

پایش وضعیت کمپرسورهای رفت و برگشتی با استفاده از شبکه عصبی احتمالی و بهینه‌سازی با الگوریتم ژنتیک

در این پژوهش، مدل ریاضی یک کمپرسور رفت و برگشتی دو مرحله‌ای و عیوب مرسوم برای استفاده به عنوان سیستم مورد پایش، شبیه‌سازی شده است. شبکه عصبی مورد استفاده شبکه عصبی احتمالی است که وظیفه اصلی آن طبقه بندی است. کلاس‌های طبقه بندی شامل یک کلاس کمپرسور سالم و هفت کلاس کمپرسور معیوب است که مجموعاً هشت کلاس می باشد. طبقه بندی با شبکه عصبی احتمالی با استفاده از ویژگی‌های حوزه زمان و طیف پوش فرکانس انجام گرفته شده است. سپس با استفاده از الگوریتم ژنتیک ویژگی‌های انتخابی قبل از خوراندن به شبکه عصبی احتمالی بهینه سازی شده اند. طبقه بندی با شبکه عصبی احتمالی با استفاده از ویژگی‌های حوزه زمان درصد طبقه بندی ضعیفی با دقت ۴۴ درصد را نشان می دهد. اما طبقه بندی با شبکه عصبی احتمالی و استفاده از ویژگی‌های طیف پوش دقت ۹۵ درصدی در طبقه بندی صحیح دارد. همچنین بهینه سازی انتخاب ویژگی‌های آماری حوزه زمان و طیف پوش فرکانس با الگوریتم ژنتیک، به ترتیب ۴۸ و ۹۹ درصد دقت صحیح در طبقه بندی را به همراه دارد.

سینا صالحی^۱

دانشجوی دکتری

مجید ساده دل^۲

استادیار

واژه‌های راهنما: کمپرسورهای رفت و برگشتی، پایش وضعیت، شبکه‌های عصبی احتمالی، الگوریتم ژنتیک

۱- مقدمه

خط مشی تحقیق حاضر، توسعه تکنیک پایش وضعیت با قابلیت تشخیص و یافتن عیب‌های مدل شده در کمپرسور رفت و برگشتی و تحلیل با استفاده از روش‌های محاسباتی و بهینه‌سازی آن است. کمپرسورهای رفت و برگشتی از جایگاه ویژه‌ای در صنعت برخوردار می‌باشند. این کمپرسورها از یک اشکال عمده رنج می‌برند و آن هزینه تعمیراتی بالای آنهاست. در واقع در مقایسه با یک نوع گریز از مرکز هم ظرفیت، رفت و برگشتی‌ها هزینه‌ی تقریباً پنج برابری دارند.^۳

^۱ دانشجوی دکتری، دانشکده مهندسی مکانیک، دانشگاه تربیت مدرس، تهران، ایران sina_salehi@modares.ac.ir

^۲ نویسنده مسئول، استادیار، دانشکده مهندسی مکانیک، دانشگاه تربیت مدرس، تهران، ایران majid.sadedel@modares.ac.ir

تاریخ دریافت: ۱۴۰۱/۰۳/۱۶، تاریخ بازنگری: ۱۴۰۲/۰۲/۰۸، تاریخ پذیرش: ۱۴۰۲/۰۷/۱۷

^۳ www.bakerhughes.com/reciprocating-compressors

هزینه‌های تعمیراتی کمپرسورهای شرکت پالایش گاز پارسیان در سال ۱۳۹۷ بیش از ۴ میلیارد ریال بوده و علاوه بر این بیش از ۱۵۰۰ نفر ساعت کار تعمیراتی بر روی این تجهیزات انجام شده است که با توجه به افزایش عمر و فرسودگی دستگاه‌ها، این مقدار در سال‌های آینده افزایش یافته است. با پایش وضعیت این ماشین‌ها می‌توان هزینه تعمیرات و نگهداری آن‌ها را تا ۵۰ درصد کاهش داد. به دلیل ماهیت پیچیده ماشین‌های رفت و برگشتی عیب‌یابی در این ماشین‌ها برخلاف ماشین‌آلات دوار فرآیند بسیار پیچیده‌ای است، که نیاز به ابزارهای خاصی داشته و به سادگی امکان‌پذیر نمی‌باشد. این موضوع به خصوص در عیب‌یابی به کمک آنالیز ارتعاشات نمود بیشتری می‌یابد. عیب‌یابی این نوع کمپرسورها همواره دغدغه متخصصان صنعت نفت، گاز و پتروشیمی کشور بوده است. تمرکز این پژوهش بر شبیه‌سازی مدل کمپرسور رفت و برگشتی سالم و معیوب و طبقه‌بندی این عیوب با شبکه عصبی احتمالی می‌باشد. شبکه عصبی احتمالی برای تشخیص عیب سیستم محور به ویژگی‌ها یا اطلاعاتی نیاز دارد که از داده‌های ارتعاشی سوپاپ‌ها به دست می‌آید. در نتیجه انتخاب ویژگی‌ها و ساختار شبکه بسیار حائز اهمیت است. در ادامه، این تحقیق، به بررسی امکان بهینه‌سازی انتخاب ویژگی‌ها با استفاده الگوریتم ژنتیک پیش از خوراندن به شبکه عصبی می‌پردازد تا درصد طبقه‌بندی صحیح عیوب توسط شبکه عصبی احتمالی را بهبود بخشد.

از روش‌های مختلفی مانند پایش فشار سیلندر، ارتعاشات کمپرسور و سیگنال آکوستیک هوابرد برای تحلیل و نظارت وضعیت کمپرسورهای رفت و برگشتی در تحقیقات پیش از این استفاده شده است. مانیتورینگ فشار سیلندر روشی موثر برای تعیین وضعیت کلی یک کمپرسور رفت و برگشتی است. پروفیل فشار دینامیکی سیلندر از ارزش بالایی برخوردار است، زیرا این توانایی را فراهم می‌کند تا وقایع حاصل از اندازه‌گیری ارتعاشات حاوی اغتشاش را با رویدادهای نمودارهای فشار مرتبط کند. چندین رویکرد با استفاده از سیگنال‌های فشار برای شناسایی عیب‌های کمپرسور رفت و برگشتی بررسی شده‌اند. پیچلر و همکارانش از نمودار فشار-حجم برای تشخیص نشتی از سوپاپ‌های کمپرسور رفت و برگشتی استفاده کرده‌اند. مطالعه آنها نشان داد که شکل نمودار P-V زمانی که نشتی روی سوپاپ‌ها وجود دارد به خصوص زمانی که سوپاپ‌ها بسته هستند، مخدوش می‌شود [۱]. در حالی که وانگ و همکاران از نمودار فشار-حجم همراه با یک ماشین بردار پشتیبان (SVM) برای تشخیص عیب سوپاپ‌های کمپرسور رفت و برگشتی استفاده کردند [۲]. الهاج و همکاران شبیه‌سازی عددی یک کمپرسور رفت و برگشتی دو مرحله‌ای را توسعه داده‌اند تا اثرات چندین شرایط عملیاتی و شرایط عیب در فشار و شکل موج سرعت زاویه‌ای لحظه‌ای (IAS) را نشان دهند. مطالعه شبیه‌سازی شده نشان داد که دو تکنیک (فشار و سرعت زاویه‌ای لحظه‌ای) مورد استفاده می‌تواند برای شناسایی عیوب مختلف در صفحات سوپاپ مکش و دهش استفاده شود. اگرچه اندازه‌گیری‌های فشار، ویژگی‌های تشخیص عیب واضحی را ارائه می‌کردند، اما اینطور تصدیق کرد که اجرای این تکنیک به دلیل نصب سنسور در داخل سیلندر دشوار می‌باشد [۳]. آنالیزهای ساختاری و هوابرد دو رویکرد اصلی مورد استفاده برای نظارت بر صدا هستند. رویکرد هوابرد امواج صوتی تابشی بالای محدوده شنوایی انسان (در بالا ۲۰ کیلوهرتز) با استفاده از میکروفون‌های بدون تماس یا با مبدل‌های صدا دریافت می‌کند، در حالی که رویکرد ارتعاش ساختاری از طریق حسگرهای نصب شده بر روی سطح ساختار سیستم اطلاعات را ثبت می‌کند. در مقایسه با رویکرد ارتعاش ساختاری، نصب مبدل‌های

¹ Support Vector Machine

صوتی هوابرد آسان‌تر هستند؛ می‌تواند محدوده فرکانس پایین و بالا را تشخیص دهد و امکان تشخیص سیگنال‌های حساس‌تر را فراهم می‌کند که تجزیه و تحلیل آن آسان‌تر است [۴]. با این حال، یک نقطه ضعف این تکنیک در حساسیت آن به آکوستیک محیطی و نفوذپذیری نسبت به صدای زمینه است. توسط صلاح و همکاران یک سیستم تشخیص خودکار شرایط سوپاپ کمپرسور رفت و برگشتی با اتخاذ ماشین بردار پشتیبان بر اساس پارامترهای انتشار آکوستیک ارائه شد. مدل تولید شده آنها می‌تواند وضعیت سوپاپ را در کمپرسور رفت و برگشتی یک مرحله‌ای به طور دقیق تشخیص دهد [۵].

سیگنال‌های ارتعاشی حاصل از یک ماشین، حاوی اطلاعات حیاتی مورد نیاز برای تعیین و پیش‌بینی وضعیت دستگاه هستند. تکنیک‌های مبتنی بر ارتعاشات رایج‌ترین و گسترده‌ترین روش نظارتی مورد استفاده در صنایع هستند. تفسیر داده‌های ارتعاشی از کمپرسور رفت و برگشتی یکی از زمینه‌هایی است که توجه تحقیقات زیادی را به خود جلب کرده است. صلاح و همکارانش به بررسی تغییرات سیگنال‌های نشر آوایی و ارتعاشات با تغییر خوردگی در سوپاپ‌های کمپرسور رفت و برگشتی پرداختند [۶]. چندین رویکرد در تجزیه و تحلیل سیگنال‌های ارتعاشی برای تشخیص عیب پیاده‌سازی شده است. با این حال، تشخیص عیب سوپاپ‌های کمپرسور بر اساس سیگنال‌های ارتعاش و انتشار صوتی کارآمدتر در نظر گرفته می‌شوند، زیرا می‌توان آن‌ها را بدون نفوذ به دستگاه انجام داد [۷].

داده‌های جمع‌آوری شده از ابزارهای اندازه‌گیری مورد استفاده برای پایش وضعیت نیاز به تجزیه و تحلیل دارد تا بتواند برای آشکار کردن اطلاعات حیاتی و ویژگی‌های ماشین استفاده شود.

سه تا از محبوب‌ترین روش‌ها که در پردازش سیگنال وجود دارند عبارتند از: تجزیه و تحلیل حوزه زمان، تجزیه و تحلیل حوزه فرکانس و تحلیل زمان-فرکانس.

نمایش سیگنال حوزه زمان حاوی اطلاعات مفیدی برای درک شرایط ماشین است، و سیگنال به عنوان تابعی از زمان نشان داده می‌شود، که نمودار دامنه نسبت به زمان است. ویژگی‌های مشخصه یک سیگنال در قالب روش‌های آماری مانند ریشه میانگین مربع یا مقدار مؤثر (X_{RMS})، مقدار پیک (X_{PK})، نسبت مقدار پیک به مقدار مؤثر^۱ یا ضریب کرس (CF)، کشیدگی (KT^2)، چولگی^۳ (SK)، مرز پایین^۴ (LB)، مرز بالا^۵ (UP) [۸]، آنتروپی اطلاعات^۶ (H) [۹]، محدوده یا رنج (R)، تابع چگالی احتمال (P) و واریانس (Var) برای خلاصه کردن داده‌های به دست آمده و ترسیم نتایج مناسب استفاده می‌شود. برخی از این تکنیک‌ها هنگام تجزیه و تحلیل سیگنال‌های ارتعاشات و ضربانی گاز مورد استفاده قرار می‌گیرند.

مشخصه‌های آماری ضریب کرس، مرز پایین، مرز بالا، رنج و آنتروپی برای یک مجموعه از داده‌ها به شکل $X_1, X_2, X_3, \dots, X_N$ ، با نماد X_{rms} به ترتیب، به صورت زیر تعریف می‌شوند.

¹ Crest Factor

² Kurtosis

³ Skewness

⁴ Lower Bound

⁵ Upper Bound

⁶ Entropy (information theory)

$$CF = \frac{X_{PK}}{X_{rms}} \quad (۱)$$

$$LB = \min(X) - 0.3 * \frac{\max(X) - \min(X)}{(N - 1)} \quad (۲)$$

$$UB = \max(X) + 0.3 * \frac{\max(X) - \min(X)}{(N - 1)} \quad (۳)$$

$$R(X) = \max(X) - \min(X) \quad (۴)$$

$$H(X) = \sum_{i=1}^N F_i \log F_i \quad (۵)$$

که F تابع چگالی احتمال مجموعه داده X است و از رابطه (۲۰) به دست می‌آید. تجزیه و تحلیل پوش برای تشخیص ماشین آلات که در آن عیب‌ها دارای اثر مدولاسیون دامنه مناسب است. بنابراین در این شرایط، طیف پوش برای مکان‌یابی عیوب مورد نیاز است. توانایی ویژگی‌های طیف پوش فرکانسی در آشکار کردن علامت عیب در خرابی ماشین ثابت شده‌اند [۱۰]:

$$x = fft(x_{in}) \quad (۶)$$

$$x_h = \begin{cases} x(n) & n_0, N/2 \\ 2 * x(n) & 1 < n < \frac{N}{2} - 1 \\ 0 & \frac{N}{2} + 1 < n < N - 1 \end{cases} \quad (۷)$$

$$x_a = ifft(x_h) \quad (۸)$$

$$x_{env} = \sqrt{x_a * conj(x_a)} \quad (۹)$$

$$|x_{env}| = |ifft(x_{env})| \quad (۱۰)$$

که x_{in} سیگنال ارتعاشی، x تبدیل فوریه سریع x_{in} ، x_h فقط شامل مقادیر غیر منفی فرکانسی x ، x_a سیگنال تحلیلی x_{in} ، x_{env} سیگنال تحلیلی پوش و $|x_{env}|$ طیف پوش می‌باشد.

بسیاری از تکنیک‌های هوش مصنوعی برای عیب‌یابی تجهیزات دوار به کار گرفته شده‌اند. در پژوهشی که توسط احمد و همکارانش انجام شده، از الگوریتم ژنتیک برای انتخاب خودکار ویژگی‌ها در سیستم پایش وضعیت استفاده شده است. علاوه بر این می‌توان از الگوریتم ژنتیک برای یافتن همزمان ساختار بهینه گسترش مقادیر شبکه عصبی احتمالی نیز استفاده کرد و همچنین به طور همزمان تعداد گره‌ها در لایه پنهان یک شبکه عصبی مصنوعی محاسبه کرد [۱۱]. سامانتا و البلوشی شبکه‌های عصبی را برای عیب‌یابی یاتاقان غلتکی، با استفاده از ویژگی‌های دامنه زمانی از سیگنال ارتعاشی به کار بستند [۱۲]. آنها همچنین از الگوریتم ژنتیک برای بهینه‌سازی بردار ویژگی‌ها در عیب‌یابی دنده‌های یک جعبه دنده با استفاده از داده‌های سیگنال ارتعاشی تجربی استفاده کردند [۱۳]. از شبکه‌های عصبی عمیقی که در چند سال اخیر در عیب‌یابی کمپرسورهای رفت و برگشتی مورد استفاده قرار گرفته‌اند می‌توان به CNNها یا شبکه‌های عصبی پیچشی اشاره کرد. به دلیل سیگنال‌های غیر خطی پیچیده و سختی به دست‌آوردن گرفتن ویژگی‌های عیب از سیگنال ارتعاشی در کمپرسورهای رفت و برگشتی، یک روش مناسب برای حل این مشکل، روش جدید با نام شبکه‌های عصبی پیچشی (CNN) که با استفاده از سنسورهای مختلف سیگنال خام ارتعاشات را به عنوان ورودی می‌گیرد و با CNN استخراج ویژگی‌ها و طبقه‌بندی را انجام می‌دهد [۱۴]. این روش با شبکه عصبی پس انتشار خطا مقایسه و تاثیر آن نمایان شده است. همچنین ژنگ از این الگوریتم در تحقیق بر امکان تشخیص انواع عیوب سوپاپ با سیگنال نشر آوایی استفاده کرد [۱۵]. با اینکه کاربرد زیاد کمپرسورهای رفت و برگشتی بر کسی پوشیده نیست اما عیوب سوپاپ‌ها معمولاً خاموشی پیش‌بینی نشده در پی دارد. با توجه به اهمیت عیوب سوپاپ‌ها و اینکه بیشترین خرابی را در دستگاه دارند، روش شبکه عصبی مصنوعی با دقت طبقه‌بندی صحیح ۹۷ درصدی سعی در به حداقل رساندن خاموشی دستگاه دارد [۱۶]. در راستای طبقه‌بندی عیب‌های سوپاپ‌های کمپرسور روش جدید معماری یادگیری برای مدل‌های عمیق ساخته شده است که با نام شبکه باور عمیق مورد استفاده قرار می‌گیرد. ژنگ و همکاران در سال ۲۰۲۰ با بهینه‌سازی شبکه باور عمیق پیچشی نیز عیب‌یابی را با این الگوریتم برای کمپرسور رفت و برگشتی انجام دادند [۱۷]. آن‌ها همچنین این الگوریتم را با استفاده از تجزیه سیگنال‌های ارتعاشی به مؤلفه‌های ذاتی نیز به کار بردند. از شبکه‌های عصبی که در چند سال اخیر در عیب‌یابی کمپرسورهای رفت و برگشتی مورد استفاده قرار گرفته‌اند می‌توان به CNNها یا شبکه‌های عصبی پیچشی اشاره کرد. به دلیل سیگنال‌های غیر خطی پیچیده و سختی به دست‌آوردن گرفتن ویژگی‌های عیب از سیگنال ارتعاشی در کمپرسورهای رفت و برگشتی، یک روش مناسب برای حل این مشکل، روش جدید با نام شبکه‌های عصبی پیچشی (CNN) که با استفاده از سنسورهای مختلف سیگنال خام ارتعاشات را به عنوان ورودی می‌گیرد و با CNN استخراج ویژگی‌ها و طبقه‌بندی را انجام می‌دهد. این روش با شبکه عصبی پس انتشار خطا مقایسه و تاثیر آن نمایان شده است. همچنین ژنگ از این الگوریتم در تحقیق بر امکان تشخیص انواع عیوب سوپاپ با سیگنال نشر آوایی استفاده کرد [۱۵].

مشاهده می‌شود که در تحقیق‌های بالا، محاسبات شبکه‌های عصبی با راندمان بهتر، مثل شبکه عصبی احتمالی زیاد تحقیق نشده‌اند و ترکیب شبکه عصبی مصنوعی و الگوریتم ژنتیک هم کمتر مورد توجه قرار گرفته است. در پژوهش‌های پیش از این تعدادی مدل مختلف شبکه عصبی به منظور آزمایش اثربخشی آنها برای سیستم کمپرسور رفت و برگشتی ارائه شده است. مدل‌های ابتدایی هوش مصنوعی که شامل مشتقات شبکه‌های عصبی

مصنوعی را شامل می‌شوند. علاوه بر این، از الگوریتم ژنتیک و روشهای SVM برای آزمایش اثربخشی و بهینه‌سازی آنها برای عیب‌یابی استفاده شده‌اند. اما نسبت به تحقیقات پیشین، شبکه‌های عصبی احتمالی مغفول مانده‌اند.

تمرکز تحقیق فعلی این است که با استفاده از چارچوبی که با شبکه عصبی احتمالی با هشت کلاس طبقه‌بندی شده است، برای تشخیص عیوب کمپرسورهای رفت و برگشتی استفاده کند، و با استفاده از الگوریتم ژنتیک سعی به بهبود آن کند. مدل ریاضی یک کمپرسور رفت و برگشتی به منظور مطالعه ویژگی‌های ارتعاشی، از طریق شبیه‌سازی عیوب مورد استفاده قرار گرفته است. همین مدل نیز برای تشخیص عیوب بر اساس یادگیری شبکه عصبی، مورد استفاده قرار گرفت. ترکیبی از عیوب مختلف سیگنال‌های ارتعاشی به دست آمده از سوپاپ‌های کمپرسور برای استخراج ویژگی‌های دامنه زمانی و طیف پوش مورد استفاده قرار گرفت.

۲- مدل‌سازی ریاضی عیوب کمپرسور رفت و برگشتی دو مرحله‌ای

درک فرآیند دینامیکی کمپرسورهای رفت و برگشتی نکته لازم و مهم در طراحی و پیش‌بینی عیوب آنهاست. مدل‌سازی کمپرسورهای رفت و برگشتی در طی سال‌ها توجه زیادی را در تحقیقات به خود جلب کرده است. بسیاری از این شهرت به خاطر نقش داشتن مدل‌های عددی است که به صورت بلادرنگ در کاربردهای پایش وضعیت ماشین‌ها و عیب‌یابی آنها استفاده شده است.

مدل ریاضی اجزای جداگانه دستگاه اما مرتبط با هم برای یک کمپرسور رفت و برگشتی که شامل مکانیزم میل‌لنگ، سیلندر و سوپاپ برای یک کمپرسور رفت و برگشتی دو مرحله‌ای است، بر مبنای پژوهش مرجع [۳] شبیه‌سازی شده است. همچنین مقادیر پارامترهای فیزیکی و ثوابت کمپرسور مورد بررسی مربوط به کمپرسور Broom Wade TS9 می‌باشد. در این بخش تاثیر عیوب خاص بر کمپرسورها را مدل خواهیم کرد.

۲-۱- نشتی سوپاپ‌ها

در این شبیه‌سازی نشتی سوپاپ به شکل یک جریان اضافی موازی با جریان جرم معمولی سوپاپ است [۱۰].

$$\dot{P}_{CL,H} = \frac{1}{V_{CL,H}} [c_{iL,H}^2 \dot{m}_{viL,H} - c_{dL,H}^2 \dot{m}_{vdL,H} - \gamma P_{CL,H} \dot{V}_{CL,H} + c_{dL,H}^2 \dot{m}_{ldL,H} - c_{iL,H}^2 \dot{m}_{liL,H}] \quad (11)$$

$$\dot{m}_{ldL,H} = \beta_{dL,H} c_{adL,H}(X) A_{fdL,H} \sqrt{2\rho_{CL,H} |P_{CL,H} - P_{dL,H}|} \quad (12)$$

که داریم: $\beta_{dL,H} = \text{sign}(P_{CL,H} - P_{dL,H})$

¹ tepen.net/facility/reciprocating-compressor-test-rig/#

۲-۳- نشتی خنک‌کن میانی

با فرض نشت کوچک در خنک‌کن میانی قبل از مرحله دوم کمپرسور:

$$\dot{P}_{ic} = \frac{1}{V_{iL}} [c_{cL}^2 \dot{m}_{vdL} - c_{iH}^2 \dot{m}_{viH} - c_{ic}^2 \dot{m}_{ic}] \quad (17)$$

جریان جرم نشتی خنک‌کن میانی به شکل زیر به دست می‌آید:

$$\dot{m}_{ic} = \beta_{ic} c_{ic}(X) A_{ic} \sqrt{2\rho_{ic} |P_{ic} - P_0|} \quad (18)$$

۲-۴- شبیه‌سازی و حل عددی کمپرسور

بخش اصلی در تبدیل مدل به کدهای متلب تصمim گیری در مورد روش حل مناسب از میان تعدادی از گزینه‌های متلب است. الگوریتم مرتبه چهارم Runge-Kutta (ode45) برای این شبیه‌سازی انتخاب شد. این الگوریتم توسط متلب توصیه شده است و ثابت شده است که در حل معادلات دیفرانسیل غیر سخت پایدار و کارآمد است. با این حال، درجاتی از سفتی در معادلات سوپاپ به دلیل گذرا بودن ضربه نشستگاه وجود دارد، که یک گام^۱ تک مرحله‌ای برای محاسبات یا به راه‌حل‌های نادرست منجر می‌شود (اندازه گام خیلی بزرگ برای دوره گذرا) و یا زمان زیادی برای محاسبه می‌گیرد (اندازه گام بسیار کوچک برای مرحله خطی‌تر). برای در نظر گرفتن با تأثیر سختی احتمالی در فرآیند حل، یک گام کوچک انتخاب شد تا راه‌حل‌های حرکت سوپاپ پایدار باشد، فرآیند حل عددی تا زمانی معادل، مدت زمان ۵ سیکل کمپرسور ادامه می‌یابد، زمانی که همه راه‌حل‌ها به عملکرد ثابت رسیده باشند. هر یک از فرآیندها، از نقطه مرگ بالا پیستون، در سیلندر یک شروع می‌شود (زاویه میل لنگ $\theta=0^\circ$)، زمانی که هر دو سوپاپ‌های مکش و دهش بسته هستند و فشار سیلندر نسبتاً کم است و پس از ۵ دور چرخش میل لنگ دوباره در نقطه مرگ بالا با $\theta = 5 \times 360^\circ = 1800^\circ$ تمام می‌شود. در شکل (۲) جریان فرآیند شبیه‌سازی مشاهده می‌شود.

۳- طبقه‌بندی با شبکه عصبی احتمالی

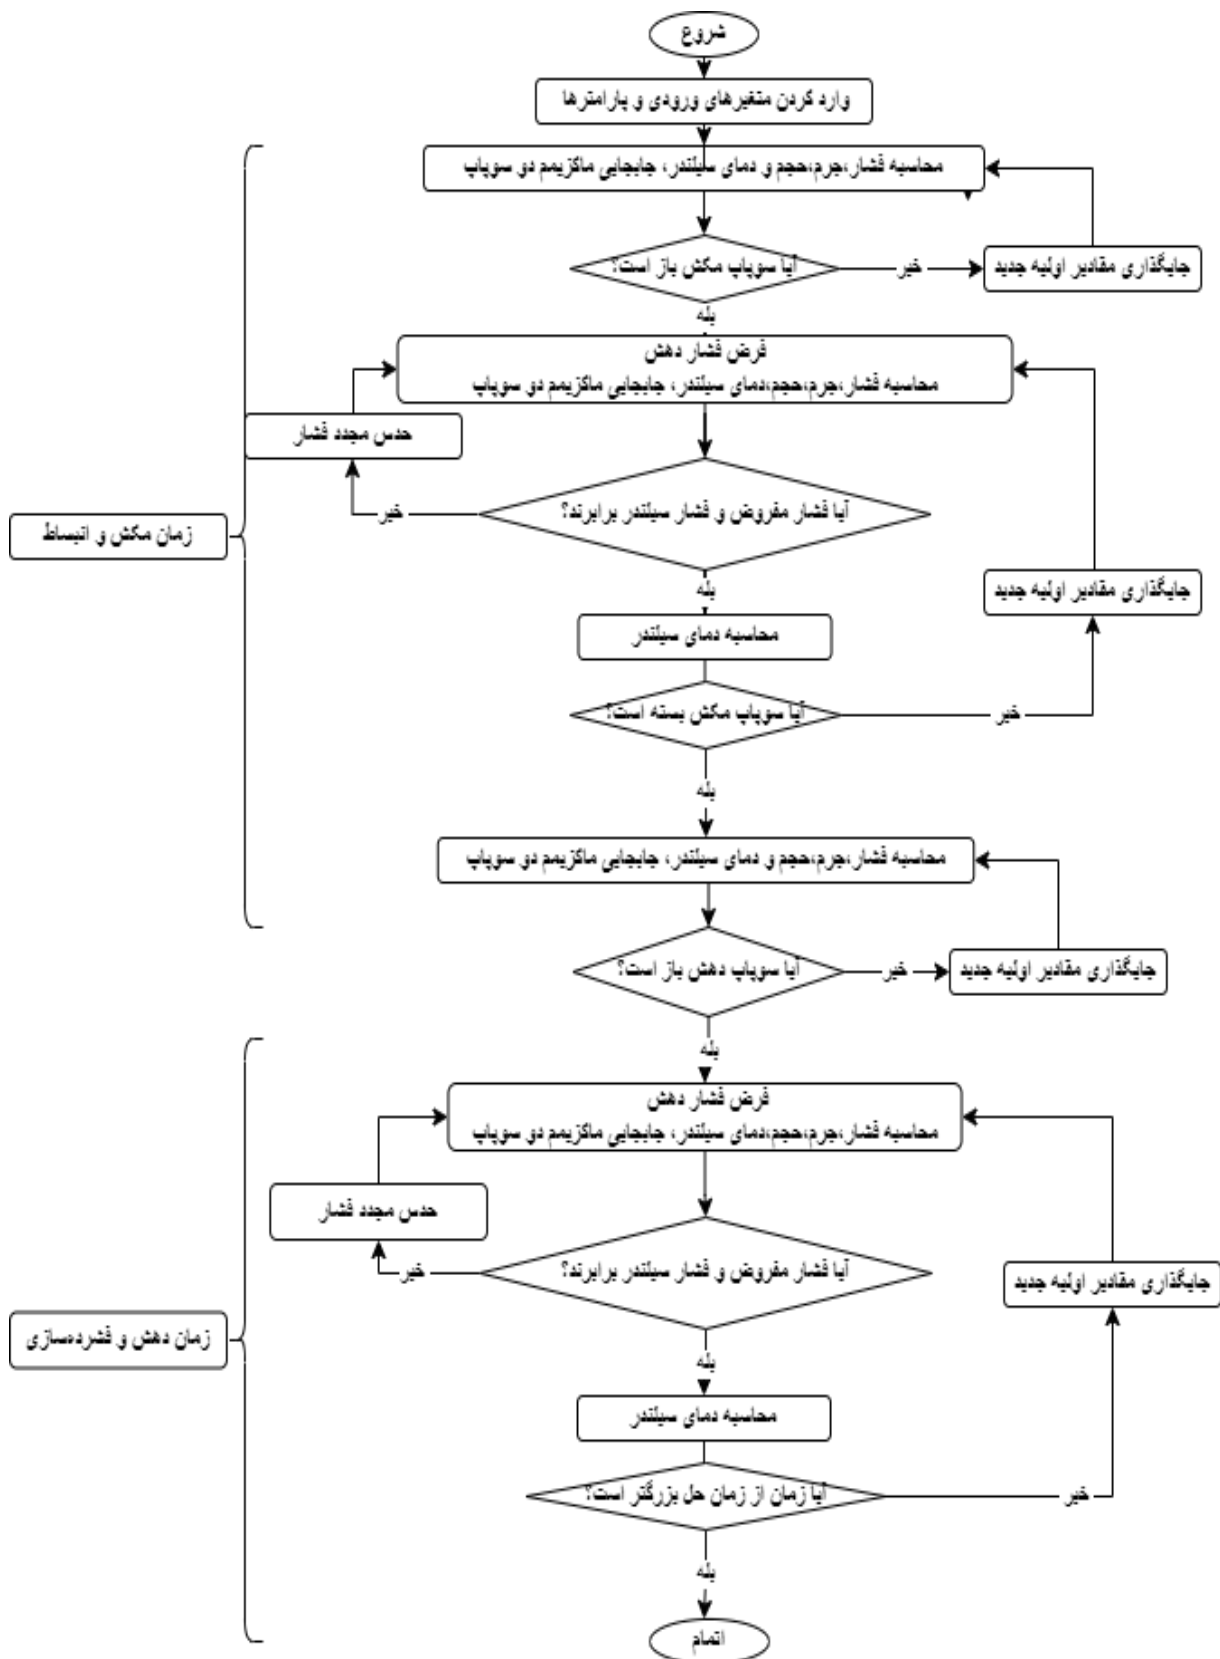
سهام اصلی این کار توسعه رویکرد کمتر دیده شده است که الگوریتم ژنتیک را با شبکه عصبی احتمالی ترکیب می‌کند. هشت کلاس مختلفی که حالات مختلف کمپرسور در آن‌ها طبقه‌بندی می‌شوند به شکل زیر هستند:

- (۱) کمپرسور سالم
- (۲) نشتی سوپاپ خروجی
- (۳) نشتی سوپاپ ورودی
- (۴) نشتی خنک‌کن میانی
- (۵) شل‌شدگی تسمه انتقال قدرت
- (۶) نشتی سوپاپ ورودی و خنک‌کن میانی

¹ Step

(۷) نشستی سوپاپ خروجی و خنک‌کن میانی

(۸) نشستی سوپاپ ورودی و سوپاپ خروجی

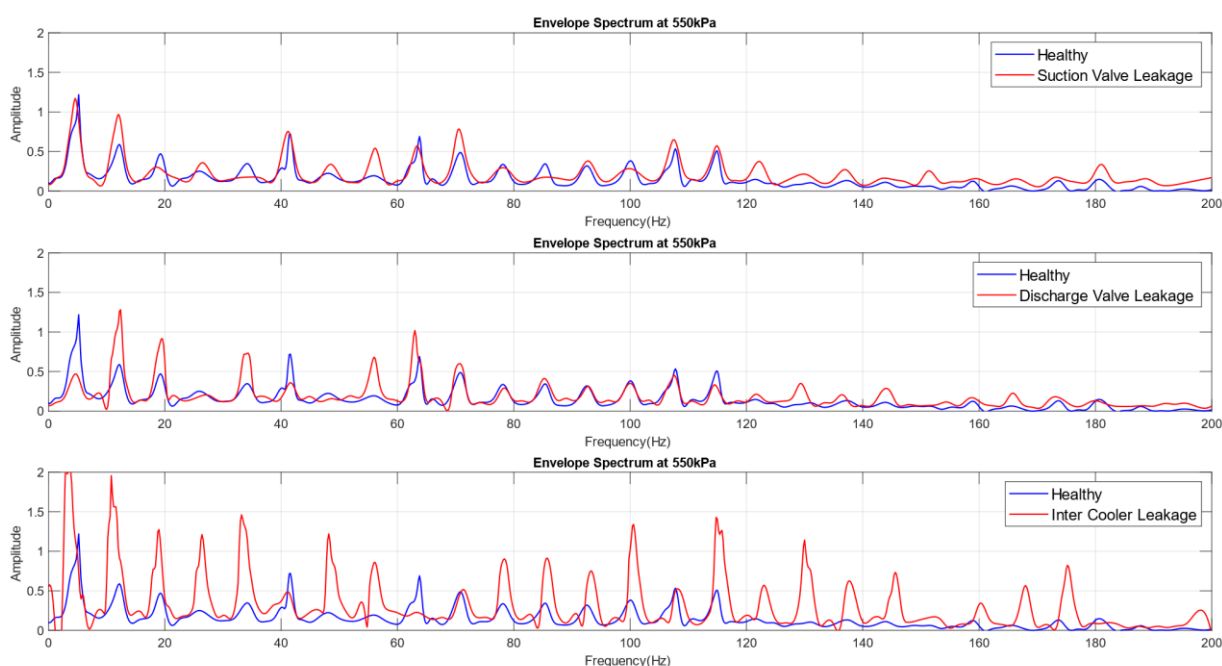


شکل ۲ - دیاگرام روند شبیه‌سازی مدل

۳-۱- استخراج ویژگی‌ها

انتخاب ویژگی‌های حیاتی از ماشین مورد نظر سهم اصلی در افزایش اثربخشی روند تشخیص عیب است. ویژگی‌های استخراج شده حوزه زمان همان ویژگی‌های آماری ذکر شده در بخش مقدمه می‌باشد. با توجه به سرعت کاری کمپرسور Broom Wade TS9 (۴۲۵ دور بر دقیقه)، فرکانس کاری کمپرسور برابر $7/3$ هرتز می‌باشد. ویژگی‌ها استخراجی مولفه‌های طیف پوش در فرکانس کاری و هارمونیک‌ها مرتبه بالاتر آن تا ۱۲۰ مرتبه به عنوان ویژگی‌های طیف پوش سیگنال انتخاب شدند. آنالیز طیف پوش با انتخاب مناسب پنجره، یک تکنیک پردازش سیگنال شناخته شده برای تشخیص عیب است. در ادامه، پنجره‌ها برای سیگنال‌های طیفی سالم و معیوب بین ۰ تا ۲۰۰ هرتز انتخاب شده است، زیرا که در این بازه تعداد کافی از هارمونیک‌ها برای طبقه‌بندی عیوب در دسترس است و این یک پنجره معمول در پایش وضعیت کمپرسور در حوزه فرکانس می‌باشد. یک تصویر بزرگ‌نمایی شده از شکل طیفی نشان می‌دهد که، برای نشی سوپاپ مکش (مورد اول شکل (۳) ۲۶ هارمونیک آشکار وجود دارد، که این هارمونیک‌ها در پنجره انتخاب شده برای نمودار طیفی عیب و کمپرسور سالم وجود دارند. با مقایسه هر دو نمودار سالم و معیوب، واضح است که افزایش دامنه در چند هارمونیک نمودار طیفی عیب مشاهده می‌شود.

در شکل (۳) قسمت سوم به دلیل وجود عیب نشی خنک کن میانی که موجب هارمونیک‌های متفاوت نسبت به حالت سالم شده است و وارد کردن نویز اندازه‌گیری یا خروجی (یعنی سنسورها نویز دارند) یعنی بعد از حل با ode نویز وارد شده است که نویز اندازه‌گیری است و در شکل سوم بین فرکانس ۶۰ تا ۸۰ هرتز نمودار کمپرسور معیوب در یک هارمونیک نمودار اصلی را دنبال نمی‌کند که این اتفاق در فرکانس ۴۰ نیز برای هارمونیک دیگری افتاده است. همان طور که در شکل (۳) مشخص است، تعدادی مولفه از کمپرسور نشان داده شده است که از فرکانس کاری کمپرسور هستند.



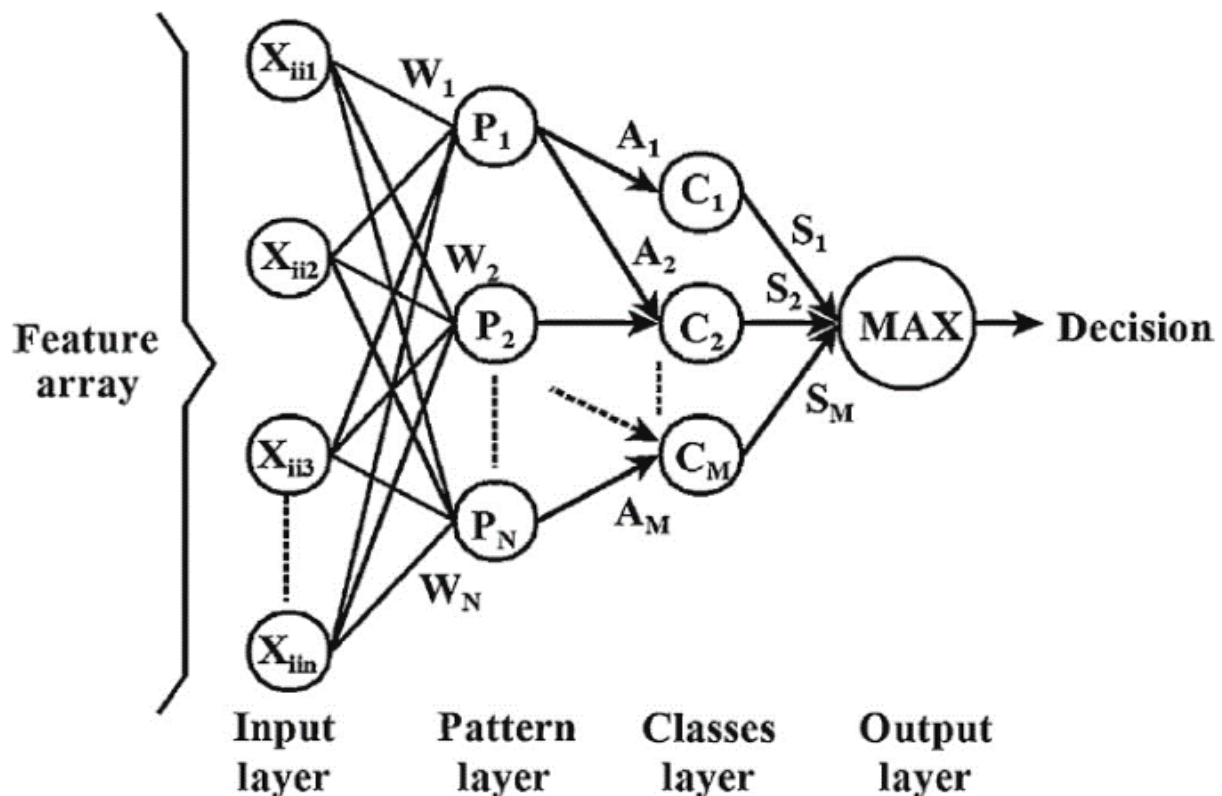
شکل ۳ - مقایسه طیف پوش کمپرسور سالم و سه عیب در فشار ۵۵۰ کیلو پاسکال

طیف سیگنال کمپرسور، تعداد کمی از مولفه‌های ویژگی‌ها را در اختیار قرار نمی‌دهد. با توجه به شکل و تغییر کم دامنه، یافتن مجموعه‌ای از ویژگی‌ها که بتوان عیوب را از یکدیگر جدا کرد، دشوار است. لذا اندازه این مولفه‌ها و دیگر هارمونیک‌ها، به عنوان نامزد ویژگی‌ها در هر بار اجرای مسئله انتخاب شدند. در نتیجه، ماتریس ویژگی‌ها یک ماتریس $n*m$ است که n تعداد هارمونیک‌ها و m تعداد نمونه‌ها است. با توجه به ۳۰ عدد هارمونیک و ۴۰ عدد نمونه از هر سیگنال، با وجود هشت کلاس کمپرسور سالم و معیوب، ماتریس ویژگی‌ها یک ماتریس $320*30$ خواهد بود.

۳-۲- شبکه عصبی احتمالی

شبکه‌های عصبی احتمالی از انواع شبکه‌های عصبی پیشخور هستند. ساده‌ترین و اصلی‌ترین پیاده‌سازی شبکه‌های عصبی احتمالی بر اساس تابع چگالی احتمال و قانون طبقه بندی بیز می‌باشد. روش مدل یادگیری شبکه‌های عصبی احتمالی بر اساس یک مسیر یک طرفه از طریق تمام مجموعه داده‌های یادگیری موجود است. شبکه‌های عصبی احتمالی یک شبکه عصبی چهار لایه هستند. به طور معمول از یک تابع فعال ساز گاوسی استفاده می‌شود، تا الگوهای طبقه بندی شده در یک منطقه با خروجی یک و در منطقه دیگر با طبقه بندی صفر قرار گیرد. یک شبکه عصبی احتمالی معمولی، در شکل (۴) نمایش داده شده است.

طبقه بندی به میزان زیادی به توابع چگالی احتمال بستگی دارد. از این رو، می‌توان چنین فرض کرد که، توابع چگالی احتمالی به دست آمده از الگوهای آموزشی را می‌توان با موفقیت برای طبقه بندی بردارهای ورودی یک شبکه عصبی احتمالی معین مورد استفاده قرار داد.



شکل ۴ - ساختار شبکه عصبی احتمالی [۱۹]

طبقه‌بندی به میزان زیادی به توابع چگالی احتمال بستگی دارد. از این رو، می‌توان چنین فرض کرد که، توابع چگالی احتمالی به دست آمده از الگوهای آموزشی را می‌توان با موفقیت برای طبقه‌بندی بردارهای ورودی یک شبکه عصبی احتمالی معین مورد استفاده قرار داد. تکنیک پنجره پارزن^۱ در شبکه عصبی احتمالی به منظور تخمین توابع احتمال وابسته به کلاس استفاده می‌شود. توابع احتمال وابسته به کلاس ایجاد شده در این روش سپس برای طبقه‌بندی در هر یک از دسته‌بندی‌ها در کلاس‌ها، با استفاده از قانون تصمیم‌بیز استفاده می‌شوند. این تکنیک تعیین می‌کند که آیا یک الگوی بردار ورودی می‌تواند در یکی از کلاس‌ها الگوها طبقه‌بندی شود یا خیر. سپس این اطلاعات طبقه‌بندی‌های ارائه شده هر کلاس، با اطلاعات دیگر کلاس‌ها ترکیب می‌شود، به طوری که شبکه عصبی احتمالی می‌تواند دسته‌ای را انتخاب کند که به احتمال زیاد بردار ورودی الگوی لازم به آن تعلق دارد.

با توجه به معماری پایه یک شبکه عصبی احتمالی در شکل (۴)، اولین لایه، لایه ورودی است که از m متغیر ورودی مختلف تشکیل شده است که بردار ورودی X را تشکیل می‌دهند. نورون‌های موجود در لایه اول برای توزیع ورودی‌های مختلف بردار X به لایه دوم عمل می‌کند. در لایه دوم که بیشتر به عنوان لایه الگو شناخته می‌شود، دارای تعداد نورون‌های موجود به اندازه تعداد نمونه‌های آموزشی است. نورون‌های موجود در این لایه وزن‌هایی متفاوتی دارد که به مجموعه داده‌های یادگیری مختلف مورد استفاده، بستگی دارد. محاسبه شباهت با استفاده از فاصله اقلیدسی در این لایه انجام می‌شود.

$$D(X, Y) = \left(\sum_{i=1}^N [(X_i - Y_i)^2 U(X_i - Y_i)] \right)^{\frac{1}{2}} \quad (19)$$

سپس تابع چگالی احتمال توسط تکنیک پنجره پارزن محاسبه می‌شود.

$$F_{j,k}(x)_c = \frac{1}{(2\pi)^{\frac{m}{2}} \sigma^m n} \exp \left[-\frac{\|x - x_{j,k}\|^2}{2\sigma^2} \right] \quad (20)$$

که n مجموعه داده‌های یادگیری، m بعد بردار ورودی X ، j الگوی مورد استفاده و σ پارامتر صافی قابل تغییر مورد استفاده است.

سری ترم‌های پنجره پارزن، توسط لایه تجمیع یا لایه کلاس‌ها که نورون‌های کمتری در مقایسه با لایه قبلی دارد، جمع‌بندی می‌شود. در واقع، نورون‌های لایه کلاس‌ها به تعداد کلاس‌ها می‌باشد. مهم است که توجه داشته باشید که وزن‌های لایه کلاس‌ها اساساً در یک محدود شده است تا خروجی‌های لایه الگو فقط با هم جمع شوند.

$$G(x)_c = \sum_{i=1}^n w_{ki} F_{i,k}(x)_c \quad (21)$$

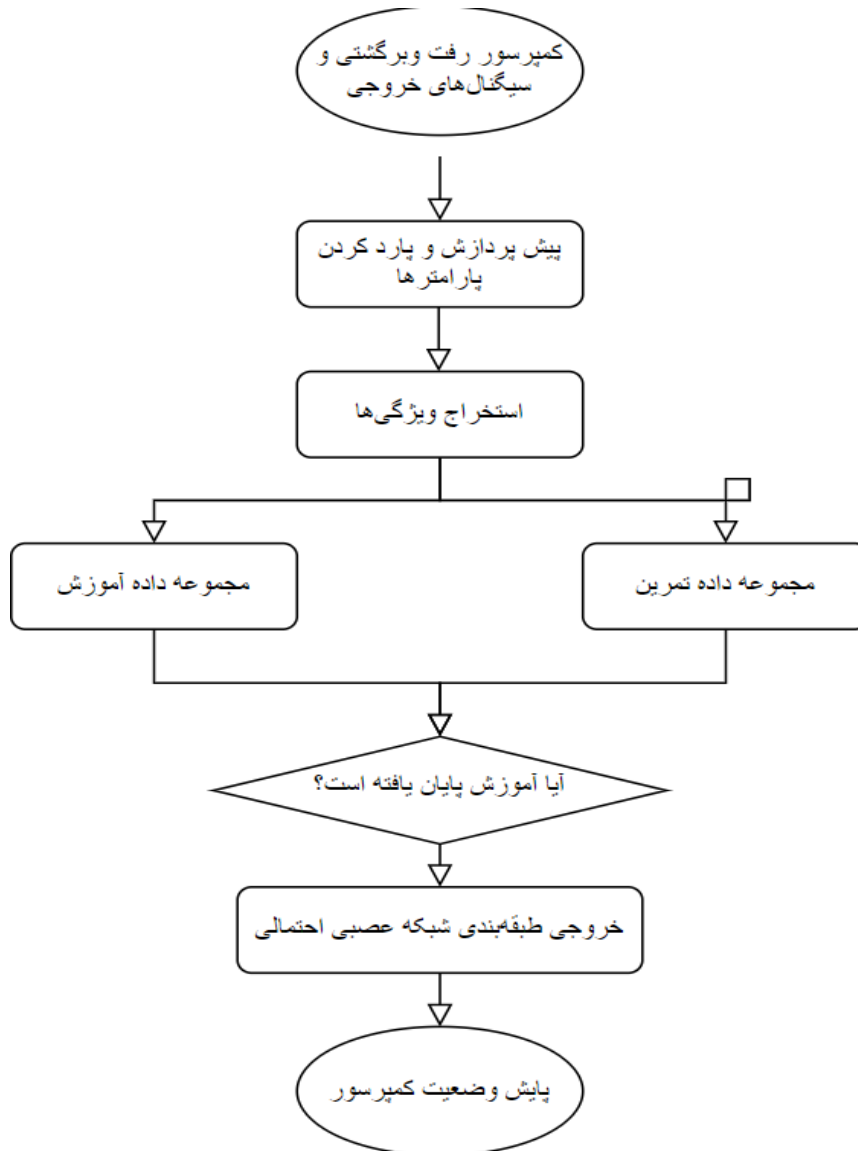
¹ Parzen window technique

$$\sum_{i=1}^n w_{ki} = 1 \quad (22)$$

سپس این مقادیر به لایه خروجی وارد می‌شوند که تنها یک عنصر نورونی دارد که طبقه بندی نهایی را انجام می‌دهد. در نورون در لایه خروجی شبکه عصبی احتمالی تمایل داریم یک مقدار باینری ناشی از تابع چگالی احتمال با بیشترین مقدار خروجی را ارائه کنیم. در اصل، بالاترین مقدار به دست آمده از طریق این مکانیسم، طبقه بندی بهینه‌ای را ارائه می‌دهد که شبکه عصبی احتمالی می‌تواند برای الگوی ورودی ارائه دهد.

$$G(x)_{c1} > G(x)_{c2} \quad (23)$$

۳-۳- شبیه سازی شبکه عصبی احتمالی



شکل ۵ - دیاگرام روند پایش وضعیت با استفاده از شبکه عصبی احتمالی

برای هر بردار داده شده در مجموعه داده‌های ورودی، بردار هدف مربوطه در ماتریس دومی ساخته شد به ابعاد بردار داده‌ها که شامل مقادیرهای ۱ تا ۸ برای انواع عیوب و کمپرسور سالم می‌باشد، و در یادگیری شبکه عصبی احتمالی استفاده شد.

برای حوزه زمان یک ماتریس 1×1920 و برای طیف پوش یک ماتریس 1×192 شامل داده‌های هدف ساخته شد. این‌ها همه داده‌های ورودی برای یادگیری شبکه عصبی احتمالی می‌باشند. مجموعه داده‌ها دارای تعداد مساوی نمونه از شرایط کمپرسور معمولی و معیوب هستند. هر دو مجموعه داده‌ها و بردار هدف با در نظر گرفتن هر یک به دو زیر مجموعه با اندازه مساوی تقسیم شدند. که یکی برای آموزش شبکه عصبی احتمالی و دیگری برای آزمایش استفاده شد. شبکه، به شکل زیر شبیه‌سازی شد:

دو مجموعه داده ایجاد شد. در اولین مجموعه داده از حوزه زمان، به دو زیر مجموعه مساوی تقسیم شد. برای آموزش از شبکه عصبی احتمالی مجموعه داده 10×960 استفاده شد و بقیه 10×960 برای تست استفاده شد. دومین مجموعه از پوش نیز به دو زیر مجموعه مساوی برای آموزش از شبکه عصبی احتمالی که یک مجموعه داده 96×30 و بقیه با اندازه 30×96 برای تست استفاده شدند. سپس داده‌ها شبیه‌سازی و پارامتر پخش شدگی (سیگما) شبکه عصبی احتمالی با یک روش آزمون و خطا $0.4/0$ شناسایی شده است. در نهایت، مشاهده طبقه بندی با رسم ارقام با ویژگی‌های مختلف در هر دو حوزه زمان و پوش انجام شد.

۴- بهینه‌سازی انتخاب ویژگی‌ها با الگوریتم ژنتیک

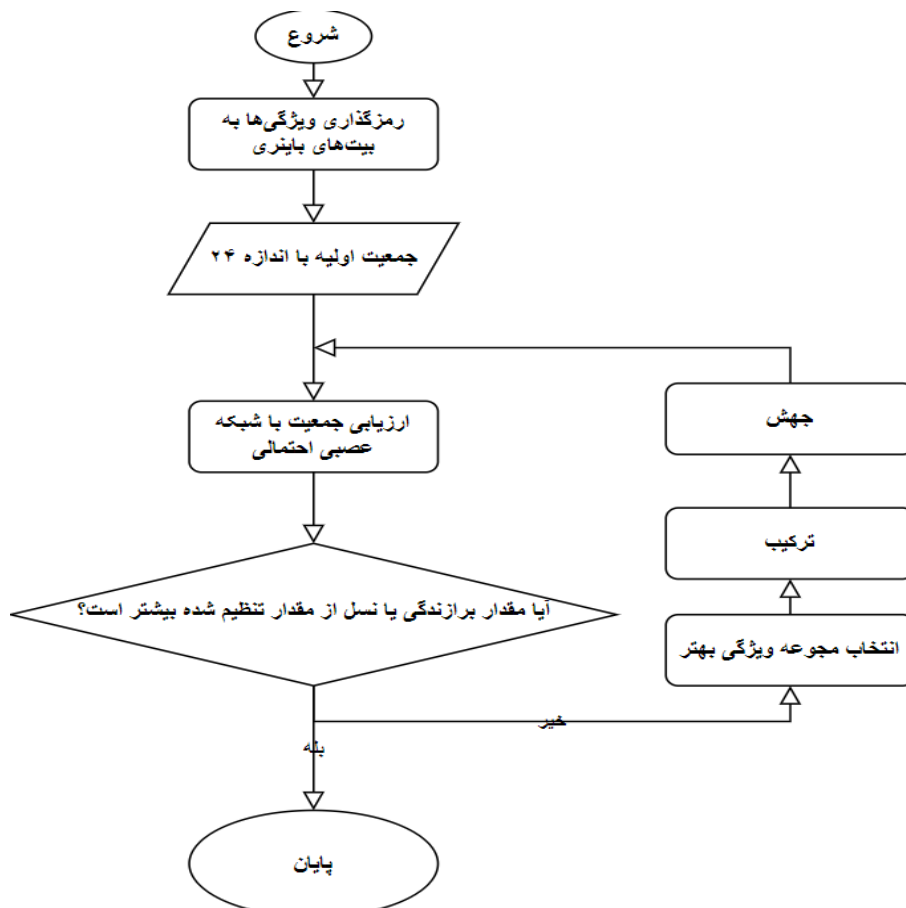
به دلیل ذات مسئله که گسسته است و تعداد ویژگی‌ها که خود یکی از پارامترهای بهینه است نمی‌توان از روش‌های تحلیلی استفاده کرد و الگوریتم ژنتیک روش مناسبی برای بهینه‌سازی می‌باشد. الگوریتم ژنتیک یک تکنیک جستجو است که برای یافتن راه حل در مسائل بهینه‌سازی استفاده می‌شود. الگوریتم ژنتیک اصول تکامل موجود در طبیعت را برای یافتن راه حل بهینه در یک مسئله به کار می‌برد. در الگوریتم ژنتیک، مسئله معمولاً در یک سری رشته بیت کدگذاری می‌شود که توسط الگوریتم دستکاری می‌شوند. بر اساس فرآیند بهینه‌سازی الگوریتم ژنتیک، انتخاب ویژگی برای طبقه بندی عیوب می‌تواند بر اساس فرآیند زیر انجام شود: یک نمایش کروموزومی باینری برای مسئله در این تحقیق انتخاب شد. طول کروموزوم به تعداد ویژگی‌های ورودی به روش شبکه عصبی مورد نیاز بستگی دارد.

برای هر دو شبیه‌سازی اول و دوم با ویژگی‌های حوزه زمان و طیف پوش، تعداد آن بین ۱۰ تا ۲۰ بود. نسل اولیه با ویژگی‌هایی که به‌طور تصادفی انتخاب شده‌اند، تولید شد که هر کدام دارای یک مقدار عددی هستند. حداکثر تعداد جمعیت، با اندازه فضای ویژگی در دسترس تعیین می‌شود. در مرحله ارزیابی برازندگی^۱ در توسعه مدل شبکه عصبی و محاسبه خطای طبقه بندی در تابع هدف، شکل باینری به اعداد اعشاری برگردانده می‌شود. تابع هدف به صورت زیر تعریف می‌شود:

$$Err = \sum_{i=1}^{N_{max}} (t_i - \bar{t}_i)^2 \quad (24)$$

¹ Fitness

که \bar{t}_i کلاس پیش بینی شده توسط شبکه عصبی احتمالی و t_i کلاس برچسب گذاری شده است. N_{max} اندازه مجموعه داده است. برنامه، زمانی خاتمه می‌یابد که خطا برابر یا کمتر از سطح تنظیم شده باشد و یا زمانی که برابر با حداکثر تعداد نسل تنظیم شده در محاسبات شود. مرحله انتخاب این عملیاتی است که طی آن فرآیند توسط الگوریتم ژنتیک به سمت جواب بهتر هدایت می‌شود. الگوریتم‌های مختلفی را می‌توان برای انتخاب بهترین مقادیر از جمعیت تخمین زده استفاده کرد، که الگوریتم انتخاب مسابقه‌ای به دلیل کارآمد بودن و آسانی برای شبیه‌سازی در این تحقیق مورد استفاده قرار گرفته است. عملیات ترکیب^۱ با استفاده از فرآیند جفت‌گیری شبیه‌سازی شده، نسل بعدی را تولید می‌کند. این عمل توسط دو والد انجام می‌شود که فرزندان^۳ را ایجاد می‌کنند که از مواد ژنتیکی هر دو والد تشکیل شده‌اند. این عملیات ترکیبی از ویژگی‌های راه‌حل‌های موجود در تلاش برای ایجاد یک راه‌حل بهتر است. احتمال ترکیب در این آزمایش ۰/۰۸ در نظر گرفته شد. در عملیات جهش هنگامی که فرزندان در طول عملیات ترکیب ایجاد می‌شوند، عملگر جهش برای هر فرزند اعمال می‌شود. هر ژن دارای یک احتمال جهش مشخص شده توسط کاربر برای جهش است. الگوریتم بهینه‌سازی با الگوریتم ژنتیک مطابق شکل زیر است که جمعیت اولیه ۲۴ برای بهینه‌سازی در حوزه زمان می‌باشد:



شکل ۶ - الگوریتم بهینه‌سازی شبکه عصبی احتمالی با الگوریتم ژنتیک

¹ Crossover

² Parent

³ Offspring

۴-۱- شبیه‌سازی الگوریتم ژنتیک

طرح انتخاب ویژگی پیشنهادی بر اساس مجموعه داده ارتعاشی به دست آمده است. همچنین یک برنامه متلب برای شبیه‌سازی شبکه عصبی احتمالی و الگوریتم ژنتیک نوشته شد. ویژگی‌های شکل موج سیگنال، طیف فرکانسی و طیف پوش برای طبقه بندی با استفاده از شبکه عصبی احتمالی، الگوریتم ژنتیک و ترکیب آنها به شرح زیر مورد بررسی قرار گرفت:

برای آزمایش شبکه آموزش دیده، در تابع برازندگی، استفاده از رابطه (۲۴)، در این قسمت تکرار می‌شود. همچنین، پارامتر گسترش شبکه عصبی احتمالی یا همان σ ، هنگامی که انتخاب ویژگی الگوریتم ژنتیک درگیر باشد توسط الگوریتم ژنتیک به طور خودکار بهینه می‌شود. الگوریتم ژنتیک برای انتخاب ویژگی‌های بهینه‌ای مربوط به یک طبقه بندی کننده خاص و به طور همزمان مقدار گسترش بهینه شبکه عصبی احتمالی استفاده شده است. کروموزوم الگوریتم ژنتیک برای انتخاب این ویژگی یک کروموزوم باینری است که طول آن بر اساس تعداد ویژگی‌های موجود برای انتخاب و محدوده پارامتر گسترش شبکه عصبی احتمالی است. به طور معمول محدوده کروموزوم‌ها از ۱۰ تا ۲۰ می‌باشد. ترکیب چند نقطه ای، که با مکان‌های نقاط ترکیب به صورت تصادفی تعیین می‌شوند، شبیه‌سازی شد. جمعیت، برای ترکیب پس از جفت شدن آنها بر اساس برازندگی، تشکیل شد. پس از آن کروموزوم‌ها به ترتیب کاهش برازندگی مرتب می‌شوند. تابع هدف رابطه شماره (۲۴) می‌باشد. در حوزه زمان متغیر بهینه‌سازی ویژگی‌های آماری و در پوش فرکانسی اندازه هارمونیک‌ها به عنوان متغیر استفاده می‌شوند. همچنین قید مسئله تعداد ویژگی‌های آماری در حوزه زمان و هارمونیک‌های فرکانسی در حوزه فرکانس و نبودن ویژگی تکراری در کروموزوم می‌باشند. تابع برازندگی، حداقل خطا در طبقه بندی هشت کلاس ارائه شده است که مقادیر ۱ برای سالم، ۲ برای عیب ناشی سوپاپ خروجی، ۳ برای عیب ناشی سوپاپ ورودی و به همین ترتیب تا ۸ برای ناشی سوپاپ ورودی و سوپاپ خروجی جهش، یک جهش چند نقطه‌ای است که بر اساس یک جهش از پیش با احتمال ۰/۱ تعیین شده است. مکان جهش در هر جهش به طور تصادفی تنظیم می‌شود. بدیهی است که در این رویکرد، پس از به دست آمدن نسل جدیدی از فرزندان، برازندگی عملکرد همه والدین و فرزندان مورد ارزیابی قرار گرفت و آنهایی که بالاترین برازندگی را داشتند، به نسل بعدی منتقل شدند.

۵- نتایج و بحث

۵-۱- نتایج شبیه‌سازی مدل کمپرسور و عیوب

در این بخش نمودار سرعت شبیه‌سازی دینامیکی سوپاپ در سه فشار مختلف ذکر می‌شود. همچنین نتیجه شبیه‌سازی عیب ناشی سوپاپ دهش با حالت کمپرسور سالم مقایسه می‌شود.


۵-۱-۱- مدل کمپرسور

در این بخش نتایج به دست آمده برای مرحله دوم کمپرسور تشریح شده است. برای پیستون در مرحله ۲، سیلندر فشار بالاتر، به اندازه $\frac{\pi}{4}$ از مرحله اول پیش است، بنابراین زمانی که پیستون مرحله یک در نقطه مرگ بالا است، سوپاپ مکش مرحله ۲ باز و سوپاپ دهش بسته خواهد شد. جدول (۱) زوایای میل لنگ را نشان

می‌دهد که در آن سوپاپ دهش باز و بسته می‌شود. با این حال، انتظار می‌رود زمانی که سوپاپ دهش باز و بسته می‌شود، به طور قابل توجهی بر روی فشار دهش بستگی داشته باشد. هر چه فشار دهش بیشتر باشد، سوپاپ دیرتر باز می‌شود. زیرا فشار بالاتر در مخزن دهش، به همان نسبت، به فشار بالاتر در سیلندر قبل از باز شدن فنر سوپاپ دهش مرحله دوم نیاز دارد. شکل (۷) از جایجایی پیش بینی شده سوپاپ‌های مکش و دهش در مرحله دوم کمپرسور، به دست آمده است که سرعت حرکت سوپاپ‌ها را نشان می‌دهد. زوایای میل لنگ که در آن سوپاپ‌ها باز و بسته شده‌اند، واضح است، و مشاهده می‌شود که سوپاپ مکش در زاویه میل لنگ $298/1$ درجه باز می‌شود و سوپاپ دهش در زاویه $180/7$ درجه باز می‌شود. بسته شدن سوپاپ‌های مکش و دهش به ترتیب در $100/7$ درجه و $274/6$ درجه در فشار دهش 690 kPa (سه فشار 550 ، 690 و 810 کیلوپاسکال در نظر گرفته شده سه فشار کاری مرسوم کمپرسور Broom Wade TS9 استفاده شده در شبیه‌سازی می‌باشند.) انجام می‌شود. با افزایش فشار خروجی کمپرسور سوپاپ خروجی دیرتر باز می‌شود که دلیل نزدیکی نمودار خروجی (مشکی رنگ) نسبت به زاویه 200 درجه و در نتیجه دیرتر باز شدن آن می‌باشد. نمودار مشکی رنگ سرعت حرکت سوپاپ خروجی و آبی رنگ متعلق به سوپاپ ورودی است.

جدول ۱ - زوایای باز و بسته شدن سوپاپ‌ها در مرحله دوم کمپرسور سالم در فشار خروجی 690 kPa

عملیات	زاویه (درجه)
نقطه مرگ پایین	۹۰
بسته شدن سوپاپ مکش	$100/7$
باز شدن سوپاپ دهش	$180/7$
نقطه مرگ بالا	۲۷۰
بسته شدن سوپاپ دهش	$274/6$
باز شدن سوپاپ مکش	$298/1$



شکل ۷ - سرعت حرکت سوپاپ‌های مکش و دهش برای مرحله دوم کمپرسور سالم در فشارهای خروجی 550 ، 690 و 810 کیلو پاسکال

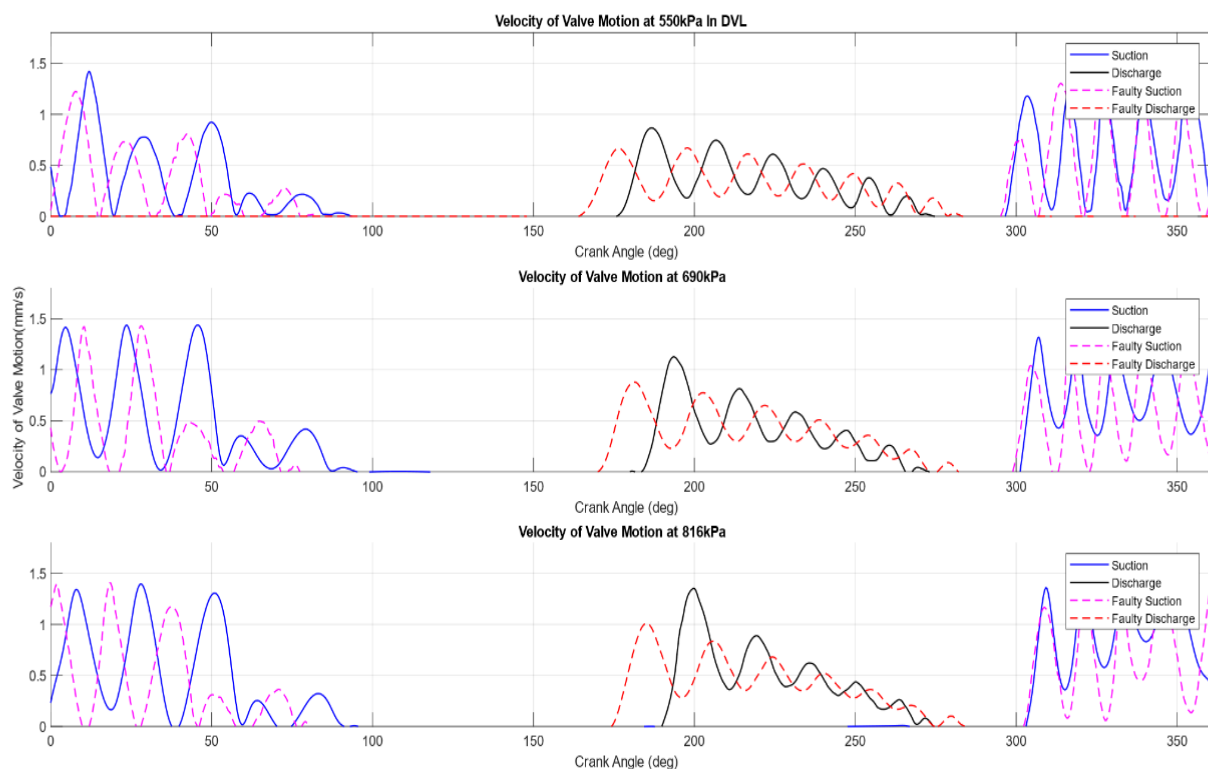
۵-۱-۲- عیب ناشی سوپاپ دهش

ناشتی سوپاپ باعث می شود هوای با دمای بالا به اجبار در سراسر سطح سوپاپ به دلیل اختلاف فشار عبور کند، که خراب شدن سیستم سوپاپ (از جمله فنر سوپاپ) را تسریع می کند و راندمان کمپرسور را به میزان قابل توجهی کاهش می دهد.

تغییرات در جابجایی های سوپاپ ناشی از ناشی سوپاپ دهش است، در شکل (۸) نشان داده شده است. ناشی باعث می شود که سوپاپ دهش زودتر باز شود. این به این دلیل است که هوای با فشار بالا که از طریق ناشی سوپاپ دهش، فشار سیلندر را بالاتر از چیزی که به طور معمول وجود دارد می برد. در نتیجه فشار مورد نیاز برای باز کردن سوپاپ است، زودتر اتفاق می افتد. حرکت سوپاپ مکش نیز تغییر می کند. زیرا فشار بالاتر سیلندر، باعث تاخیر در رسیدن به فشار مورد نیاز برای باز شدن سوپاپ مکش می شود. واحد محور عمودی میلی متر بر ثانیه.

۵-۲- نتایج پایش وضعیت با شبکه عصبی احتمالی

برای مقایسه، چهار مجموعه از شبکه عصبی احتمالی برای ارزیابی اثربخشی انواع ویژگی ها مختلف و انتخاب ویژگی با الگوریتم ژنتیک مورد مطالعه قرار گرفته است. اولین مورد شبکه عصبی احتمالی مبتنی بر ویژگی دامنه زمان است. دومین شبکه عصبی احتمالی مبتنی بر ویژگی طیف پوش است. سومین شبکه عصبی احتمالی مبتنی بر ویژگی دامنه زمان با انتخاب ویژگی الگوریتم ژنتیک است. و چهارمین شبکه عصبی احتمالی طیف پوش، مبتنی بر انتخاب ویژگی با الگوریتم ژنتیک است.



شکل ۸ - حرکت سوپاپ ها مرحله دوم کمپرسور با وجود ناشی در سوپاپ دهش

۵-۲-۱- کارایی شبکه عصبی احتمالی در استفاده از ویژگی‌های حوزه زمان

در مجموع از ده ویژگی ورودی برای ارائه نرخ طبقه‌بندی صحیح ۴۳٪ استفاده شد، که در جدول زیر نشان داده شده است. حتی با استفاده از تعداد زیادی از ویژگی‌های ورودی (۱۰ ویژگی)، نرخ طبقه بندی صحیح پایین باقی ماند.

۵-۲-۲- کارایی شبکه عصبی احتمالی در استفاده از مؤلفه‌های هارمونیک طیف پوش فرکانسی:

برای طبقه بندی شبکه عصبی احتمالی از طریق طیف پوش، مجموعه‌های متفاوتی از ویژگی‌های ورودی استفاده شده است، بین ۲۰ تا ۱۱۰ ویژگی ورودی که از مقادیر پیک در فرکانس شفت و هارمونیک‌های مرتبه بالای آن در طیف سیگنال‌های پوش به دست آمده است.

جدول (۳) نشان می‌دهد که حداکثر نرخ طبقه بندی صحیح به دست آمده با ۳۰ ویژگی ورودی ۹۵٪ است. در حالی که کمترین نرخ طبقه بندی ۸۳٪ از ۱۰۰ ویژگی‌های ورودی اول است. قابل توجه است که با افزایش تعداد ویژگی‌های ورودی به بیش از ۳۰، نرخ طبقه بندی صحیح تمایل به کاهش دارد.

۵-۲-۳- کارایی شبکه عصبی احتمالی و انتخاب ویژگی‌های حوزه زمان با الگوریتم ژنتیک

دلیل استفاده از الگوریتم ژنتیک به عنوان روش بهینه‌سازی، معمول بودن این الگوریتم و سادگی کار با آن و همچنین کم توجهی در استفاده از این الگوریتم در پایش وضعیت کمپرسورهای رفت و برگشتی می‌باشد. تابع هدف رابطه شماره (۲۴) می‌باشد. در حوزه زمان متغیر بهینه‌سازی ویژگی‌های آماری و در پوش فرکانسی اندازه هارمونیک‌ها به عنوان متغیر استفاده می‌شوند. همچنین قید مسئله تعداد ویژگی‌های آماری در حوزه زمان و هارمونیک‌های فرکانسی در حوزه فرکانس و نبودن ویژگی تکراری در کروموزوم می‌باشند.

جدول ۲- عملکرد شبکه عصبی احتمالی در طبقه‌بندی عیوب، با ویژگی‌های مختلف حوزه زمان

تعداد ویژگی ورودی	نام ویژگی‌ها	درصد طبقه‌بندی صحیح	مقدار سیگما
۶	Var ,H.SK.KT ,LB , X _{RMS}	۴۰	۰/۰۴
۱۰	CF ,Var ,H.SK.KT , LB, UP ,R ,X _{PK} ,X _{RMS}	۴۴	۰/۰۴


جدول ۳- عملکرد شبکه‌عصبی احتمالی در طبقه‌بندی عیوب، با ویژگی‌های مختلف طیف پوش فرکانسی با مقدار سیگما برابر یک

تعداد ویژگی‌های ورودی	درصد طبقه‌بندی صحیح
۲۰	۸۷
۳۰	۹۵
۵۰	۹۳
۷۰	۹۲
۹۰	۹۳
۱۰۰	۸۳


قابل توجه است که برای بدست آوردن مقادیر بهینه سیگما نیز برای طبقه بندی و انتخاب ویژگی، از الگوریتم ژنتیک استفاده می‌شود. هدف پشت برنامه الگوریتم ژنتیک سنجش کاربرد هر سیستم در انتخاب ویژگی با الگوریتم ژنتیک و مقایسه نتایج فعلی با یافته‌های قبلی بود. برای این مورد ترکیبی از ۵، ۶، ۷ و ۱۰ ویژگی با انتخاب الگوریتم ژنتیک به منظور دستیابی به بهترین نرخ طبقه بندی صحیح ممکن، انجام گرفت. از نتایج این نکته قابل توجه است که با استفاده از ده ویژگی تنها پیشرفت‌های جزئی در نرخ طبقه بندی صحیح مشاهده شد، که از مقدار پایین ۴۵ درصد به بالاترین مقدار ۴۸ درصد رسید. ستون ویژگی‌های انتخاب شده در جدول کروموزوم بهتر انتخاب شده توسط الگوریتم ژنتیک در پایان توقف الگوریتم ژنتیک می‌باشد. با وجود جهش که از تابع جهش غیر یکنواخت در این تحقیق استفاده شده است. تقاطع هم با روش مسابقه‌ای که روشی ساده و پرکاربرد می‌باشد استفاده شده است.

جدول ۴ - کارایی شبکه عصبی احتمالی و الگوریتم ژنتیک با ویژگی‌های حوزه زمان (نرخ جهش ۰/۰۱، ۳۰ نسل، ۲۴ جمعیت، ۱۰ تقاطع)

مقدار سیگما	حداقل برازندگی	درصد طبقه‌بندی صحیح	نام ویژگی‌های انتخاب شده
۰/۴۵	۰/۵۲۷۸	۴۷	H,SK,KT,LB, UP, R, X _{PK}
۰/۴۶	۰/۵۲۶	۴۷	H, KT, SK,Var, LB, X _{PK}
۰/۶۷	۰/۵۱۸۲	۴۸	CF, Var, H,SK,KT, LB, UP, R, X _{PK} , X _{RMS}
۰/۵۵	۰/۵۳۵۶	۴۶	H,KT, SK, LB, UP, KT
۰/۳۴	۰/۵۴۵۱	۴۵	H, KT, Var, KT, X _{PK}



شکل ۹ - تابع برازندگی حداقل و میانگین در انتخاب ویژگی با الگوریتم ژنتیک در حوزه زمان (اجرا دوم)



شکل ۱۰ - تابع برازندگی حداقل و میانگین در انتخاب ویژگی با الگوریتم ژنتیک در حوزه زمان (اجرا چهارم)

از آنجایی که تعداد ویژگی‌ها از پارامترهای بهینگی است در هر نسل با وقوع تقاطع با روش مسابقه‌ای و جهش این پارامتر در شکل‌ها تغییر می‌کند. بهینه‌افزایش اجرا با در نظر گرفتن برازندگی می‌توان بهینه کرد اما با توجه به رد شدن اجرا افزایش تعداد اجرا تاثیری در رسیدن به مقدار برازندگی مورد نظر نداشت و اجرای مجدد الگوریتم در رسیدن به حل بهینه مورد نظر بی‌تاثیر بود.

میانگین مقدار برازندگی و حداقل مقدار برازندگی برای اجرا دو (تعداد ویژگی=شش، نرخ طبقه بندی صحیح=۴۷٪) و اجرای چهار (تعداد ویژگی=شش، نرخ طبقه بندی صحیح=۴۶٪) در شکل (۹) و شکل (۱۰) به ترتیب نشان داده شده است. باید توجه داشت که در مجموع ۱۰ ویژگی برای هر اجرا استفاده شده است، اما الگوریتم ژنتیک ویژگی‌های انتخاب شده را برای ارائه بهترین نرخ‌های طبقه بندی انتخاب کرد. اجرای دو، یک میانگین مقدار برازندگی پایدار، با حداقل‌های محلی موجود در حداقل مقادیر برازندگی را نشان می‌دهد. در مقایسه با این مرحله، اجرای ۴ یک مقدار متوسط برازندگی پایدار را در حالی نشان می‌دهد که حداقل مقدار برازندگی در ابتدا تمایل به پایداری دارد، اما سپس تمایل دارد که نوسانات را به صورت حداقل و حداکثر فوری نشان دهد. مشاهده شد که الگوریتم ژنتیک احتمالاً به دلیل کوچک بودن تعداد متغیرهای ورودی قادر به انتخاب تعداد ویژگی‌ها نیست. اگرچه، ویژگی‌های خاصی مانند کشیدگی و آنتروپی را در هر اجرا، با متغیرهای ورودی مختلف، انتخاب کرد.

۵-۲-۴- کارایی شبکه عصبی احتمالی با انتخاب ویژگی با الگوریتم ژنتیک از طیف پوش

جدول (۵) زیر نتایج طبقه بندی به دست آمده با استفاده از شبکه عصبی احتمالی با انتخاب ویژگی با استفاده از الگوریتم ژنتیک را نشان می‌دهد؛ که با نرخ جهش بالا (۰/۷) (نرخ جهش پایین ۰/۰۱ هم بررسی شد) و

ترکیب بالا (۱۰) صورت گرفته است. به این منظور هارمونیک‌ها از پیک‌های طیف فرکانسی از هارمونیک‌های فرکانس کاری کمپرسور انتخاب شدند. نتایج در جدول (۵)، نوسان در دستیابی به نرخ‌های طبقه بندی صحیح با بالاترین نرخ طبقه بندی صحیح ۹۹٪ (۱۱۰ ویژگی) و کمترین میزان طبقه بندی صحیح ۹۳٪ (۱۰ ویژگی) قابل مشاهده است. سیگما برای اجراهای فعلی از طریق بهینه‌سازی با الگوریتم ژنتیک به دست آمد. یکی دیگر از مشاهدات، دستیابی به نرخ‌های طبقه بندی صحیح بالا، برای ۳۰ ویژگی و بالاتر از آن است. تا ۱۱۰ ویژگی، افزایش تعداد ویژگی‌ها موجب بهتر شدن درصد طبقه‌بندی ولی پس از آن موجب کاهش می‌شود. کروموزوم بهتر با ۱۱۰ ویژگی ورودی در نرخ جهش بالا، هارمونیک‌هایی است که در جدول (۶) توسط الگوریتم ژنتیک انتخاب شده‌اند.

شکل (۱۱) نوسان مقادیر متوسط برازندگی با حداقل برازندگی نسبتاً پایدار با مقادیر حداکثر محلی به سمت انتها (۵۰ ورودی) را نشان می‌دهد. در مقابل، شکل (۱۲) (۹۰ ورودی) میانگین مقدار برازندگی دائماً در نوسان در حالی که حداقل مقادیر برازندگی کاملاً پایدار است، را نشان می‌دهد. این موضوع نشان می‌دهد که با افزایش تعداد ویژگی‌های ورودی، به مقادیر حداقل برازندگی تمایل به تثبیت دارند در حالی که مقادیر متوسط برازندگی تمایل به نوسان زیادی دارند. علاوه بر این، لازم به ذکر است که کاهش قابل توجهی از تعداد ویژگی‌ها توسط بهینه‌سازی الگوریتم ژنتیک حاصل می‌شود. در هر اجرا ورودی‌ها متفاوت انتخاب شدند که این کار اجازه می‌دهد تا اجرای آنلاین شبکه عصبی احتمالی کارآمدتر باشد.

جدول (۷) زیر نتایج طبقه بندی به دست آمده با استفاده از شبکه عصبی احتمالی با انتخاب ویژگی با استفاده از الگوریتم ژنتیک با نرخ جهش کم (۰/۰۰۱) و ترکیب کم (۲) را نشان می‌دهد. نتایج در جدول (۷)، نوسان در دستیابی به نرخ‌های طبقه بندی صحیح را با بالاترین نرخ طبقه بندی ۹۹٪ (۹۰ ورودی) و کمترین میزان طبقه بندی صحیح ۹۲٪ (۱۰ ورودی) نشان می‌دهد. در مقایسه با قبل، نرخ طبقه بندی صحیح بالا پس از ۲۰ ویژگی و یک استثنا در ۵۰ ورودی به دست آمد. هارمونیک‌های انتخاب شده در پیوست آورده شده است.

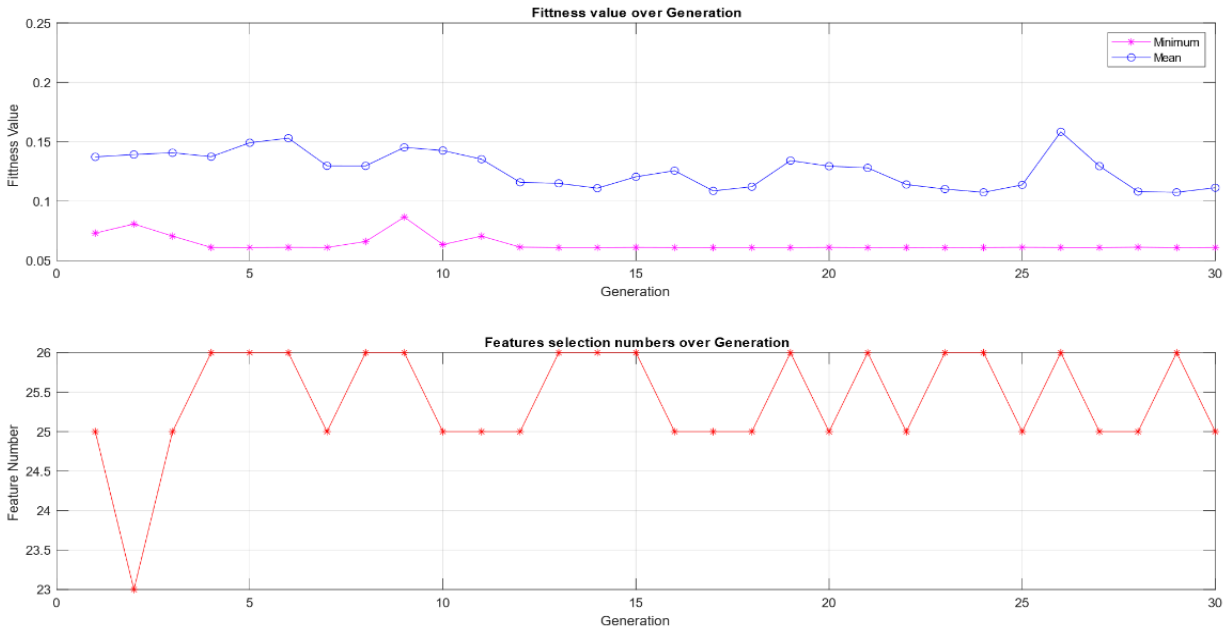
در جدول (۸) کروموزوم بهینه با تعداد ۹۰ ویژگی ورودی، هارمونیک‌های منتخب الگوریتم ژنتیک آورده شده است.

جدول ۵ - کارایی شبکه عصبی احتمالی و الگوریتم ژنتیک با ویژگی‌های طیف پوش (نرخ جهش ۰/۷، ۳۰ نسل، ۱۰ تقاطع)

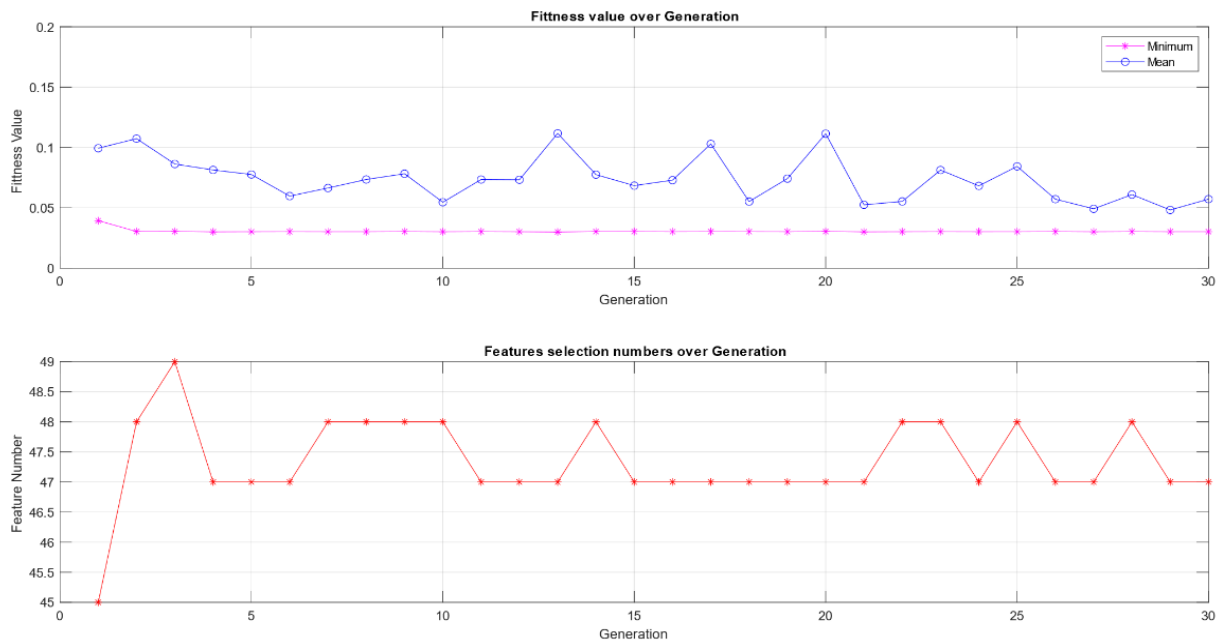
تعداد ویژگی ورودی	برازندگی	سیگما	درصد طبقه‌بندی صحیح
۱۰	۰/۰۷۲۹	۱/۱۲	۹۳
۲۰	۰/۰۶۲۵	۰/۶۹	۹۴
۳۰	۰/۰۳۱۳	۱/۲۶	۹۷
۴۰	۰/۰۴۱۷	۲/۱	۹۶
۵۰	۰/۰۶۲۵	۲/۱۴	۹۴
۷۰	۰/۰۲۰۸	۰/۹۲	۹۸
۹۰	۰/۰۳۱۳	۲/۸۳	۹۷
۱۱۰	۰/۰۱۰۴	۳/۹۱	۹۹
۱۲۰	۰/۲۰۸	۴/۳۹	۹۸

جدول ۶- هارمونیک‌های انتخاب شده با ۱۱۰ ویژگی ورودی (نرخ جهش ۰/۷، ۳۰ نسل، ۱۰ تقاطع)

تعداد ویژگی ورودی	هارمونیک‌های انتخاب شده
۱۱۰	۲،۶،۸،۹،۱۰،۱۴،۱۵،۱۶،۱۷،۱۹،۲۰،۲۴،۲۵،۳۳،۳۵،۳۷،۳۸،۳۹
	۴۰،۴۲،۴۶،۴۸،۵۰،۵۱،۵۲،۵۵،۵۸،۶۱،۶۵،۶۶،۶۸،۶۹،۷۰،۷۵
	۷۶،۷۸،۷۹،۸۰،۸۱،۸۲،۸۳،۸۵،۸۶،۸۷،۸۸،۸۹،۹۰،۹۲،۹۳،۹۴،۹۵،۹۸،۹۹،۱۰۲،۱۰۳،۱۰۶،۱۰۸



شکل ۱۱ - تابع برازندگی حداقل و میانگین در انتخاب ویژگی با الگوریتم ژنتیک از طیف پوش (ورودی ۵۰ هارمونیک)



شکل ۱۲ - تابع برازندگی حداقل و میانگین در انتخاب ویژگی با الگوریتم ژنتیک از طیف پوش (ورودی ۹۰ هارمونیک)



مقایسه مقادیر برازندگی در برابر نسل در شکل (۱۳) و شکل (۱۴)، همگرایی بین مقادیر حداقل و میانگین برازندگی را نشان می‌دهد. شکل (۱۳) یک همگرایی تدریجی بین مقادیر حداقل و میانگین برازندگی در طول نسل (۴۰ ویژگی) را نشان می‌دهد. بر خلاف این، شکل (۱۴) که در آن همگرایی دیر اتفاق می‌افتد و مقادیر میانگین برازندگی تمایل به نوسان زیادی قبل از همگرایی دارند (۷۰ ورودی).

جدول ۷- کارایی شبکه عصبی احتمالی و الگوریتم ژنتیک با ویژگی‌های طیف پوش (نرخ جهش ۰/۰۰۱، ۳۰ نسل، ۲ تقاطع)


تعداد ویژگی ورودی	برازندگی	سیگما	درصد طبقه‌بندی صحیح
۱۰	۰/۰۸۳۳	۰/۷۹	۹۲
۲۰	۰/۰۶۲۵	۰/۶۲	۹۷
۳۰	۰/۰۳۱۳	۰/۸۹	۹۶
۴۰	۰/۰۲۰۸	۱/۳۷	۹۸
۵۰	۰/۰۷۲۹	۱/۰۲	۹۳
۷۰	۰/۰۲۰۸	۲/۹	۹۸
۹۰	۰/۰۱۰۴	۲/۶۴	۹۹
۱۱۰	۰/۰۲۰۸	۲/۶۱	۹۸
۱۲۰	۰/۰۲۰۸	۳/۸۳	۹۸

جدول ۸- هارمونیک‌های انتخاب شده با ۱۱۰ ویژگی ورودی (نرخ جهش ۰/۰۰۱، ۳۰ نسل، ۲ تقاطع)

تعداد ویژگی‌های ورودی	هارمونیک‌های انتخاب شده
۹۰	۱،۳،۵،۷،۱۰،۱۱،۱۴،۱۵،۱۷،۱۸،۱۹،۲۰،۲۳،۲۴،۲۶،۲۷،۲۸،۳۴،۳۵،۳۶،۳۷،۳۹،۴۰ ۴۲،۴۴،۴۵،۴۸،۵۲،۵۳،۵۵،۵۶،۵۹،۶۰،۶۳،۶۶،۶۷،۶۹،۷۲،۷۸،۷۹،۸۰،۸۱،۸۲،۸۳،۸۴،۹۰



شکل ۱۳- تابع برازندگی حداقل و میانگین در انتخاب ویژگی با الگوریتم ژنتیک از طیف پوش (ورودی ۴۰ هارمونیک)



شکل ۱۴- تابع برازندگی حداقل و میانگین در انتخاب ویژگی با الگوریتم ژنتیک از طیف پوش (ورودی ۷۰ هارمونیک)

۶- نتیجه‌گیری

یک مدل ریاضی از کمپرسور دو مرحله‌ای شبیه‌سازی شد که مناسب استفاده برای پایش با انواع روش‌ها می‌باشد. توجه این پژوهش به دستیابی به هفت کلاس کمپرسور معیوب و در مجموع هشت کلاس برای طبقه‌بندی که نتایج آن به شبکه عصبی برای آموزش داده شد که برای افزایش دقت و بازبینی کارایی نیازمند تست با مدل تجربی می‌باشد. پیش از این طبقه‌بند با هشت کلاس برای پایش کمپرسورهای رفت و برگشتی توسعه نیافته بود. ویژگی‌های مورد استفاده در این مطالعه به گونه‌ای انتخاب شده‌اند که برای ایجاد تفکیک قابل توجه بین عیوب کارآمد باشند. ویژگی‌هایی که انتخاب نشدند کارایی لازم برای ایجاد تفکیک مناسب بین عیوب را نداشتند. به عنوان مثال، مقدار پیک انتخاب نشد، زیرا به خوبی نشان‌دهنده تغییر زیاد بین داده‌های مختلف نبود. با این حال، زمانی که RMS انتخاب می‌شود، به خوبی تغییر بین داده‌ها را نشان می‌دهد. نتایج الگوریتم ژنتیک با توجه به پارامترهای متنوع، متفاوت است. به عنوان مثال، زمانی که ترکیب و جهش کوچک هستند، نتایج الگوریتم ژنتیک به حداقل محلی ختم می‌شود، اما زمانی که ترکیب و جهش بزرگتر باشد، نتایج الگوریتم ژنتیک متفاوت است. این نشان می‌دهد که الگوریتم ژنتیک باید چند بار اجرا شود تا یک رفتار همگرایانه برای سیستم مورد مطالعه به دست دهد. با مقایسه ضریب کرس، کشیدگی و چولگی این نتیجه حاصل شد که با این مقادیر نمی‌توان تشخیص عیب مناسبی، با شبکه عصبی احتمالی، در حوزه زمان، در فشارهای خروجی متفاوت داشت. روش تحلیل طیف پوش نسبت به تحلیل حوزه زمان روش قابل اعتمادتری برای تشخیص عیب است و حساسیت بیشتری به عیوب دارد و همراهی شبکه عصبی احتمالی با ویژگی‌های طیف پوش فرکانسی روش مناسبی برای تشخیص عیوب کمپرسور رفت و برگشتی است. شبکه عصبی احتمالی نرخ طبقه‌بندی ۴۴ درصدی در با ویژگی‌های حوزه زمان و در بهینه‌سازی با الگوریتم ژنتیک به مقدار ۴۸ درصدی می‌رسیم که این مقادیر در انتخاب ویژگی با الگوریتم ژنتیک از طیف پوش تا ۹۹ درصد بالا می‌روند. بهترین تعداد ویژگی در تحلیل با طیف پوش بدون الگوریتم ژنتیک ۳۰ ویژگی است که به طبقه‌بندی صحیح ۹۵ درصدی می‌انجامد.

مراجع

- [1] K. Pichler, E. Lughofer, M. Pichler, T. Buchegger, E. P. Klement, and M. Huschenbett, "Detecting Cracks in Reciprocating Compressor Valves using Pattern Recognition in the pV Diagram," *Pattern Analysis and Applications*, Vol. 18, pp. 461-472, 2015, doi: <http://dx.doi.org/10.1007/s10044-014-0431-5>.
- [2] F. Wang, L. Song, L. Zhang, and H. Li, "Fault Diagnosis for Reciprocating Air Compressor Valve using pV Indicator Diagram and SVM," in *2010 Third International Symposium on Information Science and Engineering*, 2010: IEEE, pp. 255-258, doi: <https://doi.org/10.1109/ISISE.2010.91>.
- [3] M. Elhaj, F. Gu, A. Ball, A. Albarbar, M. Al-Qattan, and A. Naid, "Numerical Simulation and Experimental Study of a Two-stage Reciprocating Compressor for Condition Monitoring," *Mechanical Systems and Signal Processing*, Vol. 22, No. 2, pp. 374-389, 2008, doi: <http://dx.doi.org/10.1016/j.ymsp.2007.08.003>.
- [4] J. Liebetrau and S. Grollmisch, "Predictive Maintenance with Airborne Sound Analysis," *Process. Mag*, Vol. 1, p. 15587140, 2017.
- [5] S. M. Ali, K. Hui, L. Hee, and M. S. Leong, "Automated Valve Fault Detection Based on Acoustic Emission Parameters and Support Vector Machine," *Alexandria Engineering Journal*, Vol. 57, No. 1, pp. 491-498, 2018, doi: <https://doi.org/10.1016/j.aej.2016.12.010>.
- [6] S. M. Ali, K. Hui, L. Hee, M. S. Leong, A. M. Abdelrhman, and M. A. Al-Obaidi, "Observations of Changes in Acoustic Emission Parameters for Varying Corrosion Defect in Reciprocating Compressor Valves," *Ain Shams Engineering Journal*, Vol. 10, No. 2, pp. 253-265, 2019, doi: <https://doi.org/10.1016/j.asej.2019.01.003>.
- [7] Y. Wang, C. Xue, X. Jia, and X. Peng, "Fault Diagnosis of Reciprocating Compressor Valve with the Method Integrating Acoustic Emission Signal and Simulated Valve Motion," *Mechanical Systems and Signal Processing*, Vol. 56, pp. 197-212, 2015, doi: <https://doi.org/10.1016/j.ymsp.2014.11.002>.
- [8] M. Yadav and S. Wadhvani, "Vibration Analysis of Bearing for Fault Detection using Time Domain Features and Neural Network," *International Journal of Applied Research in Mechanical Engineering*, Vol. 1, no. 1, pp. 69-74, 2011, doi: <http://dx.doi.org/10.47893/IJARME.2011.1013>.
- [9] P. Raharjo, "An Investigation of Surface Vibration, Airbourne Sound and Acoustic Emission Characteristics of a Journal Bearing for Early Fault Detection and Diagnosis," University of Huddersfield, 2013.
- [10] G. Feng, A. Mustafa, J. X. Gu, D. Zhen, F. Gu, and A. D. Ball, "The Real-time Implementation of Envelope Analysis for Bearing Fault Diagnosis Based on Wireless Sensor Network," in *2013 19th International Conference on Automation and Computing*, 2013: IEEE, pp. 1-6, doi: <http://dx.doi.org/10.1007/s11633-014-0862-x>.

- [11] M. Ahmed, F. Gu, and A. Ball, "Feature Selection and Fault Classification of Reciprocating Compressors Using a Genetic Algorithm and a Probabilistic Neural Network," In *Journal of Physics: Conference Series*, 2011, Vol. 305, No. 1: IOP Publishing, p. 012112, doi: 10.1088/1742-6596/305/1/012112.
- [12] B. Samanta, K. R. Al-Balushi, and S. A. Al-Araimi, "Artificial Neural Networks and Genetic Algorithm for Bearing Fault Detection," *Soft Computing*, Vol. 10, pp. 264-271, 2006, doi: <http://dx.doi.org/10.1007/s00500-005-0481-0>.
- [13] B. Samanta, K. R. Al-Balushi, and S. A. Al-Araimi, "Bearing Fault Detection Using Artificial Neural Networks and Genetic Algorithm," *EURASIP Journal on Advances in Signal Processing*, Vol. 2004, pp. 1-12, 2004, doi: <https://doi.org/10.1155/S1110865704310085>.
- [14] H.-b. Yang, J.-a. Zhang, L.-l. Chen, H.-l. Zhang, and S.-l. Liu, "Fault Diagnosis of Reciprocating Compressor Based on Convolutional Neural Networks with Multisource Raw Vibration Signals," *Mathematical Problems in Engineering*, Vol. 2019, 2019, doi: <https://doi.org/10.1155/2019/6921975>.
- [15] Y. Zhang, G. Yang, D. Zhang, and T. Wang, "Investigation on Recognition Method of Acoustic Emission Signal of the Compressor Valve Based on the Deep Learning Method," *Energy Reports*, Vol. 7, pp. 62-71, 2021, doi: <https://doi.org/10.1016/j.egy.2021.10.053>.
- [16] M. A. A.-O. Salah *et al.*, "Automated Valve Fault Detection Based on Acoustic Emission Parameters and Artificial Neural Network," In *MATEC Web of Conferences*, 2019, Vol. 255: EDP Sciences, p. 02013, doi: <https://doi.org/10.1051/mateconf/201925502013>.
- [17] Y. Zhang, J. Ji, and B. Ma, "Reciprocating Compressor Fault Diagnosis Using an Optimized Convolutional Deep Belief Network," *Journal of Vibration and Control*, Vol. 26, No. 17-18, pp. 1538-1548, 2020, doi: <https://doi.org/10.1177/1077546319900115>.
- [18] T.-S. Kwon, D.-H. Lee, and S.-K. Sul, "Reduction of Engine Torque Ripple at Starting with Belt Driven Integrated Starter Generator," In *Twentieth Annual IEEE Applied Power Electronics Conference and Exposition, 2005. APEC 2005.*, 2005, Vol. 2: IEEE, pp. 1035-1040, doi: <http://dx.doi.org/10.1109/APEC.2005.1453119>.
- [19] J. A. Gutiérrez-Gnecchi *et al.*, "DSP-based Arrhythmia Classification Using Wavelet Transform and Probabilistic Neural Network," *Biomedical Signal Processing and Control*, Vol. 32, pp. 44-56, 2017, doi: <http://dx.doi.org/10.1016%2Fj.bspc.2016.10.005>.

فهرست نمادهای انگلیسی

تغییرات فشار درون سیلندر اول و دوم	$\dot{P}_{CL,H}$
فشار در خروجی سیلندر	$P_{dL,H}$
حجم سیلندر اول و دوم	$V_{CL,H}$
مربع سرعت صوت در ورودی هر یک از دو سیلندر	$c^2_{iL,H}$
مربع سرعت صوت در خروجی هر یک از دو سیلندر	$c^2_{dL,H}$
نرخ تغییرات حجم سیلندر	$\dot{V}_{CL,H}$
نرخ جریان جرم ورودی هر یک از دو سیلندر	$\dot{m}_{viL,H}$
نرخ جریان جرم خروجی هر یک از دو سیلندر	$\dot{m}_{vL,H}$
نرخ نشتی جریان جرم سوپاپ	$\dot{m}_{ldL,H}$
ضریب متغیر جریان خروجی	$C_{adL,H}$
سطح نشتی	$A_{fdL,H}$
ممان اینرسی موتور	J_m
نمان اینرسی کمپرسور	J_c

فهرست نمادهای یونانی

ضریب حرارتی ویژه	γ
چگالی گاز درون هر یک از سیلندر	$\rho_{CL,H}$
سرعت زاویه‌ای موتور	ω_m

Condition Monitoring of Reciprocating Compressors using Probabilistic Neural Network and Optimization with Genetic Algorithm

Sina Salehi

M.Sc., Department of Mechanical Engineering, Tarbiat Modares University, Tehran, Iran
sina_salehi@modares.ac.ir

*Corresponding author: **Majid Sadedel**

Assistant Professor, Department of Mechanical Engineering, Tarbiat Modares University, Tehran, Iran
majid.sadedel@modares.ac.ir

Abstract

Demand for cost-effective, reliable operation and safety of machinery, especially reciprocating compressors, which are among the most expensive machines in maintenance, requires accurate troubleshooting and fault classification. Due to their advantages, data-driven methods are often preferred to physical modeling methods for fault detection. This research simulates the mathematical model of a two-stage reciprocating compressor and conventional faults for use as a monitored system. The artificial neural network used is the probabilistic neural network whose main task is classification. Classification classes include one healthy compressor class and seven defective compressor classes for eight classes. Classification with the probabilistic neural network was performed using time domain and envelope spectrum characteristics. Then, the selected features are optimized using a genetic algorithm before feeding into the probabilistic neural network. Classification with the probabilistic neural network using time-domain characteristics shows a poor classification percentage with 44% Correct accuracy. But classification with a probabilistic neural network and envelope spectrum features has a 95% correct classification accuracy. Also, optimizing the selection of statistical features of the time-domain and frequency envelope spectrum with a genetic algorithm brings 48 and 99% correct accuracy in classification, respectively.

Keywords: Reciprocating compressors, Condition monitoring, Probabilistic neural networks, Genetic algorithm