

تشخیص، شناسایی و جداسازی عیب توربین گاز پالایشگاه دوم پارس جنوبی با استفاده از روش‌های ترکیبی داده‌کاوی، k-means، تحلیل مؤلفه‌های اصلی (PCA) و ماشین بردار پشتیبان (SVM)

مرتضی خرم کشکولی^۱، دانشجوی کارشناسی ارشد؛ مریم دهقانی^۲، دانشیار

۱- دانشکده آموزش‌های الکترونیکی - دانشگاه شیراز - شیراز - ایران - morteza.khorram.k@gmail.com

۲- دانشکده مهندسی برق و کامپیوتر - دانشگاه شیراز - شیراز - ایران - mdehghani@shirazu.ac.ir

چکیده: در این مقاله، به تشخیص، شناسایی و جداسازی عیب توربین گاز پرداخته شده است. در ابتدا، با استفاده از الگوریتم k-means، به کاهش بعد داده‌های اولیه پرداخته شده و سپس با پیاده‌سازی تحلیل مؤلفه‌های اصلی (PCA)، دانشی که درون داده‌های شرایط عملیاتی نرمال توربین پنهان بوده استخراج و با استفاده از آن به تشخیص و شناسایی عیب توربین گاز پرداخته شده است. در مرحله بعد، با به‌کارگیری ابزار ماشین بردار پشتیبان (SVM)، جداسازی عیب توربین گاز انجام شده است. استفاده ترکیبی از فنون داده‌کاوی و بهره‌گیری از نقاط قوت فنون به‌کاربرده شده، از نکات بارز این مقاله است. سامانه‌های مورد مطالعه، توربین گاز مدل MS6001 از شرکت جنرال الکتریک و توربین گاز مدل MS5002C از شرکت Nuovo Pignone، به ترتیب در واحد نیروگاه و ایستگاه تقویت فشار و صادرات گاز پالایشگاه دوم پارس جنوبی بوده و با توجه به دانش علمی و تجربی، سیگنال‌های مهم انتخاب و تجهیزات لازم جهت ثبت آنان توسط نویسندگان روی توربین‌های گاز به صورت عملی پیاده‌سازی و آزمایش شده و نتایج روش پیشنهادی، در این مقاله آورده شده است.

واژه‌های کلیدی: تحلیل مؤلفه‌های اصلی، توربین گاز، شناسایی و تشخیص عیب، جداسازی عیب، خوشه‌بندی، داده‌کاوی، ماشین بردار پشتیبان.

Fault Detection, Identification and Isolation of South Pars Gas Turbine Using a Combined Method Based on the Data Mining Techniques, k-means, PCA and SVM

M. Khorram Kashkooli¹, MSc Student; M. Dehghani², Associate Professor

1- School of E-Learning, Shiraz University, Shiraz, Iran, Email: morteza.khorram.k@gmail.com

2- School of Electrical and Computer Engineering, Shiraz University, Shiraz, Iran, Email: mdehghani@shirazu.ac.ir

Abstract: In this paper, fault detection, identification and isolation of gas turbines has been investigated. At first, by using k-means algorithm, dimension of primary data is reduced and then with the implementation of principal component analysis (PCA), the knowledge hidden in the data of normal operating conditions of gas turbine, is extracted and faults in the gas turbine have been detected. Then, in the next step, by applying support vector machine (SVM), the detected faults are isolated. Using the combination of data mining techniques and utilizing strong points of these techniques are highlighted points of this paper. Two real systems, GE gas turbine MS6001 and Nuovo Pignone Gas turbine MS5002C, which are located in power generation unit and gas station in second refinery of south Pars are considered. Based on scientific and empirical knowledge, signals are selected and required devices for recording them is implemented on gas turbines by authors. The results of the proposed method are included in the paper.

Keywords: Gas turbine, fault detection and isolation, clustering, data mining, principal component analysis (PCA), support vector machine (SVM).

تاریخ ارسال مقاله: ۱۳۹۴/۱۱/۰۲

تاریخ اصلاح مقاله: ۱۳۹۵/۰۳/۱۷

تاریخ پذیرش مقاله: ۱۳۹۵/۰۵/۰۳

نام نویسنده مسئول: مریم دهقانی

نشانی نویسنده مسئول: ایران - شیراز - دانشگاه شیراز - دانشکده مهندسی برق و کامپیوتر - گروه مهندسی قدرت و کنترل.

۱- مقدمه

شناسایی و تشخیص عیب، مؤلفه مرکزی مدیریت رخدادهای غیرنرمال^۱ است که در سالهای اخیر توجه زیادی را به خود جلب کرده است. توربینهای گازی نقشی بسیار مهم و حیاتی در صنایع نفت، گاز، پتروشیمی و نیرو ایفا می کنند. مدیریت رفتارهای دینامیکی و پیچیده توربینهای گازی، نیازمند سامانههای کنترل، حفاظت و مانیتورینگ با قابلیت اطمینان، انعطاف، برنامه ریزی و دسترس پذیری بالاست. از آنجا که هرگونه عیب در توربین گاز و در عملیات^۲ و سامانههای کنترل و حفاظت آن، عواقب سنگینی را در پی خواهد داشت؛ تشخیص و شناسایی عیب، یک مسئله بسیار مهم در توربینهای گازی است و با شناسایی و تشخیص خطای به موقع و تصحیح شرایط غیرنرمال، عملیاتی دقیق، سود بالاتر و کارکردی ایمن تر به دست خواهد آمد.

بحث تشخیص عیب توربین گاز، قبلاً در مقالات و تحقیقات متعددی بر پایه مدل و در حوزه داده کاوی و بر مبنای داده های فرآیندی انجام شده است. در [۱]، سیستم تشخیص خطا مبتنی بر مدل برای زیرسیستم های نیروگاهی طراحی شده است. مرجع [۲]، توسعه و شبیه سازی سیستم پایش عملکرد و تشخیص خطا در اجزای مختلف توربین گازی را با کمک روش مبتنی بر شبکه های عصبی انجام داده است. در مرجع [۳]، با استفاده از رهیافت شناسایی زیرفضاها در زیرسیستم نیروگاهی بویلر بازباب حرارتی، شناسایی و تشخیص برخط خطا مطالعه شده است. در [۴] ترکیب تحلیل مؤلفه های اصلی (PCA) و فیلتر کالمن برای تشخیص عیب برخط موتور هواپیما به کار برده شده است. مرجع [۵] روش های درخت تصمیم گیری (DT) و تحلیل همبستگی (CA) را برای استخراج ویژگی و ماشین بردار پشتیبان (SVM) را برای تشخیص عیب تجهیزات در یک نیروگاه حرارتی، پیشنهاد داده است. مرجع [۶] از PCA برای تشخیص عیب و از Structured Residual برای جداسازی عیب بهره گرفته است. در [۷] از PCA برای کاهش بعد و از ICA برای تشخیص عیب استفاده کرده است. در [۸]، از فن های PCA و y-distance برای تشخیص عیب حسگر توربین گاز صنعتی استفاده شده است. مرجع [۹] فن PCA را برای پیش بینی اندیس SPE (Square Prediction Error) و SVM را برای تشخیص عیب توربین گاز به کار برده است. مرجع [۱۰]، PCA و SVM را به صورت جداگانه برای تشخیص عیب در بویلرهای نیروگاه سیکل ترکیبی کرمان به کار برده است. در [۱۱]، از EEMD (Ensemble Empirical Mode Decomposition) برای استخراج ویژگی و از SVM برای تشخیص عیب استفاده شده است. مقاله [۱۲]، FCM (Fuzz C-Mean) را برای خوشه بندی داده ها و SVM را برای تشخیص عیب به کار گرفته است. در مرجع [۱۳]، تشخیص و جداسازی عیب حسگر یک توربین گاز صنعتی با استفاده از Partial kernel PCA انجام شده است. در نهایت در مقاله [۱۴]، تشخیص عیب توربین گاز با

شناسایی الگو در سری های زمانی چندمتغیره، مورد پژوهش قرار گرفته است.

در این مقاله کاربردی که بر مبنای داده های فرآیندی واقعی و شناخت کامل و تجربی رفتار توربین گاز است، از سه روش داده کاوی PCA، k-means و SVM به صورت ترکیبی استفاده شده است. برای وجه تمایز نوآوری ها و دستاوردهای این مقاله، به هشت نکته زیر می توان اشاره کرد:

۱- به سه مبحث تشخیص، شناسایی و جداسازی عیب توربین گاز از دیدگاه داده کاوی به طور کامل پرداخته شده که چنین رویکردی در مقالات پیشین مشاهده نمی شود.

۲- در کارهای پیشین از k-means برای کاهش بعد داده ها استفاده نشده است.

۳- با استفاده از SVM، جداسازی و تعیین کلاس عیب انجام شده که این امر، محدوده و زمان تعمیرات را به طور محسوسی کاهش خواهد داد.

۴- با مطالعه دقیق و عمیق سامانه مورد مطالعه اول و نفوذ در سامانه مانیتورینگ و ایجاد یک Batch فایل اجرایی، حجم قابل ملاحظه ای از داده عملیاتی ثبت شده است.

۵- با نصب، پیکربندی و راه اندازی یک سامانه HMI موازی و پیاده سازی پایگاه داده در سامانه مورد مطالعه دوم و اتصال آن به نرم افزار مانیتورینگ، داده های دمایی به منظور بررسی تخصصی تر مسئله تشخیص عیب، ثبت شده اند.

۶- با اتصال نرم افزار متلب به پایگاه داده، تشخیص عیب برخط توربین گاز انجام شده است.


۷- اطلاعات نرمال بودن توربین گاز، به صورت مقادیر ویژه و بردارهای ویژه ماتریس کوواریانس ظاهر شده است.

۸- با پشتوانه علمی، تجربی و شناخت دقیق توربین گاز، دو سامانه با دو کاربرد متفاوت انتخاب و مسئله تشخیص عیب به صورت کاربردی انجام شده است. کاربرد اول، نیروگاه های تولید برق و کاربرد دوم، ایستگاه های تقویت فشار گاز در خروجی پالایشگاه های گاز و خطوط سراسری انتقال گاز را شامل می شود و داده های اولیه، شامل تست کامل راه اندازی، بارگیری و کاهش بار در این دو مدل توربین گاز با دو کاربرد متفاوت است.

ساختار این مقاله بدین صورت است که در بخش دوم به معرفی سامانه های مورد مطالعه پرداخته شده است. در بخش سوم، مسئله تشخیص عیب بررسی شده و فنون تئوری بیان شده اند. در بخش چهارم، روش پیشنهادی ارائه شده است و در قسمت اول این بخش نحوه ثبت سیگنال ها به طور مفصل بیان شده است. در بخش پنجم، نتایج پیاده سازی بر روی توربین گاز واقعی آورده شده که شامل دو مدل توربین گاز است که توربین اول در واحد نیروگاه و توربین دوم در ایستگاه تقویت فشار و صادرات گاز پالایشگاه دوم پارس جنوبی واقع شده است و بخش ششم نتیجه گیری نهایی است.

۲- سامانه‌های مورد مطالعه

توربوکمپرسور MS5002C، یک توربین با دو محور است که برای درایو یک کمپرسور گاز جریان محوری پنج‌مرحله‌ای به کار می‌رود که گاز پالایش‌شده با فشار ۵۸ الی ۶۰ بار را به فشار ۸۸ الی ۹۰ بار می‌رساند و وارد خط سراسری گاز می‌کند. دور نامی این توربین ۵۱۰۰ دور در دقیقه (rpm) است و چهار قسمت کنترلی آن الکتروهایدرولیکی است و دارای ۶ حلقه کنترلی مانند توربین قبلی است.



شکل ۲: شماتیک کلی سامانه کنترل و مانیتورینگ توربین گاز مدل MS5002C شرکت Nuovo Pignone، سامانه مورد مطالعه دوم.


در اینجا خاطرنشان می‌شود که سامانه‌های مورد مطالعه یعنی توربین‌های گاز مدل MS5002C و MS6001 در قسمت کنترل دارای سامانه افزونگی سه‌تایی^۲ (TMR) می‌باشند. به این معنی که سه کنترلر S، R و T به کنترل توربین گاز مشغول‌اند. در قسمت حسگرها نیز بر طبق صلاح‌دید شرکت سازنده، افزونگی‌های مختلف انجام شده است. برای مثال، حسگر اندازه‌گیری فیدبک شیرهای کنترلی (LVDT)، دوتایی هستند و برای اندازه‌گیری سرعت توربین که از مهم‌ترین المان‌های توربین است، از سه حسگر Magnetic pickup استفاده شده است. (تصویر واقعی سامانه کنترل و مانیتورینگ توربین

در شکل ۳، نشان داده شده است).

با توجه به شکل ۳، شماره‌های ۱، ۲ و ۳ هسته‌های کنترلی S، R و T در سامانه کنترل توربین گاز SPEEDTRONIC را نشان می‌دهند. شماره ۴ هسته Common را نشان می‌دهد که جهت ارتباط با HMI و همچنین پردازش سیگنال‌های Non-Critical است. شماره ۵ هسته حفاظتی را نشان می‌دهد. شماره ۶ هسته منبع تغذیه است. شماره‌های ۷ و ۸، هسته I/Oهای دیجیتال است. در نهایت شماره ۹ سامانه HMI است که با کارت شبکه ARCNET به PLC متصل می‌شود.

سامانه‌های مورد مطالعه، دو مدل توربین گاز با دو کاربرد متفاوت هستند که در مورد اول، سامانه یک توربین گاز در کاربرد توربوژنراتور است که برای تولید برق بوده و دارای توان نامی ۳۹ مگاوات (در شرایط استاندارد) است. این توربین گاز ساخت شرکت جنرال الکتریک (GE) و مدل آن MS6001 و در واحد نیروگاه پالایشگاه دوم پارس جنوبی واقع شده است. سامانه کنترل و حفاظت این توربین SPEEDTRONIC Mark V و سامانه مانیتورینگ آن IDOS است (شکل ۱) که این سامانه‌ها، سامانه‌های خاص کنترل، حفاظت و مانیتورینگ توربین گاز از شرکت جنرال الکتریک است. شبکه‌ای که بین سامانه‌های کنترل و مانیتورینگ به تبادل داده می‌پردازد، شبکه ARCNET از خانواده Stage link با نرخ انتقال داده ۲/۵ Mb/s است.

راه‌انداز توربین گاز MS6001 یک الکتروموتور ۶ کیلوولت بوده، دور نامی این توربین ۵۱۶۳ دور در دقیقه (rpm) است و سه قسمت اصلی و کنترلی آن الکتروهایدرولیکی است. فشار سیستم هیدرولیک این توربین برای انجام دستورات کنترلی ۸۷ بار است. دارای ۶ حلقه کنترلی سرعت، دما، راه‌انداز (Start-up)، شتاب، خاموش (shut down) و دستی (Manual) است.




شکل ۱: شماتیک کلی سامانه کنترل و مانیتورینگ توربین گاز مدل MS6001 شرکت جنرال الکتریک، سامانه مورد مطالعه اول.

در مورد دوم، سامانه یک توربین گاز در کاربرد توربوکمپرسور است که به‌منظور فشرده‌سازی گاز و تزریق آن به خط لوله سراسری گاز بوده و دارای توان نامی ۲۵ مگاوات است. این توربین، ساخت شرکت Nuovo Pignone (تحت لیسانس GE) و مدل آن MS5002C و در ایستگاه تقویت فشار و صادرات گاز پالایشگاه دوم پارس جنوبی واقع شده است. سامانه کنترل و حفاظت این توربین نیز SPEEDTRONIC Mark V و سامانه مانیتورینگ آن Cimplicity و شبکه آن همانند توربین قبلی ARCNET با همان نرخ انتقال داده است (شکل ۲).

تصادفی، قطعی^۹ و سیستماتیک طبقه‌بندی می‌شوند. معمولاً یک failure بعد از شروع عملیات یا با افزایش استرس سیستم ایجاد می‌شود [۱۶].

یک malfunction نامنظمی متناوب در انجام وظیفه یک سیستم از کارکرد مطلوب است. Malfunction یک وقفه موقتی کارکرد سیستم است و مانند failure یک رخداد است و نتیجه یک یا چند عیب است و بعد از شروع عملیات یا با افزایش استرس سیستم ایجاد می‌شود [۱۶]. شکل ۴ فرق میان عیب، failure و Malfunction و نحوه توسعه عیب را نشان می‌دهد.



شکل ۴: عیب، failure و Malfunction، توسعه عیب به صورت پله‌ای (stepwise) و انحرافی (driftwise) [۱۶].

مراحل تشخیص، شناسایی و جداسازی عیب به این صورت است که در مرحله اول، بایستی وقوع عیب تشخیص داده شود (تشخیص عیب^{۱۰}). در مرحله دوم معلوم شود چه متغیر یا متغیرهایی از فرآیند با این عیب مرتبط است (شناسایی عیب^{۱۱}). در مرحله سوم تعیین می‌شود که عیب اتفاق افتاده کدام کلاس عیب است (جداسازی عیب^{۱۲}). در مرحله چهارم، فرآیند اصلاح شده و به حالت نرمال برمی‌گردد (اصلاح فرآیند^{۱۳}) [۷].



شکل ۳: سامانه کنترل و مانیتورینگ توربین گاز، SPEEDTRONIC.


۳- مسئله تشخیص، شناسایی و جداسازی عیب

در بحث تشخیص عیب با مفاهیم و اصطلاحاتی برخورد می‌شود که بایستی تعریف شوند و مرز میان آن‌ها مشخص شوند. در این بخش به اختصار به بیان تعاریف و مفاهیم پرداخته می‌شود.

عیب یا فالت: یک انحراف بدون اجازه^۴ از حداقل یکی از مشخصه‌ها یا پارامترهای سیستم از شرایط استاندارد، معمول یا قابل قبول^۵ است [۱۵]. عیب یک حالت یا state درون سیستم است و مستقل است از این که سیستم در حال عملیات باشد و ممکن است در عملکرد صحیح سیستم تأثیر نداشته باشد (عیب پنهان). عیب‌های مکرر^۶ به سستی شناسایی می‌شوند؛ به‌ویژه اگر کوچک و یا مخفی باشند. عیب‌ها ممکن است به صورت ناگهانی^۷ (پله‌ای) یا به آرامی^۸ توسعه یابند و ممکن است آغازی بر failure و یا malfunction باشند [۱۶] (شکل ۴).

یک failure، خاتمه توانایی یک واحد کارکردی در انجام عملکرد صحیح است. یک failure یک رخداد (event) است و نتیجه یک یا چند عیب یا فالت است. انواع متفاوت failureها، می‌توانند بر اساس شمار failure و یا قابلیت پیش‌بینی، مجزا شوند. ممکن است یک یا چندگانه باشند و بر اساس قابلیت پیش‌بینی به سه گونه failureهای

PCA برای تشخیص عیب و از SVM برای جداسازی عیب، بهره گرفته شده که در قسمت بعدی به شرح این فنون خواهیم پرداخت.



شکل ۵: طبقه‌بندی روش‌های تشخیص و جداسازی عیب [۱۹].

۳-۱- الگوریتم خوشه‌بندی k-means

خوشه‌بندی^{۱۹} یکی از شاخه‌های یادگیری بدون نظارت است و فرآیند خودکاری است که در طی آن، نمونه‌ها به دسته‌هایی که اعضای آن مشابه یکدیگر می‌باشند؛ تقسیم می‌شوند که به این دسته‌ها، خوشه گفته می‌شود. بنابراین، خوشه، مجموعه‌ای از اشیاء یا نمونه‌ها می‌باشد که در آن، اشیاء یا نمونه‌ها با یکدیگر مشابه بوده و با اشیاء یا نمونه‌های موجود در خوشه‌های دیگر غیرمشابه می‌باشند. برای مشابه بودن می‌توان معیارهای مختلفی را در نظر گرفت؛ مثلاً می‌توان معیار فاصله را برای خوشه‌بندی مورد استفاده قرار داد و اشیاء یا نمونه‌هایی را که به یکدیگر نزدیک‌تر هستند؛ به‌عنوان یک خوشه در نظر گرفت که به این نوع خوشه‌بندی، خوشه‌بندی مبتنی بر فاصله نیز گفته می‌شود [۲۰].

روش خوشه‌بندی k-means کاربردهای فراوانی دارد؛ از جمله در پردازش تصویر و در موضوع ادغام تصویر چندفوکوسی. برای افزایش سرعت الگوریتم در مرحله تصمیم‌گیری، بلوک‌های مطلوب با تعیین آستانه مناسب و بلوک‌های دیگر طی یک فرآیند تکراری با استفاده از الگوریتم k-Means انتخاب شده و عملیات ادغام انجام می‌شود [۲۱].

چنانچه بخواهیم خوشه‌بندی را در مقابل دسته‌بندی^{۲۰} مورد مقایسه قرار دهیم، می‌بایست عنوان کنیم که در دسته‌بندی، هر داده به یک طبقه (دسته) از پیش مشخص شده تخصیص می‌یابد؛ ولی در خوشه‌بندی، هیچ اطلاعی از خوشه‌ها وجود ندارد و به عبارتی، خود خوشه‌ها نیز از داده‌ها استخراج می‌شوند. در دسته‌بندی، مفهوم دسته

عیب‌ها می‌توانند جمع‌شونده یا ضرب‌شونده باشند که تفاوت‌های اساسی بین عیب‌های جمع‌شونده و ضرب‌شونده وجود دارد. یکی از این تفاوت‌ها این است که عیب‌های ضرب‌شونده ممکن است ساختار سیستم را تغییر دهند. به‌منظور ارائه یک تعریف واحد که برای هر دو نوع عیب جمع‌شونده و ضرب‌شونده معتبر باشد؛ در ابتدا توجه به مفهوم قابلیت تشخیص عیب^{۲۱}، معطوف می‌شود. اولاً بایستی معلوم شود که قابلیت تشخیص عیب سیستم به‌عنوان یک خصوصیت ساختاری سیستم مورد نظر، چگونه بر رفتار سیستم تأثیر می‌گذارد و بایستی مستقل از متغیرهای ورودی سیستم، اغتشاشات و همین‌طور عدم قطعیت مدل، بیان شود. ثانیاً، در صورتی که عیبی باعث تغییر در خروجی سیستم شود، قابلیت تشخیص عیب سیستم بایستی نشان داده شود. در نهایت بایستی مستقل از نوع و اندازه عیب بیان شود. تعریفی از قابلیت تشخیص عیب سیستم پذیرفته می‌شود که می‌گوید: یک فالت قابل تشخیص است؛ اگر وقوع آن مستقل از اندازه و نوع، باعث تغییر در رفتار نامی خروجی سیستم شود [۱۷]. این موضوع بیشتر در روش‌های تشخیص عیب بر پایه مدل، خود را نشان می‌دهد.

جداسازی عیب بر پایه سیگنال‌های تولیدشده از الگوریتم‌های تشخیص عیب انجام می‌شود. دانش ارتباط موجود بین سیگنال‌های عیب‌یابی و عیب‌ها یا حالت‌های سیستم برای انجام وظیفه جداسازی عیب، ضروری است. به‌دلیل دانش ناکامل سیستم، محدودیت مجزاسازی عیب‌ها و حالت‌ها، عدم قطعیت سیگنال‌های عیب‌یابی و غیره، یک ارائه غیرمبهم و کاملاً قابل اطمینان از عیب‌ها یا تعریف حالت سیستم عیب‌یابی‌شده امکان‌پذیر نیست. گستره وسیعی از روش‌های جداسازی عیب وجود دارد که Balle و Isermann در سال ۱۹۶۶ این روش‌ها را در دو گروه، متمایز کردند: روش‌های طبقه‌بندی (روش‌های رده‌بندی) و روش‌های نتیجه‌گیری خودکار^{۱۵}. یکی از اهداف معمول در جداسازی عیب، قابلیت مجزاسازی^{۱۶} همه عیب‌هاست. دقت سیستم تشخیص عیب با شمار عیب‌های نشان‌داده‌شده در عیب‌یابی، تعریف می‌شود [۱۸].

به‌طور کلی روش‌ها و رویکردهای مختلفی در تشخیص، شناسایی و جداسازی عیب وجود دارد که به دو دسته کلی بر مبنای مدل^{۱۷} و درآیوشده از داده‌ها و گذشته فرآیندی^{۱۸} تقسیم‌بندی می‌شوند. هر کدام از این روش‌ها به زیرشاخه‌های دیگری دسته‌بندی می‌شوند که در شکل ۵ نشان داده شده است [۱۹].

در روش‌های بر پایه مدل، مدلی ریاضیاتی از سیستم استفاده می‌شود که این مدل می‌تواند کمی و یا کیفی، خطی و یا غیرخطی باشد. در روش‌های درآیوشده از داده‌ها و یا بر مبنای گذشته فرآیندی، که روش‌های داده‌کاوی نیز نامیده می‌شود؛ مدلی در نظر گرفته نمی‌شود و بر اساس حجمی از داده‌های سامانه مورد مطالعه، پردازش و تصمیم‌گیری می‌شود.

در این مقاله، که در قسمت روش‌های درآیوشده از داده‌ها (داده‌کاوی) طبقه‌بندی می‌شود؛ از فنون k-means برای کاهش بعد،

ماشین بردار پشتیبان، روشی است که برای دسته‌بندی داده‌های خطی و غیرخطی به کار می‌رود. به‌اختصار، SVM الگوریتمی است که به کمک یک نگاشت غیرخطی، داده‌های آموزشی اولیه را به یک بعد بالاتر تبدیل می‌کند و در بعد جدید به دنبال ابرصفحه‌ای (Hyperplane) بهینه می‌گردد که داده‌های یک کلاس را از کلاس دیگر جدا کند. با یک نگاشت غیرخطی مناسب به یک فضای با بعد بالای کافی، داده‌های دو کلاس را همیشه می‌توان به کمک یک ابرصفحه از هم جدا نمود. الگوریتم SVM، این ابرصفحه را به کمک بردارهای پشتیبان و حاشیه‌ها می‌یابد [۲۲]. شکل ۶ جداسازی غیرخطی دو کلاس را در فضای دوبعدی نشان می‌دهد.

در حل مسئله بهینه‌سازی درجه دوم مربوط به SVM خطی (هنگام جستجو برای یک SVM خطی در فضای جدید و با ابعاد بالاتر) عضوهای آموزشی تنها در شکل ضرب برداری $\phi(x_i) \cdot \phi(x_j)$ ظاهر می‌شوند که در آن، $\phi(x)$ یک تابع نگاشت غیرخطی ساده است که برای تبدیل عضوهای آموزشی استفاده می‌شود. حال به جای ضرب برداری می‌توان از یک تابع کرنل $K(x_i, x_j)$ برای این کار استفاده کرد.

$$K(x_i, x_j) = \phi(x_i) \cdot \phi(x_j) \quad (2)$$


برخی توابع کرنل که از آن‌ها استفاده می‌شود، عبارت‌اند از:

$$K(x_i, x_j) = (x_i \cdot x_j + 1)^h \quad (3)$$

$$K(x_i, x_j) = e^{-\frac{\|x_i - x_j\|^2}{2\sigma^2}} \quad (4)$$

$$K(x_i, x_j) = \tanh(\kappa x_i \cdot x_j - \delta) \quad (5)$$

که به ترتیب با نام‌های کرنل چندجمله‌ای از درجه h ، کرنل تابع پایه شعاعی گوسی و کرنل حلقوی شناخته می‌شوند.



شکل ۶: داده‌های دوبعدی که به صورت خطی تفکیک پذیر نیستند؛ به کمک جداساز غیرخطی، جدا می‌شوند [۲۲].

در یک حقیقت خارجی نهفته است؛ حال آن که مفهوم خوشه در نهان فواصل میان رکوردها نهفته است [۲۰].

الگوریتم k-means که یک الگوریتم خوشه‌بندی مبتنی بر فاصله است شامل مراحل چهارگانه زیر است [۲۲]:

۱- در مرحله اول، ابتدا k نقطه به صورت تصادفی، به عنوان نقاط مراکز خوشه‌ها انتخاب می‌شوند.

۲- در مرحله دوم، هر نمونه داده به خوشه‌ای که مرکز آن خوشه، کمترین فاصله تا آن داده را داراست؛ نسبت داده می‌شود.

۳- در مرحله سوم، پس از تعلق تمام داده‌ها به یکی از خوشه‌ها، برای هر خوشه یک نقطه جدید به عنوان مرکز محاسبه می‌شود (میانگین نقاط هر خوشه).

۴- در مرحله چهارم، مراحل ۲ و ۳ آن قدر تکرار می‌شوند که دیگر هیچ تغییری در مراکز خوشه‌ها ایجاد نشود.

تابع هدف (x_i, x_j) داده‌ها و k_j مراکز خوشه‌ها

$$J = \sum_{j=1}^k \sum_{i=1}^n \|x_i^{(j)} - k_j\|^2 \quad (1)$$

۳-۲- تحلیل مؤلفه‌های اصلی (PCA)

تحلیل مؤلفه‌های اصلی (PCA)، یک فن تحلیل چندمتغیره است که اولین بار به وسیله Pearson در سال ۱۹۰۱ معرفی شده و به طور مستقل در سال ۱۹۳۳ به وسیله Hotelling توسعه داده شده است. از نظر ریاضیاتی، PCA می‌تواند فضای اندازه‌گیری را به دو زیرفضای عمود، به نام‌های زیرفضای Principal Component (PC) و زیرفضای Residual تقسیم کند [۶].

مانیتورینگ فرآیند و تشخیص عیب، به وسیله آزمون‌های فرض آماری در دو زیرفضای ایجادشده با PCA انجام می‌شود. دو اندیس Hotelling-T² و Q-Statistics (SPE) برای توصیف رفتار فرآیندی و تشخیص عیب‌ها استفاده می‌شوند [۶].

۳-۳- ماشین بردار پشتیبان (SVM)

اولین مقاله علمی درباره الگوریتم ماشین بردار پشتیبان (SVM) در سال ۱۹۹۲ توسط ولادمیر وپنیک و همکاران او به رشته تحریر درآمد. الگوریتم‌های SVM به دلیل آن که قابلیت مدل‌سازی کران‌های پیچیده خطی را دارند، از صحت بسیار بالایی برخوردار هستند. در ضمن، نسبت به دیگر روش‌ها کمتر دچار مشکل بیش‌برازش داده‌ها می‌شوند. بردارهای پشتیبان، توصیف فشرده‌ای از مدل یادگیری‌شده را ارائه می‌دهند. از آن‌ها در حوزه‌های مختلف کاربردی استفاده می‌شود، مانند تشخیص اعداد دست‌نویس و شناسایی صدا [۲۲]. در حوزه مهندسی پزشکی، از روش ماشین بردار پشتیبان (SVM)، برای طبقه‌بندی داده‌ها استفاده شده است [۲۳].

۴- روش پیشنهادی

۴-۱- بیان کلی روش پیشنهادی

۴-۲- مرحله اول روش پیشنهادی، تعیین و ثبت سیگنال‌ها

نحوه ثبت سیگنال‌ها در سامانه مورد مطالعه اول به این صورت است که یک سامانه HMI با استفاده از کارت شبکه ARCNET و با کابل کواکسیال RG-62 به صورت موازی به پانل سامانه کنترل SPEEDTRONIC Mark V از سامانه مورد مطالعه متصل و با نوشتن و اجرای یک Bach file و استفاده از ابزارهای داده‌گیری (Data Logging) در Mark V عملیات ثبت داده از سیگنال‌های مختلف انجام شده است. در این عملیات ثبت داده، با استفاده از دانش تجربی و با دقت، ۲۹ سیگنال انتخاب شده است (جدول ۱).

نمونه‌برداری از سیگنال‌ها به صورت یک ثانیه و در مدت‌زمان کلی ۴۰۲۷ ثانیه انجام شده است. بنابراین، ماتریس داده اولیه ثبتی شامل ۲۹ ستون و ۴۰۲۷ سطر است که در مجموع ۱۱۶۷۸۳ داده را شامل می‌شود و این داده‌ها در شرایط بارگیری از ۱۶/۸ مگاوات تا بار کامل ۳۴/۴ مگاوات و سپس کاهش بارگیری تا ۱۶/۴ مگاوات ثبت شده‌اند.

جدول ۱: سیگنال‌های ثبت‌شده در سامانه مورد مطالعه اول

شماره	نام سیگنال	توصیف سیگنال	واحد
۱	V96FG3	فشار گاز تغذیه ورودی	Bar
۲	FPG2	فشار بین ولوهای GCV و SRV	Bar
۳	V96FG4	فشار گاز ورودی به محفظه احتراق	Bar
۴	CPD	فشار هوای خروجی کمپرسور	Bar
۵	CTD	دمای هوای خروجی کمپرسور	deg C
۶	TTXM	میانگین دمای ترموکوپل‌های اگزوز	deg C
۷	TTXSPL	پراکندگی مجاز دمایی در اگزوز	deg C
۸	TTXSP1	حداکثر پراکندگی دمایی در اگزوز	deg C
۹	DWATT	توان اکتیو ژنراتور (مگاوات)	MW
۱۰	DVAR	توان راکتیو ژنراتور (مگاوار)	MVAR
۱۱	TNH	درصد سرعت توربین	%
۱۲	TNR	مرجع تغییرات سرعت (بار)	%
۱۳	FSRT	خروجی حلقه کنترل دما	%
۱۴	FSRN	خروجی حلقه کنترل سرعت	%
۱۵	CSRGVOUT	فرمان میزان باز شدن IGV	DGA
۱۶	CSGV	فیدبک میزان باز بودن IGV	DGA
۱۷	FSG	فیدبک میزان باز بودن ولو GCV	%
۱۸	FSR	فرمان میزان باز شدن GCV	%
۱۹	FPRGOUT	فرمان میزان باز بودن SRV	Bar
۲۰	BB_MAX	ماکزیمم لرزش بدنه توربین	mm/s
۲۱	TTWS1FI1	دمای wheel space مرحله ۱	deg C
۲۲	TTWS2AO1	دمای wheel space مرحله ۲	deg C
۲۳	TTWS3AO1	دمای wheel space مرحله ۳	deg C
۲۴	BB1X	لرزش شعاعی X در یاتاقان اول	mm
۲۵	BB1Y	لرزش شعاعی Y در یاتاقان اول	mm
۲۶	BB3X	لرزش شعاعی X در یاتاقان دوم	mm
۲۷	BB3Y	لرزش شعاعی Y در یاتاقان دوم	mm
۲۸	V96VC11	لرزش محوری شماره یک	mm
۲۹	V96VC12	لرزش محوری شماره دو	mm



شکل ۷: شماتیک روش پیشنهادی تشخیص و جداسازی عیب.

در این مقاله، روشی ترکیبی برای کاهش بعد داده‌ها، تشخیص، شناسایی و جداسازی عیب پیشنهاد شده است که این روش ترکیبی، از الگوریتم‌های k-means برای کاهش بعد، فن PCA برای تشخیص و شناسایی عیب و الگوریتم ماشین بردار پشتیبان برای جداسازی عیب استفاده می‌کند. شکل ۷، شماتیک روش ترکیبی پیشنهادی را به طور واضح نشان می‌دهد.

روش پیشنهادی شامل چهار مرحله کلی است که در مرحله اول، دو توربین گاز با دو کاربرد مختلف در نظر گرفته شده و سیگنال‌های مهم، تعیین و ثبت شده‌اند. در مرحله دوم، از k-means برای کاهش بعد استفاده شده است و مقدار ثابت k برای خوشه‌بندی و کاهش بعد را می‌توان بر اساس دانش تجربی و یا به صورت دلخواه تعیین نمود. مرحله سوم روش پیشنهادی، تشخیص و شناسایی عیب را بر اساس تحلیل مؤلفه‌های اصلی (PCA) انجام می‌دهد. در صورت تشخیص وقوع عیب در مرحله سوم (با توجه به نمونه‌های وارد شده به الگوریتم پیشنهادی)، مرحله چهارم وارد عمل شده و کلاس عیب پیش‌آمده را تعیین خواهد کرد. خاطرنشان می‌شود که مرحله کاهش بعد داده‌ها با k-means، تشخیص و شناسایی عیب با استفاده از تحلیل مؤلفه‌های اصلی (PCA) و تعیین کلاس‌های عیب با استفاده از ماشین بردار پشتیبان (SVM)، همگی در یک الگوریتم یکپارچه در روش پیشنهادی انجام می‌شود.

جدول ۲: سیگنال‌های ثبت‌شده در سامانه مورد مطالعه دوم

شماره	نام سیگنال	توصیف سیگنال	واحد
۱	TNH	سرعت شفت HP	%
۲	TNL	سرعت شفت LP	%
۳	TTWS1FI1	دمای wheel space ورودی مرحله ۱	deg C
۴	TTWS1AO1	دمای wheel space خروجی مرحله ۱	deg C
۵	TTWS2FO1	دمای wheel space ورودی مرحله ۲	deg C
۶	TTWS2AO1	دمای wheel space خروجی مرحله ۲	deg C
۷	TTXM	میانگین دمای ترموکوپل‌های اگزوز	deg C
۸	TTXSPL	پراکندگی مجاز دمایی در اگزوز	deg C
۹	TTXSP1	حداکثر پراکندگی دمایی در اگزوز	deg C
۱۰	CTD	دمای هوای خروجی کمپرسور	deg C
۱۱	BTT1AA	دمای یاتاقان با بار یکم	deg C
۱۲	BTT1IA	دمای یاتاقان بی‌بار یکم	deg C
۱۳	BTJ1A	دمای یاتاقان ژورنال یکم	deg C
۱۴	BTT2IA	دمای یاتاقان بی‌بار دوم	deg C
۱۵	BTT2AA	دمای یاتاقان با بار دوم	deg C
۱۶	BTJ3A	دمای یاتاقان ژورنال سوم	deg C
۱۷	BTJ4A	دمای یاتاقان ژورنال چهارم	deg C

این امکان وجود داشت که نمونه‌برداری از سیگنال‌ها تا ۳۲ میلی‌ثانیه کاهش داده شود که در این صورت حجم داده‌ها به شدت افزایش می‌یافت. اما به منظور پوشش شرایط بارگیری و کاهش بار، پیروی نمونه‌برداری سیگنال‌ها، یک ثانیه در نظر گرفته شده است. شکل ۸، تصویر ثبت داده در سامانه مورد مطالعه اول را نشان می‌دهد.

نحوه ثبت سیگنال‌ها در سامانه مورد مطالعه دوم به این صورت است که در سامانه HMI با توجه به سازگاری نرم‌افزار مانیتورینگ Cimplicity با پایگاه داده SQL server، نسخه‌ای از SQL به موازات Cimplicity نصب و به آن لینک شده و سامانه HMI با استفاده از کارت شبکه ARCNET و با کابل کواکسیال RG-62 به صورت موازی به پانل سامانه کنترل SPEEDTRONIC Mark V از سامانه مورد مطالعه متصل و عملیات ثبت داده از سیگنال‌های مختلف انجام شده است. در این عملیات داده‌گیری، با استفاده از دانش تجربی و با دقت، ۱۷ سیگنال از شرایط دمایی توربین گاز مدل MS5002C از شرکت Nuovo Pignone انتخاب شده است (جدول ۲). شکل ۹، تصویر سیستم HMI توربین گاز با استفاده از Cimplicity را نشان می‌دهد که به پایگاه داده SQL متصل است.



شکل ۹: مانیتورینگ توربین گاز با استفاده از Cimplicity که به صورت برخط به پایگاه داده SQL متصل است.



شکل ۸: تصویر واقعی از ثبت داده در سامانه مورد مطالعه اول.

```
%Set timeout
logintimeout(5)
```

```
%Set preferences with setdbprefs.
setdbprefs('DataReturnFormat', 'numeric');
setdbprefs('NullNumberRead', 'NaN');
setdbprefs('NullStringRead', 'null');
```

```
%Make connection to database. Note that the password has
been omitted.
```

```
%Using ODBC driver.
conn = database('CimplicityLogDS', 'CimLogin', '*****');
```

```
%Read data from database.
```

```
curs = exec(conn, ['SELECT
FDSIGNALS.T1_V96VC12_VAL0'...
', FDSIGNALS.T1_V96VC11_VAL0'...
', FDSIGNALS.T1_BB3Y_VAL0'...
', FDSIGNALS.T1_BB3X_VAL0'...
', FDSIGNALS.T1_BB1Y_VAL0'...
', FDSIGNALS.T1_BB1X_VAL0'...
', FDSIGNALS.T1_TTWS3AO1_VAL0'...
', FDSIGNALS.T1_TTWS2AO1_VAL0'...
', FDSIGNALS.T1_TTWS1FI1_VAL0'...
', FDSIGNALS.T1_BB_MAX_VAL0'...
', FDSIGNALS.T1_FPRGOUT_VAL0'...
', FDSIGNALS.T1_FSR_VAL0'...
', FDSIGNALS.T1_FSG_VAL0'...
', FDSIGNALS.T1_CSGV_VAL0'...
', FDSIGNALS.T1_CSRGVOUT_VAL0'...
', FDSIGNALS.T1_FSRN_VAL0'...
', FDSIGNALS.T1_FSRT_VAL0'...
', FDSIGNALS.T1_TNR_VAL0'...
', FDSIGNALS.T1 TNH_VAL0'...
', FDSIGNALS.T1_DVAR_VAL0'...
', FDSIGNALS.T1_DWATT_VAL0'...
', FDSIGNALS.T1_TTXSP1_VAL0'...
', FDSIGNALS.T1_TTXSP1_VAL0'...
', FDSIGNALS.T1_TTXM_VAL0'...
', FDSIGNALS.T1_CTD_VAL0'...
', FDSIGNALS.T1_CPD_VAL0'...
', FDSIGNALS.T1_V96FG4_VAL0'...
', FDSIGNALS.T1_FPG2_VAL0'...
', FDSIGNALS.T1_V96FG3_VAL0'...
', FDSIGNALS.timestamp'...
FROM CimplicityLogDB.CimLogin.FDSIGNALS ']);
```

```
curs = fetch(curs);
close(curs);
```

```
%Assign data to output variable
datafromDB = curs.Data;
newSampelfromDB=datafromDB(end,:);
new29SampelfromDB=newSampelfromDB(1:29)
```


```
for ii=1:29
NEWs(1,1+ii)=new29SampelfromDB(1,30-ii);
end
NEWs=NEWs(2:30)
```

```
%Close database connection.
close(conn);
```

```
%Clear variables
clear curs conn
```


در سامانه مورد مطالعه دوم به منظور بررسی تخصصی تر مسئله تشخیص عیب، المان‌های دمایی مد نظر بوده است. در این حالت نیز سیگنال‌ها با پریود یک ثانیه ثبت شده و داده‌ها از شرایط راهاندازی نرمال و کامل توربین گاز از صفر تا صد درصد ثبت شده‌اند. مدت زمان داده‌گیری ۱۴۵۵ ثانیه بوده و بنابراین، ماتریس داده ثبتی دارای ۱۴۵۵ سطر و ۱۷ ستون و مجموع داده‌ها ۲۴۷۳۵ داده است. سیگنال‌های شماره ۱ و ۲ از جدول ۲ که به ترتیب درصد سرعت شفت HP و LP توربین گاز مورد نظر هستند؛ به منظور این که توربین گاز در چه مرحله‌ای از عملیات قرار دارد، در لیست داده‌برداری قرار داده شده‌اند. در مرحله نهایی، به منظور دریافت داده‌ها به صورت برخط از سامانه مورد مطالعه و انجام تحلیل تشخیص و شناسایی عیب توربین گاز، داده‌های سیگنال‌های تعیین شده با زمان یک ثانیه در پایگاه داده ذخیره می‌شوند و نرم‌افزار متلب با استفاده از Data source (که از طریق administrative tools در ویندوز و گزینه ODBC Data source تنظیم و تعریف می‌شود) به پایگاه داده متصل می‌شود و الگوریتم پیشنهادی به تشخیص و شناسایی عیب می‌پردازد. شکل ۱۰ شماتیک کامل از نحوه اتصال نرم‌افزار متلب به پایگاه داده را نشان می‌دهد. در این شکل، فلش‌های آبی‌رنگ، جریان داده سیگنال‌های مورد نظر را از توربین گاز تا ورود به نرم‌افزار متلب، جهت تشخیص و شناسایی عیب نشان می‌دهند.

در این قسمت، نمونه کد اتصال نرم‌افزار متلب به پایگاه داده و ورود نمونه‌های جدید از ۲۹ سیگنال انتخاب شده از سامانه مورد مطالعه به فضای متلب آورده شده است.



شکل ۱۰: شماتیک اتصال متلب به پایگاه داده و تحلیل برخط.

۴-۴- مرحله سوم روش پیشنهادی، پیاده‌سازی الگوریتم PCA به منظور تشخیص و شناسایی عیب



شکل ۱۲: شماتیک الگوریتم تحلیل مؤلفه‌های اصلی (PCA).

مرحله سوم روش پیشنهادی (پیاده‌سازی PCA)، همان‌طور که در شکل ۱۲ نشان داده شده؛ در ۱۰ مرحله انجام شده است. در صورت بروز عیب در نمونه‌های جدید، در مرحله هشتم PCA، وقوع عیب اعلام می‌شود و آلام فعال می‌گردد. با اعمال PCA نیز کاهش بعد انجام می‌شود و آن هم در جایی است که دانش نرمال بودن توربین از اطلاعات اولیه به‌شکل مقادیر ویژه و بردارهای ویژه ماتریس کوواریانس ظاهر می‌شوند. نمودار مشارکت متغیرها که در مرحله ۹ الگوریتم PCA به دست می‌آید؛ مشارکت متغیرها در وقوع عیب یا به عبارتی شناسایی عیب را انجام می‌دهد. نمودار مشارکت متغیرها با استفاده از نمونه‌های جدید و بردارهای ویژه و مقادیر ویژه داده‌های شرایط نرمال توربین ترسیم می‌شوند.


حداکثر زمانی را که به نرم‌افزار MATLAB اجازه داده می‌شود تا برای اتصال به پایگاه داده تلاش نماید؛ تنظیم و تعریف می‌شود که در اینجا ۵ ثانیه تعریف شده است در صورت متصل نشدن، عیب timeout اعلام می‌شود. به‌منظور تبدیل فرمت داده‌های برگشتی از رشته‌ای به عددی از دستور setdbprefs استفاده می‌شود. در قسمت بعدی برنامه با استفاده از تابع database، متغیر متلب conn تعریف می‌شود که اتصال به پایگاه داده مورد نظر را ارائه می‌دهد. برای اتصال به پایگاه داده، نام کاربری و رمز عبور مورد نیاز است تا کاربر مجاز بتواند به پایگاه داده متصل شود (در اینجا با استفاده از کاربر CimLogin و رمز عبور مورد نظر، و یک Data source به نام CimplicityLogDS به پایگاه داده CimplicityLogDB، اتصال برقرار می‌شود). در قسمت بعدی، تابع exec دستور SQL را اجرا می‌کند (FDSIGNALS جدول مربوط به ۲۹ سیگنال مورد نظر در پایگاه داده). جهت بستن اتصال از دستور close استفاده می‌شود.

۴-۳- مرحله دوم روش پیشنهادی، پیاده‌سازی الگوریتم k-means به منظور کاهش بعد داده

به‌صورت کلی در الگوریتم k-means، جواب نهایی به انتخاب مراکز اولیه خوشه‌ها وابستگی بسیاری دارد. اما در این مقاله، به‌دلیل فشردگی داده‌های اولیه مشکلی پیش نمی‌آید و می‌توان با انتخاب k مرکز اولیه به‌صورت تصادفی، الگوریتم را اعمال کرد.

در سامانه مورد مطالعه اول با حفظ اطلاعات و تغییرات، بعد داده‌های اولیه به نسبت قابل ملاحظه‌ای در حدود ۴۰ برابر کاهش یافته است (کاهش حجم داده‌ها از ۱۱۶۷۹۳ به ۲۹۰۰). در اینجا، k مساوی ۱۰۰ در نظر گرفته شده است. در شکل ۱۱، کاهش بعد داده‌های اولیه با اعمال الگوریتم خوشه‌بندی k-means در سامانه مورد مطالعه اول نشان داده شده است.

در مورد سامانه مورد مطالعه دوم، پس از اعمال الگوریتم k-means، حجم داده‌ها از ۲۴۷۳۵ به ۱۷۰۰ کاهش می‌یابد که این مسئله ۱۴/۵۵ برابر کاهش حجم داده را نشان می‌دهد ($k=100$).



شکل ۱۱: کاهش بعد با اعمال الگوریتم خوشه‌بندی k-means


جدول ۴: تعیین کلاس‌های عیب برای ۱۷ سیگنال سامانه دوم

ردیف	نام سیگنال	توصیف سیگنال	کلاس عیب
۱	TNH	سرعت شفت HP	Sensor Fault
۲	TNL	سرعت شفت LP	Sensor Fault
۳	TTWS1FI1	دمای wheel space ورودی مرحله ۱	Turbine Fault
۴	TTWS1AO1	دمای wheel space خروجی مرحله ۱	Turbine Fault
۵	TTWS2FO1	دمای wheel space ورودی مرحله ۲	Turbine Fault
۶	TTWS2AO1	دمای wheel space خروجی مرحله ۲	Turbine Fault
۷	TTXM	میانگین دمای ترموکوپل‌های اگزوز	Sensor Fault
۸	TTXSPL	پراکندگی مجاز دمایی در اگزوز	Controller Fault
۹	TTXSP1	بیشترین پراکندگی دمایی در اگزوز	Sensor Fault
۱۰	CTD	دمای هوای خروجی کمپرسور	Compressor Fault
۱۱	BTT1AA	دمای یاتاقان با بار یکم	Bearing Fault
۱۲	BTT1IA	دمای یاتاقان بی‌بار یکم	Bearing Fault
۱۳	BTJ1A	دمای یاتاقان ژورنال یکم	Bearing Fault
۱۴	BTT2IA	دمای یاتاقان بی‌بار دوم	Bearing Fault
۱۵	BTT2AA	دمای یاتاقان با بار دوم	Bearing Fault
۱۶	BTJ3A	دمای یاتاقان ژورنال سوم	Bearing Fault
۱۷	BTJ4A	دمای یاتاقان ژورنال چهارم	Bearing Fault

۵- پیاده‌سازی روش پیشنهادی روی توربین گاز واقعی

۵-۱- توربین گاز مدل MS6001 شرکت GE، واحد نیروگاه پالایشگاه دوم پارس جنوبی

داده‌های ۲۹ سیگنال مهم از شرایط نرمال توربین در قالب یک ماتریس ۴۰۲۷ در ۲۹ به روش پیشنهادی داده می‌شود. در مرحله اول با اعمال k-means، بعد ماتریس اولیه به ۱۰۰ در ۲۹ کاهش می‌یابد و سپس با اعمال PCA و محاسبه حد معیارهای T^2 -Hotelling و SPE، سه نمونه جدید از ۲۹ سیگنال (۳ در ۲۹) همراه با خطا در بعضی سیگنال‌ها، به PCA داده می‌شود (برای مثال، در اینجا خطا در ۴ سیگنال از ۲۹ سیگنال اعمال شده است؛ مطابق شکل ۱۳). با محاسبه مجدد معیارهای T^2 -Hotelling و SPE، وقوع عیب اعلام می‌شود و عیب، تشخیص داده می‌شود. در مرحله نهایی، SVM برای جداسازی وارد عمل می‌شود.




شکل ۱۳: هفت نمونه آخر سیگنال‌های ۱، ۲، ۳، ۴، ۱۰ و ۱۸.

۴-۵- مرحله چهارم روش پیشنهادی، تعیین کلاس عیب و برپایی SVM به منظور جداسازی عیب


پس از تشخیص و شناسایی عیب در مرحله قبل، در این مرحله که پله چهارم در روش پیشنهادی است؛ عیب‌های واقع شده بایستی جداسازی شوند که این امر با برپایی ماشین بردار پشتیبان انجام می‌گیرد. کلاس‌های عیب که در قسمت SVM برای جداسازی مورد نیاز است، بر اساس دانش تجربی تعریف می‌شوند. به عنوان مثال، با توجه به دانش تجربی معلوم می‌شود که در صورت بروز عیب در فشار گاز تغذیه ورودی (سیگنال ۱)، عیب در حسگر بوده است؛ زیرا این فشار قبل از ورود به توربین گاز، چندین بار اندازه‌گیری شده است. عیب در فشار و دمای خروجی کمپرسور هوا (سیگنال‌های ۴ و ۵) نشان‌دهنده وقوع عیب در کمپرسور است؛ زیرا که کمپرسور دچار مشکل شده و قادر به ایجاد دما و فشار نرمال نیست. بنابراین، می‌توان جدول ۳ را برای تعیین کلاس عیب در سامانه مورد مطالعه اول در نظر گرفت و در سامانه مورد مطالعه دوم نیز با توجه به دانش تجربی در مورد المان‌های دمایی، تعیین کلاس عیب انجام می‌شود و بنابراین، می‌توان جدول ۴ را برای تعیین کلاس عیب در سامانه مورد مطالعه دوم در نظر گرفت.

جدول ۳: تعیین کلاس‌های عیب برای ۲۹ سیگنال سامانه اول


ردیف	نام سیگنال	توصیف سیگنال	کلاس عیب
۱	V96FG3	فشار گاز تغذیه ورودی	Sensor Fault
۲	FPG2	فشار بین ولوهای GCV و SRV	Sensor Fault
۳	V96FG4	فشار گاز ورودی به محفظه احتراق	Sensor Fault
۴	CPD	فشار هوای خروجی کمپرسور	Compressor Fault
۵	CTD	دمای هوای خروجی کمپرسور	Compressor Fault
۶	TTXM	میانگین دمای ترموکوپل‌های اگزوز	Sensor Fault
۷	TTXSPL	پراکندگی مجاز دمایی در اگزوز	Controller Fault
۸	TTXSP1	بیشترین پراکندگی دمایی در اگزوز	Sensor Fault
۹	DWATT	توان اکتیو ژنراتور (مگاوات)	Sensor Fault
۱۰	DVAR	توان راکتیو ژنراتور (مگاوار)	Sensor Fault
۱۱	TNH	درصد سرعت توربین	Sensor Fault
۱۲	TNR	مرجع تغییرات سرعت (بار)	Controller Fault
۱۳	FSRT	خروجی حلقه کنترل دما	Controller Fault
۱۴	FSRN	خروجی حلقه کنترل سرعت	Controller Fault
۱۵	CSRGVOUT	فرمان میزان باز شدن IGV	Actuator Fault
۱۶	CSGV	فیدبک میزان باز بودن IGV	Actuator Fault
۱۷	FSG	فیدبک میزان باز بودن ولو GCV	Actuator Fault
۱۸	FSR	فرمان میزان باز شدن GCV	Actuator Fault
۱۹	FPRGOUT	فرمان میزان باز بودن SRV	Actuator Fault
۲۰	BB_MAX	ماکزیمم لرزش بدنه توربین	Turbine Fault
۲۱	TTWS1FI1	دمای wheel space مرحله ۱	Turbine Fault
۲۲	TTWS2AO1	دمای wheel space مرحله ۲	Turbine Fault
۲۳	TTWS3AO1	دمای wheel space مرحله ۳	Turbine Fault
۲۴	BB1X	لرزش شعاعی X در یاتاقان اول	Sensor Fault
۲۵	BB1Y	لرزش شعاعی Y در یاتاقان اول	Sensor Fault
۲۶	BB3X	لرزش شعاعی X در یاتاقان دوم	Sensor Fault
۲۷	BB3Y	لرزش شعاعی Y در یاتاقان دوم	Sensor Fault
۲۸	V96VC11	لرزش محوری شماره یک	Sensor Fault
۲۹	V96VC12	لرزش محوری شماره دو	Sensor Fault



شکل ۱۵-ب: خروجی SVM، تعیین کلاس عیب سیگنال ۴.



شکل ۱۵-ج: خروجی SVM، تعیین کلاس عیب سیگنال ۱۰.




شکل ۱۵-د: خروجی SVM، تعیین کلاس عیب سیگنال ۱۸.

خروجی قسمت SVM، کلاس عیب را برای سیگنال‌های ۳، ۴، ۱۰ و ۱۸ به ترتیب عیب حسگر، کمپرسور، حسگر، عملگر اعلام می‌کند (شکل‌های ۱۵-الف، ب، ج، د).


در شکل ۱۳ سیگنال‌های بدون خطای ۱ و ۲، جهت مقایسه همراه با سیگنال‌های خطادار ۳، ۴، ۱۰ و ۱۸ آورده شده است.

پاسخ سامانه تشخیص عیب پیشنهادی به سه نمونه جدید به این صورت است: وقوع عیب اعلام می‌شود؛ آلام فعال می‌شود؛ معلوم می‌شود که T^2 -Hotelling نمونه‌های ثانویه از حد مجاز فراتر رفته و در واقع عیب در نمونه‌های ثانویه است و سیگنال‌های خطادار، ۳، ۴، ۱۰ و ۱۸ می‌باشند.


T^2 -Hotelling برای نمونه‌های ثانویه ۱۹/۷۰۸۳ محاسبه شده که از حد مجاز T^2 -Lim یعنی از ۳/۹۳۷۱ فراتر رفته است، بنابراین تشخیص عیب اعلام شده است. شکل ۱۴، خروجی قسمت PCA است و نمودار مشارکت متغیرها را در وقوع عیب نشان می‌دهد. خطا در سیگنال‌های ۳، ۴، ۱۰ و ۱۸ اتفاقی افتاده است و در شکل‌های ۱۵-الف، ب، ج، د عیب‌ها به وسیله SVM جداسازی شده‌اند.




شکل ۱۴: خروجی PCA، نمودار مشارکت متغیرها در وقوع عیب.




شکل ۱۵-الف: خروجی SVM، تعیین کلاس عیب سیگنال ۳.



شکل ۱۷: خروجی PCA، نمودار مشارکت متغیرها در وقوع عیب.



شکل ۱۸-الف: خروجی SVM، تعیین کلاس عیب سیگنال ۵.




شکل ۱۸-ب: خروجی SVM، تعیین کلاس عیب سیگنال ۱۰.

۵-۲- توربین گاز مدل MS5002C شرکت Nuovo Pignone ایستگاه تقویت فشار پالایشگاه دوم پارس جنوبی

داده‌های ۱۷ سیگنال مهم از شرایط دمایی نرمال توربین مدل MS5002C از شرکت ایتالیایی Nuovo Pignone در واحد تقویت فشار و صادرات گاز پالایشگاه دوم پارس جنوبی، در قالب یک ماتریس 1455×17 ، به الگوریتم پیشنهادی داده می‌شود. در مرحله اول با اعمال k -means، بعد ماتریس اولیه به 100×17 کاهش می‌یابد و سپس با اعمال PCA و محاسبه حد معیارهای T^2 -Hotelling و SPE، سه نمونه جدید از ۱۷ سیگنال (۳ در ۱۷) همراه با خطا در بعضی سیگنال‌ها، به PCA اعمال می‌شود (برای مثال در اینجا خطا در ۵ سیگنال از ۱۷ سیگنال اعمال شده است؛ مطابق شکل ۱۶). با محاسبه مجدد معیارهای T^2 -Hotelling و SPE وقوع عیب اعلام می‌شود و عیب، تشخیص داده می‌شود. در مرحله نهایی، SVM برای جداسازی وارد عمل می‌گردد.

در شکل ۱۶ سیگنال بدون خطای ۳، جهت مقایسه همراه با سیگنال‌های خطادار ۵، ۱۰، ۱۱، ۱۴ و ۱۷ نشان داده شده است. پاسخ سامانه تشخیص عیب پیشنهادی به سه نمونه جدید به این صورت است: وقوع عیب اعلام می‌شود؛ آلام فعال می‌شود؛ معلوم می‌شود که T^2 -Hotelling نمونه‌های اولیه از حد مجاز فراتر رفته و در واقع، عیب در نمونه‌های اولیه است و سیگنال‌های خطادار ۵، ۱۰، ۱۱ و ۱۴ می‌باشند.

T^2 -Hotelling برای نمونه‌های اولیه $9/2852$ محاسبه شده که از حد مجاز T^2 -Lim یعنی از $3/9371$ فراتر رفته است، همچنین SPE برای نمونه‌های اولیه $109/6298$ به دست آمده که از حد مجاز SPElim یعنی از $7/0226$ عبور کرده است، بنابراین، تشخیص عیب اعلام شده است. شکل ۱۷، خروجی قسمت PCA است و نمودار مشارکت متغیرها را در وقوع عیب نشان می‌دهد. خطا در سیگنال‌های ۵، ۱۰، ۱۱ و ۱۴ و ۱۷ اتفاق افتاده است و در شکل‌های ۱۸-الف، ب، ج، د، ه عیب‌ها به وسیله SVM جداسازی شده‌اند.



شکل ۱۶: هفت نمونه آخر سیگنال‌های ۳، ۵، ۱۰، ۱۱، ۱۴ و ۱۷.

۶- نتیجه‌گیری


در این پژوهش، توربین‌های گازی مدل MS6001 شرکت GE و مدل MS5002C شرکت Nuovo Pignone مستقر در واحد نیروگاه و ایستگاه تقویت فشار و صادرات گاز پالایشگاه دوم پارس جنوبی مورد مطالعه قرار گرفت و با استفاده از دو سامانه HMI و کارت شبکه ARCNET برای توربین اول، تعداد ۲۹ سیگنال مهم توربین در مدت زمان ۴۰۲۷ ثانیه در شرایط عملیاتی بارگیری توربوتراتور و کاهش بار آن، داده‌برداری و ثبت شدند و برای توربین دوم، به دلیل بررسی تخصصی تر مسئله تشخیص عیب، تعداد ۱۷ سیگنال از شرایط دمایی توربین گاز MS5002C، ثبت شدند. سپس، به کمک الگوریتم k-means بعد ماتریس داده‌های ثبت شده ورودی در حالت اول از ۴۰۲۷ در ۲۹ به ۱۰۰ در ۲۹ و در حالت دوم از ۱۴۵۵ در ۱۷ به ۱۰۰ در ۱۷ کاهش یافت و سپس با اعمال الگوریتم PCA، اطلاعات نرمال بودن سیستم در شکل مقادیر ویژه و بردارهای ویژه ماتریس کوواریانس ظاهر شد و با گرفتن نمونه‌های جدید و محاسبه اندیس‌های Hotelling-T² و SPE و مقایسه آن با معیارهای T²-Lim و SPE-lim داده‌های نرمال، عیب، تشخیص داده شد و در نهایت با برپاسازی ماشین بردار پشتیبان، عیب‌های تشخیص داده شده، جداسازی و کلاس آن‌ها تعیین شد. نوآوری‌های این مقاله در پیاده‌سازی کاربردی روش، استفاده از دانش تجربی، انتخاب و ثبت سیگنال‌های مهم توربین گاز و پیاده‌سازی پایگاه داده، انجام جامع بحث تشخیص، شناسایی و جداسازی عیب توربین گاز، تشخیص خطای برخط و کار با مدل‌های واقعی توربین گاز و حتمی از داده‌ها در شرایط تست کامل توربین گاز است.

سپاس‌گزاری


نویسندگان این مقاله از همکاری مدیران محترم اداره ابزار دقیق، واحد نیروگاه و ایستگاه تقویت فشار و صادرات گاز پالایشگاه دوم شرکت مجتمع گاز پارس جنوبی (SPGC)، کمال سپاس‌گزاری را دارند که امکان پیاده‌سازی و اجرای کاربردی این پژوهش را فراهم نمودند.

مراجع


- [۱] ایمان یوسفی، طراحی سیستم تشخیص خطا مبتنی بر مدل برای زیرسیستم‌های نیروگاهی، پایان‌نامه کارشناسی ارشد، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران، ۱۳۹۰.
- [۲] محمدمهدی عرب حسینی، توسعه و شبیه‌سازی سیستم پایش عملکرد و تشخیص خطا در اجزای مختلف توربین گازی با کمک روش مبتنی بر شبکه‌های عصبی، پایان‌نامه کارشناسی ارشد، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران، ۱۳۹۱.
- [۳] حسین محمدی، شناسایی و تشخیص برخط خطا با استفاده از رهیافت شناسایی زیرفضاها در زیرسیستم نیروگاهی بویلر بازیاب حرارتی، پایان‌نامه کارشناسی ارشد، دانشگاه صنعتی خواجه‌نصیرالدین طوسی، تهران، ۱۳۹۱.



شکل ۱۸-ج: خروجی SVM، تعیین کلاس عیب سیگنال ۱۱.



شکل ۱۸-د: خروجی SVM، تعیین کلاس عیب سیگنال ۱۴.



شکل ۱۸-ه: خروجی SVM، تعیین کلاس عیب سیگنال ۱۷.

خروجی قسمت SVM، کلاس عیب را برای سیگنال‌های ۵، ۱۰، ۱۱، ۱۴ و ۱۷ به ترتیب عیب توربین، کمپرسور، یاتاقان، یاتاقان، یاتاقان اعلام می‌کند (شکل‌های ۱۸-الف، ب، ج، د، ه).

- Processes SAFEPROCESS*, vol. 48, Issue 21, pp. 1389–1396, Paris, 2015.
- [14] C. Hora Fontes and O. Pereira, "Pattern recognition in multivariate time series – A case study applied to fault detection in a gas turbine", *Engineering Applications of Artificial Intelligence*, vol. 49, pp. 10–18, 2016.
- [15] H. Alwi, C. Edwards and C. P. Tan, *Fault Detection and Fault-Tolerant Control Using Sliding Modes*, Springer, London, 2011.
- [16] R. Isermann, *Fault-Diagnosis Applications, Model-Based Condition Monitoring: Actuators, Drives, Machinery, Plants, Sensors, and Fault-tolerant*, Springer, Germany, 2011.
- [17] S. X. Ding, *Model-Based Fault Diagnosis, Techniques, Design Schemes, Algorithms and Tools*, Second Edition, Springer, Germany, 2013.
- [18] J. Korbicz, J. M. Koscielny, Z. Kowalczyk and W. Cholewa (Eds.), *Fault Diagnosis, Models, Artificial Intelligence, Applications*, Springer, Germany, 2004.
- [19] V. Venkatasubramanian, R. Rengaswamy, K. Yin, and S. N. Kavuri, "A review of process fault detection and diagnosis: Part I: Quantitative model-based methods," *Computers & Chemical Engineering*, vol. 27, no. 3, pp. 298–311, 2003.
- [۲۰] صنعی آباده، محمودی و طاهرپور، داده‌کاوی کاربردی، ویراست دوم، نیاز دانش، ۱۳۹۳.
- [۲۱] یوکاید صدری، علی آقاگل‌زاده و مهدی ازوجی، «ادغام تصاویر چندفوکوسه با استفاده از همدوسی فاز و خوشه‌بند K-means»، *مجله علمی پژوهشی مهندسی برق دانشگاه تبریز*، دوره ۴۵، شماره ۴، صفحه ۱۱۵–۱۲۵، ۱۳۹۴.
- [۲۲] ژیاوی هان، میشلین کمبر و ژان پی، داده‌کاوی - مفاهیم و تکنیک‌ها، ترجمه دکتر اسماعیلی، ویراست سوم، نیاز دانش، ۱۳۹۳.
- [۲۳] محمدرضا اکبرزاده توتونچی، سیدعابد حسینی و محمدباقر نقیبه‌سیستانی، «ارزیابی حالت توجه انتخابی دیداری به کمک تحلیل پتانسیل‌های وابسته به رویداد مغزی»، *مجله علمی پژوهشی مهندسی برق دانشگاه تبریز*، دوره ۴۶، شماره ۱، صفحه ۱۳–۲۴، ۱۳۹۵.
- [4] S. Borguet and O. Leonard, "Coupling principal component analysis and Kalman filtering algorithms for on-line aircraft engine diagnostics," *Control Engineering Practice*, vol. 17, pp. 494–502, 2009.
- [5] K. Y. Chen, L. S. Chen, M. C. Chen and C. L. Lee, "Using SVM based method for equipment fault detection in a thermal power plant," *Computers in Industry*, vol. 62, pp. 42–50, 2011.
- [6] A. Rincon, "Multiple fault detection and diagnosis in a gas turbine using principal component analysis and structured residuals," *20th Mediterranean Conference on Control and Automation*, pp. 91–97, Barcelona, Spain, 2012.
- [7] A. Ajami and M. Daneshvar, "Data driven approach for fault detection and diagnosis of turbine in thermal power plant using Independent Component Analysis (ICA)," *Electrical Power and Energy Systems*, vol. 43, pp. 728–735, 2012.
- [8] Y. Zhang, C. M. Bingham, Z. Yang, M. Gallimore and W. K. Ling, "Sensor fault detection for industrial gas turbine system by using principal component analysis based y-distance indexes," *Communication Systems, Networks & Digital Signal Processing (CSNDSP), 8th International Symposium*, pp. 1–6, Poznan, Poland, 2012.
- [9] J. Ma, Q. Wang and A. Dong, "PCA-SVM based fault prognosis for flue gas turbine," *Instrumentation, Measurement, Computer, Communication and Control (IMCCC), Second International Conference*, pp. 1304–1308, Harbin, China, 2012.
- [10] M. Berahman, A. A. Safavi and M. R. Shahrabaki, "Fault detection in Kerman combined cycle power plant boilers by means of support vector machine classifier algorithms and PCA," *Control, Instrumentation, and Automation (ICCIA), 3rd International Conference*, pp. 290–295, Tehran, Iran, 2013.
- [11] W. Hu, J. Liu, J. Cui, Y. Gao, B. Cui and L. Jiang, "Fault diagnosis of gas turbine based on support vector machine," *26th Chinese Control and Decision Conference (CCDC)*, pp. 2853–2856, Changsha, China, 2014.
- [12] Z. T. Wang, N. B. Zhao, W. Y. Wang, R. Tang and S. Y. Li, "A fault diagnosis approach for gas turbine exhaust gas temperature based on fuzzy C-means clustering and support vector machine," *Mathematical Problems in Engineering*, vol. 2015, Article ID 240267, 11 pages, 2015.
- [13] M. Navi, M. R. Davoodi and N. Meskin, "Sensor Fault Detection and Isolation of an Industrial Gas Turbine Using Partial Kernel PCA," *9th IFAC Symposium on Fault Detection, Supervision and Safety for Technical*

زیر نویس‌ها

¹¹ Fault Identification

¹² Fault Isolation

¹³ Process Recovery

¹⁴ Fault Detectability

¹⁵ Automatic concluding methods

¹⁶ Fault distinguishability

¹⁷ Model-based

¹⁸ Data driven-Process history based

¹⁹ Clustering

²⁰ Classification

¹ Abnormal Event Management (AEM)

² Operation

³ Triple Module Redundancy (TMR)

⁴ Unpermitted deviation

⁵ Acceptable, usual, standard condition

⁶ Frequently faults

⁷ Abruptly

⁸ Incipiently

⁹ Deterministic

¹⁰ Fault Detection