



## تشخیص و طبقه‌بندی عیوب پمپ هیدرولیک دنده‌ای با استفاده از پردازش سیگنال‌های ارتعاشی توسط تبدیل موجک پیوسته و شبکه عصبی کانولوشنی

حیدر فاضل محمد<sup>۱</sup>، احمد سهیلی مهدی‌زاده<sup>۲\*</sup>

تاریخ دریافت: ۱۴۰۱/۰۲/۱۷

تاریخ پذیرش: ۱۴۰۱/۰۳/۲۵

### چکیده

سیگنال ضبط شد و سپس هر سیگنال توسط روش تبدیل موجک پیوسته پردازش گردید و در نهایت از این تصاویر جهت ایجاد مدل یادگیری عمیق برای طبقه‌بندی عیوب پمپ استفاده شد. شبکه عصبی کانولوشنی با ۱۳ لایه جهت طبقه بندی عیوب در پمپ ایجاد شد و پس از ۷۰ بار تکرار آموزش، مدل آموزشی بهینه شد و به دقت با دقت ۹۶/۶۷٪ دست یافت. ارزیابی مدل نشان داد که دقت این مدل برای تشخیص سه کلاس سالم، سائیدگی در دنده داخل و سائیدگی در دنده خارجی برابر با ۸۸/۳۳٪ بود.

**کلمات کلیدی:** عیب یابی، پمپ هیدرولیک، اسکالوگرام، شبکه کانولوشنی

پمپ‌های هیدرولیکی به عنوان قلب یک سیستم هیدرولیک هستند و هر گونه خرابی که در آنها ایجاد شود عملکرد سیستم هیدرولیک مختل می‌شود لذا پایش کارکرد پمپ‌های هیدرولیک جهت اطمینان از آماده به کار بودن سیستم‌های هیدرولیکی امری ضروری است. در مقاله حاضر یک روش هوشمند براساس پردازش سیگنال‌های ارتعاشی و روش یادگیری عمیق برای تشخیص عیوب در پمپ هیدرولیک دنده‌ای استفاده شد. در پژوهش حاضر از یک پمپ هیدرولیک دنده داخلی استفاده شد. آزمون‌های داده برداری بر روی پمپ در سرعت ۱۲۰۰ دور در دقیقه با استفاده از حسگر ارتعاش سنج Global Test AP 98-100 و مجموعه اکتساب داده Advantech USB-4704 و مجموعه اکتساب داده data acquisition انجام شد. برای هر وضعیت از پمپ ۱۰۰

### مقدمه

اصلی، تجزیه و تحلیل تشخیصی محلی و غیره است. با این حال، تمام این رویکردها نیاز به انتخاب دستی ویژگی‌هایی دارند که دارای دو مسأله در برنامه‌های صنعت واقعی هستند. اول، اندازه گیری نویز، خطاهای اپراتور، دینامیک غیر خطی، و غیره منجر به عدم اطمینان قابل توجهی در سیگنال می‌شود. [Simani et. al., 2014]. دوم، تعداد مشخصه‌های مربوط به عیب در سیگنال جمع آوری شده بسیار زیاد است، اما اکثر آنها نسبت به وضعیت سلامتی بی تفاوت هستند، که شناسایی آنها از طریق انتخاب دستی دشوار است. با توجه به این دو موضوع، استخراج مجموعه‌ای از ویژگی‌های حساس به صورت دستی بسیار دشوار و وقت گیر است، بنابراین به کار بردن آنها در برنامه‌های کاربردی صنعتی واقعی نیز دشوار است. [Lei et. al., 2016].

روش‌های شناسایی و تشخیص عیب مبتنی بر سیگنال به طور گسترده در نظارت و تشخیص سریع برای موتورها، ساختمان‌ها، مبدل‌های قدرت و سایر سیستم‌های مکانیکی استفاده می‌شوند. این روش‌ها شامل سه بخش است: دریافت سیگنال؛ استخراج ویژگی‌ها؛ و تشخیص عیب. چالش برانگیزترین بخش استخراج ویژگی‌های عیب حساس از سیگنال‌های نویز جمع آوری شده است [Riera-Guasp et. al., 2014]. در حال حاضر، دو نوع رویکرد برای انتخاب ویژگی‌های حساس از سیگنال نویز جمع آوری شده وجود دارد. اولین رویکرد، رویکرد پردازش سیگنال است، مانند تجزیه و تحلیل آماری، تبدیل فوریه، تبدیل موجک، تجزیه حالت تجربی و نمایش پراکنده. علاوه بر رویکرد پردازش سیگنال، کاهش ابعاد رویکرد دیگری برای انتخاب ویژگی‌ها است که شامل تحلیل مؤلفه‌های

<sup>۱-۲</sup> گروه مهندسی مکانیک، دانشکده فنی و مهندسی، واحد کرمانشاه، دانشگاه آزاد اسلامی، کرمانشاه، ایران

\* نویسنده مسؤول: Soheili2008@gmail.com



برخلاف روش‌های سنتی، یادگیری عمیق یک یادگیری ماشینی جدید ارائه شده است، که دارای ظرفیت عالی برای یادگیری خودکار ویژگی‌های ارزشمند از داده‌های خام است. مدل‌های یادگیری عمیق برای تشخیص خطا را می‌توان به سه نوع اصلی تقسیم کرد: شبکه عصبی پیچشی، شبکه باور عمیق و شبکه عصبی خود رمزگذار عمیق [Jiang et. al., 2017]. اینس و همکاران [Ince et. al., 2016] از یک شبکه عصبی پیچشی برای تشخیص عیب موتور استفاده کرد و مراحل استخراج و طبقه بندی مشخصه‌ها را با یک بدنه یادگیری واحد ادغام کرد. لیو و همکاران [Liu et. al., 2017] یک شبکه باور عمیق گاوسی برنولی را برای یادگیری ویژگی‌های حساس برای تشخیص سیستم روتور بر اساس تصویربرداری ارتعاش، ساختند. جیا و همکاران [Jia et. al., 2016] یک شبکه عصبی خود رمزگذار عمیق را برای کاهش ابعاد داده به منظور استخراج ویژگی‌های کاربردی از ارتعاش اندازه‌گیری شده جهت تشخیص عیب ساختند. با این حال، اکثر مدل‌های یادگیری عمیق به خوبی تحت یک فرض کلی خوب عمل می‌کنند. داده‌های آموزشی و آزمون‌ی باید فضای توزیع و ویژگی‌های مشابه داشته باشند [Lu et. al., 2016]. متأسفانه، این وضعیت اغلب در شرایط کاری با زمان‌های متفاوت اتفاق می‌افتد، که به شدت اعتبار روش‌های یادگیری ماشینی مورد استفاده در عیب‌یابی در خارج از شرایط آزمایشگاهی یکسان با زمان کنترل شده را به چالش می‌کشد. به منظور حل این مشکل، ون و همکاران [Wen et. al., 2017] مدل شبکه عصبی خود رمزگذار عمیق را برای تشخیص عیب بلبرینگ بر اساس ویژگی‌های انتقال عمیق، پیشنهاد کردند. لیو و همکاران [Liu et. al., 2016] یک ساختار عصبی پیچشی با سری زمانی جا به جا شده را برای پی بردن به ویژگی‌های عیب الکتریکی ماشین از سیگنال ارتعاش در شرایط غیر ثابت، طراحی کردند. لیو و همکاران [Lu et. al., 2016] یک مدل شبکه عصبی عمیق جدید را با تطبیق پذیری دامنه برای عیب‌یابی پیشنهاد کرد. بنا بر مطالب ارائه شده در فوق، هدف این تحقیق ارائه یک مدل یادگیری عمیق جهت طبقه‌بندی عیوب پمپ هیدرولیک بر اساس پردازش سیگنال‌های ارتعاشی توسط تبدیل موجک و مدل یادگیری عمیق است.

تشخیص عیوب، نگهداری و تعمیر در شرایط خاص برای پمپ‌های هیدرولیک به منظور جلوگیری از خرابی پمپ‌ها و اطمینان یافتن از عملکرد ایمن و مؤثر کل سیستم هیدرولیک، ضروری است [Sun & Xu, 2016]. برای پی بردن به لزوم نگهداری و تعمیر در شرایط خاص برای پمپ‌های هیدرولیک، حسگرهای فشار، حسگرهای لرزه، حسگرهای دما و ... بر روی یک سیستم پمپ هیدرولیک هوشمند نصب شده‌اند. داده‌های ارتعاشی جمع‌آوری شده از سنسورهای شتاب، به دلیل مزایای آن از جمله زمان واقعی و واکنش پذیری سریع، سیگنال نظارتی رایجی در تشخیص عیب پمپ‌های هیدرولیک است [Sun et. al. 2018].

هنگامی که در یک پمپ هیدرولیک نقصی رخ می‌دهد، شوک ارتعاشی مربوط به عیب داخل پمپ از جهات مختلف به محفظه پمپ که حاوی اطلاعات فراوانی از وضعیت پمپ است، منتقل می‌شود. شایان ذکر است که به دلیل پیچیدگی و نامنظم بودن ساختار داخلی پمپ‌های هیدرولیک، سیگنال‌های ارتعاشی در جهات مختلف از نظر اطلاعات وضعیت دارای تفاوت‌هایی هستند و جمع‌آوری یا پردازش یک سیگنال ارتعاشی تنها در یک جهت می‌تواند به راحتی منجر به از دست دادن اطلاعات مربوط به وضعیت شود [Yu et. al. 2019]. بنابراین لازم است سیگنال‌های ارتعاشی در جهات مختلف پمپ هیدرولیک جمع‌آوری و ادغام شوند تا مشخصه‌های عیب ضعیف احتمالی شناسایی شوند. با این حال، سیگنال‌های ارتعاش پمپ به دلیل تراکم‌پذیری مایع و ارتعاش مکانیکی ذاتی پمپ، مدل غیرخطی و غیر ایستایی قوی را نشان می‌دهند [Sun et. al., 2016]. تبدیل موجک یک رویکرد تحلیل تبدیل سیگنال معمولی با وضوح چندگانه است. ژونگدا و همکاران تبدیل موجک را برای تجزیه و بازسازی سری‌های زمانی آشفته با تلفیق اجزای تقریبی و اجزای جزئیات به کار گرفتند [Zhongda et. al. 2017]. دوگرا و همکاران از تبدیل موجک و قانون تلفیق میانگین برای ساخت یک چارچوب تلفیق تصویر استفاده کردند [Dogra et. al. 2017]. با این وجود، عملکرد پایه موجک باید از طریق تجربه ذهنی از قبل تعیین شود. این مسأله بدان معناست که تبدیل موجک قابل تطبیق نیست. علاوه بر این، مشکل نشت فرکانس آن نیز خود را قادر به پردازش و ادغام سیگنال‌های ارتعاشی پیچیده نمی‌کند [Cheng et. al., 2016].




## مواد و روش‌ها

## مجموعه مورد مطالعه جهت دانه برداری

به منظور تهیه مجموعه داده‌های لازم جهت پیاده سازی مدل یادگیری عمیق، مطابق شکل ۱، یک بستر برای دانه برداری پیاده سازی شد. یک مدل پمپ هیدرولیک دنده داخلی که توسط کوپلینگ به یک الکتروموتور کوپل شده بود، جهت عملیات دانه برداری تهیه شد. از الکتروموتور جهت تامین حرکت دورانی پمپ استفاده شد. به منظور حذف ارتعاشات ناشی از مجموعه بستر آزمایش، از سیستم ضربه گیر و پایه‌های لاستیکی استفاده شد. از کوپلینگ انعطاف پذیر جهت انتقال توان از الکتروموتور به پمپ هیدرولیک و همچنین کاهش انتقال ارتعاشات از الکتروموتور به پمپ استفاده شد. به منظور ایجاد شرایط واقعی برای کارکرد پمپ هیدرولیک مسیرهای

ورود و خروج روغن پمپ هیدرولیک به کمک شلنگ‌های هیدرولیک به مخزن روغن متصل شدند. اجزای عامل انتقال سیال هیدرولیکی در شکل ۱ نشان داده شده است. دو بخش دنده داخلی و خارجی وظیفه انتقال سیال را بر عهده دارند. دنده خارجی در جای خود ثابت شده است و با گردش دنده داخلی که از طریق محور به الکتروموتور وصل است، عملیات انتقال سیال و افزایش فشار انجام خواهد شد. در این تحقیق دو عیب رایج که در پمپ‌های دنده داخلی به وفور مشاهده می‌شود، بررسی شد. این عیوب شامل سائیدگی در دنده داخلی و دنده خارجی هستند. در شکل ۲ به ترتیب چرخ دنده داخلی و خارجی سالم و سائیده نشان داده شده است.



شکل ۱- چپ : مجموعه ساخته شده جهت دانه برداری. راست : اجزاء داخلی پمپ هیدرولیک



شکل ۲- حالت های مختلف عیوب در اجزای پمپ هیدرولیک



## مجله مهندسی زیست سامانه

در معادله ۱ اجزای طیفی سیگنال با مقیاس موجک  $s$  نسبت معکوس دارند و مکان  $u$  نشان دهنده اطلاعات زمان است. با توجه به اینکه  $f_c$  فرکانس مشخصه تابع موجک مادر است، فرکانس مربوط به یک موجک خاص در مقیاس دلخواه به صورت رابطه ۳ تعریف می‌شود. [Qin et. al., 2012]

$$f = \frac{f_c}{s} \quad 3$$

وضوح فرکانس زمانی موجک تحلیلی پیچیده به گسترش زمان- فرکانس موجک  $\psi_{us}$  بستگی دارد، که مربوط به جعبه هایزبرگ با مرکز  $(u,s)$  در صفحه زمان- فرکانس است. مساحت این جعبه در همه مقیاس‌ها ثابت می‌ماند اما وضوح زمان و فرکانس به مقیاس  $s$  بستگی دارد. به طور کلی، فرکانس لحظه‌ای را می‌توان با تشخیص برآمدگی موجک در تحلیل زمان- فرکانس با استفاده از روش تبدیل موجک پیوسته استخراج کرد که می‌تواند تأثیر نویزها را بر سیگنال مورد بررسی را کاهش دهد. مرزبندی موجک به صورت زیر تعریف می‌شود. [Qin et. al., 2012]

$$\frac{d|W_f(u,s)|^2 / s}{ds} = 0 \quad 4$$

که مربوط به ماکزیمای محلی در یک مقیاس خاص  $s$  است. اگر انتگرال تمام مقاطع زمانی را در یک مقیاس خاص  $s$  گرفته شود، یک طیف توان موجک کلی مشابه طیف توان کلاسیک از طریق روش FFT بدست می‌آید که در معادله زیر نشان داده شده است. [Qin et. al., 2012]

$$E(s) = \int_{-\infty}^{\infty} |W_f(u,s)|^2 du \quad 5$$

بیک‌ها در این طیف، مؤلفه‌های فرکانس غالب در سیگنال مورد بررسی را نشان می‌دهند [Qin et. al., 2012]. قبل از انجام هر گونه عملیات پردازشی بر روی سیگنال‌های ارتعاشی پمپ، عملیات نویز زدایی از هر سیگنال انجام شد. برای این منظور از یک فیلتر باند استاپ (BSF) که به عنوان فیلتر شکاف نیز شناخته می‌شود، استفاده شد. این فیلتر فرکانس‌هایی را که بین دو نقطه فرکانس قطع آن قرار دارند را مسدود کرده و همه آن فرکانس‌ها را از دو طرف این محدوده عبور می‌دهد. با توجه به اینکه عمده فرکانس‌های محدوده ۴۵ تا ۵۵ هرتز مربوط به نویزهای حاصل از برق شهری و ثابت دستگاه هستند لذا در این بخش محدوده استاپ فرکانسی بین ۴۵ تا ۵۵ تعریف شد. با توجه به اینکه محور پمپ با سرعت ۱۲۰۰ دور در دقیقه گردش می‌کند لذا فرکانس کاری محور دوار ۲۰ هرتز

## مجموعه گردآوری داده ارتعاشی

به منظور تهیه و گردآوری اطلاعات ارتعاشی پمپ هیدرولیک از یک شتاب سنج تک محوره پیزوالکتریک مدل Global Test AP 98-100 استفاده شد. این شتاب سنج از طریق کابل به یک تقویت کننده سیگنال و سپس به مبدل آنالوگ به دیجیتال متصل شد و در نهایت سیگنال ارتعاشی ثبت شده به رایانه منتقل گردید. مبدل آنالوگ به دیجیتال مدل Advantech USB-4704 data acquisition بود.

## مجموعه داده های بررسی شده

در این تحقیق پمپ دنده‌ای در سه حالت مختلف بررسی شد. حالت‌های بررسی شده شامل سالم، سائیدگی در دنده داخلی و سائیدگی در دنده خارجی بود. در مجموع ۳۰۰ سیگنال ارتعاشی از پمپ اکتساب شد. طول هر سیگنال دو ثانیه بود. به منظور ایجاد مدل هوشمند تشخیص عیب در پمپ، داده-های به دو دسته آموزش و آزمون تقسیم شدند. در این تحقیق برای آموزش و آزمون مدل یادگیری عمیق از روش 5-Folds استفاده شد. به این صورت که کل داده‌ها به ۵ دسته تقسیم شدند. ۴ دسته از آنها جهت آموزش مدل و ۱ دسته جهت آزمون مدل استفاده شد. در کل ۲۴۰ داده برای آموزش و ۶۰ داده برای آزمون استفاده شد.

## تبدیل موجک پیوسته

تبدیل موجک، یک سیگنال را به یک سری توابع پایه از نسخه‌های باز شده و انتقال داده شده تابع موجک مادر تجزیه می‌کند. شکل تبدیل موجک پیوسته یک سیگنال به صورت رابطه ۱ تعریف می‌شود [Qin et. al., 2012]:

$$W_f(u,s) = \int_{-\infty}^{\infty} f(t) \frac{1}{\sqrt{s}} \psi^* \left( \frac{t-u}{s} \right) dt \quad 1$$

که در آن  $f(t)$  سیگنال اصلی و  $s$  و  $u$  به ترتیب پارامترهای انتقال و مقیاس هستند.  $\psi^*(t)$  تابع مزدوج موجک مادر است. تبدیل موجک پیوسته می‌تواند با استفاده از یک موجک تحلیلی پیچیده که می‌تواند اطلاعات دامنه و فاز سیگنال‌ها را از هم جدا کند، تکامل زمانی فرکانس‌های گذرا را اندازه‌گیری کند. برای طبقه بندی به عنوان یک موجک تحلیلی پیچیده، تابع موجک باید معیارهای ریاضی را داشته باشد که تبدیل فوری آن باید برای فرکانس‌های منفی ناپدید شود. مربع مدول تبدیل موجک پیوسته به اسکالوگرام معروف است و به صورت زیر تعریف می‌شود [Qin et. al., 2012]:

$$E(u,s) = |W_f(u,s)|^2 \quad 2$$






کرده است و دارای قابلیت‌های خودآموزی و مدل‌سازی قدرتمندی جهت طبقه بندی شده است. شبکه عصبی کانولوشنال در زمینه‌های تشخیص تصویر، پردازش صدا و تشخیص رقم دست-نویس و غیره پیشرفت‌هایی داشته است. در این تحقیق از مدل شبکه عصبی کانولوشنی جهت طبقه بندی عیوب پمپ هیدرولیک استفاده شد. در شکل ۳ روش پیشنهادی جهت تشخیص عیوب پمپ هیدرولیک نشان داده شده است. ورودی مدل هوشمند تشخیص عیب اسکالوگرام خروجی روش تبدیل موجک است و خروجی مدل حالت‌های مربوط به پمپ هیدرولیک است که به ترتیب با WIG, Good و WOG نشان داده شده که نشان دهنده حالت سالم، سایش در دنده داخلی و سایش در دنده خارجی است.

می‌باشد. بنابراین دوره تناوب چرخش محور ۰/۰۵ ثانیه است. سیگنال زمانی بررسی شده در حالت‌های مختلف، به ازای چهار دوره تناوب متوالی ترسیم شد. در این تحقیق هر سیگنال توسط تبدیل موجک پیوسته پردازش و سپس اسکالوگرام آن استخراج گردید. خروجی تبدیل موجک پیوسته که به آن اسکالوگرام گفته می‌شود به عنوان ورودی مدل تشخیص و طبقه بندی عیوب به کار برده می‌شود.

### مدل یادگیری عمیق جهت تشخیص عیوب

هوش مصنوعی راه طولانی را پیموده است و به طور یکپارچه شکاف بین پتانسیل انسان و ماشین را پر می‌کند و علاقه مندان به داده در سرتاسر جهان روی جنبه‌های متعدد هوش مصنوعی کار می‌کنند و دیدها را به واقعیت تبدیل می‌کنند.

الگوریتم‌های یادگیری عمیق و شبکه عصبی کانولوشنال پتانسیل بالایی در تشخیص و طبقه بندی عیوب دارند. در سال‌های اخیر یادگیری عمیق نظرات گسترده‌ای را به خود جلب



شکل ۳- مدل یادگیری عمیق جهت تشخیص عیوب پمپ هیدرولیک

ابعاد  $300 \times 300$  و خروجی آن یک ماتریس  $3 \times 1$  است که نشان دهنده حالت‌های مربوط به پمپ هیدرولیک است. این شبکه ۱۳ لایه دارای سه لایه کانولوشنی، سه لایه مکس پولینگ، سه لایه تابع ReLU، یک لایه ورودی و سه لایه تمام متصل است.

شبکه عصبی کانولوشنی استفاده شده در این تحقیق دارای ۱۳ لایه است که در زیر شبه کد مربوط به تعریف این شبکه در محیط متلب ارائه شده است. مشخصات هر لایه و ورودی و خروجی به هر لایه در شبکه کانولوشنی در جدول ۱ نشان داده شده است. ورودی این مدل یک تصویر اسکالوگرام با

جدول ۱- مشخصات شبکه عصبی کانولوشنی جهت طبقه بندی عیوب پمپ

شماره لایه	نام لایه	اندازه و تعداد فیلتر	اندازه خروجی	گام	پدینگ
۱	Input Layer	--	$300 \times 300$	--	--
۲	Conv 1	۳۲ فیلتر $4 \times 4$	$150 \times 150$	۲	۰
۳	ReLU 1	--	$150 \times 150$	--	--
۴	MaxP 1	۱ فیلتر $4 \times 4$	$150 \times 150$	۲	۰
۵	Conv 2	۶۴ فیلتر $5 \times 5$	$75 \times 75$	۳	۰
۶	ReLU 2	--	$25 \times 25$	--	--
۷	MaxP 2	۷ فیلتر $5 \times 5$	$5 \times 5$	۵	۰
۸	Conv 3	۱۲۸ فیلتر $4 \times 4$	$5 \times 5$	۱	۰
۹	ReLU 3	--	$5 \times 5$	--	--
۱۰	MaxP 3	۱ فیلتر $3 \times 3$	$1 \times 1$	۵	۰
۱۱	FC Input	--	$10 \times 10$	--	--
۱۲	softmax	--	$10 \times 10$	--	--
۱۳	Types of Faults	--	$3 \times 1$	--	--

## پارامترهای ارزیابی مدل تشخیص هوشمند عیب

در این تحقیق از دو پارامتر زیر برای ارزیابی مدل تشخیص عیب در پمپ هیدرولیک استفاده شد.

$$Accuracy = \frac{TP + TN}{TP + FP + FN + TN} \quad (6)$$

$$Precision = \frac{TP}{TP + FP} \quad (7)$$

مثبت واقعی (TP): مقدار پیش بینی شده با مقدار واقعی مطابقت دارد. مقدار واقعی مثبت بود و مدل یک مقدار مثبت را پیش‌بینی کرد.

منفی واقعی (TN): مقدار پیش بینی شده با مقدار واقعی مطابقت دارد. مقدار واقعی منفی بود و مدل مقدار منفی را پیش‌بینی کرد.

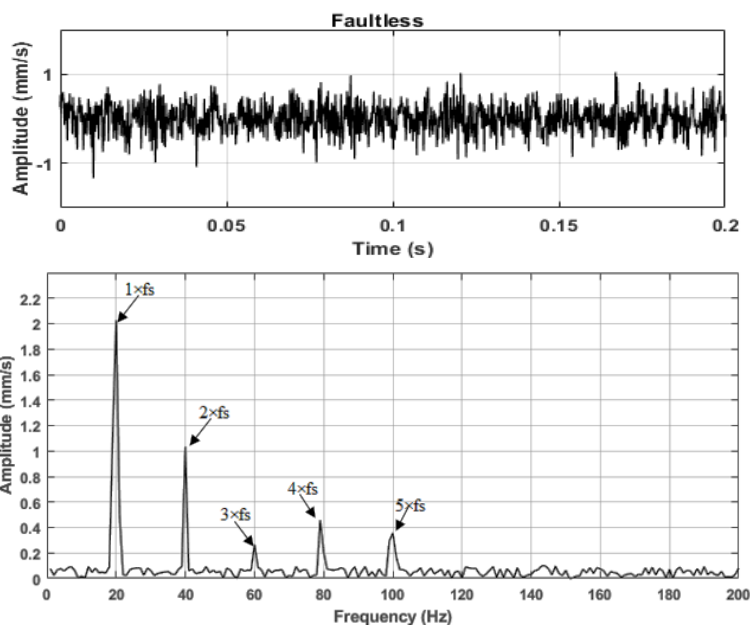
مثبت کاذب (FP): مقدار پیش‌بینی شده به اشتباه پیش‌بینی شده بود. مقدار واقعی منفی بود اما مدل یک مقدار مثبت را پیش‌بینی کرد.

منفی کاذب (FN): مقدار پیش‌بینی شده به اشتباه پیش‌بینی شده بود. مقدار واقعی مثبت بود اما مدل یک مقدار منفی را پیش‌بینی کرد.

## نتایج و بحث

## بررسی سیگنال‌های ارتعاشی پمپ

بررسی سیگنال زمانی پمپ در حالت سالم نشان دهنده تغییرات هارمونیک رفتار ارتعاشی پمپ است که محدوده دامنه نوسان ارتعاشات در این حالت بین +۱ تا -۱ در حال نوسان است. با مقایسه رفتار سیگنال ارتعاشی پمپ در حالت سالم در دوره تناوب‌های متوالی، مشخص شد که رفتار ارتعاشی پمپ تقریباً یکنواخت است و مولفه فرکانسی جدید یا پیک غالبی در سیگنال ایجاد نشد. در شکل ۴ طیف فرکانسی سیگنال ارتعاشی پمپ در حالت سالم نشان داده شده است. در این حالت شاهد هارمونیک‌های اول تا پنجم هستیم. در فرکانس ۲۰ هرتز که همان فرکانس کاری محور پمپ است شاهد بالاترین پیک فرکانسی هستیم و به همین ترتیب شدت پیک فرکانسی در هارمونیک‌های دوم و سوم کاهش یافته است.



شکل ۴- سیگنال ارتعاشی پمپ در حالت سالم در زمان (بالا) و حوزه فرکانس (پایین)

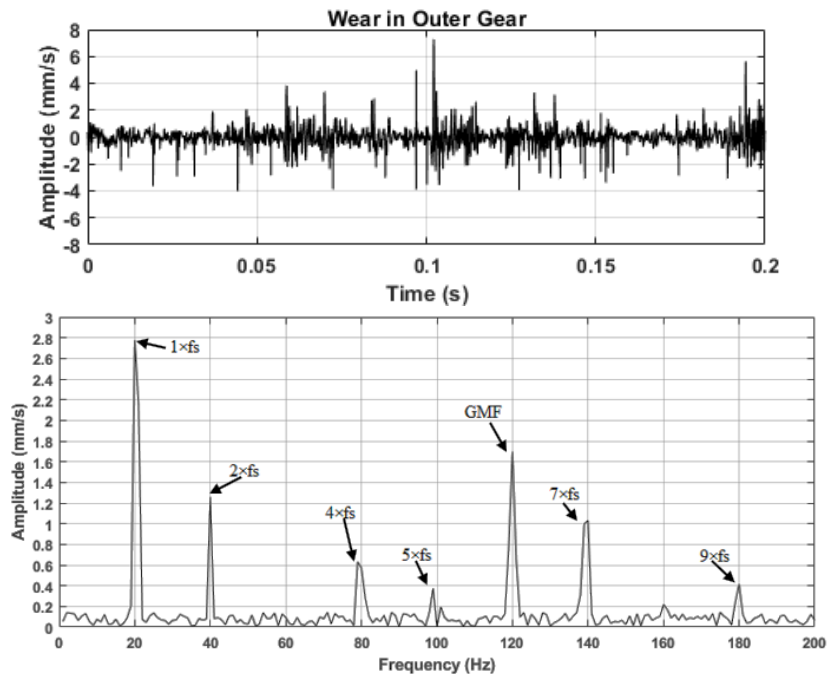
از دو برابر شد و در برخی شرایط نبض‌های فرکانسی با دامنه ۶ برابر در سیگنال زمانی مشاهده گردید. با بررسی طیف فرکانسی سیگنال ارتعاشی پمپ در حالت سائیدگی در دنده خارجی روئیت شد که پیک فرکانسی غالب در هارمونیک اول مشاهده

در شکل ۵ سیگنال زمانی پمپ هیدرولیک دنده‌ای در حالت ایجاد سایش در دنده بیرونی نشان داده شده است. با پیدایش عیب در پمپ هیدرولیک، رفتار ارتعاشی آن به شدت تغییر کرد به طوری که دامنه ارتعاشات پمپ به طور میانگین بیش



فرکانسی بودیم. همچنین در فرکانس ۱۲۰ هرتز یک پیک فرکانسی بزرگ مشاهده شد که مربوط به فرکانس درگیری چرخ دنده‌ها بود (فرکانس درگیری چرخ دنده برابر با تعداد دندانه (۶) دنده) در فرکانس گردش آن (۲۰).

شد با این تفاوت که شدت آن نسبت به حالت سالم افزایش یافته بود. پیک‌های فرکانسی بیشتری نسبت به حالت سالم در طیف فرکانسی سایش دنده خارجی مشاهده شد. در هارمونیک‌های اول، دوم، چهارم، پنجم، هفتم و نهم شاهد پیک‌های




شکل ۵- سیگنال ارتعاشی پمپ در حالت سایش در دنده خارجی در حوزه زمان (بالا) و حوزه فرکانس (پایین)

یک پیک فرکانسی در فرکانس ۱۲۰ هرتز (فرکانس درگیری چرخ دنده‌ها) بودیم اما مقدار دامنه این پیک نسبت به حالت سایش در دنده خارجی کمتر بود.

با توجه به اینکه دنده خارجی بر روی پوسته پمپ فیکس است لذا ارتعاشات ناشی از خرابی در این دنده به طور مستقیم به بدنه منتقل شده به همین دلیل است که شدت ارتعاشات ناشی از خرابی در دنده خارجی از دنده داخلی بیشتر است. ارتعاشات ناشی از خرابی در دنده داخلی بعد از انتقال به دنده خارجی توسط حسگر ثبت می‌شود که در طی انتقال ارتعاشات، بخشی از آن میرا شده که سبب می‌شود شدت ارتعاشات و تعداد پیک‌های فرکانسی غالب در حالت خرابی در دنده داخلی کمتر از دنده خارجی باشد.

در شکل ۶ سیگنال ارتعاشی پمپ هیدرولیک در حالت سایش در دنده داخلی نشان داده شده است. در این حالت نیز تغییرات قابل توجهی در سیگنال ارتعاشی نسبت به حالت سالم مشاهده شد. دامنه ارتعاشات در این حالت نسبت به حالت سالم افزایش قابل توجهی داشت و نبض‌های ارتعاشی با دامنه بیش از ۶ برابر نسبت به حالت سالم مشاهده شد اما شدت ارتعاشات در این حالت نسبت به حالت سایش در دنده خارجی کمتر بود. در شکل ۶ طیف فرکانسی پمپ در حالت سایش در دنده داخلی نشان داده شده است. در این وضعیت پیک فرکانسی غالب در فرکانس ۲۰ هرتز مشاهده شد. نسبت به حالت سالم مقدار دامنه پیک‌های فرکانسی هارمونیک‌های اول تا پنجم افزایش یافت اما در مقایسه با حالت سائیدگی در دنده خارجی کمتر بود. همچنین در طیف فرکانسی شاهد

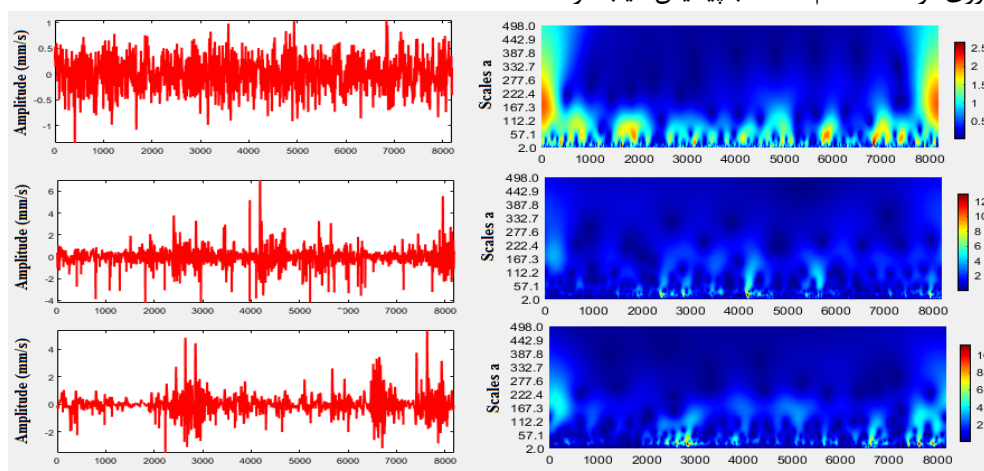


شکل ۶- سیگنال ارتعاشی پمپ در حالت سایش در دنده داخلی در حوزه زمان (بالا) و حوزه فرکانس (پایین)

دنده خارجی و دنده داخلی به ۱۲ و ۱۰ افزایش یافت. بخش عمده اسکالوگرام مربوط به حالت سائیدگی در دنده داخلی و خارجی شبیه به هم است اما تفاوت آنها با اسکالوگرام حالت سالم کاملاً مشهود و مشخص می‌باشد. اختلاف بین دو حالت سائیدگی در دنده داخلی و خارجی نیز با بررسی جزئی‌تر اسکالوگرام قابل مشاهده است که در ادامه برای تفکیک این سه حالت از هم، مدل شبکه عصبی کانولوشنی پیاده سازی شد.

### پردازش سیگنال

هر سیگنال ارتعاشی توسط تبدیل موجک پیوسته در ۱۰ سطح تجزیه شد. خروجی تبدیل موجک پیوسته به صورت اسکالوگرام نمایش داده شد. در شکل ۷ اسکالوگرام خروجی سیگنال ارتعاشی پمپ هیدرولیک برای حالت‌های مختلف نشان داده شده است. بررسی شکل ظاهری خروجی تبدیل موجک پیوسته و مقایسه آن برای حالت‌های مختلف نشان می‌دهد که با پیدایش عیب در سیگنال، بیشینه انرژی موجود در سیگنال افزایش یافت (محور عمودی سمت راست شکل ۷). این بیشینه انرژی در حالت سالم ۲/۵ اما با پیدایش عیب در



شکل ۷- نتایج تجزیه سیگنال توسط تبدیل موجک پیوسته به اسکالوگرام





لایه ReLU و سه لایه مکس پولینگ دارد. این شبکه دارای سه خروجی است که هر عدد نمایگر یک حالت از پمپ است که [1 0 0]، [0 1 0] و [0 0 1] به ترتیب نشان دهنده حالت سالم، سائیدگی در دنده داخلی و سائیدگی در دنده خارجی است.

### مدل تشخیص عیب

جهت طبقه بندی عیوب پمپ هیدرولیک، از یک شبکه عصبی کانولوشنی ۱۳ لایه استفاده شد. که ابعاد ورودی به مدل تشخیص عیب  $3 \times 300 \times 300$  بود. این شبکه متشکل از سه لایه کانولوشن با ۳۲ فیلتر به ابعاد  $4 \times 4$ ، ۶۴ فیلتر به ابعاد  $5 \times 5$  و ۱۲۸ فیلتر  $4 \times 4$  بود. همچنین شبکه مذکور سه


```

Command Window
>> 13x1 Layer array with layers:
 1 'Input Layer'      Image Input      300x300x3 images with 'zerocenter' normalization
 2 'Conv 1'          Convolution     32 4x4 convolutions with stride [2 2] and padding [0 0 0 0]
 3 'ReLU 1'         ReLU            ReLU
 4 'MaxP 1'         Max Pooling     4x4 max pooling with stride [2 2] and padding [0 0 0 0]
 5 'Conv 2'         Convolution     64 5x5 convolutions with stride [3 3] and padding [0 0 0 0]
 6 'ReLU 2'         ReLU            ReLU
 7 'MaxP 2'         Max Pooling     7x7 max pooling with stride [5 5] and padding [0 0 0 0]
 8 'Conv 31'        Convolution     128 4x4 convolutions with stride [1 1] and padding [0 0 0 0]
 9 'ReLU 3'         ReLU            ReLU
10 'MaxP 3'         Max Pooling     3x3 max pooling with stride [5 5] and padding [0 0 0 0]
11 'FC Input'       Fully Connected 10 fully connected layer
12 'softmax'        Softmax         softmax
13 'Types of Faults' Classification Output crossentropyex
  
```

شکل ۸- ساختار شبکه عصبی عمیق برای تشخیص عیب پمپ

در تکرار ۷۰ام به مدل بهینه دست یافت. بررسی شکل ۹ نشان داد که میزان خطای آموزش و ارزیابی مدل بعد از کمتر از ۱۰ تکرار آموزش همگرا شده است.

در شکل ۹ فرایند آموزش و ارزیابی مدل یادگیری عمیق برای تشخیص نوع عیب در پمپ هیدرولیک نشان داده شده است. حداکثر تعداد آموزش شبکه برای دستیابی به بهترین مد ۱۰۰ تکرار در نظر گرفته شد که مدل یادگیری عمیق



شکل ۹- فرایند آموزش و آزمون مدل یادگیری عمیق جهت تشخیص نوع عیب

است. دقت کلی آموزش شبکه عصبی ۹۶/۶۷٪ مشاهده شد که حساسیت این مدل برای تشخیص حالت سالم، سائیدگی

ماتریس اغتشاش خروجی این مدل برای داده‌های آموزش و آزمون و پارامترهای ارزیابی آن در جدول ۲ و ۳ ارائه شده



## مجله مهندسی زیست سامانه

مدل برای تشخیص کلاس سالم ۸۵٪ و برای دو کلاس سائیدگی در دنده داخلی و خارجی ۹۰٪ مشاهده شد. همچنین صحت مدل در تشخیص داده سالم، داده‌های مربوط به سائیدگی در دنده داخلی و خارجی به ترتیب برابر با ۸۹/۴۷٪، ۸۵/۷۱٪ و ۹۰٪ بود. در کل دقت کلی مدل برای داده‌های آزمون ۸۸/۳۳٪ به دست آمد.

در دنده داخلی و خارجی برای داده‌های آموزش به ترتیب برابر با ۹۲/۲۶٪، ۹۷/۵۰٪ و ۹۶/۲۶٪ بود. در مجموع از بین ۲۴۰ داده استفاده شده برای آموزش، فقط ۸ داده به اشتباهی طبقه بندی شد و سایر داده‌ها به درستی در کلاس صحیح دسته بندی شدند. بعد از اینکه مدل مذکور آموزش داده شد، از داده‌های آزمون برای ارزیابی شبکه عصبی کانولوشنی جهت تشخیص عیب در پمپ استفاده شد. حساسیت این

جدول ۲- ماتریس اغتشاش و پارامترهای ارزیابی مدل CNN برای داده های آموزش

	G	WIG	WOG	Precision (%)
G	77	1	3	96.07
WIG	3	78	0	96.30
WOG	0	1	77	98.72
Sensitivity (%)	96.26	97.50	96.26	
Total Accuracy (%)				96.67

جدول ۳- ماتریس اغتشاش و پارامترهای ارزیابی مدل CNN برای داده‌های آزمون

	G	WIG	WOG	Precision (%)
G	17	0	2	89.47
WIG	3	18	0	85.71
WOG	0	2	18	90
Sensitivity (%)	85	90	90	
Total Accuracy (%)				88.33

۲- جهت طبقه بندی عیوب پمپ یک شبکه عصبی کانولوشنی با ۱۳ لایه پیاده سازی شد. ورودی این مدل سیگنال‌های پردازش شده توسط تبدیل موجک پیوسته بودند. برای هر حالت ۱۰۰ اسکالوگرام به عنوان ورودی استفاده شد. در نهایت مدل شبکه عصبی کانولوشنی با دقت ۹۶/۶۷٪ آموزش داده شد که پس از آموزش مدل، نتایج ارزیابی مدل نشان داد که حساسیت این روش در تشخیص حالت سالم، سائیدگی در دنده داخلی و سائیدگی در دنده خارجی به ترتیب برابر با ۸۹/۴۷٪، ۸۵/۷۱٪ و ۹۰٪ بود.

## منابع

Riera-Guasp, M., J.A. Antonino-Daviu, and G.-A. Capolino, *Advances in electrical machine, power electronic, and drive condition monitoring and fault detection: state of the art*. IEEE Transactions on Industrial Electronics, 2014. 62(3): p. 1746-1759.

Simani, S., S. Farsoni, and P. Castaldi, *Fault diagnosis of a wind turbine benchmark via identified fuzzy models*. IEEE Transactions on

## نتیجه گیری

نتایج به دست آمده در این تحقیق در دو بخش تحلیلی سیگنال و تشخیص سیگنال ارائه شد که به شرح زیر است:

۱- بررسی سیگنال‌های ارتعاشی مربوط به پمپ در حالت سالم و معیوب نشان داد که با پیدایش سایش در دنده‌های داخلی و خارجی پمپ هیدرولیک رفتار ارتعاشی پمپ به شدت تغییر کرد و دامنه نوسانات پمپ افزایش یافت. همچنین با پیدایش عیب نبض‌های ارتعاشی در سیگنال ظاهر شد. از طرفی بررسی طیف فرکانسی مربوط به هر حالت پمپ نشان داد که در حالت سالم طیف فرکانسی دارای هارمونیک‌های اول تا سوم است که پیک فرکانسی در هارمونیک اول مشاهده شد اما با پیدایش عیب، نه تنها پیک‌های فرکانسی جدید در طیف ظاهر شد بلکه دامنه پیک‌های فرکانسی نیز افزایش یافت. از طرف دیگر با پیدایش عیب، شاهد پیک‌های فرکانسی در فرکانس ۱۲۰ هرتز بودیم که همان فرکانس درگیری چرخ دنده‌ها بود. شدت ارتعاشات پمپ در حالت خرابی در دنده بیرونی بیشتر از دنده داخلی بود.

Jiang, G., et al., *Stacked multilevel-denoising autoencoders: A new representation learning approach for wind turbine gearbox fault diagnosis*. IEEE Transactions on Instrumentation and Measurement, 2017. 66(9): p. 2391-2402.

Ince, T., et al., *Real-time motor fault detection by 1-D convolutional neural networks*. IEEE Transactions on Industrial Electronics, 2016. 63(11): p. 7067-7075.

Liu, Z., et al., *Capturing high-discriminative fault features for electronics-rich analog system via deep learning*. IEEE Transactions on Industrial Informatics, 2017. 13(3): p. 1213-1226.

Jia, F., et al., *Deep neural networks: A promising tool for fault characteristic mining and intelligent diagnosis of rotating machinery with massive data*. Mechanical Systems and Signal Processing, 2016. 72: p. 303-315.

Lu, W., et al., *Deep model based domain adaptation for fault diagnosis*. IEEE Transactions on Industrial Electronics, 2016. 64(3): p. 2296-2305.

Wen, L., L. Gao, and X. Li, *A new deep transfer learning based on sparse autoencoder for fault diagnosis*. IEEE Transactions on systems, man, and cybernetics: systems, 2017. 49(1): p. 136-144.

Liu, R., et al., *Dislocated time series convolutional neural architecture: An intelligent fault diagnosis approach for electric machine*. IEEE Transactions on Industrial Informatics, 2016. 13(3): p. 1310-1320.

Qin, Z., L. Chen, and X. Bao, *Continuous wavelet transform for non-stationary vibration detection with stationary vibration detection with phase-OTDR*. Optics express, 2012. 20 (18): p. 20459-20465.

Industrial Electronics, 2014. 62(6): p. 3775-3782.

Lei, Y., et al., *An intelligent fault diagnosis method using unsupervised feature learning towards mechanical big data*. IEEE Transactions on Industrial Electronics, 2016. 63(5): p. 3137-3147.

4. Sun, J., H. Li, and B. Xu, *Prognostic for hydraulic pump based upon DCT-composite spectrum and the modified echo state network*. SpringerPlus, 2016. 5 (1): p. 1-17.

Sun, H., S. Yuan, and Y. Luo, *Cyclic spectral analysis of vibration signals for centrifugal pump fault characterization*. IEEE Sensors Journal, 2018. 18 (7): p. 2925-2933.

Yu, H., et al., *A novel improved full vector spectrum algorithm and its application in multi-sensor data fusion for hydraulic pumps*. Measurement, 2019. 133: p. 145-161.

Sun, J., H. Li, and B. Xu, *The morphological undecimated wavelet decomposition-discrete cosine transform composite spectrum fusion algorithm and its application on hydraulic pumps*. Measurement, 2016. 94: p. 794-805.

Zhongda, T., et al., *A prediction method based on wavelet transform and multiple models fusion for chaotic time series*. Chaos, Solitons & Fractals, 2017. 98: p. 158-172.

Dogra, A., B. Goyal, and S. Agrawal, *Bone vessel image fusion via generalized reisz wavelet transform using averaging fusion rule*. Journal of computational science, 2017. 21: p. 371-378.

Cheng, G., et al., *Study on planetary gear fault diagnosis based on entropy feature fusion of ensemble empirical mode decomposition*. Measurement, 2016. 91: p. 140-154.



## Diagnosis and classification of gear hydraulic pump defects using vibration signal processing by continuous wavelet transform and convolutional neural network

Haider Fazel Mohammad<sup>1</sup> and Ahmad Soheili Mahdizadeh<sup>2\*</sup>

<sup>1-2</sup> Department of Mechanical Engineering, Technical and Engineering Faculty, Kermanshah Branch, Islamic Azad University, Kermanshah, Iran

\*Corresponding author: Soheili2008@gmail.com

*Received: 07 May 2022*

*Accept: 15 Jun 2022*

### Abstract

Hydraulic pumps are the heart of a hydraulic system, and any failure that occurs in them disrupts the performance of the hydraulic system, so it is essential to monitor the operation of hydraulic pumps to ensure that hydraulic systems are ready for operation. In this article, an intelligent method based on vibration signal processing and deep learning method was used to detect faults in gear hydraulic pump. In this research, an internal gear hydraulic pump was used. Data acquisition tests were performed on the pump at a speed of 1200 rpm using the Global Test AP 98-100 vibration sensor and the Advantech USB-4704 data acquisition set. For each situation, 100 signals were recorded from the pump, and then each signal was processed by the continuous wavelet transform method, and finally, these images were used to create a deep learning model for pump fault classification. A convolutional neural network with 13 layers was created to classify faults in the pump, and after 70 repetitions of training, the training model was optimized and achieved an accuracy of 96.67%. Evaluation of the model showed that the accuracy of this model to detect healthy, wear in the inner gear and wear in the outer gear was equal to 88.33%.

**Keywords:** Fault Detection, Hydraulic Pump, Scalogram, CNN.