

مانیتورینگ ارتعاشات و تشخیص هوشمند خطا در بیرینگ ها با استفاده از کلاسیفایر Multi Class SVM به همراه معرفی ویژگی های تاثیر گذار سیگنال ارتعاش

امین کرمی

A.Karami.oce@gmail.com

چکیده

طراحی های نوین صنعتی با هدف افزایش سرعت و سطح تولیدات، موجب گسترش استفاده از بیرینگها در صنایع گردید. از سوی دیگر با استفاده بیشتر از بیرینگها، بزرگترین چالش فنی پیش رو شناسایی عیوب این قطعات پیش از آسیب های جدی می باشد. در این مقاله با طراحی یک سیستم مبتنی بر کلاسیفایر ماشین بردار پشتیبان چند کلاسه (Multi Class SVM) ضمن شناسایی به موقع عیوب ایجاد شده در بیرینگها، در صورت امکان نوع آن نیز مشخص گردد. با انتخاب روش Signal base به عنوان یکی از روش های بررسی شرایط کاری و طرح سوال اصلی چگونگی تشخیص خطای بیرینگها بصورت هوشمند، ۲۸۰ نمونه سیگنال ارتعاش از ۴ وضعیت بیرینگ در آزمایشگاه استخراج شد و سپس ویژگی های مختلف این سیگنال ها مورد تجزیه و تحلیل قرار گرفت. نتایج حاصل نشان دهنده توانایی کلاسیفایر انتخاب شده و تاثیر ویژگی های انتخابی در تشخیص هوشمند خطای بیرینگ ها می باشد. واژه های کلیدی: مانیتورینگ ارتعاش، تشخیص هوشمند خطا، کلاسیفایر Multi Class SVM.

مشخصه های سیستم از رفتار قابل قبول، معمولی یا استاندارد دانست. بنابراین، وقوع خطا در یک زیر سیستم، عموماً موجب ایجاد تغییر در راندمان کل سیستم می گردد. مساله دیگری که برای سیستم های کنترلی مورد توجه قرار می گیرد، Failure یا شکست سیستم می باشد. Fault سیستم را از حالت بازده قابل قبول به بازده پایین می برد، اما Failure سیستم را از بازده پایین یا غیر قابل قبول به منطقه خطر وارد می سازد. یکی از وظایف اصلی سیستم تشخیص خطا، جلوگیری از تبدیل شدن Fault به Failure می باشد.
[1]

با توجه به تعریف خطا و شکست، در صورت وقوع خطا در سیستم، اگر عملیات تشخیص به درستی صورت نگیرد، امکان تبدیل شدن آن به شکست وجود دارد، به همین منظور اپراتورها در صنایع با گذر زمان جای خود را به سیستم های هوشمند تشخیص خطا می دهند.

۱- مقدمه

در سال های اخیر با ابداع روش های خودکار شناسایی عیب، پیشرفت سریعی در زمینه بررسی شرایط کاری ماشین ها، ایجاد شده است. هدف تحقیقات جدید، بدست آوردن روش های دسته بندی ایاست که این سیگنال ها را در دسته هایی که هر کدام نشان دهنده یک نوع عیب می باشد، قرار دهند. روش های مختلفی برای تشخیص وقوع عیب و شناسایی نوع عیب و اندازه پیش رفتگی آن مطرح شده که با گذشت زمان قابلیت آنها افزوده شده و این روش ها جایگزین اپراتورها شده اند. آشنایی با انواع خطا پیش نیاز استفاده از روش های تشخیص خطا می باشد.

در حالت کلی، Fault چیزی است که رفتار سیستم را تغییر می دهد به نحوی که سیستم دیگر مقصود مورد نظر را برآورده نکند. Fault را می توان انحراف حداقل یکی از

جدول ۲: علل خرابی بیرینگ ها و درصد وقوع نسبی آنها

علت	درصد نسبی وقوع
سائیدگی	۲۵
شکست	۱۸
خوردگی	۸
تغییرشکل	۱۴
خردشدن	۱۲
ترک برداشتن	۱۲
DAG شدن	۱۱
سائیدگی	۲۵
شکست	۱۸
خوردگی	۸
تغییرشکل	۱۴
خردشدن	۱۲
ترک برداشتن	۱۲
DAG شدن	۱۱

عیوب در بیرینگ‌های غلتتشی ناشی از جدا شدن موضعی مواد، ترک‌های ناشی از خستگی روی سطوح تماس در بیرینگ، خرد شدن یا ترک برداشتن اجزاء غلتتشی می‌باشدند. پراژر تغییر در ساختمان هندسی بیرینگ، زمانی که سطوح آسیب دیده با هم درگیر می‌شوند، باعث تولید ضربه‌هایی می‌شوند. حاصل این ضربه‌ها، تولید امواج ارتعاشی و صوتی است که از طریق حلقه بیرونی و محفظه بیرینگ به بیرون منتشر می‌شوند. بعضی اوقات به این ضربه‌ها ضربه‌های لحظه‌ای یا شوک^۱ پالس می‌گویند. شوک پالس‌های حاصل از بیرینگ معیوب با پریود بسیار کوچک و میزان صعود سریع آنها در مقایسه با زمان تکرار شوک‌ها، مشخص می‌شوند. پریود شوک پالس‌ها در مقایسه با فاصله بین دو پالس بسیار کوچک است. [17]

هر یک از خطاهای بوجود آمده در بیرینگ منتشر کننده و یا تشدید کننده شوک پالس ویژه‌ای می‌باشد.

خطاهای رایج در بیرینگ‌ها شامل موارد ذیل می‌باشند:

- Scratch on Outer Race
- Scratch on Inner Race

در این مقاله سعی شده است تا با معرفی خطاهای رایج در بیرینگ‌ها و در کنار آن سیگنال‌های ارتعاش یافته توسط این خطاهای در سطح بیرینگ، یک سیستم هوشمند تشخیص خطاهای طراحی گردد تا بتواند در کنار شناسایی فرکانس‌های خطاهای (پیش از تبدیل شدن آنها به شکست)، نوع خطاهای خطا را نیز مشخص نماید. این توانمندی به طور یقین باعث کاهش دوره تعمیرات نیز خواهد گردید.

۲- بیرینگ‌ها

بیرینگ‌های غلتتشی از جمله اجزاء با عمر کاری محدود مашین‌ها به شمار می‌آیند و بنابراین جزء اقلام پرمصرف محسوب می‌گردند. نیاز به آنها زیاد و طول عمر مفید کاری آنها با درنظر گرفتن یک سری از عوامل اثر گذار کاهش عمر یابد. جدول ۱ نشان دهنده عوامل موثر بر کاهش طول عمر مفید کاری یک بیرینگ می‌باشد.

جدول ۱: عوامل موثر و تاثیرات آنها بر عمر کاری بیرینگ‌ها. [19]

عامل	اثر حاصل
ساخت	هموژن نبودن مواد تلرانس‌های ساخت بسته‌بندی نامناسب
حمل و نقل و انبارش	ارتعاش تغییر شکل
کارکرد	بارگذاری اولیه نادرست تلرانس هندسی خطاهای هم محوری بارگذاری بیش از حد روانکاری نادرست ذرات خارجی (کثافت) واسطه‌های خارجی (گازهای خونرده) روطوبت DAG شدن بیش از حد

با سپری شدن زمان، این عوامل باعث بروز آسیب در بیرینگ‌ها و سرانجام خرابی کلی در آنها، حتی در بیرینگ‌های با کیفیت بالا و گران قیمت می‌گردند. علل خرابی‌های کلی و درصد وقوع نسبی آنها در جدول ۲ لیست شده- [19] اند

در SVM بدبیال حل همزمان معادلات زیر هستیم:

با داشتن مثالهای آموزشی (x_i, y_i) که $i=1,2,\dots,N$ ؛

$$y_i \in \{+1, -1\} \text{ Minimise } \|w\|^2$$

$$\begin{aligned} \text{Subject to } & y_i (\langle w, x_i \rangle + b) \geq 1 \text{ for} \\ & \text{all } i \end{aligned} \quad (2)$$

$$\text{Note that } \|w\|^2 = w^T w$$

این یک مسئله quadratic programming با محدودیت هایی بصورت نامعادلات خطی است. روش‌های شناخته شده ای برای چنین مسئله هایی بوجود آمده اند.

برای برطرف کردن مشکل تفکیک ناپذیری داده‌ها، از روش C-SVM استفاده می‌شود که در آن مفهوم ابرصفحه جداگذاری بهینه کلی تر شده، بگونه‌ای که جواب مسئله از طریق مینیمم کردن تابعی که ترکیبی از دو ضابطه می‌باشد بدست می‌آید. این دو ضابطه عبارتند از: ماکزیمم کردن حاشیه (مانند حالت داده‌هایی با تفکیک پذیری خطی) و مینیمم کردن خطا (برای تعریف جرمیه به نمونه‌های با طبقه بندی اشتباه).تابع جدید بصورت زیر تعریف می‌شود:

[20]

$$\Psi(W, \xi) = \frac{1}{2} \|W\|^2 + C \sum_{i=1}^N \xi_i \quad (3)$$

یک راه حل این است که اندکی کوتاه آمده و مقداری خطا در دسته بندی را پذیریم!

این کار با معرفی متغیر x_i انجام می‌شود که نشانگر تعداد نمونه هایی است که توسط تابع $w^T x + b$ غلط ارزیابی می‌شوند.

با معرفی متغیر x_i ، $i=1, 2, \dots, N$ ، محدودیت های قبلی ساده تر شده و رابطه

$$y_i (\langle w, x_i \rangle + b) \geq 1 \quad (4)$$

بصورت زیر تغییر می‌کند:

$$x_i, x_i \geq 0 - y_i (\langle w, x_i \rangle + b) \geq 1 \quad (5)$$

- Scratch on one ball
- Improper lubrication
- Foreign material inclusion

در این مقاله به جهت نمونه برداری و تهیه داده‌های آزمایشگاهی چهار وضعیت یک بیرینگ در آزمایشگاه مورد سنجش قرار گرفت. در وضعیت اول یک بیرینگ سالم (NB) بر روی شفت موتور الکتریکی با دور ثابت ۱۴۰۰ دور بر دقیقه نصب گردید و از سوبی دیگر بر روی آن باری به وزن ۵۰۰ گرم نصب گردید. با افزایش بار موتور به صورت وزنه‌های ۱۰۰ گرمی (از ۵۰۰ گرم تا ۷۵۰۰ گرم) بوسیله سنسور ارتعاش سنجی تعییه شده در یاتاقان بیرینگ، از ارتعاشات موتور نمونه برداری شد بدین صورت ۷۰ نمونه از ارتعاشات یک بیرینگ سالم در دور ثابت ۱۴۰۰ دور بر دقیقه فراهم گردید. در وضعیت دوم بیرینگی مشابه از فقط با خراشیدگی بر روی حلقه خارجی (ORD) جایگزین بیرینگ سالم شد و مراحل تکرار گردید. در وضعیت سوم بیرینگ با خراش بر روی حلقه داخلی (IRD) جایگزین گردید و در وضعیت چهارم بیرینگ با خراش بر روی لعنزنه (BD) مورد استفاده قرار گرفت. در انتها ۲۸۰ نمونه سیگنال در چهار کلاس متفاوت از یک بیرینگ در وضعیت سالم و ۳ بیرینگ مشابه دیگر اما هر یک دارای خطایی مشخص فراهم گردید.

۳- انتخاب کلاسیفایر و ویژگی جهت پردازش سیگنال

SVM دسته بندی کننده ای است که جزو شاخه KernelMethods در بیانگیری ماشین محسوب می‌شود. SVM اصولاً یک کلاسیفیر خطی است که ایده اصلی آن ایجاد یک فوق صفحه به عنوان سطح تصمیم گیرنده می‌باشد؛ به طوری که حد تفکیک بین نمونه‌ها حداکثر شود.

یک مسئله طبقه‌بندی با نظارت دو کلاسه را در نظر بگیرید. فرض کنید مجموعه داده‌های آموزشی شامل N برداراز فضای ویژگی $\mathbf{x}_i \in \mathbb{R}^m$ می‌باشد. به هر یک از بردارهای \mathbf{x}_i یک برچسب $y_i \in \{1, -1\}$ نسبت داده می‌شود که کلاس مربوط به داده \mathbf{x}_i را نشان می‌دهد. تابع جداساز مربوط به ابر صفحه بهینه یک معادله وابسته به ضرایب لاگرانژ و نمونه‌های آموزشی است که مطابق رابطه زیر محاسبه می‌گردد:

$$\left[f(x) = \operatorname{sign} \left(\sum_{i=1}^N \alpha_i y_i \cdot (x \cdot x_i) + b \right) \right] \quad (1)$$

تنها فرق این حالت با حالت قبل این است که C به عنوان یک مرز بالایی برای ضرایب لاغرانژ عمل می‌کند. [20]

نوعی از توابع kernel، اجازه می‌دهند تا حل مساله ثانویه بطور قابل توجهی ساده شود. از آنجا که از محاسبه ضرب داخلی در فضای ترانسفر شده جلوگیری می‌کند، شکل C- مساله ثانویه که از تابع kernel استفاده می‌کند، برای SVM بصورت زیر خواهد بود.

$$\begin{aligned} \max_{\alpha \in \mathbb{R}^N} & \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j K(x_i, x_j) \\ \text{Subject to : } & 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N, \sum_{i=1}^N \alpha_i y_i = 0 \end{aligned} \quad (9)$$

نتیجه نهایی، یک تابع جداساز است که معمولاً تابعی از داده‌ها در فضای ویژگی اولیه با ابعاد کمتر است.

$$f(X) = \operatorname{sign}\left(\sum_{i \in S}^N y_i \alpha_i K(X, X_i) + b\right) \quad (10)$$

شکل هندسی تابع جداساز مرتبط با نوع تابع kernel تغییر می‌کند. یک تابع kernel معروف که دارای شرایط mercer می‌باشد تابع گوسی است که بصورت رابطه ذیل تعریف می‌شود.

$$K(X, X') = \exp\left(-\gamma \|X - X'\|^2\right) \quad (11)$$

از آنجا که روش SVM برای طبقه‌بندی بین دو کلاس طراحی شده است، کلیه اطلاعات را با لیبل گذاری ± 1 به دو دسته مجزا تقسیم می‌نماید. SVM در واقع نوعی کالسیفاير باپنری است و تحقیق در مورد چگونگی استفاده موثر از آن برای طبقه‌بندی چند کلاس‌ها هنوز در حال انجام می‌باشد.

تا به حال روش‌های مختلفی پیشنهاد شده است که در آن به طور معمول ما با ترکیب چند کالسیفاير باپنری یک کالسیفاير چند کلاسه در اختیار داریم. برخی از پژوهشگران نیز روشی را پیشنهاد می‌نمایند که در آن همه کلاس‌در یک مرحله در نظر گرفته شده است و از آن می‌توان به عنوان محاسبات حجمی برای حل مشکلات چند کلاس‌ها نام برد. این روش با استفاده از مشکلات در مقیاس بزرگ به طور جدی انجام آزمایش نشده است. به خصوص برای روش

در حالت ایده آل همه این متغیرها باید صفر باشند. [20]

در اینصورت مسئله بهینه سازی تبدیل می‌شود به یافتن w به نحوی که معادله زیر مینیمم شود:

$$\frac{1}{2} \|w\|^2 + C \sum_i \xi_i^2$$

$$\begin{aligned} \text{subject} \quad & To \\ & y_i(w^T x_i + b) \geq 1 - \xi_i, \quad \xi_i \geq 0, \quad \forall i \end{aligned}$$

که در آن $C > 0$ می‌باشد. جمله اضافه شدن سعی دارد تا حد امکان همه متغیرهای slack را کوچک نماید.

ξ_i که متغیرهای slack نامیده می‌شوند برای محاسبه تفکیک ناپذیری داده‌ها مطرح شده و ثابت C یک پارامتر تنظیم کننده می‌باشد که امکان کنترل جرمیمه مربوط به خطاهای را فراهم می‌کند. هر چقدر مقدار C بزرگ‌تر باشد، جرمیمه تعلق گرفته به نمونه‌های با طبقه پندی اشتباه نیز بیشتر می‌شود. قیود تابع هدف به صورت زیر می‌باشند:

$$\begin{aligned} & y_i(w^T x_i + b) \geq 1 - \xi_i, \quad i = 1, 2, \dots, N \\ & \xi_i \geq 0, \quad i = 1, 2, \dots, N. \end{aligned} \quad (7)$$

توجه شود که در حالت داده‌های ξ_i تفکیک ناپذیر ξ_i ، دو نوع support vector وجود دارد:

۱. Margin support vector که برروی حاشیه ابر صفحه قرار می‌گیرد.

۲. Nonmargin support vector که در طرف اشتباه این حاشیه قرار دارد.

چنانچه برای حل مساله فوق از ضرایب لاغرانژ استفاده کنیم در این صورت شکل مساله ثانویه به شکل زیر تبدیل می‌شود:

$$\begin{aligned} \max_{\alpha \in \mathbb{R}^N} & \sum_{i=1}^n \alpha_i - \frac{1}{2} \sum_{i=1}^N \sum_{j=1}^N \alpha_i \alpha_j y_i y_j (x_i \cdot x_j) \\ \text{subject to : } & \sum_{i=1}^N \alpha_i y_i = 0, 0 \leq \alpha_i \leq C, i = 1, 2, \dots, N \end{aligned} \quad (8)$$

از مجموع ۲۸۰ نمونه موجود، ۲۴۰ نمونه جهت آموزش کلاسیفیر و تعداد ۶۰ نمونه باقیمانده نیز برای تست کردن کلاسیفیر بکار رفت.

همان طور که در بخش ۲ عنوان شد، خطاهای مختلف بوجود آمده در بیرینگ‌ها تاثیرات متفاوتی بر فرکانس‌های ارتعاشات منتشر شده توسط بیرینگ می‌گذارد لذا به جهت تفکیک و تمایز آنها از یکدیگر نمی‌توان به سیگنال و یا تبدیلات حوزه فرکانس آن بسته نمود. از همین رو از سیگنال‌های اصلی تعداد ۱۲ ویژگی استخراج شد.

سپس Multi Class SVM با استفاده از ۱۲ ویژگی استخراج شده از سیگنال‌های آموزشی (۲۴۰ داده نمونه)، آموزش داده شد و پس از آن عملکرد کلاسیفیر بر روی داده‌های تست مشاهده شد.

تابع کرنل استفاده شده در این طراحی (کلاسیفیر Multi Class SVM) و ویژگی‌های سیگنال کرنل گوسی با پارامتر گوسی 0.005 بوده و مقدار C نیز برابر 500 در نظر گرفته شده است. در مرحله اول تجزیه و تحلیل، تمامی ۱۲ ویژگی استخراج شده از سیگنال ارتعاش مورد استفاده قرار گرفت. نتایج بدست آمده پس از اعمال سیگنال‌های تست در ورودی کلاسیفایر طی جدول صحت درستی، در جدول ۳ ارائه شده است.

جدول ۳: خروجی کلاسیفایر با استفاده از همه ویژگی‌های سیگنال

	BD	ORD	IRD	NB
BD	۱۰	۱	۱	۳
ORD	۱	۱۱		۳
IRD	.	۲	۱۰	۳
NB	.	۱	۰	۱۴

با توجه به نتایج بدست آمده از جدول ۳ مشخص شد، کلاسیفیر طراحی شده با استفاده از ۱۲ ویژگی دارای خطای برابر با ۲۵ درصد می‌باشد.

در مرحله بعد با توجه به تاثیر متفاوت هر یک از ویژگی‌ها بر نحوه کلاس‌بندی کلاسیفیر، بر آن شدیم تا با انتخاب بهترین ویژگی‌ها میزان خطای تشخیص و دسته‌بندی را کاهش دهیم، لذا ویژگی‌ها به صورت تک به تک انتخاب شد و تاثیر هریک بر نحوه کلاس‌بندی مورد بررسی قرار گرفت. درصد خطای بدست آمده در خروجی در لحظه استفاده از

های حل Multi Class SVM در یک مرحله، یک مسئله بهینه سازی بسیار بزرگ‌تر مورد نیاز است که تا به حال آزمایشات به مجموعه داده‌های کوچک محدود بوده است.

در مقاله‌ای از Chic-Jen Lin با پیاده‌سازی و تجزیه و تحلیل دو طبقه روش‌هایی با عنوان all-together ارائه شده است. سه روش مهم ارائه شده در این مقاله شامل روش‌های ذیل می‌باشد:

- ۱ یک در برابر همه (One-against-all)
- ۲ یک در مقابل یک (One-against-one)
- ۳ DAGSVM

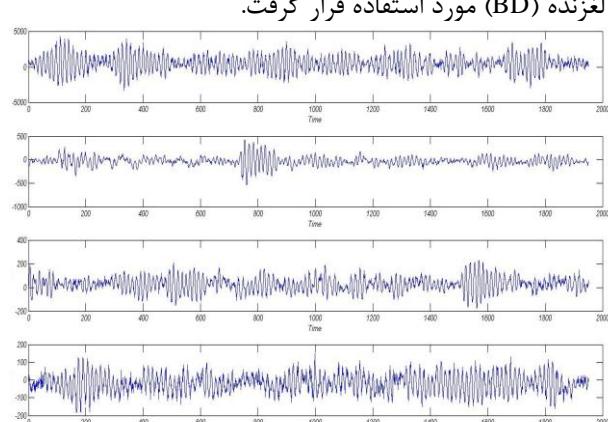
علاوه بر روش‌های ذکر شده در بالا، روش‌های دیگر برای پیاده‌سازی Multi Class SVM وجود دارد. در هر حال، با توجه به محدودیت در اینجا مانع توائیم بر روی همه روش‌ها تجزیه و تحلیل ارائه نماییم. [10]

در این مقاله جهت بکاربری Multi Class SVM از روش یک در برابر همه استفاده شده است.

۴- تحلیل بر اساس داده‌های آزمایشگاهی

در اینجا برآنیم تا با استفاده از نتایج آزمایشگاهی و تحلیل های صورت گرفته نشان دهیم کلاسیفیر پیشنهادی Multi Class SVM می‌تواند جهت تشخیص نوع خطای در بیرینگ ها مورد استفاده قرار گیرد و نتایج قابل قبولی ارائه نماید.

جهت معتبرسازی روش پیشنهادی، ۲۸۰ نمونه سیگنال از داده‌های ارتعاش حقیقی یاتاقان موتور، شامل ۴ کلاس -۱-داده‌های یاتاقان نرمال (NB)، -۲-داده‌های خراشیدگی بر روی حلقه خارجی (ORD)، -۳-داده‌های خراشیدگی بر روی حلقه داخلی (IRD) و -۴-داده‌های خراشیدگی بر روی لغزنده (BD) مورد استفاده قرار گرفت.



شکل: سیگنال استخراج شده به ترتیب NB، ORD، IRD و BD

سوم به معرفی کلاسیفایر استفاده شده و نحوه عملکرد آن پرداخته شد.

با توجه به اهمیت انتخاب ویژگی‌های مناسب از بین ویژگی‌های استخراج شده، با بکار بری روش‌های PCA به عنوان روش انتخاب ویژگی تاثیر هر یک از ویژگی‌ها بر خطای خروجی سنجیده شد و بهترین ویژگی‌ها انتخاب گردیدند.

در بخش تجزیخ و تحلیل نیز با طراحی یک کلاسیفایر Multi Class SVM و در نظر گرفتن ۴ حالت (۱) حالت سالم و سه خطای عده در بیانینگ‌ها و با درصد خطای قابل قبولی امکان تشخیص وقوع خطا و همچنین در کنار آن تشخیص نوع خطا حاصل شده است.

کلاسیفایر Multi Class SVM در مقایسه با روش‌های دیگری همچون تبدیلات فرکانس و تبدیل موجک و حتی نسبت به SVM دارای درصد خطای بسیار کمتری می‌باشد. البته این بهبود در نتایج به قیمت پیچیده‌تر شدن ساختار کلاسیفایر حاصل شده است. در واقع در این کلاسیفایر حجم محاسبات بسیار بیشتر از سایر روش‌ها می‌باشد.

جدول ۶: مقایسه روش‌های بکار رفته در مقاله

MEAN	GBR	IRD	ORD	BLD	Classifier
۷۱.۶۶۶	۸۶.۶۶۶	۶۶.۶۶۶	۶۶.۶۶۶	۶۶.۶۶۶	SVM
۷۵	۹۳.۳۳۳	۶۶.۶۶۶	۷۳.۳۳۳	۶۶.۶۶۶	M-Class (12 feature)
۸۰	۹۳.۳۳۳	۶۶.۶۶۶	۸۶.۶۶۶	۷۳.۳۳۳	M-Class (2 feature)

مراجع

- [1] Mogens Blanke, Michel Kinnaert, Jan Lunze, and Marcel Staroswiecki, 'Diagnosis and Fault-Tolerant Control,' 2nd Edition, Springer-Verlag Berlin Heidelberg 2006.
- [2] Williams, T., Ribadeneira, X., Billington, S., Kurfess, T., "Rolling element bearing diagnostics inrun-to-failure lifetime testing," Mechanical Systems and Signal Processing, v 15, n 5, Sept. 2001, 979-93.
- [3] Z.K. Peng, Peter W. Tse, F.L. Chu, 'A comparison study of improved Hilbert-Huang transform and wavelet transform: Application to fault diagnosis for rolling bearing,' Mechanical Systems and Signal Processing 19 (2005) 974-988.
- [4] Peng Z., Chu F., He Y., Vibration signal analysis and feature extraction based on re-assigned wavelet scalogram, Journal of Sound and Vibration 253 (5) 1087-1100, 2002.

کلاسیفایر با یک ویژگی سیگنال در جدول ۴ ارائه شده است.

جدول ۴: درصد خطای خروجی در کلاسیفایر با استفاده از ۱ ویژگی سیگنال

نوع ویژگی	درصد خطای خروجی کلاسیفایر
۲۵	Moment(2)
۲۵	Moment(3)
۲۵	Cov(signal)
۲۵	Moment(5)
۲۵	Moment(6)
۳۰	Zcr(signal)
۴۲.۳۳۳	Pr(signal)
۲۱.۶۶۶	Kurtosis(signal)
۲۵	Std(signal)
۳۱.۶۶۶	Mean(signal)
۲۵	Max(abs(signal))
۶۳.۳۳۳	Skewness(signal)

نتایج بدست آمده از جدول ۴ نیز، گفته قبلی را اثبات نمود و نشان داد کلاسیفایر Multi Class SVM در کلاس بندی بسیار متاثر از ویژگی انتخاب شده می‌باشد.

در هر حال نیاز به ویژگی‌هایی با درصد تفکیک دهنده‌گی بالا وجود دارد و برای این منظور از روش‌های انتخاب ویژگی نظری PCA استفاده شد. در نهایت بهترین عملکرد کلاسیفایر Kurtosis و Max(abs) با انتخاب و استفاده از دو ویژگی (Max(abs) و Kurtosis) بدست آمد که نتایج آن در جدول ۵ ارائه شده است.

جدول ۵: خروجی کلاسیفایر پس از انتخاب و استفاده از دو ویژگی Kurtosis و Max(abs)

	BD	ORD	IRD	NB
BD	۱۱	۱	.	۳
ORD	.	۱۳	.	۲
IRD	.	۲	۱۰	۳
NB	.	۱	.	۱۴

۵- نتیجه گیری

در این مقاله سعی شد با دیدگاه Signal Based و ارائه یک کلاسیفایر جدید بر مبنای Multi Class SVM به بررسی تشخیص و شناسایی عیب در بیانینگ‌ها پرداخته شود. برای این منظور ابتدا به بررسی شرایط مختلف یک کاری یک بیانینگ و معرفی خطاهای رایج در آن پرداختیم و در بخش

- [20] M.L.Sin, W.L.Swong, N.Eartugrul, University of Adelaide, "Induction Machine Online Condition Monitoring and Fault Diagnosis-Survey in 2003."
- [21] J. Zarei, J. Poshtan, "Bearing fault detection using waveletpacket transform of induction motor stator current," Journalof Tribology International, Vol. 40(5), pp. 763-769, May2007.
- [5] Yu Dejie, Cheng Junsheng, Yang Yu., 'Application of EMD method and Hilbert spectrum to the fault diagnosis of roller bearings,' Mechanical Systems and Signal Processing 19, 259–270, 2005.
- [6] V.K. Rai& A.R. Mohanty, 'Bearing fault diagnosis using FFT of intrinsic mode functions in Hilbert–Huang transform,' Mechanical Systems and Signal Processing 21, 2607–2615, 2007.
- [7] Cheng Junsheng, Yu Dejie, Yang Yu, 'A fault diagnosis approach for roller bearings based on EMD method and AR model,' Mechanical Systems and Signal Processing 20 (2006) 350–362.
- [8] Cheng Junsheng, Yu Dejie, Yang Yu, ' The envelope order spectrum based on generalized demodulation time–frequency analysis and its application to gear fault diagnosis,' Mechanical Systems and Signal Processing 24 (2010) 508–521.
- [9] Jin-II Park and Myung-Geun Chun, Fault Diagnosis of Induction Motor using C-Fuzzy Model Tree and SVM, ISIS 2007 .
- [10] J. Cheng, Y. Yang & D. Yu, "Application of support vector regression machines to the processing of end effects of Hilbert–Huang transform," Mechanical Systems and Signal Processing 21, 1197–1211, 2007.
- [11] R.B.W. Heng, M.J.M. Nor, Statistical analysis of sound and vibration signals for monitoring rolling element bearing condition,Applied Acoustics 53 (1998) 211–226.
- [12] F. Honarvar, H.R. Martin, New statistical moments for diagnostics of rolling element bearings, Journal ofManufacturing Science and Engineering 119 (1997) 425–432.
- [13] H.R. Martin, F. Honarvar, Application of statistical moments to bearing failure detection,Applied Acoustics 44(1995) 67–77.
- [14] Loparo, K. (2004). Bearing fault diagnosis based on wavelet transform and fuzzyinference. Mechanical Systems and Signal Processing, 18, 1077–1095.
- [15] Mallat, S. G. (1989). IEEE Transactions on Pattern Analysis on Machine Intelligent, 11–17, 674–693.
- [16] B. Yazici, G. B. Kliman, "An adaptive statistical timefrequencymethod for detection of broken bars and bearingfaults in motors," IEEE Trans.On Industry App., vol. 35, no.2, March/April 1999.
- [17] S. Prabhakar, A. R. Mohanty, A. S Sekhar, "Application ofdiscrete wavelet transform for detection of ball bearing racefaults," Journal of Tribology International, vol. 35(12), pp.793-800 December 2002.
- [18] B.A. Paya, I.L. Esat, M.N.M. Madi, Artificial neuralnetwork based fault diagnostics of rotating machinery usingwavelet transforms as a processor, Mechanical Systems and Signal Processing 11 (1997) 751–765.
- [19] Peter W. Tse, Y.H. Peng, Richard Yam, Wavelet analysisand envelope detection for rolling element bearing for rollingelement bearing fault diagnosis – their affectivities andflexibilities, Journal of Vibration and Acoustic 123 (2001) 303–310.