شانزدهمین کنفرانس سالانه(بین المللی) مهندسی مکانیکISME2008
ایران، کرمان، دانشگاه شهید باهنر کرمان، ۲۴-۲۶ اردیبهشت ۱۳۸۷

تحلیل سیگنال‌های ارتعاشی به کمک تبدیل فوریهٔ زمان کوتاه، شبکه‌های عصبی و استنتاج فازی برای شناسایی نوع و شدت آسیب در بلبرینگ

دانیال بوستان
کارشناسی ارشد- دانشگاه فردوسی مشهد
dbustan@ieee.org

ناصر پریز
استادیار- دانشگاه فردوسی مشهد
n-pariz@um.ac.ir

چکیده

تاکنون روش‌های زیادی برای تشخیص آسیب در تجهیزات مکانیکی معرفی شده است که در میان آنها آنالیز موجک و آنالیز ممان‌های آماری بیشتر از سایر روش‌ها مورد توجه قرار گرفته اند. اگرچه این روش‌ها کارایی خود را به اثبات رسانده‌اند، امّا پیچیدگی، نبود تعبیر فیزیکی مناسب از معیارهای انتخابی و نیز حساسیت به شرایط اولیه از عمده‌ترین نقایص آنها به شمار می‌رود. همچنین این روش‌ها صرفاً بر روی شناسایی آسیب تمرکز داشته و توجهی به شدت آسیب ندارند. در این مقاله، روشی ساده امّا کارآمد برای شناسایی آسیب‌هایی که احتمال وقوع آنها در یک بلبرینگ بسیار زیاد است ارائه می‌گردد. اساس این روش بر مبنای آنالیز فوریه زمان کوتاه بوده و لذا معیارهای مورد استفاده در آن، دارای تعبیر فیزیکی مناسبی خصوصاً در ماشین‌آلات با حرکات دورانی می‌باشد. همچنین روشی برای تخمین شدت آسیب در بلبرینگ نیز ارائه می‌گردد. این روش، آسیب را یک متغیر فازی در نظر گرفته و شدت آسیب را بر مبنای این فرض محاسبه می‌نماید. آزمایش این روش بر روی داده‌های واقعی، نشان از صحت عملکرد آن دارد.

کلمات کلیدی: تبدیل فوریهٔ زمان کوتاه، شبکه‌های عصبی، استنتاج فازی، بلبرینگ.

مقدمه

یکی از مهمترین دلائل از کار افتادگی ماشین‌آلات در کارخانجات، بروز آسیب در بلبرینگ‌های موجود در این ماشین‌آلات است. به عنوان مثال در مورد سیستم‌هایی که یک موتور، تأمین کنندهٔ اصلی نیروی محرکهٔ مورد نیاز یک مجموعه می‌باشد، شایع‌ترین دلیل از کارافتادگی این مجموعه، خرابی بلبرینگ‌های نگاه‌دارندهٔ محور موتور است[۱]. لذا تشخیص آسیب-های موجود در بلبرینگ پیش از آنکه شدت این آسیب‌ها به مراحل بحرانی رسیده و باعث از کارافتادگی سیستم گردند، می‌تواند کمک شایانی به حفظ پیوستگی کارکرد یک ماشین، جلوگیری از آسیب‌های جانی و مالی ناشی از عملکرد معیوب یک وسیله، بالابردن کیفیت تولید و نیز زمان‌بندی بازدیدها و تعمیرات دوره‌ای نماید.

تاکنون روش‌های زیادی برای تشخیص آسیب در بلبرینگ معرفی شده است که از آن جمله می‌توان به تکنیک مدل‌سازی مخفی مارکوف[۱]، تبدیل وایگنر[۲]، آنالیز موجک[۳]، آنالیز ممان‌های آماری[۴]، تکنیک جداسازی فیشر[۵]، و... اشاره کرد. اگرچه این روش‌ها کارایی خود را به اثبات رسانده-اند، امّا پیچیدگی، نبود تعبیر فیزیکی مناسب از معیارهای انتخابی و نیز حساسیت به شرایط اولیه از عمده‌ترین نقایص آنها به شمار می‌رود. همچنین این روش‌ها صرفاً بر روی شناسایی آسیب تمرکز داشته و توجهی به شدت آسیب ندارند.

در این مقاله، روشی ساده امّا کارآمد برای شناسایی آسیب‌هایی که احتمال وقوع آنها در یک بلبرینگ بسیار زیاد است ارائه می‌گردد. اساس این روش بر مبنای آنالیز فوریه زمان کوتاه بوده و می‌تواند جایگزین روش‌های پیچیده‌ای مانند تبدیل موجک، آنالیزهای آماری و... گردد. همچنین روشی برای تخمین شدت آسیب در بلبرینگ ارائه می‌گردد. این روش، آسیب را یک متغیر فازی در نظر گرفته و شدت آسیب را بر مبنای این فرض محاسبه می‌نماید.

این روش، این امکان را فراهم می‌سازد تا با اطلاع داشتن از نوع آسیب و شدت آن، برای بازدید و تعمیرات دوره‌ای برنامه‌ریزی بهینه‌ای انجام داد.

تبدیل فوریه زمان کوتاه

دنیس گیبور، برای از بین بردن ضعف‌های تبدیل فوریه در توصیف سیگنال-های غیر ایستا، تکنیک تبدیل فوریهٔ زمان کوتاه را بر مبنای تبدیل فوریه معرفی کرد. در این روش، با استفاده از تکنیک تابع پنجره و بکار بردن یک پنجرهٔ زمانی متحرک با اندازهٔ ثابت، سیگنال به قسمت‌های کوچک مجزا تقسیم شده و با اعمال تبدیل فوریهٔ مجزا بر روی هر کدام از این قسمت‌ها، محتوای فرکانسی سیگنال در بازه‌های زمانی مختلف بدست می‌آید. رابطهٔ (۱)، بیانگر نمایش ریاضی روش تبدیل فوریهٔ زمان کوتاه است[۶].

$$\mathrm{STFT}(\tau,\omega)=\int_{0}^{\infty} s(t).\,g(t-\tau).\,e^{-j\omega t}\,dt \qquad (۱)$$

سیستم مورد آزمایش

همانطور که در شکل (۱) دیده می شود، سیستم مورد آزمایش، شامل یک موتور با توان ۲ اسب بخار است که در سمت چپ قرارگرفته است. یک سنسور گشتاورسنج وظیفهٔ اندازه‌گیری بار موتور را که توسط یک دینامومتر – که در سمت راست شکل دیده می‌شود- تأمین می‌شود، برعهده دارد. یک انکدر نیز -که در وسط شکل دیده می شود- سرعت چرخش محور موتور را اندازه‌گیری می‌کند. بلبرینگ هایی که آزمایش روی آنها انجام شده است، نگه دارنده شافت موتور هستند. آسیب‌های این بلبرینگ‌ها توسط دستگاه جوش ایجاد شده و دارای ابعاد ۰٫۰۰۷، ۰٫۰۱۴ و ۰٫۰۲۱ اینچ می‌باشند[۷]. داده‌های ارتعاشی(جداول ۳،۲،۱) مربوط به وضعیت ماشین در حالات مختلف عملکرد است. حالات سیستم شامل: حالت نرمال (بدون عیب) و حالت آسیب‌دیده با آسیب در حلقهٔ داخلی و آسیب در ساچمه می‌باشد. سنسور ارتعاشی مورد استفاده در این آزمایش‌ها، شتاب‌سنج بوده که توسط یک پایهٔ مغناطیسی به بلبرینگ متصل شده است. داده‌های ارتعاشی توسط یک کارت جمع‌آوری دادهٔ ۱۶ کاناله و با سرعت ۱۲۰۰۰ نمونه بر ثانیه جمع‌آوری شده و وارد محیط MATLAB گردیده است.

داده‌های مرتبط با وضعیت کارکرد سیستم، بـه همـراه میـزان بـار و سـرعت چرخش در آن وضعیت، - که بصورت دستی اندازه‌گیری شده‌اند- در mفایل-های جداگانه‌ای ذخیره گردیده‌اند.

شکل ۱: سیستم مورد آزمایش

جدول ۱: داده‌های مربوط به حالت نرمال (بدون عیب)

بار (hp)	سرعت (RPM)	تعداد نمونه
۰	۱۷۹۷	۲۴۳۹۳۸
۱	۱۷۷۲	۴۸۳۹۰۳
۲	۱۷۵۰	۴۸۳۹۰۳
۳	۱۷۳۰	۴۸۵۶۴۳

جدول ۲: داده‌های مربوط به حالت آسیب در حلقهٔ داخلی

بار (hp)	سرعت (RPM)	تعداد نمونه (آسیب۰,۰۰۷)	تعداد نمونه (آسیب۰,۰۱۴)	تعداد نمونه (آسیب۰,۰۲۱)
۰	۱۷۹۷	۱۲۱۲۶۵	۱۲۱۸۴۶	۱۲۲۱۳۶
۱	۱۷۷۲	۱۲۱۹۹۱	۱۲۱۸۴۶	۱۲۱۵۵۶
۲	۱۷۵۰	۱۲۲۱۳۶	۱۲۱۸۴۶	۱۲۱۸۴۶
۳	۱۷۳۰	۱۲۲۹۱۷	۱۲۱۷۰۱	۱۲۱۹۹۱

جدول ۳: داده‌های مربوط به حالت آسیب در ساچمه

بار (hp)	سرعت (RPM)	تعداد نمونه (آسیب۰,۰۰۷)	تعداد نمونه (آسیب۰,۰۱۴)	تعداد نمونه (آسیب۰,۰۲۱)
۰	۱۷۹۷	۱۲۲۵۷۱	۱۲۱۸۴۶	۱۲۱۹۹۱
۱	۱۷۷۲	۱۲۱۴۱۰	۱۲۲۱۳۶	۱۲۱۷۰۱
۲	۱۷۵۰	۱۲۱۵۵۶	۱۲۱۹۹۱	۱۲۲۱۳۶
۳	۱۷۳۰	۱۲۱۵۵۶	۱۲۲۱۳۶	۱۲۲۱۳۶

پیش پردازش داده‌ها

برای استفاده از داده‌هایی که در بخش قبل به آنها اشاره شد، ابتدا باید پردازش اولیه‌ای روی آنها انجام داد. این پیش‌پردازش می‌تواند یک نرمال-سازی ساده تا یک پروسهٔ پیچیدهٔ کاهش نویز در داده‌ها را در بر گیرد. در این پژوهش ، تنها پیش‌پردازش استفاده شده حذف مقدار ثابت انحراف(trend) موجود در داده‌ها، بدلیل استفاده از تبدیل فوریه در مرحلهٔ پردازش نهایی داده‌ها بوده است. این کار توسط نرم‌افزار MATLAB و با استفاده از تابع DETREND صورت می‌گیرد.

پس از این مرحله، بدلیل ماهیت غیر ایستا بودن داده‌ها، و استفاده از تبدیل فوریهٔ زمان کوتاه، باید داده‌ها را به بازه‌های زمانی (پنجره‌های زمانی) مشخصی تقسیم نمود. بدلیل عدم استفاده از این روش در سایر مقالات، مناسبی برای انتخاب طول پنجرهٔ مورد نظر وجود ندارد. لذا باید معیار مناسبی برای انتخاب طول مناسب پنجره پیشنهاد گردد. در انتخاب این معیار سعی شد، تا دقت زمان – فرکانسی مناسبی در سرعت‌های مختلف کارکرد ماشین بدست آید. بدین معنی که در سرعت‌های پایین، طول پنجرهٔ زمانی زیاد شده و در سرعت‌های بالا طول پنجره کاهش یابد.

برای انتخاب طول پنجرهٔ مناسب، از سرعت چرخش موتور استفاده شد. بـدین صورت که ابتدا با استفاده از این سرعت، فرکانس چرخش موتور محاسبه شده و با استفاده از این فرکانس، زمان لازم برای هر دور چرخش موتـور بـه‌دسـت آمد. با توجه به فرکانس KHz ۱۲ نمونه برداری داده‌ها، و زمان به‌دست آمده، می‌توان به تعداد نمونه‌های سیگنال در هر پنجره، دست یافت. در این پژوهش طول پنجرهٔ مورد نظر، ۱۰ دور چرخش موتور در نظر گرفته شد. روابط (۴-۲) این موضوع را نشان می‌دهند:

$$f_r = \frac{RPM}{60}$$ فرکانس چرخش موتور (۲)

$$T_{10} = \frac{10}{f_r}$$ زمان ۱۰ دور چرخش (۳)

$$N = T_{10} \times f_{sampling}$$ تعداد داده‌های موجود در پنجرهٔ مورد نظر (۴)

وابستگی طول پنجره به سرعت چرخش موتور دارای این مزیـت اسـت کـه بـا زیاد شدن سرعت چرخش موتور، طبق رابطهٔ (۲) فرکانس چرخش نیز افزایش یافته و با افزایش فرکانس طبق رابطهٔ (۳)، زمان چرخش کاهش خواهد یافت. این کاهش با توجه به (۴) منجر به کاهش تعداد نمونـه‌هـای موجـود در یـک پنجره شده که این کاهش، به‌نوبهٔ خود، افـزایش دقـت فرکانـسی را بـه‌دنبـال خواهد داشت. لذا این انتخاب، دقت فرکانسی متغیر با توجه به سرعت چرخش را بدست خواهد داد که این مزیت را می‌توان معادل دقت فرکانسی متغیـر در تبدیلات زمان-فرکانس، خصوصاً تبدیل موجک دانست.

در صورتیکه داده‌ها در یک محیط آلوده به نویز، نمونـه بـرداری شـده باشـند، مـی‌تـوان از روش‌هـای مختلـف کـاهش نـویز ماننـد اسـتفاده از خاصـیت DENOISING در تبدیل موجک استفاده کرد. البته با توجه به توضـیحاتی که آزمایشگاه ارتعاشات دانشگاه Case Western Reverse ([۷])در مـورد پروسهٔ جمع آوری داده‌ها داده است، لزومی به استفاده از روش‌های کاهش نویز دیده نشد.

پردازش داده‌ها

پس از مرحلهٔ پیش‌پردازش، سیگنال‌های ارتعاشی وارد مرحلهٔ اصلی پردازش و استنتاج می‌شوند. اساس این مرحله بر مبنای تبدیل فوریهٔ داده‌هـای ارتعاشـی بنا نهاده شده است. زیرا می‌توان تعبیر مناسبی از نتایج مبتنی بر ایـن تبـدیل در مورد سیستم داشت. بطور مثال، می‌تـوان تحریـک مـدهای فرکانـسی بـه خصوصی را در طیف فرکانسی سیگنال ارتعاشی، به وجود آسیب‌هـایی خـاص، نسبت داد[۸].

همانگونه که در مرحلهٔ پیش‌پردازش داده‌ها نیز ذکر شد، طول پنجره در تبدیل فوریه زمان کوتاه، ۱۰ دور چرخش موتور در نظر گرفته شد. امّا بـرای بررسـی سیگنال به تعداد داده‌های بیشتری از نمونه‌های موجود در یـک پنجـره، نیـاز داریم. لذا از ۱۰ پنجرهٔ زمانی برای هر سیگنال ارتعاشی برای مرحلهٔ پردازش

استفاده خواهد شد. علّت این امر نیز، غیر ایستا بودن داده‌هاست.

در مرحلهٔ بعد، روی هر یک از این پنجره‌ها آنالیز فوریه انجام شده و نتایج این آنالیز برای هر پنجره، جداگانه ذخیره می‌گردد. روند انجام آنالیز بر روی هر پنجره بدین صورت است که ابتدا با استفاده از تبدیل فوریه، طیف فرکانسی داده‌های هر پنجره بدست آمده و سپس ۱۰ مد فرکانسی که بالاترین مقدار دامنه را به خود اختصاص داده‌اند، به ترتیب فرکانس در یک بردار قرار می‌گیرند. سپس این بردار بر فرکانس چرخش سیستم تقسیم شده تا فرکانس‌های نسبی طیف بدست آید. همچنین جهت نرمال‌سازی، این بردار به فرکانس نمونه برداری (۱۲۰۰۰) تقسیم شده تا رنج درایه‌های هر بردار، در بازهٔ [۰,۱] قرار گیرد. این بردار به عنوان بردار مشخصهٔ پنجرهٔ مورد پردازش، در مراحل بعد مورد استفاده قرار خواهد گرفت.

بدین ترتیب برای هر سیگنال ارتعاشی ورودی به سیستم، ۱۰ بردار مشخصه، مربوط به ۱۰ پنجرهٔ زمانی آن به‌دست خواهد آمد. هر یک از این ۱۰ بردار، بصورت جداگانه وارد مرحلهٔ استنتاج شده و با توجه به نتیجهٔ این مرحله، وضعیت هر بردار تشخیص داده می‌شود. وضعیت سیگنال اصلی نیز با توجه به وضعیت تمامی بردارهای مشخصهٔ سیگنال مشخص می‌گردد. بدین صورت که در صورتیکه اکثریت بردارها دارای وضعیت مشابهی باشند، این وضعیت، به عنوان وضعیت سیگنال اصلی شناخته خواهد شد.

مرحلهٔ استنتاج

استنتاج داده‌ها به کمک سیستمی که رابطهٔ پیچیده و غیرخطی میان بردار مشخصه و حالت (سالم یا معیوب بودن) یک سیگنال را مدل می‌کند، انجام می‌شود. این سیستم متشکل از یک شبکهٔ عصبی پیشخور سه لایه بوده که با سیگنال‌هایی با حالت شناخته شده، آموزش داده شده است.

پروسهٔ استنتاج

در این پژوهش به‌دلیل توانایی مدل‌سازی بالا، استفاده از شبکه‌های عصبی، مدنظر قرار گرفت. سه شبکهٔ عصبی به نام‌های "normal"، "inner" و "ball" وظیفهٔ شناسایی آسیب را با توجه به بردار مشخصهٔ سیگنال ورودی بر عهده دارند. تمامی این شبکه‌ها از نوع شبکهٔ عصبی پیشخور سه‌لایه هستند. در هر سه شبکه، لایهٔ ورودی، از ۱۰ نرون (به تعداد عناصر بردار مشخصه) تشکیل شده است، لایهٔ دوم که لایهٔ پنهان نام دارد، نیز شامل ۱۰ نرون بوده و در لایهٔ خروجی تنها یک نرون قرار دارد. همچنین، تابع فعال‌ساز تمام شبکه‌ها، hyperbolic tangent sigmoid انتخاب شد.

هر یک از این سه شبکه، وظیفهٔ جداگانه‌ای برعهده داشته و مستقل از دو شبکهٔ دیگر عمل می‌کند. شبکهٔ "normal" وظیفهٔ تشخیص وجود آسیب در بلبرینگ را برعهده دارد. در این شبکه خروجی ۱ به معنای سالم بودن بلبرینگ و خروجی ۱- به معنای معیوب بودن آن است.

شبکه‌های "inner" و "ball" شناسایی نوع آسیب موجود در سیستم را انجام می‌دهند: خروجی ۱ در شبکهٔ "inner" به معنای وجود آسیب در حلقهٔ داخلی و در شبکهٔ "ball" به معنای وجود آسیب در ساچمه‌ها است.

همانطور که پیشتر نیز ذکر شد، هر یک از ۱۰ بردار مشخصهٔ مربوط به سیگنال ارتعاشی ورودی، به‌صورت جداگانه وارد مرحلهٔ استنتاج می‌گردند. در این مرحله، با توجه به داده‌های آموزشی که در مرحلهٔ آموزش به شبکه داده شده‌اند، وضعیت سیگنال مرتبط با هر بردار و نوع آسیب آن (در صورت وجود) مشخص می‌شود. در صورتیکه وضعیت اکثر سیگنال‌ها مشابه هم تشخیص داده شود، این وضعیت در مورد سیگنال اصلی نیز صادق خواهد بود.

آموزش شبکهٔ عصبی

انتخاب داده‌های مناسب برای آموزش یک شبکهٔ عصبی، از مهمترین مراحل طراحی یک شبکه، برای حل یک مسئله است. این داده‌ها باید به‌گونه‌ای انتخاب شوند تا تمامی حالات ممکن در یک سیستم را در برگیرند. در این پژوهش، برای آموزش هر سه شبکه، از داده‌های یکسانی استفاده شد.

داده‌های آموزشی مورد استفاده، شامل نمونه‌های ۱۰۰ دور (۱۰ پنجره) چرخش موتور در بارهای متفاوت (بدون بار، ۱ اسب، ۲ اسب و ۳ اسب) و در حالات بدون عیب، عیب در حلقهٔ داخلی(با اندازه‌های ۰,۰۰۷، ۰,۰۱۴ و ۰,۰۲۱) و عیب در ساچمه (با اندازه‌های ۰,۰۰۷، ۰,۰۱۴ و ۰,۰۲۱) بود. در مجموع ۲۸۰ بردار مشخصه برای آموزش شبکه مورد استفاده قرار گرفت.

روند آموزش برای هر شبکه بصورت جداگانه، با پارامترهای مطابق جدول ۴ و به کمک جعبه ابزار شبکه عصبی نرم‌افزار MATLAB، صورت پذیرفت.

معیار توقف در روند آموزش، علاوه بر تعداد تکرار معین، ازدیاد خطای داده‌های اعتبار تعمیم(Validation Data) نیز، بوده است. بدین صورت که با کاهش خطای سیستم در هر تکرار روند آموزش، در صورتیکه خطای داده‌های تعمیم از تکرار قبل بیشتر شده باشد، روند آموزش متوقف خواهد شد. داده‌های مورد استفاده به عنوان داده‌های اعتبار تعمیم، ۲۸۰ بردار مشخصه، از داده‌هایی است که در مرحلهٔ آزمایش به سیستم اعمال خواهد شد.

نتایج موجود در جدول ۴، نشان از موفقیت سیستم در شناخت داده‌های آموزشی نیز دارد. برای آزمایش کارایی روش پیشنهادی، باید شبکه‌ها را در مواجهه با داده‌هایی قرار دهیم که تاکنون به شبکه اعمال نشده‌اند.

جدول ۴: پارامترهای آموزش شبکه‌ها

مرحلهٔ آموزش	شبکه		
	normal	inner	ball
بازهٔ ورودی	[0,1]	[0,1]	[0,1]
بازهٔ خروجی	[-1,1]	[-1,1]	[-1,1]
تابع آموزش	TRAINLM	TRAINLM	TRAINLM
تابع آموزش تطبیقی	LEARNGDM	LEARNGDM	LEARNGDM
معیار خطا	MSE	MSE	MSE
تعداد تکرار	500	1760	2714
درصد تشخیص درست	100%	98.9286%	95.7143%

آزمایش شبکهٔ عصبی

داده‌های مورد استفاده در این مرحله، داده‌هایی هستند که تا این مرحله به سیستم اعمال نشده‌اند. این داده‌ها، ادامهٔ سیگنال‌هایی است که در مرحلهٔ آموزش به سیستم اعمال گردید. (پنجرهٔ زمانی ۱۱ به بعد).

با استفاده از این سیگنال‌ها به عنوان داده‌های آزمایش، علاوه بر تست قابلیت تعمیم شبکه، حساسیت شبکه به لحظهٔ شروع داده‌ها نیز مورد آزمایش قرار خواهد گرفت. لازم به ذکر است که در روش‌های مبتنی بر آنالیز زمان-فرکانس، خصوصاً تبدیل موجک، حساسیت به لحظهٔ شروع داده‌ها وجود داشته و این حساسیت، در مواردی منجر به پاسخ نادرست سیستم می‌گردد.

در مجموع ۵۶۰ داده، برای آموزش شبکه انتخاب شد که این تعداد دو برابر تعداد داده‌های استفاده شده برای آموزش شبکه می‌باشد. چنین نسبتی، در مسائلی که تعداد کمی داده برای آموزش شبکه در اختیار است، مناسب بوده و در صورتیکه پاسخ شبکه مناسب بوده باشد، نشان از کارایی و قابلیت تعمیم بالای شبکه دارد. جدول ۵، نتایج مرحلهٔ آزمایش را نشان می‌دهد.

جدول ۵: نتایج آزمایش شبکه‌ها

مرحلهٔ آزمایش	شبکه		
	normal	inner	ball
تعداد داده‌های آزمایش	560	560	560
تشخیص نادرست	0	16	44
درصد تشخیص درست	100%	97.1429%	92.1429%

استنتاج نهایی

همانگونه که پیشتر نیز اشاره شد، مرحلهٔ استنتاج از دو قسمت تشکیل شده است. در قسمت اول، بردارهای مشخصهٔ هر پنجره، بصورت مجزا به شبکهٔ عصبی، وارد شده و وضعیت آن تشخیص داده می‌شود. در مرحلهٔ دوم، وضعیت یکسان حداقل ۶ پنجره از ۱۰ پنجرهٔ هر سیگنال، مشخص کنندهٔ وضعیت سیگنال خواهد بود. با توجه به این موضوع، استنتاج نهایی وضعیت سیگنال به صورت جدول ۶ است.

جدول ۶: نتایج استنتاج نهایی

مرحلهٔ استنتاج	شبکه		
	normal	inner	ball
تعداد سیگنال‌های آزمایش	56	56	56
تشخیص نادرست	0	1	1
درصد تشخیص درست	100%	98.2143%	98.2143%

تخمین شدت آسیب

تمام مطالب گفته شده تا این بخش، مربوط به شناسایی آسیب، در بلبرینگ بود. امّا در این بخش به معرفی روشی جهت تخمین شدت آسیب، خواهیم پرداخت.

باید توجه داشت که شدت آسیب یک کمیت فازی است. بدین معنا که یک سیستم پس از شروع به کار، با سیستم قبل از شروع به کار تفاوت دارد. زیرا به‌دلیل تماس اجزاء مکانیکی موجود در سیستم، روند فرسایش سیستم شروع شده و رو به پیشرفت می‌گذارد. امّا هیچ‌گاه سیستمی که تازه شروع به کار کرده است، سیستم معیوب نامیده نمی‌شود. زیرا شدت آسیب در آن کوچک بوده و قابل اغماض است. بسته به حساسیت و کاربرد سیستم، هنگامی که شدت آسیب، از حد معینی بیشتر گردد، سیستم معیوب تشخیص داده می‌شود. لذا سالم یا معیوب بودن سیستم، وابسته به حد آستانه‌ای است که برای سیستم در نظر گرفته شود.

در تمام روش‌هایی که در مقالات ذکر شده است، دو سیستم آسیب دیده نیز که از لحاظ شدت آسیب، با یکدیگر تفاوت دارند، معیوب شناخته می‌شوند. در صورتیکه در بسیاری از سیستم‌ها بروز یک آسیب را، در صورتیکه شدت آسیب کم باشد، می‌توان تنها به عنوان یک اخطار تلقی کرد و تنها هنگامی که شدت آسیب زیاد شد، تصمیمات مورد نیاز را برای ادامهٔ کارکرد سیستم گرفت. در این حالت، تشخیص زیاد یا کم بودن شدت آسیب بر عهدهٔ یک متخصص خواهد بود.

مفهوم زیاد یا کم بودن، عمومی‌ترین مثال‌هایی است که برای یک متغیر فازی آورده می‌شود. حال در صورتیکه شدت آسیب را یک متغیر فازی در نظر بگیریم، می‌توان وضعیت سیستم را به کمک این متغیر با مفهوم بیشتری بیان کرد. بدین مفهوم که در صورتیکه متغیر فازی شدت آسیب، مقدار بزرگی داشته باشد، به مفهوم شدید بودن آسیب بوده و باید توجه بیشتری نسبت به آن داشت.

برای این منظور، از سه متغیر برای تخمین شدت آسیب استفاده می‌کنیم. هر سهٔ این متغیرها، مستقیماً از سیگنال ارتعاشی (پنجرهٔ زمانی) به‌دست می‌آیند. این متغیرها عبارتند از: رنج سیگنال (تفاوت ماکزیمم و مینیمم)، میانگین و انحراف معیار استاندارد داده‌ها.

تخمین شدت آسیب داده‌ها نیز توسط یک سیستم عصبی – فازی که به کمک جعبه ابزار فازی نرم‌افزار MATALAB و توسط تابع ANFIS ایجاد شده است، انجام می‌گیرد. دو سیستم، یکی برای تخمین شدت آسیب در ساچمه و دیگری برای تخمین شدت آسیب در حلقهٔ داخلی استفاده می‌شود. پارامترهای مورد استفاده برای آموزش این دو شبکه، در جدول ۷ آورده شده است.

جدول ۷: پارامترهای مورد استفاده در آموزش دو شبکه

مرحلهٔ آموزش	شبکه	
	inner	ball
بازهٔ ورودی	استفاده از داده‌ها	استفاده از داده‌ها
نحوهٔ آموزش	Hybrid	Hybrid
تعداد توابع عضویت برای هر ورودی	3	3
توابع عضویت	gbellmf	gbellmf
تعداد تکرار	500	500
تعداد داده‌های آموزش	90	90
خطا	2.0556×10^{-5}	5.9912×10^{-3}

برای آزمایش شبکه‌ها، از داده‌های ۳۰ پنجرهٔ زمانی، استفاده گردید. شکل‌های ۵و۶، به ترتیب خروجی شبکه‌های ball و inner را در مرحلهٔ آزمایش نشان می‌دهند.

نتیجه‌گیری

در این مقاله، روشی ساده امّا کارآمد برای شناسایی آسیب‌هایی که احتمال وقوع آنها در یک بلبرینگ بسیار زیاد است ارائه شد. اساس این روش آنالیز فوریهٔ زمان کوتاه بوده و می‌تواند از آن به جای روش‌های پیچیده‌ای مانند تبدیل موجک، آنالیزهای آماری و... استفاده کرد. همچنین روشی برای تخمین شدت آسیب در بلبرینگ ارائه گردید. این روش، آسیب را یک متغیر فازی در نظر گرفته و شدت آسیب را بر مبنای این فرض محاسبه می‌نماید. صحت عملکرد روش پیشنهادی نیز با استفاده از داده‌های واقعی به اثبات رسید.

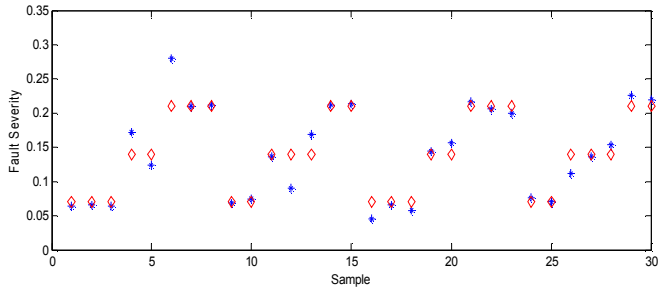

شکل ۵: خروجی شبکهٔ ball در مرحلهٔ آزمایش (لوزی، اندازهٔ واقعی و ستاره، شدت تخمین زده شده)

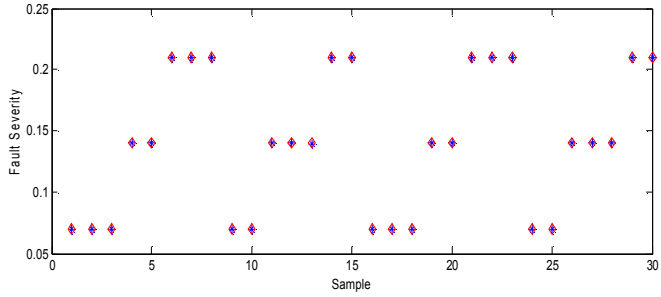

شکل ۶: خروجی شبکهٔ inner در مرحلهٔ آزمایش (لوزی، اندازهٔ واقعی و ستاره، شدت تخمین زده شده)

مراجع

1- H. Ocak, K.A. Loparo, 2005, HMM-based fault detection and diagnosis scheme for rolling element bearings, Journal of Vibration and Acoustics, Vol. 127, pp. 299-306.

2- L.Hui, Z. Yuping, 2006, Bearing Faults Diagnosis Based on EMD and Wigner-Ville Distribution, WCICA, Vol.2, pp. 5447 – 5451.

3- R. Tse, P. W. Peng, Y. H. Yam, 2001, Wavelet Analysis and Envelope Detection for Rolling Element Bearing Fault Diagnosis-Their Effectiveness and Flexibility, Journal of Vibration and Acoustics, Vol. 123, pp 303-310.

4- Z. Jia-Fan, H. Zhi-Chu, 2005, Kernel fisher discriminant analysis for bearing fault diagnosis, Proceedings of 2005 International Conference on Machine Learning and Cybernetics, Vol. 5, pp 3216 – 3220.

5- H-W Cho, 2007, Nonlinear feature extraction and classification of batch process data in kernel feature space, Expert Systems with Applications, Vol. 32, Issue 2, pp 534-542.

6- J. Shan, J., B. Bauer, The joint time-frequency and its application for vibration diagnosis of machines, Institute of Mining and Metallurgical Machine Engineering, 2003.

7- Case Western Reverse University, Vibration Laboratory (www.eecs.cwru.edu/laboratory/bearing)

8- C.M Harris, A.G., 2002, Piersol, Harris' shock and vibration handbook, 5th Edition, McGraw Hill.