

تشخیص خطای شکستگی بلبرینگ موتور القایی در داخل و بیرون حلقه بلبرینگ با روش شبکه عصبی

حسین صالحی فرگنی^۱، حمیدرضا فخاری زاده^۲

^۱دانشگاه آزاد اسلامی واحد بافق، Final@bafgh-iau.ac.ir

چکیده

در این مقاله روشی جدید با استفاده از شبکه عصبی مصنوعی برای آشکارسازی و دسته‌بندی عیوب بلبرینگ‌های موتور القایی ارائه می‌شود. شبکه عصبی توسط یک دسته داده آزمایشگاهی با مشخص بودن محل عیب آموزش داده می‌شود و یک دسته داده نیز برای آزمون شبکه به کار برده می‌شود. در این روش خصوصیات حوزه زمان و فرکانس سیگنال ارتعاشات بدنه موتور استخراج و به عنوان ورودی شبکه عصبی استفاده می‌شوند. این ویژگی‌ها از پردازش مستقیم بخش‌های مختلف سیگنال اندازه‌گیری شده بدست می‌آید. سه حالت سالم، عیب رینگ بیرونی و عیب رینگ داخلی با استفاده الگوریتم پیشنهادهی دسته‌بندی می‌شوند و نوع عیب مشخص می‌شود. نتایج نشان می‌دهد که الگوریتم‌های تشخیص الگو با استفاده از خصوصیات حوزه زمان می‌تواند محل عیب را با دقت بالا و بدون نیاز به محاسبات پیچیده مشخص کند. کلید واژه - آشکارسازی عیب، بلبرینگ، موتور القایی، تشخیص الگو.

۱- مقدمه

کرد، می‌توان تا حد زیادی از خسارات (هزینه توقف خط تولید) جلوگیری نمود.

عیب‌های بلبرینگ به دو دسته، یکی عیب‌های توزیع شده نظیر ناهموازی سطح، موجی بودن، ناهمراستا بودن رینگ‌ها، هم‌اندازه نبودن ساچمه‌ها، و دیگری عیب‌های محلی نظیر شکاف‌ها، حفره‌ها و خرده‌ریزه‌های روی سطوح چرخان تقسیم می‌شوند [۵]. عیب‌های ایجاد شده در بلبرینگ‌ها معمولاً از نوع محلی هستند که در حلقه داخلی، خارجی، ساچمه‌ها یا قفسه ایجاد می‌شوند. هنگام عبور ساچمه‌ها از روی نقاط خراب، ضربه‌های متوالی در سیگنال ارتعاشات ایجاد می‌شود که اندازه و پریود تکرار آن با توجه به سرعت چرخش، محل عیب و ابعاد مشخصه بلبرینگ تعیین می‌شود. براین اساس برای عیب‌یابی بلبرینگ‌ها اغلب از سیگنال ارتعاشات استفاده شده است [۲-۵]. ارتعاشات ایجاد شده در اثر خرابی بلبرینگ‌ها بر روی سیگنال جریان استاتور نیز مدوله می‌شود و سیگنال جریان را می‌توان به راحتی به منظور مانیتورینگ وضعیت و اهداف کنترلی اندازه‌گیری نمود. بنابراین در سالهای اخیر اغلب پژوهش‌ها به سمت

موتورهای القایی سه فاز بیشترین کاربرد را در بین ماشین‌های الکتریکی در صنعت دارند و در جوامع صنعتی بین ۴۰ تا ۵۰ درصد برق تولیدی را مصرف می‌کنند. کارایی، قابلیت اعتماد و راندمان از عمده‌ترین نگرانی‌ها در مورد استفاده از موتورهای القایی می‌باشد [۱]. زیرا اغلب تجهیزاتی که با موتور راه‌اندازی می‌شوند نقش محوری در صنعت دارند.

در دو دهه گذشته، تحقیقات وسیعی به منظور ایجاد روش‌های جدید مانیتورینگ وضعیت در موتورهای القایی بر اساس تحلیل نوسانات سیگنال ارتعاشات، جریان و ... انجام شده است [۲-۴]. ابزارهای تجاری متعددی نیز در این زمینه موجود می‌باشد. با وجود این ابزارها، هنوز بسیاری از کارخانه‌ها با عیب‌های غیرمنتظره مواجه می‌شوند که باعث کاهش عمر مفید موتور و ایجاد خسارت‌های زیادی می‌شود. تحقیقات اخیر نشان می‌دهد که بیش از ۴۰ درصد خرابی‌های ماشین‌های الکتریکی مربوط به بلبرینگ‌های آن‌ها می‌باشد. بنابراین چنانچه بتوان روند ایجاد و پیشرفت این نوع عیب را در مراحل اولیه آشکار

تکرار این ضربه‌ها با توجه به سرعت چرخش، محل عیب و ابعاد مشخصه بلبرینگ تعیین می‌شود. این ضربه‌ها با توجه به این که عیب در کدام قسمت بلبرینگ ایجاد شده باشد، توسط روابط (۱)-(۴) بدست می‌آیند [۵].

فرکانس اصلی ارتعاشات قفسه^۵ از رابطه زیر بدست می‌آید:

$$f_c = \frac{f_s}{2} \left(1 - \frac{d}{D} \cos(\alpha) \right) \quad (1)$$

فرکانس عیب ساچمه‌ها دو برابر فرکانس چرخش ساچمه به دور خود می‌باشد و از رابطه زیر بدست می‌آید:


$$f_{bd} = f_s \frac{D}{d} \left(1 - \frac{d^2}{D^2} \cos^2(\alpha) \right) \quad (2)$$

همچنین فرکانس‌های عیب رینگ خارجی و رینگ داخلی به ترتیب از روابط زیر بدست می‌آیند:

$$f_{od} = n f_c = \frac{n f_s}{2d} \left(1 - \frac{d}{D} \cos(\alpha) \right) \quad (3)$$

$$f_{id} = n(f_s - f_c) = \frac{n f_s}{2} \left(1 - \frac{d}{D} \cos(\alpha) \right) \quad (4)$$

در این روابط f_s ، فرکانس چرخش، n تعداد ساچمه‌ها، D قطر گام و d قطر ساچمه‌ها می‌باشد، که بر اساس ابعاد مشخصه بلبرینگ نشان داده شده در شکل ۱ تعیین می‌شوند.



شکل ۱: ابعاد مشخصه یک بلبرینگ ساچمه‌ای

بنابراین با معیوب شدن هر قسمت بلبرینگ انتظار داریم یک مؤلفه در طیف سیگنال‌های ارتعاشات ایجاد شود. از آنجا که تأثیر عیب در مراحل ابتدایی بسیار ناچیز است و دامنه مؤلفه‌های ایجاد شده در اثر عیب نسبت به دامنه نویز و ارتعاشات ناشی از سایر قطعات موتور بسیار کمتر است، با استفاده از روش‌های مرسوم بررسی طیف به راحتی نمی‌توان به وجود عیب پی برد، بنابراین نیاز به روش‌های پیشرفته‌تر پردازش سیگنال

مانیتورینگ الکتریکی موتور با تأکید بر جریان استاتور سوق داده شده است [۶-۸].

از نظر تئوری با استفاده از FFT^۱ می‌توان عیب را با توجه به دامنه مؤلفه‌های مربوط به آن آشکار نمود ولی چون ارتعاشات ضربه‌ای ایجاد شده نسبت به نویز و ارتعاشات ناشی از سایر قطعات^۲ دامنه و انرژی نسبتاً کمتری دارد، اغلب در آنها غرق می‌شود. به منظور غلبه بر مشکلات FFT و بهبود نسبت سیگنال به نویز و انجام آنالیز طیفی مؤثرتر، از برخی تکنیک‌های پیشرفته پردازش سیگنال استفاده شده است.

در سال‌های اخیر از روش‌های پیشرفته‌تر نظیر تبدیل فوریه زمان کوتاه^۳ (STFT) [۹]، تبدیل موجک^۴ (WT) [۱۰] و تبدیل موجک بسته‌ای [۱۱-۱۲] برای عیب‌یابی بلبرینگ‌ها استفاده شده است. این روش‌ها دارای حجم محاسبات زیادی هستند و علاوه بر آن نیاز به یک فرد با تجربه و متخصص برای تشخیص وضعیت سیستم دارند [۱۳]. در واقع یک فرد باتجربه باید تشخیص دهد که هارمونیک‌های سیگنال اندازه‌گیری شده در شرایط عادی وجود دارند یا اینکه در اثر عیب به وجود آمده‌اند. برای رفع این مشکل می‌توان از سیستم‌های هوشمند استفاده کرد. در این مقاله برای حل این مشکلات و هوشمند کردن پروسه تشخیص و جداسازی عیوب روشی بر مبنای تشخیص الگو با استفاده از شبکه‌های عصبی ارائه می‌شود. در این تحقیق با استفاده از داده‌های جمع‌آوری شده آزمایشگاهی [۱۴]، ویژگی‌های مورد نظر با پردازش سیگنال در حوزه زمان و فرکانس برای بلبرینگ در وضعیت‌های سالم، رینگ بیرونی معیوب و رینگ درونی معیوب، بدست می‌آید و به ورودی شبکه عصبی برای آموزش داده می‌شود. پس از آموزش شبکه عصبی به خوبی می‌تواند عیوب را دسته‌بندی کند.

۲- فرکانس‌های مشخصه عیب

خرابی محلی یا ساییدگی باعث ایجاد ضربه‌های پریودیک متوالی در سیگنال ارتعاشات بدنه موتور می‌شود. اندازه و پریود

^۱ - Fast- Fourier- Transfomation

^۲ - Macrostructural Components

^۳ - Short- Time Fourier Transform

^۴ - Wavelet Transform

^۵ - Fundamental Cage Frequency

این الگوریتم آموزش از روش های بهینه یابی مرتبه دوم تابع خطا برای آموزش شبکه های عصبی است [۱۵]. این روش تقریبی از روش بهینه یابی نیوتن است. برای آموزش شبکه عصبی لازم است تابع خطا بر اساس پارامترهای شبکه (وزن ها و بایاس ها) کمینه شود. بر اساس روش نیوتن تغییرات پارامترها در هنگام آموزش برابر است با:

$$\Delta \underline{x} = -[\nabla_{\underline{x}}^2 E(\underline{x})]^{-1} [\nabla_{\underline{x}} E(\underline{x})] \quad (5)$$

که در آن $\nabla_{\underline{x}}^2 E(\underline{x})$ ماتریس هسین و $\nabla_{\underline{x}} E(\underline{x})$ گرادیان تابع خطا نسبت به بردار پارامترهای شبکه، $\underline{x}$ می باشد. با تعریف خطا برابر مجموع مربعات خطا خواهیم داشت:

$$E(\underline{x}) = \frac{1}{2} \sum_{i=1}^V e_i^2(\underline{x}) = \frac{1}{2} \sum_{j=1}^P \sum_{q=1}^{S_L} \{e_q^z(\underline{x})\}_j \quad e_q = y_q^d - y_q^L, q = 1, \dots, S_L \quad (6)$$

که در آن $P, V = P.S_L$ تعداد الگوهای آموزشی و S_L تعداد خروجی های شبکه است. بنابراین می توان نوشت:

$$\nabla_{\underline{x}} E(\underline{x}) = J^T(\underline{x}) e(\underline{x}) \quad (7)$$

$$\nabla_{\underline{x}}^2 E(\underline{x}) = J^T(\underline{x}) J(\underline{x}) + R(\underline{x})$$

که در آن $J(\underline{x})$ ماتریس ژاکوبین می باشد و

$$R(\underline{x}) = \sum_{j=1}^V e_j(\underline{x}) \nabla^2 e_j(\underline{x}) \quad (8)$$

به منظور جلوگیری از افزایش حجم محاسبات در روش گوس- نیوتن فرض می شود که $R(\bar{x}) \cong 0$ و بنابراین ماتریس هسین با تقریب بدست می آید:

$$\nabla^2 E(\bar{x}) \cong J^T(\bar{x}) J(\bar{x}) \quad (9)$$

برای جلوگیری از ill-condition شدن ماتریس $J^T J$ وزن ها براساس روش تغییر یافته Levenberg- Marquardt به صورت زیر بدست می آیند:

$$\underline{x}(n+1) = \underline{x}(n) - [J^T \underline{x}(n) J \underline{x}(n) + \mu_n I]^{-1} \nabla \underline{x} E(\underline{x}) \quad (10)$$


که در آن μ_n ضریب یادگیری می باشد. هر چقدر μ_n کوچکتر باشد، الگوریتم آموزش به گوس نیوتن نزدیکتر می شود و هر قدر μ_n بزرگتر انتخاب شود، الگوریتم آموزش به آموزش پس انتشار خطا با تندترین شیب با طول گام خیلی کوچک، نزدیکتر می شود.

در مقایسه بین روش Levenberg- Marquardt و روش پس انتشار خطا، این روش برای هر مرحله آموزش به

احساس می شود. این روش ها حجم محاسبات بسیار بالایی دارند. علاوه بر این نیاز به یک فرد با تجربه و متخصص برای تشخیص وضعیت سیستم بسیار ضروری است. برای رفع این مشکل در این مقاله از سیستم های هوشمند استفاده شده است.

۳- شبکه عصبی پرسپترون چند لایه

شبکه عصبی چندلایه شامل یک لایه ورودی، یک لایه خروجی و یک یا چند لایه مخفی است. هر لایه شامل چندین نرون است که ورودی های آن تنها به لایه قبلی و خروجی آن ها به لایه بعدی متصل می شوند. یک نمونه کلی در شکل ۲ نشان داده شده است. توابع پردازش لایه ورودی همگی خطی هستند ولی در لایه های مخفی از توابع غیر خطی همانند توابع سیگموئیدی، تانژانت هیپربولیک و یا هر تابع غیر خطی پیوسته و مشتق پذیر دیگری می توان استفاده کرد. معمولاً برای افزایش سرعت آموزش، توابع محرک نرون های لایه های خروجی خطی انتخاب می شوند.



شکل ۲: ساختار شبکه عصبی سه لایه

در مدل سازی سیستم ها با استفاده از شبکه های عصبی چند لایه ابتدا ساختار شبکه به شکل فوق تعریف می گردد، پس از تعریف ساختار باید نرون های شبکه طوری تنظیم شوند که با اعمال ورودی های سیستم به آن، خروجی های بسیار نزدیک به خروجی های واقعی سیستم بدهد. به این کار آموزش شبکه عصبی می گویند و منظور از آن تنظیم وزن ها در جهت کم کردن خطای بین خروجی شبکه و خروجی واقعی می باشد. در ادامه روش آموزش Levenberg- Marquardt به طور مختصر بررسی می شود.

۳-۱- الگوریتم آموزش Levenberg- Marquardt

۲۰۲۱ آبان ماه ۱۳۹۴ - دانشگاه آزاد اسلامی واحد اصفهان (خوراگان)

بی باری است و سرعت آن $f_{rm} = 24.96 \text{ } 1498 \text{ rpm Hz}$ اندازه گیری شده است، مشخصه های عیب این بلبرینگ با توجه به روابط (۱) تا (۴) بدست آمده و در جدول ۱ نشان داده شده اند.

جدول ۱: فرکانس های مشخصه عیب در سیگنال ارتعاشات

فرکانس مشخصه عیب	محل عیب
$f_{od} = 89.18 \text{ Hz}$	رینگ بیرونی
$f_{id} = 135.5 \text{ Hz}$	رینگ داخلی
$f_c = 9.9 \text{ Hz}$	قفسه
$f_{bd} = 116 \text{ Hz}$	ساچمه ها

۴-۱- استخراج ویژگی های حوزه زمان

در این بخش داده های در هر سه حالت پس از حذف آفست DC ، به ۲۰ قسمت شامل ۱۰۲۴ نمونه بدون همپوشانی تقسیم شده است. هر کدام از این قسمت ها برای بدست آوردن ویژگی های مورد نیاز که در ادامه معرفی می شوند، پردازش شده اند: مقدار مؤثر (rms) ، واریانس (σ^2) ، کجی^۱ گشتاور مرکزی نرمال شده مرتبه سوم، γ_3 ، کورتوسیس^۲ نرمال شده مرتبه ششم، γ_6 که از روابط زیر بدست می آیند:

$$\bar{y}_i = y_i - \mu; \quad \mu = E\{y_i\}$$

$$rms = \sqrt{\frac{\sum \bar{y}_i^2}{n}}; \quad \sigma^2 = E\{\bar{y}_i^2\} \quad (11)$$

$$\gamma_3 = \frac{E\{\bar{y}_i^3\}}{\sigma^3}; \quad \gamma_4 = \frac{E\{\bar{y}_i^4\}}{\sigma^4}; \quad \gamma_6 = \frac{E\{\bar{y}_i^6\}}{\sigma^6}$$

در این روابط E نشان دهنده مقدار مورد انتظار تابع است. در شکل ۴ ویژگی های استخراج شده از سیگنال ارتعاشات نشان داده شده است. تمام این ویژگی ها در بازه $[0, +1]$ نرمال شده اند، به جز گشتاور مرکزی نرمال شده مرتبه سوم (کجی) که در بازه $[-1, +1]$ نرمال شده است. برای نرمالیزه کردن، هر ویژگی بر اختلاف مقدار ماکزیمم و مینیمم تقسیم شده است.

محاسبات بیشتری نیاز دارد. سرعت همگرایی این روش چنان است که برای رسیدن به یک خطای معین، زمان و مراحل کمتری برای آموزش نیاز دارد.

۴- جمع آوری داده های آزمایشگاهی

در تمام آزمایش ها از یک موتور القایی ۳ فاز با مشخصات نامی $1/2 \text{ kW}$ ، 380 V ، 50 Hz ، 1400 rpm چهار قطب (ساخت شرکت موتوژن) استفاده شده است [۱۵]. هر دو بلبرینگ انتهای شفت و انتهای فن $2Z - 6205$ می باشند. معمولاً از دو روش برای ایجاد عیب بر روی بلبرینگ و بررسی اثر آن استفاده می کنند [۵]. در این تحقیق برای شبیه سازی عیوب مختلف، با استفاده از جرقه سوراخ هایی بر روی رینگ های داخلی و بیرونی بلبرینگ انتهای شفت ایجاد شده است. ابتدا، آزمایش ها را بر روی موتور با بلبرینگ های سالم انجام داده ایم، این بلبرینگ را با A نشان می دهیم. در آزمایش دوم برای شبیه سازی عیب رینگ بیرونی بر روی بلبرینگ انتهای شفت سوراخی به قطر 1 mm ایجاد شده است، این بلبرینگ را با B نشان می دهیم. در شکل ۳ نمای بلبرینگ با رینگ بیرونی معیوب نشان داده شده است. در آزمایش سوم برای شبیه سازی عیب رینگ داخلی بر روی بلبرینگ انتهای شفت سوراخی به قطر 1 mm ایجاد شده است، این بلبرینگ را با C نشان می دهیم.



شکل ۳: نمای بلبرینگ معیوب

چنانچه به مشخصات بلبرینگ $2Z - 6205$ مراجعه کنیم، قطر خارجی آن 25 mm و قطر داخلی آن 25 mm می باشد.

بنابراین، قطر گام بلبرینگ $D = 35.5 \text{ mm}$ بدست می آید. همچنین این بلبرینگ دارای ۹ ساچمه می باشد که قطر آن ها تقریباً $d = 7.938 \text{ mm}$ می باشد. با فرض اینکه زاویه تماس (α) ، صفر درجه باشد و با توجه به اینکه موتور در حالت

¹ -Skewness

² -Kurtosis

این داده‌ها پس از نرمال سازی بین $[-1, +1]$ به عنوان ورودی به شبکه عصبی داده می‌شوند.

۵- طراحی شبکه عصبی MLP برای جداسازی حالت

های سالم، عیب رینگ بیرونی و عیب رینگ داخلی


در این بخش هدف جداسازی بلبرینگ های سالم و معیوب، در دو حالت عیب رینگ بیرونی و عیب رینگ داخلی است.

ویژگی های حوزه زمان و فرکانس معرفی شده در هر سه حالت بدست آمده اند. دو خروجی برای شبکه در نظر گرفته شده است و هر یک از این حالت ها با یک بردار هدف از هم متمایز شده اند. حالت سالم: $[0 \ 0]^T$ ، عیب رینگ بیرونی $[0 \ 1]^T$ ، عیب رینگ داخلی $[1 \ 0]^T$. البته می توان یک خروجی با درایه هایی شامل $+1$ ، 0 و -1 نیز در نظر گرفت. برای بدست آوردن شبکه مناسب بدین ترتیب عمل می نماییم. ابتدا شبکه با یک لایه پنهان در نظر گرفته می شود و با استفاده از الگوریتم *Levenberg- Marquardt* که سریع تر از بقیه الگوریتم ها است آموزش داده می شود،

چنانچه با افزایش سلول ها در یک لایه جواب های مناسبی بدست نیاید تعداد لایه های پنهان را افزایش می دهیم. در ادامه ابتدا با استفاده از خصوصیات حوزه زمان و فرکانس مطرح شده در مرجع [۱۶] به دسته بندی عیوب می پردازیم. سپس از ویژگی های حوزه زمان مطرح شده استفاده می کنیم و نتایج را در هر دو حالت با هم مقایسه می کنیم.

۵-۱- استفاده از خصوصیات حوزه زمان و فرکانس

به منظور طراحی شبکه مناسب، ابتدا یک شبکه سه لایه، با ۵ ورودی، ۲ سلول در لایه میانی و دو سلول در لایه خروجی در نظر گرفته می شود، سپس تعداد سلول ها و لایه های پنهان تغییر داده می شود تا تعداد بهینه سلول ها و لایه های پنهان بدست آید. تعداد نمونه هایی که برای آموزش در این بخش به کار رفته ۴۰ نمونه مربوط به حالت سالم و ۴۰ نمونه مربوط به عیب رینگ بیرونی و ۴۰ نمونه مربوط به عیب رینگ داخلی می باشد. برای سنجش کارایی شبکه طراحی شده نیز از همین تعداد داده استفاده شده است، که هیچ یک از نمونه های آزمون در آموزش به کار نرفته است. در شکل ۵ منحنی تغییرات خطا برای شبکه های مختلف و در شکل ۶ پاسخ شبکه عصبی طراحی شده شماره ۲ به داده های آزمون نشان داده شده است.



شکل ۴: ویژگی های استخراج شده نرمال برای دو حالت؛ ردیف بالا

حالت سالم، ردیف پایین حالت معیوب

۴-۲- استخراج ویژگی های حوزه فرکانس

برای تشخیص نوع عیب معمولاً از مؤلفه های فرکانسی استفاده می شود. بنابراین یک طرح محاسبه انرژی پخش شده در حوالی هارمونیک ها به عنوان ورودی برای شبکه عصبی می باشد. در این طرح طیف سیگنال ارتعاشات محاسبه شده و انرژی اطراف مؤلفه های عیب نیز به عنوان ورودی به شبکه عصبی داده می شود [۱۶]. برای این منظور ۹۶۰۰۰ نمونه از هر سیگنال را انتخاب نموده و طبق روش آشکارسازی پوش^۱ پس از عبور از یک فیلتر میان گذر $2 - 4 \text{ KHZ}$ طیف توان^۲ یا چگالی طیف توان^۳ مربع سیگنال را محاسبه می کنیم. سپس انرژی پخش شده حول فرکانس چرخش و فرکانس های مربوط به عیب، را بدست می آوریم.

بنابراین دامنه طیف برای فرکانس های f_b, f_{id}, f_{od}, f_s

عبارتند از:

$$\begin{aligned} x_{fs} &= A(f_s), x_{fod} = A(f_{od}) \\ x_{fid} &= A(f_{id}), x_{fb} = A(f_b) \end{aligned} \quad (12)$$

ویژگی های حوزه زمان مورد استفاده میانگین و دامنه ماکزیمم و ضریب کورتوسیس سیگنال ارتعاشات می باشد. بنابراین ویژگی هایی که به عنوان ورودی شبکه عصبی استفاده می شوند، عبارتند از:

$$X = [A_max, A_mean, \gamma_f, x_{fs}, x_{fb}, x_{fob}, x_{fid}] \quad (13)$$


¹ -Envelope Detection

² -Power Spectrum


³ - Power Spectral Density

حالت سالم و ۴۰ نمونه مربوط به حالت های معیوب استفاده شده است، که هیچ یک از نمونه های آزمون در آموزش به کار رفته است.


ابتدا ساختار شبکه بدین صورت در نظر گرفته می شود: ۵ سلول در لایه ورودی، دو سلول در لایه میانی و دو سلول در لایه خروجی. سپس تعداد سلول ها و لایه های پنهان تغییر داده می شود تا تعداد بهینه سلول ها و لایه های پنهان بدست آید. در شکل ۷ منحنی تغییرات خطا برای شبکه های مختلف و در شکل ۸ پاسخ شبکه عصبی طراحی شده شماره ۲ به داده های آزمون نشان داده شده است. نتایج در صد صحت تشخیص برای هر حالت در جدول ۳ آمده است. همانگونه که ملاحظه می شود در صد صحت تشخیص حالت های سالم و رینگ داخلی در همه موارد ۱۰۰٪ می باشد ولی با تغییر تعداد سلول های لایه پنهان و همچنین تعداد لایه های پنهان درصد صحت تشخیص حالت عیب رینگ بیرونی تنها در یک حالت ۱۰۰٪ شده است. نکته مهم دیگری که در شبکه شماره ۵ دیده می شود، این است که با افزایش تعداد لایه ها و سلول های پنهان، نه تنها جواب ها بهتر نشده، بلکه بسیار بدتر هم شده است.




شکل ۷: تغییر منحنی آموزش با تغییر تعداد سلول ها و لایه های پنهان



درصد صحت تشخیص هر شبکه در جدول ۲ آمده است.



شکل ۵: تغییر منحنی آموزش با تغییر تعداد سلول ها و لایه های پنهان



شکل ۶: پاسخ شبکه عصبی طراحی شده شماره ۲ به داده های آزمون

جدول ۲: مقایسه شبکه با تعداد سلول ها و لایه های پنهان متفاوت با استفاده

از خصوصیات حوزه زمان و فرکانس

شماره شبکه	ساختار شبکه	سالم	عیب رینگ خارجی	عیب رینگ داخلی	میانگین صحت تشخیص
۱	[۵ ۲ ۲]	۹۷/۵٪	۱۰۰٪	۱۰۰٪	۹۱/۱۶٪
۲	[۵ ۴ ۲]	۹۷/۵٪	۱۰۰٪	۱۰۰٪	۹۱/۱۶٪
۳	[۵ ۷ ۲]	۹۷/۵٪	۱۰۰٪	۱۰۰٪	۹۱/۱۶٪
۴	[۵ ۵ ۳ ۲]	۹۷/۵٪	۱۰۰٪	۱۰۰٪	۹۱/۱۶٪
۵	[۵ ۱۰ ۵ ۲]	۹۷/۵٪	۱۰۰٪	۱۰۰٪	۹۱/۱۶٪

۵-۲- استفاده از خصوصیات حوزه زمان

تعداد نمونه هایی که برای آموزش در این بخش به کار رفته ۲۰ نمونه مربوط به حالت سالم و ۲۰ نمونه مربوط به عیب رینگ بیرونی و ۲۰ نمونه مربوط به عیب رینگ داخلی می باشد. برای سنجش کارایی شبکه طراحی شده از ۲۰ نمونه مربوط به

element bearings,” Journal of Tribology International, vol. 32(8), pp. 469-480, August 1999.

[6] R. R. Schoen, T. G. Habetler, F. Kamran, R. G. Bartheld, “Motor Bearing damage detection using stator current monitoring,” IEEE Trans. Industry Applications, vol. 32, no. 6, pp. 1274-1279, Nov./Dec. 1995.

[7] M. E. H. Benbouzid, “A review of induction motors signature analysis as a medium for faults detection,” IEEE Trans. Industrial Electronics, vol. 47, no. 5, pp. 984-993, Oct. 2000.

[8] M. E. H. Benbouzid, “What stator current processing-based technique to use for induction motor rotor faults diagnosis?” IEEE Trans. Energy Conversion, vol. 18, no. 2, pp. 238-244, Jun. 2003.

[9] B. Yazici, G. B. Kliman, “An adaptive statistical timefrequency method for detection of broken bars and bearing faults in motors,” IEEE Trans. On Industry App., vol. 35, no. 2, March/April 1999.

[10] S. Prabhakar, A. R. Mohanty, A. S Sekhar, “Application of discrete wavelet transform for detection of ball bearing race faults,” Journal of Tribology International, vol. 35(12), pp. 793-800 December 2002.

[11] J. Zarei, J. Poshtan, “Bearing fault detection using wavelet packet transform of induction motor stator current,” Journal of Tribology International, Vol. 40(5), pp. 763-769, May 2007.

[12] N.G. Nikolaou, I.A. Antoniadis, “Rolling element bearing fault diagnosis using wavelet packets,” Journal of NDT&E, vol. 35, Issue 3, pp. 197-205, April 2002.

[13] M. Haji, H. A. Toliyat, “Pattern recognition-a technique for induction machines rotor broken bar detection,” IEEE Trans. Energy Conversion, vol. 16, no. 4, pp. 312-317, Dec. 2001.

[14] J. Zarei, Induction Motor Bearings Fault Detection using Stator Current Analysis Compared to Vibration Analysis, Msc Thesis, Iran University of Science and Technology, IRAN, March 2005, (in Persian language).

[15] Hagan, M.T.; Menhaj, M.B, “Training feedforward networks with the Marquardt algorithm,” IEEE Trans. On Neural Networks, Vol. 5, no. 6, pp. 989 – 993, November 1994.

[16] B. Li, M. Chow, Y. Tipsuwan, J. C. Hung, “Neural networkbased motor rolling bearing fault diagnosis,” IEEE Trans. Industrial Electronics, vol. 47, No. 5, pp. 1060- 1068, October 2000.

شکل ۸: پاسخ شبکه عصبی طراحی شده شماره ۲ به داده های آزمون
جدول ۳: مقایسه شبکه با تعداد سلول ها و لایه های پنهان متفاوت با استفاده

از خصوصیات حوزه زمان

شماره شبکه	ساختار شبکه	عیب رینگ داخلی	عیب رنگی خارجی	سالم	میانگین صحت تشخیص
۱	[۵ ۲ ۲]	۱۰۰٪	۸۵٪	۱۰۰٪	۹۳/۳۳٪
۲	[۵ ۴ ۲]	۱۰۰٪	۱۰۰٪	۱۰۰٪	۱۰۰٪
۳	[۵ ۷ ۲]	۱۰۰٪	۹۰٪	۱۰۰٪	۹۶/۶۶٪
۴	[۵ ۵ ۳ ۲]	۱۰۰٪	۹۰٪	۱۰۰٪	۹۶/۶۶٪
۵	[۵ ۱۰ ۵ ۲]	۱۰۰٪	۰٪	۰٪	۰٪

۶- نتیجه گیری

در این مقاله ابتدا اصول عیب یابی بلبرینگ ها ارائه شد. برای هوشمند کردن پروسه عیب یابی استفاده از الگوریتم های تشخیص الگو بر مبنای شبکه های عصبی پیشنهاد گردید. به منظور بررسی صحت روش پیشنهادی یک مجموعه آزمایشگاهی طراحی و داده های مناسب در سه حالت سالم، عیب رینگ بیرونی و عیب رینگ درونی جمع آوری شد. در ادامه یک شبکه عصبی با استفاده از خصوصیات حوزه زمان و فرکانس و یک شبکه دیگر با استفاده از خصوصیات حوزه زمان طراحی گردید. نتایج نشان می دهد، با استفاده از خصوصیات حوزه زمان، می توان با حجم محاسبات کمتر به نتایج بهتر یا مشابه نسبت به استفاده از خصوصیات حوزه زمان و فرکانس رسید. از آنجا که بدست آوردن ویژگی های حوزه زمان ساده تر و حجم محاسبات کمتری دارد، بنابراین استفاده از خصوصیات حوزه زمان برای دسته بندی عیوب مختلف بلبرینگ ها پیشنهاد می شود.

مراجع

[1] M. E. H. Benbouzid, “Bibliography on induction motors faults detection and diagnosis,” IEEE Trans. Energy Conversion, vol. 14, no. 4, Dec. 1999.

[2] W. T. Thomson, “A review of on-line condition monitoring techniques for three-phase squirrel cage induction motors— Past present and future,” in IEEE SDEMPED’99, Spain, pp. 3–18, Sept. 1999.

[3] G.K. Singh, Sa’ad Ahmed Saleh Al Kazzaz, “Induction machine drive condition monitoring and diagnostic researcha survey,” Journal of electric power research, vol. 64, pp. 145-158, Feb. 2003.

[4] S. Nandi, H. A. Toliat, X. Li, “Condition monitoring and fault diagnosis of electrical motors-A Review,” IEEE Trans. Energy Conversion, vol. 20, no. 4, Dec. 2005.

[5] N. Tandon and A. Choudhury, “A review of vibration and acoustic measurement methods for the detection of defects in rolling