی ارائه می‌دهند و قادر به اندازه‌گیری عدم قطعیت مربوط به شدت عیب نیستند. شبکه‌های عصبی بیزین راه‌حلی مناسب برای این چالش‌ها با ادغام برآورد عدم قطعیت در فرآیند طبقه‌بندی عیب ارائه می‌دهند. برخلاف شبکه‌های عصبی عمیق

جریان‌های اتصال کوتاه در [۱۰] معرفی شده است. با استفاده از FEA دو بعدی برای استخراج ماتریس‌های اندوکتانس و EMF معکوس، عیوب با قطع دوره‌های خاص و منابع جریان مستقل شبیه‌سازی شده‌اند.

برخلاف روش‌های مبتنی بر مدل، الگوریتم‌های یادگیری عمیق که به داده‌های اندازه‌گیری متکی هستند، به طور فزاینده‌ای برای تشخیص ITSC در PMSM‌ها استفاده شده‌اند. در [۱۱]، تشخیص عیب با استفاده از شبکه مولد تخاصمی شرطی<sup>۱</sup> (CGAN) و یک خودرمزگذار کم‌فشرده بهینه‌شده پیشنهاد شده است. در [۱۲]، چارچوب شبکه عمیق Q بهبودیافته‌ای برای افزایش استخراج ویژگی و دستیابی به دقت بالا در تشخیص عیب معرفی شده است. در [۱۳]، شبکه عصبی کانولوشنی<sup>۲</sup> (CNN) ارائه شده که اثربخشی خود را در شرایط مختلف عملیاتی نشان داده است. در [۱۴]، شبکه SCNN<sup>۳</sup> برای تشخیص عیوب ITSC معرفی شده که از تکنیک‌های پردازش داده برای افزایش دقت تشخیص استفاده می‌کند. در [۱۵]، معماری شبکه عصبی باقیمانده چندمقیاسی کانولوشنی پیشنهاد شده است که در تشخیص زود هنگام ITSC، به دقت ۹۷٪ دست‌یافته است. در [۱۶]، مدلی ریاضی برای PMSM‌ها تحت شرایط ITSC توسعه یافته و از ماشین بردار پشتیبان<sup>۴</sup> (SVM) و CNN برای انتخاب ویژگی و مقایسه دقت تشخیص استفاده شده است. در [۱۷]، الگوریتم تشخیصی با استفاده از معماری CNN گسترده چندمقیاسی مبتنی بر کرنل پیشنهاد شده است. در [۱۸]، از SCNN مبتنی بر استراتژی آموزش سلسله‌مراتبی و پیش‌طبقه‌بندی آستانه نرم برای افزایش حساسیت و پایداری ویژگی‌ها در تشخیص ITSC بهره گرفته شده است.

شبکه‌های عصبی بیزین<sup>۵</sup> (BNN) در کاربردهای تشخیص عیب نسبت به شبکه‌های عصبی عمیق<sup>۶</sup> (DNN) سنتی مزایای قابل‌توجهی دارند، زیرا توانایی آن‌ها در کمی‌سازی عدم قطعیت بیشتر است. برخلاف DNN‌ها که خروجی‌های قطعی ارائه می‌دهند، BNN‌ها توزیع احتمالی پیش‌بینی‌ها را تولید می‌کنند و امکان برآورد دقیق‌تر عدم قطعیت در سناریوهای تشخیص عیب را فراهم می‌کنند. این ویژگی بسیار مهم است، زیرا به سیستم اجازه می‌دهد تفاوت بین ناهنجاری‌های واقعی و نوسانات عادی را تشخیص دهد و در نتیجه دقت و پایداری تشخیص عیب را افزایش دهد. علاوه بر این، BNN‌ها می‌توانند به‌طور مؤثری با محدودیت داده‌ها که چالشی رایج در تشخیص عیب است، مقابله کنند و برآوردهای دقیق‌تری به دلیل تنظیمات ذاتی خود ارائه دهند [۱۹]. الگوریتم CNN باقی‌مانده بهینه‌سازی شده با بهینه‌سازی بیزین<sup>۷</sup> (BO) برای تخمین ITSC در [۲۰] معرفی شده است که فرآیندهای CNN و BO را برای بهینه‌سازی معماری شبکه و پارامترهای آموزشی ادغام می‌کند. روش انتخاب پارامتر تطبیقی بهینه‌سازی شده بیزین برای تجزیه حالت مدولاسیون در [۲۱] معرفی شده است. با استفاده از بهینه‌سازی بیزین، این روش دقت تشخیص عیب و مقاومت در برابر نویز را افزایش می‌دهد. روشی ترکیبی که از تنظیمات تجربی و تکنیک‌های پیشرفته الگوریتمی استفاده می‌کند در [۲۲] ارائه شده است که از الگوریتم‌های مبتنی بر

1. Conditional Generative Adversarial Networks
2. Convolution Neural Network
3. Siamese CNN
4. Support Vector Machine
5. Bayesian Neural Network
6. Deep Neural Network
7. Bayesian Optimization

## ۲- الگوریتم تشخیص و کلاسه‌بندی شدت عیب پیشنهادی

تشخیص شدت عیب، به ویژه شناسایی عیب‌های با شدت پایین، همچنان یک مسئله چالش‌برانگیز در حوزه تشخیص عیب است. این مقاله یک رویکرد مبتنی بر احتمال و داده‌محور برای تشخیص شدت عیب‌های ITSC در PMSM پیشنهاد می‌کند. این رویکرد در شکل ۱ تشریح شده است که اجزای اصلی و روابط بین آن‌ها را در روش پیشنهادی نشان می‌دهد. این فرآیند با پیش‌پردازش مجموعه داده‌های خام آغاز می‌شود که شامل سیگنال‌های جریان استاتور سه‌فاز است که تحت شرایط عملیاتی مختلف ثبت شده‌اند. در این مرحله، تکنیک‌های حوزه فرکانس مانند DWT و تحلیل PSD بر روی سیگنال‌های حوزه زمان اعمال می‌شوند. این تکنیک‌ها با ثبت رفتارهای گذرا و نوسانی که در حوزه زمان آشکار نیستند، بینش‌های بهتری درباره شدت عیب ITSC ارائه می‌دهند. پس از مرحله پیش‌پردازش، یک بلوک استخراج ویژگی، داده‌های حوزه زمان و فرکانس را پردازش کرده و مجموعه‌ای از معیارهای آماری را که فضای ویژگی را تشکیل می‌دهند، ارائه می‌دهد. این معیارهای آماری شامل پارامترهایی مانند میانگین، واریانس، چولگی و کشیدگی هستند. این مرحله برای کاهش ابعاد و بهینه‌سازی فضای ورودی مدل پیش‌بینی ضروری است.

برای بهبود بیشتر فضای ویژگی و حذف ویژگی‌های نامربوط یا تکراری، از الگوریتم KPCA به عنوان یک روش انتخاب ویژگی غیرخطی استفاده می‌شود. KPCA نه تنها ابعاد را کاهش می‌دهد بلکه روابط غیرخطی میان ویژگی‌ها را نیز به خوبی ثبت می‌کند و در نتیجه باعث بهبود دقت و پایداری طبقه‌بندی می‌شود. برای تشخیص عیب‌های ITSC در PMSM، الگوریتم درخت تصمیم‌گیری آموزش داده شده و بر روی داده‌های ویژگی اعمال می‌شود. در نهایت، مجموعه ویژگی‌های کاهش‌یافته برای آموزش و آزمایش شبکه عصبی بیزین مورد استفاده قرار می‌گیرد. BNN به عنوان مدل پیش‌بینی عمل می‌کند و با استفاده از ویژگی‌های استخراج‌شده، خروجی‌های احتمالی مربوط به سطوح مختلف شدت عیب ITSC را فراهم می‌کند. چارچوب احتمالاتی BNN به سیستم تشخیص عیب اجازه می‌دهد تا عدم قطعیت در پیش‌بینی شدت عیب‌ها را کمی‌سازی کند و بدین ترتیب قابلیت اطمینان سیستم را افزایش دهد.

رویکرد پیشنهادی به صورت قطع-خط، درخت تصمیم‌گیری و شبکه عصبی بیزین را آموزش می‌دهد. بعد از تعیین مدل‌های پیش‌بینی در مراحل تشخیص عیب و کلاسه‌بندی شدت عیب، ارزیابی عملکرد الگوریتم پیشنهادی می‌تواند به صورت برخط انجام شود.

روش پیشنهادی این پژوهش، به دلیل استفاده از تحلیل جامع سیگنال‌های جریان سه‌فاز و فرآیندهای پیش‌پردازش انعطاف‌پذیر، به گونه‌ای طراحی شده است که قابلیت تعمیم به سایر عیوب داخلی سیم‌پیچی استاتور را دارد. در این روش، تبدیل موجک گسسته و تحلیل چگالی طیفی توان به عنوان ابزارهای اصلی برای استخراج ویژگی‌های حوزه‌های زمان و فرکانس استفاده می‌شوند. این ویژگی‌ها می‌توانند نه تنها اثرات عیب اتصال کوتاه بین دوره‌ها، بلکه تغییرات ناشی از دیگر عیوب داخلی سیم‌پیچی، مانند اتصالات ناقص، شکست عایق، یا تغییرات ناگهانی مقاومت سیم‌پیچی را نیز آشکار کنند.

علاوه بر این، معیارهای آماری و تحلیل مولفه‌های اصلی کرنل به منظور کاهش ابعاد و شناسایی ویژگی‌های غالب به کار گرفته می‌شوند. این فرآیندها مستقل از نوع عیب بوده و می‌توانند برای انواع مختلف

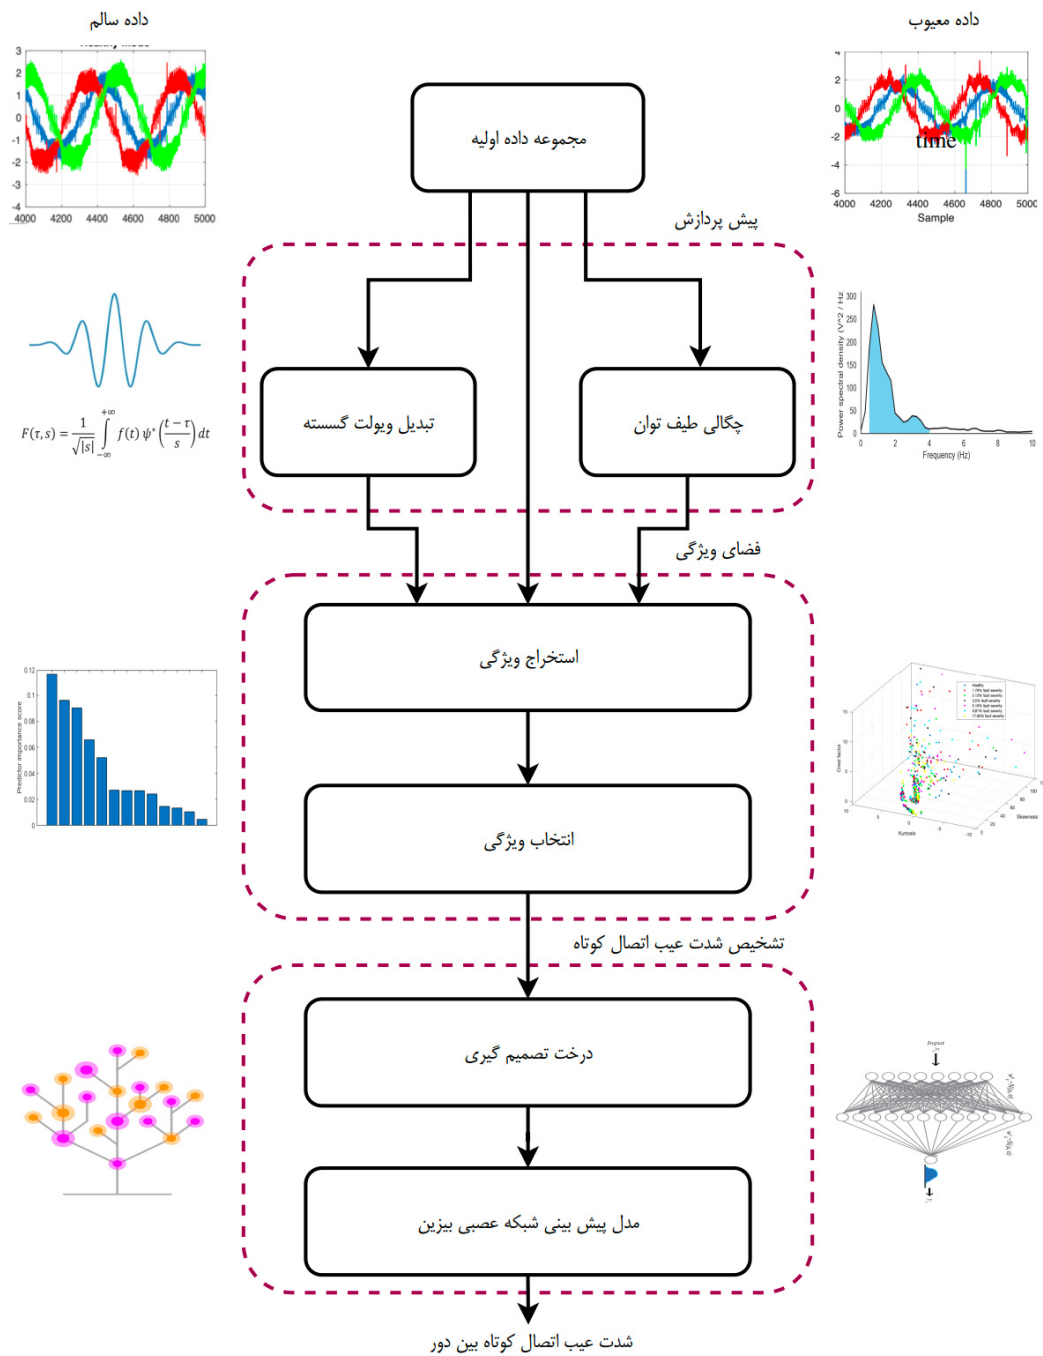
سنس، BNNها توزیع احتمالی را بر پیش‌بینی‌های خود تولید می‌کنند که امکان درک دقیق‌تری از شدت عیب را فراهم می‌کند. با ادغام BNNها در طبقه‌بندی شدت عیب، می‌توان به ارزیابی‌های عیب دقیق‌تر و قابل‌اعتمادتری دست یافت که تصمیم‌گیری‌های نگهداری بهتری را تسهیل کرده و قابلیت اطمینان کلی سیستم را بهبود می‌بخشد.

این مقاله با ارائه یک روش جدید به منظور ترکیب استخراج و انتخاب ویژگی با یادگیری عمیق بیزین برای تشخیص دقیق و مقاوم شدت عیوب ITSC در PMSMها به چالش‌های موجود پاسخ می‌دهد. به طور خاص، روش پیشنهادی یک مرحله پیش‌پردازش مناسب را معرفی می‌کند که در آن تبدیل موجک گسسته (DWT) و PSD<sup>۲</sup> به داده‌های حوزه زمان اعمال می‌شوند و کیفیت ویژگی‌های ورودی را بهبود می‌بخشند. یک فرآیند جامع استخراج ویژگی برای ثبت معیارهای آماری حیاتی که نشان‌دهنده شرایط عیب هستند، به کار گرفته شده است، در حالی که از روش انتخاب ویژگی KPCA<sup>۳</sup> برای اولویت‌بندی ویژگی‌هایی که بر شدت شدت عیب تأثیر می‌گذارند، استفاده می‌شود. درخت تصمیم‌گیری (DT)<sup>۴</sup> برای تشخیص عیوب ITSC استفاده می‌شود و یک شبکه عصبی بیزین برای طبقه‌بندی شدت عیب ITSC آموزش داده می‌شود. ادغام شبکه عصبی بیزین باعث افزایش قابلیت اطمینان سیستم می‌شود، زیرا نه تنها شدت عیب را طبقه‌بندی می‌کند بلکه سطح اطمینان پیش‌بینی‌های خود را نیز ارائه می‌دهد و بدین ترتیب عدم قطعیت را برطرف کرده و فرآیند تصمیم‌گیری در تشخیص عیب را بهبود می‌بخشد. نوآوری‌های کلیدی این مقاله به شرح زیر است:

- مرحله پیش‌پردازش که در آن PSD و DWT داده‌های حوزه زمان محاسبه می‌شوند.
- استخراج ویژگی از داده‌های PMSM که شامل اندازه‌گیری‌های آماری برای ثبت پارامترهای کلیدی که نشان‌دهنده شرایط عیب هستند، می‌باشد.
- استفاده از روش انتخاب ویژگی KPCA برای شناسایی و اولویت‌بندی ویژگی‌های مهمی که بر شدت عیب تأثیر می‌گذارند.
- کلاسه‌بندی بین داده‌های سالم و معیوب با استفاده از الگوریتم درخت تصمیم‌گیری.
- توسعه شبکه عصبی بیزین برای طبقه‌بندی شدت عیب در PMSM. این روش از استنتاج بیزین برای تخمین عدم قطعیت در پیش‌بینی‌ها بهره می‌برد و نه تنها طبقه‌بندی‌ها بلکه سطح اطمینان نتایج را نیز ارائه می‌دهد.

ساختار این مقاله به شرح زیر است: بخش دوم، روش پیشنهادی برای طبقه‌بندی شدت عیب ITSC در PMSM را ارائه می‌دهد. بخش سوم شامل پیش‌پردازش داده‌ها و توضیح ریاضیاتی DWT و PSD<sup>۵</sup> است. بخش‌های چهارم و پنجم به ترتیب مراحل استخراج و انتخاب ویژگی را توضیح می‌دهند. تشخیص عیب با استفاده از الگوریتم DT در بخش ششم ارائه شده است. بخش هفتم معماری شبکه عصبی بیزین به همراه نتایج شبیه‌سازی برای طبقه‌بندی شدت عیب را شامل می‌شود. در نهایت، بخش هشتم نتیجه‌گیری مقاله را بیان می‌کند.

1. Discrete Wavelet Transform
2. Power Spectral Density
3. Kernel Principal Component Analysis
4. Decision Tree
5. Power Spectral Density



شکل ۱: بلوک دیاگرام الگوریتم تشخیص و کلاسه‌بندی عیب پیشنهادی.

تعیین‌داده‌های نهایی جهت آموزش درخت تصمیم‌گیری و شبکه بیزین، رهیافتی مؤثر برای دستیابی به بهترین عملکرد الگوریتم پیشنهادی است. رویکرد ارائه‌شده در این مقاله قابل تعمیم برای دسته وسیعی از عیوب الکتریکی و مکانیکی است و ماهیت استخراج بهینه و مؤثر پایگاه داده برای بهینه‌سازی نهایی مدل‌های پیش‌بینی در مراحل تشخیص و کلاسه‌بندی شدت عیب، توانایی الگوریتم پیشنهادی در عیب‌یابی موتورهای الکتریکی با دقت عملکرد بالا را به طور قابل توجهی افزایش می‌دهد.

این روش علاوه بر دقت بالا در کلاسه‌بندی، توانایی قابل توجهی در مدیریت داده‌های با ابعاد بالا و عدم قطعیت‌های موجود در سیستم دارد. ترکیب پیش‌پردازش چندمرحله‌ای، شامل تبدیل حوزه زمان به فرکانس (PSD) و تحلیل چندرزولوشنی (DWT)، امکان شناسایی بهتر الگوهای پنهان در داده‌ها را فراهم می‌کند. همچنین، مدل ترکیبی به دلیل ساختار

الگوهای خرابی در سیگنال‌ها تطبیق داده شوند. بنابراین، با تنظیم مدل‌های یادگیری ماشین، مانند درخت تصمیم‌گیری و شبکه عصبی بیزین، و آموزش آن‌ها با داده‌های مناسب مربوط به سایر عیوب، این روش قادر است به طور مؤثر عیوب مختلف داخلی سیم‌پیچی استاتور را شناسایی کند. تطبیق‌پذیری روش پیشنهادی به انعطاف در طراحی مراحل استخراج ویژگی و مدل‌سازی وابسته است که آن را برای کاربردهای گسترده‌تر در تحلیل عیب ماشین‌های الکتریکی مناسب می‌سازد.

مهم‌ترین نوآوری روش پیشنهادی در این مقاله، استفاده ترکیبی از درخت تصمیم‌گیری و شبکه عصبی بیزین برای کلاسه‌بندی شدت عیب اتصال کوتاه بین دور در یک موتور مغناطیس دائم به تحلیل نوین نتایج پیش‌بینی برای مدل شبکه بیزین بر اساس توزیع احتمالات گوسی است. علاوه بر این، استفاده از سه مرحله پیش‌پردازش شامل استفاده از PSD و DWT، همراه با استخراج و انتخاب ویژگی‌های برجسته برای

در تجزیه و تحلیل سیگنال‌ها از موجک Daubechies با سطح ۱ استفاده شده است. این انتخاب به دلیل ویژگی‌های خاص این موجک است که قادر است به خوبی ویژگی‌های محلی سیگنال را حفظ کند، به‌ویژه در نواحی با تغییرات سریع و نوسانات کوتاه‌مدت. موجک Daubechies به‌طور خاص برای کاربردهای سیگنال‌های واقعی و به‌ویژه در تحلیل‌های زمانی-فرکانسی با ویژگی‌های محلی بسیار مناسب است. استفاده از سطح ۱ از این موجک به این دلیل انتخاب شده که این سطح برای تجزیه‌های اولیه و استخراج ویژگی‌های پایه‌ای سیگنال کافی است و پیچیدگی محاسباتی آن پایین است، که این امر برای برخی از کاربردهای آن‌لاین اهمیت زیادی دارد.

باید اشاره شود که در این تحلیل، فرآیند تجزیه سیگنال و استخراج ویژگی‌ها به‌صورت قطع خط صورت می‌گیرد. به این معنا که برای پردازش سیگنال‌ها به داده‌های جمع‌آوری شده از قبل نیاز داریم و این کار به‌طور بلادرنگ انجام نمی‌شود. اما با توجه به ویژگی‌های ابزار و فرآیندهای انتخابی، می‌توان از آن برای تحلیل‌های بلادرنگ نیز استفاده کرد، زیرا با انتخاب موجک مناسب و سطح تجزیه بهینه، کارایی بالایی برای تحلیل‌های بلادرنگ حاصل می‌شود.

در این مقاله از روش ولج<sup>۱</sup> برای تخمین PSD سیگنال استفاده شده است. این روش با تقسیم سیگنال به قطعات همپوشان، اعمال یک تابع پنجره به هر قطعه برای به حداقل رساندن نشت طیفی، و سپس محاسبه تبدیل فوریه گسسته<sup>۲</sup> (DFT) برای هر قطعه پنجره‌ای کار می‌کند. پریودوگرام‌های حاصل، مجذور و در تمام قطعات میانگین‌گیری می‌شوند تا یک تخمین نهایی از PSD به دست آید که واریانس را کاهش داده و تحلیل شفاف‌تری از محتوای فرکانسی سیگنال ارائه می‌دهد.

سیگنال  $x(n)$  با طول  $N$  ابتدا به  $k$  قطعه با هر قطعه‌ای با طول  $L$  و همپوشانی  $D$  نمونه بین نمونه‌های متوالی، تقسیم می‌شود. هر قطعه  $x_k(n)$  در یک تابع پنجره‌ای  $w(n)$  ضرب می‌شود. تبدیل فوریه گسسته هر قطعه پنجره‌ای به صورت رابطه (۳) محاسبه می‌شود [۳۴]

$$x_k(m) = \sum_{n=0}^{L-1} x_k'(n) e^{-j \frac{2\pi}{L} mn} \quad (3)$$

پریودوگرام قطعه  $k$  امبرابر است با

$$P_k(m) = \frac{1}{L} |x_k(m)|^2 \quad (4)$$

در نهایت، چگالی طیفی توان<sup>۳</sup> (PSD) تخمینی با میانگین‌گیری پریودوگرام‌های تمام قطعات به‌صورت ۵ محاسبه می‌شود

$$\hat{P}(m) = \frac{1}{K} \sum_{k=0}^{K-1} P_k(m) \quad (5)$$

در این مقاله، از یک مجموعه داده عملی که در [۳۵] ارائه شده است، برای توسعه روش پیشنهادی استفاده شده است. مجموعه داده مورد استفاده برای تشخیص عیوب موتورهای PMSM شامل داده‌های ارتعاش و جریان است که به صورت همزمان جمع‌آوری شده‌اند. برای ثبت داده‌های ارتعاش از یک شتاب‌سنج سرامیکی ICP مدل PCB ۳۵۲C۳۴ استفاده شده که بر اساس استاندارد ISO ۱۰۸۱۶-۱:۱۹۹۵ روی یاتاقان موتور نصب شده است. همچنین، داده‌های جریان توسط سه سنسور CT

انعطاف‌پذیر خود، قابلیت بهینه‌سازی برای انواع مختلفی از کاربردها در حوزه تشخیص و پایش وضعیت را داراست. این ویژگی‌ها نشان‌دهنده پتانسیل بالای این روش برای کاربرد در سیستم‌های صنعتی پیچیده است.

### ۳- پیش‌پردازش داده

تکنیک‌های پیش‌پردازش داده مانند DWT و PSD برای تشخیص عیب، به‌ویژه در شناسایی ITSC در PMSM ضروری هستند. این روش‌ها با فیلتر کردن مؤثر نویز و استخراج ویژگی‌های مهم از داده‌های خام، دقت و قابلیت اطمینان سیستم‌های تشخیص عیب را بهبود می‌بخشند. DWT به دلیل توانایی در تجزیه سیگنال به مؤلفه‌های فرکانسی مختلف، به‌طور خاص مفید است زیرا تسهیل‌کننده شناسایی ناهنجاری‌ها می‌باشد [۳۱]. از سوی دیگر، PSD برای تجزیه و تحلیل توزیع توان در فرکانس‌های مختلف ارزشمند است که برای شناسایی تغییرات جزئی مرتبط با عیوب ITSC حیاتی است [۳۲]. با یکپارچه‌سازی این تکنیک‌های پیش‌پردازش، عملکرد سیستم‌های تعمیر و نگهداری پیش‌بینی‌شده به‌طور قابل‌توجهی بهبود می‌یابد که منجر به تشخیص به‌موقع و دقیق عیوب می‌شود.

تبدیل موجک گسسته یک ابزار همه‌کاره برای پردازش سیگنال است که سیگنال را به مؤلفه‌های فرکانسی آن تجزیه می‌کند و در عین حال زمان رخ دادن این فرکانس‌ها را نیز حفظ می‌کند. برخلاف تبدیل فوریه که فقط محتوای فرکانس را در یک لحظه نشان می‌دهد، DWT دیدگاه دوگانه‌ای ارائه می‌دهد که هم اطلاعات زمانی و هم مکانی فرکانس‌های خاص را در سیگنال مشخص می‌کند. DWT از موجک‌ها که توابع نوسانی کوتاه و محلی در زمان هستند، برای تحلیل سیگنال استفاده می‌کند. این موجک‌ها در فواصل گسسته نمونه‌برداری می‌شوند و DWT را قادر می‌سازد تا سیگنال را به چندین سطح از جزئیات تجزیه کند. این تکنیک شامل فیلتر کردن سیگنال از طریق مجموعه‌ای از فیلترهای بالاگذر و پایین‌گذر است که سیگنال را به باندهای فرکانسی مختلف تقسیم می‌کند. نتیجه آن مجموعه‌ای از ضرایب است که سیگنال را در مقیاس‌ها و وضوح‌های مختلف توصیف می‌کنند.

با توجه به سیگنال ورودی  $s$  با طول  $N$  دو مجموعه ضریب به نام‌های ضرایب تقریب  $CA$  و ضرایب جزئیات  $CD$  محاسبه می‌شوند. این تجزیه از طریق دو فرآیند موازی انجام می‌شود. ابتدا سیگنال  $s$  با یک فیلتر پایین‌گذر LoD همبسته می‌شود. سیگنال فیلترشده سپس با ضریب ۲ پایین‌نمونه‌برداری شده و  $CA$  به دست می‌آید. سپس، سیگنال  $s$  با یک فیلتر بالاگذر HiD همبسته می‌شود. سیگنال فیلترشده سپس با ضریب ۲ پایین‌نمونه‌برداری شده و  $CD$  به دست می‌آید. DWT از یک تابع موجک مادر که در (۱) ارائه شده است، استفاده می‌کند که با مقیاس و انتقال آن، یک خانواده از موجک‌ها ایجاد می‌شود [۳۳]

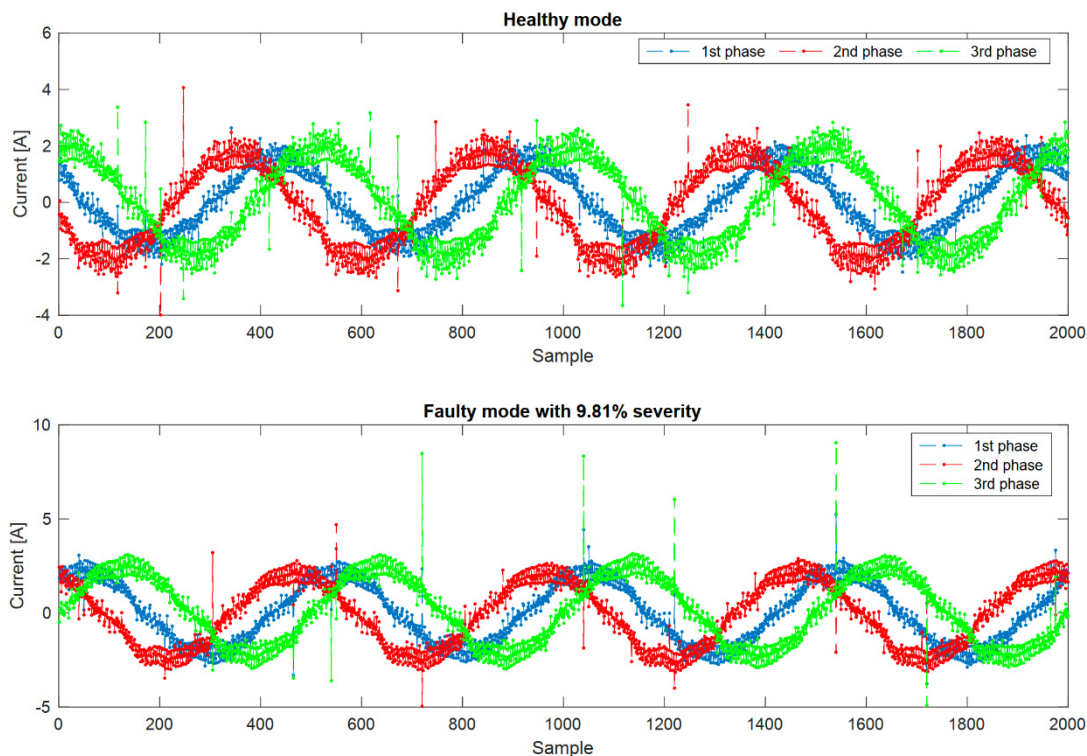
$$\psi_{a,b}(t) = \frac{1}{\sqrt{a}} \psi\left(\frac{t-a}{b}\right) \quad (1)$$

که در آن،  $a$  پارامتر مقیاس‌دهی و  $b$  پارامتر جابجایی است. به‌علاوه، تابع موجک، یک تابع مقیاس‌دهی  $\varphi(t)$  برای تقریب سیگنال در مقیاس‌های مختلف استفاده می‌شود. به‌طور ریاضی، ضرایب تقریب  $CA_{j,k}$  و ضرایب جزئیات  $CD_{j,k}$  به‌صورت (۲) محاسبه می‌شوند

$$CA_{j,k} = \int f(t) \varphi_{j,k}(t) dt, \quad (2)$$

$$CD_{j,k} = \int f(t) \psi_{j,k}(t) dt$$

1. Welch
2. Discrete Fourier Transform
3. Power Spectral Density



شکل ۲: سیگنال‌های جریان سه فاز برای داده‌های سالم و معیوب با شدت عیب ۹٫۸۱٪.

سیم‌پیچ‌های یک فاز درگیر اتصال کوتاه هستند. باید اشاره کرد که تعداد سطوح عیب بر اساس طراحی آزمایش و شرایط عملیاتی موتور در آزمایشگاه صورت گرفته است. این تعداد برای ارائه تعادلی مناسب بین تفکیک دقیق‌تر شدت‌های مختلف و ساده‌سازی تحلیل انتخاب شده است. به عنوان مثال، انتخاب تعداد سطوح بیشتر می‌تواند اطلاعات دقیق‌تری درباره شدت عیب ارائه دهد، اما تحلیل داده‌ها را پیچیده‌تر می‌کند. انتخاب تعداد سطوح کمتر ممکن است باعث شود جزئیات برخی شدت‌های عیب نادیده گرفته شوند.

شکل ۲ سیگنال‌های جریان سه‌فاز را برای شرایط سالم و دارای عیب با شدت ۹٫۸۱٪ نمایش می‌دهد. همچنین، ضرایب تقریب و جزئیات تبدیل موجک گسسته (DWT)، به همراه تراکم طیف توان (PSD) جریان‌های سه‌فاز برای شرایط سالم و دارای عیب با شدت ۹٫۸۱٪ در شکل ۳ ارائه شده است. سیگنال‌های حوزه زمان و فرکانس هر دو برای ارائه فضای ویژگی استفاده شده‌اند. این مجموعه داده که مطابق با استاندارد ISO ۱۰۱۶-۱:۱۹۹۵ جمع‌آوری شده است، ابزار مناسبی برای تحلیل رفتار موتورهای PMSM تحت شرایط مختلف و ارزیابی روش‌های تشخیص خطاهای استاتور با استفاده از تکنیک‌های یادگیری عمیق و تحلیل داده‌های ارتعاش و جریان فراهم می‌کند.

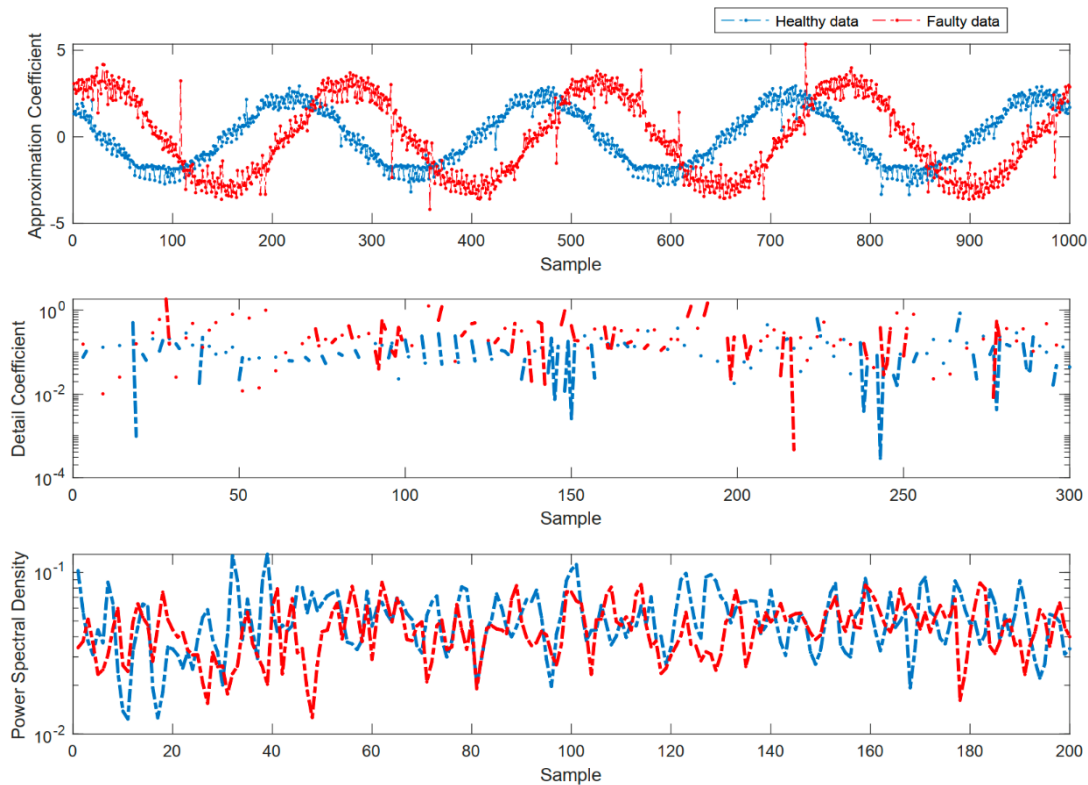
با وجود اینکه مجموعه داده ارائه شده در مرجع [۳۵] شامل داده‌های جریان سه‌فاز استاتور و سیگنال‌های ارتعاش است، در این پژوهش تصمیم گرفته شد تنها از داده‌های جریان برای تشخیص و طبقه‌بندی شدت عیب استفاده شود. این تصمیم به دو دلیل اصلی اتخاذ شد. نخست، عیب اتصال کوتاه یکی از انواع عیوب الکتریکی است که می‌توان آن را به‌طور مؤثر با تحلیل سیگنال‌های الکتریکی شناسایی کرد. دوم، سنسورهای ارتعاش معمولاً گران‌قیمت هستند و به‌طور پیش‌فرض بر روی همه موتورهای نصب نمی‌شوند. در نتیجه، وابستگی الگوریتم پیشنهادی به سیگنال‌های ارتعاش می‌تواند قابلیت تعمیم‌پذیری آن را در کاربردهای مختلف موتورهای الکتریکی محدود کند.

مدل Hioki C T۶۷۰۰ که روی فازهای U، V و W موتور قرار داده شده‌اند، جمع‌آوری شده است. داده‌های ارتعاش از طریق ماژول NI ۹۲۳۴ و داده‌های جریان از طریق ماژول NI ۹۷۷۵ ثبت شده‌اند. این مجموعه داده شامل اطلاعات جمع‌آوری شده از سه موتور با توان‌های مختلف ۱/۰ کیلووات، ۱/۵ کیلووات و ۳/۰ کیلووات است. تمامی آزمایش‌ها تحت شرایط یکسان شامل سرعت چرخش ثابت ۳۰۰۰ دور در دقیقه و بار گشتاور معادل ۱۵ درصد از حد مجاز بار موتور (۱/۵ نیوتن‌متر) انجام شده‌اند. داده‌های ارتعاش با نرخ نمونه‌برداری ۲۵/۶ کیلوهرتز و داده‌های جریان با نرخ نمونه‌برداری ۱۰۰ کیلوهرتز برای مدت زمان ۱۲۰ ثانیه ثبت شده‌اند. داده‌های ارتعاش که توسط شتاب‌سنج اندازه‌گیری شده‌اند، در محور Z موتور جمع‌آوری شده و تغییرات ناشی از عدم تعادل گشتاور به دلیل خطاهای استاتور را نشان می‌دهند. داده‌های جریان نیز تغییرات قدرت محرکه موتور را در شرایط خطا منعکس می‌کنند.

تمامی موتورهای مورد استفاده در این پژوهش از لحاظ ویژگی‌هایی نظیر سه‌فاز بودن، چهار قطب، تولیدکننده یکسان و شرایط بارگذاری و سرعت یکسان مشابه هستند. استفاده از یک ساختار آزمایشی کنترل شده شامل یک ترمز هیستریزیس (AHB-۱۰A) با قابلیت اعمال گشتاور تا ۱۰ نیوتن‌متر، اتصال‌های انعطاف‌پذیر و راهنمای خطی، اطمینان از صحت داده‌های جمع‌آوری شده را افزایش داده است. این مجموعه داده شامل شرایط سالم و معیوب موتور است. عیب اتصال کوتاه بین دورها با سطوح مختلف شدت عیب به موتور PMSM اعمال شده است. داده‌های عیب شامل شش سطح از شدت عیب هستند: ۱/۷۸٪، ۲/۱۳٪، ۲/۶۵٪، ۳/۵٪، ۹/۸۱٪ و ۱۷/۶۸٪.

شدت عیب در زمینه تحلیل اتصال کوتاه دور به دور در موتورهای سنکرون مغناطیس دائم به میزان و گستردگی اختلال یا آسیب وارد شده به سیم‌پیچ موتور اشاره دارد. این شدت به‌صورت کمی و با پارامترهایی مانند درصد سیم‌پیچی که دچار اتصال کوتاه شده است، بیان می‌شود. برای مثال، شدت عیب ۹٫۸۱٪ بدین معنی است که ۹٫۸۱٪ از





شکل ۳: DWT<sup>۳</sup> و PSD سیگنال‌های جریان سه فاز برای داده‌های سالم و معیوب با شدت عیب ۹/۸۱٪.

$$\left\{ \begin{array}{l} \mu_x = \frac{1}{n} \sum_{i=1}^n x_i \\ \sigma_x = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - \mu)^2} \end{array} \right\}, \left\{ \begin{array}{l} s_x = \frac{\sum_{i=1}^n (x_i - \mu)^3}{\sigma_x^3} \\ k_x = \frac{\sum_{i=1}^n (x_i - \mu)^4}{\sigma_x^4} \end{array} \right\}, \left\{ \begin{array}{l} cr_x = \frac{\max(x_i)}{\sqrt{\frac{1}{n} \sum_{i=1}^n |x_i|^2}} \\ cl_x = \frac{\max(x_i)}{\left[ \sum_{i=1}^n |x_i| \right]^2} \end{array} \right\} \quad (6)$$

میانگین، کشیدگی<sup>۱</sup>  $k_x$  به‌عنوان معیاری برای سنجش اوج‌پیک توزیع، چولگی<sup>۲</sup>  $s_x$  به‌عنوان معیاری برای سنجش عدم تقارن توزیع، فاکتور اوج<sup>۳</sup>  $cr_x$  به‌عنوان نسبت اوج به میانگین سیگنال، و فاکتور پاک‌سازی<sup>۴</sup>  $cl_x$  به‌عنوان معیاری برای هم‌راستایی اجزای موتور انتخاب شده‌اند.

برای  $x \in R^n$ ، این معیارها در (۶) آورده شده‌اند.

برای ایجاد فضای ویژگی، ابتدا سیگنال‌های جریان سالم و معیوب به بسته‌های کوچکی با اندازه ۱۰۰۰ نمونه تقسیم می‌شوند. سپس DWT و PSD هر بخش استخراج می‌شود. در نهایت، ویژگی‌های آماری با اعمال معادلات (۶) بر روی داده‌های تقسیم‌شده به‌دست می‌آیند. در مجموع ۲۴ ویژگی با ۷۰۰ نمونه متناظر با هر ویژگی محاسبه می‌شود.

شکل ۴ توزیع ویژگی‌ها را برای داده‌های سالم و معیوب با سطوح مختلف شدت عیب نشان می‌دهد. برای تسهیل مرحله آموزش مدل‌های پیش‌بینی در هر دو بخش تشخیص عیب و طبقه‌بندی شدت عیب اتصال کوتاه بین دور، الگوریتم KPCA به‌کار گرفته می‌شود تا مهم‌ترین ویژگی‌ها انتخاب شوند.

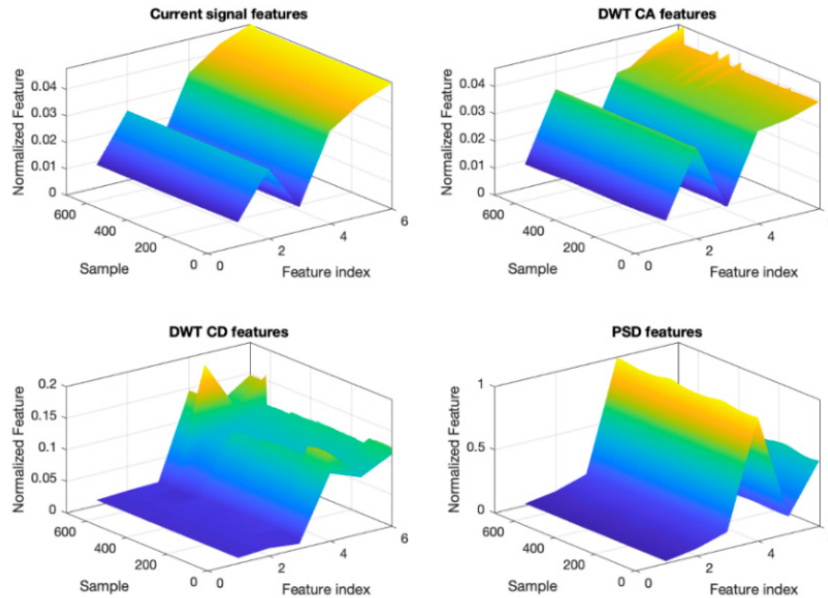
هرچند داده‌های آزمایشگاهی در این تحقیق تنها از یک نمونه موتور معیوب به‌دست آمده‌اند، اما ویژگی‌های فیزیکی و دینامیکی که در تحلیل این نوع عیب استفاده می‌شوند، معمولاً میان انواع مختلفی از موتورهای سنکرون مغناطیس دائم مشترک هستند. روش پیشنهادی با استفاده از استخراج ویژگی‌های عمومی مانند فرکانس‌های مشخصه عیب یا الگوهای دینامیکی جریان و ولتاژ و تکنیک‌های پیش‌پردازش پیشرفته، قادر است این ویژگی‌های مشترک را شناسایی کرده و به تعمیم‌پذیری روش کمک کند.

#### ۴- استخراج ویژگی با استفاده از معیارهای آماری

استخراج ویژگی‌ها برای تشخیص و شناسایی عیوب ITSC در PMSMها بسیار حائز اهمیت است. تکنیک‌های قوی استخراج ویژگی امکان شناسایی دقیق ویژگی‌های عیب از داده‌های عملیاتی موتور را فراهم می‌آورند. این توانایی برای بهبود قابلیت اطمینان و کارایی PMSMها بسیار مهم است.

در این مقاله، میانگین  $\mu_x$  به‌عنوان مقدار متوسط سیگنال در طول زمان، انحراف معیار  $\sigma_x$  به‌عنوان پراکندگی سیگنال از نظر واریانس حول

1. Kurtosis
2. Skewness
3. Crest factor
4. Clearance factor



شکل ۴: توزیع ویژگی‌ها برای داده‌های سالم و معیوب با شدت عیب مختلف.

که در آن پارامترهای ناشناخته هستند. تابع کرنل (۱۱) را در نظر بگیرید

$$\kappa(x_i, x_j) = \Psi(x_i) \Psi^T(x_j) \quad (11)$$

این امکان را به ما می‌دهد که مسئله را در قالب ماتریس کرنل  $\mathbf{K}$  باز فرمول‌بندی کنیم، که منجر می‌شود به

$$\mathbf{K}^2 \mathbf{a}_k = \lambda_k n \mathbf{K} \mathbf{a}_k \quad (12)$$

که در آن  $K_{ij} = \kappa(x_i, x_j)$ ،  $\mathbf{a}_k = [a_{k1} \ a_{k2} \ \dots \ a_{kn}]^T$  مجموعه ویژگی  $F = \{f_1, f_2, \dots, f_m\}$  و بردار تصادفی فضایی  $w$  تابع کرنل گوسی (۱۳) برای اندازه‌گیری شباهت بین نقاط داده استفاده می‌شود:

$$\kappa(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|_F^2}{\sigma}\right) \quad (13)$$

برای انتخاب مناسب‌ترین ویژگی‌ها، (۱۳) را به صورت زیر بازنویسی می‌کنیم

$$\kappa(x_i, x_j) = \exp\left(-\frac{(\mathbf{w}^T x_i - \mathbf{w}^T x_j)^2}{\sigma}\right) \quad (14)$$

برای هر ویژگی در هر تکرار، یک بردار تصادفی پراکنده  $\mathbf{w}_b$  تولید می‌شود و به  $\mathbf{w}_b^*$  تبدیل می‌شود. به عبارت دیگر

$$\mathbf{w}_b^* = \begin{cases} 0 & \text{if } w_b[f] \neq 0 \\ 1 & \text{else} \end{cases} \quad (15)$$

با استفاده از تابع کرنل،  $\mathbf{w}_b$  و  $\mathbf{w}_b^*$  برای تعیین  $\hat{\mathbf{X}}_b^f$  و  $\hat{\mathbf{X}}_b$  به عنوان تخمین‌هایی از  $\mathbf{X}$  استفاده می‌شود. در نهایت، برای هر ویژگی  $f$ ، اندازه‌گیری اهمیت  $h_f$  به صورت (۱۶) محاسبه می‌شود

$$h_f = \sum_{i=1}^{n_b} \frac{\|\hat{\mathbf{X}}_b - \hat{\mathbf{X}}_b^f\|}{n_b} \quad (16)$$

## ۵- انتخاب ویژگی با استفاده از KPCA

تحلیل مؤلفه‌های اصلی کرنل (KPCA) یک تکنیک پیشرفته برای انتخاب ویژگی است که به‌ویژه در مواجهه با داده‌هایی که روابط غیرخطی دارند مفید است. برخلاف تحلیل مؤلفه‌های اصلی سنتی، که از تبدیلات خطی استفاده می‌کند، KPCA از روش‌های کرنل برای نگاشت داده‌ها به فضایی با ابعاد بالاتر استفاده می‌کند که در آن جداسازی خطی امکان‌پذیر است. این تبدیل به ابعاد بالاتر به KPCA اجازه می‌دهد الگوهای پیچیده در داده‌ها را آشکار کند و آن را برای هر دو استخراج ویژگی و کاهش ابعاد مؤثرتر می‌سازد. با تمرکز بر ویژگی‌هایی که با بزرگ‌ترین مقادیر ویژه در این فضای تبدیل‌شده مرتبط هستند، KPCA شناسایی مهم‌ترین ویژگی‌ها را بهبود می‌بخشد و عملکرد مدل‌های یادگیری ماشین را ارتقا می‌دهد. فرض کنید  $x_i, i = 1, 2, \dots, n$  نقاط داده ورودی باشند. این نقاط با استفاده از یک تابع  $\Psi(x_i)$  به یک فضای جدید نگاشت می‌شوند. فرض بر این است که ویژگی‌های نگاشت‌شده دارای میانگین صفر هستند [۳۶]. به عبارت دیگر

$$\frac{1}{n} \sum_{i=1}^n \Psi(x_i) = 0 \quad (7)$$

ماتریس کوواریانس  $\mathbf{C} \in \mathbb{R}^{m \times m}$  از ویژگی‌های نگاشت‌شده به صورت (۸) تعریف می‌شود

$$\mathbf{C} = \frac{1}{n} \sum_{i=1}^n \Psi(x_i) \Psi^T(x_i) \quad (8)$$


با در نظر گرفتن  $\mathbf{v}_k$  به‌عنوان بردار ویژه و  $\lambda_k$  به‌عنوان مقدار ویژه ماتریس  $\mathbf{C}$ ، (۹) را خواهیم داشت

$$\frac{1}{n} \sum_{i=1}^n \Psi(x_i) \Psi^T(x_i) \mathbf{v}_k = \lambda_k \mathbf{v}_k \quad (9)$$

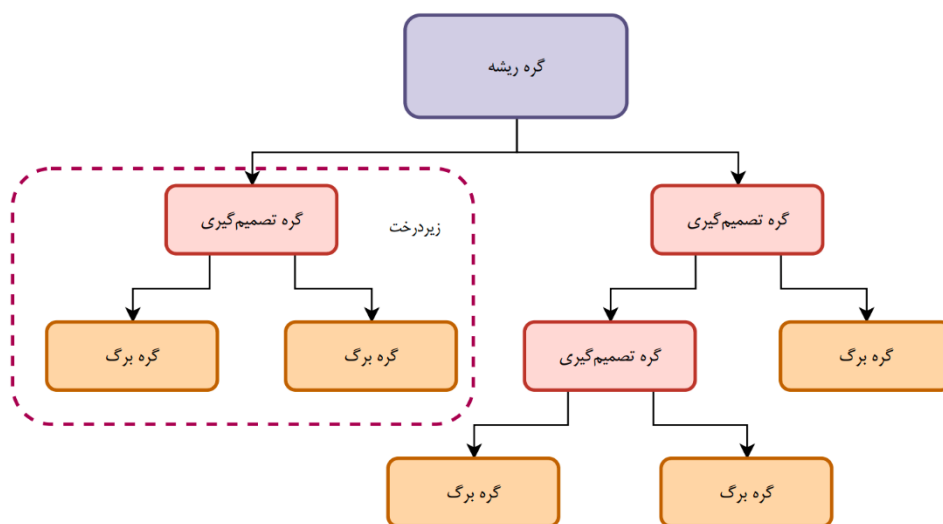
بردارهای ویژه به صورت (۱۰) بیان می‌شوند

$$\mathbf{v}_k = \sum_{i=1}^n a_{ki} \Psi(x_i) \quad (10)$$





شکل ۵: ویژگی‌های رتبه‌بندی شده با استفاده از الگوریتم KPCA.



شکل ۶: شکل بلوکی الگوریتم درخت تصمیم‌گیری.

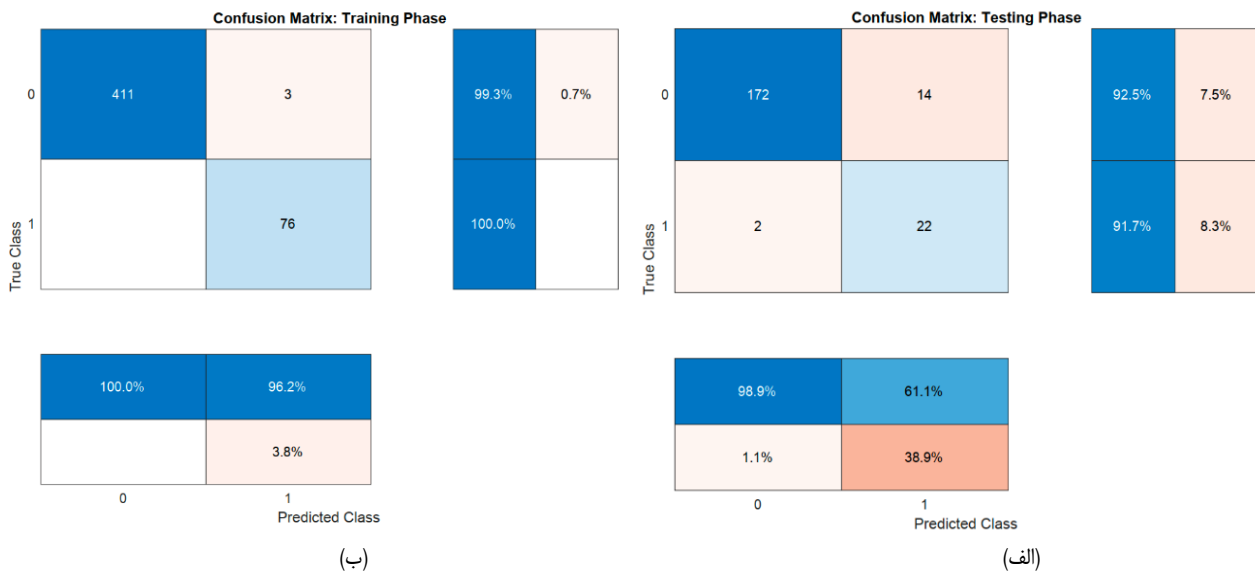
در تشخیص عیب، درخت‌های تصمیم‌گیری به‌ویژه مفید هستند زیرا می‌توانند داده‌های عددی و دسته‌بندی شده را مدیریت کنند و مدل واضح و قابل تفسیر را ارائه دهند. شیوه استفاده از درخت‌های تصمیم‌گیری در تشخیص عیب شامل سه مرحله اصلی است. ابتدا، ویژگی‌های مرتبط که می‌توانند بین وضعیت‌های مختلف عیب تمایز قائل شوند، انتخاب می‌شود. سپس، این ویژگی‌ها برای آموزش مدل درخت تصمیم‌گیری استفاده می‌شوند تا مدل الگوهای مربوط به هر نوع عیب را یاد بگیرد. در نهایت، مدل آموزش دیده با استفاده از یک مجموعه داده جداگانه اعتبارسنجی می‌شود تا اطمینان حاصل شود که طبقه‌بندی داده‌های جدید و دیده‌نشده به درستی انجام می‌شود، که برای جلوگیری از پیش‌برازش و اطمینان از استحکام مدل حیاتی است.

شکل ۶ ساختار اصلی الگوریتم درخت تصمیم‌گیری را نشان می‌دهد. گره‌ها و شاخه‌ها هر درخت را تشکیل می‌دهند. هر گره نمایانگر یک ویژگی درون دسته‌ای است که باید طبقه‌بندی شود و هر زیرمجموعه مقداری را که گره می‌تواند بپذیرد، تعریف می‌کند. با توجه به بردارهای آموزشی  $x_i \in R^l, i=1,2,\dots,l$  و بردار برچسب  $y \in R^l$ ، یک درخت تصمیم‌گیری به‌طور بازگشتی فضای ویژگی را تقسیم می‌کند و نمونه‌های

شکل ۵ ویژگی‌های رتبه‌بندی شده با استفاده از الگوریتم KPCA را نشان می‌دهد. طبق این شکل، فاکتور پاک‌سازی ضریب‌های تقریب و میانگین سیگنال‌های جریان، مهمترین ویژگی‌ها هستند. ویژگی‌هایی از جمله کشیدگی ضریب‌های تقریب، فاکتور پاک‌سازی جریان‌ها، چولگی داده‌های PSD، فاکتور اوج و کشیدگی سیگنال‌های جریان رتبه‌های نسبتاً مشابهی دارند که به این معنی است که یکی از آن‌ها می‌تواند به‌عنوان ویژگی بعدی برای مجموعه داده‌های آموزشی انتخاب شود. مهم‌ترین ویژگی‌ها برای آموزش الگوریتم درخت تصمیم‌گیری به‌منظور طبقه‌بندی داده‌های سالم و معیوب استفاده می‌شوند.

## ۶- تشخیص عیب به کمک الگوریتم درخت تصمیم‌گیری

درخت‌های تصمیم‌گیری ابزار قدرتمندی در تشخیص عیب هستند که به‌دلیل سادگی و کارایی بالا در صنایع مختلف به‌طور گسترده‌ای استفاده می‌شوند. این روش الگوریتم یادگیری نظارت شده است که برای وظایف طبقه‌بندی و رگرسیون استفاده می‌شود و با تقسیم داده‌ها به زیرمجموعه‌ها بر اساس مقادیر ویژگی‌های ورودی، مدل درخت‌مانند از تصمیمات ایجاد می‌کند.



شکل ۷: دقت تشخیص عیب درخت تصمیم‌گیری در فازهای (الف) آموزش و (ب) آزمون بر اساس نتایج ماتریس سردرگمی.

جدول ۱: دقت درخت تصمیم‌گیری بر اساس نتایج ماتریس در هم ریختگی

مرحله	سالم صحیح (TN)	سالم اشتباه (FN)	معیوب صحیح (TP)	معیوب اشتباه (FP)	دقت
آموزش	۴۱۱	۰	۷۶	۳	٪۹۹٫۳
آزمون	۱۷۲	۲	۲۲	۱۴	٪۹۴٫۱

به دو بخش آموزش (۷۰٪) و آزمون (۳۰٪) تقسیم شدند تا عملکرد مدل ارزیابی شود.

انتخاب ویژگی با استفاده از KPCA انجام شده است. این ویژگی‌های رتبه‌بندی شده سپس به درخت تصمیم‌گیری وارد شدند. در مرحله آموزش، درخت تصمیم‌گیری عملکرد بسیار خوبی را نشان داده است و دقت کلی ۹۹٫۳٪ را به دست آورده است. مطابق ماتریس سردرگمیدر شکل ۷، از ۴۸۷ نمونه موجود در مجموعه آموزش، ۴۱۱ نمونه به درستی به عنوان سالم شناسایی شدند، در حالی که تنها ۳ نمونه به اشتباه به عنوان معیوب طبقه‌بندی شدند.

به طور مشابه، تمامی ۷۶ نمونه معیوب به درستی شناسایی شدند و در نتیجه یادآوری کامل برای کلاس معیوب حاصل شد. در مرحله آزمون، درخت تصمیم‌گیری همچنان عملکرد قابل قبولی دارد و دقت ۹۴٫۱٪ را به دست آورده است. در این حالت، از ۱۷۲ از ۱۸۸ نمونه سالم به درستی طبقه‌بندی شدند، در حالی که ۱۴ نمونه به اشتباه به عنوان معیوب برچسب‌گذاری شدند. مدل به درستی ۲۲ از ۲۴ نمونه معیوب را شناسایی کرد، هرچند ۲ نمونه به اشتباه به عنوان سالم طبقه‌بندی شدند. کاهش جزئی در دقت نسبت به مرحله آموزش نشان می‌دهد که در حالی که مدل به خوبی تعمیم‌یابد، تمایل‌های اندکی به پیش‌بینی بیش از حد عیوب دارد، که احتمالاً به دلیل معرفی تغییرات نادیده در داده‌های آزمون است. جدول ۱ خلاصه‌ای از نتایج ماتریس سردرگمی برای هر دو مرحله آموزش و آزمون را ارائه می‌دهد.

برای ارزیابی کامل عملکرد مدل درخت تصمیم‌گیری در هر دو فاز آموزش و آزمون، از چندین معیار کلیدی مانند دقت، صحت، یادآوری و اختصاصیت، و امتیاز F1 استفاده می‌شود. فرض کنید TP، TN، FP و FN به ترتیب معرف نمونه‌های سالمی که به درستی به عنوان سالم شناسایی شده‌اند، نمونه‌های معیوبی که به درستی به عنوان معیوب طبقه‌بندی شده‌اند، نمونه‌های سالمی که به اشتباه به عنوان

با برچسب‌های مشابه را در کنار هم گروه‌بندی می‌کند. داده‌های موجود در یک گره  $m$ ، که با  $Q_m$  نشان داده می‌شود و شامل  $n_m$  نمونه است، برای هر تقسیم بالقوه  $\theta = (j, t_m)$  که شامل یک ویژگی  $j$  و آستانه  $t_m$  است، به دو زیرمجموعه  $Q_m^{\text{left}}(\theta)$  و  $Q_m^{\text{right}}(\theta)$  تقسیم می‌شود [۳۷]. به عبارت دیگر

$$Q_m^{\text{left}}(\theta) = \{(x, y) | x_j \leq t_m\} \quad (۱۷)$$

$$Q_m^{\text{right}}(\theta) = Q_m \setminus Q_m^{\text{left}}(\theta) \quad (۱۸)$$

موثر بودن یک تقسیم‌بندی کاندید در گره  $m$  با استفاده از یک تابع ناپاک  $H(\cdot)$  ارزیابی می‌شود

$$H(Q_m) = \sum_k p_{mk} (1 - p_{mk}) \quad (۱۹)$$

که در آن  $p_{mk}$  نسبت مشاهدات کلاس  $k$  در گره  $m$  است و به صورت (۲۰) تعریف می‌شود

$$p_{mk} = \frac{1}{n_m} \sum_{y \in Q_m} I(x = y) \quad (۲۰)$$


که در آن  $n_m$  تعداد نمونه‌ها در گره  $m$  است. پارامترهای بهینه درخت تصمیم‌گیری با کمینه‌کردن معیار (۲۱) تعیین می‌شوند

$$\theta^* = \arg \min_{\theta} G(Q_m, \theta) \quad (۲۱)$$

که در آن تابع  $G$  به صورت (۲۲) تعریف شده است

$$G(Q_m, \theta) = \frac{n_m^{\text{left}}}{n_m} H(Q_m^{\text{left}}(\theta)) + \frac{n_m^{\text{right}}}{n_m} H(Q_m^{\text{right}}(\theta)) \quad (۲۲)$$

این فرآیند به صورت بازگشتی به زیرمجموعه‌های  $Q_m^{\text{left}}(\theta)$  و  $Q_m^{\text{right}}(\theta)$  اعمال می‌شود تا زمانی که به حداکثر عمق درخت برسد، یا زمانی که کمتر از حداقل اندازه نمونه‌ها شود یا برابر با ۱ گردد. داده‌ها



شکل ۸: عملکرد درخت تصمیم‌گیری در طبقه‌بندی داده‌ها با استفاده از تعداد مختلف ویژگی‌های رتبه‌بندی‌شده و محاسبه معیارهای مربوطه.

جدول ۲: خلاصه‌ای از معیارهای کلیدی برای ارزیابی مدل درخت تصمیم‌گیری در مراحل آموزش و آزمون.

مرحله	دقت	صحت	بازیابی	تشخیص	نمره F1
آموزش	٪۹۹٫۴	٪۹۶٫۲	٪۱۰۰	٪۹۹٫۳	٪۹۸٫۱
آزمون	٪۹۲٫۴	٪۶۱٫۱	٪۹۱٫۷	٪۹۲٫۵	٪۷۳٫۶

اشتباه به عنوان معیوب پیش‌بینی کرده است، در حالی که بازیابی بالا نشان می‌دهد که مدل قادر به شناسایی بیشتر نمونه‌های معیوب بوده است. این تعادل معمولاً در مدل‌های یادگیری ماشین دیده می‌شود و نیاز به توجه دقیق به بیش‌برازش و تعادل بین دقت و بازیابی در کاربردهای دنیای واقعی را برجسته می‌کند.

در ادامه، تعداد مختلفی از ویژگی‌های رتبه‌بندی‌شده به درخت تصمیم‌گیری اعمال شده و تمام معیارها محاسبه شده‌اند. شکل ۸ نتایج دقت، صحت، بازیابی، تشخیص و نمره F1 را در مرحله آزمون نشان می‌دهد. بر اساس نتایج، استفاده از ۵، ۸، ۹، ۱۵، ۲۲، و ۲۳ ویژگی همواره عملکرد بالایی را در تمام معیارها با بسیاری از مقادیر نزدیک به یک به همراه دارد. در میان این موارد، ۵ ویژگی نخست، نقطه‌ای است که در آن تمام معیارها به امتیاز کامل دست می‌یابند، که آن را به عنوان یک انتخاب بهینه برای مدل متعادل و فشرده معرفی می‌کند. به طور جایگزین، ۸ ویژگی نیز عملکرد بالایی را با معیارهای پایدار حفظ می‌کند و مجموعه ویژگی کمی وسیع‌تر بدون خطر زیاد بیش‌برازش را ارائه می‌دهد.

## ۷- کلاسه‌بندی شدت عیب به کمک شبکه عصبی بیزین

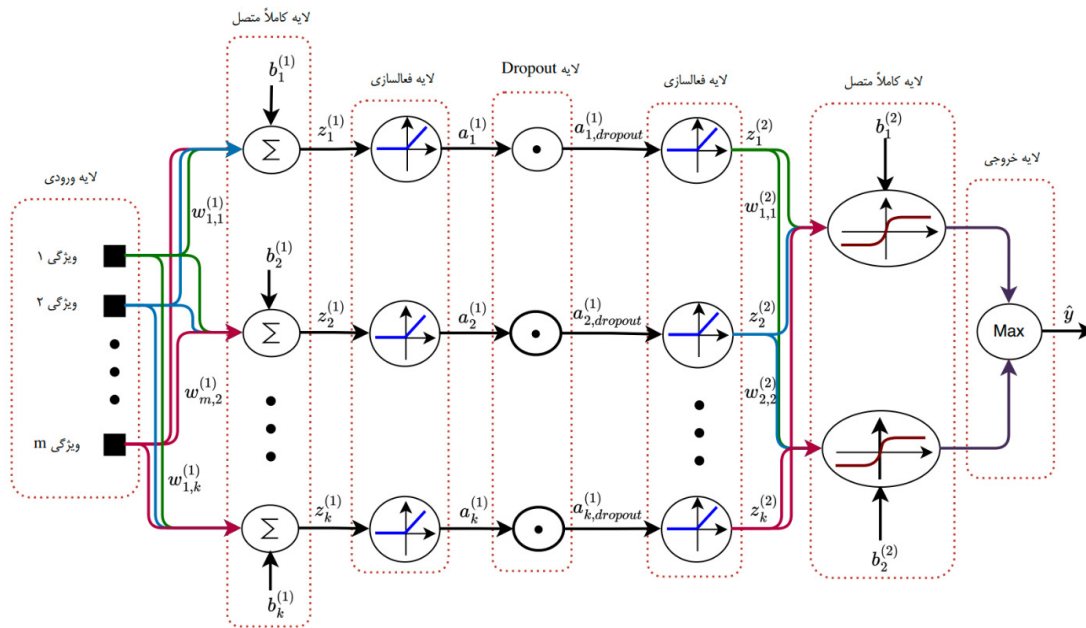
شبکه‌های عصبی بیزی به عنوان یک روش قوی برای طبقه‌بندی عیب در سیستم‌های پیچیده ظهور کرده‌اند. با ادغام استنتاج بیزی در معماری‌های شبکه عصبی، BNNها پیش‌بینی‌های احتمالاتی را ارائه می‌دهند که عدم اطمینان را کمی‌سازی می‌کند، که یک عامل بحرانی در تشخیص عیب است. این رویکرد به‌ویژه در سناریوهایی که شامل داده‌های نویزی یا ناقص هستند، مؤثر است. BNNها در ارائه بازه‌های اطمینان برای طبقه‌بندی‌های خود برتری دارند و قابلیت اطمینان تشخیص عیب را در زمینه‌های مختلف مانند ماشین‌آلات دوار و سیستم‌های انتقال قدرت افزایش می‌دهند.

طبقه‌بندی شده‌اند و نمونه‌های معیوبی که به اشتباه به عنوان سالم طبقه‌بندی شده‌اند.

دقت نشان‌دهنده نسبت کلی نمونه‌های صحیح طبقه‌بندی‌شده (مجموع TP و TN) به کل تعداد نمونه‌ها است. صحت ۱ میزان نسبت پیش‌بینی‌های مثبت صحیح (TP) از تمام پیش‌بینی‌های مثبت (مجموع TP و FN) را اندازه‌گیری می‌کند. صحت بالا به این معنی است که وقتی مدل یک نقص را پیش‌بینی می‌کند، احتمالاً درست است. بازیابی ۲ نسبت نمونه‌های مثبت واقعی (TP) از تمام پیش‌بینی‌های مثبت (مجموع TP و FN) است. بازیابی بالا نشان‌دهنده این است که مدل تعداد زیادی از نمونه‌های معیوب را به درستی شناسایی می‌کند. تشخیص ۳ نسبت نمونه‌های منفی (TN) به تمام پیش‌بینی‌های مثبت (مجموع FN و TP) است. تشخیص بالا زمانی مهم است که جلوگیری از طبقه‌بندی نادرست نمونه‌های سالم به عنوان معیوب بحرانی باشد. نمره F1 تعادل بین دقت و بازیابی را برقرار می‌سازد، به ویژه در مواردی که توزیع کلاس‌ها نامتوازن است. جدول ۲ خلاصه‌ای از این معیارها برای هر دو مرحله آموزش و آزمایش را ارائه می‌دهد.

نتایج جدول ۲ نشان می‌دهند که مدل درخت تصمیم‌گیری در داده‌های آموزشی عملکرد بسیار خوبی داشته است و به طور مؤثری الگوهای داده‌های آموزشی را یاد گرفته است. کاهش جزئی در معیارهای عملکرد در مرحله آزمایش، به ویژه در دقت و نمره F1، نشان می‌دهد که ممکن است مدل به داده‌های آموزشی بیش‌برازش شده باشد. دقت پایین‌تر در مرحله آزمون نشان می‌دهد که مدل تعداد بیشتری از نمونه‌های سالم را به

1. Precision
2. Recall
3. Specificity



شکل ۹: معماری BNN در این مقاله شامل یک لایه ورودی، دو لایه کاملاً متصل، دو لایه فعال‌سازی، یک لایه dropout و یک لایه خروجی.

واحد خطی یکسوشده  $\text{ReLU}^1$  به عنوان تابع فعال‌سازی غیرخطی  $\phi(\cdot)$  اعمال می‌شود تا خروجی‌های فعال‌شده  $\mathbf{a}^{(l)}$  تولید شوند. از آنجا که  $\mathbf{z}^{(l)}$  یک متغیر تصادفی به دلیل طبیعت بیز وزن‌ها است،  $\mathbf{a}^{(l)}$  نیز نمایانگر توزیع بر روی فعال‌سازی‌ها به جای یک مقدار ثابت است. برای جلوگیری از پیش‌برازش و بهبود قابلیت‌های تعمیم شبکه، یک لایه dropout پس از اولین لایه کاملاً متصل اعمال می‌شود. این لایه به‌طور تصادفی درصدی از واحدهای ورودی را در هر تکرار آموزشی با نرخ dropout به میزان ۵۰٪ صفر می‌کند. به‌طور ریاضی، عملیات dropout به صورت (۲۴) نمایش داده می‌شود [۴۱].

$$\mathbf{a}_{\text{dropout}}^{(l)} = \mathbf{q} \odot \mathbf{a}^{(l)} \quad (24)$$

جایی که  $\mathbf{q}$  یک بردار ماسک باینری است که از توزیع برنولی با احتمال  $p = 0.5$  نمونه‌برداری شده و  $\odot$  معرف ضرب عنصر به عنصر را است. لایه کاملاً متصل دوم، که همچنین از وزن‌های بیز استفاده می‌کند، شامل دو نورون است که به دو کلاس خروجی مربوط می‌شود. وزن‌ها و بایاس  $\mathbf{W}^{(r)}$  از توزیع‌های گاوسی نمونه‌برداری شده‌اند، یعنی  $\mathbf{W}^{(r)} \sim N(\mu_w^{(r)}, \sigma_w^{(r)})$ ،  $\mathbf{b}^{(r)} \sim N(\mu_b^{(r)}, \sigma_b^{(r)})$ . خروجی این لایه  $\mathbf{z}^{(r)}$ ، به صورت (۲۵) بیان می‌شود

$$\mathbf{z}^{(r)} = \mathbf{W}^{(r)} \cdot \mathbf{a}_{\text{dropout}}^{(l)} + \mathbf{b}^{(r)} \quad (25)$$

برای تبدیل  $\mathbf{z}^{(r)}$  به یک توزیع احتمال، تابع SoftMax اعمال می‌شود. این تابع خروجی‌ها را به گونه‌ای نرمالیزه می‌کند که مجموع آن‌ها برابر با یک شود و امکان تفسیر آن‌ها به عنوان احتمال را فراهم می‌آورد. خروجی SoftMax برای هر کلاس  $c$  به صورت (۲۶) است [۴۲]

$$\mathbf{z}^{(r)} = \mathbf{W}^{(r)} \cdot \mathbf{a}_{\text{dropout}}^{(l)} + \mathbf{b}^{(r)} \quad (25)$$

برای تبدیل  $\mathbf{z}^{(r)}$  به یک توزیع احتمال، تابع SoftMax اعمال می‌شود. این تابع خروجی‌ها را به گونه‌ای نرمالیزه می‌کند که مجموع آن‌ها برابر با یک شود و امکان تفسیر آن‌ها به عنوان احتمال را فراهم می‌آورد. خروجی SoftMax برای هر کلاس  $c$  به صورت (۲۶) است [۴۲]

ظرفیت BNNها برای مدیریت عدم اطمینان و ارائه خروجی‌های احتمالاتی، پیشرفت قابل توجهی نسبت به شبکه‌های عصبی سنتی در حوزه طبقه‌بندی عیب و قابلیت اطمینان تشخیص عیب به حساب می‌آید [۳۸].

در یک BNN، لایه ورودی داده‌های خام را دریافت می‌کند، جایی که هر نورون نمایانگر ویژگی خاصی از ورودی است. لایه‌های پنهان اکثر محاسبات را انجام می‌دهند و تبدیل‌های غیرخطی را بر روی داده‌ها اعمال می‌کنند. برخلاف شبکه‌های سنتی، وزن‌ها و بایاس‌ها در یک BNN به‌عنوان متغیرهای تصادفی در نظر گرفته می‌شوند که هر کدام با توزیع احتمالی مرتبط هستند. این امر به شبکه کمک می‌کند تا عدم اطمینان در این پارامترها را به‌درستی درک کند. لایه خروجی پیش‌بینی‌های نهایی را تولید می‌کند که اغلب از تابع فعال‌سازی Softmax برای خروجی دادن احتمالات هر کلاس استفاده می‌کند [۳۹]. تکنیک‌های بهینه‌سازی بیزی اغلب برای تنظیم دقیق این هابیر پارامترها استفاده می‌شوند. استنتاج بیزی در BNNها شامل استفاده از توزیع پیشین است که نمایانگر باورهای اولیه درباره پارامترهای شبکه قبل از مشاهده هر داده است. پس از مشاهده داده‌ها، توزیع پیشین با استفاده از قضیه بیز به‌روزرسانی می‌شود تا توزیع پسین را بدست آورد که دانش پیشین را با اطلاعات جدید از داده‌ها ترکیب می‌کند.

طبق شکل ۹، معماری BNN شامل یک لایه ورودی، دو لایه بیزی کاملاً متصل، یک لایه dropout برای منظم‌سازی، یک لایه SoftMax برای تخمین احتمالات و یک لایه خروجی برای تصمیم‌گیری نهایی طبقه‌بندی است. لایه ورودی BNN ویژگی‌ها را به‌عنوان دریافت می‌کند. لایه اول کاملاً متصل شامل  $k$  نورون است که هر کدام دارای وزن‌های بیزی هستند. این وزن‌ها و بایاس‌ها به‌عنوان توزیع‌های گاوسی مدل می‌شوند، یعنی  $\mathbf{W}^{(l)} \sim N(\mu_w^{(l)}, \sigma_w^{(l)})$  و  $\mathbf{b}^{(l)} \sim N(\mu_b^{(l)}, \sigma_b^{(l)})$  [۴۰].

خروجی لایه اول به‌صورت (۲۳) محاسبه می‌شود

$$\mathbf{z}^{(l)} = \mathbf{W}^{(l)} \cdot \mathbf{x} + \mathbf{b}^{(l)} \quad (23)$$

		1st BNN: Training		1st BNN: Test	
True Class		Faulty	Healthy	Faulty	Healthy
		Faulty	59	12	25
Healthy	10	69	3	18	
		Predicted Class		Predicted Class	

شکل ۱۰: ماتریس‌های سردرگمی برای شناسایی ITSC با شدت عیب ۱.۷۸٪، (الف) مرحله آموزش و (ب) مرحله آزمون.

شناسایی دقیق عیوب تنظیم شده است در حالی که تعادل معقولی را بین مثبت‌های اشتباه و منفی‌های اشتباه حفظ می‌کند. در مجموعه داده‌های آزمون، BNN دقت ۸۶.۰۰٪ را حفظ کرده است که کمی بالاتر از دقت آموزش است. این به این معنی است که مدل به خوبی به داده‌های جدید و دیده‌نشده تعمیم یافته و به پیش‌برازش دچار نشده است. برای کلاس سالم، دقت به ۸۹.۲۹٪ بهبود یافت، در حالی که بازیابی ۸۶.۲۱٪ بود که منجر به نمره F1 ۸۷.۷۲٪ شده است. این بهبود در دقت و نمره F1 در مجموعه آزمایش نشان می‌دهد که مدل در شناسایی شرایط سالم عملکردی قابل قبول دارد. ماتریس سردرگمی، آزمایش ۲۵ پیش‌بینی مثبت درست و ۳ منفی اشتباه برای وضعیت‌های غیر عیب، و ۱۸ پیش‌بینی مثبت درست و ۴ مثبت اشتباه برای وضعیت‌های عیب را نشان می‌دهد. این ماتریس تأیید می‌کند که در حالی که مدل به طور مؤثر عیوب را شناسایی می‌کند، هنوز هم برخی از وضعیت‌های سالم را به عنوان عیب طبقه‌بندی می‌کند.

یکی از مزایای اصلی استفاده از BNN برای طبقه‌بندی عیوب، توانایی آن در توصیف خروجی‌های پیش‌بینی شده به صورت توزیع‌های احتمالاتی است. شکل ۱۱ نمای ۲ بعدی و ۳ بعدی توزیع خروجی‌های پیش‌بینی شده در مرحله آزمون را نشان می‌دهد. برای ارزیابی بیشتر BNN از نظر عدم قطعیت پیش‌بینی، توزیع برچسب‌های پیش‌بینی شده برای کلاس‌های سالم و معیوب نمونه آزمایشی اول، بررسی شده است. شکل ۱۲ دو توزیع سالم (آبی) و معیوب (قهوه‌ای) توصیف می‌کند و نشان می‌دهد که BNN به طور مؤثر توانسته است بین این کلاس‌ها تمایز قائل شود. توزیع کلاس سالم حول یک مقدار خروجی پیش‌بینی شده پایین‌تر  $\mu_h$  متمرکز است، در حالی که کلاس معیوب حول یک مقدار بالاتر  $\mu_f$  متمرکز است. گسترش باریک توزیع‌ها در اطراف میانگین‌های مربوطه، که توسط انحراف معیارهای کم مشخص شده است، نشان‌دهنده اعتماد بالا به پیش‌بینی‌های مدل و عدم قطعیت کم است. وجود همپوشانی حداقلی بین دو توزیع، پایداری مدل در تمایز بین شرایط سالم و معیوب را بیشتر نشان می‌دهد. اگر خروجی پیش‌بینی شده برای این نمونه به خوبی با میانگین کلاس عیب‌دار  $\mu_f$  هم‌راستا باشد و در محدوده یک انحراف معیار  $\mu_f \pm \sigma_f$  قرار گیرد، این نشان‌دهنده طبقه‌بندی صحیح با اعتماد بالا است. جداسازی واضح و عرض باریک توزیع‌ها اثبات می‌کند که BNN در تشخیص عیب بسیار قابل اعتماد است و قادر به کمینه‌سازی مثبت‌های کاذب و منفی‌های کاذب است که در کاربردهای عملی که تشخیص دقیق عیب ضروری است، بسیار حائز اهمیت است.

$$p(y = c | x, W) = \frac{e^{z_c^{(y)}}}{e^{z_1^{(y)}} + e^{z_2^{(y)}}}, c \in \{1, 2\} \quad (26)$$

تصمیم‌گیری نهایی برای طبقه‌بندی با انتخاب کلاسی که بالاترین احتمال را دارد، انجام می‌شود. به عبارت دیگر

$$\hat{y} = \arg \max_c p(y = c | x, W) \quad (27)$$

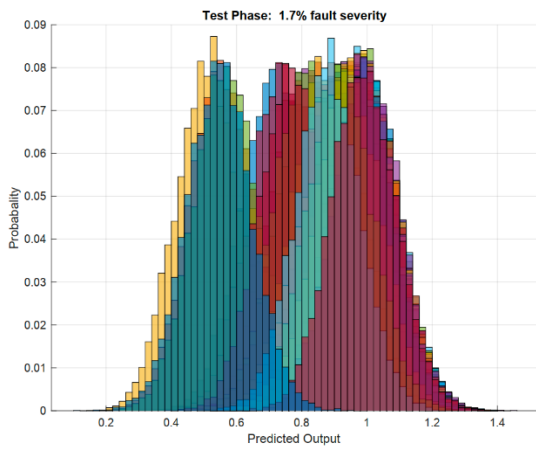
آموزش BNN شامل بهینه‌سازی مدل برای کمینه‌سازی مرز پایین شواهد منفی (ELBO) به عنوان تابع هدف رایج در استنباط واریانس است. ELBO شامل منفی لگاریتم احتمال داده‌ها تحت توزیع پسین تقریبی و واگرایی کلباک-لیبلر (KL) بین توزیع پسین تقریبی  $q(W)$  و توزیع پیشین  $p(W)$  است [۴۳]. به عبارت دیگر

$$L(W) = E_{q(W)} [-\log p(y|x, W)] + KL(q(W) || p(W)) \quad (28)$$

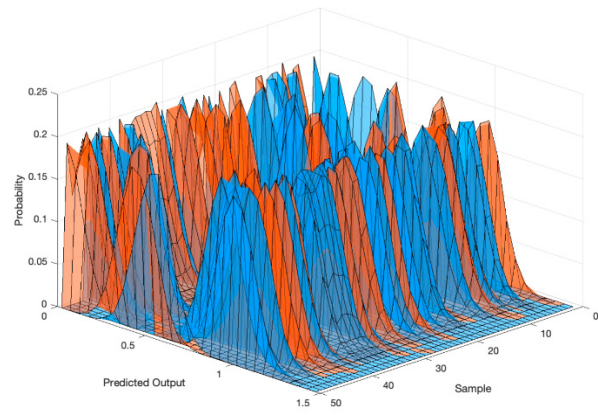
برای بهینه‌سازی، از گرادیان نزول تصادفی با مومنتوم استفاده شده است، که نوعی از گرادیان نزولی است که با در نظر گرفتن گرادیان‌های قبلی به تسریع همگرایی کمک می‌کند. آموزش بر روی حداکثر ۵۰۰ دوره با ۳۲ مینی‌بچ انجام شده است که به روزرسانی‌های کارآمد و استفاده مؤثر از منابع محاسباتی را فراهم می‌آورد. برای تمایز شدت عیب، شش BNN توسعه داده شده که هر BNN یکی از شدت‌های عیب را در برابر داده‌های سالم شناسایی می‌کند. ابتدا عملکرد BNN را برای اولین شدت عیب که سطح عیب ۱.۷۸٪ است، ارائه می‌شود. شکل ۱۰ عملکرد BNN را بر اساس ماتریس سردرگمی نمایش می‌دهد.

در طول آموزش، BNN به دقت ۸۵.۳۳٪ دست‌یافت. معیارها برای کلاس ۰ (وضعیت سالم) نشان می‌دهد که دقت ۸۵.۵۱٪، بازیابی ۸۳.۱۰٪ و نمره F1 ۸۴.۲۹٪ است. این مقادیر نشان می‌دهد که مدل به طور کلی مؤثر در شناسایی وضعیت‌های سالم است و تعادل بین دقت و بازیابی وجود دارد. برای کلاس ۱ (وضعیت عیب)، BNN دقت ۸۵.۱۹٪، بازیابی ۸۷.۳۴٪ و نمره F1 ۸۶.۲۵٪ را نشان داده است. مقدار بالاتر بازیابی نشان می‌دهد که مدل به ویژه در شناسایی عیوب واقعی رفتار موثری دارد. ماتریس سردرگمی آموزش عملکرد مدل را با ۵۹ پیش‌بینی مثبت درست و ۱۰ منفی اشتباه برای وضعیت‌های غیر عیب، و همچنین ۶۹ پیش‌بینی مثبت درست و ۱۲ مثبت اشتباه برای وضعیت‌های عیب توصیف می‌کند. توزیع این مقادیر نشان می‌دهد که BNN به خوبی برای






(ب)



(ف)

شکل ۱۱: توزیع خروجی‌های پیش‌بینی شده در مرحله آزمایش برای شناسایی ITSC با شدت عیب ۱٫۷۸٪، در نمودار ۳ بعدی، توزیع‌های آبی مربوط به نقاط داده پیش‌بینی شده به عنوان عیب‌دار هستند، در حالی که توزیع‌های قهوه‌ای نمایانگر نقاط داده سالم هستند.



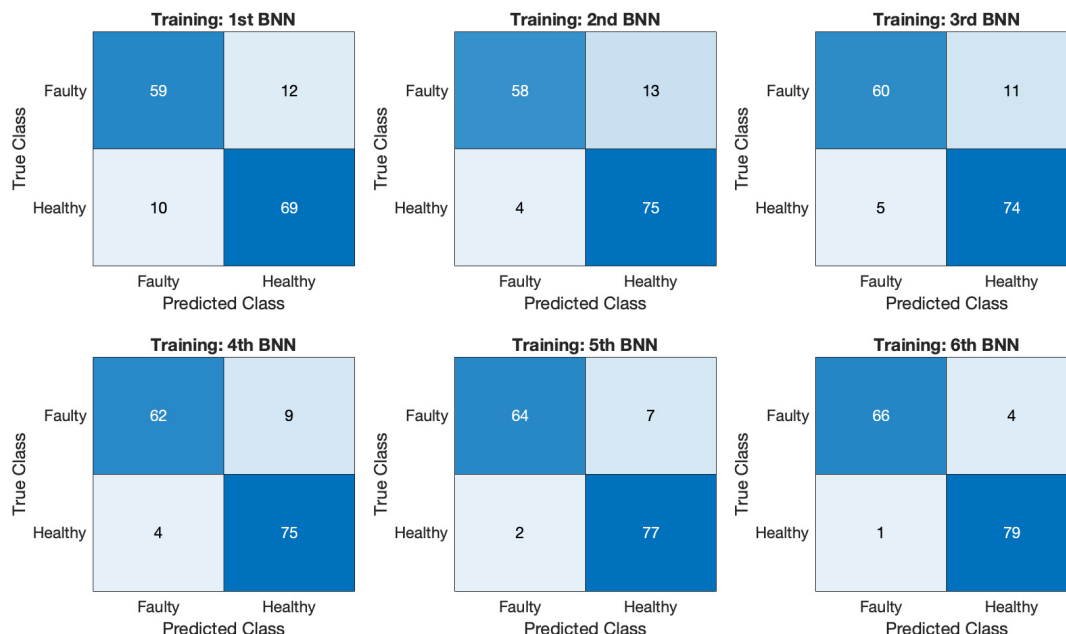
شکل ۱۲: توزیع خروجی پیش‌بینی شده در مرحله آزمایش برای نمونه اول. توزیع آبی نمایانگر کلاس سالم و توزیع قهوه‌ای نمایانگر کلاس معیوب است.

۲٫۶۵٪، عملکرد را بیشتر بهبود می‌بخشد. ماتریس سردرگمی کاهش در مثبت‌های کاذب و منفی‌های کاذب را نشان می‌دهد که به معنای طبقه‌بندی دقیق‌تر است. دقت و بازیابی نیز این پیشرفت را منعکس می‌کنند. در مدل چهارم BNN که با شدت نقص ۳٫۵٪ عمل می‌کند، بهبود قابل توجه‌تری در عملکرد مشاهده می‌شود. ماتریس سردرگمی نشان‌دهنده کاهش در خطاهای طبقه‌بندی، با کاهش مثبت‌های کاذب و منفی‌های کاذب است. مدل پنجم BNN که به شدت نقص ۹٫۸۱٪ می‌پردازد، بهبودهای خیلی بالایی را نشان می‌دهد. ماتریس سردرگمی برای این مدل نشان‌دهنده تعداد بسیار کمی از مثبت‌های کاذب و منفی‌های کاذب است که عملکرد قوی آن را برجسته می‌کند. مقادیر دقت و یادآوری به طور قابل توجهی بالا هستند که نشان می‌دهد مدل به طور مؤثر خطاهای طبقه‌بندی را کاهش داده و دقت بالایی در شناسایی عیوب دارد. در نهایت، مدل ششم BNN با شدت عیب ۱۷٫۶۸٪، بالاترین عملکرد را در بین مدل‌های ارزیابی شده نشان می‌دهد. ماتریس سردرگمی نشان‌دهنده طبقه‌بندی تقریباً بی‌نقص با حداقل مثبت‌های کاذب و منفی‌های کاذب است. این مدل دقت و بازیابی فوق‌العاده‌ای را به دست می‌آورد و عملکرد نزدیک به پهنه‌ای را در شناسایی عیوب و طبقه‌بندی دقیق داده‌های سالم نشان می‌دهد. نمرات بالای F1 به‌طور بیشتری اثربخشی مدل در تعادل بین دقت و بازیابی را تأیید می‌کند.

عملکرد شش مدل BNN از طریق ماتریس‌های سردرگمی و شاخص‌های مربوطه از جمله دقت، صحت، یادآوری و امتیاز F1 ارزیابی شده است. شکل‌های ۱۳ و ۱۴ ماتریس‌های سردرگمی برای شش مدل BNN در مراحل آموزش و آزمون را نشان می‌دهند. جدول ۳ عملکرد این شبکه‌ها را از نظر شاخص‌ها ارائه می‌دهد. مدل اول BNN که با شدت عیب ۷۸٫۱٪ کار می‌کند، عملکرد متوسطی در تشخیص عیب نشان می‌دهد. ماتریس سردرگمی نشان می‌دهد که مدل مربوطه تعداد بیشتری از موارد مثبت کاذب نسبت به منفی کاذب دارد. مقادیر صحت و بازیابی برای هر دو کلاس نسبتاً متوازن است اما صحت برای کلاس ۱ نسبت به کلاس ۰ کمی پایین‌تر است. این نشان‌دهنده تمایل به از دست دادن برخی از موارد عیب است، در حالی که داده‌های سالم به درستی شناسایی می‌شوند.

با مدل دوم BNN که به شدت نقص ۲٫۱۳٪ پرداخته است، عملکرد به طور قابل توجهی بهبود یافته است. ماتریس سردرگمی نشان‌دهنده تعداد کمتر مثبت‌های کاذب و منفی‌های کاذب در مقایسه با مدل اول است و نشان‌دهنده توانایی بهتر در تمایز بین داده‌های نقص و سالم است. این بهبود همچنین در مقادیر دقت و یادآوری برای هر دو کلاس منعکس شده است. مدل مربوطه تعادل مؤثرتری را بین شناسایی نقص‌ها و طبقه‌بندی صحیح داده‌های سالم نشان می‌دهد که قابلیت‌های تصمیم‌گیری را برجسته می‌کند. مدل سوم BNN، طراحی شده برای شدت نقص





شکل ۱۳: ماتریس‌های سردرگمی برای مدل‌های BNN در مرحله آموزش مربوط به شدت‌های ۱، ۷۸، ۲، ۶۵، ۳، ۵، ۴، ۸۱، ۵، ۶۸ و ۶، ۶۸٪.

جدول ۳: عملکرد مدل‌های BNN در طبقه‌بندی شدت‌های مختلف عیب بر اساس معیارهای دقت، صحت، بازیابی و امتیاز F1.

شدت عیب	دقت (آموزش)	دقت (آزمون)	صحت (کلاس سالم)	بازیابی (کلاس سالم)	نمره F1 (کلاس سالم)	صحت (کلاس معیوب)	بازیابی (کلاس معیوب)	نمره F1 (کلاس معیوب)
۱، ۷۸	۸۵،۳۳٪	۸۶٪	۸۵،۵۱٪	۸۳،۱۰٪	۸۴،۳۹٪	۸۵،۱۹٪	۸۷،۳۴٪	۸۶،۲۵٪
۲، ۱۳	۸۸،۶۷٪	۸۸٪	۹۳،۵۵٪	۸۱،۶۹٪	۸۷،۲۲٪	۸۵،۲۳٪	۹۴،۹۴٪	۸۹،۸۲٪
۲، ۶۵	۸۹،۳۳٪	۹۰٪	۹۲،۳۱٪	۸۴،۵۱٪	۸۸،۲۴٪	۸۷،۰۶٪	۹۳،۶۷٪	۹۰،۲۴٪
۳، ۵	۹۱،۳۳٪	۹۲٪	۹۳،۹۴٪	۸۷،۳۲٪	۹۰،۵۱٪	۸۹،۲۹٪	۹۴،۹۴٪	۹۲،۰۲٪
۴، ۸۱	۹۴٪	۹۴٪	۹۶،۹۷٪	۹۰،۱۴٪	۹۳،۴۳٪	۹۱،۶۷٪	۹۷،۴۷٪	۹۴،۴۸٪
۵، ۶۸	۹۷،۳۳٪	۹۶٪	۹۸،۵۵٪	۹۵،۷۷٪	۹۷،۱۴٪	۹۶،۳۰٪	۹۸،۷۳٪	۹۶،۳۰٪

است. این مقایسه به‌منظور بررسی میزان بهبود روش پیشنهادی در تشخیص دقیق‌تر و پایدارتر شدت عیب انجام شده است. نتایج این مقایسه در شکل ۱۵ ارائه شده است که عملکرد دو روش را در سطوح مختلف شدت عیب نشان می‌دهد.

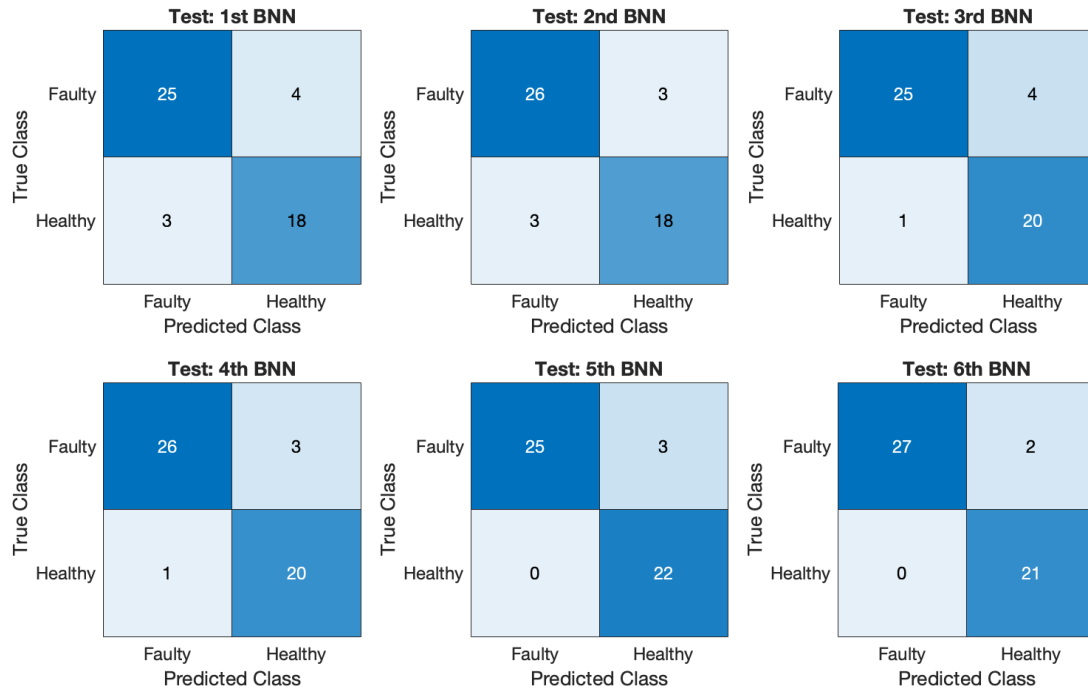
دقت مدل در روش پیشنهادی در تمامی شدت‌های عیب از LSTM بهتر است. در شدت ۱، ۷۸٪، دقت LSTM برابر ۷۴،۰۰٪ است، در حالی که روش پیشنهادی با ۸۶،۰۰٪، ۲، ۱۶٪ بهبود داشته است. این روند در شدت ۲، ۱۳٪ نیز حفظ شده و روش پیشنهادی دقت ۸۸،۰۰٪ را نشان می‌دهد که ۲، ۱۰٪ بالاتر از LSTM با دقت ۷۸،۰۰٪ است. با افزایش شدت عیب، تفاوت عملکرد دو روش بیشتر نمایان می‌شود. در شدت ۴، ۸۱٪، دقت روش پیشنهادی ۹۴،۰۰٪ است، در حالی که دقت LSTM ۸۸،۰۰٪ گزارش شده که بیانگر ۶، ۸٪ بهبود است. در شدت عیب ۵، ۶۸٪، دقت روش پیشنهادی به ۹۶،۰۰٪ می‌رسد، که ۴٪ بالاتر از LSTM با دقت ۹۲،۰۰٪ است. این نشان می‌دهد که روش پیشنهادی در شدت‌های بالاتر از پایداری بیشتری برخوردار است و دقت آن در مواجهه با داده‌های پیچیده کاهش قابل توجهی ندارد.

دقت پیش‌بینی کلاس سالم نشان می‌دهد که مدل تا چه حد نمونه‌های سالم را به‌درستی شناسایی می‌کند. در شدت ۱، ۷۸٪ روش پیشنهادی دقت ۸۵،۵۱٪ را ارائه می‌دهد که ۲، ۶۴٪ بالاتر از LSTM با دقت ۶۳،۸۷٪ است. این بهبود در شدت ۲، ۱۳٪ نیز مشاهده می‌شود، جایی که روش پیشنهادی دقت ۹۳،۵۵٪ را ارائه داده که ۶، ۴٪ بیشتر از

روش‌های متعددی برای طبقه‌بندی شدت عیوب اتصال کوتاه بین دور موتورهای PMSM پیشنهاد شده‌اند. از جمله این روش‌ها می‌توان به شبکه حافظه طولانی کوتاه مدت [۱]، شبکه‌های عصبی خودتوجهی [۲]، و شبکه‌های کانولوشنی [۳] اشاره کرد. به‌عنوان مثال، استفاده از حافظه طولانی کوتاه مدت برای تخمین شدت عیوب بر اساس تحلیل داده‌های زمانی- مکانی، دقت بالایی در تشخیص شدت عیب ارائه داده است. همچنین، شبکه‌های خودتوجهی توانایی تحلیل وابستگی‌های طولانی‌مدت داده‌ها و ویژگی‌های پیچیده را دارند. این روش‌ها عمدتاً به دلیل توانایی یادگیری غیرخطی و استخراج ویژگی‌های مهم از داده‌های پیچیده مورد توجه قرار گرفته‌اند.

با این حال، شبکه عصبی بیزین نسبت به این روش‌ها برتری‌هایی دارد. این شبکه علاوه بر دقت بالا در طبقه‌بندی شدت عیب، اطلاعاتی درباره عدم قطعیت مدل ارائه می‌دهد که در کاربردهای حساس مانند پیش‌بینی و نگهداری پیشگیرانه موتورهای PMSM بسیار حائز اهمیت است. این ویژگی به مهندسان اجازه می‌دهد تصمیمات دقیق‌تری در شرایط عدم قطعیت بگیرند. علاوه بر این، BNN می‌تواند با ترکیب دانش پیشین و داده‌های جدید، بهبود عملکرد مدل را تضمین کند، در حالی که روش‌های دیگر به داده‌های آموزشی بزرگ‌تر و پیچیده‌تر نیاز دارند.

در این بخش، هدف مقایسه عملکرد روش پیشنهادی با شبکه حافظه طولانی-کوتاه‌مدت (LSTM) ارائه شده در [۴۴] در کلاس‌بندی شدت عیب از دیدگاه دقت، صحت، بازیابی، امتیاز F1 و سایر معیارهای ارزیابی



شکل ۱۴: ماتریس‌های سردرگمی برای مدل‌های BNN در مرحله آزمون مربوط به شدت‌های ۱/۷۸٪، ۲/۱۳٪، ۲/۶۵٪، ۳/۵٪، ۹/۸۱٪ و ۱۷/۶۸٪.

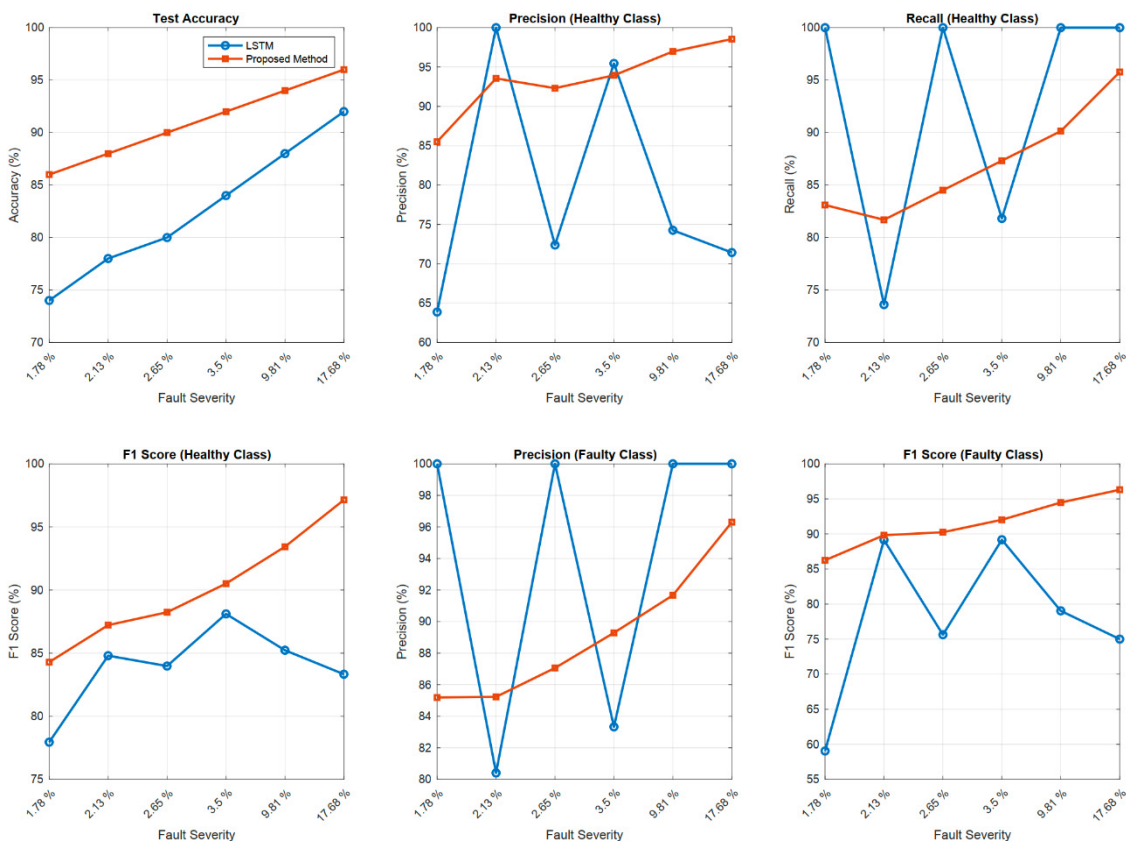
۲۱/۳۰٪ بالاتر از مقدار ۷۵/۰۰٪ در LSTM است.

نتایج عددی نشان می‌دهند که روش پیشنهادی در تمامی شدت‌های عیب از نظر دقت، بازخوانی، امتیاز F1 و سایر معیارها عملکرد بهتری نسبت به LSTM [۴۴] دارد. بیشترین بهبود در شدت‌های بالای عیب مشاهده می‌شود، جایی که روش پیشنهادی قادر است نرخ خطا را کاهش داده و تشخیص را با دقت بیشتری انجام دهد. این عملکرد بهبود یافته نشان‌دهنده توانایی روش پیشنهادی در یادگیری بهتر الگوهای پیچیده و تفکیک دقیق‌تر بین کلاس‌های سالم و معیوب است، که باعث افزایش قابلیت اطمینان سیستم تشخیص عیب می‌شود. نتایج ماتریس‌های درهم ریختگی الگوریتم LSTM برای کلاس بندی شدت عیوب مختلف در مرحله آزمون در شکل ۱۶ ارائه شده است.


در ارتباط با تعمیم‌پذیری روش پیشنهادی باید اشاره کرد که اولاً روش پیشنهادی مبتنی بر تحلیل سیگنال‌های جریان سه‌فاز است. از آنجایی که سیگنال جریان به‌طور مستقیم ویژگی‌های الکتریکی موتور را نشان می‌دهد، با تغییر توان یا سرعت موتور، این سیگنال تغییراتی خواهد داشت که ممکن است بر مدل تأثیر بگذارد. بنابراین، برای تعمیم الگوریتم پیشنهادی به انواع PMSM با توان و سرعت مختلف، مدل پیش‌بینی باید برای توان‌ها و سرعت‌های مختلف آموزش داده شود یا ویژگی‌هایی که مستقل از توان و سرعت هستند، استخراج شود. اثر توان و سرعت: تغییر توان موتور و سرعت چرخش آن می‌تواند دامنه، فرکانس، و سایر ویژگی‌های سیگنال جریان را تغییر دهد. در فرآیند تبدیل موجک گسسته و تحلیل چگالی طیفی توان، این تغییرات می‌توانند در مرحله پیش‌پردازش تأثیرگذار باشند. بنابراین، لازم است که مدل پیشنهادی انعطاف‌پذیری لازم برای تنظیم خودکار نسبت به این تغییرات را داشته باشد یا اینکه نمونه‌های آموزشی متنوعی با توان‌ها و سرعت‌های مختلف در فرآیند آموزش استفاده شوند. به‌علاوه برای اطمینان از اینکه روش پیشنهادی به توان‌ها و سرعت‌های مختلف قابل تعمیم است، می‌توان از تکنیک‌هایی مانند نرمال‌سازی ویژگی‌ها یا استفاده از داده‌های آموزشی جامع و متنوع بهره برد. همچنین، استفاده از شبکه عصبی عمیق بیزین که ذاتاً به عدم قطعیت حساس است، می‌تواند به بهبود تعمیم‌پذیری کمک کند.

LSTM با مقدار ۸۷/۰۰٪ است. در شدت ۹/۸۱٪، دقت مدل پیشنهادی ۹۶/۹۷٪ است که نسبت به ۷۴/۲۶٪ در LSTM ۳۰/۶۴٪ بهبود یافته است. این مقدار در شدت ۱۷/۶۸٪ به ۹۸/۵۵٪ می‌رسد که ۲۷/۱۲٪ بالاتر از LSTM با مقدار ۷۱/۴۳٪ است. این نشان می‌دهد که مدل پیشنهادی در جلوگیری از خطای نوع اول (false positive) عملکرد بهتری دارد و نمونه‌های سالم را با دقت بیشتری از موارد معیوب تفکیک می‌کند.

در شدت ۱/۷۸٪، بازخوانی روش پیشنهادی ۸۳/۱۰٪ و در LSTM ۱۰۰/۰۰٪ است، اما در شدت‌های بالاتر، روش پیشنهادی با ۸۷/۳۲٪ در شدت ۳/۵٪ و ۹۰/۱۴٪ در شدت ۹/۸۱٪ عملکرد بهتری نسبت به LSTM دارد، که در این شدت‌ها مقدار ۶۵/۳۳٪ و ۶۰/۰۰٪ گزارش شده است. افزایش بازخوانی مدل پیشنهادی در شدت‌های بالاتر باعث می‌شود که مدل بتواند نمونه‌های سالم را به‌درستی شناسایی کند و خطای نوع دوم (false negative) کاهش یابد. در شدت ۱۷/۶۸٪، روش پیشنهادی بازخوانی ۹۵/۷۷٪ را ارائه داده که نسبت به ۶۰/۰۰٪ در LSTM ۳۵/۷۷٪ بهبود دارد. صحت مدل در پیش‌بینی نمونه‌های معیوب در روش پیشنهادی به‌طور کلی بالاتر از LSTM در [۴۴] است. در شدت ۱/۷۸٪، مقدار ۸۵/۱۹٪ برای روش پیشنهادی و ۱۰۰/۰۰٪ برای LSTM است. اما با افزایش شدت عیب، روش پیشنهادی برتری خود را نشان می‌دهد. در شدت ۱۹/۸۱٪، مقدار صحت روش پیشنهادی ۹۱/۶۷٪ است، در حالی که LSTM تنها ۷۱/۴۳٪ دقت دارد که نشان‌دهنده ۲۰/۲۴٪ بهبود است. در شدت ۱/۷۸۳٪، بازخوانی روش پیشنهادی ۸۷/۳۴٪ و در LSTM ۴۱/۸۹٪ است که ۴۵/۴۵٪ بهبود دارد. در شدت ۱۷/۶۸٪، بازخوانی روش پیشنهادی ۹۸/۷۳٪ گزارش شده که نسبت به مقدار ۶۰/۰۰٪ در LSTM، ۳۸/۷۳٪ بهبود نشان می‌دهد. این نتایج نشان می‌دهد که روش پیشنهادی عملکرد بسیار بهتری در کاهش میزان خطای نوع دوم دارد و احتمال عدم شناسایی عیوب را به حداقل می‌رساند. در شدت ۱/۷۸٪، مقدار F1 برای روش پیشنهادی ۸۶/۲۵٪ و برای LSTM ۵۹/۰۵٪ است که ۲۷/۲٪ بهبود دارد. در شدت ۹/۸۱٪، مقدار F1 روش پیشنهادی به ۹۴/۴۸٪ افزایش یافته که نسبت به ۷۹/۰۳٪ در LSTM، ۱۵/۴۵٪ بهبود نشان می‌دهد. در شدت ۱۷/۶۸٪ نیز، مقدار ۹۶/۳۰٪ برای روش پیشنهادی گزارش شده که



شکل ۱۵: مقایسه عملکرد روش پیشنهادی LSTM [۴۴] بر اساس معیارهای مختلف ارزیابی در فاز آزمون. این مقایسه شامل دقت، صحت، بازخوانی و امتیاز F1 در شدت‌های مختلف عیب.



شکل ۱۶: ماتریس‌های سردرگمی الگوریتم LSTM در [۴۴] در مرحله آزمون برای طبقه‌بندی شدت عیوب مختلف.

بیزی را به کار می‌برد. این روش با پیش‌پردازش سیگنال‌های جریان سه‌فاز از طریق تحلیل DWT و PSD آغاز شد. استخراج ویژگی‌ها با استفاده از معیارهای آماری مانند میانگین، انحراف معیار، کشیدگی و چولگی انجام شد. این ویژگی‌ها سپس از طریق KPCA به منظور

### ۸- نتیجه‌گیری

این مقاله الگوریتمی برای تشخیص شدت عیب ITSC در PMSM ارائه کرده است و ترکیبی از درخت تصمیم‌گیری و شبکه‌های عصبی

- learning and small fault samples," *Neurocomputing*, vol. 442, pp. 348-358, Jun. 2021.
- [12] Y. Li, et al., "A fault diagnosis method based on an improved deep Q-network for the inter-turn short circuits of a permanent magnet synchronous motor," *IEEE Trans. Transp. Electrific.*, vol. 10, no. 2, pp. 3870-3887, Jun. 2024.
- [13] M. Skowron, T. Orłowska-Kowalska, and C. T. Kowalski, "Detection of permanent magnet damage of PMSM drive based on direct analysis of the stator phase currents using convolutional neural network," *IEEE Trans. Ind. Electron.*, vol. 69, no. 12, pp. 13665-13675, Dec. 2022.
- [14] X. Wu, Y. Geng, M. Li, W. Wang, and M. Tu, "Inter-turn short circuit diagnosis of permanent magnet synchronous motor based on Siamese convolutional neural network under small fault samples," *IEEE Sensors J.*, vol. 24, no. 16, pp. 26982-26993, 15 Aug., 2024.
- [15] Q. Chen, X. Dai, X. Song, and G. Liu, "ITSC fault diagnosis for five phase permanent magnet motors by attention mechanisms and multiscale convolutional residual network," *IEEE Trans. Ind. Electron.*, vol. 71, no. 8, pp. 9737-9746, Aug. 2024.
- [16] K. J. Shih, M. F. Hsieh, B. J. Chen, and S. F. Huang, "Machine learning for inter-turn short-circuit fault diagnosis in permanent magnet synchronous motors," *IEEE Trans. Magn.*, vol. 58, no. 8, pp. 1-7, Aug. 2022.
- [17] Q. Song, M. Wang, W. Lai, and S. Zhao, "Multiscale kernel-based residual CNN for estimation of inter-turn short circuit fault in PMSM," *Sensors*, vol. 22, no. 18, Article ID: 6870, Sept. 2, 2022.
- [18] W. Sun, A. R. Paiva, P. Xu, A. Sundaram, and R. D. Braatz, "Fault detection and identification using Bayesian recurrent neural networks," *Comput. Chem. Eng.*, vol. 141, Article ID: 106991, Oct. 2020.
- [19] P. Pietrzak and M. Wolkiewicz, "Machine learning-based stator current data-driven PMSM stator winding fault diagnosis," *Sensors*, vol. 22, no. 24, Article ID: 9668, Dec. 2 2022.
- [20] Y. Qi, M. Zafarani, V. Gurusamy, and B. Akin, "Advanced severity monitoring of interturn short circuit faults in PMSMs," *IEEE Trans. Transp. Electrific.*, vol. 5, no. 2, pp. 395-404, Jun. 2019.
- [21] S. Huang, et al., "Mitigation of interturn short-circuits in IPMSM by using MTPCC control adaptive to fault severity," *IEEE Trans. Power Electron.*, vol. 37, no. 4, pp. 4685-4696, Apr. 2021.
- [22] Y. Qi, E. Bostanci, M. Zafarani, and B. Akin, "Severity estimation of interturn short circuit fault for PMSM," *IEEE Trans. Ind. Electron.*, vol. 66, no. 9, pp. 7260-7269, Sept. 2018.
- [23] C. Fan, M. Chen, X. Wang, J. Wang, and B. Huang, "A review on data preprocessing techniques toward efficient and reliable knowledge discovery from building operational data," *Front. Energy Res.*, vol. 9, Article ID: 652801, Mar. 2021.
- [24] D. Divya, B. Marath, and M. B. Santosh Kumar, "Review of fault detection techniques for predictive maintenance," *J. Qual. Maint. Eng.*, vol. 29, no. 2, pp. 420-441, 2023.
- [25] S. M. Alessio, "Discrete wavelet transform (DWT)," in Silvia Maria Alessio, Ed., *Digital Signal Processing and Spectral Analysis for Scientists: Concepts and Applications*, pp. 645-714, 2016.
- [26] P. K. Rahi and R. Mehra, "Analysis of power spectrum estimation using Welch method for various window techniques," *Int. J. Emerg. Technol. Eng.*, vol. 2, no. 6, pp. 106-109, 2014.
- [27] W. Jung, S. H. Yun, Y. S. Lim, S. Cheong, and Y. H. Park, "Vibration and current dataset of three-phase permanent magnet synchronous motors with stator faults," *Data Brief*, vol. 47, Article ID: 108952, Apr. 2023.
- [28] K. Shen, H. Wang, A. Chaudhuri, and Z. Asgharzadeh, "Automatic Gaussian bandwidth selection for kernel principal component analysis," in *Proc. Int. Conf. Knowl. Sci. Eng. Manag.*, pp. 15-26, Guangzhou, China, 16-18 Aug. 2023.
- [29] L. Breiman, *Classification and Regression Trees*, Routledge, 2017.
- [30] L. Zou, K. J. Zhuang, and J. Hu, "A Bayesian adaptive resize-residual deep learning network for fault diagnosis of rotating machinery," in *Proc. 17th EASEC Conf.*, pp. 783-801, Singapore, 27-30 2022.
- [31] R. M. Neal, *Bayesian Learning for Neural Networks*, vol. 118, Springer, 2012.
- [32] D. J. MacKay, "A practical Bayesian framework for backpropagation networks," *Neural Comput.*, vol. 4, no. 3, pp. 448-472, May 1992.
- [33] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929-1958, 2014.
- [34] I. Goodfellow, *Deep Learning*, vol. 196, MIT Press, 2016.
- [35] A. Graves, "Practical variational inference for neural networks," *Adv. Neural Inf. Process. Syst.*, vol. 24, 2011.

انتخاب ویژگی‌های برجسته‌تر بهینه شدند. مرحله اولیه طبقه‌بندی با استفاده از الگوریتم درخت تصمیم‌گیری انجام شد که موفق به دستیابی به دقت توجه ۹۹/۴٪ در مرحله آموزش و ۹۲/۴٪ در مرحله آزمون گردید. طبقه‌بندی شدت عیوب با استفاده از شش مدل BNN انجام شد که هر کدام برای مدیریت سطوح مختلف شدت عیب آموزش دیده بودند. با افزایش شدت عیب، عملکرد مدل‌های BNN به طور قابل توجهی بهبود یافت. به طور خاص، دقت مدل‌های BNN از ۸۵/۳۳٪ برای شدت عیب ۱/۷۸٪ به ۹۷/۳۳٪ برای شدت عیب ۱۷/۶۸٪ افزایش یافت که نشان‌دهنده بهبود عملکرد با افزایش شدت است. دقت و بازیابی برای کلاس سالم از ۸۵/۵۱٪ و ۸۳/۱۰٪ به ترتیب در شدت عیب ۱/۷۸٪ به ۹۸/۵۵٪ و ۹۵/۷۷٪ در شدت عیب ۱۷/۶۸٪ بهبود یافت. به طور مشابه، دقت و بازیابی برای کلاس معیوب نیز بهبود یافت و مقادیر از ۸۵/۱۹٪ و ۸۷/۳۴٪ به ترتیب به ۹۶/۳۰٪ و ۹۸/۷۳٪ در همان دامنه شدت عیب افزایش یافت. امتیازهای F1 نیز روند مشابهی را دنبال کردند که نشان‌دهنده تعادل بهتر بین دقت و بازیابی با افزایش شدت عیب است. در مقایسه با یکی از روشهای اخیر در این حوزه، روش پیشنهادی در همه شدت‌های عیب، از نظر دقت، بازخوانی، امتیاز F1 و سایر معیارها، عملکرد بهتری دارد. این بهبود به‌ویژه در شدت‌های بالای عیب مشهود است، جایی که روش پیشنهادی می‌تواند نرخ خطا را کاهش داده و تشخیص را دقیق‌تر انجام دهد. نتایج نشان می‌دهد که روش پیشنهادی الگوهای پیچیده را بهتر یاد می‌گیرد و کلاس‌های سالم و معیوب را با دقت بیشتری تفکیک می‌کند، که در نهایت موجب افزایش اطمینان در سیستم تشخیص عیب می‌شود.

## مراجع

- [1] E. A. Bhuiyan, et al., "A survey on fault diagnosis and fault tolerant methodologies for permanent magnet synchronous machines," *Int. J. Autom. Comput.*, vol. 17, pp. 763-787, 2020.
- [2] A. Kilic and F. Weiss, "Early detection of PMSM faults at static and dynamic operating points by using artificial neural network for automated electric vehicle," *J. Braz. Soc. Mech. Sci. Eng.*, vol. 45, no. 9, Article ID: 493, 2023.
- [3] X. Chen, P. Qin, Y. Chen, J. Zhao, W. Li, Y. Mao, and T. Zhao, "Inter-turn short circuit fault diagnosis of PMSM," *Electronics*, vol. 11, no. 10, p. 1576, 2022.
- [4] D. Wang and Y. Chen, "Fault-tolerant control of coil inter-turn short-circuit in five-phase permanent magnet synchronous motor," *Energies*, vol. 13, no. 21, Article ID: 5669, Nov. 1 2020.
- [5] Y. Qin, G. J. Li, C. Jia, and P. McKeever, "Investigation of inter-turn short-circuit fault of PM machines using PWM voltage-based modeling," *IEEE Trans. Transp. Electrific.*, vol. 10, no. 1, pp. 1324-1334, 2023.
- [6] G. Forstner, A. Kugi, and W. Kemmetmüller, "Model-based fault identification of inter-turn winding short circuits in PMSM," in *Proc. Int. Conf. Elect. Mach.*, vol. 1, pp. 1390-1396, Gothenburg, Sweden, 23-26 Aug. 2020.
- [7] D. Niu and D. Song, "Model-based robust fault diagnosis of incipient ITSC for PMSM in elevator traction system," *IEEE Trans. Instrum. Meas.*, vol. 72, Article ID: 3533512, 2023.
- [8] A. Sarikhani and O. A. Mohammed, "Inter-turn fault detection in PM synchronous machines by physics-based back electromotive force estimation," *IEEE Trans. Ind. Electron.*, vol. 60, no. 8, pp. 3472-3484, Aug. 2012.
- [9] M. Fitouri, Y. Bensalem, and M. N. Abdelkrim, "Modeling and detection of the short-circuit fault in PMSM using finite element analysis," *IFAC-PapersOnLine*, vol. 49, no. 12, pp. 1418-1423, 2016.
- [10] Y. Qi, E. Bostanci, V. Gurusamy, and B. Akin, "A comprehensive analysis of short-circuit current behavior in PMSM interturn short-circuit faults," *IEEE Trans. Power Electron.*, vol. 33, no. 12, pp. 10784-10793, Dec. 2018.
- [11] Y. Li, Y. Wang, Y. Zhang, and J. Zhang, "Diagnosis of inter-turn short circuit of permanent magnet synchronous motor based on deep

**سید محسن سید موسوی** تحصیلات خود را در مقطع کارشناسی و کارشناسی ارشد مهندسی برق به ترتیب در سال‌های ۱۳۷۶ و ۱۳۷۸ از دانشگاه یزد و تربیت مدرس تهران به اتمام رساند و از سال ۱۳۷۸ همکاری خود را با دانشگاه آزاد اسلامی آغاز نمود پس از آن به دوره دکترای مهندسی برق در دانشگاه آزاد اسلامی واحد علوم تحقیقات تهران وارد گردید و در سال ۱۳۹۶ موفق به اخذ درجه دکترا در مهندسی برق از دانشگاه مذکور گردید. هم‌اکنون وی استادیار دانشکده فنی و مهندسی دانشگاه آزاد اسلامی واحد اهواز است، زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: کنترل سیستم‌های صنعتی، تشخیص عیب سیستم‌های تعیین موقعیت کنترل سیستم‌های حفاری انحرافی.

**بهزاد مشیری** در سال ۱۳۶۲ در رشته مهندسی مکانیک از دانشگاه علم و صنعت ایران فارغ‌التحصیل شده و مقاطع کارشناسی ارشد و دکترا را در رشته مهندسی سیستم‌های کنترل از دانشگاه منچستر انگلستان در سال ۱۳۶۶ و ۱۳۷۰ به ترتیب اخذ نمود ایشان از سال ۱۳۷۰ به دانشگاه تهران پیوست و در حال حاضر به عنوان استاد دانشکده مهندسی برق و کامپیوتر فعالیت دارد ایشان عضو ارشد موسسه IEEE می‌باشند. زمینه‌های تحقیقاتی نامبرده عبارتند از: کنترل فرآیند، ابزار دقیق پیشرفته، اتوماسیون صنعتی پیشرفته، ترکیب اطلاعات سنسوری، حمل و نقل هوشمند و مگاترونیک.

- [36] J. Yan, S. Senemmar, and J. Zhang, "Inter-turn short circuit fault diagnosis and severity estimation for wind turbine generators," in *J. Phys.: Conf. Ser.*, vol. 2767, no. 3, Article ID: 032021, 2024.
- [37] L. Breiman, *Classification and Regression Trees*, Routledge, 2017.
- [38] L. Zou, K. J. Zhuang, and J. Hu, "A Bayesian adaptive resize-residual deep learning network for fault diagnosis of rotating machinery," in *Proc. 17th East Asian-Pacific Conf. Struct. Eng. Constr.*, pp. 783-801, Singapore, 27-30 Jun. 2022.
- [39] R. M. Neal, *Bayesian Learning for Neural Networks*, vol. 118, Springer, 2012.
- [40] D. J. MacKay, "A practical Bayesian framework for backpropagation networks," *Neural Comput.*, vol. 4, no. 3, pp. 448-472, May 1992.
- [41] N. Srivastava, G. Hinton, A. Krizhevsky, I. Sutskever, and R. Salakhutdinov, "Dropout: a simple way to prevent neural networks from overfitting," *J. Mach. Learn. Res.*, vol. 15, no. 1, pp. 1929-1958, Jan. 2014.
- [42] I. Goodfellow, Y. Bengio, and A. Courville, *Deep Learning*, MIT Press, 2016.
- [43] A. Graves, "Practical variational inference for neural networks," *Adv. Neural Inf. Process. Syst.*, vol. 24, 2011.
- [44] J. Yan, S. Senemmar, and J. Zhang, "Inter-turn short circuit fault diagnosis and severity estimation for wind turbine generators," *J. Phys.: Conf. Ser.*, vol. 2767, no. 3, Article ID: 032021, 2024.

**عباس درویشی** در سال‌های ۱۳۷۰ و ۱۳۷۳ به ترتیب در رشته‌های مهندسی الکترونیک و مهندسی شیمی از دانشگاه نفت اهواز و دانشگاه آزاد اسلامی واحد ماهشهر فارغ‌التحصیل شد و مقاطع کارشناسی ارشد مهندسی شیمی را از دانشگاه نفت در سال ۱۳۷۷ اخذ نموده و از سال ۱۳۹۴ در مقطع دکترا سیستم‌های کنترل در دانشگاه آزاد اهواز وارد گردید. زمینه‌های تحقیقاتی مورد علاقه ایشان عبارتند از: کنترل فرآیندهای پتروشیمی، ابزار دقیق پیشرفته، تشخیص عیب، سیستم‌های کنترل پیشرفته و اتوماسیون صنعتی ویژه فرآیندهای پتروشیمی.