

معرفی یک روش مبتنی بر یادگیری انتقالی برای تشخیص عیوب ترکیبی در پمپ‌های گریز از مرکز

رضا حسن نژاد قدیم^{*}، میرمحمد اتفاق^آ، یوسف بهرامی مسیبی^آ

^آایران، تبریز، بلوار ۲۹ بهمن، دانشگاه تبریز، دانشکده مهندسی مکانیک، کدپستی ۱۴۷۶۶-۵۱۶۶۶

*پست الکترونیکی نویسنده مسئول: hassannejhad@tabrizu.ac.ir

چکیده

نظر به اهمیت پمپ‌های گریز از مرکز در صنایع مختلف، عیب یابی آنها دارای اهمیت می‌باشد. در همین راستا، استفاده از سیگنال‌های ارتعاشی، کاربرد فراوانی در عیب یابی ماشین‌های دوار دارد. علاوه بر این، امروزه با گسترش روز افزون کاربردهای هوش مصنوعی در زمینه‌های مختلف، ارائه روش‌های هوشمند برای عیب یابی ماشین‌های دوار مورد توجه محققان قرار گرفته است. اکثر روش‌های عیب یابی پمپ‌های گریز از مرکز در ادبیات فن برای تشخیص عیوب تنها ارائه شده است. بنابراین در تحقیق حاضر، یک روش جدید مبتنی بر یادگیری انتقالی برای عیب یابی ترکیبی این پمپ‌ها معرفی شده است. در این روش ابتدا تصاویر زمان-فرکانسی از روی سیگنال‌های ارتعاشی محاسبه شده و سپس یک شبکه عصبی عمیق برای طبقه‌بندی این تصاویر بر حسب نوع عیب معرفی شده است. روند آموزش این شبکه با یادگیری انتقالی انجام شده است که باعث کاهش وابستگی شبکه‌ی عمیق به تعداد داده ورودی می‌شود. فرایند یادگیری انتقالی به این صورت انجام گرفته است که لایه‌های کانولوشنی فقط بر روی داده‌های عیوب تنها آموزش داده شده و داده‌های مربوط به عیوب ترکیبی در آموزش لایه‌های طبقه‌بندی کننده وارد می‌شوند. روش پیشنهادی با استفاده از سیگنال‌های ارتعاشی یک پمپ گریز از مرکز ارزیابی شده و کارایی آن در مقایسه با چند روش دیگر نشان داده شده است. دقت طبقه بندی روش پیشنهادی برای داده‌های مربوط به عیوب تنها ۱۰۰ درصد و برای داده‌های مربوط به عیوب ترکیبی، ۹۹.۱۵ درصد بدست آمده است. دقت بالا در تشخیص عیوب تنها و ترکیبی، عدم نیاز به تعداد داده زیاد و عیب یابی در محیط صنعتی واقعی از ویژگی‌های بارز روش پیشنهادی می‌باشد.

کلمات کلیدی: عیب یابی ترکیبی؛ یادگیری انتقالی؛ ماشین دوار؛ پمپ گریز از مرکز.

۱- مقدمه

پمپ‌های گریز از مرکز یک ماشین دوار پر کاربرد در صنایع مختلف می‌باشند. این ماشین‌ها در صنایع مختلفی مثل صنایع نفت و گاز، نیروگاه‌ها، کارخانجات مواد شیمیایی، معادن و غیره دارای اهمیت قابل توجهی هستند. با توجه به شرایط کاری خشن و

سرعت‌های کاری بالا، در هر لحظه احتمال وقوع خرابی در پمپ‌ها وجود دارد. در نتیجه برای پیش‌گیری از خسارت‌های جبران‌ناپذیر و توقف واحد صنعتی، پایش وضعیت و تشخیص زودهنگام عیوب مختلف پمپ‌های گریز از مرکز دارای اهمیت است [۱، ۲]. یک پمپ شامل قطعات مکانیکی مختلفی است که هر یک می‌توانند دچار عیب شوند [۳]. این عیوب می‌تواند هم بصورت تنها در یک بخش خاص، و هم بصورت همزمان در چند بخش مختلف ماشین دوار رخ دهد [۴]. به ویژه خرابی در یک بخش از ماشین دوار، می‌تواند بر روی عملکرد بخش‌های دیگر نیز تاثیر گذاشته و باعث عیوب ترکیبی در ماشین دوار شود [۵]. با توجه به اینکه در عیوب همزمان، عیب‌ها دارای شدت‌های متفاوتی هستند، عیب با شدت کمتر تحت تاثیر عیب شدیدتر قرار گرفته و شناسایی آن مشکل‌تر خواهد بود [۶]. همچنین عیوب رخ داده در بخش‌های متفاوت یک ماشین دوار، دارای مشخصه‌های عیب متفاوتی هستند که ترکیب این مشخصه‌ها با یکدیگر، از چالش‌های اصلی عیب‌یابی ترکیبی است [۷].

در سال‌های اخیر با گسترش روز افزون هوش مصنوعی و کاربردهای آن در زمینه‌های مختلف، روش‌های مختلفی برای عیب‌یابی ماشین‌های دوار بر اساس الگوریتم‌های هوش مصنوعی و به ویژه شبکه‌های عصبی ارائه شده است. عمده این روش‌ها بر پایه ترکیب روش‌های پردازش سیگنال و شبکه‌های عصبی می‌باشند. به این صورت که ابتدا یک مرحله پیش‌پردازش بر روی سیگنال‌های ارتعاشی اخذ شده از یک ماشین دوار به عنوان داده‌های خام انجام می‌شود. سپس خروجی این بخش وارد شبکه‌ی عصبی شده و سیگنال‌های ارتعاشی بر اساس نوع عیب رخ داده در ماشین دوار، طبقه‌بندی می‌شوند [۸-۱۰]. شبکه‌های عمیق کانولوشنی یکی از دقیق‌ترین و پرکاربردترین روش‌های مبتنی بر هوش مصنوعی می‌باشد که مورد توجه محققان بوده است. از مشکلات اصلی این شبکه‌ها، نیاز به تعداد داده بالا و سخت افزارهای محاسباتی مناسب می‌باشد. برای حل این مشکل نیز، روش‌هایی مثل یادگیری انتقالی، یادگیری متخاصم، شبکه‌های عصبی مولد و غیره ارائه شده است [۱۱، ۱۲]. در ادامه برخی از تحقیقاتی که در سال‌های اخیر برای عیب‌یابی هوشمند پمپ‌های گریز از مرکز انجام شده، بصورت خلاصه مرور شده‌اند.

حاج‌نایب [۱۳] از یادگیری انتقالی برای تشخیص عیب کاپیتاسیون در پمپ‌های گریز از مرکز استفاده کرده است. در روشی که او ارائه کرده است، ابتدا تحلیل طیف درجه سوم بر روی سیگنال‌های ارتعاشی پمپ انجام می‌شود. سپس تصاویر بدست آمده از تحلیل طیف درجه سوم وارد یک شبکه عصبی عمیق کانولوشنی شده و در مورد وقوع کاپیتاسیون در پمپ گریز از مرکز تصمیم‌گیری می‌شود. شبکه‌های کانولوشنی بکار رفته در تحقیق ایشان، دو شبکه عصبی عمیق پیش‌آموزش داده شده می‌باشد که با اعمال یادگیری انتقالی، برای عیب‌یابی پمپ‌ها تنظیم شده است. در تحقیق دیگری توسط حسن و همکاران [۱۴] یک روش مبتنی بر یادگیری عمیق برای تشخیص عیوب تنها در یک پمپ گریز از مرکز نصب شده در محیط آزمایشگاهی ارائه شده است. در این روش، ابتدا تبدیل موجک پیوسته بر روی سیگنال‌های ارتعاشی اعمال شده و تصاویر زمان-فرکانسی محاسبه می‌شود. سپس این تصاویر وارد یک شبکه عصبی عمیق کانولوشنی شده و بر حسب نوع عیب، طبقه‌بندی می‌شوند. ژانگ و ژائو [۱۵] نیز از یادگیری انتقالی برای تشخیص عیوب تنها در پمپ‌های گریز از مرکز با دور کاری بالا ارائه کرده‌اند. به طور خلاصه، در روش آنها ابتدا تصاویر زمان-فرکانسی ساده از روی سیگنال‌های ارتعاشی محاسبه می‌شود. سپس این تصاویر برای آموزش مبتنی بر یادگیری انتقالی بخشی از یک شبکه عصبی عمیق پیش‌آموزش داده شده استفاده می‌شود. نهایتاً این شبکه عصبی عمیق برای طبقه‌بندی سیگنال‌های ارتعاشی بر حسب نوع عیب بکار می‌رود. چنگ و همکاران [۱۶] با ترکیب روش تحلیل مولفه اصلی با کرنل وزن دار شده و طبقه‌بندی کننده ماشین بردار پشتیبان ازدحام ذرات، یک روش عیب‌یابی برای تشخیص سه عیب تنها در پمپ‌های گریز از مرکز ارائه کرده‌اند. در روش آنها، تعدادی از ویژگی‌های آماری سیگنال‌های ارتعاشی محاسبه شده و فرایند انتخاب ویژگی با روش تحلیل مولفه اصلی انجام می‌شود. سپس ویژگی‌های انتخاب شده وارد یک طبقه‌بندی کننده ماشین بردار پشتیبان که پارامترهای آن با الگوریتم بهینه‌سازی ازدحام ذرات تعیین می‌شوند وارد می‌شود. در نهایت سیگنال‌های ارتعاشی بر حسب نوع عیب رخ داده در پمپ، طبقه‌بندی می‌شوند. کومار و همکاران [۱۷] نیز از یک شبکه عصبی عمیق بهبود یافته برای تشخیص عیوب پمپ گریز از مرکز استفاده کرده‌اند. بهبود شبکه با معرفی یک تابع خطا مبتنی بر آنتروپی انجام شده است. سپس تصاویر زمان-فرکانسی محاسبه شده با تبدیل موجک تحلیلی وارد شبکه عصبی شده و طبقه‌بندی می‌شوند. زمان و همکاران [۱۸] یک روش مبتنی بر فیلترهای سوبل و شبکه‌های عصبی کانولوشنی برای تشخیص و طبقه‌بندی عیوب مختلف پمپ‌ها ارائه کرده‌اند. در این روش ابتدا با اعمال تبدیل S به سیگنال‌های ارتعاشی، تصاویر زمان-فرکانسی محاسبه می‌شوند. سپس این تصاویر با اعمال فیلتر سوبل تقویت شده و لبه‌های تصویر واضح‌تر می‌شود. در نهایت تصاویر

جدید با استفاده از یک شبکه عصبی کانولوشنی طبقه بندی می‌شوند. همچنین مانیکاندان و دورایولو [۱۹] در یک تحقیق دیگر از شبکه‌های عصبی عمیق برای طبقه بندی عیوب تنها در یک پمپ گریز از مرکز استفاده کرده‌اند. آنها در کار خود یک شبکه عمیق معرفی شده کرده‌اند که بر روی تصاویر زمان-فرکانسی سیگنال‌های ارتعاشی اخذ شده از یک پمپ گریز از مرکز در یک محیط آزمایشگاهی، آموزش داده می‌شود. سپس این شبکه عصبی برای عیب یابی و طبقه بندی سیگنال‌های ارتعاشی بر حسب نوع عیب پمپ استفاده می‌شود.

با بررسی روش‌های موجود در ادبیات فن برای عیب یابی هوشمند پمپ‌های گریز از مرکز، چند نکته اساسی وجود دارد که قابل توجه است. نخست اینکه اکثر روش‌های ارائه شده بر روی داده‌های تهیه شده در محیط آزمایشگاهی ارزیابی شده‌اند و قابلیت آنها برای تشخیص عیوب در محیط‌های صنعتی واقعی مشخص نیست. دوم اینکه تمرکز اکثر محققان بر روی تشخیص عیب‌های تنها بوده است، در حالی که عیوب ترکیبی در پمپ‌های گریز از مرکز بسیار محتمل است و عیب یابی ترکیبی نیز مسئله‌ای چالش برانگیز است. بنابراین در راستای حل چالش‌های ذکر شده و کاهش وابستگی شبکه‌های عمیق به تعداد بالای داده‌های ورودی، در تحقیق حاضر روشی بر مبنای یادگیری انتقالی برای تشخیص عیوب ترکیبی پمپ‌های گریز از مرکز پیشنهاد شده است. خلاصه روش به اینصورت است که ابتدا تبدیل ویولت فشرده کننده همزمان (WSST) بر روی سیگنال‌های ارتعاشی اعمال شده و تصاویر زمان-فرکانسی تهیه می‌شوند. با محاسبه این تصاویر، ویژگی‌های فرکانسی سیگنال‌های ارتعاشی بهتر نمایان خواهند شد. سپس تصاویر زمان-فرکانسی تهیه شده وارد یک شبکه عصبی عمیق مبتنی بر یادگیری انتقالی خواهند شد. شبکه مذکور یک شبکه کانولوشنی است که شامل لایه‌های کانولوشنی و لایه‌های تمام متصل می‌باشد. روند یادگیری شبکه به اینصورت در نظر گرفته شده است که ابتدا کل شبکه بر روی داده‌های مربوط به پمپ با عیوب تنها آموزش داده می‌شود و سپس با یادگیری انتقالی، داده‌های مربوط به عیوب ترکیبی فقط برای آموزش لایه‌های تمام متصل استفاده می‌شوند. روش پیشنهادی با استفاده از سیگنال‌های ارتعاشی اخذ شده از یک پمپ گریز از مرکز فعال در محیط صنعتی مورد ارزیابی قرار گرفته و قابلیت عیب یابی آن برای عیوب تنها و عیوب ترکیبی بررسی شده است.

۲- مواد و روش‌ها

شبکه‌های عصبی کانولوشنی کاربردهای بسیاری در زمینه‌های مختلف بینایی ماشین دارند. یک شبکه عصبی شامل لایه ورودی، لایه(های) پنهان و لایه خروجی می‌باشد [۲۰]. در شبکه‌های کانولوشنی، لایه‌های پنهان معمولاً ترکیبی از لایه‌های کانولوشنی، لایه‌های ادغام و لایه‌های تمام متصل می‌باشد. لایه خروجی نیز بر حسب هدف شبکه عصبی می‌تواند متفاوت باشد. در یک لایه کانولوشنی، وزن‌های لایه که اصطلاحاً کرنل نامیده می‌شوند با ورودی لایه کانولوشن شده و با یک بردار بایاس جمع می‌شود. همچنین هر لایه دارای یک تابع فعالسازی نیز می‌باشد که به خروجی عملیات قبلی اعمال می‌شود [۲۱]. خروجی یک لایه کانولوشنی (نقشه ویژگی) برای ورودی P بصورت رابطه زیر می‌باشد:

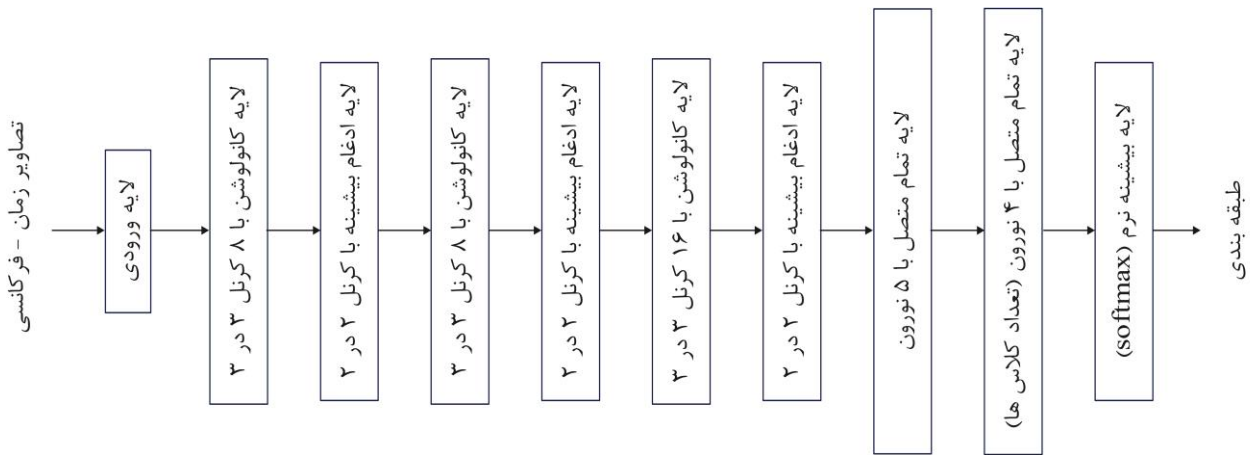
$$out = F(P * W + B) \quad (1)$$

که در این رابطه W ، B و F به ترتیب وزن‌های لایه، بایاس لایه و تابع فعالسازی می‌باشد. در کارهای طبقه‌بندی معمولاً تابع واحد یکسوسوده خطی که رلو (ReLU) نامیده می‌شود به عنوان تابع فعالساز لایه‌های کانولوشنی بکار می‌رود که در کار حاضر نیز از همین تابع استفاده شده است. تابع رلو یک تابع غیر خطی است که همگرایی شبکه‌های عمیق را سرعت می‌بخشد [۶]. رابطه این تابع بصورت زیر است:

$$F(x) = \text{ReLU}(x) = \begin{cases} x & x > 0 \\ 0 & x \leq 0 \end{cases} \quad (2)$$

در لایه‌های تمام متصل نیز کلیت روند همانند لایه‌های کانولوشنی است با این تفاوت که ضرب کانولوشنی با ضرب نقطه‌ای و تابع فعالسازی رلو با تابع خطی ($F = x$) جایگزین می‌شود. ادغام بیشینه، به دلیل اینکه علاوه بر کاهش ابعاد ورودی و وزن‌ها،

ویژگی‌های با بیشترین تاثیر و اهمیت را انتخاب می‌کند، پرکاربردترین نوع لایه ادغام است [۲۲]. در کار حاضر از ادغام بیشینه به عنوان لایه‌های ادغام و از تابع بیشینه هموار (softmax) به عنوان تابع لایه خروجی استفاده شده است. لایه خروجی در شبکه‌های طبقه‌بندی کننده، برداری به طول تعداد دسته‌های مجموعه داده تولید می‌کند. برای تابع بیشینه هموار، هر کدام از عناصر این بردار بیانگر احتمال عضویت ورودی در دسته مربوطه می‌باشد. معماری شبکه عصبی کانولوشنی مورد نظر در شکل (۱) نمایش داده شده است. لازم به ذکر است که گام کانولوشن در لایه‌های کانولوشنی ۱ در نظر گرفته شده است.



شکل ۱. معماری شبکه عصبی کانولوشنی مبتنی بر یادگیری انتقالی پیشنهادی.

آموزش شبکه‌های عصبی با الگوریتم پس انتشار انجام می‌شود. به این صورت که برای هر مجموعه از ورودی‌ها، خروجی شبکه عصبی محاسبه می‌شود. سپس مقدار خطا با توجه به مقدار واقعی (هدف) و مقدار پیش بینی شده‌ی شبکه عصبی محاسبه می‌شود. سپس با پس انتشار خطا از لایه خروجی به لایه ورودی، گرادیان وزن‌ها و پارامترهای قابل یادگیری شبکه عصبی بدست می‌آید. گرادیان‌های بدست آمده در یافتن ضرایب بهینه شبکه عصبی با اعمال الگوریتم‌های بهینه‌سازی بکار می‌روند. در نهایت وزن‌های بهینه شبکه بدست آمده و آموزش شبکه عصبی به پایان می‌رسد. در تحقیق حاضر از الگوریتم بهینه‌سازی آدام [۲۳] برای تعیین وزن‌های بهینه شبکه در طول آموزش استفاده شده است.

بصورت سنتی، شبکه‌های عصبی مصنوعی بر روی بخشی از داده‌های یک دیتاست آموزش داده شده و با بخش دیگری از همان دیتاست تست می‌شوند. از طرفی شبکه‌های عصبی عمیق نیاز به تعداد داده بالایی دارند و طرف دیگر آموزش این شبکه‌ها به دلیل تعداد وزن‌های زیاد و حجم داده ورودی زمانبر است. در کارهای واقعی، تهیه مجموعه داده‌های با حجم و کیفیت بالا بسیار مشکل است [۲۴]. یادگیری انتقالی یکی از روش‌هایی است که با هدف افزایش دقت شبکه عصبی و کاهش وابستگی آن به داده‌های تعداد بالا ارائه شده است. در یادگیری انتقالی، ابتدا یک شبکه عصبی کانولوشنی که اصطلاحاً شبکه معلم نامیده می‌شود بر روی مجموعه داده منبع آموزش داده می‌شود. سپس شبکه عصبی آموزش داده شده برای یک مجموعه داده مشابه به نام مجموعه داده هدف تنظیم دقیق می‌شود [۹]. برای روش پیشنهادی، در مرحله تنظیم دقیق تنها لایه‌های تمام متصل شبکه عصبی کانولوشنی با مجموعه هدف آموزش داده شده و وزن‌های لایه‌های کانولوشنی ثابت خواهند ماند. همچنین داده‌های مربوط به عیوب تنها به عنوان مجموعه داده منبع و داده‌های مربوط به عیوب ترکیبی نیز به عنوان مجموعه داده هدف در نظر گرفته شده است.

در این تحقیق برای محاسبه تصاویر زمان-فرکانسی سیگنال‌های ارتعاشی از تبدیل موجک فشرده کننده همزمان استفاده شده است. تبدیل موجک فشرده کننده همزمان یک روش آنالیز زمان-فرکانسی است که برای تجزیه سیگنال‌ها به اجزا سازنده با ویژگی‌های نوسانی متغیر با زمان طراحی شده است [۲۵]. این روش با صرفه جویی در وضوح زمانی، انرژی سیگنال را در حوزه فرکانسی تخصیص مجدد می‌دهد. این تخصیص مجدد یا به بیان دیگر جابجایی مکان انرژی، اثرات پراکندگی ناشی از موجک مادر را جبران می‌کند [۲۶].

همچنین تبدیل موجک فشرده کننده همزمان معکوس ضمن ثابت نگهداشتن وضوح زمانی، قادر است که تصویر دقیقی از سیگنال اصلی را بازسازی کند [۲۷]. بطور خلاصه، الگوریتم تبدیل موجک فشرده کننده همزمان صورت زیر است:

۱- محاسبه ضرایب تبدیل ویولت پیوسته $w_x(t, a)$ برای سیگنال ورودی $x(t)$ از رابطه زیر:

$$w_x(t, a) = \left| \frac{1}{\sqrt{a}} \right| x(t) * \psi^*\left(\frac{-t}{a}\right) \quad (3)$$

که a ضریب مقیاس، $*$ عملگر ضرب کانولوشنی و ψ^* مزدوج مختلط تابع موجک مادر ψ می‌باشد.

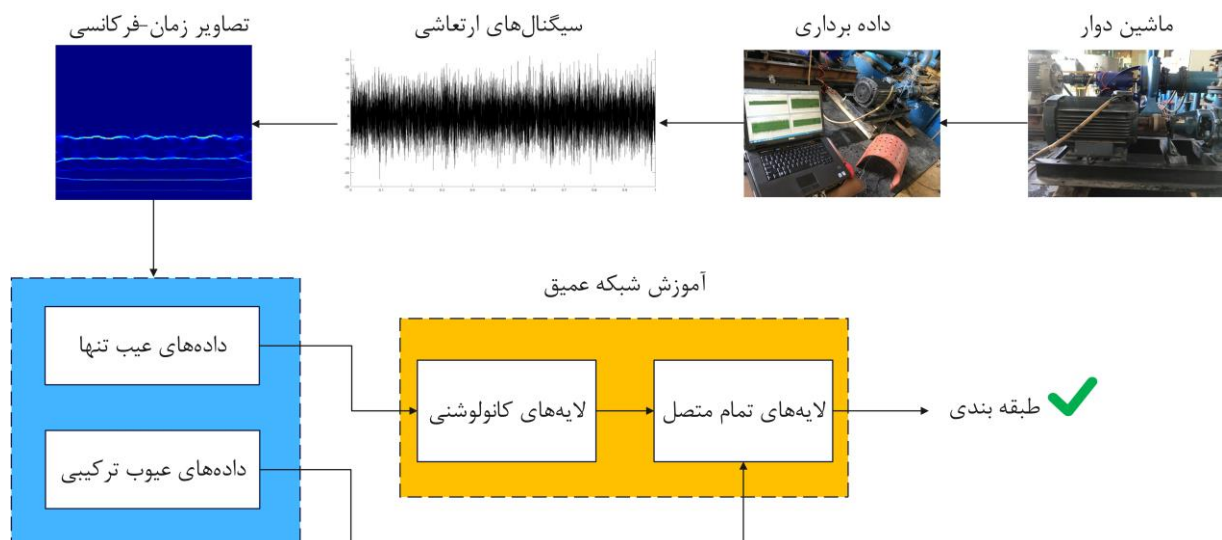
۲- استخراج فرکانس‌های لحظه‌ای از خروجی تبدیل موجک پیوسته. رابطه فرکانس لحظه‌ای ω_i بصورت زیر است:

$$\omega_i = -i \frac{dw_x(t, a)}{w_x(t, a)} \quad (4)$$

در رابطه فوق، b و d به ترتیب ضریب انتقال تبدیل موجک و عملگر دیفرانسیل می‌باشند.

۳- فشرده سازی ضرایب تبدیل موجک پیوسته روی مکان‌هایی که فاز تبدیل ثابت است. این تخصیص مجدد باعث تیز شدن وضوح فرکانسی انرژی در مقایسه با تبدیل موجک پیوسته می‌شود.


لازم به ذکر است که در کار حاضر از تبدیل موجک بامپ به عنوان موجک مادر استفاده شده است. در نهایت، فلوجارت روش پیشنهادی در شکل (۲) نمایش داده شده است.



شکل ۲. فلوجارت روش عیب یابی پیشنهادی.

۳- نتایج تجربی

برای ارزیابی روش عیب یابی پیشنهادی، یک پمپ گریز از مرکز تولید شرکت پمپیران (مدل ۱۶۰-۶۵ EN) که در یک محیط صنعتی واقعی (شرکت نوید سهند) نصب شده برای بررسی انتخاب شده است. داده‌های تجربی با فرکانس نمونه برداری ۱۶۳۸۴ هرتز دریافت شده‌اند. همچنین سرعت دورانی این پمپ گریز از مرکز، ۳۰۰۰ دور بر دقیقه می‌باشد. فرایند داده برداری به نحوی انجام شده است که سه عیب مختلف کاویتاسیون، ناهمراستایی محوری و خرابی بلبرینگ هرکدام بصورت تکی، دو عیب همزمان و سه عیب همزمان برای پمپ در نظر گرفته شده باشد. تصویر پمپ مذکور در شکل (۳) نمایش داده شده است.



شکل ۳. تجهیزات تست تجربی پمپ گریز از مرکز.

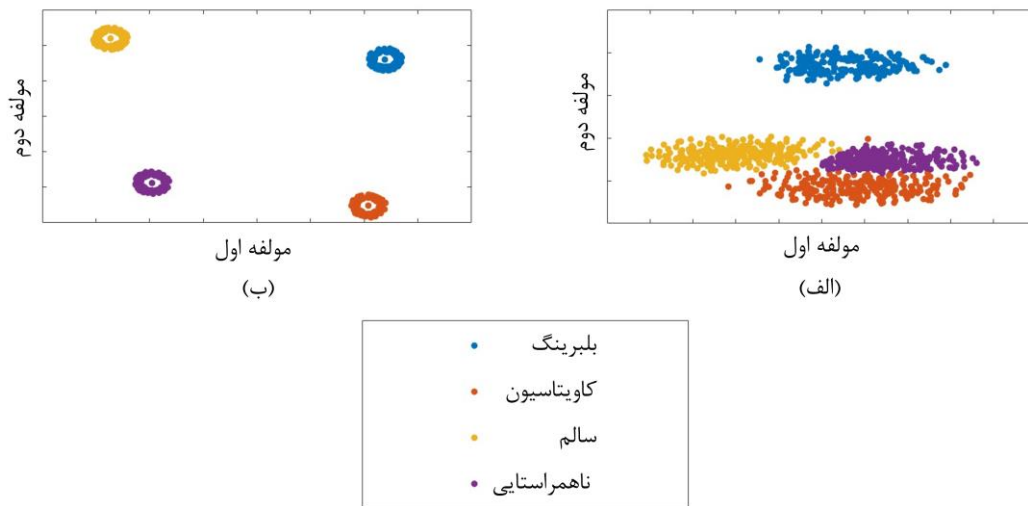
با توجه به شرایط در نظر گرفته شده برای پمپ در داده برداری، این داده‌ها در هشت دسته مختلف قابل طبقه‌بندی هستند. این دسته‌ها به این صورت است: ۱- سالم، ۲- عیب تنه‌های بلبرینگ، ۳- عیب تنه‌های ناهمراستایی، ۴- عیب تنه‌های کاویتاسیون، ۵- عیوب ترکیبی بلبرینگ و ناهمراستایی، ۶- عیوب ترکیبی بلبرینگ و کاویتاسیون، ۷- عیوب ترکیبی ناهمراستایی و کاویتاسیون و ۸- عیوب ترکیبی بلبرینگ، ناهمراستایی و کاویتاسیون. طول سیگنال‌ها ۴۰۹۶ داده در نظر گرفته شده است. با توجه به حجم داده‌های در دسترس تعداد ۲۴۰ سیگنال برای هر دسته موجود است. از هر دسته تعداد ۲۰۰ داده برای آموزش شبکه عصبی و سایر داده‌ها برای تست شبکه مورد استفاده قرار گرفته‌اند. برای الگوریتم آموزش وزن‌های شبکه عصبی، نرخ یادگیری ۰/۰۰۰۰۱، نرخ منظم سازی ۰/۰۰۰۱ و تعداد دسته‌های ۱۰ تایی در نظر گرفته شده است. پس از پایان آموزش شبکه عصبی با داده‌های مربوط به پمپ با عیوب تنها، دقت طبقه بندی ۱۰۰ درصد هم برای طبقه بندی داده‌های آموزشی و هم داده‌های تست بدست آمده است. دقت طبقه‌بندی شبکه عصبی پیشنهادی پس از آموزش با یادگیری انتقالی و همچنین چند الگوریتم طبقه بندی دیگر در جدول (۱) ذکر شده است.

جدول ۱. دقت طبقه بندی روش پیشنهادی در مقایسه با چند روش دیگر.

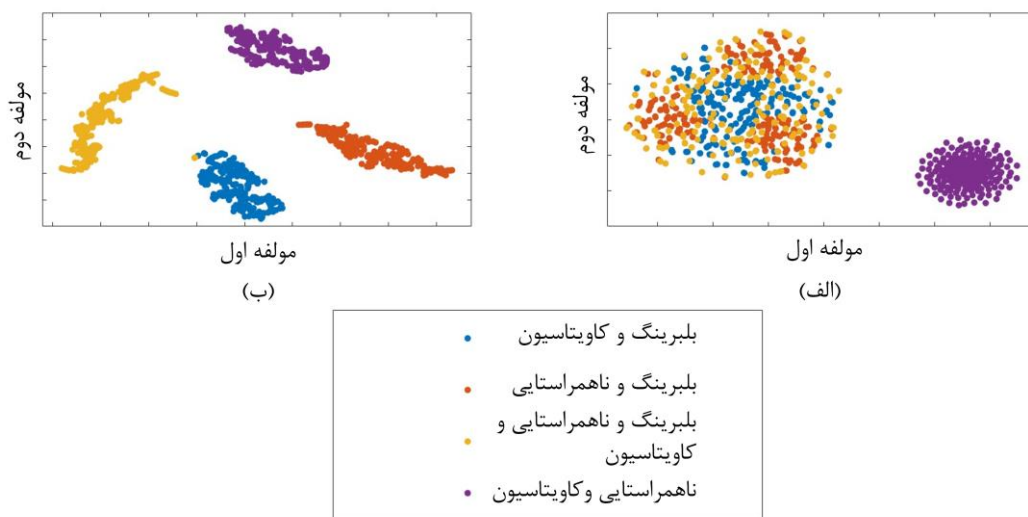
روش	دقت طبقه بندی داده‌های آموزشی (%)	دقت طبقه بندی داده‌های تست (%)
ماشین بردار پشتیبان [۲۲]	۹۷.۱۹	۹۷.۰۸
نزدیک ترین همسایه [۲۸]	۱۰۰	۵۸.۲۴
نزدیک ترین همسایه بر روی ویژگی های هیستوگرام گرا [۱۸]	۱۰۰	۷۷.۴۴
درخت تصمیم [۲۹]	۹۸.۳۱	۸۷.۵۴
شبکه عصبی مبتنی بر یادگیری انتقالی پیشنهادی	۱۰۰	۹۹.۱۵

با مقایسه نتایج طبقه بندی روش پیشنهادی با چند روش طبقه بندی معروف، مشاهده می‌شود که روش پیشنهادی برای طبقه بندی داده‌های آموزشی و داده‌های تست بهترین نتیجه را ارائه کرده است. برای بررسی‌های بیشتر، نمودار خروجی‌های نخستین لایه

کانولوشنی و لایه آخر شبکه (بیشینه نرم) پس از کاهش بعد با الگوریتم کاهش ابعادی t-sne [۳۰] در شکل‌های (۴) و (۵) نمایش داده شده است. شکل (۴) پس از آموزش شبکه عصبی عمیق با داده‌های عیب تنها و شکل (۵) پس از تنظیم دقیق آن با داده‌های عیوب ترکیبی رسم شده است.



شکل ۴. رسم خروجی‌های دو لایه از شبکه عصبی کانولوشنی پیشنهادی با استفاده از t-sne برای داده‌های عیوب تنها (الف) لایه اول کانولوشنی (ب) لایه خروجی شبکه عصبی.



شکل ۵. رسم خروجی‌های دو لایه از شبکه عصبی کانولوشنی پیشنهادی با استفاده از t-sne برای داده‌های عیوب ترکیبی (الف) لایه اول کانولوشنی (ب) لایه خروجی شبکه عصبی.

با بررسی شکل‌های (۴) و (۵) مشخص است که در خروجی شبکه عصبی پیشنهادی، داده‌های ورودی به خوبی به دسته‌های مختلف تفکیک و طبقه بندی شده‌اند. نکته قابل توجه این است که داده‌های مربوط به عیوب تنهای پمپ از همان لایه نخست شبکه از یکدیگر تفکیک شده‌اند (شکل ۴-الف). دلیل این تفکیک می‌تواند ویژگی‌های متفاوت هر یک از عیوب تنها باشد. این درحالی است که

داده‌های مربوط به سه دسته عیوب ترکیبی بلبرینگ با کاویتاسیون، بلبرینگ با ناهمراستایی و بلبرینگ با ناهمراستایی با کاویتاسیون در لایه نخست شبکه عصبی کاملاً با یکدیگر مخلوط شده‌اند (شکل ۵-الف). این ترکیب شدن داده‌های مربوط به دسته‌های عیوب ترکیبی، نشان دهنده وجود ویژگی‌های مشترک در دسته‌های مختلف است. بنابراین دشواری و چالش عیب‌یابی ترکیبی در مقایسه با تشخیص عیوب تنها، به خوبی مشخص می‌شود. لازم به ذکر است که عدم ترکیب داده‌های مربوط به دسته عیوب ترکیبی ناهمراستایی با کاویتاسیون با سه دسته دیگر، می‌تواند بیانگر این نکته باشد که شدت عیب بلبرینگ که خرابی مشترک در سه دسته مذکور می‌باشد، نسبت به عیوب دیگر بیشتر است. در نتیجه از همان لایه‌های ابتدایی، شبکه داده‌های شامل خرابی بلبرینگ را از داده‌های بدون خرابی بلبرینگ تفکیک کرده است.

۴- نتیجه‌گیری

از یک طرف با توجه به اهمیت پمپ‌های گریز از مرکز در صنایع و از طرف دیگر با توجه به اینکه اکثر روش‌های موجود در ادبیات فن برای تشخیص عیوب تنها در این پمپ‌ها ارائه شده است، در کار حاضر یک روش هوشمند جدید برای تشخیص عیوب ترکیبی در پمپ‌های گریز از مرکز پیشنهاد شد. بصورت خلاصه در این روش، ابتدا تصاویر زمان-فرکانسی از روی سیگنال‌های ارتعاشی پمپ محاسبه می‌شوند. سپس این تصاویر وارد یک شبکه عصبی عمیق مبتنی بر یادگیری انتقالی شده و فرایند عیب‌یابی انجام می‌شود. آموزش شبکه عصبی عمیق پیشنهادی به این صورت انجام شده است که ابتدا کل شبکه بر روی داده‌های عیب تنها آموزش داده شده است. پس از آموزش شبکه با داده‌های مربوط به عیب‌های پمپ، داده‌های عیوب ترکیبی فقط برای آموزش و تنظیم دقیق لایه‌های تمام متصل شبکه عصبی استفاده شده‌اند. بنابراین لایه‌های کانولوشنی تنها با داده‌های عیوب تنها آموزش داده شده‌اند. برای ارزیابی روش پیشنهادی، از سیگنال‌های ارتعاشی یک پمپ گریز از مرکز که در محیط صنعتی واقعی نصب شده، استفاده شده است. در نتایج تحقیق نشان داده شده است که روش پیشنهادی دقت بسیار بالایی برای طبقه‌بندی و تشخیص عیوب تنها و ترکیبی دارد. همچنین دقت طبقه‌بندی این روش با چند روش طبقه‌بندی دیگر مقایسه شده و کارایی آن مشخص شده است. قابلیت تفکیک و دسته‌بندی روش پیشنهادی در بررسی سیگنال‌های ارتعاشی اخذ شده از محیط صنعتی، نشان دهنده کارایی بالا و عملیاتی بودن روش می‌باشد. علاوه بر این پیچیدگی عیب‌یابی ترکیبی در مقایسه با تشخیص عیوب تنها نیز با بررسی خروجی لایه‌های شبکه عصبی عمیق نشان داده شده است. در نهایت نتیجه می‌شود که روش پیشنهادی، روش مناسب و دقیقی برای تشخیص عیوب ترکیبی پمپ‌های گریز از مرکز می‌باشد. این روش با کاهش وابستگی شبکه‌های عمیق به تعداد بالای داده، کارایی خوبی برای عیب‌یابی در محیط‌های صنعتی را دارد.

تشکر و قدردانی

نویسندگان از همکاری و حمایت شرکت پمپ‌سازی نوید سهند (گروه صنعتی پمپیران) در تهیه این تحقیق قدرانی می‌کنند.

مراجع

- [1] A. Al-Braik, O. Hamomd, F. Gu, and A. Ball, "Diagnosis of impeller faults in a centrifugal pump based on spectrum analysis of vibration signals," in *11th International Conference on Condition Monitoring and Machinery Failure Prevention Technologies*, 2014: British Institute of Non-Destructive Testing.
- [2] R. B. Randall, *Vibration-based Condition Monitoring: Industrial, Automotive and Aerospace Applications*. John Wiley & Sons, 2021.
- [3] M. Zhang, Z. Jiang, and K. Feng, "Research on variational mode decomposition in rolling bearings fault diagnosis of the multistage centrifugal pump," *Mechanical Systems and Signal Processing*, vol. 93, pp. 460-493, 2017.

- [4] A. K. Panda, J. S. Rapur, and R. Tiwari, "Prediction of flow blockages and impending cavitation in centrifugal pumps using Support Vector Machine (SVM) algorithms based on vibration measurements," *Measurement*, vol. 130, pp. 44-56, 2018.
- [5] M. Y. Asr, M. M. Etefagh, R. Hassannejad, and S. N. Razavi, "Diagnosis of combined faults in rotary machinery by non-naive Bayesian approach," *Mechanical Systems and Signal Processing*, vol. 85, pp. 56-70, 2017, doi: <https://doi.org/10.1016/j.ymssp.2016.08.005>
- [6] A. Dibaj, M. M. Etefagh, R. Hassannejad, and M. B. Ehghaghi, "A hybrid fine-tuned VMD and CNN scheme for untrained compound fault diagnosis of rotating machinery with unequal-severity faults," *Expert Systems with Applications*, vol. 167, p. 114094, 2021, doi: <https://doi.org/10.1016/j.eswa.2020.114094>.
- [7] J. C. A. J. Correa and A. A. L. Guzman, *Mechanical vibrations and condition monitoring*. Academic Press, 2020.
- [8] Y. Lei, B. Yang, X. Jiang, F. Jia, N. Li, and A. K. Nandi, "Applications of machine learning to machine fault diagnosis: A review and roadmap," *Mechanical Systems and Signal Processing*, vol. 138, p. 106587, 2020, doi: <https://doi.org/10.1016/j.ymssp.2019.106587>.
- [9] C. Qian, J. Zhu, Y. Shen, Q. Jiang, and Q. Zhang, "Deep transfer learning in mechanical intelligent fault diagnosis: application and challenge," *Neural Processing Letters*, vol. 54, no. 3, pp. 2509-2531, 2022, doi: <https://doi.org/10.1007/s11063-021-10719-z>.
- [10] S. Djaballah, K. Meftah, K. Khelil, and M. Sayadi, "Deep Transfer Learning for Bearing Fault Diagnosis using CWT Time-Frequency Images and Convolutional Neural Networks," *Journal of Failure Analysis and Prevention*, pp. 1-13, 2023.
- [11] Y. Ma, J. Yang, and L. Li, "Collaborative and adversarial deep transfer auto-encoder for intelligent fault diagnosis," *Neurocomputing*, vol. 486, pp. 1-15, 2022, doi: <https://doi.org/10.1016/j.neucom.2022.02.050>.
- [12] W. Zhang, X. Li, and Q. Ding, "Deep residual learning-based fault diagnosis method for rotating machinery," *ISA transactions*, vol. 95, pp. 295-305, 2019, doi: <https://doi.org/10.1016/j.isatra.2018.12.025>.
- [13] A. Hajnayeb, "Cavitation analysis in centrifugal pumps based on vibration bispectrum and transfer learning," *Shock and Vibration*, vol. 2021, pp. 1-8, 2021.
- [14] M. J. Hasan, A. Rai, Z. Ahmad, and J.-M. Kim, "A fault diagnosis framework for centrifugal pumps by scalogram-based imaging and deep learning," *IEEE Access*, vol. 9, pp. 58052-58066, 2021.
- [15] D. Zhang and T. Zhou, "Deep Convolutional Neural Network Using Transfer Learning for Fault Diagnosis," *IEEE Access*, vol. 9, pp. 43889-43897, 2021, doi: 10.1109/ACCESS.2021.3061530.
- [16] Z. Cheng, H. Liu, R. Hua, L. Dong, Q. Ma, and J. Zhu, "Research on Multi-Fault Identification of Marine Vertical Centrifugal Pump Based on Multi-Domain Characteristic Parameters," *Journal of Marine Science and Engineering*, vol. 11, no. 3, p. 551, 2023.
- [17] A. Kumar, C. Gandhi, Y. Zhou, R. Kumar, and J. Xiang, "Improved deep convolution neural network (CNN) for the identification of defects in the centrifugal pump using acoustic images," *Applied Acoustics*, vol. 167, p. 107399, 2020.
- [18] W. Zaman, Z. Ahmad, M. F. Siddique, N. Ullah, and J.-M. Kim, "Centrifugal Pump Fault Diagnosis Based on a Novel SobelEdge Scalogram and CNN," *Sensors*, vol. 23, no. 11, p. 5255, 2023.
- [19] S. Manikandan and K. Duraivelu, "Vibration-based fault diagnosis of broken impeller and mechanical seal failure in industrial mono-block centrifugal pumps using deep convolutional neural network," *Journal of Vibration Engineering & Technologies*, vol. 11, no. 1, pp. 141-152, 2023.
- [20] Y. LeCun, L. Bottou, Y. Bengio, and P. Haffner, "Gradient-based learning applied to document recognition," *Proceedings of the IEEE*, vol. 86, no. 11, pp. 2278-2324, 1998.
- [21] H. Han, H. Wang, Z. Liu, and J. Wang, "Intelligent vibration signal denoising method based on non-local fully convolutional neural network for rolling bearings," *ISA transactions*, vol. 122, pp. 13-23, 2022.
- [22] Y. Xue, D. Dou, and J. Yang, "Multi-fault diagnosis of rotating machinery based on deep convolution neural network and support vector machine," *Measurement*, vol. 156, p. 107571, 2020, doi: <https://doi.org/10.1016/j.measurement.2020.107571>.
- [23] D. P. Kingma and J. Ba, "Adam: A method for stochastic optimization," *arXiv preprint arXiv:1412.6980*, 2014.
- [24] Z. Jin, D. He, R. Ma, X. Zou, Y. Chen, and S. Shan, "Fault diagnosis of train rotating parts based on multi-objective VMD optimization and ensemble learning," *Digital Signal Processing*, vol. 121, p. 103312, 2022, doi: <https://doi.org/10.1016/j.dsp.2021.103312>.
- [25] G. Thakur, E. Brevdo, N. S. Fućkar, and H.-T. Wu, "The synchrosqueezing algorithm for time-varying spectral analysis: Robustness properties and new paleoclimate applications," *Signal processing*, vol. 93, no. 5, pp. 1079-1094, 2013.
- [26] I. Daubechies, J. Lu, and H.-T. Wu, "Synchrosqueezed wavelet transforms: An empirical mode decomposition-like tool," *Applied and computational harmonic analysis*, vol. 30, no. 2, pp. 243-261, 2011.

- [27] A. Kumar, C. Gandhi, Y. Zhou, G. Vashishtha, R. Kumar, and J. Xiang, "Improved CNN for the diagnosis of engine defects of 2-wheeler vehicle using wavelet synchro-squeezed transform (WSST)," *Knowledge-Based Systems*, vol. 208, p. 106453, 2020.
- [28] J. Tian, C. Morillo, M. H. Azarian, and M. Pecht, "Motor bearing fault detection using spectral kurtosis-based feature extraction coupled with K-nearest neighbor distance analysis," *IEEE Transactions on Industrial Electronics*, vol. 63, no. 3, pp. 1793-1803, 2015, doi: 10.1109/TIE.2015.2509913.
- [29] V. Muralidharan and V. Sugumaran, "Feature extraction using wavelets and classification through decision tree algorithm for fault diagnosis of mono-block centrifugal pump," *Measurement*, vol. 46, no. 1, pp. 353-359, 2013.
- [30] L. Van der Maaten and G. Hinton, "Visualizing data using t-SNE," *Journal of machine learning research*, vol. 9, no. 11, 2008.