

بررسی کاهش نویز در تحلیل سیگنال در عیب‌یابی ماشین‌های دوار توسط شبکه عصبی

حامد پورهاشم، علی جمالی*، نادر نریمان زاده، علی چائی بخش

دانشکده مهندسی مکانیک، دانشگاه گیلان، گیلان، ایران

چکیده

عیب‌یابی سیستم‌های مکانیکی برای عملکرد بهتر سیستم و همچنین محافظت از آن، دارای اهمیت ویژه‌ای می‌باشد. در این پژوهش از یک سیستم آزمایشگاهی ماشین دوار برای تولید سیگنال استفاده شده است. داده‌های بدست آمده در فرآیند پیش پردازش قرار می‌گیرند. در این مقاله برای بهبود عملکرد تحلیل سیگنال روش ترکیبی تحلیل توسط ویژگی‌های سیگنال و فیلتر کالمن پیشنهاد می‌شود. ابتدا برای کاهش نویز سیگنال‌ها از فیلتر کالمن استفاده می‌شود. و در ادامه برای پیش پردازش سیگنال ویژگی‌های سیگنال در حوزه زمان و حوزه فرکانس پیشنهاد می‌شود که از آن به عنوان پیش‌پردازش یک بعدی سیگنال استفاده شده است. در ادامه برای تحلیل ویژگی‌های بدست آمده از کلاس‌بندهای ماشین بردار پشتیبان، شبکه عصبی پرسپترون چند لایه و شبکه عصبی پیچشی استفاده شده است. برای بررسی نتایج داده‌ها به دسته داده‌های آموزشی و داده‌های صحت سنجی تقسیم‌بندی می‌شود. نتایج دقت برای داده‌های صحت سنجی در روش‌های مختلف مورد بررسی قرار می‌گیرد. نتایج حاکی از عملکرد بهتر شبکه عصبی پیچشی الکسنت در حضور فرآیند کاهش نویز با فیلتر کالمن می‌باشد. این شبکه به طور میانگین به دقت ۹۶/۱ درصد برای داده‌های صحت سنجی رسیده است که نسبت به سایر کلاس‌بندها و همچنین نسبت به عیب‌یابی بدون کاهش نویز، دقت آن بهبود یافته است.

کلمات کلیدی

عیب‌یابی، کاهش نویز، فیلتر کالمن، شبکه عصبی، پردازش سیگنال.

* آدرس پست الکترونیک نویسنده مسئول: ali.jamli@guilan.ac.ir

با توجه به پیشرفت در سیستم‌های مکانیکی و افزایش اهمیت در تعمیر و نگهداری آنها، عیب‌یابی هوشمند این سیستم‌ها نیز همواره از اهمیت بیشتری برخوردار می‌شود. عیب در سیستم‌ها می‌تواند منجر به آسیب‌های جدی به سیستم شود و باعث ایجاد مشکلات بزرگتری شود. از این رو شناسایی عیب در مراحل که هنوز به صورت جدی پیشرفت نکرده است، حائز اهمیت می‌باشد. افزایش اعتمادپذیری سیستم و همچنین تضمین امنیت آن اهمیت عیب‌یابی را افزایش می‌دهند. این موضوع در سیستم‌های دوار نظیر پمپ‌ها، کمپرسورها، توربین‌ها و موتورها که از اجزای مهم سیستم‌های مکانیکی می‌باشند، نیز از اهمیت ویژه‌ای برخوردار است. در مواردی افزایش هزینه‌های مصرفی مانند مصرف انرژی بیشتر و در نتیجه آلاینده‌گی بیشتر که از عیب سیستم ناشی می‌شوند، مشاهده می‌شود و این در حالی است که سیستم ظاهراً درست کار می‌کند. از این رو عیب‌یابی می‌تواند عیب‌های مخفی سیستم را آشکار سازد و به نحوی مصرف انرژی و هزینه‌های مشابه را کاهش دهد. در مجموع برای داشتن عملکرد بهینه یک سیستم و تنظیم بهتر آن در بازه و عملکرد، عیب‌یابی امری مهم در سیستم‌های متفاوت به ویژه سیستم‌های دوار باشد.

استفاده عملی عیب‌یابی ماشین‌های دوار را می‌توان در صنایع تولیدی مانند صنعت خودروسازی، تولیدات فولاد، صنایع پتروشیمی و مواردی دیگر که ماشین‌های دوار در آنها نقش کلیدی دارند، مشاهده نمود. با استفاده از سیستم‌های عیب‌یابی ماشین‌های دوار، می‌توان توقفات ناگهانی خطوط تولید را به حداقل رساند و عیب‌هایی که به طور معمول به دلیل فرسایش و استهلاک در ماشین‌های دوار اتفاق می‌افتد را به صورت زودهنگام شناسایی و رفع نمود. در صنایع نفت و گاز، ماشین‌های دوار نقش بسیار مهمی در فرآیندهای حیاتی مانند حفاری، پمپاژ، فرآوری و... دارند. از این رو استفاده از سیستم‌های عیب‌یابی ماشین‌های دوار می‌تواند به بهبود کارایی، ایمنی و کاهش هزینه‌ها در این صنعت نیز کمک کند. در صنایع پیشرفته‌تر مانند صنعت هواپیما، فضا، الکترونیک و... نیز از ماشین‌های دوار پیچیده و حساس استفاده می‌کنند. که این موضوع اهمیت عیب‌یابی سیستم‌های دوار را افزایش می‌دهد. به طور کلی، عیب‌یابی ماشین‌های دوار در هر صنعتی که از ماشین‌های دوار استفاده می‌شود، اهمیت دارد و می‌تواند به بهبود عملکرد، افزایش بهره‌وری، کاهش هزینه‌ها و افزایش ایمنی کمک کند.

در این راستا می‌توان برای سیستم‌های مکانیکی نظیر ماشین‌های دوار، جعبه دنده و مواردی این چنین، پردازش سیگنال‌های ارتعاشی را پیشنهاد داد. این سیگنال‌ها می‌توانند در تشخیص عیب بسیار موثر عمل کرده و قبل از اینکه عیب سیستم آشکار شود آن عیب را شناسایی کنند. برای این منظور روش‌های متعددی پیشنهاد شده است که در این بین به کارهای انجام شده در عیب‌یابی سیستم‌های دوار و همچنین اهمیت پردازش سیگنال در آن اشاره می‌شود.

روش تبدیل فوریه زمان کوتاه^۱ یکی از روش‌های تحلیل در حوزه زمان-فرکانس می‌باشد که به عنوان مثال جونیور و همکاران برای عیب‌یابی سیستم موتور الکتریکی در ماشین‌های دوار از آن به عنوان پیش پردازش سیگنال استفاده کرده‌اند [۱]. زکی زاده و همکاران برای عیب‌یابی سیستم دوار بلوتر لکوموتیوهای آلستوم از آنالیز ارتعاشی و ماشین بردار پشتیبان استفاده کردند. در این پژوهش جهت کاهش تعداد ویژگی‌ها از آزمون فیلترتی استفاده شده است [۲]. در مرجع [۳] برای عیب‌یابی یاتاقان غلتشی که از اصلی‌ترین اجزاء در ماشین‌های دوار می‌باشد، روشی مبتنی بر بررسی محتوای منحنی پوش سیگنال‌های اندازه‌گیری شده، ارائه شده است. شکارزاده و همکاران در مرجع [۴] برای تشخیص عیب یاتاقان‌های سانتریفیوژ با استفاده از داده‌های آزمایشگاهی، روش تحلیل مولفه‌های غیروابسته و بهینه سازی دسته ذرات را ارائه دادند. در این پژوهش از ویژگی‌ها در حوزه زمان استفاده شد. در مرجع [۵] نویسندگان برای تشخیص عیب ماشین‌های دوار با استفاده از روش تحلیل اجزای اصلی ابعاد ویژگی‌ها را کاهش داده و با استفاده از شبکه فازی-عصبی و شبکه عصبی چند لایه عیب‌یابی را انجام دادند.

استخراج ویژگی از سیگنال به صورت یک بعدی در تحلیل سیگنال می‌تواند بسیار مفید باشد که به نمونه‌هایی از آن نیز اشاره شد. از جمله برتری‌های این روش سادگی و محاسبات کمتر آن نسبت به تحلیل دو بعدی سیگنال می‌باشد و در عین حال این روش می‌تواند موثر باشد. در مراجع [۶، ۷] نویسندگان از ویژگی‌های حوزه زمان و استخراج یک بعدی ویژگی‌ها برای عیب‌یابی یاتاقان‌ها استفاده کرده

¹ Short time Fourier transform

است. بررسی آنالیز خود همبستگی ویژگی‌ها نیز می‌تواند در تحلیل سیگنال برای عیب‌یابی موثر واقع شود [۸]. استخراج ویژگی‌ها در حوزه زمان و حوزه فرکانس می‌تواند به همراه تجزیه سیگنال‌ها به صورت چند بعدی نیز انجام شود که روش تجزیه حالت تجربی^۱ روشی مناسب برای تجزیه یک سیگنال است [۹].

علاوه بر پردازش سیگنال در حوزه‌های مختلف، کاهش نویز سیگنال‌ها حائز اهمیت می‌باشد. اهمیت این موضوع از آن جهت است که سیگنال‌هایی که از یک سیستم گرفته می‌شوند عموماً تحت تاثیر اغتشاشات و نویزهای خارجی مانند امواج الکترومغناطیس قرار می‌گیرند. در این زمینه برای سیگنال ارتعاشی ماشین دوار، روش حذف نویز با کمک تجزیه مد تجربی و بررسی شباهت بین تابع چگالی احتمال سیگنال اصلی با مودهای آن توسط نظامیوند و همکاران در مرجع [۱۰] ارائه شد. استفاده از روش آستانه‌گذاری نرم بعد از تجزیه سیگنال روش موجه تجربی، می‌تواند در کاهش نویز سیگنال‌ها موثر باشد. این روش در مرجع [۱۱] برای سیگنال‌های ارتعاشی ماشین دوار پیشنهاد شده است. در مرجع [۱۲] از روش ترکیبی تبدیل موجه کسری^۲ برای کاهش نویز سیگنال استفاده شده است، به این صورت که از تبدیل موجه برای کاهش نویز و از تبدیل فوری کسری برای تحلیل در حوزه زمان-فرکانس استفاده شده است. در مرجع [۱۳] نمونه‌هایی از نویزهای مختلف که می‌تواند در عیب‌یابی سیستم هیدروژنراتور اتفاق بیفتد، مورد بررسی قرار گرفته است. علاوه بر روش تبدیل موجه که پیشتر به آن اشاره شد، فیلتر کالمن هم نیز می‌تواند در کاهش نویز موثر باشد. یکی از کاربردهای این روش کاهش نویزهای رنگی موثر است [۱۴]. نویسندگان در مرجع [۱۵] یک روش جدید ترکیبی فیلتر کالمن بدون عطر^۳ و منطق فازی ارائه دادند که برای تنظیم کوواریانس نویز اندازه‌گیری به صورت تطبیقی از منطق فازی استفاده می‌شود. ترکیب فیلتر کالمن و همچنین روش تجزیه مد تجربی نیز می‌تواند در کاهش نویز موثر باشد [۱۶]. از دیگر کاربردهای فیلتر کالمن در عیب‌یابی می‌توان تخمین حالات برای سیستم را نام برد که به عنوان مثال در تشخیص عیب حس گر می‌تواند موثر باشد [۱۷]. عیب‌یابی با تخمین زاویه گام تیغه و موقعیت قرقره سوپاپ توربین باد شناور توسط فیلتر کالمن، از دیگر کارهایی است که در این زمینه انجام شده است [۱۸].

در عیب‌یابی سیستم‌ها بعد از مرحله پیش پردازش سیگنال استفاده از ابزارهای یادگیری ماشین^۴ بسیار موثر است. در این بین می‌توان ماشین بردار پشتیبان^۵ [۱۵] و یا شبکه‌های عصبی پیچشی^۶ [۱۹] و یا شبکه عصبی پرسپترون چند لایه^۷ [۲۰] را به عنوان روش‌هایی مرسوم یادگیری ماشین در عیب‌یابی سیستم‌ها مثال زد. ترکیب این روش‌ها با یکدیگر و همچنین ترکیب آنها با پیش پردازش های مختلف می‌تواند نتایج خوبی ارائه دهد. به عنوان مثال در مرجع [۲۰] پارامترهای شبکه عصبی پرسپترون توسط فیلتر کالمن بدون عطر تنظیم می‌شود. در مرجع [۲۱] نویسندگان با ترکیب روش ماشین بردار پشتیبان و تبدیل استوکویل^۸ و با انتخاب اکتشافی ویژگی‌ها روشی برای تشخیص عیب اولیه در سیم پیچ‌های استاتور یک موتور القایی ارائه داده‌اند. نویسندگان در [۲۲] برای عیب‌یابی باتری لیتیوم-یونی با مدلسازی باتری و محاسبه خطای باقیمانده، شدت نویز را توسط فیلتر کالمن بدون عطر کاهش دادند و از آن برای داده‌های آموزشی روش ماشین بردار پشتیبان استفاده کرده‌اند. در نمونه دیگر زمانی و همکاران در مرجع [۲۳] برای عیب‌یابی توربین باد با استفاده از فیلتر کالمن به عنوان تخمین‌گر حالت باقیمانده‌های مناسب را ایجاد کردند و با از شبکه فازی-عصبی برای ارزیابی و کلاس‌بندی عیب‌ها استفاده کردند.

همانطور که تاکید شد، کاهش نویز سیگنال‌ها همواره در عیب‌یابی سیستم بسیار موثر می‌باشد. باید توجه داشت محدودیت‌هایی مانند عدم اطلاع دقیق از قدرت نویز و یا به عبارت دیگر میزان آلودگی سیگنال به نویز می‌تواند چالش برانگیز باشد. از این رو پارامترهای یک فیلتر در کاهش نویز سیستم بسیار دخیل هستند و تنظیم دقیق آنها نیز بسیار حائز اهمیت است، به نحوی که کیفیت سیگنال

¹ Empirical Mode Decomposition

² fractional Wavelet Transform

³ Unscented Kalman filter

⁴ Machine Learning

⁵ Support Vector Machine

⁶ Convolutional Neural Network

⁷ Multilayer perceptron

⁸ Stockwell transform

کاهش نیابد و در عین حال اطلاعات غیرمفید نیز از آن حذف شود و در نتیجه دقت و عملکرد سیستم عیب‌یابی افزایش یابد. در این پژوهش علاوه بر کاهش نویز و طبقه‌بندی سیگنال‌ها تنظیم پارامتر نامعلوم کوواریانس نویز مد نظر قرار داده شده است.

در این مقاله روشی جدید برای عیب‌یابی ماشین دوار مبتنی بر استخراج ویژگی در هر دو حوزه زمان و فرکانس و ترکیب آن با روش فیلتر کالمن و شبکه عصبی، ارائه می‌شود. ابتدا سیگنال‌های اولیه توسط فیلتر کالمن نویززدایی می‌شوند. برای این منظور از آنجایی که اطلاعات دقیق در مورد نویز وجود ندارد، کوواریانس نویز سیگنال با آزمایش و تکرار بدست آورده شد. در ادامه با استخراج ویژگی در حوزه زمان و همچنین استخراج ویژگی در حوزه فرکانس که با کمک روش تبدیل سریع فوریه^۱ داده‌های اولیه برای پردازش نهایی آماده می‌شوند. در ادامه این داده‌های اولیه به عنوان داده‌های آموزشی به شبکه عصبی‌های مختلف تغذیه می‌شوند. در قسمت دوم این مقاله نحوه جمع‌آوری داده‌های آزمایشگاهی و آماده سازی آن توضیح داده می‌شود. در قسمت سوم فیلتر کالمن معرفی می‌شود و فرآیند کاهش نویز سیگنال در این قسمت بیان می‌شود. در ادامه در قسمت چهارم از این مقاله نحوه استخراج ویژگی‌ها در حوزه زمان و فرکانس بیان می‌شود و در قسمت پنجم از این مقاله نتایج نهایی آموزش شبکه‌های عصبی مختلف برای داده‌های آماده شده نمایش داده می‌شود.

۲- جمع‌آوری داده‌های آزمایشگاهی

همانطور که در قسمت قبل بیان شد، در این پژوهش از داده‌های آزمایشگاهی سیستم ماشین دوار استفاده می‌شود. از دلایل استفاده از داده‌های آزمایشگاهی می‌توان به بررسی اصول بنیادی سیستم‌های دوار در یک محیط کنترل شده آزمایشگاهی اشاره کرد، که این می‌تواند برای ساخت یک مدل واقعی با دقت بالا و همچنین عیب‌یابی آن حائز اهمیت باشد. به این ترتیب می‌توان عیب‌های مختلف این سیستم را در یک محیط با خطرهای احتمالی کمتری شبیه‌سازی کرد و قابلیت اطمینان آن را زیر نظر گرفت و در ادامه این سیستم اولیه را برای یک محیط واقعی تعمیم داد. از جمله دیگر مزایای داده‌های آزمایشگاهی بررسی روش‌های نوین و تکنولوژی‌های جدید است که برای پیشرفت در یک زمینه بسیار حائز اهمیت می‌باشد. مقایسه روش‌های مختلف و ایده‌های نوین نیز با داده‌های آزمایشگاهی میسر می‌شود. در حالی که اگر ایده‌های جدید بر روی یک سیستم واقعی پیاده شود، در صورت عدم موفقیت آمیز بودن آن، می‌تواند منجر هزینه‌های سنگین شود. از این رو بررسی داده‌های آزمایشگاهی علاوه بر اهداف آموزشی و تئوری در پیشرفت تکنولوژی‌های موجود می‌توان بسیار موثر واقع شود.

سیستم آزمایشگاهی مورد استفاده در این پژوهش در شکل ۱ نمایش داده شده است. سیستم مذکور شامل یک موتور جریان متناوب^۲ می‌شود که به یک میله متصل است و این میله بر روی سه یاتاقان سوار می‌شود. این سیستم دارای دیسک‌هایی است که می‌توان برای عیب عدم تعادل از آن استفاده کرد. برای ثبت داده‌های سیگنال از دو سنسور شتاب‌سنج استفاده شده است که بر روی یاتاقان اول و دوم (از سمت راست) استفاده شده است. محل قرارگیری یاتاقان‌ها در شکل ۱ معلوم است. به این ترتیب در عیب‌یابی یاتاقان‌ها، علاوه بر یاتاقان‌های دارای سنسور، یاتاقان بدون سنسور نیز مورد تحلیل قرار می‌گیرد. در نحوه قرارگیری سنسورها با فاصله دادن آنها از موتور و مبدل فرکانس در ورودی موتور، تلاش شده تا اثرات نویز را کاهش داد، هر چند همواره نویز به سیگنال‌های سیستم وارد می‌شود، اما با این کار تلاش برای به حداقل رساندن آن شده است.


برای ثبت سیگنال‌های آزمایشی در سیستم ماشین دوار، سه نوع عیب به سیستم وارد می‌شود. عیب‌های وارده شامل عیب ساچمه یاتاقان (عیب کلاس ۱)، عیب رینگ خارجی یاتاقان (عیب کلاس ۲) و نابالانس بودن میله (عیب کلاس ۳) می‌باشد. علت در نظر گرفتن این عیب‌ها این است که میله و یاتاقان اجزای اصلی و مشترک سیستم‌های مکانیکی دوار می‌باشند. عیب نابالانس بودن میله یکی از عیب‌های رایج در سیستم‌های دوار می‌باشد که عوامل مختلفی می‌تواند منجر شود. این عیب می‌تواند در فرآیند تولید و یا نصب میله بوجود آید، که یکی از دلایل آن می‌تواند تراز کردن نادرست میله باشد. از عوامل دیگر در بروز این مشکل لرزش و یا ارتعاشات نامطلوب در سیستم است که می‌تواند ناشی از بارهای نامطلوب بر روی میله و یا عیب‌های احتمالی بوجود آمده در سیستم باشد. عیب‌های در نظر گرفته شده برای یاتاقان جزء عیب‌های متداول یاتاقان‌ها در سیستم‌های دوار می‌باشد که به دلایل مختلفی از جمله عدم گریس‌کاری

¹ Fast Fourier Transform

² Alternating current

مناسب، ورود ذرات غبار یا فلزی بوجود می‌آید. همچنین بهم خوردن توازن میله و سایش یکطرفه نیز می‌تواند باعث ایجاد عیب‌های یاتاقان شود. در ثبت سیگنال برای سیستم علاوه بر حالات معیوب سیستم، در حالت سیستم سالم نیز از سنسورها سیگنال دریافت می‌شود.

برای ثبت سیگنال در هر حالت از معیوب یا سالم بودن سیستم، فرکانس تغذیه موتور را در بازه ۸ تا ۳۰ هرتز با گام ۲ هرتز تغییر دادیم یعنی فرکانس تغذیه موتور به صورت ۸، ۱۰، ۱۲، ...، ۳۰ هرتز می‌باشد. موتور استفاده شده دارای دور نامی ۲۸۲۵ دور بر دقیقه در فرکانس تغذیه ۵۰ هرتز است و توان ۳۷۰ وات دارد.



شکل ۱: ماشین دوار آزمایشگاهی جهت ثبت داده

Figure 1: Laboratory rotating machine for data recording

در حالت کلی برای ثبت داده سیستم، یک حالت سالم برای سیستم در نظر گرفته شده است. در حالت عیب ساچمه یاتاقان، یاتاقان معیوب در سه موقعیت مطابق شکل ۱ قرار می‌گیرد. در حالت عیب رینگ خارجی یاتاقان مشابه حالت قبل یاتاقان معیوب در سه موقعیت قرار می‌گیرد و برای عیب نابالانس بودن میله، وزنه بر هم زنده تعادل بر روی هر کدام از شش دیسک سوار بر میله دوار قرار می‌گیرد (شکل ۱). پس در مجموع با توضیحات داده شده در حالت کلی سیستم معیوب و سالم، ۱۳ حالت برای سیستم داریم. در نتیجه با توجه به اینکه داده‌ها در این ۱۳ حالت در ۱۲ فرکانس تغذیه مختلف برای موتور ثبت می‌شوند، در نتیجه ۱۵۶ داده اولیه ساخته می‌شود. هر کدام از این ۱۵۶ داده اولیه شامل دو سیگنال یک دقیقه‌ای (دو سنسور در سیستم وجود دارد) و ۴ برجسب حالت سیستم یعنی سالم، عیب ۱، عیب ۲ و عیب ۳ است که عیب‌ها به ترتیب بیانگر عیب ساچمه یاتاقان، عیب رینگ خارجی یاتاقان عیب نابالانس بودن میله می‌باشند. برای ثبت هر داده سیگنال، در هر ثانیه ۱۰۰۰ نمونه ثبت شده است.


به این ترتیب با توجه به بالا بودن فرکانس داده‌برداری و رزولوشن بالای سیگنال، شناسایی دقیق‌تر جزئیات به خصوص در فرکانس‌های بالاتر امکان‌پذیر می‌شود. این امر در سیگنال‌های پویا و ارتعاشی اهمیت بیشتری دارد تا جزئیات دقیق‌تری از سیگنال شناسایی شود. برای ثبت دقیق‌تر اطلاعات زمانی و شناسایی بهتر ویژگی‌های حوزه زمان، زمان ثبت سیگنال یک دقیقه در نظر گرفته شد. در مجموع در سیگنال‌هایی که فرکانس بالای داده‌برداری وجود دارد، زمان بیشتر در ثبت اطلاعات می‌تواند برای جمع‌آوری اطلاعات موثر واقع شود و با افزایش زمان سیگنال می‌توان اثرات نویز را در ویژگی‌های موجود در سیگنال کاهش داد. افزایش بیش از حد فرکانس داده‌برداری و همچنین زمان ثبت داده‌ها نیازمند حافظه بیشتر برای ذخیره داده‌ها و همچنین پردازش پیچیده‌تر داده‌ها می‌باشد. از این رو سیگنال‌های با فرکانس بالا و زمان ثبت بالا نیازمند سخت‌افزار قوی‌تری می‌باشند.

برای جداسازی داده‌های آموزشی و داده‌های صحت‌سنجی از روش تصادفی هدفمند استفاده شده است. ۳۱ داده از ۱۵۶ داده (چیزی حدود ۲۰ درصد) به عنوان داده‌های صحت‌سنجی استفاده می‌شود. برای این منظور در هر حالت از عیب ۲ یا ۳ داده برای صحت‌سنجی کنار گذاشته می‌شود. برای مثال در حالت عیب ساچمه یاتاقان شماره ۱ (از سمت راست یاتاقان اول) که در ۱۲ دور موتور متفاوت ثبت شده است، به صورت تصادفی ۲ یا ۳ سیگنال برای داده صحت‌سنجی انتخاب می‌شود. برای کاهش اثر جداسازی داده‌ها (آموزشی و

صحت سنجی) بر روی نتایج نهایی پژوهش، این جداسازی را ۵ بار انجام شده است تا نتایج را بتوان بهتر تحلیل کرد. یعنی در حالت کلی ۵ نوع دسته داده آموزشی و صحت سنجی ایجاد می‌شود.

۳- فیلتر کالمن

فیلتر کالمن یک روش حداقل مربعات خطای بازگشتی بیزین^۱ برای تخمین سیگنال‌هایی است که در یک فرآیند تغییر پیدا کرده و یا در قسمت مشاهده سیگنال نویز وجود داشته است. از فیلتر کالمن می‌توان برای فرآیندهای متغیر با زمان^۲ و همچنین فرآیندهای تغییر ناپذیر با زمان^۳ استفاده کرد. این فیلتر از توزیع احتمال که در سیگنال و نویز وجود دارد، استفاده می‌کند و فرض می‌شود فرآیندهای گاوسی با میانگین صفر هستند. این فیلتر همچنین فرض می‌کند که پارامترهای مدل سیگنال و تولید نویز و معادلات اندازه‌گیری^۴ از قبل مشخص هستند [۲۴، ۲۵]. فرآیند الگوریتم فیلتر کالمن در شکل ۲ نمایش داده شده است.



شکل ۲: فرآیند الگوریتم فیلتر کالمن [۲۵]

Figure 2: Kalman filter algorithm process

معادلات سیستمی که فیلتر کالمن به آن اعمال می‌شود، به صورت معادلات (۱) و (۲) در نظر گرفته می‌شود.

$$x(m) = A x(m-1) + B u(m) + e(m) \quad (1)$$

$$y(m) = H x(m) + n(m) \quad (2)$$

در سیستم معرفی شده $x(m)$ یک سیگنال p بعدی یا پارامتر حالت در لحظه m می‌باشد. A ماتریس انتقال حالت $p \times p$ است. ماتریس B ماتریس کنترل $p \times n$ می‌باشد که n ابعاد ورودی کنترل است. $u(m)$ ورودی کنترلی n بعدی است و $e(m)$ ورودی p بعدی به عنوان تحریک نامرتبط در ورودی است، این سیگنال یک فرآیند گاوسی با میانگین صفر و کوواریانس Q در نظر گرفته می‌شود. $n(m)$ نیز بردار نویز در اندازه‌گیری با ابعاد M در خروجی است و دارای میانگین صفر و کوواریانس R است. M ابعاد خروجی $y(m)$ می‌باشد. در نهایت H نیز یک ماتریس اعوجاج کانال با ابعاد $M \times p$ است.

در این پژوهش با توجه به اینکه فیلتر کالمن بر روی سیگنال یک بعدی اعمال می‌شود، فرض می‌شود نویز در معادلات اندازه‌گیری سیستم وارد شده است. برای این منظور پارامتر کوواریانس مرتبط با نویز مدل سیگنال صفر در نظر گرفته شده است. در معادلات اندازه‌گیری برای پارامتر کوواریانس R با توجه به اینکه اطلاعات دقیقی از آن موجود نیست، به صورت سعی و خطا سه مقدار 0.25 و 0.5 و 0.75 داده شده است. در واقع این مقدار R برای نویز سیگنال اندازه‌گیری شده در سنسور در نظر گرفته شده است. پارامتر R در بروز رسانی مدل و تصحیح پیش‌بینی‌ها بکار می‌رود.

شکل ۳ مثالی از سیگنال‌های اصلی و سیگنال‌های نویززدایی شده توسط فیلتر کالمن در این پژوهش را نمایش می‌دهد. همانطور که از این شکل مشخص است، هرچه کوواریانس نویز معادلات اندازه‌گیری بزرگ‌تر در نظر گرفته شود سیگنال نویززدایی شده دارای

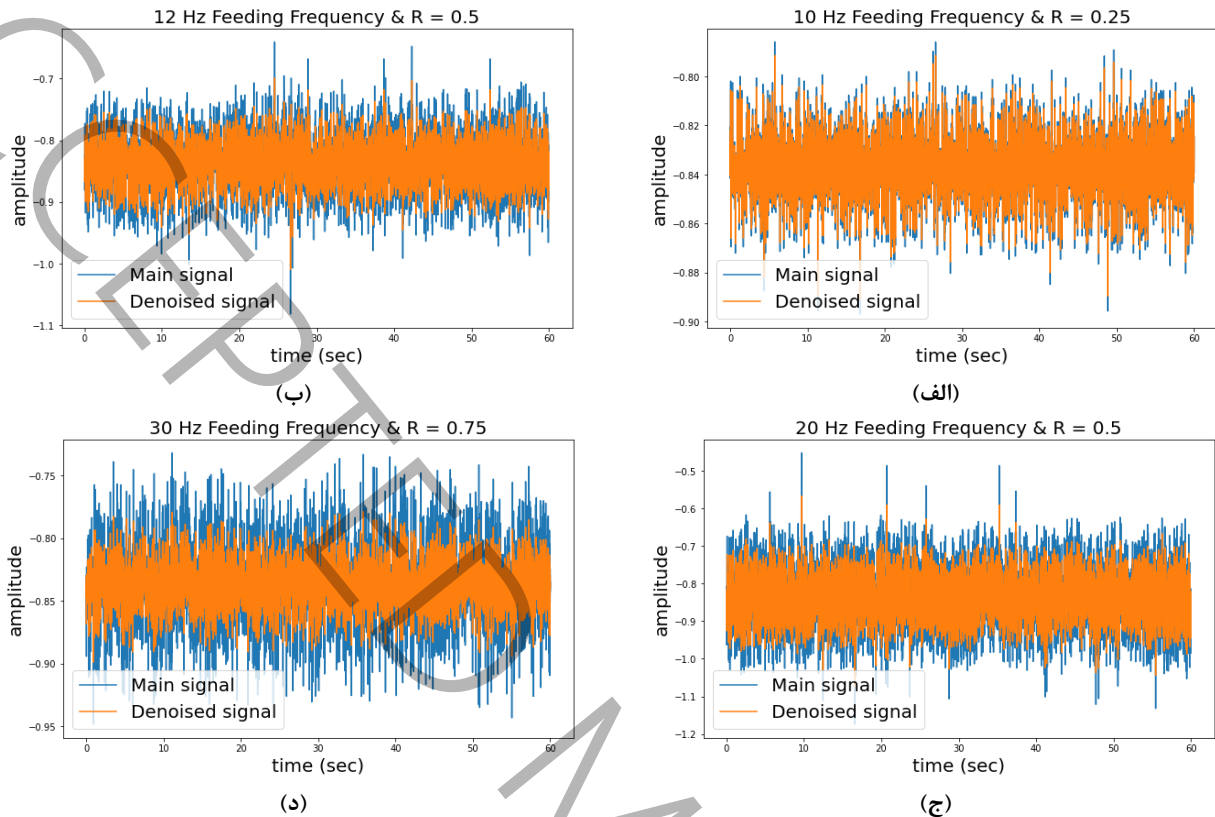
¹ Bayesian recursive least square error

² time-varying

³ time-invariant

⁴ Channel distortion

اندازه کوچکتری و قدرت کمتری می‌شود. شکل ۴ نیز طیف توان سیگنال‌ها قبل و بعد از کاهش نویز توسط فیلتر کالمن را نمایش می‌دهد. همانطور که از شکل ۴ مشخص است، فرکانس‌های بالا بعد از کاهش نویز تضعیف می‌شوند.



شکل ۳: نمونه سیگنال سیستم و کاهش نویز آن به ازاء (الف) سیستم سالم (ب) سیستم با عیب ساچمه یاتاقان (ج) سیستم با عیب رینگ خارجی یاتاقان (د) سیستم با عیب نابالانس بودن میله

Figure 3: System signal sample and its noise reduction for (a) Healthy system (b) System with bearing ball fault (c) System with bearing outer ring fault (d) System with shaft unbalance fault

برای بررسی دقیق‌تر تاثیر کاهش نویز انجام شده بر روی سیگنال‌ها از معیار نرخ سیگنال به نویز^۱ استفاده می‌شود. نرخ سیگنال به نویز در واقع نسبت قدرت سیگنال اصلی و نویز را در واحد dB نمایش می‌دهد و به نحوی بیانگر کیفیت سیگنال می‌باشد [۲۶]. به این ترتیب با توجه به اینکه ۱۵۶ سیگنال مختلف توسط دو سنسور ثبت شده‌اند، مقادیر نسبت نویز به سیگنال برای هر کدام از این سیگنال‌ها محاسبه شد و در شکل ۵ بیشینه مقدار نرخ سیگنال به نویز در کاهش نویز کل سیگنال‌ها که توسط سنسورهای ۱ و ۲ ثبت شده‌اند، نمایش داده می‌شود. این نمایش به ازاء کوواریانس‌های اندازه‌گیری متفاوت در روش فیلتر کالمن می‌باشد.

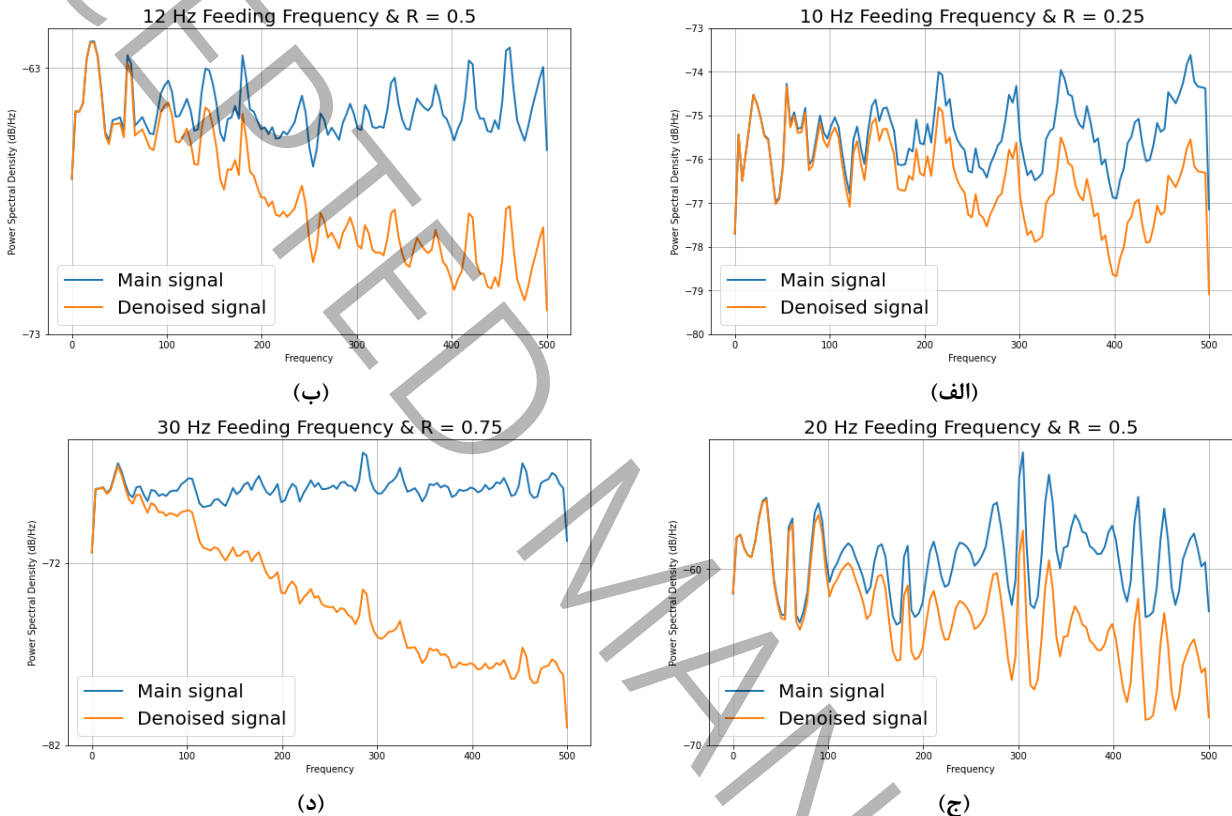
برای بررسی عملکرد فیلتر کالمن در کاهش نویز، از یک فیلتر پایین‌گذر باترورث^۲ مرتبه ۴ استفاده شده است [۲۷] و با آن مقایسه شده است. هر چه مرتبه فیلتر پایین‌گذر باترورث بیشتر شود، بعد از فرکانس قطع، قدرت طیف سیگنال بیشتر کاهش پیدا می‌کند و قبل از آن قدرت طیف سیگنال کمتر کاهش پیدا می‌کند. استفاده از فیلتر مرتبه ۴ تا حد معقولی می‌تواند در کاهش توان فرکانس‌های بالای فرکانس قطع و همچنین حفظ توان فرکانس‌های پایین‌تر از فرکانس قطع مناسب باشد. با توجه به اینکه چگالی طیف توان سیگنال‌های ارتعاشی در فرکانس‌های متفاوت به صورت یکنواخت است، در این حالت هم مشابه فیلتر کالمن با استفاده از سعی خطا، بهترین فرکانس قطع انتخاب می‌شود. نتایج چگالی طیف توان سیگنال‌های ارتعاشی و همچنین اثر کاهش نویز آن در سه فرکانس قطع متفاوت برای سیگنال سیستم سالم در فرکانس تغذیه موتور ۱۴ هرتز در شکل ۶ نمایش داده شده است. در این شکل برای فرکانس‌های قطع، با توجه به اینکه فرکانس داده‌برداری ۱۰۰۰ هرتز می‌باشد، مقادیر ۶۵۰، ۷۵۰ و ۸۵۰ هرتز در نظر گرفته شده است. این فرکانس‌ها به نحوی

¹ Signal to Noise Ratio

² Butterworth


انتخاب شدند که اطلاعات اصلی سیگنال از دست نرود. کاهش بیش از حد این فرکانس‌ها می‌تواند منجر به از بین رفتن اطلاعات مهم سیگنال شود.

در شکل ۷ تغییرات طیف توان برای سیگنال فیلتر شده توسط فیلتر پایین‌گذر با فرکانس‌های قطع متفاوت، نمایش داده می‌شود. با مقایسه شکل ۷ و شکل ۴ به راحتی می‌توان دریافت که در فیلتر پایین‌گذر عملاً یک سری فرکانس‌ها حذف می‌شوند، اما در فیلتر کالمن فرکانس‌های بالا نهایتاً در حد ۱۰ dB تضعیف شده است. این در حالی است که این مقدار در شکل ۷ برای فیلتر پایین‌گذر تقریباً ۱۰۰ dB می‌باشد. باید توجه داشت که در یک سیگنال ارتعاشی با فرکانس داده برداری بالا اطلاعات در فرکانس‌های بالا نیز حائز اهمیت می‌باشد.

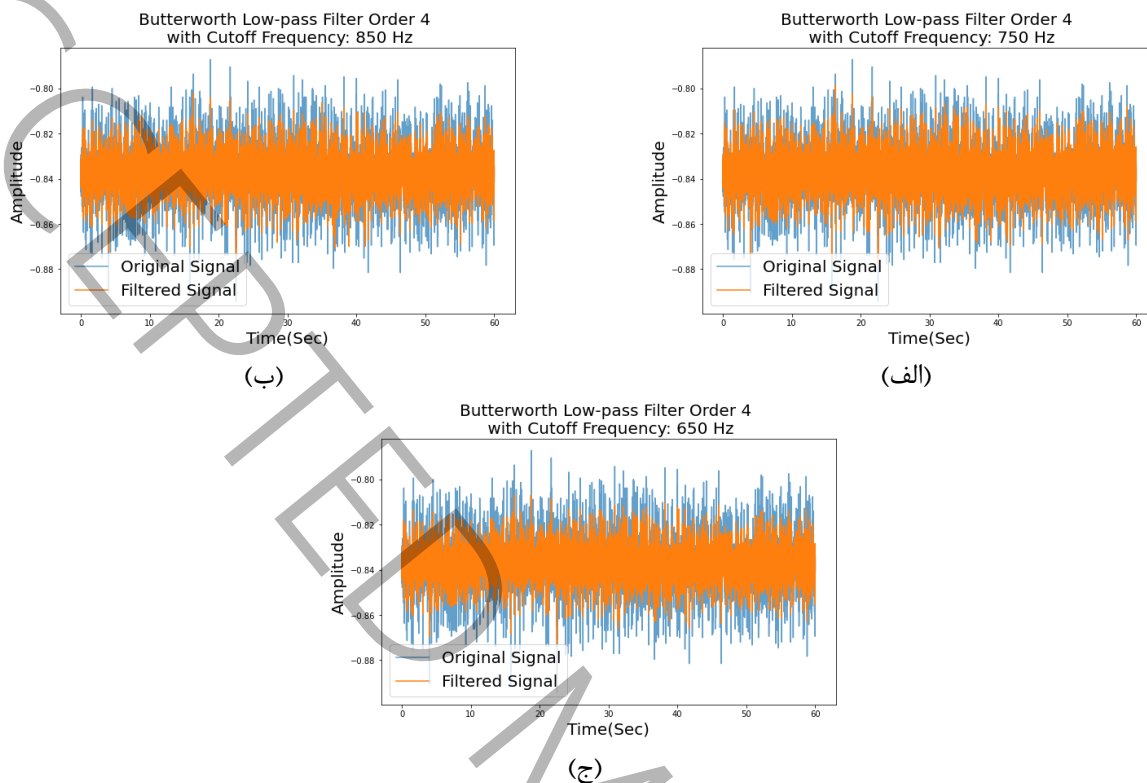


شکل ۴: تغییرات چگالی طیف توان بعد از کاهش نویز توسط فیلتر کالمن در (الف) سیستم سالم (ب) سیستم با عیب ساچمه یاتاقان (ج) سیستم با عیب رینگ خارجی یاتاقان (د) سیستم با عیب نابالانس بودن میله

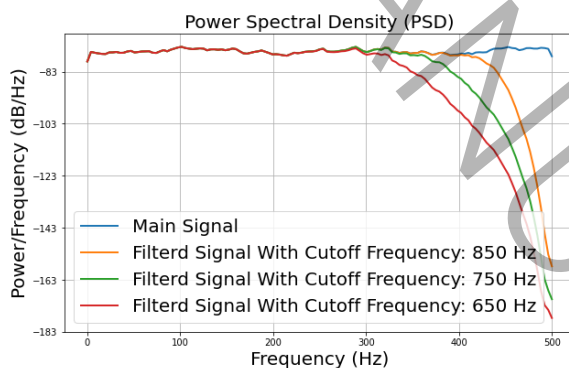
Figure 4: Power spectral density changes after noise reduction by Kalman filter in (a) Healthy system (b) System with bearing ball fault (c) System with bearing outer ring fault (d) System with shaft unbalance fault



شکل ۵: بیشینه نرخ سیگنال به نویز در سیگنال‌های مختلف هر سنسور بعد از کاهش نویز توسط فیلتر کالمن در کوواریانس اندازه‌گیری متفاوت
 Figure 5: Maximum Signal to Noise Ratio in different signals of each sensor after noise reduction by Kalman filter for different measurement covariance



شکل ۶: سیگنال سیستم سالم در فرکانس تغذیه موتور ۱۴ هرتز و کاهش نویز آن در فرکانس قطع (الف) ۸۵۰ هرتز (ب) ۷۵۰ هرتز (ج) ۶۵۰ هرتز
 Figure 6: Healthy system signal at 14 Hz motor feeding frequency and noise reduction for cut-off frequency (a) 850 Hz (b) 750 Hz (c) 650 Hz



شکل ۷: تغییرات چگالی طیف توان بعد از کاهش نویز توسط فیلتر پایین‌گذر در سیگنال سیستم سالم در فرکانس تغذیه موتور ۱۴ هرتز
 Figure 7: Power spectral density changes after noise reduction by low-pass filter in healthy system signal at 14 Hz motor feeding frequency

۴- استخراج ویژگی‌ها برای تحلیل سیگنال‌ها

برای تحلیل سیگنال‌ها از استخراج ویژگی در حوزه زمان و فرکانس استفاده می‌شود. برای استخراج ویژگی‌ها از داده‌های سیگنال، ویژگی‌هایی در حوزه زمان و حوزه فرکانس در نظر گرفته شده است. در این پژوهش از ۱۴ ویژگی در حوزه زمان و ۹ ویژگی در حوزه فرکانس استفاده می‌شود. جدول ۱ ویژگی‌ها در حوزه زمان را نشان می‌دهد و در جدول ۲ ویژگی‌های در حوزه فرکانس معرفی می‌شوند.

در جدول ۱ مقدار m طول سیگنال است و X_{sd} مقدار واریانس سیگنال می‌باشد و به صورت معادله (۳) است و در جدول ۲ پارامتر $S(k)$ مقدار طیف سیگنال می‌باشد و k طول طیف سیگنال است. f_k نیز مقدار فرکانس به ازاء k مین داده در طول طیف سیگنال است.

$$x_{sd} = \sqrt{\frac{1}{m-1} \sum_{n=1}^m (x(n) - F_1)^2} \quad (3)$$

جدول ۱: ویژگی‌های حوزه زمان [۲۹، ۲۸، ۶]

Table 1: Features of the time domain

معادله	نام ویژگی	معادله	نام ویژگی
$F_8 = \frac{F_4}{F_2}$	فاکتور ترخیص ^۱	$F_1 = \frac{1}{m} \sum_{n=1}^m x(n)$	مقدار میانگین
$F_9 = \frac{F_3}{F_1}$	فاکتور اندازه	$F_2 = \left(\frac{1}{m} \sum_{n=1}^m \sqrt{ x(n) } \right)^2$	مربع ریشه اندازه
$F_{10} = \frac{F_4}{F_1}$	فاکتور ضربه	$F_3 = \sqrt{\frac{1}{m} \sum_{n=1}^m (x(n))^2}$	مربع ریشه میانگین
$F_{11} = \max x_n - \min x_n $	اوج به اوج	$F_4 = \max x(n) $	اوج
$F_{12} = \frac{F_4}{F_3}$	فاکتور حاشیه	$F_5 = \frac{\sum_{n=1}^m (x(n) - F_1)^3}{(m-1)X_{sd}^3}$	اسکیونس ^۲
$F_{13} = \log(F_6 + F_3)$	فاکتور جمع ۱	$F_6 = \frac{\sum_{n=1}^m (x(n) - F_1)^4}{(m-1)X_{sd}^4}$	کورتوسیس ^۳
$F_{14} = \log \left(F_6^{F_7} + \left(\frac{F_3}{0.078} \right)^{F_{11}} \right)$	فاکتور جمع ۲	$F_7 = \frac{F_4}{F_3}$	فاکتور کرس ^۴

برای استخراج ویژگی در حوزه زمان، سیگنال به طور مستقیم در روابط جدول ۱ قرار داده می‌شود. در حوزه فرکانس، قبل از استخراج ویژگی باید ابتدا طیف^۵ سیگنال را استخراج کرد. برای این کار توسط تحلیل تبدیل سریع فوریه، سیگنال وارد حوزه فرکانس می‌شود و طیف سیگنال بدست می‌آید. از تبدیل سریع فوریه به عنوان روشی برای افزایش سرعت تبدیل فوریه گسسته^۶ استفاده می‌شود. برای استفاده از تبدیل سریع فوریه طول طیف آن باید توانی از دو به صورت $N = 2^n$ باشد [۳۱]. در ادامه ویژگی‌های جدول ۲ بر روی طیف سیگنال اعمال می‌شود تا ویژگی‌های در حوزه فرکانس نیز بدست آید.

۵- بررسی نتایج آموزش شبکه‌های عصبی

با توجه به توضیحات داده شده در قسمت قبل ۲۳ ویژگی از هر سیگنال استخراج می‌شود، و هر داده ما دارای دو سیگنال می‌باشد، در نتیجه در هر داده ۴۶ عدد ثبت می‌شود. در نتیجه ابعاد داده‌های ورودی آموزشی ۱۲۵ در ۴۶ می‌باشد (۱۲۵ داده از ۱۵۶ داده آموزشی هستند). این داده‌ها به عنوان ورودی شبکه‌های عصبی پرسپترون چند لایه و شبکه ماشین بردار پشتیبان و برای شبکه‌های عصبی پیچشی با ساختار الهام و الکسنت، در نظر گرفته می‌شود.

¹ Clearance

² Skewness

³ Kurtosis

⁴ crest

⁵ Spectrum

⁶ Discrete Fourier Transform

کلاس‌بند ماشین بردار پشتیبان با توجه به قابلیت کاربرد در داده‌های با ابعاد بالا به خوبی می‌تواند با ویژگی‌های استخراج شده در عیب‌یابی ماشین دوار کار کند. این روش معمولاً دارای کارایی خوبی برای مسائل دسته‌بندی می‌باشد و می‌تواند در مواقعی که داده‌ها جداپذیر هستند، عملکرد بسیار خوبی داشته باشد. شبکه پرسپترون چند لایه به دلیل انعطاف پذیری زیاد در مدلسازی و توانایی تطبیق با الگوهای پیچیده معمولاً در مسائل پیچیده‌تر کارآمد هستند. این روش می‌تواند ویژگی‌های پیچیده و توزیع نامنظم داده‌های یک بعدی را یاد بگیرد. شبکه پیچشی الکسنت نیز به خوبی برای تشخیص الگوهای پیچیده در تصاویر عمل می‌کند، که می‌تواند برای تشخیص عیوب در ماشین‌های دوار مفید باشد. از این رو از ویژگی چند بعدی بودن این روش و کارایی بالا و انعطاف پذیری این شبکه عصبی که در مسابقات داده‌های بینایی ماشین بسیار موفق بوده، می‌توان در داده‌های مختلف استفاده کرد. معماری الهام‌شده شبکه الکسنت با استفاده از ماژول‌های پیچش با اندازه‌های مختلف، انعطاف پذیری بالایی در معماری شبکه‌ای خود دارد که می‌تواند منجر به عملکرد بهتر در تشخیص الگوها و ویژگی‌های پیچیده شود. همچنین دارای ساختار کوچک‌تر نسبت به الکسنت می‌باشد. از این رو در این پژوهش این شبکه به عنوان شبکه پیچشی با ساختار کوچک مورد ارزیابی قرار گرفت.

جدول ۲: ویژگی‌های حوزه فرکانس [۳۰]

Table 2: Features of the frequency domain

معادله	نام ویژگی	معادله	نام ویژگی
$F_{20} = \frac{F_{18}}{X_{17}}$	ضریب تغییر پذیری	$F_{15} = \frac{1}{k} \sum_{k=1}^K S(k)$	مقدار میانگین
$F_{21} = \frac{\sum_{k=1}^K (f_k - X_{17})^3 S(k)}{KF_{18}^3}$	اسکیونس	$F_{16} = \frac{1}{k-1} \sum_{k=1}^K (S(k) - F_{15})^2$	واریانس
$F_{22} = \frac{\sum_{k=1}^K (f_k - X_{17})^4 S(k)}{KF_{18}^4}$	کورتوسیس	$X_{17} = \frac{\sum_{k=1}^K f_k S(k)}{\sum_{k=1}^K S(k)}$	مرکز فرکانس
$F_{23} = \frac{\sum_{k=1}^K (f_k - X_{17})^{0.5} S(k)}{K \sqrt{F_{18}}}$	نرخ مربع ریشه میانگین	$F_{18} = \sqrt{\frac{1}{k} \sum_{k=1}^K (f_k - X_{17})^2 S(k)}$	ریشه واریانس
		$F_{19} = \sqrt{\frac{\sum_{k=1}^K f_k^2 S(k)}{\sum_{k=1}^K S(k)}}$	مربع ریشه میانگین

با تنظیم داده‌ها و ویژگی‌های مناسب به عنوان ورودی به این مدل‌ها همچنین تنظیم صحیح پارامترهای مدل‌ها، می‌توان عملکرد این شبکه‌ها را افزایش داد و استفاده از این شبکه‌ها می‌تواند به دقت و کارایی مدل در تشخیص و پیش‌بینی عیوب در ماشین‌های دوار کمک کند.

شبکه عصبی پرسپترون چند لایه بکار برده شده در این پژوهش دارای ۳۰ لایه مخفی است و از شبکه ماشین بردار پشتیبان با هسته خطی^۱ استفاده شده است. برای تحلیل ویژگی‌ها توسط ابزارهای ۲ بعدی در شبکه عصبی پیچشی، ورودی شبکه را به صورت ۲ بعدی در آورديم. برای این منظور از ویژگی آخر صرف نظر کردیم و ۴۵ ویژگی را به صورت ماتریس ۵ در ۹ در آورديم. در نتیجه برای شبکه عصبی پیچشی ابعاد ورودی داده‌های آموزشی به صورت ۱۲۵ در ۵ در ۹ می‌باشد.

برای بررسی تاثیر کاهش نویز سیگنال توسط فیلتر کالمن، از آنجایی که اطلاعاتی در مورد کوواریانس نویز سیستم نداریم، برای کوواریانس R در نویز اندازه‌گیری سیگنال، به صورت سعی و خطا مقادیر ۰/۲۵، ۰/۵ و ۰/۷۵ قرار داده شده است. یعنی قبل از استخراج ویژگی سیگنال مورد نظر در سه حالت نویزدایی می‌شود و یک حالت بدون کاهش نویز نیز از سیگنال ویژگی استخراج می‌شود.

¹ Linear kernel

از آنجایی که تقسیم‌بندی داده‌های ارزیابی و داده‌های آموزشی در نتایج آموزش شبکه‌ها تاثیر گذار هستند، کلاس‌بندی نام برده در پنج تقسیم‌بندی مختلف داده‌ها آموزش داده می‌شود. نتایج آموزش شبکه‌های عصبی استفاده شده در جدول‌های ۳، ۴، ۵ و ۶ نمایش داده شده است. این جدول‌ها نتایج را برای هر کلاس‌بندی، به ازاء تقسیم داده‌های مختلف و حالات مختلف کاهش نویز توسط فیلتر کالمن نمایش می‌دهند.

در ادامه کار در دو حالت نتایج با هم مقایسه شده‌اند: یکی برای دقت شبکه عصبی و دیگری برای تاثیر کاهش نویز. برای مقایسه بهتر دقت کلاس‌بندی میانگین و واریانس کل داده‌های ارزیابی به ازاء کلاس‌بندی‌های مختلف در جدول ۷ نمایش داده شده است. در جدول ۷ میانگین و واریانس دقت داده‌های ارزیابی در هر کلاس‌بندی برای کل نتایج، در حالت بدون کاهش نویز و ۳ حالت کاهش نویز اندازه‌گیری شده است. همانطور که از این جدول مشخص است شبکه عصبی الکسنت دارای بهترین میانگین دقت برای داده‌های ارزیابی در تمامی حالات کاهش نویز می‌باشد و شبکه عصبی پرسپترون چند لایه دارای کمترین واریانس دقت برای داده‌های ارزیابی است، یعنی پراکندگی کمتری در نتایج دقت داده‌های ارزیابی دارد. در مجموع با توجه به اینکه شبکه عصبی الکسنت شبکه عصبی عمیق تری نسبت به سایر شبکه‌ها می‌باشد به دقت بالاتری برای داده‌های ارزیابی رسیده است.

برای مقایسه اثر کاهش نویز توسط فیلتر کالمن، میانگین و واریانس دقت کل داده‌های ارزیابی به ازاء نوع کاهش نویز سیگنال محاسبه شده است و نتایج در جدول ۸ نمایش داده شده است. با توجه به جدول ۸ می‌توان متوجه شد که در کاهش نویز با فیلتر کالمن به ازاء کوواریانس $R = 0.5$ در نویز اندازه‌گیری، بهترین دقت برای داده‌های ارزیابی را داریم. در نتیجه با استفاده از فیلتر کالمن این دقت نسبت به حالت بدون کاهش نویز بهبود داده شده است. همچنین نتایج دقت داده‌های ارزیابی در کوواریانس نویز اندازه‌گیری $R = 0.5$ نسبت به حالتی که کاهش نویز وجود نداشته باشد، پراکندگی کمتری دارد.

جدول ۳: نتایج دقت آموزش شبکه ماشین بردار پشتیبان

Table 3: SVM network accuracy results

بدون کاهش نویز	کاهش نویز فیلتر کالمن با $R = 0.75$	کاهش نویز فیلتر کالمن با $R = 0.5$	کاهش نویز فیلتر کالمن با $R = 0.25$	نوع داده	تقسیم‌بندی داده
۱	۱	۱	۱	داده آموزش	۱
۰.۸۷۱	۰.۹۳۵	۰.۹۳۵	۰.۹۰۳	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۲
۰.۹۶۸	۰.۹۶۸	۱	۱	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۳
۰.۹۶۸	۰.۹۳۵	۰.۹۶۸	۰.۹۶۸	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۴
۰.۸۷۱	۰.۸۷۱	۰.۸۷۱	۰.۸۷۱	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۵
۰.۸۷۱	۰.۹۰۳	۰.۹۳۵	۰.۹۳۵	داده ارزیابی	

جدول ۴: نتایج دقت آموزش شبکه عصبی پرسپترون چند لایه

Table 4: Multi-layer perceptron network accuracy results

بدون کاهش نویز	کاهش نویز فیلتر کالمن با $R = 0.75$	کاهش نویز فیلتر کالمن با $R = 0.5$	کاهش نویز فیلتر کالمن با $R = 0.25$	نوع داده	تقسیم‌بندی داده
۱	۱	۱	۱	داده آموزش	۱
۱	۰.۹۳۵	۰.۹۶۸	۰.۹۶۸	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۲
۰.۹۳۵	۰.۹۰۳	۰.۹۳۵	۰.۹۳۵	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۳
۰.۹۳۵	۰.۹۳۵	۰.۹۳۵	۰.۹۳۵	داده ارزیابی	

۱	۱	۱	۱	داده آموزش	۴
۰/۹۳۵	۰/۹۳۵	۰/۹۳۵	۰/۹۳۵	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۵
۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	داده ارزیابی	

جدول ۵: نتایج دقت آموزش شبکه عصبی الکسنت

Table 5: AlexNet network accuracy results

بدون کاهش نویز	کاهش نویز فیلتر $R = 0.75$ کالمن با	کاهش نویز فیلتر $R = 0.5$ کالمن با	کاهش نویز فیلتر $R = 0.25$ کالمن با	نوع داده	تقسیم‌بندی داده
۰/۹۶۸	۰/۹۹۲	۰/۹۷۶	۰/۹۶	داده آموزش	۱
۰/۹۳۵	۰/۹۳۵	۰/۹۰۳	۰/۹۳۵	داده ارزیابی	
۰/۹۸۴	۰/۹۶۸	۰/۹۹۲	۰/۹۲۸	داده آموزش	۲
۱	۱	۱	۱	داده ارزیابی	
۰/۹۹۲	۰/۹۸۴	۰/۹۵۲	۰/۹۸۴	داده آموزش	۳
۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	داده ارزیابی	
۰/۹۱۲	۰/۹۰۴	۰/۹۸۴	۰/۹۶۸	داده آموزش	۴
۰/۹۳۵	۰/۹۳۵	۰/۹۶۸	۰/۹۶۸	داده ارزیابی	
۰/۹۴۴	۰/۹۲	۰/۸۴	۰/۹۲	داده آموزش	۵
۰/۹۳۵	۰/۹۳۵	۰/۹۶۸	۰/۹۳۵	داده ارزیابی	

جدول ۶: نتایج دقت آموزش شبکه عصبی الهام

Table 6: Inception network accuracy results

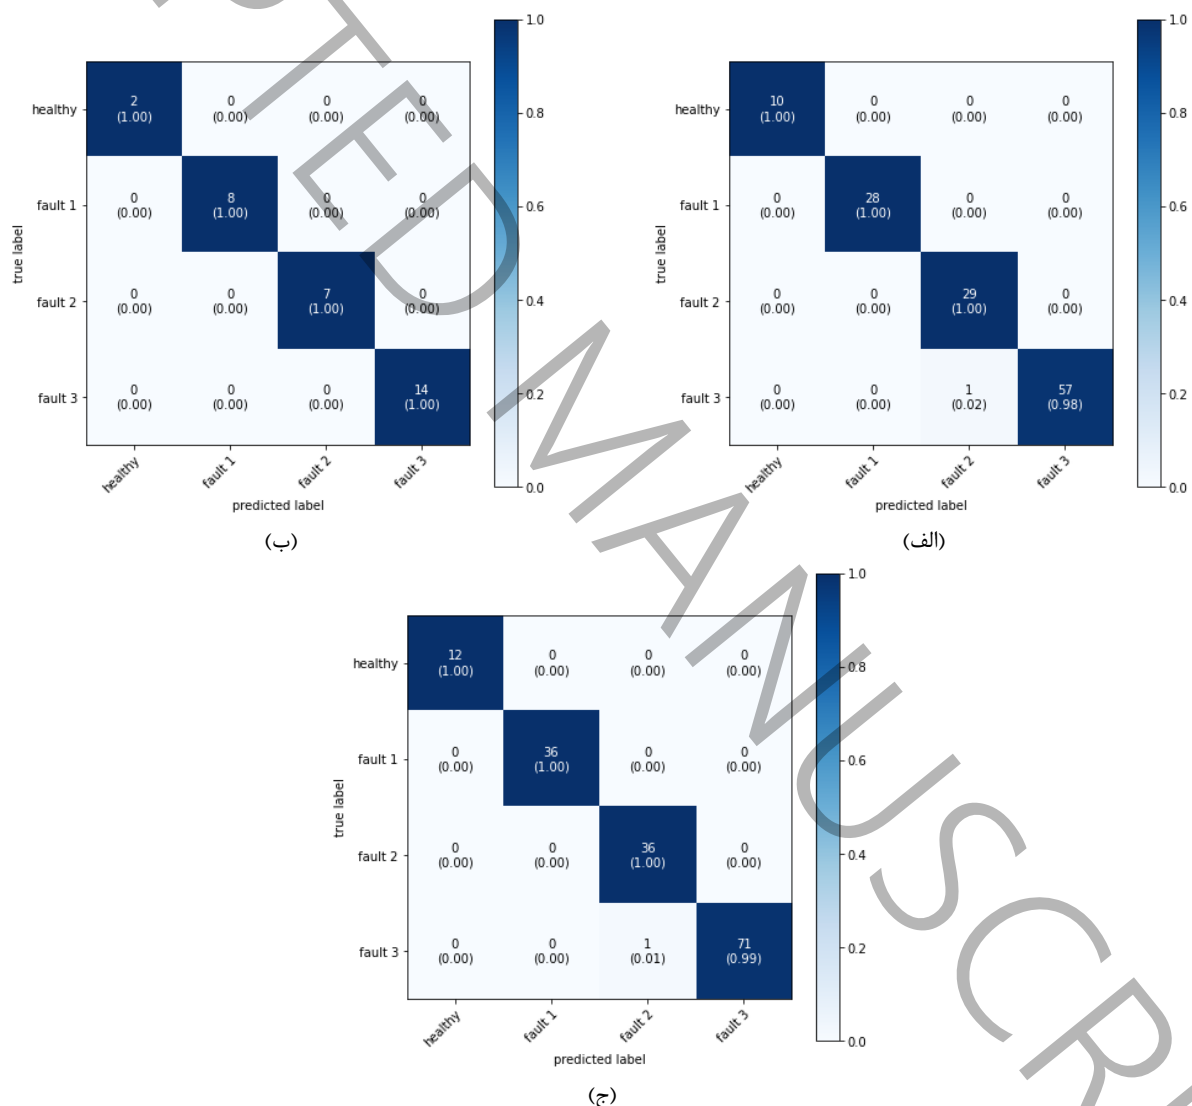
بدون کاهش نویز	کاهش نویز فیلتر $R = 0.75$ کالمن با	کاهش نویز فیلتر $R = 0.5$ کالمن با	کاهش نویز فیلتر $R = 0.25$ کالمن با	نوع داده	تقسیم‌بندی داده
۱	۱	۱	۱	داده آموزش	۱
۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	۰/۹۶۸	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۲
۱	۰/۹۶۸	۱	۱	داده ارزیابی	
۱	۰/۹۱۲	۱	۱	داده آموزش	۳
۰/۹۶۸	۰/۹۰۳	۰/۹۳۵	۰/۹۳۵	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۴
۰/۹۰۳	۰/۹۳۵	۰/۹۶۸	۰/۹۰۳	داده ارزیابی	
۱	۱	۱	۱	داده آموزش	۵
۰/۹۰۳	۰/۹۰۳	۰/۸۷۱	۰/۹۰۳	داده ارزیابی	

در ادامه با توجه به اینکه بهترین نتایج در حالت کاهش نویز با کوواریانس نویز اندازه‌گیری $R = 0.5$ بدست آمده است، مقایسه میانگین و واریانس دقت داده‌های ارزیابی برای شبکه عصبی‌های مختلف در این حالت کاهش نویز بررسی می‌شود. برای این منظور با توجه به جدول ۷ همانطور که انتظار می‌رفت شبکه عصبی الکسنت در حالت کاهش نویز با کوواریانس نویز اندازه‌گیری $R = 0.5$ بهترین دقت برای داده‌های ارزیابی را دارد. با توجه به اینکه شبکه عصبی الکسنت در حالت کاهش نویز $R = 0.5$ در تقسیم‌بندی شماره ۲ داده‌ها بهترین عملکرد را داشته است، ماتریس سردرگمی^۱ آن به عنوان نمونه در شکل ۸ نمایش داده شده است. همچنین برای بررسی

^۱ Confusion Matrix

بهتر نتایج شبکه عصبی الکسنت در حالت کاهش نویز با کوواریانس $R = 0.5$ در نویز اندازه‌گیری، در شکل ۹ منحنی مشخصه عملکرد سیستم^۱ به همراه محاسبه سطح زیر نمودار آن^۲ نمایش داده شده است.

ماتریس سردرگمی شکل ۸ نتایج شبکه عصبی الکسنت را برای داده‌های آموزشی و داده‌های تست به خوبی نشان می‌دهد. این شکل دقت سیستم عیب‌یابی برای کلاس‌های مختلف عیب را مشخص می‌سازد. با توجه به شکل ۸ (الف) تنها یک نمونه داده آموزشی عیب کلاس ۳ یعنی عیب نابالانس بودن میله به اشتباه کلاس ۲ یعنی عیب ساچمه یاتاقان تشخیص داده شده است و در باقی موارد نیز عیب کلاس‌های ۱ و ۲ یعنی عیب ساچمه یاتاقان و عیب رینگ خارجی یاتاقان بودن میله کاملاً درست تشخیص داده شده است. در داده‌های تست نیز با توجه به شکل ۸ (ب) تمامی کلاس‌ها به درستی تشخیص داده شد. شکل ۸ (ج) داده‌ها را به صورت کلی بررسی می‌کند که در مجموع یک پیش‌بینی اشتباه در عیب کلاس ۳ داشتیم که کلاس ۲ تشخیص داده شد. شکل ۸ برای بهترین نتیجه‌ای که در جداول ۳ تا ۶ بدست آمد، بدست آمده است. همانطور که اشاره شد شبکه عصبی الکسنت به ازاء تقسیم‌بندی داده‌های شماره ۲ در حالت کاهش نویز با کوواریانس $R = 0.5$ بهترین نتایج را داشته است.



شکل ۸: ماتریس سردرگمی برای شبکه عصبی الکسنت در حالت کاهش نویز با کوواریانس $R = 0.5$ در نویز اندازه‌گیری در تقسیم‌بندی شماره ۲ برای (الف) داده‌های آموزشی (ب) داده‌های ارزیابی (ج) کل داده‌ها

¹ Receiver Operating Characteristics (ROC)

² Area under the ROC curve (AUC)

Figure 8: Confusion matrix for AlexNet neural network in noise reduction mode with covariance $R = 0.5$ in measurement noise in division number 2 for (a) training data (b) validation data (c) total data

در شکل ۹ منحنی مشخصه عملکرد سیستم به همراه محاسبه سطح زیر نمودار آن برای هر کلاس معیوب و همچنین سالم نمایش داده شده است. این نمودار، حساسیت^۱ یا نرخ مثبت صحیح^۲ نتایج را بر حسب متمم تشخیص پذیری^۳ یا نرخ مثبت غلط^۴ نتایج نشان می‌دهد. هر چه نمودار منحنی مشخصه عملکرد سیستم بالای خط نیم‌ساز قرار بگیرد در نتیجه سطح زیر نمودار بیشتر است و در نتیجه عملکرد بهتری را شاهد خواهیم بود و اعتمادپذیری شبکه نیز بیشتر خواهد بود. در همین راستا اگر منحنی مشخصه عملکرد سیستم پایین خط نیم‌ساز قرار گیرد، عملکرد نامناسب سیستم را شاهد هستیم. با توجه به شکل ۹ بهترین جواب‌ها در تقسیم‌بندی شماره ۲ اتفاق افتاده است که به برای هر کلاس سطح زیر نمودار به مقدار ۱ رسیده است. در تقسیم‌بندی شماره ۳ و ۴ می‌توان گفت با دقت خوبی سطح زیر نمودار به ۱ رسیده است. در تقسیم‌بندی شماره ۱ و ۵ نیز برای بعضی از کلاس‌ها مقدار سطح زیر نمودار کاهش یافته است، که این مقدار ناچیز می‌باشد. در مجموع با توجه به شکل ۹ در روش استفاده از شبکه عصبی الکسنت در حالت کاهش نویز با کوواریانس $R = 0.5$ در نویز اندازه‌گیری، از اعتمادپذیری خوبی برخوردار هستیم.

با توجه به اینکه تا به اینجای کار شبکه عصبی الکسنت بهترین جواب‌ها را برای داده‌های نویززدایی شده توسط فیلتر کالمن را داشته است، از این شبکه عصبی برای داده‌های بدست آمده توسط فیلتر پایین‌گذر باترورث استفاده می‌شود و شبکه عصبی الکسنت توسط این داده‌ها آموزش داده می‌شود. نتایج بدست آمده شبکه الکسنت برای این داده‌ها در جدول ۹ نمایش داده شده است.

جدول ۷: میانگین و واریانس دقت برای داده‌های ارزیابی در آموزش برای هر کلاس بند به ازاء حالات مختلف کاهش نویز فیلتر کالمن

Table 7: Mean and variance of accuracy for the validation data for each classifier's training according to different Kalman filter noise reduction mode

روش کلاس بندی	کل حالات کاهش نویز		کاهش نویز فیلتر کالمن با $R = 0.25$		کاهش نویز فیلتر کالمن با $R = 0.5$		کاهش نویز فیلتر کالمن با $R = 0.75$		بدون کاهش نویز
	میانگین	واریانس	میانگین	واریانس	میانگین	واریانس	میانگین	واریانس	
ماشین بردار پشتیبان	۰/۹۲۷	۰/۰۰۲۱	۰/۹۳۵	۰/۰۰۲۶	۰/۹۴۲	۰/۰۰۲۳	۰/۹۲۲	۰/۰۰۱۴	۰/۰۰۲۸
پرسپترون چند لایه	۰/۹۴۷	۰/۰۰۰۵	۰/۹۴۸	۰/۰۰۰۳	۰/۹۴۸	۰/۰۰۰۳	۰/۹۳۵	۰/۰۰۰۵	۰/۰۰۰۸
الهام	۰/۹۴۴	۰/۰۰۱۵	۰/۹۴۲	۰/۰۰۱۸	۰/۹۴۸	۰/۰۰۲۴	۰/۹۳۵	۰/۰۰۱۱	۰/۰۰۱۹
الکسنت	۰/۹۵۸	۰/۰۰۰۸	۰/۹۶۱	۰/۰۰۰۷	۰/۹۶۱	۰/۰۰۱۳	۰/۹۵۵	۰/۰۰۰۸	۰/۰۰۰۸

جدول ۸: میانگین و واریانس دقت داده‌های ارزیابی در آموزش برای کل کلاس بندها در هر حالت کاهش نویز فیلتر کالمن

Table 8: Mean and variance of accuracy of the validation data for entire classifier's training according Kalman filter noise reduction mode

نوع کاهش نویز	میانگین	واریانس
$R = 0.25$	۰/۹۴۷	۰/۰۰۱۲
$R = 0.5$	۰/۹۵	۰/۰۰۱۴
$R = 0.75$	۰/۹۳۷	۰/۰۰۰۹
بدون کاهش نویز	۰/۹۴۲	۰/۰۰۱۷

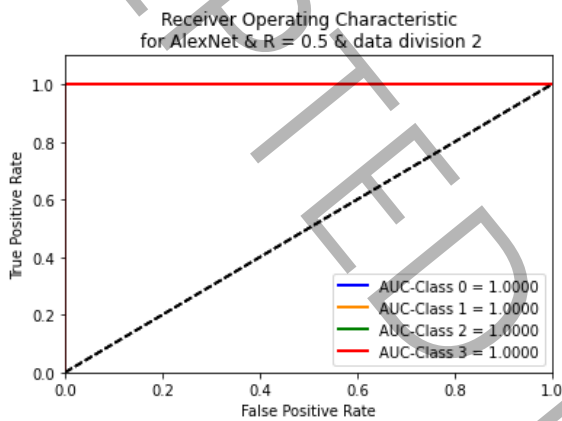
¹ Sensitivity

² True Positive Rate

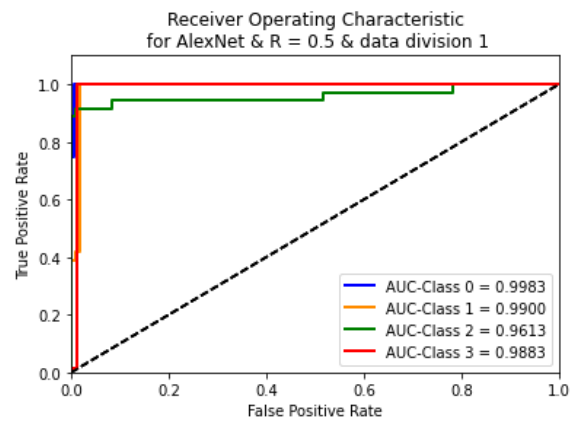
³ Specificity

⁴ False Positive Rate


با توجه به جدول شماره ۹ می‌توان گفت شبکه عصبی الکسنت برای سیگنال‌های کاهش نویز یافته در فرکانس قطع ۷۵۰ هرتز توسط فیلتر باترورث بهترین جواب را داده است. در این حالت، بهترین جواب بدست آمده برای فیلتر باترورث در تقسیم بندی شماره ۳ داده‌ها اتفاق افتاده است و دقت عیب‌یابی با سیگنال‌های مربوطه برای داده‌های آموزشی ۱۰۰ درصد و برای داده‌های ارزیابی ۹۸ درصد می‌باشد. این در حالی است که بهترین دقت شبکه عصبی الکسنت در حالت کاهش نویز توسط فیلتر کالمن با کوواریانس اندازه‌گیری $R = 0.5$ مقدار دقت داده‌های آموزشی ۹۹ درصد و برای داده‌های ارزیابی ۱۰۰ درصد بوده است. در جدول ۹ میانگین دقت اندازه‌گیری برای داده‌های ارزیابی در فرکانس‌های ۶۵۰، ۷۵۰ و ۸۵۰ هرتز به ترتیب $94/2$ ، $95/5$ و $94/2$ درصد می‌باشد که این مقادیر در مقایسه با میانگین داده‌های ارزیابی در روش کاهش نویز توسط فیلتر کالمن با $R = 0.5$ توسط شبکه عصبی الکسنت (جدول ۷)، کمتر می‌باشند. در مجموع با مقایسه جدول ۵ و جدول ۹ می‌توان بهبود کاهش نویز توسط فیلتر کالمن نسبت به روش‌های مرسوم کاهش نویز توسط فیلترهای پایین‌گذر را شاهد بود.




(ب)



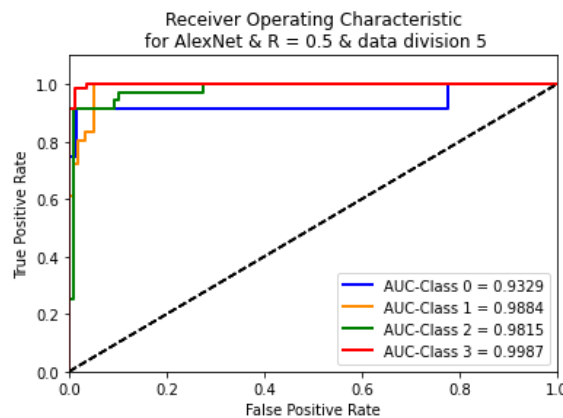
(الف)



(د)



(ج)



(ه)

شکل ۹: منحنی مشخصه عملکرد سیستم به همراه محاسبه سطح زیر نمودار آن برای روش شبکه عصبی الکسنت در حالت کاهش نویز با کوواریانس $R = 0.5$ در نویز اندازه‌گیری برای کل داده‌های آموزشی و ارزیابی در تقسیم‌بندی (الف) شماره ۱ (ب) شماره ۲ (ج) شماره ۳ (د) شماره ۴ (ه) شماره ۵

Figure 9: ROC-AUC diagram for the AlexNet neural network in noise reduction mode with covariance $R = 0.5$ in the measurement noise for all training and validation data in (a) division 1, (b) division 2, (c) division 3, (d) division 4, and (e) division 5

جدول ۹: نتایج دقت آموزش شبکه عصبی الکسنت توسط داده‌های بدست آمده از فیلتر باتروث

Table 9: The accuracy results of the AlexNet neural network training using the data obtained from the Butterworth filter

تقسیم‌بندی داده	نوع داده	کاهش نویز با فرکانس قطع ۶۵۰ هرتز	کاهش نویز با فرکانس قطع ۷۵۰ هرتز	کاهش نویز با فرکانس قطع ۸۵۰ هرتز
۱	داده آموزش	۰/۹۲۸	۰/۹۲	۰/۹۵۲
	داده ارزیابی	۰/۹۰۳	۰/۹۳۵	۰/۹۰۳
۲	داده آموزش	۰/۹۶۸	۰/۹۷۶	۰/۹۷۶
	داده ارزیابی	۰/۹۶۸	۱	۰/۹۶۸
۳	داده آموزش	۰/۹۱۲	۰/۹۸۴	۰/۸۱۶
	داده ارزیابی	۰/۹۶۸	۰/۹۶۸	۰/۹۳۵
۴	داده آموزش	۰/۹۲	۰/۹۵۲	۰/۹۴۴
	داده ارزیابی	۰/۹۳۵	۰/۹۶۸	۰/۹۶۸
۵	داده آموزش	۰/۸۸	۰/۹۶۸	۰/۸۶۴
	داده ارزیابی	۰/۹۳۵	۰/۹۰۳	۰/۹۳۵

۶- جمع بندی

در این پژوهش، هدف بررسی تاثیر کاهش نویز سیگنال توسط فیلتر کالمن برای عیب‌یابی سیستم ماشین دوار بوده است. برای این منظور از سیستم آزمایشگاهی ماشین دوار برای داده برداری استفاده شده است و در هر حالت از معیوب یا سالم بودن سیستم دو سیگنال ۱ دقیقه‌ای توسط دو سنسور ثبت شده است. این داده‌ها به عنوان داده‌های اولیه مورد استفاده قرار گرفته است. برای عیب‌یابی سیستم ابتدا داده‌ها توسط فیلتر کالمن در چند حالت نویززدایی می‌شود و در ادامه از سیگنال کاهش نویز یافته و یا سیگنال خام، ویژگی‌هایی در حوزه زمان و حوزه فرکانس استخراج می‌شود. سیگنال‌ها بعد از پیش پردازش به عنوان داده‌های آموزشی و داده‌های ارزیابی تقسیم‌بندی می‌شوند و با این داده‌ها شبکه‌های عصبی مختلف آموزش داده می‌شود. در این پژوهش از روش ماشین بردار پشتیبان و شبکه عصبی پرسپترون چند لایه و شبکه‌های عصبی پیچشی الهام و الکسنت استفاده می‌شود و این روش‌ها با هم مقایسه می‌شوند.

در قسمت ۵ این مقاله نتایج بدست آمده برای کلاس‌بندی‌های مختلف نمایش داده می‌شود. این نتایج به ازاء حالات مختلف کاهش نویز، در ۵ حالت تقسیم‌بندی داده‌ها انجام شده است. در مجموع با توجه به نتایج، عملکرد شبکه عصبی پیچشی الکسنت نسبت به سایر روش‌ها بهتر بوده است. در بررسی کاهش نویز سیگنال‌ها به ازاء کوواریانس اندازه‌گیری $R = 0.5$ بهترین نتایج حاصل شد. در نهایت نشان داده شد که شبکه عصبی پیچشی الکسنت نیز در کاهش نویز سیگنال با $R = 0.5$ نتایج بهتری داده است که ۹۶/۱ درصد رسیده است. با مقایسه میانگین نتایج برای حالات مختلف کاهش نویز در همه کلاس‌بندی‌ها، در کوواریانس اندازه‌گیری $R = 0.5$ به بهترین دقت یعنی ۹۵ درصد رسیده است که نسبت به حالت بدون کاهش نویز بهبود داده شده است. در نهایت روش کاهش نویز توسط فیلتر کالمن با روش فیلتر باتروث مقایسه شد و نتایج حاکی از بهبود عملکرد توسط فیلتر کالمن نشان بودند.

برای ادامه کار پیشنهاد می‌شود برای کاهش نویز سیگنال مقادیر کوواریانس Q و R در فیلتر کالمن مورد بررسی قرار گیرد. از آنجایی که سیگنال‌های واقعی که توسط حسگرها ثبت می‌شوند، دارای نویز با کوواریانس نامعلوم هستند، مقادیر کوواریانس Q و R را نمی‌توان به صورت دقیق مشخص کرد. این مقادیر می‌توانند توسط روش‌های بهینه‌سازی بدست آیند.

۷- فهرست علائم

A	ماتریس انتقال حالت
B	ماتریس کنترل
H	ماتریس اندازه‌گیری
u	ورودی کنترلی
$e(m)$	تحریک نامرتبط در ورودی در لحظه m
$n(m)$	نویز در اندازه‌گیری در لحظه m
R	واریانس نویز سیگنال اندازه‌گیری
Q	واریانس نویز سیگنال تحریک در ورودی
$x(n)$	سیگنال در حوزه زمان در لحظه n
F_i	ویژگی i ام سیگنال
$S(k)$	اندازه طیف سیگنال در به ازاء k مین داده طیف
f_k	اندازه فرکانس به ازاء k مین داده طیف

۸- منابع

- [1] R.F. Ribeiro Junior, I.A. dos Santos Areias, M.M. Campos, C.E. Teixeira, L.E.B. da Silva, G.F. Gomes, Fault detection and diagnosis in electric motors using convolution neural network and short-time fourier transform, *Journal of Vibration Engineering & Technologies*, (2022) 1-12.
- [2] M. Zakizadeh, A. Jamali, M. Rafeeyan, A. Chaibakhsh, Monitoring and Troubleshooting Alstom Locomotive Blowers using Vibration Analysis and Support Vector Machine, *Amirkabir Journal of Science & Research (Mechanical Engineering)*, 54(8) (2022) 1833-1850 (in Persian).
- [3] V.H. Farahani, Applying the envelope curve of vibration signals in condition monitoring and rolling bearings fault detection, *Journal of Vibration & Sound*, 2(3) (2013) 11-20 (in Persian).
- [4] M. Shekarzadeh, M. Sadegh Alayy, Centrifugal pump bearings Fault diagnosis using the combination of independent component analysis methods and particle swarm optimization, *Journal of New Applied and Computational Findings in Mechanical Systems*, 3(1) (2023) 53-61 (in Persian).
- [5] M. Kamari, G. Payeganeh, K.N. Khajavi, Implementation of Neuro- Fuzzy and Multi-Layer Perceptron System Intelligent Techniques for Main Fault Diagnosis of Rotating Machinery, *Amirkabir Journal of Science & Research (Mechanical Engineering)*, 45(2) (2013) 105-118 (in Persian).
- [6] M.A. Sattari, G.H. Roshani, R. Hanus, E. Nazemi, Applicability of time-domain feature extraction methods and artificial intelligence in two-phase flow meters based on gamma-ray absorption technique, *Measurement*, 168 (2021) 108474.
- [7] X. Wang, D. Mao, X. Li, Bearing fault diagnosis based on vibro-acoustic data fusion and 1D-CNN network, *Measurement*, 173 (2021) 108518.
- [8] R.-P. Nikula, K. Karioja, M. Pylvänäinen, K. Leiviskä, Automation of low-speed bearing fault diagnosis based on autocorrelation of time domain features, *Mechanical Systems and Signal Processing*, 138 (2020) 106572.
- [9] A. Kafeel, S. Aziz, M. Awais, M.A. Khan, K. Afaq, S.A. Idris, H. Alshazly, S.M. Mostafa, An Expert System for Rotating Machine Fault Detection Using Vibration Signal Analysis, *Sensors*, 21(22) (2021) 7587.
- [10] S. Nezamivand Chegini, Z. Karimi Rastehkenari, A. Bagheri, B. Ahmadi, Denoising vibration signals of rotating machines using probability density function, similarity measure and improved

thresholding function, Amirkabir Journal of Science & Research (Mechanical Engineering), 53(Number 4 (Special Issue)) (2021) 2493-2512 (in Persian).

[11] S. Nezamivand Chegini, F. Zarif, A. Bagheri, A. Tavoli, Vibration signals denoise of rotating machines using experimental wavelet transform and common thresholding methods, Journal of Solid and Fluid Mechanics, 9(1) (2019) 111-124 (in Persian).

[12] V. Gupta, M. Mittal, Arrhythmia detection in ECG signal using fractional wavelet transform with principal component analysis, Journal of The Institution of Engineers (India): Series B, 101(5) (2020) 451-461.

[13] H. Ehya, A. Nysveen, T.N. Skreien, Performance evaluation of signal processing tools used for fault detection of hydrogenerators operating in noisy environments, IEEE Transactions on Industry Applications, 57(4) (2021) 3654-3665.

[14] Y. Gao, Y. Gao, B. Liu, Y. Jiang, Enhanced fault detection and exclusion based on Kalman filter with colored measurement noise and application to RTK, GPS Solutions, 25 (2021) 1-13.

[15] S. Mokhtari, K.K. Yen, A novel bilateral fuzzy adaptive unscented kalman filter and its implementation to nonlinear systems with additive noise, in: 2020 IEEE Industry Applications Society Annual Meeting, IEEE, 2020, pp. 1-6.

[16] P. Talwar, K. Cecil, Adaptive Filter and EMD Based De-Noising Method of ECG Signals: A Review, American Journal of Multidisciplinary Research & Development (AJMRD), 5(03) (2023) 09-14.

[17] F. Honarmand-Shazilehei, N. Pariz, M.B.N. Sistani, Sensor fault detection in a class of nonlinear systems using modal Kalman filter, ISA transactions, 107 (2020) 214-223.

[18] S. Cho, M. Choi, Z. Gao, T. Moan, Fault detection and diagnosis of a blade pitch system in a floating wind turbine based on Kalman filters and artificial neural networks, Renewable Energy, 169 (2021) 1-13.

[19] Y. Yao, J. Wang, M. Xie, Adaptive residual CNN-based fault detection and diagnosis system of small modular reactors, Applied Soft Computing, 114 (2022) 108064.

[20] M. Yakoubi, R. Hamdi, M.B. Salah, EEG enhancement using extended Kalman filter to train multi-layer perceptron, Biomedical Engineering: Applications, Basis and Communications, 31(01) (2019) 1950005.

[21] M. Singh, A.G. Shaik, Incipient fault detection in stator windings of an induction motor using stockwell transform and SVM, IEEE Transactions on Instrumentation and Measurement, 69(12) (2020) 9496-9504.

[22] S. Chatterjee, R.K. Gatla, P. Sinha, C. Jena, S. Kundu, B. Panda, L. Nanda, A. Pradhan, Fault detection of a Li-ion battery using SVM based machine learning and unscented Kalman filter, Materials Today: Proceedings, 74 (2023) 703-707.

[23] Z. Zemali, L. Cherroun, N. Hadroug, A. Hafifa, A. Iratni, O.S. Alshammari, I. Colak, Robust intelligent fault diagnosis strategy using Kalman observers and neuro-fuzzy systems for a wind turbine benchmark, Renewable Energy, 205 (2023) 873-898.

[24] M. Khodarahmi, V. Maihami, A review on Kalman filter models, Archives of Computational Methods in Engineering, 30(1) (2023) 727-747.

[25] R.I. Alfian, A. Ma'arif, S. Sunardi, Noise reduction in the accelerometer and gyroscope sensor with the Kalman filter algorithm, Journal of Robotics and Control (JRC), 2(3) (2021) 180-189.

[26] F. Li, Z. Luo, K. Bai, M. Yin, D. Zou, W. Wang, X. Wang, W. Tan, Q. Sui, Z. Li, Noise shaping enhanced DMT signal transmission utilizing low-resolution DAC, IEEE Photonics Journal, 13(6) (2021) 1-7.

[27] S.K. Mishra, M. Gupta, D.K. Upadhyay, Active realization of fractional order Butterworth lowpass filter using DVCC, Journal of King Saud University-Engineering Sciences, 32(2) (2020) 158-165.

- [28] I.M. Khairuddin, S.N. Sidek, A.P.A. Majeed, M.A.M. Razman, A.A. Puzi, H.M. Yusof, The classification of movement intention through machine learning models: the identification of significant time-domain EMG features, *PeerJ Computer Science*, 7 (2021) e379.
- [29] K. Zhang, J. Chen, T. Zhang, Z. Zhou, A compact convolutional neural network augmented with multiscale feature extraction of acquired monitoring data for mechanical intelligent fault diagnosis, *Journal of Manufacturing Systems*, 55 (2020) 273-284.
- [30] J.J. Saucedo-Dorantes, A.Y. Jaen-Cuellar, M. Delgado-Prieto, R. de Jesus Romero-Troncoso, R.A. Osornio-Rios, Condition monitoring strategy based on an optimized selection of high-dimensional set of hybrid features to diagnose and detect multiple and combined faults in an induction motor, *Measurement*, 178 (2021) 109404.
- [31] A.F. Khalil, S. Rostam, Machine Learning-based Predictive Maintenance for Fault Detection in Rotating Machinery: A Case Study, *Engineering, Technology & Applied Science Research*, 14(2) (2024) 13181-13189.

Investigating Noise Reduction in Signal Analysis in Rotary Machines Fault Diagnosing by Neural Network

Hamed Pourhashem, Ali jamali¹, Nader Nariman-zade, Ali Chaibakhsh

Faculty of Mechanical Engineering, University of Guilan, Rasht, Iran

ABSTRACT

Fault diagnosis of mechanical systems is of special importance for better system performance as well as its protection. In this work, a rotary machine laboratory system is used to generate signals. The obtained data are placed in the pre-processing process. In this article, to improve the performance of signal analysis, the combined analysis methods using signal features and Kalman filter are proposed. First, the Kalman filter is used to reduce the signal noise. In the following, for signal pre-processing, the features of the signal in the time domain and frequency domain are suggested, which have been used as one-dimensional signal pre-processing. In the following, several neural networks such as support vector machine, multilayer perceptron, and convolutional neural networks have been used to analyze the obtained features. To check the results, the data is divided into training data and validation data. Accuracy results for validation data are examined in different methods. The results indicate the better performance of the AlexNet convolutional neural network in the presence of the Kalman filter noise reduction. In this case, this network has reached an average of 96.1% accuracy for validation data, which has been improved compared to other classifiers and fault diagnosis without noise reduction.

KEYWORDS

Fault diagnosis, noise reduction, Kalman filter, neural network, signal processing.

¹ Corresponding Author: Email: ali.jamli@guilan.ac.ir