

تشخیص عیوب در داده‌های واقعی بلبرینگ

سید محمد عماد اولیائی^۱، سیروس طلایی^۲

^۱دانشگاه هوافضا عاشورا

چکیده

بلبرینگ‌ها یکی از قطعات مهم در صنعت هوایی می‌باشد که خرابی در آن می‌تواند سوانح جبران ناپذیری از قبیل جان افراد منجر شود؛ بنابراین تعیین صحت عملکرد آن موضوع بسیار مهمی می‌باشد. بلبرینگ‌های دارای عیب در حین عملکرد منجر به ایجاد ارتعاشاتی شده که با آنالیز سیگنال حاصله می‌توان به تشخیص و تفکیک عیب پرداخت. در این مقاله با محاسبه پراکندگی و پارامترهایی ارتعاشات از طریق کاهش بعد با روش‌های LDA دینامیکی و PCA و آنالیز گشتاورها، سعی بر تشخیص عیوب را داریم. کلاس‌های داده‌ها نیز به صورت حالات سالم، عیب رینگ داخلی، عیب رینگ خارجی و عیب ساچمه می‌باشد. نتایج شبیه‌سازی نشان داده است که روش LDA دینامیکی، تشخیص خیلی خوبی از عیوب را امکان پذیر کرده است.

واژگان کلیدی: تشخیص عیب، شناسایی عیب، بلبرینگ، روش PCA، LDA

۱- مقدمه

از آغاز دهه‌ی ۱۹۸۰ تحقیقات وسیعی بر روی عیب‌یابی بلبرینگ انجام شد. بلبرینگ‌ها یکی از پر استفاده ترین قطعات در ماشین‌ها می‌باشند که به دلیل چرخش دائمی زودتر از قطعات دیگر مستهلک می‌شوند. حدود ۴۱٪ از عیب‌های موتورهای القایی، مربوط به بلبرینگ است. شناسایی و رفع عیب بلبرینگ در مراحل ابتدایی، درصد زیادی از خسارات من جمله هزینه‌ی توقف خط تولید را می‌کاهد.

۱-۱- تاریخچه

اخیراً روش‌هایی نظیر تبدیل فوریه زمان کوتاه، تبدیل ویولت و تبدیل ویولت بسته‌ای برای عیب‌یابی بلبرینگ‌ها استفاده شده است که از جمله روش‌هایی هستند که مبتنی بر سیگنال می‌باشند. علی رغم مزایایی که هر یک از این روش‌ها دارند؛ ولی دارای حجم محاسباتی زیادی بوده و برای تشخیص عیب نیاز به مشخصات موتور و بلبرینگ دارند. [۱]

تبدیل فوریه یکی از ساده‌ترین روش‌های عیب‌یابی است ولی این روش بیشتر برای سیگنال‌های ایستا کاربرد دارد. برای حل این مشکل اخیراً روش‌های نظیر تبدیل فوریه زمان کوتاه و تبدیل ویولت بسته‌ای [۲] مورد استفاده قرار گرفته است که هر کدام مزایای و معایب خاص خود را دارند.

در مقایسه با تبدیل فوریه می‌توان چنین عنوان کرد که سیگنال فوریه که با تبدیل سیگنال اولیه به مجموعه‌ای از سیگنال‌های سینوسی با فرکانس‌های مختلف خواص سیگنال را در یک دوره‌ی زمانی به خوبی نشان می‌دهد، در مورد سیگنال‌های غیر ایستا که در یک دوره‌ی زمانی تغییرات زیادی دارند کاربرد ندارند، در حالی که تبدیل ویولت برای این سیگنال‌ها هم پاسخ مناسب می‌دهد. از این رو تبدیل ویولت به عنوان ابزار نیرومندی شناخته شده است. [۲]

از جمله روش‌های دیگر می‌توان روش تبدیل پارک [۳] و Envelope [۴] را نام برد. حال همان‌طور که جلوتر نیز گفته خواهد شد، داده‌های در دسترس این مقاله، داده‌های خروجی ارتعاشات دو بلبرینگ است و ورودی‌ای از سیستم ذخیره نشده است و بنابراین نمی‌توان مبتنی بر مدل بکار ادامه داد و به ناچار باید مبتنی بر سیگنال پیش رفت. چون داده‌ها دو بُعدی است و بین کلاس‌ها نیز همپوشانی بسیار وجود دارد، لذا داده‌ها به‌صورت دینامیک در نظر گرفته شده است.

برای حل این مسئله از روش PCA، LDA دینامیکی و استفاده از پارامترهای گشتاوری برای کاهش بعد استفاده شده است. همچنین در ادامه روش طبقه‌بندی کننده خطی جهت تولید جدول اطمینان و تشخیص عیب بکار بسته شده است. یکی از ویژگی‌های عمده این مقاله، استفاده از داده‌های واقعی جهت تشخیص عیب می‌باشد که به‌طور مستقیم قابل استفاده در صنعت می‌باشد.


بنابراین در ادامه توضیح مختصری در باب بلبرینگ و داده‌های آن ارائه شده است. در بخش سوم روش‌های کاهش بعد به‌ویژه PCA، LDA و پارامترهای گشتاوری مطرح شده است. در بخش چهارم به ارائه‌ی روش‌ها و تشخیص عیوب پرداخته شده است. در نهایت نیز جمع‌بندی مقاله در بخش پنجم آورده

شده است.

۲- بلبرینگ

بلبرینگ‌ها یکی از پر استفاده‌ترین قطعات در ماشین‌ها می‌باشند که به دلیل چرخش دائمی زودتر از قطعات دیگر مستهلک می‌شوند. بلبرینگ از اجزای مختلفی شامل رینگ داخلی، رینگ خارجی، قفسه نگه‌دارنده و المان‌های چرخنده تشکیل شده است. در شکل (۱) نمایی از یک بلبرینگ نشان داده شده است. معمولاً رینگ داخلی بلبرینگ بر روی یک شفت در حال چرخش نصب می‌شود و رینگ خارجی روی یک محل ثابت قرار می‌گیرد. المان‌های چرخنده می‌توانند ساچمه‌ها و یا غلطک‌ها باشند. برای جلوگیری از برخورد المان‌های چرخشی با یکدیگر قفسه‌ای آن‌ها را از یکدیگر جدا می‌کند.


سیگنال ارتعاشات نمونه برداری شده از یک موتور معیوب، شامل ضربه‌های متوالی و متناوب است. اندازه و پریود ترم‌های ضربه‌ای سیگنال ارتعاشات که به علت عبور ساچمه‌های بلبرینگ از نقاط معیوب رینگ موتور ایجاد می‌شود، بسته به سرعت چرخش، محل عیب و ابعاد مشخصه بلبرینگ قابل محاسبه بوده و این اساس عیب‌یابی متداول بلبرینگ‌ها با توجه به سیگنال ارتعاشات می‌باشد.



شکل ۱- اجزای مختلف بلبرینگ

۲-۱- داده‌های مورد استفاده

داده‌های مورد استفاده از سایت csegroups.case.edu/bearingdatacenter/home دانلود شده است. این وب سایت دسترسی به داده‌های واقعی بلبرینگ را در حالات معمولی و معیوب فراهم می‌کند. عیوب اعم از ۰,۰۰۷ اینچ در قطر تا ۰,۰۴۰ اینچ در قطر به طور جداگانه در رینگ داخلی، ساچمه‌ها و رینگ بیرونی رخ می‌دهند. با تست موتور و اعمال عیوب یاطاقان، داده‌های ارتعاش برای بارهای مختلف موتور از ۰ تا ۳ اسب بخار (۱۷۲۰-۱۷۹۷ RPM) ثبت شده است.



شکل ۲- سیستم مورد آزمایش

شکل (۲) سیستم مورد آزمایش را نشان می‌دهد. موتور در سمت چپ، انکدر در مرکز و دینامومتر در سمت راست قرار دارد.

اطلاعات ارتعاش با استفاده از شتاب سنج جمع‌آوری می‌شود. شتاب سنج در موقعیت ساعت ۱۲ در هر دو drive end و fan end موتور قرار دارد. در نهایت سیگنال ارتعاش با استفاده از یک دیتارکورد ۱۶ کاناله جمع‌آوری می‌شود و بعد از پردازش در محیط نرم‌افزار Matlab آماده می‌شود. ما برای این مقاله سه عیب به نام‌های عیب رینگ داخلی، عیب رینگ خارجی و عیب ساچمه وجود دارد. در نهایت ارتعاشات drive end و fan end برای همه حالات ثبت و ذخیره می‌شود. پس به عبارتی داده‌ها دارای ۲ بُعد (drive end و fan end) در ۴ کلاس می‌باشند (حالت نرمال و ۳ نوع فالت).

۳- روش‌های مورد استفاده


سه تا عامل اصلی وجود دارد که باعث می‌شود کاهش بعد امکان‌پذیر باشد: نویز ممکن است هنگام ثبت داده یک سری اطلاعاتی ناخواسته همراه با سیگنال اصلی ثبت شود که ربطی به مسئله نداشته باشد و موقع استخراج ویژگی، ویژگی‌هایی ثبت شوند که مربوط به نویز باشند. پس باید چنین ویژگی‌هایی را حذف کرد.

اطلاعات نامرتب ممکن است اطلاعاتی هنگام ثبت داده ثبت شود که مرتبط با مسئله نباشد، مثل background تصویر که ممکن است در اکثر مسائل ربطی به مسئله اصلی نداشته باشد و موقع استخراج ویژگی، ویژگی‌هایی ثبت شوند که مربوط به مسئله نداشته باشند. پس باید ما چنین ویژگی‌هایی را حذف کنیم.

اطلاعات تکراری (redundancy) ممکن است ویژگی‌هایی استخراج شود که اطلاعات جدیدی به مسئله اضافه نکند، با اینکه ویژگی خوبی است ولی اطلاعاتی که به مسئله می‌دهد همان اطلاعاتی باشد که در ویژگی یا ویژگی‌های دیگر موجود باشد. پس وجود چنین ویژگی‌هایی هیچ کمکی به ما در حل مسئله نخواهند کرد و تنها باعث افزایش پارامترهای مدل طبقه بند یا رگرسیون شود. پس بهتر چنین ویژگی‌هایی را حذف کنیم. یا به عبارت دیگر ویژگی‌هایی را نگه داریم که اطلاعات مستقل و

جدیدی در مورد مسئله ارائه می‌دهند.

استفاده از داده‌های با بعد کمتر سبب می‌شود تا کلاس‌بندی و شناسایی سریع‌تر و مقاوم‌تر انجام شوند [۵]. کاهش ابعاد ورودی می‌تواند به دو صورت کلی انتخاب ویژگی^۱ و استخراج ویژگی^۲ انجام شود. انتخاب ویژگی اولین روش شناسایی متغیرهایی است که در کلاس‌بندی و یا شناسایی تأثیرگذار می‌باشند. این روش عمل انتخاب r ورودی مؤثر از مجموعه n متغیر می‌باشد که در شکل (۳) نمایش داده شده است؛ اما همان‌طور که پیشتر نیز بیان شد، مشکل در این میان پیدا کردن این ورودی‌های مناسب است که نیاز به یک جستجوی با هزینه بالا دارد.



شکل ۳- کاهش ابعاد با استفاده از روش انتخاب ویژگی [۶]

از طرفی این عمل سبب کاهش دقت مدل خواهد شد. چراکه یک سری از داده‌هایی که دارای اطلاعات کمتری می‌باشند دور ریخته می‌شوند و این دور ریختن اطلاعات به ظاهر کم، ممکن است در دقت تخمین مؤثر باشد.

این درحالیست که استخراج ویژگی، یافتن تبدیلی از n متغیر ورودی به تعداد r متغیر می‌باشد که در شکل (۴) نشان داده شده است. در این تبدیل ورودی‌ها در فضای دیگری تصویر^۳ می‌شوند تا اطلاعات مهم موجود در آن‌ها بهتر نمایش داده شود. این تصویرسازی می‌تواند به صورت رابطه خطی و یا غیرخطی از ویژگی‌های اولیه باشد و ممکن است با مربی و یا بدون مربی انجام شود تا بتوانند مجموعه‌ی ویژگی‌هایی فشرده‌تر و غنی‌تری را تولید کنند. به‌طور کلی به این روش‌ها مهندسی ویژگی نیز گفته می‌شود. با گسترش فعالیت‌ها در حوزه مهندسی ویژگی، امروزه اصطلاحات و عناوینی مطرح شده‌اند که عموماً با یکدیگر قابل تعویض‌اند مانند مهندسی ویژگی، استخراج ویژگی، آموزش ویژگی^۴، آموزش بازنمایی [۷].


^۱Feature Selection

^۲Feature Extraction

^۳Projection

^۴Feature learning

^۵Representation learning




شکل ۴- کاهش ابعاد با استفاده از روش استخراج ویژگی [۶]

روش‌ها و روش‌های یادگیری ماشین مانند PCA و LDA نمونه‌ای از این تبدیلات می‌باشد.

۳-۱- روش PCA

الگوریتم PCA [۸] یکی از معروف‌ترین روش‌های کاهش بعد است که جزء دسته استخراج ویژگی است. این روش بر اساس پراکندگی کار می‌کند و داده‌ها را در جهتی نگاشت می‌دهد که بیشترین واریانس باشد. روش‌هایی که بر اساس پراکندگی کار می‌کنند، فرضشان این است که ویژگی‌هایی که واریانس بیشتری دارند، حاوی اطلاعات مهمی از مسئله هستند. برای همین داده‌ها را در جهتی نگاشت می‌دهند که واریانس یا همان پراکندگی در آن جهت ماکزیمم شود.

این الگوریتم با دو هدف اساسی در پروژه‌ها استفاده می‌شود: کاهش بعد، کاهش افزونگی هدف اصلی این روش این است که با کمک ویژگی‌های حوزه اصلی، ویژگی‌هایی را در فضای جدید ایجاد کند که کاملاً مستقل از هم باشند.



شکل ۵- مثال دوبعدی برای PCA

به این ترتیب که داده‌ها از طریق یک ماتریس به نام G به فضای جدید (Z) تصویر می‌شوند. ستون‌های این ماتریس همان بردار ویژه داده‌های ورودی هستند.

$$Z = G.X_{input}, \quad G = \text{eigen_Vector}(X) \quad (۱)$$

۳-۲- روش LDA

الگوریتم PCA با اینکه یک روش بسیار خوبی در اکثر مسائل هست، ولی از آنجا که به صورت غیر نظارتی کار می‌کند و همچنین رویکرد الگوریتم بر اساس پراکندگی است، ممکن است در بعضی مسائل با مشکل

مواجه شود و خوب عمل نکند. ایراد این روش این است که تنها به پراکندگی داده نگاه می‌کند و ویژگی‌ای که پراکندگی کمتری دارد به منزله این است که اطلاعات مهمی ندارد و در ساخت ویژگی‌های جدید سهم کمتری دارد. این در حالی است که ممکن است یک ویژگی‌ای که پراکندگی کمتری دارد، تفکیک‌پذیری بهتری داشته باشد و بتوان با کمک این ویژگی داده‌های دو کلاس یا چند کلاس را با دقت بالایی دسته‌بندی کرد. برخلاف الگوریتم PCA، الگوریتم LDA^۱ [۹] یک روشی است که با ناظر کار می‌کند یعنی بر اساس تفکیک‌پذیری، داده‌ها را به فضای جدید نگاشت می‌دهد. هدف این روش این است که برای نگاشت داده‌ها از فضای اصلی به فضای جدید، جهتی پیدا کند که بعد از نگاشت داده‌ها در آن جهت، داده‌ها در فضای جدید قابل کلاس‌بندی بهتری باشند؛ به عبارت دیگر این روش می‌خواهد داده‌ها را طوری به فضای جدید نگاشت دهد که واریانس بین کلاسی داده‌ها در فضای جدید حداکثر و واریانس درون کلاسی آن‌ها حداقل شود. این هدف را معیار فیشر می‌گویند. به عبارت دیگر تابع هزینه این روش به صورت زیر تعریف می‌شود:

$$J = \frac{tr(S_w)}{tr(S_B)} \quad (۲)$$

در این ترم $tr(.)$ اپراتور مجموع در آیه‌های قطر ماتریس است. همچنین S_w ماتریس واریانس درون کلاسی و S_B ماتریس واریانس برون کلاسی است. هدف از آموزش، کمینه کردن تابع هزینه است. زمانی این کسر کمینه می‌شود که واریانس برون کلاسی افزایش یابد و ماتریس درون کلاسی کاهش یابد. مقادیر این ماتریس از رابطه زیر به دست می‌آیند.

$$S_w = \frac{1}{N} \sum_{i=1}^l \sum_{n_i=1}^{N_i} (X_{n_i} - \mu_i)^T (X_{n_i} - \mu_i) \quad (۳)$$


$$S_B = \frac{1}{N} \sum_{i=1}^l N_i (\mu_i - \mu)^T (\mu_i - \mu)$$

در این رابطه‌ها X_{n_i} همان بردار داده نمونه‌ی n ام از کلاس i ام است و μ_i میانگین داده‌های کلاس i ام و μ میانگین همه‌ی کلاس‌ها می‌باشد.

همچنین N_i تعداد نمونه‌های کلاس i ام و l تعداد کلاس‌ها می‌باشد.

$$\mu_{i_{\text{bcm}}} = \frac{1}{N_i} \sum_{n_i=1}^{N_i} X_{n_i} \quad (۴)$$

$$\mu_{\text{bcm}} = \frac{1}{l} \sum_{i=1}^l \mu_i$$



شکل ۶- مثال داده دوبعدی دارای ۳ کلاس

۳-۳- روش استفاده از گشتاوری

این بار با الهام از [۱۰]، مشخصاتی که به عنوان عناصر بردار الگوی ورودی در این قسمت انتخاب شده‌اند، مشخصات حوزه زمان سیگنال بوده که عبارت‌اند از:

✓ گشتاور مرتبه اول زمانی یا مجذور مقدار مؤثر سیگنال (RMS^*)

✓ گشتاور مرتبه دوم زمانی یا واریانس (σ^2)

✓ گشتاور مرتبه سوم نرمالیزه شده (SK)

✓ گشتاور مرتبه چهارم نرمالیزه شده (K)

بدین ترتیب به ازای سیگنال ارتعاشات مربوط به هر یک از حالت‌های مختلف عیب شامل: حالت سالم، عیب رینگ داخلی، عیب رینگ خارجی و عیب ساچمه، خروجی حاصل از گام اول محاسبه شده و سپس مشخصات زمانی مذکور برای آن‌ها محاسبه شده و به تعداد حالت‌های مختلف عیب الگوهای ورودی طبق رابطه‌ی زیر تعریف می‌شوند.

$$P = \begin{bmatrix} \text{first central moment}(RMS^*) \\ \text{second central moment(variance)} \\ \text{third central moment(skewness)} \\ \text{forth central moment (kurtosis)} \end{bmatrix} \quad (5)$$

عناصر الگوی ورودی به ترتیب طبق روابط زیر محاسبه می‌شوند:

عنصر اول الگوی مرجع ورودی، مجذور گشتاور زمانی مرتبه اول (RMS^*):

^{*}Variance
^{*}Skewness
^{*}Kurtosis

$$RMS^{\tau} = \frac{1}{N} \sum_{j=1}^N (x_j^i - \mu^i) \quad (۶)$$

N: تعداد کل نمونه‌های موجود در سیگنال خروجی از گام اول
 μ^i : مقدار میانگین سیگنال مشخص که از رابطه‌ی (۱۵) به دست می‌آید.

$$\mu^i = \frac{1}{N} \sum_{j=1}^N x_j^i \quad (۷)$$

عنصر دوم الگوی مرجع ورودی، گشتاور زمانی مرتبه دوم (σ^{τ}):

$$\sigma^{\tau} = \frac{1}{N-1} \sum_{j=1}^N (x_j^i - \mu^i)^{\tau} \quad (۸)$$

عنصر سوم الگوی مرجع ورودی، گشتاور زمانی نرمالیزه شده‌ی مرتبه سوم (SK):

$$SK = \frac{1}{(N-1)\sigma^{\tau}} \sum_{j=1}^N (x_j^i - \mu^i)^{\tau} \quad (۹)$$


عنصر چهارم الگوی مرجع ورودی، گشتاور زمانی نرمالیزه شده‌ی مرتبه چهارم (K):

$$K = \frac{1}{(N-1)\sigma^{\tau}} \sum_{j=1}^N (x_j^i - \mu^i)^{\tau} \quad (۱۰)$$


حال قرار است این پارامترها را برای پنجره‌هایی از داده ورودی (طول دینامیک) محاسبه کرد و هر یک داده‌ای (هر داده به اضافه دینامیک‌های قبلی‌اش) را با ۴ بُعد (۴ پارامتر) متناظر کنیم.

۴- تشخیص عیب

همان‌طور که در قسمت قبل اشاره شد، داده‌های موجود دارای ۲ بُعد و در ۴ کلاس می‌باشند (حالت نرمال و ۳ نوع فالت). نمودار این داده‌های کلاس‌ها در زیر آمده است:



شکل ۷- داده‌های ثبت شده از Fan_end در کلاس‌های مختلف



شکل ۸- داده‌های ثبت شده از Drive_end در کلاس‌های مختلف

همان‌طور که ملاحظه می‌شود میانگین داده‌های کلاس‌ها تقریباً برابرند. از طرفی اختلاف و تغییرات این کلاس‌ها در دامنه به وضوح دیده می‌شود. با این همه داده‌هایی وجود دارند که در بازه تغییرات کلاس‌های دیگر قرار دارند. به عبارتی داده‌هایی وجود دارند که مقدار مشابه دارند ولی متعلق به یک کلاس نمی‌باشند. ناگفته پیداست که تعداد این داده‌ها خیلی زیاد می‌باشد.

اولین فکری که به ذهن می‌رسد این است که داده‌های زمان قبلی را نیز برای آن داده‌ها لحاظ کنیم؛ یعنی به عبارتی برای داده‌ها، دینامیک در نظر بگیریم و روند تغییرات آن را در هم وارد محاسبات کنیم؛ بنابراین با این کار، بُعد داده‌ها را افزایش داده‌ایم.


همچنین اگر بخواهیم آنگوشتی! بیان کنیم، می‌توان گفت که یک پنجره‌ای به طول دینامیک مورد نظر روی داده‌ها قرار داده‌ایم و آن را به حرکت درآورده‌ایم.

۴-۱- روش اول: روش PCA

ابتدا به بررسی تحلیلات آماری برای هر پنجره پرداخته شد. همان‌طور که در شکل و شکل ملاحظه شد، اطلاعاتی در میانگین داده‌ها دیده نمی‌شود و برعکس استفاده از پراکندگی و واریانس هر پنجره معقول به نظر برسد. پس برای هر پنجره سه پارامتر تولید می‌کنیم. این سه پارامتر، واریانس‌های Fan_End و Drive_End و همبستگی این دو در نظر می‌گیریم. با انجام این کار برای هر داده‌ی دینامیک دار شده (هر پنجره)، سه بُعد در نظر گرفته شده است.

در اینجا سؤالی پیش می‌آید مبنی بر اینکه طول پنجره (عمق دینامیک) چقدر باشد. برای پیدا کردن آن از مقادیر کوچک شروع کرده و آن را افزایش دادیم به امید اینکه کلاس‌ها از هم جدا شوند. برای مثال با در نظر گرفتن طول پنجره ۳۰۰ و اعمال الگوریتم PCA نمودار سه‌بعدی آن‌ها برای داده‌های آموزش در زیر آمده است.

لازم به ذکر است که در الگوریتم PCA، بعد خروجی برابر با سه بعد در نظر گرفته شده است.



شکل ۹- نمودار سه‌بعدی داده‌های آموزش تصویر شده با طول پنجره ۳۰۰


در ادامه نیز از طبقه‌بندی کننده خطی با $A*Z=b$ استفاده شد و ماتریس اطمینان به صورت زیر به دست آمد:

جدول ۱- ماتریس اطمینان برای طول پنجره ۳۰۰

Class 0	Class 0	Class 0	Class0	
0	0	0	1.0000	Class 0
0.1500	0.0500	0.775 0	0.0250	Class 1
0.0250	0.9750	0	0	Class 2
0.8500	0.1500	0	0	Class 3

$$\frac{\text{Trace(Confidence Matrix)}}{\text{number of class}} \times 100 = 90,00\% \quad (11)$$

حال با در نظر گرفتن طول پنجره ۷۰۰ داریم:



شکل ۱۰- نمودار سه بعدی داده‌های آموزشی تصویر شده با طول پنجره ۷۰۰

در ادامه نیز از طبقه‌بندی کننده خطی با $A*Z=b$ استفاده شد و ماتریس اطمینان به صورت زیر به دست آمد:

جدول ۲- ماتریس اطمینان برای طول پنجره ۷۰۰

Class 0	Class 0	Class 0	Class 0	
0	0	0	1.0000	Class 0
0.0250	0	0.9750	0	Class 1
0	1.0000	0	0	Class 2
1.0000	0	0	0	Class 3

$$\frac{\text{Trace(Confidence Matrix)}}{\text{number of class}} \times 100 = 99,38\% \quad (12)$$


همان‌طور که دیده می‌شود با دینامیک ۷۰۰، تفکیک‌پذیری تقریباً خوب است؛ به عبارت دیگر بعد از حدود ۷۰۰ سمپل، می‌توان وقوع فالت را اظهار کرد.

۲-۴- روش دوم: روش Dynamic LDA

در ادامه، از روش LDA شد برای کاهش بُعد نیز استفاده می‌کنیم. چرا که این روش نیز از مفهوم پراکندگی بهره می‌برد و در آن سعی می‌شود پراکندگی بین کلاسی را افزایش داده و در عین حال پراکندگی درون کلاسی را کاهش دهد.


پس برای عملی کردن این ایده، مانند قبل بُعد داده‌ها را با اضافه کردن دینامیک‌های گذشته از دو بُعد به چند ده بُعد افزایش داده و سپس بر روی آن الگوریتم LDA را اجرا می‌کنیم؛ بنابراین به آن روش Dynamic LDA گفته می‌شود.

از آنجا که تعداد کلاس‌ها برابر ۴ تا می‌باشد پس حداکثر بعد تولیدی با LDA می‌تواند ۳ باشد. با عملی کردن این صحبت‌ها می‌بینیم که با دینامیک ۵۰۰ کلاس‌ها بسیار عالی جدا شده‌اند.



شکل ۱۱- نمودار سه‌بعدی داده‌های آموزش تصویر شده را با در نظر گرفتن ۵۰۰ دینامیک و اعمال LDA

حال با احتساب ۳۵۰ دینامیک نیز کلاس‌ها به صورت ۱۰۰٪ تفکیک می‌شوند. در زیر نمودار سه‌بعدی داده‌های آموزش تصویر شده را با در نظر گرفتن ۳۵۰ دینامیک و اعمال LDA به همراه جدول اطمینان آن آورده شده است. در ضمن طبقه‌بندی کننده مورد استفاده نیز مانند قبل طبقه‌بندی کننده خطی ($WZ=b$) می‌باشد.



شکل ۱۲- نمودار سه بعدی داده‌های آموزش تصویر شده را با در نظر گرفتن ۳۵۰ دینامیک و اعمال LDA

جدول ۳- ماتریس اطمینان با در نظر گرفتن ۳۵۰ دینامیک و اعمال LDA

Class 0	Class 0	Class 0	Class 0	
0	0	0	1.0000	Class 0
0	0	0.9750	0	Class 1
0	1.0000	0	0	Class 2
1.0000	0	0	0	Class 3

$$\frac{\text{Trace(Confidence Matrix)}}{\text{number of class}} \times 100 = 100\% \quad (13)$$

همچنین در ادامه جدول اطمینان را برای ۲۵۰ دینامیک و ۱۵۰ دینامیک می‌بینیم.

جدول ۴- ماتریس اطمینان با در نظر گرفتن ۲۵۰ دینامیک و اعمال LDA

Class 0	Class 0	Class 0	Class 0	
0.0108	0	0	0.9892	Class 0
0	0	1.0000	0	Class 1
0.0045	0.9955	0	0	Class 2
0.9908	0.0092	0	0	Class 3

$$\frac{\text{Trace(Confidence Matrix)}}{\text{number of class}} \times 100 = 99.39\% \quad (14)$$

جدول ۵- ماتریس اطمینان با در نظر گرفتن ۱۸۰ دینامیک و اعمال LDA

Class 0	Class 0	Class 0	Class 0	
0.1218	0.0190	0	0.8591	Class 0
0	0.0024	0.9976	0	Class 1
0.0500	0.9500	0	0	Class 2
0.9651	0.0349	0	0	Class 3

$$\frac{Trace(Confidence\ Matrix)}{number\ of\ class} \times 100 = 94,30\% \quad (15)$$

یعنی با گذشت حدود ۳۰۰ سمپل از شروع بکار موتور می‌توان فالت در صورت وقوع اعلام کرد و این زمان درست نصف زمان حالت قبل است.

۳-۴- روش سوم: روش محاسبه گشتاوری

در این مرحله قرار است پارامترهای گشتاوری معرفی شده در بخش قبل را برای پنجره‌ها محاسبه کرده و هر یک داده‌ای (هر داده به اضافه دینامیک‌های قبلی‌اش) را با ۴ بُعد (۴ پارامتر) متناظر کنیم. در جدول زیر ماتریس اطمینان طبقه‌بندی کننده خطی این پارامترها با ۷۰۰ دینامیک و ۳۵۰ دینامیک نمایش داده شده است.

جدول ۶- ماتریس اطمینان با در نظر گرفتن ۷۰۰ دینامیک و اعمال گشتاورها

Class 0	Class 0	Class0	Class 0	
0	0.0488	0	0.9512	Class 0
0	0	1.0000	0	Class 1
0	0.9268	0	0.0732	Class 2
0.9756	0.0244	0	0	Class 3

$$\frac{Trace(Confidence\ Matrix)}{number\ of\ class} \times 100 = 96,34\% \quad (16)$$

جدول ۷- ماتریس اطمینان با در نظر گرفتن ۳۵۰ دینامیک و اعمال گشتاورها

Class 0	Class 0	Class 0	Class 0	
0	0.2439	0	0.7561	Class 0
0.0732	0	0.9268	0	Class 1
0.0732	0.5610	0.0244	0.3415	Class 2
0.9024	0.0488	0.0244	0.0244	Class 3

$$\frac{Trace(Confidence\ Matrix)}{number\ of\ class} \times 100 = 78,66\% \quad (17)$$

همان‌طور که دیده می‌شود، بدترین جواب‌ها با تعریف این پارامترها به دست آمد و حتی انتخاب ۷۰۰ دینامیک نیز جوابی به‌خوبی سایر روش‌ها نیز نمی‌دهد.

۵- جمع بندی

بررسی و توجه به صحت عملکرد بلبرینگ‌ها، یکی از کارهای بسیار مهم در جلوگیری از سوانح و کاهش هزینه‌ها است.

در این مقاله با آنالیز سیگنال حاصله از ارتعاشات آن با روش‌های LDA دینامیکی و PCA و آنالیز گشتاورها، سعی بر تشخیص و تفکیک عیب شده است.

در تمامی این روش‌ها برای طبقه‌بندی از طبقه‌بندی کننده خطی استفاده شده است. ولی برای مقایسه این سه روش می‌توان جدول زیر بررسی کرد:

جدول ۸- مقایسه روش‌های استفاده شده

روش مورد استفاده	تیس ماتریس اعتبار بدنه‌های	زمان تشخیص
روش PCA	99.38%	۷۰۰ سیمپل
روش Dynamic LDA	100%	۳۵۰ سیمپل
روش محاسبه گشتاوری و ...	96.34%	۷۰۰ سیمپل

همین‌طور که دیده می‌شود روش LDA دینامیکی بهترین پاسخ در زمان کمتری دارد و دلیل آن نوع راه‌حلی است که در این روش استفاده شده است؛ یعنی توجه به پراکندگی درون کلاسی در مقابل پراکندگی برون کلاسی.

۶- مراجع

- [۱] C. Qiu, X. Wu, C. Xu, X. Qiu, and Z. Xue, "An Approximate Estimation Approach of Fault Size for Spalled Ball Bearing in Induction Motor by Tracking Multiple Vibration Frequencies in Current," Sensors, vol. 20, p. 1631, 2020.
- [۲] L. Eren and M. J. Devaney, "Bearing damage detection via wavelet packet decomposition of the stator current, IEEE Transactions on Instrumentation and measurement, vol. 53, pp. 431-436, 2004.
- [۳] A. Hajary, R. Kianinezhad, S. G. Seifossadat, S. Mortazavi, and A. Saffarian, "Detection and localization of open-phase fault in three-phase induction motor drives using second order rotational park transformation, IEEE Transactions on Power Electronics, vol. 34, pp. 11241-11252, 2019.
- [۴] D. Wang, X. Zhao, L.-L. Kou, Y. Qin, Y. Zhao, and K.-L. Tsui, "A simple and fast guideline for generating enhanced/squared envelope spectra from spectral coherence for bearing fault diagnosis," Mechanical Systems and Signal Processing, vol. 122, pp. 754-768, 2019.
- [۵] X. He, S. Yan, Y. Hu, P. Niyogi, and H.-J. Zhang, "Face recognition using laplacianfaces," IEEE transactions on pattern analysis and machine intelligence, vol. 27, pp. 328-340, 2005.

- [^۶] A. R. Webb, Statistical pattern recognition: John Wiley & Sons, 2003.
- [^۷] Y. Bengio, A. Courville, and P. Vincent, "Representation learning: A review and new perspectives," IEEE transactions on pattern analysis and machine intelligence, vol. 35, pp. 1798-1828, 2013.
- [^۸] R. P. Good, D. Kost, and G. A. Cherry, "Introducing a unified PCA algorithm for model size reduction," IEEE Transactions on Semiconductor Manufacturing, vol. 23, pp. ۲۰۱-۲۰۹, ۲۰۱۰.
- [^۹] Y. Wang, D. Wu, and X. Yuan, "LDA-based deep transfer learning for fault diagnosis in industrial chemical processes," Computers & Chemical Engineering, vol. 140, p.106964, 2020.
- [^{۱۰}] م. تاج‌الدینی، عیب‌یابی بلبرینگ در سیستم‌های دینامیکی: پایان‌نامه مهندسی برق کنترل دانشگاه شیراز، ۱۳۹۱.